

**UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS**

**REVISIÓN DEL IMPACTO DEL DESARROLLO FINANCIERO EN EL
CONSUMO DE ENERGÍAS RENOVABLES: COMPARACIÓN ENTRE
ALGORITMOS DE MACHINE LEARNING Y DATOS DE PANEL**

**TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA INGENIERÍA
INDUSTRIAL Y AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL**

AUTOR

ALEXIS IGNACIO ALFARO SUAZO

PROFESOR GUÍA

DR. WERNER KRISTJANPOLLER RODRÍGUEZ

PROFESOR CO-REFERENTE

DR. FELIPE ESCUDERO BARROS

VALPARAÍSO, CHILE, JULIO 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): Memoria o trabajo de título; Tesis de Postgrado;

Título del trabajo: Revisión del Impacto del Desarrollo Financiero en el Consumo de Energías Renovables: Comparación entre Algoritmos de Machine Learning y Datos de Panel

Nombre del candidato(a): Alexis Alfaro Suazo

Carrera / Grado: Magíster en Ciencias de la Ingeniería Industrial

Campus: Casa Central Valparaiso ; **Departamento:** Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Werner Kristjanpoller Rodríguez, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL

El trabajo **NO contiene información que amerite confidencialidad** y puede ser publicado de inmediato en repositorio con acceso abierto.

El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (embargo) por:

6 meses; 12 meses; 2 años; 3 años; 5 años; 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 04-07-2025

; Firma:

Estudiante o Candidato(a):

Fecha: 04-07-2025

; Firma:

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

Agradecimientos

Creo sinceramente que esta es la hoja más difícil de escribir en todos mis años de estudios. Me facilita un poco el trabajo el hecho de que quienes están acá conocen, de manera tácita e íntima, el rol que han tenido en mi proceso personal y académico. No obstante lo anterior, me parece imperante inmortalizar su importancia para mí en la culminación de este largo camino.

En primer lugar, debo agradecer a mi madre Alejandra, quien me brindó una crianza cálida, con valores de los que a día de hoy continúo aprendiendo, y una resiliencia única que la convierten en una persona admirable y de la que me siento orgulloso de ser hijo. Es una alegría indescriptible poder compartir este logro con ella, después de años de incertidumbre de saber si estaría a mi lado o no. A mi padre Ariel, de quien aprendo a mirar la vida con alegría y con amabilidad, aun si a uno le cuesta. Gracias a él, sé que el cambio es verdadero si te lo propones de corazón. A mi hermano Ariel, quien se volvió mi modelo a seguir desde pequeño, un ejemplo vivo de que una vida enfocada en la humildad y el esfuerzo siempre tendrá frutos tarde o temprano. Gracias a mi hermano, sé que la vida es un desafío, pero un lindo e ineludible desafío. No puedo dejar de mencionar a mis sobrinas, Rafaela y Josefa, quienes me motivan a crecer cada día para ser un ejemplo de tío y convertirme en soporte para ellas siempre que me necesiten.

Agradezco a Sofía, mi novia, con quien deseo tener una vida entera de amor, felicidad y suavidad, por su apoyo incondicional, aun en mis momentos más débiles. De ti admiro y aprendo esa fortaleza para reinventarte y ser capaz de darle un revés a la vida, por más difícil que esto pueda ser. No sabes cuán importante fue tu rol en mi crecimiento y redescubrimiento personal, y te lo agradeceré por la eternidad.

No puedo dejar atrás a mis amigos Joaquín, Iván, Pablo, Luciano, Patricio y Elson, quie-

nes me han brindado su amistad desde hace tantos años. Han sido un apoyo fundamental en mi proceso y espero que esto perdure por muchos años más. Debo mencionar también a mis amigos Miguel, Cristóbal e Ignacio, quienes hicieron de la Universidad una experiencia más agradable, entregándome momentos únicos y acompañándome en gran parte de este viaje. Agradezco también a Vincent, con quien he formado una linda amistad que ha trascendido la vida universitaria, no olvido tantas conversaciones críticas y todo el apoyo que me brindaste en todo esto. Finalmente, agradezco a Benjamín, compañero de tantos proyectos y amigo del pasado, presente y futuro. Es impresionante que cualquier cosa que pueda inmortalizar de nuestra amistad es tácito.

Debo agradecer también a la profesora María Elisa Farías, de quien aprendí mucho, abriéndome las puertas a esta etapa, permitiéndome descubrir esta pasión por la investigación como una herramienta de cambio y siendo una inspiración en la docencia. Al profesor Eloy Alvarado, quien se volvió un motivador inconsciente de mi autoexigencia, pero que, a la vez, fomentó la confianza en mí mismo para entender cosas que me llegaron a parecer imposibles. Al profesor Werner Kristjanpoller, quien me respaldó en este proceso de titulación y me recibió en el programa con una enorme disposición y cercanía, así como con una batería de conocimientos que me permitieron formarme hasta el día de hoy.

Agradezco al Departamento de Balanza de Pagos de la Gerencia de Estadísticas Macroeconómicas del Banco Central, lugar donde hice mi práctica profesional durante los años 2024 y 2025, por su aporte en mi formación tanto en lo técnico como en lo humano. Mi experiencia en esta institución me motivó a pensar en cosas más grandes. Enfatizo mi agradecimiento a Pilar, Juan José y Daniel, quienes confiaron en mí para proyectos complejos y de quienes aprendí más del mundo laboral.

No puedo dejar atrás una breve dedicatoria a Amanda, *la mamita*, con quien desde pequeño



y en mi adolescencia, era la conversación que siempre disfruté más. Aún si tengo recuerdos difusos, se que te la jugaste por mí, también esto va para ti en tu merecido descanso.

RESUMEN EJECUTIVO

Este estudio examina la relación entre el desarrollo financiero y el consumo de energías renovables, integrando métodos econométricos dinámicos con técnicas interpretables de aprendizaje automático (ML). Utilizando un panel de 83 países entre 2004 y 2021, todas las variables son expresadas en diferencias logarítmicas para asegurar estacionariedad y capturar las dinámicas de crecimiento. El análisis evalúa nueve índices de desarrollo financiero, junto con un conjunto exhaustivo de controles económicos y ambientales. Mientras que la estimación System-GMM revela efectos lineales acotados, particularmente a través de la profundidad de instituciones financieras, los modelos de ML permiten descubrir patrones no lineales complejos, incluyendo formas en U y U invertida en el vínculo entre las finanzas y las energías limpias.

Se implementan seis algoritmos de ML (CNN, SVR, *Random Forest*, *LightGBM*, *XGBoost*, *NGBoost*) bajo validación cruzada (*GroupKFold*) y ajuste de hiperparámetros (*GridSearchCV*), seleccionando los mejores modelos mediante el procedimiento *Model Confidence Set* (MCS). *Random Forest* y *LightGBM* presentan consistentemente el mejor desempeño predictivo, superando a la estimación econométrica tanto en el error cuadrático medio (ECM) como en el error absoluto medio (EAM). Para garantizar interpretabilidad, se utilizan valores SHAP, generando gráficos de enjambre y de dependencia que permiten revelar efectos heterogéneos entre componentes financieros, destacando el rol positivo de la eficiencia institucional y de mercado.

Complementariamente, las pruebas de causalidad de Granger para datos de panel muestran una relación bidireccional generalizada entre desarrollo financiero y consumo de energías renovables, reforzando la existencia de un vínculo recíproco que debe ser considerado en el diseño de políticas públicas. El estudio concluye con recomendaciones orientadas a promover una macroeco-



nomía estable y un fortalecimiento gradual del sistema financiero como mecanismos para facilitar la transición energética.

Palabras clave. Consumo de Energías Renovables; Estimación Machine Learning; Financial Desarrollo Financiero; SHapley Additive exPlanations; Análisis de Causalidad; System-GMM

ABSTRACT

This study examines the relationship between financial development and renewable energy consumption by integrating dynamic panel data methods with interpretable machine learning (ML) techniques. Using a panel of 83 countries from 2004 to 2021, all variables are expressed in log-differenced form to ensure stationarity and capture growth dynamics. The analysis evaluates nine financial development indices and a comprehensive set of economic and environmental controls. While the traditional System Generalized Method of Moments (System-GMM) framework identifies limited linear effects, particularly through financial institutional depth, ML models uncover rich nonlinear patterns, including U-shaped and inverted U-shaped relationships between financial indicators and renewable energy consumption.

Six ML models (CNN, SVR, Random Forest, LightGBM, XGBoost, NGBoost) are assessed through cross-validation (GroupKFold) and hyperparameter optimization (GridSearchCV), with model selection based on the Model Confidence Set (MCS). Random Forest and LightGBM consistently outperform the econometric benchmark in both predictive accuracy (MSE, MAE) and model robustness. To ensure interpretability, SHapley Additive exPlanations (SHAP) are employed through beeswarm and dependence plots, revealing heterogeneous effects across financial subcomponents and confirming the positive role of efficiency in financial institutions and markets.

Additionally, Granger causality tests suggest a generalized bidirectional causal link between financial development and renewable energy consumption, reinforcing the relevance of this feedback loop for policy design. The study concludes with policy recommendations that emphasize macroeconomic stability and gradual financial sector strengthening as levers for a sustainable energy transition.



Keywords. Renewable Energy Consumption; Machine Learning Estimation; Financial Development; SHapley Additive exPlanations; Causality Analysis; System-GMM



Índice

1. Introducción	14
2. Problema de Investigación	17
3. Objetivos	19
3.1. Objetivo General	19
3.2. Objetivos Específicos	19
4. Marco Teórico	21
4.1. Relaciones Macroeconómicas en el Contexto del Nexo Energía-Finanzas	21
4.1.1. Crecimiento Económico y Consumo de Energía	22
4.1.2. Crecimiento Económico y Desarrollo Financiero	24
4.1.3. Desarrollo Financiero y Consumo de Energía	25
4.2. Implementaciones Relacionadas de Algoritmos de Machine Learning	29
4.3. Medidas de Desarrollo Financiero	30
5. Metodología	34
5.1. Datos y Variables	34
5.2. Estimador System-GMM	37
5.3. Algoritmos de Machine Learning	39
5.3.1. Convolutional Neural Networks	39
5.3.2. Support Vector Regression	41
5.3.3. Random Forest	42



5.3.4.	XGBoost	42
5.3.5.	LightGBM	43
5.3.6.	NGBoost	44
5.4.	Optimización de Parámetros y Model Confidence Set	45
5.5.	SHapley Additive exPlanations	46
5.6.	Prueba de Causalidad	47
5.7.	Resumen de la Metodología	48
5.8.	Especificación de los Modelos	50
6.	Resultados y Discusión	51
6.1.	Pruebas de Raíz Unitaria	51
6.2.	Resultados de la estimación System-GMM	52
6.3.	Selección de Algoritmos de Machine Learning	55
6.4.	Comparación de Desempeño entre Algoritmos de Machine Learning y System-GMM	58
6.5.	Interpretación de resultados mediante SHAP	59
6.5.1.	Impacto de las Variables de Control en el Consumo de Energía	62
6.5.2.	Impacto de las Dimensiones de Desarrollo Financiero en el Consumo de Energía	64
6.6.	Análisis de Causalidad	66
6.7.	Implicancias de Política Pública	68
7.	Conclusiones	71
8.	Referencias	74



A. Lista de países	82
B. Hiperparámetros	84
B.1. Hiperparámetros para CNN	84
B.2. Hiperparámetros para SVR	84
B.3. Hiperparámetros para LightGBM	85
B.4. Hiperparámetros para Random Forest	85
B.5. Hiperparámetros para XGBoost	86
B.6. Hiperparámetros para NGBoost	86

Índice de Tablas

4.1. Medidas de Desarrollo Financiero	31
4.2. Variables pertenecientes al análisis propuesto por Svirydzenka (2016)	33
5.1. Lista de Variables y Características	35
5.2. Estadísticas Descriptivas de las variables escaladas y normalizadas	37
5.3. Hipótesis Nula y Alternativa para las pruebas de especificación	39
6.1. Resultados Pruebas Raíz Unitaria (Variables en Nivel)	52
6.2. Estimaciones System-GMM	53
6.3. Valores del ECM en el conjunto de prueba para los algoritmos de ML a través de los índices de desarrollo financiero.	57
6.4. Valores del EAM en el conjunto de prueba para los algoritmos de ML a través de los índices de desarrollo financiero.	57
6.5. Comparación de desempeño: ML vs. System-GMM (Conjunto de Prueba)	58
6.6. Resultados del Test de Causalidad de Granger	67
A.1. Nivel de desarrollo por país	82
B.1. Mejores hiperparámetros de CNN por conjunto de variables (seleccionados mediante GridSearchCV)	84
B.2. Mejores hiperparámetros de SVR por conjunto de variables (seleccionados mediante GridSearchCV)	84
B.3. Mejores hiperparámetros de LightGBM por conjunto de variables (seleccionados mediante GridSearchCV)	85



B.4. Mejores hiperparámetros de Random Forest por conjunto de variables (seleccionados mediante GridSearchCV)	85
B.5. Mejores hiperparámetros de XGBoost por conjunto de variables (seleccionados mediante GridSearchCV)	86
B.6. Mejores hiperparámetros de NGBoost por conjunto de variables (seleccionados mediante GridSearchCV)	86



Índice de Figuras

5.1. Matriz de Correlación	38
5.2. Esquema metodológico del estudio.	49
6.1. Gráficos SHAP de enjambre para cada combinación de variables	60
6.2. Gráficos SHAP de dependencia para las variables de control	62
6.3. Gráficos SHAP de dependencia para cada variable financiera	64

1. Introducción

El cambio climático, durante el presente siglo, se ha convertido en una de las grandes preocupaciones de la sociedad moderna, motivando tanto a académicos como a gestores de política pública a abordar esta problemática mediante la investigación de causas e identificación de secuelas. En este sentido, el alza de las temperaturas globales ha sido una de las consecuencias con mayor impacto en los ecosistemas, alarmando a autoridades ante la potencial irreversibilidad de este efecto.

Ante esta situación, una respuesta destacable es la Organización de las Naciones Unidas (ONU) al generar iniciativas como los 17 Objetivos de Desarrollo Sostenible (ODS) (2015), que fomentan la protección al medioambiente y un uso responsable de la energía. En esta misma línea, 196 países en conjunto con la Unión Europea adoptan el Acuerdo de París (ONU, 2015), en orden de limitar el aumento de las temperaturas del planeta a un máximo de 2°C por sobre los niveles preindustriales, incluso con esfuerzos dirigidos a restringir a un alza máxima de 1.5°C.

Dentro de los factores más relevantes en el agravamiento de las condiciones climáticas es el uso de energías fósiles, cuya característica más perjudicial es su alto nivel de emisiones de gases contaminantes. A partir de esta situación, se ha hecho énfasis en la necesidad de transicionar al uso de energías limpias, considerando sus costos, estabilidad, y escalabilidad, entre otros factores. Parte de estos esfuerzos se han orientado a la revisión del impacto del crecimiento de las energías renovables en los países, lo que ha consolidado el interés por develar sus dinámicas. Estudios como los de Nasir *et al.* (2021) y Quan *et al.* (2024) presentan evidencia a favor del uso de estas energías en la labor de la reducción de emisiones, sin afectar el crecimiento económico de los países.

En los últimos años, ha surgido una corriente académica que se encarga de cuantificar e

identificar la complejidad de los vínculos que surgen entre variables económicas, financieras y contextuales en aspectos como el uso de energía, el nivel de emisiones de CO₂ o la cuota de energías renovables en la composición de la matriz energética, por solo presentar ejemplos comunes de la literatura.

Dentro de los primeros artículos presentados que abordan estas temáticas se encuentran los de Sadorsky (2009) y Sadorsky (2010), que definen lineamientos preliminares para el estudio de esta rama de la literatura. La primera contribución muestra un acercamiento al vínculo del uso de energías renovables en el ingreso de un grupo de países, mientras que la segunda revisa el impacto del desarrollo financiero en el consumo general de energía, encontrando en ambos casos relaciones significativas que incrementarían el interés en estas relaciones.

Recientemente, la literatura se ha enfocado en revelar las dinámicas, formas funcionales y naturaleza de estas relaciones, de tal manera que aparecen estudios que proveen evidencia empírica para demostrar que ciertos vínculos tienen estructuras no lineales, sugiriendo habitualmente que se configuran con una forma de U o U invertida, lo que remite a estructuras típicas de las Curvas de Kuznets.

Dentro de la metodología usual empleada para obtener estas conclusiones se encuentran métodos econométricos, tales como paneles dinámicos o de series de tiempo, que si bien tienen la ventaja de tener un marco robusto en la identificación de significancia y determinación de la magnitud del impacto entre variables, cuentan con la desventaja de evaluar mediante formas funcionales predeterminadas, lo que puede limitar el entendimiento real de las dinámicas propias de cada fenómeno.

Como alternativa para mejorar la capacidad estimativa y predictiva de los modelos, han surgido metodologías de *Machine Learning* (Aprendizaje de Máquina, ML por sus siglas en inglés),



que mediante estructuras flexibles y complejas suelen alcanzar desempeños superiores. No obstante, estos modelos suelen presentar una limitada interpretabilidad, ya que la trazabilidad de sus interacciones internas no es evidente, lo que dificulta comprender cómo se generan sus predicciones. Para enfrentar este desafío, se han desarrollado técnicas como *SHapley Additive exPlanations* (SHAP), que, a partir de principios de teoría de juegos, permiten cuantificar la contribución de cada variable a la predicción de una observación específica. Esto no solo facilita una interpretación local de los resultados, sino que también permite inferencias agregadas sobre la importancia global de los predictores.

