



TAILON MARTINS
ADRIANO M. SOUZA
FRANCISCA M SOUZA
CRISTIANO ZIEGLER
RENAN M. UEDA
BIANCA REICHERT

**EXPLORANDO RELAÇÕES
CAUSAIS DE CURTO E LONGO
PRAZO EM CONTEXTOS
PRÁTICOS:
UMA ANÁLISE APLICADA COM
MODELOS ARDL**

LABORATÓRIO DE ANÁLISE E MODELAGEM ESTATÍSTICA
LAME - UFSM



Conselho Editorial

Prof. Dr. Adilson Tadeu Basquerote Silva - UNIDAVI
Prof. Dr. Astor João Schönell Júnior - IFFAR
Prof. Dr. Alan Ricardo Costa - UFRR
Prof. Dr. Allan Diêgo Rodrigues Figueiredo – UESPI
Profa. Dra. Andréia Bulaty - UNESPAR
Profa. Dra. Carla da Conceição de Lima – UFVJM
Prof. Dr. Camilo Darsie de Souza - UNISC
Profa. Dra. Clarice Caldeira Leite - UFRGS
Profa. Dra. Cecilia Decarli - UFRGS
Prof. Dr. Carlos Adriano Martins - UNICID
Prof. Dr. Christian Dennys Monteiro de Oliveira - UFCE
Profa. Dra. Dayse Marinho Martins - UFMA
Prof. Dr. Deivid Alex dos Santos - UEL
Prof. Dr. Dioni Paulo Pastorio – UFRGS
Prof. Dr. Douglas Manoel Antonio de Abreu Pestana dos Santos – FASESP
Profa. Dra. Elane da Silva Barbosa - UERN
Profa. Dra. Elen Gomes Pereira - IFBA
Profa. Dra. Francielle Benini Agne Tybusch - UFN
Prof. Dr. Francisco Odécio Sales - IFCE
Prof. Dr. Francisco Ricardo Miranda Pinto - UFCAT
Prof. Dr. Gilvan Charles Cerqueira de Araújo – UCB
Prof. Dr. Ismar Inácio dos Santos Filho - UFAL
Prof. Dr. Leonardo Bigolin Jantsch - UFSM
Profa. Dra Liziany Müller Medeiros - UFSM
Profa. Dra Marcela Mary José da Silva - UFRB Prof. Dr. Mateus Henrique Köhler - UFSM
Prof. Dr. Michel Canuto de Sena - UFMS
Profa. Dra. Mônica Aparecida Bortolotti - UNICENTRO
Prof. Nilton David Vilchez Galarza - UPLA
Prof. Dr. Olavo Barreto de Souza - UEPB
Prof. Dr. Rafael Nogueira Furtado - UFABC
Prof. Dr. Roberto Araújo da Silva Vasques Rabelo - UNISANTOS
Prof. Dr. Rodrigo Toledo – USCS
Prof. Dr. Rodolfo Rodrigues de Souza - UERJ
Prof. Dr. Sidnei Renato Silveira - UFSM
Prof. Dr. Thiago Ribeiro Rafagnin - UFOB
Prof. Dr Tomás Raúl Gómez Hernández – UCLV

Editor Chefe: Ivanio Folmer

Diagramação: Raíssa da Silva Deodato

Imagem capa: www.canva.com

Correções: O/a(s) autor/a(es/as), organizador/a(es/as) e a editora

Dados Internacionais de Catalogação na Publicação (CIP)
(Câmara Brasileira do Livro, SP, Brasil)

Explorando relações causais de curto e longo prazo em con
textos práticos [livro eletrônico] : uma análise aplicada
com modelos ARDL / Tailon Martins...[et al.]. --
Santa Maria, RS : Arco Editores, 2025.
PDF

Outros autores: Adriano M. Souza, Francisca M Souza,
Cristiano Ziegler, Renan M. Ueda, Bianca Reichert.
Bibliografia.

ISBN 978-65-5417-533-3

1. Autorregressivos de Defasagens Distribuídas (ARDL)
2. Economia 3. Economia – Análise – Estudo e ensino 4.
Estatística matemática 5. Estatística – Métodos I. Martins,
Tailon. II. Souza, Adriano M. III. Souza, Francisca M. IV.
Ziegler, Cristiano. V. Ueda, Renan M. VI. Reichert, Bianca.

25-298357.0

CDD-330.01

Índices para catálogo sistemático:

1. Economia : Análise teórica 330.01

Aline Grazielle Benitez – Bibliotecária – CRB-1/3129



10.48209/978-65-5417-533-3

ISBN: 978-65-5417-533-3

Esta obra é de acesso aberto.

É permitida a reprodução parcial ou total desta obra, desde que citada a fonte e a autoria
e respeitando a Licença Creative Commons indicada



PREFÁCIO

¹Daniel Arruda Coronel

Os cursos de Graduação em Ciências Econômicas no Brasil têm adotado, cada vez mais, práticas de ensino consagradas nos grandes centros internacionais de Economia, como a Universidade de Harvard e o Instituto de Tecnologia de Massachusetts, entre outros. Essas práticas incluem o uso de ferramental quantitativo e analítico, com o objetivo de proporcionar análises mais robustas e parcimoniosas para os problemas econômicos e sociais. De acordo com Portugal (2000, p. 181), “os avanços na Matemática e na Econometria têm permitido um resgate dos problemas mais complicados que já estavam presentes na discussão econômica tradicional. Nesse sentido, o que está acontecendo é uma formalização de problemas complicados que não podiam ser tratados adequadamente no passado”.

É nesse contexto que se insere o livro *Explorando relações causais de curto e longo prazo em contextos práticos: uma análise aplicada com modelos ARDL*, de autoria dos pesquisadores e docentes Tailon Martins, Adriano M. Souza, Francisca M. Souza, Cristiano Ziegler, Renan M. Ueda e Bianca Reichert. Nessa obra, os leitores encontrarão um texto didático, consistente e tecnicamente fundamentado, que explora as potencialidades dos modelos econométricos Autoregressive Distributed Lag Models (ARDL) na investigação de relações dinâmicas entre variáveis econômicas, articulando rigor teórico e aplicação prática, de modo a evidenciar como esses modelos permitem captar simultaneamente os efeitos de curto prazo (choques conjunturais) e de longo prazo (relações estruturais de equilíbrio), superando limitações dos métodos convencionais de cointegração. A obra distingue-se pela clareza na exposição dos fundamentos conceituais, pela precisão nos procedimentos de estimação e seleção de modelos, bem como pelo arcabouço metodológico dos exemplos empíricos apresentados, constituindo-se em uma contribuição relevante para pesquisadores, profissionais e estudantes que buscam aprofundar sua compreensão sobre análise de séries temporais e sobre a aplicação de modelos ARDL como ferramenta de investigação de relações causais em economia e áreas correlatas.

¹Professor Associado do Departamento de Economia e Relações Internacionais, com atuação como Docente Permanente nos Programas de Pós-Graduação (*Stricto sensu*) em Gestão de Organizações Públicas e de Economia e Desenvolvimento, da Universidade Federal de Santa Maria (UFSM). Atualmente é bolsista de produtividade do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); líder do Grupo de Pesquisa Finanças Públicas, Economia Internacional e Desenvolvimento Econômico (UFSM); Consultor *ad hoc* da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES); do Instituto de Pesquisas Educacionais INEP/MEC e do CNPq e Editor Associado da Revista de Economia e Sociologia Rural. E-mail: daniel.coronel@uol.com.br

Ainda nessa perspectiva, os exemplos apresentados são aplicados a problemas econômicos, utilizando a Econometria de Séries Temporais. A obra mescla teoria e prática com exemplos didáticos e faz uso do *software* EViews, que se destaca como diferencial em relação a obras importantes utilizadas nos grandes centros acadêmicos do país, tais como: Hamilton (1994); Johnston e Dinardo (2001); Brandt e Williams (2007); Lütkepohl (2007); Greene (2008); Brooks (2008); Johansen (2014); e Enders (2015).

Neste livro, os autores apresentam, com acuidade, os principais procedimentos aplicados à análise de séries temporais no âmbito dos modelos ARDL, contemplando o uso do operador de defasagem, os processos de diferenciação, a verificação da estacionariedade por meio de testes de raiz unitária, a avaliação da ordem de integração das variáveis, bem como a análise de cointegração para identificar relações de equilíbrio de longo prazo. Além disso, discute-se a formulação do Modelo de Correção de Erros (ECM) associado ao ARDL, que permite integrar as dinâmicas de curto prazo aos ajustes em direção ao equilíbrio de longo prazo.

Para cada exemplo apresentado na obra, são realizados os respectivos testes, com a explicação das hipóteses nula e alternativa, além da notação matemática correspondente e dos *outputs* do *software* EViews. Isto contribui para que os pesquisadores e demais interessados possam aplicar o embasamento teórico e analítico proporcionado pelo livro.

Por fim, esta obra deve ser saudada pela academia com entusiasmo, pois representa mais uma importante contribuição deste grupo de pesquisadores, que tem realizado diversos trabalhos nacionais e internacionais utilizando séries temporais. A obra pode ser utilizada não apenas por pesquisadores das áreas sociais aplicadas, mas também das áreas de Matemática, Engenharias, Ciências Rurais e Saúde.

Tenho plena convicção de que o leitor terá à sua disposição um material moderno, eficiente e eficaz, além de uma leitura aprazível.

Desejo a todos uma boa leitura!

SUMÁRIO

1. INTRODUÇÃO	8
2. COINTEGRAÇÃO E MODELOS ARDL	10
2.1 <i>Procedimentos para seleção dos modelos</i>	12
3. APLICAÇÃO DOS MODELOS ARDL NO SOFTWARE EViews	17
3.1 <i>Base de Dados</i>	17
3.2 <i>Etapas metodológicas para ajuste dos modelos</i>	19
4. MODELAGEM E AJUSTE DOS MODELOS ARDL NO SOFTWARE EViews: PROCEDIMENTOS E RESULTADOS	22
4.1 <i>Organização dos Dados</i>	22
4.2 <i>Importando os dados do Microsoft Excel para o EViews</i>	23
4.3 <i>Verificação da Estacionariedade</i>	27
4.4 <i>Ajuste do modelo ARDL</i>	39
CONSIDERAÇÕES FINAIS	49
REFERÊNCIAS	51
ANEXO A – Dados originais utilizados no estudo prático da metodologia ARDL	55

1. INTRODUÇÃO

Em meio às discussões político-econômicas, os embates em torno da economia e seus diversos setores persistem, visando a preservação de um equilíbrio constante. Nos últimos anos, as flutuações macroeconômicas nesse contexto têm exercido influência significativa sobre a economia global, refletindo as interações transnacionais e suas consequências. (SARKER; TANG, 2009; WU *et al.*, 2020; KHAN, 2020).

Tornou-se indispensável compreender quais são as principais causas, consequências e quais mecanismos que afetam e são afetados pelos desequilíbrios econômicos. Para avaliar e se precaver, as análises econométricas têm sido empregadas amplamente no setor político-econômico, analisando variáveis por meio de métodos estatísticos e matemáticos (BAIG *et al.*, 2018; ODHIAMBO, 2009).

A pretensão de examinar dados econômicos, surge com o propósito de fornecer conteúdo para subsidiar teorias econômicas, traçando relações funcionais para a descrição dos fenômenos, a fim de planejá-los e os torna-los aplicáveis em pontos estratégicos (KHAN, 2020; WU *et al.*, 2020).

A econometria, em meio às suas diversas funcionalidades, utiliza a análise de regressão, ajustando funções matemáticas para descrever o comportamento de uma variável explicada (variável dependente) com base nos valores de uma ou mais variáveis explicativas (variáveis independentes) (BÖLÜK; MERT, 2015; GARZA-RODRIGUEZ *et al.*, 2020).

Amplamente utilizadas nas duas últimas décadas, em análises macroeconômicas, os modelos Autorregressivos e de Defasagens Distribuídas (ARDL) contribuíram significativamente em diversas áreas de desenvolvimento mundial. No entanto, a abordagem ganhou popularidade por meio das pesquisas de Pesaran e Shin (1999) e Pesaran, Shin e Smith (2001). O método proposto surgiu com a finalidade de ajustar modelos matemáticos baseados em Mínimos Quadrados Ordinários a fim de identificar as relações de curto e longo prazo entre variáveis, por meio da cointegração (BAIG *et al.*, 2018; ODHIAMBO, 2009; PESARAN *et al.*, 1999; PESARAN; SHIN; SMITH, 2001).

O processo de estimação abordado pelos autores é dividido em dois momentos. Primeiramente, é estimada uma equação de cointegração pelo método de Mínimos Quadrados Ordinários, a qual é utilizada para evidenciar a existência de relações de longo prazo, por meio da cointegração. Em segundo momento, se confirmada a hipótese de cointegração, estimam-se os coeficientes de longo e curto prazo, e a velocidade de ajuste para o equilíbrio de longo prazo

em meio a perturbações de curto prazo (BAIG *et al.*, 2018; ODHIAMBO, 2009; PESARAN *et al.*, 1999).

Para a identificação de cointegração, consequentemente pressupondo a existência de um relacionamento de longo prazo, Pesaran *et al.* (2001) desenvolveram o “*bound testing approach*”. O teste é fundamentado em valores críticos (F-statistic) fornecidos pelos autores (similar ao teste de *Wald*), tendo hipótese nula (H_0) de que não há nenhuma cointegração (HE, 2020; NARAYAN, 2004; ODHIAMBO, 2009).

Comparado à outros métodos convencionais para identificar a cointegração, os modelos ARDL apresentam algumas vantagens, como abranger séries de dados estacionárias $I(0)$, não estacionárias $I(1)$, ou com ambas ordens de integração; ser eficiente em capturar as relações de curto e longo prazo em amostras com poucas observações; e de capturar as relações de curto e longo prazo simultaneamente (AKRAM e LI, 2020; BÖLÜK e MERT, 2015; NAGAWA, *et al.* 2020).

Este livro tem como propósito apresentar um estudo de caso prático da aplicação dos modelos ARDL, utilizando variáveis nacionais que abrangem o crescimento econômico brasileiro. Serão exploradas as exportações *Free on Board* (FOB) com destino ao Oriente Médio e à Ásia-Pacífico. O termo “*Free on Board*” (FOB) refere-se a uma condição comercial na qual o vendedor é responsável pelos custos e riscos associados ao transporte dos bens até o momento em que são carregados no navio no porto de origem. O objetivo principal é examinar as relações causais de curto e longo prazo, bem como as elasticidades, nas interações das variáveis, a fim de avaliar o impacto que as exportações para esses destinos exercem sobre o Produto Interno Bruto (PIB) brasileiro. As variáveis e seus respectivos dados para estimação dos modelos ARDL foram coletados no site do Índice de Pesquisa Econômica Aplicada (IPEA) (<http://www.ipeadata.gov.br/Default.aspx>). Os dados são de periodicidade mensal, e a amostra compreende o período de janeiro de 2000 a junho de 2019.

