



## Estimación municipal de la pobreza por ingresos en México mediante un modelo espacial para áreas pequeñas: una propuesta metodológica

Municipal estimation of income poverty in Mexico using a small-area spatial model: a methodological proposal

Estimativa municipal da pobreza por renda no México por meio de um modelo espacial para áreas pequenas: uma proposta metodológica

Víctor Adrián Morales Linares; Beatriz Martínez Carreño; María Isabel Garrido Lastra

Doctor en Economía Política del Desarrollo, Benemérita Universidad Autónoma de Puebla. Colaborador del Cuerpo Académico 130 Análisis Económico de la Facultad de Economía, Benemérita Universidad Autónoma de Puebla. ORCID: 0009-0008-1532-3191. E-mail: economia.asesor03@correo.buap.mx. Puebla - México.

Doctora en Procesos Territoriales, Benemérita Universidad Autónoma de Puebla. Profesora-Investigadora de la Facultad de Economía, Benemérita Universidad Autónoma de Puebla. ORCID: 0000-0003-1288-4926. E-mail: beatriz.martinezc@correo.buap.mx. Puebla - México.

Doctora en Administración Pública, Instituto de Administración Pública de Puebla. Colaboradora del Cuerpo Académico 130 Análisis Económico de la Facultad de Economía, Benemérita Universidad Autónoma de Puebla. ORCID: 0000-0002-5450-5229. E-mail: maría.garrido@puebla.gob.mx. Puebla - México.

**Recibido:** 8 de enero de 2026

**Aceptado:** 1 de junio de 2026

**DOI:** <https://doi.org/10.22267/rtend.26272.299>

**Cómo citar este artículo:** Morales, V., Carreño, B. y Garrido, M. (2026). Estimación municipal de la pobreza por ingresos en México mediante un modelo espacial para áreas pequeñas: una propuesta metodológica. *Tendencias*, 27(2), 119-146. <https://doi.org/10.22267/rtend.26272.299>

### Resumen

**Introducción:** La medición de la pobreza subnacional es clave para políticas públicas focalizadas; sin embargo, las encuestas en México no tienen representatividad municipal. **Objetivo:** Desarrollar y validar una metodología para generar estimaciones municipales de pobreza monetaria con medidas explícitas de incertidumbre. **Metodología:** Este estudio presenta la metodología ALIVIO, orientada a la estimación municipal de la pobreza monetaria en contextos de baja representatividad muestral. Se empleó un predictor empírico a nivel unidad, combinado con una estructura espacial Intrinsic Conditional Autoregressive. La estimación se realizó mediante inferencia bayesiana aproximada, integrando microdatos de la ENIGH 2024 y variables auxiliares del Censo 2020. **Resultados:** El modelo redujo sustantivamente la incertidumbre frente a estimadores directos y permitió generar información para todos los municipios, incluso aquellos sin muestra, y no evidenció autocorrelación espacial residual relevante en los diagnósticos agregados. **Discusión:** La incorporación espacial fortaleció la capacidad predictiva respecto a modelos tradicionales, aunque depende de supuestos de normalidad y armonización temporal entre fuentes. **Conclusiones:** ALIVIO constituye un marco metodológico potencialmente robusto, eficiente y replicable para generar mapas municipales de pobreza y priorizar territorios con baja disponibilidad de datos primarios.

**Palabras clave:** econometría; México; modelo económico; modelo espacial; pobreza.

**JEL:** C11; C21; C51; C81; I32; R12.



## Abstract

**Introduction:** The measurement of subnational poverty is key for targeted public policies; however, surveys in Mexico lack representativeness at the municipal level. **Objective:** To develop and validate a methodology for generating municipal estimates of monetary poverty with explicit uncertainty measures. **Methodology:** This study presents the ALIVIO methodology, aimed at the municipal estimation of monetary poverty in contexts of low sample representativeness. A unit-level empirical predictor was employed, combined with an Intrinsic Conditional Autoregressive spatial structure. Estimation was carried out via approximate Bayesian inference, integrating microdata from the ENIGH 2024 and auxiliary variables from the 2020 Census. **Results:** The model substantially reduced uncertainty compared to direct estimators and enabled the generation of information for all municipalities, including those with no sample, and showed no relevant residual spatial autocorrelation in the aggregate diagnostics. **Discussion:** Spatial incorporation strengthened predictive capacity relative to traditional models, though it depends on normality assumptions and temporal harmonization across sources. **Conclusions:** ALIVIO constitutes a potentially robust, efficient, and replicable methodological framework for generating municipal poverty maps and prioritizing territories with low availability of primary data.

**Keywords:** econometrics; Mexico; economic model; spatial model; poverty.

**JEL:** C11; C21; C51; C81; I32; R12.

## Resumo

**Introdução:** A medição da pobreza a nível subnacional é fundamental para políticas públicas direcionadas; no entanto, os inquéritos no México não têm representatividade municipal. **Objetivo:** Desenvolver e validar uma metodologia para gerar estimativas municipais de pobreza monetária com medidas explícitas de incerteza. **Metodologia:** Este estudo apresenta a metodologia ALIVIO, orientada para a estimativa municipal da pobreza monetária em contextos de baixa representatividade amostral. Foi utilizado um preditor empírico ao nível da unidade, combinado com uma estrutura espacial Intrinsic Conditional Autoregressive. A estimativa foi realizada por meio de inferência bayesiana aproximada, integrando microdados da ENIGH 2024 e variáveis auxiliares do Censo 2020. **Resultados:** O modelo reduziu substancialmente a incerteza em relação aos estimadores diretos e permitiu gerar informação para todos os municípios, inclusive aqueles sem amostra, e não evidenciou autocorrelação espacial residual relevante nos diagnósticos agregados. **Discussão:** A incorporação espacial reforçou a capacidade preditiva em relação aos modelos tradicionais, embora dependa de pressupostos de normalidade e harmonização temporal entre fontes. **Conclusões:** O ALIVIO constitui um quadro metodológico potencialmente robusto, eficiente e replicável para gerar mapas municipais de pobreza e priorizar territórios com baixa disponibilidade de dados primários.

**Palavras-chave:** econometria; México; modelo econômico; modelo espacial; pobreza.

**JEL:** C11; C21; C51; C81; I32; R12.

## Introducción

La medición precisa de la pobreza subnacional es un desafío central para el diseño de políticas públicas focalizadas (Ballini et al., 2006). En México, la Encuesta Nacional de Ingresos y Gastos de los Hogares (ENIGH) ofrece datos detallados, pero su diseño muestral limita la representatividad a niveles agregados.

Esta limitación muestral provoca que los estimadores directos municipales presenten alta varianza e inestabilidad, especialmente en dominios con muestra reducida o nula (Fay & Herriot, 1979; Rao & Molina, 2015). Ante este escenario, los enfoques basados en modelos (*model-based*) surgen como una alternativa robusta para combinar información muestral con fuentes auxiliares exhaustivas (Jiang & Rao, 2020).

Recientemente, la aplicación de la Estimación en Áreas Pequeñas (SAE) ha experimentado un auge global para cumplir con los Objetivos de Desarrollo Sostenible (ODS). Estudios internacionales han documentado la utilidad de los enfoques SAE en distintos contextos, desde la prevalencia del VIH en Zambia (Mweemba et al., 2022) hasta la incidencia de pobreza en Italia considerando el costo de vida local (Marchetti et al., 2024). En el ámbito metodológico, la inferencia bayesiana jerárquica y los modelos de nivel unidad se han validado como el enfoque de referencia para capturar la heterogeneidad no observada y proporcionar una mayor riqueza analítica frente a los modelos de nivel de área (Arima et al., 2015; Morales et al., 2021; Purwa et al., 2019).

A diferencia de enfoques que tratan a los municipios como unidades independientes, esta investigación reconoce la naturaleza territorial de la pobreza e incorpora dependencia espacial residual mediante un campo aleatorio gaussiano con estructura de vecindad (Besag et al., 1991; Blangiardo & Cameletti, 2015). El modelo propuesto, denominado ALIVIO, combina microdatos de la ENIGH (2024) con información auxiliar del Censo 2020 para generar estimaciones en los 2,469 municipios de México. La contribución de ALIVIO frente a enfoques de nivel de área y regresiones logísticas se organiza en tres elementos.