2. Problema de Investigación

Gran parte de la literatura referente a la rama de energía y economía se ha presentado con la intención de encontrar relaciones que vinculen indicadores y variables en contextos temporales y geográficos diversos. Típicamente, los modelos econométricos tradicionales se destacan por su potencial a la hora de identificar la significancia del impacto de ciertas variables independientes en una dependiente, así como por su capacidad de cuantificar la magnitud y dirección de esta relación que potencialmente le daría forma al estudio de relaciones específicas, lo que tiende a limitar su uso a modelos más sencillos, con formas funcionales predeterminadas. Por este motivo, se consideran enfoques de ML, que permiten capturar dinámicas más complejas, mejorar la capacidad explicativa de los modelos y, en consecuencia, afinar su desempeño predictivo.

En este contexto, se han realizado pocos estudios que utilicen enfoques alternativos para enfrentar problemáticas que analicen el vínculo entre el consumo energético y variables económicas o financieras. Un acercamiento destacable es el trabajo de Jabeur *et al.* (2021), que evalúa la importancia de ciertas variables en las emisiones de CO₂ mediante arquitecturas de ML en conjunto con valores SHAP con el objetivo de alcanzar niveles de interpretabilidad comparables a los obtenidos en estimaciones tradicionales sobre datos de panel.

Para efectos de la presente tesis, se espera abordar la relación entre el consumo de energías renovables como componente de la matriz energética y las distintas dimensiones del desarrollo financiero, junto con incorporar el impacto de variables de control tales como crecimiento, inflación, emisiones de CO₂, valor agregado de la industria y rentas de recursos naturales como porcentaje del PIB. Asimismo, se presenta un contexto amplio que revisa el periodo 2004-2021 para 83 países.

El trasfondo de la investigación espera responder las siguientes preguntas:

- ¿Cuál es el impacto del desarrollo financiero en fomentar una transición eficiente a energías renovables?
- ¿Qué tipo de relación mantienen ambas variables?
- ¿Puede establecerse una relación causal entre ambas variables?
- ¿Cuál es el impacto de otras variables contextuales en la transición y cómo estas se ven afectadas por el desarrollo financiero?
- ¿Qué metodologías permiten tener una visión más amplia de las dinámicas subyacentes del fenómeno estudiado?

Para responder estas interrogantes, se emplearán diversas metodologías y estrategias que, en combinación y comparación, buscan esclarecer la naturaleza de estas relaciones, así como aportar evidencia empírica útil para la toma de decisiones informadas en el diseño de políticas públicas, tanto a nivel global como local.

3. Objetivos

Tras la exposición del problema de investigación, se propone el siguiente objetivo general y una serie de objetivos específicos que guían la estructura del análisis y los resultados esperados.

3.1. Objetivo General

Analizar exhaustivamente el vínculo entre el desarrollo financiero y consumo de energías renovables, abordando el estado del arte y contraponiéndolo con metodologías contemporáneas en un contexto geográfico y temporal amplio, con la finalidad de comprender íntegramente el rol de los sistemas financieros en la transición a energías limpias.

3.2. Objetivos Específicos

Identificar los determinantes del desarrollo financiero que tienen mayor influencia en la transición a energías renovables, diferenciando explícitamente el impacto relativo de las instituciones y los mercados dentro del sistema financiero.

Comparar el desempeño explicativo entre modelos de datos de panel dinámicos tradicionales y algoritmos de ML en un contexto empírico representativo de los desafíos del desarrollo sostenible.

Determinar la naturaleza funcional del vínculo entre el desarrollo financiero y el consumo de energías renovables, mediante el análisis de valores SHAP y su contraste con los coeficientes y niveles de significancia estadística obtenidos en modelos de datos de panel.

Evaluar el efecto de variables macroeconómicas de control sobre la relación entre el desarrollo financiero y el consumo de energías renovables.

Explorar la existencia y dirección de la Granger-causalidad entre el consumo de energías renovables y los determinantes del desarrollo financiero.



Analizar las implicancias de política pública derivadas de los resultados de esta investigación, con el fin de enriquecer el debate sobre el rol de la estabilidad macroeconómica y financiera en transiciones energéticas sostenibles.

4. Marco Teórico

Para abordar en mayor profundidad el problema planteado, esta sección presenta una revisión de la literatura enfocada en las relaciones económicas y financieras más estudiadas en este campo, así como en los métodos utilizados para analizarlas. Adicionalmente, se presenta un recorrido por trabajos que han acercado el análisis al uso de herramientas de ML, destacando las complicaciones que tiene su interpretación y exponiendo las alternativas utilizadas para abordar estas limitaciones intrínsecas de estos algoritmos. Finalmente, se delimita el marco que define el resto del estudio, en lo que refiere al concepto del desarrollo financiero, contrastando con definiciones de otros autores y resaltando la amplitud que brinda un análisis con distintas dimensiones y comportamientos de instituciones y mercados.

4.1. Relaciones Macroeconómicas en el Contexto del Nexo Energía-Finanzas

En el análisis de las relaciones macroeconómicas relevantes en este campo, se han identificado diversas interacciones entre variables económicas y energéticas. Entre las más típicas está el vínculo entre crecimiento y consumo energético, sin perjuicio de que se han considerado variables como inversión extranjera directa (IED), entre otras. Este enfoque ha llevado a examinar el efecto del desarrollo financiero en el uso de energía, dado que el vínculo entre este y el crecimiento han sido ampliamente aceptado en la literatura. Varios estudios relevantes han contribuido a la comprensión de las relaciones no lineales, coincidiendo en que el desarrollo económico y financiero tiende a generar efectos de eficiencia en las industrias, lo que influye positivamente en los patrones de consumo energético de los países.

Un ejemplo que engloba el recorrido de estas ramas de la literatura es el trabajo de Alam *et al.* (2024), quienes exploran las determinantes del consumo energético en lo que respecta a re-

novables y no-renovables de manera conjunta e independiente, incluyendo variables tales como la balanza comercial, niveles de urbanización, indicadores financieros junto con factores ambientales, mostrando la complejidad de los estudios recientes, los cuales se han alimentado de los aportes de autores precedentes. Las siguientes subsecciones presentan una revisión detallada de los principales aportes que configuran el marco teórico de esta investigación.

4.1.1. Crecimiento Económico y Consumo de Energía

La relación entre consumo energético y crecimiento económico ha sido considerado ampliamente investigada durante las últimas dos décadas. Académicos han desarrollado diversos modelos enfocados en este análisis, incorporando distintos contextos, variables y metodologías. Uno de los focos principales se ha centrado en el entendimiento de la interacción entre el crecimiento y el consumo de energías renovables, apuntando a un desarrollo sostenible.

Sadorsky (2009) propuso un modelo analizando el comportamiento del consumo de energía renovable en función del crecimiento de 18 economías emergentes, mediante el uso de un estimador *Fully Modified Ordinary Least Squares* (Mínimos Cuadrados Ordinarios Completamente Modificados y FMOLS, en su sigla en inglés) para develar elasticidades de corto y largo plazo. Doytch y Narayan (2016) por su parte, incluyen en la parte central de su estudio el rol que tiene la IED en el consumo de energía renovable en un panel de 74 países, mediante el uso de un estimador *System-Generalized Method of Moments* (Método Generalizado de Momentos del Sistema, o habitualmente abreviado System-GMM), en un enfoque que divide tres subconjuntos distintos basados en niveles de ingresos, encontrando una relación entre las variables propuestas en todos los grupos propuestos.

En una propuesta más reciente, Rafique *et al.* (2021) introducen el concepto de la complejidad económica, explorando el efecto de los cambios estructurales dentro de las economías en

los comportamientos de consumo de energías renovables. Este estudio utilizó una combinación de distintas técnicas econométricas, entre las que se incluyen System-GMM, estimación de efectos fijos y FMOLS, para un panel que incluye países del G7 y E7. Sus resultados sugieren que las economías más complejas tienen una tendencia a consumir mayor cantidad de energías renovables, vinculando los cambios estructurales con consumo de energías limpias.

Asimismo, se han presentado estudios que se centran en otros aspectos consecuentes del desarrollo económico, tales como la solidez de las instituciones. En este sentido, Chen *et al.* (2021) aportan una perspectiva referente al rol de las instituciones democráticas en el consumo de energías renovables para un panel de 97 países, destacando la importancia que tienen estas en el establecimiento de políticas que favorecen la diversificación energética.

En una línea de estudio paralela, se ha propuesto la investigación de modelos que enfatizan en el impacto ambiental, tales como el modelo Stochastic Impacts by Regression on Population, Affluence, and Technology (Regresión por Impactos Estocásticos de Población, Afluencia y Tecnología, STIRPAT en su sigla en inglés) han sido ampliamente utilizados para verificar la relación tripartita entre desarrollo económico, degradación ambiental y consumo energético. Trabajos como el propuesto por Omri y Nguyen (2014) destacan el impacto de emisiones de CO₂ y exportaciones netas en el consumo de energías limpias, en un panel de 64 países, evaluando mediante un estimador System-GMM.

Extensiones de este campo suele revisar relaciones no lineales, particularmente ligadas a Environmental Kuznets Curves (Curvas Ambientales de Kuznets, o EKC en su sigla común), las cuales proponen que existe una relación con forma de U invertida entre el crecimiento económico y degradación ambiental, incluyendo el consumo energético y emisiones de CO₂, según lo estudiado por Nasir *et al.* (2021) y Quan *et al.* (2024).

Estas últimas curvas tienen particular relevancia en la revisión de la literatura, dado que relaciones que previamente se presentaban como negativas o simplemente no significativas, ahora tienen una profundización mayor, al evidenciar que un crecimiento económico responsable, consistente y eficiente promueve una disminución en las emisiones de contaminantes.

4.1.2. Crecimiento Económico y Desarrollo Financiero

El vínculo entre crecimiento económico y desarrollo financiero se ha consolidado como uno de los objetos de estudios con mayor profundización en la teoría económica. Trabajos tempranos tales como los de Schumpeter (1911) son muestra evidente del interés histórico de los investigadores en comprender la complejidad de la relación entre estos indicadores. Decadas más tarde destaca el aporte de King y Levine (1993), quienes proveen una demostración empírica del efecto positivo que incita el desarrollo financiero en el crecimiento económico, entregando evidencia de que los sistemas financieros sólidos facilitan la inversión y la productividad, derivando en una mejora del desempeño macroeconómico.

Calderón y Liu (2002) extienden el estudio de esta relación mediante la identificación de una relación causal bidireccional. Los autores destacan una interacción cíclica en la que el desarrollo financiero contribuye al crecimiento, mientras que este último admite una mayor profundización de los mercados financieros, fortaleciéndolos en una relación simbiótica.

En estudios más recientes, tales como los de Abdul Bahri *et al.* (2019) y Botev *et al.* (2019), se enfatiza en el estudio de no linealidad de esta relación, revisando si el vínculo se caracteriza por una forma funcional con forma de U o con U-invertida, concluyendo que el impacto del desarrollo financiero en el crecimiento del PIB depende principalmente del nivel de desarrollo de los países. Junto con lo anterior, se evidencia que el comportamiento de los sistemas financieros, en su dimensionalidad de instituciones y mercados, también influye de manera diferente a la forma relacional

entre crecimiento y desarrollo financiero.

Si bien, usualmente este nexo se suele obviar en la literatura, es de alta relevancia considerar su rol en la conformación de no linealidades entre variables que muestran una caracterización del consumo energético y las que evalúan el desarrollo financiero. Aspectos claves como la bidireccionalidad entre crecimiento y estabilidad de los sistemas financieros o estudios en paneles no lineales, admiten la evaluación en tres partes entre variables macrofinancieras y el consumo de energías renovables. Ante esto, ha emergido una rama de la literatura especialmente enfocada a la comprensión de la influencia del estado de los sistemas financieros en el consumo de energía y en particular, de aquellas renovables, con la intención de definir el rol que tienen en un desarrollo sostenible.

4.1.3. Desarrollo Financiero y Consumo de Energía

La relación entre el desarrollo financiero y el consumo de energía, en particular de las renovables, se ha convertido en un área incrementalmente relevante de investigación. Distintos autores han puesto énfasis en el rol de las instituciones y mercados financieros en el consumo energético, proporcionando información de alto valor para gestores de política y la industria, apuntando a una transición sustentable y responsable en lo que respecta a los sistemas energéticos. A continuación se presentan los trabajos más relevantes que aportan a la estructura de este nexo.

Alsagr y van Hemmen (2021) examinan el impacto de variables financieras y riesgos geopolíticos, mediante el uso de un estimador System-GMM de dos pasos en mercados emergentes. Entre los hallazgos de este trabajo se encuentra una relación positiva entre el desarrollo financiero y el consumo energético total, destacando la capacidad de los sistemas financieros en facilitar el acceso a la energía. De manera similar, Anton y Afloarei Nucu (2020) se enfocó específicamente en el rol de los mercados de bonos y capital en el consumo de energías renovables en países

Europeos, encontrando que los mercados de capitales no tienen una influencia directa en el consumo de renovables, sugiriendo que el comportamiento de sectores financieros distintos impactan de manera diferente en la transición a energías limpias.

Por su parte, Çoban y Topcu (2013) emplean un estimador System-GMM de dos pasos en conjunto con un Análisis de Componentes Principales (ACP) para estudiar el impacto del desarrollo financiero en el consumo de energía general, explorando las formas funcionales lineales y cuadráticas de las variables financieras, identificando tres efectos, el efecto directo, definido como la simplificación y reducción en los precios de los préstamos, el efecto de la industria, que hace alusión a la mayor capacidad de las empresas para obtener financiamiento y el efecto riqueza, que se refleja en la confianza de la sociedad en los sistemas financieros, contribuyendo todas a explicar las dinámicas del consumo energético.

En lo que respecta al planteamiento de posibles no linealidades, se considera el trabajo de Mimouni y Temimi (2018), quienes enfatizan en el rol de la IED en promover la eficiencia energética, con efectos con forma funcional cuadrática invertida, en el contexto de la crisis financiera del 2008. En adelante, estudios como los de Baloch *et al.* (2019) y Yue *et al.* (2019) directamente proponen relaciones no lineales entre desarrollo financiero y el consumo de energía, contemplando la posibilidad de que el nexo entre ambas variables contienen dinámicas complejas de modelar en enfoques tradicionales.

Doytch *et al.* (2023) expandieron esta línea de estudio al comparar la Financial Kuznets Curve (Curva Financiera de Kuznets, FKC en inglés) con la Income Kuznets Curve (Curva del Ingreso de Kuznets, IKC por su sigla en inglés) utilizando tanto una regresión de cuantiles y con System-GMM para un panel de 85 países. Los resultados extraídos de esta investigación destacan el cumplimiento de la FKC, en particular para los mercados de acciones, que tienen un rol potenciador

en la inversión en infraestructura energética.

En implementaciones metodológicas alternativas, se destaca la investigación de Chang *et al.* (2022), quienes mediante un modelo *Nonlinear Autoregressive Distributed Lag* (Autorregresivo No Lineal de Rezago Distribuido, o NARDL por su sigla en inglés) presentan evidencia para un nexo positivo entre desarrollo financiero y consumo de energía en 30 provincias chinas. Por otro lado, Demirtas *et al.* (2025) mediante el uso de transformadas de Wavelets y pruebas de causalidad basadas en cuantiles de Fourier llegan a conclusiones similares en el contexto del Reino Unido, haciendo énfasis en el desarrollo tanto de instituciones como mercados financieros.

Otros estudios, tales como el de Khan *et al.* (2021), se centran en el impacto de variables contextuales en interacción con la relación propuesta de energía con finanzas. El trabajo mencionado examina el rol de la innovación tecnológica, encontrando una relación causal bidireccional entre energía renovable, desarrollo financiero, innovación tecnológica e IED, donde estas dos en conjunto pueden estimular una transición sustentable a energías limpias.

Alternativamente, Durusu-Ciftci *et al.* (2020) proponen una metodología que integra pruebas de causalidad con estimaciones basadas en métodos de Fourier en orden de capturar cambios estructurales graduales que afectan la relación entre consumo de energía, desarrollo financiero y crecimiento económico. Este estudio enfatiza la naturaleza evolutiva de estas relaciones causales, donde se destaca la importancia de un modelamiento dinámico, que sea capaz de capturar aspectos complejos del vínculo energía-finanzas.

Kim y Park (2016) estudian el impacto del desarrollo financiero en la implementación de tecnologías e infraestructura para energías renovables, utilizando un modelo de regresión Tobit y un enfoque Heckman de dos pasos. Entre los hallazgos más relevantes, se destaca que el financiamiento tanto en deuda y patrimonio son cruciales en el apoyo de sectores industriales energéticos,

reforzando el rol del desarrollo financiero en la transición energética.

La literatura en este campo se ha expandido mediante incluir indicadores económicos y financieros que salen del marco tradicional, incorporando variables contextuales, usualmente asociadas a condiciones aparentemente no relacionadas al consumo de energías renovables o a dinámicas macroeconómicas. Usman *et al.* (2022) estudian los efectos de la globalización y de las rentas de recursos naturales, interactuando con el consumo de energías limpias y desarrollo financiero, para explicar variaciones en la huella de carbono. De manera similar, Tao *et al.* (2023) examinan el rol de la tecnología en información y comunicación, junto al desarrollo financiero, en emisiones, proporcionando evidencia de un nexo no lineal entre desarrollo financiero y degradación medioambiental. Más aun, Nawaz y Rahman (2023) incorporan como variables el capital humano y calidad de las instituciones para analizar el efecto que tienen en combinación al desarrollo financiero, sobre el consumo de renovables. Finalmente, Yi *et al.* (2023) exploran como la incertidumbre en política pública juega un rol adverso al consumo de energías renovables. Estos hallazgos destacan el rol evolutivo y central del desarrollo financiero en dinámicas socioeconómicas complejas que afectan al consumo de energías renovables y a la emisión de contaminantes.