A cointegração é um conceito fundamental em séries temporais econômicas, indicando a existência de relações de longo prazo entre variáveis que não são estacionárias individualmente. No próximo capítulo, exploraremos detalhadamente a teoria da cointegração e sua importância na modelagem econômica, preparando o terreno para a aplicação prática dos modelos ARDL. A cointegração desempenha um papel crucial na aplicação dos modelos ARDL, fornecendo uma estrutura sólida para analisar e interpretar as relações de longo prazo entre variáveis econômicas. Ao estabelecer a presença de relações de equilíbrio de longo prazo, a cointegração permite que os modelos ARDL capturem de forma mais precisa e robusta os

efeitos das variáveis independentes sobre a variável dependente ao longo do tempo. Portanto, compreender os fundamentos da cointegração é essencial para uma aplicação eficaz e interpretativa dos modelos ARDL na modelagem econômica.

2. COINTEGRAÇÃO E MODELOS ARDL

O método de cointegração foi desenvolvido por Granger (1981), tendo seu uso destinado às mais diversificadas áreas da macroeconomia, desempenhando uma conduta indispensável nas análises econométricas nos últimos anos. Sua aplicabilidade é adequada em inúmeras áreas, como mercado de ações, economia internacional, comércio exterior, planejamento econômico, economia doméstica, matemática financeira, entre outros (AKRAM e LI, 2020; BÖLÜK e MERT, 2015).

No entanto, a grande maioria das variáveis no contexto econômico exibe instabilidade ao longo do tempo, ou seja, não são estacionárias. Portanto, para realizar análises econométricas, é necessário estabilizá-las, transformando-as em séries estacionárias (XIONG e XU, 2021). Isso permite uma interpretação mais precisa e confiável dos resultados obtidos. O processo de estabilização de uma série temporal pelo método de diferenciação, faz com que ocorra a perda de informação sobre os movimentos de longo prazo. Diante disto, Engle e Granger (1987) encontraram uma alternativa para esta situação, por meio do método de cointegração. O método considera que se Y_t e X_t compartilham tendências estocásticas semelhantes e sua diferença μ_t será estacionária. Possivelmente, Y_t e X_t irão movimentar-se conjuntamente no longo prazo (BILDIRICI; GÖKMENOĞLU, 2017; FACHINELLI, 2014; WU *et al.*, 2020).

Diante das considerações observadas por Engle e Granger (1987), a base teórica iniciada por Granger (1981), foi estruturada por meio da manifestação de testes e técnicas em séries temporais não estacionárias e cointegradas. Nesta estruturação, o método tornou-se aplicável em variáveis não-estacionárias, sob condição de que sejam cointegradas. A cointegração pressupõem a existência de um inter-relacionamento de longo prazo entre as variáveis observadas, por meio de relações lineares evidenciadas ao longo do tempo (FACHINELLI, 2014; WU *et al.*, 2020).

O método de Engle e Granger (1987) foi amplamente difundido em análises econométricas, por outro lado, questionamentos surgiram quanto a sua eficácia, o que

oportunizou o desenvolvimento de novos estudos sobre o método de cointegração (BÖLÜK e MERT, 2015).

Em meio aos estudos encontrados na literatura, o método elaborado por Johansen (1991) tem sido vastamente utilizado e de grande relevância para analisar relações de longo prazo em um modelo de regressão. A metodologia proposta por Johansen sustenta uma abordagem baseada em estimadores de máxima verossimilhança, permitindo que sejam testadas versões restritas de vetores de cointegração e a velocidade de ajustamento dos parâmetros, baseando na relação entre as raízes características de uma matriz. O método determina o número de vetores de cointegração de um Vetor Autorregressivo (VAR) de séries temporais não estacionárias com restrições, conhecidas como Modelo de Correção de Erro (MCE) (HE, 2020; JOHANSEN, 1988).

Ainda que as abordagens anteriores tenham sido satisfatórias quanto à aplicabilidade, tanto a de Engle e Granger (1987) como a de Johansen (1991), ambos apresentavam limitações quanto à ordem de integração, pois exigiam que todas as variáveis impostas no modelo apresentassem a mesma ordem de integração, impondo que todas fossem integradas de ordem 1 - I(1) (AKRAM e LI, 2020; PESARAN *et al.*, 2001).

Pesaran e Shin (1999) e Pesaran, Shin e Smith (2001) manifestaram uma nova proposta sobre o método de cointegração, tratando-se de uma metodologia econométrica empírica em que utiliza modelos Autorregressivos e de Defasagens Distribuídas (ARDL) para evidenciar relações de curto e longo prazo simultaneamente, com o auxílio de um Modelo de Correção de Erros (MCE) para obter a velocidade de ajuste para o equilíbrio de longo prazo (ODHIAMBO, 2009; PESARAN *et al.*, 1999; PESARAN *et al.*, 2001).

De forma alternativa aos métodos de Engle e Granger (1987) e de Johansen (1991), Pesaran, Schin e Smith (2001) propuseram uma metodologia que permite abranger variáveis com ordem de integração que diferem entre si, sendo também eficiente para as situações em que todas as variáveis apresentem a mesma ordem de integração. Em síntese, o novo método proposto para cointegração pode empregar um conjunto de variáveis puramente I(0), puramente I(1), ou com as duas ordens de integração, desde que não sejam I(2) (BÖLÜK; MERT, 2015; ODHIAMBO, 2009; PESARAN *et al.*, 1999).

É assegurado por Pesaran *et al.* (2001) que o teste de cointegração proposto nos modelos ARDL apreende as relações dinâmicas de curto e longo prazo em variáveis com número pequeno de observações de modo mais eficiente e, por meio de um critério de seleção

previamente estabelecido, um nível ótimo de defasagens pode ser determinado para cada uma das variáveis do modelo ARDL (TANG, 2009).

A condução da estimação dos modelos ARDL ocorre por meio de um procedimento conduzido em dois momentos. Em primeiro, verifica-se a presença de cointegração nas variáveis, o qual é estimado por meio de uma equação de cointegração pelo Método de Mínimos Quadrados Ordinários (ODHIAMBO, 2009; PESARAN *et al.*, 1999; TANG, 2009).

No teste de cointegração, utiliza-se um teste similar ao de Wald (teste F), o *Bound test*”, também conhecido como teste de limites ou teste de fronteiras. Pesaran *et al.* (2001), fornecem valores críticos para limite superior $I(1)$ e inferior $I(0)$, tendo hipótese nula de que não há nenhuma cointegração (CHAND; AFTAB, 2018; SARKER; KHAN, 2020).

Após a confirmação da cointegração, o segundo momento consiste em estimar os coeficientes de longo e curto prazo da equação, com base em critérios de informação, como por exemplo Schwartz (BIC) ou Akaike (AIC) (AKAIKE, 1974; ODHIAMBO, 2009; TANG, 2009).

2.1 Procedimentos para seleção dos modelos

O primeiro estágio na condução do procedimento ARDL consiste em verificar se as variáveis são cointegradas, sendo necessário que seja estimada uma equação via Mínimos Quadrados Ordinários, para que em seguida, seja procedido o *bound test* para detecção de cointegração. O emprego do modelo ARDL requer a especificação *a priori* do número de defasagens de cada umas das variáveis X e Y . São raras as situações em que a teoria especifica os valores exatos das defasagens, o que torna necessário determiná-las empiricamente (AHMAD *et al.*, 2020; SIKDER *et al.*, 2022; BULUS e KOC, 2021).

Pelo princípio da parcimônia, é utilizado o critério de informação para definição do número apropriado de defasagens (*lags*) no modelo, selecionando aquele que apresentar o menor número de parâmetros, estando de acordo com sua significância (NKORO *et al.*, 2016; MARTINS, *et al.*, 2021).

Para uma análise precisa, é recomendável iniciar considerando um número específico de defasagens, variando conforme a frequência dos dados. Para conjuntos de dados mensais, sugere-se iniciar com até 6 defasagens, enquanto para dados anuais, até 5 defasagens podem ser consideradas inicialmente. Posteriormente, procede-se à avaliação da significância estatística do coeficiente associado à maior defasagem. Se este coeficiente for estatisticamente significativo, é retido no modelo; caso contrário, ajusta-se o modelo excluindo essa defasagem.

Esse processo é iterativo, continuando até que todos os coeficientes associados às defasagens sejam estatisticamente significativos. Esse método, conhecido como "seleção de defasagens", permite capturar efetivamente as dinâmicas temporais das variáveis econômicas, adaptando-se à frequência dos dados disponíveis (NKORO *et al.*, 2016; RAHMAN *et al.*, 2020).

Os critérios de informação adotados têm a finalidade de mensurar a quantidade de informação sobre a variável dependente contida no conjunto de variáveis independentes, considerando o erro padrão das estimativas dos coeficientes e penalizando pelo número de parâmetros do modelo. Dentre os critérios de informação, os mais utilizados são o critério de informação de Akaike (AIC) (AKAIKE, 1973) (Equação 1) e o critério de informação bayesiano (BIC) (SCHWARZ, 1978) (Equação 2), em que se determina o número de defasagens com base no modelo que retoma os menores valores para os critérios de informação (MENEGAKI, 2019; MARTINS *et al.*, 2021).

$$AIC_{(p,q)} = \ln \sigma_{p,q}^2 + \frac{2(p+q)}{n} \quad (1)$$

$$BIC_{(p,q)} = \ln \sigma_{(p,q)}^2 + (k+l) \frac{\ln(n)}{n} \quad (2)$$

Nos critérios de informação, o critério de informação de Akaike é representado pela Equação 1, onde os valores de p e q representam o número de defasagens da variável dependente e das variáveis independentes, respectivamente. Esses valores são utilizados para penalizar modelos com muitos parâmetros, visando encontrar um modelo mais parcimonioso. Por sua vez, o critério de informação bayesiano é definido pela Equação 2, onde σ^2 representa a variância do erro, k e l representam o número de parâmetros do modelo e n é o tamanho da amostra.

Ambos os critérios de informação são empregados na escolha do número apropriado de defasagens, visando minimizar os valores resultantes. Os valores de p e q , nas Equações 1 e 2, são usados para penalizar modelos com muitos parâmetros, com o objetivo de encontrar um modelo mais parcimonioso. Esses procedimentos são aplicados tanto na escolha de p defasagens da variável dependente quanto de q defasagens das variáveis independentes (MENEGAKI, 2019; SIKDER *et al.*, 2022). A equação geral do modelo com p defasagens para Y e q defasagens para X , proposto pelo modelo ARDL (p, q), é dado pela Equação 3.

$$\phi(L)Y_t = \alpha + \theta(L)X_t + \varepsilon_t \quad (3)$$

Em que $\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p$, cujas raízes não pertencem ao círculo unitário, o que significa dizer que Y é estacionário, $\theta(L) = \theta_0 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q$ e L é um operador de defasagem tal que $L^k Y_t = Y_{t-k}$ (MARTINS *et al.*, 2021). O modelo pode ser reescrito como (Equação 4):

$$Y_t = \alpha + \alpha_1 t + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \theta_0 X_{t-p} + \theta_1 X_{t-1} + \varepsilon_t \quad (4)$$

Na Equação 4, os coeficientes têm os seguintes significados: α representa o *intercepto* do modelo, ou seja, o valor esperado de Y quando todas as variáveis independentes são iguais a zero; $\alpha_1 t$ representa o termo de tendência temporal, indicando a mudança linear esperada em Y ao longo do tempo; $\phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p}$ são os coeficientes das defasagens da variável dependente Y , representando o efeito das suas próprias defasagens no valor atual de Y . Cada ϕ_p (onde i varia de 1 a p) indica o impacto de Y_{t-i} no valor de Y_t , com ϕ_1 representando o efeito da primeira defasagem, ϕ_2 o efeito da segunda defasagem, e assim por diante; $\theta_0 X_{t-p} + \theta_1 X_{t-1}$ são os coeficientes das defasagens da variável independente X , indicando o efeito das suas defasagens no valor atual de Y . θ_0 representa o efeito da defasagem mais antiga de X , enquanto θ_1 representa o efeito da defasagem mais recente de X ; ε_t representa o termo de erro, que captura a parte não explicada do modelo e é assumido como homoscedástico (variância constante), não-autocorrelacionado e distribuído normalmente.

Após estimada a equação ARDL é necessário examinar se há a existência de relação de longo prazo dada pela cointegração. Conforme mencionado anteriormente, o *bound test* será utilizado para avaliar os valores críticos de todos os regressores $I(0)$, $I(1)$ ou mutuamente cointegrados (AHMAD *et al.*, 2020; BULUS e KOC, 2021). Nesse teste, a hipótese nula de que não há nenhuma cointegração, pode ser visualizada conforme a Equação 5:

$$H_0 = \phi_1 = \phi_2 = \phi_3 = \dots = \phi_p = 0 \quad (5)$$

A hipótese nula, representada pela Equação 5, afirma que não há presença de cointegração entre as variáveis em análise. Isso é expresso pela igualdade de todos os

coeficientes de defasagem da variável dependente Y (ϕ_1 a ϕ_p) a zero. Se todos esses coeficientes forem insignificantes, isso sugere que as variáveis não estão relacionadas de forma estável a longo prazo, ou seja, não há uma relação de equilíbrio de longo prazo entre elas. Assim, a hipótese nula sugere a ausência de uma relação duradoura entre as variáveis, indicando que não compartilham uma tendência comum ao longo do tempo. Se a estatística $F_{calculada}$ estiver acima do limite superior $I(1)$ do *bound test*, a cointegração é confirmada, rejeitando-se a hipótese nula; se essa estatística encontrar-se abaixo do limite inferior $I(0)$, a hipótese nula não pode ser rejeitada, o que indica a ausência de cointegração; e o resultado da estatística F pode ser inconclusivo quando estiver entre os limites inferior e superior do teste de *bounds* (HE *et al.*, 2019; ODHIAMBO, 2009; TANG, 2009).

Caso as estatísticas do *bound test* estiverem entre os valores críticos calculados por Pesaran *et al.* (2001), ou seja, na região dita inconclusiva, será necessário conhecer a ordem de integração de cada uma das variáveis. Vale salientar que o *bound test* permite trabalhar com séries $I(0)$ e $I(1)$, ou com ambas ordens de integração, desde que não sejam $I(2)$ AHMAD *et al.*, 2020; SIKDER *et al.*, 2022; BULUS e KOC, 2021).

Em alguns casos, dependendo das variáveis utilizadas, torna-se necessário efetuar os testes de estacionariedade antes mesmo de serem gerados os modelos, como garantia de que nenhuma série seja $I(2)$ e possa prejudicar os resultados obtidos nas análises (MARTINS *et al.*, 2021).

