



UNIVERSIDAD DE CUENCA

Facultad de Ciencias Económicas y Administrativas

Maestría en Economía

Análisis del impacto ambiental de la recepción de industrias
extranjeras aplicando la metodología de la estimación de la curva de
Kuznets: casos de China e India

Trabajo de titulación previo a la
obtención del título de Magíster
en Economía

Autor:

Boris Genaro Tipán Barros

CI: 0105277271

Correo electrónico: boris.tipan.barros@gmail.com

Director:

Dr. Diego Fernando Roldán Monsalve

CI: 0101693588

Cuenca, Ecuador

26-enero-2021

**Resumen:**

El presente estudio tuvo como finalidad determinar el impacto de la contaminación transfronteriza para los casos de China e India durante el periodo 1971-2019, aplicando el enfoque de la Curva de Kuznets Ambiental (EKC). Para ello se aplicó una estimación de un modelo autorregresivo de rezagos distribuidos (ARDL) planteado por Pesaran y Shin (1998). Se evaluó el nivel de impacto que tiene el Producto Interno Bruto (PIB), el consumo de energía renovable, el consumo de combustibles fósiles y el nivel de emisiones de CO_2 de Estados Unidos para el caso de China, y el de Alemania para el caso de India, sobre los niveles de emisiones de los países estudiados. Los resultados confirman la no existencia de una EKC para ninguno de los dos países. Adicionalmente con el test de causalidad de Granger se logra confirmar la hipótesis de la contaminación transfronteriza o paraísos de contaminadores para los dos casos. Finalmente, la aplicación de un pronóstico en base a la metodología ARIMA evidencia un crecimiento de los niveles de emisiones CO_2 de para los dos casos hasta 2030.

Palabras claves: Contaminación transfronteriza. Curva de Kuznets ambiental. Rezagos autoregresivos distribuidos. Paraísos de contaminadores.



Abstract: This study had the aim to determine the impact of cross-border pollution for the case of China and India, during the period 1971-2019, by applying the Environmental Kuznets Curve (EKC) approach. For this, an estimate of an autoregressive distributed lag model (ARDL), which was proposed by Pesaran and Shin (1998), was applied. The level of impact of the Gross Domestic Product (GDP), the consumption of renewable energy, the consumption of fossil fuels and the CO_2 emission levels of the USA was evaluated for the case of China, and the case of Germany for India, according to the emission levels of the countries within this research. Additionally, with the Granger causality test, it is possible to confirm the hypothesis of cross-border pollution or the pollution paradises for both cases. Finally, the application of a forecast based on the ARIMA methodology shows a growth in the emission levels of CO₂ for both cases until 2030.

Keywords: Cross-border pollution. Environmental Kuznets Curve. Distributed autoregressive lags. Pollution paradises.



Índice del Trabajo

I.	INTRODUCCIÓN.....	6
	Apertura Comercial en China	9
	Apertura Comercial en India.....	10
II.	MÉTODO	12
	Revisión de Literatura.....	12
	Especificación del modelo	15
	Método de Cointegración y Rezagos Autorregresivos Distribuidos (ARDL)	17
	Prueba de causalidad de Granger	19
III.	RESULTADOS.....	21
	Test de Raíz Unitaria	21
	Estimación ARDL.....	22
	Causalidad.	25
	Pronóstico.	26
IV.	DISCUSIÓN.....	27
	Bibliografía.	30
	Anexos.....	37
	Anexo 1: Test de Dickey-Fuller Aumentado y Phillip Perron para China	37
	Anexo 2: Test de Dickey-Fuller Aumentado y Phillip Perron para India.....	47
	Anexo 3: ARDL Bound Test para China e India.....	60
	Anexo 4 Estimación ARDI y pruebas de Diagnóstico para China	62
	Anexo 5: Estimación ARDL py pruebas de diagnóstico para India.....	65
	Anexo 6: Rezago óptimo para China e India	67
	Anexo 7: Prueba de Cointegración de Johansen para China e India	67
	Anexo 8: Estimación OLS para China e India.....	68



Cláusula de licencia y autorización para publicación en el Repositorio Institucional

Yo Boris Genaro Tipán Barros en calidad de autor y titular de los derechos morales y patrimoniales del trabajo de titulación “Análisis del impacto ambiental de la recepción de industrias extranjeras aplicando la metodología de la estimación de la curva de Kuznets: casos de China e India”, de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 26 de enero de 2021

Boris Genaro Tipán Barros

C.I: 010527727-1



Cláusula de Propiedad Intelectual

Yo Boris Genaro Tipán, autor del trabajo de titulación “Análisis del impacto ambiental de la recepción de industrias extranjeras aplicando la metodología de la estimación de la curva de Kuznets: casos de China e India”, certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 26 de enero de 2021

Boris Genaro Tipán Barros

C.I: 010527727-1



I. INTRODUCCIÓN

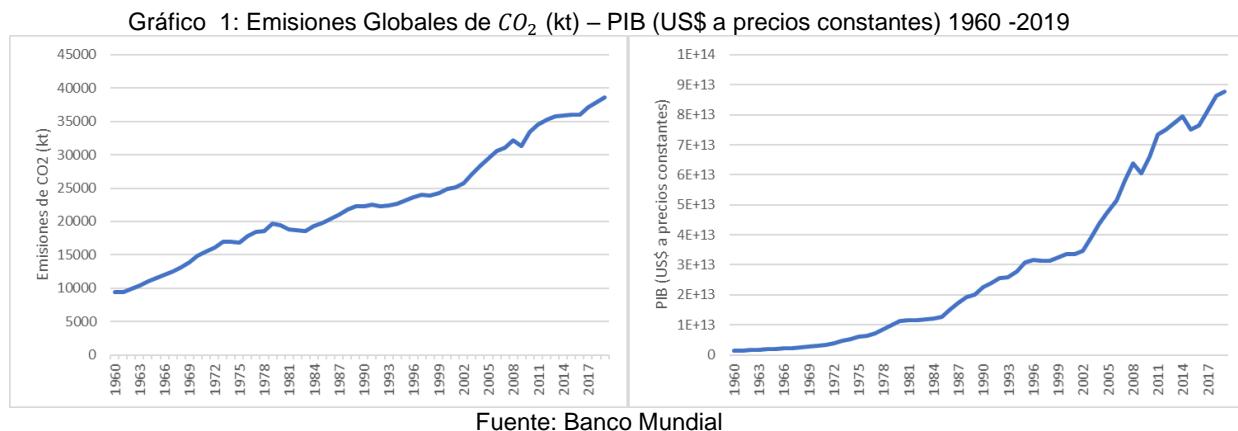
En la actualidad, el desarrollo humano y el de un país son evidenciados en medida de su crecimiento económico. El cual se ve reflejado en los crecientes niveles de producción, demanda de recursos naturales y uso de energía (Hanif et al., 2019). Con esta percepción se ha diseñado un sistema económico que prioriza un modelo de desarrollo basado en consumo, es así, como la producción mundial ha aumentado más de 60 veces desde 1960 (Zhang et al., 2019). Sin embargo, a partir la revolución industrial, este crecimiento ha traído consigo una acelerada degradación ambiental, llegando a ser considerado el problema global más importante de las últimas cinco décadas. (Budhi & Widodo, 2019).

Entre las consecuencias de la degradación ambiental se encuentra el incremento de la temperatura global, intensificada a su vez, por la alta concentración de gases de efecto invernadero (Zerbo, 2015). El 60% de estos gases corresponden al Dióxido de Carbono (CO_2), el cual es generado en su mayoría por la quema de combustibles fósiles (Ozturk & Acaravci, 2010). Por lo cual existe un gran número de estudios que investigan la relación entre el crecimiento económico y la contaminación(Álvarez-Herránz et al., 2017).

Todas las investigaciones han concluido que en la realidad existe una correlación entre el crecimiento económico y la contaminación ambiental (Zhang et al., 2019). Sin embargo, es solo hasta 1991 cuando Grossman y Krueger demuestran que dicha relación tiene la forma de “U invertida” para el caso de América del Norte, la misma que es conocida en la actualidad como la “Curva de Kuznets Ambiental” debido a la metodología aplicada por los autores (Bertinelli & Strobl, 2005). Esto da origen a la “Hipótesis de la Curva de Kuznets Ambiental” (EKC por sus siglas en inglés) que es analizada por diversos autores en diversos casos a nivel regional o países, con resultados que no son concluyentes (He & Richard, 2010).

La hipótesis de la EKC implica que en un primer momento si un país es de bajos ingresos, un crecimiento en su economía generará un incremento de la contaminación ambiental. Esta relación se mantiene hasta llegar al “Turning Point” que es donde este comportamiento se logra revertir, formando así la U invertida

(Azomahou et al., 2006). Para este tipo de análisis la mayoría de estudios han utilizado el Producto Interno Bruto (PIB) como indicador del crecimiento económico y el nivel de Emisiones de CO_2 para medir el nivel de contaminación ambiental.



Como se puede observar en el Gráfico 1, tanto las emisiones globales de CO_2 como el PIB Mundial muestran una tendencia creciente. Esto puede llevar interpretaciones erradas sobre la validez del hipótesis de la EKC, por lo que tras analizar sus tasas de crecimiento interanuales se puede notar que siguen una tendencia más estacionaria.

Con los datos obtenidos del Banco mundial se ha determinado que la tasa de crecimiento interanual de las emisiones globales de CO_2 crecen en un promedio de 2.45%, mientras que las del PIB mundial al 7.45%. Lo que da como resultado que se hayan multiplicado por tres y seis veces respectivamente desde el año 1960.

Resulta complejo inferir sobre la relación entre emisiones de CO_2 y crecimiento económico a nivel global. Esto se debe a que los países difieren en múltiples aspectos uno de otros. Lo que puede sesgar los resultados, por lo que se recomienda estimar la EKC para cada economía o grupos de países similares, analizando sus características esenciales (Jha & Murthy, 2003).

China e India constan como el primer y tercer país con los más altos niveles de emisiones de CO_2 en el mundo, con una participación promedio actual de 27.52% y 7.26% respectivamente. Situación que merece ser analizada de tal manera que permita encontrar las causas reales para los resultados antes mencionados.



Una de las ideas fundamentales que sostienen la existencia de una EKC es que, una vez conseguido cierto nivel de desarrollo, la economía se vuelve prestadora de servicios y posee regulaciones ambientales más estrictas. Es decir, un país de bajos ingresos normalmente es extractivista, por lo que no puede aplicar fuertes medidas de cuidado ambiental, a medida que aumenta sus ingresos, aumenta su producción y su industria, con lo que provoca un mayor nivel de contaminación. Al mantenerse ese crecimiento, la mejora de tecnología se intensifica lo que genera un mayor valor agregado, transformándola en prestadora de servicios. Esto puede resultar conveniente para la mencionada economía, sin embargo, la necesidad de bienes con producción altamente contaminantes se mantiene. Por lo que es necesario que trasladen sus fábricas hacia países que tengan menos regulaciones y aporten con recursos primarios, de tal manera que se importan estos bienes (Grossman & Krueger, 1991). En pocas palabras, la existencia de la EKC implica una reducción de la contaminación debido a un desplazamiento de la misma, y más no una reducción real a nivel global.

Esto refleja la importancia de analizar cuantitativamente los factores que intensifican las emisiones de CO_2 de un país. Más aún, al ser este receptor de Inversión Extranjera Directa (IED) destinada al aumento de la manufactura de bienes con procesos productivos contaminantes. China e India han sido dos de los países con mayor crecimiento económico en los últimos 50 años, período en el cual se ha evidenciado una notoria apertura comercial e ingreso de capitales desde Europa y Norteamérica, situación similar que ocurre con su niveles de emisiones (Instituto de Investigación Económica y Social Sader Patel & Pradhan, 2008). Razón que evidencia la necesidad de un análisis de los factores reales de la creciente contaminación para estas dos economías¹.

¹ Esta propuesta es una colaboración al planteamiento original de Diego Roldán quién sugiere que la EKC de un país puede estar explicado de manera importante por factores de otros países si este ha sido delegado para producir, mediante *offshoring* o *outsourcing*, aquellos productos que generan contaminación en los países que inicialmente contaminaban. Es decir, la EKC de un país delegado para la producción desde otro, puede detectar un incremento contaminante a la par que en el país (o países) que delega se benefician de una desaceleración o decremento en su EKC.



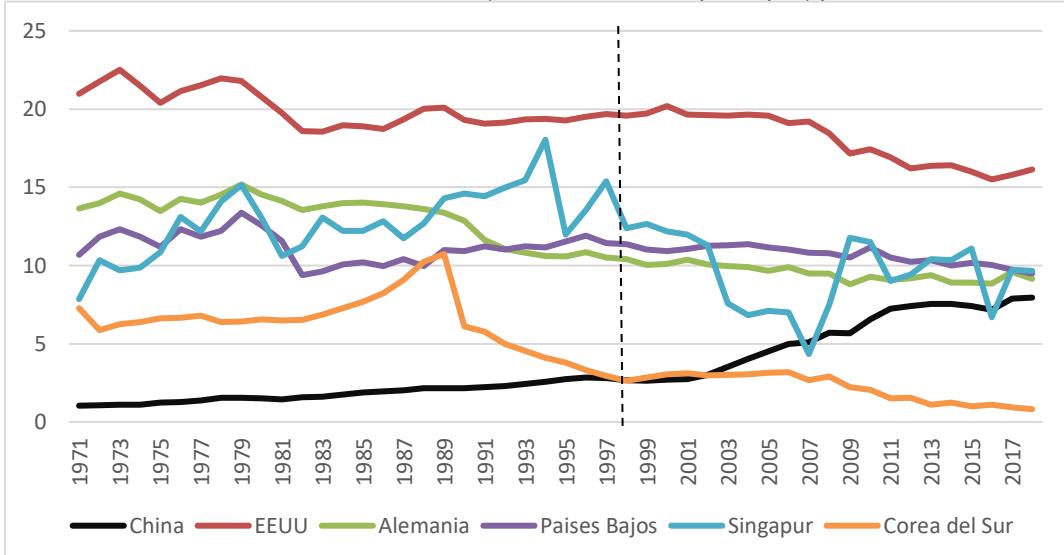
Apertura Comercial en China.