- Predictor empírico mejor (Empirical Best Predictor, EBP) a nivel de unidad: Modela la variabilidad entre hogares y el efecto municipal no observado (Molina, 2024).
- Estructura espacial ICAR: Aprovecha la contigüidad territorial para tomar prestada fuerza de municipios vecinos, reconociendo la inercia geográfica de la pobreza (Cameletti et al., 2013).
- Implementación mediante Aproximación de Laplace Anidada Integrada (INLA): Ofrece una precisión y eficiencia computacional superior a los algoritmos de cadenas de Markov Monte Carlo (MCMC) en modelos de alta dimensionalidad (Possolo, 2023).

Además, el esquema incorpora un procedimiento de *benchmarking* para garantizar consistencia con agregados estatales y un mecanismo de actualización alineado con los ciclos bienales de la ENIGH.

El objetivo de este estudio es desarrollar y validar una metodología SAE a nivel unidad que permita generar estimaciones municipales periódicas de pobreza por ingresos en México, y producir indicadores acompañados de medidas explícitas de incertidumbre, adecuados para dominios con muestra escasa (Molina & Rao, 2010).

La pregunta de investigación que guía el estudio es: ¿En qué medida la incorporación de un enfoque basado en modelos con estructura espacial mejora la precisión, estabilidad y coherencia territorial de las estimaciones municipales de pobreza frente a los estimadores directos? Esta interrogante se inscribe en el debate entre enfoques *design-based* y *model-based*, con el propósito de documentar las ganancias de eficiencia al incorporar estructuras jerárquicas y mecanismos de transferencia de fuerza estadística.

---

## Metodología

El estudio emplea un modelo de SAE a nivel unidad (Arias, 2023), combinando un EBP con un componente espacial estructurado tipo Intrinsic Conditional Autoregressive (ICAR). Este enfoque permite modelar el ingreso a nivel hogar y derivar indicadores no lineales de pobreza con mayor eficiencia que los modelos de nivel área (Molina & Rao, 2010). La especificación reconoce la dependencia territorial mediante un campo aleatorio gaussiano con

matriz de vecindad (Besag et al., 1991).

En cuanto al indicador de pobreza y las fuentes de información, el estudio se centra exclusivamente en la pobreza monetaria, definida operativamente a partir del ingreso corriente per cápita trimestral reportado en la ENIGH y contrastado con las líneas oficiales de pobreza monetaria (Comisión Económica para América Latina y el Caribe [CEPAL], 2025). La incidencia municipal se estima mediante el índice Foster-Greer-Thorbecke (FGT) de orden cero (0), ampliamente utilizado en la literatura internacional para medir la proporción de población en situación de pobreza (Foster et al., 1984). Para ello, se integran los microdatos de la ENIGH 2024 con covariables auxiliares provenientes del Censo 2020; el desfase temporal entre ambas fuentes se aborda bajo el supuesto de estabilidad condicional en la relación entre ingreso, características sociodemográficas y condiciones territoriales.

Se construyó un conjunto de variables auxiliares armonizadas entre la ENIGH y el Censo de Población y Vivienda. El proceso de armonización consistió en homologar nombres, escalas de medición, categorías y reglas de codificación entre ambas fuentes, garantizando que las covariables utilizadas en el modelo fueran conceptualmente equivalentes y estadísticamente comparables.

La armonización incluyó: i) depuración de categorías “no especificado”; ii) recodificación de variables binarias bajo criterios equivalentes; iii) agrupación homogénea de categorías educativas y de calidad de vivienda; iv) construcción de indicadores proporcionales y variables derivadas; y v) validación automática de consistencia entre ENIGH y Censo mediante diagnósticos de rangos, catálogos y coherencia lógica.

Se definió una lista de covariables auxiliares para el modelo EBP. La selección final consideró los siguientes criterios: disponibilidad simultánea en ENIGH y censo; consistencia conceptual después de la armonización; capacidad explicativa sobre el ingreso del hogar; ausencia de problemas de colinealidad severa o categorías inconsistentes; interpretabilidad socioeconómica. Las variables auxiliares finalmente incorporadas al modelo fueron las siguientes (Tabla 1).

**Tabla 1**

*VARIABLES AUXILIARES UTILIZADAS EN EL MODELO EBP*

<b>Variable</b>	<b>Definición</b>	<b>Medición / Construcción</b>	<b>Justificación para su inclusión</b>
rooms_per_person	Disponibilidad relativa de espacio habitable	Número de habitaciones dividido entre los miembros del hogar	Indicador de bienestar residencial
overcrowding	Presión de hacinamiento en el hogar	Número de personas por dormitorio	Proxy de privación social
percentage_of_minors	Proporción de menores de edad en el hogar	Menores de edad / total de miembros del hogar	Relacionado con la dependencia económica
public_social_security	Cobertura de seguridad social pública	Proporción de miembros con seguridad social pública	Indicador de inserción en el mercado laboral formal
equipment_index	Índice de bienes duraderos	Promedio de posesión de bienes seleccionados	Proxy patrimonial
housing_index	Índice de calidad de la vivienda	Promedio de componentes estructurales y servicios	Indicador sintético de bienestar
movies	Disponibilidad de servicios de entretenimiento digital	Variable binaria (1 = sí, 0 = no)	Proxy de acceso y consumo tecnológico
vehicle	Disponibilidad de vehículo	Variable binaria	Indicador patrimonial
microwave	Disponibilidad de horno microondas	Variable binaria	Indicador de equipamiento del hogar
shower	Disponibilidad de ducha	Variable binaria	Indicador de calidad de los servicios de la vivienda
computer	Disponibilidad de computador	Variable binaria	Proxy de acceso tecnológico
household_head_education	Nivel educativo del jefe del hogar	Categorías armonizadas de escolaridad	Indicador de capital humano

*Fuente:* Elaboración propia con base en INEGI (2020, 2024) y lineamientos de medición de pobreza del Consejo Nacional de Evaluación de la Política de Desarrollo Social [CONEVAL] (2020).

En conjunto, estas covariables permiten capturar heterogeneidad socioeconómica territorial y mejorar la precisión de las estimaciones municipales del ingreso mediante el modelo EBP.

**Marco espacial y equivalencia territorial:** La estimación utiliza la malla municipal 2020 para construir una matriz de adyacencia tipo Queen, modelando la dependencia de primer orden entre municipios contiguos. Para garantizar la relevancia administrativa actual, los resultados se transfieren a la malla municipal 2024 mediante un procedimiento determinístico de máxima intersección geométrica, buscando preservar la comparabilidad estadística de la estimación original.

**Especificación y supuestos:** El modelo EBP-ICAR se define como un modelo lineal mixto sobre el ingreso transformado. Incorpora efectos fijos (covariables socioeconómicas) y un efecto aleatorio municipal con estructura espacial. Se asume normalidad condicional del error e independencia a nivel hogar, mientras que la dependencia residual se captura vía ICAR.

La implementación se realiza mediante INLA en el software RStudio. Este método permite procesar modelos gaussianos latentes de alta dimensión con una eficiencia computacional superior a los algoritmos MCMC tradicionales (Rue et al., 2009).

**Benchmarking y coherencia:** Se aplica un procedimiento de ajuste de coherencia (benchmarking) para asegurar que las estimaciones municipales coincidan con los agregados estatales oficiales por ámbito urbano/rural, especificando fuente y fórmula de ajuste, garantizando la consistencia entre niveles territoriales sin alterar la estructura relativa de pobreza dentro de los municipios, alineándose con las recomendaciones metodológicas de Rao y Molina (2015).

Para garantizar coherencia entre la variable dependiente y el umbral de comparación, tanto el ingreso como la línea de pobreza se expresan en términos trimestrales y se transforman en la misma escala logarítmica, práctica común en modelos a nivel de individuo cuando se busca aproximar normalidad condicional del ingreso (Molina & Rao, 2010; Rao & Molina, 2015).

La variable dependiente se define como:

### Ecuación 1

$$y_{ih}^* = \log(y_{ih} + c_{opt}) \quad (1)$$

donde  $y_{ih}$  es el ingreso corriente per cápita trimestral del hogar  $h$  en el municipio  $i$ , y  $c_{opt}$  es una constante seleccionada endógenamente para mejorar la simetría de la distribución y permitir la inclusión de observaciones con ingreso nulo.

