



ESCUELA UNIVERSITARIA DE POSGRADO

PRONÓSTICO DE LAS EMISIONES DE DIÓXIDO DE CARBONO EN EL PERÚ EN BASE AL PRODUCTO BRUTO INTERNO, 2022-2028

Línea de investigación:

Biodiversidad, ecología y conservación

Tesis para Optar el Grado Académico de Maestro en Gestión Ambiental y
Minera

Autor

Bejarano Monroy, Giuliano Salvatore

Asesor

Breña Oré, Jorge Luis

ORCID: 0000-0001-6450-7052

Jurado

Gómez Escriba, Benigno Paul

Paricoto Simón, María Mercedes

Rivera Murillo, Jhoana Juliana

Lima - Perú

2026

PRONÓSTICO DE LAS EMISIONES DE DIOXIDO DE CARBONO EN EL PERÚ EN BASE AL PRODUCTO BRUTO INTERNO, 2022-2028

INFORME DE ORIGINALIDAD

15%

INDICE DE SIMILITUD

14%

FUENTES DE INTERNET

6%

PUBLICACIONES

3%

TRABAJOS DEL
ESTUDIANTE

FUENTES PRIMARIAS

1	repositorio.unfv.edu.pe Fuente de Internet	2%
2	www.coursehero.com Fuente de Internet	1%
3	dokumen.pub Fuente de Internet	1%
4	hdl.handle.net Fuente de Internet	1%
5	es.wikipedia.org Fuente de Internet	<1%
6	repositorio.unp.edu.pe Fuente de Internet	<1%
7	evidencia.midis.gob.pe Fuente de Internet	<1%
8	Submitted to Universidad Nacional de San Cristóbal de Huamanga Trabajo del estudiante	<1%
9	centro.paot.org.mx Fuente de Internet	<1%
10	issuu.com Fuente de Internet	<1%
11	Submitted to Universidad San Ignacio de Loyola	<1%



ESCUELA UNIVERSITARIA DE POSGRADO

**PRONÓSTICO DE LAS EMISIONES DE DIÓXIDO DE CARBONO EN EL PERÚ EN
BASE AL PRODUCTO BRUTO INTERNO, 2022-2028**

Línea de investigación

Biodiversidad, ecología y conservación

Tesis para Optar el Grado Académico de
Maestro en Gestión Ambiental y Minera

Autor

Bejarano Monroy, Giuliani Salvatore

Asesor

Breña Oré Jorge Luis
ORCID: 0000-0001-6450-7052

Jurado

Gómez Escriba, Benigno Paul
Paricoto Simón, María Mercedes
Rivera Murillo, Jhoana Juliana

Lima – Perú

2026

Dedicatoria

A mis padres por las enseñanzas en cada etapa de este camino, por creer en mí cuando yo dudaba; a mis hermanas por ser mi sostén incondicional en toda mi travesía. A mí por este gran logro que lleva consigo un sacrificio silencioso. Esta tesis es el fruto de sus enseñanzas ejemplo y su fe constante.

Agradecimientos

Quiero expresar mi más sentido agradecimiento a quienes hicieron posible la realización de esta tesis. A mi asesor por su criterio analítico, apoyo y compartir no solo conocimiento, sino también pasión, paciencia y humanidad; a mis amistades que me brindaron su apoyo emocional. Este logro refleja mi esfuerzo, también el apoyo de quienes creyeron en mí.

Índice

Resumen.....	xi
Abstract.....	xii
I. INTRODUCCIÓN.....	1
1.1. Planteamiento del problema.....	2
1.2. Descripción del problema	2
1.3. Formulación del problema	6
<i>1.3.1. Problema general</i>	6
<i>1.3.2. Problemas específicos</i>	6
1.4. Antecedentes	6
<i>1.4.1. Antecedentes internacionales</i>	6
<i>1.4.2. Antecedentes nacionales</i>	9
1.5. Justificación de la investigación	11
1.6. Limitaciones de la investigación.....	12
1.7. Objetivos de la investigación.....	12
<i>1.7.1. Objetivo general</i>	12
<i>1.7.2. Objetivos específicos</i>	13
1.8 Hipótesis	13
<i>1.8.1. Hipótesis general</i>	13
<i>1.8.2. Hipótesis específicas</i>	13
II. MARCO TEÓRICO	14
2.1. Calentamiento global y cambio climático.....	14
2.2. Causas del calentamiento global y del cambio climático	18
2.3. Efectos del calentamiento global y del cambio climático.....	21
<i>2.3.1. Cuantificación de los efectos: La huella de carbono</i>	22

2.3.2. Efectos en el medio ambiente	23
2.3.3. Efectos en la seguridad alimentaria	26
2.3.4. Efectos en la salud humana.....	30
2.3.5. Efectos económicos	32
2.4. De la Conferencia de Estocolmo (1972) al Acuerdo de París (2015).....	34
2.5. Emisiones de dióxido de carbono y los Objetivos de Desarrollo Sostenible.....	37
2.6. Emisiones de dióxido de carbono y producto bruto interno	39
2.7. La Curva Medioambiental de Kuznets	40
2.8. Perú: Evolución de las emisiones de dióxido de carbono (2001-2021).....	43
2.9. Perú: Evolución del producto bruto interno a precios de 2007 (2001-2021).....	45
2.10. El análisis de regresión lineal	47
2.11. El principio de parsimonia	51
2.12. La precisión de los pronósticos.....	51
2.13. El sesgo en los pronósticos	52
2.14. El concepto de elasticidad.....	53
III. MÉTODO	55
3.1. Tipo de investigación.....	55
3.2. Población y muestra.....	55
3.2.1 Población	55
3.2.2 Muestra	56
3.3. Operacionalización de variables	57
3.4. Instrumentos.....	58
3.5. Procedimientos.....	58
3.5.1. Hipótesis General: El Pronóstico de las Emisiones de CO ₂ en el Perú Tendrá una Tendencia Creciente en el Espacio Temporal 2022-2028.....	58

3.5.2. Hipótesis Específica 1: En el Perú las Emisiones de CO ₂ y el PBI Muestran una Relación Positiva en el Lapso 2005-2021	60
3.5.3. Hipótesis Específica 2: En el Perú las emisiones de CO ₂ Son Inelásticas con Respecto al PBI en los Años 2005-2021	60
3.5.4. Hipótesis Específica 3: Las Estimaciones de las Emisiones de CO ₂ en el Perú Presentan una Precisión Muy Buena ($MAPE \leq 10\%$) Entre los Años 2005-2021	61
3.5.5. Hipótesis Específica 4: Las Estimaciones de las Emisiones de CO ₂ en el Perú Son Inseguras Durante el Periodo 2005-2021	61
3.6. Análisis de datos	62
IV. RESULTADOS	63
4.1. Hipótesis general.....	63
4.2. Hipótesis específica 1	69
4.3. Hipótesis específica 2	70
4.4. Hipótesis específica 3	71
4.5. Hipótesis específica 4	72
V. DISCUSIÓN DE RESULTADOS	74
5.1. Hipótesis general.....	74
5.2. Hipótesis específica 1	75
5.3. Hipótesis específica 2	77
5.4. Hipótesis específica 3	80
5.5. Hipótesis específica 4	82
VI. CONCLUSIONES.....	83
VII. RECOMENDACIONES	84
VIII. REFERENCIAS.....	86
IX. ANEXOS	119

Anexo A. Matriz de Consistencia	119
Anexo B. Validación y Confiabilidad de Instrumentos	120
Anexo C. Fichas Técnicas de las Variables	121

Índice de Tablas

Tabla 1. Marcos metodológicos para el cálculo de la huella de carbono	23
Tabla 2. Supuestos MCO, medios de verificación, criterios de decisión y medidas remediales	50
Tabla 3. Precisión del pronóstico de acuerdo al valor del MAPE	51
Tabla 4. Operacionalización de las variables	57
Tabla 5. Validación de los supuestos MCO en modelos L-CO ₂ sobre L-PBI por periodo.....	63
Tabla 6. Perú: Variación real del PBI (2024-2028)	68

Índice de Figuras

Figura 1. Efecto invernadero natural y efecto invernadero incrementado (antropogénico)	15
Figura 2. Emisiones globales de CO ₂ en gigatoneladas (1751-2022).....	16
Figura 3. Emisiones de CO ₂ acumuladas (1750-2021) y per cápita (2021) en países seleccionados.....	16
Figura 4. Concentración de CO ₂ atmosférico en ppm (1751-2022)	17
Figura 5. Gramos de CO ₂ para generar 1 kWh de electricidad según tipo de energía.....	20
Figura 6. Actividades liberadoras de gases de efecto invernadero	22
Figura 7. Perú: Número de distritos expuestos a eventos climáticos extremos	26
Figura 8. Perú: Vulnerabilidad de la seguridad alimentaria según distrito.....	29
Figura 9. Efectos del cambio climático en la salud humana	30
Figura 10. Los objetivos de desarrollo sostenible.....	38
Figura 11. La curva medioambiental de Kuznets	41
Figura 12. Perú: Evolución y variación de las emisiones de CO ₂ (2001-2021)	43
Figura 13. Perú: Evolución y variación de las emisiones de CO ₂ per cápita (2001-2021).....	44
Figura 14. Perú: Participación de las emisiones de CO ₂ por fuente energética (2001-2021) ..	44
Figura 15. Perú: Participación de las emisiones de CO ₂ por sector económico (2001-2021) .	45
Figura 16. Perú: Evolución y variación del PBI a precios de 2007 (2001-2021)	46
Figura 17. Perú: Evolución y variación del PBI per cápita a precios de 2007 (2001-2021) ...	46
Figura 18. El sesgo de los pronósticos (a) Sesgo positivo y (b) Sesgo negativo.....	52
Figura 19. Pronóstico: Combinaciones posibles entre precisión y sesgo	53
Figura 20. Modelo MCO L-CO ₂ sobre L-PBI (2005-2021) y valores p de las pruebas de linealidad (cuadrados y logaritmos), especificación correcta, homocedasticidad y normalidad.....	64

Figura 21. Modelo MCO L-CO ₂ sobre L-PBI (2005-2021): Estadístico “d” de Durbin-Watson para autocorrelación	65
Figura 22. Modelo MCO L-CO ₂ sobre L-PBI (2005-2021): Valores críticos d_L y d_U de la prueba de Durbin-Watson de autocorrelación.....	65
Figura 23. Modelo MCO L-CO ₂ sobre L-PBI (2005-2021): Resultado de la prueba de Durbin-Watson de autocorrelación	66
Figura 24. Modelo MCO L-CO ₂ sobre L-PBI (2005-2021): Resultado de la prueba gráfica CUSUM de estabilidad paramétrica.....	66
Figura 25. Modelo MCO L-CO ₂ sobre L-PBI (2005-2021): Resultado de la prueba gráfica CUSUMSQ de estabilidad paramétrica.....	67
Figura 26. Modelo MCO L-CO ₂ sobre L-PBI (2005-2021): Resultado de las pruebas t de significancia individual y coeficiente de determinación (R^2)	68
Figura 27. Perú: Emisiones de CO ₂ observado (2005-2021) y pronosticado (2022-2028) en miles de t	69
Figura 28. Modelo MCO L-CO ₂ sobre L-PBI (2005-2021): Signo de la variable L-PBI	70
Figura 29. Modelo MCO L-CO ₂ sobre L-PBI (2005-2021): Elasticidad CO ₂ - PBI.....	70
Figura 30. Perú: Emisiones de CO ₂ observado y estimado (2005-2021) en miles de t	71
Figura 31. Error absoluto porcentual de las emisiones de CO ₂ estimadas y MAPE (2005-2021)	71
Figura 32. Error y sesgo de las emisiones de CO ₂ estimadas (2005-2021)	72
Figura 33. Resultado de las pruebas de normalidad para los errores de la estimación.....	72
Figura 34. Resultado de la prueba t de media igual a cero para los errores de la estimación..	73

Resumen

Esta tesis estimó la tendencia del pronóstico de las emisiones de CO₂ en el Perú en el lapso 2022-2028. Asimismo, estableció la relación entre emisiones de CO₂ y PBI. Igualmente, precisó el tipo de elasticidad que existe entre emisiones de CO₂ y PBI. También, calculó la precisión de las estimaciones de las emisiones de CO₂. Finalmente, determinó el sesgo de las estimaciones de las emisiones de CO₂. Se acopiaron series temporales de emisiones de CO₂ (variable dependiente) y PBI a precios del 2007 (variable independiente) para el periodo 2001-2021. Se elaboraron, comprobaron y enmendaron los modelos de regresión lineal empleando el software Gretl. Se encontró que el modelo elaborado con la información del intervalo 2005-2021 (17 años) cumplió con todos los supuestos MCO, fue significativo y exhibió suficiente poder explicativo ($R^2 = 95,03\%$). Según los resultados, se estimó que la tendencia del pronóstico de las emisiones de CO₂ en el Perú durante 2022-2028 será creciente, a una tasa de 2,25% anual. Asimismo, se estableció una relación positiva ($\beta = 0,924$, valor $p = 3,47 \times 10^{-11}$) entre emisiones de CO₂ y PBI. Igualmente, se precisó que las emisiones de CO₂ son inelásticas con respecto al PBI, la expansión del PBI en 1% incrementa las emisiones de CO₂ en 0,924%. También, las estimaciones de las emisiones de CO₂ presentaron una precisión muy buena (MAPE = 3,78%). Finalmente, se determinó un sesgo no significativo de 31,47 (valor $p = 0,929$), por tanto, las estimaciones de las emisiones de CO₂ son insesgadas.

Palabras clave: calentamiento global, cambio climático, emisiones de CO₂, regresión lineal.

Abstract

This thesis estimated the forecast trend of CO₂ emissions in Peru in the period 2022-2028. Likewise, the relationship between CO₂ emissions and GDP was established. Similarly, the type of elasticity that exists between CO₂ emissions and GDP was specified. Also, the precision of the CO₂ emissions estimates was calculated. Finally, the bias of the CO₂ emissions estimates was determined. Time series of CO₂ emissions (dependent variable) and GDP at 2007 prices (independent variable) were collected for the period 2001-2021. Linear regression models were constructed, checked, and amended using Gretl software. It was found that the model prepared with information from the 2005-2021 interval (17 years) met all OLS assumptions, was significant and exhibited sufficient explanatory power ($R^2 = 95,03\%$). According to the results, it was estimated that the forecast trend of CO₂ emissions in Peru during 2022-2028 will be increasing, at a rate of 2,25% annually. Likewise, a positive relationship ($\beta = 0,924$, p value = $3,47 \times 10^{-11}$) was established between CO₂ emissions and GDP. Similarly, it was specified that CO₂ emissions are inelastic with respect to GDP, the expansion of GDP by 1% increases CO₂ emissions by 0,924%. Also, the estimates of CO₂ emissions presented very good precision (MAPE = 3,78%). Finally, a non-significant bias of 31,47 was determined (p value = 0,929), therefore the estimates of CO₂ emissions are unbiased.

Keywords: *climate change, CO₂ emissions, global warming, linear regression.*

I. INTRODUCCIÓN

Durante décadas las diversas actividades desarrolladas por la humanidad han generado ingentes cantidades de gases de efecto invernadero (GEI), en especial dióxido de carbono (CO_2), que han dado lugar a la sobreacumulación de CO_2 en la atmósfera. Ciertamente, en la atmósfera se requiere de cierta cantidad de CO_2 que mantenga una temperatura adecuada para viabilizar la vida en la Tierra. Sin embargo, la acumulación excesiva de CO_2 ha ocasionado calentamiento global (CG) y cambio climático (CC). Fenómenos relacionados que han puesto en peligro la vida sobre la faz de la Tierra.

Si bien los países industrializados son los mayores emisores de CO_2 y, por tanto, son los principales responsables del CG y CC, todo el planeta sin excepción, sufre y sufrirá las consecuencias negativas. En especial los países en vías de desarrollo, que aunque sus emisiones de CO_2 solo representan una pequeña fracción, padecen y padecerán los efectos más severos, dada su muy limitada capacidad de mitigación y adaptación al CG y CC. En este contexto, por sus condiciones geográficas, el Perú es considerado como un país extremadamente vulnerable al CC, por lo cual padecerá las consecuencias más implacables; a pesar de solo ser responsable del 0,4% de las emisiones mundiales de GEI.

Aunque se están haciendo esfuerzos globales para limitar las emisiones de CO_2 y así mitigar sus efectos nocivos (por ejemplo, el Acuerdo de París de 2015), los pronósticos no son alentadores, año tras año las emisiones globales de CO_2 son cada vez mayores. Esto en gran parte por la existencia de una relación directa entre las emisiones de CO_2 y el crecimiento económico medido a través del Producto Bruto Interno (PBI).

Por un lado, un crecimiento económico suficiente y sostenido conlleva al desarrollo de un país y, por consiguiente, a mejorar los niveles de vida de las personas. Por otro lado, el crecimiento económico requiere del funcionamiento de un aparato productivo, el cual genera

grandes cantidades de CO₂, en particular en economías no tan desarrolladas o en vías de desarrollo como la peruana.

1.1 Planteamiento del problema

Las emisiones de GEI es uno de los problemas más alarmantes del mundo (Furkan et al., 2023). El CG inducido por la emisión de GEI, especialmente CO₂, tiene el mayor impacto en el CC (Das et al., 2021). Las emisiones de CO₂ explican alrededor del 66% del total de emisiones de GEI actuales (United Nations Environment Programme [UNEP], 2023).

En las últimas dos décadas CG y CC han sido las principales preocupaciones mundiales (Shahbaz et al., 2023). El CG altera y afecta negativamente al medioambiente y obstaculiza y modifica el funcionamiento de los ecosistemas, la sociedad humana y las vidas (Udemba, 2023). Por su parte, el CC afecta la salud humana de muchas maneras, causando enfermedades y muerte (Malkhazova et al., 2023).

Globalmente, 50 son las naciones más afectadas por el CC, 13 de ellas se encuentran en América Latina y el Caribe (Organización para la Cooperación y el Desarrollo Económico [OCDE] et al., 2022).

1.2 Descripción del problema

Los GEI se forman cada vez que la atmósfera absorbe demasiado CO₂, monóxido de carbono, óxido nitroso y otros gases (Alaganthiran y Anaba, 2022). La concentración de GEI es más alta ahora que en los pasados 80 000 años, debido al uso de combustibles fósiles desde el comienzo de la Revolución industrial, y al proceso de deforestación (McPhaden et al., 2021).

El CO₂ es uno de los más importantes GEI y el incremento de su concentración es causa directa del CG y del CC (Ferrer et al., 2023). Así, la concentración global atmosférica de CO₂ se ha incrementado de 280 ppm en 1750 a más de 420 ppm en 2021 (Li et al., 2023). El último nivel de concentración de CO₂ superior a 400 ppm ocurrió hace 3 millones de años, cuando la temperatura global promedio y el nivel del mar eran significativamente mayores (Bergmann et

al., 2021; US Global Change Research Program [USGCRP], 2017). Se espera que para el año 2047 se alcance una concentración de 500 ppm, lo cual constituiría un punto de no retorno (Bhatt et al., 2023). Más aún, de acuerdo a los pronósticos del IPCC, el nivel de CO₂ puede llegar a 590 ppm y la temperatura global promedio puede aumentar en 1,9°C para el 2100 (Li et al., 2023).

A nivel global, entre 3 300 y 3 600 millones de personas son altamente vulnerables al CC (Intergovernmental Panel on Climate Change [IPCC], 2023). Asimismo, al 2030 el CC podría llevar a la situación de pobreza extrema a entre 32 y 132 millones de personas (Jafino et al., 2020), de las cuales entre 2,4 y 5,8 millones serían de América Latina y el Caribe (Banco de desarrollo de América Latina y el Caribe [CAF], 2023). Además, se espera que en el intervalo 2030-2050 el CC origine alrededor de 250 000 muertes adicionales anuales debido a malaria, diarrea, desnutrición y olas de calor en los países en vías de desarrollo (IPCC, 2022).

Por su parte, el Perú es extremadamente vulnerable a los efectos del CC (Bergmann et al., 2021; López et al., 2023; Ministerio del Ambiente [MINAM], 2020; Pinzón, 2024; Trinidad y Soberón, 2021; Villarroel et al., 2021). El Perú presenta siete de las nueve características de vulnerabilidad identificadas por la Convención Marco de las Naciones Unidas sobre el Cambio Climático (UNFCCC, por sus siglas en inglés): 1) áreas costeras bajas, 2) áreas áridas y semiáridas, 3) zonas susceptibles de deforestación o erosión, 4) zonas susceptibles de desastres naturales, 5) zonas susceptibles de sequías y desertificación, 6) áreas urbanas altamente contaminadas y 7) ecosistemas frágiles (MINAM, 2020; Trinidad y Soberón, 2021).

Adicionalmente, más del 50% de la población peruana habita en zonas altamente vulnerables a desastres relacionados con el clima y el CC (Bergman et al., 2021; World Food Programme [WFP], 2024). Más de 9 millones están expuestos a precipitaciones intensas, inundaciones y deslizamientos de tierra; 7 millones a temperaturas bajas y muy bajas, y cerca

de 3,5 millones a sequías (Bergmann et al., 2021). Al 2050 los costos económicos del CC llegarán al 20% del Producto Bruto Interno (PBI) peruano (Altamirano, 2020).

De otro lado, el 10% de la población con más alto ingreso produce el 48% de las emisiones de GEI globales (cerca del 66% vive en países desarrollados), en tanto solo el 12% de las emisiones es originado por el 50% más pobre (UNEP, 2023).

Paradójicamente, los países más pobres y vulnerables, y los que menos han aportado al CC son los que soportan y soportarán los impactos más severos (Bathiany et al., 2018; Fanzo y Miachon, 2023; Usher, 2022). En efecto, la participación conjunta en las emisiones de CO₂ de los 10 países más impactados por el CC (Somalia, Madagascar, Burkina Faso, Kenia, Níger, Yibuti, Zimbabue, Guatemala, Haití y Afganistán) apenas es el 0,13% (Oxford Committee for Famine Relief [OXFAM], 2022).

Además, en el lapso 1970-2021 los desastres imputados a fenómenos meteorológicos, climáticos y extremos del agua originaron más de 2 millones de muertes y pérdidas económicas por US\$ 4,3 billones, más del 90% de las muertes y el 60% de las pérdidas económicas ocurrió en países en vías de desarrollo (World Meteorological Organization [WMO], 2023).

Por otro lado, la responsabilidad de un país al CC depende de sus emisiones de CO₂ acumuladas en el tiempo (CAF, 2023). Así, en el periodo 1850-2021, el mayor emisor de CO₂ fue EEUU (19%), seguido de China (13%), la Unión Europea (13%), Rusia (5%) e India (4%), mientras que los países menos desarrollados aportaron el 4% (UNEP, 2023).

En 2022 las emisiones de GEI alcanzaron las 57,4 Gt (+1,06% respecto del 2021), de los cuales 38,5 Gt (+1,06% respecto del 2021) correspondieron a emisiones de CO₂ (UNEP, 2023). América Latina y el Caribe representa el 10% del total de emisiones GEI (CAF, 2023), mientras que el Perú aporta el 0,4% (Blanco-Villafuerte y Hartinger, 2023; MINAM, 2023).

Por su cuenta, en el lapso 1850-2022, las emisiones de CO₂ sumaron 2 550 Gt, de las cuales el 70% se acumuló en el periodo 1960-2022 y el 33% lo hizo entre 2000-2022

(Friedlingstein et al., 2023). La existencia de una relación directa entre emisiones de CO₂ y CG, origina que por cada 1 000 Gt de CO₂ antropogénico la temperatura global media se incremente entre 0,27°C y 0,63°C (IPCC, 2023).

De otro lado, el Acuerdo de París de diciembre 2015 tiene como objetivo mantener el incremento global de temperatura en el rango de entre 1,5°C y 2°C (Shahbaz et al., 2023), para lo cual la emisión de GEI debiera reducirse entre 30% y 45% al 2030 y las emisiones de CO₂ deberían acercarse al cero neto al 2050 (WMO, 2023).

No obstante, para evitar un desastre mundial, las emisiones deberían reducirse en 45% (Bayram et al., 2023; Fanzo y Miachon, 2023). Se espera que los impactos negativos de un CG entre 1,5°C y 2°C se hagan globales y empeoren con la reducción de la producción de alimentos, la desaceleración económica, el incremento de la desigualdad y la pobreza, la pérdida de biodiversidad, el aumento de la morbilidad humana y la mortalidad (Benschop et al., 2023).

En tal contexto, en 2020 el Perú asumió el reto de disminuir en 30% las emisiones de GEI pronosticadas para el año 2030, pudiendo incrementarse a 40% en caso de concretarse financiamiento externo no reembolsable (MINAM, 2020). Sin embargo, aún con reducciones considerables en las emisiones globales de GEI, el CC impactará severamente en Perú (Bergmann et al., 2021).

A pesar de todo, el mundo no está enfocado en lograr los objetivos del Acuerdo de París, al 2100 la temperatura global puede aumentar en 2,8°C (Akhtar, 2023) o incluso podría incrementarse entre 2,9°C y 3,4°C (Bergmann et al., 2021). En septiembre de 2023, la temperatura media global estuvo 1,8°C por encima de la era pre-industrial (UNEP, 2023).

Por otro lado, en razón de sus graves efectos muchos países han pronosticado sus emisiones de CO₂ (Segar et al., 2024). Dado que un pronóstico preciso facilita la elección de la manera óptima en que debe reducirse las emisiones de CO₂ (Chukwunonso et al., 2024; Meng y Noman, 2022). También, juega un rol importante en la determinación de los picos de

las emisiones y en la elaboración de políticas carbono-neutral (Wang et al., 2023). Asimismo, ayuda a los gobiernos a optimizar sus planes y políticas energéticas (Boontome et al., 2019).

1.3 Formulación del problema

1.3.1 Problema general

- ¿Qué tendencia tendrá el pronóstico de las emisiones de CO₂ en el Perú en el espacio temporal 2022-2028?

1.3.2 Problemas específicos

- ¿Qué relación existe en el Perú entre las emisiones de CO₂ y el PBI en el lapso 2005-2021?
- ¿Qué tipo de elasticidad existe en el Perú entre las emisiones de CO₂ y el PBI en los años 2005-2021?
- ¿Cuál es la precisión de las estimaciones de las emisiones de CO₂ en el Perú entre los años 2005-2021?
- ¿Son sesgadas las estimaciones de las emisiones de CO₂ en el Perú durante el periodo 2005-2021?

1.4 Antecedentes

1.4.1 Antecedentes internacionales

Choi y Abdullah (2016), evaluaron el desempeño de dos técnicas de regresión en pronosticar las emisiones de CO₂ en Malasia (1981-2005). Las técnicas fueron regresión lineal difusa posibilista (RLDP) y regresión lineal múltiple (RLM). En ambas técnicas la variable dependiente fue emisiones de CO₂. En la técnica RLDP las variables independientes fueron mezcla de combustible (X₁), transporte (X₂), Producto Bruto Interno (PBI, X₃) y población (X₄). En cambio, en la técnica RLM las variables independientes fueron transporte (X₂) y PBI (X₃). En la técnica RLM se encontró significancia estadística en las variables transporte (valor $p = 0,001$) y PBI (valor $p = 0,040$), y un poder explicativo de 69,10%. Además, se halló una

relación positiva entre emisiones de CO₂ y las variables transporte ($\beta_2 = 0,792$) y PBI ($\beta_3 = 0,685$). De acuerdo al error medio absoluto porcentual (MAPE, por sus siglas en inglés) y a la raíz cuadrada media del error (RMSE, por sus siglas en inglés), la técnica RLM tuvo los errores más pequeños y por ende presentó el mejor desempeño. Los investigadores no evaluaron el cumplimiento de los supuestos del análisis de regresión lineal múltiple.

Cederborg y Snöbohm (2016), examinaron la relación entre el PBI per cápita y las emisiones per cápita de CO₂ en 69 países industrializados y en 45 países pobres. Por tal motivo, con datos de corte transversal del Banco Mundial del año 2012, construyeron modelos de regresión lineal para ambos grupos de países. Los investigadores encontraron una relación positiva entre PBI per cápita y emisiones per cápita de CO₂, tanto en los países industrializados como en los países pobres. Es decir, el incremento del PBI per cápita produjo el aumento de las emisiones de CO₂. En cuanto a la verificación del cumplimiento de los supuestos del análisis de regresión lineal, solo se comprobó el supuesto de no multicolinealidad.

Hosseini et al. (2019), pronosticaron las emisiones de CO₂ en Irán (2015-2030) suponiendo dos escenarios. El primer escenario consideró cambios no significativos en las políticas de gobierno. Por su parte, el segundo escenario tomó en cuenta los objetivos del Sexto plan quinquenal de desarrollo de Irán (2016-2021). Para el desarrollo de los modelos de pronóstico, se utilizó información histórica del Banco Mundial (1971-2014) y se aplicaron dos técnicas: regresión lineal múltiple (RLM) y regresión polinomial múltiple (RPM). La variable dependiente fue emisiones de CO₂, mientras que las variables independientes fueron población (X_1), intensidad de CO₂ (X_2), PBI per cápita (X_3), producción de electricidad de fuentes fósiles (X_4) y uso de energía per cápita (X_5). Según el modelo RLM, se halló una relación positiva entre emisiones de CO₂ y PBI per cápita ($\beta_3 = 6,7$). Y, de acuerdo a los resultados del modelo RLM, el pronóstico para el primer escenario fue 671 450 kt (2017) y 730 595 kt (2030). En cambio, el pronóstico para el segundo escenario fue 610 771 kt (2017) y 315 739 kt (2030).

