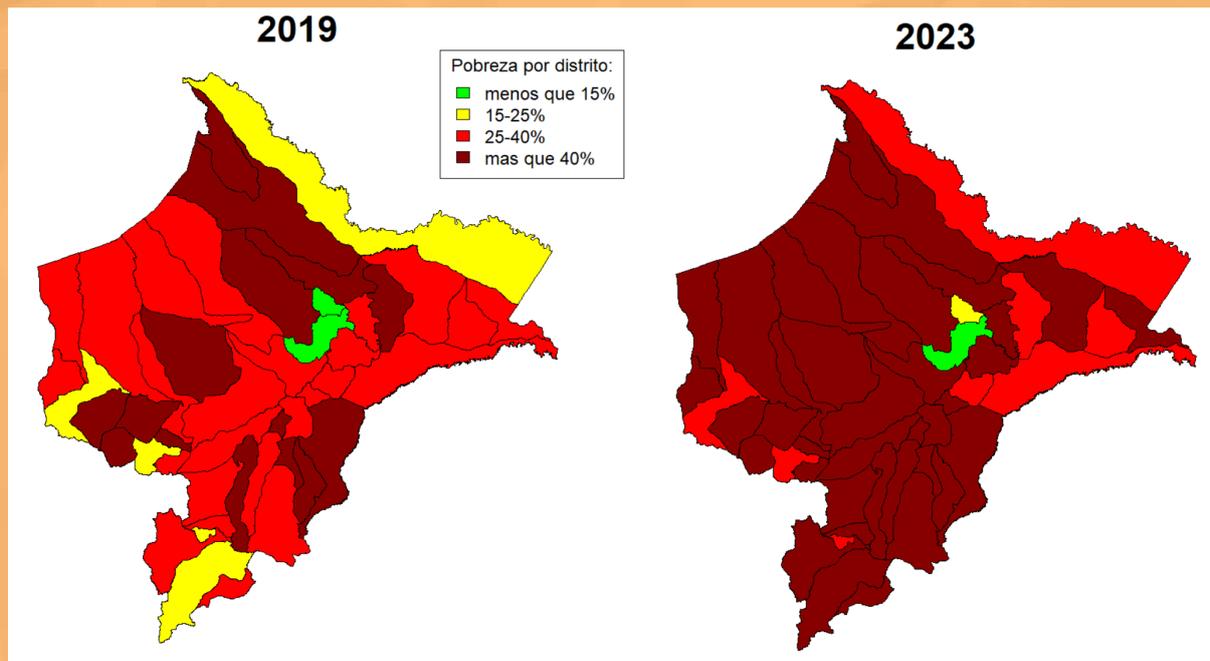




EFFECTO DEL COVID-19 SOBRE LA POBREZA MONETARIA EN LOS HOGARES DEL PERÚ (2019-2023): UN ENFOQUE VÍA ÁREAS PEQUEÑAS



**ANNA SIKOV
JOSÉ CERDA HERNÁNDEZ
JESÚS CERNADES GÓMEZ**

Nº 1

Series in Empirical Research

Editor-in-Chief

Anna Sikov, Ph.D.
Universidad Nacional de Ingeniería, Perú.
E-mail: edms@uni.edu.pe

Associate Editors

José Cerda-Hernández, Ph.D. Universidad Nacional de Ingeniería, Perú.
Roberto Vila, Ph.D. Universidad de Brasilia, Brasil.
Alberto Ramos, Ph.D. Universidad de Tarapacá, Chile.
Evgenia Chunikhina, Ph.D. Pacific Univesity, USA.
Manuel Gonzales Navarrete, Ph.D. Universidad de La Frontera, Chile.
Cira Guevara, Ph.D. Universidad de Brasilia, Brasil
Daniel Gutierrez, Ph.D. Universidad Católica San Pablo.

The *Series in Empirical Research* (SER) publishes advances in statistical methodology, statistical learning, and their applications across diverse fields, including statistics, economics, demography, and more. SER focuses on original research and practical applications of econometric and statistical methodologies, particularly those addressing real-world challenges. We particularly welcome pioneering and inventive applications of modern statistical methodologies, including intricate approaches to data analysis.

SER publishes peer-reviewed manuscripts in English and Spanish. Contributions reflect substantial empirical research and/or theoretical innovation with respect to the current state of the art. Each manuscript undergoes a double-blind peer review by at least two experts, including the Editor(s) and an external reviewer selected by the Editorial Board.

<https://www.emds.uni.edu.pe/>

Series in Empirical Research

1

Efecto del Covid-19 sobre la pobreza monetaria en los hogares del Perú: Un enfoque vía áreas pequeñas

Anna Sikov

Universidad Nacional de Ingeniería

José Cerda Hernández

Universidad Nacional de Ingeniería

Jesús Cernades Gómez

Universidad Nacional de Ingeniería

Marzo, 2025



Series in Empirical Research N° 1

Econometric Modelling and Data Science Research Group

<https://www.emds.uni.edu.pe>

E-mail: emds@uni.edu.pe

Copyright ©, 2025 by EMDS

Universidad Nacional de Ingeniería

Casilla 100-1301, Lima, Perú

Av. Tupac Amaru, 210 LIMA - PERU

Primera Edición. Lima, marzo del 2025.

Todos los derechos reservados.

Certificado de Depósito Legal N° 2025-XXXXX

ISBN: XXX-XXX-XXXX-XX-X

e- ISBN: XXX-XXX-XXXX-XX-X

Efecto del Covid-19 sobre la pobreza monetaria en los hogares del Perú: Un enfoque vía áreas pequeñas

Effect of Covid-19 on Monetary Poverty in Peruvian Households: A Small Area Approach

Anna Sikov¹, José Cerda-Hernández^{1*}, Jesús Cernades Gómez²

¹*Econometric Modelling and Data Analysis Research Group, Universidad Nacional de Ingeniería, Av. Tupac Amaru 210, Rimac, Lima, Perú.*

²*Facultad de Ingeniería Industrial y de Sistemas, Universidad Nacional de Ingeniería, Av. Tupac Amaru 210, Rimac, Lima, Perú.*

26 de marzo de 2025

Resumen

Este estudio aplica el modelo de áreas pequeñas desarrollado en [Sikov and Cerda-Hernández \(2024\)](#) para generar mapas detallados del porcentaje de familias que viven en pobreza monetaria a nivel distrital en el Perú para los años 2019 y 2023. Utilizando datos de la ENAHO, se estimó la incidencia de la pobreza a nivel distrital, permitiendo identificar conglomerados de alta vulnerabilidad y analizar los cambios en la distribución espacial de la pobreza antes y después de la pandemia del COVID-19. La desagregación y comparación a nivel distrital revelan disparidades significativas, cruciales para la focalización de políticas públicas. Nuestros resultados evidencian que, en la mayoría de los departamentos, la pobreza supera los niveles prepandemia, señalando un retroceso en los avances socioeconómicos. Destacablemente, Lima Metropolitana experimentó un deterioro marcado, con distritos alcanzando niveles de pobreza entre el 25% y 40% en 2023. Este análisis subraya la necesidad de intervenciones específicas y focalizadas para mitigar el impacto persistente de la pandemia y revertir el aumento de la pobreza en el país.

*jcerdah@uni.edu.pe

Palabras Claves: Hogares en pobreza, Estimación en áreas pequeñas, Modelo de Fay-Herriot, Correlación espacial, Error cuadrático medio.

Abstract

This study applies the small area estimation model developed in [Sikov and Cerda-Hernández \(2024\)](#) to generate detailed maps of the percentage of households living in monetary poverty at the district level in Peru for the years 2019 and 2023. Using data from the ENAHO, the incidence of poverty was estimated at the district level, allowing for the identification of high-vulnerability clusters and the analysis of changes in the spatial distribution of poverty before and after the COVID-19 pandemic. The disaggregation and comparison at the district level reveal significant disparities, crucial for the targeting of public policies.

Our results demonstrate that, in most departments, poverty exceeds pre-pandemic levels, indicating a setback in socioeconomic progress. Notably, Metropolitan Lima experienced a marked deterioration, with districts reaching poverty levels between 25% and 40% in 2023. This analysis underscores the need for specific and targeted interventions to mitigate the persistent impact of the pandemic and reverse the increase in poverty in the country.

Keywords: Households in poverty, Small area estimation, Fay-Herriot model, Spatial correlation, Mean squared error.

Índice

1. Introducción	4
2. Construcción de Mapas de Hogares en Pobreza Monetaria en el Perú	7
2.1. Objetivos del estudio	7
2.2. Dominio	8
2.3. Elección de variables auxiliares	8
2.4. Muestra	8
2.5. Análisis estadístico	9
3. Resultados y Consideraciones	9
3.1. Panorama nacional	9
3.2. Pobreza urbana	12
3.3. Recomendaciones	13
4. Mapas del porcentaje de hogares que viven en pobreza a nivel distrital: Un Análisis Comparativo (2019-2023)	15
A. Análisis espacial de la pobreza: Estimación en Áreas Pequeñas	30

1. Introducción

La erradicación de la pobreza sigue siendo uno de los desafíos más importantes a nivel global, y el Perú, a pesar de sus avances económicos, enfrenta desafíos en este ámbito. A pesar de la significativa reducción de la pobreza a nivel nacional en los últimos 20 años, persisten marcadas disparidades regionales y locales que demandan una atención minuciosa (Banco Mundial, 2023, 2024; INEI, 2024). Como señalan diversos artículos (ver por ejemplo Alcázar, 2019; Sánchez, 2022; Banco Mundial, 2023, 2024; Sikov et al., 2024a), la pobreza no es un fenómeno homogéneo, sino que se manifiesta de manera heterogénea a lo largo de un territorio, influenciada por factores socioeconómicos, geográficos y culturales específicos de cada localidad.

En este contexto, la información sobre pobreza a nivel distrital se erige como un instrumento indispensable para la formulación de políticas públicas efectivas y focalizadas (Pratesi, 2016; Corral et al., 2022; Sikov and Cerda-Hernández, 2023; Molina, 2024; Arias-Salazar et al., 2025). Así, la desagregación de datos permite identificar las áreas de mayor vulnerabilidad, posibilitando una asignación más eficiente de recursos y la implementación de intervenciones adaptadas a las necesidades locales. La omisión de esta heterogeneidad a nivel distrital puede conducir a la invisibilización de disparidades críticas y a la ineficacia de las intervenciones.

Este artículo propone contribuir al análisis de la pobreza monetaria en el Perú mediante la elaboración de mapas de hogares en pobreza a nivel distrital, empleando la metodología de estimación en áreas pequeñas (SAE) desarrollada en Sikov and Cerda-Hernández (2024). Esta técnica estadística, reconocida por su capacidad para generar estimaciones confiables en áreas con muestras limitadas, se presenta como una herramienta valiosa para superar las limitaciones de las encuestas nacionales (ver por ejemplo Fay and Herriot, 1979; Pratesi and Salvati, 2008, 2009; Pfeffermann, 2013; Molina and Rao, 2010; Rao and Molina, 2015; Casas-Cordero et al., 2016; Corral et al., 2022; Molina, 2024; Arias-Salazar et al., 2025; Sikov and Cerda-Hernández, 2023; Sikov et al., 2023, 2024a; Sikov and Cerda-Hernández, 2024; Sikov et al., 2024b; Sikov and Cerda-Hernandez, 2024; Benedetti et al., 2024, donde se aplica la metodología de SAE para la estimación de la pobreza y otros indicadores socioeconómicos a nivel de área). Usando los datos de la ENAHO, implementamos el modelo para los años 2019 y 2023, y posteriormente comparamos los resultados e identificamos regiones donde la pobreza aumentó o disminuyó significativamente para analizar el impacto que tuvo el Covid-19 sobre el ingreso de los hogares peruanos. Realizar un análisis desagregado y comparativo a nivel distrital, permite identificar zonas con mayor concentración de pobreza y sus características específicas. Nuestros resultados revelan que en la mayoría de departamentos la pobreza aún está significativamente por encima de los niveles prepandemia.

La pobreza monetaria es un indicador de bienestar de una población y, en el caso del Perú, se estima anualmente a partir de la información obtenida de la Encuesta Nacional de Hogares (ENAHO) elaborada y aplicada por el Instituto Nacional de

Estadística e Informática (INEI). Según el enfoque monetario, “se considera como pobres a las personas que residen en hogares cuyo gasto per cápita es insuficiente para adquirir una canasta básica de alimentos y no alimentos (vivienda, vestido, educación, salud, transporte, entre otros). Son pobres extremos aquellas personas que integran hogares cuyos gastos per cápita están por debajo del costo de la canasta básica de alimentos” (INEI, 2024, p. 63), siendo S/ 446 y S/ 251 per cápita mensual el valor de la línea de pobreza y pobreza extrema para el año 2023, respectivamente. Según el último informe del INEI (INEI, 2024), en el año 2023, la pobreza monetaria en el Perú afectó al 29 % de la población, que equivale a 9 millones 780 mil personas, un incremento del 1.5 % respecto al año 2022, sin embargo, esa cifra no explica ni refleja la heterogeneidad que existe entre las regiones peruanas en términos de características socioeconómicas, creencias idiosincrásicas y composición económica que inciden sobre la pobreza. Por ejemplo, en el 2023 la pobreza monetaria en Cajamarca, Loreto y Puno fue de 44.5 %, 43.5 % y 41.6 %, respectivamente (INEI, 2024). Esta heterogeneidad entre las regiones se refleja en la diferencia entre factores como el acceso a servicios de salud, falta de infraestructura, calidad de alimentación y condiciones socioeconómicas.

Las encuestas nacionales en países emergentes como el Perú enfrentan desafíos significativos en la inferencia a nivel distrital. La limitada representatividad muestral, tanto en el número de distritos incluidos como en el tamaño de muestra dentro de estos, restringe la capacidad de realizar un análisis desagregado confiable (problema de áreas pequeñas Rao and Molina (2015); Sikov and Cerda-Hernández (2023, 2024)). Adicionalmente, una alta proporción de distritos queda excluida de la muestra (ver 1). En el caso peruano, esta situación se agrava debido a limitaciones logísticas y presupuestales (ver Sikov and Cerda-Hernández, 2023; Sikov et al., 2023, 2024a; Sikov and Cerda-Hernández, 2024, para una mayor discusión). Esta problemática dificulta la toma de decisiones políticas basadas en datos a niveles subnacionales como provincias y distritos, limitando su confiabilidad a niveles agregados como el nacional, departamental o regional.