**Especificación del modelo a nivel de individuo:** En la escala transformada se plantea un modelo lineal mixto:

### Ecuación 2

$$y_{ih}^* = x'_{ih}\beta + u_i + \varepsilon_{ih}, \varepsilon_{ih} \sim N(0, \sigma_e^2) \quad (2)$$

donde:  $x_{ih}$  es el vector de covariables armonizadas entre ENIGH y Censo;  $\beta$  representa los efectos fijos;  $u_i$  es el efecto aleatorio municipal;  $\varepsilon_{ih}$  es el error idiosincrático a nivel hogar.

Este esquema corresponde al modelo clásico de error anidado (*nested error model*) en SAE a nivel unidad, base del enfoque EBP (Molina & Rao, 2010; Rao & Molina, 2015). Se asume independencia condicional entre hogares y normalidad del error en la escala transformada.

**Definición del indicador de pobreza:** La incidencia municipal de pobreza se define mediante el índice FGT de orden cero:

### Ecuación 3

$$FGT0_i = \frac{1}{N_i} \sum_{h \in i} 1(y_{ih} < LP_{ih}) \quad (3)$$

donde  $LP_{ih}$  es la línea de pobreza correspondiente al ámbito urbano o rural (Foster et al., 1984). Bajo el enfoque EBP, el indicador binario se reemplaza por su esperanza condicional respecto a la distribución posterior de parámetros y efectos aleatorios.

#### Ecuación 4

$$\widehat{FGT0}_i^{EBP} = \frac{1}{N_i} \sum_{h \in i} E[1(y_{ih} < LP_{ih}) | x_{ih}, \hat{\beta}, \hat{u}_i, \hat{\sigma}_e^2] \quad (4)$$

Este procedimiento sigue la lógica de Predicción Empírica Mejor para indicadores no lineales derivables de modelos a nivel de individuo (Molina & Rao, 2010; Rao & Molina, 2015).

Dado el supuesto de normalidad en la escala logarítmica, la probabilidad de pobreza puede derivarse analíticamente como:

#### Ecuación 5

$$\hat{p}_{ih} = \Phi\left(\frac{\log(LP_{ih} + c_{opt}) - \eta_{ih}}{\sigma_e}\right), \eta_{ih} = x'_{ih}\hat{\beta} + \hat{u}_i \quad (5)$$

donde  $\Phi(\cdot)$  es la función de distribución normal estándar.

La estimación municipal se obtiene agregando probabilidades ponderadas por el peso poblacional del hogar:

#### Ecuación 6

$$\widehat{FGT0}_i^{EBP} = \frac{\sum_{h \in i} w_{ih}^{(p)} \hat{p}_{ih}}{\sum_{h \in i} w_{ih}^{(p)}} \quad (6)$$

donde  $w_{ih}^{(p)}$  es el producto del factor de expansión y el tamaño del hogar. Esta forma de agregación es consistente con la literatura SAE aplicada a pobreza monetaria (Lange et al., 2022; Molina & Rao, 2010).

**Componente espacial ICAR:** La heterogeneidad territorial residual se modela mediante un proceso ICAR:

#### Ecuación 7

$$u \sim ICAR(\tau_u, W) \quad (7)$$

donde  $W$  es la matriz de vecindad municipal (Queen) y  $\tau_u$  el parámetro de precisión espacial, sujeto a la restricción  $\sum_i u_i = 0$ .

El modelo ICAR deriva de la formulación de campos aleatorios de Markov gaussianos

propuesta por Besag (1974) y extendida en Besag et al. (1991), y constituye un mecanismo de suavizamiento espacial que permite compartir información entre municipios contiguos (Blangiardo & Cameletti, 2015).

**Inferencia y propagación de incertidumbre:** El modelo se estima mediante INLA bajo el marco de modelos gaussianos latentes:

### Ecuación 8

$$\eta = X\beta + Au \quad (8)$$

INLA permite aproximar de manera determinista las distribuciones posteriores marginales sin recurrir a simulación MCMC, siendo particularmente eficiente en modelos espaciales de alta dimensión (Blangiardo & Cameletti, 2015; Rue et al., 2009).

Los factores de expansión de la ENIGH se incorporan como ponderaciones normalizadas en la verosimilitud, manteniendo la interpretación *model-based* de la inferencia (Rao & Molina, 2015).

Para propagar la incertidumbre hacia el indicador municipal, se generan  $B$  réplicas posteriores conjuntas:

### Ecuación 9

$$(\beta^{(b)}, u^{(b)}, \sigma_e^{2(b)}, \sigma_u^{2(b)}), b = 1, \dots, B \quad (9)$$

En cada réplica se recalculan las probabilidades  $\hat{p}_{ih}^{(b)}$  y la incidencia municipal  $\widehat{FGT0}_i^{(b)}$ , obteniendo así la distribución posterior completa del indicador para cada municipio, conforme al procedimiento estándar de EBP bajo marcos bayesianos aproximados (Molina & Rao, 2010; Rao & Molina, 2015).

El modelo completo puede resumirse como:

### Ecuación 10

$$y_{ih}^* = x'_{ih}\beta + u_i + \varepsilon_{ih}, \varepsilon_{ih} \sim N(0, \sigma_e^2), u \sim ICAR(\tau_u, W) \quad (10)$$

Estimado mediante INLA con *priors* penalizados de complejidad (PC *priors*) para los parámetros de precisión, enfoque que permite controlar la complejidad efectiva del modelo espacial y evitar sobreajuste (Simpson et al., 2017).

**Inferencia bayesiana y estructura espacial:** Para la estimación del modelo ALIVIO se utiliza la Aproximación de Laplace Anidada Integrada (INLA), una técnica de inferencia bayesiana que optimiza el tiempo de cómputo en modelos de alta dimensionalidad al emplear aproximaciones analíticas en lugar de simulaciones MCMC tradicionales (Rue et al., 2009).

La dependencia territorial se integra mediante una estructura ICAR, que asume que el componente aleatorio de un municipio está condicionado por sus vecinos contiguos. Este enfoque permite tomar prestada fuerza de dominios adyacentes, capturando la autocorrelación espacial residual de forma eficiente.

La combinación de INLA e ICAR contribuye a mejorar la precisión relativa superior en modelos gaussianos latentes, permitiendo realizar análisis de sensibilidad y validaciones cruzadas con agilidad. El resultado es un mapa de pobreza nacional estadísticamente robusto, territorialmente coherente y con medidas de incertidumbre explícitas (Blangiardo & Cameletti, 2015).

---

## Resultados

Los valores medios posteriores de los hiperparámetros del modelo EBP–ICAR son:

### Ecuación 11

$$\tau_u = 18.51 \Rightarrow \sigma_u^2 = \tau_u^{-1} = 0.054; \tau_e = 4.06 \Rightarrow \sigma_e^2 = \tau_e^{-1} = 0.246 \quad (11)$$

La mayor parte de la variabilidad residual del ingreso per cápita transformado se concentra a nivel hogar, como es esperable en un modelo *a nivel de individuo* de error anidado (Molina & Rao, 2010; Rao & Molina, 2015). No obstante, la varianza espacial municipal no es despreciable.

A partir de estas varianzas se calcula el coeficiente de correlación intraclase espacial:

## Ecuación 12

$$ICC = \frac{\sigma_u^2}{\sigma_u^2 + \sigma_e^2} \quad (12)$$

El valor estimado ( $\approx 18\%$ ) indica que cerca de una quinta parte de la variabilidad residual del ingreso transformado se asocia a diferencias sistemáticas entre municipios, una vez controladas las covariables. Este tipo de descomposición es consistente con la interpretación de efectos aleatorios en modelos jerárquicos gaussianos (Blangiardo & Cameletti, 2015). El resultado confirma la relevancia empírica del componente espacial ICAR en la explicación de heterogeneidad territorial persistente.