El 1 de octubre de 1949 nace la República Popular de China, con su capital Beijín. Su gobierno se basa en la alianza de cuatro clases sociales: obreros, campesinos, intelectuales y burguesía nacional. Con esto se forma una dictadura democrática del proclamado Partido Comunista. Sin embargo, no es hasta 1978 cuando el gobierno apuesta por una economía de mercado socialista para modernizar al país, bajo el mando de Deng Xiaoping (Macías, 2011).

Las medidas liberalizadoras de China se enfocaron en cuatro sectores. En la agricultura los campesinos pasan a ser dueños de la tierra, con lo que deben vender parte de sus cultivos al estado a precios fijados y el excedente de manera libre. La ciencia y tecnología se llegan a considerar como la primera fuerza de producción del país. El ejército Chino considera una reducción del número de militares con un mejor equipamiento de los mismos, Finalmente la industria se intensifica al punto de exportar bienes finales de manera masiva al resto del mundo (Treacy, 2020).

Esta liberalización permitió que países desarrollados transfieran gran cantidad de su contaminación a China, con las llamadas empresas offshore (Yunfeng & Laike, 2010). Situación que puede ser percibida en el Gráfico 2, en el cual se muestra los niveles de emisiones de CO_2 per cápita de China con su principales inversores, entre ellos Estados Unidos, Alemania, Singapur, Corea del Sur y Países Bajos. El interés surge al notarse un ligero comportamiento tendencial desde 1990, año en el que China Intensifica su apertura comercial (Adamu et al., 2019). El mismo muestra que los mencionados inversionistas empiezan a reducir su nivel de emisiones y de manera paralela China empieza a aumentar.

Gráfico 2 Emisiones de CO2 (toneladas métricas per cápita) por País



Fuente: Banco Mundial

Por esta razón, resulta importante analizar la existencia de una correlación entre las emisiones de los países inversores con la de su receptor. Percepción que abarca las ideas de los modelos teóricos Norte-Sur, que implica que por su mano de obra barata y sus deficientes restricciones ambientales los países de bajos ingresos son receptoras de grandes empresas contaminantes en búsqueda de un rápido crecimiento económico (Jenkins, 2003). Además de que la problemática fundamental radica en una inadecuada definición de la propiedad sobre los recursos ambientales en el comercio internacional (Yunfeng & Laike, 2010).

Actualmente China ha llegado a ser considerado el mayor contaminante a nivel mundial. Por lo que se han realizado diferentes estudios para determinar no solo sus factores, sino la posible existencia de una EKC para esta economía. Resultando conclusiones divididas por metodologías, tipo de datos y variables utilizadas.

Apertura Comercial en India

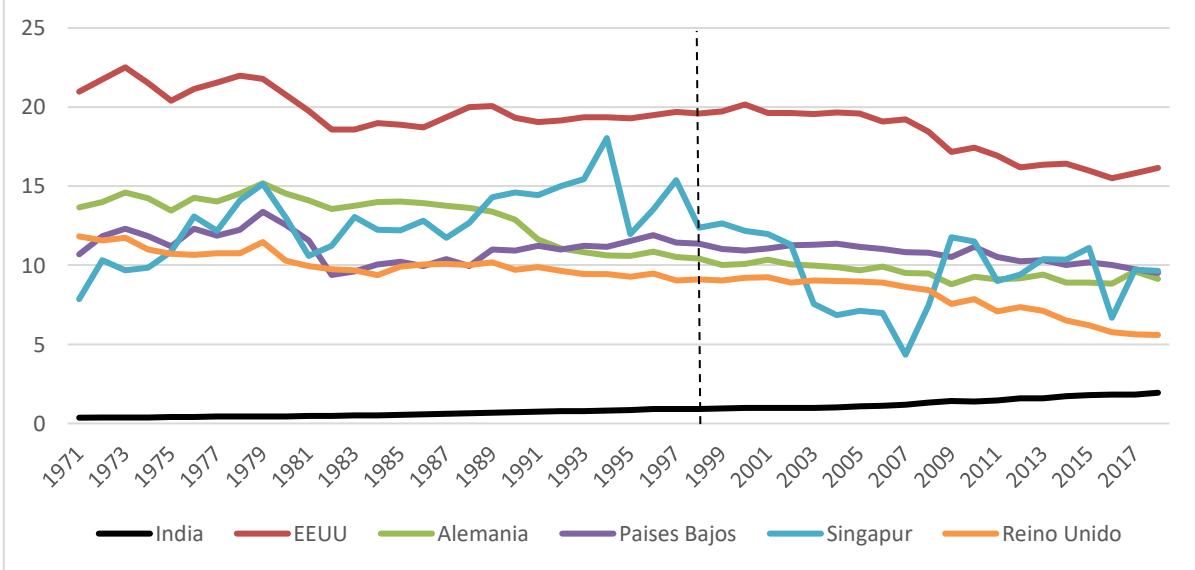
India a diferencia de China inicia su apertura comercial desde 1991 debido a su crisis financiera. Desde 1947 el país contaba con un sistema democrático liberal cuyo objetivo fue la eficiencia competitiva en el mercado internacional para acelerar su crecimiento. Para 1980 la gran exportación de alimentos origina la llamada

revolución verde, acompañada de un política de reducción del tamaño del estado y control del déficit fiscal (Silva et al., 2017). Sin embargo el débil manejo macroeconómico ocasionó que las reservas en divisas se redujeran al punto de dejar a India en una bancarrota. (Macías, 2011)

Debido a esta crisis financiera India apuesta por nuevos acuerdos comerciales y una participación activa en asociaciones para liberar el comercio internacional. Lo que ha permitido a su PIB contar con altas tasas de crecimiento llegando a cuaduplicarse en comparación al período previo a la crisis. Siendo su principal atractivo de inversiones su gran cantidad de mano de obra barata, expertos técnicos y frágiles controles ambientales (Adamu et al., 2019).

De la misma manera que en China resulta importante analizar la relación entre las emisiones de CO_2 de India con sus principales inversionistas. Tal como lo muestra la Gráfica 3 la tendencia es muy semejante a la de China, con la salvedad, de que los cambios no resultan tan notorios como en el primer caso. Sin embargo, sus resultados nos permiten contrastar la metodología aplicada para analizar la existencia de una EKC para los dos casos, y su correlación entre niveles de emisiones.

Gráfico 3: Emisiones de CO_2 (toneladas métricas per cápita) India y sus socios comerciales



Fuente: Banco Mundial



En la Literatura aún no está del todo clara el verdadero efecto de la IED sobre el nivel de emisiones de CO_2 del país anfitrión (Vieira, 2009). Por lo que el objetivo del presente estudio es determinar la existencia de una correlación entre las emisiones del país inversionista con su receptor y, la existencia de una EKC aplicando a los casos de China e India.

Para cumplir con el mencionado objetivo se utilizará en ambos casos como variable dependiente el nivel de emisiones de CO_2 a nivel per cápita; y, para las variables explicativas el PIB per cápita, el consumo de energía per cápita de fuentes renovable y fósiles, así como también el nivel de emisiones de CO_2 per cápita de sus principales inversores. Con esta información se aplicará un modelo de estimación ARDL, lo cual permite determinar la forma que tenga relación a corto y largo plazo, con ello aceptar o rechazar la hipótesis de la EKC. Finalmente se realizarán pruebas de causalidad, cointegración y pronóstico del comportamiento de cada variable. Logrando así concluir si existe alguna relación entre sus emisiones.

II. MÉTODO

Revisión de Literatura

La necesidad de analizar el impacto ambiental sobre un país receptor de industrias extranjeras, ha dividido a los investigadores en función de sus variables aplicadas. Para fines de este trabajo se ha decidido establecer dos categorías. Primero entre quienes consideran a la Inversión Extranjera como factor fundamental, y segundo entre quienes apuesta por que sea el Comercio Internacional su principal causante.

El enfoque base para demostrar la validez de la hipótesis de la EKC plantea una relación entre el crecimiento económico medido a través del PIB y el nivel de emisiones de Dióxido de carbono como medida de la contaminación. Es así, como Ahmad (2018), Wang, (2016), Kang (2016), Lee & Oh (2015), confirman la existencia de la EKC para China. Utilizando estimaciones con datos de panel para las provincias con mayor desarrollo. Mientras que Li (2012), reporta una relación positiva de largo plazo entre las variables antes mencionadas. Para el caso de India Ahmad (2016), Managi & Jena (2008), verifican que se cumple esta hipótesis de la



U Invertida debido a que el aumento de su productividad ha reducido sus niveles de emisiones. Finalmente Mani (2012); reporta que resultados contradictorios a los ya mencionados.

La apertura comercial se intensificó para las dos economías a partir del año 1990 (Adamu et al., 2019), por lo que, resulta importante incluir esta variable dentro del análisis. Es como Kanjilal & Ghosh (2013), Pal & Mitra (2017) demuestran que existe una relación muy elástica entre el ingreso, la apertura comercial y el nivel de contaminación para la India; rechazando con esto la hipótesis de la EKC. Mientras que Tariq (2018); sostiene lo contrario. Para China Cui (2020); Xu (2020) concluyen que la apertura comercial ha permitido aumentar los recursos para la protección ambiental por medio de mejoras de sus procesos productivos y la reducción de emisiones. Sin embargo, Hao (2016), Jun (2020) verifican que existe una relación causal positiva a largo plazo entre sus diferentes mecanismos de apertura comercial y la intensidad de sus emisiones.

La IED resulta ser una variable fundamental dentro del crecimiento económico en un país, lo que a su vez ha intensificado los niveles de contaminación (Sharma et al., 2020). Esta relación positiva entre la IED y los niveles de emisiones de CO_2 se lo conoce como la Hipótesis del Paraíso de la Contaminación (PHH por sus siglas en inglés). Zheng & Sheng (2017) rechaza la mencionada hipótesis en China. Para el caso de India Sinha & Shahbaz (2018) también rechazan esta afirmación y confirman la de la U invertida. Con esto resulta importante considerar la IED dentro de la presente investigación.

Para profundizar en el análisis de los factores que han intensificado los niveles de contaminación para China e India se aplicará métodos de causalidad, cointegración y estimación ARDL. Esto permitirá conocer los efectos tanto de corto como de largo plazo. Para con ello, confirmar o rechazar la hipótesis de la U invertida, lo que nos permitirá determinar si el *turning point* se encuentra en un nivel debajo del umbral de tolerancia para que el daño ambiental generado sea reversible (Yang et al., 2015).

Con esto podemos comparar los resultados obtenidos en otros países al aplicar las metodologías antes mencionadas. Ahmad (2017) muestra una relación



positiva entre misiones y crecimiento en Irán. Nasir & Ur Rehman (2011) evidencia efectos directos de las emisiones a corto plazo en Pakistán, mientras que los de largo plazo resultan poco significativos. Para el caso de Vietnam Tang & Tan (2015) verifica la importancia de la IED sobre el aumento de las emisiones de CO_2 , mientras que Linh & Lin (2014) desestiman su efecto. Una situación similar ocurre en África siendo Kenia y Zimbabwe quienes relacionan directamente a la IED con la degradación ambiental, y por el contrario para los casos de Sur África y República del Congo según el estudio realizado por Zerbo (2015). Para el caso de Latino América la forma de la EKC depende del grado de apertura económica en base a la investigación de Pablo-Romero & De Jesús (2016). Con esto podemos verificar que el ingreso resulta no ser la única variable que puede explicar el daño ambiental, tanto en países desarrollados como emergentes. Evidenciando la importancia de incluir tanto la apertura comercial como los niveles de inversión.

Todo lo antes mencionado refleja la inconsistencia entre resultados empíricos de la validez de la hipótesis de la EKC. Bruyn (1998), Harbaugh (2018), Lee (2010), Stern (1996) Özokcu & Özdemir (2017) consideran diferentes factores que explican la variabilidad de los resultados como cambios estructurales, la sensibilidad de los parámetros, la composición de la actividad económica o hasta la forma de medir la degradación ambiental, lo que ha llevado a proponer además diferentes técnicas econométricas que validen sus conclusiones. Hosseini & Kaneko (2013), Vollebergh (2009), Azomahou (2006), Bertinelli & Strobl (2005) consideran en su metodología técnicas de pruebas no paramétricas, semi paramétricas y metodología Engle-Granger, entre las cuales consideran al tiempo como variable para probar no solo la validez de la hipótesis de la U invertida, sino que además, la de desplazamiento de contaminación o contaminación transfronteriza. Objetivo fundamental de la presente investigación

Finalmente en base a lo antes mencionado podemos incluir a los niveles de contaminación de los países inversores como variable dentro de nuestras estimaciones. Lo que nos permitirá no solo probar la validez de la hipótesis de la EKC, sino que, además determinar el nivel de impacto ambiental que tiene este desplazamiento de industrias. Para esto se han evidenciado tres visiones: la neoclásica que establece una relación neutral; la segunda de un impacto directo y



la tercera que reafirma la validez de la U invertida (Alam et al., 2011). La cual será contrastada con la evidencia empírica

Especificación del modelo

El objetivo principal de la presente investigación es la de determinar el impacto ambiental que tienen los países receptores de industrias extranjeras sobre su nivel de emisiones de dióxido de carbono, para lo cual la estimación se lo hará en base a la metodología planteada por Grossman & Krueger, 1991 sobre la EKC con la técnica ARDL. Con ello se desea probar la hipótesis de la U invertida y cuantificar la correlación entre el nivel de emisiones del país inversor con su receptor.