En general, la literatura existente destaca la relación multifacética entre consumo de energía y desarrollo financiero. Mientras varios estudios validan este nexo, ciertamente, la mayor diferencia entre estos radica en la metodología empleada para llegar a ciertas conclusiones, en contextos distintos, con modelos y variables que también suelen diferir entre ellos. Asimismo, se ha enfatizado en la potencial relación no lineal que subyace de este fenómeno, así como se destaca que el impacto también es diverso en función de los niveles de ingreso y tipos de mercados existentes. Los estudios presentados tienen un rol fundamental en la comprensión del estado del arte y delimitan el marco conceptual sobre el cual se lleva a cabo la investigación de este vínculo, cuyo impacto es

sumamente relevante para decisiones de autoridades y empresas.

4.2. Implementaciones Relacionadas de Algoritmos de Machine Learning

En general, tal como se presenta en la revisión hecha por Ghoddusi *et al.* (2019), gran parte de los esfuerzos enfocados en la integración de técnicas de ML en estudios energéticos-económicos se ha centrado en tareas predictivas, tales como el pronóstico de precios, demanda, riesgo o condiciones de ciertos mercados localizados. Esta aplicación se alinea con los usos tradicionales de ML en contextos financieros. Una de las principales limitaciones de este acercamiento es la falta de interpretabilidad de sus salidas, lo que merma el entendimiento de las relaciones entre el comportamiento de la industria energética y las dinámicas macroeconómicas. Esto ha motivado avances en la búsqueda de métodos capaces de revelar tanto la importancia como formas funcionales subyacentes a nexos entre variables explicativas y dependientes, abriendo nuevas oportunidades a nivel comparativo entre algoritmos de ML y técnicas tradicionales en econometría.

En esta tendencia emergente, es destacable el trabajo de Silva *et al.* (2024), donde se implementan técnicas de ML para analizar la evolución del estado del arte en lo que respecta a los mercados energéticos. Utilizando un enfoque de *Random Forest* (Bosques Aleatorios, por su traducción directa desde el inglés) en combinación con el uso de valores SHAP, los autores identifican las determinantes más influyentes de la literatura, ofreciendo información interpretable que anticipa la evolución de este campo. En un contexto aplicado, por su parte, Esenyel İçen (2025) busca las variables más relevantes en el consumo de energías renovables en Turquía, enfatizando en el rol de aquellas determinantes asociadas al desarrollo social y educación como aquellas que promueven y respaldan una transición a fuentes más limpias de energía.

Uno de los artículos más relevantes en el contexto de la presente investigación es el de Ja-beur *et al.* (2021), quienes buscan las principales determinantes de emisiones de CO₂ mediante el

uso de variables macroeconómicas e institucionales. Los autores presentan un marco metodológico en el que se compara el desempeño entre cinco algoritmos de ML con uno de Mínimos Cuadrados Ordinarios para identificar el mejor modelo, el cual es seleccionado para su posterior interpretación mediante valores SHAP. En este sentido, el modelo seleccionado es uno de *Natural Gradient Boosting (NGBoost)*, que destaca por su versatilidad al capturar dinámicas inusuales entre variables. Tras graficar valores SHAP, se destaca que todas las formas funcionales identificadas son no lineales.

En contraste, los estudios de Ouni *et al.* (2025) y Zhang *et al.* (2025) también adoptan técnicas de ML, pero su foco se encuentra asociado a tareas de clasificación, proporcionando información relacionada a la calidad ambiental y el impacto de varios factores dentro de países específicos.

En general, mientras la aplicación de ML en el estudio del nexo energía-finanzas permanece acotado a implementaciones clásicas, es remarcable el rol que han tomado ciertos trabajos en la capacidad de revelar patrones complejos más allá del alcance de métodos econométricos tradicionales. En este contexto, el presente estudio contribuye a la literatura en la aplicación de una combinación de métodos de ML y herramientas de interpretabilidad para identificar y analizar dinámicas entre las variables de interés.

4.3. Medidas de Desarrollo Financiero

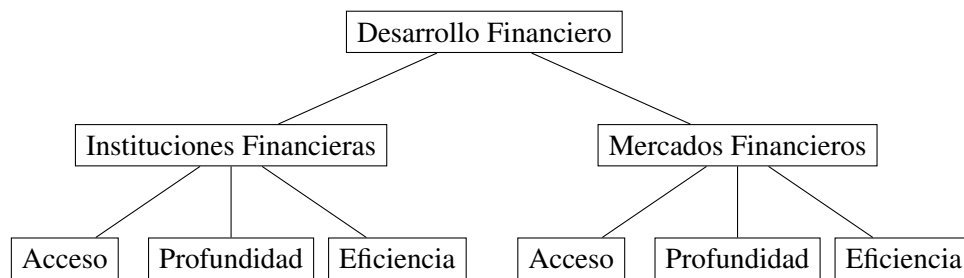
Una de las decisiones más relevantes en la literatura, en lo que respecta al análisis de causalidad y el impacto del desarrollo financiero en el consumo de energías renovables es la selección de variables, considerando la variedad de indicadores y la importancia de ciertos sub-sectores en la actividad financiera en las economías. La Tabla 4.1 muestra un desglose de las variables más comunes en el estudio de este fenómeno.

Tabla 4.1: Medidas de Desarrollo Financiero

Categoría	Variable	Referencias
Crédito y Financiamiento Privado	Crédito de los hogares en relación con todo el sector financiero	Durusu-Ciftci <i>et al.</i> (2020), Farhani y Solarin (2017), Shahbaz <i>et al.</i> (2022), Yi <i>et al.</i> (2023)
	Crédito de los hogares otorgado por la banca en relación con todo el sector financiero	Alsagr y van Hemmen (2021), Shahbaz <i>et al.</i> (2021)
	Crédito de los hogares otorgado por todo el sector financiero	Anton y Afloarei Nucu (2020), Baloch <i>et al.</i> (2019), Ji y Zhang (2019), Shahbaz <i>et al.</i> (2021)
	Crédito privado por parte de los bancos comerciales	Alsagr y van Hemmen (2021)
	Creditos bancarios en relación con depósitos bancarios	Alsagr y van Hemmen (2021)
Mercados de valores	Rotación del mercado de valores	Alsagr y van Hemmen (2021), Anton y Afloarei Nucu (2020), Doytch <i>et al.</i> (2023), Sadorsky (2010), Yue <i>et al.</i> (2019)
	Capitalización de mercado	Ji y Zhang (2019)
	Acciones negociadas como % del PIB	Mukhtarov <i>et al.</i> (2022)
	Capitalización del mercado de valores	Doytch <i>et al.</i> (2023), Sadorsky (2010), Yue <i>et al.</i> (2019)
	Valor total negociado en el mercado accionario como % del PIB	Doytch <i>et al.</i> (2023), Sadorsky (2010)
Desarrollo de los mercados financieros	Apertura de los mercados financieros	Yue <i>et al.</i> (2019)
	Desarrollo del mercado de deuda y crédito	Kim y Park (2016)
Otros factores financieros	Pasivos, Dinero	Doytch <i>et al.</i> (2023)
	Desempeño de las firmas	He <i>et al.</i> (2019)
	Valores de deuda privada internacional sobresalientes en relación con el PIB	Anton y Afloarei Nucu (2020)
Variables extraídas de ACP	Índice del mercado de valores y del mercado bancario	Çoban y Topcu (2013)
	Índice del mercado de valores, mercado bancario y mercado de bonos	Topcu y Payne (2017)
	Índices del Fondo Monetario Internacional (FMI)	Demirtas <i>et al.</i> (2025), Liu <i>et al.</i> (2023), Pata <i>et al.</i> (2022), Usman <i>et al.</i> (2022)

En este estudio, las variables financieras a utilizar son los índices desarrollados por el FMI en su investigación propia: *Introducing a New Broad-based Index of Financial Development* de Svirydzenka (2016), quien presenta una conceptualización jerárquica. En el nivel superior, se ubica un índice compacto de desarrollo financiero, que luego es subdividido en dos dimensiones: Instituciones Financieras y Mercados Financieros. Finalmente, ambas variables presentan 3 subdimensiones cada una: Profundidad, Acceso y Eficiencia. Lo anterior está ilustrado en la Figura 4.3.

Estructura del desarrollo financiero según Svirydzenka (2016)



Estos índices están contruidos mediante un ACP, evaluando la relevancia e influencia de 20 variables relacionadas que permiten definir los 8 índices. Esta estructura se presenta en la Tabla 4.2.

Tabla 4.2: Variables pertenecientes al análisis propuesto por Svirydenka (2016)

Categoría	Indicador
Instituciones Financieras	
Profundidad	Crédito del sector privado en relación al PIB Activos de fondos de pensiones en relación al PIB Activos de fondos mutuos en relación al PIB Primas de seguros, vida y no vida en relación al PIB
Acceso	Sucursales bancarias por 100.000 adultos Cajeros automáticos por 100.000 adultos
Eficiencia	Margen de interés neto Diferencial entre préstamos y depósitos Los ingresos no vinculados a intereses en relación con los ingresos totales Gastos generales en relación a activos totales Retornos sobre activos Retornos sobre patrimonio
Mercados Financieros	
Profundidad	Capitalización de mercados de valores en función del PIB Acciones negociadas en relación al PIB Deuda internacional del gobierno en relación con el PIB Deuda de las corporaciones financieras en relación al PIB Deuda total de valores de empresas no financieras con respecto al PIB
Acceso	Porcentaje de capitalización de mercado fuera de las 10 compañías más grandes Número total de emisores de deuda
Eficiencia	Rotación del mercado de valores

El presente marco conceptual permite establecer una evaluación de las características del sistema financiero en gran parte de sus dimensiones, capturando aspectos de accesibilidad u operativos, lo que facilita el estudio del impacto del desarrollo financiero en el consumo de energías renovables.

5. Metodología

Uno de los aspectos más extendidos dentro de la presente investigación es el enfoque metodológico, donde se propone un enfoque metodológico clásico para analizar el vínculo planteado y se contraponen con métodos empíricos alternativos de ML. Las ventajas presuntas de estos métodos se remiten a su desempeño predictivo y explicativo, mientras que dentro de sus desventajas se suele mencionar su debilidad interpretativa. Para contrarrestar esa característica, se proponen métodos auxiliares como los valores SHAP, que permiten revelar las dinámicas usualmente catalogadas como 'caja negra'. Finalmente, de manera complementaria, se inspecciona la naturaleza causal del fenómeno, mediante pruebas respaldadas en la literatura.

5.1. Datos y Variables

Este estudio examina 83 países¹ mediante el uso de datos anuales entre el 2004 y el 2021. La Tabla 5.1 resume las variables utilizadas en este trabajo, incluyendo sus descripciones, unidades de medida y fuentes.

¹La lista de países y su desglose, según nivel de desarrollo, se encuentra disponible en el Apéndice A.

Tabla 5.1: Lista de Variables y Características

Variable	Descripción	Unidad	Fuente
Renewable	Consumo de energía renovable	% del consumo final total de energía	Banco Mundial
GDP	Producto Interno Bruto (constante 2015 US\$)	Millones de US\$	Banco Mundial
CPI	Índice de Precios al Consumidor (2010 = 100)	Índice	FMI
Industry	Valor agregado de la industria (incluye construcción)	Millones de US\$ corrientes	Banco Mundial
NatResRent	Rentas totales de recursos naturales	% del PIB	Banco Mundial
CO2	Emisiones de CO ₂ excluyendo LULUCF per cápita	tCO ₂ e/cápita	Banco Mundial
FinDevIndex	Índice de Desarrollo Financiero	Índice	FMI
FinInsAccessIndex	Índice de Acceso a Instituciones Financieras	Índice	FMI
FinInsDepthIndex	Índice de Profundidad de Instituciones Financieras	Índice	FMI
FinInsEffIndex	Índice de Eficiencia de Instituciones Financieras	Índice	FMI
FinInsIndex	Índice de Instituciones Financieras	Índice	FMI
FinMarkAccessIndex	Índice de Acceso a Mercados Financieros	Índice	FMI
FinMarkDepthIndex	Índice de Profundidad de Mercados Financieros	Índice	FMI
FinMarkEffIndex	Índice de Eficiencia de Mercados Financieros	Índice	FMI
FinMarkIndex	Índice de Mercados Financieros	Índice	FMI

Nota: Los nombres de las variables se conservan en inglés para mantener coherencia con el resto de la investigación y las fuentes originales.

Se considera como variable dependiente u objetivo el consumo energía renovable como parte del total del consumo de energía final, según lo utilizado por Anton y Afloarei Nucu (2020), Shahbaz *et al.* (2022) y Alsagr y van Hemmen (2021). Además, en línea con las consideraciones habituales en el campo, se propone el uso de las variables vinculadas el PIB, IPC y emisiones de CO₂ como variables de control. En adición, se incluyen las rentas de recursos naturales, según el

aporte de Doytch *et al.* (2023). Junto con lo anterior, se incorpora el valor agregado de la industrial, en línea con la metodología de Mimouni y Temimi (2018). Finalmente, para englobar las determinantes del sistema financiero, se utilizan los índices propuestos por Svirydenka (2016), dada su alta capacidad de condensar una gran cantidad de variables en categorías evidentes y de simple seguimiento, facilitando el análisis de política pública.

En lo que respecta al tratamiento de los datos, en primera instancia, se aplica una transformación en primera diferencia de la forma logarítmica, cuya notación es $\Delta \ln(\cdot)$, como una aproximación de las tasas de crecimiento. Esta transformación es implementada para mitigar potenciales problemas de no estacionariedad en las series de tiempo. Aún más, se normalizan todas las variables explicativas mediante el uso de *MinMaxScaler* (Escalamiento Mínimo Máximo, desde su traducción al inglés), cuya función es reescalar las series de tiempo para que permanezcan en un intervalo predefinido. Para efectos de esta investigación, el intervalo es $[0, 1]$. Este procedimiento permite asegurar la convergencia de los métodos de ML. Se presentan las estadísticas descriptivas en la Tabla 5.2.

Tabla 5.2: Estadísticas Descriptivas de las variables escaladas y normalizadas


Variable	Obs.	Media	Desv. Est.	Mín.	Máx.
$\Delta \ln(\text{Renewable})$	1577	0.0169	0.1232	-1.1436	1.3863
$\Delta \ln(\text{NatResRent})$	1472	0.5366	0.0555	0.0000	1.0000
$\Delta \ln(\text{CO}_2)$	1577	0.5272	0.0755	0.0000	1.0000
$\Delta \ln(\text{GDP})$	1577	0.6188	0.0847	0.0000	1.0000
$\Delta \ln(\text{CPI})$	1545	0.0905	0.0537	0.0000	1.0000
$\Delta \ln(\text{Ind})$	1488	0.6731	0.0797	0.0000	1.0000
$\Delta \ln(\text{FinDevIndex})$	1577	0.4322	0.0714	0.0000	1.0000
$\Delta \ln(\text{FinInsIndex})$	1577	0.4817	0.0581	0.0000	1.0000
$\Delta \ln(\text{FinMarkIndex})$	1577	0.5192	0.0625	0.0000	1.0000
$\Delta \ln(\text{FinInsAccessIndex})$	1577	0.2585	0.0588	0.0000	1.0000
$\Delta \ln(\text{FinInsDepthIndex})$	1577	0.4694	0.0742	0.0000	1.0000
$\Delta \ln(\text{FinInsEffIndex})$	1577	0.5519	0.0561	0.0000	1.0000
$\Delta \ln(\text{FinMarkDepthIndex})$	1577	0.4483	0.0590	0.0000	1.0000
$\Delta \ln(\text{FinMarkAccessIndex})$	1520	0.5619	0.0600	0.0000	1.0000
$\Delta \ln(\text{FinMarkEffIndex})$	1292	0.5935	0.0564	0.0000	1.0000

Finalmente, con el objetivo de brindar una caracterización completa a los datos utilizados, se presenta en la Figura 5.1, la matriz de correlación entre las variables utilizadas:

5.2. Estimador System-GMM

Para investigar la naturaleza de la relación entre consumo de energía renovable y el desarrollo financiero, se considera la implementación de un estructura de datos de panel dinámicos basados en el enfoque System-GMM, presentado por Blundell y Bond (1998). Esta técnica es capaz de contrarrestar potenciales conflictos de endogeneidad e instrumentos débiles, mediante el uso de rezagos en nivel y diferencias como instrumentos. Dada la posible presencia de heterocedasticidad en la estimación, se utiliza el estimador System-GMM de dos pasos, con el fin de mejorar la eficiencia y asegurar resultados consistentes. La estructura de panel dinámico se suele preferir por sobre un panel estático en estas aplicaciones, dada la necesidad de capturar fenómenos de persistencia y reducir los riesgos de variables omitidas.