Frente a la problemática de representatividad limitada en las encuestas nacionales peruanas, surge la necesidad de adoptar metodologías estadísticas avanzadas que permitan superar las limitaciones de los datos disponibles. Una solución efectiva, empleada con éxito en países como Estados Unidos e Israel, es la aplicación del modelo Fay-Herriot espacial (ver Fay and Herriot, 1979; Petrucci and Salvati, 2006; Pratesi and Salvati, 2008). Este modelo, adaptado a las particularidades de los datos peruanos desarrollado en Sikov and Cerda-Hernández (2023, 2024), compensa la baja representatividad muestral y la exclusión de distritos mediante la incorporación de variables socioeconómicas y correlaciones espaciales.

La implementación de este modelo genera estimadores confiables tanto en distritos con muestras reducidas como en aquellos excluidos de la muestra (para más detalle ver Sikov and Cerda-Hernández, 2024), permitiendo obtener estimaciones más precisas y la identificación de conglomerados de pobreza a nivel distrital. Esta mayor precisión resulta fundamental para la toma de decisiones informadas, facili-

tando la implementación eficiente de programas sociales e intervenciones focalizadas en las áreas de mayor vulnerabilidad del país. En este sentido, la representación espacial detallada de la pobreza monetaria a nivel subnacional constituye una herramienta fundamental para la formulación e implementación de políticas sociales efectivas. Al proporcionar información geográficamente desagregada, se obtiene una visión precisa de la distribución y concentración de la pobreza, lo que permite priorizar intervenciones y optimizar la asignación de recursos en las áreas de mayor vulnerabilidad.

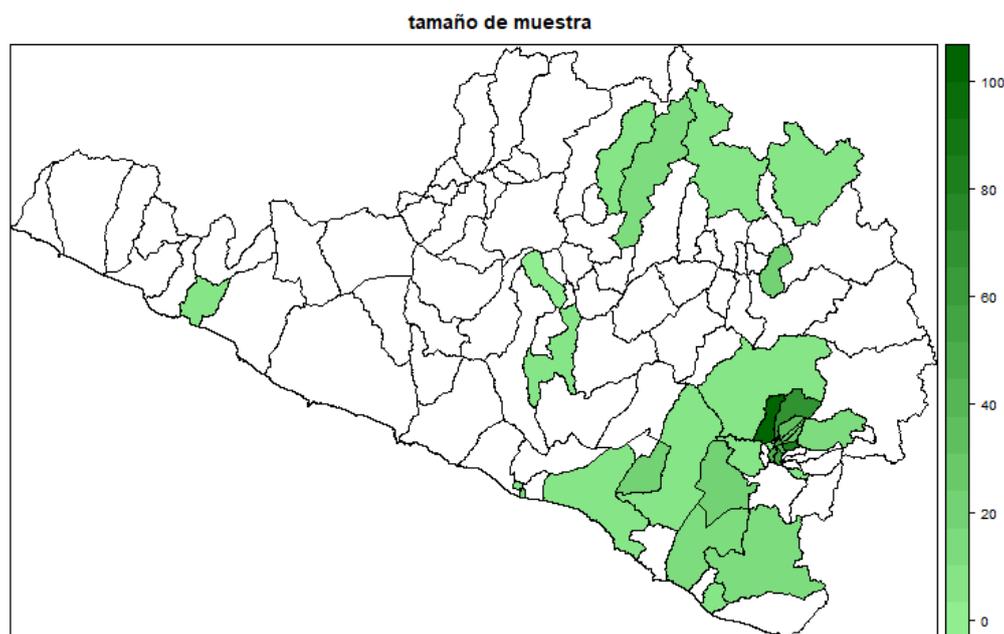


Figura 1. Mapa de calor del tamaño de la muestra en los distritos incluidos en la ENDES 2023.

En consecuencia, el objetivo primordial de este estudio es la elaboración de mapas del porcentaje de viviendas que viven en pobreza a nivel distrital para los años 2019 y 2023, que permitan visualizar la distribución espacial de la pobreza y la identificación de zonas críticas para dichos años. La comparación e identificación de tendencias en el porcentaje de viviendas que viven en pobreza permitirá ver como la pandemia del Covid-19 impactó en los ingresos de los hogares. Esta información desagregada es fundamental para que los responsables de políticas públicas prioricen intervenciones focalizadas en las áreas de mayor vulnerabilidad del país, superando las limitaciones de las estimaciones a nivel departamental, que no reflejan la heterogeneidad inherente a provincias y distritos. Finalmente, Para obtener factores que caractericen los hogares pobres en los distritos, usamos como variables instrumentales las variables socioeconómicas del Censo Nacional 2017.

2. Construcción de Mapas de Hogares en Pobreza Monetaria en el Perú

2.1. Objetivos del estudio

Como se ha señalado, el objetivo central de esta investigación es obtener estimaciones precisas del porcentaje de hogares en situación de pobreza y elaborar mapas detallados de este indicador a nivel distrital en el Perú para los años 2019 y 2023. Para lograrlo, se emplea la metodología de estimación en áreas pequeñas (SAE) propuesta por [Sikov and Cerda-Hernández \(2024\)](#), que incorpora hechos estilizados de las variables socioeconómicas específicas del contexto peruano ([Gonzales de Olarte, 1997](#)). La identificación precisa de las zonas de mayor vulnerabilidad permitirá analizar el impacto del COVID-19 en los ingresos familiares y proporcionar información crucial para el diseño de políticas públicas efectivas y focalizadas.

La pandemia del COVID-19 desencadenó un severo deterioro de las condiciones socioeconómicas en el Perú, exacerbando la pobreza y la desigualdad. Según el Instituto Nacional de Estadística e Informática (INEI) ([INEI, 2024](#)), en 2020, la pobreza alcanzó el 30,1 % de la población, lo que implicó que aproximadamente 3,3 millones de personas adicionales cayeran en esta situación. Este shock económico, caracterizado por una contracción del Producto Bruto Interno (PBI) del 11,1 %, la pérdida masiva de empleos y el aumento de la inflación, impactó de manera desproporcionada a los hogares de bajos ingresos. Adicionalmente, la pobreza monetaria en niños, niñas y adolescentes peruanos se incrementó de 26,9 % en 2019 a 39,9 % en 2020 (ver [INEI, 2024](#), para un informe detallado sobre los indicadores de pobreza a nivel nacional y departamental). Sin embargo, estas cifras agregadas ocultan la heterogeneidad del impacto a nivel distrital, donde las realidades locales difieren significativamente. El objetivo primordial de esta investigación es, por lo tanto, estudiar el problema de la pobreza a nivel distrital antes y después de la pandemia, revelando las disparidades ocultas por las estadísticas nacionales. La combinación de la pandemia, políticas públicas ineficaces y la corrupción en el sector público generó un retroceso de una década en la lucha contra la pobreza, como evidencian los informes de la Contraloría General de la República ([Procuraduría Pública Especializada en Delitos de Corrupción, 2022](#)) y el INEI ([INEI, 2024](#)).

Este retroceso se manifestó en una drástica disminución de los ingresos familiares, comprometiendo la capacidad de los hogares para satisfacer sus necesidades alimentarias básicas y precipitando a un número significativo de hogares a la pobreza extrema. Desde una perspectiva económica, este fenómeno representa una pérdida sustancial de capital humano y una contracción del consumo agregado. La malnutrición infantil, resultado directo de la pobreza, genera daños irreversibles en el desarrollo cognitivo, limitando las oportunidades futuras de los niños y perpetuando el ciclo de pobreza. Como lo menciona [Alcázar \(2012\)](#), esta merma en el capital humano no solo afecta la productividad individual, sino que también reduce

el potencial de crecimiento económico a largo plazo, al disminuir la capacidad innovadora y la fuerza laboral calificada (ver también [Beard and Connor, 2003](#); [Walter, 2003](#); [Lozoff, 2007](#); [Martínez and Fernández, 2009](#); [Francke and Acosta, 2020](#)). En este contexto, la reducción de la pobreza a nivel local, mediante la utilización de los mapas de pobreza generados en esta investigación, se erige como una estrategia crucial para revitalizar la economía nacional y mejorar la calidad de vida de los ciudadanos peruanos, especialmente en el marco de la recuperación post-pandemia. La implementación de intervenciones focalizadas, basadas en evidencia a nivel distrital, permitirá una asignación más eficiente de los recursos públicos, impulsando la reactivación económica, el desarrollo inclusivo y la acumulación de capital humano.

2.2. Dominio

El Perú está compuesto por 24 departamentos y la provincia constitucional del Callao. Cada departamento se subdivide en provincias, que van de 3 a 20, lo que da como resultado un total de 196 provincias en todo el país. Así mismo, cada provincia se divide en distritos, lo que da un total de 1874 distritos. Estas dos estructuras se utilizan para nuestro análisis. Los datos proporcionados por las ENAHO 2019 y 2023 permiten un análisis comparativo entre las áreas que cuentan con información disponible para todos los años estudiados.

2.3. Elección de variables auxiliares

La información auxiliar a nivel distrital es proporcionada por el censo nacional ([INEI, 2017](#)), realizado en 2017, e incluye mayoritariamente la información asociada a la pobreza de cada distrito. Nuestro análisis preliminar ha indicado que la mayoría de las variables auxiliares consideradas tenían una fuerte asociación con la pobreza; sin embargo, sólo las variables que resultaron significativas en presencia de otras variables se retuvieron en el modelo final, a saber, la altitud (la elevación sobre nivel del mar, medido en km.), $Altitud^2$ (el cuadrado de la Altitud), Agua (% de viviendas con acceso a suministro centralizado de agua), Alcantarillado (% de viviendas con acceso a sistema centralizado de alcantarillado), Nativo (% de población nativa población) y Región (la región natural). Cabe señalar que, según numerosos estudios de investigación, el acceso al agua, el saneamiento e infraestructura juegan un papel importante en la predicción de la pobreza [Martínez and Fernández \(2009\)](#); [Sikov and Cerda-Hernández \(2023\)](#).

2.4. Muestra

Para nuestra investigación utilizamos los datos de la ENAHO 2019 y 2023, cuyo objetivo es generar indicadores que permitan conocer la evolución de la pobreza, del bienestar y de las condiciones de vida de los hogares en el Perú. La ENAHO es una encuesta probabilística cuyas unidades de muestreo son los hogares, obtenidos mediante un diseño muestral de dos etapas, donde en la primera etapa se seleccionó

una muestra de localidades y en la segunda etapa se eligió una muestra de viviendas dentro de cada una de las localidades previamente seleccionadas (INEI, 2008). Esta encuesta identifica un hogar como un grupo de personas que viven en la misma vivienda y comparten el mismo presupuesto para gastos de alimentación y otros. De esta encuesta obtenemos estimaciones directas del porcentaje de hogares que viven en pobreza, para cada distrito muestreado.

Como se ha señalado previamente, las estimaciones directas derivadas de las encuestas nacionales presentan una baja confiabilidad a nivel distrital. Esta limitación se debe a la escasez de observaciones, con casi el 50 % de los distritos muestreados conteniendo menos de 10 observaciones. En consecuencia, el objetivo primordial de esta investigación es evaluar la ganancia en precisión obtenida al emplear modelos estadísticos avanzados. Específicamente, nos enfocamos en dos aspectos cruciales: primero, la selección óptima del criterio de vecindad, utilizando la metodología propuesta por Sikov and Cerda-Hernández (2023); y segundo, la comparación del Error Cuadrático Medio (MSE) y el coeficiente de variación del predictor SEBLUP1, definido en (7), derivado del modelo espacial de Fay-Herriot adaptado al contexto peruano Sikov and Cerda-Hernández (2024).

2.5. Análisis estadístico

Para la elaboración de mapas del porcentaje de hogares en situación de pobreza a nivel distrital, se implementó el modelo espacial de Fay-Herriot descrito en la Ecuación (1) del Anexo A. La estimación del porcentaje de hogares en pobreza a nivel distrital se realizó mediante el estimador SEBLUP1, definido en (7). La precisión de este estimador fue rigurosamente evaluada en Sikov and Cerda-Hernández (2024). El modelo espacial, especificado en (1), captura la heterogeneidad socioeconómica y regional de la pobreza distrital, así como la correlación espacial entre los distritos (Gonzales de Olarte, 1997; Sikov and Cerda-Hernández, 2024). La implementación efectiva de este modelo requirió la aplicación de la definición de vecindad propuesta por Sikov and Cerda-Hernández (2023). Los detalles del modelo estadístico empleado se encuentran en el Anexo A.

Posteriormente, se calculó el Error Cuadrático Medio (MSE) del estimador SEBLUP1, definido en (9). La estimación del MSE se realizó mediante las técnicas de bootstrap paramétrico y no paramétrico, siguiendo la metodología desarrollada por Molina et al. (2009).

3. Resultados y Consideraciones

3.1. Panorama nacional

A nivel nacional, los resultados de la aplicación del modelo (1) a los datos de la ENAHO revelan un panorama preocupante, con un aumento significativo de la pobreza en el año 2023 y con cifras aún muy por encima de las cifras observadas el 2019

(pre pandemia). Nuestro estudio muestra que la mayor concentración de pobreza se encuentra en las zonas rurales del Perú, específicamente en la sierra y la selva (ver Figura 2). En estas regiones, muchos distritos experimentan niveles de pobreza que superan considerablemente las cifras observadas en 2019. Este incremento se asocia a diversos factores, entre los que podrían incluirse la falta de oportunidades laborales, el limitado acceso a servicios básicos, la infraestructura deficiente y el impacto de la pandemia del Covid-19.

Un aspecto alarmante de los resultados, que se puede observar en la Figura 2, es el aumento de la pobreza en distritos costeros, donde antes de la pandemia del Covid-19 se observaban niveles relativamente bajos. Esta situación se refleja en el paso de muchos distritos del grupo de pobreza 0-15 % al grupo 15 %-25 %, e incluso a niveles superiores al 25 % en algunos casos. Departamentos como Ica y Arequipa, que en 2019 tenían niveles de pobreza de 2.6 % y 6.0 %, respectivamente, ahora presentan cifras de 6.9 % y 13.9 % para el 2023 INEI (2024).

Nuestro estudio identificó a Loreto, departamento de la selva norte del Perú, como una de las regiones más golpeadas por la pobreza en 2023. Gran parte del departamento presenta niveles de pobreza superiores al 40 %, lo que evidencia una situación crítica que requiere atención urgente. Implícitamente, nuestro análisis también revela un deterioro del ingreso per cápita de los hogares peruanos en el periodo de estudio, lo que se traduce en un mayor porcentaje de hogares viviendo en situación de pobreza para el 2023. Esta disminución del ingreso puede estar relacionada con diversos factores económicos, como la pandemia de COVID-19, el aumento del desempleo y la inflación, impactando en el poder adquisitivo de las familias.