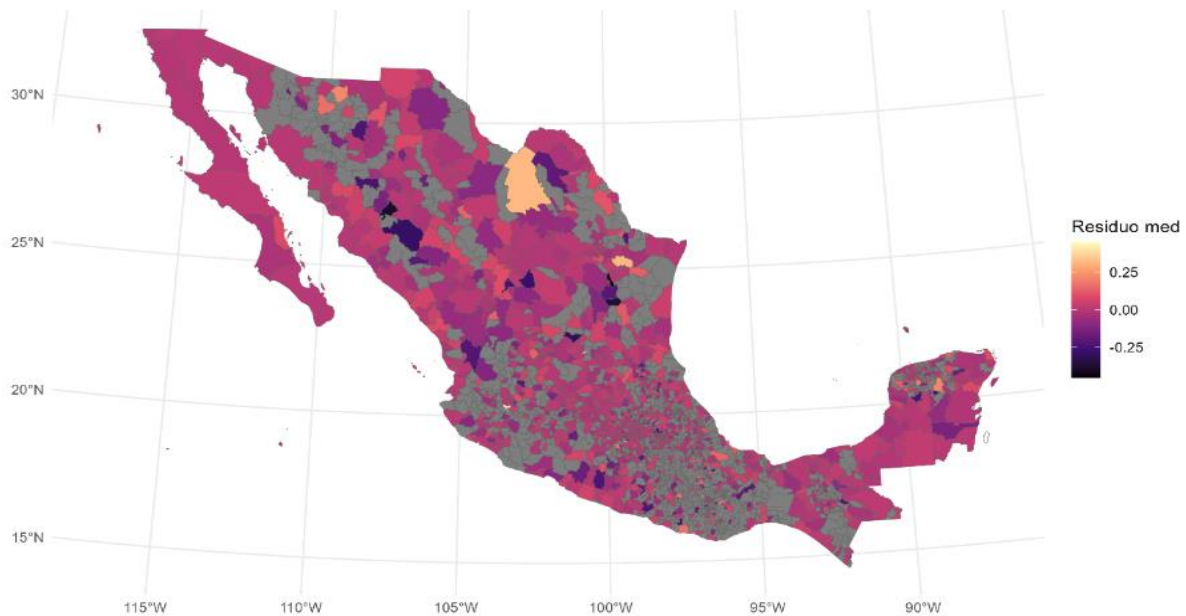
Para verificar la adecuación del componente ICAR, se evaluó la presencia de autocorrelación espacial residual en los residuos municipales agregados. Los residuos marginales medios municipales se calcularon como el promedio ponderado de los residuos individuales dentro de cada municipio (Figura 1).

El patrón espacial muestra residuos dispersos, sin formación de clústeres extensos ni regiones contiguas con valores persistentemente altos o bajos. La mayoría de los municipios presentan residuos cercanos a cero, y las desviaciones más pronunciadas aparecen de forma aislada.

En conjunto, estos diagnósticos indican que el efecto espacial ICAR está identificado y centrado, que no se observa dependencia espacial residual sistemática y que la magnitud del efecto espacial es coherente con la descomposición de varianza estimada (Figura 1).

## Figura 1

*Residuos medios municipales ponderados del modelo EBP-ICAR, México, ENIGH  
2024/Censo 2020*



*Fuente:* Elaboración propia con base en estimaciones del modelo ALIVIO.

La evaluación del modelo EBP-ICAR muestra un mejor desempeño relativo frente al estimador directo en los diagnósticos considerados. La ausencia de autocorrelación residual valida la especificación espacial (Besag et al., 1991), mientras que los análisis de sensibilidad demuestran que el sesgo medio permanece cercano a cero independientemente del tamaño muestral.

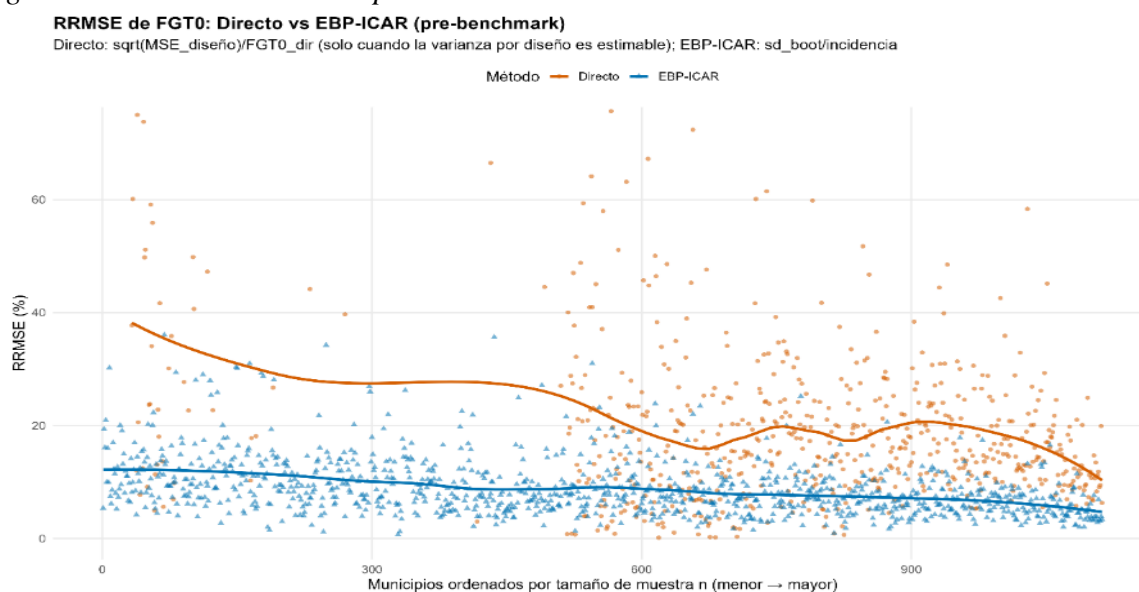
En municipios con al menos 30 observaciones, la correlación entre ambos estimadores supera 0.90, lo que refleja la convergencia teórica del modelo hacia el dato directo cuando la información es suficiente. Sin embargo, en dominios con muestra reducida, el modelo introduce un efecto de contracción (*shrinkage*) que reduce la inestabilidad extrema de los estimadores por diseño (Chandra et al., 2018; Rao & Molina, 2015).

La comparación del Error Cuadrático Medio Relativo (RRMSE) evidencia que el enfoque basado en modelos ofrece errores sistemáticamente menores y trayectorias más estables. Mediante curvas suavizadas (Regresión local ponderada, LOESS), se confirma que la sensibilidad del error al tamaño muestral disminuye drásticamente gracias a la transferencia de fuerza (*borrowing strength*) de las covariables y la estructura espacial (Jiang & Rao, 2020). Estos resultados sugieren que el modelo ALIVIO ofrece estimaciones más estables y

territorialmente coherentes incluso ante limitaciones muestrales severas (Figura 2).

## Figura 2

Comparación del RRMSE entre el estimador directo y el estimador EBP-ICAR para FGTO, según tamaño muestral municipal



*Nota.* El RRMSE directo se muestra únicamente cuando la varianza por diseño es estimable ( $\text{MSE} > 0$ ).

*Fuente:* Elaboración propia con base en estimaciones del modelo ALIVIO.

La validación del modelo EBP-ICAR confirma su consistencia teórica y robustez estadística. Conforme el tamaño muestral aumenta, el estimador converge al dato directo; en dominios con baja información, el modelo ofrece una ganancia sustantiva de estabilidad mediante el efecto de contracción (shrinkage), reduciendo la variabilidad extrema sin introducir sesgos sistemáticos (Rao & Molina, 2015).

La adecuada calibración de la incertidumbre se evidencia en la cobertura empírica de los intervalos, que se mantiene cercana a los niveles nominales. Asimismo, los estadísticos estandarizados muestran una dispersión decreciente respecto al tamaño de muestra, alineándose con los supuestos de los modelos de áreas pequeñas (Fay & Herriot, 1979).