Figura 5.1: Matriz de Correlación



Parte de la metodología tradicional en la implementación de este enfoque de panel, se presenta una batería de pruebas para asegurar la confiabilidad del esquema propuesto. Esto incluye pruebas de raíz unitaria, tales como los de Im-Pesaran-Shin (IPS) Im *et al.* (2003) y de Phillips-Perron Phillips y Perron (1986) para verificar la estacionariedad de las series. Por otro lado, se utilizan los tests de Arellano y Bond (1991) para detectar autocorrelación serial de primer y segundo orden en los residuos, mientras que se aplica la prueba Hansen J Hansen (1982) para asegurar la validez del conjunto de instrumentos. Finalmente, se aplica una prueba de Hansen en diferencias para evaluar la exogeneidad de los subconjuntos de instrumentos. Las contraposición de hipótesis

se presenta en la Tabla 5.3

Tabla 5.3: Hipótesis Nula y Alternativa para las pruebas de especificación

Prueba	H_0	H_1
<i>Pruebas de Raíz Unitaria</i>		
Im–Pesaran–Shin	Todos los paneles contienen raíces unitarias	Algunos paneles son estacionarios
Phillips–Perron	Todos los paneles contienen raíces unitarias	Al menos un panel es estacionario
<i>Pruebas de Especificación de Panel GMM</i>		
AR(1)	Autocorrelación de primer orden está presente	Autocorrelación de primer orden está ausente
AR(2)	Autocorrelación de segundo orden está ausente	Autocorrelación de segundo orden está presente
Hansen J	Los instrumentos están no correlacionados con residuos	Sobreidentificación de instrumentos
Difference-in-Hansen	Subconjuntos de instrumentos válidos	Subconjuntos de instrumentos inválidos

5.3. Algoritmos de Machine Learning

Como una alternativa a las técnicas econométricas tradicionales, se presenta un conjunto de algoritmos de ML para modelar la relación entre el consumo de energía renovable y desarrollo financiero. Estos modelos proporcionan un marco flexible que complementa enfoques paramétricos tales como System-GMM, mediante ofrecer ventajas en la captura de no linealidades e interacciones complejas entre variables. En las siguientes subsecciones se presentan los algoritmos utilizados en esta investigación.

5.3.1. Convolutional Neural Networks

Siguiendo la definición propuesta en Borovykh *et al.* (2018), una red neuronal multicapa para pronóstico en series de tiempo consiste en una composición de capas y nodos ocultos diseñada en orden de capturar dinámicas lineales y no lineales en los datos. En la primera capa, los datos

pasan por combinaciones lineales en función del número de nodos ocultos. Estas combinaciones luego son pasadas a través de una función de activación diferenciable no lineal. En cada capa contigua el proceso es conceptualmente repetida, permitiendo a la red acercarse progresivamente a relaciones complejas. El producto esperado en el tiempo $t + 1$ está dado por:

$$\hat{x}(t + 1) = h \left(\sum_{j=0}^{M_{L-1}} w^L(j) f^{L-1}(j) + b^L \right) \quad (5.1)$$

donde $x(1), \dots, x(t)$ denota la secuencia de entrada, $\hat{x}(t + 1)$ es el valor predicho, $w^L(j)$ son los pesos de la capa final L , $f^{L-1}(j)$ es la transformación no lineal de la capa anterior, mientras que b^L es un término de sesgo.

Una convolución es una operación lineal que calcula una suma ponderada a través de un filtro, usualmente llamado *kernel* y un segmento local de entrada. Esta operación es llevada a cabo a través de la secuencia de entrada, permitiendo a la red la detección de patrones locales y características que pueden ser útiles para predicción. Una convolución unidimensional discreta se define según:

$$(f * g)(i) = \sum_{j=0}^{k-1} f(j) \cdot g(i - j) \quad (5.2)$$

donde $f(j)$ es la secuencia de entrada, $g(\cdot)$ es el filtro de tamaño k y $(f * g)(i)$ es la salida *convolucionada* en cierta posición i .

Una *Convolutional Neural Network* (Red Neuronal Convolucional, CNN de su sigla en inglés) es una arquitectura especializada de redes neuronales que se destaca por la aplicación de filtros dentro del espacio de entrada en lugar de capas completamente conectadas. En vez de asignar un conjunto de pesos distintos a cada conexión de entrada y salida, un pequeño conjunto de

convoluciones es aplicado en toda la secuencia de entrada. En este estudio, el enfoque CNN considera una capa convolucional unidimensional (*Conv1D*) mediante una función de activación ReLU. Le sigue una capa de agrupación de máximo global, que reduce cada mapa de características a su activación más destacada. Esta salida se transmite a una capa densa oculta con 64 neuronas, y posteriormente a una capa lineal final, que genera la predicción. El modelo se entrena utilizando el optimizador Adam.

5.3.2. *Support Vector Regression*

Propuesto por Drucker *et al.* (1996), *Support Vector Regression* (Regresión de Vectores de Apoyo, SVR en su sigla en inglés) es un algoritmo que extiende la base de las *Support Vector Machines* en tareas asociadas a regresiones. En este contexto, SVR pretende encontrar funciones que aproximen los valores objetivos dentro de ciertos niveles de tolerancia ϵ , mientras es capaz de prevenir de un exceso de complejidad en el modelo. SVR resuelve el siguiente problema de optimización:

$$\begin{aligned} \min_{w,b,\xi,\xi^*} \quad & \frac{1}{2}(w^T w) + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{sujeto a} \quad & y_i - (w^T v_i) - b \leq \epsilon + \xi_i, \\ & (w^T v_i) + b - y_i \leq \epsilon + \xi_i^*, \\ & \xi_i, \xi_i^* \geq 0 \quad \text{para } i = 1, \dots, n. \end{aligned} \tag{5.3}$$

donde w es el vector de pesos, C es un término de regularización, ξ_i y ξ_i^* son variables de holgura, v_i representa el vector de entrada e y_i es el valor objetivo. Para efectos de esta investigación, la implementación persigue el enfoque previamente descrito.

5.3.3. *Random Forest*

Un RF, como se presenta en Breiman (2001), está definido como un conjunto predictor compuesto de una colección de K árboles de decisión $\{h(\mathbf{x}, \Theta_k)\}_{k=1}^K$, donde cada Θ_k es un vector muestreado aleatoriamente y \mathbf{x} es un vector de entrada.

En problemas de regresión, RFs generan salidas numéricas en lugar de etiquetas de clasificación. En este contexto, el error cuadrático medio (ECM) es utilizado como función de pérdida para evaluar el desempeño de un predictor individual h , según lo expresado por:

$$E_{X,Y} (Y - h(X))^2 \quad (5.4)$$

La predicción final del RF se obtiene mediante el promedio de la salida de todos los árboles del conjunto:

$$\hat{Y} = \frac{1}{K} \sum_{k=1}^K h(\mathbf{X}, \Theta_k) \quad (5.5)$$

5.3.4. *XGBoost*

Propuesto inicialmente por Chen y Guestrin (2016), *XGBoost*, o *Extreme Gradient Boosting* es una implementación escalable y eficiente de árboles de decisión potenciados por gradiente, diseñada para optimizar tanto el rendimiento del modelo como la velocidad computacional. El algoritmo se basa en una estructura aditiva secuencial, en la cual cada árbol de regresión se entrena para predecir los residuos de la función de pérdida respecto a la predicción anterior. Entre las principales ventajas de este enfoque se encuentran los mecanismos de regularización para mitigar el sobreajuste, el tratamiento eficiente de valores perdidos mediante técnicas conscientes de

la dispersión, y una alta escalabilidad.

La salida predicha está dada por:

$$\hat{Y}_i = \sum_{k=1}^K f_k(\mathbf{x}_i), \quad f_k \in \mathcal{F} \quad (5.6)$$

donde f_k representa un árbol de regresión y \mathcal{F} es el espacio de todos los posibles árboles.

El proceso de aprendizaje minimiza la siguiente función objetivo regularizada:

$$\mathcal{L} = \sum_i l(y_i, \hat{y}_i^{(t)}) + \sum_k \Omega(f_k) \quad (5.7)$$

donde $l(\cdot)$ denota una función de pérdida convexa diferenciable y $\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2$ es el término de regularización que penaliza la complejidad del modelo mediante el número de hojas T y los pesos de estas w .

5.3.5. *LightGBM*

El algoritmo *LightGBM*, presentado por Ke *et al.* (2017), está fundamentado en la estructura de árbol potenciado por gradiente y apunta a acelerar los procesos de entrenamiento a la vez que mantiene una precisión predictiva comparable con otros modelos tales como *XGBoost*. Una de las diferencias principales de este método con otros similares recae en un estrategia de crecimiento de árboles: En vez de proponer una expansión nivel a nivel, *LightGBM* se expande a través de la ramificación con mayor ganancia. Mientras que este enfoque puede reducir pérdidas de manera más eficiente, también puede incurrir en sobreajuste. Este obstáculo suele ser evitado mediante técnicas de regularización y mediante la limitación de la profundidad de los árboles. La forma final de la salida está dada por:

$$\hat{Y} = \sum_{t=0}^{M-1} f_t(X_i) \quad (5.8)$$

donde $f_t(X_i)$ es la función aprendida del t -ésimo árbol de decisión y M es el número de árboles, como se establece en Jabeur *et al.* (2021).

5.3.6. *NGBoost*

NGBoost o *Natural Gradient Boosting*, introducido por Duan *et al.* (2020), representa una extensión del marco metodológico vinculado a potenciadores de gradiente, dada su capacidad de predecir la distribución probabilística condicional para cada observación, permitiendo la cuantificación de la incertidumbre asociada. Este algoritmo hace uso de gradientes naturales en vez de los gradientes usuales usados en métodos similares, mejorando la estabilidad y eficiencia en parámetros distribucionales. Adicionalmente, permite el uso de distribuciones no normales, haciéndolas adaptables para modelar colas pesadas o asimetría. La formulación de su salida está dada por:

$$\theta = \theta^{(0)} - \eta \sum_{m=1}^M \rho^{(m)} \cdot f^{(m)}(x) \quad (5.9)$$

donde $\theta^{(0)}$ es el valor inicial de los parámetros, η es la tasa de aprendizaje, $\rho^{(m)}$ es el peso de la m -ésima base aprendiz y $f^{(m)}(x)$ es la salida de este, dada cierta entrada x .

Los seis algoritmos de ML son implementados y ajustados mediante un enfoque común de validación cruzada, descrita en la siguiente sección. Asimismo, su desempeño es comparado eventualmente con el modelo System-GMM, mediante el uso de métricas predictivas y herramientas de interpretabilidad.

5.4. Optimización de Parámetros y Model Confidence Set

Uno de los aspectos fundamentales en la implementación de algoritmos de ML es la selección de hiperparámetros. Este proceso apunta a encontrar una configuración que se aproxime al desempeño óptimo del modelo, al mismo tiempo que evita riesgos de sobreajuste, el cual es capaz de perjudicar la capacidad del modelo de generalizar a través de países y periodos de tiempo al introducir sesgos de predicción.

Para alcanzar este objetivo, cada algoritmo de ML es afinado mediante un enfoque de *Grid-SearchCV*. La optimización de hiperparámetros es llevada a cabo utilizando una validación cruzada de 5 grupos mediante una estrategia *GroupKFold*, que permite respetar una estructura que agrupa por países, asemejándose a un panel. Adicionalmente, los datos están divididos cronológicamente: El conjunto de entrenamiento comprende observaciones entre el 2004 y 2015 (lo que corresponde a dos tercios de toda la muestra), mientras que el conjunto de prueba se compone por las observaciones entre 2016 y 2021 (el tercio restante), reforzando una lógica de prueba fuera de muestra en un marco semejante a datos de panel.

Una vez se realiza la búsqueda de hiperparámetros, se selecciona la mejor configuración mediante el criterio del ECM. Luego, estos modelos son evaluados comparativamente mediante el uso del procedimiento *Model Confidence Set* (Conjunto de Modelos Confiables, o MCS en su sigla en inglés), que identifica estadísticamente un subconjunto de modelos que no pueden ser descartados como inferiores a cierto nivel de significancia.

MCS, introducido por Hansen *et al.* (2011), es un procedimiento diseñado para seleccionar un subconjunto de modelos estadísticamente superiores, usualmente referidos como .objetos.^{en} el artículo original, de un conjunto mayor \mathcal{M} . Este método se basa en la construcción de una prueba

estadística $\delta_{\mathcal{M}}$ y una regla de eliminación asociada $e_{\mathcal{M}}$, que sigue un criterio determinado, tal como puede ser el ECM. Este mecanismo evalúa el desempeño de cada modelo en una lógica iterativa que permite remover modelos que son estadísticamente inferiores a sus contendores en el conjunto. Su flexibilidad radica en su capacidad para definir un subconjunto sobreviviente $\widehat{\mathcal{M}}^*$ que, dado cierto nivel de significancia, contiene solo modelos que son indistinguibles estadísticamente en lo que respecta a su capacidad predictiva. Para la presente aplicación, se implementa MCS con 10.000 réplicas por remuestreos y un nivel de confianza de un 5 %.

El resultado esperado del uso de este mecanismo es la identificación del algoritmo más robusto dentro de los otros candidatos. Una vez se encuentra, este es comparado en contraposición con la estimación System-GMM y luego es sujeta a análisis de interpretabilidad mediante el uso de valores SHAP.

5.5. SHapley Additive exPlanations

Una de las tareas más desafiantes en la estimación con métodos de ML es identificar un método que asegure interpretabilidad, cuando los objetivos no están exclusivamente alineados con la precisión predictiva, sino que también pretenden extraer información relevante en lo que respecta a la importancia y forma funcional de los predictores en relación con la variable objetivo, en especial cuando se requiere transparencia para complementar la labor predictiva. Como solución a este problema, aparece SHAP, propuesta por Lundberg y Lee (2017). Un marco unificado que atribuye la salida de un modelo a características de entrada en una lógica aditiva. En esta formulación, la salida está expresada como una suma de contribuciones individuales:

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(M - |S| - 1)!}{M!} [f_{S \cup \{i\}}(x) - f_S(x)] \quad (5.10)$$

donde $f(x)$ es la salida del modelo para una instancia x , ϕ_0 es la salida esperada del modelo y ϕ_i representa la contribución de la i -ésima característica.

Los valores SHAP se derivan de la teoría de juegos cooperativos, donde cada variable explicativa contribuye a la predicción del modelo. El valor atribuido a una variable corresponde a su contribución marginal promedio a través de todas las posibles coaliciones de variables. Formalmente, el valor SHAP para la variable i es calculado según:

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(M - |S| - 1)!}{M!} [f_{S \cup \{i\}}(x) - f_S(x)] \quad (5.11)$$

donde M es el número de variables explicativas, S es el subconjunto de variables que no incluye a i y $f_S(x)$ representa el modelo entrenado únicamente con las variables en S .

En esta investigación, se adopta esta estrategia como una medida para proporcionar interpretabilidad a los algoritmos de ML, en contraste con los modelos econométricos clásicos. Su principal ventaja se encuentra en su capacidad para capturar potenciales no linealidades e interacciones complejas entre variables financieras y de control. Mediante la descomposición del impacto de cada variable sobre observaciones individuales, SHAP apoya una comparación estructurada entre modelos de ML y System-GMM, asegurando una contraposición justa entre desempeño y capacidad explicativa.

