


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS



**EFFECTOS CAUSALES DE TRATAMIENTO EN SERIES DE TIEMPO:
EMISIONES DE CO₂, CONSUMO ENERGÉTICO Y CRECIMIENTO
ECONÓMICO**

Tesis de Grado presentada por

Cristian David Llanos Angulo

como requisito para optar al grado de
Magíster en Ciencias de la Ingeniería Industrial

Profesor Referente:
Dr. Werner Kristjanpoller Rodríguez

Profesor Correferente Interno:
Dr.

Profesor Correferente Externo:
Dr.

VALPARAÍSO, ABRIL 2022

TITULO DE LA TESIS:

EFFECTOS CAUSALES DE TRATAMIENTO EN SERIES DE TIEMPO: EMISIONES DE CO₂, CONSUMO ENERGÉTICO Y CRECIMIENTO ECONÓMICO

AUTOR:

Cristian David Llanos Angulo

TRABAJO DE TESIS, presentado en cumplimiento de los requisitos para el Grado de Magíster en Ciencias de la Ingeniería Industrial de la Universidad Técnica Federico Santa María.

Dr. Werner Kristjanpoller Rodríguez

Dr.

Dr.

VALPARAÍSO, Chile. ABRIL 2022



...A mi familia, pareja y amigos.

RESUMEN EJECUTIVO

Este estudio extiende la literatura sobre el uso de redes neuronales junto con técnicas de causalidad para el desarrollo de políticas económicas. Se presenta evidencia empírica sobre los efectos del consumo de energía y las emisiones de carbono en el crecimiento económico per cápita con datos de panel desbalanceados para 94 países entre los años 1971 y 2018. Para ello, se presenta un marco metodológico que emplea la transformación de las series temporales en un conjunto de intervalos de tratamiento según las potenciales políticas que puede adoptar un país. A partir de los intervalos de tratamiento, se propone un modelo de dos etapas basado en redes neuronales recurrentes (*Long Short-Term Memory*, LSTM) junto con un clasificador multiclase para obtener puntuaciones de propensión. A continuación, se estiman los efectos utilizando los resultados potenciales dinámicos en un marco de causalidad basada en tratamientos. Los resultados indican que, tanto para las políticas de consumo energético como para las de emisiones de carbono, el rango de tratamiento que genera los mejores resultados se sitúa entre el -2 % y el 0,4 %; además, en ambos casos, las políticas extremas, como reducir o aumentar drásticamente el consumo energético, generan los peores resultados para el desarrollo económico. Se observa que cuando se agrupan los países según el nivel de ingresos, los de ingresos medio-bajos y bajos tienen un mejor desarrollo bajo una política de crecimiento moderado con respecto a los niveles de emisiones de carbono y consumo de energía, lo que apoya la hipótesis de la Curva Ambiental de Kuznets. Lo anterior podría estar relacionada con el hecho de que estos países no tienen el nivel de infraestructura necesario para sostener el crecimiento. Estos hallazgos tienen importantes implicancias para el análisis, formulación e implementación de políticas económicas, energéticas y medioambientales.

ABSTRACT

This study broadens the research on the use of neural networks in conjunction with causality techniques for economic policy development. Empirical evidence is presented on the effects of energy consumption and carbon emissions on per capita economic growth with unbalanced panel data for 94 countries between 1971 and 2018. We present a methodological framework that employs the transformation of time series into a set of treatment intervals according to potential policies that a country may adopt. Based on treatment intervals, a two-stage model based on recurrent neural networks (Long Short-Term Memory) is proposed together with a multiclass classifier to obtain propensity scores. We then estimate the effects using the dynamic potential outcomes under a framework of treatment-based causality. The results indicate that for both energy consumption and carbon emissions policies, the treatment range that generates the best performance is between -2 % and 0.4 %; moreover, in both cases, extreme policies such as drastically reducing or increasing energy consumption generates the worst results for economic development. We find that when grouping countries according to income level, mid-low and low levels of income have better development under moderate growth policy with respect to levels of carbon emissions and energy consumption, supporting the Environmental Kuznets Curve hypothesis. This finding could be related to the fact that these countries do not have the level of infrastructure to sustain growth. However, the impact of this growth on pollution would not be comparable to the reduction effect of high-income countries, given that they make the largest overall contribution to global emissions. These findings have important implications for the analysis, formulation and implementation of economic, energy and environmental policies.

ÍNDICE DE CONTENIDOS

1. INTRODUCCIÓN	1
1.1. Motivación y contribuciones	1
1.2. Objetivos	5
1.2.1. Objetivo general	5
1.2.2. Objetivos específicos	5
2. MARCO TEÓRICO	6
2.1. Antecedentes previos de las relaciones causales	6
2.2. Causalidad basada en tratamientos en datos macroeconómicos	8
2.3. Machine learning y su aplicación en causalidad	12
3. METODOLOGÍA	14
3.1. Datos	14
3.2. Metodología propuesta	15
3.2.1. Generación de tratamientos	15
3.2.2. Estimación de las puntuajes de propensión	16
3.2.2.1. Selección de variables de entrada	17
3.2.2.2. Red neuronal de dos etapas	18
3.2.3. Efecto de tratamiento dinámico	20
4. RESULTADOS	24
4.1. Especificación del modelo	24
4.2. Efecto de las emisiones de carbono	26
4.3. Efectos del consumo energético	30

4.4. Efectos direccionales conjuntos	33
5. DISCUSIÓN	35
6. CONCLUSIONES	38
Bibliografía	41
A.	49
A.1. Segmentación de datos	50
A.2. Resumen mejor intervalo de tratamiento por país	52
B.	54
B.1. Comparación métodos de clustering	55
B.2. Comparación de AUC en puntajes de propensión	56
B.3. Efectos Emisiones de carbono sobre PIB	57
B.4. Efectos del Consumo energético sobre PIB	59
B.5. Efectos direccionales conjuntos	62

ÍNDICE DE TABLAS

4.1. Resultados de la agrupación de las emisiones de carbono y el consumo de energía.	25
A.1. Listado de países y clasificaciones.	50
A.1. Listado de países y clasificaciones (continuación)	51
B.1. Resumen de los mejores intervalos de tratamiento por país	52
B.1. Resumen de los mejores intervalos de tratamiento por país (continuación)	53

ÍNDICE DE FIGURAS

3.1. Representación gráfica de la metodología utilizada.	17
4.1. Efecto del tratamiento ponderado de las emisiones de carbono sobre el PIB per cápita para los países de la OCDE	27
4.2. Efecto ponderado del tratamiento de las emisiones de carbono sobre el PIB per cápita para todos los países	28
4.3. Efecto ponderado del tratamiento de las emisiones de carbono sobre el PIB per cápita agrupado por nivel de ingresos	29
4.4. Mapa mundial donde se indica el mejor intervalo de tratamiento en las emisiones de CO ₂ para cada país de la muestra. Para más detalles sobre los intervalos obtenidos, véase Tabla B.1.	30
4.5. Mapa mundial donde se indica el mejor intervalo de tratamiento en el consumo de energía para cada país de la muestra. Para más detalles sobre los intervalos obtenidos, véase Tabla B.1.	31
4.6. Mapa mundial donde se indica el mejor tratamiento conjunto direccional para cada país de la muestra. Para más detalles sobre los rangos obtenidos, véase Tabla B.1	31
4.7. Efecto ponderado del tratamiento del consumo de energía sobre el PIB per cápita agrupado por nivel de ingresos	32
4.8. Efecto ponderado del tratamiento direccional conjunto sobre el PIB per cápita agrupado por nivel de ingresos	34
B.1. Comparación entre los métodos de clustering	55

B.2. Comparación de la estimación de la puntuación de propensión	56
B.3. Efecto ponderado del tratamiento de las emisiones de carbono sobre el PIB per cápita agrupado por nivel de ingresos (solo crisis)	57
B.4. Efecto ponderado del tratamiento de las emisiones de carbono sobre el PIB per cápita agrupado por nivel de ingresos (sin crisis ni recuperación) . . .	58
B.5. Efecto ponderado del tratamiento del consumo energético sobre el PIB per cápita para los países de la OCDE	59
B.6. Efecto ponderado del tratamiento del consumo energético sobre el PIB per cápita para todos los países	60
B.7. Efecto ponderado del tratamiento del consumo de energía sobre el PIB per cápita agrupado por nivel de ingresos (solo crisis)	60
B.8. Efecto ponderado del tratamiento del consumo de energía sobre el PIB per cápita agrupado por nivel de ingresos (sin crisis ni recuperación)	61
B.9. Efecto ponderado del tratamiento direccional conjunto sobre el PIB per cápita agrupado por nivel de ingresos (solo crisis)	62
B.10. Efecto ponderado del tratamiento direccional conjunto sobre el PIB per cápita agrupado por nivel de ingresos (sin crisis ni recuperación)	63
B.11. Efecto ponderado del tratamiento conjunto direccional sobre el PIB per cápita	63

CAPÍTULO 1

INTRODUCCIÓN

1.1. Motivación y contribuciones

La relación entre el consumo de energía, las emisiones de CO₂ y el crecimiento económico ha sido un tema cada vez de mayor relevancia debido al aumento en la preocupación por el cambio climático. La celebración de la Convención Marco de las Naciones Unidas sobre el Cambio Climático en 1992, reconocida como el primer hito en este campo, ha sido ratificada por 197 países. Posteriormente, con el Protocolo de Kioto en 1997, se asumió el primer compromiso mundial para reducir las emisiones responsables del calentamiento global, lo que ha sentado las bases de numerosos compromisos internacionales hasta la fecha.

El Acuerdo de París, adoptado por 196 países en 2015, en parte representa, la culminación de los dos acuerdos mencionados anteriormente. Ninguno de estos pactos fue fácil de alcanzar, puesto que para llevar a cabo estos convenios, se requiere mantener el equilibrio entre los objetivos climáticos con el crecimiento económico, además de comprender el impacto que el grado de inmediatez en la obtención de estos objetivos tiene en el desarrollo económico de un país. En algunos casos, los países más pequeños y menos desarrollados pueden percibir como poco equitativa la exigencia de reducir el consumo de energía y las emisiones de carbono. Esto debido a que los países con mayor desarrollo han sido los que más han contribuido al cambio climático y cosechado los beneficios de esta práctica. Por el contrario, países desarrollados podrían rehusarse a tener que asumir los costes neces-

rios para ayudar a compensar la carga de los países más pequeños. No obstante, una vez acordado, los países firmantes deben determinar aquellas políticas que ayuden a alcanzar los objetivos climáticos manteniendo sus objetivos de crecimiento económico lo cual no resulta ser una tarea sencilla.

Como resultado de los acuerdos internacionales mencionados anteriormente, los países participantes han empleado diferentes estrategias energéticas para reducir las emisiones de CO₂. Con el fin de incentivar la adhesión a estas las políticas, los gobiernos han impuesto sanciones por el exceso de consumo, así como créditos y subvenciones para la modernización y el uso de energías limpias. Estas estrategias pueden tener éxito si se fijan en un nivel adecuado, con el objetivo de lograr una huella energética neta nula y aumentar la concienciación del público sobre el uso de estas nuevas tecnologías.

Sin embargo, la creciente preocupación también recae en países que se encuentran en desarrollo, en donde es importante generar políticas medioambientales que sean coherentes con los objetivos fijados en los tratados, pero que también fomenten el crecimiento económico. Es aquí donde radica la relevancia y utilidad en la obtención de efectos causales a largo plazo sobre políticas específicas y en la adopción de estos nuevos programas globales.

Como se menciona en Waheed et al. [2019], varios estudios han intentado evidenciar la relación entre el consumo de energía, las emisiones de carbono y el crecimiento económico, haciendo uso de diferentes metodologías para la estimación de la causalidad, tanto a nivel individual como agregado. En particular, en cuanto a la relación entre el consumo de energía y el Producto Interno Bruto (PIB), las cuatro hipótesis más utilizadas son: la hipótesis de la conservación (causalidad unidireccional del PIB al consumo de energía); la hipótesis del crecimiento (causalidad unidireccional del consumo de energía al PIB); la hipótesis de la retroalimentación (causalidad bidireccional); y la hipótesis de la neutralidad (ausencia de efectos causales). Estas cuatro relaciones hipotéticas han sido ampliamente estudiadas sin ningún resultado concluyente.

Desde otra arista y con el fin de analizar el impacto del nivel de ingresos de los países con sus respectivos niveles de contaminación, otros estudios han intentado poner a prueba la conocida hipótesis de curva ambiental de Kuznets (*EKC*), la cual sugiere que existe una relación con forma de U invertida entre el nivel de ingresos y el grado de contaminación.

Aun así, al igual que con el resto de las hipótesis, no hay ningún resultado concluyente que confirme o rechace dicha hipótesis [Dinda, 2004; Kijima et al., 2010; Furuoka, 2015].

Por otro lado, a pesar del gran número de estudios en el área, todavía no hay consenso respecto a las teorías relacionadas con el consumo de energía, las emisiones de carbono y su relación con el crecimiento económico. Esto podría estar relacionado, como mencionan Dinda [2004], Stern [2004] y Yang and Zhao [2014], a los datos utilizados, el periodo de tiempo analizado, los diferentes enfoques econométricos y el posible sesgo debido a la omisión de variables relevantes. Además, mientras que los modelos de causalidad clásicos proporcionan una dirección causal entre las variables, todavía hay una falta de acuerdo en el establecimiento de políticas claras, ya que la pregunta de si existen diferencias entre las políticas restrictivas o más permisivas es un tema no resuelto en la literatura.

Angrist et al. [2018] proponen un enfoque causal alternativo para evaluar los impactos de las políticas monetarias a través de los efectos causales basados en tratamiento y la generación de los efectos de tratamiento de políticas a través de la estimación de la puntuación de propensión. Sin embargo, el gran número de variables involucradas con potenciales relaciones no lineales hace que los métodos de estimación probabilística, como la regresión logística, no identifiquen correctamente los sesgos.

En los últimos años, diversos estudios han incluido el uso de redes neuronales dentro de escenarios de tratamiento dependientes del tiempo los cuales han mostrado resultados favorables en modelos estructurales marginales [Lim et al., 2018] y mediante la estimación de puntuaciones de propensión [Lee et al., 2010; Setoguchi et al., 2008; Westreich et al., 2010]. Por lo tanto, la aplicación de técnicas de *machine learning* junto con los efectos de tratamientos dinámicos parece ser una alternativa viable para abordar estos problemas. Bajo esta premisa, este estudio contribuye al cuerpo de investigación de las siguientes cuatro maneras:

En primer lugar, se propone una metodología híbrida basada en redes neuronales para obtener los efectos de tratamientos causales del consumo de energía y las emisiones de carbono sobre el PIB per cápita, teniendo en cuenta variables clave e incluyendo estos factores que influyen en el tratamiento como *input* en las redes. De este modo, se intenta mejorar la estimación de las puntuaciones de propensión reduciendo así, el sesgo.

