

## DETERMINANTES ECONÔMICOS E SOCIAIS DE IMPACTO NAS EMISSÕES DE CO<sub>2</sub>: O CASO DA AMÉRICA LATINA.

Fillipe Guedes Soares<sup>1</sup>

### Resumo

Aliar progresso econômico com desenvolvimento sustentável tem sido um dos principais desafios para as sociedades modernas. A emissão de gases de efeito estufa, em geral, têm sido prejudiciais em uma série de aspectos como se pode perceber no acontecimento de chuvas ácidas, mudança na incidência de chuvas, desequilíbrio da temperatura através do aumento de sua média e acidificação dos oceanos. Este trabalho propõe, portanto, estimar o modelo STIRPAT para a região da América Latina motivado pela pequena quantidade de estudos que analisam especificamente esta localidade e, para isto, foi utilizado um modelo de mínimos quadrados ordinários com dados agrupados (*Pooled OLS*) para 19 países da região no período de 2000-2014. Dentre os resultados encontrados neste trabalho, se observa que o consumo de energia advindo de combustíveis fósseis possui forte influência no que tange o aumento/redução de emissões de CO<sub>2</sub> dentro da região analisada, adicionalmente o PIB *per capita* e população também se mostram positivamente correlacionados com as emissões, destacando-se para o fato de que a última possui maior impacto dentre as demais variáveis.

**Palavras-chave:** desenvolvimento sustentável, efeito estufa, STIRPAT, América Latina.

### Abstract

Combining economic progress and sustainable development has been one of the major challenges for modern societies. The emission of greenhouse gases in general has been harmful in a variety of aspects, as can be seen in the occurrence of acid rain, precipitation patterns changes, temperature imbalance and oceans acidification. Therefore, this paper proposes estimates of the STIRPAT model for Latin America motivated by a small number of studies that analyze this area in specific and, for this purpose, a pooled ordinary least squares model was estimated for 19 Latin American countries in the period between 2000-2014. Among the findings are that the energy consumption from fossil fuels has a strong influence on the increase/reduction of CO<sub>2</sub> emissions within the analyzed region. In addition, GDP *per capita* and population were positive correlated with the emissions, highlighting the fact that the latter has the greatest impact among the other variables.

**Keywords:** sustainable development, greenhouse effect, STIRPAT, Latin America.

### Introdução

A ampliação das discussões acerca dos impactos ambientais do crescimento econômico foi impulsionada através do trabalho de Kuznets (1955), que mostrou que a relação entre crescimento e distribuição de renda teria o formato de U-invertido. Na década de 90, Kuznets passou a ser referência para explicar a relação de como a poluição ambiental evolui em razão do crescimento econômico. O formato da curva é explicado

---

<sup>1</sup> Universidade do Estado do Rio de Janeiro / PPGCE

através de dois argumentos: a porção ascendente reflete o progresso natural do desenvolvimento econômico, passando-se de uma economia agrária “limpa” para uma economia industrial “poluída”, enquanto a porção descendente seria o mecanismo das economias desenvolvidas exportarem processos de produção intensivos em poluição para economias menos desenvolvidas. (ARRAES; DINIZ; DINIZ, 2006)

Para Solomon (2007), cerca de 90% das mudanças climáticas observadas resultam das diferentes atividades humanas, em particular àquelas ligadas a queima de combustíveis fósseis, produção agropecuária e desmatamento. Observa-se que o aumento das emissões reflete os pressupostos subjacentes do crescimento econômico: com o aumento do PIB e da demanda de energia, especialmente em economias de rápido crescimento, como Índia e China, as emissões de poluentes atmosféricos aumentam.

As emissões globais de CO<sub>2</sub> da combustão de combustíveis fósseis aumentaram consideravelmente desde 1950. Em 2013, as emissões globais de carbono foram de 9.776 bilhões de toneladas ou Gigatons (Gt) de carbono. A queima de carvão é atualmente responsável por cerca de 42% das emissões globais de carbono, enquanto os combustíveis líquidos (principalmente o petróleo) são a fonte de outros 33, a combustão do gás natural representa 19 %, com 6% de produção de cimento e queima de gás. (HARRIS; ROACH; CODUR, 2007)

Os impactos das emissões de carbono nos países da América Latina podem ser sentidos através de fenômenos de diversas naturezas, tais como: inundações, chuvas torrenciais, deslizamentos de terras, danos aos corais, acidificação dos oceanos e escassez de água em determinadas regiões.