Los investigadores no reportaron el resultado de las pruebas de significancia, ni tampoco confirmaron el cumplimiento de los supuestos del análisis de regresión lineal.

Zhang (2022), evaluó la relación entre las emisiones de CO₂, el PBI y la población en China. Para lo cual, con series de tiempo del Banco Mundial (1960-2020) se construyó un modelo de regresión múltiple, en donde la variable dependiente fue emisiones de CO₂ (Y) y las variables independientes fueron población (X₁) y PBI (X₂). El autor encontró alta correlación de las emisiones de CO₂ tanto con la población ($r=0,86$) como con el PBI ($r=0,93$). También, ambas variables resultaron altamente significativas y se halló una relación positiva entre las emisiones de CO₂ y la población ($\beta_1 = 0,4243$) y el PBI ($\beta_2 = 0,6405$). Además, el modelo mostró un alto poder explicativo ($R^2 = 95,90\%$). En consecuencia, el incremento de la población y del PBI aumentó las emisiones de CO₂. Sin embargo, el investigador no verificó el cumplimiento de los supuestos del análisis de regresión lineal múltiple.

Tleppayev y Zeinolla (2023), estudiaron la relación entre las emisiones de CO₂ per cápita y el PBI per cápita en Kazakstán. Por tal motivo, los investigadores utilizaron series de tiempo (1999-2000) del Banco Mundial y de la Oficina de Estadísticas Nacionales para la elaboración de un modelo de regresión múltiple, en el cual la variable dependiente fue el logaritmo natural (ln) de las emisiones per cápita de CO₂ (ln CO₂) y las variables independientes fueron ln del PBI per cápita (ln PBI) y ln del consumo de electricidad per cápita (ln CE). Se encontró significancia estadística al 10% en ln PBI (valor $p = 0,053$) y en ln CE (valor $p = 0,003$), y la relación entre ln CO₂ y ln PBI fue positiva ($\beta_1 = 0,088$), por lo que el incremento en 1% en el PBI produce el aumento de las emisiones de CO₂ en 0,088%. No se reportó el poder explicativo del modelo. En cuanto a la corroboración del cumplimiento de los supuestos del análisis de regresión lineal, solo se confirmó el supuesto de no multicolinealidad.

Jeevanasai y Hegde (2023), pronosticaron las emisiones de CO₂ en la India para el año 2019. En la elaboración de un modelo de regresión lineal múltiple, los investigadores utilizaron

datos (1995-2018) de la Agencia internacional de energía (IEA, por sus siglas en inglés). En el modelo, la variable dependiente fue emisiones de CO₂, mientras que las variables independientes fueron: año (X₁), población (X₂) y consumo de electricidad (X₃). Se encontró una relación positiva entre las emisiones de CO₂ y las variables año ($\beta_1 = 198,5318$) y consumo de electricidad ($\beta_3 = 0,2161$), en cambio para la variable población, la relación fue negativa ($\beta_2 = -7,7402$). Por último, suponiendo que la población será de 1 370 millones y que el consumo de electricidad alcanzará los 1 673 TWh, las emisiones de CO₂ en 2019 bordearán las 2 476 toneladas métricas. Los autores no confirmaron el cumplimiento de los supuestos del análisis de regresión lineal múltiple, ni tampoco reportaron el resultado de las pruebas de significancia.

1.4.2 Antecedentes nacionales

Moreno (2018), examinó la relación entre diversos contaminantes atmosféricos per cápita (CO₂, monóxido de carbono, CO, óxido de nitrógeno, NO_x, partículas contaminantes, metano, CH₄, y óxido de azufre, SO_x) y las variables PBI per cápita y coeficiente de desigualdad de Gini. Para la construcción de los modelos de regresión lineal múltiple (1990-2015), el autor obtuvo el coeficiente de Gini del Banco Mundial, mientras que la fuente de las demás variables fue el Instituto Nacional de Estadística e Informática (INEI). De acuerdo al valor p, se encontró evidencia de significancia estadística entre el PBI per cápita y los contaminantes: CO₂, CO, NO_x, partículas contaminantes y CH₄. De otro lado, el coeficiente de Gini resultó significativo solo para el CH₄. Respecto del CO₂, se descubrió una relación positiva ($\beta_1 = 135,7013$) con el PBI per cápita, por lo cual el incremento del PBI per cápita en una unidad produciría un aumento de la contaminación por CO₂ en alrededor de 136 veces. Respecto de la no violación de los supuestos del análisis de regresión lineal, se verificó el supuesto de estabilidad paramétrica y el de no autocorrelación.

Choquehuanca et al. (2022), investigaron la relación entre las emisiones de los contaminantes ambientales CO₂ y óxido nitroso (N₂O), y el PBI. Para la construcción de los

modelos de regresión lineal (1990-2015), los autores obtuvieron las emisiones de CO₂ y N₂O del Ministerio de Energía y Minas (MINEM), mientras que la fuente del PBI fue el Banco Central de Reserva del Perú (BCRP). Se encontró una relación lineal positiva entre emisiones de CO₂ y PBI ($\beta_1 = 0,05875$, $r^2 = 76,85\%$). Asimismo, la relación entre N₂O y PBI fue lineal positiva ($\beta_1 = 0,00024$, $r^2 = 91,35\%$). En cuanto al cumplimiento de los supuestos del análisis de regresión lineal, solo se comprobó y remedió el supuesto de no autocorrelación.

Fernández (2024), evaluó la relación de las variables PBI per cápita y tasa de crecimiento poblacional (TCP) con las emisiones de CO₂ per cápita. Por tal motivo, se utilizó información estadística (1990-2019) del Banco Mundial para la construcción de un modelo de regresión múltiple. El autor encontró significancia estadística en la variable Ln PBI per cápita (valor $p = 0,000$), pero no en la variable TCP (valor $p = 0,144$). Seguidamente, se construyó un modelo de regresión simple. En el nuevo modelo, variable Ln PBI per cápita resultó nuevamente estadísticamente significativa (valor $p = 0,000$), además el modelo presentó un alto poder explicativo ($r^2 = 86,05\%$). Por otro lado, la relación entre el CO₂ per cápita y Ln PBI per cápita fue positiva ($\beta_1 = 0,5648927$). En relación a los supuestos, en el modelo simple se verificó correctamente la no violación de los supuestos de normalidad y de homocedasticidad, además se encontró autocorrelación, pero se corrigió. De otro lado, el supuesto de especificación correcta fue erróneamente validado. Finalmente, no se corroboró el cumplimiento de los supuestos de linealidad paramétrica y estabilidad paramétrica.

Infante y Suarez (2024), estudiaron la influencia del PBI per cápita en la emisión de CO₂ per cápita y la validez de la curva medioambiental de Kuznets. Así, con series temporales (1970-2020) del PBI per cápita del BCRP y del CO₂ per cápita del INEI, los investigadores elaboraron un modelo de regresión cuadrático log-log. Según los resultados, no se encontró significancia estadística ni en la variable Ln PBI per cápita (valor $p = 0,1728$) ni en la variable Ln PBI² per cápita (valor $p = 0,2594$). Por lo cual, no se pudo probar la influencia del PBI per

cápita en la emisión de CO₂ per cápita, ni tampoco el cumplimiento de la curva medioambiental de Kuznets. En cuanto a los supuestos, se verificó correctamente la no violación de los supuestos de homocedasticidad y de normalidad. El supuesto de no autocorrelación fue erróneamente validado. Finalmente, no se corroboró el cumplimiento de los supuestos de linealidad paramétrica, especificación correcta, estabilidad paramétrica y no colinealidad.

1.5 Justificación de la investigación

Dada la magnitud global de los diversos efectos negativos ocasionados por los GEI, en especial por las emisiones de CO₂, nacional e internacionalmente se han realizado numerosas investigaciones utilizando el análisis de regresión lineal para modelar el comportamiento de las emisiones de CO₂, empleando como variables independientes al PBI, PBI per cápita, población, tasas de crecimiento poblacional, uso de energía per cápita, etc.

Unos estudios se enfocaron en pronosticar las emisiones de CO₂, mientras que en otros se estimó la relación, positiva o negativa, entre las emisiones de CO₂ y una o más variables independientes. No obstante, en ninguno de los estudios encontrados se corroboró el cabal cumplimiento de todos los supuestos del análisis de regresión lineal, por lo tanto, no se realizó correctamente las pruebas de significancia estadística. En consecuencia, los resultados y conclusiones de tales estudios podrían no ser confiables y podrían no ser la mejor referencia para la toma de decisiones.

En la presente investigación también se empleará el análisis de regresión lineal para modelar las emisiones de CO₂. La diferencia radica en que el modelo construido se someterá a todas las pruebas estadísticas pertinentes para corroborar el cumplimiento de todos los supuestos. En caso el modelo viole uno o más supuestos, se aplicará la medida correctiva correspondiente. Luego, se probará la significancia estadística de los parámetros del modelo. Solo después se procederá a realizar el pronóstico de las emisiones de CO₂ para el periodo 2022-2028 y se analizarán e interpretarán los resultados.

1.6 Limitaciones de la investigación

- La investigación se centró en las emisiones de CO₂. Aunque los GEI se componen de varios gases y por tanto no se limitan a las emisiones de CO₂, éste es el componente primordial de los GEI y en consecuencia es el principal generador del CG y CC. Por tal motivo, muchos estudios, que han utilizado el análisis de regresión lineal y otros métodos, han empleado las emisiones de CO₂ como variable dependiente.
- Inicialmente, para la construcción del modelo de regresión se utilizará series temporales del lapso 2001-2021. En el más reciente Anuario de estadísticas ambientales del INEI (2023), se ha registrado las emisiones de CO₂ solo hasta el año 2021. Según lo programado, los Anuarios se publican en diciembre de cada año y contiene información de las emisiones de CO₂ con un retraso de dos años. Sin embargo, dado que se requiere construir un modelo de regresión que satisfaga todos los supuestos MCO, que sea significativo y que exhiba suficiente poder explicativo; es posible que la extensión de las series temporales utilizadas sea menor a la inicial, es decir el lapso podría ser 2002-2021, 2003-2021, etc. Este proceso de elaboración de modelos de regresión ha sido empleado por Montoya (2022) en su tesis de maestría.
- El espacio temporal del pronóstico está limitado al periodo 2022-2028. Por un lado, el año inicial del pronóstico (2022) se debe a la limitación descrita en el párrafo previo. Por otro lado, el año final del pronóstico (2028) está en concordancia con el último pronóstico de crecimiento económico realizado por el Ministerio de economía y finanzas (MEF) en el Marco Macroeconómico Multianual (MMM) 2025-2028.

1.7 Objetivos

1.7.1 *Objetivo general*

- Estimar la tendencia del pronóstico de las emisiones de CO₂ en el Perú en el espacio temporal 2022-2028.

1.7.2 Objetivos específicos

- Establecer la relación entre las emisiones de CO₂ y el PBI en el Perú en el lapso 2005-2021.
- Precisar el tipo de elasticidad que existe en el Perú entre las emisiones de CO₂ y el PBI en los años 2005-2021.
- Calcular la precisión de las estimaciones de las emisiones de CO₂ en el Perú entre los años 2005-2021.
- Determinar el sesgo de las estimaciones de las emisiones de CO₂ en el Perú durante el periodo 2005-2021.

1.8 Hipótesis

1.8.1 Hipótesis general

- El pronóstico de las emisiones de CO₂ en el Perú tendrá una tendencia creciente en el espacio temporal 2022-2028.

1.8.2 Hipótesis específicas

- En el Perú las emisiones de CO₂ y el PBI muestran una relación positiva en el lapso 2005-2021.
- En el Perú las emisiones de CO₂ son inelásticas con respecto al PBI en los años 2005-2021.
- Las estimaciones de las emisiones de CO₂ en el Perú presentan una precisión muy buena ($MAPE \leq 10\%$) entre los años 2005-2021.
- Las estimaciones de las emisiones de CO₂ en el Perú son insesgadas durante el periodo 2005-2021.

II MARCO TEÓRICO

2.1 Calentamiento global y cambio climático


Frecuentemente, las expresiones calentamiento global (CG) y cambio climático (CC) son usadas como sinónimos, pero tienen significados diferentes (Godbole y Lamb, 2023; Hagen, 2022). Aunque, ambos términos sugieren el mismo gran conjunto de fenómenos (Sarfaty, 2022). Por un lado, el CG es el incremento de la temperatura superficial global en relación a la temperatura promedio de un periodo referencial suficientemente extenso para eliminar variaciones interanuales (IPCC, 2023). Por otro lado, CC hace referencia a alteraciones en el clima de la Tierra que incluyen variación en la temperatura, en las precipitaciones y en los vientos, y que ocurren en un periodo de varias décadas o más (Berlie, 2018).

En sentido económico, el CC es una externalidad de tipo negativo con consecuencias globales (Alatorre et al., 2019; China International Capital Corporation Limited [CICC], 2022; Chirinos, 2021; Claeys et al., 2024; Hussain et al., 2023; Rajhi y Bardi, 2023) que origina cuantiosos costos que no se contabilizaron en el costo original de los combustibles fósiles (Evans y Thomas, 2024). Una externalidad ocurre cuando las acciones o decisiones de una persona o grupo imponen costos (perjudican) o benefician a terceros (Case et al., 2020). Una externalidad negativa es una consecuencia no deseada originada en la producción de un bien o servicio que no afecta directamente al productor (Vasigh y Pearce, 2024).

De otro lado, el efecto invernadero es conocido desde 1824, cuando Joseph Fourier pensó que la Tierra sería más fría sin atmósfera (Mawi, 2024). El efecto invernadero es un mecanismo de protección de la atmósfera que estabiliza su temperatura adsorbiendo radiación infrarroja y liberándola al espacio (Manahan, 2022). Cuando la luz solar alcanza la atmósfera, una parte se refleja al espacio y el resto es absorbido y re-irradiado por los GEI (Figura 1) (Mendoza et al., 2021).

Figura 1

Efecto invernadero natural y efecto invernadero incrementado (antropogénico)



Nota: Tomado de ¿Qué es el efecto invernadero? [Gráfico], por Ideas en 5 minutos, 2024,

<https://ideasen5minutos.me/mejora-vida/que-es-el-efecto-invernadero-2900/>


Este mecanismo de protección mantiene habitable el clima de la Tierra, sin su existencia la superficie terrestre podría ser en promedio 33°C (59,4°F) más fría (Mawi, 2024; Nelles y Serrer, 2021). Sin embargo, dejando pasar el tiempo suficiente, las actuales tasas de generación de CO_2 , hará de la Tierra un lugar inhabitable (Johansen, 2023). Es decir, el CC es una seria amenaza para todo tipo de vida terrestre (Kotzé y Kim, 2021).

En 2022, las emisiones de GEI alcanzaron las 57,4 Gt (+1,06% respecto del 2021), de los cuales 38,5 Gt (+1,06% respecto del 2021) correspondieron a emisiones de CO_2 (Figura 2) (UNEP, 2023). América Latina y el Caribe representa el 10% del total de emisiones GEI (CAF, 2023), mientras que el Perú aporta el 0,4% (MINAM, 2023).

De otro lado, en el lapso 1850-2022 las emisiones de CO_2 sumaron 2 550 Gt, el 70% se acumuló en el periodo 1960-2022 y el 33% lo hizo entre 2000-2022 (Friedlingstein et al., 2023). La relación directa entre emisiones de CO_2 y CG, origina que por cada 1 000 Gt de CO_2 antropogénico la temperatura global media aumente entre 0,27°C y 0,63°C (IPCC, 2023).

Figura 2

Emisiones globales de CO₂ en gigatoneladas (1751-2022)




Nota: Adaptado de *Global atmospheric carbon dioxide compared to annual emissions (1751-2022)* [Gráfico], por NOAA, 2023, <https://www.climate.gov/media/14596>

Por otro lado, en el periodo 1850-2021 el mayor emisor de CO₂ fue EEUU (19%), seguido de China (13%), la Unión Europea (13%), Rusia (5%) e India (4%), mientras que los países menos desarrollados aportaron el 4% (Figura 3) (UNEP, 2023).

Figura 3

Emisiones de CO₂ acumuladas (1750-2021) y per cápita (2021) en países seleccionados




Nota: Adaptado de *Cumulative and per capita emissions* (p. 94), por G. Claeys, M. Le Mouel, S. Tagliapietra, G. Wolff & G. Zachmann, 2024, *The macroeconomics of decarbonisation: implications and policies*. Cambridge University Press.

La composición atmosférica de equilibrio, cerca de la superficie terrestre a 20°C y 1 atmósfera de presión es: nitrógeno (78%, 780 800 ppm), oxígeno (21%), argón (0,9%, 10 000 ppm), CO₂ (0,04%, 400 ppm), metano (0,0002%), además de trazas de agua y otros gases (hidrógeno) (Birdi, 2024; Levin, 2023).

Sin embargo, la concentración atmosférica de CO₂ se ha incrementado de 280 ppm en 1750 a más de 420 ppm en 2021 (Figura 4) (Li et al., 2023). Por otro lado, el incremento en 95 ppm ocurrido entre 1950 (315 ppm) y 2018 (410 ppm), es producto del proceso de reconstrucción y crecimiento industrial acontecido después la segunda guerra mundial (Siegel, 2020). Es decir, el incremento de la concentración promedio anual de CO₂ atmosférico se elevó de menos 1 ppm en la década de 1950 a más de 2 ppm (Senthilkumar, 2021).

Figura 4

Concentración de CO₂ atmosférico en ppm (1751-2022)



Nota: Adaptado de *Global atmospheric carbon dioxide compared to annual emissions (1751-2022)* [Gráfico], por NOAA, 2023, <https://www.climate.gov/media/14596>

El último nivel de concentración de CO₂ superior a 400 ppm ocurrió aproximadamente hace 3 millones de años, cuando la temperatura global promedio y el nivel del mar eran significativamente mayores (US Global Change Research Program [USGCRP], 2017).

Se espera que en 2047 se alcance una concentración de CO₂ de 500 ppm, lo cual constituiría un punto de no retorno (Bhatt et al., 2023). Más aún, de acuerdo a los pronósticos

del IPCC, el nivel de CO₂ puede llegar a 590 ppm y la temperatura global promedio puede aumentar en 1,9°C para el 2100 (Li et al., 2023).

Igualmente, se ha proyectado que la concentración de CO₂ atmosférico se duplique o triplique (de 350-400 ppm a 800-1200 ppm) en los próximos 25-50 años (Leggieri et al., 2021). En Perú, el calentamiento más pronunciado se ha observado en el sur andino, donde la temperatura se ha incrementado a razón de 0,3°C por década desde 1981 (Bergmann et al., 2021).

Asimismo, sin grandes cambios en las políticas climáticas actuales, el CG llegará a 2,7°C al 2100 (Climate Action Tracker [CAT], 2023). De hecho, es muy probable que en esta década la Tierra esté más caliente de lo ha estado en los últimos 125 000 años (Sadler, 2023).

Por su parte, en Perú en un escenario de emisiones bajas el calentamiento al 2050 podría variar entre 0,75°C y 1,5°C, mientras que al 2100 podría fluctuar entre 1°C y 1,75°C (Bergmann et al., 2021). En cambio, en un escenario de emisiones altas, la temperatura al 2050 podría moverse entre 1°C y 2°C, en tanto que al 2100 podría oscilar entre 3,5°C y 6°C (Bergmann et al., 2021).

2.2 Causas del calentamiento global y del cambio climático

Hace mucho más de 100 años el científico sueco Svante Arrhenius demostró que la duplicación de CO₂ atmosférico podría originar CG (Levin, 2023). El CG es causado por la acumulación de GEI en la atmósfera (Ahmed et al., 2022; Bayram et al., 2023; Furkan et al., 2023; Roos y Hoffart, 2021). Los GEI son gases que absorben la radiación de onda larga (térmica) saliente y atrapan el calor en la atmósfera (The Royal Society, 2021).

Las emisiones de CO₂ son el principal aportante a los GEI y al CG (Bayram et al., 2023; Famielec et al., 2019; Goel et al., 2021; Hossain, 2023; Hussein et al., 2023; Kayakuş et al., 2023; Shahbaz et al., 2023; Sinha et al., 2019; WMO, 2023), significan el 70% del total de las

emisiones de GEI (Alaganthiran y Anaba, 2022; Bayram et al., 2023) y representan alrededor del 50% del CG (Johansen, 2023).

Por otro lado, la concentración de CO₂ atmosférico adsorbe la radiación solar que rodea la superficie terrestre, causando de esta manera CG (Mendoza et al., 2021). La capacidad de absorción de la atmósfera está directamente relacionada con su concentración de CO₂ (Mathez y Smerdon, 2018)

Entre los años 2013-2022 la temperatura se incrementó en 1,15°C en relación a la época pre-industrial (1850-1900), 1,14°C son atribuibles a actividades humanas (WMO; 2023). En efecto, el CG es un fenómeno antropogénico (Claeys et al., 2024; Goel et al., 2021; Hussein et al., 2023; IPCC, 2023; Levin, 2023; Sinha y Schneider, 2023).


Uno de los principales aportantes al CC es el uso de combustibles fósiles (Asnicar y Marín, 2022; OCDE et al., 2022; Ulucak et al., 2019; Wang et al., 2018). Las actividades humanas que causan el continuo incremento de GEI en la atmósfera son las emisiones originadas por el desarrollo industrial, en particular la quema de combustibles fósiles en plantas de energía y otras industrias, y la combustión interna de los vehículos motorizados (Siegel, 2020).

En efecto, el 87% de la energía requerida por el mundo proviene de fuentes fósiles (Ulucak et al., 2019), aunque se espera que sea 67% para 2050 (Sen, 2021). En tal sentido, por cada 1 000 Gt de CO₂ generadas por actividades humanas, la temperatura superficial global aumenta en 0,45°C (IPCC, 2023). Si una planta de energía de 1 000 Mw utiliza carbón libera 7 t/año de CO₂, si emplea petróleo genera 5 t/año de CO₂ y si usa gas produce 3 t/año de CO₂ (Birdi, 2024).

En términos de emisiones de CO₂ para generar 1 kWh de electricidad según tipo de energía, la energía menos contaminante es la hidráulica (6 g de CO₂ por kWh), mientras que la más contaminante es el carbón (1 024 g de CO₂ por kWh) (Figura 5).

Figura 5

Gramos de CO₂ para generar 1 kWh de electricidad según tipo de energía



Nota: Adaptado de *CO₂ emissions produced by 1 kWh electricity, according to different types of energy* (p. 194), por A. Cracknell & C. Varotsos, 2022, *Understanding global climate change. Modelling the climatic system and human impacts* (2nd ed.), CRC Press.

Así, cada año al menos 8 000 millones t de CO₂ se liberan a la atmósfera (Hannah, 2022), producto del consumo global de 100 millones de barriles diarios de petróleo, destinados al sector transporte y a la generación de electricidad (Sadler, 2023). En el último medio siglo, las empresas petroleras y gasíferas han ganado US\$ 2 800 millones diarios (OXFAM, 2022).

Asimismo, la tala de árboles es otro de los mayores aportantes al CC (OCDE et al., 2022). Las emisiones de CO₂ per cápita se expanden en 0,19% por cada 1% de incremento en el área deforestada (Hussein et al., 2023). Igualmente, los sistemas de producción alimentaria insostenibles contribuyen al CC y a la degradación de los recursos naturales (Morgan y Fanzo, 2020), explican entre el 20% y 30% de las emisiones globales de GEI (Agostoni et al., 2023). También, las exportaciones y el comercio internacional se relacionan con grandes requerimientos de energía y, por tanto, con emisiones de CO₂ y con el CG (Leitão et al., 2023).

2.3 Efectos del calentamiento global y del cambio climático

Investigadores han identificado, empíricamente y científicamente, que los niveles de emisión de GEI causan efectos adversos severos en el medio ambiente y en la salud humana

(Alaganthiran y Anaba, 2022). También, genera escasez de alimento y agua (Udemba, 2023) y pone en peligro muchos ecosistemas y especies (Ekardt, 2022; Hussain et al., 2023).

Además, podría incrementar la frecuencia de los conflictos bélicos (Ekardt, 2022), por lo cual es una amenaza potencial a la paz y seguridad internacional (Matz-Luck y Christiansen, 2021). Durante 2020, los conflictos obligaron a migraciones poblaciones, el 95% provinieron de países vulnerables al CC (OXFAM, 2022). Doce de los 20 países más vulnerables y con menos recursos para adaptarse al CC son escenario de conflictos bélicos (Maurer, 2021).

Igualmente, impacta en la economía, en la seguridad alimentaria, en la productividad laboral, en el crecimiento económico y en los mercados energéticos (Adom, 2024), reducirá la fuerza laboral, los rendimientos agrícolas y el turismo mundial y dañará los activos, el capital y la tierra productiva (CPI, 2023). Además, amenaza la estabilidad financiera y puede generar inflación (Swiss Re Institute, 2024). Los eventos climáticos extremos (sequías, inundaciones) impactarán en la producción agrícola, lo cual resultará en el incremento de los precios de los alimentos (Claeys et al., 2024).

Asimismo, el CC es un factor crítico para el desarrollo nacional e internacional (Connell, 2023). En tal sentido, los ecosistemas producen una amplia variedad de beneficios a la humanidad, el CC modificará la distribución de los ecosistemas y cambiará el flujo de sus beneficios (Bastien-Olvera et al., 2024).

Del mismo modo, el CG afectará severamente las condiciones de vida en los países en vías de desarrollo, en los países ricos los impactos podrían ser más limitados (Roos y Hoffart, 2021). El CC afecta la mano de obra, en especial en países tropicales (Dasgupta et al., 2021). A tal efecto, el CC agudiza la pobreza al afectar los medios de vida, incrementar la escasez de alimentos y agua; y generar inestabilidad económica (WMO, 2023). También, la industria ganadera puede volverse inviable, si el incremento del CG llega a 3°C (Benschop et al., 2023).

Por otro lado, aun logrando una reducción muy significativa de las emisiones de GEI, lo que es improbable dada la tendencia actual, las futuras generaciones sufrirán las consecuencias del CG y del CC, por los GEI ya acumulados en la atmósfera (Pinho-Gomes et al., 2023), dado que el CO₂ permanece en la atmósfera por más de 1 000 años (Sadler, 2023). Por tanto, pocas naciones podrán afrontar exitosamente los efectos del CC (Adom, 2024).

2.3.1 Cuantificación de los efectos: La huella de carbono

La huella de carbono (HC) representa la cantidad de GEI que son liberados a la atmósfera producto de las actividades de una persona, comunidad, país, empresa, organización, etc. (Figura 6) (United Nations Development Programme [UNDP], 2023). Es una métrica que se expresa en unidades equivalentes de CO₂ (CO₂-eq) y que es ampliamente utilizada en la cuantificación de los efectos ambientales de los productos (Mostafaei et al., 2024).

Figura 6

Actividades liberadoras de gases de efecto invernadero



Nota: Adaptado de *What's part of your carbon footprint?* [Gráfico], por Decode 6, 2023, <https://decode6.org/articles/what-is-a-carbon-footprint/>

La HC puede ser primaria o secundaria. La HC primaria proviene de las emisiones del sector transporte, uso de energía de los hogares, etc. (Jaisri y Balaji, 2025). Mientras que la HC secundaria se refiere a las emisiones resultantes de los procesos productivos de los diversos

productos (Jaisri y Balaji, 2025). Se dispone de un conjunto de marcos metodológicos para calcular la HC, cada uno con ventajas y limitaciones (Tabla 1).

Tabla 1

Marcos metodológicos para el cálculo de la huella de carbono

Marco metodológico	Ventajas	Limitaciones
1. Análisis del ciclo de vida: Los productos y servicios generan emisiones a lo largo de todo su ciclo de vida, desde la extracción de materias primas, fabricación, procesamiento, prestación de servicios, demolición y gestión de residuos.	Considera los impactos indirectos, especialmente en la etapa de la cadena de suministro, e incluyen los efectos ambientales en todos los subsectores.	Se requieren inventarios de datos muy detallados. El enfoque integral del análisis plantea dificultades a la hora de estudiar muestras de gran tamaño.
2. Consumo de energía o combustible y factores de emisión: Por lo general, se complementan con un cuestionario o con la recopilación de datos in situ. Se centran en los usos energéticos. Los factores de emisión ponen en perspectiva los diferentes tipos de energía utilizados en cada proceso.	Los factores de emisión nacionales e internacionales se actualizan y recalibran periódicamente. Algunos incluyen emisiones indirectas. Los datos de consumo procedentes de encuestas o auditorías se ajustan con precisión al estudio.	Los factores de emisión para algunos países o regiones son limitados, lo que podría generar subestimaciones o sobreestimaciones. La calidad de la encuesta puede afectar a los resultados.
3. Insumo-Producto (I-P): Usa datos macroeconómicos para estimar las emisiones derivadas de la producción y el consumo de productos y servicios en una zona determinada. Ha evolucionado hacia enfoques centrados en la sostenibilidad, con la introducción de nuevos modelos I-P ampliados desde el punto de vista ambiental.	No es necesario recopilar datos primarios. Los datos utilizados han sido validados previamente. Se pueden calcular los impactos indirectos.	Las tablas nacionales de I-P no se actualizan anualmente. Por lo es necesario plantear varias hipótesis, como un crecimiento lineal en el futuro o precios constantes.
4. Análisis de escenarios: Uso de datos estadísticos para simular escenarios económicos y sociales en los que se predicen las implicaciones de la HC y otras repercusiones sociales, ambientales y económicas.	Las estrategias y medidas de reducción de emisiones pueden planificarse en función de los escenarios previstos.	La calidad de los escenarios depende tanto de los datos disponibles como del modelo desarrollado.