En segundo lugar, establecer un marco metodológico de discretización de los tratamientos en series temporales, que permita establecer un caso base y obtener efectos comparables bajo una estructura de elaboración de políticas económicas y ambientales.

En tercer lugar, bajo este mismo enfoque, una discretización de series temporales permite la elaboración de variables más complejas como una causalidad conjunta, donde dos variables se abordan como un único tipo de tratamiento. Esto permite llevar a cabo un análisis de los efectos conjuntos del consumo de energía y las emisiones de carbono sobre el crecimiento económico.

En cuarto lugar y último, se contribuye a la literatura con información actualizada sobre la relación entre el consumo de energía, las emisiones de CO₂ y el crecimiento económico, incluyendo una variación que no sólo considera los efectos de las crisis económicas históricas, sino también los períodos de recuperación posteriores, obteniendo un espectro de los efectos más amplio y claro.

1.2. Objetivos

1.2.1. Objetivo general

Proponer una metodología con la capacidad de proporcionar una comparativa para distintas políticas de tratamientos con el fin de determinar los efectos causales en series de tiempo y generar una serie de estimaciones comparables y medibles para los efectos del consumo energético y las emisiones de carbono sobre el crecimiento económico medido a través del PIB.

1.2.2. Objetivos específicos

- Desarrollar una metodología de generación de intervalos de tratamiento para políticas económicas a partir de series de datos continuos.
- Establecer un marco metodológico basado en redes neuronales que permita incorporar las relaciones temporales y de corte transversal de las variables en estudio con un enfoque causal.
- Determinar los efectos de las emisiones de carbono y el consumo energético sobre el PIB bajo un conjunto de políticas aplicables a los países en estudio.
- Generar comparativas en los efectos causales entre países agrupados por variables de interés, con el fin de observar disimilitudes entre países desarrollados y en vías de desarrollo.

CAPÍTULO 2

MARCO TEÓRICO

2.1. Antecedentes previos de las relaciones causales

La relación entre el consumo de energía, las emisiones de carbono y el crecimiento económico es crucial en una amplia gama de aplicaciones. Por ejemplo, en la gestión de la política económica; la gestión del consumo energético total y sectorial; y la planificación medioambiental a nivel nacional y mundial, esto debido a que no todos los sectores consumen energía a los mismos niveles ni emiten carbono por igual. Por ello, el interés por estudiar estas relaciones ha generado numerosos trabajos en el área, teniendo en cuenta diferentes periodos de tiempo, indicadores, conjuntos de países y técnicas econométricas [Ang, 2008; Apergis and Payne, 2010; Zhao et al., 2017; Rauf et al., 2018].

A pesar de la existencia de numerosos estudios y de la utilización de diversos enfoques, los resultados obtenidos difieren, proporcionando diferentes implicaciones políticas sobre las interdependencias entre el consumo de energía, las emisiones de carbono y el crecimiento económico [Waheed et al., 2019]. Por este motivo, no se desprende claramente qué políticas pueden ser adoptadas en un país determinado de manera que se apliquen, eficazmente, medidas de control ambiental manteniendo al mismo tiempo un buen crecimiento económico.

Del mismo modo, otros estudios se han centrado en encontrar las relaciones entre el consumo de energía, las emisiones de CO₂ y el crecimiento económico bajo un único enfoque metodológico [Soytas et al., 2007; Soytas and Sari, 2009; Apergis and Payne,

2009; Halicioglu, 2009; Yang and Zhao, 2014; Antonakakis et al., 2017].

En un trabajo reciente, Acheampong [2018] analiza mediante un VAR de panel y System-GMM la relación causal para 116 países diferenciados por región. Entre sus hallazgos, a nivel global, existe una relación positiva entre las emisiones de carbono y el crecimiento económico; sin embargo, se identificó un efecto contrario entre el consumo energético y el crecimiento económico. Al mismo tiempo, el análisis por regiones mostró efectos causales disímiles, lo que apoya la idea de que las políticas energéticas deben tener una lógica específica en función de la ubicación del país. Además, el autor presenta pruebas que contribuyen a la hipótesis de la curva ambiental de Kuznets (EKC) a nivel mundial.

La hipótesis de la curva ambiental de Kuznets (EKC) plantea la hipótesis de una relación de U invertida entre el nivel de renta y el nivel de contaminación de los países. Esta hipótesis, después del trabajo seminal de Grossman and Krueger [1991], ha sido objeto de múltiples estudios con el fin de encontrar pruebas de la misma. Sobre esto, Dinda [2004]; Kijima et al. [2010] y Furuoka [2015] ofrecen una amplia revisión.

Por otro lado existen cuatro hipótesis para la relación entre consumo energético y el crecimiento económico, generalmente asociado al PIB. La primera es la hipótesis de la conservación, que sostiene que el PIB impulsa el consumo de energía. Kraft and Kraft [1978] fueron uno de los primeros en establecer esta relación mediante el uso de causalidad estadística de Granger. La segunda hipótesis corresponde a la hipótesis del crecimiento, que sostiene que el consumo de energía provoca cambios en el crecimiento. Esta teoría ha sido respaldada por estudios como Sari et al. [2013] y Bowden and Payne [2009]. La tercera es la hipótesis de la retroalimentación, que implica una relación causal bidireccional entre el PIB y el consumo de energía. [Stern, 1993; Mohammadi and Parvaresh, 2014; Mishra et al., 2009]. La cuarta y última corresponde a la hipótesis neutral, que establece que no existe una relación causal entre el PIB y el consumo de energía en ninguna dirección. Un número significativo de autores apoyan esta teoría como Soytaş et al. [2007], Payne [2009] y más recientemente Kourtzidis et al. [2018].

Sin embargo, a pesar del gran número de estudios, aún no existe consenso sobre ninguna de las teorías sobre el consumo de energía, las emisiones de carbono, y su relación con el crecimiento económico. Además, existe una falta de precisión a la hora de establecer

políticas claras. Mientras que los modelos clásicos de causalidad pueden proporcionar una dirección causal entre las variables, la pregunta de si se deben aplicar políticas agresivas o graduales es una cuestión no resuelta en la literatura. Por ello, la aplicación de modelos de tratamiento causal en economía puede aportar una solución a esta problemática, facilitando el proceso de toma de decisiones.

2.2. Causalidad basada en tratamientos en datos macro-económicos

Estudiar la dependencia entre series temporales es crucial para prácticamente todos los estudios de sistemas complejos, y la capacidad de describir la estructura de causalidad en los datos financieros puede ser de gran utilidad para la generación de políticas económicas. Existe una importante distinción entre la causalidad basada en intervenciones o tratamientos, introducida por Pearl et al. [2000], y la causalidad estadística, desarrollada por Granger [1980]. El primer concepto combina datos estadísticos y no estadísticos con el fin de comparar efectos sobre sujetos con tratamientos en contraposición a un caso base controlado, este tipo de esquema ha sido ampliamente utilizado en el área clínica para medir la eficacia de terapias y el desarrollo de medicamentos, así como también, en publicidad [Sun et al., 2015; Wang et al., 2015], educación y generación de políticas públicas. La causalidad estadística, por otro lado, no opera con el concepto de intervención y está mayormente relacionado a herramientas de análisis de datos. Por lo tanto, la causalidad en sentido estadístico corresponde a un tipo de dependencia, en la que se infiere la dirección como resultado del conocimiento de la estructura temporal y la noción de que la causa tiene que preceder al efecto.

La causalidad en base a tratamientos entonces, depende de que exista un grupo de unidades que reciban un estímulo, mientras que otro grupo de similares características actúe como base de referencia. Los efectos generados se conocen como *potential outcomes*, los cuales han sido definidos como un vector de resultados para un mismo período dados los diferentes niveles de tratamiento. A modo de ejemplo, si los *potential outcomes* son denotados por $Y_t(0)$ e $Y_t(1)$, donde $Y_t(0)$ es el resultado que se obtendría en el periodo t si

no se aplicara la política y del mismo modo, $Y_t(1)$ es el resultado que se obtendría en el periodo t si se aplica la política. Rubin [1973] define el efecto causal como la diferencia entre este par de *potential outcomes*, es decir, $Y_t(1) - Y_t(0)$, como el efecto del tratamiento de la política en el periodo t . Este enfoque genera un problema fundamental debido a la falta de observaciones, puesto que en el periodo t , la política puede o no ser aplicada, pero no es posible que sucedan ambas cosas, por lo que existen casos en los que no se podrá obtener el contrafactual del tratamiento dado que existe una temporalidad en las variables.

Tres supuestos son necesarios para la inferencia causal siguiendo el teorema de los resultados potenciales o *potential outcomes* [10]. En primer lugar, la hipótesis del valor unitario estable del tratamiento (SUTVA) garantiza que el resultado potencial de una unidad no se ve afectado por los cambios en la asignación del tratamiento de otras unidades. Este supuesto puede violarse cuando los efectos del tratamiento se propagan naturalmente a través de la red que conforma a las unidades de estudio. El segundo supuesto es la ausencia de confusión condicional o *conditional unconfoundedness*, es decir, se debe garantizar la independencia entre los resultados potenciales y la asignación del tratamiento dado un conjunto de covariables observadas (X). El tercer supuesto, denominado solapamiento o *overlap*, garantiza que para todo $x \in X_i$ la probabilidad de recibir el tratamiento $e(x) = P(D = 1|X_i = x)$ está acotada entre 0 y 1, es decir $0 < e(x) < 1$, con ello se garantiza que cada unidad puede recibir cualquier tratamiento con probabilidad no nula.

Otro factor relevante a considerar en la causalidad basada en tratamientos, es mecanismo de asignación de los mismos. Este mecanismo es aquel por el que las políticas se llevan a cabo o no en el periodo t y está expresado como la probabilidad condicional de recibir el tratamiento dadas las covariables observadas y los resultados potenciales. Así, según sea la relación entre los resultados potenciales y el mecanismo de asignación, se distinguen comúnmente tres clases de mecanismo: experimentos aleatorios, selección sobre observables y selección sobre inobservables.

El primero corresponde a una aleatorización de los tratamientos, en donde la probabilidad de asignación del tratamiento, corresponde a una función conocida en base a un conjunto de covariables y es independiente con los resultados potenciales. Este mecanismo carece de aplicabilidad en políticas macroeconómicas dado que por su naturaleza no pueden

ser tratadas como aleatorias.

La segunda clase de mecanismos de asignación es la selección sobre observables, que también se denomina asignación no confusa, presentada por Rosenbaum and Rubin [1983b]. Este mecanismo supone que los factores que determinan la asignación de una política son observables y dado un conjunto de covariables, la probabilidad de asignación no depende de los resultados potenciales. A diferencia de los experimentos aleatorios, ya no se asume que la probabilidad de asignación sea una función conocida de las covariables.

Por último se encuentra la selección sobre inobservables, que contiene casos fuera del experimento aleatorio y la selección sobre observables. En este escenario, la aplicación de una política depende no sólo de factores observables, sino también de factores inobservables. Así, la probabilidad de asignación tiene cierta dependencia de los resultados potenciales. Por lo tanto, dado un conjunto de covariables, no es posible identificar los efectos del tratamiento, y se requieren otros supuestos para el análisis.

Hasta ahora, la mayoría de los métodos estadísticos y econométricos para la evaluación de efectos causales se han desarrollado en una configuración de selección sobre observables bajo los supuestos de iid y SUTVA. Estos supuestos establecen que los resultados potenciales de cualquier unidad no se ven afectados por el tratamiento asignado a otras unidades y, para cada unidad, no hay diferentes formas o versiones de cada nivel de tratamiento y que, por tanto, conduzcan a diferentes resultados potenciales. Algunas de las técnicas desarrolladas en esta área incluyen, el ajuste por regresión (AR) [Heckman et al., 1997], el ajuste por emparejamiento [Abadie and Imbens, 2006, 2008], el emparejamiento basado en los puntajes de propensión [Abadie and Imbens, 2016; Caliendo and Kopeinig, 2008], la reponderación en la probabilidad inversa de la puntuación de propensión (IPW) [Rosenbaum and Rubin, 1983b; Dehejia and Wahba, 1999; Hahn, 1998; Hirano et al., 2003; Wooldridge, 2010; Imbens, 2004] y el *double-robust estimator* (DR) [Robins and Rotnitzky, 1995; Van der Laan and Robins, 2003].

Sin embargo, la temporalidad de las variables en estudio que responden a la política aplicada debe ser necesariamente considerada en un marco de evaluación de una política macroeconómica. Angrist and Kuersteiner [2011]; Angrist et al. [2018]; Jordà and Taylor [2016]; Kuersteiner et al. [2018]; Bojinov and Shephard [2019] ampliaron el análisis

estadístico/econométrico moderno de los efectos del tratamiento a un contexto de series temporales para datos macroeconómicos. En un análisis de corte transversal, se tienen datos que suelen consistir en múltiples unidades para un único período, algunas de las cuales reciben tratamiento pero otras no. Dado que no es posible observar el contrafactual para una unidad específica, no es posible obtener el efecto individual que se genera sobre este individuo en particular, pero dado que se pueden comparar los resultados del grupo de tratamiento con el grupo de control, si es posible una estimación del efecto de tratamiento promedio. Sin embargo, en el análisis de series temporales, sólo se dispone de datos de una única unidad en múltiples períodos. En lugar del efecto de tratamiento promedio, los conceptos de *potential outcomes paths* introducidos por Robins (1986) y los *dynamic potential outcomes* introducidos por Angrist and Kuersteiner [2011]; Angrist et al. [2018] se convierten en el núcleo de esta literatura.

Los *potential outcomes paths* corresponden a una variante de los modelos convencionales, en donde los tratamientos adquieren temporalidad. Esto determina que los efectos serán medidos sobre vectores de tratamientos y no bajo efectos binarios, lo anterior permitiría comparar efectos de forma mas específica ampliando enormemente el alcance de los modelos. Sin embargo, las combinaciones aumentan exponencialmente en el tiempo por lo que esta variante agrega complejidad en la resolución de los modelos sobretodo para horizontes que abarquen un gran número de periodos.

Por otro lado los *dynamic potential outcomes* intentan emular la función de respuesta al impulso (IRF) que corresponden a los efectos contemporáneos y posteriores de las variables de resultado frente a un *shock* para el tiempo t . Angrist and Kuersteiner [2011] y Angrist et al. [2018] proponen el nuevo concepto de efectos de tratamiento dinámico como la parte correspondiente de la función de respuesta al impulso.