En base a lo antes mencionado, los casos de análisis serán aplicados a China e India durante el período 1971-2019. En ellos cuales se verificará si alguno de estos países cumple con la hipótesis de la EKC y la relación entre los niveles de emisiones de CO_2 entre cada país y sus principales inversores. Adicionalmente se proyectará el comportamiento de la intensidad de la contaminación hasta el año 2030, el cual permite inferir sobre el cumplimiento de las condiciones de sus objetivos de desarrollo sostenible.

Como primer paso debemos establecer para los dos casos la cointegración entre el nivel de emisiones de CO_2 per cápita, PIB per cápita, consumo de combustibles fósiles, consumo de energía renovable, IED, y los nivel de emisiones per cápita de sus principales países inversores. Sin embargo, es necesaria una estandarización de las unidades de las variables por lo que serán expresadas como logaritmos.

Con esto el primer modelo a ser estimado en base al trabajo presentado por Pal & Mitra, 2017 se muestra en la ecuación (1). Misma que incluye el logaritmo del PIB per cápita al cuadrado y al cubo, para identificar si la relación está en forma de U invertida o N.

$$\begin{aligned} \logco2_{it} = & \beta_0 + \beta_{1i}\logpib_{it} + \beta_{2i}\logpib2_{it} + \beta_{3i}\logpib3_{it} + \beta_{4i}\logied_{it} + \\ & \beta_{5i}\loger_{it} + \beta_{6i}\logef_{it} + \beta_{7i}\logsc1_{it} + \beta_{8i}\logsc2_{it} + \dots + \varepsilon_{it} \end{aligned} \quad (1)$$



Donde:

i nos permite diferenciar entre China o India; $\logco2_{it}$ representa el nivel emisiones de dióxido de carbono per cápita para cada país; \logpib_{it} es el PIB per cápita; $\logpib2_{it}$ es el cuadrado del PIB per cápita; $\logpib3_{it}$ es el cubo del PIB per cápita; \logied_{it} es la Inversión Extranjera Directa; \loger_{it} es el consumo de energías renovables; \logef_{it} es el consumo de fuentes fósiles; $\logsc1_{it}$; $\logsc2_{it}$; etc. es el nivel de emisiones de CO_2 de su principales países inversores.

Para la selección de sus principales socios comerciales se eligió el porcentaje que cada país tiene dentro de la IED de sus receptores. De este modo para China los países seleccionados fueron: Hong Kong (72%); Singapur (3%); Islas Vírgenes (3%); Corea del Sur (2%); Japón (2%) Estados Unidos (2%); Islas Caimán (1%); Países Bajos (1%); Taiwan (1%); y Alemania (1%) datos que fueron obtenidos del Informe anual de estadísticas de China, 2018. Mientras que en el caso de India están: Singapur (38%); Islas Mauricio (18%) Países Bajos (8%); Estados Unidos (7%); Japón (6%); Reino Unido (3%); Alemania (1%); y Francia (1%), información extraída del Departamento de Promoción y Política Industrial del Ministerio de Comercio e Industria de India, 2018.

Tras las primeras pruebas de significancia estadística, el $\logco2_{it}$ y el $\logpib3_{it}$ debieron ser descartadas por su colinealidad perfecta, mientras que la variable \logied_{it} por su baja significancia. Finalmente para los países inversores de China e India se determinó utilizar el nivel de emisiones de solo Estados Unidos y Alemania respectivamente. Quedando la ecuación (2) para China y la ecuación (3) para India definidas de la siguiente manera:

$$\logco2_t = \beta_0 + \beta_1 \logpib_t + \beta_2 \loger_t + \beta_3 \logef_t + \boldsymbol{\beta}_4 \logeeuu_t + \varepsilon_t \quad (2)$$

$$\logco2_t = \beta_0 + \beta_1 \logpib_t + \beta_2 \loger_t + \beta_3 \logef_t + \boldsymbol{\beta}_4 \logalem_t + \varepsilon_t \quad (3)$$

Con la información obtenida del Banco Mundial se pretende estimar las elasticidades β_1 , β_2 , β_3 y β_4 además del término de intercepto β_0 . Con esto se plantea el supuesto de que ruido blanco del término de error ε_t .



Las ecuaciones (2) y (3) basan su estructura en el trabajo presentado por Adamu, 2019. Mismo que plante que este tipo de estructura supera el problema de multicolinealidad. Adicionalmente basados en el criterio de Zambrano-Monserrate, 2018 se rechaza la existencia de la EKC si la elasticidad de largo plazo es mayor a la de corto plazo. Ya que, esto implicaría que el crecimiento del PIB mantendrá una relación directa con el de las emisiones en un largo periodo de tiempo.

Método de Cointegración y Rezagos Autorregresivos Distribuidos (ARDL)

Para los trabajos presentados por Zerbo, 2015; N. Ahmad, 2017; Nasir & Ur Rehman, 2011; el procedimiento ARDL tiene como principal ventaja diferenciar los efectos de corto y largo plazo que tienen las variables dependientes sobre la independiente. Este modelo fue presentado inicialmente por Pesaran & Smith, 2001 para superar los problemas de muestras pequeñas que generalmente se presentan en series de tiempo. Además, garantiza la estacionariedad del modelo al permitirnos estimar la cointegración en diferentes órdenes, misma que puede ser en valores enteros o incluso fraccionarios. Así se presenta el modelo a estimar para China en la ecuación (4) y para India en la ecuación (5):

$$\begin{aligned} \Delta \log co2_t = & \alpha_0 + \sum_{k=1}^{\pi_1} \alpha_{1k} \Delta \log co2_{t-k} + \sum_{k=0}^{\pi_2} \alpha_{2k} \Delta \log pib_{t-k} \\ & + \sum_{k=0}^{\pi_3} \alpha_{3k} \Delta \log er_{t-k} + \sum_{k=0}^{\pi_4} \alpha_{4k} \Delta \log ef_{t-k} + \sum_{k=0}^{\pi_5} \alpha_{5k} \Delta \log eeuu_{t-k} \\ & + \delta_1 \log co2_{t-1} + \delta_2 \log pib_{t-1} + \delta_3 \log er_{t-1} + \delta_4 \log ef_{t-1} \\ & + \delta_5 \log eeuu_{t-1} + \mu_t \end{aligned} \tag{4}$$



$$\begin{aligned}\Delta \log co2_t = & \alpha_0 + \sum_{k=1}^{\pi_1} \alpha_{1k} \Delta \log co2_{t-k} + \sum_{k=0}^{\pi_2} \alpha_{2k} \Delta \log pib_{t-k} \\ & + \sum_{k=0}^{\pi_3} \alpha_{3k} \Delta \log er_{t-k} + \sum_{k=0}^{\pi_4} \alpha_{4k} \Delta \log ef_{t-k} + \sum_{k=0}^{\pi_5} \alpha_{5k} \Delta \log alem_{t-k} \\ & + \delta_1 \log co2_{t-1} + \delta_2 \log pib_{t-1} + \delta_3 \log er_{t-1} + \delta_4 \log ef_{t-1} \\ & + \delta_5 \log alem_{t-1} + \mu_t\end{aligned}\tag{5}$$

Los valores de $\pi_1, \pi_2, \pi_3, \pi_4$ y π_5 representan el número de rezagos para cada variable. Para calcular el orden óptimo del rezago se utilizará el criterio información de: Akaike (AIC), Bayesiano de Schwars (SBIC) y el de Hannan y Quinn (HQIC). Además de la prueba de Razón de Verosimilitud para todos los VAR completos de orden menor o igual al orden del retardo más alto.

Una vez obtenido el orden óptimo del rezago se aplica el Test de Bondad ARDL. Mismo que prueba si el modelo cointegra o no a largo plazo (Pesaran & Smith, 2001). Esta metodología se encarga de probar las siguientes hipótesis:

$$H_0: \delta_1 = \delta_2 = \delta_3 = \delta_4 = \delta_5 = 0$$

$$H_1: \text{Al menos un valor de } \delta \text{ es diferente de cero}$$

Para realizar la prueba de hipótesis planteada se aplica el criterio del estadístico F- Wald. El valor obtenido se lo compara con los valores críticos a sus diferentes niveles de confianza y con su respectivo orden de rezago. El ARDL Bound Test establece que en caso de caer dentro de la zona de no rechazo de la hipótesis nula, el modelo no cointegra. Esto significa que:

- Acepta H_0 si: $F < \text{límite inferior } I(0) \rightarrow \text{No hay cointegración}$
- Rechaza H_0 si: $F > \text{límite superior } I(1) \rightarrow \text{Hay cointegración}$
- No hay conclusión: $I(0) < F < \text{límite superior } I(1)$

Con esto en base a las ecuaciones (2) y (3) podemos obtener las ecuaciones de corto plazo, expresadas en (4) y (5):



$$\begin{aligned}\Delta \log co2_t = & \alpha_0 + \sum_{k=1}^{\pi_1} \alpha_{1k} \Delta \log co2_{t-k} + \sum_{k=0}^{\pi_2} \alpha_{2k} \Delta \log pib_{t-k} \\ & + \sum_{k=0}^{\pi_3} \alpha_{3k} \Delta \log er_{t-k} + \sum_{k=0}^{\pi_4} \alpha_{4k} \Delta \log ef_{t-k} + \sum_{k=0}^{\pi_5} \alpha_{5k} \Delta \log eeuu_{t-k} \\ & + \theta ect_{t-1} + \mu_t\end{aligned}\quad (4)$$

$$\begin{aligned}\Delta \log co2_t = & \alpha_0 + \sum_{k=1}^{\pi_1} \alpha_{1k} \Delta \log co2_{t-k} + \sum_{k=0}^{\pi_2} \alpha_{2k} \Delta \log pib_{t-k} \\ & + \sum_{k=0}^{\pi_3} \alpha_{3k} \Delta \log er_{t-k} + \sum_{k=0}^{\pi_4} \alpha_{4k} \Delta \log ef_{t-k} + \sum_{k=0}^{\pi_5} \alpha_{5k} \Delta \log alem_{t-k} \\ & + \theta ect_{t-1} + \mu_t\end{aligned}\quad (5)$$

Donde:

ect_{t-1} representa al término de corrección de error rezagado un período. El cual se lo calcula al estimar los residuos de la ecuación (2) o (3), según corresponde el caso. Es decir que:

$$ect_{it} = \widehat{\varepsilon}_{it} \quad (6)$$

El calcular el coeficiente de ect_{it-1} al momento de estimar ect_{it} nos revelará la velocidad de convergencia. Es decir la velocidad a la que las variables vuelven a su equilibrio en el largo plazo. Por esto el coeficiente θ deber resultar negativo y significativo. Lo cual cumple con la metodología del modelo de corrección de errores. Lo que nos permitirá considerar consistentes a los parámetros del MCO a corto plazo independientemente del tamaños de su muestra. La misma debe ser contrastada con te test de CUSUM cuadrado sobre estabilidad de los parámetros.

Prueba de causalidad de Granger

La estimación ARDL determina la existencia de causalidad entre variables, pero no su direccionalidad. Para ello se necesita aplicar el test de causalidad de



Granger, el cual se basa en la matriz del vector de corrección del error (VECM). Con lo que podemos expresar para el caso de China

$$(1 - L) \begin{bmatrix} \logco2_t \\ \logpib_t \\ \loger_t \\ \logef_t \\ \logeeuu_t \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \\ b_4 \\ b_4 \end{bmatrix} + \sum_{i=1}^{\pi} (1 - L) \begin{bmatrix} d_{11i} & d_{12i} & d_{13i} & d_{14i} & d_{15i} \\ d_{21i} & d_{22i} & d_{23i} & d_{24i} & d_{25i} \\ d_{31i} & d_{32i} & d_{33i} & d_{34i} & d_{35i} \\ d_{41i} & d_{42i} & d_{43i} & d_{44i} & d_{45i} \\ d_{51i} & d_{52i} & d_{53i} & d_{54i} & d_{55i} \end{bmatrix} \begin{bmatrix} \logco2_{t-1} \\ \logpib_{t-1} \\ \loger_{t-1} \\ \logef_{t-1} \\ \logeeuu_{t-1} \end{bmatrix} + \\ \begin{bmatrix} \eta_1 \\ \eta_2 \\ \eta_3 \\ \eta_4 \\ \eta_4 \end{bmatrix} (ect_{t-1}) + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_4 \end{bmatrix} \quad (7)$$

Donde:

L representa el operador de rezagos y $(1 - L)$ representa el operador de primera diferencia. Para el caso de India se aplica de la misma manera, con la variación del país inversor.

$$(1 - L) \begin{bmatrix} \logco2_t \\ \logpib_t \\ \loger_t \\ \logef_t \\ \logalem_t \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \\ b_4 \\ b_4 \end{bmatrix} + \sum_{i=1}^{\pi} (1 - L) \begin{bmatrix} d_{11i} & d_{12i} & d_{13i} & d_{14i} & d_{15i} \\ d_{21i} & d_{22i} & d_{23i} & d_{24i} & d_{25i} \\ d_{31i} & d_{32i} & d_{33i} & d_{34i} & d_{35i} \\ d_{41i} & d_{42i} & d_{43i} & d_{44i} & d_{45i} \\ d_{51i} & d_{52i} & d_{53i} & d_{54i} & d_{55i} \end{bmatrix} \begin{bmatrix} \logco2_{t-1} \\ \logpib_{t-1} \\ \loger_{t-1} \\ \logef_{t-1} \\ \logalem_{t-1} \end{bmatrix} + \\ \begin{bmatrix} \eta_1 \\ \eta_2 \\ \eta_3 \\ \eta_4 \\ \eta_4 \end{bmatrix} (ect_{t-1}) + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_4 \end{bmatrix} \quad (8)$$

El test de causalidad de Granger consiste en estimar los d . Una vez determinado los valores de cada uno se plantea la hipótesis:

$$\mathbf{H}_0: d's = 0$$

Para rechazar o no la hipótesis nula se compara el valor del estadístico F o chi-cuadrado. En caso de que el valor calculado se encuentre dentro de la zona de no rechazo de H_0 implica que no existe causalidad de Granger. Mientras que para el largo plazo se estiman los valores de los coeficientes de η los cuales deben ser



negativos y significativos para considerar la existencia de causalidad de Granger a largo plazo entre las variables.