Na literatura acerca dos impactos de variáveis sociais e econômicas na determinação da emissão de CO<sub>2</sub>, é possível verificar que existe variedade de referenciais teóricos que se utilizam de abordagens quantitativas, fazendo o uso de matemática e estatística para formulação e estimação de modelos. Um dos modelos mais conhecidos sobre o tema vem de Ehrlich; Holdren et al. (1971) que especificaram que os impactos no ambiente através do uso do produto multiplicativo de três forças: tamanho da população, afluência (consumo ou produção per capita) e tecnologia. Este modelo acabou ficando conhecido como identidade IPAT.

$$I = P (\text{population}) \times A (\text{affluences}) \times T (\text{technology}) \quad (1)$$

A identidade IPAT, contudo, possui algumas limitações. Assim como equações contábeis, elas não permitem testes de hipóteses, uma vez que os valores conhecidos de alguns termos determinam o valor do termo faltante. Além disso, adiciona-se o fato de que se assume proporcionalidade na relação entre os fatores, ou seja, modelos que assumem uma dobra no número da população, acarretará no dobro de impactos, por exemplo. (YORK; ROSA; DIETZ, 2003)

Para superar a limitação anteriormente citada, Dietz e Rosa (1997) reformularam o IPAT em um modelo estocástico, chamando-o de STIRPAT (*Stochastic Impacts by Regression on Population, Affluence and Technology*), que pode ser resumido da seguinte forma:

$$I_i = aP_i^b A_i^c T_i^d e_i \quad (2)$$

Onde a constante  $a$  escala o modelo,  $b$ ,  $c$  e  $d$  são expoentes de  $P$ ,  $A$  e  $T$ , respectivamente e que devem ser estimados, e o termo  $e$  é o erro resídual da equação. O subscrito  $i$  indica que as quantidades de cada variável se diferem de acordo com cada unidade observacional.

O STIRPAT, por sua vez, não é uma equação contábil. Se trata de um modelo estocástico, onde são permitidas as realizações de testes empíricos, sendo assim, existe um campo maior para realização do aprofundamento da pesquisa quantitativa dada a natureza do modelo.

### Objetivo

Uma vez que a literatura sobre o tema carece de estudos específicos sobre a região da América Latina, o objetivo do presente trabalho é estimar os principais fatores de impacto nas emissões de CO<sub>2</sub> para os países da referida região através do modelo STIRPAT clássico e, com isso, comparar os resultados com os que existem sobre o tema para outras regiões.

### Material e Método

Dados em painel ou dados longitudinais são tipicamente caracterizados por dados que contém observações em séries de tempo de um número de indivíduos. Com isso, as observações de dados em painel envolvem pelo menos duas dimensões, são elas representadas pelo subscrito  $i$  e  $t$ . (HSIAO, 2007)

Ainda segundo Hsiao (2007), modelos que utilizam dados em painel possuem uma série de vantagens, dentre elas: inferência mais acurada dos parâmetros, uma vez que contém mais graus de liberdade e menor incidência de multicolinearidade, ou seja, baixa probabilidade das variáveis serem correlacionadas entre si; maior capacidade em captar a complexidade do comportamento humano do que modelos em seções-transversais ou séries temporais, pois pode testar hipóteses comportamentais mais complicadas; simplificação da computação, dada a disponibilidade dos dados em painel.

Visando cumprir o objetivo proposto no presente trabalho, o método de análise proposto se baseia na estimação do modelo STIRPAT através do modelo de dados em painel linear sem efeitos heterogêneos, conhecido na literatura econométrica como *Pooled OLS*. Tal estimador pode ser representado através da seguinte equação:

$$y_{it} = \alpha + \beta^T x_{it} + \varepsilon_{it} \quad (3)$$

Onde  $i$  denota as unidades de dados-transversais, nesse caso, os países da América Latina e  $t$  se caracteriza pelos anos presentes na análise,  $\varepsilon_{it}$  é o termo de distúrbios aleatórios na equação,  $y_{it}$  e  $x_{it}$  são, respectivamente, as variáveis dependente e independentes do modelo,  $\alpha$  é o intercepto que é comum para todos os países e todas as unidades de tempo e, por último,  $\beta$  corresponde ao vetor coluna K-dimensional de coeficientes que serão estimados.