Para entender cómo el efecto dinámico del tratamiento se corresponde con una función de respuesta al impulso no lineal, se ilustra su conexión mediante la ecuación (2.1) y (2.2).

$$D_t = D(z_t, \psi, u_t) \text{ y } Y_{t+l} = F_{t,l}(z_t, D_t, \eta_{n,l}) \quad (2.1)$$

donde z_t es un vector, que incluye la covariable X_t , y algunos rezagos de Y_t así como D_t , u_t es información propia no observable que se asume independiente de los resultados

potenciales, y $\eta_{t,l}$ ruido blanco. Considerando una perturbación ϵ_t de D_t en el tiempo t , la respuesta al impulso no lineal de Y_{t+l} se define como

$$\delta_l(z_t, D_t, \epsilon_t) = F_{t,l}(z_t, D_t + \epsilon_t, \eta_{n,l}) - F_{t,l}(z_t, D_t, \eta_{n,l}) \quad (2.2)$$

Si $D_t + \epsilon_t = j$, y $D_t = 0$, está claro que (2.1) corresponde al efecto de tratamiento dinámico. En concreto, Angrist and Kuersteiner [2011] en su trabajo, establecen un fuerte vínculo de su modelo con la función de respuesta al impulso lineal.

Entonces, el efecto causal asociado a este cambio de política correspondería a $Y_{t,l}^\psi(j) - Y_{t,l}^\psi(0) = \beta_l j$, que significa cómo cambiaría el resultado Y_{t+j} si la política cambiase de 0 a j , suponiendo que el resto de variables se mantiene constante. Obviamente, esta es precisamente la idea de la función de respuesta al impulso. Además, en comparación con los modelos SVAR y DSGE, la identificación y estimación de los efectos de tratamiento dinámicos no requieren especificar el proceso estructural de Y_t y sólo estarían centrados en el proceso de elaboración de políticas. Esto permite aliviar el problema crucial de falta de especificación del modelo al que se enfrentan los principales modelos macroeconómicos y por ende, proporciona una herramienta más flexible para el análisis y la evaluación de las relaciones causales macroeconómicas.

2.3. Machine learning y su aplicación en causalidad

Ante la necesidad de extender la aplicación de modelos de causalidad a bases de datos más complejas y con un mayor número de variables se ha hecho necesario el uso de algoritmos que no solo otorguen la capacidad de captar todas las relaciones sino que además que posean la suficiente flexibilidad para afrontar los problemas de omisión de variables y los factores de confusión en los modelos. El *machine learning* ha resultado ser una alternativa que cada vez toma mayor relevancia en el área.

Una de las líneas en las que se ha utilizado el *machine learning* en causalidad es en la estimación de los puntajes de propensión o *propensity scores*. Este concepto, introducido en Rosenbaum and Rubin [1983a], corresponde a uno de los métodos más utilizados en la causalidad basada en tratamientos y se define como la probabilidad condicional de asignar

un tratamiento en particular a una unidad, dado un vector de covariables observadas.

Un enfoque común para estimar los *propensity scores*, es utilizar la regresión logística. Rubin [2004] ha recomendado la estimación de las puntuajes mediante el uso de modelos complejos no paramétricos, incluyendo interacciones y/o términos cuadráticos. Este tipo de estimación, en lugar de utilizar un modelo paramétrico, requiere fuertes suposiciones sobre la forma funcional de la relación entre el tratamiento y las covariables. Una especificación errónea en el modelo de las puntuaciones de propensión produciría estimaciones sesgadas del efecto del tratamiento [Drake, 1993; Kang et al., 2007].

El uso de *machine learning* y la aplicación de métodos de adaptación de datos también han sido utilizados para estimar los *propensity scores*. Los árboles de clasificación y regresión (*Classification and regression trees*, cCART), las redes neuronales y los modelos reforzados se han propuesto como alternativas adecuadas a los modelos paramétricos para la estimación de los *propensity scores* [Lee et al., 2010; Setoguchi et al., 2008; Westreich et al., 2010].

En un estudio reciente aplicado a la epidemiología, Lim et al. [2018], proponen el *Inverse Probability of Treatment Weighting* (IPTW) para modelos estructurales marginales, utilizando redes recurrentes para estimar las probabilidades de tratamiento y un modelo de secuencia en secuencia para aprender predicciones sin sesgo.

Asimismo, el uso de redes neuronales en el área causal ha generado el uso de modelos específicos de aprendizaje profundo como el *Balancing Counterfactual Regression* [Johansson et al., 2016] y el TARnet [Shalit et al., 2017], entre otros. Esta breve revisión bibliográfica sugiere que el uso de redes neuronales en causalidad ha comenzado a generar interés en el desarrollo de nuevas arquitecturas que puedan hacer frente a las variables de confusión al tiempo que abordan las debilidades de modelos econométricos tradicionales.

CAPÍTULO 3

METODOLOGÍA

3.1. Datos

Este estudio es aplicado a datos de panel desbalanceado para 94 países durante el periodo 1971-2018. Los datos proceden de las siguientes fuentes: el consumo de energía per cápita desde la *BP Statistical Review of World Energy*; las emisiones de carbono, medidas en toneladas anuales, provienen del *Global Carbon Project* y del *Carbon Dioxide Information Analysis Centre* (CDIAC); y, por último, el Producto Interno Bruto (PIB) per cápita, proviene de los Indicadores de Desarrollo del Banco Mundial (2020). Las emisiones de carbono y el consumo de energía fueron ajustados según el porcentaje del PIB de cada país. Las tres variables fueron transformadas a su primera diferencia logarítmica para tener en cuenta la estacionariedad de las series.

También son incluidas en el estudio un conjunto de covariables clave basadas en la literatura en las que se encuentran: las entradas netas de inversión extranjera directa (FDI) [Omri and Kahouli, 2014; Zhu et al., 2016]; porcentaje de urbanización respecto a la población total [Poumanyong and Kaneko, 2010; Parshall et al., 2010; Al-Mulali et al., 2013; Ghosh and Kanjilal, 2014]; la apertura comercial [Sebri and Ben-Salha, 2014]; y las exportaciones e importaciones totales, ambas como porcentaje del PIB. Dichas covariables fueron obtenidas desde los Indicadores de Desarrollo del Banco Mundial (2020). Cabe mencionar que para cada variante de tratamiento, se incluyeron como covariables los rezagos para cada una de las variables en estudio, es decir, las emisiones de CO₂, el

consumo energético y el crecimiento económico.

Como parte del estudio, se añaden variables dicotómicas que logren diferenciar los periodos temporales marcados por alguna crisis, en este caso fueron consideradas la crisis financiera mundial (2008-2009) y la crisis *dotcom* (2000-2002). Además, bajo la misma lógica, se incluyeron variables dicotómicas para los periodos de recuperación correspondientes a dos años después de cada una de las respectivas crisis. Esto último ayuda a prevenir un posible sesgo en los efectos que podría generar un sobre dimensionamiento del crecimiento, sin embargo, si no existe tal efecto, el modelo debiese prescindir de estos valores, indicando que este efecto fue descartado.

3.2. Metodología propuesta

Este estudio está compuesto por tres módulos con diferentes objetivos. En primer lugar, se establece un marco para encontrar los intervalos de tratamiento para las variables generadoras de tratamiento, emisiones de carbono y consumo energético, que serán la base para generar los efectos sobre el crecimiento económico per cápita. En segundo lugar, bajo un enfoque de redes neuronales, se estiman las puntuaciones de propensión de cada tratamiento utilizando un modelo de dos etapas compuesto por redes neuronales recurrentes y un clasificador multiclase, respectivamente. En tercer lugar, se generan los efectos causales para cada país mediante el enfoque de efectos de tratamiento dinámicos, generando comparaciones entre los distintos tratamientos con respecto a un caso base. Cada uno de estos módulos se detallará en las siguientes secciones. Un esquema completo de la metodología global puede ser visto en la [Figura 3.1](#).

3.2.1. Generación de tratamientos

Antes de discretizar los tratamientos, se deben tener en cuenta múltiples factores, por ejemplo, los tratamientos deben estar unificados para todos los países, de manera que el efecto pueda ser estimado globalmente, permitiendo además, una comparación entre países. Al mismo tiempo, debe comprobarse que no exista una concentración de datos en un solo tratamiento y que cada país contenga la posibilidad de que exista cada tipo de tratamiento,

cumpliendo así con el supuesto de positividad. Teniendo en cuenta lo anterior, sumado a la presencia de valores atípicos entre los países estudiados, se propone el uso de un algoritmo de *clustering* para agrupar los datos de forma eficiente.

Dado que los datos tienen una alta variabilidad con presencia de valores atípicos, se opta por una optimización de *clustering* basada en medioides, los cuales son menos sensibles a los datos extremos en comparación con los métodos basados en medias [Arora et al., 2016; Kaufman and Rousseeuw, 2009]. Para la formación de los intervalos de tratamiento, se tuvo en cuenta tres aspectos. En primer lugar, se ejecutó una optimización de clústeres basada en el método PAM (partición alrededor de medioides) propuesta por Kaufman and Rousseeuw [2009] que es conocida por ser una de las más potentes frente a otros métodos K-medioides. En segundo lugar, se comparan los resultados con la optimización de clusters unidimensionales mediante programación dinámica descrita en Wang and Song [2011]. Como tercer filtro, utilizamos un punto de vista económico considerando que los datos fuesen agrupados de tal manera que los tratamientos puedan ser utilizados como políticas económicas, asegurando que cada tipo de tratamiento esté disponible para cada país. Esto permite evitar el sesgo por muestreo debido a la falta de datos en algún tratamiento y evita además, el uso de cualquier técnica de aumento de datos que pudiese contaminar la muestra.

Una de las ventajas de utilizar la programación dinámica en la agrupación es que no es necesario especificar el número de clusters, ya que el modelo permite la optimización basada en el criterio de información bayesiano (BIC), lo que la hace más robusta y directa en comparación con otros métodos. En el caso del método PAM, se utilizó para optimizar los intervalos el indicador propuesto por Caliński and Harabasz [1974]. Como complemento a los dos métodos presentados, se incluyó el algoritmo de rupturas naturales de Jenks, también conocido como método de la bondad de ajuste de la varianza (GVF) [Jenks, 1967], que se utiliza para minimizar las desviaciones al cuadrado de las medias de las clases, obtenido al maximizar el estadístico GVF.

3.2.2. Estimación de las puntajes de propensión

Dado que la causalidad basada en tratamientos es propensa al sesgo por el factor de confusión (*counfounders*) , es necesario considerar qué variables o factores podrían estar




Figura 3.1: Representación gráfica de la metodología utilizada. El enfoque se divide en tres procedimientos: primero, formulación de los intervalos de tratamiento; segundo, estimación de las puntuaciones de propensión mediante un marco de redes neuronales; y tercero, cálculo de los efectos dinámicos del tratamiento mediante ponderación probabilística inversa con respecto a un tratamiento base respectivo.

generando los tratamientos. En la práctica, es difícil tener en cuenta todos los efectos de confusión, ya que no existen datos contrafactuales para comparar. En esta sección, se presenta la configuración propuesta para tratar las posibles variables de confusión mediante técnicas basadas en redes neuronales.

3.2.2.1. Selección de variables de entrada

Para tomar en cuenta los efectos temporales y transversales, se realizó un procedimiento previo de selección de variables de entrada para las redes neuronales recurrentes. Para ello se utilizó el Marco de Descubrimiento Causal Temporal (TCDF) propuesto por Nauta et al. [2019], el cual busca relaciones temporales proporcionando tanto el número de rezagos como la dirección causal entre las variables. Este novedoso método utiliza redes neuronales convolucionales basadas en atención combinadas con un paso de validación causal. Interpretando los parámetros internos de las redes convolucionales, el TCDF también puede descubrir el rezago entre una causa y la ocurrencia de su efecto, comparando pieza por pieza dos series temporales asignando una puntuación de correlación entre ellas, de tal manera que cuando se supera un umbral se confirma la relación causal.

Además, este enfoque ayuda a tener en cuenta los factores externos y las interdependen-

cias entre países. Con este primer filtro, se puede descubrir qué variables están implicadas a través de un gráfico causal para cada serie de tratamiento sobre cada país. Este filtro puede ayudar a identificar posibles efectos indirectos entre países, sirviendo como una preoptimización de las variables de entrada para la estimación de las puntuaciones de propensión. Para más detalles sobre este método, véase Nauta et al. [2019].

3.2.2.2. Red neuronal de dos etapas

Una vez realizada la optimización de variables de entrada a la red, se propone una metodología de dos etapas para estimar las puntuaciones de propensión para cada tipo de tratamiento en cada variable de estudio. Dada la alta complejidad de las relaciones temporales y el número de variables involucradas, la primera etapa está compuesta por una *Long short-term memory network* (LSTM) introducida por Hochreiter and Schmidhuber [1997].

La red LSTM es una representante de las redes neuronales recurrentes profundas las cuales son especialmente expertas en el procesamiento de datos secuenciales. La principal característica de esta red es que está compuesta por las llamadas células de memoria, que están diseñadas para retener información sin modificarla durante el barrido temporal de ajuste. Asimismo, las redes LSTM poseen la capacidad para aprender la dependencia a largo plazo, lo que no es posible con las RNN convencionales. Para mantener la información de periodos anteriores, es necesario actualizar los valores de los pesos en la red, una RNN simple está limitada a las relaciones a corto plazo; mientras que la LSTM puede aprender adecuadamente estas dependencias a largo plazo. Una red LSTM se compone de tres estructuras llamadas puertas: de entrada, de olvido y de salida. La puerta de olvido está diseñada para indicar cuánto de la memoria anterior está almacenado y cuánto ha sido descartado. Para la LSTM, el estado oculto se calcula de la siguiente manera:

$$g_t = \sigma(U_g x_t + W_g h_{t-1} + b_g) \quad (3.1)$$

$$i_t = \sigma(U_i x_t + W_i h_{t-1} + b_i) \quad (3.2)$$

$$\tilde{c}_t = \tanh(U_c x_t + W_c h_{t-1} + b_c) \quad (3.3)$$

$$c_t = g_t * c_{t-1} + i_t * \tilde{c}_t \quad (3.4)$$

$$o_t = \sigma(U_o x_t + W_o h_{t-1} + b_o) \quad (3.5)$$

$$h_t = o_t * \tanh(c_t) \quad (3.6)$$

donde i_t , g_t y o_t son las puertas de entrada, olvido y salida en el tiempo t , respectivamente; U_i , U_f , U_o y U_c son los pesos que asignan la entrada de la capa oculta a las tres puertas de entrada, olvido y salida, mientras que W_i , W_f , W_o y W_c son las matrices de pesos que relacionan la salida de la capa oculta con las puertas; b_i , b_f , b_o y b_c son vectores.