Nota: Adaptado de *Calculation methodologies: advantages and limitations* (p. 7), por A.

Pousa-Unanue, A. Alzua-Sorzabal y F. Femenia-Serra, 2026, Methodological pathways for measuring tourism carbon footprint: A framework-oriented systematic review. *Climate*, 14(2),

28. <https://www.mdpi.com/2225-1154/14/2/28>

2.3.2 Efectos en el medio ambiente

El CC ha causado daños significativos e incrementado pérdidas irreparables en los ecosistemas terrestres, de agua dulce, criosféricos, costeros y oceánicos (IPCC, 2023). El CC ha provocado y está provocando mucho daño: eleva el nivel del mar, derrite la Antártida,

extingue especies salvajes (Abbass et al., 2022; Hussain et al., 2023; Udemba, 2023), empobrece y merma las tierras de cultivo y contamina los recursos hídricos (Connell, 2023).

Los océanos absorben el 30% del CO₂ antropogénico, dando como resultado su acidificación y cambios en la química de los carbonatos que no tienen precedentes por lo menos en los últimos 65 millones de años (IPCC, 2019). La acidificación oceánica afecta al ecosistema y a los organismos marinos, amenazando la pesquería y acuicultura e impactando la seguridad alimentaria (WMO, 2023).

También, el calentamiento modifica otros parámetros químicos oceánicos tales como salinidad y concentración de oxígeno (Agostoni et al., 2023), lo cual altera las funciones corporales y las tasas de crecimiento y de reproducción de las especies marinas (Guibourd de Luzinai et al., 2023).

En tal contexto, el CC está provocando la disminución de la biomasa de peces y la degradación del coral (Connell, 2023). Todos los cambios descritos podrían afectar a más del 60% de los océanos (escenario de emisiones altas) o a más del 30% (escenario de emisiones bajas) al 2100 (Freestone, 2021). La biomasa de peces que habita en el sistema de Humboldt podría reducirse en alrededor de 35% si el CG alcanza los 2°C al 2050, por lo cual el sector pesquero peruano es uno de los más vulnerables al CC (Bergmann et al., 2021).

Además, en las últimas décadas el nivel del mar se ha elevado en promedio 1,8 mm por año (Sen, 2021). Al 2100, el nivel del mar peruano podría elevarse por encima de 70 cm (Bergmann et al., 2021). También, en Perú desde 1970 se han perdido alrededor del 43% de los glaciares, por lo cual es probable que sufra de una reducción significativa de flujo hídrico a inicios de 2030 (World Bank, 2022). Más aun, de no ocurrir una reducción drástica de las emisiones globales de GEI, los glaciares podrían casi desaparecer y podría perderse una parte significativa de la selva (Bergmann et al., 2021).

Igualmente, el CC altera la frecuencia y desarrollo de eventos climáticos extremos (Agostoni et al., 2023; Nogueira et al., 2023; OXFAM, 2022). A tal efecto, en las postrimerías del siglo 19 se producía un evento climático extremo por decenio, en la actualidad ocurren 2,8 por decenio y si el CG alcanza 1,5°C podrían suceder hasta 4,1 por decenio (Adom, 2024). En 2022, ocurrieron 15 eventos extremos (sequías, incendios forestales, tormentas severas, inundaciones y huracanes) en EEUU, mientras que en las cuatro décadas previas el promedio de estos eventos fue sólo entre 7 y 8 (Brewer, 2023).

Hallazgos recientes indican que la severidad del evento El Niño se ha incrementado desde 1982 (Githeko, 2023). Así, como consecuencia del CG, la temperatura superficial del mar tropical es más caliente ahora durante el evento La Niña, que lo era tres décadas atrás durante el evento El Niño (Johansen, 2023). Por ejemplo, las condiciones del evento El Niño fuerte de 1998 aunado al CG resultó en el año más caliente jamás registrado, la temperatura global fue 0,52°C más alta que el promedio del lapso 1961-1990 (Hossain, 2023).

Por tanto, en cualquier escenario de emisiones, en este siglo se duplicaría la frecuencia de ocurrencia del evento El Niño (Bergmann et al., 2021). Además, en el siguiente lustro, los efectos combinados del evento El Niño y del CC elevarán, temporalmente, la temperatura mundial a niveles críticos (más de 1,5°C) (Blanco-Villafuerte y Hartinger, 2023).

También, el CG altera el ciclo hidrológico de la Tierra, incrementando la intensidad de las tormentas, sequías e inundaciones (Johansen, 2023). En Perú, se aprecia una tendencia decreciente en el número de días con lluvia (o con humedad) acompañado por un incremento en la intensidad de las precipitaciones (Bergmann et al., 2021).


De otro lado, en el periodo 2010-2020, la mortalidad humana debido a tormentas, sequías e inundaciones fue 15 veces mayor en las zonas altamente vulnerables, en comparación con las zonas de muy baja vulnerabilidad (IPCC, 2023). Para el 2045, el 14% de los bienes inmuebles de Miami Beach podrían estar inundados (Cracknell y Varotsos, 2022). El CC

sobrecalienta el aire aumentando su contenido de vapor de agua, lo que incrementa la capacidad de agua de los huracanes (Nogueira et al., 2023).

Asimismo, debido al incremento de la temperatura, aumentará el potencial de las condiciones para la ocurrencia de incendios forestales (Meadows, 2023). También, el calentamiento y los cambios en las precipitaciones han incrementado la mortalidad de árboles (Agostoni et al., 2023). Por su parte, Perú está conformado por 1 736 distritos, muchos de ellos están expuestos a diversos eventos climáticos extremos (Figura 7).

Figura 7

Perú: Número de distritos expuestos a eventos climáticos extremos



Nota: Adaptado de *Peru: Districts' Exposure to Natural Disasters, 2017* (p. 114), por M. Tostes, A. Villavicencio & C. Motta, 2019, Vulnerability index elaboration for climate change adaptation in Peru. *European Journal of Sustainable Development*, 8(5), 102-114. <http://dx.doi.org/10.14207/ejsd.2019.v8n5p102>

2.3.3 Efectos en la seguridad alimentaria

Seguridad alimentaria es un estado en el cual “las personas tienen en todo momento acceso físico, social y económico a suficientes alimentos inocuos y nutritivos para satisfacer sus necesidades alimenticias y sus preferencias en cuanto a los alimentos, a fin de llevar una vida activa y sana” (WFP, 2009, p. 28). La seguridad alimentaria es crucial para la salud

humana y del planeta (Pérez-Escamilla, 2024). El CC ya impacta en la seguridad alimentaria como consecuencia del aumento de la temperatura, la variabilidad de las precipitaciones y al incremento de la frecuencia de algunos eventos climáticos extremos (IPCC, 2020).

En efecto, en los 10 países más impactados por el CC (Somalia, Madagascar, Burkina Faso, Kenia, Níger, Yibuti, Zimbabue, Guatemala, Haití y Afganistán) la población en estado de hambruna se ha incrementado de 21,3 millones (2016) a 47,8 millones (2021) (OXFAM, 2022). En ese sentido, hasta el 2030 se requiere invertir entre US\$ 39 000 y US\$ 50 000 millones anuales para erradicar el hambre global al 2030 (Chichaibelu et al., 2023). Además, la oferta insuficiente de alimentos y de agua, a consecuencia de los eventos climáticos extremos, impulsa los desplazamientos (OXFAM, 2022).

El CC impacta en el funcionamiento de los eslabones de los sistemas alimentarios (Fanzo y Miachon, 2023; Mirzabaev et al., 2023). Así, el CG puede desestabilizar el ecosistema al reducir las producciones agrícolas, ganaderas y pesqueras (Agostoni et al., 2023). Además, el CC impacta en la calidad, disponibilidad, diversidad, seguridad y asequibilidad de los alimentos (Fanzo et al., 2018; Pérez-Escamilla, 2024). Niveles altos de CO₂ disminuyen la concentración proteínica del trigo, la cebada, el arroz y la papa (Agostoni et al., 2023).

En particular, el CC y la variabilidad climática son los principales factores que afectan la producción de los cultivos (Jägermeyr et al., 2021). El CC explica aproximadamente el 50% de la variabilidad en la producción global de alimentos (Mirzabaev et al., 2023). En especial, en las zonas parcialmente áridas al menos el 80% de los cambios en la cosecha de cereales pueden ser causados por el CC (OXFAM, 2022). Además, el incremento de la temperatura y de las emisiones de CO₂ en 1% resulta en una disminución de la producción en 1,93% y 0,32%, respectivamente (Chandio et al., 2022).

En tal contexto, los cultivos retrocederán en Filipinas (-11,4%), Laos (-9,2%), Tailandia (-2,6%), Indonesia (-17,3%), Myanmar (-3,7%), Camboya (-4,3%) y Malasia (-10,4%), en caso

de un estado de inacción (Taniushkina et al., 2024). También, se espera que al 2028 respecto de 2021, se reduzca la producción de arroz en Vietnam (-18,9%) y Tailandia (-6,7%) y se incremente en Filipinas (+5,1%) (Taniushkina et al., 2024).


Por otro lado, desde 1961 la productividad total del sector agrícola global ha decrecido en alrededor de 21% debido al CC (Ortiz-Bobea et al., 2021). En efecto, en un escenario de emisiones altas, pronósticos al 2100 estiman que el CC reducirá la productividad del maíz (entre -20% y -45%), trigo (entre -5% y -50%), arroz (entre -20% y -30%) y soya (entre -30% y -60%) (Agostoni et al., 2023). Igualmente, hacia el 2100 la productividad del maíz podría reducirse en 24%, mientras que la productividad del trigo podría incrementarse en 18% (Jägermeyr et al., 2021). No obstante, según aumente el calentamiento, en las áreas tropicales de menor latitud se advertirá una merma de la productividad agrícola, en tanto en las latitudes mayores la productividad podría incrementarse (IPCC, 2019).

Por su cuenta, el sector pesquero es un actor principal en la seguridad alimentaria mundial, sin embargo, la sostenibilidad de la actividad está seriamente amenazada por el CC (Segaran et al., 2024). Uno de los efectos del calentamiento es el cambio en la distribución espacial de las especies marinas (Lah et al., 2024). También, la acidificación de los océanos, producto de la absorción de CO₂, altera la disponibilidad de plancton, alimento vital de los peces (Cooke et al., 2022). Asimismo, es probable que el calentamiento provoque la disminución de ácidos grasos polinsaturados y de hierro en los mariscos (Agostoni et al., 2023).

En Perú, la seguridad alimentaria es impactada severamente o muy severamente por las olas de frío (a 5,3 millones habs.) y por las lluvias intensas (a 9,3 millones habs.) (Bergmann et al., 2021). Asimismo, la seguridad alimentaria de más de 12,5 millones (40% de la población) que habitan en 1 565 distritos de un total de 1 874, es vulnerable o muy vulnerable (Figura 8) (Ministerio de Desarrollo e Inclusión Social [MIDIS] y WFP, 2022).

Figura 8

Perú: Vulnerabilidad de la seguridad alimentaria según distrito




Nota: Adaptado de *Perú: Quintil del IVIA, según distrito, 2018* (p. 63), por MIDIS y WFP, 2022, Vulnerabilidad a la inseguridad alimentaria por departamento, provincia y distrito, 2018, Ministerio de Desarrollo e Inclusión Social (MIDIS).

2.3.4 Efectos en la salud humana

El CC es la mayor amenaza a la salud humana, mucha gente ya está sintiendo sus efectos negativos (World Health Organization [WHO], 2024). Los impactos del CC en la salud son directos (clima extremo, contaminación del aire, etc.) e indirectos (afecta los determinantes de la salud: nutrición, asistencia médica, etc.) (Figura 9) (WHO, 2024). Además, el CC empeora los efectos nocivos de la malnutrición en la salud en todas sus formas (Morgan y Fanzo, 2020).

Figura 9

Efectos del cambio climático en la salud humana



Nota: Adaptado de *Impact of climate change on human health* (p. 3), por M. Sarfaty, 2022, *Climate change and population health*. A primer, Jones & Bartlett Learning.

Globalmente, el impacto del CC en los factores determinantes de la salud (agricultura, acceso al agua) es negativo (Agostoni et al., 2023). Además, debido a sus ineficientes sistemas de salud, los países en vías de desarrollo padecerán la mayoría de los efectos en salud del CC (Adom, 2024).

El CG y el CC probablemente produzcan cambios en los límites y la estructura de las enfermedades (Malkhazova et al., 2023). Así, el CC está cambiando la distribución de enfermedades infecciosas, todas con efectos en la salud mental (Connell, 2023). También, el CC es la causa de la rápida propagación y exacerbación de ciertas epidemias y pandemias (Abbass et al., 2022; Sadler, 2023). Además, el CC contribuye a los factores que acercan los patógenos a la humanidad (Sadler, 2023). Igualmente, el CC acelera la resistencia antimicrobiana de los agentes patógenos (Abbass et al., 2022). En tal contexto, el CC es uno de los factores más importantes que afecta los ciclos de vida y la transmisión de la mayoría de infecciones tales como malaria, cólera, dengue, fiebre aftosa y la reciente pandemia del coronavirus (Wahid et al., 2021).

Del mismo modo, el CC causa patologías tales como enfermedad pulmonar obstructiva crónica (EPOC), asma, dificultad para respirar y enfermedades cardiovasculares (Shahbaz et al., 2023). Además, el CG influye en la prevalencia, duración y severidad de infecciones respiratorias comunes como influenza y el virus respiratorio sincitial (Bayram et al., 2023).

También, las olas de calor favorecen la ocurrencia de accidentes cerebrovasculares y el agravamiento de enfermedades respiratorias, cardíacas, renales y psiquiátricas (Connell, 2023). Además, el CC está incrementando el riesgo de cáncer por la exposición a carcinógenos, luego de la ocurrencia de huracanes e incendios forestales (Nogueira et al., 2020).

Asimismo, el CC puede exacerbar los riesgos en la salud o incorporar nuevos riesgos (Doelle y Seck, 2021). Se prevé también que el CC aumentará las patologías transmitidas por los alimentos y el agua (Agostoni et al., 2023).

Por otro lado, el incremento de la temperatura produce el aumento de decesos prematuros, particularmente en poblaciones vulnerables (Blanco-Villafuerte y Hartinger, 2023). También, un clima más caliente sumado al desmejoramiento de la calidad del aire

incrementará la tasa de mortalidad, las patologías relacionadas con el clima y los costos en atenciones médicas (Climate Policy Initiative [CPI], 2023).

Asimismo, el CC puede alterar la distribución e interacción entre animales y personas, originando cambios en vectores y agentes e incrementando el riesgo de enfermedades zoonóticas (Li, 2023). Expertos han afirmado que el CC ha dado lugar a la aparición de enfermedades virales como el ébola en África occidental y el zika en América Latina (Akhtar, 2023). Además, el CG impulsa la propagación de los virus a lugares que albergan las especies que generan los virus (Sadler, 2023).

Igualmente, el derretimiento de los casquetes polares expone a vida microbiana ancestral congelada en la nieve, que supone un riesgo de muchas más pandemias y enfermedades nunca antes vistas (Bhatt et al., 2023). Adicionalmente, es ampliamente reconocido que el CC es un impulsor significativo del desarrollo y exacerbación de enfermedades no transmisibles relacionadas con la dieta (Tapkigen et al., 2024).

2.3.5 Efectos económicos

Los efectos económicos del CC son de diversa índole. Por un lado, se contabilizan las pérdidas económicas asociadas a los impactos de los eventos climáticos exacerbados por el CC. Por otro lado, están las ingentes inversiones requeridas en adaptación y mitigación de los impactos del CC. Las inversiones en adaptación y mitigación generan réditos globales en el largo plazo, mientras que los costos son locales e inmediatos (Tostes et al., 2019).

Entre los años 2000-2019, los costos de los eventos climáticos extremos atribuibles al CC alcanzaron los US\$ 143 000 millones anuales, US\$ 90 000 millones por pérdida de vidas humanas y US\$ 53 000 millones por daños económicos (Newman y Noy, 2023). Igualmente, en los EEUU en el periodo 2018-2022, los desastres naturales costaron US\$ 788 400 millones (Brewer, 2023). En los países de ingresos bajos los costos del CC representaron el 1% del PBI, mientras que en los países de ingresos altos el impacto fue 0,2% (Newman y Noy, 2023).

También, el sector pesquero mundial podría experimentar pérdidas anuales por encima de los US\$ 10 000 millones por los impactos del CC (Segaran et al., 2024).

De otro lado, para lograr el objetivo del Acuerdo de París de 2°C, se ha sugerido ampliar la capacidad instalada de las plantas nucleares a 930 GW en 2050, lo cual implicaría una inversión de más de US\$ 4 billones (Cracknell y Varotsos, 2022). No obstante, para lograr la meta de cero emisiones al 2050, se requiere inversiones anuales adicionales de US\$ 9,4 billones en promedio (Swiss Re Institute, 2024). Con respecto a la Unión Europea, se ha estimado que el logro de cero emisiones en 2050 podría requerir alrededor de € 1 billón por año en el lapso 2021-2050 (European Court of Auditors [ECA], 2023).

Por su cuenta, los países emergentes y las economías en desarrollo, sin incluir a China, requieren de financiación climática externa por US\$ 1 billón anual hasta el 2030 (Songwe et al., 2022). No obstante, el financiamiento otorgado por los países desarrollados a los países en vías de desarrollo ha sido de US\$ 79 900 millones (2018), US\$ 80 400 millones (2019) y US\$ 83 300 millones (2020) (Brewer, 2023). De otro lado, en el lapso 2000-2019, los 10 países más afectados por el CC recibieron financiamiento por US\$ 23 000 millones, casi el 2% del presupuesto total (CPI, 2023).

Para los países en vías de desarrollo, en un escenario de riesgo moderado (entre +1,7°C y +3,3°C), el costo promedio anual de adaptación al CC podría ser de US\$ 98 000 millones (0,34% del PBI) al 2030, US\$ 189 000 millones (0,37% del PBI) al 2050 y US\$ 420 000 millones (0,34% del PBI) al 2100 (Chapagain et al., 2020).

Por su parte, en los países de ingresos medios-altos (incluida China) las inversiones necesarias para encarar al CC equivalen a un 1,1% del PBI, mientras que en los países de ingresos medios-bajos significan el 5,1% y en los países de ingresos bajos representan el 8% (World Bank, 2022).

Sin embargo, aun logrando las metas del Acuerdo de París, el PBI mundial podría caer en -4,2% (Swiss Re Institute, 2021). También, al 2200 las pérdidas económicas por no mitigar el CC significarían entre 5,3% y 13,8% del PBI per cápita global (Swiss Re Institute, 2021). Asimismo, si la temperatura global se incrementa en 3°C las pérdidas económicas equivaldrían al 10% del PBI global y significarían el 17% del PBI total de los países pobres (Waidelich et al., 2024). Igualmente, un calentamiento superior a los 3°C podría significar pérdidas del PBI mundial en 18% (2050) y 20% (2100) (CPI, 2023).

Del mismo modo, si la temperatura global aumenta en 2°C, 3°C o 4°C las pérdidas económicas anuales hasta el 2100 serían US\$ 5,66 billones, US\$ 9,59 billones o US\$ 23,15 billones, respectivamente (Kompas et al., 2018). También, con un CG de 3,7°C los costos económicos del CC podrían ascender a US\$ 551 billones, aproximadamente dos veces la riqueza global (Cracknell y Varotsos, 2022).

El CC también afectará al mercado laboral. Con un CG de 1,5°C la mano de obra efectiva global se reducirá en 6,7 puntos porcentuales (pp), con un CG de 2°C la contracción será de 10,3 pp y con un CG de 3°C el decremento será de 18,3 pp (Dasgupta et al., 2021).

En Perú, al 2050 en un escenario pesimista, pero con adaptación al CC el PBI se expandiría un 4,2%, sin adaptación el PBI retrocedería un -0,8% (World Bank, 2022). Por otro lado, si el calentamiento prosigue la tendencia mostrada en las últimas tres décadas, el PBI per cápita se contraería en -9% al 2050 y en -22% al 2100 (Chirinos, 2021). Asimismo, si la temperatura mundial se incrementara en 1°C, 2°C, 3°C o 4°C el PBI hasta el 2100 se reduciría anualmente en -0,509%, -1,169%, -1,934% o -2,768%, respectivamente (Kompas et al., 2018).

2.4 De la Conferencia de Estocolmo (1972) al Acuerdo de París (2015)

Conferencias y tratados sobre temas ambientales y estudios pioneros han despertado la conciencia colectiva con respecto al CG y al CC (Kayakuş et al., 2023; Leitão et al., 2023). El primer paso fue la Conferencia de Estocolmo de 1972 (Kayakuş et al., 2023). Seguidamente,

en 1987 se firma el Protocolo de Montreal. Luego, en 1988 se crea el Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC por sus siglas en inglés) (CAF, 2023). Más tarde, en 1992 se establece la Convención Marco de las Naciones Unidas sobre el Cambio Climático (UNFCCC por sus siglas en inglés) (CAF, 2023). Después, en 1997 se suscribe el Protocolo de Kioto (CAF, 2023). Por último, en 2015 se sella el Acuerdo de París (CAF, 2023).

En 1972, ante el argumento de la ONU de que los problemas ambientales y la protección del ambiente es deber de todos los países del mundo, se materializa la Conferencia de Estocolmo, con la cual los problemas ambientales se universalizaron (Akyol y Uçar, 2021). La Conferencia se desarrolló entre 5-16 de junio de 1972 y reunió a representantes de 130 países (Sundstrom, 2021). Antes del encuentro de Estocolmo, las cuestiones del medioambiente usualmente se abordaban bilateralmente o regionalmente (Desai, 2021). Aunque, la Conferencia no produjo ninguna norma legal (Desai, 2021) se le considera el génesis del derecho medioambiental global (Matz-Luck y Christiansen, 2021).

En 1987, respondiendo al problema global y creciente de agotamiento de la capa de ozono, la ONU redactó el Protocolo de Montreal, que entró en vigencia en 1989. El Protocolo, ratificado por más de 190 países, estableció controles vinculantes sobre la producción y el consumo de gases que dañan la capa de ozono (Cracknell y Varotsos, 2022). Dado que las imágenes satelitales que mostraban el agrandamiento del agujero de la capa de ozono resultaban irrefutables, se logró el consenso político acordándose financiamiento y estableciéndose un cronograma de eliminación de las sustancias agotadoras de la capa de ozono (Desai, 2021). Aunque, el Protocolo no calificó como delito el comercio ilícito de sustancias agotadoras de la capa de ozono, los firmantes adoptaron medidas destinadas a detectar y combatir el comercio ilegal (Rose, 2021).

En 1988, la Organización Meteorológica Mundial (WMO por sus siglas en inglés) y el Programa de las Naciones Unidas para el Medio Ambiente (UNEP por sus siglas en inglés)

crean el Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC por sus siglas en inglés), con la finalidad de actualizar, sistematizar y difundir el conocimiento científico acerca del CC y sus impactos (Sundstrom, 2021). En la primera sesión del IPCC celebrada en noviembre de 1988 en Ginebra, se establecieron tres grupos de trabajo: ciencia física, adaptación y mitigación (Brewer, 2023).

En 1990, la ONU inició las negociaciones para la creación de UNFCCC, y en junio de 1992, durante la Cumbre de la Tierra efectuada en Río de Janeiro, muchos países se adhirieron a la UNFCCC (Guglyuvatyy, 2022). La UNFCCC propuso que para el año 2000, los países industrializados deberían reducir sus emisiones de GEI a los niveles de 1990 (Guglyuvatyy, 2022). Sin embargo, la limitación era voluntaria y solo unos pocos países dictaron medidas obligatorias para lograr la meta (Guglyuvatyy, 2022). Las reuniones anuales posteriores de la UNFCCC se denominaron Conferencia de las Partes (COP, por sus siglas en inglés), en el que los miembros discuten medidas para lograr las metas de La Convención (Reichelt, et al., 2023).

Después, en diciembre de 1997, durante la tercera COP de la UNFCCC se adoptó el Protocolo de Kioto (Guglyuvatyy, 2022). El Protocolo tuvo la finalidad de limitar las emisiones de GEI, especialmente en los países industrializados (Shahbaz et al., 2023). Firmado por 192 países, el Protocolo estuvo vigente desde 2005 hasta 2012 y ayudó a reducir las emisiones de CO₂ en 12,5%, mucho más del doble de la meta original de 4,7% (Hossain, 2023).

Por último, en diciembre 2015 se firma el Acuerdo de París por 197 países durante el vigésimo primer encuentro de la UNFCCC. El Acuerdo tiene como objetivo mantener el incremento global de temperatura en el rango de 1,5°C-2°C (Shahbaz et al., 2023). Para lograr la meta, la emisión de GEI debe reducirse entre 30% y 45% al 2030 y las emisiones de CO₂ deberían acercarse a cero al 2050 (WMO, 2023). Por lo cual, cada año deberían eliminarse 10 Gt de CO₂ (Hossain, 2023). La inversión anual necesaria para lograr las metas del Acuerdo es

de US\$ 1,5 billones (Azam et al., 2023). El Acuerdo entró en vigencia el 4 de noviembre de 2016 (MINAM, 2020).

Por su cuenta, Perú ratificó el Acuerdo el 22 de julio de 2016 y en 2020 se comprometió a disminuir en 30% las emisiones de GEI pronosticadas para el 2030, pudiendo incrementarse a 40% en caso de concretarse financiamiento externo no reembolsable (MINAM, 2020). Sin embargo, aún con reducciones considerables en las emisiones globales de GEI, el CC impactará severamente en Perú (Bergmann et al., 2021).

En 2019, la Unión Europea presentó el documento denominado “Green deal” con la finalidad de reducir las emisiones de GEI en 50% al 2030 y eliminar las emisiones de CO₂ al 2050 y así, satisfacer los compromisos del Acuerdo (Kayakuş et al., 2023).

No obstante, el Acuerdo no garantiza que los países reduzcan sus emisiones de GEI lo suficiente como para lograr la meta mundial, ni tampoco es explícita la cantidad proporcional que cada país debe reducir (CAF, 2023). Además, para lograr las metas del Acuerdo los compromisos de reducción deberían cuadruplicarse (Bergmann et al., 2021). Así, las emisiones de CO₂ siguen incrementándose persistentemente (Agostoni et al., 2023).

2.5 Emisiones de dióxido de carbono y los Objetivos de Desarrollo Sostenible

Los predecesores de los Objetivos de desarrollo sostenible (ODS) fueron los Objetivos de desarrollo del milenio (ODM), introducidos por la ONU en 2001 y que se componían de una serie de objetivos genéricos que debían lograrse globalmente hacia el 2015 (Aslam et al., 2024). De otro lado, desarrollo sostenible es aquel desarrollo que logra satisfacer las necesidades humanas actuales sin poner en riesgo la satisfacción de las necesidades de las generaciones venideras (Fonseca et al., 2020).

Por su parte, los ODS que fueron establecidos en 2015 por la Organización de las Naciones Unidas (ONU), constituyen un plan de acción global para enfrentar los retos más urgentes y lograr un futuro sostenible hacia el año 2030 (Hariyani et al., 2025).

Los ODS que constan de 17 objetivos interconectados (Figura 10), tienen como finalidad la eliminación de la pobreza, la reducción de las desigualdades y asegurar un medioambiente sostenible, al tiempo que se promueve el bienestar de la sociedad y la expansión de la economía (Hariyani et al., 2025). Para el logro de los ODS es necesario el diseño de estrategias integradas y multisectoriales que exhiban los nexos intrincados inherentes a los sistemas sociales, económicos y ambientales (Almulhim y Abubakar, 2026).

Figura 10

Los objetivos de desarrollo sostenible



Nota: Tomado de *Objetivos de Desarrollo Sostenible (ODS)* [Gráfico], por CEPAL, 2018,

https://www.cepal.org/sites/default/files/static/images/e_2018_ods_poster_with_un_emblem_es.png

Por otro lado, la presente tesis (Pronóstico de las emisiones de dióxido de carbono en el Perú en base al producto bruto interno, 2022-2028) se enmarca en la Línea de investigación: Biodiversidad, ecología y conservación, la cual se relaciona con los objetivos ODS-7 (Energía asequible y no contaminante) y ODS-13 (Acción por el clima). En efecto, abordar el aumento de las emisiones de CO₂ antropogénico está directamente relacionado con los objetivos ODS-7 y ODS-13 (Malhotra et al., 2026). Asimismo, para lograr los objetivos ODS-7 y ODS-13 es

imprescindible transitar desde los combustibles fósiles hacia las energías renovables (Hassan et al., 2024).