Dos 20 países que compõem o território da América Latina, a única exceção que se encontra neste trabalho é Cuba, dada a indisponibilidade de dados essenciais para a realização do estudo. Portanto, foram incluídos na análise 19 países, são eles: Argentina, Bolívia, Brasil, Chile, Colômbia, Costa Rica, República Dominicana, Equador, Guatemala, Honduras, Haiti, México, Nicarágua, Panamá, Peru, Paraguai, El Salvador, Uruguai e Venezuela.

As variáveis utilizadas para a realização deste trabalho são de publicação do Banco Mundial, obtidas através do pacote WDI no R e foram as seguintes:

Variável Dependente:

$CO_2$  - Emissões de  $CO_2$  (kilotoneladas)

Variáveis Independentes:

$POP$  - População Total (em número de habitantes)

$ERN$  - Consumo de energia renovável (% do total de consumo de energia final)

*ECF* - Consumo de Energia de Combustíveis Fósseis (% do total)

*PIB* - PIB per capita PPP (convertido em dólares constantes de 2011)

Em consonância com a literatura acerca do modelo STIRPAT, da equação (2) tem-se que as variáveis *I*, *P*, *A*, são medidas pelos dados que formam as variáveis *CO<sub>2</sub>*, *POP*, *PIB*, respectivamente, tais como são caracterizadas acima. Sobre a tecnologia no modelo STIRPAT, representada por *T*, ela representa um amplo termo que pretende refletir fatores que afetam as emissões e, para esta variável são usadas duas *proxies*, as quais, *ERN* e *ECF*. Deste modo, a equação a ser estimada pode ser expressa da seguinte maneira:

$$\ln CO_{2it} = \alpha + \beta_1 (\ln POP_{it}) + \beta_2 (\ln ERN_{it}) + \beta_3 (\ln ECF_{it}) + \beta_4 (\ln PIB_{it}) + u_{it} \quad (4)$$

Onde, mais uma vez, *i* denota as unidades de dados-transversais e *t* se caracteriza pelos anos presentes na análise,  $\alpha$  é o termo constante do modelo, o conjunto de letras beta ( $\beta_1$ ,  $\beta_2$ ,  $\beta_3$  e  $\beta_4$ ) representa os parâmetros de cada uma das variáveis explicativas a serem estimados,  $u_{it}$  comporta os resíduos da regressão e  $\ln$  indica que todas as variáveis estão sendo expressas em logaritmo natural.

Os dados estão disponíveis entre os anos de 2000 até 2014 em um formato de painel não-balanceado, ou seja, quando uma ou mais unidades não está presente em todos os períodos da base de dados. No caso deste trabalho, a única informação faltante foi o dado de Consumo de Energia de Combustíveis Fósseis para a Venezuela no ano de 2014, ademais, todas as outras informações para todos os países analisados estão disponíveis.

Um outro fator que deve ser levado em consideração quando se trabalha com o tipo de modelagem proposta neste artigo é a questão da estacionaridade das variáveis. Uma variável não é estacionária quando sua média, variância e/ou covariância mudam ao longo do tempo, caso contrário, ela é considerada estacionária. Quando variáveis não são estacionárias, existe uma grande tendência de que as relações estimadas sejam espúrias, isto é, por mais que os resultados da regressão mostrem que as variáveis são integradas, na verdade, elas são independentes uma das outras.

Como o período temporal que envolve este trabalho não é considerado longo,  $T = 15$  anos, interpretar se as séries são estacionárias pode não ser muito claro. Entretanto, em Liddle (2015), foram feitos testes de estacionaridade em bases de dados com séries temporais muito mais extensas, onde é obtido um resultado altamente robusto de  $I(1)$  para as variáveis que englobam o modelo STIRPAT, o que quer dizer que as variáveis precisam

ser diferenciadas uma vez para se tornarem estacionárias. Portanto, tal método de diferenciação das variáveis foi realizado.