Finalmente se pronosticará el nivel de emisiones para los dos países el cual permitirá confirmar la validez del modelo. Para ello se utilizará la metodología ARIMA y pronósticos dinámicos con el que se comparará entre los valores reales, calculados y pronosticados. Mismo que se extenderán hasta el año 2030.

III. RESULTADOS.

Test de Raíz Unitaria

El primer paso necesario previo a las estimaciones con series de tiempo, es probar si los datos utilizados son estacionarios. Para ello la presente investigación se ha utilizado el Test de Dickey-Fuller Aumentado conjuntamente con el de Phillips-Perron, mismas que reportaron que las variables son integradas de orden 1, I(1) y orden 4, I(4). Los resultados del Anexo 1 y 2 se los agrupa en la Tabla 1:

Tabla 1: Resultados de la prueba de ADF y PP para China e India

Variable		China				India				Orden de integración	
		ADF t-statistics		PP Adj t-statistics		ADF t-statistics		PP Adj t-statistics			
		Nivel	Primera Diferencia	Nivel	Primera Diferencia	Nivel	Primera Diferencia	Nivel	Primera Diferencia		
Intercepción	<i>logco2</i>	-0.365	-0.5339***	-0.137	-4.839***	0.695	-6.633***	0.679	-6.646***	I(1)	
	<i>logpib_t</i>	1.099	-6.512***	1.548	-5.389***	0.200	-6.247***	0.119	-6.292***	I(1)	
	<i>logert</i>	0.597	-6.523***	0.987	-5.492***	-1.156	-8.529***	1.326	-8.633***	I(1)	
	<i>logef_t</i>	0.113	-5.660***	-0.060	-5.057***	0.990	-5.568***	0.832	-5.581***	I(1)	
	<i>loggeeuu_t</i>	-0.597	-5.989***	-0.554	-3.607***	-	-	-	-	I(1)	
	<i>logalem_t</i>	-	-	-	-	-0.491	-7.331***	-0.434	-7.341***	I(1)	
Intercepción y tendencia	<i>logco2</i>	-1.580	-5.293***	-2.006	-4.793***	-2.193	-6.697***	-2.341	-6.687***	I(1)	
	<i>logpib_t</i>	-1.762	-6.302***	-1.344	-5.823***	-1.143	-6.195***	-1.354	-6.239***	I(1)	
	<i>logert</i>	-2.146	-6.544***	-1.808	-5.624***	-1.129	-8.606***	-0.779	-8.792***	I(1)	
	<i>logef_t</i>	-1.796	-5.616***	-2.010	-5.006***	-0.963	-5.598***	-1.304	-5.620***	I(1)	
	<i>loggeeuu_t</i>	-2.180	-5.924***	-2.016	-5.117***	-	-	-	-	I(1)	
	<i>logalem_t</i>	-	-	-	-	-2.475	-7.248***	-2.549	-7.256***	I(1)	



Fuente: Elaboración propia

Estimación ARDL

Para encontrar una relación de largo plazo entre las emisiones de CO_2 y las variables explicativas para las dos economías se aplica el ARDL Bound Test. El mismo que no rechaza la hipótesis de cointegración. Como se puede ver en la Tabla 2 que es formada del Anexo 3 el rezago óptimo es 1 en base al criterio de Información Bayesiano. Mientras que al contrastar el estadístico F con los valores críticos se confirma una la relación de largo plazo con 1 y 5 rezagos para China e India respectivamente.

Tabla 2: Resultados del ARDL Bound Test

	China		India	
	Límite Inferior	Límite Superior	Límite Inferior	Límite Superior
Significacia	I(0)	I(1)	I(0)	I(1)
1%	5.051	4.321	4.832	6.696
5%	3.769	5.002	3.510	4.979
10%	3.205	6.535	2.951	4.250
Estadístico F		13.669		9.129

Fuente: Elaboración Propia

Una vez que se verifica la estacionariedad de las variables, así como de su relación a largo plazo se procede a estimar los parámetros del modelo por la metodología ARDL. Los parámetros encontrados representan las elasticidades de largo plazo para el PIB, consumo de energía renovable, consumo de combustibles fósiles y los niveles de emisiones de CO_2 de su país inversor. Los resultados son presentados en la Tabla 3 elaborada a partir de los Anexos 4 y 5.

Para el caso de China el logaritmo del PIB, consumo de combustibles fósiles y emisiones de Estados Unidos resultan estadísticamente significativos en por lo menos 5%. Siendo de manera coherente con la teoría de signo positivo las dos primeras y negativo para la tercera. Sin embargo, tanto el PIB como el consumo de combustibles fósiles resulta muy bajos ya que el aumento del 1% en cualquiera de ellas, generará un incremento 0.07% y 0.09% de emisiones de dióxido de carbono respectivamente. El signo negativo del nivel de Emisiones de Estados Unidos



implica que una caída de esta del 1% genera un aumento en las emisiones de China del 0.86%. lo que implica un efecto de desplazamiento de la contaminación.

En el caso de India todas las variables planteadas en la ecuación (3) resultan ser significativas y coherentes a la teoría. Con lo que podemos verificar que un aumento de 1% del PIB per cápita o del consumo de combustibles fósiles generará un aumento de las emisiones de CO_2 en un 0.43% y 0.66% respectivamente. Mientras que para el consumo de energías renovables y el nivel de emisiones de Alemania muestran una relación indirecta. Lo cual implica que por cada 1% de reducción de emisiones en Alemania se aumenta 0.45% las de India. Verificándose una vez más un efecto desplazamiento de la contaminación.

Es importante mencionar que en los resultados de corto plazo, el software Stata, elimina de manera automática algunas variables tanto para China como para India, lo cual dificulta la conclusión sobre la hipótesis de la Curva de Kuznets Ambiental. Sin embargo, no se ha logrado establecer las causas sobre esta situación. Por lo que se considera como variables no significativas y que pueden alterar a los resultados de corto plazo. Sin embargo, esta situación debe ser estudiada de manera más profunda. Lo que no es objetivo de esta investigación.

Los resultados de India en el corto plazo nos indica que no se cumple la hipótesis de la EKC ya que su elasticidad de largo plazo (0.439) resulta mayor que la de corto plazo (-0.138). Con esto resulta imposible encontrar un Turning Point y conocer si el mismo se encuentra o no debajo del umbral de remediación ambiental.



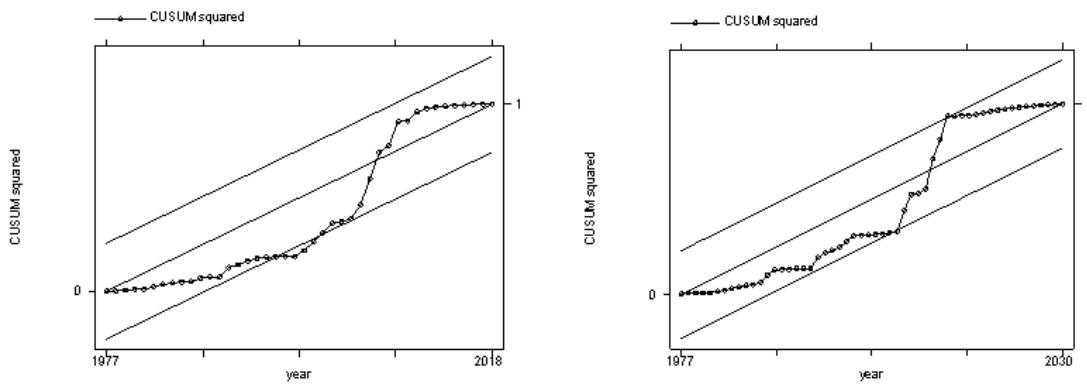
Tabla 3: Resultados de la Estimación ARDL y pruebas de Diagnóstico

Variable	China		India	
	Estimación de Largo Plazo	Estimación de Corto Plazo	Estimación de Largo Plazo	Estimación de Corto Plazo
<i>logpib_t</i>	0.072943** (0.041605)		0.43919*** (0.09814)	-0.13823*** (0.0399)
<i>loger_t</i>	0.094002 -0.060301	-0.13552*** 0.04695	-0.467681*** (0.141433)	0.09477*** (0.03734)
<i>logef_t</i>	1.10183*** -0.057659		0.66107*** (0.126903)	
<i>logeeuu_t</i>	-0.860671*** (0.0986919)	0.58165*** (0.150525)		
<i>logalem_t</i>			-0.4492631*** (0.152316)	
ect-1		-0.90032*** (0.080471)		-0.4714648** (0.087747)
constante		98.17552 (10.23878)		10.177 (6.0774)
R-Cuadrado	0.84		0.6737	
R-Cuadrado Ajustado	0.7915		0.5727	
Pruebas de Diagnóstico	Estadístico	P-value	Estadístico	P-value
Autocorrelación (Breush-Godfrey)	1.7543	0.1303	18.74	0.000
Heterocedasticidad (White)	44	0.4290	0.56	0.25
Heterocedasticidad (ARCH)	1.075	0.2998	0.766	0.3814
Especificación (Ramsey)	0.59	0.6233	0.21	0.8894
Normalidad (Skewness/Kurtosis)	2.45	0.2941	0.33	0.29

Nota: Nivel de significancia: 1%(**), 5%(**) y 10%(*). Los valores debajo de las elasticidades representan las desviaciones estándar.

Fuente: Elaboración Propia

Gráfico 4: CUSUM Cuadrado para China e India



Fuente: Elaboración propia.

El gráfico 4 muestra los resultados de CUSUM al cuadrado para China e India. El mismo que evidencia la estabilidad de los parámetros.

Causalidad.

El test de causalidad de Granger nos permite determinar la direccionalidad de la causalidad entre las variables. Para lo cual se aplico 1 rezago para China y 4 para India basados en el criterio de Información de Akaike, Bayesiano de Schwarz y el de Hannan Quinn. Este resultado se puede comprobar en el Anexo 6. Finalmente en el Anexo 7 al aplicar la prueba de cointegración de Johansen se pudo determinar dos ecuaciones cointegrantes para China e India.

Los resultados de las Tablas 4 y 5, muestran los resultados del anexo 7 . Para el Caso de China se evidencia una relación causal unidireccional entre el consumo de energías renovables y el PIB per cápita, además de que es última tiene una relación causal unidireccional con el consumo de combustibles fósiles. Mientras que la Tabla 5 evidencia la relación causal unidireccional entre el crecimiento del PIB y el consumo de combustibles fósiles, a su la que tiene el nivel de emisiones de Alemania con el consumo de combustibles fósiles.



Tabla 4: Resultados de la Causalidad de Granger en VECM para China

CHINA	logco2	logpib	loger	logef	logeu
logco2		0.46	3.4	0.57***	12.42
logpib_t	0.75		5.76	1.25	2.54
loger_t	0.02	8.28***		1.9	0.63
logef_t	4.5	4.79	2.12		2.48
logeeuu_t	2.05	1.56	1.66	2.12	

Nota: Nivel de significancia: 1%(***) , 5%(**) y 10%(*).

Fuente: Elaboración Propia

Tabla 5: Resultados de la Causalidad de Granger en VECM para India

INDIA	logco2	logpib	loger	logef	logalem
logco2		2.13	2.28	12.48***	5
logpib	4.11		1.48	2.9	0.67
loger	1.32	3		5.82	4.08
logef	2.23	2.25	0.79		8.48**
logeu	0.08	4.82	0.18	6.26	

Nota: Nivel de significancia: 1%(***) , 5%(**) y 10%(*).