Para determinar a ordem de integração das variáveis, é essencial submetê-las a testes de raízes unitárias. Os testes de estacionariedade mais utilizados em análises relacionadas aos modelos ARDL são: *Augmented Dickey-Fuller* (ADF) (Dickey & Fuller, 1979), Phillips-Perron (PP) (Phillips & Perron, 1988) e o Kwiatkowski, Phillips, Schmidt and Shin (KPSS) (Kwiatkowski *et al.*, 1992) (MARTINS *et al.*, 2021).

Os testes ADF e PP utilizam a estatística τ e apresentam hipótese nula (H_0) de que a série de dados apresenta raízes unitárias (sendo não estacionária), enquanto o teste KPSS utiliza a estatística LM e possui hipótese nula (H_0) de que a série de dados é estacionária. Os testes são avaliados a nível de 1%, 5% ou 10%, estando a critério do pesquisador. Quando pelo menos 2 desses testes apontarem o mesmo resultado, este será utilizado para as análises (AHMAD *et al.*, 2020; SIKDER *et al.*, 2022; BULUS e KOC, 2021).

A confirmação da hipótese de cointegração permite estimar os coeficientes da relação de longo prazo. Embora seja identificada a relação de longo prazo nas estimações, não significa que os modelos estimados estejam livres de serem acometidos por choques de curto prazo. Para

que a relação de cointegração seja sempre mantida, há que se ter um mecanismo de correção destes choques para se retornar a dinâmica de longo prazo, o qual é realizado com um Modelo de Correção de Erros – *Error Correction Model* (ECM) (BÖLÜK; MERT, 2015; PESARAN *et al.*, 2001).

O ECM tem a finalidade de identificar a dinâmica de curto prazo entre as variáveis consistente em um equilíbrio de longo prazo. Esta relação de longo prazo entre as variáveis corresponderá uma representação em termos de um ECM (Equação 6), o qual evidencia o comportamento padronizado das variáveis cointegradas no tempo, em eventuais choques que a desloquem da trajetória de equilíbrio de longo prazo (BÖLÜK; MERT, 2015; HE, 2020).

$$Y = \alpha_0 + \alpha_1 t + \sum_{i=0}^l \varphi_{1i} \Delta Y_{t-i} + \sum_{i=0}^l \varphi_{2i} \Delta X_{t-i} + \sum_{i=0}^l \beta_{1i} Y_{t-i} + \sum_{i=0}^l \beta_{2i} X_{t-i} + \delta ECM_{t-1} + \varepsilon_t \quad (6)$$

Todos os coeficientes da equação são relacionados às dinâmicas de curto prazo de convergência para o equilíbrio; ECM_{t-1} é a série defasada dos resíduos da estimação MQO do modelo ARDL, associado ao modelo ECM; δ é a velocidade de ajuste ao equilíbrio de longo prazo após um choque de curto prazo (BÖLÜK e MERT, 2015; KHAN, 2020).

O resultado negativo do ECM reflete a velocidade moderada de ajuste de desequilíbrio de curto prazo para o estado de equilíbrio de longo prazo, que reafirma os resultados de cointegração. O modelo ECM é derivado do modelo ARDL por uma transformação linear simples, que integra ajustes de curto prazo com equilíbrio de longo prazo, sem perda de informações de longo prazo (BÖLÜK e MERT, 2015; TANG, 2009).

Os coeficientes de curto prazo são representados pelas variáveis $I(1)$, isto é, são as variáveis que sofreram transformação (representadas pelo Δ) e, portanto, perderam as suas propriedades de longo prazo. Os coeficientes de longo prazo são representados pelas variáveis em nível, pois preservam as suas características de longo prazo, e a velocidade que o sistema assume para chegar ao equilíbrio de longo prazo é determinada pelo coeficiente (δ) do Modelo de Correção de Erros (AHMAD *et al.*, 2020; SIKDER *et al.*, 2022; BULUS e KOC, 2021).

Os modelos ajustados poderão ser analisados conforme os resíduos gerados, utilizando testes de diagnóstico: como o teste de normalidade de Jarque-Bera, teste de autocorrelação serial Breush-Godfrey (LM *test*) e teste de Breusch-Pagan-Godfrey para heteroscedasticidade (AKRAM e LI, 2020; BAIG *et al.*, 2018; WU *et al.*, 2020).

O teste de Jarque-Bera, tem como hipótese nula (H_0) de que os resíduos seguem uma distribuição normal. A estatística do teste JB χ^2 (qui-quadrado) com 2 graus de liberdade (gl) (n-2). Caso o p-valor for menor do que 5%, ($p < 0,05$) será rejeita a normalidade, e se $p > 0,05$, aceita-se a normalidade. Esta estatística serve para testar se os resíduos do modelo ajustado seguem uma distribuição normal, baseada em diferenças entre assimetria e curtose em relação à normal (KIM, 2016).

O teste de Breusch-Godfrey, também conhecido como LM será utilizado para verificação da correlação serial dos erros no modelo ajustados, sendo aplicável a termos defasados ou não. O teste é apto para identificar autocorrelação nos erros em um modelo de regressão, possuindo a hipótese nula de que não há correlação serial de qualquer ordem (WALDMAN, 1983).

Para avaliar se os resíduos são homoscedásticos, será aplicado o teste de heteroscedasticidade de Breush-Pagan (1979) e Godfrey (1978). A homoscedasticidade é a variância dos resíduos e o ideal é que os erros sejam aleatórios, de modo que não sejam relacionados com as características das variáveis em análise. O teste é do tipo multiplicador de Lagrange com hipótese nula de homoscedasticidade (BAIG *et al.*, 2018; WU *et al.*, 2020).

3. APLICAÇÃO DOS MODELOS ARDL NO *SOFTWARE* EVIDEWS

Este capítulo apresenta uma análise prática do crescimento econômico brasileiro em relação às exportações, abrangendo o período de janeiro de 2000 a junho de 2019. Foram coletadas 234 observações mensais diretamente do Instituto de Pesquisa Econômica Aplicada (IPEA) (<http://www.ipeadata.gov.br/Default.aspx>). As variáveis macroeconômicas selecionadas incluem o Produto Interno Bruto (PIB), que mensura o crescimento econômico nacional em milhões de reais, bem como as exportações para o Oriente Médio (EXPOM) em dólares americanos (US\$) e as exportações para a Ásia e o Pacífico (EXPAP) em dólares americanos (US\$).

3.1 Base de Dados

As exportações são os valores das vendas para o exterior e outras remessas de bens de propriedade de residentes no país, registrado na Balança Comercial do Balanço de Pagamentos. Refere-se ao valor dólar FOB (US\$) das exportações para o destino. O valor FOB indica o preço da mercadoria em dólares americanos sob o Incoterm FOB (*Free on Board*), modalidade na qual o exportador é responsável por embarcar a mercadoria enquanto o importador assume o

pagamento do frete, seguros e demais custos pós embarque. Segundo a fonte Secex/MDIC, país de destino é aquele conhecido no momento do despacho como o último país para onde os bens se destinam.

Nesta aplicação, adotaremos a prática de analisar variáveis em logaritmo natural, o que está associado à necessidade de interpretar as elasticidades em termos de variações percentuais. Essa abordagem simplifica a compreensão dos efeitos das mudanças nas variáveis independentes sobre a variável dependente, tornando-os diretamente interpretáveis como elasticidades. Na pretensão de que os resultados possam ser lidos em variações percentuais, as variáveis foram modificadas para logaritmo natural.

Tal método é particularmente relevante em situações onde a elasticidade constante é uma suposição válida, permitindo uma especificação precisa dos modelos. A função $Y = \log(X)$ é definida apenas para $X > 0$ e assim possibilita a especificação de modelos de elasticidade constante, sendo útil para lidar com variações proporcionais em aplicações econométricas (MATEM, 2017).

O termo "logaritmo natural" e "logaritmo neperiano" são usados de forma intercambiável e referem-se ao mesmo conceito, representado pela função logarítmica com base no número de Euler, denotado por "e". Portanto, tanto "logaritmo natural" quanto "logaritmo neperiano" se referem ao logaritmo de base "e", representado pela função $\ln(x)$. Em modelos econômicos, especialmente em análises de elasticidades em modelos ARDL, o logaritmo natural (ou neperiano) é comumente utilizado para transformar variáveis e facilitar a interpretação dos resultados em termos de variações percentuais.

No Quadro 1 estão representadas as variáveis, siglas e unidades de medidas que serão abordadas no decorrer do capítulo.

Quadro 1 – Variáveis selecionadas para o modelo ARDL

Sigla	Variável	Un. De medida
LOG(PIB)	Logaritmo natural do Produto Interno Bruto	Reais (R\$)
LOG(EXPOM)	Logaritmo natural das exportações com destino ao Oriente Médio	Dólares (US\$)
LOG(EXPAP)	Logaritmo natural das exportações com destino à Ásia-Pacífico	Dólares (US\$)

Fonte: Os autores

O Produto Interno Bruto (LOGPIB) foi selecionado como a variável dependente neste modelo, enquanto as exportações direcionadas ao Oriente Médio (LOG(EXPOM)) e as exportações destinadas à Ásia-Pacífico (LOG(EXPAP)) foram designadas como as variáveis independentes. A escolha dessas variáveis é fundamentada na sua relevância para compreender o impacto das exportações sobre o crescimento econômico brasileiro. O logaritmo natural foi aplicado a essas variáveis para facilitar a interpretação dos resultados em termos de elasticidades e variações percentuais.

3.2 Etapas metodológicas para ajuste dos modelos

O ajuste dos modelos Autoregressivos e de Defasagens Distribuídas (ARDL) segue a abordagem proposta por Pesaran, Shin e Smith (2001). Inicialmente, é fundamental verificar a possível existência de uma relação de longo prazo, utilizando uma equação pelo Método de Mínimos Quadrados Ordinários (MQO). Isso serve como base para os testes de detecção de cointegração, realizados pelo *bound test* (BAIG *et al.*, 2018; PESARAN *et al.*, 2001). Essa análise é crucial para determinar se há uma relação estável de longo prazo entre as variáveis, essencial para compreender as dinâmicas econômicas investigadas. A equação 7 representa o modelo geral ARDL, fornecendo uma estrutura sólida para entender os processos econômicos em estudo.

$$\begin{aligned}
 LOG(PIB) = & \alpha_0 + \alpha_1 t + \sum_{i=0}^l \varphi_{1i} \Delta LOG(PIB)_{t-i} + \sum_{i=0}^l \varphi_{2i} \Delta LOG(EXPOM)_{t-i} \\
 & + \sum_{i=0}^l \varphi_{3i} \Delta LOG(EXPAP)_{t-i} + \sum_{i=0}^l \beta_{1i} LOG(PIB)_{t-i} \\
 & + \sum_{i=0}^l \beta_{2i} LOG(EXPOM)_{t-i} + \sum_{i=0}^l \beta_{3i} LOG(EXPAP)_{t-i} + \varepsilon_t
 \end{aligned} \tag{7}$$

Em que, LOG representa o logaritmo natural; α_0 corresponde a uma constante; $\alpha_0 t$ é o termo de tendência; Δ é o operador de primeira diferença das variáveis; φ os coeficientes de curto prazo; β os coeficientes de longo prazo; e ε_t a série de resíduos.

O teste de cointegração, irá verificar se os coeficientes das variáveis são significativos a longo prazo considerando suas defasagens, avaliando os valores críticos de todos os regressores (NKORO, 2016; BULUS e KOC, 2021). A hipótese nula do teste é de que H_0 : não há nenhuma cointegração, podendo ser visualizada na equação 8.

$$H_0 = \varphi_1 = \varphi_2 = \varphi_3 = 0 \quad (8)$$


O resultado do teste é interpretado de acordo com o $F_{statistic}$ calculado. Caso o valor de F se posicionar acima do limite superior do *bound test*, a cointegração será confirmada, rejeitando a hipótese nula; se a estatística encontrar-se abaixo do limite inferior, a hipótese nula não pode ser rejeitada, indicando a ausência de cointegração; e se a estatística estiver entre o limite superior e inferior, o resultado é dito inconclusivo. Resultando em um valor dado na região inconclusiva, será necessário conhecer a ordem de integração das variáveis por meio dos testes de raízes unitárias (HUSSAIN e REHMAN, 2021).

O segundo momento só irá ocorrer se for confirmada a hipótese de cointegração. Se confirmada, será estima-se a velocidade de ajustamento ao equilíbrio de longo prazo, representada por coeficiente ECM(-1), obtendo os coeficientes de curto prazo das variáveis (LI e SHAO, 2022). O modelo geral estimado na forma de correção de erros (ARDL-ECM) nesta análise é especificado conforme a equação 9:

$$\begin{aligned} LOG(PIB) = & \alpha_0 + \alpha_1 t + \sum_{i=0}^l \varphi_{1i} \Delta LOG(PIB)_{t-i} + \sum_{i=0}^l \varphi_{2i} \Delta LOG(EXPOM)_{t-i} \\ & + \sum_{i=0}^l \varphi_{3i} \Delta LOG(EXPAP)_{t-i} + \sum_{i=0}^l \beta_{1i} LOG(PIB)_{t-i} \\ & + \sum_{i=0}^l \beta_{2i} LOG(EXPOM)_{t-i} + \sum_{i=0}^l \beta_{3i} LOG(EXPAP)_{t-i} + \delta ECM_{t-1} + \varepsilon_t \end{aligned} \quad (9)$$

Para a velocidade de alinhamento a conversão de equilíbrio, os coeficientes ECM(-1), devem ser negativos e estatisticamente significativos (BÖLÜK e MERT, 2015; ODHIAMBO, 2009). De forma sintetizada, na Figura 1 está ilustrado o passo a passo do ajuste dos modelos ARDL de forma simples e explicativa.

Figura 1 – Fluxograma das etapas metodológicas para seleção dos modelos ARDL



Fonte: Os autores

Recorrendo ao *Software* EViews, serão abordados os seguintes procedimentos:

Etapa 1 – Organização dos Dados: Preparação e estruturação dos conjuntos de dados relevantes para a análise.

Etapa 2 – Importação dos Dados do Excel para o EViews: Transferência dos dados do formato Excel para o *software* EViews para análise econômica.

Etapa 3 – Avaliação da Ordem de Integração das Variáveis: Determinação do nível de estacionariedade das variáveis, essencial para a aplicação correta dos modelos.

Etapa 4 – Especificação do Modelo ARDL: Definição da estrutura do modelo Autorregressivo de Defasagens Distribuídas (ARDL) com as variáveis selecionadas.

Etapa 5 – Testes de Diagnóstico do Modelo Selecionado: Realização de testes estatísticos para verificar a validade das premissas do modelo e a qualidade da especificação.

Etapa 6 – Verificação da Existência de Cointegração ARDL - "*Bound test*": Aplicação do teste de "*bound*" para avaliar se existe uma relação de longo prazo entre as variáveis.

Etapa 7 – Identificação de Coeficientes de Curto e Longo Prazo: Estimação dos coeficientes que representam as relações de curto e longo prazo entre as variáveis.