En este estudio para la conformación de la primera etapa de la red neuronal, el *target* de la serie se define en forma ordinal de tal manera que la red pueda captar e identificar esta característica de los intervalos. Para ello, se utiliza una configuración de salidas mediante un *one hot encoding*, en la que los tratamientos son transformados en cadenas binarias. En este caso la primera clase está definida como [1, 0, 0, ..., 0], la segunda clase como [1, 1, 0, ..., 0] y así sucesivamente, con una función de activación sigmoidea para cada una, de forma que la red pueda identificar un patrón ascendente interpretando claramente la característica creciente y ordinal de los intervalos de tratamiento.

Como segunda etapa, se obtienen las probabilidades de ocurrencia de cada tratamiento en cada periodo a partir de una segunda capa densa que utiliza una función de activación *Softmax*, obteniendo así, las puntuaciones de propensión para cada tipo de tratamiento en cada periodo. Ésta segunda etapa ayuda a determinar las probabilidades de ocurrencia según los resultados obtenidos en la primera etapa. En específico, ésta segunda etapa consiste en una red clasificadora multiclase, compuesta por una capa densa acoplada a una función de salida *Softmax*. Dado que pueden existir configuraciones atípicas y la clasificación podría estar sesgada a sólo resultados positivos, se utiliza una función de pérdida focal para adaptarse mejor a los posibles valores que tomen el resto de las variables.

Esto debido a que, a diferencia de otras funciones de pérdida como la entropía cruzada, la pérdida focal no sufre problemas de desequilibrio de clases. Tal como se indica en Lin et al. [2017], una característica de la pérdida de entropía cruzada es que incluso los elementos fáciles de clasificar pueden causar pérdidas significativas. La función de pérdida de los datos fáciles de clasificar, que constituyen la mayor parte del conjunto de datos durante el proceso de entrenamiento, afecta negativamente a las clases menos comunes dentro de la muestra. La pérdida focal está diseñada para hacer frente a este problema de desequilibrio mediante la remodelación de la función de pérdida de entropía cruzada, reduciendo la atención a los ejemplos fáciles y centrándose en los difíciles. En la práctica, la variante de equilibrio α de la pérdida focal se utiliza normalmente cuando una o más categorías están muy desequilibradas, definidas como:

$$F_{loss} = - \sum_i^C t_i \alpha_i (1 - p_i)^\gamma \log(p_i) \quad (3.7)$$

donde γ actúa como factor modulador y α_i es el factor de ponderación de cada categoría. Cuanto mayor sea el valor de γ , menor será el coste de los datos bien clasificados. En el marco de este estudio, fue utilizado un γ de 0,4 y α de 0,25 para cada clase, como recomienda [Lin et al., 2017].

La optimización de los hiperparámetros de las redes se evaluó mediante prueba y error considerando: en la primera etapa, ventanas de 3, 5, 7 y 10 años; para las entradas, una *drop rate* de 0,25; y, 1000 iteraciones. Para las capas, en el caso de la red LSTM, se utilizaron 40, 60, 80, 100 neuronas, mientras que en la capa densa se utilizaron 5, 10, 20 neuronas. Como función de pérdida para la primera etapa se utilizó el error cuadrático medio (MSE), junto con el optimizador Adam.

3.2.3. Efecto de tratamiento dinámico

La causalidad dentro de las políticas macroeconómicas ha sido ampliamente estudiada durante los últimos años, siendo los modelos de Equilibrio General Dinámico Estocástico (DSGE) y Vector Autorregresivo (VAR) los más utilizados para este fin, centrando su análisis en las respectivas funciones de respuesta al impulso. En estudios recientes Angrist

and Kuersteiner [2011] y Angrist et al. [2018] proponen un nuevo concepto de efectos de tratamiento dinámicos como una emulación de la función de respuesta al impulso enfocada bajo una lógica de causalidad bajo diferentes escenarios de tratamiento en series de tiempo.

En primer lugar, definieron el llamado resultado potencial dinámico como sigue:

Sea $Y_{t:L} = (Y_{t+1}, \dots, Y_{t+L})^j$

$$Y_{t:L} = \sum_{d \in D} Y_{t:L}^{\psi}(d) 1\{D_t = d\} \quad (3.8)$$

Dada esta definición, el efecto causal de la política d_j viene dado por $Y_{t,l}^{Psi}(d_j) - Y_{t,l}^{Psi}(d_0)$, donde d_0 es la política de referencia. Para determinar el efecto medio, definieron los efectos de tratamiento dinámicos, donde para una política d_j :

$$\Theta_{t,j} = E[Y_{t,l}^{\Psi}(d_j) - Y_{t,l}^{\Psi}(d_0)] \quad (3.9)$$

$$\Theta_j = E[Y_{t,L}^{\Psi}(d_j) - Y_{t,L}^{\Psi}(d_0)] \quad (3.10)$$

donde $\Theta_j = (\Theta_{1,j}, \dots, \Theta_{L,j})$

Este enfoque, cuando se incluye en un método asociado a la función de respuesta al impulso, como se indica en Angrist and Kuersteiner [2011], permite encontrar cuánto variará el resultado potencial si ocurre el cambio desde la política base (d_0) a la política d_j suponiendo que todos los demás efectos permanecen constantes. Además, en comparación con otros modelos, como el DGSE, la estimación de los efectos dinámicos del tratamiento no requiere la especificación del modelo, lo que proporciona flexibilidad y reduce los problemas de mala especificación a los que se enfrentan otros modelos macroeconómicos.

Uno de los principales supuestos para que el modelo se aplique en un contexto de series temporales es el supuesto de independencia condicional, también llamado supuesto de selección sobre observables. Este supuesto indica que los tratamientos sólo dependen de los resultados potenciales de períodos anteriores y, por tanto, no están influidos por los efectos futuros o contemporáneos que puedan existir. Este supuesto es similar a la aleatorización

secuencial adoptada en Robins [1994]. Entonces, dado un conjunto de covariables z_t , el supuesto puede ser formulado como:

$$Y_{t,l}^\psi(d_j) \perp D_t | z_t \forall l \geq 0, d_j, \text{ con } \psi \text{ fijo}, \psi \in \Psi. \quad (3.11)$$

Según el enfoque propuesto en Angrist et al. [2018], los efectos se obtienen a través de estimadores de ponderación probabilística inversa. Este método define $p^j(z_t, \psi) = \Pr(D_t = d_j | z_t)$ como la puntuación de propensión de una política d_j , donde z_t es un conjunto de covariables y ψ determina el régimen de tratamiento. Suponiendo que $0 < p^j(z_t, \psi) < 1$ y bajo el supuesto de independencia condicional, la expectativa del resultado potencial para el tratamiento d_j viene dada por (3.12) que deriva en (3.13).

$$E[Y_{t,l} 1_{D_t = d_j} | z_t] = E[Y_{t,l}^\psi(d_j) | z_t] p^j(z_t, \psi) \quad (3.12)$$

$$\Theta_{t,j}^{IPW} = E \left[Y_{t,l} \left(\frac{1\{D_t = d_j\}}{p^j(z_t, \psi)} - \frac{1\{D_t = d_0\}}{p^0(z_t, \psi)} \right) \right] \quad (3.13)$$

Dado que el estimador depende de las probabilidades estimadas, si $p^j(z_t, \psi)$ toma valores muy pequeños, el estimador en (3.13) podría estar sesgado por estos valores extremos. La solución adoptada, como se sugiere en Angrist et al. [2018], fue excluir estas observaciones con un margen de tolerancia α , es decir, se descartaron aquellas observaciones que cumplieron que $p^j(z_t, \psi) < \alpha$ cuando $1\{D_t = D_j\} = 1$. El parámetro α se fijó en 0,025 como se sugiere en su trabajo seminal.

Bajo este enfoque, teniendo en cuenta las ponderaciones definidas por (3.14), los efectos dinámicos del tratamiento pueden ser redefinidos como $\Theta_{t,j}^{IPW} = E[w_{t,j}(\psi) Y_{t,j}]$. En un modelo bien especificado, las ponderaciones $\delta_{t,j}(\psi)$ tienen media cero y no están correlacionadas con z_t . Como paso final, las respuestas estimadas a los tratamientos se determinan mediante (3.15), donde $\hat{\delta}_{t,j}$ corresponde a los residuos de la regresión de $\delta_{t,j}(\psi)$ en z_t si fuese necesario.

$$\delta_{t,j}(\psi) = \frac{1\{D_t = d_j\}}{p^j(z_t, \psi)} - \frac{1\{D_t = d_0\}}{p^0(z_t, \psi)} \quad (3.14)$$

$$\hat{\Theta}_j = \frac{1}{T} \sum_{t=1}^T Y_{t,L} \hat{\delta}_{t,j} \quad (3.15)$$

Como complemento, los efectos se agrupan por países y luego se ponderan por el producto interno bruto global. Este paso se dio dado que, a nivel mundial, las tres variables se concentran en gran medida en pocos países, como se indica en el marco político mundial. Sin embargo, los efectos individuales de cada país también fue tomado en cuenta para el análisis posterior. Mediante la agrupación, se pretende comparar entre los efectos globales, los países miembros de la OCDE y los diferentes niveles de ingresos.

CAPÍTULO 4

RESULTADOS

En esta sección, los resultados se dividen en cuatro partes. Primero se presentan los ajustes del modelo, incluida la estimación de la puntuación de propensión. En la segunda y tercera parte se muestran los efectos de las emisiones de carbono y consumo energético sobre el PIB per cápita, respectivamente. Finalmente, en la cuarta sección, se presenta el análisis del efecto direccional del tratamiento compuesto por ambas variables. Los análisis incluyen los efectos globales, los efectos de los países de la OCDE y los efectos del nivel de ingresos. Además, los resultados fueron sensibilizados a los periodos de crisis y recuperación como fue descrito en la metodología.

4.1. Especificación del modelo

Dado que los datos corresponden a un panel desbalanceado y con el fin de medir los efectos dinámicos del tratamiento, es necesario transformar las series temporales continuas en intervalos de tratamiento ordenados. Los intervalos de tratamiento fueron generados de forma unificada; es decir, la generación de los intervalos de tratamiento considera todos los países de la muestra. Como se mencionó anteriormente en la sección 3.2.1, los resultados de los algoritmos fueron sensibilizados de 5 a 12 *clusters*. Según nuestro segundo criterio, teniendo en cuenta la cantidad de datos por tratamiento, limitamos el número de intervalos a cinco de manera que los datos extremos se agrupen en los tratamientos más externos, permitiendo al menos un tratamiento de cada tipo para cada país de la muestra. Esto resulta

TABLA 4.1: Resultados de la agrupación de las emisiones de carbono y el consumo de energía. Se muestran los tres métodos utilizados con sus respectivos criterios de optimización. También se incluyen los rangos obtenidos para la generación de los intervalos de tratamiento. BIC: criterio de información bayesiano; C-H: índice Calinski-Harabaez; GVF: bondad de ajuste de la varianza.

		Puntos de Corte				Criterio
	Método	n=1	n=2	n=3	n=4	
Emisiones de CO2	Dynamic Programing	-5.286	-2.089	0.899	4.499	BIC
	PAM	-5.850	-2.409	0.755	4.532	C-H
	Jenks	-10.486	-4.686	-0.408	4.033	GVF
Consumo Energético	Dynamic Programing	-4.189	-1.987	0.211	3.114	BIC
	PAM	-5.758	-2.854	-0.260	2.909	C-H
	Jenks	-5.321	-1.308	3.003	9.797	GVF

ser de suma importancia para evitar sesgos de agrupación y también para evitar contaminar la muestra con técnicas de expansión de datos.

Se aplica el mismo procedimiento para las emisiones de carbono y el consumo de energía, obteniendo cinco intervalos de tratamiento (4 cortes) que se codifican naturalmente de forma ordinal. En la [Tabla 4.1](#), se observan los resultados de los tres métodos aplicados. Se constata que los métodos PAM y DP proporcionan rupturas similares, mientras que Jenks resultó ser más sensible a los valores atípicos (véase [Figura B.1](#)). La agrupación de los datos extremos es coherente en lo que respecta a las políticas económicas, clasificando las políticas extremas como agresivas y las más centrales como moderadas.

Una vez definidos los tipos de tratamiento, se realiza la preoptimización de variables dada por la TCDF descrita en la sección [3.2.2.1](#). Como hiperparámetros de la red, se utilizó un tamaño de kernel de 4, un parámetro de dilatación de 4, y una tasa de aprendizaje de 0,001 y 5000 iteraciones, con Adam como optimizador. El parámetro de significación τ se fijó en 0,8. El filtro fue estudiado bajo dos configuraciones, en la primera se comparó las series entre países (efecto exógeno o externo) y la segunda comparando las series de cada país con sus respectivas covariables (efecto endógeno o interno). Por ejemplo, un país concreto puede mostrar un efecto de contagio de otro país en su consumo de energía, lo que señala que esta variable debe añadirse como posible factor de confusión. Por otro lado, cuando una variable propia de un país tiene un efecto sobre el consumo de energía, se tendría un efecto endógeno que podría ser tratado con políticas económicas.

Los resultados indican que no habría ningún efecto de contagio entre los países de la muestra, debido a que ninguno logró superar el umbral de τ , lo que indica que no hubo efectos lo suficientemente fuertes como para ser considerados en el modelo, lo que implicó que no fuese necesario incluir una variable entre países para el cálculo de las puntuaciones de propensión para cada tratamiento en cada país.

En cuanto a la influencia de las variables endógenas, se encontró que existe una estrecha relación entre las emisiones de CO₂, el consumo de energía y el PIB per cápita, seguido del efecto de la inversión extranjera directa (IED). En los resultados obtenidos de la red TCDF, se encontraron relaciones predominantemente unidireccionales entre estas variables, con menor incidencia en el caso de las importaciones y la apertura comercial. Además, la red detectó 15 países con una relación bidireccional entre las emisiones de CO₂ y el PIB per cápita, mientras que en 16 países hubo una relación bidireccional entre el consumo de energía y el PIB per cápita. Estos resultados actuaron como un primer filtro para la selección de las covariables que fueron incluidas en el proceso de cálculo de las puntuaciones de propensión.

Una vez filtradas las variables, se utilizó la red recurrente de dos etapas descrita en la sección 3.2.2.2. A modo comparativo, se realiza un probit ordinal de panel como referencia para la estimación de las puntuaciones de propensión. Los resultados muestran una mejora considerable del modelo propuesto en términos de AUC (véase Figura B.2). Por último, los resultados de los efectos del tratamiento se muestran en las siguientes secciones.

4.2. Efecto de las emisiones de carbono

Como primer resultado se muestran los países más influyentes a nivel mundial, en este caso agrupados como miembros de la Organización para la Cooperación y el Desarrollo Económico (OCDE). Dado que la muestra considera un periodo amplio, para evitar sesgos, sólo fueron incluidos los miembros fundadores, dejando fuera a los países de reciente incorporación (Véase Tabla A.1).