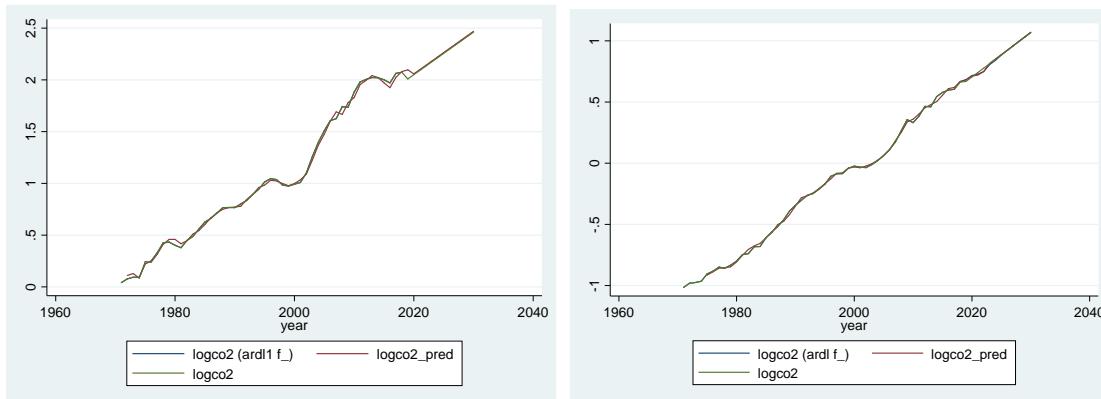
Fuente: Elaboración Propia

Finalmente al confirmarse la cointegración del modelos podemos estimar el impacto que tiene las caídas de los niveles de emisiones de Estados Unidos y Alemania sobre China e India Respectivamente. Como se puede ver en el Anexo 8 una disminución del 1% de las emisiones de CO_2 en Estados Unidos provoca un aumento del 0.9425% en la China, mientras que una disminución del 1% en Alemania provoca un aumento de 05627% sobre India. Con estos resultados se confirma la hipótesis de la contaminación transfronteriza o paraísos para contaminadores.

Pronóstico.

Una vez establecido el modelo y tras probar la validez de su consistencia y aplicar diferentes pruebas de cointegración podemos proyectar los resultados hasta 2030. Fecha que en la que se deben cumplir los objetivos de desarrollo sostenible. Por lo que al aplicar la metodología del modelo autoregresivo para las emisiones obtenemos el Gráfico 5.

Gráfico 5: Pronóstico de las emisiones de dióxido de carbono para China e India



Fuente: Elaboración Propia

Como se puede ver en el gráfico 5 la técnica de estimación ARDL y todas las pruebas aplicadas reportan que el nivel de emisiones de China va a aumentar en promedio un 2.06% anual. Mientras que en India el crecimiento de sus emisiones será de 0.87% promedio anual

IV. DISCUSIÓN.

El presente documento tuvo como objetivo principal determinar el impacto sobre las emisiones de dióxido de carbono de China e India al ser países receptores de industrias contaminantes. Para ello se ha utilizado la metodología de la estimación de la Curva de Kuznets Ambiental mediante la técnica ARDL. Por lo que a más de las variables como el PIB per cápita, consumo de energía renovable, consumo de combustibles fósiles, se incluyó las emisiones de los países con mayor inversión dentro de cada economía analizada.

La hipótesis que se ha tratado de verificar es que la relación entre el crecimiento económico y la contaminación muestren la forma de una U invertida, además de cuantificar el impacto de una caída en el nivel de emisiones de aquellos países que han desplazado sus industrias sobre sus receptores. Lo cual puede ser como referente sobre si en la praxis se está reduciendo los niveles de contaminación o simplemente se trasladan a países con menores restricciones y controles ambientales.



Los resultados obtenidos muestran que no se han llegado a confirmar la existencia de la EKC para ninguna de las dos economías. Además de ello, una correlación negativa con uno de sus principales inversores. Mismos que han considerado el desplazamiento de sus fábricas debido al bajo precio de la mano de obra y a las bajas restricciones ambientales. Es así, como China e India que impulsaron su apertura comercial desde 1990 han tenido que diseñar políticas que les permitan ser atractivos para los inversionistas y así generar crecimiento económico. El mismo ha dado resultado que sean consideradas las economías con las más altas tasas de crecimiento a nivel global (Bosworth & Collins, 2008). Adicionalmente se han posicionado como las economías más contaminantes del planeta.

Los resultados también muestran que para China el consumo de energía renovable resulta poco significativo. Sin embargo, este resultado puede ser temporal. Debido a que la información utilizada fue hasta el año 2019, mientras que para el año 2020 entró en funcionamiento la megacentral hidroeléctrica de Wudongde con una capacidad de 39TWh siendo esta la séptima mas grande a nivel mundial y la cuarta dentro de China.

Por otro lado el consumo de combustibles fósiles resulta significativo para los dos países. Esto se debe principalmente a que en los dos casos la principal fuente de generación de energía es el carbón. Convirtiéndolos así en los mas grandes consumidores de carbón del mundo. Siendo su uso principal en la manufactura según los datos del Banco Mundial.

En cuanto a la relación entre las emisiones de cada país con su inversor. Resulta importante mencionar que el inversionista seleccionado no es aquel que más aporta a su respectiva IED. Sin embargo debido a la naturaleza y a su significancia estadística resultó apropiado incluirlas dentro de las estimaciones. Es así como se evidencia también que China mantiene un mayor nivel de relaciones comerciales con América en general, mientras que India lo hace con Europa. Esto puede deberse a que según Macías, 2011 China se ha enfocado en ser productor de bienes finales, mientras que India ha considerado tener mano de obra más calificada para la prestación de servicios.



Es necesario también acotar el rápido desarrollo urbano que han tenido las dos economías, misma que se traduce en un mayor consumo de energía, uso de transporte, y mayor infraestructura. Siendo la industria cementera una de las más prósperas para los países, la cual es a su vez una de las más contaminantes. La creciente demanda de recursos naturales debido también a sus altas tasas de crecimiento poblacional ha sido factores que han intensificado la degradación ambiental según varios estudios.

Finalmente tanto China como India según los resultados obtenidos deben intensificar sus políticas de cuidado medioambiental para futuros inversores, intensificar la generación de energía a partir de fuentes renovables para reducir su dependencia del carbón. El crecimiento económico genera los recursos necesarios para mejorar la tecnología y con ello reducir su contaminación. Lo cual puede reflejar una EKC y un posible cumplimiento de los objetivos de desarrollo sostenible.



Bibliografía.

- Adamu, T., Haq, I., & Shafiq, M. (2019). Analyzing the Impact of Energy, Export Variety, and FDI on Environmental Degradation in the Context of Environmental Kuznets Curve Hypothesis: A Case Study of India. *Energies*, 12(6), 1076. <https://doi.org/10.3390/en12061076>
- Ahmad, A., Zhao, Y., Shahbaz, M., Bano, S., Zhang, Z., Wang, S., & Liu, Y. (2016). Carbon emissions, energy consumption and economic growth: An aggregate and disaggregate analysis of the Indian economy. *Energy Policy*, 96, 131-143. <https://doi.org/10.1016/j.enpol.2016.05.032>
- Ahmad, M. (2018). Empirics on linkages among industrialization, urbanization, energy consumption, CO₂ emissions and economic growth: A heterogeneous panel study of China. *Environ Sci Pollut Res*, 16.
- Ahmad, N. (2017). *Effects of energy production and CO₂ emissions on economic growth in Iran: ARDL approach*. 17.
- Alam, M. J., Begum, I. A., Buysse, J., Rahman, S., & Van Huylenbroeck, G. (2011). Dynamic modeling of causal relationship between energy consumption, CO₂ emissions and economic growth in India. *Renewable and Sustainable Energy Reviews*, 15(6), 3243-3251. <https://doi.org/10.1016/j.rser.2011.04.029>
- Álvarez-Herránz, A., Balsalobre, D., Cantos, J. M., & Shahbaz, M. (2017). Energy Innovations-GHG Emissions Nexus: Fresh Empirical Evidence from OECD Countries. *Energy Policy*, 101, 90-100. <https://doi.org/10.1016/j.enpol.2016.11.030>
- Azomahou, T., Laisney, F., & Nguyen Van, P. (2006). Economic development and CO₂ emissions: A nonparametric panel approach. *Journal of Public Economics*, 90(6-7), 1347-1363. <https://doi.org/10.1016/j.jpubeco.2005.09.005>



- Bertinelli, L., & Strobl, E. (2005). The Environmental Kuznets Curve semi-parametrically revisited. *Economics Letters*, 88(3), 350-357.
<https://doi.org/10.1016/j.econlet.2005.03.004>
- Bosworth, B., & Collins, S. M. (2008). *Accounting for Growth: Comparing China and India*. 37.
- Budhi, G., & Widodo, T. (2019). The Environmental Kuznets Curve in ASEAN: The Case of Carbon Emissions. *Munich Personal RePEc Archive*, 1-17.
- Cui, J., Tam, O. K., Wang, B., & Zhang, Y. (2020). The environmental effect of trade liberalization: Evidence from China's manufacturing firms. *The World Economy*, twec.13005. <https://doi.org/10.1111/twec.13005>
- de Bruyn, S. M., van den Bergh, J. C. J. M., & Opschoor, J. B. (1998). Economic growth and emissions: Reconsidering the empirical basis of environmental Kuznets curves. *Ecological Economics*, 25(2), 161-175. [https://doi.org/10.1016/S0921-8009\(97\)00178-X](https://doi.org/10.1016/S0921-8009(97)00178-X)
- Grossman, G., & Krueger, A. (1991). *Environmental Impacts of a North American Free Trade Agreement* (N.º w3914; p. w3914). National Bureau of Economic Research.
<https://doi.org/10.3386/w3914>
- Hanif, I., Faraz Raza, S. M., Gago-de-Santos, P., & Abbas, Q. (2019). Fossil fuels, foreign direct investment, and economic growth have triggered CO₂ emissions in emerging Asian economies: Some empirical evidence. *Energy*, 171, 493-501.
<https://doi.org/10.1016/j.energy.2019.01.011>
- Hao, Y., Zhang, Z.-Y., Liao, H., Wei, Y.-M., & Wang, S. (2016). Is CO₂ emission a side effect of financial development? An empirical analysis for China. *Environmental Science and Pollution Research*, 23(20), 21041-21057.
<https://doi.org/10.1007/s11356-016-7315-8>



Harbaugh, W. T., Levinson, A., & Wilson, D. M. (s. f.). REEXAMINING THE EMPIRICAL EVIDENCE FOR AN ENVIRONMENTAL KUZNETS CURVE. *THE REVIEW OF ECONOMICS AND STATISTICS*, 17.

He, J., & Richard, P. (2010). Environmental Kuznets curve for CO₂ in Canada. *Ecological Economics*, 69(5), 1083-1093. <https://doi.org/10.1016/j.ecolecon.2009.11.030>

Hosseini, H. M., & Kaneko, S. (2013). Can environmental quality spread through institutions? *Energy Policy*, 56, 312-321.

<https://doi.org/10.1016/j.enpol.2012.12.067>

Instituto de Investigación Económica y Social Sarder Patel, & Pradhan, J. P. (2008). Rise of Indian Outward FDI: What Implications Does it Hold for Host Developing Countries? *Economía Teoría y Práctica*, 29.

<https://doi.org/10.24275/ETYPUAM/NE/292008/Pradhan>

Jenkins, R. (2003). La apertura comercial ¿ha creado paraísos de contaminadores en América Latina? *Revista de la CEPAL*, 30, 85-100.

Jha, R., & Murthy, K. V. B. (2003). An inverse global environmental Kuznets curve. *Journal of Comparative Economics*, 31(2), 352-368. [https://doi.org/10.1016/S0147-5967\(03\)00042-8](https://doi.org/10.1016/S0147-5967(03)00042-8)

Jun, W., Mahmood, H., & Zakaria, M. (2020). IMPACT OF TRADE OPENNESS ON ENVIRONMENT IN CHINA. *Journal of Business Economics and Management*, 21(4), 1185-1202. <https://doi.org/10.3846/jbem.2020.12050>

Kang, Y.-Q. (2016). Environmental Kuznets curve for CO₂ emissions in China: A spatial panel data approach. *Ecological Indicators*, 9.

Kanjilal, K., & Ghosh, S. (2013). Environmental Kuznet's curve for India: Evidence from tests for cointegration with unknown structuralbreaks. *Energy Policy*, 56, 509-515.