Nuestra investigación construye mapas a un nivel más desagregado (nivel distrital) para ilustrar la distribución espacial de la pobreza en los hogares del Perú comparando los niveles del 2023 con los observados en el 2019, antes de la pandemia del COVID-19. Nuestros resultados revelan que, en la mayoría de los distritos, la pobreza aún no ha alcanzado los niveles prepandemia, lo que evidencia un impacto persistente de la crisis en el ingreso de los hogares, ver Figuras de la Sección 4.

- **Departamentos con Niveles de Pobreza Superiores al 2019:** Nuestro análisis espacial identifica un grupo significativo de departamentos donde la pobreza a nivel distrital ha experimentado un aumento considerable en comparación con 2019. Entre estos se encuentran: Ancash, Arequipa, Cajamarca, Huancavelica, Huánuco, Ica, Junín, La Libertad, Lambayeque, Callao, Lima, Loreto, Madre de Dios, Moquegua, Pasco, Piura, Puno, Tacna, Tumbes, Ucayali. El incremento de la pobreza en estos departamentos resalta la necesidad de implementar estrategias o políticas focalizadas para abordar las causas subyacentes de la situación y promover la recuperación económica en estas regiones.
- **Departamentos con Niveles de Pobreza Inferiores al 2019:** En contraste con el panorama general, cuatro departamentos presentan niveles de pobreza inferiores a los observados en 2019: Amazonas, Apurímac, Cusco, San

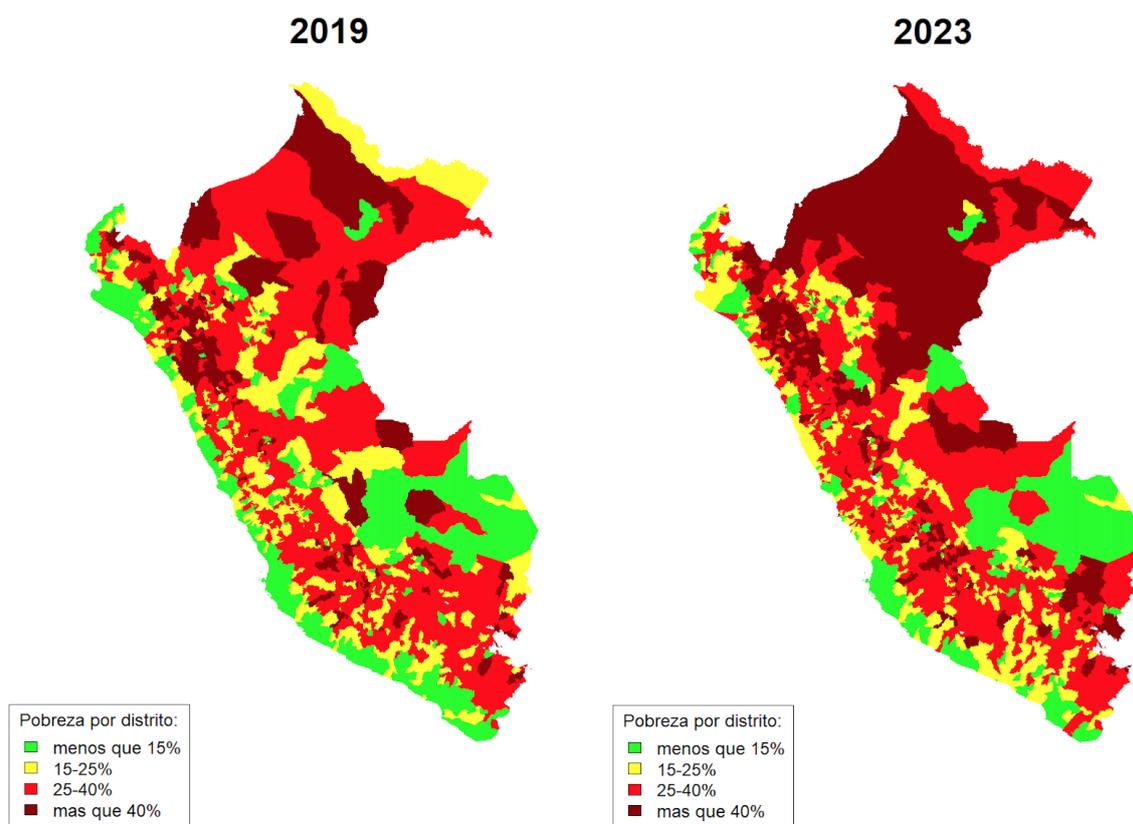


Figura 2. Mapa de porcentaje de hogares que viven en pobreza en el Perú. Comparación entre el 2019 y el 2023.

Martín. Es crucial analizar las características y políticas implementadas en estos departamentos para comprender los factores que han contribuido a un mejor desempeño en la lucha contra la pobreza.

- **Mismo Nivel de Pobreza que en 2019:** El departamento de Ayacucho presenta un caso particular, donde la tasa de pobreza y su patron de comportamiento espacial en 2023 (39.4 %) se mantiene estadísticamente igual que en el 2019. Esta situación requiere un análisis más profundo para identificar los posibles factores que han impedido un avance en la reducción de la pobreza en esta región.

Los mapas presentados en este estudio ofrecen una valiosa herramienta para comprender la distribución espacial de la pobreza en el Perú y el impacto persistente de la pandemia. La identificación de departamentos con mayor aumento o disminución de la pobreza permite orientar esfuerzos y recursos de manera más efectiva hacia las regiones que más lo necesitan.

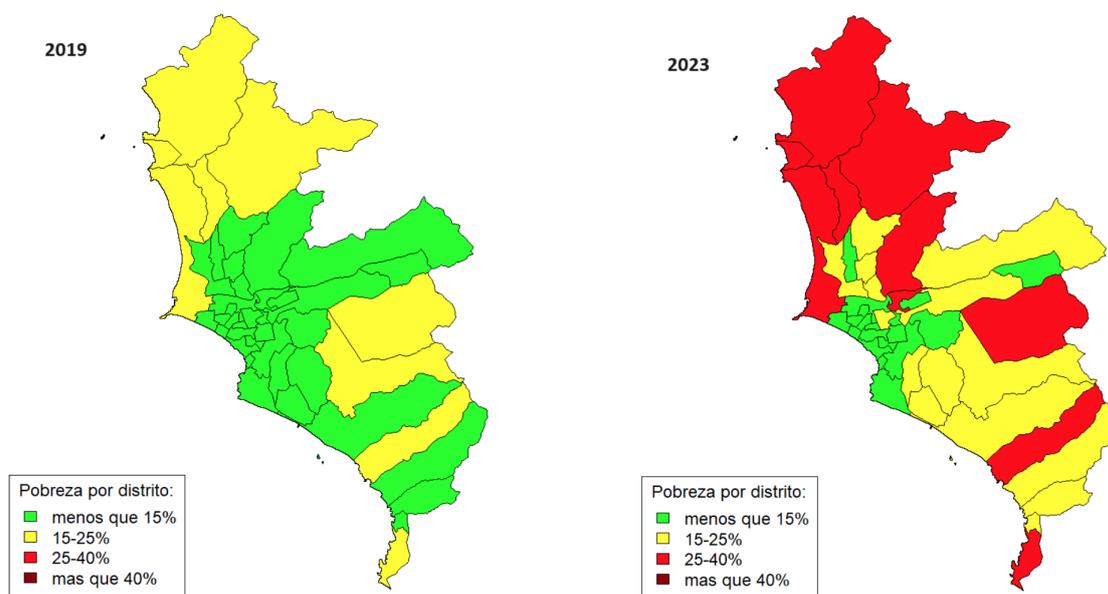


Figura 3. Mapa de porcentaje de hogares que viven en pobreza en Lima Metropolitana. Este mapa muestra el deterioro de los hogares en términos monetarios.

3.2. Pobreza urbana

Otro hallazgo importante obtenido en este trabajo es el aumento del porcentaje de hogares que viven en pobreza en Lima Metropolitana. La Figura 3 muestra claramente el deterioro de los hogares de la mayor zona metropolitana en términos monetarios, llevando muchos distritos de la ciudad a tener niveles de pobreza entre 25 y 40 % para el 2023. Usando los datos de la ENAHO 2019 y el modelo (1), el porcentaje de hogares que vivían en pobreza antes de la pandemia no excedían el 25 %. Sin embargo, los resultados de la aplicación del modelo (1) a los datos de la ENAHO 2023 muestra que los distritos de la zona sur y norte de Lima Metropolitana son los que más impacto han recibido de la pandemia del Covid-19, siendo esta última zona la más golpeada. Por ejemplo, San Juan de Lurigancho antes de la pandemia tenía un nivel de pobreza menor al 14.2 %, sin embargo, para el 2023 aproximadamente el 32.4 % de los hogares vivió en pobreza en el mencionado distrito (ver Figura 3). Según la ENAHO la pobreza urbana ha aumentado en 11.8 % desde el 2019 (INEI, 2024), llegando a 26.4 % en el 2023, siendo la costa la región más afectada. Nuestro análisis espacial y construcción de mapas a nivel distrital muestran claramente este fenómeno a nivel distrital (ver Figura 2).

Los mapas construidos en este trabajo revelan que la pandemia ha tenido un impacto desigual en las diferentes zonas de Lima Metropolitana (ver Figura 3) y de otras zonas urbanas del país (ver Figura 2), permitiendo visualizar claramente el deterioro de la situación económica de los hogares. En el caso de Lima, la distribución espacial de los hogares pobres muestra una concentración más alta en las zonas sur y norte, confirmando el impacto desproporcionado de la pandemia en estas áreas. El

aumento de la pobreza en Lima Metropolitana y las zonas urbanas puede atribuirse a diversos factores relacionados con la pandemia y el bajo crecimiento del país en los últimos años, como:

1. **Pérdida de Empleo:** Las restricciones y el cierre de negocios durante la pandemia provocaron una ola de desempleo, especialmente en sectores informales y de bajos ingresos, que son prevalentes en las zonas sur y norte de Lima, y en las zonas urbanas del país.
2. **Disminución de Ingresos:** La reducción de la jornada laboral, el trabajo remoto no remunerado y la suspensión de actividades económicas generaron una disminución significativa en los ingresos de los hogares, impactando directamente en su capacidad para cubrir necesidades básicas.
3. **Dificultades de Acceso a Servicios:** La pandemia también dificultó el acceso a servicios básicos como educación, salud y alimentación, especialmente para los hogares más vulnerables en las zonas marginadas de la ciudad.

Para combatir eficazmente la pobreza urbana, es fundamental implementar intervenciones que aborden las causas mencionadas y fomenten la recuperación económica.

3.3. Recomendaciones

Los resultados obtenidos en esta investigación ofrecen una imagen preocupante de la situación de pobreza en el Perú durante el año 2023. El aumento significativo de la pobreza en zonas rurales y costeras (ver Figura 2), junto con el deterioro del ingreso per cápita y la situación crítica en regiones como Loreto (ver Figura 19), exigen una respuesta inmediata y efectiva del estado. Es fundamental implementar políticas públicas focalizadas que aborden las causas profundas de la pobreza, promuevan el desarrollo económico en las regiones más afectadas y garanticen el acceso a servicios básicos y oportunidades para todos los peruanos.

A partir del análisis espacial distrital de la pobreza para identificar zonas con mayor concentración de pobreza y sus características específicas, se sugieren las siguientes recomendaciones para abordar esta problemática en el Perú:

1. **Inversión en Zonas Rurales:** Destinar recursos para fortalecer la infraestructura, mejorar el acceso a educación y salud, y promover el desarrollo de actividades económicas en las zonas rurales del país.
2. **Promoción del Desarrollo Económico Local:** Impulsar el desarrollo económico local a través de iniciativas que fomenten la creación de empleo, el emprendimiento y la inversión en las regiones más afectadas por la pobreza.
3. **Diseño de Intervenciones Focalizadas:** Diseñar e implementar intervenciones focalizadas en los departamentos y regiones que han experimentado un mayor aumento de la pobreza, considerando las características y necesidades particulares de cada zona.

4. Generación de Empleo: Implementar programas de capacitación y creación de empleo, especialmente en las regiones más afectadas por la pobreza.
5. Apoyo a Sectores Vulnerables: Brindar asistencia social y programas de inclusión a grupos poblacionales en situación de mayor vulnerabilidad, como mujeres, niños, adultos mayores y personas con discapacidad.
6. Lucha contra la Informalidad: Implementar medidas para reducir la informalidad laboral y garantizar el acceso a la seguridad social para todos los trabajadores.
7. Gestión Eficiente de Recursos Públicos: Asegurar el uso transparente y eficiente de los recursos públicos destinados a programas de lucha contra la pobreza.
8. Lucha contra la corrupción: Implementar medidas drásticas para eliminar funcionarios públicos que comentan actos de corrupción.
9. Monitoreo y Evaluación: Implementar sistemas de monitoreo y evaluación constantes para evaluar el impacto de las políticas públicas y realizar ajustes cuando sea necesario.

La lucha contra la pobreza en el Perú requiere un enfoque integral y multisectorial que combine acciones a nivel nacional, regional y local. El análisis espacial de la pobreza, como el presentado en este trabajo, puede ser una herramienta valiosa para guiar la toma de decisiones y la asignación de recursos de manera más eficiente, contribuyendo a construir un Perú más justo y equitativo para todos.

Finalmente, es necesario un análisis distrital no solo desde la perspectiva monetaria, sino también multidimensional, como la propuesta recientemente en [Arias-Salazar et al. \(2025\)](#), para obtener más evidencia, más innovación, y más herramientas de política social pertinentes para cada contexto. Este abordaje será realizado en investigaciones futuras.