En primer lugar, es importante aclarar que estos resultados, así como la metodología utilizada, tienen como objetivo encontrar el mejor tratamiento (rango) en el que los efectos




Figura 4.1: Efecto del tratamiento ponderado de las emisiones de carbono sobre el PIB per cápita para los países de la OCDE: (a) sin considerar el efecto de las crisis financieras; (b) efectos de las crisis subprime y puntocom; y, (c) efecto de las crisis y su respectiva recuperación tras la crisis. Los intervalos de confianza de los efectos se estiman con un 95 % mediante el método bootstrap.

sobre la variable estudiada (PIB per cápita) tendrían el mejor impacto a largo plazo.

Teniendo en cuenta como tratamiento base una variación de -2,1 a 0,9 por ciento en las emisiones de CO₂, en la [Figura 4.1](#) se observa que para los tres casos presentados los intervalos extremos generan peores resultados en el largo plazo, resultando en un efecto inferior al cuatro por ciento respecto al caso base. Al considerar la crisis y recuperación, se observa una mejora en el efecto ponderado hacia una mayor reducción de las emisiones de carbono para estos países. Esto permitiría generalizar, a partir de estos tres resultados, que todos los casos apuntan hacia una política reductora de las emisiones siempre que se mantengan dentro de un rango razonable.

Más concretamente, se puede inferir que la inclusión del efecto de la crisis dentro del cálculo de la puntuación de propensión generó un cambio en los resultados. El impacto de las emisiones de CO₂ sobre el PIB per cápita se vio afectado al considerar tanto los efectos de las crisis como su posterior recuperación, en ambos casos se produjo un aumento significativo de la eficacia tanto de las políticas reductoras como de las más expansivas al incluir la recuperación. Esto podría deberse a una sobreestimación del intervalo central en los periodos de recuperación, así como a una subestimación de otros intervalos durante la crisis cuando el crecimiento tiende a estancarse.




Figura 4.2: Efecto ponderado del tratamiento de las emisiones de carbono sobre el PIB per cápita para todos los países: (a) sin considerar el efecto de las crisis financieras; (b) efectos de las crisis subprime y puntocom incluidos; y, (c) efectos de las crisis financieras y la respectiva recuperación tras la crisis. Los intervalos de confianza de los efectos se estiman en un 95 %.

En el caso del efecto ponderado a nivel global, la [Figura 4.2](#) muestra resultados similares a los países de la OCDE. Sin embargo, el efecto de las reducciones extremas de las emisiones de carbono tendría un mayor impacto negativo alcanzando una reducción del 6 % en el crecimiento económico per cápita a largo plazo, lo que implica que para una parte del resto de los países de la muestra el efecto de las políticas extremas sería menos efectivo que el escenario de referencia. Sin embargo, este resultado podría estar sesgado hacia las grandes economías, dejando de lado las diferencias que podrían existir con respecto a las economías emergentes, lo que hace necesaria una diferenciación por nivel de ingresos.

Para analizar la relación entre el crecimiento económico y las emisiones de carbono en los distintos niveles de ingreso, los países fueron agrupados según la clasificación realizada por el Banco Mundial de Datos. Este utiliza datos de la Renta Nacional Bruta (RNB) per cápita en dólares estadounidenses, convertidos a partir de la moneda local mediante el método Atlas del Banco Mundial, que se aplica para suavizar las fluctuaciones del tipo de cambio. La lista completa de países y sus respectivas clasificaciones puede ser consultada en la [Tabla A.1](#). Los efectos por nivel de ingreso se presentan en la [Figura 4.3](#), donde se observa que los resultados para los países de ingreso alto fueron muy similares a los obtenidos en los países de la OCDE conforme a lo esperado. Sin embargo, se observó una




Figura 4.3: Efecto ponderado del tratamiento de las emisiones de carbono sobre el PIB per cápita agrupado por nivel de ingresos: (a) países de ingreso alto; (b) ingreso medio-alto; (c) ingreso medio-bajo; y, (d) ingreso bajo, clasificados según los indicadores de desarrollo mundial 2020. Los intervalos de confianza de los efectos se estiman con un 95 %. Incluye efectos de crisis y subsecuente recuperación.

transición hacia propuestas más expansivas en las emisiones de CO₂ conforme se reduce el nivel de ingreso, esto podría estar relacionado con el grado de desarrollo de cada país y su infraestructura energética instalada. Además, se pudo observar que tanto para los países de ingreso medio-bajo como para los de ingreso bajo, el rango de variaciones positivas más extremas comienza a ser más efectivo con respecto al resto de los intervalos de tratamiento.

Dado que los efectos ponderados dan una visión global basada en el PIB, también fue necesario examinarlo desde un punto de vista individual, para obtener así, el mejor intervalo de tratamiento por país. Los resultados se resumen en la [Figura 4.4](#) donde se observa que a pesar de que los efectos ponderados favorecen una reducción en las emisiones, en los países con economías emergentes sigue habiendo una tendencia a un mayor crecimiento basado en el aumento de las mismas. Además, en los países miembros de la OCDE se da esta disimilitud, por ejemplo, países como Dinamarca o Suiza presentaron su mejor efecto en el primer intervalo de tratamiento, mientras que Irlanda encontró su óptimo en el quinto




Figura 4.4: Mapa mundial donde se indica el mejor intervalo de tratamiento en las emisiones de CO2 para cada país de la muestra. Para más detalles sobre los intervalos obtenidos, véase [Tabla B.1](#).

intervalo con políticas expansivas. Este fenómeno también se dio a nivel de ingresos, lo que sugiere que las políticas ambientales deben ser tomadas a nivel local, teniendo en cuenta las características de la matriz productiva de cada país.

4.3. Efectos del consumo energético

Para determinar los efectos de un cambio en el consumo de energía sobre el PIB per cápita, al igual que en el caso de las emisiones de carbono, se analizaron los efectos ponderados del tratamiento para tres submuestras.

Agrupados según los miembros de la OCDE, la [Figura B.5](#) muestra que bajo todas las variantes utilizadas, tanto con las crisis como con las recuperaciones, el mejor tratamiento se observa en el intervalo -2 a 0,2 por ciento, ya que es el que genera los mejores efectos acumulados sobre el PIB per cápita. Cabe señalar que los resultados negativos de los demás tratamientos no indican una caída del crecimiento, sino un efecto menor con respecto al tratamiento base.

Para el caso global, se produce el mismo fenómeno ilustrado en la [Figura B.6](#), siendo el tratamiento ideal el mismo que para los miembros de la OCDE. Nuevamente, los cambios




Figura 4.5: Mapa mundial donde se indica el mejor intervalo de tratamiento en el consumo de energía para cada país de la muestra. Para más detalles sobre los intervalos obtenidos, véase [Tabla B.1](#).




Figura 4.6: Mapa mundial donde se indica el mejor tratamiento conjunto direccional para cada país de la muestra. Para más detalles sobre los rangos obtenidos, véase [Tabla B.1](#)




Figura 4.7: Efecto ponderado del tratamiento del consumo de energía sobre el PIB per cápita agrupado por nivel de ingresos: (a) países de ingresos altos; (b) ingresos medios-altos; (c) ingresos medios-bajos; y, (d) ingresos bajos, clasificados según los indicadores de desarrollo mundial 2020. Los intervalos de confianza de los efectos se estiman con un 95 %.

extremos en el consumo de energía tienden a tener un menor efecto que los cambios graduales y moderados. Con respecto a la agrupación por nivel de ingresos, se obtienen los mismos resultados, en los que el tratamiento base sigue siendo aquel que arroja los mejores resultados (véase [Figura 4.7](#)).

Sin embargo, a nivel individual, existen disimilitudes con respecto a lo observado en los análisis ponderados. Aunque la mayoría de los países desarrollados se encuentran en el rango moderado, los países nórdicos como Suecia, Noruega y Finlandia optarían por un crecimiento económico en base a un crecimiento del consumo energético en el rango del 0,2 % - 3,1 %, lo que fortalece la idea de que políticas unificadas no serían óptimas y deberían adaptarse a las necesidades y estrategias según la matriz productiva de cada país. A nivel individual, la [Figura 4.5](#) muestra que los países en general deberían elegir una reducción del consumo energético o un crecimiento muy reducido del mismo, el detalle con los tratamientos así como su variación media relativa se muestran en la [Tabla B.1](#).

4.4. Efectos direccionales conjuntos

Dada la posibilidad de generar tratamientos y también la flexibilidad que ofrecen las redes neuronales en cuanto a sus entradas, fueron generados tratamientos compuestos de tipo direccional; es decir, que sólo consideran un cambio positivo o negativo en las dos variables de tratamiento, lo que permite obtener los efectos conjuntos de un cambio simultáneo en ambas variables. Para todos los casos, el tratamiento de referencia considerado fue un aumento conjunto de las emisiones de carbono y del consumo de energía.

En la [Figura B.11](#) se observa que para ambos casos, global y OCDE, todas las combinaciones tienen un mejor escenario de crecimiento económico respecto al caso base (un crecimiento de las emisiones de carbono y del consumo de energía). Además, se encuentra que la mejor alternativa a largo plazo consistiría en una reducción de ambas variables, aunque al ser direccional, sólo se puede inferir un efecto conjunto sin especificar en que grado debería ser el nivel de reducción óptimo. El estudio se ha realizado en los escenarios de crisis y de recuperación, sin que se aprecien diferencias al añadir o eliminar estos efectos.

Sin embargo, cuando se agrupan por niveles de ingresos, en consonancia con los efectos univariantes, los países de menores ingresos tienden a obtener mejores resultados a medida que aumenta el consumo de energía y las emisiones de carbono. Para todos los niveles de ingreso, como se muestra en la [Figura 4.8](#), el mejor escenario viene dado por una reducción conjunta de ambas variables.

En consonancia con el análisis anterior, al evaluar a nivel individual, como se muestra en la [Figura 4.6](#), la mayoría de los países muestran un mejor rendimiento del crecimiento al reducir sus emisiones y su consumo de energía. Sin embargo, 16 de los países mostraron que el aumento de ambos generaría un mayor crecimiento a largo plazo. Para más detalles véase [Tabla B.1](#), donde se muestran los rangos óptimos para cada país junto con la variación porcentual del exceso de crecimiento entre las dos mejores alternativas de tratamiento.

Profundizando en los resultados, se podrían inferir cuatro tipos de efectos según cada uno de los cuatro cuadrantes basados en ambas variables. Un aumento de las emisiones de carbono junto con un aumento del consumo de energía podría clasificarse como un crecimiento expansivo basado en la industrialización con un aumento de la capacidad




Figura 4.8: Efecto ponderado del tratamiento direccional conjunto sobre el PIB per cápita agrupado por nivel de ingreso: (a) países de ingresos altos; (b) ingresos medios-altos; (c) ingresos medios-bajos; y, (d) ingresos bajos, clasificados según los indicadores de desarrollo mundial 2020. Los intervalos de confianza de los efectos se estiman con un 95 %.

energética basado en energías convencionales. Un crecimiento basado en la disminución de las emisiones y el aumento del consumo de energía podría ser clasificado como una industrialización basada en energías verdes, en la que se produce una expansión de la capacidad energética, pero sin representar un aumento de las emisiones de carbono. Por el contrario, cuando el crecimiento va acompañado de una caída en el consumo de energía, hablaríamos de políticas de eficiencia energética o de cambios en la matriz productiva. En el caso de una caída de las emisiones de carbono junto con una caída del consumo de energía, estaríamos hablando de un crecimiento verde, basado en un uso más eficiente de la energía junto con la implementación de la generación de energía limpia. Por último, cuando se produce un descenso del consumo energético pero un aumento de las emisiones de carbono, estaríamos ante un crecimiento bajo una industrialización orientada a los servicios o con un alto grado de eficiencia energética. Para más detalles sobre los países que conforman cada uno de los cuadrantes véase la [Tabla B.1](#).

CAPÍTULO 5

DISCUSIÓN

Los resultados obtenidos en esta investigación pueden ser divididos en efectos ponderados y efectos individuales. A nivel ponderado, los resultados apoyan que una propuesta de reducción de las emisiones de CO₂ es compatible con el crecimiento económico a nivel global, el mismo resultado se obtuvo en un subgrupo formado por los países de la OCDE. Este primer resultado indicaría que existiría una relación inversa entre las emisiones de carbono y el crecimiento económico; sin embargo, al agrupar las variables por nivel de ingresos, se observó que para los países de bajos ingresos la relación se vuelve positiva, es decir, el crecimiento económico estaría dado por un aumento de las emisiones de carbono. Este resultado es coherente con la *Environmental Kuznets Curve hypothesis* (EKC), que indica que los países de menores ingresos o menos desarrollados mostrarán un crecimiento basado en un aumento de sus niveles de contaminación, mientras que los países desarrollados o de altos ingresos pueden generar crecimiento a medida que disminuyen sus niveles de contaminación.

Para el caso de los efectos del consumo energético sobre el crecimiento económico, a nivel agregado se encontró que las políticas moderadas generarían el mejor efecto, tanto para los países de la OCDE como para una segregación por nivel de ingresos. Esto es sin duda relevante en el ámbito de la generación de políticas de expansión energética, ya que la mayoría de los estudios se centran en encontrar relaciones de causalidad direccional como se revisa en Dinda [2004]; Kijima et al. [2010] y Furuoka [2015], mientras que en este estudio se proporciona no sólo la dirección sino también el grado en que se deben


establecer los objetivos a largo plazo.

Por otro lado, a nivel individual, se obtuvieron resultados mixtos, donde se observaron comportamientos diferentes tanto en las emisiones de carbono como en el consumo energético. Países de altos ingresos como Finlandia, Islandia y Singapur mostraron que las políticas permisivas sobre sus emisiones tendrían mejores efectos sobre sus respectivos crecimientos. Asimismo, en el caso de los países menos desarrollados, como Honduras, las políticas reduccionistas resultaron ser la mejor alternativa. Este hallazgo podría implicar que no existe una política global aplicable a todas las naciones del mundo y que variables como la ubicación geográfica, la actividad económica principal y las fuentes de energía son relevantes a la hora de elegir una política económica, tal como mencionan Dinda [2004], Stern [2004] y Yang and Zhao [2014].

Ampliando el análisis y dada la dinámica en la que deben establecerse las políticas económicas, se obtuvieron los efectos del tratamiento conjunto, donde se consideraron los efectos sobre el crecimiento ante movimientos conjuntos de las emisiones de carbono y del consumo de energía. En este punto, como se puede observar en la [Figura B.11](#), se afirma que una reducción conjunta de ambas variables tendría los mejores efectos sobre el crecimiento. Sin embargo, al igual que en el caso univariado de las emisiones de carbono, en la [Figura 4.8](#) se observa que cuando se agrupa por nivel de ingresos el exceso de rendimiento comienza a disiparse frente al caso base, definido como el aumento conjunto de emisiones de carbono y consumo de energía, relacionado a un proceso de industrialización clásico. Este efecto se da para países menos desarrollados o de menores ingresos, lo que da apoyo a la hipótesis EKC. Este resultado, sin embargo, se limita a los movimientos direccionales debido a la falta de datos suficientes, por lo que se recomendaría reforzar estos resultados con investigaciones futuras.