<https://doi.org/10.1016/j.enpol.2013.01.015>



- Lee, C.-C., Chiu, Y.-B., & Sun, C.-H. (2010). The environmental Kuznets curve hypothesis for water pollution: Do regions matter? *Energy Policy*, 38(1), 12-23.
<https://doi.org/10.1016/j.enpol.2009.05.004>
- Lee, S., & Oh, D.-W. (2015). Economic growth and the environment in China: Empirical evidence using prefecture level data. *China Economic Review*, 36, 73-85.
<https://doi.org/10.1016/j.chieco.2015.08.009>
- Li, H., Mu, H., Zhang, M., & Gui, S. (2012). Analysis of regional difference on impact factors of China's energy – Related CO₂ emissions. *Energy*, 39(1), 319-326.
<https://doi.org/10.1016/j.energy.2012.01.008>
- Linh, D. H., & Lin, S.-M. (2014). *Co2 Emissions, Energy Consumption, Economic Growth and fdi in Vietnam*. 12(3), 14.
- Macías, C. L. H. (2011). *Reformas económicas liberales: Casos de China e India*. 17.
- Managi, S., & Jena, P. R. (2008). Environmental productivity and Kuznets curve in India. *Ecological Economics*, 65(2), 432-440.
<https://doi.org/10.1016/j.ecolecon.2007.07.011>
- Mani, M., Markandya, A., Sagar, A., & Sahin, S. (2012). *India's Economic Growth and Environmental Sustainability: What are the Tradeoffs?* The World Bank.
<https://doi.org/10.1596/1813-9450-6208>
- Nasir, M., & Ur Rehman, F. (2011). Environmental Kuznets Curve for carbon emissions in Pakistan: An empirical investigation. *Energy Policy*, 39(3), 1857-1864.
<https://doi.org/10.1016/j.enpol.2011.01.025>
- Özokcu, S., & Özdemir, Ö. (2017). Economic growth, energy, and environmental Kuznets curve. *Renewable and Sustainable Energy Reviews*, 72, 639-647.
<https://doi.org/10.1016/j.rser.2017.01.059>



- Ozturk, I., & Acaravci, A. (2010). CO₂ emissions, energy consumption and economic growth in Turkey. *Renewable and Sustainable Energy Reviews*, 14(9), 3220-3225.
<https://doi.org/10.1016/j.rser.2010.07.005>
- Pablo-Romero, M. del P., & De Jesús, J. (2016). Economic growth and energy consumption: The Energy-Environmental Kuznets Curve for Latin America and the Caribbean. *Renewable and Sustainable Energy Reviews*, 60, 1343-1350.
<https://doi.org/10.1016/j.rser.2016.03.029>
- Pal, D., & Mitra, S. K. (2017). The environmental Kuznets curve for carbon dioxide in India and China: Growth and pollution at crossroad. *Journal of Policy Modeling*, 39(2), 371-385. <https://doi.org/10.1016/j.jpolmod.2017.03.005>
- Pesaran, M. H., Shin, & Smith, R. J. (2001). Bounds testing approaches to the analysis of level relationships. *Journal of Applied Econometrics*, 289-326.
- Sharma, S., Kaur, M., Sharma, P., & Sandhu, S. (2020). A STUDY OF RELATIONSHIP AND IMPACT OF FOREIGN DIRECT INVESTMENT ON ECONOMIC GROWTH RATE OF INDIA. *International Journal of Economics and Financial Issues*, 10(5), 327-330. <https://doi.org/10.32479/ijefi.10463>
- Silva, E. M. da, Vieira, E. T. V., Tashima, L. da C. N., & Guilherme, D. de O. (2017). A sustainability rereading of agrarian production systems. *Interações (Campo Grande)*, 43-54. <https://doi.org/10.20435/inter.v18i4.1527>
- Sinha, A., & Shahbaz, M. (2018). Estimation of Environmental Kuznets Curve for CO₂ emission: Role of renewable energy generation in India. *Renewable Energy*, 119, 703-711. <https://doi.org/10.1016/j.renene.2017.12.058>
- Stern, D. I., Common, M. S., & Barbier, E. B. (1996). Economic growth and environmental degradation: The environmental Kuznets curve and sustainable development.



World Development, 24(7), 1151-1160. [https://doi.org/10.1016/0305-750X\(96\)00032-0](https://doi.org/10.1016/0305-750X(96)00032-0)

Tang, C. F., & Tan, B. W. (2015). The impact of energy consumption, income and foreign direct investment on carbon dioxide emissions in Vietnam. *Energy*, 79, 447-454. <https://doi.org/10.1016/j.energy.2014.11.033>

Tariq, G., Sun, H., Haris, M., Kong, Y., & Nadeem, A. (2018). Trade liberalization, FDI inflows economic growth and environmental sustainability in Pakistan and India. *Journal of Agriculture and Environment for International Development (JAEID)*, 112(2), 253-269. <https://doi.org/10.12895/jaeid.20182.722>

Treacy, M. (2020). El pasado puede ser discutido en el futuro: De la modernización de Deng Xiaoping a las tensiones que despierta China como potencia mundial. *Izquierdas*, 49, 0-0. <https://doi.org/10.4067/S0718-50492020000100210>

Vieira, L. C. A. (2009). THE IMPACT OF FOREIGN DIRECT INVESTMENT ON DEVELOPING ECONOMIES AND THE ENVIRONMENT. *Revista Ingenierías Universidad de Medellín*, 14, 18.

Vollebergh, H. R. J., Melenberg, B., & Dijkgraaf, E. (2009). Identifying reduced-form relations with panel data: The case of pollution and income. *Journal of Environmental Economics and Management*, 58(1), 27-42. <https://doi.org/10.1016/j.jeem.2008.12.005>

Wang, S., Li, Q., Fang, C., & Zhou, C. (2016). The relationship between economic growth, energy consumption, and CO₂ emissions: Empirical evidence from China. *Science of The Total Environment*, 542, 360-371. <https://doi.org/10.1016/j.scitotenv.2015.10.027>



- Xu, Y., Fan, X., Zhang, Z., & Zhang, R. (2020). Trade liberalization and haze pollution: Evidence from China. *Ecological Indicators*, 109, 105825.
<https://doi.org/10.1016/j.ecolind.2019.105825>
- Yang, H., He, J., & Chen, S. (2015). The fragility of the Environmental Kuznets Curve: Revisiting the hypothesis with Chinese data via an “Extreme Bound Analysis”. *Ecological Economics*, 109, 41-58. <https://doi.org/10.1016/j.ecolecon.2014.10.023>
- Yunfeng, Y., & Laike, Y. (2010). China's foreign trade and climate change: A case study of CO₂ emissions. *Energy Policy*, 38(1), 350-356.
<https://doi.org/10.1016/j.enpol.2009.09.025>
- Zambrano-Monserrate, M. A., Silva-Zambrano, C. A., Davalos-Penafiel, J. L., Zambrano-Monserrate, A., & Ruano, M. A. (2018). Testing environmental Kuznets curve hypothesis in Peru: The role of renewable electricity, petroleum and dry natural gas. *Renewable and Sustainable Energy Reviews*, 82, 4170-4178.
<https://doi.org/10.1016/j.rser.2017.11.005>
- Zerbo, E. (2015). CO₂ emissions, growth, energy consumption and foreign trade in Sub-Saharan African countries. 24.
- Zhang, Y., Chen, X., Wu, Y., Shuai, C., & Shen, L. (2019). The environmental Kuznets curve of CO₂ emissions in the manufacturing and construction industries: A global empirical analysis. *Environmental Impact Assessment Review*, 79, 106303.
<https://doi.org/10.1016/j.eiar.2019.106303>
- Zheng, J., & Sheng, P. (2017). The Impact of Foreign Direct Investment (FDI) on the Environment: Market Perspectives and Evidence from China. *Economies*, 5(1), 8.
<https://doi.org/10.3390/economies5010008>



Anexos

Anexo 1: Test de Dickey-Fuller Aumentado y Phillip Perron para China

```
. dfuller logco2
```

Dickey-Fuller test for unit root		Number of obs = 48		
Test Statistic	Value	Interpolated Dickey-Fuller		
		1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	0.015	-3.594	-2.936	-2.602

MacKinnon approximate p-value for Z(t) = 0.9597

```
.
```

```
. dfuller D.logco2
```

Dickey-Fuller test for unit root		Number of obs = 47		
Test Statistic	Value	Interpolated Dickey-Fuller		
		1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-4.764	-3.600	-2.938	-2.604

MacKinnon approximate p-value for Z(t) = 0.0001

```
.
```

```
. dfuller logco2, trend
```

Dickey-Fuller test for unit root		Number of obs = 48		
Test Statistic	Value	Interpolated Dickey-Fuller		
		1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-1.543	-4.168	-3.508	-3.185

MacKinnon approximate p-value for Z(t) = 0.8141

```
.
```

```
. dfuller D.logco2, trend
```

Dickey-Fuller test for unit root		Number of obs = 47		
Test Statistic	Value	Interpolated Dickey-Fuller		
		1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-4.715	-4.178	-3.512	-3.187

MacKinnon approximate p-value for Z(t) = 0.0007



```
. dfuller logpib
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	1.878	-3.600	-2.938
			-2.604

```
MacKinnon approximate p-value for Z(t) = 0.9985
```

```
. dfuller D.logpib
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.299	-3.607	-2.941
			-2.605

```
MacKinnon approximate p-value for Z(t) = 0.0000
```

```
. dfuller logpib, trend
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-1.259	-4.178	-3.512
			-3.187

```
MacKinnon approximate p-value for Z(t) = 0.8977
```

```
. dfuller D.logpib, trend
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.808	-4.187	-3.516
			-3.190

```
MacKinnon approximate p-value for Z(t) = 0.0000
```



Dickey-Fuller test for unit root Number of obs = 47

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	1.060	-3.600	-2.938

MacKinnon approximate p-value for Z(t) = 0.9949

. dfuller D.loger

Dickey-Fuller test for unit root Number of obs = 46

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.510	-3.607	-2.941

MacKinnon approximate p-value for Z(t) = 0.0000

. dfuller loger, trend

Dickey-Fuller test for unit root Number of obs = 47

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-1.706	-4.178	-3.512

MacKinnon approximate p-value for Z(t) = 0.7482

. dfuller D.loger, trend

Dickey-Fuller test for unit root Number of obs = 46

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.667	-4.187	-3.516

MacKinnon approximate p-value for Z(t) = 0.0000



```
. dfuller logef
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	0.001	-3.600	-2.938

MacKinnon approximate p-value for Z(t) = 0.9586

```
.
```

```
. dfuller D.logef
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.018	-3.607	-2.941

MacKinnon approximate p-value for Z(t) = 0.0000

```
.
```

```
. dfuller logef, trend
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-1.603	-4.178	-3.512

MacKinnon approximate p-value for Z(t) = 0.7911

```
.
```

```
. dfuller D.logef, trend
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-4.964	-4.187	-3.516

MacKinnon approximate p-value for Z(t) = 0.0002



```
. dfuller logeu
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-0.470	-3.600	-2.938

```
MacKinnon approximate p-value for Z(t) = 0.8978
```

```
. dfuller D.logeu
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.331	-3.607	-2.941

```
MacKinnon approximate p-value for Z(t) = 0.0000
```

```
. dfuller logeu, trend
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-1.819	-4.178	-3.512

```
MacKinnon approximate p-value for Z(t) = 0.6953
```

```
. dfuller D.logeu, trend
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.232	-4.187	-3.516

```
MacKinnon approximate p-value for Z(t) = 0.0001
```



```
. pperron logco2
```

Phillips-Perron test for unit root Number of obs = 48
 Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-0.097	-18.764	-13.236	-10.660
Z(t)	-0.137	-3.594	-2.936	-2.602

MacKinnon approximate p-value for Z(t) = 0.9457

```
. pperron D.logco2
```

Phillips-Perron test for unit root Number of obs = 47
 Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-33.341	-18.696	-13.204	-10.640
Z(t)	-4.839	-3.600	-2.938	-2.604

MacKinnon approximate p-value for Z(t) = 0.0000

```
. pperron logco2, trend
```

Phillips-Perron test for unit root Number of obs = 48
 Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-7.903	-25.444	-19.648	-16.704
Z(t)	-2.006	-4.168	-3.508	-3.185

MacKinnon approximate p-value for Z(t) = 0.5984

```
. pperron D.logco2, trend
```

Phillips-Perron test for unit root Number of obs = 47
 Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Boris Genaro Tipán Barrios	-25.316	-19.572	-16.656
Z(t)	-4.793	-4.178	-3.512

MacKinnon approximate p-value for Z(t) = 0.0005



. pperron logpib

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	0.775	-18.696	-13.204	-10.640
Z(t)	1.548	-3.600	-2.938	-2.604

MacKinnon approximate p-value for Z(t) = 0.9977

. pperron D.logpib

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-38.677	-18.628	-13.172	-10.620
Z(t)	-5.389	-3.607	-2.941	-2.605

MacKinnon approximate p-value for Z(t) = 0.0000

. pperron logpib, trend

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-2.721	-25.316	-19.572	-16.656
Z(t)	-1.334	-4.178	-3.512	-3.187

MacKinnon approximate p-value for Z(t) = 0.8793

. pperron D.logpib, trend

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Boris Genaro Tipán Barros				
Z(rho)	-40.922	-25.188	-19.496	-16.608
Z(t)	-5.823	-4.187	-3.516	-3.190

MacKinnon approximate p-value for Z(t) = 0.0000



. pperron loger

Phillips-Perron test for unit root

Number of obs	=	47
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	0.414	-18.696	-13.204	-10.640
Z(t)	0.987	-3.600	-2.938	-2.604

MacKinnon approximate p-value for Z(t) = 0.9941

. pperron D.loger

Phillips-Perron test for unit root

Number of obs	=	46
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-37.161	-18.628	-13.172	-10.620
Z(t)	-5.492	-3.607	-2.941	-2.605

MacKinnon approximate p-value for Z(t) = 0.0000

. pperron loger, trend

Phillips-Perron test for unit root

Number of obs	=	47
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-5.914	-25.316	-19.572	-16.656
Z(t)	-1.808	-4.178	-3.512	-3.187

MacKinnon approximate p-value for Z(t) = 0.7007

. pperron D.loger, trend

Phillips-Perron test for unit root

Number of obs	=	46
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Boris Genaro Tipán Barros	44			
Z(rho)	-37.225	-25.188	-19.496	-16.608
Z(t)	-5.624	-4.187	-3.516	-3.190



. pperron logef

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-0.021	-18.696	-13.204
Z(t)	-0.060	-3.600	-2.938

MacKinnon approximate p-value for Z(t) = 0.9532

. pperron D.logef

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-34.602	-18.628	-13.172
Z(t)	-5.057	-3.607	-2.941

MacKinnon approximate p-value for Z(t) = 0.0000

. pperron logef, trend

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-7.959	-25.316	-19.572
Z(t)	-2.010	-4.178	-3.512

MacKinnon approximate p-value for Z(t) = 0.5960

. pperron D.logef, trend

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Boris Genaro Tipán Barrios	-25.188	-19.496	-16.608
Z(t)	-5.006	-4.187	-3.516

MacKinnon approximate p-value for Z(t) = 0.0002



. pperron logeu

Phillips-Perron test for unit root

Number of obs	=	47
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-1.252	-18.696	-13.204	-10.640
Z(t)	-0.554	-3.600	-2.938	-2.604