4. Mapas del porcentaje de hogares que viven en pobreza a nivel distrital: Un Análisis Comparativo (2019-2023)

Amazonas

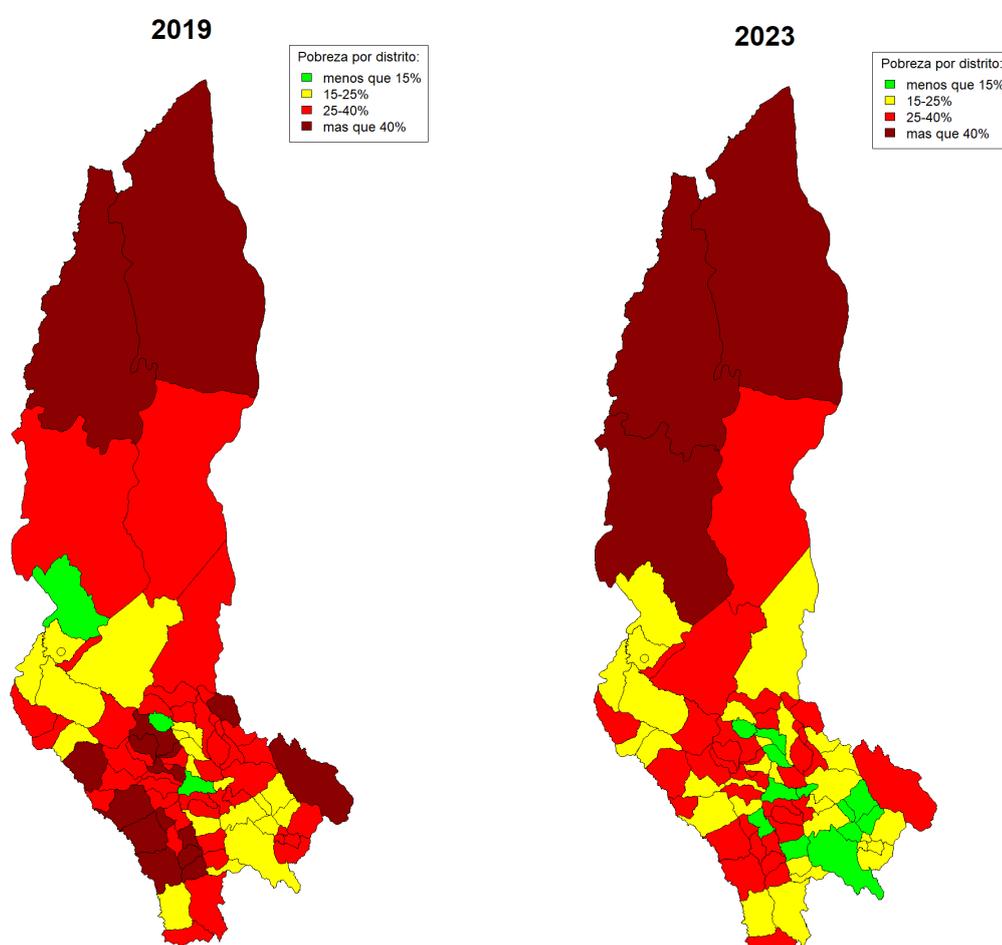


Figura 4. Mapa comparativo de la incidencia de la pobreza monetaria distrital en la región Amazonas: años 2019 y 2023

Ancash

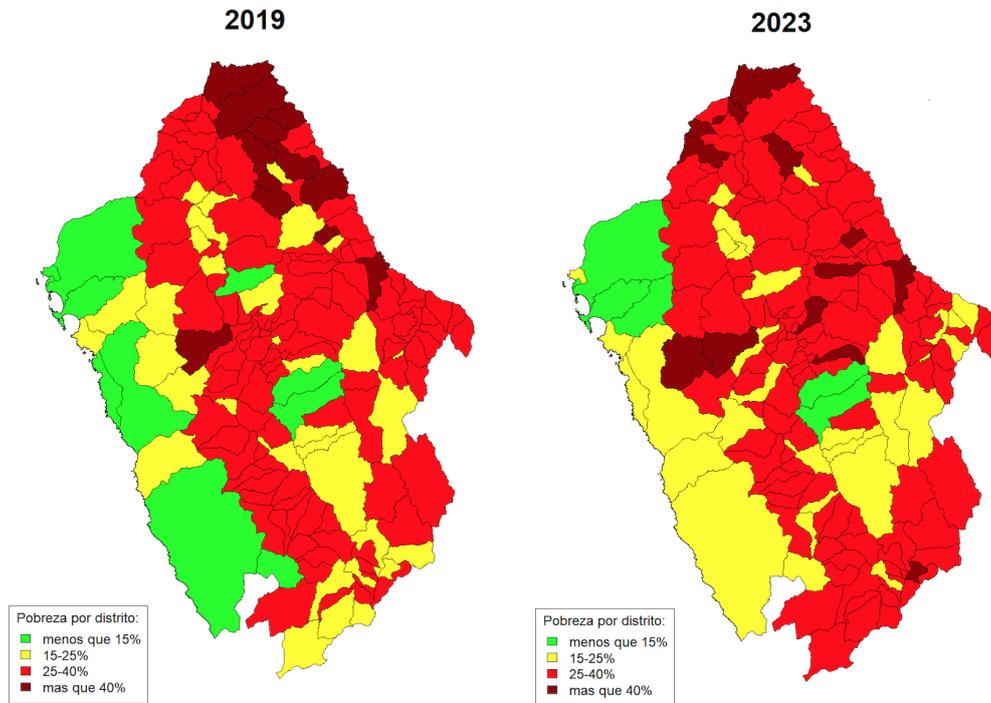


Figura 5. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Ancash: años 2019 y 2023.

Apurimac

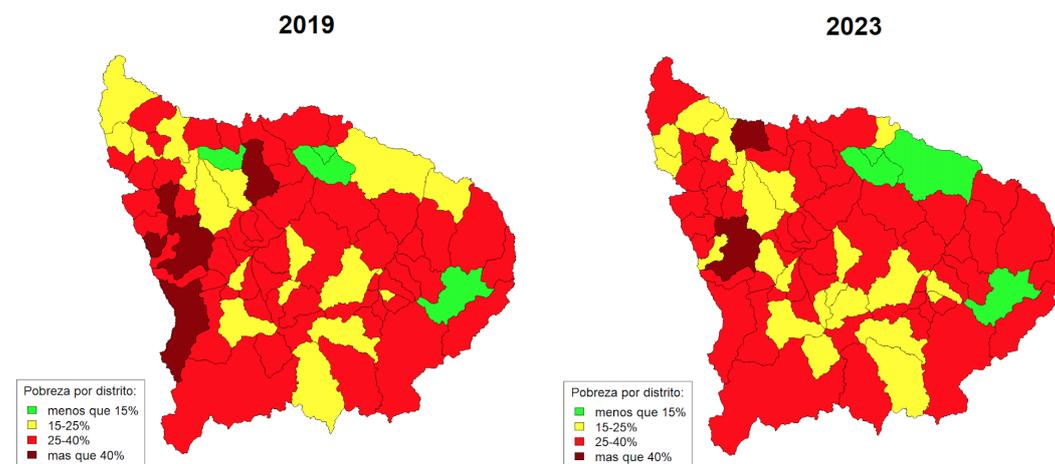


Figura 6. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Apurimac: años 2019 y 2023.

Arequipa

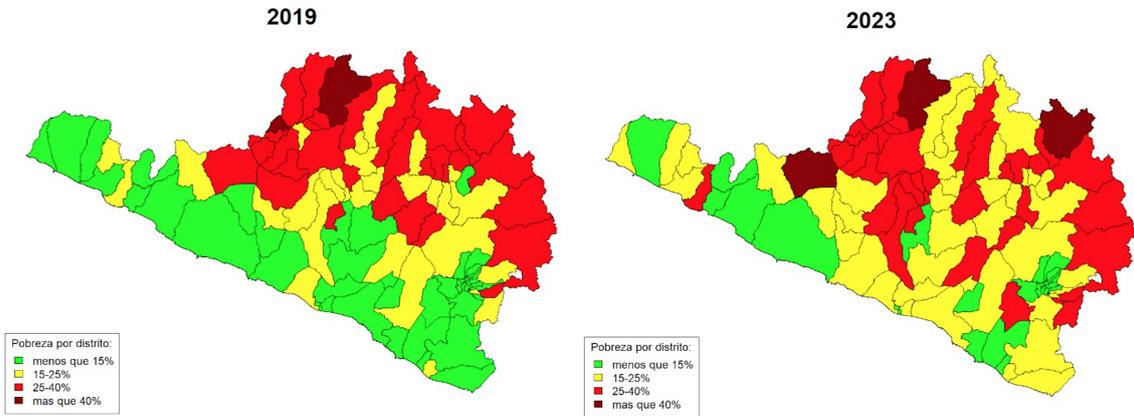


Figura 7. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Arequipa: años 2019 y 2023.

Ayacucho

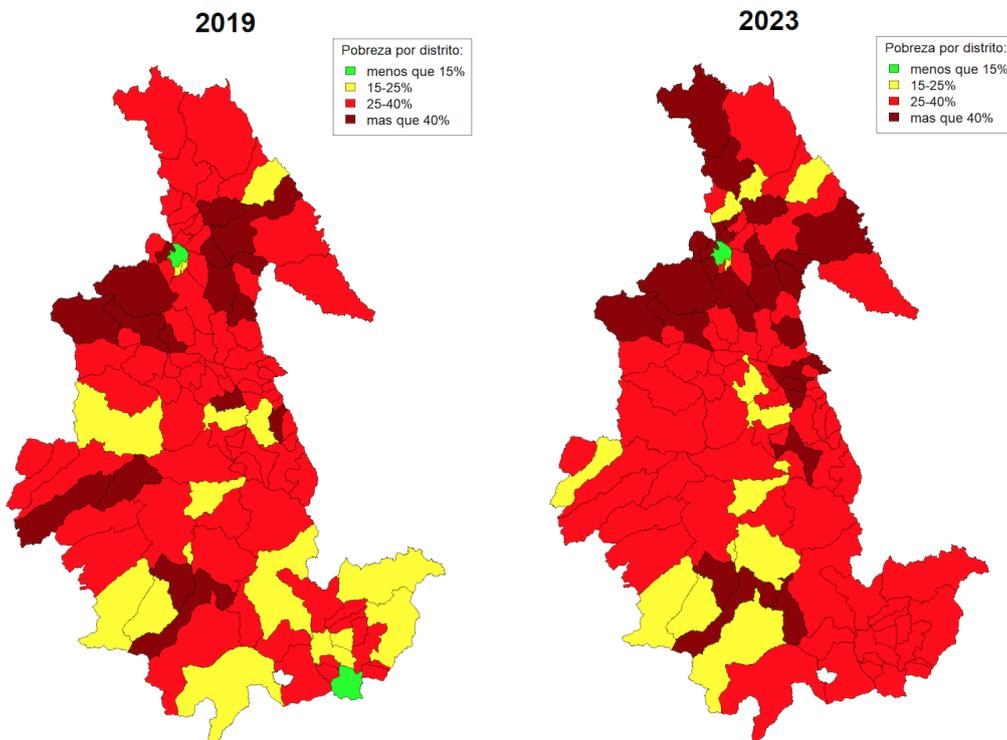


Figura 8. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Ayacucho: años 2019 y 2023.

Cajamarca

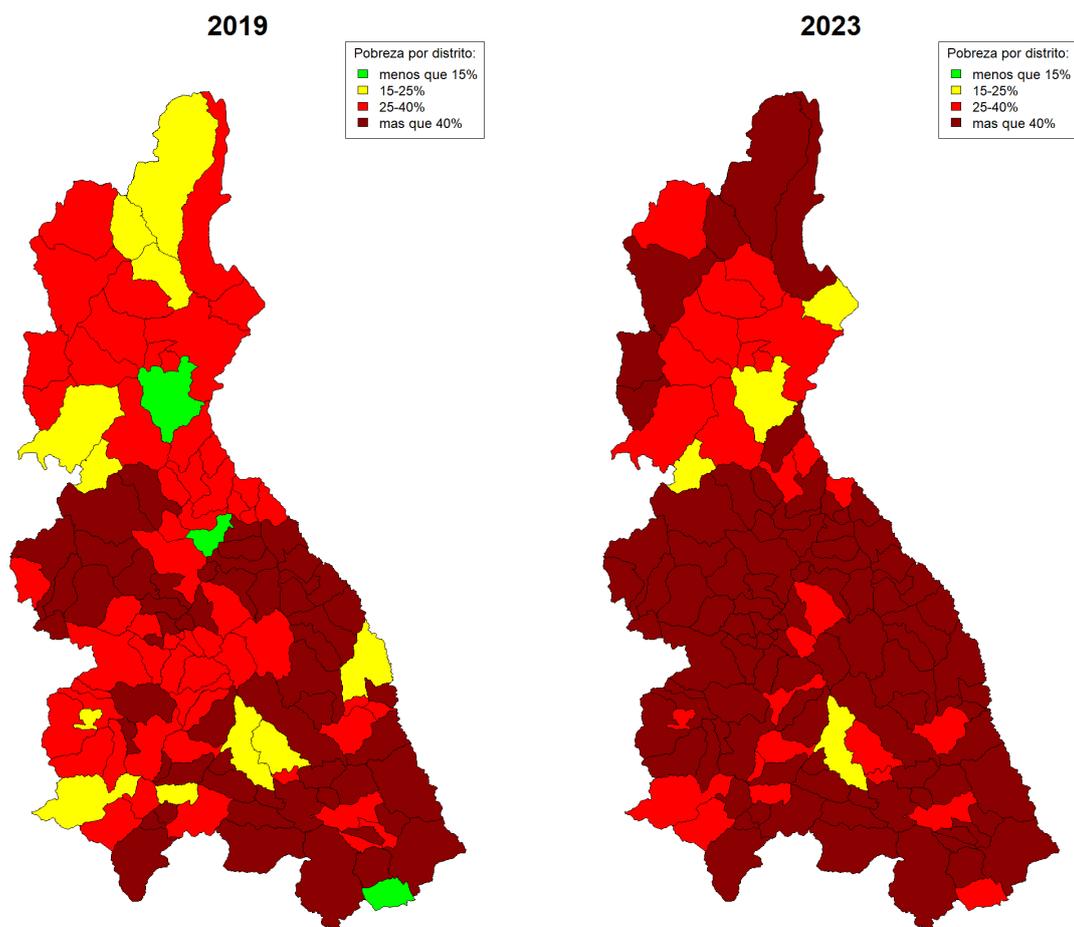


Figura 9. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Cajamarca: años 2019 y 2023.