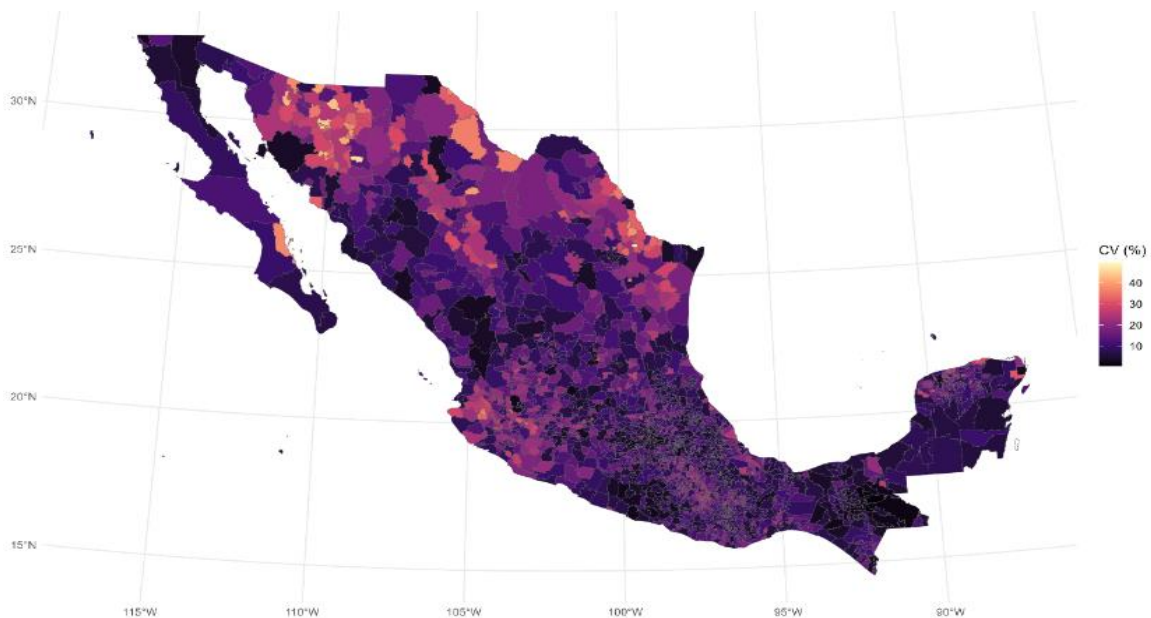
A nivel nacional, la precisión medida a través del coeficiente de variación (CV) presenta una media de 13.75%. Destaca que más del 97% de los municipios registran un CV inferior al 30%, umbral de referencia utilizado frecuentemente para evaluar precisión en dominios pequeños. Especialmente, la mayor precisión se concentra en zonas urbanas, mientras que los

CV más altos aparecen en áreas rurales aisladas, patrón coherente con la disponibilidad de información directa.

En conjunto, los resultados presentan una media de incidencia de pobreza del 49.1% y una mediana de 48.9%. La ausencia de patrones sistemáticos de baja precisión respalda la estabilidad global del modelo ALIVIO para la generación de mapas de pobreza municipal en México, garantizando coherencia territorial y soporte estadístico formal (Figura 3).

### Figura 3

*Coefficiente de variación (%) de la incidencia de pobreza municipal EBP–ICAR (post-benchmark)*



*Fuente:* Elaboración propia con base en estimaciones del modelo ALIVIO.

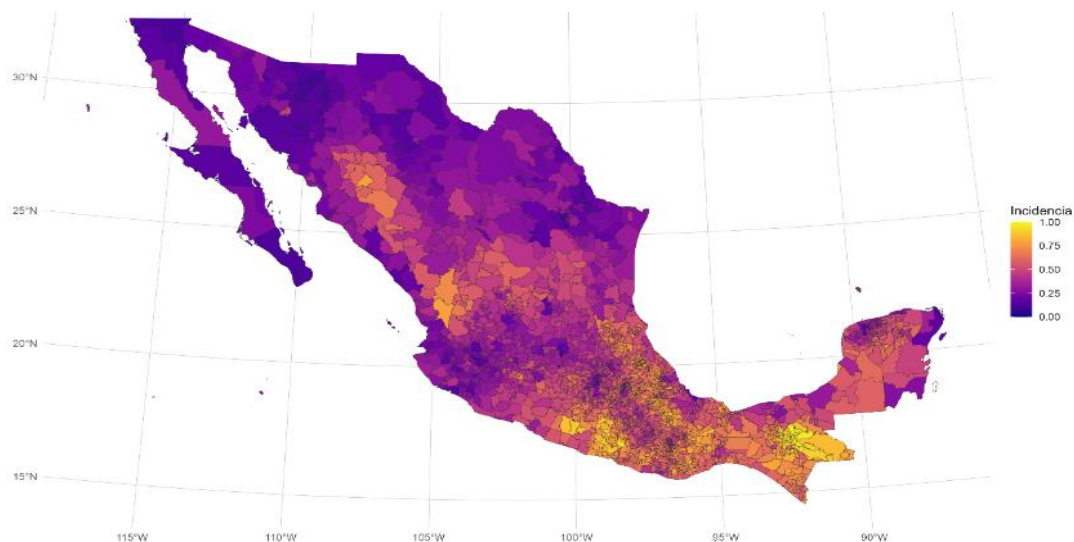
Los resultados revelan una marcada heterogeneidad territorial en México, con incidencias que fluctúan desde niveles mínimos en centros urbanos de alto ingreso hasta valores cercanos al 100% en zonas rurales marginadas. El patrón geográfico identificado es plenamente coherente con la estructura socioeconómica nacional, se observan concentraciones de pobreza en el sur y sureste, así como persistencia en regiones rurales del centro y occidente, contrastando con la menor incidencia en nodos metropolitanos e industriales.

Cabe destacar que las transiciones entre municipios son graduales, lo que evidencia el efecto de suavizamiento espacial del componente ICAR (Figura 4). Esta estructura permite

capturar la dependencia territorial y aprovechar información de municipios contiguos sin imponer una homogeneización artificial, garantizando que el mapa refleje tanto la inercia geográfica como las particularidades locales (Blangiardo & Cameletti, 2015).

#### Figura 4

*Incidencia de pobreza municipal — EBP–ICAR (malla 2024)*



*Fuente:* Elaboración propia con base en estimaciones del modelo ALIVIO.

Finalmente, se subraya que las estimaciones corresponden exclusivamente a pobreza monetaria medida mediante el índice FGT0 (Foster et al., 1984) y no sustituyen la medición multidimensional oficial; no obstante, constituyen un insumo valioso para análisis territorial detallado bajo un marco estadístico formal.

#### Municipios con mayor y menor incidencia estimada

Para verificar la coherencia del modelo tras el ajuste estatal (benchmarking), se analizaron los municipios con incidencias extremas de pobreza, una práctica estándar en la SAE para validar la estabilidad de la inferencia (Rao & Molina, 2015). Los diez municipios con mayor incidencia se localizan en Chiapas, en zonas con alta marginación y población indígena. Estos presentan estimaciones de entre 0.949 y 1.000, con coeficientes de variación sumamente bajos (menores al 3%) e intervalos de credibilidad estrechos.

Esta alta precisión y la concentración geográfica de los resultados son coherentes con la estructura del modelo ICAR, que aprovecha la información de municipios vecinos y

variables auxiliares para estabilizar dominios con datos directos limitados (Molina & Rao, 2010). La alineación de estos valores con la realidad socioeconómica documentada respalda la robustez y plausibilidad empírica de la metodología propuesta.

Los municipios con menor incidencia de pobreza se localizan en zonas metropolitanas de alto ingreso, como San Pedro Garza García y alcaldías de la Ciudad de México, así como en nodos con alta integración económica o turística. Las estimaciones en estos dominios oscilan entre 0.012 y 0.105.

En estos casos, se observan coeficientes de variación (CV) relativamente elevados. Este comportamiento es estadísticamente consistente en la SAE, cuando la media es muy baja, el CV tiende a incrementarse, aunque la desviación estándar absoluta sea pequeña (Rao & Molina, 2015). No obstante, los intervalos de credibilidad se mantienen acotados, descartando cualquier inestabilidad estructural.

En resumen, los valores extremos generados por el modelo EBP-ICAR muestran una sólida consistencia territorial y magnitudes plenamente compatibles con la evidencia socioeconómica vigente, lo que valida la plausibilidad sustantiva del enfoque adoptado (Jiang & Rao, 2020) (Tabla 2).