Finalmente, las relaciones entre las emisiones de carbono y el crecimiento económico han sido ampliamente estudiadas en la literatura con resultados mixtos, a partir de los resultados individuales de los países, se puede inferir que esta realidad podría concebirse debido a las características de la matriz productiva propia de cada país. La existencia de países con crecimiento económico asociado a una caída de sus emisiones de carbono podría explicarse no sólo por la reducción de estas emisiones, sino también por el desarrollo de la

industria relacionada con el cambio hacia la generación de energías renovables, así como de nuevos dispositivos, que generarán un nuevo mercado para el desarrollo y uso de fuentes que antes no existían, como el hidrógeno verde, que podría establecer nuevos retos en pos de un mayor desarrollo económico junto con una reducción de emisiones. Dicho lo anterior, se sugiere que futuras investigaciones incluyan una serie de factores como la capacidad industrial instalada, el porcentaje de generación de energía según sus diferentes orígenes y la inversión en energías renovables como posibles determinantes clave.



CAPÍTULO 6

CONCLUSIONES

Este estudio extiende la literatura sobre la relación entre el consumo energético y las emisiones de carbono con respecto al PIB per cápita. La relación fue investigada en 94 países bajo un nuevo marco metodológico que combina redes neuronales con efectos causales dinámicos. Como primer paso se aplica una discretización a las series para generar un conjunto de intervalos de tratamiento utilizando una clusterización en base a programación dinámica. Luego, se utilizó un método de redes neuronales de dos etapas; la primera con una red recurrente con salidas ordinales y una segunda etapa con una red de clasificación multiclase con función de pérdida focal. A partir de estos se obtienen las puntuaciones de propensión para cada intervalo de tratamiento. A continuación, las puntuaciones de propensión estimadas son utilizadas para generar los resultados potenciales dinámicos con lo que se logra obtener la relación causal entre los tratamientos y a su vez, un marco que permita compararlos con respecto a un caso base predefinido.

Desde un punto de vista metodológico, con este estudio se evidencia que el *Machine Learning* (ML) y en especial de las redes neuronales profundas pueden llegar a ser relevantes en el ámbito de la causalidad en series económicas dada su flexibilidad y relativa facilidad de implementación. La facilidad y flexibilidad del ML no solo permitió elegir las variables del modelo sino también, establecer las relaciones entre el conjunto de covariables y los tratamientos, por lo que se recomienda ampliar el uso de estas herramientas en aplicaciones de causalidad. Uno de los factores a considerar, es el volumen de datos de los que se dispone, sin embargo, la recopilación de datos es cada vez más detallada y con ello se abre

la posibilidad a realizar estudios más específicos y precisos con respecto a la generación de políticas eficientes. Esto, con el fin de que no sólo aseguren un crecimiento económico sino que maximicen el beneficio total a la vez que mantienen un equilibrio alineado a los objetivos tanto económicos como ambientales.

Por otro lado, a partir de los resultados obtenidos y en la búsqueda de determinar qué nivel de cambio es más efectivo en los tratamientos generados, se encontró que para ambas variables los casos extremos eran menos efectivos a nivel global, con la excepción del efecto sobre países de bajos ingresos. Este resultado sugiere que una política estricta de reducción de las emisiones de carbono podría ser perjudicial para una economía en comparación con una reducción más razonable de las mismas. Como complemento, lo mismo ocurre para un cambio extremo positivo en las emisiones de carbono y en el consumo de energía. Este hallazgo es de vital importancia ante el escenario actual que ha surgido durante las últimas décadas, con un alto nivel de contaminación y el interés de formar estrategias globales para su control.

Numerosos estudios avalan la idea de que el crecimiento económico está basado en una expansión de la capacidad energética de los países, y que durante las últimas décadas este aumento se sustentó principalmente en la generación de energía a través de fuentes convencionales, aumentando así sus emisiones de carbono. Sin embargo, una nueva etapa, a través del auge y la eficiencia de la generación de energías limpias, ha permitido desacoplar esta asociación. Sin embargo, indudablemente una mayor industrialización y crecimiento de la población debiesen implicar un aumento de los índices de contaminación. En base a esto, se recomienda que los futuros estudios estén centrados en la eficiencia con la que se genera la contaminación, es decir, unidad de crecimiento económico por tonelada de emisión de carbono generada, de tal manera de poder visualizar el crecimiento en base a los índices de contaminación existentes. Esto podría ayudar a establecer políticas globales que se adapten a las necesidades productivas de los países emergentes, no sólo para reducir las emisiones sino también para establecer objetivos de cómo generar crecimiento a un ritmo mayor que el aumento de las emisiones de carbono. Los resultados de este estudio sugieren que las políticas deberían estar orientadas y posiblemente adaptadas a las actividades económicas a las que está dedicado cada país, agrupando según el principal motor de crecimiento

respectivo, ya sea la agricultura, la manufactura, la industrialización o los servicios.

Así también, este estudio no sólo contribuye a la literatura económica sobre el desarrollo de políticas, sino que, mediante esta causalidad basada en tratamientos, se pueden encontrar resultados más relevantes desde el punto de vista de la gestión de la política medioambiental. El hecho de que se puedan comparar los rangos de objetivos de estas políticas permite aclarar qué nivel de variación es necesario para conseguir beneficios económicos. Además, en combinación con otros modelos basados en la respuesta al impulso (IRF), podrían constituir una herramienta eficaz para alcanzar objetivos económicos a largo plazo. Este marco permite no sólo determinar la dirección para un mayor desarrollo económico, sino que también indica dentro de qué rango deben establecerse para que sean más eficientes. El modelo podría ser utilizado en diferentes áreas financieras, especialmente en aquellas áreas con datos de alta frecuencia donde se podrían generar intervalos suficientemente pequeños para establecer, con mayor precisión, los efectos para cada nivel agregado. Este estudio también proporciona una herramienta para que los responsables de generar políticas económicas puedan planificar la mejor estrategia con beneficios no sólo para el crecimiento económico sino también para el beneficio ambiental, incluso algunos países podrían decidir intercambiar parte de su crecimiento eligiendo correctamente un plan de reducción de emisiones y gestión del consumo energético en beneficio del planeta.

Por último, los resultados de este estudio sugieren un método para ayudar a establecer objetivos climáticos a nivel mundial. Los países de menores ingresos y menos desarrollados son aquellos que mayor daño económico podrían sufrir por políticas ambientales restrictivas, siendo que gran parte de la actual crisis climática fue resultado de la fuerte industrialización de los países desarrollados. Mas aún, se puede sugerir que el desarrollo de estos últimos se debe a su auge energético produciendo grandes cantidades de CO₂, lo que dio lugar a un fuerte crecimiento económico. Los resultados de este estudio demuestran una forma de establecer objetivos climáticos para cada país que reduzcan la producción de carbono a nivel global, manteniendo el crecimiento económico para cada país según sus necesidades locales.

Bibliografía

- A. Abadie and G. W. Imbens. Large sample properties of matching estimators for average treatment effects. *econometrica*, 74(1):235–267, 2006.
- A. Abadie and G. W. Imbens. On the failure of the bootstrap for matching estimators. *Econometrica*, 76(6):1537–1557, 2008.
- A. Abadie and G. W. Imbens. Matching on the estimated propensity score. *Econometrica*, 84(2):781–807, 2016.
- A. O. Acheampong. Economic growth, co2 emissions and energy consumption: what causes what and where? *Energy Economics*, 74:677–692, 2018.
- U. Al-Mulali, H. G. Fereidouni, J. Y. Lee, and C. N. B. C. Sab. Exploring the relationship between urbanization, energy consumption, and co2 emission in mena countries. *Renewable and Sustainable Energy Reviews*, 23:107–112, 2013.
- J. B. Ang. Economic development, pollutant emissions and energy consumption in malaysia. *Journal of Policy Modeling*, 30(2):271–278, 2008.
- J. D. Angrist and G. M. Kuersteiner. Causal effects of monetary shocks: Semiparametric conditional independence tests with a multinomial propensity score. *Review of Economics and Statistics*, 93(3):725–747, 2011.
- J. D. Angrist, Ò. Jordà, and G. M. Kuersteiner. Semiparametric estimates of monetary policy effects: string theory revisited. *Journal of Business & Economic Statistics*, 36(3): 371–387, 2018.

- N. Antonakakis, I. Chatziantoniou, and G. Filis. Energy consumption, co2 emissions, and economic growth: An ethical dilemma. *Renewable and Sustainable Energy Reviews*, 68: 808–824, 2017.
- N. Apergis and J. E. Payne. Co2 emissions, energy usage, and output in central america. *Energy Policy*, 37(8):3282–3286, 2009.
- N. Apergis and J. E. Payne. Renewable energy consumption and economic growth: evidence from a panel of oecd countries. *Energy policy*, 38(1):656–660, 2010.
- P. Arora, S. Varshney, et al. Analysis of k-means and k-medoids algorithm for big data. *Procedia Computer Science*, 78:507–512, 2016.
- I. Bojinov and N. Shephard. Time series experiments and causal estimands: exact randomization tests and trading. *Journal of the American Statistical Association*, 114(528): 1665–1682, 2019.
- N. Bowden and J. E. Payne. The causal relationship between us energy consumption and real output: a disaggregated analysis. *Journal of Policy Modeling*, 31(2):180–188, 2009.
- M. Caliendo and S. Kopeinig. Some practical guidance for the implementation of propensity score matching. *Journal of economic surveys*, 22(1):31–72, 2008.
- T. Caliński and J. Harabasz. A dendrite method for cluster analysis. *Communications in Statistics-theory and Methods*, 3(1):1–27, 1974.
- R. H. Dehejia and S. Wahba. Causal effects in nonexperimental studies: Reevaluating the evaluation of training programs. *Journal of the American statistical Association*, 94 (448):1053–1062, 1999.
- S. Dinda. Environmental kuznets curve hypothesis: a survey. *Ecological economics*, 49(4): 431–455, 2004.
- C. Drake. Effects of misspecification of the propensity score on estimators of treatment effect. *Biometrics*, pages 1231–1236, 1993.

- F. Furuoka. The co2 emissions–development nexus revisited. *Renewable and Sustainable Energy Reviews*, 51:1256–1275, 2015.
- S. Ghosh and K. Kanjilal. Long-term equilibrium relationship between urbanization, energy consumption and economic activity: empirical evidence from india. *Energy*, 66:324–331, 2014.
- C. W. Granger. Testing for causality: A personal viewpoint. *Journal of Economic Dynamics and control*, 2:329–352, 1980.
- G. M. Grossman and A. B. Krueger. Environmental impacts of a north american free trade agreement. Technical report, National Bureau of economic research, 1991.
- J. Hahn. On the role of the propensity score in efficient semiparametric estimation of average treatment effects. *Econometrica*, pages 315–331, 1998.
- F. Halicioglu. An econometric study of co2 emissions, energy consumption, income and foreign trade in turkey. *Energy policy*, 37(3):1156–1164, 2009.
- J. J. Heckman, H. Ichimura, and P. E. Todd. Matching as an econometric evaluation estimator: Evidence from evaluating a job training programme. *The review of economic studies*, 64(4):605–654, 1997.
- K. Hirano, G. W. Imbens, and G. Ridder. Efficient estimation of average treatment effects using the estimated propensity score. *Econometrica*, 71(4):1161–1189, 2003.
- S. Hochreiter and J. Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, 1997.
- G. W. Imbens. Nonparametric estimation of average treatment effects under exogeneity: A review. *Review of Economics and statistics*, 86(1):4–29, 2004.
- G. F. Jenks. The data model concept in statistical mapping. *International yearbook of cartography*, 7:186–190, 1967.

- F. Johansson, U. Shalit, and D. Sontag. Learning representations for counterfactual inference. In *International conference on machine learning*, pages 3020–3029. PMLR, 2016.
- Ò. Jordà and A. M. Taylor. The time for austerity: estimating the average treatment effect of fiscal policy. *The Economic Journal*, 126(590):219–255, 2016.
- J. D. Kang, J. L. Schafer, et al. Demystifying double robustness: A comparison of alternative strategies for estimating a population mean from incomplete data. *Statistical science*, 22(4):523–539, 2007.
- L. Kaufman and P. J. Rousseeuw. *Finding groups in data: an introduction to cluster analysis*, volume 344. John Wiley & Sons, 2009.
- M. Kijima, K. Nishide, and A. Ohyama. Economic models for the environmental kuznets curve: A survey. *Journal of Economic Dynamics and Control*, 34(7):1187–1201, 2010.
- S. A. Kourtzidis, P. Tzeremes, and N. G. Tzeremes. Re-evaluating the energy consumption-economic growth nexus for the united states: An asymmetric threshold cointegration analysis. *Energy*, 148:537–545, 2018.
- J. Kraft and A. Kraft. On the relationship between energy and gnp. *The Journal of Energy and Development*, pages 401–403, 1978.
- G. M. Kuersteiner, D. C. Phillips, and M. Villamizar-Villegas. Effective sterilized foreign exchange intervention? evidence from a rule-based policy. *Journal of International Economics*, 113:118–138, 2018.
- B. K. Lee, J. Lessler, and E. A. Stuart. Improving propensity score weighting using machine learning. *Statistics in medicine*, 29(3):337–346, 2010.
- B. Lim, A. Alaa, and M. van der Schaar. Forecasting treatment responses over time using recurrent marginal structural networks. *NeurIPS*, 18:7483–7493, 2018.

- T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár. Focal loss for dense object detection. In *Proceedings of the IEEE international conference on computer vision*, pages 2980–2988, 2017.
- V. Mishra, R. Smyth, and S. Sharma. The energy-gdp nexus: evidence from a panel of pacific island countries. *Resource and Energy Economics*, 31(3):210–220, 2009.
- H. Mohammadi and S. Parvaresh. Energy consumption and output: Evidence from a panel of 14 oil-exporting countries. *Energy Economics*, 41:41–46, 2014.
- M. Nauta, D. Bucur, and C. Seifert. Causal discovery with attention-based convolutional neural networks. *Machine Learning and Knowledge Extraction*, 1(1):312–340, 2019.
- A. Omri and B. Kahouli. Causal relationships between energy consumption, foreign direct investment and economic growth: Fresh evidence from dynamic simultaneous-equations models. *Energy Policy*, 67:913–922, 2014.
- L. Parshall, K. Gurney, S. A. Hammer, D. Mendoza, Y. Zhou, and S. Geethakumar. Modeling energy consumption and co2 emissions at the urban scale: Methodological challenges and insights from the united states. *Energy Policy*, 38(9):4765–4782, 2010.
- J. E. Payne. On the dynamics of energy consumption and employment in illinois. *Journal of Regional Analysis and Policy*, 39, 2009.
- J. Pearl et al. Models, reasoning and inference. *Cambridge, UK: CambridgeUniversityPress*, 19:2, 2000.
- P. Poumanyvong and S. Kaneko. Does urbanization lead to less energy use and lower co2 emissions? a cross-country analysis. *Ecological Economics*, 70(2):434–444, 2010.
- A. Rauf, J. Zhang, J. Li, and W. Amin. Structural changes, energy consumption and carbon emissions in china: empirical evidence from ardl bound testing model. *Structural Change and Economic Dynamics*, 47:194–206, 2018.