De otro lado, el ODS-7 se relaciona significativamente con los objetivos ODS-1 (Fin de la pobreza), ODS-2 (Hambre cero), ODS-3 (Salud y bienestar) ODS-8 (Trabajo decente y crecimiento económico) y ODS-13 (Acción por el clima) (Fonseca et al., 2020). Además, de hacer posibles avances en los objetivos ODS-10 (Reducción de las desigualdades) y ODS-11 (Ciudades y comunidades sostenibles) (Almulhim y Abubakar, 2026).

Por su parte, el ODS-13 está vinculado a los objetivos ODS-1 (Fin de la pobreza), ODS-4 (Educación de calidad), ODS-6 (Agua limpia y saneamiento) y ODS-7 (Babacan, 2025).

2.6 Emisiones de dióxido de carbono y producto bruto interno

El crecimiento económico es el incremento del PBI de un país, si el PBI crece más rápido que la población, el PBI per cápita se incrementa y mejora el nivel de vida de los habitantes (Case et al., 2020). Por su parte, el PBI es el valor de mercado de los bienes y servicios finales producidos en un país en cierto espacio temporal (Parkin, 2023).

Los primeros estudios se concentraron en factores que podían influir en el nivel de las emisiones de GEI, principalmente crecimiento económico, consumo de energía, población, comercio y otros (Alaganthiran y Anaba, 2022). En efecto, el crecimiento económico está enlazado con la emisión de GEI (Furkan et al., 2023) y con el continuo deterioro del medioambiente (Erazo-Camacho et al., 2024; Matz-Luck y Christiansen, 2021; Ruppel, 2021).

Dado que el principal aportante de GEI son las emisiones de CO₂ (Famielec et al., 2019) y que la mayoría de estudios usa las emisiones de CO₂ para medir la calidad ambiental (Ahmed et al., 2022; Villanthenkodath, 2023), se ha hallado un nexo positivo entre crecimiento económico y emisiones de CO₂ (Bala et al., 2023; Dinçer et al., 2023; Leitão et al., 2023)

Asimismo, la expansión y el crecimiento de una economía inevitablemente incrementará la producción, lo cual aumentará las emisiones de CO₂ debido al crecimiento de

la demanda de energía (Shahbaz et al., 2023). En efecto, la demanda global de energía está creciendo a una tasa promedio anual de 2% y está asociada al crecimiento del PBI global (Sen, 2021). En tal sentido, los países en vías de desarrollo argumentan que aun necesitan emitir grandes cantidades de CO₂, dado que las fuentes alternativas de energía son muy costosas (Dhongde, 2021). Aunque las emisiones de CO₂, provenientes de la producción de energía de fuentes renovables, son pequeñas o cero (Zhao et al., 2023), el sustento de más del 70% de la población mundial aún depende de los combustibles fósiles (Bose y Satyanarayana, 2021). Por tanto, el crecimiento económico, las emisiones de CO₂ y el consumo de energía son complementarios (Saidi y Hammami, 2015).

En países de altos ingresos (Singapur, USA, Corea del sur), el PBI tiene un fuerte impacto positivo en las emisiones de CO₂, y en países de ingresos medios (Latinoamérica) el impacto es positivo pero débil (Galván et al., 2022). En otros países como Japón y Corea, la relación es positiva entre emisiones de CO₂ y PBI per cápita, mientras que en China la relación es negativa (Mendoza et al., 2021).


2.7 La Curva Medioambiental de Kuznets

La Curva Medioambiental de Kuznets (EKC por sus siglas en inglés) se utiliza para modelar el enlace entre deterioro medioambiental de un país y su PBI per cápita (Rodríguez, 2022). La EKC está inspirada en un estudio de Simón Kuznets de 1955, en el cual se afirma que, inicialmente, la inequidad del ingreso se incrementa hasta cierto punto de inflexión, después del cual la inequidad decrece en el proceso de evolución de un país de ingresos bajos a uno de ingresos altos (Özcan y Öztürk, 2019). Luego, desde 1991 Grossman y Krueger extendieron lo propuesto por Kuznets hacia el campo medioambiental y en 1993 Panayotou utilizó la expresión curva medioambiental de Kuznets (Rajhi y Bardi, 2023).

De acuerdo al modelo EKC, el desarrollo económico de los países y su relación con la degradación del medioambiente se compone de tres etapas (Figura 11).

Figura 11

La curva medioambiental de Kuznets



Nota: Adaptado de *An environmental Kuznets curve (EKC)* (p. 133), por A. Sinha & N. Schneider, 2023, *EKC Modelling in a post-pandemic era. A policy note on socio-ecological trade-offs*. In M. Shahbaz, D. Balsalobre & R. Sharma (Eds.), *Economic growth and environmental quality in a post-pandemic world* (pp. 121-148). Routledge.

En la etapa 1, una economía agrícola transita hacia la industrialización, generando crecimiento económico y degradación medioambiental (Mendoza et al., 2021). Una industria que utiliza tecnologías que afectan al medioambiente, el desconocimiento de los problemas ambientales y la búsqueda del desarrollo económico; puede explicar la asociación positiva entre crecimiento económico y degradación medioambiental (Vo et al., 2019). En esta etapa se produce el efecto escala, bajo el cual el desarrollo de la economía podría incrementar el uso de recursos energéticos, aumentando las emisiones de CO₂ dado cierto nivel tecnológico (Yao et al., 2019). Es decir, en esta etapa prevalece la producción de bienes, la generación de empleo y el incremento del ingreso antes que la calidad medioambiental (Hussain et al., 2023).

En tanto, en la etapa 2 la degradación del medioambiente empeora a medida que se desarrollan las actividades industriales (Mendoza et al., 2021). En esta etapa se produce el efecto estructura, en el cual el desarrollo de la economía es acompañado por el reemplazo

gradual de tecnologías altamente contaminantes por tecnologías mucho menos contaminantes, produciéndose la reducción de las emisiones de CO₂ por unidad producida (Yao et al., 2019). También, en esta etapa se presenta el punto de inflexión, en donde el nivel de degradación medioambiental alcanza su punto máximo. Luego del punto de inflexión, el crecimiento económico puede elevar el nivel de vida (incremento del PBI per cápita) mientras mejora la calidad medioambiental (disminución de las emisiones) (Zhang et al., 2020).

Dado que los países en vías de desarrollo pueden importar tecnologías limpias de los países desarrollados, el punto de inflexión de los países en vías de desarrollo es menor que el de los países desarrollados (Zhao et al., 2023). Así, en términos de PBI per cápita el punto de inflexión es mayor en países de ingreso alto como Suecia (US\$ 88 669) o EEUU (US\$ 43 522), que en países de ingreso medio-bajo como Angola (US\$ 7 421) o El Salvador (US\$ 2 974), o que en países de ingreso bajo como Haití (US\$ 685) o Togo (US\$ 512) (Zhang et al., 2020).

Finalmente, en la etapa 3 la relación entre crecimiento económico y degradación medioambiental se torna negativa (Mendoza et al., 2021). En esta etapa se produce el efecto tecnológico, por el cual se adoptan tecnologías energéticamente eficientes, lo que conduce a menores emisiones de CO₂ para cualquier nivel de producción, o incluso a la reducción neta de las emisiones a pesar de la expansión económica (Yao et al., 2019). Más aún, el crecimiento económico, correctamente orientado, se convierte en una condición para la preservación medioambiental (Rajhi y Bardi, 2023).


En el caso del Perú, no se ha demostrado la presencia de la EKC (Aye y Edoja, 2017; Erazo-Camacho et al., 2024; Mougenot et al., 2022; Pinilla et al., 2018; Zhang et al., 2020). Por tanto, Perú se encuentra en la primera etapa de la EKC, donde la degradación ambiental y el crecimiento económico se relacionan positivamente (Mougenot et al., 2022).

2.8 Perú: Evolución de las emisiones de dióxido de carbono (2001-2021)

Según el Anuario de estadísticas ambientales del INEI (2023), en el lapso 2001-2021 las emisiones de CO₂ mostraron una tendencia creciente, se expandieron un 90,24% de 20 947 miles de t (2001) a 39 850 miles de t (2021), a un ritmo promedio de 3,11% anual. En tanto, en el periodo pre-pandemia COVID-19 (2001-2019) la tasa de crecimiento promedio anual fue 3,25%. Luego, en 2020 las emisiones de CO₂ se contrajeron un -19,32% (a 31 049 miles de t). Por último, en 2021 las emisiones registraron un incremento de 28,34% (Figura 12).

Figura 12

Perú: Evolución y variación de las emisiones de CO₂ (2001-2021)




Nota. Fuente INEI.

Asimismo, entre los años 2001 y 2021 las emisiones de CO₂ per cápita crecieron un 53,84%, de 784 kg/hab. (2001) a 1 206 kg/hab. (2021), a una tasa promedio anual de 2,07%. Mientras que, entre los años 2001 y 2019 (pre-pandemia) la tasa de crecimiento promedio anual fue 2,25%. A continuación, en 2020 las emisiones de CO₂ per cápita decrecieron un -20,54% (a 952 kg/hab.). Finalmente, en 2021 las emisiones de CO₂ per cápita se expandieron un 26,75% (Figura 13).

Figura 13

Perú: Evolución y variación de las emisiones de CO₂ per cápita (2001-2021)




Nota. Fuente INEI.

En cuanto a emisiones de CO₂ según fuente energética, en el lapso 2001-2021 el mayor aportante de emisiones de CO₂ ha sido el rubro hidrocarburos líquidos, aunque su participación ha decrecido de 92% (2001) a 80% (2021). En cambio, la participación del rubro gases se amplió de 1% (2001) a 14% (2021). Por último, la participación del rubro carbón y derivados se ha mantenido estable (Figura 14).

Figura 14

Perú: Participación de las emisiones de CO₂ por fuente energética (2001-2021)




Nota. Fuente INEI.

Con respecto a emisiones de CO₂ según sector económico, en el intervalo 2001-2021 los mayores aportantes de emisiones de CO₂ han sido los sectores transporte, industria y residencial-comercial. En particular, la participación del sector transporte creció de 43% (2001) a 66% (2021). En cambio, la participación del sector industria se redujo de 31% (2001) a 18% (2021). Igualmente, la participación del sector residencial-comercial se contrajo de 16% (2001) a 10% (2021) (Figura 15).

Figura 15


Perú: Participación de las emisiones de CO₂ por sector económico (2001-2021)




Nota. Fuente INEI.

2.9 Perú: Evolución del producto bruto interno a precios de 2007 (2001-2021)

Según la información estadística contenida en la página web del BCRP, en el periodo 2001-2021 el PBI creció un 147,14%, de S/ 223 580 millones (2001) a S/ 552 560 millones (2021), a una media anual de 4,40%. En el lapso pre-pandemia (2001-2019) la tasa de crecimiento fue 4,82% anual. Luego, en 2020 el PBI se contrajo un -10,87% (a S/ 487 192 millones) debido a las medidas adoptadas por el Gobierno para afrontar la pandemia. Después, en 2021 con la progresiva normalización de las actividades económicas y por rebote estadístico, el PBI se incrementó un 13,42% (Figura 16).

Figura 16*Perú: Evolución y variación del PBI a precios de 2007 (2001-2021)**Nota.* Fuente BCRP.

De igual manera, entre los años 2001 y 2021 el PBI per cápita creció un 99,86%, de S/ 8 369 por hab. (2001) a S/ 16 726 por hab. (2021), a una tasa media anual de 3,35%. En tanto, entre 2001 y 2019 (pre-pandemia) la tasa promedio anual fue 3,80%. A continuación, en 2020 el PBI per cápita experimentó disminuyó un -12,22% (a S/ 14 933 por hab.). Seguidamente, en 2021 el PBI per cápita se expandió un 12,01% (Figura 17).

Figura 17*Perú: Evolución y variación del PBI per cápita a precios de 2007 (2001-2021)**Nota.* Fuente BCRP.

2.10 El análisis de regresión lineal

El análisis de regresión lineal es el método estadístico que consiste en explicar el comportamiento de una variable dependiente, por medio de una o más variables independientes. Mediante el método mínimos cuadrados ordinarios (MCO), se construye el modelo de regresión lineal que explica el comportamiento de las variables.

El análisis de regresión lineal presenta dos variantes. Por un lado, si el método solo emplea una variable independiente, se denomina análisis de regresión lineal simple. Por otro lado, si el método emplea más de una variable independiente, se configura el análisis de regresión lineal múltiple. Así, la ecuación de un modelo de regresión lineal simple es:

$$Y = \beta_0 + \beta_1 X_{1t} + \mu_t$$

De otro lado, la ecuación de un modelo de regresión lineal múltiple con k variables independientes es:

$$Y = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_k X_{kt} + \mu_t$$

En las dos ecuaciones, Y representa la variable dependiente, β_0 simboliza la constante (intercepto), los parámetros son representados por los demás β , las variables independientes se simbolizan por medio de las X y, finalmente, μ_t constituye el error del modelo. El subíndice t indica un modelo de regresión lineal con series de tiempo. Una serie de tiempo es aquella compuesta por datos que han sido obtenidos para cierto espacio temporal (semana, mes, año).

Antes de que un modelo de regresión lineal sea considerado apropiado, primero debe corroborarse el cumplimiento de ciertos supuestos (Asteriou y Hall, 2021). Ciertamente, es crucial satisfacer los supuestos para que el modelo produzca resultados precisos (Bolin, 2023). El desconocimiento de los supuestos o de cómo verificarlos puede llevar a conclusiones erróneas (Levine et al., 2021).

Si algún supuesto es violado, el modelo podría no ser el correcto y los resultados de las pruebas de significancia podrían no ser fiables (Newbold et al., 2023). Además, el

incumplimiento de algún supuesto puede originar pronósticos erróneos y sesgados (Flatt y Jacobs, 2019). Los supuestos del análisis de regresión lineal con series temporales son los siguientes:

- Supuesto 1: Linealidad paramétrica. De acuerdo al supuesto, cada variable independiente debe relacionarse linealmente con la variable dependiente (Bolin, 2023). La relación lineal se presenta cuando un parámetro únicamente tiene asignada a la unidad como potencia, y no se divide ni multiplica con otro parámetro (Mignon, 2024). En suma, la variable dependiente es función línea-recta de cada variable independiente (Nayebi, 2020).
- Supuesto 2: El promedio de los errores es cero. El supuesto establece que no existe relación o correlación entre los errores y las variables independientes (exogeneidad) (Tsolacos y Andrew, 2021). Es decir, el término de error explica la variación de la variable dependiente que no es explicada por la(s) variable(s) independiente(s) (Frost, 2019). En realidad, más que un supuesto es una propiedad de MCO, dado que el intercepto se ajusta automáticamente para que la media sea cero (Arkes, 2023).
- Supuesto 3: Especificación correcta del modelo. Un modelo está correctamente especificado cuando su forma funcional es la apropiada y cuando solo incluye variables independientes relevantes (Kumar, 2020).
- Supuesto 4: Los errores son homocedásticos. Los errores son homocedásticos cuando varían similarmente a lo largo de toda la muestra, por tanto, la varianza del error no cambia y es finita (Das, 2019). Cuando se viola el supuesto, los errores son heterocedásticos.
- Supuesto 5: Los errores se distribuyen normalmente. Los errores deben distribuirse de manera normal, con media cero y varianza constante (Greene, 2020).

- Supuesto 6: Los errores no están autocorrelacionados. El supuesto requiere que no pueda predecirse el signo de un error, conociendo el signo el error previo (Frost, 2019). En el caso de regresiones con series temporales, el error de un dato no está correlacionado con el error de otro dato (Mignon, 2024). En las series de tiempo, es muy común la presencia de errores autocorrelacionados (Chatterjee y Simonoff, 2020; Greene, 2020).
- Supuesto 7: Ausencia de quiebre estructural (Estabilidad paramétrica). Los parámetros deben ser invariables, tanto para el período de datos empleado para construir el modelo, como para cualquier período subsiguiente empleado para pronosticar (Brooks, 2019). El quiebre estructural es, principalmente, una fuente de especificación incorrecta en las regresiones con series temporales (Tsolacos y Andrew, 2021).
- Supuesto 8: Ausencia de colinealidad o multicolinealidad. La colinealidad aparece cuando dos variables independientes están altamente correlacionadas, mientras que multicolinealidad significa que más de dos variables independientes están altamente correlacionadas (Martin, 2021). Correlaciones mayores a 0,5 se consideran altas y mayores a 0,7 se consideran extremas (McNulty, 2021). Este supuesto solo es aplicable a modelos de regresión múltiple.

Ante el incumplimiento de algún supuesto, el modelo se corrige y vuelve a verificarse, así hasta encontrar un modelo que no viole ningún supuesto; solo entonces puede realizarse inferencia sobre la relación entre la variable dependiente y la(s) variable(s) independiente(s), o puede pronosticarse la variable dependiente (Rossi, 2022).

Una forma de intentar corregir la violación de los supuestos es transformando las variables (Graham, 2023; Levine et al., 2021). Entre todas las transformaciones posibles (logaritmos, inversas, raíz cuadrada, etc.), la logarítmica es la más común y la más útil (Westfall y Arias, 2020). Finalmente, cada supuesto tiene una herramienta estadística para su

comprobación y un criterio de decisión, así como también medidas remediales en caso el supuesto sea violado (Tabla 2).

Tabla 2

Supuestos MCO, medios de verificación, criterios de decisión y medidas remediales

Supuesto MCO	Medio de verificación	Criterio de decisión	Medidas remediales
1 Linealidad paramétrica	Multiplicador de Lagrange: Cuadrados y logaritmos	valor $p > 0,05$ (5%)	1.1 Transformación de variables 1.2 Modelos polinomiales
2 El promedio de los errores es cero ^a	No requiere	No aplica	No aplica
3 Especificación correcta del modelo	Prueba RESET ^b de Ramsey	valor $p > 0,05$ (5%)	3.1 Exclusión de variable irrelevante 3.2 Inclusión de variable relevante 3.3 Transformación de variables
4 Los errores son homocedásticos	Prueba de heterocedasticidad de White	valor $p > 0,05$ (5%)	4.1 Corrección por heterocedasticidad 4.2 Transformación de variables 4.3 Mínimos cuadrados ponderados
5 Los errores se distribuyen normalmente	Prueba de Doornik-Hansen	valor $p > 0,05$ (5%)	5.1 Incrementar muestra 5.2 Transformación de variables
6 Los errores no están autocorrelacionados	Prueba d de Durbin-Watson	$du \leq d \leq 4-du$	6.1 Regresión Prais-Winsten
7 Ausencia de quiebre estructural	Pruebas CUSUM ^c y CUSUMSQ ^d	Gráficas no cruzan las bandas de confianza.	7.1 Inclusión de variable dummy
8 Ausencia de colinealidad o multicolinealidad	Factor inflacionario de varianza (FIV)	$FIV \leq 10$	8.1 Exclusión de variables ($FIV > 10$) 8.2 Transformación de variables 8.3 Incrementar muestra

Nota. ^a Es una propiedad del método MCO. ^b RESET = Regression equation specification error test. ^c CUSUM = Cumulative sum of residuals. ^d CUSUMSQ = Cumulative sum of square residuals.

2.11 El principio de parsimonia

El principio de parsimonia estipula que siempre se debe preferir los modelos más simples, aquellos con menos variables independientes o parámetros (Asteriou y Hall, 2021; Martin, 2021; Newbold et al., 2023). Un modelo de regresión con fines de pronóstico requiere conocer con suficiente precisión los valores futuros de las variables independientes. Así, la precisión de un modelo de regresión simple depende, entre otros factores, del pronóstico preciso de solo una variable independiente, a diferencia de un modelo de regresión múltiple.

2.12 La precisión de los pronósticos

La precisión mide la cercanía entre el pronóstico y el dato observado (Swink et al., 2020). El error medio absoluto porcentual (MAPE, por sus siglas en inglés) y el coeficiente de determinación (R^2) son los indicadores más comunes para medir la precisión de un pronóstico (Ashour y Aldahhan, 2023). El MAPE es el indicador más empleado para establecer que tan preciso es un pronóstico (Liu, 2022; Myerson, 2023; Tay, 2024; Vandeput, 2023). El MAPE es el promedio de los valores absolutos de los errores expresado en porcentaje. Mientras menor sea el MAPE, más preciso será el pronóstico (Klimberg, 2023; Tsolacos y Andrew, 2021). Así, la precisión de un pronóstico presenta cuatro categorías (Tabla 3) (Ghiani et al., 2022).

Tabla 3

Precisión del pronóstico de acuerdo al valor del MAPE

Valor del MAPE	Precisión del pronóstico
$\text{MAPE} \leq 10\%$	Muy buena
$10\% < \text{MAPE} \leq 20\%$	Buena
$20\% < \text{MAPE} \leq 30\%$	Moderada
$\text{MAPE} > 30\%$	Pobre

Nota: Adaptado de *Evaluation of the quality of a forecasting method by means of the mean absolute percentage error* (p. 155), por G. Ghiani, G. Laporte & R. Musmanno, 2022, *Introduction to logistics systems management with Microsoft Excel and Python examples* (3rd ed.), Wiley.

De otro lado, para lograr un pronóstico confiable el modelo de regresión debe presentar un R^2 suficientemente alto, en tal caso la(s) variable(s) independiente(s) explica(n) sustancialmente el comportamiento de la variable dependiente (Stock y Watson, 2020). Así, un modelo con un R^2 mayor a 0,91 produce pronósticos muy buenos, mientras que un modelo con un R^2 entre 0,81 y 0,90 pronostica bastante bien (Man et al., 2022).


2.13 El sesgo en los pronósticos

El sesgo es la tendencia persistente de un pronóstico a sobrestimar o subestimar los datos observados (Reid y Sanders, 2023) y puede ocurrir, entre otros motivos, por la exclusión de variables relevantes y por la elección de una forma funcional inapropiada (Jacobs y Chase, 2023).

El sesgo puede medirse calculando el error medio, el cual es el promedio de la sumatoria de los errores (Tsolacos y Andrew, 2021). El sesgo puede tomar cualquier valor, cuando es positivo el pronóstico tiende a subestimar los datos observados (Figura 18a) y cuando es negativo el pronóstico tiende a sobreestimarlos (Figura 18b) (Groebner et al., 2018).

Figura 18

El sesgo de los pronósticos (a) Sesgo positivo y (b) Sesgo negativo



Nota: Adaptado de *Pronóstico con Sesgo (a) Mayor a Cero y (b) Menor a Cero* (p. 25), por I.


Montoya, 2022, El análisis de regresión lineal y la precisión del pronóstico de demanda de productos hidrobiológicos congelados en el Perú [Tesis de maestría]. Universidad Nacional Federico Villarreal (UNFV). <https://hdl.handle.net/20.500.13084/6542>

Un pronóstico no debe presentar sesgo, es decir, en promedio debe ser correcto (Cachon y Terwiesch, 2020). No obstante, se considera que un pronóstico es insesgado cuando el valor del sesgo es cercano a cero (Ravindran et al, 2023; Russell et al., 2020).

Finalmente, el objetivo es obtener un pronóstico preciso e insesgado (Wisner et al., 2023). Sin embargo, pronósticos precisos pueden ser sesgados y pronósticos insesgados pueden ser imprecisos (Figura 19) (Vandeput, 2023).

Figura 19

Pronóstico: Combinaciones posibles entre precisión y sesgo



Nota: Adaptado de *Forecasting accuracy and bias* (p. 62), por N. Vandeput 2023, Demand forecasting. Best practices, Manning.

2.14 El concepto de elasticidad

Elasticidad es un concepto general usado para cuantificar el cambio de una variable frente al cambio de otra variable (Case et al., 2020). La elasticidad se calcula dividiendo el valor absoluto del cambio porcentual de una variable entre el valor absoluto del cambio porcentual de la otra variable. Si el valor de la división está entre cero y uno, el cambio es inelástico. Mientras que, si el resultado es mayor a uno, entonces el cambio es elástico.

Por otro lado, si en el análisis de regresión lineal se emplea el logaritmo natural de las variables, la pendiente del modelo (β_1) es la elasticidad de la variable dependiente respecto de la variable independiente (Asteriou y Hall, 2021; Kumar, 2020; Mignon, 2024). Así, un cambio de 1% en la variable independiente genera un cambio de $\beta_1\%$ en la variable dependiente.

III MÉTODO

3.1 Tipo de investigación

La investigación es de tipo cuantitativa y aplicada. Por un lado, la investigación cuantitativa procesa una cantidad suficiente de datos de eventos representativos con la finalidad de obtener conclusiones (Deb et al., 2019). Por otro lado, investigación aplicada utiliza el conocimiento teórico o científico para resolver problemas tangibles que afectan a la humanidad (Ajimotokan, 2023).

El nivel de la investigación es el correlacional. La investigación correlacional determina la presencia y el tipo de asociación (positiva o negativa) que podría existir entre dos variables (Gravetter et al., 2021).

El diseño de la investigación es no experimental de múltiples series de tiempo. De un lado, en la investigación no experimental las variables no son modificadas y suceden de manera natural antes y durante la investigación (Singh y Thirsk, 2022). De otro lado, la investigación de múltiples series de tiempo involucra el empleo de más de un conjunto de datos que han sido colectados en el tiempo con cierta periodicidad (semanal, mensual, anual, etc.) (Babbie, 2021).

3.2 Población y muestra

3.2.1 Población

Población es todo el conjunto de individuos u objetos de interés, o bien los datos que se han obtenido de individuos u objetos de interés (Lind et al., 2022). En estudios que utilizan información de series temporales de fuentes oficiales, la población está conformada por el total de registros disponibles de tales series.

Por ejemplo, para Barreto (2018) la población estuvo conformada por las series anuales Consumo final privado y PBI para el periodo 1950-2016. No obstante, los modelos de regresión se construyeron con datos del lapso 2000-2013.

Del mismo modo, Huacoto (2021) determinó como población a las series mensuales PBI, Tasa de interés de referencia, Base monetaria y Tipo de cambio para los años 1990-2018. Con todo, los modelos de regresión se crearon con datos del periodo 2007-2018.

Asimismo, Montoya (2022) estableció como población a la serie anual Demanda de productos hidrobiológicos congelados (1980-2018), además de las series anuales Población, PBI, PBI pesquero, PBI manufacturero, Demanda interna, Inversión privada e Inflación para el intervalo 1950-2018. Sin embargo, los modelos de regresión se elaboraron con información del periodo 1980-2013.

Por último, Paucar (2023) definió como población a las series anuales PBI y PBI agrícola para el periodo 1950-2023. Aun así, los modelos de regresión se construyeron con datos del intervalo 2001-2021.

En consecuencia, para la presente investigación la población está constituida por las series temporales:

- Emisiones de CO₂ en miles de toneladas para el periodo 1993-2021 (29 años).
- PBI en millones de soles a precios de 2007 para el intervalo 1922-2023 (102 años).

3.2.2 Muestra

Para la construcción de modelos de regresión lineal el tamaño muestral debe ser suficientemente grande. Una muestra insuficiente puede ser incapaz de detectar relaciones entre la variable dependiente y la(s) variable(s) independiente(s) (Pardoe, 2021). Además, el coeficiente de determinación (R^2) deja de ser una medida confiable de ajuste del modelo (Doane y Seward, 2022; Rivera 2020). Asimismo, las pruebas estadísticas pierden potencia (rechazar correctamente una hipótesis nula falsa) (Hair et al., 2019; Keith, 2019; Rivera 2020).

Por lo cual, se ha sugerido que, por cada variable independiente contenida en el modelo de regresión, debe existir entre 10 y 20 datos (Hassouna, 2023; Keith, 2019; Siems 2024). Aunque, autores más conservadores han propuesto utilizar entre 15 y 20 datos (Carvalho y

Kostelíjk, 2022; Cooksey, 2020; Hair et al., 2019; Podaras et al., 2021). Por otro lado, se ha sugerido que los pronósticos son más precisos empleando entre 13 y 16 datos por cada variable independiente (Montoya, 2022).

En razón de que el modelo de regresión a construir se compondrá de una variable independiente, y además, siendo conservadores, se requiere que las series temporales tengan una extensión de entre 15 y 20 datos. Sin embargo, considerando que el Anuario de estadísticas ambientales 2023 del INEI contiene la serie Emisiones de dióxido de carbono para el periodo 2001-2021 (21 años), se decidió utilizar ese marco muestral. Por tanto, la muestra está constituida por las series temporales especificadas en el acápite 3.2.1 (Población), pero para los años 2001-2021:

- Emisiones de CO₂ en miles de toneladas (CO₂).
- Producto bruto interno en millones de soles a precios de 2007 (PBI)

3.3 Operacionalización de variables

A continuación, se presenta la definición conceptual, definición operacional, dimensiones e indicadores de las variables de estudio (Tabla 4).

Tabla 4

Operacionalización de las variables

Variable	Definición conceptual	Definición operacional	Dimensión	Indicador
Variable independiente (X): Producto Bruto Interno (PBI)	Valor de mercado de los bienes y servicios finales producidos por un país durante cierto periodo (Mankiw, 2024).	Valor monetario de la producción nacional anual de bienes y servicios publicado por el BCRP.	Desempeño económico	Logaritmo natural del PBI en millones de soles a los precios de 2007.
Variable dependiente (Y): Emisiones de dióxido de carbono (CO ₂)	Cantidad de CO ₂ liberado que tendría un efecto significativo en el cambio climático (IPCC, 2023).	Cantidad anual de CO ₂ liberado a nivel nacional publicado por el INEI.	Degradación ambiental	Logaritmo natural de las emisiones de CO ₂ en miles de toneladas.