Etapa 8 – Estimativa da Velocidade de Ajuste ECM: Cálculo da velocidade com que as variáveis se ajustam de volta ao equilíbrio de longo prazo após perturbações.

Esses procedimentos delineados fornecerão uma abordagem estruturada e sistemática para a análise econômica por meio do *Software* EViews. Desde a organização inicial dos dados até a estimação dos coeficientes de curto e longo prazo e a verificação da existência de cointegração, cada etapa desempenha um papel fundamental na construção e avaliação dos modelos ARDL. Por meio da execução desses passos, os pesquisadores e analistas serão capazes de explorar e entender as dinâmicas subjacentes entre as variáveis econômicas em estudo. No próximo capítulo, iremos detalhar cada uma dessas etapas, fornecendo um guia passo a passo para sua implementação prática utilizando o *Software* EViews.

4. MODELAGEM E AJUSTE DOS MODELOS ARDL NO *SOFTWARE* EIEWS: PROCEDIMENTOS E RESULTADOS

4.1 Organização dos Dados

Inicialmente, é necessário organizar os dados em uma planilha no Excel (Figura 2), seguindo uma estrutura que permita uma análise eficiente e precisa. Isso envolve categorizar as variáveis relevantes, garantir consistência nos formatos de dados e eliminar qualquer inconsistência ou ruído nos dados brutos. Essa etapa é crucial para garantir a qualidade e integridade dos dados antes de prosseguir para a análise econômica propriamente dita.

Figura 2 – Planilha Excel com os dados a serem importados para o EViews

	A	B	C	D
1	Data	EXPAP	EXPOM	PIB
2	2000.01	450137951,00	117208941,00	92576,60
3	2000.02	431359210,00	130585231,00	91770,40
4	2000.03	472458438,00	111637972,00	92579,90
5	2000.04	434234147,00	111397922,00	91376,20
6	2000.05	695881988,00	135449418,00	98727,00
7	2000.06	735424319,00	140321651,00	102685,40
8	2000.07	678260616,00	168382981,00	103410,40
9	2000.08	667320086,00	248016459,00	105177,80
10	2000.09	482282679,00	190426254,00	100307,60
11	2000.10	464637733,00	197878060,00	106951,10
12	2000.11	438642572,00	168751816,00	107678,00
13	2000.12	533791344,00	135128438,00	105851,60
14	2001.01	568414098,00	190457365,00	102530,70
15	2001.02	340565934,00	145479477,00	101635,30
16	2001.03	508649519,00	174777820,00	108303,80
17	2001.04	489582520,00	141591960,00	107572,00
18	2001.05	707358307,00	212081354,00	111202,20
19	2001.06	673086777,00	234063878,00	104949,40
20	2001.07	633305960,00	219503892,00	110758,90
21	2001.08	758291887,00	261425300,00	113064,70
22	2001.09	633586383,00	298184518,00	108700,80


Fonte: Os autores

Conforme a Figura 2, na primeira coluna está identificando o período das observações, podendo ser visualizado que se iniciam em janeiro de 2000. As demais colunas mostram os valores observados das variáveis para as exportações com destino à Ásia-Pacífico e Oriente Médio. Após todas as variáveis necessárias estiverem organizadas, é necessário importar os dados (planilha Excel) para o *software* EViews.

4.2 Importando os dados do Microsoft Excel para o EViews

Primeiramente, inicie o *software* EViews. Para importar os dados do Microsoft Excel para o EViews, é necessário clicar em “File”, “Import” e “Import from file” (conforme Figura 3). Em seguida, selecione o arquivo do Excel com os dados organizados, o qual deve estar salvo em alguma pasta no seu computador. O processo ocorre em três etapas, as quais serão detalhadas a seguir.


Figura 3 – Importar o arquivo para o EViews



Fonte: Os autores

Após selecionar o arquivo, irá abrir a janela conforme mostra a Figura 4.


Figura 4 – Etapa 1 da importação de dados



Fonte: Os autores

Nesta janela, deve-se selecionar a opção “*Custom range*” e clicar na seta que indica direção para a direita em “*Start cell*”, conforme a Figura 5. Este processo é realizado a fim de eliminar a coluna que contem a periodicidade dos dados, deixando somente as variáveis na tela inicial do *software*. Feito isso, clique em “Avançar”.


Figura 5 – Etapa 1 da importação de dados concluída



Fonte: Os autores

Ao clicar em “Avançar”, irá abrir a janela correspondente à segunda etapa do processo de importação dos dados, conforme pode ser visualizado na Figura 6.

Figura 6 – Etapa 2 da importação de dados



Fonte: Os autores

Nesta janela (Figura 6) é necessário somente clicar em “Avançar” e irá avançar para a terceira e última etapa do processo de importação dos dados, conforme pode ser visualizado na Figura 7.

Figura 7 – Etapa 3 da importação de dados

Excel 97-2003 Read - Step 3 of 3

Import method: Create new workbook

Structure of the Data to be Imported

Basic structure: Dated - specified by date series

Frequency: Monthly

Identifier series: Date series: data

	DATA	EXPAP	EXPOM	PIB
1	2000M01	4.50E+08	117208941	92576.6
2	2000M02	4.31E+08	130585231	91770.4
3	2000M03	4.72E+08	111637972	92579.9
4	2000M04	4.34E+08	111397922	91376.2
5	2000M05	6.96E+08	135449418	98727.0
6	2000M06	7.35E+08	140321651	102685.4
7	2000M07	6.78E+08	169382981	103410.4
8	2000M08	6.67E+08	248016459	105177.8
9	2000M09	4.82E+08	190426254	100307.6

Buttons: Cancel, <Back, Next>, Finish

Fonte: Os autores

Nesta janela (Figura 7), será necessário ir até a opção “*Basic structure*” e selecionar “*Dated – regular Frequency*”. Ao clicar para selecionar esta opção, irá aparecer a opção “*Frequency*”. Nesta opção, selecione aquela que convém aos seus dados importados. Neste exemplo, será selecionado a opção “*Monthly*” pois os dados são mensais. Vale lembrar que é necessário que todas as variáveis tenham a mesma periodicidade. Em “*Start date*” deve-se inserir o período em que a série de dados se inicia, por se tratar de dados mensais neste exemplo, que se iniciam em janeiro de 2000, será inserido na caixa de texto “2000M01”. Em seguida, clique em “*Finish*”, conforme a Figura 8.

Figura 8 – Importação de dados finalizada

Excel 97-2003 Read - Step 3 of 3

Import method: Create new workbook

Structure of the Data to be Imported

Basic structure: Dated - regular frequency

Frequency/date specification: Frequency: Monthly

Start date: 2000m01

	DATA	EXPAP	EXPOM	PIB
2000M01	2000M01	4.50E+08	117208941	92576.6
2000M02	2000M02	4.31E+08	130585231	91770.4
2000M03	2000M03	4.72E+08	111637972	92579.9
2000M04	2000M04	4.34E+08	111397922	91376.2
2000M05	2000M05	6.96E+08	135449418	98727.0
2000M06	2000M06	7.35E+08	140321651	102685.4
2000M07	2000M07	6.78E+08	169382981	103410.4
2000M08	2000M08	6.67E+08	248016459	105177.8
2000M09	2000M09	4.82E+08	190426254	100307.6


Buttons: Cancel, <Back, Next>, Finish

Fonte: Os autores

Caso você esteja lidando com dados anuais, será necessário selecionar a opção “*Annual*” em “*Frequency*” e, em seguida, inserir somente o ano em “*Start date*” - por exemplo: “2000”.

Na janela subsequente, conforme Figura 9, deve-se selecionar a opção “*No*” e os dados finalmente serão importados para o EViews.

Figura 9 – Vincular séries a uma fonte externa




Fonte: Os autores

No próximo tópico, será apresentado como será realizado o teste de estacionariedade das variáveis, a fim de identificar a ordem de integração $I(d)$ necessária para as tornar estáveis.

4.3 Verificação da Estacionariedade

Realizar a análise gráfica das variáveis é indispensável para identificar visualmente a presença de tendências, sazonalidades ou ciclos. Para realizar essa análise, é necessário selecionar a opção “*Quick*” e depois escolher “*Graph...*”, como exemplificado na Figura 10.

Figura 10 – Gerando gráficos




Fonte: Os autores

Em seguida, será necessário listar as séries para reportar aos gráficos. Neste exemplo, iremos gerar os gráficos das séries originais, e também das séries modificadas em logaritmo

natural. Na janela “*Serie List*”, conforme mostra a Figura 11, está listado as séries do exemplo recorrente.


Figura 11 – Lista de séries



Fonte: Os autores

O *software* abrirá uma janela (conforme ilustrado na Figura 12) na qual você poderá configurar o tipo de gráfico que deseja gerar.

Figura 12 – Configurando os gráficos




Fonte: Os autores

No lado esquerdo da Figura 12, está disponibilizado a opção “*Option Pages*” que permite configurar o gráfico, como as cores, escala de números, *templates*, entre muitas outras

opções. Em “*Specific*” é possível selecionar o tipo de gráfico, para este exemplo segue a opção “*Line & Symbol*”. Na opção “*Multiple series*” as duas opções mais usadas são a “*Single graph*” e “*Multiple graphs*”. No exemplo utilizamos a opção “*Multiple graphs*” (conforme a Figura 13) para que cada série permaneça em um gráfico. Caso fosse selecionado a opção “*Single graphss*”, as séries que possuem magnitudes diferentes, quanto aos valores, seria difícil, ou até mesmo impossível identificar algumas peculiaridades de cada série de forma isolada.

A opção “*Single graphss*” é indicada quando o conjunto de séries analisadas pode ser incorporado em um único gráfico, apresentando a mesma escala para evitar discrepâncias. Essa abordagem é indispensável ao analisar séries temporais, pois permite identificar visualmente a presença de tendências, sazonalidades e ciclos, que por sua vez podem levar a conclusões significativas no processo de modelagem. Ao finalizar a escolha da forma em que o gráfico será reportado, deve-se clicar em “OK”. Os gráficos gerados estão na Figura 13.

Figura 13 – Gráficos das séries originais e das séries em *log*



Fonte: Os autores

Conforme ilustrado na Figura 13, que exibe os gráficos das variáveis utilizadas neste exemplo, é possível identificar uma tendência aparente nas séries, sugerindo que as mesmas não são estacionárias - ou seja, não são do tipo $I(0)$. Para confirmar a ordem de integração das séries, é essencial realizar testes de raiz unitária, já que esse método é estatisticamente mais confiável do que depender apenas da análise visual.

É válido ressaltar que os modelos ARDL não são compatíveis com séries integradas de ordem dois ($I(2)$), como mencionado anteriormente. Enquanto os modelos ARDL são resilientes para lidar com combinações de séries estacionárias ($I(0)$) e séries integradas de primeira ordem ($I(1)$), eles não podem ser aplicados a séries integradas de segunda ordem. Quando uma variável em uma série temporal possui uma ordem de integração igual a dois, isso implica que ela precisa ser diferenciada duas vezes para se tornar estacionária. No entanto, os modelos ARDL operam sob a suposição de que as variáveis são integradas de primeira ordem ou estacionárias. Portanto, a presença de séries $I(2)$ pode resultar em resultados inconsistentes ou pouco confiáveis ao se usar modelos ARDL. Assim, é essencial assegurar que todas as variáveis no modelo tenham uma ordem de integração de um ou zero para garantir a validade e a interpretabilidade dos resultados.

Existem diversos métodos para avaliar a estacionariedade das séries temporais, incluindo análise gráfica, correlograma e testes de raiz unitária. Dentre esses métodos, o teste de raiz unitária é amplamente utilizado na pesquisa como a abordagem preferencial. Para verificar a estacionariedade das séries, serão aplicados os testes mais comuns na literatura: o Teste de Dickey-Fuller Aumentado (ADF) (DICKEY e FULLER, 1981), o Teste de Phillips-Perron (PP) (PHILLIPS e PERRON, 1988) e o Teste de Kwiatkowski, Phillips, Schmidt e Shin (KPSS) (KWIATKOWSKI *et al.*, 1992).

Para facilitar a compreensão da interpretação dos resultados desses testes, o Tabela 1 sintetiza informações relevantes.


Tabela 1 – Interpretação dos testes de Raízes Unitárias

Teste de raiz unitária	Interpretação
Augmented Dickey e Fuller	Para que a série seja estacionária a hipótese H_0 deve ser rejeitada, ou seja, $ \tau ^{\text{calculado}} > \tau ^{\text{crítico}}$. Caso $ \tau ^{\text{calculado}} < \tau ^{\text{crítico}}$, aceita-se a hipótese H_0 e diz-se que a série possui uma raiz unitária (não estacionária).
Kwiatkowski, Phillips, Schmidt e Shin	A série é considerada estacionária se a hipótese nula H_0 for aceita.
Phillips e Perron.	Se a hipótese H_0 for rejeitada a série é considerada estacionária, $ \tau ^{\text{calculado}} > \tau ^{\text{crítico}}$. Porém, se $ \tau ^{\text{calculado}} < \tau ^{\text{crítico}}$, aceita-se H_0 , a série possui raiz unitária (não estacionária).

Fonte: Os autores

A aplicação de somente um teste poderia trazer incerteza quando ao grau de integração da variável, por isso, a literatura sugere que seja aplicado mais de um teste. No EViews é possível realizar os testes mencionados no Quadro 2, além de outros testes. Optou-se em utilizar estes, pois o ADF e o PP apresentam hipótese nula contrária ao teste KPSS. Para conduzir os testes é necessário ir na opção “Quick” e “Unit Root Test...”, conforme a Figura 14.

Figura 14 – Selecionando o teste de raiz unitária




Fonte: Os autores

O próximo passo é inserir a série que será analisada na janela (Figura 15). Neste exemplo, começaremos com a variável dependente, que corresponde ao PIB. Como mencionado anteriormente, o modelo ARDL permite avaliar as elasticidades, e para isso é

necessário utilizar as variáveis em logaritmo natural. Portanto, analisaremos a estacionariedade das séries que estão no formato de logaritmo. Essa abordagem reduz a variância dos dados e permite uma análise mais precisa das elasticidades.


Figura 15 – Selecionando a série para verificar a estacionariedade



Fonte: Os autores

Ao clicar em “OK” irá surgir a janela para configuração do teste, conforme é possível visualizar na Figura 16.

Figura 16 – Seleção do teste de raiz unitária ADF em nível



Fonte: Os autores

Nesta janela “Unit Root Test”, é selecionado o tipo de teste em “Test type”. Nesta aba é possível verificar que o EViews disponibiliza 6 testes de estacionariedade: Augmented Dickey-

Fuller, Dickey Fuller GLS, Phillips Perron, Kwiatkowski-Phillips-Schmidt-Schin, Elliott-Rothenberg-Stock Point-Optimal e Ng-Perron.