**Tabla 2**

*Municipios con mayor y menor incidencia estimada — EBP-ICAR (post-benchmark)*

<b>Diez municipios con mayor incidencia</b>							
<b>Entidad</b>	<b>Municipio</b>	<b>Clave localidad geostatística</b>	<b>Incidencia</b>	<b>CV (%)</b>	<b>SD</b>	<b>ICr 95% inferior</b>	<b>ICr 95% superior</b>
Chiapas	Oxchuc	07064	1.000	0.71	0.007	0.994	1.000
Chiapas	Tumbalá	07100	0.994	1.21	0.012	0.965	1.000
Chiapas	Tila	07096	0.977	1.25	0.012	0.950	0.998
Chiapas	San Juan Cancuc	07112	0.975	2.26	0.022	0.922	1.000
Chiapas	Chanal	07024	0.974	2.07	0.020	0.927	1.000
Chiapas	Zinacantán	07111	0.967	1.37	0.013	0.937	0.989
Chiapas	Pantelhó	07066	0.965	2.69	0.026	0.901	1.000
Chiapas	Chilón	07031	0.964	0.98	0.009	0.944	0.982
Chiapas	Yajalón	07109	0.963	1.43	0.014	0.933	0.986
Chiapas	San Andrés Duraznal	07118	0.949	2.62	0.025	0.891	0.989
<b>Diez municipios con menor incidencia</b>							

Entidad	Municipio	ubica_geo	Incidencia	CV (%)	SD	ICr 95% inferior	ICr 95% superior
Nuevo León	San Pedro Garza García	19019	0.012	17.9	0.002	0.008	0.017
Ciudad de México	Benito Juárez	09014	0.019	7.9	0.002	0.017	0.023
Ciudad de México	Miguel Hidalgo	09016	0.041	7.9	0.003	0.035	0.048
Nuevo León	San Nicolás de los Garza	19046	0.085	6.5	0.006	0.075	0.097
Querétaro	Corregidora	22006	0.085	9.0	0.008	0.071	0.101
Sonora	Huépac	26034	0.090	37.2	0.034	0.041	0.171
Sonora	Bacoachi	26011	0.094	42.0	0.039	0.038	0.188
Baja California	Playas de Rosarito	02005	0.096	12.9	0.012	0.074	0.122
Sonora	Fronteras	26027	0.104	28.5	0.030	0.058	0.174
Quintana Roo	Isla Mujeres	23003	0.105	22.0	0.023	0.067	0.157

*Fuente:* Elaboración propia con base en estimaciones del modelo ALIVIO.

### Análisis de sensibilidad de especificación

Con el fin de evaluar la robustez de las estimaciones municipales, se comparó el modelo EBP–ICAR con dos especificaciones alternativas, estimadas bajo el mismo esquema de ajuste de coherencia estatal (benchmarking): un modelo de error anidado a nivel de individuo, sin componente espacial explícito (NER–EBP), y un modelo que incorpora estructura espacial a través de covariables y filtros espaciales (SLX–ESF).

El modelo NER constituye la especificación estándar de error anidado utilizada en la SAE, donde el efecto aleatorio municipal  $U_i$  se asume independiente e idénticamente distribuido (IID), sin incorporar dependencia espacial explícita entre áreas.

Por su parte, la especificación SLX–ESF introduce información espacial a través del componente sistemático del modelo. En particular, incorpora rezagos espaciales de covariables (SLX) y filtros espaciales basados en vectores propios (ESF), permitiendo capturar patrones territoriales en el predictor lineal. No obstante, el efecto aleatorio municipal permanece IID, por lo que la dependencia espacial no se modela directamente en el término aleatorio.

En contraste, el modelo ICAR incorpora explícitamente la estructura espacial en el componente aleatorio municipal, asumiendo que municipios vecinos presentan efectos

correlacionados. De esta manera, la dependencia espacial se modela como un proceso latente estructurado, permitiendo un suavizamiento espacial directo entre áreas contiguas.

El objetivo no es proponer modelos alternativos, sino verificar que los resultados principales no dependan críticamente de una única especificación. La comparación entre estructuras de efectos aleatorios y configuraciones espaciales constituye una práctica estándar en la validación de modelos jerárquicos espaciales (Blangiardo & Cameletti, 2015). Asimismo, la evaluación de sensibilidad frente a la omisión del componente espacial permite aislar el aporte específico del término ICAR en la reducción de varianza y estabilización territorial (Rao & Molina, 2015).

En particular, la comparación entre el modelo NER clásico y la versión con estructura espacial permite identificar el efecto adicional de suavizamiento inducido por la dependencia territorial explícita, más allá del efecto de encogimiento ya presente en el modelo de error anidado tradicional (Fay & Herriot, 1979; Molina & Rao, 2010).

La comparación entre estimaciones municipales muestra una correlación de  $\rho = 0.593$  entre ICAR y NER, y de  $\rho = 0.896$  entre ICAR y SLX–ESF. La elevada correlación entre ICAR y SLX–ESF indica que ambos modelos espaciales reproducen patrones territoriales similares, mientras que la correlación moderada con el NER sugiere que la incorporación explícita de estructura espacial modifica sistemáticamente la distribución territorial, especialmente en municipios con escasa información muestral. Este comportamiento es consistente con la lógica de modelos jerárquicos espaciales, donde el término estructurado redistribuye información entre dominios contiguos (Besag, 1974; Blangiardo & Cameletti, 2015).

En términos absolutos, el Error Absoluto Medio (MAE) es mayor entre ICAR y NER (0,141 en escala de proporción, equivalente a 14,1 puntos porcentuales) que entre ICAR y SLX–ESF (0.096 puntos), lo que confirma que la principal divergencia ocurre entre modelos con y sin componente espacial. Esta diferencia refleja el aporte adicional del suavizamiento territorial más allá del efecto de encogimiento clásico del modelo de error anidado (Fay & Herriot, 1979; Rao & Molina, 2015).

La comparación de la distribución del coeficiente de variación (CV) muestra una mejora sustantiva bajo el modelo ICAR. La media del CV se reduce de 26.8% en el NER a 13.2% en ICAR, mientras que la mediana pasa de 26.0% a 12.1%. Más del 82% de los municipios presentan  $CV < 20\%$  bajo ICAR, y solo 0.24% supera el umbral de 40%. Además, la media ponderada por población es considerablemente menor en ICAR (6.5%), lo que indica ganancias particularmente relevantes en municipios de mayor tamaño.

En contraste, el modelo NER presenta una concentración en el rango de 25–30%, mientras que el SLX–ESF exhibe mayor dispersión y colas superiores más extensas. La reducción sistemática del CV bajo ICAR es coherente con la teoría de SAE, donde la incorporación de estructura jerárquica y dependencia espacial permite disminuir la varianza sin introducir sesgos sistemáticos cuando el modelo está correctamente especificado (Newhouse et al., 2022).

La reducción promedio del 48,7% respecto al modelo NER, con una mediana de  $-53.3\%$  y un percentil 95 de  $-82.6\%$ . Esto implica que, en la mayoría de los municipios, la inclusión del efecto espacial ICAR reduce aproximadamente a la mitad la incertidumbre asociada a la estimación. La magnitud y consistencia de esta mejora sugieren que el efecto espacial no actúa como un ajuste marginal, sino como un componente estructural que incrementa la eficiencia del estimador en dominios con información limitada, en línea con el principio de aprovechamiento de información auxiliar en SAE (Jiang & Rao, 2020; Rao & Molina, 2015).

El modelo se estima bajo un enfoque plenamente *model-based* a nivel unidad. Los factores de expansión de la ENIGH se incorporan como ponderaciones normalizadas en la verosimilitud para preservar la contribución relativa de cada observación, sin replicar explícitamente el diseño complejo (estratos y UPM) como estructura jerárquica adicional.

La inferencia se fundamenta exclusivamente en la distribución posterior obtenida mediante INLA y no en aproximaciones de varianza derivadas del diseño muestral, por lo que los resultados deben interpretarse dentro del marco *model-based* (Jiang & Rao, 2020; Rao & Molina, 2015). Además, el modelo ya incorpora dependencia territorial explícita a través del componente espacial ICAR. Dado que las UPM suelen presentar concentración geográfica, incluir simultáneamente efectos intra-UPM y espaciales podría generar solapamiento en la

descomposición de varianza y problemas de identificación. En modelos jerárquicos espaciales, la correlación relevante debe modelarse directamente en el término aleatorio correspondiente (Blangiardo & Cameletti, 2015).