- J. M. Robins. Correcting for non-compliance in randomized trials using structural nested mean models. *Communications in Statistics-Theory and methods*, 23(8):2379–2412, 1994.
- J. M. Robins and A. Rotnitzky. Semiparametric efficiency in multivariate regression models with missing data. *Journal of the American Statistical Association*, 90(429):122–129, 1995.
- P. R. Rosenbaum and D. B. Rubin. The central role of the propensity score in observational studies for causal effects. *Biometrika*, 70(1):41–55, 1983a.
- P. R. Rosenbaum and D. B. Rubin. The central role of the propensity score in observational studies for causal effects. *Biometrika*, 70(1):41–55, 1983b.
- D. B. Rubin. The use of matched sampling and regression adjustment to remove bias in observational studies. *Biometrics*, pages 185–203, 1973.
- D. B. Rubin. On principles for modeling propensity scores in medical research. *Pharmacoepidemiology and drug safety*, 13(12):855–857, 2004.
- R. Sari, M. Uzunkaya, and S. Hammoudeh. The relationship between disaggregated country risk ratings and stock market movements: an ardl approach. *Emerging markets finance and trade*, 49(1):4–16, 2013.
- M. Sebri and O. Ben-Salha. On the causal dynamics between economic growth, renewable energy consumption, co2 emissions and trade openness: Fresh evidence from brics countries. *Renewable and Sustainable Energy Reviews*, 39:14–23, 2014.
- S. Setoguchi, S. Schneeweiss, M. A. Brookhart, R. J. Glynn, and E. F. Cook. Evaluating uses of data mining techniques in propensity score estimation: a simulation study. *Pharmacoepidemiology and drug safety*, 17(6):546–555, 2008.
- U. Shalit, F. D. Johansson, and D. Sontag. Estimating individual treatment effect: generalization bounds and algorithms. In *International Conference on Machine Learning*, pages 3076–3085. PMLR, 2017.

- U. Soytaş and R. Sari. Energy consumption, economic growth, and carbon emissions: challenges faced by an eu candidate member. *Ecological economics*, 68(6):1667–1675, 2009.
- U. Soytaş, R. Sari, and B. T. Ewing. Energy consumption, income, and carbon emissions in the united states. *Ecological Economics*, 62(3-4):482–489, 2007.
- D. I. Stern. Energy and economic growth in the usa: a multivariate approach. *Energy economics*, 15(2):137–150, 1993.
- D. I. Stern. The rise and fall of the environmental kuznets curve. *World development*, 32(8):1419–1439, 2004.
- W. Sun, P. Wang, D. Yin, J. Yang, and Y. Chang. Causal inference via sparse additive models with application to online advertising. In *Twenty-Ninth AAAI Conference on Artificial Intelligence*, 2015.
- M. J. Van der Laan and J. M. Robins. *Unified methods for censored longitudinal data and causality*, volume 5. Springer, 2003.
- R. Waheed, S. Sarwar, and C. Wei. The survey of economic growth, energy consumption and carbon emission. *Energy Reports*, 5:1103–1115, 2019.
- H. Wang and M. Song. Ckmeans. 1d.dp: optimal k-means clustering in one dimension by dynamic programming. *The R journal*, 3(2):29, 2011.
- P. Wang, W. Sun, D. Yin, J. Yang, and Y. Chang. Robust tree-based causal inference for complex ad effectiveness analysis. In *Proceedings of the Eighth ACM International Conference on Web Search and Data Mining*, pages 67–76, 2015.
- D. Westreich, J. Lessler, and M. J. Funk. Propensity score estimation: neural networks, support vector machines, decision trees (cart), and meta-classifiers as alternatives to logistic regression. *Journal of clinical epidemiology*, 63(8):826–833, 2010.
- J. M. Wooldridge. *Econometric analysis of cross section and panel data*. MIT press, 2010.

- Z. Yang and Y. Zhao. Energy consumption, carbon emissions, and economic growth in india: Evidence from directed acyclic graphs. *Economic Modelling*, 38:533–540, 2014.
- X. Zhao, X. Zhang, N. Li, S. Shao, and Y. Geng. Decoupling economic growth from carbon dioxide emissions in china: a sectoral factor decomposition analysis. *Journal of Cleaner Production*, 142:3500–3516, 2017.
- H. Zhu, L. Duan, Y. Guo, and K. Yu. The effects of fdi, economic growth and energy consumption on carbon emissions in asean-5: evidence from panel quantile regression. *Economic Modelling*, 58:237–248, 2016.

ANEXO A



A.1. Segmentación de datos

TABLA A.1: Listado de países y clasificaciones.

País	Región	Nivel de ingresos	Miembro OCDE
Alemania	Europa y Asia Central	Alto	Sí
Arabia Saudí	Oriente Medio y África del Norte	Alto	No
Argelia	Oriente Medio y Norte de África	Media-baja	No
Argentina	América Latina y el Caribe	Medio-alto	No
Australia	Asia Oriental y Pacífico	Alto	Sí
Austria	Europa y Asia Central	Alto	Sí
Bahamas	América Latina y el Caribe	Alto	No
Bahrein	Oriente Medio y África del Norte	Alto	No
Bangladesh	Asia del Sur	Medio-Bajo	No
Barbados	América Latina y el Caribe	Alto	No
Bélgica	Europa y Asia Central	Alto	Sí
Belice	América Latina y el Caribe	Medio-alto	No
Benín	África subsahariana	Medio-Bajo	No
Bolivia	América Latina y el Caribe	Medio-Bajo	No
Botsuana	África subsahariana	Medio-alto	No
Brasil	América Latina y el Caribe	Medio-alto	No
Bulgaria	Europa y Asia Central	Medio-alto	No
Burkina Faso	África subsahariana	Bajo	No
Burundi	África subsahariana	Bajo	No
Canadá	América del Norte	Alto	Sí
Chile	América Latina y el Caribe	Alto	No
China	Asia Oriental y Pacífico	Medio-alto	No
Chipre	Europa y Asia Central	Alto	No
Colombia	América Latina y el Caribe	Medio-alto	No
Comoras	África subsahariana	Medio-Bajo	No
Corea, Rep.	Asia Oriental y Pacífico	Alto	Sí
Costa Rica	América Latina y el Caribe	Medio-alto	No
Dinamarca	Europa y Asia Central	Alto	Sí
Dominica	América Latina y el Caribe	Medio-alto	No
Ecuador	América Latina y el Caribe	Medio-alto	No
Egipto, Rep. Árabe	Oriente Medio y África del Norte	Medio-Bajo	No
El Salvador	América Latina y el Caribe	Medio-Bajo	No
España	Europa y Asia Central	Alto	Sí
Estados Unidos	América del Norte	Alto	Sí
Filipinas	Asia Oriental y Pacífico	Medio-Bajo	No
Finlandia	Europa y Asia Central	Alto	Sí
Francia	Europa y Asia Central	Alto	Sí
Gabón	África subsahariana	Medio-alto	No
Gambia	África subsahariana	Bajo	No
Ghana	África subsahariana	Medio-Bajo	No
Granada	América Latina y el Caribe	Medio-alto	No
Grecia	Europa y Asia Central	Alto	Sí
Guatemala	América Latina y el Caribe	Medio-alto	No
Guinea-Bissau	África subsahariana	Bajo	No
Guyana	América Latina y el Caribe	Medio-alto	No
Honduras	América Latina y el Caribe	Medio-Bajo	No
Hong Kong RAE, China	Asia Oriental y Pacífico	Alto	No

TABLA A.1: (continuación)

País	Región	Nivel de ingresos	Miembro OCDE
India	Asia del Sur	Medio-bajo	No
Indonesia	Asia Oriental y Pacífico	Medio-alto	No
Irán, Rep. Islámica	Oriente Medio y África del Norte	Media-alto	No
Irlanda	Europa y Asia Central	Alto	Sí
Islandia	Europa y Asia Central	Alto	Sí
Israel	Oriente Medio y África del Norte	Alto	No
Italia	Europa y Asia Central	Alto	Sí
Jamaica	América Latina y el Caribe	Medio-alto	No
Japón	Asia Oriental y Pacífico	Alto	Sí
Jordania	Oriente Medio y África del Norte	Medio-alto	No
Kenia	África subsahariana	Medio-Bajo	No
Kiribati	Asia Oriental y Pacífico	Medio-Bajo	No
Madagascar	África subsahariana	Bajo	No
Malasia	Asia Oriental y Pacífico	Medio-alto	No
Malawi	África subsahariana	Bajo	No
Malí	África subsahariana	Bajo	No
Malta	Oriente Medio y África del Norte	Alto	No
Marruecos	Oriente Medio y África del Norte	Medio-Bajo	No
Mauricio	África subsahariana	Alto	No
México	América Latina y el Caribe	Medio-alto	Sí
Nicaragua	América Latina y el Caribe	Medio-Bajo	No
Níger	África subsahariana	Bajo	No
Nigeria	África subsahariana	Medio-Bajo	No
Noruega	Europa y Asia Central	Alto	Sí
Nueva Zelanda	Asia Oriental y Pacífico	Alto	Sí
Países Bajos	Europa y Asia Central	Alto	Sí
Pakistán	Asia del Sur	Medio-Bajo	No
Panamá	América Latina y el Caribe	Alto	No
Paraguay	América Latina y el Caribe	Medio-Alto	No
Perú	América Latina y el Caribe	Medio-alto	No
Portugal	Europa y Asia Central	Alto	Sí
Reino Unido	Europa y Asia Central	Alto	Sí
República Centroafricana	África subsahariana	Bajo	No
República Dominicana	América Latina y el Caribe	Medio-alto	No
Ruanda	África subsahariana	Bajo	No
Senegal	África subsahariana	Medio-Bajo	No
Singapur	Asia Oriental y Pacífico	Alto	No
Sri Lanka	Asia del Sur	Medio-Bajo	No
Sudáfrica	África subsahariana	Medio-Alto	No
Suecia	Europa y Asia Central	Alto	Sí
Suiza	Europa y Asia Central	Alto	Sí
Tailandia	Asia Oriental y Pacífico	Medio-alto	No
Túnez	Oriente Medio y África del Norte	Medio-Bajo	No
Turquía	Europa y Asia Central	Medio-alto	Sí
Uruguay	América Latina y el Caribe	Alto	No
Venezuela, RB	América Latina y el Caribe	Medio-alto	No
Zimbabue	África subsahariana	Medio-Bajo	No

A.2. Resumen mejor intervalo de tratamiento por país

TABLA B.1: Resumen de los mejores intervalos de tratamiento por país considerando los efectos de las emisiones de carbono, el consumo de energía y el efecto direccional compuesto. Se incluye la diferencia media de 6 años entre los dos mejores intervalos de tratamiento.