5.6. Prueba de Causalidad

En complemento al marco metodológico presentado previamente, se evaluar la existencia de relaciones causales entre el desarrollo financiero y consumo de energías renovables. Para esto, se presenta la prueba de causalidad de Dumitrescu y Hurlin (2012). Esta metodología extiende el enfoque de causalidad de Granger a datos de panel, permitiendo la heterogeneidad de los co-

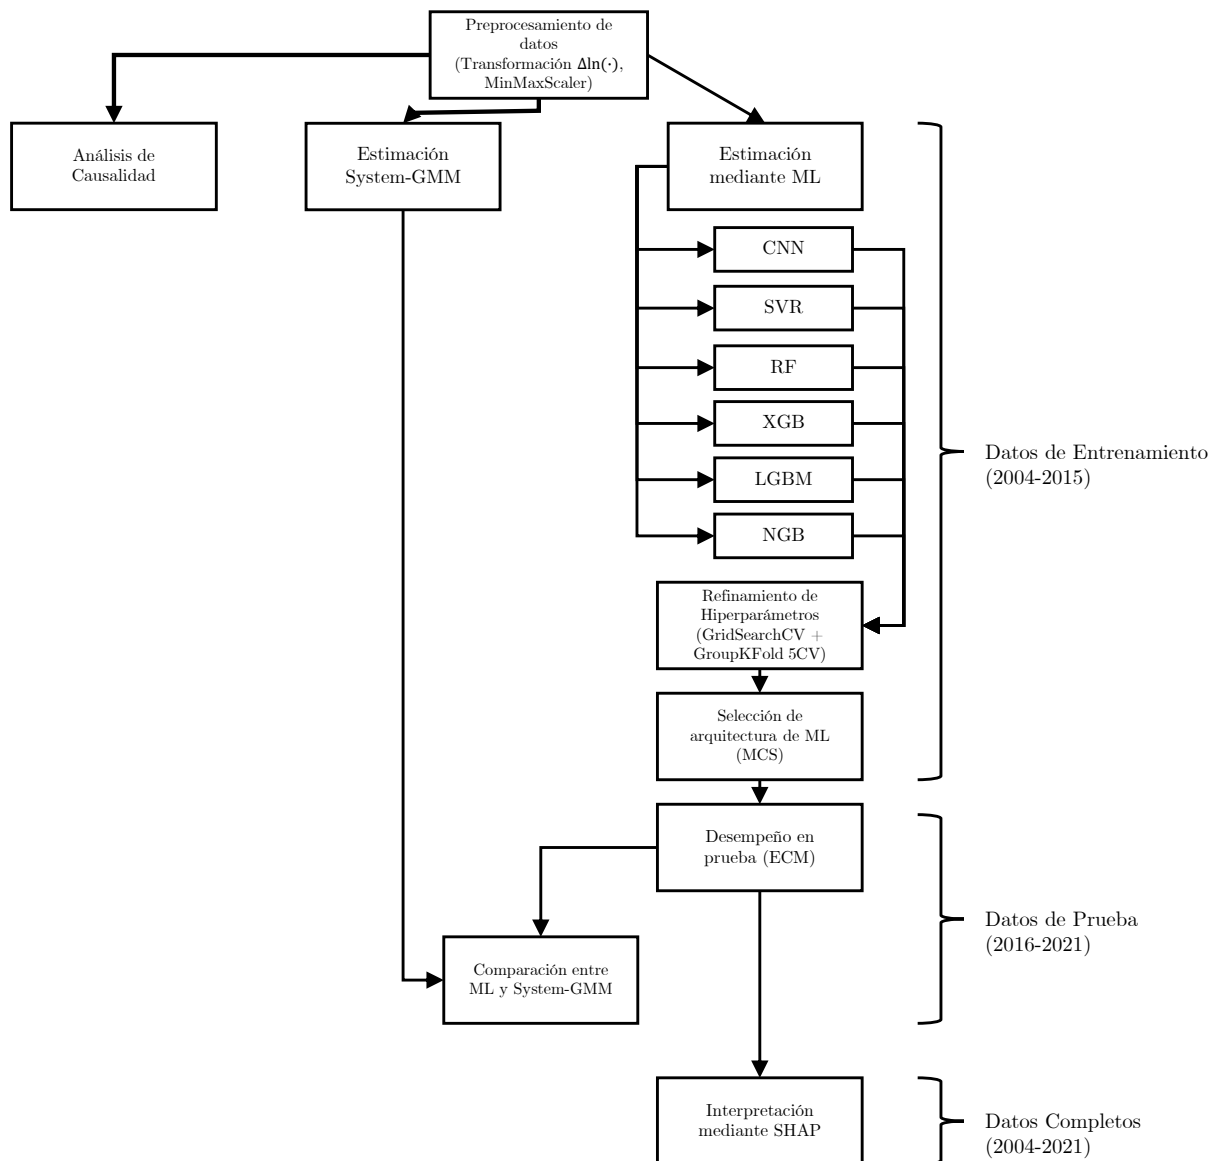
eficientes de causalidad entre países. A diferencia de las pruebas de causalidad tradicionales, que suponen homogeneidad total en la relación causal, esta prueba considera que algunos individuos pueden presentar causalidad mientras otros no, lo que ofrece mayor flexibilidad y realismo al análisis empírico, respetando la naturaleza de cada observación.

La motivación de evaluar causalidad está dada por la necesidad de atribuir direccionalidad de ciertos fenómenos, entendiendo que existen relaciones que se nutren de manera positiva y colaborativamente. Esto permite proveer de un análisis de política eficaz y apropiado para cada contexto, que sea consistente con el comportamiento de cada relación.

5.7. Resumen de la Metodología

Tras presentar los datos y métodos de estimación. Se presenta un resumen ilustrado en la Figura 5.2, que muestra el flujo secuencial adoptado en esta investigación, desde la preparación de los datos hasta la evaluación, interpretación y análisis causal.

Figura 5.2: Esquema metodológico del estudio.



Como se muestra en el diagrama, el proceso parte en el preprocesamiento, donde se aplica una transformación $\Delta \ln(\cdot)$ y se normalizan las variables mediante el uso de *MinMaxScaler* para asegurar comparabilidad entre modelos. Luego se estima simultáneamente mediante System-GMM y los algoritmos de ML. Para estos últimos, se realiza un refinamiento de hiperparámetros mediante

GridSearchCV con validación de 5 grupos mediante *GroupKFold* para los datos de entrenamiento.

Posteriormente, el mejor modelo de los conjuntos de variables es seleccionado mediante MCS. Luego la capacidad predictiva es evaluada mediante ECM en el conjunto de prueba, permitiendo una comparación justa con System-GMM. Finalmente, se le brinda interpretabilidad a los modelos de ML a través de la aplicación de valores SHAP en todo el conjunto de datos.

De manera paralela, se aplica un análisis de causalidad para determinar la dirección de la evidencia obtenida en la estructura metodológica anterior.

5.8. Especificación de los Modelos

Esta investigación adopta la siguiente forma funcional, la cual se aplica consistentemente en todos los modelos de ML, así como también en la estimación System-GMM. La siguiente formulación captura efectos dinámicos y de persistencia de la variable dependiente:

$$\begin{aligned} \Delta \ln Renewable_{it} = f(\Delta \ln(Renewable)_{it-1}, \Delta \ln(FinIndex)_{it}^{(k)}, \Delta \ln(CO_2)_{it}, \Delta \ln(GDP)_{it}, \\ \Delta \ln(CPI)_{it}, \Delta \ln(Ind)_{it}, \Delta \ln(NatResRent)_{it}) \end{aligned} \quad (5.12)$$

donde $FinIndex_{it}^{(k)}$ representa uno de los nueve indicadores de desarrollo financiero presentados en la Tabla 5.1.

Para estimar mediante la estructura de datos de panel dinámicos según la metodología de Blundell y Bond (1998), se especifica el siguiente modelo para el estimador System-GMM:

$$\begin{aligned} \Delta \ln(Renewable)_{it} = \alpha + \beta_0 \Delta \ln(Renewable)_{it-1} + \beta_1 \Delta \ln(FinIndex)_{it}^{(k)} + \beta_2 \Delta \ln(CO_2)_{it} + \beta_3 \Delta \ln(GDP)_{it} \\ + \beta_4 \Delta \ln(CPI)_{it} + \beta_5 \Delta \ln(Ind)_{it} + \beta_6 \Delta \ln(NatResRent)_{it} + \varepsilon_{it} \end{aligned} \quad (5.13)$$

donde ε_{it} representa el término de error.

6. Resultados y Discusión

Para comprender el impacto del desarrollo financiero sobre el consumo de energías renovables, se presenta una mirada multidimensional, en la que se evalúan distintos indicadores de desarrollo financiero. Asimismo, se utiliza una serie de variables de control que permite dilucidar interacciones de los sistemas financieros en indicadores contextuales o de desarrollo. A continuación se presentarán pruebas de raíz unitaria, las estimaciones System-GMM y ML, criterio de selección de modelos, interpretación mediante SHAP, análisis de causalidad e implicancias de política.

6.1. Pruebas de Raíz Unitaria

En primer lugar, se presentan las pruebas de raíz unitaria presentadas por Im *et al.* (2003) y Phillips y Perron (1986), cuyas hipótesis nulas y alternativas están descritas en la Tabla 5.3. El propósito central de la aplicación de estos tests es verificar si las variables deben ser incluidas en sus formas en nivel o transformadas en su primera diferencia. La Tabla 6.1 reporta los resultados para ambos tests y muestra evidencia mixta. En particular, la variable *Renewable* falla en el rechazo de la hipótesis nula en ambas pruebas, indicando una fuerte evidencia de no estacionariedad. Se llega a conclusiones semejantes al aplicarlos en los indicadores financieros y en variables de control, con excepción de *NatResRent*, que resulta estacionaria según ambos criterios. Para asegurar consistencia y comparabilidad entre todos los modelos y metodologías, se respalda la decisión de incluir todas las variables en su forma de primera diferencia, tal como se enfatiza en la sección correspondiente.

Tabla 6.1: Resultados Pruebas Raíz Unitaria (Variables en Nivel)

Variable	Prueba IPS		Prueba PP	
	Estadístico	valor-p	Estadístico	valor-p
Renewable	-1.0595	1.0000	0.9826	0.1629
FinDevIndex	-1.8601	0.0016	5.8601	0.0000
FinInsAccessIndex	-1.1252	1.0000	2.6332	0.0042
FinInsDepthIndex	-1.3798	0.9712	2.6105	0.0045
FinInsEffIndex	-2.3623	0.0000	14.7333	0.0000
FinInsIndex	-1.6711	0.3629	7.5604	0.0000
FinMarkAccessIndex	—	—	12.3629	0.0000
FinMarkDepthIndex	-2.0415	0.0000	9.4024	0.0000
FinMarkEffIndex	—	—	3.6745	0.0001
FinMarkIndex	-1.9338	0.0000	5.2021	0.0000
NatResRent	-1.7557	0.0022	2.1488	0.0158
GDP	-0.8907	1.0000	-1.6376	0.9492
CO ₂	-1.3189	0.9874	-0.0402	0.5160
CPI	0.0367	1.0000	-0.2785	0.6097
Industry	-1.5926	0.1985	1.3336	0.0912

Nota: IPS = Im-Pesaran-Shin; PP = Phillips-Perron. — indica que la prueba no reporta resultados dada la naturaleza del panel.

6.2. Resultados de la estimación System-GMM

En esta sección, se muestran los resultados de la aplicación del estimador System-GMM de dos pasos para evaluar la relación entre el crecimiento del consumo de energías renovables y los cambios en los índices financieros, en 9 modelos. La Tabla 6.2 reporta los resultados considerando el panel de 83 países. Cada columna representa una especificación del modelo diferente, mostrando la inclusión de una variable financiera a la vez como variable explicativa principal. La correspondencia entre cada modelo y su índice asociado se presenta en la nota al pie de la tabla.

Tabla 6.2: Estimaciones System-GMM

Variable	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9
$\Delta \ln(\text{L.Renewable})$	-0.538 (0.364)	-0.546 (0.369)	-0.535 (0.352)	-0.507 (0.348)	-0.513 (0.356)	-0.270 (0.354)	-0.529 (0.362)	-0.676 (0.412)	-0.542 (0.369)
$\Delta \ln(\text{FinIndex})$	-0.030 (0.045)	-0.052 (0.076)	-0.118*** (0.040)	0.026 (0.039)	-0.054 (0.057)	-0.057 (0.039)	-0.028 (0.053)	0.006 (0.055)	-0.026 (0.049)
$\Delta \ln(\text{NatResRent})$	0.126** (0.051)	0.126** (0.051)	0.124** (0.050)	0.128** (0.051)	0.125** (0.050)	0.129*** (0.049)	0.126** (0.051)	0.131** (0.055)	0.126** (0.051)
$\Delta \ln(\text{CPI})$	-0.042 (0.063)	-0.044 (0.062)	-0.079 (0.069)	-0.048 (0.065)	-0.044 (0.062)	-0.072 (0.082)	-0.045 (0.064)	-0.067 (0.074)	-0.042 (0.064)
$\Delta \ln(\text{GDP})$	-0.094* (0.050)	-0.094* (0.049)	-0.107** (0.050)	-0.096* (0.050)	-0.093* (0.050)	-0.084 (0.056)	-0.095* (0.050)	-0.068 (0.067)	-0.094* (0.050)
$\Delta \ln(\text{CO}_2)$	-0.310*** (0.099)	-0.305*** (0.099)	-0.315*** (0.099)	-0.312*** (0.097)	-0.315*** (0.098)	-0.391*** (0.109)	-0.311*** (0.099)	-0.391*** (0.131)	-0.307*** (0.100)
$\Delta \ln(\text{Industry})$	-0.081 (0.054)	-0.082 (0.053)	-0.114** (0.055)	-0.082 (0.054)	-0.082 (0.054)	-0.040 (0.055)	-0.083 (0.054)	-0.057 (0.062)	-0.082 (0.054)
Constante	0.487*** (0.158)	0.490*** (0.156)	0.566*** (0.154)	0.448*** (0.151)	0.492*** (0.155)	0.394*** (0.150)	0.486*** (0.162)	0.551*** (0.172)	0.489*** (0.164)
AR(1) (valor-p)	(0.037)	(0.039)	(0.033)	(0.031)	(0.031)	(0.024)	(0.039)	(0.086)	(0.044)
AR(2) (valor-p)	(0.270)	(0.259)	(0.233)	(0.278)	(0.288)	(0.461)	(0.271)	(0.434)	(0.269)
Hansen (valor-p)	(0.891)	(0.889)	(0.962)	(0.864)	(0.884)	(0.560)	(0.883)	(0.825)	(0.878)
Hansen-Diff (valor-p)									
GMM inst. (Nivel)	(0.942)	(0.937)	(0.911)	(0.875)	(0.817)	(0.398)	(0.833)	(0.681)	(0.852)
Inst. Exógenos	(0.393)	(0.397)	(0.779)	(0.442)	(0.632)	(0.880)	(0.581)	(0.991)	(0.522)
Número de Obs.	1437	1437	1437	1437	1437	1385	1437	1178	1437
Número de Ins.	12	12	12	12	12	12	12	12	12

Nota: Todos los modelos son estimados mediante System-GMM de dos pasos. Los niveles de significancia se indican según: *** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$. Los errores estándar robustos se muestran entre paréntesis. Los valores-p de las pruebas de especificación se indican en paréntesis. Cada columna incluye una variable financiera diferente como FinIndex, Modelo 1; FinDevIndex, Modelo 2; FinInsAccessIndex, Modelo 3; FinInsDepthIndex, Modelo 4; FinInsEffIndex, Modelo 5; FinInsIndex, Modelo 6; FinMarkAccessIndex, Modelo 7; FinMarkDepthIndex, Modelo 8; FinMarkEffIndex, Modelo 9; FinMarkIndex.

Siguiendo el marco conceptual propuesto por Blundell y Bond (1998), se construye un conjunto de instrumentos para lidiar con potenciales problemas de endogeneidad, mientras se preserva la validez de los momentos condicionales. En específico, los instrumentos de tipo generalizado de momentos se utilizan para potenciales regresores endógenos, tales como $\Delta \ln(\text{NatResRent})$, $\Delta \ln(\text{CPI})$, $\Delta \ln(\text{GDP})$, $\Delta \ln(\text{CO}_2)$ y $\Delta \ln(\text{Industry})$. Adicionalmente, la primera diferencia de cada índice financiero es utilizado como instrumento externo de la ecuación en nivel. Esta estrategia busca maximizar la eficiencia de la estimación, reduciendo la proliferación de instrumentos y sobreajuste.

Para verificar la robustez de la metodología, se reportan los resultados de las pruebas de especificación previamente presentados en Table 5.3. Las pruebas de Arellano-Bond para autocorrelación de orden 1 y 2 examinan cuando las condiciones de los momentos son válidas en presencia de autocorrelación en primeras diferencias. Para los nueve modelos, la hipótesis de no autocorrelación de primer orden es rechazada ($p < 0,05$), con la excepción del Modelo 8, cuya significancia es marginal ($p = 0,086$). Complementando, las pruebas de autocorrelación de segundo orden fallan en rechazar la H_0 en todos los casos ($p > 0,23$), indicando la ausencia de autocorrelación de segundo orden y respaldando la validez del conjunto de instrumentos.

En lo que respecta al test de Hansen J para la sobreidentificación de restricciones, este consistentemente falla en el rechazo de la hipótesis nula de instrumentos validos en todas las especificaciones, con valores-p por sobre 0.5. Finalmente, en los tests de Hansen en Diferencia, cuyo rol es evaluar la exogeneidad de los instrumentos, se tiene que se este falla en favor de respaldar la validez del conjunto, dado que todos los valores-p exceden 0.35.

Para todos los modelos, se encuentra evidencia para afirmar que existe una relación negativa entre la variación de las emisiones de CO_2 y el consumo de energías renovables, con coeficientes

cercanos a -0.3. Sobre las rentas de recursos naturales, estas muestran una asociación estable con el uso de energías limpias, con un efecto estimado de 0.13 en todos los modelos. En lo que refiere al resto de las variables de control, el crecimiento del PIB es significativo en todos los modelos salvo el 6 y 8, que se vinculan con factores específicos de los mercados. Para el crecimiento industrial, solo el modelo 3 muestra evidencia para relacionarla con el consumo de energías renovables. La única variable financiera significativa es la profundidad de las instituciones financieras, mostrando una relación negativa, presumiendo una influencia perjudicial. Estos resultados permiten perseguir razones no observadas en este modelo para comprender la naturaleza de este nexo. En este sentido, algoritmos de ML podrían ser apropiados para esta tarea.

En complemento a este análisis, la evidencia presentada en la Tabla 6.2 es clara en sugerir que existe una relación débil entre la variación del consumo de energías renovables y cambios en el sistema financiero, con la notable excepción de la profundidad de las instituciones, que muestra una ligera relación negativa. Si bien, esto podría ser interpretado como una señal de que los sistemas financieros no influyen mayormente en la transición de energías limpias, el rol de las dinámicas no lineales siguen sin ser exploradas. En este contexto, técnicas de ML entregan una oportunidad única para descubrir patrones complejos.

6.3. Selección de Algoritmos de Machine Learning

Tal como es discutido en la metodología, se presentan seis algoritmos de ML, en específico, CNN, SVR, *Random Forest*, *LightGBM*, *XGBoost* y *NGBoost*. La estructura evaluativa está basada en una validación cruzada de 5 grupos mediante el uso de *GroupKFold* con países como criterio de agrupación, en un esquema de *GridSearchCV*². El conjunto de datos se divide en un subconjunto

²La información detallada en lo que respecta a la selección de hiperparámetros para cada modelo se presenta en el Apéndice B

de entrenamiento (con observaciones entre 2004 y 2015) y en otro subconjunto de prueba (con observaciones entre 2016 y 2021).