O fato de tirar a primeira diferença das variáveis automaticamente implica que se está abrindo mão de uma unidade de tempo, ou seja, será considerado o período compreendido entre 2001-2014.

O software R cumpliu fundamental importância na realização deste trabalho. Primeiramente, toda a base de dados foi obtida através do pacote WDI, onde é possível encontrar dados referentes aos Indicadores de Desenvolvimento Mundial (*World Development Indicators*) do Banco Mundial; tanto a ordenação dos dados para serem utilizados em formato de painel quanto as estimativas da equação (4) e seus erros padrão corrigidos foram obtidos através da utilização do pacote plm; transformações nos dados tais como aplicação de log e primeiras-diferenças também foram realizadas através de comandos no software; o teste nos resíduos que aparece em seguida na Tabela 1 é obtido por meio da função lm; e o Gráfico 1 foi gerado por meio do pacote ggplot2.

## Resultados e Discussão

Visando obter um estimador não-viesado e eficiente, antes de reportar os resultados da estimação da equação (4) foram aplicados testes para verificação da presença de correlação serial, dependência *cross-section* e endogeneidade no modelo.

Sobre a correlação serial, se os resíduos da regressão são correlacionados em série, então tem-se que os resultados produzirão estimadores ineficientes. Para testar a correlação serial, foi rodada uma regressão OLS auxiliar que envolve regredir os resíduos ( $u_{it}$ ) da estimação da equação (4) contra um *lag* destes mesmos resíduos ( $\Delta u_{it-1}$ ). Caso o resultado seja estatisticamente significativo no termo residual com um *lag* ( $\Delta u_{it-1}$ ), isto pode mostrar evidência de correlação de primeira ordem. (LIDDLE, 2015)

**Tabela 1 – Regressão para verificação de correlação serial de primeira ordem**

<b>Variável</b>	
<b>Dependente:</b>	
$\Delta u_{it}$	
$u_{it-1}$	- 0.146 *
	(0.061)

<i>Constante</i>	0.001
	(0.004)

Fonte: Elaboração própria com base nos resultados da regressão.

Notas: Os resíduos são obtidos das variáveis em primeira diferença logarítmica, conforme especificado. \* indica significância estatística ao nível de 0.05.

O resultado produzido pela regressão é significativo estatisticamente, indicando, portanto, que há indícios para acreditar na presença de correlação serial de primeira ordem no modelo.

Também foi estimada uma regressão de mínimos quadrados em dois estágios (*Two-Stage Least Squares*) com variáveis instrumentais selecionadas a partir de inclusão de *lags* tanto nas variáveis explicativas quanto na variável dependente através da função ivreg do pacote AER. O teste de Wu-Hausman indicou que não foram encontradas relações entre as variáveis e o termo de erro, o que corrobora para acreditar que não existem variáveis endógenas presentes no modelo.

Na presença de erros não-esféricos, ou seja, havendo a possibilidade da variância dos erros não ser constante e/ou dependência *cross-section* e/ou efeitos de grupo (*cluster effects*), o método em questão fornece estimativas ineficientes dos coeficientes e erros padrão se tornam viesados. Levando isto em conta, Beck e Katz (1995) desenvolveram um método que ficou conhecido como Erros Padrão Corrigidos (*Panel Corrected Standard Errors – PCSE*), que é capaz de produzir estimativas mais precisas dos erros. Reed e Webb (2010) mostram que o método PCSE fornece um bom desempenho na estimativa do erro padrão quando o número de N é similar ao de T, neste caso, quando o número de países é próximo do número de anos.

Dados os testes realizados até aqui, por fim, a equação (4) é estimada e seus resultados aparecem na tabela a seguir:

**Tabela 2 – Modelo STIRPAT para países da América Latina.**

<b>Variável Dependente:</b>	
	<b>CO2</b>
<i>Constante</i>	0.007
	(0.011)
<i>POP</i>	1.191 ·

		(0.713)
<i>ERN</i>		-0.100
		(0.073)
<i>ECF</i>		0.816 ***
		(0.117)
<i>PIB</i>		0.224 *
		(0.105)
<hr/>		
Observações		265
<i>R</i> <sup>2</sup>		0.31
<i>R</i> <sup>2</sup> ajustado		0.30
Estatística F		29.99 ***
CD de Pesaran		-1.01

Fonte: Elaboração própria com base nos resultados do modelo.