En síntesis, los pesos ajustan la contribución observacional, mientras que la dependencia territorial se modela estructuralmente mediante ICAR, en coherencia con el enfoque *a* nivel de individuo model-based (Rao & Molina, 2015).

---

## Discusión

La implementación del modelo EBP–ICAR en el proyecto ALIVIO implica un compromiso metodológico característico de los enfoques model-based: una reducción sustantiva de la varianza a cambio de depender de supuestos estructurales explícitos. En dominios municipales con tamaños muestrales reducidos, los estimadores directos presentan inestabilidad severa e incluso imposibilidad de estimación. La incorporación de efectos aleatorios jerárquicos y estructura espacial permite redistribuir información entre dominios y estabilizar las estimaciones mediante mecanismos de efecto de encogimiento y aprovechamiento de información auxiliar (Fay & Herriot, 1979; Jiang & Rao, 2020; Rao & Molina, 2015).

La evidencia empírica muestra una reducción marcada de la incertidumbre y la ausencia de autocorrelación espacial residual relevante, lo que sugiere que el componente ICAR captura adecuadamente la dependencia territorial del ingreso (Besag, 1974; Blangiardo & Cameletti, 2015). No obstante, esta ganancia en eficiencia depende de la validez de la especificación adoptada y de la estabilidad estructural de las relaciones modeladas.

El modelo combina información del Censo 2020 con la ENIGH 2024, lo que supone estabilidad condicional en la relación entre ingreso y covariables. Aunque este supuesto podría verse comprometido por cambios macroeconómicos recientes, la consistencia entre especificaciones alternativas sugiere que los resultados no están dominados por inestabilidad estructural. Dado que el ingreso per cápita presenta asimetría positiva y posibles valores nulos, se emplea una transformación logarítmica con desplazamiento:

### Ecuación 13

$$y_i^* = \log(y_i + c) \quad (13)$$

donde  $c > 0$  se selecciona endógenamente minimizando la asimetría de la variable transformada. Esta estrategia permite incluir ingresos nulos sin truncamiento y reduce la influencia de valores extremos altos sin recurrir a procedimientos ad hoc. Para reexpresar el ingreso esperado en la escala original, se utiliza el estimador de *smearing* de Duan (1983), garantizando consistencia en la retransformación.

El modelo depende de covariables armonizadas entre ENIGH y Censo. Aunque se aplicaron criterios explícitos de equivalencia conceptual, siempre existe riesgo residual de un desajuste de medición. Sin embargo, la estabilidad de los patrones territoriales y la coherencia entre especificaciones espaciales sugieren que los resultados no responden a artefactos de medición.

La estimación se realiza íntegramente sobre la malla municipal 2020, coherente con la estructura espacial ICAR. La transferencia a la malla 2024 mediante máxima intersección geométrica constituye un ajuste cartográfico que no altera la inferencia estadística ni la varianza estimada, preservando la integridad de la unidad de análisis original (Brinegar & Popick, 2010; Gutiérrez et al., 2022).

Las estimaciones dependen de definiciones oficiales de líneas de pobreza urbana y rural y de la conversión temporal del ingreso. Estos umbrales condicionan la clasificación, por lo que modificaciones institucionales afectarían automáticamente los niveles estimados.

En comparación con ejercicios previos, el modelo ALIVIO integra explícitamente estructura espacial ICAR dentro de un marco a nivel de individuo bayesiano estimado vía INLA (Blangiardo & Cameletti, 2015; Rue et al., 2009). Este enfoque permite capturar heterogeneidad territorial persistente y producir estimaciones completas con medidas formales de incertidumbre.

Aunque ningún modelo estructural está exento del riesgo de mala especificación, los diagnósticos obtenidos (reducción sustantiva de la varianza, atenuación de la dependencia espacial residual y estabilidad frente a especificaciones alternativas) sugieren que las ganancias

de eficiencia no generan distorsiones sistemáticas relevantes. En consecuencia, el enfoque propuesto constituye una herramienta metodológicamente robusta y operativamente viable para la producción periódica de mapas municipales de pobreza monetaria, especialmente en contextos con restricciones muestrales severas.

---

## Conclusiones

Este estudio desarrolla e implementa una metodología de SAE a nivel municipal que integra un predictor empírico tipo EBP con una estructura espacial ICAR estimada mediante INLA. La arquitectura propuesta permite combinar de manera coherente la información muestral de la ENIGH, las covariables exhaustivas del Censo y la dependencia territorial entre municipios, generando estimaciones completas para los 2,469 municipios del país.

Los resultados empíricos muestran que la incorporación del componente espacial produce una mejora sustantiva en precisión respecto a especificaciones sin estructura territorial, particularmente en municipios con escasa o nula muestra. Al mismo tiempo, el modelo mantiene concordancia global con el estimador directo cuando el tamaño muestral es suficiente, reflejando el mecanismo teórico de efecto de encogimiento característico de los enfoques a nivel de individuo. La ausencia de autocorrelación espacial residual relevante y la estabilidad frente a especificaciones alternativas refuerzan la validez empírica de la estructura adoptada.

Desde el punto de vista operativo, el enfoque permite generar mapas municipales de pobreza monetaria con niveles de incertidumbre explícitamente cuantificados, lo que amplía significativamente la capacidad analítica disponible en periodos intercensales. Esta característica es especialmente relevante en contextos donde la representatividad directa a nivel municipal no es viable mediante encuestas tradicionales.

En términos de política pública, esta granularidad permite transitar de una planeación basada en promedios estatales a una focalización de precisión (Saeed & Salvati, 2024). Al identificar 'bolsas de pobreza' que antes quedaban ocultas por el error de muestreo, las autoridades pueden optimizar la asignación de recursos presupuestales y el diseño de programas de infraestructura social básica en los municipios con mayor rezago monetario, contribuyendo a orientar la intervención hacia territorios con menores niveles de ingreso.

No obstante, las estimaciones deben interpretarse dentro del marco model-based adoptado. El modelo depende de supuestos de estabilidad estructural entre fuentes, de la calidad de la armonización de covariables y de la definición oficial de líneas de pobreza monetaria. Asimismo, los resultados se circunscriben a pobreza por ingresos y no sustituyen la medición multidimensional oficial.

Sustantivamente, los hallazgos confirman que la pobreza en México no es un fenómeno aislado por municipio, sino que presenta una fuerte inercia territorial; es decir, la probabilidad de ser pobre está condicionada no solo por las características del hogar, sino por el desempeño socioeconómico de los municipios vecinos. Esta interpretación sugiere que las estrategias de superación de la pobreza deben tener un enfoque regional coordinado, rompiendo la lógica de actuación municipal aislada.

Más allá de la eficiencia estadística, los resultados del modelo ALIVIO ofrecen una interpretación sustantiva sobre la configuración de la pobreza en México; esta no se distribuye de forma aleatoria, sino que presenta una inercia territorial donde la vulnerabilidad de un municipio está intrínsecamente ligada al desempeño de su entorno regional.

La identificación de 'bolsas de pobreza' y clústeres críticos, antes invisibilizados por el error de muestreo en encuestas tradicionales, proporciona a los tomadores de decisiones una hoja de ruta para optimizar la asignación presupuestal. Al reducir la incertidumbre en municipios con 'muestra cero', el enfoque ALIVIO garantiza que la inversión en infraestructura social y programas de transferencia pueda dirigirse con mayor exactitud a los territorios donde la privación de ingresos es estructural, promoviendo una justicia distributiva basada en evidencia estadística granular.

En términos metodológicos, el proyecto contribuye a la literatura aplicada en América Latina (Gutiérrez et al., 2024) al incorporar explícitamente estructura espacial ICAR dentro de un marco a nivel de individuo replicable con datos oficiales. Para asegurar la replicabilidad del enfoque, se subraya la importancia de mantener un diccionario de variables armonizado entre el Censo y la ENIGH, así como el uso de librerías de código abierto para la implementación en INLA, lo que permite que instituciones de estadística locales puedan adoptar el modelo de forma sistemática.