3.4 Instrumentos

Debido a que la presente investigación emplea información de fuentes secundarias oficiales, no se requiere de instrumentos específicos para el acopio de información. En tal sentido, las series temporales necesarias para construir los modelos de regresión se obtuvieron directamente de las páginas oficiales del BCRP y del INEI. Concretamente, la serie temporal PBI para el intervalo 2001-2021 se obtuvo de las series estadísticas del BCRP (<https://estadisticas.bcrp.gob.pe/estadisticas/series/anuales/pbi-por-sectores>). De la misma manera, la serie temporal Emisiones de dióxido de carbono para el lapso 2001-2021 se obtuvo de la publicación digital Anuario de estadísticas ambientales 2023 del INEI (<https://www.inei.gob.pe/biblioteca-virtual/publicaciones-digitales/>).

3.5 Procedimientos

3.5.1 Hipótesis General: El Pronóstico de las Emisiones de CO₂ en el Perú Tendrá una Tendencia Creciente en el Espacio Temporal 2022-2028

- a. Con la información del periodo 2001-2021 construir un modelo de regresión lineal con los logaritmos naturales de las series emisiones de CO₂ (variable dependiente) y PBI (variable independiente).
- b. Verificar cada uno de los supuestos del análisis de regresión lineal (ver pp. 47-50). Primero corroborar los supuestos de linealidad, especificación correcta, homocedasticidad y normalidad. Si el valor p de la prueba respectiva es mayor a 0,05 se concluye que el modelo no ha violado el supuesto. En cambio, si el valor p es menor e igual a 0,05 se colige que el supuesto ha sido violado y, por tanto, se deberá aplicar la medida remedial pertinente para intentar corregir el modelo.
- c. Corroborar el supuesto de no autocorrelación. Si el estadístico “d” de Durbin-Watson cae en la zona de no autocorrelación se deduce que no se ha violado el supuesto. Caso

contrario, el supuesto ha sido violado y, por tanto, se deberá aplicar la medida remedial pertinente para intentar corregir el modelo.

- d. Probar el supuesto de ausencia de quiebre estructural. Si las gráficas CUSUM (Cumulative sum of residuals) y CUSUMSQ (Cumulative sum of square residuals) no cruzan las bandas de confianza se concluye que el supuesto ha sido satisfecho. En su defecto, el supuesto ha sido violado, por ende, se deberá aplicar la medida remedial pertinente para intentar corregir el modelo.
- e. Dado que se está evaluando un modelo de regresión lineal simple, no es pertinente validar el supuesto de ausencia de colinealidad o multicolinealidad. Continuar con el paso “f”.
- f. Si el modelo no satisface todos los supuestos se deberá repetir el proceso desde el paso “a”, pero con los datos del periodo 2002-2021. Si el nuevo modelo viola algún supuesto, volver al paso 1 con las series 2003-2021, etc. Así, hasta obtener un modelo que no viole ningún supuesto, en tal caso continuar con el paso “g”.
- g. Practicar la prueba de significancia individual (prueba t). Si los valores p de la prueba t de la constante y del coeficiente de la variable independiente son menores e iguales a 0,05 se concluye que ambos son significativamente diferentes de cero, continuar con el paso “h”. En cambio, si los valores p son mayores a 0,05 se colige que la constante, la variable independiente o ambos no son significativamente diferentes de cero y deberá descartarse el modelo. Regresar al paso “f”, el modelo satisface los supuestos, pero no es significativo.
- h. Verificar que el coeficiente de determinación (R^2) del modelo sea mayor o igual a 0,81, continuar con el paso 9. De lo contrario, volver al paso “f”, el modelo satisface los supuestos y es significativo, pero carece de suficiente poder explicativo.

- i. Pronosticar las emisiones de CO₂ para el lapso 2022-2028. El pronóstico de la variable independiente PBI se obtuvo del Marco macroeconómico multianual (MMM) 2025-2028 (Ministerio de Economía y Finanzas [MEF], 2024).
- j. Evaluar la tendencia del pronóstico de las emisiones de CO₂. Si la tendencia es creciente, no se rechazará (aceptará) la hipótesis general. De lo contrario, se deberá rechazar la hipótesis general.

3.5.2 Hipótesis Específica 1: En el Perú las Emisiones de CO₂ y el PBI Muestran una Relación Positiva en el Lapso 2005-2021

- a. Verificar el signo del coeficiente de la variable PBI en el modelo construido para probar la hipótesis general. Si el signo es positivo se deduce que existe una relación positiva entre las emisiones de CO₂ y el PBI. Por el contrario, si el signo es negativo se concluye que la relación es negativa.

3.5.3 Hipótesis Específica 2: En el Perú las Emisiones de CO₂ Son Inelásticas con Respecto al PBI en los Años 2005-2021

- a. Verificar el valor del coeficiente de la variable PBI en el modelo construido para probar la hipótesis general. Por un lado, si el valor absoluto del coeficiente es mayor a 0 pero menor que 1, se deduce que las emisiones de CO₂ son inelásticas con respecto al PBI. Por lo tanto, una variación de 1% en el PBI generará que las emisiones de CO₂ varíen en menos de 1%. Por otro lado, si el valor absoluto del coeficiente es superior a 1, se concluye que las emisiones de CO₂ son elásticas con relación al PBI. En consecuencia, un cambio de 1% en el PBI producirá que las emisiones de CO₂ cambien en más de 1%. Por último, si el valor absoluto del coeficiente es exactamente 1, se colige que existe elasticidad unitaria entre las emisiones de CO₂ y el PBI. Por tanto, una modificación de 1% en el PBI producirá que las emisiones de CO₂ se modifiquen en exactamente 1%.

3.5.4 Hipótesis Específica 3: Las Estimaciones de las Emisiones de CO₂ en el Perú Presentan una Precisión Muy Buena ($MAPE \leq 10\%$) Entre los Años 2005-2021

- a. Estimar las emisiones de CO₂ para el periodo 2005-2021 utilizando el modelo construido para probar la hipótesis general.
- b. Para cada año calcular el error restando al dato observado (real) la estimación generada por el modelo de regresión.
- c. Tomar el valor absoluto de cada resta, dividirlo entre el valor observado (real) y multiplicarlo por 100 para convertirlo en porcentaje.
- d. Calcular el MAPE del modelo promediando los porcentajes obtenidos en el paso “c”.

Si el MAPE es $\leq 10\%$, entonces las estimaciones de las emisiones de CO₂ en el Perú presentan una precisión muy buena.

3.5.5 Hipótesis Específica 4: Las Estimaciones de las Emisiones de CO₂ en el Perú Son Insesgadas Durante el Periodo 2005-2021

- a. Estimar las emisiones de CO₂ para el periodo 2005-2021 utilizando el modelo construido para probar la hipótesis general.
- b. Para cada año calcular el error restando al dato observado (real) la estimación producida por el modelo.
- c. Calcular el sesgo del modelo promediando los valores obtenidos en el paso “b”.
- d. Si el número de datos en el paso “b” es mayor a 30 continuar con el paso “e”. Caso contrario, aplicar la prueba de normalidad a los datos. Si los datos se distribuyen normalmente continuar con el paso “e”. De no ser así, no se puede probar que el sesgo calculado en el paso “c” es estadísticamente igual a cero.
- e. Aplicar la prueba t para probar que el sesgo calculado es estadísticamente igual a cero. Si el valor p de la prueba es mayor a 0,05 se deduce el sesgo es estadísticamente igual a cero y por tanto las estimaciones de las emisiones de CO₂ per cápita son insesgadas.

De otro modo, el sesgo no es estadísticamente igual a cero, por lo cual las estimaciones presentan sesgo.

3.6 Análisis de datos

El procesamiento y el análisis de la información estadística se realizarán con el software estadístico Gretl versión 2024a y con la hoja de cálculo Excel. Para descargar el software gratuitamente ir al siguiente enlace: <https://gretl.sourceforge.net/es.html>

IV RESULTADOS

4.1 Hipótesis general

En la construcción de los modelos de regresión lineal simple se empleó la transformación logarítmica de las variables. Los logaritmos pueden corregir el incumplimiento de los supuestos y, además, el coeficiente de la variable independiente cuantifica la elasticidad de la variable dependiente (emisiones de CO₂) respecto de la variable independiente (PBI).

Los cuatro primeros modelos construidos violaron entre dos y tres supuestos (Tabla 5). En consecuencia, en ninguno de estos modelos se puede llevar a cabo las pruebas de significancia, ni tampoco pueden ser utilizados con fines de pronóstico.

Tabla 5

Validación de los supuestos MCO en modelos L-CO₂ sobre L-PBI por periodo

Supuesto	Periodo			
	2001-2021	2002-2021	2003-2021	2004-2021
Linealidad paramétrica ^a				
Cuadrados	0,006	0,020	0,069	0,135
Logaritmos	0,005	0,019	0,066	0,129
Especificación correcta ^a	0,003	0,010	0,039	0,036
Errores homocedásticos ^a	0,279	0,263	0,280	0,093
Errores normales ^a	0,189	0,315	0,636	0,735
Errores sin autocorrelación ^b	1,047	1,176	1,278	1,286
Estabilidad paramétrica ^c				
CUSUM	No	No	Si	No
CUSUMSQ	Si	Si	Si	Si


Nota. Fuente software Gretl versión 2024a. En negritas cuando se cumple el supuesto.

^a Los valores corresponden al valor p de la prueba respectiva. ^b Los valores representan el “d” de Durbin-Watson. Un valor cercano a 2 implica el cumplimiento del supuesto. ^c Corresponde al resultado de las pruebas gráficas CUSUM y CUSUMSQ. Si = cumple, No = no cumple.

A continuación, se construye el modelo MCO L-CO₂ sobre L-PBI (2005-2021). Para el modelo, los valores p de las pruebas supera el 0,05 motivo por el cual no se rechazan las hipótesis nulas (Figura 20). Por lo tanto, el modelo MCO L-CO₂ sobre L-PBI (2005-2021) satisface los supuestos de linealidad (cuadrados y logaritmos), especificación correcta, homocedasticidad y normalidad.

Figura 20

Modelo MCO L-CO₂ sobre L-PBI (2005-2021) y valores p de las pruebas de linealidad (cuadrados y logaritmos), especificación correcta, homocedasticidad y normalidad




Nota. Fuente software Gretl versión 2024a.

Seguidamente, se lleva a cabo la prueba de no autocorrelación. El estadístico “d” de Durbin-Watson del modelo MCO L-CO₂ sobre L-PBI (2005-2021) es 1,636 (Figura 21) y sus valores críticos, para 17 datos (n) y una variable independiente (k), son 1,133 (d_L) y 1,381 (d_U) (Figura 22).

Figura 21

Modelo MCO L-CO₂ sobre L-PBI (2005-2021): Estadístico “d” de Durbin-Watson para autocorrelación




	coeficiente	Desv. típica	Estadístico t	valor p
const	-1,64817	0,707263	-2,330	0,0342 **
l_PBI	0,924189	0,0545862	16,93	3,47e-011 ***

Media de la vble. dep.	10,32471	D.T. de la vble. dep.	0,211009
Suma de cuad. residuos	0,035425	D.T. de la regresión	0,048597
R-cuadrado	0,950274	R-cuadrado corregido	0,946959
F(1, 15)	286,6530	Valor p (de F)	3,47e-11
Log-verosimilitud	28,35328	Criterio de Akaike	-52,70657
Criterio de Schwarz	-51,04014	Crit. de Hannan-Quinn	-52,54092
rho	0,114131	Durbin-Watson	1,635761

Nota. Fuente software Gretl versión 2024a.

Figura 22

Modelo MCO L-CO₂ sobre L-PBI (2005-2021): Valores críticos d_L y d_U de la prueba de Durbin-Watson de autocorrelación



Valores críticos al 5% del estadístico de Durbin-Watson, n = 17, k = 1	
dL	= 1,1330
dU	= 1,3812


Nota. Fuente software Gretl versión 2024a.

Dado que el estadístico “d” de Durbin-Watson cae en la zona de no autocorrelación, se concluye que los errores del modelo no presentan autocorrelación. Por tanto, se colige que el modelo MCO L-CO₂ sobre L-PBI (2005-2021) satisface el supuesto de no autocorrelación

(Figura 23). Si el “d” hubiese caído en una zona de indecisión, lo recomendado es asumir la violación del supuesto y aplicar la regresión Prais-Winsten para intentar superar el problema.

Figura 23


Modelo MCO L-CO₂ sobre L-PBI (2005-2021): Resultado de la prueba de Durbin-Watson de autocorrelación



De otro lado, las pruebas gráficas CUSUM (Cumulative sum of residuals) y CUSUMSQ (Cumulative sum of square residuals) no exceden las bandas de confianza (Figuras 24 y 25). Por lo tanto, el modelo MCO L-CO₂ sobre L-PBI (2005-2021) satisface el supuesto de estabilidad paramétrica.

Figura 24


Modelo MCO L-CO₂ sobre L-PBI (2005-2021): Resultado de la prueba gráfica CUSUM de estabilidad paramétrica



Nota. Fuente software Gretl versión 2024a.

Figura 25

Modelo MCO L-CO₂ sobre L-PBI (2005-2021): Resultado de la prueba gráfica CUSUMSQ de estabilidad paramétrica



Nota. Fuente software Gretl versión 2024a.

Puesto que se ha demostrado que el modelo MCO L-CO₂ sobre L-PBI (2005-2021) cumple con todos los supuestos, se procede a practicar las pruebas t de significancia individual de los parámetros (coeficientes). En tal sentido, considerando que los valores p de la constante y de la variable L-PBI son menores e iguales a 0,05 (Figura 26) se rechaza la hipótesis nula de parámetros iguales a cero. Es decir, individualmente los parámetros son significativamente diferentes de cero.

Además, el coeficiente de determinación (R^2) del modelo es 0,95 (Figura 26), el cual es considerado muy alto, lo que significa que el modelo produce pronósticos confiables y muy buenos, y que la variable L-PBI explica en un 95% el comportamiento de la variable L-CO₂.

En consecuencia, la variable L-PBI es útil para explicar y pronosticar el comportamiento de la variable L-CO₂. El modelo se plasma en la ecuación siguiente:

$$\text{L-CO}_2 = -1,64817 + 0,924189 \text{ L-PBI}$$

Figura 26

Modelo MCO L-CO₂ sobre L-PBI (2005-2021): Resultado de las pruebas t de significancia individual y coeficiente de determinación (R²)

	coeficiente	Desv. típica	Estadístico t	valor p
const	-1,64817	0,707263	-2,330	0,0342 **
l_PBI	0,924189	0,0545862	16,93	3,47e-011 ***

Media de la vble. dep.	10,32471	D.T. de la vble. dep.	0,211009
Suma de cuad. residuos	0,035425	D.T. de la regresión	0,048597
R-cuadrado	0,950274	R-cuadrado corregido	0,946959
F(1, 15)	286,6530	Valor p (de F)	3,47e-11
Log-verosimilitud	28,35328	Criterio de Akaike	-52,70657
Criterio de Schwarz	-51,04014	Crit. de Hannan-Quinn	-52,54092
rho	0,114131	Durbin-Watson	1,635761

Nota. Fuente software Gretl versión 2024a.

Seguidamente, para pronosticar las emisiones de CO₂ es indispensable conocer el comportamiento del PBI durante el periodo 2022-2028. Por un lado, el PBI para el bienio 2022-2023 se encuentra disponible en la web del BCRP. Por otro lado, el pronóstico de la variación porcentual real del PBI para el periodo 2024-2028 (Tabla 6) está publicado en la web del MEF en el Marco Macroeconómico Multianual 2025-2028.

Tabla 6

Perú: Variación real del PBI (2024-2028)


Año	Variación real del producto bruto interno	
	Pronóstico MEF	Millones de soles
2024	3,2%	582 317
2025	3,1%	600 369
2026	2,9%	617 780
2027	3,0%	636 313
2028	3,0%	655 402

Nota. Fuente Ministerio de economía y finanzas

De acuerdo a los pronósticos del modelo MCO L-CO₂ sobre L-PBI (2005-2021), entre los años 2022-2028 las emisiones de CO₂ crecerán en 14,26%, de 39 984 miles de t (2022) a 45 684 miles de t (2028) (Figura 27), lo cual revela una tendencia creciente que se estaría acelerando. Así, en el septenio 2015-2021 la tasa de crecimiento promedio anual fue 2,11%, mientras que en el septenio 2022-2028 la tasa sería de 2,25%. Por lo tanto, no se rechaza la hipótesis general. Es decir, el pronóstico de las emisiones de CO₂ en el Perú tendrá una tendencia creciente en el espacio temporal 2022-2028.

Figura 27

Perú: Emisiones de CO₂ observado (2005-2021) y pronosticado (2022-2028) en miles de t




4.2 Hipótesis específica 1

Dado que el signo del coeficiente de la variable L-PBI es positivo (Figura 28), se deduce que ambas variables se mueven en la misma dirección. Vale decir, la expansión (contracción) del PBI produce el aumento (decremento) de las emisiones de CO₂. Por lo tanto, no se rechaza la hipótesis específica 1. Es decir, en el Perú las emisiones de CO₂ y el PBI muestran una relación positiva en el lapso 2005-2021.

Figura 28

Modelo MCO L-CO₂ sobre L-PBI (2005-2021): Signo de la variable L-PBI



gretl: modelo 5

Archivo Editar Contrastes Guardar Gráficos Análisis LaTeX

Modelo 5: MCO, usando las observaciones 2005-2021 (T = 17)
Variable dependiente: l_CO2

	coeficiente	Desv. típica	Estadístico t	valor p	
const	-1,64817	0,707263	-2,330	0,0342	**
l_PBI	0,924189	0,0545862	16,93	3,47e-011	***
Media de la vble. dep.	10,32471	D.T. de la vble. dep.	0,211009		
Suma de cuad. residuos	0,035425	D.T. de la regresión	0,048597		
R-cuadrado	0,950274	R-cuadrado corregido	0,946959		
F(1, 15)	286,6530	Valor p (de F)	3,47e-11		
Log-verosimilitud	28,35328	Criterio de Akaike	-52,70657		
Criterio de Schwarz	-51,04014	Crit. de Hannan-Quinn	-52,54092		
rho	0,114131	Durbin-Watson	1,635761		


Nota. Fuente software Gretl versión 2024a.

4.3 Hipótesis específica 2

En razón de que el valor del coeficiente de la variable L-PBI es menor a 1 (Figura 29), se colige que el incremento del PBI en x% genera un incremento en las emisiones de CO₂ menor a x%. Concretamente, la expansión del PBI en 1% resulta en el aumento de las emisiones de CO₂ en 0,924%. En consecuencia, no se rechaza la hipótesis específica 2. Es decir, en el Perú las emisiones de CO₂ son inelásticas con respecto al PBI en los años 2005-2021.

Figura 29

Modelo MCO L-CO₂ sobre L-PBI (2005-2021): Elasticidad CO₂ - PBI



gretl: modelo 5

Archivo Editar Contrastes Guardar Gráficos Análisis LaTeX

Modelo 5: MCO, usando las observaciones 2005-2021 (T = 17)
Variable dependiente: l_CO2

	coeficiente	Desv. típica	Estadístico t	valor p	
const	-1,64817	0,707263	-2,330	0,0342	**
l_PBI	0,924189	0,0545862	16,93	3,47e-011	***
Media de la vble. dep.	10,32471	D.T. de la vble. dep.	0,211009		
Suma de cuad. residuos	0,035425	D.T. de la regresión	0,048597		
R-cuadrado	0,950274	R-cuadrado corregido	0,946959		
F(1, 15)	286,6530	Valor p (de F)	3,47e-11		
Log-verosimilitud	28,35328	Criterio de Akaike	-52,70657		
Criterio de Schwarz	-51,04014	Crit. de Hannan-Quinn	-52,54092		
rho	0,114131	Durbin-Watson	1,635761		


Nota. Fuente software Gretl versión 2024a.

4.4 Hipótesis específica 3

Dado que la aplicación del modelo MCO L-CO₂ sobre L-PBI (2005-2021) visualmente produce estimados de las emisiones de CO₂ muy cercanas a las emisiones de CO₂ observadas (Figura 30), se puede presumir que la precisión se clasifica como muy buena.

Figura 30


Perú: Emisiones de CO₂ observado y estimado (2005-2021) en miles de t



Por un lado, los errores absolutos porcentuales del periodo 2005-2021 son menores o iguales a 10%, excepto para el año 2020 (11,86%) (Figura 31). Por otro lado, el MAPE del periodo 2005-2021 de 3,78% confirma que la precisión de la estimación clasifica como muy buena (Figura 31). En consecuencia, no se rechaza la hipótesis específica 3. Es decir, las estimaciones de las emisiones de CO₂ en el Perú presentan una precisión muy buena (MAPE $\leq 10\%$) entre los años 2005-2021.

Figura 31

Error absoluto porcentual de las emisiones de CO₂ estimadas y MAPE (2005-2021)




4.5 Hipótesis específica 4

La aplicación del modelo MCO L-CO₂ sobre L-PBI (2005-2021) genera errores positivos y negativos de forma aleatoria con un sesgo de 31,47 (Figura 32). En esa línea, el modelo parece no sobrestimar ni subestimar las emisiones de CO₂ observadas. Lo que corresponde es determinar si el sesgo de 31,47 es estadísticamente igual a cero.

Figura 32


Error y sesgo de las emisiones de CO₂ estimadas (2005-2021)



Seguidamente, se realiza la prueba de normalidad de los errores de la estimación. Dado que el valor p de las pruebas de normalidad es mayor a 0,05 (Figura 33), no se rechaza la hipótesis de normalidad y se concluye que los errores de la estimación se distribuyen normalmente. Por tanto, se puede proceder a probar que el sesgo (error medio de la estimación) de 31,47 es estadísticamente igual a cero.

Figura 33

Resultado de las pruebas de normalidad para los errores de la estimación




Nota. Fuente software Gretl versión 2024a.

Finalmente, en razón de que el valor p de la prueba t es mayor a 0,05 (Figura 34), no se rechaza la hipótesis de que la media es igual a cero y se colige que el sesgo de 31,47 es estadísticamente igual a cero, es decir, las estimaciones carecen de sesgo. Por lo tanto, no se rechaza la hipótesis específica 4. Es decir, las estimaciones de las emisiones de CO₂ en el Perú son insesgadas durante el periodo 2005-2021.

Figura 34

Resultado de la prueba t de media igual a cero para los errores de la estimación



Nota. Fuente software Gretl versión 2024a.

V DISCUSIÓN DE RESULTADOS

5.1 Hipótesis general

El pronóstico de las emisiones de CO₂ en el Perú tendrá una tendencia creciente (2022-2028) con una expansión promedio de 2,25% anual. Este resultado coincide con los hallazgos de otras investigaciones. En efecto, Pao y Fu (2015) hallaron para México (2012-2020) una tendencia creciente (1,46% anual). Asimismo, Wu et al. (2015) encontraron tendencias ascendentes (2015-2020) en Brasil (1,87% anual), Rusia (1,63% anual), India (2,50% anual), China (2,12% anual) y Sudáfrica (1,22% anual). Igualmente, Pabuççu y Bayramoglu (2016) revelaron para Turquía (2020-2030) una tendencia alcista (5,33% anual). También, Ho (2018) halló en Vietnam (2015-2019) una tendencia creciente (3,32% anual).

De igual modo, Del Cioppo (2019) encontró para Ecuador (2020-2050) una tendencia expansiva (0,97% anual). Además, Ameyaw et al. (2020) descubrieron tendencias crecientes (2015-2030) en Benín (2,08% anual), Burkina Faso (1,91% anual), Cabo Verde (1,22% anual), Gambia (0,52% anual), Ghana (1,33% anual), Guinea (1,97% anual), Guinea Bissau (0,52% anual), Costa de Marfil (4,02% anual), Liberia (0,04% anual), Mali (2,42% anual), Mauritania (1,51% anual), Níger (2,32% anual), Nigeria (0,35% anual), Senegal (0,69% anual), Sierra Leona (2,58% anual) y Togo (2,06% anual).

Además, Qader et al. (2022) descubrieron en Bahrein (2020-2025) una tendencia ascendente (1,05% anual). De igual forma, Kayakuş et al. (2023) encontraron en Turquía (2019-2030) una tendencia positiva (3,11% anual). Por último, Segar et al. (2024) pronosticaron en Malasia (2021-2030) una tendencia creciente (0,93% anual).

Por el contrario, otros estudios hallaron tendencias decrecientes. Por ejemplo, Pabuççu y Bayramoglu (2016) descubrieron tendencias declinantes de las emisiones de CO₂ (2020-2030) en Francia (-1,00% anual), Alemania (-2,58% anual), España (-0,82% anual) y Rumanía (-1,09% anual).

Asimismo, Xu et al. (2021) encontraron tendencias descendentes (2020-2022) en México (-1,13% anual), Argentina (-4,03% anual), Venezuela (-9,43% anual), Italia (-1,25% anual), Finlandia (-8,01% anual), Alemania (-3,12% anual), Reino Unido (-7,31% anual), Grecia (-0,06% anual), Polonia (-1,69% anual), España (-0,39% anual), Suecia (-2,12% anual), Ucrania (-3,83% anual), Kazakstán (-1,81% anual), Rusia (-0,44,% anual), Uzbekistán (-2,68% anual), Egipto (-0,53% anual), Hong Kong (-4,23% anual), Japón (-2,16% anual), Corea del Sur (-1,32% anual), Malasia (-0,22% anual), Singapur (-1,86% anual) y Taiwán (-4,52% anual).

También, otras investigaciones plantearon escenarios con resultados crecientes en un primer momento que luego se tornaron en decrecientes. Así, Hosseini et al. (2019) aplicaron las técnicas regresión lineal múltiple (RLM) y regresión polinomial múltiple (RPM) para pronosticar las emisiones de CO₂ en Irán (2017-2030). Se plantearon dos escenarios: uno sin cambios relevantes de políticas y otro con cambios significativos. En el primer escenario la tendencia creció en 0,65% anual (RLM) y 2,07% anual (RPM). Por el contrario, bajo el segundo escenario la tendencia fue decreciente en -4,95% anual (RLM) y -8,09% anual (RPM).

Igualmente, Yue y Bu (2023) plantearon tres escenarios para pronosticar las emisiones de CO₂ en China (2020-2035). En los tres escenarios las emisiones presentaron una tendencia creciente para el periodo 2020-2030 en 0,38%, 0,29% y 0,18% anual, respectivamente. Sin embargo, en los tres escenarios para el periodo 2030-2035 la tendencia se revierte y las emisiones decrecen en -0,04%, -0,08% y -0,08% anual, respectivamente.

5.2 Hipótesis específica 1

De acuerdo a los resultados, en Perú existe una relación positiva ($\beta = 0,924$) entre las emisiones de CO₂ y el PBI (2005-2021). Es decir, ambas variables se mueven en la misma dirección creciente. El hallazgo coincide con los resultados de otros estudios nacionales. En esa línea, Moreno (2018) halló una asociación positiva ($\beta = 135,701$) entre CO₂ y PBI per cápita

(1990-2015). Igualmente, Choquehuanca et al. (2022) encontraron un nexo positivo ($\beta = 0,059$) entre CO₂ y PBI (1990-2015). También, Sumalave (2022) reveló una asociación positiva ($\beta = 0,656$) entre L-CO₂ y L-PBI (2004-2019). Asimismo, Fernández (2024) descubrió una conexión positiva ($\beta = 0,565$) entre CO₂ per cápita y L-PBI per cápita (1990-2019).

Si bien todos los estudios hallaron en Perú una relación positiva entre CO₂ y PBI, el impacto no fue el mismo, dado que los β fueron diferentes. Puesto que el método de estimación fue el análisis de regresión lineal, la divergencia tiene otras dos posibles explicaciones. Por un lado, los periodos de evaluación no son los mismos, lo que implica que la relación entre las variables puede haber cambiado en el tiempo. Por otro lado, los modelos no son exactamente iguales. No es equivalente construir el modelo L-CO₂ sobre L-PBI que elaborar el modelo CO₂ sobre PBI per cápita, o que procesar el modelo CO₂ sobre PBI, o que realizar el modelo CO₂ per cápita sobre L-PBI per cápita.

Asimismo, con otros métodos también se ha encontrado un enlace positivo entre emisiones de CO₂ y PBI. En efecto, Fabian y Fernández (2022) por medio del modelo mínimos cuadrados dinámicos generalizados (DGLS por sus siglas en inglés), descubrieron una asociación positiva ($\beta = 1,019$) entre L-CO₂ y L-PBI (1960-2020).

A nivel internacional diversos estudios han coincidido con los hallazgos de esta investigación. En efecto, Wu et al. (2015) hallaron un nexo positivo (2004-2010) entre emisiones de CO₂ y PBI en India ($\beta = 9,3 \times 10^{-7}$), China ($\beta = 1,49 \times 10^{-7}$) y Sudáfrica ($\beta = 6,8 \times 10^{-7}$). A su turno, Rafindadi (2016) descubrió un enlace positivo ($\beta = 1,72$) entre emisiones de CO₂ per cápita y PBI per cápita en Nigeria (1971-2011). De igual forma, Begum et al. (2020) descubrieron una relación positiva ($\beta = 0,931$) entre L-CO₂ y L-PBI en Malasia (1990-2016).