MacKinnon approximate p-value for Z(t) = 0.8811

. pperron D.logeu

Phillips-Perron test for unit root

Number of obs	=	46
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-31.266	-18.628	-13.172	-10.620
Z(t)	-5.235	-3.607	-2.941	-2.605

MacKinnon approximate p-value for Z(t) = 0.0000

. pperron logeu, trend

Phillips-Perron test for unit root

Number of obs	=	47
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-8.133	-25.316	-19.572	-16.656
Z(t)	-2.016	-4.178	-3.512	-3.187

MacKinnon approximate p-value for Z(t) = 0.5928

. pperron D.logeu, trend

Phillips-Perron test for unit root

Number of obs	=	46
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Boris Genaro Tipán Bartos				
Z(rho)	-31.263	-25.188	-19.496	-16.608
Z(t)	-5.117	-4.187	-3.516	-3.190

MacKinnon approximate p-value for Z(t) = 0.0001



Anexo 2: Test de Dickey-Fuller Aumentado y Phillip Perron para India

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	0.695	-3.600	-2.938	-2.604
MacKinnon approximate p-value for Z(t) = 0.9897				
. dfuller D.logco2				
Dickey-Fuller test for unit root		Number of obs = 46		
Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-6.633	-3.607	-2.941	-2.605
MacKinnon approximate p-value for Z(t) = 0.0000				
. dfuller logco2, trend				
Dickey-Fuller test for unit root		Number of obs = 47		
Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-2.193	-4.178	-3.512	-3.187
MacKinnon approximate p-value for Z(t) = 0.4936				
. dfuller D.logco2, trend				
Dickey-Fuller test for unit root		Number of obs = 46		
Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-6.679	-4.187	-3.516	-3.190
MacKinnon approximate p-value for Z(t) = 0.0000				



```
. dfuller logpib
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	0.200	-3.600	-2.938

MacKinnon approximate p-value for Z(t) = 0.9723

```
. dfuller D.logpib
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-6.247	-3.607	-2.941

MacKinnon approximate p-value for Z(t) = 0.0000

```
. dfuller logpib, trend
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-1.143	-4.178	-3.512

MacKinnon approximate p-value for Z(t) = 0.9216

```
. dfuller D.logpib, trend
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-6.195	-4.187	-3.516

MacKinnon approximate p-value for Z(t) = 0.0000



```
. dfuller D.loger
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-8.529	-3.607	-2.941

```
MacKinnon approximate p-value for Z(t) = 0.0000
```

```
. dfuller loger, trend
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-1.129	-4.178	-3.512

```
MacKinnon approximate p-value for Z(t) = 0.9241
```

```
. dfuller D.loger, trend
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-8.606	-4.187	-3.516

```
MacKinnon approximate p-value for Z(t) = 0.0000
```



. dfuller logef

Dickey-Fuller test for unit root Number of obs = 47

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	0.990	-3.600	-2.938

MacKinnon approximate p-value for Z(t) = 0.9942

. dfuller D.logef

Dickey-Fuller test for unit root Number of obs = 46

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.568	-3.607	-2.941

MacKinnon approximate p-value for Z(t) = 0.0000

. dfuller logef, trend

Dickey-Fuller test for unit root Number of obs = 47

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-0.963	-4.178	-3.512

MacKinnon approximate p-value for Z(t) = 0.9489

. dfuller D.logef, trend

Dickey-Fuller test for unit root Number of obs = 46

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.598	-4.187	-3.516

MacKinnon approximate p-value for Z(t) = 0.0000



```
. dfuller logalem
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-0.491	-3.600	-2.938

MacKinnon approximate p-value for Z(t) = 0.8938

```
. dfuller D.logalem
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-7.331	-3.607	-2.941

MacKinnon approximate p-value for Z(t) = 0.0000

```
. dfuller logalem, trend
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-2.475	-4.178	-3.512

MacKinnon approximate p-value for Z(t) = 0.3407

```
. dfuller D.logalem, trend
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-7.248	-4.187	-3.516

MacKinnon approximate p-value for Z(t) = 0.0000



```
. dfuller logim
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-1.068	-3.600	-2.938

```
MacKinnon approximate p-value for Z(t) = 0.7276
```

```
. dfuller D.logim
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-8.414	-3.607	-2.941

```
MacKinnon approximate p-value for Z(t) = 0.0000
```

```
. dfuller logim, trend
```

```
Dickey-Fuller test for unit root Number of obs = 47
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-1.829	-4.178	-3.512

```
MacKinnon approximate p-value for Z(t) = 0.6904
```

```
. dfuller D.logim, trend
```

```
Dickey-Fuller test for unit root Number of obs = 46
```

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-8.305	-4.187	-3.516

```
MacKinnon approximate p-value for Z(t) = 0.0000
```





```
. pperron logco2
```

```
Phillips-Perron test for unit root          Number of obs = 47
                                                Newey-West lags = 3
```

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	0.267	-18.696	-13.204	-10.640
Z(t)	0.679	-3.600	-2.938	-2.604

MacKinnon approximate p-value for Z(t) = 0.9894

```
. pperron D.logco2
```

```
Phillips-Perron test for unit root          Number of obs = 46
                                                Newey-West lags = 3
```

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-48.220	-18.628	-13.172	-10.620
Z(t)	-6.646	-3.607	-2.941	-2.605

MacKinnon approximate p-value for Z(t) = 0.0000

```
. pperron logco2, trend
```

```
Phillips-Perron test for unit root          Number of obs = 47
                                                Newey-West lags = 3
```

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-9.716	-25.316	-19.572	-16.656
Z(t)	-2.341	-4.178	-3.512	-3.187

MacKinnon approximate p-value for Z(t) = 0.4116

```
. pperron D.logco2, trend
```

```
Phillips-Perron test for unit root          Number of obs = 46
                                                Newey-West lags = 3
```

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-48.642	-25.188	-19.496	-16.608
Z(t)	-6.687	-4.187	-3.516	-3.190

MacKinnon approximate p-value for Z(t) = 0.0000



. pperron logpib

Phillips-Perron test for unit root

Number of obs	=	47
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	0.092	-18.696	-13.204	-10.640
Z(t)	0.119	-3.600	-2.938	-2.604

MacKinnon approximate p-value for Z(t) = 0.9673

. pperron D.logpib

Phillips-Perron test for unit root

Number of obs	=	46
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-46.407	-18.628	-13.172	-10.620
Z(t)	-6.292	-3.607	-2.941	-2.605

MacKinnon approximate p-value for Z(t) = 0.0000

. pperron logpib, trend

Phillips-Perron test for unit root

Number of obs	=	47
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-4.237	-25.316	-19.572	-16.656
Z(t)	-1.354	-4.178	-3.512	-3.187

MacKinnon approximate p-value for Z(t) = 0.8740

. pperron D.logpib, trend

Phillips-Perron test for unit root

Number of obs	=	46
Newey-West lags	=	3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-46.427	-25.188	-19.496	-16.608
Z(t)	-6.239	-4.187	-3.516	-3.190

Boris Genaro Tipán Barros

MacKinnon approximate p-value for Z(t) = 0.0000



. pperron loger

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	0.884	-18.696	-13.204
Z(t)	1.326	-3.600	-2.938

MacKinnon approximate p-value for Z(t) = 0.9967

. pperron D.loger

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-55.412	-18.628	-13.172
Z(t)	-8.633	-3.607	-2.941

MacKinnon approximate p-value for Z(t) = 0.0000

. pperron loger, trend

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-3.180	-25.316	-19.572
Z(t)	-0.779	-4.178	-3.512

MacKinnon approximate p-value for Z(t) = 0.9674

. pperron D.loger, trend

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-55.196	-25.188	-19.496
Z(t)	-8.792	-4.187	-3.516

Boris Genaro Tipán Barros MacKinnon approximate p-value for Z(t) = 0.0000



. pperron logef

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	0.329	-18.696	-13.204	-10.640
Z(t)	0.832	-3.600	-2.938	-2.604

MacKinnon approximate p-value for Z(t) = 0.9921

. pperron D.logef

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-39.829	-18.628	-13.172	-10.620
Z(t)	-5.581	-3.607	-2.941	-2.605

MacKinnon approximate p-value for Z(t) = 0.0000

. pperron logef, trend

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-4.696	-25.316	-19.572	-16.656
Z(t)	-1.304	-4.178	-3.512	-3.187

MacKinnon approximate p-value for Z(t) = 0.8870

. pperron D.logef, trend

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-40.730	-25.188	-19.496	-16.608
Z(t)	-5.620	-4.187	-3.516	-3.190

MacKinnon approximate p-value for Z(t) = 0.0000
Boris Genaro Tipán Barros



. pperron logalem

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-0.559	-18.696	-13.204	-10.640
Z(t)	-0.434	-3.600	-2.938	-2.604

MacKinnon approximate p-value for Z(t) = 0.9043

. pperron D.logalem

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-50.103	-18.628	-13.172	-10.620
Z(t)	-7.341	-3.607	-2.941	-2.605

MacKinnon approximate p-value for Z(t) = 0.0000

. pperron logalem, trend

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-10.970	-25.316	-19.572	-16.656
Z(t)	-2.549	-4.178	-3.512	-3.187

MacKinnon approximate p-value for Z(t) = 0.3040

. pperron D.logalem, trend

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-50.113	-25.188	-19.496	-16.608
Z(t)	-7.256	-4.187	-3.516	-3.190

MacKinnon approximate p-value for Z(t) = 0.0000



Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-1.330	-18.696	-13.204
Z(t)	-1.074	-3.600	-2.938

MacKinnon approximate p-value for Z(t) = 0.7252

. pperron D.logim

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-48.989	-18.628	-13.172
Z(t)	-8.010	-3.607	-2.941

MacKinnon approximate p-value for Z(t) = 0.0000

. pperron logim, trend

Phillips-Perron test for unit root
Number of obs = 47
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-8.985	-25.316	-19.572
Z(t)	-2.073	-4.178	-3.512

MacKinnon approximate p-value for Z(t) = 0.5613

. pperron D.logim, trend

Phillips-Perron test for unit root
Number of obs = 46
Newey-West lags = 3

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(rho)	-48.245	-25.188	-19.496
Z(t)	-7.938	-4.187	-3.516

MacKinnon approximate p-value for Z(t) = 0.0000



Anexo 3: ARDL Bound Test para China e India

Pesaran/Shin/Smith (2001) ARDL Bounds Test

H0: no levels relationship F = 31.669
 t = -11.188

Critical Values (0.1-0.01), **F-statistic**, Case 5

	[I_0] L_1	[I_1] L_1	[I_0] L_05	[I_1] L_05	[I_0] L_025	[I_1] L_025	[I_0] L_01	[I_1] L_01
k_4	3.03	4.06	3.47	4.57	3.89	5.07	4.40	5.72

accept if F < critical value for I(0) regressors
reject if F > critical value for I(1) regressors

Critical Values (0.1-0.01), **t-statistic**, Case 5

	[I_0] L_1	[I_1] L_1	[I_0] L_05	[I_1] L_05	[I_0] L_025	[I_1] L_025	[I_0] L_01	[I_1] L_01
k_4	-3.13	-4.04	-3.41	-4.36	-3.65	-4.62	-3.96	-4.96

accept if t > critical value for I(0) regressors
reject if t < critical value for I(1) regressors

k: # of non-deterministic regressors in long-run relationship

Critical values from Pesaran/Shin/Smith (2001)

**Pesaran/Shin/Smith (2001) ARDL Bounds Test**

H0: no levels relationship F = 9.129
 t = -5.852

Critical Values (0.1-0.01), **F-statistic**, Case 5

	[I_0] L_1	[I_1] L_1	[I_0] L_05	[I_1] L_05	[I_0] L_025	[I_1] L_025	[I_0] L_01	[I_1] L_01
k_5	2.75	3.79	3.12	4.25	3.47	4.67	3.93	5.23

accept if F < critical value for I(0) regressors
reject if F > critical value for I(1) regressors

Critical Values (0.1-0.01), **t-statistic**, Case 5

	[I_0] L_1	[I_1] L_1	[I_0] L_05	[I_1] L_05	[I_0] L_025	[I_1] L_025	[I_0] L_01	[I_1] L_01
k_5	-3.13	-4.21	-3.41	-4.52	-3.65	-4.79	-3.96	-5.13

accept if t > critical value for I(0) regressors
reject if t < critical value for I(1) regressors

k: # of non-deterministic regressors in long-run relationship
Critical values from Pesaran/Shin/Smith (2001)



Anexo 4 Estimación ARDI y pruebas de Diagnóstico para China

```
. ardl logco2 logpib loger logef logeu, ec bic trendvar(year) regstore(ecreg)
```

```
ARDL(1,0,2,0,2) regression
```

Sample: 1975 - 2018

Number of obs	=	44
R-squared	=	0.8400
Adj R-squared	=	0.7915
Root MSE	=	0.0237

Log likelihood = 108.60932

	D.logco2	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
ADJ						
logco2	L1.	-.9003251	.0804706	-11.19	0.000	-1.064044 -.7366064
LR						
logpib		-.0729434	.0416052	-1.75	0.089	-.1575898 .011703
loger		.0940026	.0603008	1.56	0.129	-.0286802 .2166855
logef		1.101832	.0576587	19.11	0.000	.9845249 1.21914
logeu		-.8606712	.0986919	-8.72	0.000	-1.061461 -.659881
SR						
loger	D1.	-.1355217	.0469592	-2.89	0.007	-.231061 -.0399825
	LD.	-.1096653	.047031	-2.33	0.026	-.2053506 -.0139799
logeu	D1.	.5816151	.1505248	3.86	0.000	.27537 .8878602
	LD.	.5319869	.166716	3.19	0.003	.1928006 .8711733
year		-.050673	.0052133	-9.72	0.000	-.0612795 -.0400665
_cons		98.17552	10.23878	9.59	0.000	77.34457 119.0065