Notas: Conforme foi especificado, todas as variáveis se encontram em primeira diferença logarítmica. Os valores em parênteses são os desvios padrão corrigidos (*Panel Corrected Standard Errors*). \*\*\*, \* e · indicam significância estatística aos níveis de 0, 0.05 e 0.10, respectivamente.

A partir dos resultados apresentados na tabela acima, é possível perceber que a variável de consumo de energia de combustíveis fósseis tem tido um impacto fundamental no que tange as emissões de CO<sub>2</sub> nos países da América Latina. No caso, um maior consumo de energia advindo de combustíveis fósseis, tendo como principais fontes o petróleo, gás natural e carvão mineral, possui um impacto positivo e significativo no aumento de emissões.

A região da América Latina é marcada pela forte heterogeneidade no sentido da matriz de produção e distribuição energética. A área é um território dividido entre o petróleo e a energia verde e isto é possível de ser observado, pois países como Costa Rica, Brasil, Uruguai, Chile e México têm sido reconhecidos pelos seus esforços em disponibilizar uma matriz energética mais limpa, já outros países como Bolívia, Peru e Equador a disseminação de energia renovável é algo muito menos trivial uma vez que contam com subsídios para o uso de combustível fóssil.

Outra variável que mostra uma correlação positiva e significativa no modelo estimado é o PIB *per capita*. Sendo assim, espera-se que quando exista um aumento (diminuição) no PIB per capita, tudo o mais constante, haja um aumento (diminuição) na emissão de carbono.

Dentre as explicações que podem ser encontradas para justificar tal comportamento para a variável PIB *per capita*, pode-se pensar que para países de baixa renda, a diminuição da poluição pode ser indesejável, pois a melhoria de rendimentos vinda do progresso econômico faz com que indivíduos ampliem o atendimento de suas necessidades básicas de consumo. Isto acontece até que se chegue ao ponto onde, atingido determinado nível de renda, os indivíduos passam a demandar mais qualidade ambiental. Essa explicação é a presente na teoria da Curva de Kuznets Ambiental.

Uma maneira alternativa de se pensar acerca do impacto do PIB *per capita* nas emissões de CO<sub>2</sub> para os países da América Latina é oriunda da competição internacional, onde esta leva inicialmente a um aumento no dano ambiental até o ponto em que os países desenvolvidos começam a reduzir seu impacto ambiental, mas também terceirizam atividades poluentes para países mais pobres. (STERN, 2004)

Acerca da variável população, há muita divergência na literatura sobre os resultados da mesma dentro do modelo STIRPAT. Os resultados encontrados neste trabalho mostram que a população tem o maior impacto no que tange o incremento nos lançamentos de carbono, tal como é possível também observar em Dietz e Rosa (1997), Shi (2003) e Cole e Neumayer (2004).

Para testar a dependência *cross-section*, foi aplicado o teste CD de Pesaran (2004), que emprega os coeficientes de correlação entre as séries temporais para cada membro do painel. Segundo Croissant e Millo (2008), em painéis, isto pode surgir se indivíduos respondem a choques comuns e se a dependência *cross-section* está presente, pode causar ineficiência dos estimadores usuais. Como a hipótese nula do teste indica que o modelo não possui dependência, a mesma é aceita em detrimento da hipótese alternativa que defende a existência da relação.

Sobre o R<sup>2</sup> encontrado neste trabalho, verifica-se que o valor de 0.30 é muito menor do que outros trabalhos que aplicam a mesma metodologia e também usam séries de tempo em anos consecutivos, como é possível encontrar em Shi (2003) e York (2008) . Entretanto, um fato importante que deve ser levado em consideração é que estes trabalhos citados não verificam a estacionaridade das variáveis e, pelo fato do modelo lidar com variáveis que possuem alta probabilidade de serem estacionárias por serem consideradas variáveis de estoque (População) ou relacionadas com medidas de estoque (PIB, emissões, consumo energético), isto ocasiona no aparecimento de valores inflados de R<sup>2</sup> e consequentemente em relações espúrias.