Na aba “*Test for unit root in*”, deve-se selecionar primeiramente a opção “*level*”, que irá identificar se a série é estacionária em nível $I(0)$. Caso os resultados evidenciem que a série não seja estacionária em nível, deve-se selecionar a opção “*1st difference*” – $I(1)$. Comumente, mas não exclusivamente, a maioria das séries se tornam estáveis em nível ou em primeiras diferenças, são raros os casos em que é necessário utilizar a opção “*2st difference*”, mas não se descarta esta possibilidade, principalmente em séries financeiras com alta volatilidade.

Na aba “*Include in test equation*” (Figura 16), é possível observar três opções: “*intercept*”, “*trend and intercept*” e “*none*”. Para selecionar estas opções é necessário aderir a visualização gráfica. Nos gráficos gerados, pode-se visualizar se a série possui *intercepto*, ou se apresenta tendência e *intercepto*, ou se não apresenta nenhuma das opções. Cada variável apresenta suas peculiaridades, por isso esta opção é singular de cada estudo. Nas abas “*Lag Length*”, opção “*Automatic Selection*” e “*Maximum lags*” – 14, será mantida, e por fim, deve-se clicar em “OK”. A Figura 17 mostra o resultado do teste.

Figura 17 – Resultado do teste de raiz unitária ADF em nível

Null Hypothesis: LOG(PIB) has a unit root		
Exogenous: Constant, Linear Trend		
Lag Length: 12 (Automatic - based on SIC, maxlag=14)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	1.263394	1.0000
Test critical values: 1% level	-4.000122	
5% level	-3.430289	
10% level	-3.138717	
*Mackinnon (1996) one-sided p-values.		

Fonte: Os autores

Na parte superior da Figura 17 é possível visualizar a hipótese nula e a variável selecionada para análise “*Null Hypothesis: LOG(PIB) has unit root*”, ou seja, a hipótese nula do teste é de que a série apresenta raiz unitária, sendo não estacionária. De acordo com o resultado gerado no teste ADF a série “LOG(PIB)” é não-estacionária em nível, pois aceita a hipótese nula H_0 , onde $|\tau|^{\text{calculado}} > |\tau|^{\text{crítico}}$ e p-valor $> 0,05$. Como a série é não-estacionária em nível, é necessário testá-la em “*1st difference*”. Para isso é necessário ir até a opção “*View*”, “*Unit Root Test...*” e selecionar a opção “*1st difference*”. O resultado gerado segue na Figura 18.

Figura 18 – Resultado do teste de raiz unitária ADF em primeiras diferenças

Null Hypothesis: D(LOG(PIB)) has a unit root		
Exogenous: Constant, Linear Trend		
Lag Length: 11 (Automatic - based on SIC, maxlag=14)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.891731	0.0000
Test critical values: 1% level	-4.000122	
5% level	-3.430289	
10% level	-3.138717	
*MacKinnon (1996) one-sided p-values.		

Fonte: Os autores

Conforme visualizado na Figura 18, os resultados apontam para a rejeição da hipótese nula, sendo confirmado que a série é estacionária após a aplicação de primeiras diferenças (*1st difference*), concluindo que a série LOG(PIB) é I(1).

O próximo teste a se realizar é o teste PP (Figura 19). Novamente é selecionado a opção “Quick”, “Series statistics...” e “Unit Root Test”. Na janela, deve-se escrever o nome da série desejada, e logo após clicar em “OK”. Neste exemplo, segue com a série “LOG(PIB)”.

Figura 19 – Seleção do teste de raiz unitária PP em nível

Unit Root Test

Test type: Phillips-Perron

Test for unit root in: ☒ Level, ☐ 1st difference, ☐ 2nd difference

Spectral estimation method: Default (Bartlett kernel)

Bandwidth: ☒ Automatic selection: Newey-West Bandwidth, ☐ User specified: 4

Include in test equation: ☐ Intercept, ☒ Trend and intercept, ☐ None

OK Cancel

Fonte: Os autores

Neste outro teste, continua-se com a opção tendência e *intercepto*. As configurações do teste são alteradas, alterando a opção em “Test type” para “Phillips-Perron”, “Test for unit root

in” mantendo selecionada a opção “level” (nível), ao final, deve-se clicar em “OK”. A Figura 20 mostra os valores obtidos para o teste.

Figura 20 – Resultado do teste de raiz unitária PP em nível

Null Hypothesis: LOG(PIB) has a unit root Exogenous: Constant, Linear Trend Bandwidth: 15 (Newey-West automatic) using Bartlett kernel		
	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-2.581474	0.2893
Test critical values:		
1% level	-3.997930	
5% level	-3.429229	
10% level	-3.138092	
*MacKinnon (1996) one-sided p-values.		

Fonte: Os autores

Na parte superior da Figura 20 é possível visualizar a hipótese nula e a variável selecionada para análise “Null Hypothesis: LOG(PIB) has unit root”, ou seja, a hipótese nula do teste é de que a série apresenta raiz unitária, sendo não estacionária. Segundo o resultado gerado no teste PP a série “LOG(PIB)” é não-estacionária em nível, pois aceita a hipótese nula. Como a série é não-estacionária em nível, é necessário testá-la em “1st difference”. É preciso clicar em “View”, “Unit Root Test...” e selecionar a opção “1st difference”, conforme pode-se observar na Figura 21. Após alterado, deve-se clicar em “OK”.

Figura 21 – Seleção do teste PP em primeiras diferenças

Fonte: Os autores

O resultado do teste está exposto na Figura 22.

Figura 22 – Resultado do teste PP em primeiras diferenças


Null Hypothesis: D(LOG(PIB)) has a unit root		
Exogenous: Constant, Linear Trend		
Bandwidth: 139 (Newey-West automatic) using Bartlett kernel		
	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-56.54804	0.0001
Test critical values: 1% level	-3.998104	
5% level	-3.429313	
10% level	-3.138142	
*MacKinnon (1996) one-sided p-values.		

Fonte: Os autores

O resultado em “*1st difference*” rejeitou a hipótese nula, sendo assim, a série é $I(1)$, resultado que corrobora com o primeiro teste realizado. Os testes ADF e PP apresentam a mesma hipótese nula H_0 : a série apresenta raiz unitária. Ambos testes apresentaram o mesmo resultado para a variável “LOG(PIB)” identificando que a série é $I(1)$.

Um terceiro teste será realizado, com hipótese nula alternativa aos testes realizados, que é o teste KPSS, que tem H_0 : a série é estacionária. O teste segue os mesmos passos dos testes anteriores, apenas será modificado a opção “*Test type*” para “Kwiatkowski-Phillips-Schmidt-Shin, conforme a Figura 23.

Figura 23 – Seleção do teste de raiz unitária KPSS em nível



Fonte: Os autores

Após modificar o teste, é preciso clicar em “OK”. O resultado para a série em nível está apresentado na Figura 24.


Figura 24 – Resultado do teste KPSS em nível

Null Hypothesis: LOG(PIB) is stationary Exogenous: Constant, Linear Trend Bandwidth: 11 (Newey-West automatic) using Bartlett kernel		
		LM-Stat.
Kwiatkowski-Phillips-Schmidt-Shin test statistic		0.455323
Asymptotic critical values*:	1% level	0.216000
	5% level	0.146000
	10% level	0.119000
*Kwiatkowski-Phillips-Schmidt-Shin (1992, Table 1)		

Fonte: Os autores

O teste KPSS é baseado na *LM-Statistic*, conforme Figura 24, pode-se perceber que o valor calculado de LM-Stat. rejeita a hipótese nula de que a série é estacionária, ao nível de significância de 1%, 5% e 10%. Sendo assim, é necessário aplicar o teste para a variável em “*1st difference*”, como pode ser visualizado na Figura 25.

Figura 25 – Seleção do teste KPSS em primeiras diferenças



Fonte: Os autores

Ao selecionar o teste de acordo com o pretendido, deve se clicar em “OK”. O resultado do teste está disposto na Figura 26.

Figura 26 – Resultado do teste KPSS em primeiras diferenças

Null Hypothesis: D(LOG(PIB)) is stationary Exogenous: Constant, Linear Trend Bandwidth: 70 (Newey-West automatic) using Bartlett kernel		
		LM-Stat.
Kwiatkowski-Phillips-Schmidt-Shin test statistic		0.140185
Asymptotic critical values*:	1% level	0.216000
	5% level	0.146000
	10% level	0.119000
*Kwiatkowski-Phillips-Schmidt-Shin (1992, Table 1)		

Fonte: Os autores

A hipótese nula do teste KPSS é de que a série é estacionária. De acordo com o resultado apresentado pelo teste KPSS ($\alpha=1\%$, 5% ou 10%) a série “PIB” é estacionária após a aplicação de primeiras diferenças, o que não diverge dos demais resultados apontados pelos testes anteriores. Concluimos então que a série é $I(1)$.

Estes mesmos testes serão realizados para as demais variáveis utilizadas neste exemplo, que correspondem as variáveis independentes. A fim de sintetizar os resultados, é válido representar os resultados no formato de tabela, o qual pode ser baseado no formato da Tabela 2.

Tabela 2 – Resultado dos testes de raízes unitárias ADF, PP e KPSS para as variáveis

Variáveis	ADF (t-stat)		PP (t-stat)		KPSS (LM-stat)	
	d=0	d=1	d=0	d=1	d=0	d=1
LOG(PIB)	1,263	-5,891	-2,581	-56,548	0,455	0,140
LOG(EXPOM)	-1,177	-11,338	-4,627	-	0,493	0,033
LOG(EXPAP)	-1,188	-5,185	-4,156	-	0,473	0,044
$\alpha = 0,05$: ADF (t-stat) valor crítico = -3,430; PP(t-stat) valor crítico = -3,429; KPSS(LM-stat) valor crítico = 0,146.						

Fonte: Os autores

A aplicação dos testes de estacionariedade ADF, PP e KPSS com $\alpha = 5\%$ permitiu identificar que as séries LOG(PIB), LOG(EXPOM) e LOG(EXPAP) são estacionárias após a aplicação de primeiras diferenças, o que as identifica como $I(1)$. Quando pelo menos dois dos testes evidenciarem a mesma ordem de integração para determinada variável, opta-se pelo resultado apontado. Tendo conhecimento sobre a ordem de integração das variáveis, e de que


nenhuma delas apresenta ordem de integração $I(2)$, o próximo passo é ajustar os modelos ARDL.

4.4 Ajuste do modelo ARDL

A seleção do número de defasagens presentes no modelo é estimada empiricamente, a não ser que as teorias macroeconômicas tenham especificado algum número apropriado em que os lapsos de tempo de uma variável independente causam na variável dependente. Nesta etapa surgem duas possibilidades, a primeira, inserir um número mínimo de lags para as variáveis dependentes e independentes, ou a segunda, inserir um número máximo de lags e ir reduzindo até que sejam significativos. A combinação ideal é então definida como a que minimiza algum critério de informação, como Akaike (AIC) ou Schwarz (BIC), ou até mesmo o coeficiente de determinação ajustado R^2 .

Os modelos ARDL são gerados a partir do método de Mínimos Quadrados Ordinários. No EViews é possível recorrer ao objeto de equação especializado para o ARDL. Para isso, é necessário seguir as etapas: “*Quick*”, “*Estimate equation...*”, o qual irá abrir a janela representada na Figura 27.


Figura 27 – Estimando a equação



Fonte: Os autores

A janela da Figura 27 é utilizada para estimar equações, então na parte inferior “*Estimation settings*”, a opção será modificada de “*Method*” de LS – *Least Squares (NLS and ARMA)*” para “*ARDL – Auto-Regressive Distributed Lag Models*”. Em seguida, a janela será alternada, de acordo com a Figura 28. A opção “*Sample*” se refere ao período da amostra, comprovando que a série se inicia em janeiro de 2000 (2000M01) até junho de 2019 (2019M06).

Figura 28 – Estimando a equação no método ARDL



Fonte: Os autores

A nova janela (Figura 28) é dividida em duas abas, uma “*Specification*” para a especificação do modelo e a outra “*Options*” que é para a escolha do critério de informação para seleção do modelo.

Na aba “*Specification*”, na opção “*Dynamic Specification*” é o campo onde serão inseridas as variáveis. Primeiramente é inserida a variável dependente, seguida das variáveis independentes: no caso do exemplo abordado neste capítulo, seria – LOG(PIB) LOG(EXPAP) LOG(EXPOM).


Para que o melhor modelo seja selecionado automaticamente, quanto ao número de lags, é necessário selecionar a opção “*Automatic Selection*”. Ao lado desta opção, se tem o campo “*Max lags*” referindo-se no primeiro campo para a variável dependente, e o segundo, para as variáveis independentes. Automaticamente, o *software* surge inicialmente com o número de 4

lags, porém neste exemplo, usaremos 6 lags, o que corresponderia a meio ano (6 meses). Caso necessário utilizar regressores fixos, eles poderão ser inseridos no campo “*List of fixed regressors*” (em nosso exemplo não há).

De acordo com a análise gráfica das variáveis, é possível observar que há um comportamento em todas as série indicando crescimento ao longo do tempo, ou seja, uma tendência. Na opção “*Trend Specification*” será selecionada a opção “*Linear trend*”.

Na aba “*Options*”, conforme Figura 29, na parte superior esquerda está o campo “*Model selection criteria*” onde é possível selecionar o critério de informação desejado. São 4 opções: “*Akaike info criterion (AIC)*”, “*Schwarz criterion (SC)*”, “*Hannan-Quinn criterion (HQ)*” e “*Adjusted R-squared*” (que se trata do coeficiente de determinação – R^2). Em nosso exemplo usaremos o critério de informação “*Schwarz criterion (SC)*”, pois apresenta melhor desempenho.

Figura 29 – Seleção do critério de informação



Fonte: Os autores

Voltando para a aba “*Specification*” deve-se inserir as variáveis: primeiramente, a variável dependente, e em seguida as variáveis independentes (Figura 30), ao finalizar, deve-se clicar em “OK”.

Figura 30 – Inserindo as variáveis no modelo

Fonte: Os autores

Ao clicar em “OK” serão gerados os resultados conforme a Figura 31.

Figura 31 – Modelo Selecionado

Dependent Variable: LOG(PIB)				
Method: ARDL				
Date: 06/10/20 Time: 12:49				
Sample (adjusted): 2000M06 2019M06				
Included observations: 229 after adjustments				
Maximum dependent lags: 6 (Automatic selection)				
Model selection method: Schwarz criterion (SIC)				
Dynamic regressors (6 lags, automatic): LOG(EXPAP) LOG(EXPOM)				
Fixed regressors: C @TREND				
Number of models evaluated: 294				
Selected Model: ARDL(5, 0, 1)				
Note: final equation sample is larger than selection sample				
Variable	Coefficient	Std. Error	t-Statistic	Prob.*
LOG(PIB(-1))	0.538956	0.062205	8.664256	0.0000
LOG(PIB(-2))	-0.123244	0.066981	-1.839977	0.0671
LOG(PIB(-3))	0.139333	0.065688	2.121117	0.0350
LOG(PIB(-4))	0.117527	0.065363	1.798067	0.0735
LOG(PIB(-5))	0.140735	0.056981	2.469870	0.0143
LOG(EXPAP)	0.040109	0.009199	4.360190	0.0000
LOG(EXPOM)	0.055345	0.012712	4.353918	0.0000
LOG(EXPOM(-1))	-0.036354	0.011392	-3.191223	0.0016
C	0.999232	0.316068	3.161448	0.0018
@TREND	0.000834	0.000257	3.238729	0.0014
R-squared	0.997627	Mean dependent var	12.54598	
Adjusted R-squared	0.997529	S.D. dependent var	0.557609	
S.E. of regression	0.027716	Akaike info criterion	-4.290954	
Sum squared resid	0.168226	Schwarz criterion	-4.141010	
Log likelihood	501.3142	Hannan-Quinn criter.	-4.230463	
F-statistic	10229.89	Durbin-Watson stat	1.933810	
Prob(F-statistic)	0.000000			
*Note: p-values and any subsequent tests do not account for model selection.				