Asimismo, Zhang (2022) halló una asociación positiva ($\beta = 0,641$) entre emisiones de CO₂ y PBI en China (1960-2020). Igualmente, Raihan et al. (2022) descubrieron un nexo positivo ($\beta = 0,356$) entre L-CO₂ y L-PBI en Indonesia (1990-2020). También, Tleppayev y

Zeinolla (2023) encontraron una relación positiva ($\beta = 0,088$) entre L-CO₂ per cápita y L-PBI per cápita en Kazakstán (1990-2020). Del mismo modo, Sabroso et al. (2023) descubrieron un enlace positivo ($\beta = 8\,276,662$) entre emisiones de CO₂ y PBI per cápita en Filipinas (1990-2014).

Por otro lado, también se ha encontrado relaciones negativas entre emisiones de CO₂ y PBI. Es decir, las variables se mueven se sentido contrario. Por ejemplo, Wu et al. (2015) para el periodo 2004-2010, hallaron asociaciones negativas entre emisiones de CO₂ y PBI en Brasil ($\beta = -3,8 \times 10^{-8}$) y Rusia ($\beta = -2,2 \times 10^{-8}$). También, Oikonomou et al. (2021), utilizaron dos métodos y un panel de datos (1996-2019) agregando las emisiones de EEUU, Reino Unido, la Unión Europea, Brasil, China, Japón, Arabia Saudita, los Emiratos Árabes Unidos, Australia, Canadá y Rusia. Tanto con el método grupo medio combinado (PMG por sus siglas en inglés) como con el método MCO dinámicos (DOLS por sus siglas en inglés) la relación fue negativa con betas de -0,149 y -0,313, respectivamente. Del mismo modo, Raihan y Tuspekova (2022b) emplearon la técnica DOLS y hallaron un nexo negativo ($\beta = -0,985$) entre L-PBI y L-CO₂ en Singapur (1990-2019).

5.3 Hipótesis específica 2

Dado que la expansión del PBI en 1% resulta en el aumento de las emisiones de CO₂ en 0,924%, en el Perú las emisiones de CO₂ son inelásticas con respecto al PBI (2005-2021). Vale decir, el crecimiento del PBI genera el incremento de las emisiones de CO₂, pero en menores proporciones. Otras investigaciones coincidieron con este hallazgo. Así, Huanchi y Calsin (2015) encontraron que el incremento del PBI per cápita en 1% aumenta en 0,350% las emisiones de CO₂ (1970-2010). A su turno, Pinilla et al. (2018) hallaron que la expansión del PBI en 1% incrementa en 0,899% las emisiones de CO₂ (1990-2015).

Asimismo, Raihan y Tuspekova (2022a) encontraron que el incremento del PBI en 1% aumenta en 0,588% las emisiones de CO₂ (1990-2018). Por su cuenta, Sumalave (2022)

descubrió que el crecimiento del PBI en 1% incrementa en 0,656% las emisiones de CO₂ (2004-2019). Por último, Acuña-Ascencio et al. (2024) encontraron que el alza del PBI per cápita en 1% expande en 0,136% las emisiones de CO₂ (1971-2019).

Sin embargo, también se halló emisiones de CO₂ elásticas con relación positiva con respecto al PBI. Esto es, el crecimiento del PBI genera un incremento de las emisiones de CO₂ en mayores proporciones. Por ejemplo, Fabian y Fernández (2022) descubrieron que la expansión del PBI en 1% incrementa en 1,019% las emisiones de CO₂ (1960-2020).

En estudios internacionales también se encontró inelasticidad. En efecto, Begum et al. (2020) hallaron que la expansión en 1% del PBI resultó en el aumento de las emisiones de CO₂ en 0,931% en Malasia (1990-2016). Del mismo modo, Raihan et al. (2022) encontraron que el aumento en 1% del PBI expande las emisiones de CO₂ en 0,356% en Indonesia (1990-2000). También, Tleppayev y Zeinolla (2023) descubrieron que el incremento en 1% en el PBI produjo el aumento de las emisiones de CO₂ en 0,088% en Kazakstán (1999-2020).

No obstante, también se ha encontrado emisiones de CO₂ elásticas positivas con respecto al PBI. Así, Rafindadi (2016) descubrió que el incremento del PBI per cápita en 1% aumenta en 1,72% las emisiones de CO₂ per cápita en Nigeria (1971-2011). También, Cohen et al. (2018) hallaron que la expansión del PBI per cápita en 1% incrementa en 1,2% las emisiones de CO₂ en Brasil e Indonesia (1990-2014).

Asimismo, se ha hallado emisiones de CO₂ inelásticas con relación negativa con respecto al PBI. Es decir, el crecimiento del PBI genera la disminución de las emisiones de CO₂, aunque en menores proporciones. En tal sentido, Oikonomou et al. (2021), utilizaron dos métodos y un panel de datos (1996-2019) agregando las emisiones de EEUU, Reino Unido, la Unión Europea, Brasil, China, Japón, Arabia Saudita, los Emiratos Árabes Unidos, Australia, Canadá y Rusia. Con el método grupo medio combinado (PMG por sus siglas en inglés) hallaron que el incremento en 1% del PBI reduce las emisiones de CO₂ en -0,15%. En tanto,

con el método mínimos cuadrados ordinarios dinámico (DOLS por sus siglas en inglés) revelaron que la expansión en 1% del PBI contrae las emisiones de CO₂ en -0,31%. Del mismo modo, Raihan y Tuspekova (2022b) hallaron que el aumento del PBI en 1% reduce las emisiones de CO₂ en -0,985% en Singapur (1990-2019).

Las tendencias decrecientes (hipótesis general), las asociaciones negativas (hipótesis específica 1) y sus correspondientes elasticidades (hipótesis específica 2) halladas en las diversas investigaciones citadas, pueden ser explicadas por la curva ambiental de Kuznets (EKC por sus siglas en inglés).

La EKC tiene forma de U invertida y establece que en una primera etapa una economía poco desarrollada se expande a la par que aumenta la degradación ambiental (emisiones de CO₂), hasta cierto punto de inflexión. El punto de inflexión está dado por el PBI per cápita que una economía debe alcanzar para lograr el desarrollo. Luego del punto de inflexión la tendencia se revierte y el país continúa con su expansión y desarrollo, pero generando cada vez menos degradación ambiental (emisiones de CO₂). Esto es posible debido a que los agentes económicos invierten parte de su riqueza acumulada, en la investigación y desarrollo de medios productivos amigables con el medioambiente (Rajhi y Bardi, 2023).

En tal contexto, los países con tendencias crecientes, enlaces positivos y elasticidades positivas se encontrarían en el tramo ascendente de la curva EKC. Por lo cual, estos países aún no habrían superado el punto de inflexión, no habrían alcanzado el desarrollo y el crecimiento de su economía generaría degradación ambiental (emisiones de CO₂) significativa.

Por el contrario, los países con tendencias decrecientes, nexos negativos y elasticidades negativas se encontrarían en la porción descendente de la curva EKC. Es decir, estos países habrían alcanzado el punto de inflexión, habrían desarrollado y la expansión de su economía ya no produciría degradación ambiental (emisiones de CO₂) significativa.

5.4 Hipótesis específica 3

Según los resultados, el MAPE alcanzó el 3,78%, por lo cual las estimaciones de las emisiones de CO₂ en el Perú presentan una precisión clasificada como muy buena (MAPE $\leq$ 10%) entre los años 2005-2021.

En el ámbito nacional, algunos estudios también encontraron MAPE con precisiones muy buenas. En efecto, Rosales (2022) usó dos modelos para estimar las emisiones de CO₂ (1960-2018). El modelo autorregresivo integrado de medias móviles (ARIMA por sus siglas en inglés) produjo un MAPE de 4,76%. En tanto, con el modelo redes neuronales artificiales (ANN por sus siglas en inglés) se halló un MAPE de 1,96%.

A nivel internacional múltiples estudios, que utilizaron diversos métodos y técnicas, hallaron MAPE que variaron entre $3,07 \times 10^{-8} \%$ (Yue y Bu, 2023 en China) y 9,690% (Jena et al., 2021 en Indonesia). Así, Abdullah (2015) estimó las emisiones de CO₂ en Reino Unido (1990-2010) y Malasia (1981-2005). Las estimaciones para Reino Unido y Malasia resultaron con MAPE de 0,004% y 2,610%, respectivamente.

Asimismo, Choi y Abdullah (2016) hicieron uso de dos técnicas para estimar las emisiones de CO₂ en Malasia (1981-2005). La técnica regresión lineal múltiple (MLR por sus siglas en inglés) produjo un MAPE de 2,010%. En tanto, con el modelo de regresión lineal difusa (PFLR por sus siglas en inglés) se halló un MAPE de 2,029%.

A su turno, Sun y Sun (2017) utilizaron seis técnicas para estimar las emisiones de CO₂ en China (1978-2014). La técnica máquina de aprendizaje extremo (ELM por sus siglas en inglés) produjo un MAPE de 2,239%. En tanto, la técnica máquina de aprendizaje extremo regularizada (RELM por sus siglas en inglés) arrojó un MAPE de 1,704%. Por su parte, la combinación de la técnica análisis de componentes principales (PCA por sus siglas en inglés) y RELM (PC-RELM) resultó con un MAPE de 0,252%. A su turno, la red neuronal de propagación inversa (BPNN por sus siglas en inglés) alcanzó un MAPE de 5,498%. Por su

cuenta, el modelo gris (GM por sus siglas en inglés) obtuvo un MAPE de 5,774%. Finalmente, el modelo logístico exhibió un MAPE de 4,683%.

Igualmente, Mustaffa y Shabri (2020) estimaron las emisiones de CO₂ en Malasia y Singapur (2008-2016). Los MAPE para Malasia y Singapur fueron 3,53% y 4,24%, respectivamente.

Por su parte, Jena et al. (2021) estimaron las emisiones de CO₂ (1960-2016) en 17 países, nueve con alta participación mundial en las emisiones ($\geq 2\%$) y ocho con baja participación ($< 2\%$). Los países con alta participación y sus MAPE fueron India (2,929%), China (1,790%), Irán (2,361%), Corea del Sur (2,480%), Canadá (2,936%), Indonesia (9,690%), EEUU (2,717%), Japón (3,521%) y Arabia Saudita (5,915%). En tanto, los países con baja participación y sus MAPE fueron Brasil (5,335%), Sudáfrica (2,752%), México (1,927%), Turquía (2,154%), Australia (3,400%), Reino Unido (3,542%), Italia (8,802%) y Francia (3,816%).

Del mismo modo, Sulaiman y Shabri (2021) emplearon tres métodos para estimar las emisiones de CO₂ en Malasia (2014-2018). Con el modelo gris (GM por sus siglas en inglés) se obtuvo un MAPE de 1,05%. Por su parte, el modelo gris discreto (DGM por sus siglas en inglés) produjo un MAPE de 3,54%. Por último, con el modelo gris de estructura optimizada (SOGM por sus siglas en inglés) se halló un MAPE de 0,74%.

Asimismo, Kayakuş et al. (2023) pronosticaron las emisiones de CO₂ en Turquía (2019-2030) aplicando tres modelos. El modelo de redes neuronales artificiales (ANN por sus siglas en inglés) produjo un MAPE de 6,3%. Por su parte, el modelo de regresión del vector de apoyo (SVR por sus siglas en inglés) resultó con un MAPE de 2,4%. Para finalizar, el modelo de regresión lineal múltiple (MLR por sus siglas en inglés) exhibió un MAPE de 5,1%.

También, Yue y Bu (2023) utilizaron tres técnicas para estimar las emisiones de CO₂ en China (1998-2014). La red neuronal de propagación inversa (BPNN por sus siglas en inglés)

produjo un MAPE 1,83%. A su turno, la red neuronal de regresión generalizada (GRNN por sus siglas en inglés) exhibió un MAPE de 5,20%. En último término, la combinación del algoritmo de optimización de moscas de fruta (FOA por sus siglas en inglés) y GRNN presentó un MAPE de $3,07 \times 10^{-8} \%$.

Tal como se ha descrito, con la utilización de técnicas muy sofisticadas, híbridas y más laboriosas se obtienen MAPE muy pequeños y por ende estimaciones y pronósticos muy precisos. El modelo de regresión simple construido para ésta investigación también produjo estimaciones muy precisas (MAPE = 3,78%).

No obstante, para obtener estimaciones y pronósticos muy precisos es imprescindible que el modelo de regresión lineal simple satisfaga los supuestos de linealidad, especificación, homocedasticidad, normalidad, estabilidad y no autocorrelación. Además, el modelo debe ser significativo individual y globalmente. Por último, el coeficiente de determinación (R^2) del modelo debe ser suficientemente grande como para asegurar un alto poder explicativo y predictivo.

5.5 Hipótesis específica 4

Las estimaciones de las emisiones de CO₂ en el Perú son insesgadas durante el periodo 2005-2021. Aunque se encontró un sesgo de 31,47, éste resultó en no significativo, es decir estadísticamente no diferente de cero. Sobre el particular, en las investigaciones citadas no se reportó o no se calculó el sesgo de las estimaciones.

VI CONCLUSIONES

- ✓ El pronóstico de las emisiones de CO₂ en el Perú tendrá una tendencia creciente en el espacio temporal 2022-2028. En esa línea, en el intervalo 2022-2028 las emisiones de CO₂ crecerán un 14,26%, de 39 984 miles de t (2022) a 45 684 miles de t (2028), a una tasa media de 2,25% anual. En tanto, de acuerdo al pronóstico del MEF el PBI se expandirá un 12,55%, de S/ 582 317 millones (2022) a S/ 655 402 millones (2028) a un ritmo de 3,00% anual. Es decir, el ritmo de crecimiento del PBI será mayor al ritmo de crecimiento de las emisiones de CO₂.
- ✓ En el Perú las emisiones de CO₂ y el PBI han mostrado una relación positiva en el lapso 2005-2021 ($R^2 = 95,03\%$). Así, en el periodo 2005-2021 las emisiones de CO₂ se expandieron un 82,68% a un promedio anual de 3,84%. En tanto, el PBI creció un 101,69% a una tasa de 4,48% anual. Vale decir, el PBI ha crecido más rápido que las emisiones de CO₂.
- ✓ En el Perú las emisiones de CO₂ fueron inelásticas con respecto al PBI en los años 2005-2021. En efecto, la expansión del PBI en 1% resultó en el aumento de las emisiones de CO₂ en 0,924% (valor $p = 3,47 \times 10^{-11}$).
- ✓ Las estimaciones de las emisiones de CO₂ en el Perú presentaron una precisión muy buena ($\text{MAPE} \leq 10\%$) entre los años 2005-2021, el MAPE resultó en 3,78%. Es decir, la discrepancia promedio entre las emisiones de CO₂ observadas y las estimadas fue 3,78%.
- ✓ Las estimaciones de las emisiones de CO₂ en el Perú fueron insesgadas durante el periodo 2005-2021. En efecto, el sesgo de 31,47 resultó no ser significativamente diferente de cero. Vale decir, las estimaciones de las emisiones de CO₂ generadas por el modelo propuesto, no sobrestiman ni subestiman sistemáticamente las emisiones de CO₂ observadas.

VII RECOMENDACIONES

- ✓ Lograr el desarrollo económico es el objetivo primordial de todo país que aún no lo ha logrado. El desarrollo supone un nivel de vida satisfactorio para la población de un país. En tal sentido, la expansión sostenida del PBI a altas tasas es el factor más relevante para que la economía de un país alcance el desarrollo (Mendoza, 2023). En efecto, con una expansión promedio anual del 4% el Perú alcanzaría el desarrollo económico en el año 2076, mientras que con una tasa de 6% el desarrollo se lograría en 2040 (Peñaranda, 2018). Cabe resaltar que entre los años 2001 y 2012 el PBI se expandió en 6% anual (Parodi, 2023). Sin embargo, el MEF ha pronosticado que el PBI crecerá un 3% anual (2024-2028). Por lo cual, los Gobiernos deben impulsar medidas que por un lado promuevan el aceleramiento de la tasa de crecimiento del PBI (fomento de la inversión privada), pero que por otro lado no incrementen la tasa de crecimiento de las emisiones de CO₂ (beneficios tributarios para empresas que cambien su matriz energética).
- ✓ El Perú es un país megadiverso con grandes cantidades de riquezas hídricas, desiertos calurosos, así como zonas montañosas con fuertes vientos por ende el estado debería promover, impulsar y aprovechar en acelerar los megaproyectos en procesos relacionados a fuentes energéticas renovables como proyectos hidroeléctricos, proyectos eólicos, proyectos de energía solar, etc. que traería en consecuencia avances económicos como reducción en su huella de carbono.
- ✓ Dado que, según fuente energética, alrededor del 80% de las emisiones de CO₂ tiene su origen en los hidrocarburos líquidos y que el sector transportes representa más del 65% de las emisiones, se recomienda a los poderes Ejecutivo y Legislativo formular e implementar políticas de estado que promuevan un proceso de masificación de vehículos eléctricos. En esa línea, se debe aprovechar la ventaja competitiva que ofrece el novísimo puerto de Chancay. En razón de que el Puerto supone una reducción significativa del tiempo de

travesía y por ende de costos operativos, las importaciones arribarán a Chancay a precios más competitivos, entre ellas los vehículos eléctricos producidos en China.

- ✓ Si bien el Perú ha fomentado de alguna manera el cambio de fuentes energéticas en el sector industrial (bono de carbono) y vehicular (bono gas), tratando de reducir los gases de efecto invernadero, pero en la actualidad no son nada alentador esto debido a que el país sufre con una inestabilidad políticas y corrupción consecutiva; por esas razones deberíamos como ciudadanos elegir analíticamente a nuestros gobernantes, para que se pueda seguir con la incentivación y promulgación de más proyectos de reducción de la huella de carbón para que pueda ver avances y cumplir con los objetivos del desarrollo sostenible.
- ✓ El análisis de regresión lineal es una herramienta estadística muy versátil, potente y de fácil aplicación e interpretación. Sin embargo, el modelo resultante debe ser sometido a todas las pruebas pertinentes para verificar el cumplimiento de los supuestos. Solo después se puede realizar las pruebas de significancia (individual y global), asegurando así la confiabilidad, consistencia y veracidad de los resultados.
- ✓ Durante el proceso de construcción de un modelo de regresión lineal, debe preferirse el empleo del menor número de variables independientes (modelo parsimonioso). Si bien es cierto que la utilización de un mayor número de variables independientes aumenta el poder explicativo del modelo, también es cierto que el resultante es un modelo más complejo, pero quizá menos útil. En efecto, para que un pronóstico posea muy buena precisión, se requiere conocer también con muy buena precisión los valores futuros de las variables independientes. Así, mientras más variables independientes contenga un modelo, la precisión de sus pronósticos estará más condicionada a la precisión de los pronósticos de las variables independientes.

VIII REFERENCIAS

- Abbass, K., Qasim, M., Song, H., Murshed, M., Mahmood, H. & Younis, I. (2022). A review of the global climate change impacts, adaptation, and sustainable mitigation measures. *Environmental Science and Pollution Research*, 29(28), 42539–42559. <https://doi.org/10.1007/s11356-022-19718-6>
- Abdullah, L. (2015). Linear relationship between CO₂ emissions and economic variables: Evidence from a developed country and a developing country. *Journal of Sustainable Development*, 8(2), 66-72. <https://doi.org/10.5539/jsd.v8n2p66>
- Acuña-Ascencio, R., Carhuamaca-Coronel, E. & Mougenot, B. (2024). Incidence of energy consumption, mining sector and economic growth on CO₂ emission levels: evidence from Peru. *International Journal of Energy Economics and Policy*, 14(1), 6-11. <https://doi.org/10.32479/ijeep.14786>
- Adom P. (2024). The socioeconomic impact of climate change in developing countries over the next decades: A literature survey. *Heliyon*, 10(15), 1-30. <https://doi.org/10.1016/j.heliyon.2024.e35134>
- Agostoni, C., Baglioni, M., La Vecchia, A., Molari, G., Berti, C. (2023). Interlinkages between climate change and food systems: The impact on child malnutrition. Narrative review. *Nutrients*, 15(2), 1-15. <https://doi.org/10.3390/nu15020416>
- Ahmed, F., Ali, I., Kousar, S. & Ahmed, S. (2022). The environmental impact of industrialization and foreign direct investment: empirical evidence from Asia-Pacific region. *Environmental Science and Pollution Research*, 29(20), 29778–29792. <https://doi.org/10.1007/s11356-021-17560-w>
- Ajimotokan, H. (2023). *Research techniques. Qualitative, quantitative and mixed methods. Approaches for engineers*. Springer.

- Akhtar, R. (2023). *Introduction: Climate change and human health scenarios*. In R. Akhtar, (Ed.), *Climate change and human health scenarios* (pp. 1-12). Springer.
- Akyol, M. & Uçar, E. (2021). Carbon footprint forecasting using time series data mining methods: the case of Turkey. *Environmental Science and Pollution Research*, 28(29), 38552–38562. <https://doi.org/10.1007/s11356-021-13431-6>
- Alaganthiran, J. & Anaba, J. (2022). The effects of economic growth on carbon dioxide emissions in selected Sub-Saharan African (SSA) countries. *Heliyon*, 8(11), 1-8. <https://doi.org/10.1016/j.heliyon.2022.e11193>
- Alatorre, J., Caballero, K., Ferrer, J. y Galindo L. (2019). *El costo social del carbono: una visión agregada desde América Latina*. Comisión Económica para América Latina y el Caribe (CEPAL).
- Almulhim, A. & Abubakar, I. (2026). The role of renewable energy in achieving the Sustainable Development Goals: A systematic review and conceptual framework. *Renewable and Sustainable Energy Reviews*, 230, 116679. <https://doi.org/10.1016/j.rser.2025.116679>
- Altamirano, T. (2020). Climate change, vulnerability, social conflicts and human displacement in the Andes: The case of Huaytapallana glacier. *Ambiente, Comportamiento y Sociedad*, 3(1), 1-7. <https://doi.org/10.51343/racs.v3i1.417>
- Ameyaw, B., Yao, L., Annan, A. & Agyeman, J. (2020). West Africa's CO₂ emissions: investigating the economic indicators, forecasting, and proposing pathways to reduce carbon emission levels. *Environmental Science and Pollution Research*, 27(12), 13276-13300. <https://doi.org/10.1007/s11356-020-07849-7>
- Arkes, J. (2023). *Regression analysis. A practical introduction* (2nd ed.). Routledge.
- Ashour, M. & Aldahhan, I. (2023). *Optimal combination forecast for bitcoin dollars time series*. In O. Valenzuela, F. Rojas, L. Herrera, H. Pomares & I. Rojas (Eds.), *Theory*

and applications of time series analysis and forecasting. Selected contributions from ITISE 2021 (pp. 161-174). Springer.

Aslam, B., Asghar, R., Muzammil, S., Shafique, M., Siddique, A., Khurshid, M., Ijaz, M., Rasool, M., Chaudhry, T., Aamir A. & Baloch, Z. (2024). AMR and sustainable development goals: at a crossroads. *Globalization and Health*, 20(1), 73.

<https://www.proquest.com/openview/83cd2e0c32226488b5f2362c10d5e9d9/1?pq-origsite=gscholar&cbl=54663>

Asnicar, D. & Marín, M. (2022). Effects of seawater acidification on echinoid adult stage: A review. *Journal of Marine Science and Engineering*, 10(4), 1-32.

<https://www.mdpi.com/2077-1312/10/4/477#>

Asteriou, D. & Hall, S. (2021). *Applied econometrics* (4th ed.). Macmillan.

Aye, G. & Edoja, P. (2017). Effect of economic growth on CO₂ emission in developing countries: Evidence from a dynamic panel threshold model. *Cogent Economics & Finance*, 5(1), 1-22. <https://doi.org/10.1080/23322039.2017.1379239>

Azam, M., Hunjra, A., Hanif, M. & Zureigat, Q. (2023). *Revising the environmental Kuznets curve in the post-COVID-19 era from a SDGs perspective*. In M. Shahbaz, D. Balsalobre & R. Sharma (Eds.), *Economic growth and environmental quality in a post-pandemic world* (pp. 217-232). Routledge.

Babacan, H. (2025). From crisis to policy action: Tackling climate change through SDG 13. *The International Journal of Community and Social Development*, 7(2), 205-221.

<https://doi.org/10.1177/25166026251351370>

Babbie, E. (2021). *The practice of social research* (15th ed.). Cengage.

Bala, H., Mustapha, U., Ya'u, A., Khatoon, G., Nik, N. & Rashid, M. (2023). Evaluating the impact of carbon emissions on Iraq's economic growth. *Review of Economics and Finance*, 21(1), 1647-1653. <https://refpress.org/ref-vol21-a180/>

- Banco de desarrollo de América Latina y el Caribe (CAF). (2023). *Reporte de economía y desarrollo 2023. Desafíos globales, soluciones regionales: América Latina y el Caribe frente a la crisis climática y de biodiversidad*.
- Barreto, C. (2018). Modelo de regresión del consumo final privado y el producto bruto interno nacional del Perú durante el periodo 2000 – 2013. *In Crescendo*, 9(1), 13-32. <https://dialnet.unirioja.es/servlet/articulo?codigo=6508879>
- Bastien-Olvera, B., Conte, M., Dong, X., Briceno, T., Batker, D., Emmerling, J., Tavoni, M., Granella, F., & Moore, F. (2024). Unequal climate impacts on global values of natural capital. *Nature*, 625(7996), 722–727. <https://doi.org/10.1038/s41586-023-06769-z>
- Bathiany, S., Dakos, B., Scheffer, M. & Lenton, T. (2018). Climate models predict increasing temperature variability in poor countries. *Science Advances*, 4(5), 1–10. <https://doi.org/10.1126%2Fsciadv.aar5809>
- Bayram, H., Konyalilar, N. & Akpinar-Elci, M. (2023). *Health impacts of global climate change in the Middle East; Vulnerabilities*. In R. Akhtar, (Ed.), *Climate change and human health scenarios* (pp. 171-188). Springer.
- Begum, R., Raihan, A. & Said, M. (2020). Dynamic impacts of economic growth and forested area on carbon dioxide emissions in Malaysia. *Sustainability*, 12(22), 1-15. <https://doi.org/10.3390/su12229375>
- Benschop, N., Chironda-Chikanya, G., Naidoo, S., Jafta, N., Ramsay, L. & Naidoo, R. (2023). *El Niño, rainfall and temperature patterns influence perinatal mortality in South Africa: Health services preparedness and resilience in a changing climate*. In R. Akhtar, (Ed.), *Climate change and human health scenarios* (pp. 333-355). Springer.
- Bergmann, J., Vinke, J., Fernández, C., Gornott, C., Gleixner, S., Laudien, R., Lobanova, A., Ludescher, J. & Schellnhuber, H. (2021). *Assessing the evidence: Climate change and*

- migration in Peru*. Potsdam Institute for Climate Impact Research (PIK) & International Organization for Migration (IOM).
- Berlie, A. (2018). Global warming: A review of the debates on the causes, consequences and politics of global response. *Ghana Journal of Geography*, 10(1), 144-164. <https://www.ajol.info/index.php/gjg/article/view/170410>
- Bhatt, H., Davawala, M., Joshi, T., Shah, M. & Unnarkat, A. (2023). Forecasting and mitigation of global environmental carbon dioxide emission using machine learning techniques. *Cleaner Chemical Engineering*, 5(1), 1-9. <https://doi.org/10.1016/j.clce.2023.100095>
- Birdi, J. (2024). *Climate change and carbon recycling. Surface chemistry applications*. CRC Press.
- Blanco-Villafuerte, L. y Hartinger, S. (2023). Impacto del cambio climático en la salud de los peruanos: desafíos y estrategias para una respuesta integral. *Revista Peruana de Medicina Experimental y Salud Pública*, 40(2), 130-131. <https://doi.org/10.17843/rpmesp.2023.402.12998>
- Bolin, J. (2023). *Regression analysis in R: A comprehensive view for the social sciences*. CRC Press.
- Boontome, P., Therdyothin, A. & Chontanawat, J. (2019). Forecasting carbon dioxide emission and sustainable economy: Evidence and policy responses. *International Journal of Energy Economics and Policy*, 9(5), 55-62. <https://doi.org/10.32479/ijeep.7918>
- Bose, H. & Satyanarayana, T. (2021). *Mitigating global warming through carbonic anhydrase-mediated carbon sequestration*. In M. Goel, T. Satyanarayana, M. Sudhakar & D. Agrawal (Eds.), *Climate change and green chemistry of CO₂ sequestration* (pp. 197-230). Springer.
- Brewer, T. (2023). *Climate change. An interdisciplinary introduction*. Springer.