Dentre os trabalhos em que se lida com a estacionaridade das variáveis por meio do método de primeiras diferenças, como pode ser visto em Cole e Neumayer (2004) e

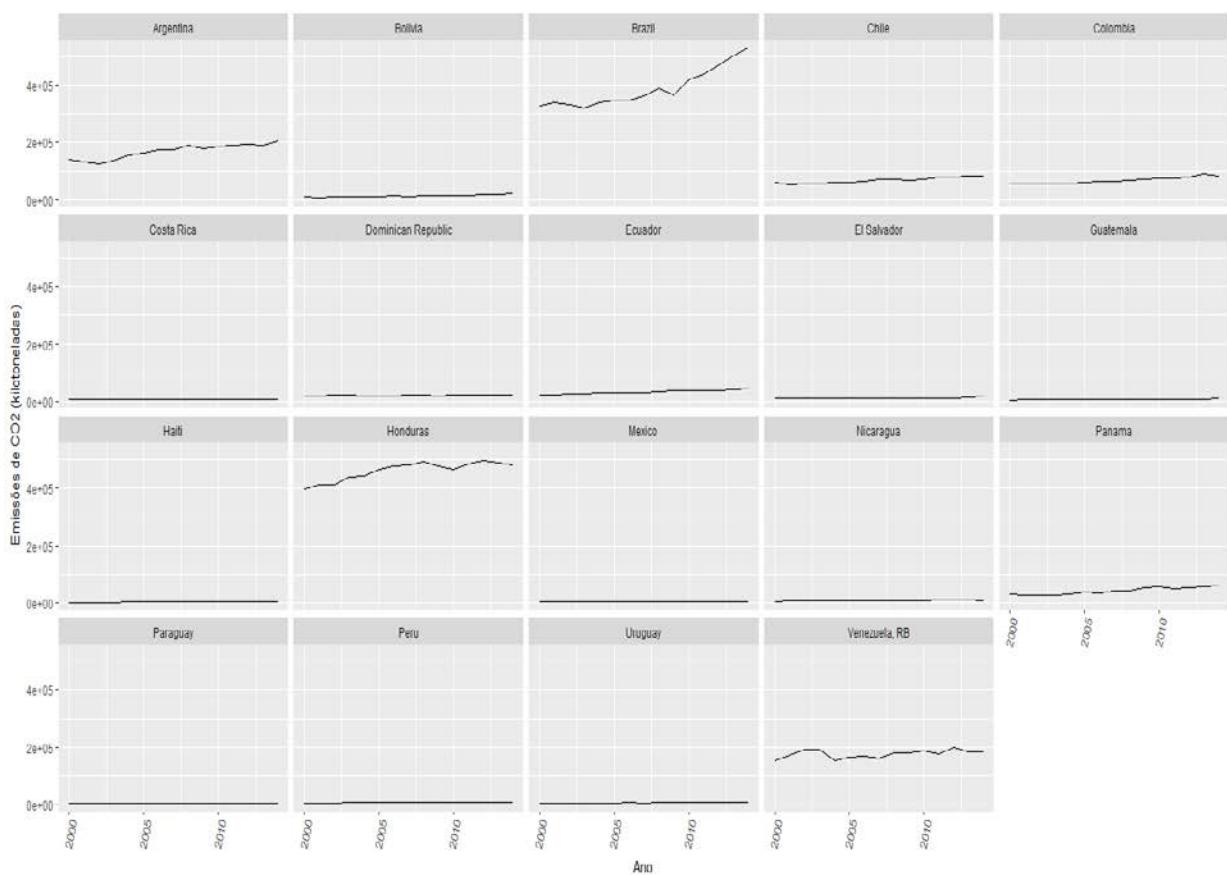
Jorgenson et al. (2010), o valor de  $R^2$  encontrado neste trabalho supera o primeiro artigo e fica um pouco abaixo do segundo.

**Tabela 3 – Estatísticas Descritivas.**

Variável	Média	Desvio-Padrão	Mínimo	Máximo
$CO_2$	10.04	1.58	7.22	13.18
$POP$	16.46	1.10	14.92	19.13
$ERN$	3.41	0.62	2.03	4.42
$ECF$	4.09	0.40	2.88	4.51
$PIB$	9.07	0.62	7.31	10.01

Fonte: Elaboração própria com base nos dados utilizados.