Cusco

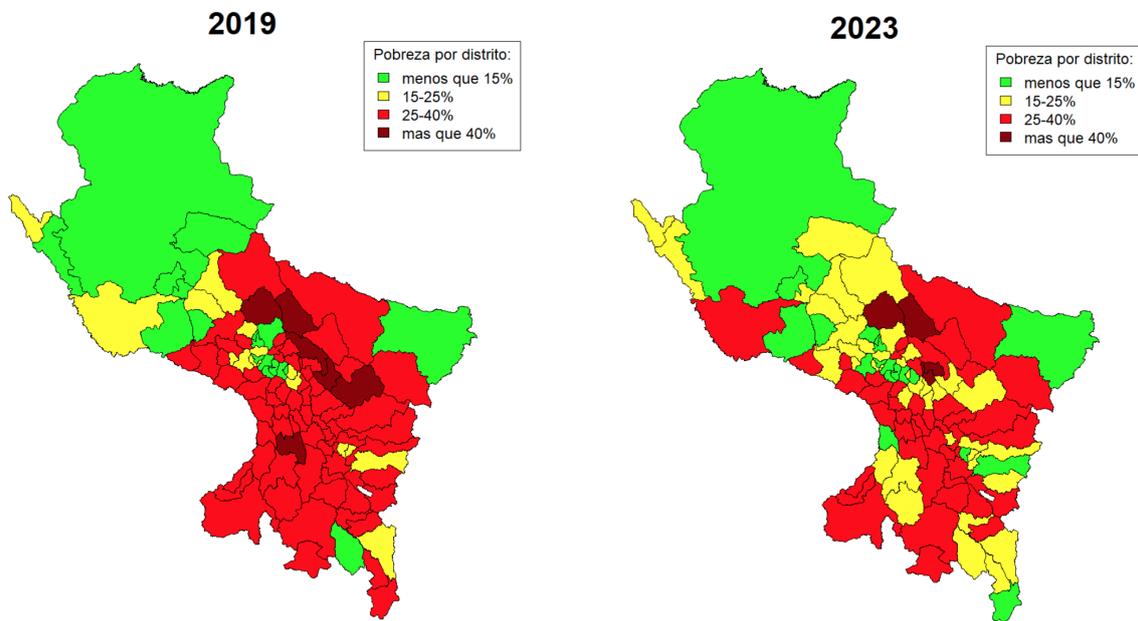


Figura 10. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Cusco: años 2019 y 2023.

Huancavelica

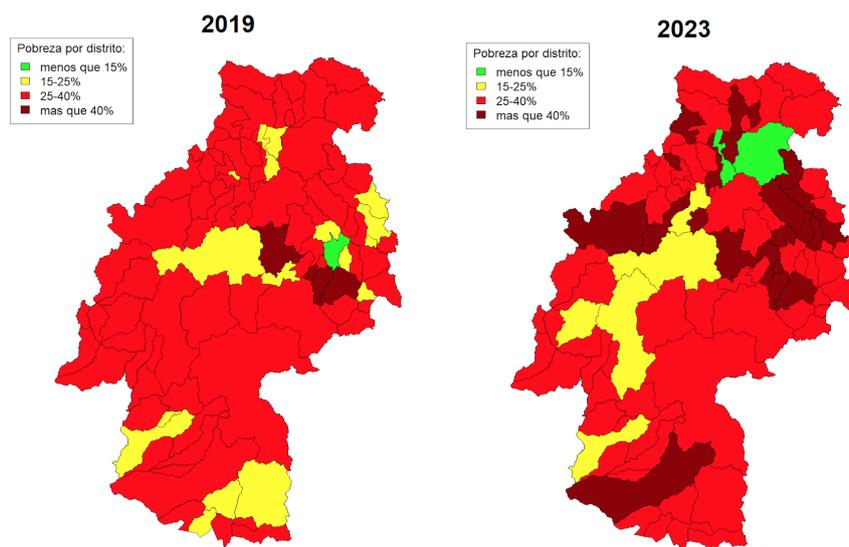


Figura 11. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Huancavelica: años 2019 y 2023.

Huánuco

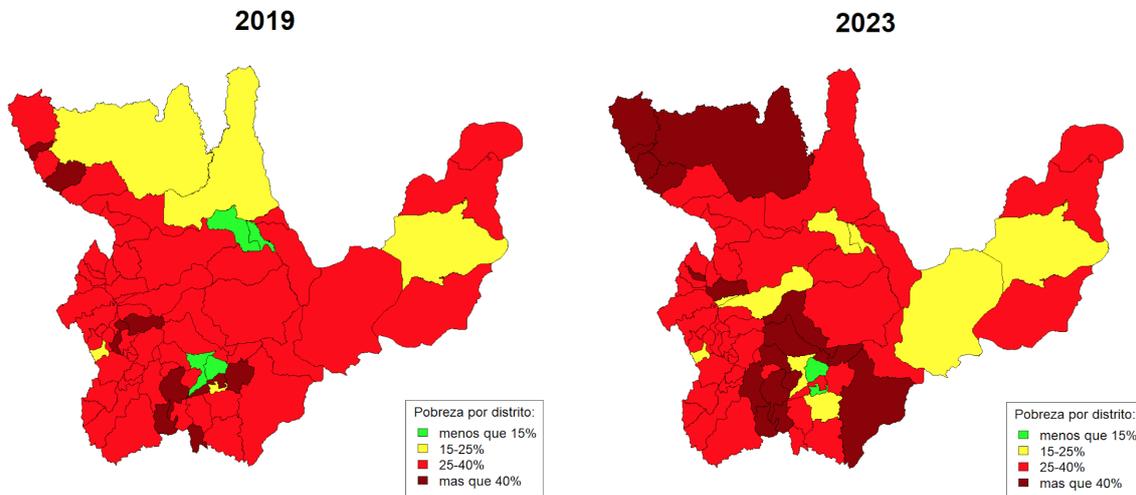


Figura 12. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Huánuco: años 2019 y 2023.

Ica

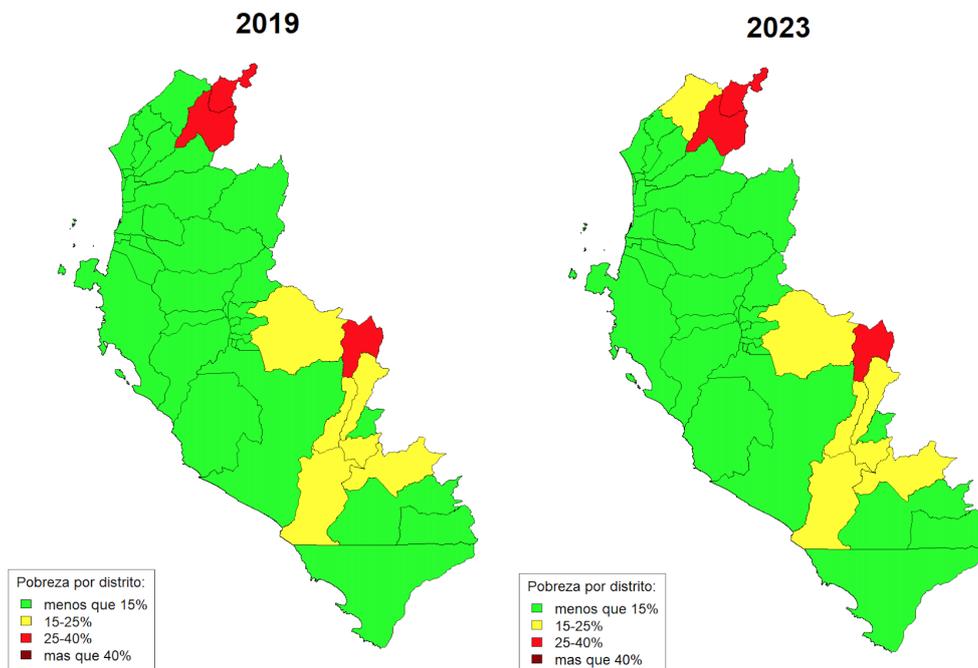


Figura 13. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Ica: años 2019 y 2023.

Junín

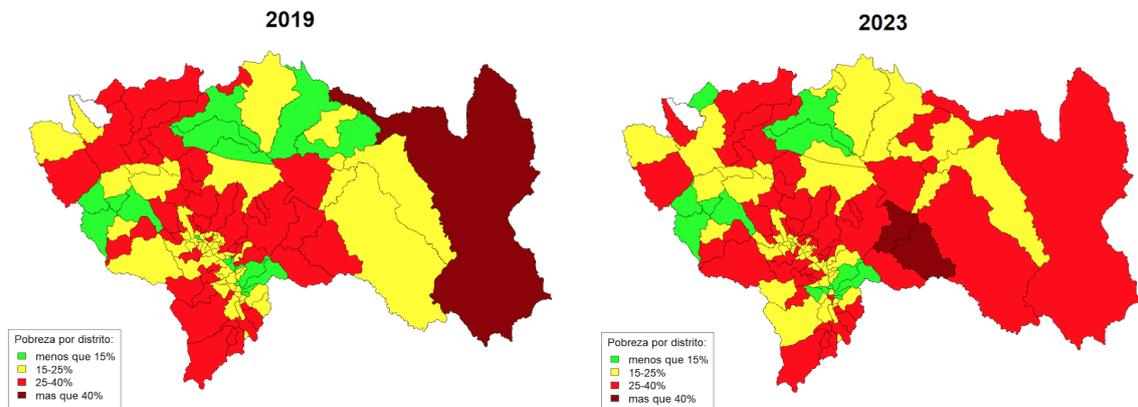


Figura 14. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Junín: años 2019 y 2023.

La Libertad

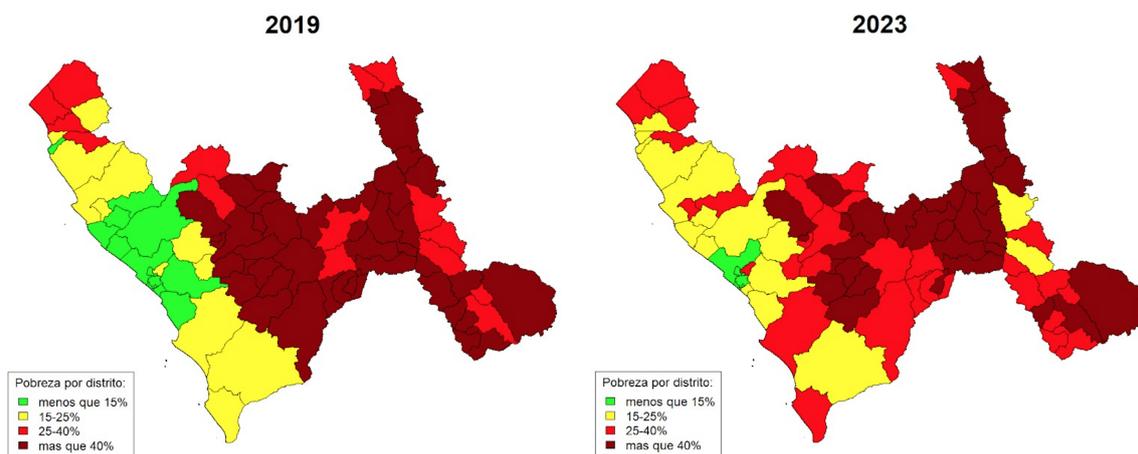


Figura 15. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de La Libertad: años 2019 y 2023.

Lambayeque

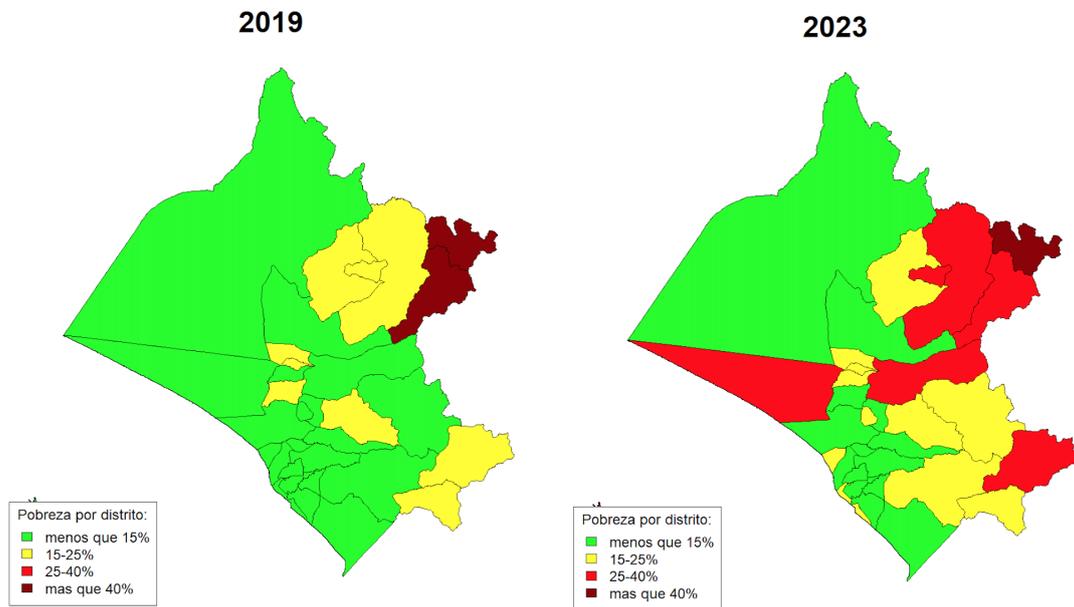


Figura 16. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Lambayeque: años 2019 y 2023.

Lima Metropolitana

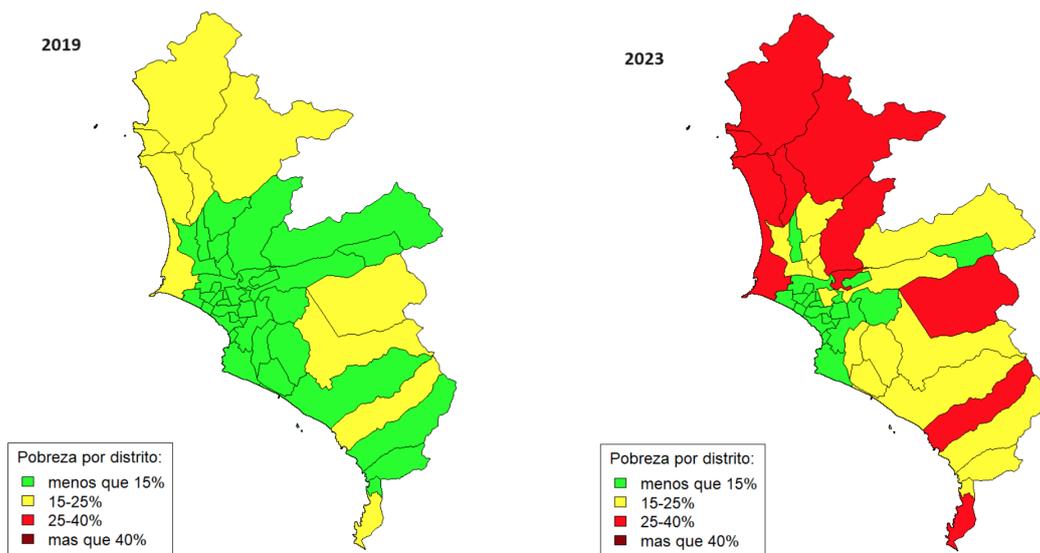


Figura 17. Mapa comparativo de la incidencia de la pobreza monetaria distrital en Lima Metropolitana: años 2019 y 2023.