País	Tratamiento CO2		Tratamiento Ener		Efecto Conjunto (Ene-CO2)	
	Mejor Int.	Dif Prom 6 años [%]	Mejor Int.	Dif Prom 6 años [%]	Mejor Int.	Dif Prom 6 años [%]
Alemania	[0.9 %, 4.5 %]	2.52	[-2 %, 0.2 %]	6.83	-Δ ENE -Δ CO2	3.93
Arabia Saudí	> 4.5 %	0.09	[-4.2 %, -2 %]	1.78	-Δ ENE +Δ CO2	2.50
Argelia	[-2.1 %, 0.9 %]	4.45	[-4.2 %, -2 %]	2.25	-Δ ENE +Δ CO2	6.76
Argentina	> 4.5 %	3.87	[0.2 %, 3.1 %]	2.24	-Δ ENE -Δ CO2	2.72
Australia	[-2.1 %, 0.9 %]	4.05	[-4.2 %, -2 %]	3.83	-Δ ENE -Δ CO2	4.55
Austria	[-2.1 %, 0.9 %]	0.21	[0.2 %, 3.1 %]	1.77	-Δ ENE -Δ CO2	5.78
Bahamas	[0.9 %, 4.5 %]	2.36	> 3.1 %	1.60	+Δ ENE +Δ CO2	2.62
Bahrein	> 4.5 %	2.98	> 3.1 %	1.65	-Δ ENE -Δ CO2	4.91
Bangladesh	[-2.1 %, 0.9 %]	3.29	[-2 %, 0.2 %]	4.66	-Δ ENE +Δ CO2	1.87
Barbados	[-5.3 %, -2.1 %]	7.77	[-2 %, 0.2 %]	4.33	-Δ ENE -Δ CO2	3.17
Bélgica	[0.9 %, 4.5 %]	11.69	[0.2 %, 3.1 %]	5.29	+Δ ENE -Δ CO2	5.36
Belice	[-2.1 %, 0.9 %]	0.40	< -4.2 %	3.62	+Δ ENE -Δ CO2	9.36
Benín	[-2.1 %, 0.9 %]	1.01	[0.2 %, 3.1 %]	0.57	-Δ ENE -Δ CO2	2.87
Bolivia	[-5.3 %, -2.1 %]	2.42	> 3.1 %	0.86	-Δ ENE +Δ CO2	11.60
Botsuana	[0.9 %, 4.5 %]	0.17	< -4.2 %	1.36	+Δ ENE +Δ CO2	4.48
Brasil	[0.9 %, 4.5 %]	0.05	[-2 %, 0.2 %]	4.58	-Δ ENE -Δ CO2	2.92
Bulgaria	> 4.5 %	8.16	[-4.2 %, -2 %]	8.42	+Δ ENE -Δ CO2	9.05
Burkina Faso	[0.9 %, 4.5 %]	15.41	[-2 %, 0.2 %]	9.85	-Δ ENE +Δ CO2	3.70
Burundi	> 4.5 %	0.21	< -4.2 %	0.80	-Δ ENE -Δ CO2	3.27
Canadá	[-2.1 %, 0.9 %]	7.34	[-4.2 %, -2 %]	0.36	-Δ ENE -Δ CO2	5.81
Chile	> 4.5 %	6.26	[-4.2 %, -2 %]	6.73	+Δ ENE -Δ CO2	11.29
China	[-2.1 %, 0.9 %]	41.76	[-2 %, 0.2 %]	31.75	-Δ ENE -Δ CO2	29.38
Chipre	> 4.5 %	11.81	[-2 %, 0.2 %]	5.90	+Δ ENE -Δ CO2	6.22
Colombia	[0.9 %, 4.5 %]	0.41	< -4.2 %	0.29	-Δ ENE -Δ CO2	4.24
Comoras	[-5.3 %, -2.1 %]	0.02	> 3.1 %	0.04	-Δ ENE +Δ CO2	2.80
Corea, Rep.	> 4.5 %	13.78	[0.2 %, 3.1 %]	4.49	+Δ ENE +Δ CO2	2.99
Costa Rica	[-2.1 %, 0.9 %]	7.25	< -4.2 %	1.47	-Δ ENE +Δ CO2	4.25
Dinamarca	< -5.3 %	1.05	[-4.2 %, -2 %]	0.14	-Δ ENE -Δ CO2	11.06
Dominica	[-2.1 %, 0.9 %]	0.17	[-4.2 %, -2 %]	6.06	-Δ ENE -Δ CO2	6.38
Ecuador	[-5.3 %, -2.1 %]	3.79	[-4.2 %, -2 %]	0.63	-Δ ENE +Δ CO2	1.27
Egipto, Rep. Árabe	> 4.5 %	4.04	[-4.2 %, -2 %]	9.11	+Δ ENE -Δ CO2	4.66
El Salvador	[0.9 %, 4.5 %]	0.78	[-4.2 %, -2 %]	0.88	+Δ ENE -Δ CO2	5.45
España	[-5.3 %, -2.1 %]	0.94	[0.2 %, 3.1 %]	0.01	-Δ ENE -Δ CO2	2.56
Estados Unidos	[-5.3 %, -2.1 %]	2.33	[-2 %, 0.2 %]	5.40	-Δ ENE -Δ CO2	7.62
Filipinas	[-2.1 %, 0.9 %]	0.75	[-4.2 %, -2 %]	0.49	-Δ ENE -Δ CO2	19.06
Finlandia	> 4.5 %	1.95	< -4.2 %	0.04	+Δ ENE -Δ CO2	2.36
Francia	[-5.3 %, -2.1 %]	0.30	[-2 %, 0.2 %]	1.51	+Δ ENE -Δ CO2	1.41
Gabón	> 4.5 %	1.49	> 3.1 %	0.34	-Δ ENE -Δ CO2	4.99
Gambia	[-2.1 %, 0.9 %]	1.12	[-2 %, 0.2 %]	0.37	+Δ ENE +Δ CO2	6.20
Ghana	[-2.1 %, 0.9 %]	1.16	< -4.2 %	8.05	+Δ ENE +Δ CO2	3.22
Granada	< -5.3 %	0.32	[0.2 %, 3.1 %]	8.04	-Δ ENE -Δ CO2	4.24
Grecia	[0.9 %, 4.5 %]	7.72	[0.2 %, 3.1 %]	1.63	+Δ ENE +Δ CO2	4.59
Guatemala	[-5.3 %, -2.1 %]	7.72	[-2 %, 0.2 %]	0.33	+Δ ENE +Δ CO2	1.94
Guinea-Bissau	[0.9 %, 4.5 %]	0.62	> 3.1 %	0.22	-Δ ENE -Δ CO2	2.01
Guyana	> 4.5 %	8.07	[-2 %, 0.2 %]	6.44	+Δ ENE -Δ CO2	10.18
Honduras	< -5.3 %	1.18	[0.2 %, 3.1 %]	0.85	-Δ ENE -Δ CO2	8.94
Hong Kong	[-5.3 %, -2.1 %]	12.44	> 3.1 %	3.04	-Δ ENE -Δ CO2	5.52

TABLA B.1: (continuación)

País	Tratamiento CO2		Tratamiento Ener		Efecto Conjunto (Ene-CO2)	
	Mejor Int.	Dif Prom 6 años [%]	Mejor Int.	Dif Prom 6 años [%]	Mejor Int.	Dif Prom 6 años [%]
India	> 4.5 %	2.18	[-2 %, 0.2 %]	14.39	-Δ ENE +Δ CO2	5.81
Indonesia	> 4.5 %	7.28	[0.2 %, 3.1 %]	7.69	+Δ ENE +Δ CO2	0.69
Irán, Rep. Islámica	[-2.1 %, 0.9 %]	0.62	[-2 %, 0.2 %]	0.01	-Δ ENE +Δ CO2	4.69
Irlanda	> 4.5 %	5.04	[-4.2 %, -2 %]	8.40	-Δ ENE -Δ CO2	13.42
Islandia	> 4.5 %	1.94	[0.2 %, 3.1 %]	4.99	-Δ ENE -Δ CO2	3.51
Israel	[-5.3 %, -2.1 %]	1.10	< -4.2 %	1.18	+Δ ENE -Δ CO2	3.77
Italia	[0.9 %, 4.5 %]	2.00	[-2 %, 0.2 %]	0.63	-Δ ENE -Δ CO2	5.87
Jamaica	[-5.3 %, -2.1 %]	11.66	> 3.1 %	1.84	-Δ ENE +Δ CO2	3.20
Japón	[0.9 %, 4.5 %]	3.33	[-2 %, 0.2 %]	4.78	+Δ ENE -Δ CO2	7.01
Jordania	[-2.1 %, 0.9 %]	10.19	[-2 %, 0.2 %]	2.99	+Δ ENE +Δ CO2	1.91
Kenia	[0.9 %, 4.5 %]	0.94	[0.2 %, 3.1 %]	0.35	-Δ ENE -Δ CO2	10.95
Kiribati	[-5.3 %, -2.1 %]	0.36	[-4.2 %, -2 %]	0.61	+Δ ENE +Δ CO2	2.58
Madagascar	> 4.5 %	0.12	[-2 %, 0.2 %]	0.38	-Δ ENE -Δ CO2	0.80
Malasia	> 4.5 %	2.18	> 3.1 %	2.05	-Δ ENE -Δ CO2	5.98
Malawi	> 4.5 %	1.96	< -4.2 %	3.85	-Δ ENE +Δ CO2	6.18
Malí	> 4.5 %	3.27	< -4.2 %	3.39	+Δ ENE -Δ CO2	4.42
Malta	> 4.5 %	0.21	[0.2 %, 3.1 %]	4.41	+Δ ENE +Δ CO2	8.75
Marruecos	[-2.1 %, 0.9 %]	14.70	[-2 %, 0.2 %]	1.94	-Δ ENE -Δ CO2	5.24
Mauricio	> 4.5 %	2.04	[-4.2 %, -2 %]	8.54	-Δ ENE -Δ CO2	3.22
México	[0.9 %, 4.5 %]	3.36	[0.2 %, 3.1 %]	0.88	-Δ ENE +Δ CO2	4.79
Nicaragua	[-5.3 %, -2.1 %]	3.89	[0.2 %, 3.1 %]	3.53	-Δ ENE +Δ CO2	4.58
Níger	[-2.1 %, 0.9 %]	0.59	[-2 %, 0.2 %]	0.24	+Δ ENE +Δ CO2	1.89
Nigeria	> 4.5 %	1.52	< -4.2 %	6.37	-Δ ENE -Δ CO2	6.98
Noruega	[0.9 %, 4.5 %]	3.30	[0.2 %, 3.1 %]	3.41	-Δ ENE +Δ CO2	11.64
Nueva Zelanda	[-5.3 %, -2.1 %]	2.79	[-2 %, 0.2 %]	0.15	-Δ ENE -Δ CO2	4.02
Países Bajos	[-2.1 %, 0.9 %]	2.65	< -4.2 %	0.01	-Δ ENE +Δ CO2	3.81
Pakistán	[-2.1 %, 0.9 %]	2.52	[-4.2 %, -2 %]	1.57	+Δ ENE +Δ CO2	4.72
Panamá	> 4.5 %	1.96	< -4.2 %	2.92	-Δ ENE -Δ CO2	7.95
Paraguay	[-5.3 %, -2.1 %]	16.09	> 3.1 %	0.07	+Δ ENE +Δ CO2	0.77
Perú	[0.9 %, 4.5 %]	10.51	[0.2 %, 3.1 %]	3.60	+Δ ENE +Δ CO2	5.85
Portugal	[-5.3 %, -2.1 %]	2.50	> 3.1 %	0.58	-Δ ENE +Δ CO2	15.64
Reino Unido	< -5.3 %	0.04	< -4.2 %	0.90	-Δ ENE -Δ CO2	8.71
Rep Centroafricana	[0.9 %, 4.5 %]	1.99	> 3.1 %	2.16	+Δ ENE -Δ CO2	5.65
Rep Dominicana	> 4.5 %	11.29	< -4.2 %	7.04	+Δ ENE -Δ CO2	2.92
Ruanda	> 4.5 %	5.95	< -4.2 %	0.57	+Δ ENE -Δ CO2	12.53
Senegal	[0.9 %, 4.5 %]	1.60	[0.2 %, 3.1 %]	2.78	-Δ ENE -Δ CO2	2.17
Singapur	> 4.5 %	12.14	< -4.2 %	5.09	-Δ ENE +Δ CO2	13.38
Sri Lanka	> 4.5 %	2.89	> 3.1 %	0.87	-Δ ENE +Δ CO2	8.65
Sudáfrica	[0.9 %, 4.5 %]	4.54	[0.2 %, 3.1 %]	6.98	-Δ ENE -Δ CO2	24.95
Suecia	[-2.1 %, 0.9 %]	2.96	< -4.2 %	1.14	-Δ ENE +Δ CO2	2.94
Suiza	[-2.1 %, 0.9 %]	0.21	[-4.2 %, -2 %]	3.44	+Δ ENE -Δ CO2	7.70
Tailandia	> 4.5 %	4.55	[0.2 %, 3.1 %]	11.02	+Δ ENE +Δ CO2	6.84
Túnez	[0.9 %, 4.5 %]	0.04	> 3.1 %	5.08	+Δ ENE -Δ CO2	27.35
Turquía	> 4.5 %	6.55	[-2 %, 0.2 %]	0.75	-Δ ENE -Δ CO2	4.35
Uruguay	< -5.3 %	1.43	> 3.1 %	1.04	-Δ ENE -Δ CO2	7.66
Venezuela, RB	> 4.5 %	0.66	[-2 %, 0.2 %]	2.25	-Δ ENE +Δ CO2	6.71
Zimbabue	> 4.5 %	2.36	[-2 %, 0.2 %]	1.32	+Δ ENE -Δ CO2	4.03

ANEXO B



B.1. Comparación métodos de clustering




Figura B.1: Comparación entre los métodos de clustering, sensibilizando por el número de clusters. Se muestran los modelos basados en medioides (programación dinámica) y en medias (Kmeans).

B.2. Comparación de AUC en puntajes de propensión




Figura B.2: Comparación de la estimación de la puntuación de propensión para los tratamientos de emisiones de carbono y consumo de energía. A la izquierda se presentan los resultados del modelo propuesto; a la derecha, la estimación mediante un modelo probit ordenado de panel con las mismas variables objetivo.

B.3. Efectos Emisiones de carbono sobre PIB




Figura B.3: Efecto ponderado del tratamiento de las emisiones de carbono sobre el PIB per cápita agrupado por nivel de ingresos: (a) países de ingreso alto; (b) ingreso medio-alto; (c) ingreso medio-bajo; y, (d) ingreso bajo, clasificados según los indicadores de desarrollo mundial 2020. Los intervalos de confianza de los efectos se estiman con un 95 %. Incluye solo efectos de crisis financieras.




Figura B.4: Efecto ponderado del tratamiento de las emisiones de carbono sobre el PIB per cápita agrupado por nivel de ingresos: (a) países de ingreso alto; (b) ingreso medio-alto; (c) ingreso medio-bajo; y, (d) ingreso bajo, clasificados según los indicadores de desarrollo mundial 2020. Los intervalos de confianza de los efectos se estiman con un 95 %. No se incluyen efectos de crisis ni recuperación.

B.4. Efectos del Consumo energético sobre PIB




Figura B.5: Efecto del tratamiento ponderado del consumo energético sobre el PIB per cápita para los países de la OCDE: (a) sin considerar el efecto de las crisis financieras; (b) efectos de las crisis subprime y puntocom; y, (c) efecto de las crisis y su respectiva recuperación tras la crisis. Los intervalos de confianza de los efectos se estiman con un 95 % mediante el método bootstrap.




Figura B.6: Efecto ponderado del tratamiento del consumo energético sobre el PIB per cápita para todos los países: (a) sin considerar el efecto de las crisis financieras; (b) efectos de las crisis subprime y puntocom incluidos; y, (c) efectos de las crisis financieras y la respectiva recuperación tras la crisis. Los intervalos de confianza de los efectos se estiman en un 95 %.




Figura B.7: Efecto ponderado del tratamiento del consumo de energía sobre el PIB per cápita agrupado por nivel de ingresos: (a) países de ingresos altos; (b) ingresos medios-altos; (c) ingresos medios-bajos; y, (d) ingresos bajos, clasificados según los indicadores de desarrollo mundial 2020. Los intervalos de confianza de los efectos se estiman con un 95 %. Incluye efectos de crisis financieras.




Figura B.8: Efecto ponderado del tratamiento del consumo de energía sobre el PIB per cápita agrupado por nivel de ingresos: (a) países de ingresos altos; (b) ingresos medios-altos; (c) ingresos medios-bajos; y, (d) ingresos bajos, clasificados según los indicadores de desarrollo mundial 2020. Los intervalos de confianza de los efectos se estiman con un 95 %. No se incluyen efectos de crisis ni recuperación.

B.5. Efectos direccionales conjuntos




Figura B.9: Efecto ponderado del tratamiento direccional conjunto sobre el PIB per cápita agrupado por nivel de ingreso: (a) países de ingresos altos; (b) ingresos medios-altos; (c) ingresos medios-bajos; y, (d) ingresos bajos, clasificados según los indicadores de desarrollo mundial 2020. Los intervalos de confianza de los efectos se estiman con un 95 %. Incluye crisis financieras.




Figura B.10: Efecto ponderado del tratamiento direccional conjunto sobre el PIB per cápita agrupado por nivel de ingreso: (a) países de ingresos altos; (b) ingresos medios-altos; (c) ingresos medios-bajos; y, (d) ingresos bajos, clasificados según los indicadores de desarrollo mundial 2020. Los intervalos de confianza de los efectos se estiman con un 95 %. No se incluyen efectos de crisis ni recuperación.




Figura B.11: Efecto ponderado del tratamiento conjunto direccional sobre el PIB per cápita, donde (a) corresponde a los miembros de la OCDE y (b) considera toda la muestra. Los efectos se estiman teniendo en cuenta los efectos de la crisis y la posterior recuperación. Los intervalos de confianza se estiman con un 95 %.