Nota: Todas as variáveis se encontram em logaritmo.



### Figura 1 – Gráficos de Emissão de CO<sub>2</sub> por país (2000-2014)

Fonte: Elaboração própria com base nos dados utilizados.

## Conclusão

Através do uso do R, foi possível obter diversas vantagens na realização do presente trabalho. Resumidamente, foi possível obter todos os dados que compõe as variáveis de análise através do pacote WDI, o que torna a tarefa de obtenção de informações mais precisa e prática. Outro fator são os pacotes disponibilizados para estimação do modelo da equação (4), que possuem uma gama importante de testes auxiliares que auxiliam nas decisões acerca da escolha do melhor modelo dentre as opções factíveis.

Um maior consumo de energia oriunda de combustíveis fósseis, tudo o mais constante, tende a elevar a emissão de CO<sub>2</sub>, o mesmo efeito ocorre só que em diferente magnitude, caso haja uma elevação do PIB *per capita*. O mesmo vale para o contrário.

A variável população se mostrou o fator que acarreta maior impacto no lançamento de gases de carbono, dado o valor de seu coeficiente de 1.19 ser maior do que os demais, indicando que o crescimento da população tende a ser acompanhado por um aumento de emissões de CO<sub>2</sub> e vice-versa, tudo o mais constante.

Não foram encontradas evidências de que um aumento na porcentagem de consumo de energia renovável acarrete em menos poluição de CO<sub>2</sub> em países da América Latina.

O aumento de gases de efeito estufa na atmosfera tem efeitos adversos, conforme já foi mostrado neste trabalho. Tendo isto em vista, inúmeros esforços têm sido realizados no que tange a mitigação dos efeitos adversos do acréscimo de emissões de carbono, como é o caso do Acordo de Paris, onde um compromisso global foi firmado para que haja uma cooperação em que cada país integrante do Acordo estabelece metas e estratégias para redução de emissões.

## Referências

- ARRAES, Ronaldo A.; DINIZ, Marcelo B.; DINIZ, Márcia JT. **Curva ambiental de Kuznets e desenvolvimento econômico sustentável**. Revista de Economia e Sociologia Rural, v. 44, n. 3, p. 525-547, 2006.
- BECK, Nathaniel; KATZ, Jonathan N. **What to do (and not to do) with time-series cross-section data**. American political science review, v. 89, n. 3, p. 634-647, 1995.
- COLE, Matthew A.; NEUMAYER, Eric. **Examining the impact of demographic factors on air pollution**. Population and Environment, v. 26, n. 1, p. 5-21, 2004.
- CROISSANT, Yves; MILLO, Giovanni. **Panel data econometrics in R: The plm package**. Journal of Statistical Software, v. 27, n. 2, p. 1-43, 2008.

DIETZ, Thomas; ROSA, Eugene A. **Effects of population and affluence on CO<sub>2</sub> emissions**. Proceedings of the National Academy of Sciences, v. 94, n. 1, p. 175-179, 1997.

EHRLICH, Paul R.; HOLDREN, John P. **Impact of population growth**. Science, v. 171, n. 3977, p. 1212-1217, 1971.

HARRIS, Jonathan M.; ROACH, Brian; ENVIRONMENTAL, Jonathan M. Harris. **The economics of global climate change**. Global Development And Environment Institute Tufts University, 2007.

HSIAO, Cheng. **Panel data analysis**: advantages and challenges. Test, v. 16, n. 1, p. 1-22, 2007.

JORGENSEN, Andrew K.; RICE, James; CLARK, Brett. **Cities, slums, and energy consumption in less developed countries, 1990 to 2005**. Organization & Environment, v. 23, n. 2, p. 189-204, 2010.

KUZNETS, Simon. **Economic growth and income inequality**. The American economic review, p. 1-28, 1955.

LIDDLE, Brantley. **What are the carbon emissions elasticities for income and population? Bridging STIRPAT and EKC via robust heterogeneous panel estimates**. Global Environmental Change, v. 31, p. 62-73, 2015.