Fonte: Os autores

Na parte superior da Figura 31, estão algumas informações específicas, como qual é a variável dependente; qual é o método de estimação, neste caso ARDL; a hora em que o modelo foi gerado; o período amostral; o critério de informação; os regressores dinâmicos e os fixos; o número de modelos gerados e por último, o modelo selecionado.

O modelo que apresentou as melhores estatísticas de ajuste, selecionado automaticamente pelo *software*, obteve um coeficiente de determinação próximo de 1 (0,997627) e os menores valores para os critérios de informação (AIC=-4,29 e SC=-4,14). Esse modelo específico é o ARDL (5,0,1): significa que a variável dependente, crescimento econômico nacional “LOG(PIB)” é influenciada por ela mesma em até quatro períodos defasados: LOG(PIB)_{t-1}, LOG(PIB)_{t-2}, LOG(PIB)_{t-3}, LOG(PIB)_{t-4} e LOG(PIB)_{t-5}. O crescimento econômico brasileiro está associado às exportações destinadas à região Pacífico-Atlântico somente no período atual: LOG(EXPAP); enquanto que as exportações ao Oriente Médio influenciam o crescimento econômico no período corrente e em um período defasado: LOG(EXPOM) e LOG(EXPOM)_{t-1}. O modelo apresentou coeficientes significativos para as defasagens, e também para a constante e tendência, ambos a 1% de significância.

Vale ressaltar que o período defasado corresponde a 1 mês. O *software* considera a maior defasagem significativa, mesmo que as menores defasagens de uma variável não sejam significativas. Caso alguma das variáveis apresente coeficientes insignificativos, é preciso alterar o número de defasagens até que todos sejam significativos a um nível de significância arbitrado, 1%, 5% ou 10%. O processo se torna contínuo, até que o modelo ajustado satisfaça as preposições exigidas. A opção “View”, “Model Selection Summary” e “Criteria graph”, mostra um *ranking* dos 20 melhores modelos gerados estando de acordo com o critério de informação selecionado, conforme destaca a Figura 32.

Figura 32 – Modelos concorrentes




Fonte: Os autores

A validade do modelo selecionado é confirmada por meio dos testes de diagnóstico: Jarque-Bera (normalidade); Breusch-Godfrey *Serial Correlation* LM e o teste de heteroscedasticidade de Breusch-Pagan-Godfrey.

Para analisar a normalidade, é necessário selecionar a opção “View”, “Residual Diagnostics”, “Histogram-Normality Test”. A análise é interpretada conforme a imagem gerada na Figura 33.

Figura 33 – Resultado do teste de normalidade



Fonte: Os autores

O teste Jarque-Bera tem como hipótese nula (H_0) de que os resíduos seguem uma distribuição normal. A estatística do teste JB qui-quadrado com 2 graus de liberdade (gl). Assim, se o p-valor for menor do que 5%, ($p < 0,05$) será rejeita a normalidade, e se $p > 0,05$, aceita-se a normalidade. Neste caso, p-valor de 0,2718 ($p\text{-valor} > 0,05$), pode-se confirmar a hipótese nula de que os resíduos seguem uma distribuição normal. O valor esperado para assimetria (*skewness*) é zero e curtose 3 (*Kurtosis*), o resultado do modelo ajustado esteve em torno destes valores, com assimetria de -0.178 e curtose de 2,618. O próximo passo, é identificar se os resíduos são correlacionados.

A estatística de Breusch-Godfrey Serial Correlation LM, tem a hipótese nula de que não há correlação serial. Reportando ao teste, é necessário selecionar a opção “View”, “Residual Diagnostics” e “Serial Correlation LM Test...”. Irá abrir uma janela “Lags Specification” com a opção de “Lags to include”, preenchido automaticamente com “2”, então clicar em “OK”. Por se tratar da análise residual, Soma dos Quadrados dos Resíduo ($SQ_{\text{Resíduo}}$), o número 2 corresponde a distribuição de χ^2 (qui-quadrado) com 2 graus de liberdade (n-2). O resultado pode ser observado na Figura 34.

Figura 34 – Resultado do teste de autocorrelação residual

Breusch-Godfrey Serial Correlation LM Test:				
F-statistic	2.065718	Prob. F(2,218)	0.1292	
Obs*R-squared	4.259184	Prob. Chi-Square(2)	0.1189	
Test Equation:				
Dependent Variable: RESID				
Method: ARDL				
Date: 06/10/20 Time: 12:57				
Sample: 2000M06 2019M06				
Included observations: 229				
Presample missing value lagged residuals set to zero.				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(PIB(-1))	-0.067787	0.146563	-0.462511	0.6442
LOG(PIB(-2))	0.218496	0.141152	1.547951	0.1231
LOG(PIB(-3))	-0.128070	0.091736	-1.396062	0.1641
LOG(PIB(-4))	0.014977	0.067905	0.220558	0.8256
LOG(PIB(-5))	-0.031416	0.069715	-0.450640	0.6527
LOG(EXPAP)	-0.003490	0.011377	-0.306747	0.7593
LOG(EXPOM)	-0.001560	0.013910	-0.112166	0.9108
LOG(EXPOM(-1))	0.001144	0.012394	0.092309	0.9265
C	0.005618	0.065094	0.086305	0.9313
RESID(-1)	0.081975	0.163856	0.500290	0.6174
RESID(-2)	-0.255132	0.129390	-1.971803	0.0499
R-squared	0.018599	Mean dependent var	-1.19E-15	
Adjusted R-squared	-0.026419	S.D. dependent var	0.027806	
S.E. of regression	0.028171	Akaike info criterion	-4.254210	
Sum squared resid	0.173005	Schwarz criterion	-4.089271	
Log likelihood	498.1070	Hannan-Quinn criter.	-4.187669	
F-statistic	0.413144	Durbin-Watson stat	2.031036	
Prob(F-statistic)	0.939479			

Fonte: Os autores

A estatística de Breusch-Godfrey *Serial Correlation LM*, com hipótese nula de que não há nenhuma correlação serial foi aceita (p-valor de 0,1292 > 0,05). Como conclusão do teste, conclui-se que os resíduos não são autocorrelacionados. A próxima etapa consiste em verificar se os resíduos são homoscedásticos.

Para verificar o homoscedasticidade, deve-se ir até a opção “View”, “Residual Diagnostics” “Heteroskedasticity Test” e “Breusch-Pagan-Godfrey”. O resultado do teste segue conforme a Figura 35.

Figura 35 – Resultado do teste de heteroscedasticidade

Heteroskedasticity Test: Breusch-Pagan-Godfrey				
F-statistic	1.190077	Prob. F(9,219)	0.3025	
Obs*R-squared	10.67756	Prob. Chi-Square(9)	0.2985	
Scaled explained SS	7.935845	Prob. Chi-Square(9)	0.5406	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 06/10/20 Time: 13:12				
Sample: 2000M06 2019M06				
Included observations: 229				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.012981	0.010664	1.217354	0.2248
LOG(PIB(-1))	-0.002629	0.002099	-1.252849	0.2116
LOG(PIB(-2))	0.002807	0.002260	1.242175	0.2155
LOG(PIB(-3))	-0.000890	0.002216	-0.401550	0.6884
LOG(PIB(-4))	0.001903	0.002205	0.862740	0.3892
LOG(PIB(-5))	-0.002217	0.001922	-1.153129	0.2501
LOG(EXPAP)	-0.000243	0.000310	-0.784352	0.4337
LOG(EXPOM)	-0.000326	0.000429	-0.759034	0.4486
LOG(EXPOM(-1))	0.000567	0.000384	1.474664	0.1417
@TREND	8.25E-06	8.68E-06	0.950465	0.3429
R-squared	0.046627	Mean dependent var	0.000735	
Adjusted R-squared	0.007447	S.D. dependent var	0.000939	
S.E. of regression	0.000935	Akaike info criterion	-11.06918	
Sum squared resid	0.000191	Schwarz criterion	-10.91923	
Log likelihood	1277.421	Hannan-Quinn criter.	-11.00869	
F-statistic	1.190077	Durbin-Watson stat	2.110480	
Prob(F-statistic)	0.302454			

Fonte: Os autores

O teste de heteroscedasticidade de Breush-Pagan-Godfrey tem como H_0 : os resíduos são homoscedásticos. Com p-valor de 0,3025 (p-valor > 0,05) a hipótese nula é aceita, confirmando estatisticamente que os resíduos são homoscedásticos.

Sabendo que o modelo tem resíduos homoscedásticos, autocorrelacionados e que seguem uma distribuição normal, a próxima etapa é a identificação da relação de longo prazo por meio do *bound test* para detecção de cointegração. Para tal, é necessário ir na opção “View”, “Coefficient diagnostics” e “Bounds Test”, conforme está reportado na Figura 36.

Figura 36 – Teste para cointegração

View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Representations						Ljung-Box			
Estimation Output						Ljung-Box			
Actual, Fitted, Residual						Ljung-Box			
ARMA Structure...						Ljung-Box			
Gradients and Derivatives						Ljung-Box			
Covariance Matrix						Ljung-Box			
Model Selection Summary						Ljung-Box			
Coefficient Diagnostics						Ljung-Box			
Residual Diagnostics						Ljung-Box			
Stability Diagnostics						Ljung-Box			
Label						Ljung-Box			
LOG(PIB(-1))						Ljung-Box			
LOG(PIB(-2))						Ljung-Box			
LOG(PIB(-3))						Ljung-Box			
LOG(PIB(-4))						Ljung-Box			
LOG(PIB(-5))						Ljung-Box			
LOG(EXPAP)						Ljung-Box			
LOG(EXPOM)						Ljung-Box			
LOG(EXPOM(-1))						Ljung-Box			
@TREND						Ljung-Box			
R-squared						Ljung-Box			
Adjusted R-squared						Ljung-Box			

Fonte: Os autores

Os resultados obtidos para o teste de detecção de cointegração estão dispostos na Figura 37.

Figura 37 – Resultado do teste de cointegração

ARDL Bounds Test		
Date: 06/10/20 Time: 13:21		
Sample: 2000M06 2019M06		
Included observations: 229		
Null Hypothesis: No long-run relationships exist		
Test Statistic	Value	k
F-statistic	9.080902	2
Critical Value Bounds		
Significance	I0 Bound	I1 Bound
10%	4.19	5.06
5%	4.87	5.85
2.5%	5.79	6.59
1%	6.34	7.52


Fonte: Os autores

De acordo com os resultados do *Bound test*, dispostos na Figura 37, o valor do $F_{\text{statistic}}$ foi de 9,080 para $K=2$ (variáveis independentes), estando situado acima do limite inferior $I(0)$ de 6,34 e do limite superior $I(1)$ de 7,52. Dadas circunstâncias, é possível afirmar que ao nível

de 1% de significância a hipótese nula de não existência de cointegração foi rejeitada, no entanto, as variáveis são cointegradas e apresentarão relação de longo prazo.

O resultado do teste de cointegração implica que o crescimento econômico nacional (PIB) e as exportações com destino ao Oriente Médio e Ásia-Pacífico movem-se simultaneamente, de forma que as variáveis não se divergem de forma independente. É possível dizer que qualquer desequilíbrio que ocorra entre as variáveis é um fenômeno de curto prazo. Os coeficientes de longo prazo podem ser visualizados clicando na opção “*View*”, “*Coefficient diagnostics*” e “*Cointegration and Long Run Form*”, conforme está representado na Figura 38.

Figura 38 – Cointegração e performance de longo prazo



Fonte: Os autores

Após selecionada esta opção, serão gerados os coeficientes de curto e longo prazo conforme a figura 39. Os coeficientes nos quais estão representados pela letra D seguida da variável, em que D representa Δ , são os coeficientes de curto prazo; CointEq(-1) representa a velocidade de ajuste para o equilíbrio de longo prazo; na parte inferior, estão os coeficientes de longo prazo.

Figura 39 – Coeficientes de curto e longo prazo e velocidade de ajuste

ARDL Cointegrating And Long Run Form Dependent Variable: LOG(PIB) Selected Model: ARDL(5, 0, 1) Date: 06/10/20 Time: 13:22 Sample: 2000M01 2019M06 Included observations: 229				
Cointegrating Form				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
DLOG(PIB(-1))	-0.274351	0.058997	-4.650275	0.0000
DLOG(PIB(-2))	-0.397595	0.059078	-6.729993	0.0000
DLOG(PIB(-3))	-0.258262	0.058556	-4.410549	0.0000
DLOG(PIB(-4))	-0.140735	0.056981	-2.469870	0.0143
DLOG(EXPAP)	0.040109	0.009199	4.360190	0.0000
DLOG(EXPOM)	0.055345	0.012712	4.353918	0.0000
D(@TREND())	0.000834	0.000257	3.238729	0.0014
CointEq(-1)	-0.186693	0.038913	-4.797667	0.0000
Cointeq = LOG(PIB) - (0.2148*LOG(EXPAP) + 0.1017*LOG(EXPOM) + 5.3523 + 0.0045*@TREND)				
Long Run Coefficients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LOG(EXPAP)	0.214840	0.056477	3.804036	0.0002
LOG(EXPOM)	0.101722	0.051830	1.962618	0.0510
C	5.352281	0.786806	6.802545	0.0000
@TREND	0.004465	0.000558	8.003306	0.0000

Fonte: Os autores

Conforme esperado o ECM (-1), representado no EViews como CointEq(-1) é de -0,186693. O resultado negativo segue conforme esperado, o que significa que 18,66% dos movimentos em desequilíbrio são corrigidos por um período, o que levaria em torno de 5 períodos (5 meses) para ser estabilizado por completo. A magnitude significativa e negativa do ECM reflete a velocidade moderada de ajustamento de desequilíbrio de curto prazo para o estado de equilíbrio de longo prazo, que reafirma os resultados de cointegração.