Para evaluar el desempeño de los modelos seleccionados, se adopta la estrategia de MCS para seleccionar la arquitectura con mejor performance, basada en el criterio del ECM. La Tabla 6.3 muestra los resultados del ECM para 54 especificaciones, en correspondencia con la combinación de nueve variables financieras con seis modelos de ML. Además, de manera complementaria, en la Tabla 6.4 se muestran los resultados utilizando el Error Absoluto Medio (EAM) como criterio.

Tabla 6.3: Valores del ECM en el conjunto de prueba para los algoritmos de ML a través de los índices de desarrollo financiero.

Algoritmo de ML	FDIndex	FIAIndex	FIDIndex	FIEIndex	FIIndex	FMAIndex	FMDIndex	FMEIndex	FMIndex
CNN	0.01156	0.01157	0.01159	0.01248	0.01196	0.01168	0.01164	0.01122	0.01145
LightGBM	0.01116	0.01121	0.01115	0.01113	0.01120	0.01150	0.01120	0.01007	0.01112
NGBoost	0.01126	0.01118	0.01107	0.01114	0.01132	0.01168	0.01116	0.01039	0.01123
Random Forest	0.01103	0.01108	0.01106	0.01105	0.01109	0.01126	0.01103	0.01010	0.01103
SVR	0.01146	0.01133	0.01143	0.01147	0.01145	0.01143	0.01146	0.01026	0.01147
XGBoost	0.01125	0.01113	0.01122	0.01111	0.01119	0.01140	0.01118	0.01008	0.01115

Nota: Valores en **negrita** indican el menor ECM para cada índice financiero, el cual está abreviado según sus iniciales.

Tabla 6.4: Valores del EAM en el conjunto de prueba para los algoritmos de ML a través de los índices de desarrollo financiero.

Algoritmo de ML	FDIndex	FIAIndex	FIDIndex	FIEIndex	FIIndex	FMAIndex	FMDIndex	FMEIndex	FMIndex
CNN	0.06290	0.06059	0.06276	0.06780	0.06379	0.06443	0.06317	0.06653	0.06067
LightGBM	0.06035	0.06066	0.06035	0.06046	0.06050	0.06163	0.06053	0.05883	0.06002
NGBoost	0.06121	0.06086	0.06038	0.06037	0.06123	0.06297	0.06080	0.05992	0.06028
Random Forest	0.05904	0.05914	0.05913	0.05907	0.05927	0.06033	0.05913	0.05829	0.05904
SVR	0.05983	0.05956	0.05973	0.05984	0.05968	0.05996	0.05983	0.05828	0.06043
XGBoost	0.06055	0.06033	0.06056	0.06000	0.06034	0.06138	0.06083	0.05862	0.05990

Nota: Valores en **negrita** indican el menor EAM para cada índice financiero, el cual está abreviado según sus iniciales.

Tras aplicar MCS con el criterio de MSE, tal como se evidencia en la Tabla 6.3, se selecciona *Random Forest* para todas las variables financieras, con excepción de *FinMarkEffIndex*, donde *LightGBM* muestra desempeño superior. En este caso, la selección del MCS coincide con los modelos que alcanzan un menor ECM. Tras considerar el criterio del EAM, las conclusiones permanecen consistentes, con la excepción de que SVR emerge como el modelo con mejor desempeño para las variables *FinMarkAccessIndex* y *FinMarkEffIndex*. No obstante, se conserva la consistencia metodológica mediante la aplicación del procedimiento MCS en el resto del análisis.

6.4. Comparación de Desempeño entre Algoritmos de Machine Learning y System-GMM

Una vez seleccionados los modelos, se procede a comparar su desempeño con los resultados de la estimación System-GMM. La Tabla 6.5 presenta la contraposición entre los dos enfoques mediante el uso de dos métricas: ECM y EAM. Esta evaluación se centra en encontrar el mejor desempeño predictivo mediante utilizar datos de prueba, ajenos al entrenamiento.

Tabla 6.5: Comparación de desempeño: ML vs. System-GMM (Conjunto de Prueba)

Variable	Algoritmo ML	ECM		EAM	
		Prueba	System-GMM	Prueba	System-GMM
FDIndex	RandomForest	0.0118	0.0127	0.0587	0.0652
FIAIndex	RandomForest	0.0118	0.0127	0.0594	0.0653
FIDIndex	RandomForest	0.0118	0.0126	0.0592	0.0648
FIEIndex	RandomForest	0.0117	0.0126	0.0587	0.0648
FIIndex	RandomForest	0.0117	0.0126	0.0586	0.0648
FMAIndex	RandomForest	0.0120	0.0118	0.0593	0.0617
FMDIndex	RandomForest	0.0117	0.0126	0.0585	0.0652
FMEIndex	LightGBM	0.0090	0.0116	0.0562	0.0652
FMIndex	RandomForest	0.0117	0.0127	0.0583	0.0653

Nota: Los valores en **negrita** indican el menor ECM y EAM para cada variable financiera, las cuales están abreviadas según sus iniciales.

Tras comparar las métricas de desempeño, es evidente que los métodos de ML se muestran

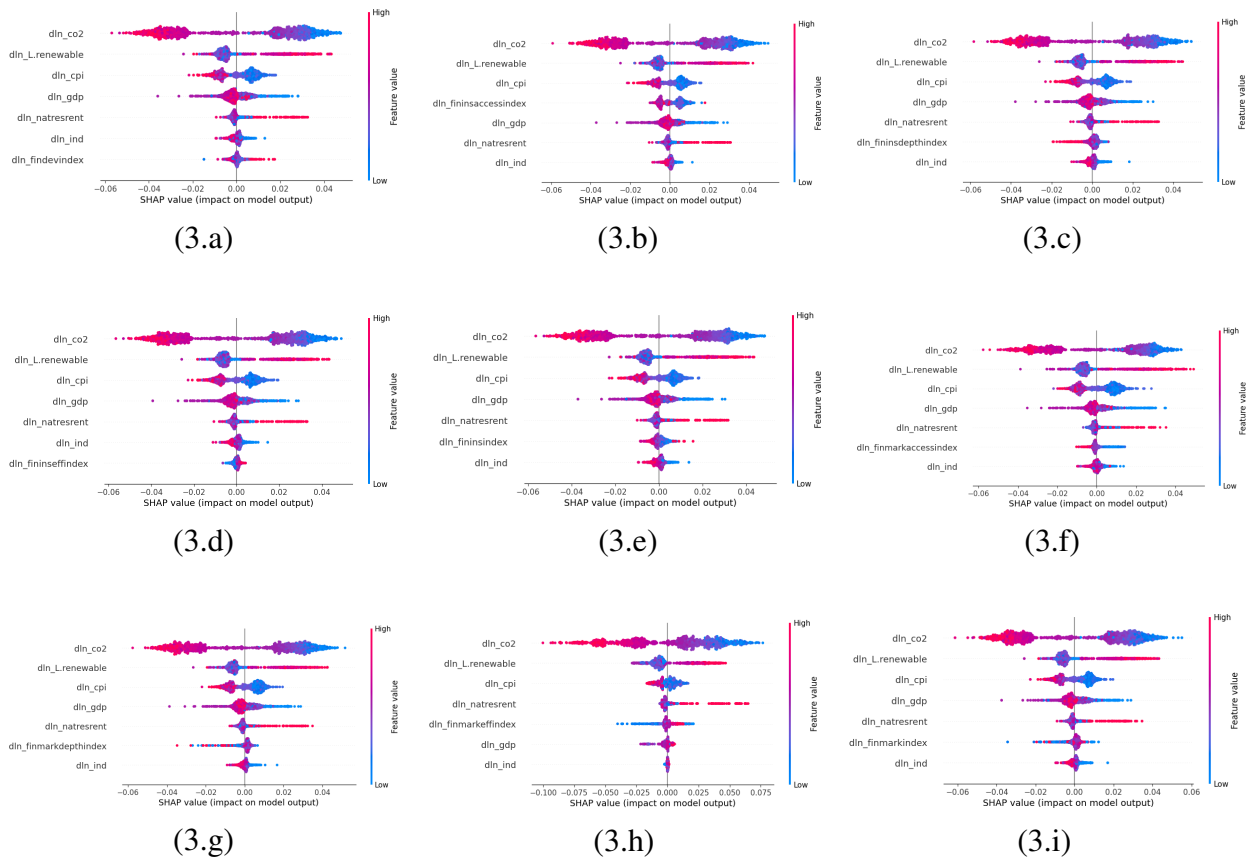
superiores a la estimación System-GMM en prácticamente todos los casos, siendo FinMarkAccessIndex la única excepción cuando se usa el ECM como métrica. Esto respalda las ventajas discutidas de las arquitecturas ML, al demostrar una gran capacidad para capturar no linealidades y para aprender las dinámicas subyacentes de cada relación en entrenamientos apropiados. Tradicionalmente, uno de los motivos por los que se evita utilizar estos métodos es por si carencia en lo interpretativo. A fin de contrarrestar esta limitación, se recurre al uso de valores SHAP, permitiendo la entrega de información relevante con respecto al rol del desarrollo financiero en el consumo de energías renovables.

6.5. Interpretación de resultados mediante SHAP

En esta sección, se presenta un análisis detallado y descomposición de los modelos de ML seleccionados mediante el uso de valores SHAP y dos tipos de gráficos. Primeramente, se muestran gráficos de tipo enjambre para observar de manera general la contribución de cada observación para todas las variables en relación con la dependiente. Luego, en las siguientes subsecciones se enfatiza en gráficos de dependencia que permiten una simple inspección de las dinámicas específicas entre las variables explicativas y la fenomenología.

Las figuras desde la 6.1.a hasta la 6.1.i presentan gráficos de enjambre para las nueve combinaciones de variables financieras, ordenadas según: FinDevIndex, FinInsAccessIndex, FinInsDepthIndex, FinInsEffIndex, FinInsIndex, FinMarkAccessIndex, FinMarkDepthIndex, FinMarkEffIndex y FinMarkIndex. Previo al análisis individual de cada variable financiera, es relevante proveer un contexto sobre el cual las variables de control tienen un rol relevante.

Figura 6.1: Gráficos SHAP de enjambre para cada combinación de variables



Dentro de los patrones más notables en lo referente a las variables de control, se tiene que la influencia de las emisiones de CO₂ en el consumo de energías renovables es consistente con la literatura. Los gráficos de enjambre revelan una clara relación donde menores emisiones están asociadas con altos niveles de variación positiva al consumo de renovables, sugiriendo un alineamiento con los ODS. Además, al analizar el rezago de la variable dependiente, se tiene que, en general, se percibe un alto efecto de la persistencia, de tal manera que países que tienen un mayor crecimiento de energías renovables tienden a mantener ese comportamiento. La inflación también juega un rol relevante, donde menores tasas inflacionarias apoyan la transición a energías limpias. En lo que respecta al efecto del crecimiento, si bien el impacto que este tiene es limita-

do, ciertos episodios de alta expansión dificultan la transición a renovables. Finalmente, tanto las rentas de recursos naturales como el valor agregado por la industria exhiben asociaciones débiles con el consumo de energías renovables, con excepción de una observaciones con altas rentas que aparentemente canalizan esas ganancias en inversión para energías limpias.

El Desarrollo Financiero, como un todo, aparentemente tiene una influencia limitada en la transición a energías renovables. Tal como se muestra en los gráficos, la gran mayoría de los valores SHAP están concentrados en la vecindad del cero, indicando una contribución relativamente débil a la variable objetivo. No obstante, se muestra una ligera indicación de que valores más altos de desarrollo financiero permitiría un mayor consumo de energías renovables. En particular, unas pocas observaciones con grandes variaciones en desarrollo financiero muestran una contribución fuerte positiva.

Al inspeccionar los efectos desagregados de las instituciones financieras, se observa que una mayor expansión en el acceso tiende a mermar la consolidación del consumo de energías renovables. En relación con la profundidad, una tendencia al alza es observada, lo que implica que mayores niveles de profundidad institucional tienden a complejizar la transición. En contraste, la eficiencia de las instituciones financieras muestra un efecto prácticamente nulo, pero con una ligera relación positiva hacia el crecimiento de energías renovables. En general, tal como es expuesto en la Figura 6.1.e, el crecimiento de las instituciones tiende a inhibir el establecimiento de la transición, con algunas excepciones dignas de mención.

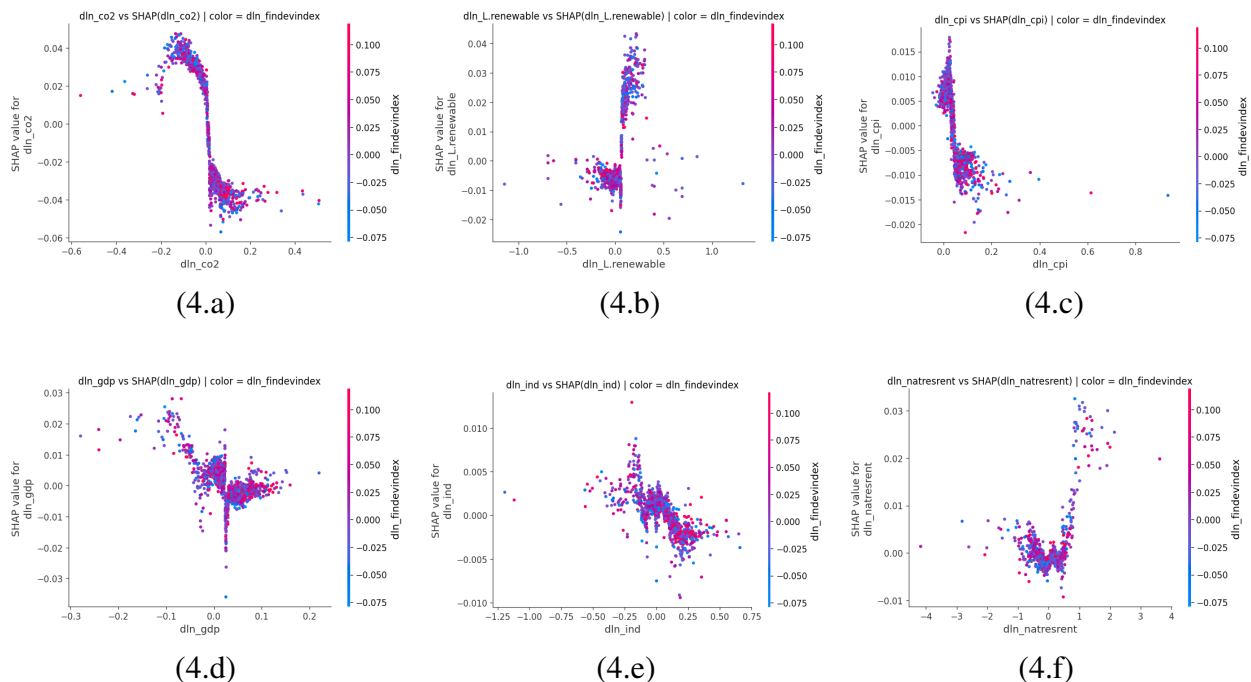
Por otro lado, los efectos desagregados de los mercados financieros es más diverso. En lo que refiere al acceso, se observa una ligera tendencia a la baja con un efecto general nulo, pero con una relación aparentemente negativa con el consumo de renovables. Para la profundidad, existe una tendencia al alza, sin perjuicio de que los efectos en el crecimiento de renovables son incon-

sistentes. En el caso de la eficiencia, el efecto es leve, aun cuando hay crecimiento, aparentemente respalda el desarrollo de energías limpias. Finalmente, al observar los mercados financieros como un todo, se muestra una relación débil pero generalmente positiva con la adopción de energías renovables.

6.5.1. Impacto de las Variables de Control en el Consumo de Energía

Con el objetivo de comprender las dinámicas implícitas no lineales de las variables de control, se propone el análisis de gráficos SHAP de dependencia, que en el eje X muestra los valores de la tasa de crecimiento de cada variable de control, mientras que en el eje Y se exponen los valores SHAP para esa variable. Adicionalmente, cada observación está coloreada según la magnitud del crecimiento de desarrollo financiero, de tal manera de proveer de un análisis completo y contingente para una gestión responsable de políticas públicas. Las Figuras desde la 6.2.a a la 6.2.f muestran los gráficos SHAP de dependencia.

Figura 6.2: Gráficos SHAP de dependencia para las variables de control



En lo que refiere a las emisiones de CO_2 , se corrobora el comportamiento previsto en los gráficos de enjambre, donde hay una tendencia al alza de las renovables ante bajas en la emisión de contaminantes. Adicionalmente, la forma funcional de esta relación es aparentemente cúbica, con una forma semejante a una N. Esto refuerza la percepción de la literatura, donde hay una retroalimentación entre ambas variables.

Cuando se comparan los rezagos del crecimiento de energías renovables con su valor SHAP, se evidencia el efecto positivo de persistencia previamente aludido. Aun más, se nota que el crecimiento en energías renovables fomenta una transición más comprometida, mientras que el decrecimiento en renovables solo promueve una tendencia relativamente constante. La forma funcional es semejante a una U, mostrando que después de cierto umbral, el efecto positivo es aún mayor.