White's test for Ho: homoskedasticity
against Ha: unrestricted heteroskedasticity

chi2(43) = 44.00
Prob > chi2 = 0.4290

Cameron & Trivedi's decomposition of IM-test

Source	chi2	df	p
Heteroskedasticity	44.00	43	0.4290
Skewness	15.29	10	0.1217
Kurtosis	0.83	1	0.3620
Total	60.13	54	0.2636

. estat archlm
LM test for autoregressive conditional heteroskedasticity (ARCH)

lags(p)	chi2	df	Prob > chi2
1	1.075	1	0.2998

H0: no ARCH effects vs. H1: ARCH(p) disturbance

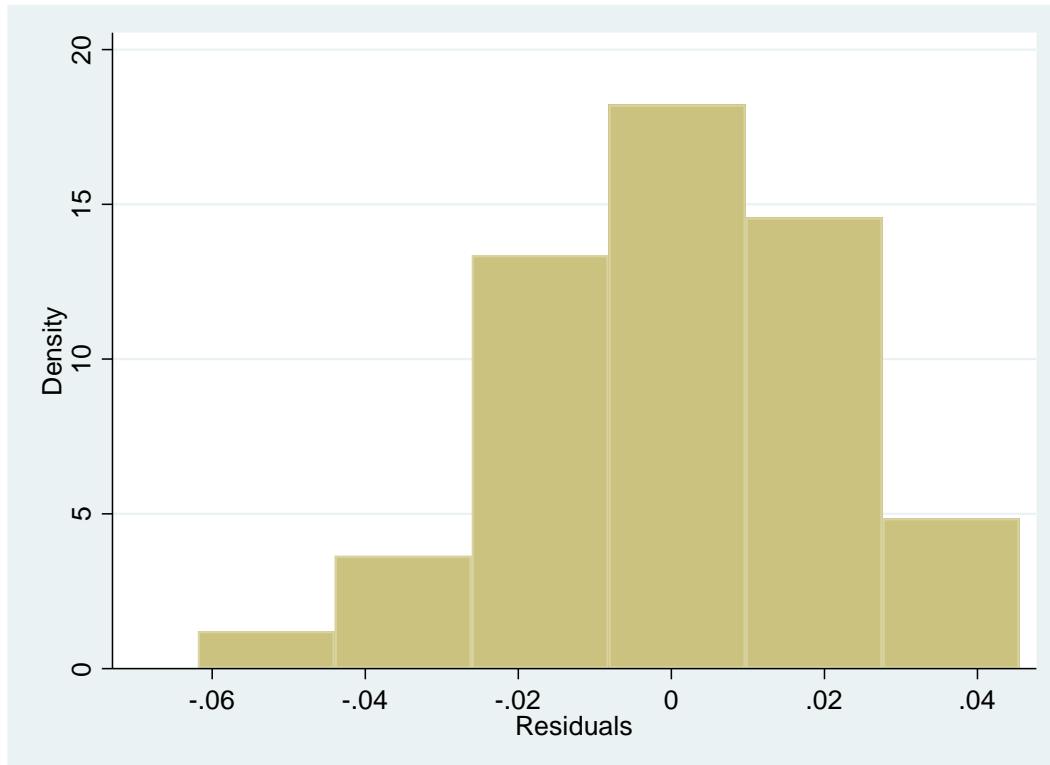


Ramsey RESET test using powers of the fitted values of D.logco2

H₀: model has no omitted variables

F(3, 30) = 0.59

Prob > F = 0.6233





Anexo 5: Estimación ARDL y pruebas de diagnóstico para India.

. ardl logco2 logpib loger logef logalem, ec bic trendvar(year) regstore(ecreg)

ARDL(2,2,4,0,0) regression

Sample: 1975 - 2030
Number of obs = 56
R-squared = 0.6737
Adj R-squared = 0.5727
Root MSE = 0.0165
Log likelihood = 158.5907

	D.logco2	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
ADJ						
logco2						
L1.	-.4714648	.0877473	-5.37	0.000	-.6485459	-.2943836
LR						
logpib	.4391973	.0981439	4.48	0.000	.2411349	.6372598
loger	-.4676814	.1414334	-3.31	0.002	-.7531056	-.1822572
logef	.6610707	.1269034	5.21	0.000	.4049693	.9171721
logalem	-.4492631	.1523168	-2.95	0.005	-.7566509	-.1418753
SR						
logco2						
LD.	-.3111141	.1142603	-2.72	0.009	-.5417007	-.0805275
logpib						
D1.	-.13823	.039938	-3.46	0.001	-.2188283	-.0576318
LD.	-.0877708	.0397704	-2.21	0.033	-.1680307	-.007511
loger						
D1.	.0947793	.0373439	2.54	0.015	.0194163	.1701424
LD.	.0937933	.0313128	3.00	0.005	.0306016	.156985
L2D.	.1208228	.0298725	4.04	0.000	.0605377	.181108
L3D.	.1068158	.0280291	3.81	0.000	.0502508	.1633807
year	-.0061157	.0030968	-1.97	0.055	-.0123652	.0001339
_cons	10.17734	6.077395	1.67	0.101	-2.087337	22.44202

White's test for Ho: homoskedasticity
against Ha: unrestricted heteroskedasticity

chi2(50) = 56.00
Prob > chi2 = 0.2599

Cameron & Trivedi's decomposition of IM-test

Source	chi2	df	p
Heteroskedasticity	56.00	50	0.2599
Skewness	20.70	13	0.0790
Kurtosis	0.98	1	0.3229
Total	77.68	64	0.1170



```
. estat archlm  
LM test for autoregressive conditional heteroskedasticity (ARCH)
```

lags(p)	chi2	df	Prob > chi2
1	0.766	1	0.3814

H0: no ARCH effects vs. H1: ARCH(p) disturbance

```
. estat ovtest
```

```
Ramsey RESET test using powers of the fitted values of D.logco2
```

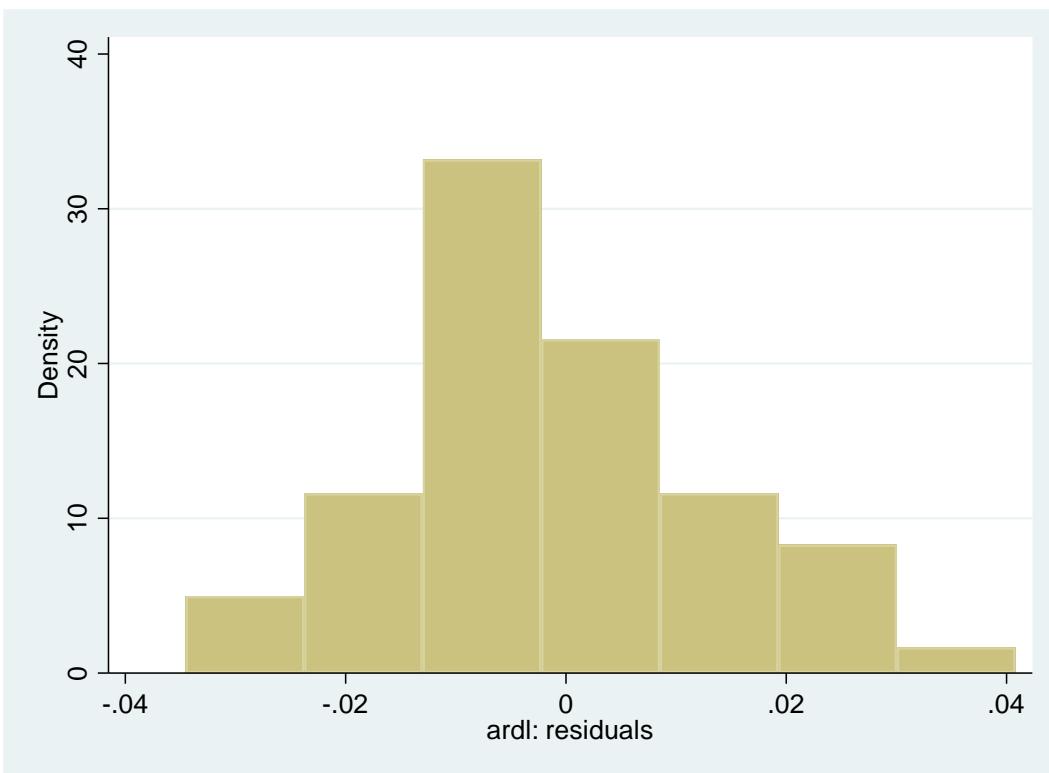
Ho: model has no omitted variables

F(3, 39) = 0.21
Prob > F = 0.8894

```
. sktest resid
```

```
Skewness/Kurtosis tests for Normality
```

Variable	Obs	Pr(Skewness)	Pr(Kurtosis)	joint	
				adj	chi2(2)
residuos	56	0.3346	0.2365	2.45	0.2941





Anexo 6: Rezago óptimo para China e India

Selection-order criteria
 Sample: 1975 - 2018 Number of obs = 44

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	111.505				5.4e-09	-4.84113	-4.76594	-4.63838
1	381.165	539.32	25	0.000	8.1e-14	-15.9621	-15.5109*	-14.7456*
2	408.549	54.767	25	0.001	7.6e-14	-16.0704	-15.2433	-13.8402
3	432.829	48.559	25	0.003	8.9e-14	-16.0377	-14.8346	-12.7937
4	467.252	68.846*	25	0.000	7.4e-14*	-16.466*	-14.887	-12.2083

Endogenous: logco2 logpib loger logef logeu

Exogenous: _cons

. varsoc logco2 logpib loger logef logalem logim

Selection-order criteria
 Sample: 1975 - 2018 Number of obs = 44

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	173.501				2.0e-11	-7.61366	-7.52344	-7.37037
1	458.829	570.66	36	0.000	2.4e-16*	-18.9468	-18.3152*	-17.2437*
2	489.951	62.243	36	0.004	3.3e-16	-18.725	-17.5521	-15.5622
3	519.407	58.911	36	0.009	5.8e-16	-18.4276	-16.7133	-13.8049
4	569.013	99.212*	36	0.000	5.4e-16	-19.046*	-16.7904	-12.9636

Endogenous: logco2 logpib loger logef logalem logim

Anexo 7: Prueba de Cointegración de Johansen para China e India

. vecrank logco2 logpib loger logef logeu, trend(constant) lags(4)

Johansen tests for cointegration					
Trend:	constant	Number of obs	=	44	
Sample:	1975 - 2018	Lags	=	4	
maximum			5%		
rank	parms	LL	eigenvalue	trace	critical
0	80	415.98409	.	102.5350	68.52
1	89	442.2796	0.69737	49.9440	47.21
2	96	454.23405	0.41922	26.0351*	29.68
3	101	463.44693	0.34214	7.6093	15.41
4	104	466.459	0.12795	1.5852	3.76
5	105	467.25161	0.03539		



```
. vecrank logco2 logpib loger logef logalem, trend(constant) lags(1)
```

Johansen tests for cointegration

Trend: constant

Number of obs = 47

Sample: 1972 - 2018

Lags = 1

5%					
maximum		trace	critical		
rank	parms	LL	eigenvalue	statistic	value
0	5	384.35942	.	68.5560	68.52
1	14	396.82476	0.41165	43.6253*	47.21
2	21	407.98656	0.37810	21.3017	29.68
3	26	414.48658	0.24164	8.3016	15.41
4	29	418.4831	0.15639	0.3086	3.76
5	30	418.6374	0.00654		

Anexo 8: Estimación OLS para China e India

```
. reg logco2 logpib logied loger logef logeu
```

Source	SS	df	MS	Number of obs	=	48
Model	19.0480046	5	3.80960093	F(5, 42)	=	1582.08
Residual	.101134456	42	.002407963	Prob > F	=	0.0000
Total	19.1491391	47	.407428491	R-squared	=	0.9947
				Adj R-squared	=	0.9941
				Root MSE	=	.04907

logco2	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
logpib	-.0030256	.0783044	-0.04	0.969	-.1610502 .154999
logied	-.0154126	.0051963	-2.97	0.005	-.0258992 -.0049261
loger	-.1851604	.0703047	-2.63	0.012	-.3270411 -.0432797
logef	.8116145	.0837772	9.69	0.000	.6425454 .9806837
logeu	-.9424852	.1718619	-5.48	0.000	-1.289317 -.595654
_cons	-.5618315	.7175477	-0.78	0.438	-2.009901 .8862385



. reg logco2 logpib loger logef logalem

Source	SS	df	MS	Number of obs	=	60
Model	23.9577174	4	5.98942936	F(4, 55)	=	7672.50
Residual	.042934965	55	.000780636	Prob > F	=	0.0000
				R-squared	=	0.9982
Total	24.0006524	59	.406790719	Adj R-squared	=	0.9981
				Root MSE	=	.02794

logco2	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
logpib	.1540298	.0272001	5.66	0.000	.0995197	.20854
loger	-.0161617	.0454956	-0.36	0.724	-.1073369	.0750136
logef	.3097854	.0356942	8.68	0.000	.2382526	.3813182
logalem	-.5627295	.079364	-7.09	0.000	-.7217784	-.4036805
_cons	-1.363466	.3624613	-3.76	0.000	-2.089855	-.6370777