- Brooks, C. (2019). *Introductory econometrics for finance* (4th ed.). Cambridge University Press.
- Cachon, G. Terwiesch, C. (2020). *Matching supply with demand. An introduction to operations management* (4th ed.). McGraw-Hill.
- Carvalho, J. & Kosteljik, E. (2022). *Marketing analytics. Statistical tools for marketing and consumer behavior using SPSS*. Routledge.
- Case, K., Fair, R. & Oster, S. (2020). *Principles of economics* (13th ed.). Pearson.
- Cederborg, J. & Snöbohm, S. (2016). *Is there a relationship between economic growth and carbon dioxide emissions?* [Tesis de pregrado]. Södertörns University. <http://sh.diva-portal.org/smash/get/diva2:1076315/FULLTEXT01.pdf>
- Centro Nacional de Planeamiento Estratégico (CEPLAN). (2023). *Plan estratégico de desarrollo nacional al 2050*.
- Chandio, A., Jiang, Y., Amin, A., Ahmad, M., Akram, W., & Ahmad, F. (2022). Climate change and food security of South Asia: fresh evidence from a policy perspective using novel empirical analysis. *Journal of Environmental Planning and Management*, 66(1), 169-190. <https://doi.org/10.1080/09640568.2021.1980378>
- Chapagain, D., Baarsch, F., Schaeffer M. & D'haen, S. (2020). Climate change adaptation costs in developing countries: insights from existing estimates. *Climate and Development*, 12(10), 934–942. <https://doi.org/10.1080/17565529.2020.1711698>
- Chatterjee, S. & Simonoff, J. (2020). *Handbook of regression analysis with applications in R* (2nd ed.). Wiley.
- Chichaibelu, B., Bekchanov, M., Von Braun, J. & Torero, M. (2023). *The global cost of reaching a world without hunger: Investment costs and policy action opportunities*. In J. Von Braun, K. Afsana, L. Fresco & M. Hassan (Eds.), *Science and innovations for food systems transformation* (pp. 625-660). Springer.

- China International Capital Corporation Limited (CICC). (2022). *Guidebook to carbon neutrality in China: Macro and industry trends under new constraints*.
- Chirinos, R. (2021). *Efectos económicos del cambio climático en el Perú*. Banco Central de Reserva del Perú (BCRP). <https://www.bcrp.gob.pe/docs/Publicaciones/Documentos-de-Trabajo/2021/documento-de-trabajo-009-2021.pdf>
- Choi, C. & Abdullah, L. (2016). Prediction of carbon dioxide emissions using two linear regression-based models: A comparative analysis. *Journal of Applied Engineering*, 4(4), 305-312. <http://dac.umt.edu.my:8080/jspui/handle/123456789/5429>
- Choquehuanca, C., Díaz, J., Huamán, S., Valenzuela A., Franco, J. & García, G. (2022). Determinantes de la salud ambiental en el Perú: curva de Kuznets 1990-2015. *Boletín de Malariología y Salud Ambiental*, 42(4), 856-868. <https://doi.org/10.52808/bmsa.7e6.624.028>
- Chukwunonso, B., Al-Wesabi, I., Shixiang, L., AlSharabi, K., Al-Shamma'a, A., Farh, H., Saeed, F., Kandil, T., & Al-Shaalan, A. (2024). Predicting carbon dioxide emissions in the United States of America using machine learning algorithms. *Environmental Science and Pollution Research International*, 31(23), 33685–33707. <https://doi.org/10.1007/s11356-024-33460-1>
- Claeys, G., Le Mouel, M., Tagliapietra, S., Wolff, G. & Zachmann, G. (2024). *The macroeconomics of decarbonisation: implications and policies*. Cambridge University Press.
- Climate Action Tracker (CAT). (2023). *Warming projections global update*. <https://climateactiontracker.org/publications/?page=1>
- Climate Policy Initiative (CPI). (2023). *Global landscape of climate finance 2023*.

- Cohen, R., Jalles, J., Loungani, P. & Marto, R. (2018). The long-run decoupling of emissions and output: Evidence from the largest emitters. *Energy Policy*, 118, 58-68. <https://doi.org/10.1016/j.enpol.2018.03.028>
- Comisión Económica para América Latina y el Caribe (CEPAL). (2018). Objetivos de Desarrollo Sostenible (ODS) [Gráfico]. https://www.cepal.org/sites/default/files/static/images/e_2018_ods_poster_with_un_emblem_es.png
- Connell, J. (2023). *'Like shells off the beach'.* *Climate change and health in Australia*. In R. Akhtar, (Ed.), *Climate change and human health scenarios* (pp. 15-31). Springer.
- Cooke, S., Auld, H., Birnie-Gauvin, K., Elvidge, C., Piczak, M., Twardek, W., Raby, G., Brownscombe, J., Midwood, J., Lennox, R., Madliger, C., Wilson, A., Binder, T., Schreck, C., McLaughlin, R., Grant, J., & Muir, A. (2023). On the relevance of animal behavior to the management and conservation of fishes and fisheries. *Environmental Biology of Fishes*, 106, 785-810. <https://doi.org/10.1007/s10641-022-01255-3>
- Cooksey, R. (2020). *Illustrating statistical procedures: Finding meaning in quantitative data* (3rd ed.). Springer.
- Cracknell, A. & C. Varotsos, C. (2022). *Understanding global climate change. Modelling the climatic system and human impacts* (2nd ed.), CRC Press.
- Das, P. (2019). *Econometrics in theory and practice. Analysis of cross section, time series and panel data with Stata 15.1*. Springer.
- Das, I., Ramkumar, V. & Gardas, R. (2021). *Thermodynamic analysis of ionic liquids for CO₂ capture, regeneration and conversion*. In M. Goel, T. Satyanarayana, M. Sudhakar & D. Agrawal (Eds.), *Climate change and green chemistry of CO₂ sequestration* (pp. 123-140). Springer.

- Dasgupta, S., van Maanen, N., Gosling, S., Piontek, F., Otto, C., & Schleussner, C. (2021). Effects of climate change on combined labour productivity and supply: an empirical, multi-model study. *The Lancet. Planetary health*, 5(7), 455-465.
[https://doi.org/10.1016/S2542-5196\(21\)00170-4](https://doi.org/10.1016/S2542-5196(21)00170-4)
- Deb, D., Dey, R. & Balas, V. (2019). *Engineering research methodology. A practical insight for researchers*. Springer.
- Decode 6. (2023). What's part of your carbon footprint? [Gráfico].
<https://decode6.org/articles/what-is-a-carbon-footprint/>
- Del Cioppo, F. (2019). Inserción de dióxido de carbono (CO₂) con base al crecimiento económico y la población en Ecuador (2000-2050). *Económicas CUC*, 40(2), 183-194.
<https://doi.org/10.17981/econcuc.40.2.2019.11>
- Desai, B. (2021). *International environmental law-making*. In B. Desai (Ed.), *Our Earth matters. Pathways to a better common environmental future* (pp. 43-62). IOS press.
- Dhongde, S. (2021). *The effect of GDP on a country's CO₂ emission*. Georgia Institute of Technology.
- Dinçer, H., Wang, Q., Li, R., Yüksel, S., Çelebi, B. & Vatandaş, E. (2023). *The impacts of energy transparency for the improvements of health tourism*. In H. Dinçer & S. Yüksel (Eds.), *Economic development and the environmental ecosystem. The role of energy policy in economic growth* (pp. 101-114). Springer.
- Doane, D. & Seward, L. (2022). *Applied statistics in business and economics* (7th ed.). McGraw-Hill.
- Doelle, M. & Seck, S. (2021). *Introducing loss and damage*. In M. Doelle & S. Seck, (Eds.), *Research handbook on climate change law and loss & damage* (pp. 1-15). Edward Elgar Publishing.

- Erazo-Camacho, M., Cubos-Sifuentes, U., Mejía-Avalos, M. & Ramírez-Santana, A. (2024). La curva de Kuznets ambiental de Perú 2010-2020: una visión departamental. *Revista Kawsaypacha: Sociedad y Medio Ambiente*, (14), D-005. <https://doi.org/10.18800/kawsaypacha.202402.D005>
- Ekardt, F. (2022). *Economic evaluation, cost-benefit analysis, economic ethics. A review with regard to climate change - Figures in the sustainability discourse*. Springer.
- European Court of Auditors. (2023). *Special report 18/2023: EU climate and energy targets. 2020 targets achieved, but little indication that actions to reach the 2030 targets will be sufficient*. European Union. <https://www.eca.europa.eu/en/publications?ref=SR-2023-18>
- Evans, J. & Thomas, C. (2024). *Environmental governance* (2nd ed.). Routledge.
- Fabian, P. y Fernández, E. (2022). *Crecimiento económico y su incidencia sobre la contaminación ambiental en el Perú de 1960 a 2020*. [Tesis de pregrado]. Universidad Privada del Norte (UPN). <https://repositorio.upn.edu.pe/handle/11537/32907>
- Fanzo, J., Davis, C., McLaren, R. & Choufani, J. (2018). The effect of climate change across food systems: Implications for nutrition outcomes. *Global Food Security*, 18(1), 12-19. <https://doi.org/10.1016/j.gfs.2018.06.001>
- Fanzo, J., & Miachon, L. (2023). Harnessing the connectivity of climate change, food systems and diets: Taking action to improve human and planetary health. *Anthropocene*, 42(2), 1-20. <https://doi.org/10.1016/j.ancene.2023.100381>
- Famielec, J., Kijanka, A. & Nieroda-Zaba, R. (2019). Economic growth and carbon dioxide emissions. *The Polish Statistician*, 64(4), 5-21. <https://doi.org/10.5604/01.3001.0013.8506>
- Fernández, J. (2024). *El crecimiento económico y la contaminación ambiental por las emisiones de CO₂ en el Perú en el período 1990-2019. Una aplicación de la hipótesis*

de la curva medioambiental de Kuznets a la realidad nacional. [Tesis de pregrado].

Universidad Nacional Pedro Ruiz Gallo (UNPRG).

<https://repositorio.unprg.edu.pe/handle/20.500.12893/12917>

Ferrer, J., Passarelli, V. & Carmona, D. (2023). *Homogeneous CO₂ hydrogenation*. In G. Stefanidis & A. Stankiewicz (Eds.), *Chemical valorisation of carbon dioxide* (pp. 97-127). The Royal Society of Chemistry.

Flatt, C. & Jacobs, R. (2019). Principle assumptions of regression analysis: Testing, techniques, and statistical reporting of imperfect data sets. *Advances in Developing Human Resources*, 21(4), 484-502. <http://dx.doi.org/10.1177/1523422319869915>

Fonseca, L., Domingues, J., & Dima, A. (2020). Mapping the sustainable development goals relationships. *Sustainability*, 12(8), 3359. <https://www.mdpi.com/2071-1050/12/8/3359>

Freestone, D. (2021). *Can we save the blue half of our planet?* In B. Desai (Ed.), *Our Earth matters. Pathways to a better common environmental future* (pp. 127-134). IOS press.

Friedlingstein, P., O'Sullivan, M., Jones, M., Andrew, R., Bakker, D., Hauck, J., Landschützer, P., Le Quéré, C., Luijkx, I., Peters, G., Peters, W., Pongratz, J., Schwingshackl, C., Sitch, S., Canadell, J., Ciais, P., Jackson, R., Alin, S., Anthoni, P.,... Zheng, B. (2023). Global carbon budget 2023. *Earth System Science Data*, 15(12), 5301-5369. <https://doi.org/10.5194/essd-15-5301-2023>

Frost, J. (2019). *Regression analysis. An intuitive guide for using and interpreting linear models*. Jim Frost.

Furkan, H., Hasan, K. & Uddin, J. (2023). Greenhouse gas emission, GDP, tertiary education, and rule of law: A comparative study between high-income and lower-middle income countries. *Heliyon*, 9(6), 1-10. <https://doi.org/10.1016/j.heliyon.2023.e16265>

- Galván, L., Bhatti, U., Campo, C. & Trujillo, R. (2022). The nexus between CO₂ emission, economic growth, trade openness: Evidences from middle-income trap countries. *Frontiers on Environmental Science*, 10(938776), 1-16.
<https://doi.org/10.3389/fenvs.2022.938776>
- Ghiani, G., Laporte, G. & Musmanno, R. (2022). *Introduction to logistics systems management with Microsoft Excel and Python examples* (3rd ed.). Wiley.
- Githeko, A. (2023). *Responding to Climate Change in the Health Sector, Kenya*. In R. Akhtar, (Ed.), *Climate change and human health scenarios* (pp. 303-316). Springer.
- Godbole, N. y Lamb J. (2023). *Smart energy practices for a sustainable world: How we all can contribute?* The Energy and Resources Institute (TERI).
- Goel, M., Pal, R. & Sharma, A. (2021). *An assessment of CO₂ reduction potential from carbon sequestration versus renewable energy targets in India*. In M. Goel, T. Satyanarayana, M. Sudhakar & D. Agrawal (Eds.), *Climate change and green chemistry of CO₂ sequestration* (pp. 27-46). Springer.
- Goel, M., Satyanarayana, T., Sudhakar, M. & Agrawal, D. (2021). *Climate change and green chemistry of CO₂ sequestration*. Springer.
- Graham, D. (2023). *Integrated electronic payment technologies for smart cities* (3rd ed.). Springer.
- Gravetter, F., Forzano, L. & Rakow, T. (2021). *Research methods for the behavioural sciences* (EMEA ed.). Cengage.
- Greene, W. (2020). *Econometric analysis* (8th ed.). Pearson.
- Groebner, D., Shannon, P. & Fry, P. (2018). *Business statistics: A decision-making approach* (10th ed.). Pearson.
- Guglyuvatyy, E. (2022). *Climate change, forests and federalism. Australian experience*. Springer.

- Guibourd de Luzinais, V., du Pontavice, H., Reygondeau, G., Barrier, N., Blanchard, J., Bornarel, V., Büchner, M., Cheung, W., Eddy, T., Everett, J., Guet, J., Harrison, C., Maury, O., Novaglio, C., Petrik, C., Steenbeek, J., Tittensor, D., & Gascuel, D. (2023). Trophic amplification: A model intercomparison of climate driven changes in marine food webs. *PloS one*, 18(8), 1-23. <https://doi.org/10.1371/journal.pone.0287570>
- Hair, J., Black, W., Babin, B. & Anderson R. (2019). *Multivariate data analysis* (8th ed.). Cengage.
- Hannah, L. (2022). *Climate change biology* (3rd ed.). Elsevier.
- Hariyani, D., Hariyani, P., & Mishra, S. (2025). Digital technologies for the sustainable development goals. *Green Technologies and Sustainability*, 3(3), 100202. <https://doi.org/10.1016/j.grets.2025.100202>
- Hassan, A., Haseeb, M., Bekun, F., Yazdi, A., Ullah, E. & Hossain, M. (2024). Does nuclear energy mitigate CO₂ emissions in the USA? Testing IPAT and EKC hypotheses using dynamic ARDL simulations approach. *Progress in Nuclear Energy*, 169, 105059. <https://doi.org/10.1016/j.pnucene.2024.105059>
- Ho, H. (2018). Forecasting of CO₂ emissions, renewable energy consumption and economic growth in Vietnam using grey models. *2018 4th International Conference on Green Technology and Sustainable Development (GTSD)*, Ho Chi Minh City, Vietnam, 452-455. <https://doi.org/10.1109/GTSD.2018.8595679>
- Hossain, E. (2023). *The sun, energy, and climate change*. Springer.
- Hosseini, S., Saifoddin, A., Shirmohammadi, R. & Aslani, A. (2019). Forecasting of CO₂ emissions in Iran based on time series and regression analysis. *Energy Reports*, 5(11), 619-631. <https://doi.org/10.1016/j.egyr.2019.05.004>

- Huacoto, C. (2021). *Política monetaria y su impacto en el crecimiento económico del Perú durante los años 2007-2018*. [Tesis de pregrado]. Universidad Privada del Norte (UPN). <https://repositorio.upn.edu.pe/handle/11537/29289>
- Huanchi, W. y Calsin, G. (2015). Curva ambiental de Kuznets: evidencia empírica para la economía peruana, periodo 1972 - 2010. *Semestre Económico*, 4(2), 107-133. <https://doi.org/10.26867/se.2015.v04i2.43>
- Hussain, I., Ahmad, E., & Majeed, M. T. (2023). Curvature and turning point of the environmental Kuznets curve in a global economy: the role of governance. *Environmental Science and Pollution Research International*, 30(18), 53007–53019. <https://doi.org/10.1007/s11356-023-25835-7>
- Ideas en 5 minutos. (2024) ¿Qué es el efecto invernadero? [Gráfico]. <https://ideasen5minutos.me/mejora-vida/que-es-el-efecto-invernadero-2900/>
- Infante, A. & Suarez, A. (2024). *Crecimiento económico y calidad ambiental del Perú, 1970-2020* [Tesis de pregrado]. Universidad Nacional de Tumbes (UNTumbes). <https://repositorio.untumbes.edu.pe/handle/20.500.12874/65067>
- Instituto Nacional de Estadística e Informática (INEI). (2023). *Perú: Anuario de estadísticas ambientales 2023*.
- Intergovernmental Panel on Climate Change (IPCC). (2019). *Global warming of 1.5°C. An IPCC special report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty*. Cambridge University Press. <https://doi.org/10.1017/9781009157940>
- Intergovernmental Panel on Climate Change (IPCC). (2020). *El cambio climático y la tierra. Informe especial del IPCC sobre el cambio climático, la desertificación, la*

degradación de las tierras, la gestión sostenible de las tierras, la seguridad alimentaria y los flujos de gases de efecto invernadero en los ecosistemas terrestres. Resumen para responsables de políticas.

https://www.ipcc.ch/site/assets/uploads/sites/4/2020/06/SRCCL_SPM_es.pdf

Intergovernmental Panel on Climate Change (IPCC). (2022). *Climate change 2022: Impacts, adaptation and vulnerability. Working group II contribution to the sixth assessment report of the Intergovernmental Panel on Climate Change.*

Intergovernmental Panel on Climate Change (IPCC). (2023). *Climate change 2023. Synthesis report. Contribution of working groups I, II and III to the sixth assessment report of the Intergovernmental panel on climate change.* <https://dx.doi.org/10.59327/IPCC/AR6-9789291691647>

Jacobs, R. & Chase, R. (2023). *Operations and supply chain management. The core* (6th ed.). McGraw-Hill.

Jafino, B., Walsh, B., Rozenberg, J. & Hallegatte, S. (2020). *Revised estimates of the impact of climate change on extreme poverty by 2030.* World Bank.

Jägermeyr, J., Müller, C., Ruane, A., Elliott, J., Balkovic, J., Castillo, O., Faye, B., Foster, I., Folberth, C., Franke, J., Fuchs, K., Guarin, J., Heinke, J., Hoogenboom, G., Iizumi, T., Jain, A., Kelly, D., Khabarov, N., Lange, S., Lin, T., ... Rosenzweig, C. (2021). Climate impacts on global agriculture emerge earlier in new generation of climate and crop models. *Nature Food*, 2(11), 873–885. <https://doi.org/10.1038/s43016-021-00400-y>

Jaisri, J. y Balaji, S. (2025). *Environmental footprint of luxury textile manufacturing.* En Sadhna, R. Kumar & E. Mokanaasri (Eds.), *Crafting sustainability in luxury textiles for a zero-waste future* (pp. 13-24). Springer.

- Jeevanasai, P. & Hegde, S. (2023). CO₂ emission prediction using machine learning. *International Journal of Advance Research and Innovative Ideas in Education*, 9(4), 1127-1133. <https://ijariie.com/FormDetails.aspx?MenuScriptId=219959>
- Jena, P., Managi, S. & Majhi, B. (2021). Forecasting the CO₂ emissions at the global level: A multilayer artificial neural network modelling. *Energies*, 14(19), 1-23. <https://doi.org/10.3390/en14196336>
- Johansen, B. (2023). *Global warming and the climate crisis. Science, spirit and solutions*. Springer.
- Kayakuş, M., Terzioğlu, M., Erdoğan, D., Zetter, S., Kabas, O. & Moiceanu, G. (2023). European Union 2030 carbon emission target: The case of Turkey. *Sustainability*, 15(17), 1-23. <https://www.mdpi.com/2071-1050/15/17/13025#>
- Keith, T. (2019). *Multiple regression and beyond. An introduction to multiple regression and structural equation modeling* (3rd ed.). Routledge.
- Klimberg, R. (2023). *Fundamentals of predictive analytics with JMP®* (3rd ed.). SAS Institute Inc.
- Kompas, T., Pham, V. & Che, T. (2018). The effects of climate change on GDP by country and the global economic gains from complying with the Paris Climate Accord. *Earth's Future*, 6(8), 1153–1173. <https://doi.org/10.1029/2018EF000922>
- Kotzé, L. & Kim, R. (2021). *Exploring the analytical, normative and transformative dimensions of Earth system law*. In B. Desai (Ed.), *Our Earth matters. Pathways to a better common environmental future* (pp. 11-24). IOS press.
- Kumar, K. (2020). *Econometrics*. CRC Press.
- Lah, R., Bencedira, S., Kassim, M., Azra, M., Segaran, T., Noor, M., Ariffin, H., Kari, Z., Bottje, W. & Hussin, W. (2024). *A scientometric analysis on the impacts of climate*

- change on molluscs*. In M. Azra, T. Segaran, G. Téllez-Isaías & H. Ariffin (Eds.), *Marine life in changing climates* (pp. 71-99). Nova Science Publishers.
- Leggieri, M., Toscano, P. & Battilani, P. (2021). Predicted aflatoxin b1 increase in Europe due to climate change: Actions and reactions at global level. *Toxins*, 13(4), 1-21.
<https://doi.org/10.3390/toxins13040292>
- Leitão, N., Balsalobre-Lorente, D. & Shahbaz, M. (2023). *The effect of trade, renewable energy, and economic growth on CO₂ emissions in central and eastern Europe*. In M. Shahbaz, D. Balsalobre & R. Sharma (Eds.), *Economic growth and environmental quality in a post-pandemic world* (pp. 34-48). Routledge.
- Leitão, N., Parente, C. & Balsalobre-Lorente, D. (2023). *The impact of economic growth, international trade, and carbon dioxide emissions on Portuguese energy consumption*. In M. Shahbaz, D. Balsalobre & R. Sharma (Eds.), *Economic growth and environmental quality in a post-pandemic world* (pp. 61-80). Routledge.
- Levin, F. (2023). *Global warming: Truth and consequences. A primer*. Springer.
- Levine, D., Stephan, D. & Szabat, K. (2021). *Statistics for managers using Microsoft® Excel®* (9th ed.). Pearson.
- Li, M. (2023). *Double exposure framework of COVID-19 pandemic and climate change*. In R. Akhtar, (Ed.), *Climate change and human health scenarios* (pp. 49-65). Springer.
- Li, H., Chen, K., Fu, J. & Liu, M. (2023). *Photocatalytic CO₂ reduction reactions*. In G. Stefanidis & A. Stankiewicz (Eds.), *Chemical valorisation of carbon dioxide* (pp. 285-307). The Royal Society of Chemistry.
- Lind, D., Marchal, W. & Wathen, S. (2022). *Basic statistics for business & economics* (10th ed.). McGraw-Hill.
- Liu, K. (2022). *Supply chain analytics. Concepts, techniques and applications*. Palgrave Macmillan.

- López, S., Moncagatta, A. & Tarazona, C. (2023). *Blue and green infrastructure as public spaces. Five proposals for resilient urban development and social integration in Peru*. In M. Rahman (Ed.), *Handbook of waterfront cities and urbanism* (pp. 163-187). Routledge.
- Malhotra, M., Singh, P., Van Le, Q., Khan, A., Katin, K., Kaya, S., Hu, C., Nguyen, V. & Raizada, P. (2026). Strategic design and mechanistic unveiling of Ni-based S-scheme heterojunctions for efficient CO₂ photoreduction to C1 products: Coordination chemistry, spectroscopic evidence, and future directions. *Coordination Chemistry Reviews*, 548, 217179. <https://doi.org/10.1016/j.ccr.2025.217179>
- Malkhazova, S., Korennoy, F. & Orlov, D. (2023). *Climate change and environmental infectious diseases in Russia: Case studies in temperate and Arctic climate*. In R. Akhtar, (Ed.), *Climate change and human health scenarios* (pp. 283-300). Springer.
- Man, A., Chaichana, C., Wicharuck, S. & Rinchumphu, D. (2022). Predicting sunlight availability for vertical shelves using simulation. *IOP Conference Series: Earth and Environmental Science*, 1091(1), 1-9. <http://dx.doi.org/10.1088/1755-1315/1094/1/012011>
- Manahan, S. (2022). *Environmental chemistry* (11th ed.). CRC Press.
- Mankiw, G. (2024). *Principles of economics* (10th ed.). Cengage.
- Martin, P. (2021). *Linear regression: An introduction to statistical models*. SAGE.
- Mathez, E. & Smerdon, J. (2018). *Climate change. The science of global warming and our energy future* (2nd ed.). Cambridge University Press.
- Matz-Luck, N. & Christiansen, L. (2021). *UNGA as the anchor: Global environmental conferencing*. In B. Desai (Ed.), *Our Earth matters. Pathways to a better common environmental future* (pp. 73-84). IOS press.

- Maurer, P. (2021). *Protecting the natural environment in armed conflict*. In B. Desai (Ed.), *Our Earth matters. Pathways to a better common environmental future* (pp. 113-116). IOS press.
- Mawi, S. (2024). *An environmental study of global warming and climate change*. In partial fulfillment for the final requirement of HST060 – World geography section Dd. <http://dx.doi.org/10.13140/RG.2.2.32320.71684>
- McNulty, K. (2021). *Handbook of Regression modeling in people analytics with examples in R and Python*. CRC Press.
- McPhaden, M., Santoso, A. & Cai, W. (2021). *Introduction to El Niño Southern Oscillation in a changing climate*. In M. McPhaden, A. Santoso & W. Cai (Eds.), *El Niño Southern Oscillation in a changing climate* (pp. 3-20). Wiley.
- Meadows, R. (2023). *Climate Change, Wildfires, and Health in Canada*. In R. Akhtar, (Ed.), *Climate change and human health scenarios* (pp. 385-397). Springer.
- Mendoza, W. (2023). *Propuesta IPAE en desarrollo nacional. Del crecimiento económico al desarrollo*. Instituto Peruano de Administración de Empresas (IPAE). <https://www.ipae.pe/wp-content/uploads/2023/02/Propuesta-IPAE-Del-crecimiento-economico-al-desarrollo-2023.pdf>
- Mendoza, J., Garret, K., Soriano, P. & Cabauatan, R. (2021). The impact of CO₂ emissions on the GDP per capita, employment rate and energy consumption of China, Korea and Japan. *Malaysian Journal of Social Sciences and Humanities*, 6(11), 315-333. <https://doi.org/10.47405/mjssh.v6i11.1134>
- Meng, Y. & Noman, H. (2022). Predicting CO₂ emission footprint using AI through machine learning. *Atmosphere*, 13(11), 1-15. <https://doi.org/10.3390/atmos13111871>
- Ministerio de Desarrollo e Inclusión Social (MIDIS) y World Food Programme (WFP). (2022). *Vulnerabilidad a la inseguridad alimentaria por departamento, provincia y distrito*,

2018. https://evidencia.midis.gob.pe/wp-content/uploads/2022/09/WFA-MIDIS_Inseguridad-alimentaria-08092022.pdf
- Ministerio de Economía y Finanzas (MEF). (2024). *Marco macroeconómico multianual 2025-2028*.
- Mignon, V. (2024). *Principles of econometrics. Theory and applications*. Springer.
- Ministerio del Ambiente (MINAM). (2020). *Contribuciones determinadas a nivel nacional del Perú. Reporte de actualización periodo 2021-2030*.
- Ministerio del Ambiente (MINAM). (2023). *Inventario nacional de gases de efecto invernadero 2000-2019*.
https://www.mef.gob.pe/contenidos/pol_econ/marco_macro/MMM_2025_2028.pdf
- Mirzabaev, A., Olsson, L., Kerr, R., Pradhan, P., Rivera, M. & Lotze-Campen, H. (2023). *Climate change and food systems*. In J. Von Braun, K. Afsana, L. Fresco & M. Hassan (Eds.), *Science and innovations for food systems transformation* (pp. 511-530). Springer.
- Montoya, I. (2022). *El análisis de regresión lineal y la precisión del pronóstico de demanda de productos hidrobiológicos congelados en el Perú* [Tesis de maestría]. Universidad Nacional Federico Villarreal (UNFV). <https://hdl.handle.net/20.500.13084/6542>
- Moreno, N. (2018). Dinámica de sistemas y la curva medio ambiental de Kuznets en Perú (1990-2015). *Semestre Económico*, 21(49), 57-88.
<https://doi.org/10.22395/seec.v21n49a3>
- Morgan, A., & Fanzo, J. (2020). Nutrition transition and climate risks in Nigeria: Moving towards food systems policy coherence. *Current environmental health reports*, 7(4), 392–403. <https://doi.org/10.1007/s40572-020-00292-3>
- Mostafaei, H., Rostampour, M., Chamasemani, N. y Wu, C. (2024). *An in-depth exploration of carbon footprint analysis in the construction sector with emphasis on the dam*