Lima Provincias

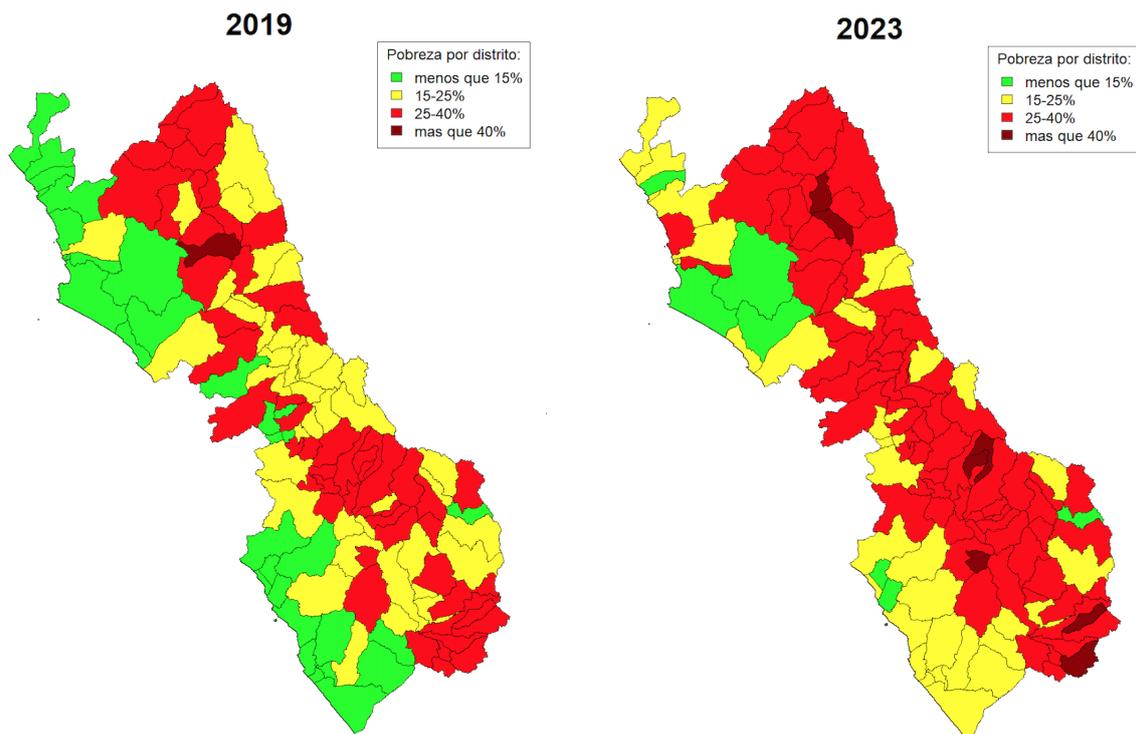


Figura 18. Mapa comparativo de la incidencia de la pobreza monetaria distrital en Lima Provincias: años 2019 y 2023.

Loreto

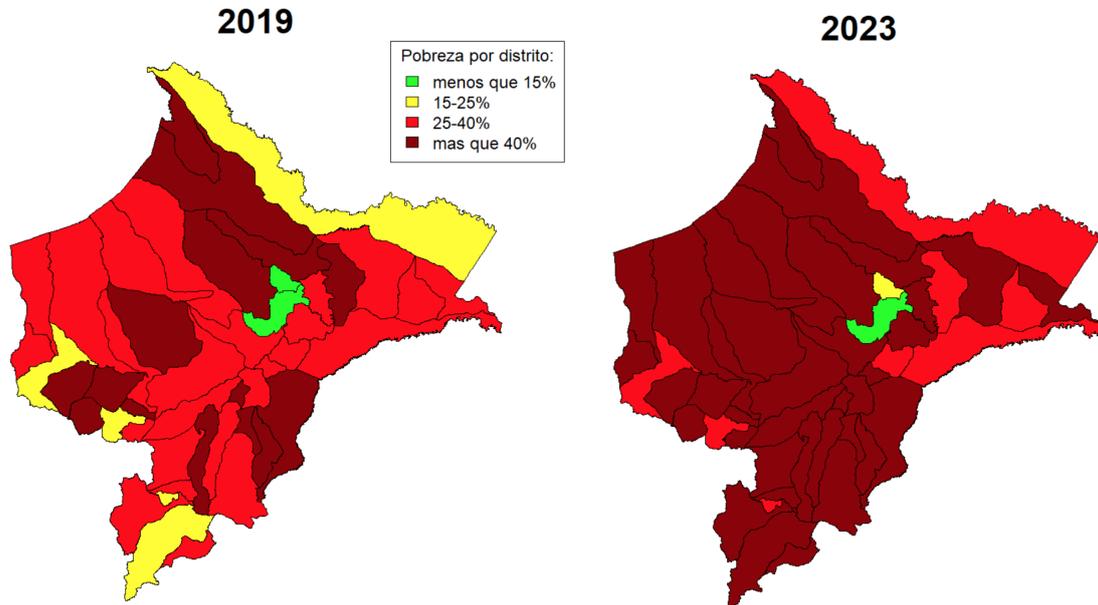


Figura 19. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Loreto: años 2019 y 2023.

Madre de Dios

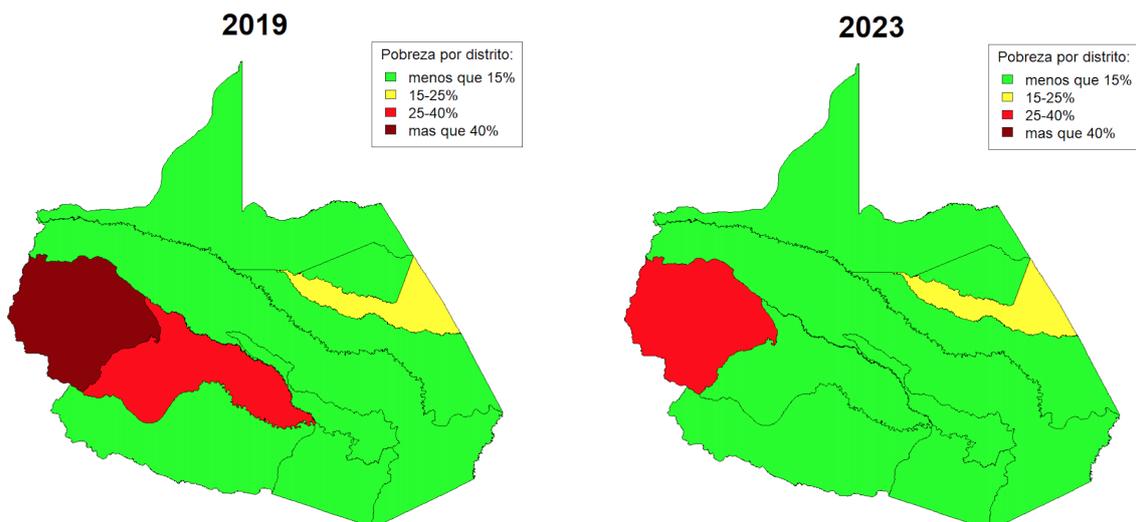


Figura 20. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Madre de Dios: años 2019 y 2023.

Moquegua

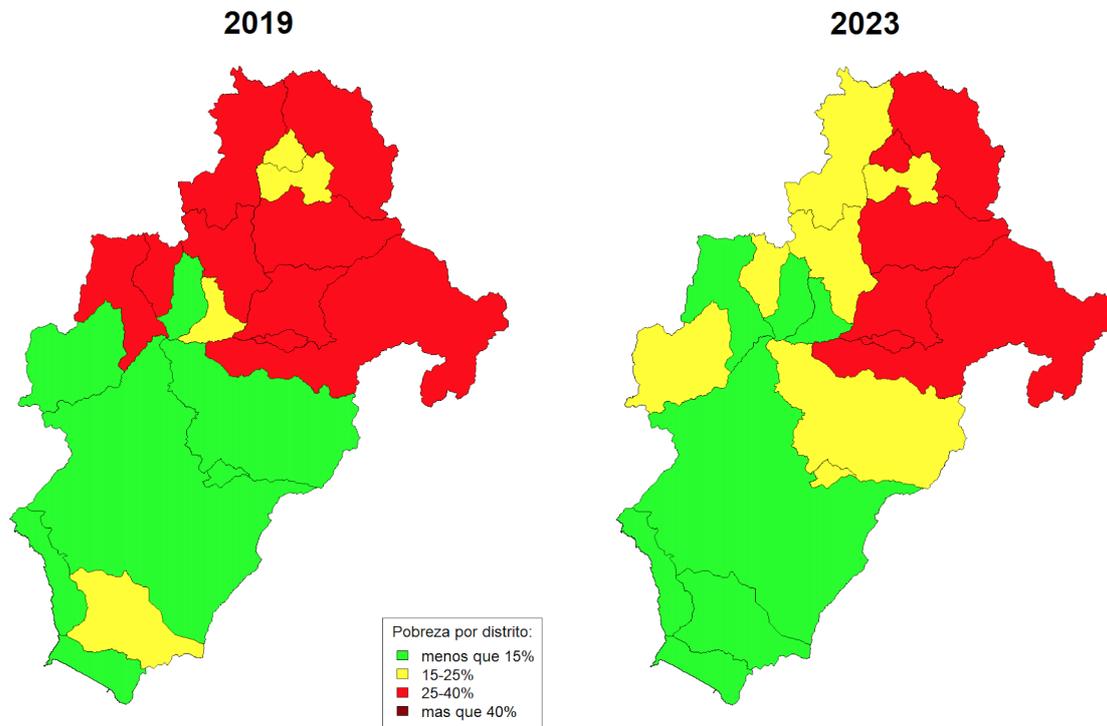


Figura 21. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Moquegua: años 2019 y 2023.

Pasco

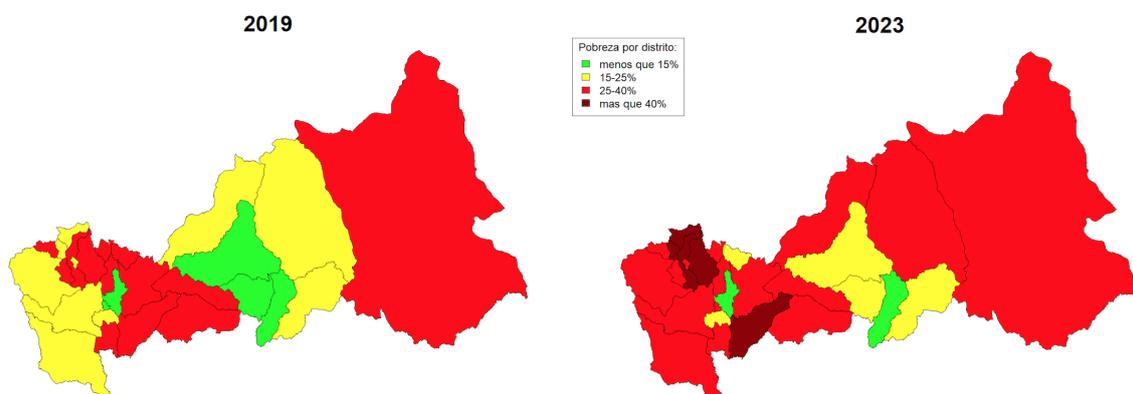


Figura 22. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Pasco: años 2019 y 2023.

Piura

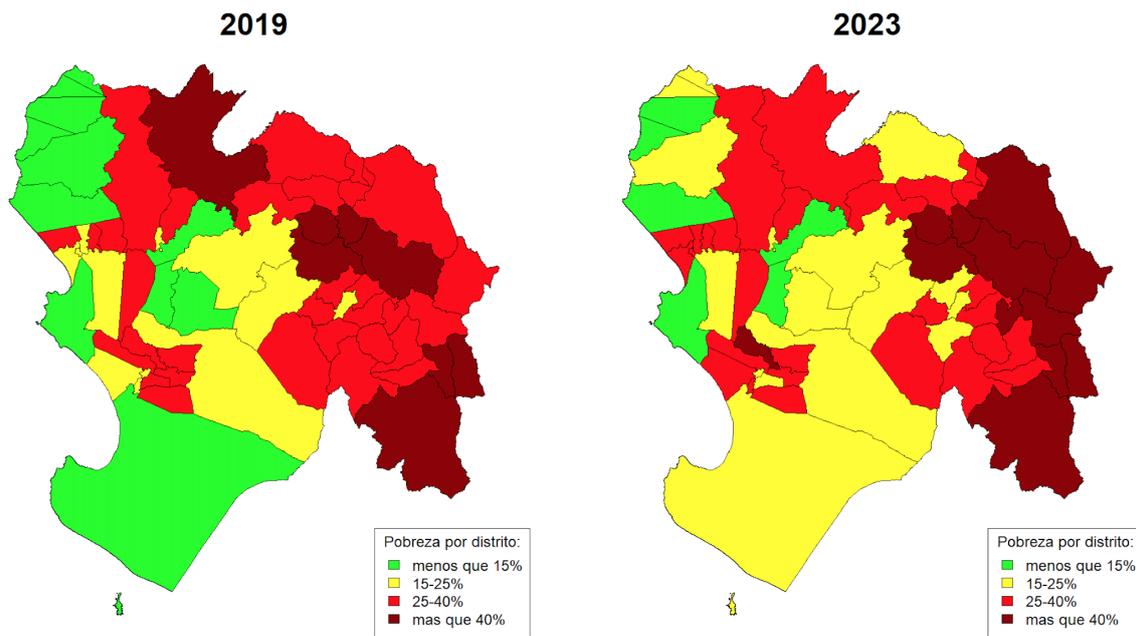


Figura 23. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Piura: años 2019 y 2023.