CONSIDERAÇÕES FINAIS

Neste capítulo, empenhou-se em apresentar ao leitor os conceitos e a aplicação passo a passo dos modelos Autoregressivos e de Defasagens Distribuídas (ARDL), utilizando o *Software* EViews. Nos tópicos iniciais foram discutidos os dois principais assuntos tratados neste capítulo, a cointegração e modelos autorregressivos de defasagens distribuídas, bem como sua evolução metodológica e exigências e pressupostos para ajuste dos modelos.

O interesse em utilizar a metodologia ARDL, conforme apresenta Pesaran *et al.* (2001), pode ser empregada quando não se tem certeza sobre a ordem de integração das variáveis, pois admite séries em nível, em primeiras diferenças ou com ambas as ordens de integração em um único modelo, desde que não sejam de ordem de integração igual a dois; outro ponto que torna a metodologia satisfatória, é para situações em que se tem limitação quanto à amostra, principalmente se tratando das observações que comportam dados anuais, sendo eficiente em capturar as relações de curto e longo prazo em amostras com número pequeno de observações; e também, de ser apta em capturar as relações de curto e longo prazo simultaneamente.

Como resultado do exemplo, em que o objetivo era examinar as relações dinâmicas de curto e longo prazo, bem como as elasticidades, no inter-relacionamento das variáveis para avaliar o impacto que as exportações para estes destinatários exercem sobre o Produto Interno Bruto (PIB) brasileiro, resultou na seleção do seguinte modelo: ARDL (5,0,1), o qual satisfaz os pressupostos de normalidade, heteroscedasticidade e autocorrelação serial dos resíduos mediante a aplicação dos testes. Isso significa que os resíduos do modelo exibem propriedades estatísticas desejáveis e não violam pressupostos importantes. Portanto, o modelo selecionado pode ser considerado apropriado para análise e interpretação das relações entre as variáveis em estudo.

A interpretação do resultado, indica que a variável dependente, crescimento econômico nacional “LOG(PIB)” é influenciada por ela mesma em até quatro períodos defasados: LOG(PIB)_{t-1} , LOG(PIB)_{t-2} , LOG(PIB)_{t-3} , LOG(PIB)_{t-4} e LOG(PIB)_{t-5} . O crescimento econômico brasileiro está associado às exportações destinadas à região Pacífico-Atlântico somente no período atual: LOG(EXPAP) ; enquanto que as exportações ao Oriente Médio influenciam o crescimento econômico no período corrente e em um período defasado: LOG(EXPOM) e LOG(EXPOM)_{t-1} .

O modelo apresentou coeficientes significativos para as defasagens, e também para a constante e tendência, em até 5% de significância. Isso sugere uma relação de autocorrelação nos períodos anteriores, indicando a dependência do crescimento econômico passado para o crescimento presente.

Os resultados mostram que o crescimento econômico brasileiro está associado positivamente às exportações destinadas à região do Pacífico-Atlântico no período atual (LOG(EXPAP)). Isso implica que um aumento nas exportações para essa região está relacionado a um aumento no crescimento econômico atual do Brasil.

Por outro lado, as exportações para o Oriente Médio também influenciam o crescimento econômico do Brasil, mas tanto no período atual quanto em um período anterior ($\text{LOG}(\text{EXPOM})$ e $\text{LOG}(\text{EXPOM})_{t-1}$). Isso sugere que o impacto das exportações para o Oriente Médio no crescimento econômico brasileiro pode se estender além do período imediato, possivelmente refletindo uma relação mais duradoura.

O fato de o modelo ter apresentado coeficientes significativos para as defasagens, bem como para a constante e a tendência, com um nível de significância de até 5%, indica a relevância dessas variáveis na explicação das variações no crescimento econômico. As defasagens mostram a influência dos períodos passados, enquanto a constante e a tendência podem representar componentes de longo prazo e tendências subjacentes na série.

Em geral, esses resultados sugerem que tanto o crescimento econômico passado quanto as exportações para diferentes regiões têm impactos significativos no crescimento econômico atual do Brasil.

Sucintamente, evidenciamos que os modelos ARDL são capazes de identificar o inter-relacionamento na dinâmica de curto e longo prazo entre as séries temporais, sendo de fácil interpretação, principalmente se tratando de uma amostra com um número limitado a poucas observações. Os modelos ARDL podem ser amplamente difundidos em diversas áreas de estudo, sendo aplicável em uma grande gama de variáveis. Os resultados podem fornecer estimativas para tomadas de decisão, contribuindo para políticas de desenvolvimento nos mais diversos setores.

REFERÊNCIAS

AHMAD, Nisar; MENEGAKI, Angeliki N.; AL-MUHARRAMI, Saeed. Systematic literature reView of tourism growth nexus: An overView of the literature and a content analysis of 100 most influential papers. **Journal of Economic Surveys**, v. 34, n. 5, p. 1068-1110, 2020.

AKAIKE, H. A New Look at the Statistical Model Identification. **IEEE Transactions on Automatic Control**, v. 19, n. 6, p. 716–723, 1974.

AKRAM, T.; LI, H. An inquiry concerning long-term U.S. interest rates using monthly data. **Applied Economics**, v. 52, n. 24, p. 2594–2621, 2020.

BAIG, N. et al. Do natural disasters cause economic growth? An ARDL bound testing approach. **Studies in Business and Economics**, v. 13, n. 1, p. 5–20, 2018.

- BILDIRICI, M. E.; GÖKMENOĞLU, S. M. Environmental pollution, hydropower energy consumption and economic growth: Evidence from G7 countries. **Renewable and Sustainable Energy REViews**, v. 75, n. October, p. 68–85, 2017.
- BÖLÜK, G.; MERT, M. The renewable energy, growth and environmental Kuznets curve in Turkey: An ARDL approach. **Renewable and Sustainable Energy REViews**, v. 52, p. 587–595, 2015.
- BRANDT, P. T.; WILLIAMS, J. T. **Multiple Time Series Models**. California: Sage, 2007.
- BROOKS, C. **Introductory Econometrics for Finance**. New York: Cambridge University Press, 2008.
- BROWN, R. L.; DURBIN, J.; EVANS, J. M. Techniques for Testing the Constancy of Regression Relationships Over Time. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 37, n. 2, p. 149–163, 1975.
- BULUS, Gokay Canberk; KOC, Suleyman. The effects of FDI and government expenditures on environmental pollution in Korea: the pollution haven hypothesis revisited. **Environmental Science and Pollution Research**, v. 28, n. 28, p. 38238–38253, 2021.
- CHAND, S.; AFTAB, N. Modified Variance Ratio Test for Autocorrelation in the Presence of Heteroskedasticity. **The Lahore Journal of Economics**, v. 23, n. 1, p. 1–19, 2018.
- CHEUNG, Y. Augmented Dickey-Fuller. v. 13, n. 3, p. 277–280, 2014.
- ENDERS, W. **Applied Econometric Time Series**. 4. ed. Nova Jersey: Wiley, 2015.
- FACHINELLI, A. D. S. Cointegração E Correção De Erro Para a Formação Bruta De Capital Fixo No Brasil Pós-Plano Real. **Revista Economia & Tecnologia**, v. 10, n. 1, p. 31–44, 2014.
- GARZA-RODRIGUEZ, J. et al. The Impact of Human Capital on Economic Growth: the Case of Mexico. **Journal of the Knowledge Economy**, 2020.
- GREENE, W. H. **Econometrics Analysis**. 6. ed. New Jersey: Pearson Education, 2008.
- HAMILTON, J. D. **Time series analysis**. New Jersey: Princeton University Press, 1994.
- HE, P. et al. Energy taxes, carbon dioxide emissions, energy consumption and economic consequences: A comparative study of Nordic and G7 countries. **Sustainability (Switzerland)**, v. 11, n. 21, p. 1–17, 2019.
- HE, Y. Agricultural population urbanization, long-run economic growth, and metropolitan electricity consumption: An empirical dynamic general equilibrium model. **Energy Strategy REViews**, v. 30, p. 100498, 2020.
- HUSSAIN, Imran; REHMAN, Abdul. Exploring the dynamic interaction of CO2 emission on population growth, foreign investment, and renewable energy by employing ARDL Bounds Testing approach. **Environmental Science and Pollution Research**, v. 28, p. 39387–39397, 2021.
- JOHANSEN, S. Statistical analysis of cointegration vectors. **Journal of Economic Dynamics and Control**, v. 12, n. 2–3, p. 231–254, 1988.

- JOHANSEN, S. Times series cointegration. **Creates Research Paper**, n. 38, 2014.
- JOHNSTON, J.; DINARDO, J. **Métodos Econométricos**. 4. ed. Lisboa: McGraw-Hill, 2001.
- KIM, N. A robustified Jarque-Bera test for multivariate normality. **Economics Letters**, v. 140, p. 48–52, 2016.
- KWIATKOWSKI, D. et al. Testing the null hypothesis of stationarity against the alternative of a unit root. How sure are we that economic time series have a unit root? **Journal of Econometrics**, v. 54, n. 1–3, p. 159–178, 1992.
- LI, Songran; SHAO, Qinglong. Greening the finance for climate mitigation: An ARDL–ECM approach. **Renewable Energy**, v. 199, p. 1469-1481, 2022.
- LÜTKEPOHL, H. **New introduction to multiple time series analysis**. New York: Springer, 2007.
- MARTINS, Tailon et al. Fossil fuels consumption and carbon dioxide emissions in G7 countries: Empirical evidence from ARDL Bounds Testing approach. **Environmental Pollution**, v. 291, p. 118093, 2021.
- MATEM, F. Ferramentas matemáticas. v. 1, p. 1–141, 2017.
- MENEGAKI, Angeliki N. The ARDL method in the energy-growth nexus field; best implementation strategies. **Economies**, v. 7, n. 4, p. 105, 2019.
- NAGAWA, V.; WASSWA, F.; BBAALE, E. Determinants of gross domestic savings in Uganda: an autoregressive distributed lag (ARDL) approach to cointegration. **Journal of Economic Structures**, v. 9, n. 1, p. 1–19, 2020.
- NARAYAN, S.; NARAYAN, P. K. Determinants of demand for Fiji’s exports: An empirical investigation. **Developing Economies**, v. 42, n. 1, p. 95–112, 2004.
- NKORO, Emeka et al. Autoregressive Distributed Lag (ARDL) cointegration technique: application and interpretation. **Journal of Statistical and Econometric methods**, v. 5, n. 4, p. 63-91, 2016.
- ODHIAMBO, N. M. Energy consumption and economic growth nexus in Tanzania: An ARDL Bounds Testing approach. **Energy Policy**, v. 37, n. 2, p. 617–622, 2009.
- PESARAN, M. H. et al. Pooled Mean Group Estimation of Dynamic Heterogeneous Panels. **Journal of the American Statistical Association**, v. 94, n. 446, p. 621–634, 1999.
- PESARAN, M. H.; SHIN, Y.; SMITH, R. J. Bounds Testing approaches to the analysis of level relationships. **Journal of Applied Econometrics**, v. 16, n. 3, p. 289–326, 2001.
- PHILLIPS, P. C. B.; PERRON, P. Testing for a unit root in time series regression. **Biometrika**, v. 75, n. 2, p. 335–346, 1988.
- PORTUGAL, M. S. O economista e a ciência econômica nos anos recentes. In: CARRION, B, K. et al. **O ensino de economia na UFRGS**. Porto Alegre: Ed. UFRGS, 2000.

RAHMAN, Habib-ur et al. Role of economic growth, financial development, trade, energy and FDI in environmental Kuznets curve for Lithuania: evidence from ARDL Bounds Testing approach. **Engineering Economics**, v. 31, n. 1, p. 39-49, 2020.

ReView, v. 38, n. 2, p. 215–227, 2009.

SARKER, B.; KHAN, F. Nexus between foreign direct investment and economic growth in Bangladesh: an augmented autoregressive distributed lag Bounds Testing approach. **Financial Innovation**, v. 6, n. 1, 2020.

SIKDER, Mukut et al. The integrated impact of GDP growth, industrialization, energy use, and urbanization on CO2 emissions in developing countries: evidence from the panel ARDL approach. **Science of the Total Environment**, v. 837, p. 155795, 2022.

TANG, C. F. An examination of the government spending and economic growth Nexus for Malaysia using the leveraged bootstrap simulation approach. **Global Economic**.

WALDMAN, D. M. A note on algebraic equivalence of White's test and a variation of the Godfrey/Breusch-Pagan test for heteroscedasticity. **Economics Letters**, v. 13, n. 2–3, p. 197–200, 1983.

WU, C. F. et al. The nexus of financial development and economic growth across major Asian economies: Evidence from bootstrap ARDL testing and machine learning approach. **Journal of Computational and Applied Mathematics**, v. 372, p. 112660, 2020.

XIONG, Jinhui; XU, Deyi. Relationship between energy consumption, economic growth and environmental pollution in China. **Environmental Research**, v. 194, p. 110718, 2021.