- industry*. En S. Muthu (Ed.), *Carbon footprint assessments. Case studies & best practices* (pp. 45-80). Springer.
- Mougenot, B., Durand, R. & Koc, C. (2022). Testing the environmental Kuznets curve hypothesis: An empirical study for Peru. *International Journal of Energy Economics and Policy*, 12(1), 193–199. <https://doi.org/10.32479/ijeep.11895>
- Mustaffa, A. & Shabri, A. (2020). An improved rolling NGBM (1,1) forecasting model with GRG nonlinear method of optimization for fossil carbon dioxide emissions in Malaysia and Singapore. *2020 11th IEEE Control and System Graduate Research Colloquium (ICSGRC)*, Shah Alam, Malaysia, 32-37. <https://doi.org/10.1109/ICSGRC49013.2020.9232665>
- Myerson, P. (2023). *The art and science of demand and supply chain planning in today's complex global economy*. Routledge.
- National Oceanic and Atmospheric Administration (NOAA). (2023). Global atmospheric carbon dioxide compared to annual emissions (1751-2022) [Gráfico]. <https://www.climate.gov/media/14596>
- Nayebi, H. (2020). *Advanced statistics for testing assumed casual relationships. Multiple regression analysis. Path analysis. Logistic regression analysis*. Springer.
- Nelles, D. & Serrer, C. (2021). *This is climate change. A visual guide to the facts*. Springer.
- Newbold, P., Carlson, W. & Thorne, B. (2023). *Statistics for business and economics* (10th ed.). Pearson.
- Newman, R. & Noy, I. (2023). The global costs of extreme weather that are attributable to climate change. *Nature Communications*, 14(6103), 1-13. <https://doi.org/10.1038/s41467-023-41888-1>
- Nogueira, L., Crane, T., Ortiz, A., D'Angelo, H. & Neta, G. (2023). Climate change and cancer. *Cancer Epidemiology, Biomarkers & Prevention: a publication of the American*

- Association for Cancer Research*, cosponsored by the American Society of Preventive Oncology, 32(7), 869-875. <https://doi.org/10.1158/1055-9965.epi-22-1234>
- Nogueira, L., Yabroff, R. & Bernstein, A. (2020). Climate change and cancer. *CA: A Cancer Journal for Clinicians*, 70(4), 239-244. <https://doi.org/10.3322/caac.21610>
- Oikonomou, A., Polemis, M., & Soursou, S. (2021). International environmental agreements and CO₂ emissions: Fresh evidence from 11 polluting countries. *Journal of Risk and Financial Management*, 14(7), 1-13. <https://doi.org/10.3390/jrfm14070331>
- Organización para la Cooperación y el Desarrollo Económico (OCDE), Banco de desarrollo de América Latina y el Caribe (CAF) y Unión europea (UE). (2022). *Perspectivas económicas de América Latina 2022: Hacia una transición verde y justa*.
- Ortiz-Bobea, A., Ault, T., Carrillo, C., Chambers, R. & Lobell, D. (2021). Anthropogenic climate change has slowed global agricultural productivity growth. *Nature Climate Change*, 11(4), 306–312. <https://doi.org/10.1038/s41558-021-01000-1>
- Oxford Committee for Famine Relief (OXFAM). (2022). *Hambre y calentamiento global. El impacto de la crisis climática en un mundo hambriento*. <https://www.oxfam.org/en/research/hunger-heating-world>
- Özcan, B. & Öztürk, I. (2019). *A historical perspective on environmental Kuznets curve*. In B. Özcan & I. Öztürk (Eds.), *Environmental Kuznets Curve (EKC). A manual* (pp. 1-7). Academic Press.
- Pabuççu, H. & Bayramoglu, T. (2016). CO₂ emissions forecast with neural networks with: The case of Turkey. *Gazi University Faculty of Economics and Administrative Sciences Journal*, 18(3), 762-778. https://www.researchgate.net/profile/Hakan-Pabuccu/publication/312187507_YAPAY_SINIR_AGLARI_ILE_CO2_EMISYONU_TAHMINI_TURKIYE_ORNEGI/links/5874e42a08ae8fce4927e77d/YAPAY-SINIR-AGLARI-ILE-CO2-EMISYONU-TAHMINI-TUeRKIYE-OeRNEGI.pdf

- Pao, H. & Fu, H. (2015). Competition and stability analyses among emissions, energy, and economy: Application for Mexico. *Energy*, 82(2015), 98-107.
<https://doi.org/10.1016/j.energy.2014.12.076>
- Pardoe, I. (2021). *Applied regression modeling* (3rd ed.). Wiley.
- Parkin, M. (2023). *Economics* (14th ed.). Pearson.
- Parodi, C. (2023). *Reformas estructurales*. En G. Aragón y J. Ruiz (Eds.), *Reformas económicas para un Perú sostenible* (pp. 7-16). Universidad del Pacífico.
- Paucar, D. (2023). *La actividad agropecuaria y el crecimiento económico en el Perú durante el periodo 2001-2021*. [Tesis de pregrado]. Universidad Nacional José Faustino Sánchez Carrión (UNJFSC).
<https://repositorio.unjfsc.edu.pe/handle/20.500.14067/7734>
- Peñaranda, C. (23 de abril de 2018). Urge priorizar siete reformas de cara al 2021. *La Cámara*.
<https://www.camaralima.org.pe/wp-content/uploads/2020/10/180423.pdf>
- Pérez-Escamilla R. (2024). Food and nutrition security definitions, constructs, frameworks, measurements, and applications: global lessons. *Frontiers in Public Health*, 12, 1340149. <https://doi.org/10.3389/fpubh.2024.1340149>
- Pinho-Gomes, A., Roaf, E., Fuller, G., Fowler, D., Lewis, A., ApSimon, H., Noakes, C., Johnstone, P. & Holgate, S. (2023). Air pollution and climate change. *The Lancet Planetary Health*, 7(9), 727-728. [https://doi.org/10.1016/S2542-5196\(23\)00189-4](https://doi.org/10.1016/S2542-5196(23)00189-4)
- Pinilla, M., Díaz-Rodríguez, C. y Sánchez-Buendía, E. (2018). Crecimiento económico y emisiones de CO₂ en América Latina, 1990-2015. *Semestre Económico*, 21(49), 41-55.
<https://doi.org/10.22395/seec.v21n49a2>
- Pinzón, A. (2024). *Inhabiting, expanding, and greening: The PREVI housing development approach*. In P. Du, K. Al-Kodmany & M. Ali (Eds.), *The Routledge handbook of greening high-density cities: climate, society and health* (pp. 140-154). Routledge.

- Podaras, A., Moirogiorgou, K. & Zervakis, M. (2021). *Regression-based recovery time predictions in business continuity management: A public college case study*. In C. Babaoglu, E. Akman & O. Kulac (Eds.), *Handbook of research on global challenges for improving public services and government operations* (pp. 380-408). IGI Global.
- Pousa-Unanue, A., Alzua-Sorzabal, A., & Femenia-Serra, F. (2026). Methodological pathways for measuring tourism carbon footprint: A framework-oriented systematic review. *Climate*, 14(2), 28. <https://www.mdpi.com/2225-1154/14/2/28>
- Qader, M., Khan, S., Kamal, M., Usman, M. & Haseeb, M. (2022). Forecasting carbon emissions due to electricity power generation in Bahrain. *Environmental Science and Pollution Research*, 29(12), 17346–17357. <https://doi.org/10.1007/s11356-021-16960-2>
- Rafindadi, A. (2016). Does the need for economic growth influence energy consumption and CO₂ emissions in Nigeria? Evidence from the innovation accounting test. *Renewable and Sustainable Energy Reviews*, 62(2016), 1209-1225. <https://doi.org/10.1016/j.rser.2016.05.028>
- Raihan, A., Muhtasim, D., Pavel, M., Faruk, O. & Rahman, M. (2022). An econometric analysis of the potential emission reduction components in Indonesia. *Cleaner Production Letters*, 3(2022), 1-9. <https://doi.org/10.1016/j.clpl.2022.100008>
- Raihan, A. & Tuspekova, A. (2022a). The nexus between economic growth, renewable energy use, agricultural land expansion, and carbon emissions: New insights from Peru. *Energy Nexus*, 6(2022), 1-12. <https://doi.org/10.1016/j.nexus.2022.100067>
- Raihan, A. & Tuspekova, A. (2022b). The nexus between economic growth, energy use, urbanization, tourism, and carbon dioxide emissions: New insights from Singapore. *Sustainability Analytics and Modeling*, 2(2022), 1-13. <https://doi.org/10.1016/j.samod.2022.100009>

- Rajhi, H. & Bardi, A. (2023). *Phytoremediation of endocrine disrupting pollutants in industrial wastewater*. In I. Haq, A. Kalamdhad & A. Pandey (Eds.), *Current developments in biotechnology and bioengineering. Bioremediation of endocrine disrupting pollutants in industrial wastewater* (pp. 55-84). Elsevier.
- Ravindran, R., Warsing, D. & Griffin, P. (2024). *Supply chain engineering: Models and applications*, (2nd ed.). CRC Press.
- Reichelt, H., Allen, D. & Scott, C. (2023). *Mainstreaming climate action in public and private investments: mobilizing finance towards sustainable investments through the bond markets*. In A. Sundaram & R. Hansen (Eds.), *Handbook of business and climate change* (pp. 430-457). Edward Elgar Publishing.
- Reid, D. & Sanders, N. (2023). *Operations management. An integrated approach* (8th ed.). Wiley.
- Rivera, R. (2020). *Principles of managerial statistics and data science*. Wiley.
- Rodríguez, I. (2022). *Las emisiones de dióxido de carbono y su impacto en las economías latinoamericanas según distribución de ingresos*. [Tesis de pregrado]. Universidad Peruana de Ciencias Aplicadas (UPC).
- Roos, M. & Hoffart, F. (2021). *Climate economics. A call for more pluralism and responsibility*. Palgrave Macmillan.
- Rosales, J. (2022). Predicción de la contaminación atmosférica generada por las emisiones del CO₂ en el Perú utilizando los métodos ARIMA y Redes Neuronales. *Journal BioFab*, 1(1), 114-125. <http://dx.doi.org/10.53673/jb.v1i1.4>
- Rose, G. (2021). *Time for a protocol on transnational environmental crime?* In B. Desai (Ed.), *Our Earth matters. Pathways to a better common environmental future* (pp. 167-172). IOS press.
- Rossi, R. (2022). *Applied biostatistics for the health sciences* (2nd ed.). Wiley.

- Ruppel, O. (2021). *Soil protection and the right to food for a better common future*. In B. Desai (Ed.), *Our Earth matters. Pathways to a better common environmental future* (pp. 149-165). IOS press.
- Russell, R., Taylor, B., Bayley, T. & Castillo, I. (2020). *Operations management. Creating value along the supply chain* (2nd ed.). Wiley.
- Sabroso, L, Duyo, J. & Salapa, A. (2023). Unraveling the intricate nexus of Philippine environment and economy: An empirical analysis using multiple regression. *American Journal of Environmental Economics*, 2(1), 24-28.
<https://doi.org/10.54536/ajee.v2i1.1640>
- Sadler, T. (2023). *Understanding global crises. From Covid to climate change and economic collapse*. Routledge.
- Saidi, K. & Hammami, S. (2015). The impact of CO₂ emissions and economic growth on energy consumption in 58 countries. *Energy Reports*, 1, 62-70.
<https://doi.org/10.1016/j.egy.2015.01.003>
- Sarfaty, M. (2022). *Climate change and population health. A primer*. Jones & Bartlett Learning.
- Segar, Y, Mohamad, N. & Sanusi, N. (2024). Forecasting CO₂ emissions in Malaysia through ARIMA modelling: Implications for environmental policy. *International Journal of Design & Nature and Ecodynamics*, 19(3), 849-857.
<https://doi.org/10.18280/ij dne.190315>
- Segaran, T., Kassim, M., Mohamad, N., Lananan, F., Wang, Y., Téllez-Isaías, G., Bottje, W., Kari, Z. & Azra, M. (2024). *Mapping the research landscape and identifying emerging trends in climate change impacts on capture fisheries and fish landing: A scientometric review*. In M. Azra, T. Segaran, G. Téllez-Isaías & H. Ariffin (Eds.), *Marine life in changing climates* (pp. 25-70). Nova Science Publishers.

- Sen, G. (2021). *Research & development pathways/challenges in direct air capture of CO₂*. In M. Goel, T. Satyanarayana, M. Sudhakar & D. Agrawal (Eds.), *Climate change and green chemistry of CO₂ sequestration* (pp. 181-196). Springer.
- Senthilkumar, P. (2021). *Feasibility study of CO₂ control in automobile sources*. In M. Goel, T. Satyanarayana, M. Sudhakar & D. Agrawal (Eds.), *Climate change and green chemistry of CO₂ sequestration* (pp. 69-86). Springer.
- Shahbaz, M., Ilarslan, K. & Yildiz, M. (2023). *Examination of the environmental Kuznets curve hypothesis with quadratic and cubic functional models. An econometric analysis of European countries*. In M. Shahbaz, D. Balsalobre & R. Sharma (Eds.), *Economic growth and environmental quality in a post-pandemic world* (pp. 1-33). Routledge.
- Siegel, F. (2020). *Adaptations of coastal cities to global warming, sea level rise, climate change and endemic hazards*. Springer.
- Siems, M. (2024). *Empirical methods*. In M. Siems & P. Yap (Eds.), *The Cambridge handbook of comparative law* (pp. 157-176). Cambridge University Press.
- Singh, M. & Thirsk, L. (2022). *Nursing research in Canada. Methods and critical appraisal and utilization* (5th ed.). Springer.
- Sinha, A., Shahbaz, M. & Balsalobre, D. (2019). *Data selection and environmental Kuznets curve models – environmental Kuznets curve models, data choice, data sources, missing data, balanced and unbalanced panels*. In B. Özcan & I. Öztürk (Eds.), *Environmental Kuznets Curve (EKC). A manual* (pp. 65-83). Elsevier.
- Sinha, A. & Schneider, N. (2023). *EKC modelling in a post-pandemic era. A policy note on socio-ecological trade-off*. In M. Shahbaz, D. Balsalobre & R. Sharma (Eds.), *Economic growth and environmental quality in a post-pandemic world* (pp. 121-148). Routledge.

- Songwe, V., Stern, N. & Bhattacharya, A. (2022). *Finance for climate action: Scaling up investment for climate and development. Report of the independent high-level expert group on climate finance*. Grantham Research Institute on Climate Change and the Environment, London School of Economics and Political Science.
<https://repository.uneca.org/handle/10855/49154>
- Stock, J. & Watson, M. (2020). *Introduction to econometrics* (4th ed.). Pearson.
- Sulaiman, A. & Shabri, A. (2021). Forecasting carbon dioxide emissions for Malaysia using grey model with Cramer's rule. *Malaysian Journal of Fundamental and Applied Sciences*, 17(4), 437-445. <https://doi.org/10.11113/mjfas.v17n4.2091>
- Sumalave, F. (2022). *Degradación ambiental y el PBI en el Perú, 2004-2019*. [Tesis de maestría]. Universidad Nacional del Callao (UNAC).
- Sun, W. & Sun, J. (2017). Prediction of carbon dioxide emissions based on principal component analysis with regularized extreme learning machine: The case of China. *Environmental Engineering Research*, 22(3), 302-311.
<https://doi.org/10.4491/eer.2016.153>
- Sundstrom, A. (2021). *Looking through Palme's vision for the global environment*. In B. Desai (Ed.), *Our Earth matters. Pathways to a better common environmental future* (pp. 175-182). IOS press.
- Swink, M., Melnyk, S. & Hartley, J. (2020). *Managing operations across the supply chain* (4th ed.). McGraw-Hill.
- Swiss Re Institute. (2021). *The economics of climate change: no action not an option*. Swiss Re Institute. <https://www.swissre.com/dam/jcr:e73ee7c3-7f83-4c17-a2b8-8ef23a8d3312/swiss-re-institute-expertise-publication-economics-of-climate-change.pdf>

- Swiss Re Institute. (2024). *Changing climates: the heat is (still) on. Hazard intensification set to compound economic losses.* Swiss Re Institute. <https://www.swissre.com/dam/jcr:cdbae8ed-24d0-4ec8-ad49-14f16846e556/2024-02-28-sri-expertise-publication-changing-climates-heat-still-on.pdf>
- Taniushkina, D., Lukashevich, A., Shevchenko, V., Belalov, I., Sotiriadi, N., Narozhnaia, V., Kovalev, K., Krenke, A., Lazarichev, N., Bulkin, A., & Maximov, Y. (2024). Case study on climate change effects and food security in Southeast Asia. *Scientific Reports*, 14(1), 1-15. <https://doi.org/10.1038/s41598-024-65140-y>
- Tapkigen, J., Harding, S., Pulkki, J., Atkins, S., & Koivusalo, M. (2024). Climate change-induced shifts in the food systems and diet-related non-communicable diseases in sub-Saharan Africa: a scoping review and a conceptual framework. *BMJ open*, 14(6), 1-13. <https://doi.org/10.1136/bmjopen-2023-080241>
- Tay, D. (2024). *Data analytics for discourse analysis with python. The case of therapy talk.* Routledge.
- The Royal Society. (2021). *Effects of net-zero policies and climate change on air quality.* The Royal Society. <https://royalsociety.org/-/media/policy/projects/air-quality/air-quality-and-climate-change-report.pdf>
- Tleppayev, A. & Zeinolla, S. (2023). Climate change, CO₂ emission, and economic development: evidence from Kazakhstan. *Central Asian Journal of Sustainability and Climate Research*, 2(1), 62-82. <https://doi.org/10.29258/CAJSCR/2023-R1.v2-1/62-82.eng>
- Tostes, M., Villavicencio, A. & Motta, C. (2019). Vulnerability index elaboration for climate change adaptation in Peru. *European Journal of Sustainable Development*, 8(5), 102-114. <http://dx.doi.org/10.14207/ejsd.2019.v8n5p102>

- Trinidad, C. & Soberón, D. (2021). *Carbon pricing in Perú: a matter of climate justice in the Covid-19 context*. In H. Ashiabor, J. Milne & M. Andersen (Eds.), *Environmental taxation in the pandemic era. Opportunities and challenges* (pp. 96-110). Edward Elgar Publishing.
- Tsolacos, S. & Andrew, M. (2021). *Applied quantitative analysis for real estate*. Routledge.
- Udemba, E. (2023). *Sustainable development through carbon neutrality. A policy insight from foreign direct investment and service policy*. In M. Shahbaz, D. Balsalobre & R. Sharma (Eds.), *Economic growth and environmental quality in a post-pandemic world* (pp. 149-176). Routledge.
- Ulucak, R., Yücel, A. & Koçak, E. (2019). *The process of sustainability: From past to present*. In B. Özcan & I. Öztürk (Eds.), *Environmental Kuznets Curve (EKC). A manual* (pp. 37-53). Elsevier.
- United Nations Development Programme (UNDP). (2023). *The climate dictionary. Speak climate fluently*. <https://www.undp.org/sites/g/files/zskgke326/files/2023-10/undp-the-climate-dictionary-v3.pdf>
- United Nations Environment Programme (UNEP). (2023). *Emissions gap report 2023: Broken record*. <https://doi.org/10.59117/20.500.11822/43922>
- U.S. Global Change Research Program (USGCRP). (2017). *Climate science special report: Fourth national climate assessment, Volume I*.
- Usher, B. (2022). *Investing in the era of climate change*. Columbia University Press.
- Vandeput, J. (2023). *Demand forecasting. Best practices*. Manning.
- Vasigh, B. & Pearce, B. (2024). *Air transport economics. From theory to applications* (4th ed.). Routledge.
- Villanthenkodath, M. (2023). *Revisiting the environmental Kuznets curve (EKC). An analysis using the sectoral output and ecological footprint in India*. In M. Shahbaz, D.

- Balsalobre & R. Sharma (Eds.), *Economic growth and environmental quality in a post-pandemic world* (pp. 233-250). Routledge.
- Villarroel, V., Révolo, R., Quispe, U., Carmen, E., Colonio, J. Quispe, B. (2021). Analysis of climate change and sustainable development in Peru and its departments during the year 2006-2018. *International Journal of Environment and Climate Change*, 11(8), 31-46. <http://dx.doi.org/10.9734/ijecc/2021/v11i830456>
- Vo, A., Vo, D. & Le, Q. (2019). CO₂ emissions, energy consumption, and economic growth: new evidence in the ASEAN countries. *Journal of Risk and Financial Management*, 12(3), 1-20. <https://doi.org/10.3390/jrfm12030145>
- Wahid, N., Suhaila, J. & Rahman, H. (2021). Effect of climate factors on the incidence of hand, foot, and mouth disease in Malaysia: A generalized additive mixed model. *Infectious Disease Modelling*, 6(2021), 997–1008. <https://doi.org/10.1016/j.idm.2021.08.003>
- Waidelich, P., Batibeniz, F., Rising, J., Kikstra, J. & Seneviratne, S. (2024). Climate damage projections beyond annual temperature. *Nature Climate Change*, 14(6), 592–599. <https://doi.org/10.1038/s41558-024-01990-8>
- Wang, C., Li, M., Yan, J. (2023). Forecasting carbon dioxide emissions: application of a novel two-stage procedure based on machine learning models. *Journal of Water and Climate Change*, 14, (2), 477-493. <https://doi.org/10.2166/wcc.2023.331>
- Wang, S., Li, G., Fang, C. (2018). Urbanization, economic growth, energy consumption, and CO₂ emissions: Empirical evidence from countries with different income levels. *Renewable and Sustainable Energy Reviews*, 81, (2), 2144-2159. <https://doi.org/10.1016/j.rser.2017.06.025>
- Westfall, P. & Arias, A. (2020). *Understanding regression analysis: A conditional distribution approach*. CRC Press.

- World Food Programme (WFP). (2009). *Manual para la evaluación de la seguridad alimentaria en emergencia* (2nd.ed.). <https://reliefweb.int/report/world/manual-para-la-evaluaci%C3%B3n-de-la-seguridad-alimentaria-en-emergencias-esae-segunda>
- World Food Programme (WFP). (2024). *Peru, annual country report 2023. Country strategic plan 2023-2026*.
- World Health Organization (WHO). (2024). *Communicating on climate change and health. Toolkit for health professionals*.
- Wisner, J., Tan, K. & Leong, K. (2023). *Principles of supply chain management. A balanced approach* (6th ed.). Cengage.
- World Bank. (2022). *Climate and development: An agenda for action-Emerging insights from World Bank Group 2021–22 country climate and development reports*. World Bank. <https://openknowledge.worldbank.org/handle/10986/38220>
- World Meteorological Organization (WMO). (2023). *United in science 2023*.
- Wu, L., Liu, S., Liu, D., Fang, Z. & Xu, H. (2015). Modelling and forecasting CO₂ emissions in the BRICS (Brazil, Russia, India, China, and South Africa) countries using a novel multi-variable grey model. *Energy*, 79(2015), 489-495. <https://doi.org/10.1016/j.energy.2014.11.052>
- Xu, Z., Liu, L. & Wu, L. (2021). Forecasting the carbon dioxide emissions in 53 countries and regions using a non-equigap grey model. *Environmental Science and Pollution Research*, 28(13), 15659–15672. <https://link.springer.com/article/10.1007/s11356-020-11638-7>
- Yao, S., Zhang, S. & Zhang, X. (2019). Renewable energy, carbon emission and economic growth: A revised environmental Kuznets Curve perspective. *Journal of Cleaner Production*, 235(11), 1338-1352. <https://doi.org/10.1016/j.jclepro.2019.07.069>

- Yue, H. & Bu, L. (2023). Prediction of CO₂ emissions in China by generalized regression neural network optimized with fruit fly optimization algorithm. *Environmental Science and Pollution Research*, 30(33), 80676-80692. <https://doi.org/10.1007/s11356-023-27888-0>
- Zhang, Y. (2022). China's CO₂ Emission prediction by population and GDP based on MLR and BP neural network. *Advances in Economics, Business and Management Research*, 217(2022), 410-415. <https://doi.org/10.2991/aebmr.k.220502.073>
- Zhang, Y., Chen, X., Wu, Y., Shuai, C., Shen, L., & Ye, G. (2020). Peaks of transportation CO₂ emissions of 119 countries for sustainable development: Results from carbon Kuznets curve. *Sustainable Development*, 28(4), 550-571. <https://doi.org/10.1002/sd.2008>
- Zhao, C., Dong, X. & Dong, K. (2023). *Renewable energy, carbon emissions, and economic growth. The comparison between EKC and RKC*. In M. Shahbaz, D. Balsalobre & R. Sharma (Eds.), *Economic growth and environmental quality in a post-pandemic world* (pp. 81-106). Routledge.

IX ANEXOS

Anexo A Matriz de Consistencia

PRONÓSTICO DE LAS EMISIONES DE DIOXIDO DE CARBONO EN EL PERÚ EN BASE AL PRODUCTO BRUTO INTERNO, 2022-2028				
PROBLEMAS	OBJETIVOS	HIPÓTESIS	VARIABLES	MÉTODO
GENERAL	GENERAL	GENERAL	VARIABLE INDEPENDIENTE	TIPO DE INVESTIGACIÓN
¿Qué tendencia tendrá el pronóstico de las emisiones de CO ₂ en el Perú en el espacio temporal 2022-2028?	Estimar la tendencia del pronóstico de las emisiones de CO ₂ en el Perú en el espacio temporal 2022-2028.	El pronóstico de las emisiones de CO ₂ en el Perú tendrá una tendencia creciente en el espacio temporal 2022-2028.	Producto bruto interno (PBI)	La investigación es de tipo cuantitativa y aplicada.
ESPECÍFICO 1	ESPECÍFICO 1	ESPECÍFICA 1	DIMENSIÓN	NIVEL DE LA INVESTIGACIÓN
¿Qué relación existe en el Perú entre las emisiones de CO ₂ y el PBI en el lapso 2005-2021?	Establecer la relación entre las emisiones de CO ₂ y el PBI en el Perú en el lapso 2005-2021.	En el Perú las emisiones de CO ₂ y el PBI muestran una relación positiva en el lapso 2005-2021.	Desempeño económico	El nivel de la investigación es el correlacional.
ESPECÍFICO 2	ESPECÍFICO 2	ESPECÍFICA 2	INDICADOR	DISEÑO DE LA INVESTIGACIÓN
¿Qué tipo de elasticidad existe en el Perú entre las emisiones de CO ₂ y el PBI en los años 2005-2021?	Precisar el tipo de elasticidad que existe en el Perú entre las emisiones de CO ₂ y el PBI en los años 2005-2021.	En el Perú las emisiones de CO ₂ son inelásticas con respecto al PBI en los años 2005-2021.	Logaritmo natural del PBI en millones de soles a los precios de 2007.	El diseño de la investigación es no experimental de múltiples series de tiempo.
ESPECÍFICO 3	ESPECÍFICO 3	ESPECÍFICA 3	VARIABLE DEPENDIENTE	POBLACIÓN
¿Cuál es la precisión de las estimaciones de las emisiones de CO ₂ en el Perú entre los años 2005-2021?	Calcular la precisión de las estimaciones de las emisiones de CO ₂ en el Perú entre los años 2005-2021.	Las estimaciones de las emisiones de CO ₂ en el Perú presentan una precisión muy buena (MAPE ≤ 10%) entre los años 2005-2021.	Emisiones de dióxido de carbono (CO ₂)	La población está compuesta por las series temporales:
ESPECÍFICO 4	ESPECÍFICO 4	ESPECÍFICA 4	DIMENSIÓN	• Emisiones de CO ₂ en miles de toneladas (1993-2021). Fuente: INEI.
¿Son sesgadas las estimaciones de las emisiones de CO ₂ en el Perú durante el periodo 2005-2021?	Determinar el sesgo de las estimaciones de las emisiones de CO ₂ en el Perú durante el periodo 2005-2021.	Las estimaciones de las emisiones de CO ₂ en el Perú son insesgadas durante el periodo 2005-2021.	Degradación ambiental	• Producto bruto interno (PBI) en millones de soles a precios de 2007 (1922-2023). Fuente: BCRP.
			INDICADOR	MUESTRA
			Logaritmo natural de las emisiones de CO ₂ en miles de toneladas.	La muestra la componen las series temporales listadas en el ítem población, pero para el periodo 2001-2021.

Anexo B Validación y Confiabilidad de Instrumentos

Para el desarrollo de la presente investigación se utilizó información estadística de series de tiempo de fuentes secundarias oficiales. Con tal información se construyó un modelo de regresión lineal, con el cual se pronosticó las emisiones de CO₂ (2022-2028) en función al PBI. La información estadística necesaria para la elaboración del modelo de regresión, se recopiló directamente de las páginas web de fuentes oficiales tales como el INEI (Emisiones de CO₂) y el BCRP (PBI). Por lo cual, no fue necesario el uso de instrumentos y por consiguiente no se requirió de su validación, ni tampoco evaluar su confiabilidad.

Anexo C Fichas Técnicas de las Variables

Ficha técnica de la variable independiente

Nombre	Producto Bruto Interno (PBI)
Descripción	Valor de mercado de los bienes y servicios finales producidos por un país en cierto periodo (Mankiw, 2024).
Dimensión	Desempeño económico
Unidad de medida	Millones de soles a precios de 2007
Tipo de datos	Serie de tiempo
Periodicidad	Anual
Data disponible	1922 - 2023
Periodo muestral	2001 - 2021
Fuente	Banco Central de Reserva del Perú (BCRP) https://estadisticas.bcrp.gob.pe/estadisticas/series/anuales/pbi-por-sectores

Ficha técnica de la variable dependiente

Nombre	Emisiones de dióxido de carbono (CO ₂)
Descripción	Cantidad de CO ₂ liberado que tendría un efecto significativo en el cambio climático (IPCC, 2023).
Dimensión	Degradación ambiental
Unidad de medida	Miles de toneladas
Tipo de datos	Serie de tiempo
Periodicidad	Anual
Data disponible	1993 - 2021
Periodo muestral	2001 - 2021
Fuente	Instituto Nacional de Estadística e Informática (INEI) https://www.inei.gob.pe/biblioteca-virtual/publicaciones-digitales/