Puno

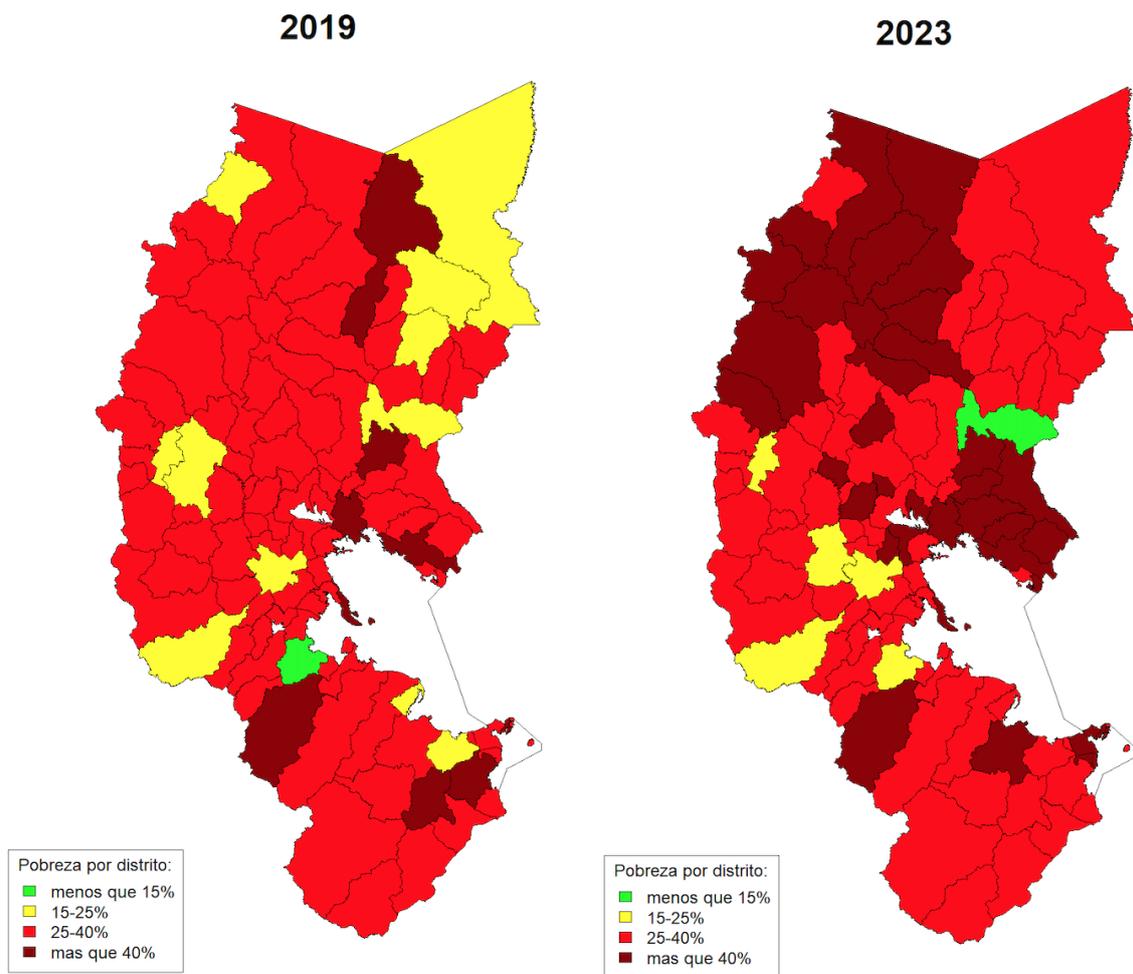


Figura 24. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Puno: años 2019 y 2023.

San Martín

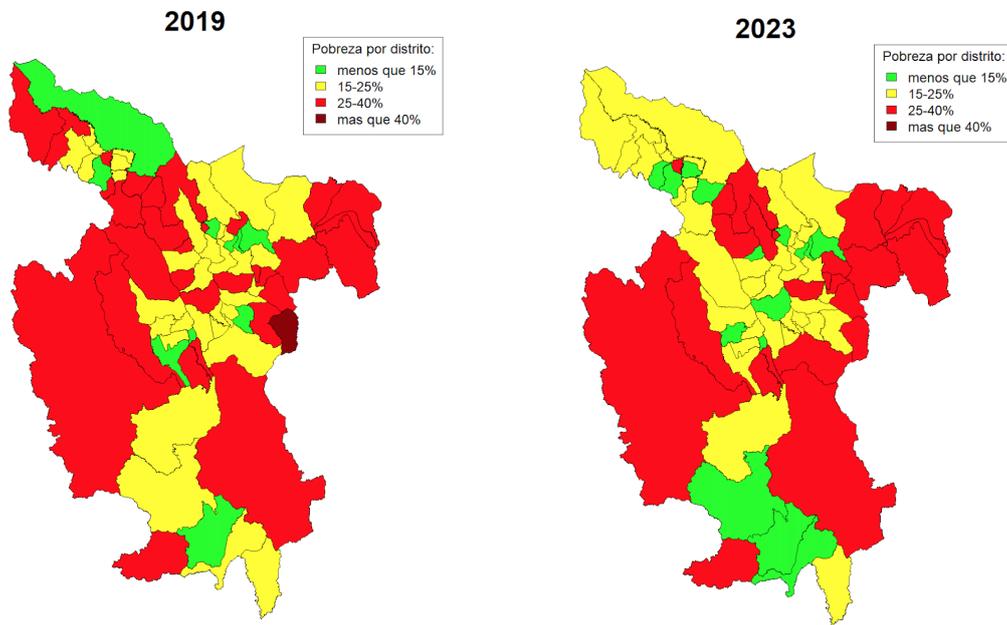


Figura 25. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de San Martín: años 2019 y 2023.

Tacna

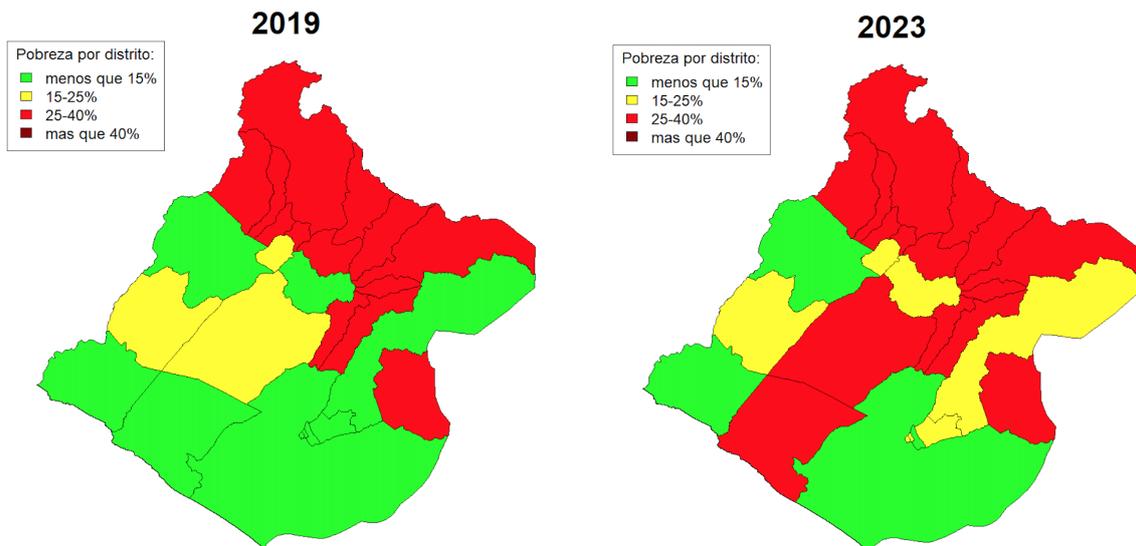


Figura 26. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Tacna: años 2019 y 2023.

Tumbes

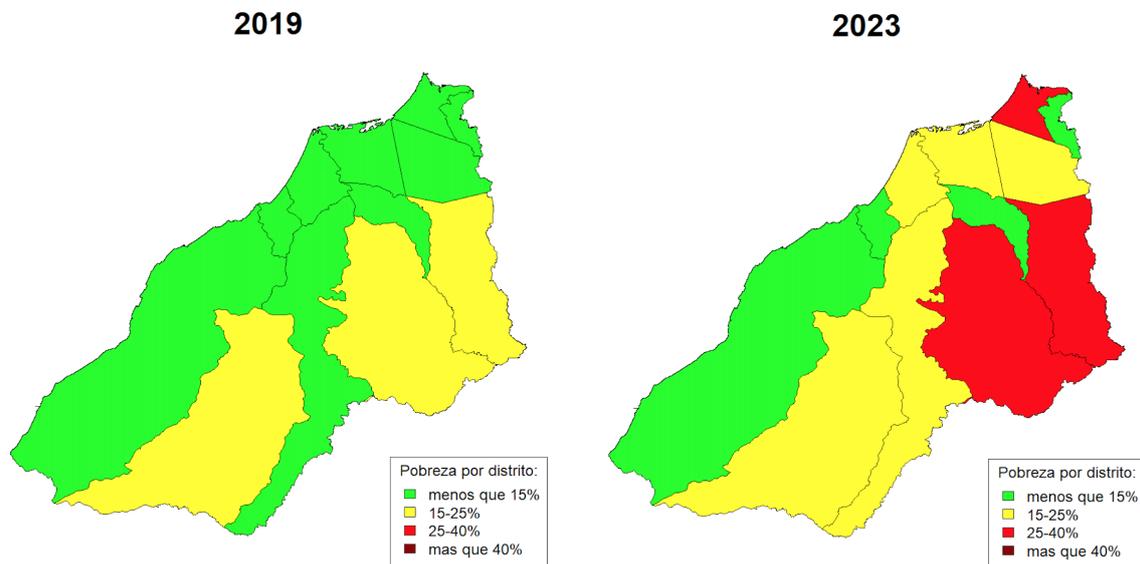


Figura 27. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Tumbes: años 2019 y 2023.

Ucayali

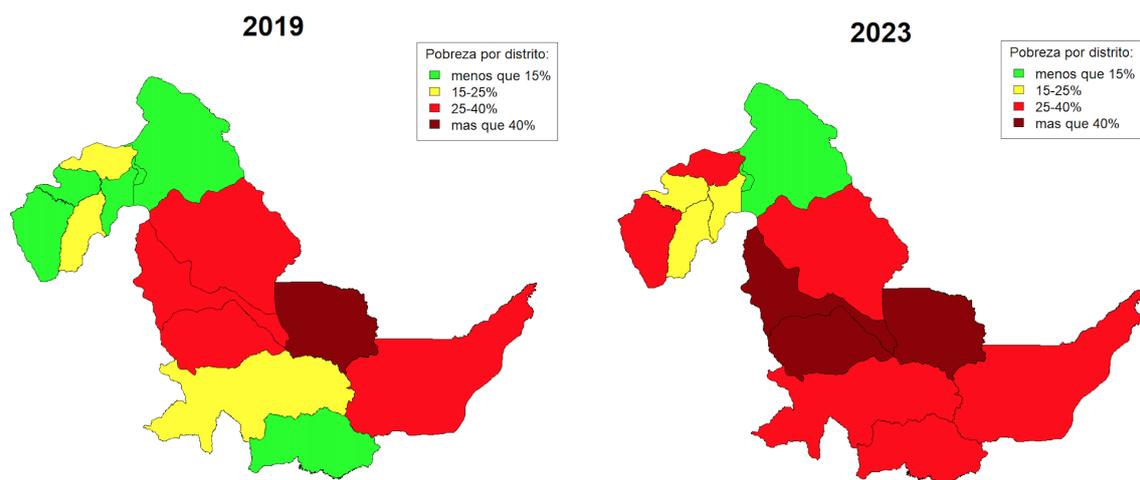


Figura 28. Mapa comparativo de la incidencia de la pobreza monetaria distrital en el Departamento de Ucayali: años 2019 y 2023.

A. Análisis espacial de la pobreza: Estimación en Áreas Pequeñas

La metodología detallada en este anexo, desarrollada y validada exhaustivamente en [Sikov and Cerda-Hernández \(2024\)](#), se fundamenta en la aplicación del modelo espacial de Fay-Herriot, adaptado específicamente para el contexto peruano. Con el fin de demostrar la solidez y el rendimiento superior del modelo, los autores llevaron a cabo un riguroso análisis empírico mediante simulaciones de Monte Carlo. Este enfoque permitió no solo estudiar la sensibilidad del modelo ante variaciones en los parámetros, sino también evaluar su capacidad para capturar las complejidades inherentes a los datos socioeconómicos del Perú.

Adicionalmente, se calcularon diversas métricas de precisión y eficiencia, tales como el Error Cuadrático Medio (MSE), el coeficiente de variación y la cobertura de los intervalos de confianza. Estos indicadores, validados a través de técnicas de bootstrap paramétrico y no paramétrico, proporcionaron evidencia sólida del buen comportamiento y desempeño de los estimadores del modelo, especialmente en el contexto de la heterogeneidad y la escasez de datos que caracterizan a las encuestas peruanas. La validación empírica y la evaluación exhaustiva de métricas de precisión aseguran la confiabilidad de las estimaciones generadas por el modelo, lo cual es crucial para la toma de decisiones informadas en la formulación de políticas públicas.

En lo que sigue de esta sección presentamos el modelo que usaremos con suficiente detalle, que es una modificación del modelo espacial de Fay-Herriot ([Pratesi and Salvati, 2008](#); [Molina et al., 2009](#)), como un intento de manejar situaciones en las que un porcentaje considerable de áreas (distritos) no están incluidas en la muestra, situación típica en los datos presentados en las encuestas nacionales en el Perú.

Supongamos que cada área (distrito) pertenece a una de P divisiones administrativas más grandes (provincias), y denotamos por N_i y D_i , $i = 1, \dots, P$ el número total de distritos que componen la i -ésima provincia y el número correspondiente de distritos muestreados de N_i , donde $D_i > 0$, $\forall i$.

Sea Y_{ij} la estimación directa de la característica de interés θ_{ij} , asociada con el j -ésimo distrito que pertenece a la i -ésima provincia, y por X_{ij} , e_{ij} , u_{ij} y v_i el vector correspondiente de variables auxiliares, error de muestreo y efectos aleatorios a nivel de distrito y provincia, donde $i = 1, \dots, P$, $j = 1, \dots, D_i$. Denotamos por w_{ij}^* las entradas de la matriz W^* , que establecen la medida de proximidad entre las provincias i y j . Entonces, el modelo propuesto se define como

$$\begin{aligned} Y_{ij} &= \theta_{ij} + e_{ij}, \\ \theta_{ij} &= X_{ij}\beta + u_{ij} + v_i, \\ v_i &= \rho \sum_{j=1}^P w_{ij}^* v_j + \eta_i \end{aligned} \tag{1}$$

donde $e_{ij} \sim N(0, \sigma_e^2)$, $u_{ij} \sim N(0, \sigma_u^2)$ and $\eta_i \sim \sigma_\eta^2$. Suponemos que los términos de error e_{ij} y η_i son mutuamente independientes e independientes de los efectos aleatorios u_{ij} y v_i . Aunque según el modelo propuesto, los efectos aleatorios a nivel de distrito no están correlacionados espacialmente, las características de interés a nivel de distrito sí lo están, debido a correlaciones espaciales entre las provincias. Además, el modelo implica que las características de interés de dos distritos, pertenecientes a provincias distintas, también pueden correlacionarse, de modo que la magnitud de esta correlación depende de la proximidad entre las provincias correspondientes.