Sobre la inflación, es evidente que si bien el efecto no es sustancialmente relevante, tasas inflacionarias controladas admiten una transición consistente, mientras que tasas descontroladas merman el crecimiento del consumo de renovables, incluso induciendo a una tendencia decreciente. Asimismo, en lo que refiere al crecimiento del PIB, se percibe que existe una forma funcional semejante a una U, donde ciertos niveles de crecimiento directamente perjudican el establecimiento de renovables. Es más, en aquellas observaciones que muestran decrecimiento económico, existe un alza leve de las renovables, mientras que crecimientos explosivos son inertes en la transición a renovables. Este efecto podría estar explicado por un aumento de energías contaminantes en situaciones de crecimiento del PIB.


En lo que respecta al valor agregado de la industria, se confirma la tendencia decreciente observada en los gráficos de enjambre, pero con efecto prácticamente nulo. En este sentido, se podría afirmar que salvo excepciones muy puntuales, esta variable no tiene un impacto evidente en el fenómeno. En cambio, en las rentas de recursos naturales se observa una forma de U, pero

que muestra beneficios en las energías renovables solo en crecimientos muy altos de la renta, por sobre el 100 %. Esto indica que solo en situaciones en las que hay un superávit excesivo, esto se transfiere a la industria energética.

6.5.2. Impacto de las Dimensiones de Desarrollo Financiero en el Consumo de Energía

Por su parte, las Figuras desde la 6.3.a hasta la 6.3.i exponen gráficos de dependencia para cada variable financiera, persiguiendo el mismo orden presentado para los gráficos de enjambre.

Figura 6.3: Gráficos SHAP de dependencia para cada variable financiera



Estas visualizaciones se centran exclusivamente en el nexo entre consumo de energía re-

novable y desarrollo financiero. Asimismo, es relevante destacar que la variable coloreada es $\Delta \ln(GDP)$, lo que permite tener un contexto económico-financiero completo.

Para el desarrollo financiero como un todo, los gráficos de dependencia confirman la presencia de un patrón no lineal similar a una forma de W, pero en simplificación, se le puede considerar como una U con ciertos valores que se desligan. Cuando se pone el foco en valores sobre cero, una forma de U interna se vuelve más evidente, el cual se intensifica con variaciones sobre el 10 %, confirmando que altos niveles sostenidos de desarrollo financiero están asociados con el incremento del consumo de energías renovables. Adicionalmente, es notable que en este rango más alto, existe una concentración de un alto crecimiento económico, sugiriendo una relación simbiótica entre desarrollo financiero, expansión económica y consumo de energías renovables.

En lo que refiere al efecto de las instituciones, los índices desagregados muestran comportamiento diverso. El acceso exhibe una relación con forma de U que se intensifica con el crecimiento económico y variaciones grandes, sin embargo, en parte importante de las variaciones existe un desmedro a la transición energética. Al examinar la profundidad, se observa una curva con forma de U invertida, con efectos positivos concentrados solo con variaciones inferiores a 0.2. En contraste, la eficiencia institucional muestra una relación prácticamente lineal con el consumo de energía renovable. Finalmente, el índice compuesto sugiere una relación con forma de U, donde variaciones moderadas son más favorables.

Sobre el efecto de los mercados financieros, los patrones desagregados muestran resultados mixtos. Para el acceso, se observan formas no lineales, con altas variaciones positivas de consumo de energías renovables en valores bajos del índice y estabilizándose en torno al cero. La relación entre profundidad de mercado y energías renovables revelan una forma funcional de U invertida, donde la mayor parte de los valores SHAP son negativos, implicando una asociación consistente

con valores bajos de consumo de renovables, independiente de la magnitud de la variación. Similar al caso institucional, la eficiencia en los mercados muestra una relación prácticamente lineal positiva, excepto con ciertos valores puntuales. Finalmente, el índice compuesto persigue una forma funcional de U invertida, privilegiando crecimientos estables en vez de tendencias explosivas.

En general, la metodología SHAP provee claridad adicional al nexo entre el desarrollo financiero y consumo de energías renovables. Al complementar los hallazgos obtenidos mediante las estimaciones de System-GMM, es posible construir un panorama más claro que revele la importancia, las interacciones y las formas funcionales entre los componentes de los sistemas financieros, gracias a la capacidad de los algoritmos de ML para ofrecer interpretabilidad a sus resultados. La presencia de patrones en forma de U y U invertida, particularmente bajo condiciones de crecimiento económico estable, refuerza la relevancia de considerar respuestas heterogéneas entre los distintos subcomponentes financieros.

6.6. Análisis de Causalidad

Por último, considerando la evidencia presentada en las secciones previas, es de suma importancia determinar la dirección de la causalidad entre el consumo de energías renovables y el desarrollo financiero. En este sentido, la Tabla 6.6 presenta los resultados del test de causalidad de Dumitrescu y Hurlin (2012) para las variables *Renewable* con todas las variables financieras. La hipótesis nula es que la primera variable no Granger-causea la segunda.

Tabla 6.6: Resultados del Test de Causalidad de Granger

Dirección de Causalidad	Rezago	\bar{W}	\bar{Z} (p-valor)	\tilde{Z} (p-valor)
<i>renewable</i> → <i>findevindex</i>	1	3.1921	14.1217 (0.0000)	9.8090 (0.0000)
<i>findevindex</i> → <i>renewable</i>	1	2.0159	6.5442 (0.0000)	4.1126 (0.0000)
<i>renewable</i> → <i>fininsindex</i>	1	3.1937	14.1319 (0.0000)	9.8167 (0.0000)
<i>fininsindex</i> → <i>renewable</i>	1	2.7013	10.9599 (0.0000)	7.4321 (0.0000)
<i>renewable</i> → <i>finmarkindex</i>	1	2.4339	9.2375 (0.0000)	6.1372 (0.0000)
<i>finmarkindex</i> → <i>renewable</i>	1	1.6379	4.1093 (0.0000)	2.2821 (0.0225)
<i>renewable</i> → <i>fininsaccessindex</i>	1	5.0519	26.1028 (0.0000)	18.8160 (0.0000)
<i>fininsaccessindex</i> → <i>renewable</i>	1	2.7158	11.0532 (0.0000)	7.5022 (0.0000)
<i>renewable</i> → <i>fininsdepthindex</i>	1	2.3046	8.4041 (0.0000)	5.5107 (0.0000)
<i>fininsdepthindex</i> → <i>renewable</i>	1	2.5663	10.0902 (0.0000)	6.7783 (0.0000)
<i>renewable</i> → <i>fininseffindex</i>	1	2.3021	8.3879 (0.0000)	5.4986 (0.0000)
<i>fininseffindex</i> → <i>renewable</i>	1	1.4181	2.6934 (0.0071)	1.2177 (0.2233)
<i>renewable</i> → <i>finmarkdepthindex</i>	1	2.2272	7.9057 (0.0000)	5.1361 (0.0000)
<i>finmarkdepthindex</i> → <i>renewable</i>	1	1.9367	6.0341 (0.0000)	3.7291 (0.0002)

Nota: El test de Dumitrescu y Hurlin (2012) evalúa causalidad de Granger en datos de panel. Los p-valores reportados indican significancia estadística. \bar{W} , \bar{Z} y \tilde{Z} corresponden a estadísticos bajo distintas aproximaciones asintóticas. Los resultados para *finmarkaccessindex* y *finmarkeffindex* fueron omitidos debido a errores derivados de datos faltantes o panel no balanceado.

En este sentido, el complemento que entrega este test es evidente, en prácticamente todas las comparaciones entre variables es la afirmación de que el consumo de energías renovables mantienen una causalidad bidireccional con las determinantes del desarrollo financiero, confirmando que un crecimiento en la primera, tiende a inducir un crecimiento en la segunda, y viceversa. La excepción está constituida por la eficiencia en las instituciones, donde solo hay un vínculo unidireccional donde el consumo de renovables Granger-cause a la eficiencia de las instituciones, pero no al revés. Es relevante mencionar que debido a paneles con datos faltantes, los índices de acceso en mercados y eficiencia en mercados quedan excluidos del análisis.

Considerando estos resultados, es evidente que una mejora en las condiciones financieras es

un factor que favorece el crecimiento del consumo de energías renovables. Es más, un aumento en el consumo de renovables también contribuye a un sector financiero más sólido. Esta información es de alta utilidad para gestores de política pública y para las industrias energética y financiera, por lo que esa revisión se propone en la siguiente sección.

6.7. Implicancias de Política Pública

Uno de los aspectos más relevantes en el estudio de los vínculos entre el consumo energético y variables macroeconómicas o financieras es la gestión de políticas públicas y toma de decisiones. Esto brinda evidencia empírica a los fenómenos de interés, lo que permite generar un debate informado, integrando a diversos agentes de la sociedad, tales como comunidades, académicos, políticos o para las organizaciones. En esta sección, se proponen algunas medidas puntuales, en línea con los resultados obtenidos de la presente investigación.

Dentro de las componentes que tienen mayor incidencia dentro del crecimiento de energías renovables son las bajas emisiones de CO₂, lo que se remite a una secuencia esperable, el uso de energías limpias tiende a reducir los contaminantes. En coherencia con esto, el efecto de la persistencia en el crecimiento también es fundamental, un crecimiento sostenible del uso de renovables incita a una transformación constante. Es por esto que se recomienda una transición paulatina, considerando aspectos sociales, ambientales y económicos para las naciones.

Asimismo, en lo que respecta a las decisiones económicas, si bien se evidencia un efecto leve del crecimiento del PIB en la transición a renovables, es destacable que un alza responsable no perjudica en la instalación y puesta en marcha de estas tecnologías. Por su parte, en lo que respecta al crecimiento del IPC, se evidencia que una inflación responsable fomenta una transformación de la matriz energética. Por lo que la principal recomendación se centra en ese punto: La salud macroeconómica es de alta importancia para el crecimiento del uso de energías renovables, por

lo que mantener una inflación baja, en conjunto con un desarrollo sostenible, es fundamental para cumplir con este objetivo.

Sobre el desarrollo financiero, al observar su comportamiento general, se percibe que muestra una no linealidad que en su parte positiva, favorece al uso de renovables. Además, al observar los efectos individuales, se nota que un crecimiento (o decrecimiento) leve, no perjudica a la transición energética. Por contraparte, oscilaciones excesivas si pueden generar efectos contraproducentes en el consumo de energías limpias. La recomendación es promover el crecimiento del sector financiero de manera sostenible, tanto para instituciones como para mercados.

El caso de la eficiencia en mercados e instituciones es de alto interés, dado que muestran una relación semejante a una lineal positiva, donde se nota que un sector financiero más robusto tiene efectos importantes en la transición energética, manifestando que las decisiones de política pública orientadas a favorecer y fortalecer el sistema financiero en este aspecto, solo tiene consecuencias positivas para el uso de energías limpias. En esta línea, la recomendación es fomentar políticas que refuercen al sistema financiero, ya que la eficiencia en este sector, se traslada a una transición responsable a energías renovables.

Al observar los resultados de las pruebas de causalidad, se respalda lo sugerido previamente. Existe una relación de retroalimentación general entre el desarrollo financiero y el consumo de energías renovables. Esta evidencia habla del potencial de este vínculo, cuando se utiliza de manera positiva, dado que un crecimiento en una, fomenta el crecimiento en la otra. Si bien, hay en el caso particular de la eficiencia en instituciones se percibe una relación unidireccional, si se nota que el consumo de renovables termina contribuyendo al robustecimiento del sector financiero, lo que permite afectar de manera colateral a las otras componentes que si tienen efecto directo en el fortalecimiento de industrias de energías limpias. La recomendación general es aprovechar



responsablemente el vínculo entre ambas variables, dado que si bien, desde la perspectiva positiva, el crecimiento fomenta una relación virtuosa, también puede mostrar un nexo perjudicial si las decisiones no son adecuadas.

7. Conclusiones

Este estudio ofrece un análisis comparativo entre un marco econométrico tradicional, en específico la estimación System-GMM, con métodos interpretables de ML, enfocado en la configuración del vínculo entre desarrollo financiero y consumo de energías renovables. Mediante el uso de un panel de 83 países en los periodos entre el 2004 y 2021, el análisis incorpora un conjunto de controles económicos y ambientales, incluyendo emisiones de CO₂, PIB, inflación, rentas de recursos naturales y valor agregado de la industria. Asimismo, en lo que respecta al desarrollo financiero, se presenta un enfoque multidimensional, que permite examinar exhaustivamente los efectos individuales de los sistemas financieros en el uso de energías limpias. Todas las variables expresadas en sus formas de primera diferencia, en orden de evitar problemas de no estacionariedad y capturar las dinámicas propias del crecimiento.

A continuación, se presentan las conclusiones del estudio, organizadas en torno a los objetivos planteados en la sección de introducción.

Dentro de las principales contribuciones de este trabajo se encuentran el análisis del vínculo entre el desarrollo financiero y el consumo de energías limpias, mediante una revisión de la literatura, así como en una implementación metodológica amplia, incorporando técnicas econométricas clásicas y el uso de herramientas de ML interpretable, brindando una mayor comprensión al nexo entre estas variables.

Adicionalmente, se identifican las determinantes más influyentes en la transición energética, evidenciando que instituciones y mercados más eficientes permiten una transformación sostenible de la matriz, en busca de energías limpias. Sin embargo, se evidencia que todas las componentes tienen influencia en el fenómeno.

Se brinda una comparación metodológica entre métodos clásicos de datos de panel dinámicos y algoritmos de ML, privilegiando el uso de estos últimos en una labor estimativa, con desempeños superiores en prácticamente todos los conjuntos de variables.

Se determina que la naturaleza del vínculo es no lineal, consolidando patrones con forma de U, previamente estudiadas en la literatura, así como también percibiendo otras estructuras funcionales no mencionadas usualmente. En este sentido, es de alto interés seguir fomentando la comprensión del nexo, mediante la desagregación mayor de variables o el uso de otras para brindar de mayor contexto al fenómeno.

Se evalúa el impacto de variables de control asociadas usualmente con la transición de energías limpias, donde se destaca el rol de las emisiones de CO₂, del crecimiento y la inflación. Asimismo, se obtiene mayor comprensión de las dinámicas subyacentes y fenómenos que permiten el aumento del uso de energías renovables.

Se evidencia una Granger-causalidad bidireccional generalizada para prácticamente todas las variables financieras en relación con el consumo de energías renovables, exceptuando a la eficiencia de instituciones, donde se muestra una relación unidireccional desde el consumo de renovables a esta variable. En general, esto respalda la evidencia encontrada en otros momentos del estudio y fomenta al aprovechamiento de esta relación simbiótica.

Finalmente, se entregan algunas recomendaciones de política pública, en función de los hallazgos de la investigación. Estas se vinculan principalmente con el aprovechamiento de la relación entre bajas emisiones y consumo de renovables, así como fomentar una macroeconomía estable, con crecimiento sostenido e inflación controlada. Además, se enfatiza en que el desarrollo financiero es una herramienta sumamente útil para consolidar el establecimiento de industrias energéticas limpias, haciendo especial énfasis en la necesidad de políticas que promuevan mayor

eficiencia en los sistemas financieros. Por último, se recomienda considerar la relación causal bi-direccional entre el desarrollo financiero y consumo de energías renovables, de tal manera que los efectos positivos de una sean efectivos en la otra.

Existen ciertas limitaciones vinculadas con la investigación, de las que se destaca que la inclusión de la variable dependiente rezagada como regresor es capaz de capturar persistencia en la serie, no obstante, puede ser perjudicial para la comprensión de efectos que se diluyen en el tiempo, tanto en los predictores propuestos, como en otros no considerados en el estudio.

Investigación futura podría extender este trabajo al incluir modelos temporales más avanzados, tales como redes *Long Short-Term Memory* (LSTM) u otras, para capturar dependencias secuenciales. Además, se podrían incluir variables en interacción, de tal forma de capturar efectos indirectos y entre variables de forma explícita. Por último, una división en subpaneles, con criterios vinculados con el nivel de desarrollo o regiones geográficas pueden revelar efectos heterogéneos y respaldar el diseño de política pública enfocados de manera específica.

8. Referencias

- Abdul Bahri, E. N., Shaari Md Nor, A. H., Sarmidi, T., y Haji Mohd Nor, N. H. (2019). The role of financial development in the relationship between foreign direct investment and economic growth: A nonlinear approach. *Review of Pacific Basin Financial Markets and Policies*, 22(02):1950009.
- Alam, M. M., Murshed, M., Ozturk, I., y Khudoykulov, K. (2024). Macroeconomic determinants of non-renewable and renewable energy consumption in india: The roles of international trade, innovative technologies, financial globalization, carbon emissions, financial development, and urbanization. *Energy*, 308:132939.
- Alsagr, N. y van Hemmen, S. (2021). The impact of financial development and geopolitical risk on renewable energy consumption: Evidence from emerging markets. *Environmental Science and Pollution Research*, 28(20):25906–25919.
- Anton, S. G. y Afloarei Nucu, A. E. (2020). The effect of financial development on renewable energy consumption. a panel data approach. *Renewable Energy*, 147:330–338.
- Arellano, M. y Bond, S. (1991). Some tests of specification for panel data: Monte carlo evidence and an application to employment equations. *The Review of Economic Studies*, 58(2):277–297.
- Baloch, M. A., Danish, y Meng, F. (2019). Modeling the non-linear relationship between financial development and energy consumption: statistical experience from OECD countries. *Environmental Science and Pollution Research*, 26(9):8838–8846.
- Blundell, R. y Bond, S. (1998). Initial conditions and moment restrictions in dynamic panel data models. *Journal of Econometrics*, 87(1):115–143.