MARTÍNEZ-ZARZOSO, Inmaculada; BENGOCHEA-MORANCHO, Aurelia; MORALES-LAGE, Rafael. **The impact of population on CO<sub>2</sub> emissions**: evidence from European countries. Environmental and Resource Economics, v. 38, n. 4, p. 497-512, 2007.

REED, W. Robert; WEBB, Rachel. **The PCSE Estimator is Good, Just Not As Good As You Think**. Journal of Time Series Econometrics, v. 2, n. 1, 2010.

SHI, Anqing. **The impact of population pressure on global carbon dioxide emissions, 1975–1996**: evidence from pooled cross-country data. Ecological Economics, v. 44, n. 1, p. 29-42, 2003.

SOLOMON, Susan (Ed.). **Climate change 2007-the physical science basis**: Working group I contribution to the fourth assessment report of the IPCC. Cambridge university press, 2007.

STERN, David I. **The rise and fall of the environmental Kuznets curve**. World development, v. 32, n. 8, p. 1419-1439, 2004.

YORK, Richard. **De-carbonization in former Soviet republics, 1992–2000**: The ecological consequences of de-modernization. Social Problems, v. 55, n. 3, p. 370-390, 2008.

YORK, Richard; ROSA, Eugene A.; DIETZ, Thomas. **STIRPAT, IPAT and ImPACT: analytic tools for unpacking the driving forces of environmental impacts**. Ecological economics, v. 46, n. 3, p. 351-365, 2003.

## Anexo

```
# Pacotes utilizados:
library(WDI)
library(plm)
library(lmtest)
library(dplyr)
library(lmtest)
library(ggplot2)

# Obtendo os dados desejados:
dados = WDI(indicator=c('EN.ATM.CO2E.KT', 'SP.POP.TOTL', 'EG.FEC.RNEW.ZS',
'EG.USE.COMM.FO.ZS', 'NY.GDP.PCAP.PP.KD'), country=c('BR', 'AR', 'CO',
'EC', 'PE', 'PA', 'BO', 'CL', 'VE', 'PY', 'CR', 'SV', 'GT', 'HT', 'HN',
'MX', 'NI', 'DO', 'UY'), start=2000, end=2014)

# Renomeando colunas:
names(dados)[names(dados) == 'EN.ATM.CO2E.KT'] <- 'CO2'
names(dados)[names(dados) == 'SP.POP.TOTL'] <- 'POP'
names(dados)[names(dados) == 'EG.FEC.RNEW.ZS'] <- 'ERN'
```



```

names(dados)[names(dados) == 'EG.USE.COMM.FO.ZS'] <- 'ECF'
names(dados)[names(dados) == 'NY.GDP.PCAP.PP.KD'] <- 'PIB'

# Gráfico para cada país:
ggplot(dados, aes(x=year, y=dados$CO2)) +
  geom_line(aes(group=country)) +
  facet_wrap(~ country) +
  xlab("Ano") +
  ylab("Emissões de CO2 (kilotoneladas)") +
  ggtitle(" ") +
  theme(axis.text.x = element_text(angle = 75, hjust = 1))

# Transformando dados em log:
dados[,4:8] <- log(dados[,4:8])

# Colocando em primeira diferença:
dados <- dados %>%
  group_by(country) %>%
  mutate_at(vars(CO2:PIB), funs(. - lag(.)))

dados <- na.omit(dados)

# Colocando os dados em formato de painel:
panel_data <- pdata.frame(dados, index = c("country", "year"), drop.index = F, row.names = TRUE)

# Modelo estimado:
modelo_ols_noeffects <-
  plm(dados$CO2 ~ dados$POP + dados$ERN + dados$ECF + dados$PIB, index = c("year",
  "country"), data = panel_data, model = "pooling")
summary(modelo_ols_noeffects)

# Testando cross-sectional dependence:
pcdtest(modelo_ols_noeffects, test = "cd")

# Testando auto correlação nos erros idiossincráticos:
res <- modelo_ols_noeffects$residuals
n <- length(res)
teste <- lm(res[-n] ~ res[-1])
summary(teste)

# PCSE:
coeftest(modelo_ols_noeffects, vcov. = vcovBK)

```