Ahora, denotamos por $Y_{(i)}$ el vector de estimaciones directas, asociado con los distritos muestreados pertenecientes a la i -ésima provincia, y por $X_{(i)}$, $e_{(i)}$, $u_{(i)}$ y $v_{(i)}$ la matriz correspondiente de variables auxiliares, vector de errores de muestreo, vector de efectos aleatorios a nivel de distrito y vector de efectos aleatorios a nivel de provincia. Sea además $Y = (Y_{(1)}^t, \dots, Y_{(P)}^t)^t$, $X = (X_{(1)}^t, \dots, X_{(P)}^t)^t$, $e = (e_{(1)}^t, \dots, e_{(P)}^t)^t$, $u = (u_{(1)}^t, \dots, u_{(P)}^t)^t$ y $v = (v_1, \dots, v_P)^t$. Entonces, el modelo propuesto se puede definir alternativamente de la siguiente manera:

$$\begin{aligned} Y &= X\beta + u + Zv + e, \\ v &= \rho Wv + \eta \end{aligned} \quad (2)$$

donde $u \sim N(0, \sigma_u I_D)$, $e \sim N(0, \Sigma_e)$, $\eta \sim N(0, \sigma_\eta I_D)$ y Z es una matriz cero-uno de dimensión $D \times P$, donde $\{Z\}_{ij} = 1$ si el i -ésimo distrito pertenece a la j -ésima provincia, y 0 en caso contrario.

De (2) obtenemos que

$$Y = X\beta + \zeta, \quad \zeta \sim N(0, H) \quad (3)$$

tal que

$$\zeta = u + Z(I - \rho W)^{-1}\eta + e,$$

y

$$\begin{aligned} H &= Z[(I - \rho W)^t(I - \rho W)]^{-1}Z^t\sigma_\eta^2 + \sigma_u^2 I_D + \Sigma_e \\ &= Z\Omega^*Z^t + \sigma_u^2 I_D + \Sigma_e \end{aligned}$$

donde $\Omega^* = [(I - \rho W)^t(I - \rho W)]^{-1}\sigma_\eta^2$.

Como en el caso del modelo espacial de Fay-Herriot [Pratesi and Salvati \(2008\)](#); [Molina et al. \(2009\)](#), β puede estimarse utilizando la estimación de mínimos cuadrados generalizados (MCG),

$$\hat{\beta}(\phi^*) = (X^t[H(\phi^*)]^{-1}X)^{-1}X^t[H(\phi^*)]^{-1}Y, \quad (4)$$

donde $\phi^* = (\rho, \sigma_u^2, \sigma_\eta^2)$ es el vector de parámetros desconocidos del modelo. Además, las predicciones para los efectos aleatorios u y v se pueden obtener de la siguiente manera

$$\begin{aligned} \hat{v}(\phi^*) &= E(v | Y) \\ &= \Omega^*(\phi^*)Z^t[H(\phi^*)]^{-1}(Y - X\hat{\beta}(\phi^*)) \end{aligned} \quad (5)$$

y

$$\begin{aligned}\hat{u}(\phi^*) &= E(u | Y) \\ &= \sigma_u^2 [H(\phi^*)]^{-1} \left(Y - X\hat{\beta}(\phi^*) \right)\end{aligned}\quad (6)$$

Para estimar los parámetros desconocidos del modelo ϕ^* se puede aplicar el método de Máxima Verosimilitud (MV) o Máxima Verosimilitud Restringida (REML) (para más detalles ver Pratesi and Salvati (2008); Molina et al. (2009); Sikov and Cerda-Hernández (2024)). Habiendo estimado ϕ^* por $\hat{\phi}^*$ y reemplazado ϕ^* por $\hat{\phi}^*$ en (4), (5) y (6), obtenemos una predicción para la característica verdadera θ_{ij} tanto en los distritos muestreados como en los no muestreados, de la siguiente manera:

$$\hat{\theta}_{ij}^{SEBLUP1}(\hat{\phi}^*) = \begin{cases} X_{ij}\hat{\beta}(\hat{\phi}^*) + \hat{v}_i(\hat{\phi}^*) + \hat{u}_{ij}(\hat{\phi}^*), & j \in S_i \\ X_{ij}\hat{\beta}(\hat{\phi}^*) + \hat{v}_i(\hat{\phi}^*), & j \notin S_i \end{cases}\quad (7)$$

donde S_i denota el conjunto de índices j , tales que el j -ésimo distrito perteneciente a la i -ésima provincia está incluido en la muestra.

Las predicciones también se pueden obtener de la siguiente manera:

$$\hat{\theta}^{SEBLUP1}(\hat{\phi}^*) = (I - \Lambda(\hat{\phi}^*))X\hat{\beta}(\hat{\phi}^*) + \Lambda(\hat{\phi}^*)Y, \quad (8)$$

correspondiente a los distritos muestreados si $\Lambda(\hat{\phi}^*) = I - \Sigma_e H^{-1}(\hat{\phi}^*)$ y a los distritos no muestreados si $\Lambda(\hat{\phi}^*) = I - (\sigma_u^2 I_{N-D} + \Sigma_e) H^{-1}(\hat{\phi}^*)$.

Es importante destacar que el enfoque propuesto anteriormente nos permite estimar las características de interés en los distritos no muestreados de una manera sencilla. Para estimar el MSE del $\hat{\theta}^{SEBLUP1}(\hat{\phi}^*)$ utilizamos la siguiente descomposición para el MSE (para más detalles ver Molina et al. (2009), Pratesi and Salvati (2009) y Singh et al. (2005)):

$$\begin{aligned}MSE(\hat{\theta}^{SEBLUP1}(\hat{\phi}^*)) &\approx E \left[\left(\hat{\theta}^{SEBLUP1}(\hat{\phi}^*) - \theta \right) \times \right. \\ &\quad \left. \left(\hat{\theta}^{SEBLUP1}(\hat{\phi}^*) - \theta \right)^t \right] \\ &= g_1(\phi^*) + g_2(\phi^*) + g_3(\phi^*),\end{aligned}\quad (9)$$

Se puede demostrar fácilmente que, en el caso de los distritos muestreados,

$$\begin{aligned}g_1(\phi^*) + g_2(\phi^*) &= \\ \Sigma_e - \Sigma_e H^{-1}(\phi^*) \Sigma_e + \Sigma_e Q(\phi^*) \Sigma_e\end{aligned}\quad (10)$$

y en el caso de distritos no muestreados

$$\begin{aligned}g_1(\phi^*) + g_2(\phi^*) &= \\ (\sigma_u^2 I_{N-D} + \Sigma_e) H^{-1}(\phi^*) (\sigma_u^2 I_{N-D} + \Sigma_e) \\ + \Sigma_e Q(\phi^*) \Sigma_e - \sigma_u^4 Q\end{aligned}\quad (11)$$

donde

$$Q(\phi^*) = H^{-1}(\phi^*)X(X^tH^{-1}(\phi^*)X)^{-1}X^tH^{-1}(\phi^*).$$

Como se discutió en [Molina et al. \(2009\)](#), no es posible derivar una forma exacta para $g_3(\phi^*)$ debido a la no linealidad de $\hat{\theta}^{SEBLUP1}(\hat{\phi}^*)$ en el vector de datos Y . Por lo tanto, el estimador de MSE para $\hat{\theta}^{SEBLUP1}(\hat{\phi}^*)$, tanto para los distritos muestreados como para los no muestreados, se puede obtener como

$$g_1(\hat{\phi}^*) + g_2(\hat{\phi}^*) + g_3^{Boot}(\hat{\phi}^*),$$

donde $g_3^{Boot}(\hat{\phi}^*)$ es el estimador Bootstrap para $g_3(\phi^*)$ ([Molina et al. \(2009\)](#)). Alternativamente, se puede utilizar el estimador con sesgo corregido (véanse [Molina et al. \(2009\)](#) y [Pfeffermann and Tiller \(2005\)](#)).

Referencias

- Alcázar, L. (2012). Impacto económico de la anemia en el Perú.
- Alcázar, L. (2019). *Las brechas que perduran: una radiografía de la exclusión social en Perú*. Lima: BID.
- Arias-Salazar, A., Gutiérrez, A., Guerrero-Gómez, S., Mancero, X., Rojas-Perilla, N., and Zhang, H. (2025). Small area estimation for composite indicators: The case of multidimensional poverty incidence. *Journal of Official Statistics*, 41(1):35–59.
- Banco Mundial, B. (2023). *Resurgir fortalecidos: Evaluación de pobreza y equidad en el Perú*. Banco Mundial.
- Banco Mundial, B. (2024). *Tendencias recientes de pobreza y desigualdad América Latina y el Caribe: Octubre 2024*. Banco Mundial.
- Beard, J. and Connor, J. (2003). Iron status and neural functioning. 23(1):41–58.
- Benedetti, R., Piersimoni, F., Pratesi, M., Salvati, N., and Suesse, T. (2024). Handling out-of-sample areas to estimate the unemployment rate at local labour market areas in Italy. *International Statistical Review*, n/a(n/a).
- Casas-Cordero, C., Encina, J., and Lahiri, P. (2016). Poverty mapping for the Chilean comunas. In *In Analysis of Poverty Data by Small Area Estimation*, Ed. Pratesi.
- Corral, P., Molina, I., Cojocarú, A., and Segovia, S. (2022). *Guidelines to Small Area Estimation for Poverty Mapping*. International Bank for Reconstruction and Development / The World Bank.
- Fay, R. and Herriot, R. (1979). Estimates of income for small places: an application of James-Stein procedures to census data. *J Am Stat Assoc*, 74(366):269–77.
- Francke, P. and Acosta, G. (2020). Impacto del programa de alimentación escolar Qali Warma sobre la anemia y la desnutrición crónica infantil. *Apuntes. Revista De Ciencias Sociales*, 48(88):269–277.
- Gonzales de Olarte, E. (1997). *Medio ambiente y pobreza en Perú*. IEP.
- INEI (2008). *Encuesta Demográfica y de Salud Familiar. Diseño muestral*. INEI.
- INEI (2017). *Censo Nacional 2017: XII de población, VII de vivienda y III de comunidades indígenas*. INEI.
- INEI (2024). *Perú: Evolución de la Pobreza Monetaria 2014-2023*. INEI.
- Lozoff, B. (2007). Iron deficiency and child development. *Food Nutr Bull*, 28(4):S560–71.

- Martínez, R. and Fernández, A. (2009). El costo del hambre: Impacto social y económico de la desnutrición infantil en bolivia, ecuador, paraguay y perú. *Santiago de Chile: CEPAL*.
- Molina, I. (2024). *Frontiers in Small Area Estimation Research Application to Welfare Indicators*. Policy Research Working Paper 10828. Poverty and Equity Global Practice.
- Molina, I., Pratesi, M., and Salvati, N. (2009). Bootstrap for estimating the mse of the spatial eblup. *Computational Statistics*, 24:441–458.
- Molina, I. and Rao, J. (2010). Small area estimation of poverty indicators. *The Canadian Journal of Statistics*, 38:369–385.
- Petrucci, A. and Salvati, N. (2006). Small area estimation for spatial correlation in watershed erosion assessment. *J Am Stat Assoc*, 11(2):169–82.
- Pfeffermann, D. (2013). New important developments in small area estimation. *Statistical Science*, 28:40–68.
- Pfeffermann, D. and Tiller, R. (2005). Bootstrap approximation to prediction mse for state-space models with estimated parameters. *J Time Ser Anal*, 26:893–916.
- Pratesi, M. (2016). *Analysis of Poverty Data by Small Area Estimation*. Wiley Series in Survey Methodology. Editor(s):Monica Pratesi.
- Pratesi, M. and Salvati, N. (2008). Small area estimation: the eblup estimator based on spatially correlated random area effects. *Stat Methods Appl*, 17:113–141.
- Pratesi, M. and Salvati, N. (2009). Small area estimation in the presence of correlated random area effects. *J Off Stat*, 25(1):37–53.
- Procuraduría Pública Especializada en Delitos de Corrupción, P. (2022). *Informe sobre Corrupción durante el Estado de Emergencia por Covid-19 en el Perú*. Unidad de Análisis de Información (UAI) de la Procuraduría Pública Especializada en Delitos de Corrupción (PPEDC).
- Rao, J. N. K. and Molina, I. (2015). *Small area estimation*. Wiley series in survey methodology. 2nd ed. Hoboken, New Jersey: Wiley.
- Sánchez, A. (2022). *Trayectorias educativas a lo largo del ciclo de vida: el rol de la pobreza, el área de residencia y las brechas de género*. En: Balarin, M., Cueto, S. y Fort, R. (Eds.), *El Perú pendiente: ensayos para un desarrollo con bienestar* (pp. 179-202). Lima: GRADE.
- Sikov, A. and Cerda-Hernández, J. (2023). Estimating the prevalence of anemia rates among children under five in peruvian districts with a small sample size. *Statistical Methods and Applications*, 32:1779–1804.

- Sikov, A. and Cerda-Hernández, J. (2024). Prediction in non-sampled areas under spatial small area models. *Statistical Methods and Applications*, 33:1079–1116.
- Sikov, A. and Cerda-Hernandez, J. (2024). A spatial analysis of disparity in the prevalence of stunting rates among children aged under five between rural and urban areas in peru. *Preprint*.
- Sikov, A., Cerda-Hernández, J., and Haro, E. (2023). Is it possible to obtain reliable estimates for the prevalence of anemia and childhood stunting among children under 5 en the most poor districts in Perú? *Apuntes. Revista De Ciencias Sociales*, 50(95).
- Sikov, A., Cerda-Hernández, J., and Vidal, L. (2024a). Análisis espacial de la anemia infantil en Perú 2022: construcción de mapas a nivel distrital para políticas públicas. *Salud Pública de México*, 66(3, may-jun):236–244.
- Sikov, A., Cerda-Hernández, J., and Vidal, L. (2024b). Impact of the covid-19 pandemic on the prevalence of anemia rates in children under five in peru: Importance of disaggregated analysis. *Preprint*.
- Singh, B., Shukla, K., and Kundu, D. (2005). Spatial-temporal models in small area estimation. *Surv Methodol*, 31(2):183–195.
- Walter, T. (2003). Effect of iron-deficiency anemia on cognitive skills and neuromaturation in infancy and childhood. *Food Nutr Bull*, 24(4):S104–10.