- Borovykh, A., Bohte, S., y Oosterlee, C. W. (2018). Conditional time series forecasting with convolutional neural networks.
- Botev, J., Égert, B., y Jawadi, F. (2019). The nonlinear relationship between economic growth and financial development: Evidence from developing, emerging and advanced economies. *International Economics*, 160:3–13.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45:5–32.
- Calderón, C. y Liu, L. (2002). The direction of causality between financial development and economic growth. Working Paper 184, Central Bank of Chile, Santiago, Chile.
- Cf, O. (2015). Transforming our world: the 2030 agenda for sustainable development. *United Nations, New York*.
- Chang, L., Qian, C., y Dilanchiev, A. (2022). Nexus between financial development and renewable energy: Empirical evidence from nonlinear autoregression distributed lag. *Renewable Energy*, 193:475–483.
- Chen, C., Pinar, M., y Stengos, T. (2021). Determinants of renewable energy consumption: Importance of democratic institutions. *Renewable Energy*, 179:75–83.
- Chen, T. y Guestrin, C. (2016). Xgboost: A scalable tree boosting system. En *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '16, p. 785–794. ACM.
- Demirtas, C., Tiwari, A. K., Soyu Yıldırım, E., y Shahbaz, M. (2025). Does financial development support renewable energy consumption: Evidence from the uk. *Renewable Energy*, 243:122480.

- Doytch, N., Elheddad, M., y Hammoudeh, S. (2023). The financial kuznets curve of energy consumption: Global evidence. *Energy Policy*, 177:113498.
- Doytch, N. y Narayan, S. (2016). Does fdi influence renewable energy consumption? an analysis of sectoral fdi impact on renewable and non-renewable industrial energy consumption. *Energy Economics*, 54:291–301.
- Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A., y Vapnik, V. (1996). Support vector regression machines. En Mozer, M., Jordan, M., y Petsche, T., editores, *Advances in Neural Information Processing Systems*, volumen 9. MIT Press.
- Duan, T., Avati, A., Ding, D. Y., Thai, K. K., Basu, S., Ng, A. Y., y Schuler, A. (2020). Ngboost: Natural gradient boosting for probabilistic prediction.
- Dumitrescu, E.-I. y Hurlin, C. (2012). Testing for granger non-causality in heterogeneous panels. *Economic Modelling*, 29(4):1450–1460.
- Durusu-Ciftci, D., Soytaş, U., y Nazlıoğlu, S. (2020). Financial development and energy consumption in emerging markets: Smooth structural shifts and causal linkages. *Energy Economics*, 87:104729.
- Esenyel İçen, N. M. (2025). What are the determinants of renewable energy consumption? an application for variable selection. *Renewable Energy*, 239:122029.
- Farhani, S. y Solarin, S. A. (2017). Financial development and energy demand in the united states: New evidence from combined cointegration and asymmetric causality tests. *Energy*, 134:1029–1037.

- Ghoddusi, H., Creamer, G. G., y Rafizadeh, N. (2019). Machine learning in energy economics and finance: A review. *Energy Economics*, 81:709–727.
- Hansen, L. P. (1982). Large sample properties of generalized method of moments estimators. *Econometrica*, 50(4):1029–1054.
- Hansen, P. R., Lunde, A., y Nason, J. M. (2011). The model confidence set. *Econometrica*, 79(2):453–497.
- He, L., Liu, R., Zhong, Z., Wang, D., y Xia, Y. (2019). Can green financial development promote renewable energy investment efficiency? a consideration of bank credit. *Renewable Energy*, 143:974–984.
- Im, K. S., Pesaran, M., y Shin, Y. (2003). Testing for unit roots in heterogeneous panels. *Journal of Econometrics*, 115(1):53–74.
- Jabeur, S., Ballouk, H., Ben Arfi, W., y Khalfaoui, R. (2021). Machine learning-based modeling of the environmental degradation, institutional quality, and economic growth. *Environmental Modeling Assessment*, 27.
- Ji, Q. y Zhang, D. (2019). How much does financial development contribute to renewable energy growth and upgrading of energy structure in china? *Energy Policy*, 128:114–124.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., y Liu, T.-Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. En Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., y Garnett, R., editores, *Advances in Neural Information Processing Systems*, volumen 30. Curran Associates, Inc.

- Khan, A., Chenggang, Y., Hussain, J., y Kui, Z. (2021). Impact of technological innovation, financial development and foreign direct investment on renewable energy, non-renewable energy and the environment in belt road initiative countries. *Renewable Energy*, 171:479–491.
- Kim, J. y Park, K. (2016). Financial development and deployment of renewable energy technologies. *Energy Economics*, 59:238–250.
- King, R. G. y Levine, R. (1993). Finance and growth: Schumpeter might be right. *The Quarterly Journal of Economics*, 108(3):717–737.
- Liu, W., Shen, Y., y Razzaq, A. (2023). How renewable energy investment, environmental regulations, and financial development derive renewable energy transition: Evidence from g7 countries. *Renewable Energy*, 206:1188–1197.
- Lundberg, S. y Lee, S.-I. (2017). A unified approach to interpreting model predictions.
- Mimouni, K. y Temimi, A. (2018). What drives energy efficiency? new evidence from financial crises. *Energy Policy*, 122:332–348.
- Mukhtarov, S., Yüksel, S., y Dinçer, H. (2022). The impact of financial development on renewable energy consumption: Evidence from turkey. *Renewable Energy*, 187:169–176.
- Nasir, M. A., Canh, N. P., y Lan Le, T. N. (2021). Environmental degradation role of financialisation, economic development, industrialisation and trade liberalisation. *Journal of Environmental Management*, 277:111471.
- Nawaz, A. y Rahman, M. M. (2023). Renewable energy consumption in sub-saharan africa: the

role of human capital, foreign direct investment, financial development, and institutional quality.

Energy Reports, 10:3383–3393.

Omri, A. y Nguyen, D. K. (2014). On the determinants of renewable energy consumption: International evidence. *Energy*, 72:554–560.

ONU (2015). Acción por el clima, el acuerdo de París. (Consultado el 22 de Abril 2023) <https://www.un.org/es/climatechange/paris-agreement>.

Ouni, M., Mrad, S., y Mraïhi, R. (2025). Pathways to sustainable transportation in G-20 countries: Unveiling the role of green technology, green energy, green finance and digital economy using panel data and machine learning analyses. *Research in Transportation Business Management*, 60:101355.

Pata, U. K., Yilanci, V., Zhang, Q., y Shah, S. A. R. (2022). Does financial development promote renewable energy consumption in the USA? Evidence from the Fourier-wavelet quantile causality test. *Renewable Energy*, 196:432–443.

Phillips, P. y Perron, P. (1986). Testing for a Unit Root in Time Series Regression. *Cowles Foundation, Yale University, Cowles Foundation Discussion Papers*, 75.

Quan, Z., Xu, X., Jiang, J., Wang, W., y Gao, S. (2024). Uncovering the drivers of ecological footprints: A stirpat analysis of urbanization, economic growth, and energy sustainability in OECD countries. *Journal of Cleaner Production*, 475:143686.

Rafique, M. Z., Doğan, B., Husain, S., Huang, S., y Shahzad, U. (2021). Role of economic complexity to induce renewable energy: Contextual evidence from G7 and E7 countries. *International Journal of Green Energy*, 18(7):745–754.

- Sadorsky, P. (2009). Renewable energy consumption and income in emerging economies. *Energy Policy*, 37(10):4021–4028. Carbon in Motion: Fuel Economy, Vehicle Use, and Other Factors affecting CO2 Emissions From Transport.
- Sadorsky, P. (2010). The impact of financial development on energy consumption in emerging economies. *Energy Policy*, 38(5):2528–2535. Greater China Energy: Special Section with regular papers.
- Schumpeter, J. A. (1911). *The Theory of Economic Development*. Harvard University Press, Cambridge, MA.
- Shahbaz, M., Sinha, A., Raghutla, C., y Vo, X. V. (2022). Decomposing scale and technique effects of financial development and foreign direct investment on renewable energy consumption. *Energy*, 238:121758.
- Shahbaz, M., Topcu, B. A., Sarigül, S. S., y Vo, X. V. (2021). The effect of financial development on renewable energy demand: The case of developing countries. *Renewable Energy*, 178:1370–1380.
- Silva, T. C., Braz, T., y Tabak, B. M. (2024). Mapping the landscape of energy markets research: A bibliometric analysis and predictive assessment using machine learning. *Energy Economics*, 136:107698.
- Svirydzenka, K. (2016). Introducing a new broad-based index of financial development. IMF Working Paper 16/5, International Monetary Fund.
- Tao, M., Sheng, M. S., y Wen, L. (2023). How does financial development influence carbon

- emission intensity in the oecd countries: Some insights from the information and communication technology perspective. *Journal of Environmental Management*, 335:117553.
- Topcu, M. y Payne, J. E. (2017). The financial development–energy consumption nexus revisited. *Energy Sources, Part B: Economics, Planning, and Policy*, 12(9):822–830.
- Usman, M., Balsalobre-Lorente, D., Jahanger, A., y Ahmad, P. (2022). Pollution concern during globalization mode in financially resource-rich countries: Do financial development, natural resources, and renewable energy consumption matter? *Renewable Energy*, 183:90–102.
- Yi, S., Raghutla, C., Chittedi, K. R., y Fareed, Z. (2023). How economic policy uncertainty and financial development contribute to renewable energy consumption? the importance of economic globalization. *Renewable Energy*, 202:1357–1367.
- Yue, S., Lu, R., Shen, Y., y Chen, H. (2019). How does financial development affect energy consumption? evidence from 21 transitional countries. *Energy Policy*, 130:253–262.
- Zhang, Z., Chang, Z., Gan, Y., y Li, J. (2025). Renewable energy, innovation, and stock markets: Machine learning perspectives on environmental sustainability. *International Review of Financial Analysis*, 97:103880.
- Çoban, S. y Topcu, M. (2013). The nexus between financial development and energy consumption in the eu: A dynamic panel data analysis. *Energy Economics*, 39:81–88.

A. Lista de países

El nivel de clasificación según ingreso está basado en la categoría predominante para el periodo de estudio. El país se asigna en cierta categoría si es que permanece la mayor parte del tiempo. Para el caso particular de Paraguay, dado que en primera mitad del periodo pertenecía al nivel medio-bajo y en la segunda mitad es parte del nivel medio-alto, se le asigna la última categoría.

Tabla A.1: Nivel de desarrollo por país

País	Nivel	País	Nivel	País	Nivel
Algeria	2	Angola	1	Argentina	2
Australia	3	Austria	3	Bahamas	3
Bangladesh	1	Barbados	3	Bélgica	3
Bolivia	1	Botswana	2	Brasil	2
Brunei Darussalam	3	Bulgaria	2	Burundi	1
Canadá	3	Chile	3	Colombia	2
Costa Rica	2	Chipre	3	Dinamarca	3
Ecuador	2	El Salvador	1	Finlandia	3
Francia	3	Georgia	1	Alemania	3
Ghana	1	Grecia	3	Guatemala	1
Honduras	1	Hungría	3	Islandia	3
India	1	Indonesia	1	Irlanda	3
Israel	3	Italia	3	Jamaica	2

País	Nivel	País	Nivel	País	Nivel
Japón	3	Jordania	2	Kenia	1
Kuwait	3	Letonia	3	Líbano	2
Lituania	3	Luxemburgo	3	Malasia	2
Malta	3	Mauricio	2	México	2
Mongolia	1	Marruecos	1	Namibia	2
Nueva Zelanda	3	Nigeria	1	Noruega	3
Oman	3	Pakistán	1	Panamá	2
Papua Nueva Guinea	1	Paraguay	2	Perú	2
Filipinas	1	Portugal	3	Rumania	2
Federación Rusa	2	Rwanda	1	Arabia Saudita	3
Seychelles	3	Singapur	3	Sudáfrica	2
España	3	Sri Lanka	1	Santa Lucía	2
Suecia	3	Suiza	3	Tailandia	2
Togo	1	Trinidad y Tobago	3	Túnez	1
Ucrania	1	Emiratos Árabes Unidos	3	Reino Unido	3
Estados Unidos	3	Uruguay	3	Zambia	1

Nota: El Nivel 1 hace referencia a los niveles de desarrollo bajos y medios-bajos. El Nivel 2 refiere a países de ingreso medio-alto. El Nivel 3 alude a aquellos países de mayor ingreso.

B. Hiperparámetros

En cada subsección, se presentan los hiperparámetros seleccionados para los nueve modelos.

B.1. Hiperparámetros para CNN

Tabla B.1: Mejores hiperparámetros de CNN por conjunto de variables (seleccionados mediante GridSearchCV)

Variables Fin.	Filtros	Tamaño del Kernel	Tasa de Aprendizaje	Tamaño de Lote
dln_findevindex	64	3	0.003	32
dln_fininsaccess	64	3	0.003	16
dln_fininsdepth	32	3	0.01	64
dln_fininseff	32	3	0.01	32
dln_fininsindex	32	3	0.01	64
dln_finmarkaccess	32	3	0.003	16
dln_finmarkdepth	32	3	0.01	32
dln_finmarkeff	32	3	0.001	32
dln_finmarkindex	128	3	0.001	32

B.2. Hiperparámetros para SVR

Tabla B.2: Mejores hiperparámetros de SVR por conjunto de variables (seleccionados mediante GridSearchCV)

Variables Fin.	C	Épsilon	Gamma	Kernel
dln_findevindex	0.01	0.01	scale	rbf
dln_fininsaccess	0.1	0.05	scale	rbf
dln_fininsdepth	0.01	0.01	scale	rbf
dln_fininseff	0.01	0.01	scale	rbf
dln_fininsindex	0.01	0.001	scale	rbf
dln_finmarkaccess	0.01	0.01	scale	rbf
dln_finmarkdepth	0.01	0.01	scale	rbf
dln_finmarkeff	0.1	0.05	scale	rbf
dln_finmarkindex	1	0.001	scale	rbf

B.3. Hiperparámetros para LightGBM

Tabla B.3: Mejores hiperparámetros de LightGBM por conjunto de variables (seleccionados mediante GridSearchCV)

VARIABLES FIN.	COLSAMPLE	TASA DE APRENDIZAJE	PROF. MÁX.	ESTIMADORES	HOJAS
dln_findevindex	0.7	0.01	3	300	31
dln_fininsaccess	0.9	0.01	3	300	31
dln_fininsdepth	0.7	0.01	3	300	31
dln_fininseff	0.9	0.01	3	300	31
dln_fininsindex	0.9	0.01	3	300	31
dln_finmarkaccess	0.7	0.01	3	300	31
dln_finmarkdepth	0.9	0.01	3	300	31
dln_finmarkeff	0.9	0.01	3	300	31
dln_finmarkindex	1.0	0.01	3	300	31

Nota: La fila en **negrita** corresponde al modelo seleccionado por el procedimiento MCS como mejor configuración.

B.4. Hiperparámetros para Random Forest

Tabla B.4: Mejores hiperparámetros de Random Forest por conjunto de variables (seleccionados mediante GridSearchCV)

VARIABLES FIN.	PROF. MÁX.	CARACT. MÁX.	MÍN.M.HOJA.	MÍN.M.DIV.	ESTIMADORES
dln_findevindex	5	sqrt	4	10	500
dln_fininsaccess	5	sqrt	4	10	500
dln_fininsdepth	5	sqrt	4	2	500
dln_fininseff	5	sqrt	4	10	500
dln_fininsindex	5	sqrt	4	10	500
dln_finmarkaccess	5	sqrt	4	10	100
dln_finmarkdepth	5	sqrt	4	2	500
dln_finmarkeff	10	sqrt	4	2	500
dln_finmarkindex	5	sqrt	4	2	500

Nota: Las filas en **negrita** corresponden a los modelos seleccionados por el procedimiento MCS como configuración óptima.

B.5. Hiperparámetros para XGBoost

Tabla B.5: Mejores hiperparámetros de XGBoost por conjunto de variables (seleccionados mediante GridSearchCV)

Variables Fin.	csample	T.Aprendizaje	Prof. Máx.	Mín.Hijo	Est.	Submuest.
dln_findevindex	0.9	0.01	3	1	300	1.0
dln_fininsaccess	0.9	0.01	3	1	300	1.0
dln_fininsdepth	0.9	0.01	3	4	300	1.0
dln_fininseff	0.7	0.01	3	1	300	0.7
dln_fininsindex	0.9	0.01	3	1	300	1.0
dln_finmarkaccess	0.7	0.01	3	4	300	0.7
dln_finmarkdepth	0.9	0.01	3	1	300	1.0
dln_finmarkeff	1.0	0.01	3	6	300	0.7
dln_finmarkindex	0.7	0.01	3	1	300	1.0

B.6. Hiperparámetros para NGBoost

Tabla B.6: Mejores hiperparámetros de NGBoost por conjunto de variables (seleccionados mediante GridSearchCV)

Variables Fin.	Est.Base	csample	T.Aprendizaje	minibatch	Est.
dln_findevindex	max_depth=3	0.7	0.01	0.7	300
dln_fininsaccess	max_depth=3	1.0	0.01	0.7	300
dln_fininsdepth	max_depth=3	0.7	0.01	0.7	300
dln_fininseff	max_depth=3	0.7	0.01	0.7	300
dln_fininsindex	max_depth=3	0.7	0.01	0.7	300
dln_finmarkaccess	max_depth=3	0.7	0.01	0.7	300
dln_finmarkdepth	max_depth=3	0.7	0.01	0.7	300
dln_finmarkeff	max_depth=4	0.7	0.01	0.7	300
dln_finmarkindex	max_depth=3	0.7	0.01	1.0	300