ANEXO A – Dados originais utilizados no estudo prático da metodologia ARDL

Data	EXPAP	EXPOM	PIB	Data	EXPAP	EXPOM	PIB
2000.01	450137951,0	117208941,0	92576,6	2009.10	2982153263,0	825663924,0	301895,9
2000.02	431359210,0	130585231,0	91770,4	2009.11	2418088330,0	853725037,0	305048,8
2000.03	472458438,0	111637972,0	92579,9	2009.12	2764958388,0	904126919,0	313522,8
2000.04	434234147,0	111397922,0	91376,2	2010.01	2380297713,0	721113539,0	288972,8
2000.05	695881988,0	135449418,0	98727,0	2010.02	2473182728,0	714501069,0	285723,2
2000.06	735424319,0	140321651,0	102685,4	2010.03	3768812648,0	896821334,0	311651,6
2000.07	678260616,0	168382981,0	103410,4	2010.04	4018511012,0	834711461,0	307083,5
2000.08	667320086,0	248016459,0	105177,8	2010.05	5232207560,0	1065693910,0	315988,4
2000.09	482282679,0	190426254,0	100307,6	2010.06	4847275730,0	1203829600,0	321023,2
2000.10	464637733,0	197878060,0	106951,1	2010.07	5121036938,0	1449874667,0	332454,2
2000.11	438642572,0	168751816,0	107678,0	2010.08	5515874416,0	1295305517,0	334225,6
2000.12	533791344,0	135128438,0	105851,6	2010.09	5504977448,0	1479142377,0	331255,9
2001.01	568414098,0	190457365,0	102530,7	2010.10	5396888598,0	1338021690,0	344963,8
2001.02	340565934,0	145479477,0	101635,3	2010.11	4584632229,0	1210620822,0	356707,5
2001.03	508649519,0	174777820,0	108303,8	2010.12	4683012994,0	1322974917,0	355797,4
2001.04	489582520,0	141591960,0	107572,0	2011.01	3668910220,0	1087377576,0	333255,6
2001.05	707358307,0	212081354,0	111202,2	2011.02	4115195698,0	995393514,0	334982,0
2001.06	673086777,0	234063878,0	104949,4	2011.03	5168810185,0	1092930525,0	347879,6
2001.07	633305960,0	219503892,0	110758,9	2011.04	5717958831,0	1118013644,0	349049,3
2001.08	758291887,0	261425300,0	113064,7	2011.05	6914775907,0	1331058397,0	366256,2
2001.09	633586383,0	298184518,0	108700,8	2011.06	7724121004,0	1298354833,0	370951,2
2001.10	589873003,0	263501112,0	116139,0	2011.07	6648481453,0	1619826816,0	373143,3
2001.11	527356500,0	260671623,0	117882,0	2011.08	7794909716,0	2060980013,0	376769,3
2001.12	508578344,0	227227642,0	113016,7	2011.09	7494213873,0	1582233299,0	361724,6
2002.01	452748459,0	176315716,0	112374,8	2011.10	6682723587,0	1421644452,0	378491,0
2002.02	438871319,0	176337858,0	111477,1	2011.11	6352201508,0	1468818875,0	389560,8
2002.03	529308236,0	208476658,0	118444,7	2011.12	6347840042,0	1292393655,0	391595,1
2002.04	533039365,0	144695555,0	120385,9	2012.01	3807514343,0	987688845,0	367215,4
2002.05	521455012,0	173530092,0	123552,5	2012.02	3870330614,0	908753220,0	367177,3
2002.06	512871739,0	138488389,0	123424,4	2012.03	6256266908,0	1207045851,0	392996,5
2002.07	957333790,0	339734118,0	126856,6	2012.04	6021142929,0	961875372,0	381795,3
2002.08	879534434,0	236813266,0	127800,1	2012.05	7736471488,0	1242691087,0	400281,3
2002.09	1292304183,0	395878445,0	125137,8	2012.06	6221650629,0	1103843983,0	398714,5

Explorando relações causais de curto e longo prazo em contextos práticos

2002.10	950602132,0	416974639,0	133125,4	2012.07	6162699257,0	1523973609,0	414617,4
2002.11	686161670,0	264930384,0	135966,6	2012.08	6690159726,0	1604529178,0	419906,3
2002.12	672464350,0	259703942,0	130241,2	2012.09	5913136230,0	1642178722,0	393524,7
2003.01	668130222,0	327400198,0	127177,5	2012.10	6084814018,0	1699181863,0	422672,1
2003.02	626695843,0	240210159,0	131373,6	2012.11	5931065332,0	1405959550,0	423816,4
2003.03	747246696,0	204200836,0	138690,5	2012.12	5831712256,0	1246610546,0	423195,9
2003.04	927354828,0	222897226,0	141388,1	2013.01	3966920482,0	1209167755,0	414131,8
2003.05	1222500142,0	259523709,0	139605,8	2013.02	4222352304,0	1021827512,0	398645,4
2003.06	1015071370,0	201676293,0	137993,4	2013.03	6011437542,0	1197550892,0	427409,8
2003.07	1116131835,0	307258693,0	145970,6	2013.04	7260307785,0	1028130089,0	438856,8
2003.08	993767834,0	297175756,0	144819,4	2013.05	8115762091,0	1090303355,0	439054,2
2003.09	1160124519,0	424880791,0	148559,8	2013.06	7255539595,0	895861519,0	442857,0
2003.10	1222033112,0	441932643,0	154925,9	2013.07	6738999909,0	1056117584,0	458458,9
2003.11	872536257,0	326990736,0	153644,4	2013.08	7348601062,0	1275454124,0	452862,2
2003.12	928098933,0	358861005,0	153801,4	2013.09	6759227984,0	1336770078,0	438766,7
2004.01	948735630,0	288396471,0	144558,6	2013.10	6203594683,0	1364041960,0	466166,0
2004.02	764091511,0	276234232,0	142861,3	2013.11	5592358218,0	1372941170,0	465693,8
2004.03	1246875067,0	405382744,0	157363,5	2013.12	5947148222,0	1264659869,0	473552,5
2004.04	996940756,0	268819606,0	156953,9	2014.01	4341332306,0	1060670275,0	455935,0
2004.05	1327631259,0	403917922,0	159498,9	2014.02	5029756094,0	1015660750,0	450358,8
2004.06	1542204700,0	625442458,0	165342,2	2014.03	6660717934,0	980911713,0	462159,8
2004.07	1306807420,0	429220626,0	171370,9	2014.04	6727922246,0	1028265625,0	468767,5
2004.08	1411496552,0	565404838,0	169178,9	2014.05	7329845974,0	1054652056,0	473347,1
2004.09	1460941013,0	460244876,0	164702,5	2014.06	6987172728,0	1062318439,0	458516,5
2004.10	1154224550,0	350446382,0	170536,5	2014.07	7330526528,0	1235844607,0	481994,0
2004.11	1035456880,0	333043714,0	176921,5	2014.08	6079261573,0	1318873452,0	477052,9
2004.12	1181379917,0	400182186,0	178462,4	2014.09	5879895286,0	1408914916,0	476520,6
2005.01	974788722,0	347518340,0	163540,1	2014.10	4603733957,0	1324461569,0	493304,7
2005.02	988812432,0	371268533,0	160701,6	2014.11	3860530013,0	1268704897,0	489484,4
2005.03	1317806172,0	451788342,0	175468,7	2014.12	4543404398,0	1322181909,0	499867,7
2005.04	1413977516,0	416628551,0	177179,0	2015.01	3544737476,0	1093003680,0	472913,9
2005.05	1293002145,0	457015930,0	177496,7	2015.02	3151859953,0	852721036,0	460156,7
2005.06	1680709114,0	492203946,0	180881,8	2015.03	5452939272,0	1076602822,0	501752,2
2005.07	1872626392,0	564011106,0	184073,7	2015.04	4983198685,0	953801735,0	486614,6
2005.08	1642729558,0	703120807,0	187246,6	2015.05	5813883284,0	1146698447,0	483239,7

Explorando relações causais de curto e longo prazo em contextos práticos

2005.09	1678898388,0	549898831,0	181538,9	2015.06	7337457219,0	1231733814,0	486647,5
2005.10	1568715599,0	470528207,0	189183,0	2015.07	6001258178,0	1374429220,0	502275,2
2005.11	1687448333,0	462119651,0	194794,5	2015.08	4684610310,0	1182061317,0	492505,7
2005.12	1874330642,0	538772689,0	198480,0	2015.09	5342624573,0	1099196320,0	496004,7
2006.01	1398623298,0	437130605,0	185564,8	2015.10	4932708065,0	1133032602,0	518828,9
2006.02	1121941558,0	509260625,0	178482,2	2015.11	4074604085,0	948363055,0	513819,8
2006.03	1729164708,0	537134691,0	190223,3	2015.12	4723595746,0	1263702567,0	521918,7
2006.04	1495563384,0	409509643,0	185030,6	2016.01	3132170253,0	957540126,0	490284,0
2006.05	1524047594,0	539617850,0	197874,3	2016.02	4022428080,0	999214302,0	491011,7
2006.06	1912555406,0	658915787,0	199071,9	2016.03	5624596152,0	1211519107,0	516985,9
2006.07	2207029029,0	867977839,0	206974,4	2016.04	6018855747,0	999671403,0	508058,7
2006.08	2055330365,0	788186800,0	209818,0	2016.05	6287062938,0	977584873,0	513267,5
2006.09	1967895742,0	663658610,0	201055,4	2016.06	5879314609,0	991173631,0	536459,3
2006.10	1780263162,0	816489220,0	214271,7	2016.07	5271351482,0	1114937325,0	532947,8
2006.11	1627169420,0	772283110,0	219724,2	2016.08	4844011213,0	1552336832,0	534761,8
2006.12	1727997797,0	857798682,0	221359,3	2016.09	4583214293,0	1210904327,0	509975,0
2007.01	1502265394,0	633781417,0	211130,7	2016.10	4012970935,0	1019070629,0	525162,7
2007.02	1400846602,0	562267207,0	202704,1	2016.11	5259131351,0	1101688973,0	541530,7
2007.03	2155541028,0	756819259,0	217588,9	2016.12	4332301685,0	1252835323,0	565780,5
2007.04	1958872258,0	606837184,0	215128,8	2017.01	4608299048,0	1077300532,0	526564,7
2007.05	2195146031,0	725147846,0	226537,9	2017.02	5202779423,0	989165968,0	514120,5
2007.06	2128750313,0	719517034,0	228988,6	2017.03	7747161361,0	1277253087,0	544312,9
2007.07	2397998083,0	910805487,0	233824,1	2017.04	7075112466,0	1183403794,0	525238,1
2007.08	2604070613,0	873540043,0	235019,1	2017.05	7454364618,0	1139988552,0	548887,7
2007.09	2277336007,0	738478223,0	223002,7	2017.06	6753276986,0	1503354211,0	556787,6
2007.10	2401192904,0	728555133,0	241939,4	2017.07	6704992208,0	1380634674,0	557458,2
2007.11	2001930338,0	661967958,0	241938,4	2017.08	6515030574,0	1549010846,0	555578,7
2007.12	1957609011,0	630086125,0	242460,2	2017.09	6151326290,0	1644017371,0	528871,2
2008.01	1952240324,0	716324784,0	237247,7	2017.10	5997988638,0	1596200405,0	549304,7
2008.02	2070234136,0	656609814,0	232680,4	2017.11	4772355419,0	1310082347,0	566209,3
2008.03	1957832490,0	602217985,0	242124,4	2017.12	5476476251,0	1310859374,0	588892,8
2008.04	2865991769,0	656538011,0	248793,8	2018.01	4816863225,0	1230697565,0	555644,6
2008.05	4245162447,0	841142196,0	254936,9	2018.02	4860637317,0	1082362204,0	528905,5
2008.06	3463206029,0	1080309669,0	265791,2	2018.03	7540329108,0	1264797121,0	560120,7
2008.07	4494874733,0	1060373296,0	278095,6	2018.04	7667529317,0	918663185,0	559359,8

Explorando relações causais de curto e longo prazo em contextos práticos

2008.08	4274173627,0	1025539109,0	269235,6	2018.05	8617753385,0	1193961536,0	547016,5
2008.09	3893049330,0	1069021138,0	265271,2	2018.06	7630161446,0	1072382380,0	580697,8
2008.10	3553867897,0	1015242219,0	280522,5	2018.07	10033915784,0	1245055329,0	583054,8
2008.11	2847919033,0	848427271,0	270698,8	2018.08	7967976945,0	1469947595,0	582756,7
2008.12	2338289261,0	894909926,0	264404,8	2018.09	6994672603,0	1396332266,0	556776,6
2009.01	2320053796,0	514499647,0	249934,4	2018.10	8041553070,0	1223467128,0	591983,9
2009.02	2114229557,0	481412471,0	244024,5	2018.11	7806254827,0	1213173300,0	593926,9
2009.03	2943730748,0	756574381,0	262181,7	2018.12	7779888397,0	1226856060,0	603155,2
2009.04	3768649845,0	760439753,0	259563,5	2019.01	5985563027,0	1095023511,0	578452,6
2009.05	3355295300,0	766471639,0	268324,0	2019.02	5896567554,0	1108554771,0	567999,2
2009.06	4458611711,0	1037188098,0	275701,2	2019.03	7203518585,0	1305516384,0	579230,2
2009.07	3584797005,0	846518106,0	285444,2	2019.04	7721763331,0	1278912593,0	592915,6
2009.08	3323852152,0	923357862,0	284240,4	2019.05	7998636173,0	1467722156,0	604560,4
2009.09	3432532196,0	944146022,0	283157,9	2019.06	7792851571,0	1226623455,0	598318,6

SOBRE OS AUTORES E AS AUTORAS

Tailon Martins

Engenheiro de Produção pela UFSM, Mestre em Engenharia de Produção pela UFSM e Doutorando em Engenharia de Produção pela mesma instituição, com ênfase na linha de Métodos Quantitativos para Tomada de Decisão. Atua em pesquisas aplicadas com foco em modelos econométricos e análise multivariada. É Professor do curso de Engenharia Logística na Universidad Tecnológica (UTEC), Instituto Tecnológico Regional Norte (ITRN), Uruguai, com atuação nas áreas de serviços logísticos multimodais e globais de exportação e importação.

Renan Mituso Ueda

Engenheiro de Produção pela Universidade Federal da Grande Dourados (UFGD), Mestre e Doutor em Engenharia de Produção pela Universidade Federal de Santa Maria (UFSM). Atualmente é Professor Adjunto na Universidade Federal de Mato Grosso do Sul (UFMS), câmpus de Nova Andradina. Suas áreas de interesse incluem previsão de demanda, modelagem estatística, métodos quantitativos aplicados à tomada de decisão e planejamento e controle da produção.

Adriano Mendonça Souza

Graduado em Matemática, Mestre e Doutor em Engenharia de Produção pela UFSM, com estágios de pós-doutorado realizados no ISCTE-IUL (Portugal) e na Texas A&M University (EUA). É Professor Titular da UFSM. Suas áreas de atuação incluem estatística aplicada, controle de qualidade, análise de séries temporais, análise multivariada, pesquisa operacional, gerência da produção e avaliação de políticas públicas com uso de modelos econométricos.

Francisca Mendonça Souza

Graduada em Matemática Aplicada Computacional, Mestre em Engenharia de Produção pela UFSM e Doutora em Estatística e Análise de Dados pelo Instituto Universitário de Lisboa (ISCTE-IUL). Atua como pesquisadora nas áreas de estatística aplicada, controle de qualidade, análise de séries temporais, análise multivariada, econometria, pesquisa operacional e gerência da produção. Desenvolve estudos voltados à aplicação de ferramentas estatísticas e análise exploratória com enfoque em qualidade e tomada de decisão.

Bianca Reichert

Engenheira de Produção, Mestre e Doutora em Engenharia de Produção pela Universidade Federal de Santa Maria (UFSM). Possui experiência profissional na indústria metalmeccânica e no setor de energia eólica, com ênfase em gestão da produção, análise de dados e controle da qualidade. Suas linhas de pesquisa abrangem séries temporais, econofísica e modelagem por fluidodinâmica, com foco em geração de energia, fontes renováveis e transição energética.

Cristiano Ziegler

Graduado em Planejamento e Gestão para o Desenvolvimento Rural pela Universidade Federal do Rio Grande do Sul (UFRGS) e em Engenharia Mecânica pela Faculdade Horizontina (FAHOR). É Mestre e Doutor em Engenharia de Produção pela Universidade Federal de Santa Maria (UFSM). Atua em temáticas interdisciplinares que envolvem engenharia de produção, desenvolvimento rural, gestão de processos produtivos e inovação tecnológica.

TAILON MARTINS
ADRIANO M. SOUZA
FRANCISCA M SOUZA
CRISTIANO ZIEGLER
RENAN M. UEDA
BIANCA REICHERT

**EXPLORANDO RELAÇÕES
CAUSAIS DE CURTO E LONGO
PRAZO EM CONTEXTOS
PRÁTICOS:
UMA ANÁLISE APLICADA COM
MODELOS ARDL**