Debe reconocerse que el rigor de estas estimaciones está condicionado a la validez del marco model-based. En primer lugar, la precisión depende críticamente de la estabilidad estructural y la calidad de la armonización entre la ENIGH y el Censo. En segundo lugar, el enfoque asume supuestos de normalidad y linealidad que deben monitorearse ante cambios abruptos en la distribución del ingreso. Finalmente, aunque ALIVIO resuelve con éxito la estimación de pobreza monetaria, esta es solo una dimensión del bienestar; los resultados deben considerarse complementarios y no sustitutos de la medición multidimensional oficial. Como agenda futura, queda pendiente la extensión hacia estructuras espaciotemporales que permitan evaluar el dinamismo de estos indicadores ante choques económicos.

Como líneas de investigación futura se plantea: (i) extender el modelo hacia estructuras espaciotemporales que capturen la evolución de las brechas de ingreso ante choques macroeconómicos, (ii) explorar esquemas alternativos de vecindad que incorporen la conectividad económica y flujos de conmutación laboral, y (iii) profundizar en estrategias de validación externa mediante el uso de fuentes de datos no convencionales (big data o imágenes satelitales) en dominios con muestra cero.

En conjunto, el enfoque ALIVIO ofrece una base técnica robusta para fortalecer la producción de evidencia territorial en México. Al superar la fragmentación de los datos municipales, se facilita un análisis de la desigualdad que reconoce la continuidad del tejido social y económico, apoyando procesos de planeación pública basados en información estadísticamente consistente y espacialmente coherente.

---

### **Consideraciones éticas**

La presente investigación no requirió de aval ético debido a que se basó en documentos de instancias gubernamentales.

---

### **Conflicto de interés**

Todos los autores realizaron aportes significativos al documento y declaran que no existe ningún conflicto de interés relacionado con este artículo.

---

## Declaración de contribución de los autores

Víctor Adrián Morales Linares: conceptualización, metodología, análisis formal, curación de datos, escritura-borrador original.

Beatriz Martínez Carreño: validación, redacción: revisión y edición, supervisión, administración de proyecto, escritura-borrador original

María Isabel Garrido Lastra: conceptualización, investigación, escritura-borrador original, redacción: revisión y edición.

---

## Fuente de financiación

El artículo no cuenta con fuentes de financiamiento.

## Referencias

- (1) Arias, A. (2023). Small area estimates of poverty incidence in Costa Rica under a Structure Preserving Estimation (SPREE) approach. *Journal of Official Statistics*, 39(4), 435–458. <https://doi.org/10.2478/jos-2023-0021>
- (2) Arima, S., Datta, G. S. & Liseo, B. (2015). Bayesian estimators for small area models when auxiliary information is measured with error. *Scandinavian Journal of Statistics*, 42(2), 518–529. <https://doi.org/10.1111/sjos.12120>
- (3) Ballini, F., Betti, G., Carrette, S. y Neri, L. (2006). Mapeo de la pobreza y la desigualdad en la Mancomunidad de Dominica. *Estudios Económicos*, 2, 123–162. <https://doi.org/10.24201/ee.v0i0.384>
- (4) Besag, J. (1974). Spatial interaction and the statistical analysis of lattice systems. *Journal of the Royal Statistical Society: Series B (Methodological)*, 36(2), 192–236. <https://doi.org/10.1111/j.2517-6161.1974.tb00999.x>
- (5) Besag, J., York, J. & Mollié, A. (1991). Bayesian image restoration, with two applications in spatial statistics. *Annals of the Institute of Statistical Mathematics*, 43(1), 1–20. <https://doi.org/10.1007/BF00116466>
- (6) Blangiardo, M. & Cameletti, M. (2015). *Spatial and spatio-temporal Bayesian models with R-INLA*. John Wiley & Sons. <https://doi.org/10.1002/9781118950203>
- (7) Brinegar, S. J. & Popick, S. J. (2010). A comparative analysis of small area population estimation methods. *Cartography and Geographic Information Science*, 37(4), 273–284. <https://doi.org/10.1559/152304010793454327>
- (8) Cameletti, M., Finazzi, F. & Lindgren, F. (2013). Spatio-temporal integrated nested Laplace

- approximation for disease mapping. *Advances in Statistical Analysis*, 97(2), 241–261. <https://doi.org/10.1007/s10182-012-0196-3>
- (9) Chandra, H., Salvati, N. & Chambers, R. (2018). Small area estimation under a spatially non-linear model. *Computational Statistics & Data Analysis*, 126, 19–38. <https://doi.org/10.1016/j.csda.2018.04.002>
- (10) Comisión Económica para América Latina y el Caribe (CEPAL). (2025). *Definición de ingreso corriente per cápita*. Naciones Unidas. <https://www.cepal.org/es>
- (11) Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL). (2020). *Metodología para la medición multidimensional de la pobreza en México* (3.ª ed.). CONEVAL. <https://www.coneval.org.mx/InformesPublicaciones/InformesPublicaciones/Documents/Metodologia-medicion-multidimensional-3ed.pdf>
- (12) Duan, N. (1983). Smearing estimate: A nonparametric retransformation method. *Journal of the American Statistical Association*, 78(383), 605–610. <https://doi.org/10.1080/01621459.1983.10478017>
- (13) Fay, R. E. & Herriot, R. A. (1979). Estimates of income for small places: An application of James-Stein procedures to census data. *Journal of the American Statistical Association*, 74(366a), 269–277. <https://doi.org/10.1080/01621459.1979.10482505>
- (14) Foster, J., Greer, J. & Thorbecke, E. (1984). A class of decomposable poverty measures. *Econometrica*, 52(3), 761–766. <https://doi.org/10.2307/1913475>
- (15) Gutiérrez, A., Mancero, X. & Guerrero, S. (2022). Poverty mapping in Latin America. *Statistical Journal of the IAOS*, 38(3), 1021–1033. <https://doi.org/10.3233/SJI-220037>
- (16) Gutiérrez, A., Mancero, X. & Trujillo, L. (2024). Poverty mapping in Latin America using advanced small area estimation models. *Journal of Official Statistics*, 40(3), 615–639. <https://doi.org/10.3233/SJI-220037>
- (17) INEGI. (2024). *Encuesta Nacional de Ingresos y Gastos de los Hogares (ENIGH) 2024*. INEGI. <https://www.inegi.org.mx/programas/enigh/nc/2024/>
- (18) Instituto Nacional de Estadística y Geografía (INEGI). (2020). *Censo de Población y Vivienda 2020*. INEGI. <https://www.inegi.org.mx/programas/ccpv/2020/>
- (19) Jiang, J. & Rao, J. N. (2020). *Small area estimation*. John Wiley & Sons. <https://doi.org/10.1002/9781118445112.stat03310.pub2>
- (20) Lange, S., Pape, U. J. & Pütz, P. (2022). Small area estimation of poverty under structural change. *Review of Income and Wealth*, 68(S2), S264–S281. <https://doi.org/10.1111/roiw.12558>
- (21) Marchetti, S., Giusti, C., Schirripa, F., Bertarelli, G. & Biggeri, L. (2024). The impact of

- local cost-of-living differences on relative poverty incidence: An application using retail scanner data and small area estimation models. *Statistical Methods & Applications*, 33(4), 1117–1143. <https://doi.org/10.1007/s10260-023-00742-w>
- (22) Molina, I. & Rao, J. N. K. (2010). Small area estimation of poverty indicators. *Canadian Journal of Statistics*, 38(3), 369–385. <https://doi.org/10.1002/cjs.10051>
- (23) Molina, I. (2024). *Frontiers in small area estimation research: Application to welfare indicators (Policy Research Working Paper No. 10828)*. World Bank. <https://doi.org/10.1596/41801>
- (24) Morales, D., Esteban, M. D., Pérez, A. & Hobza, T. (2021). *A course on small area estimation and mixed models*. Springer. <https://doi.org/10.1007/978-3-030-63757-6>
- (25) Mweemba, C., Hangoma, P. & Masiye, F. (2022). Estimating district HIV prevalence using SAE. *Population Health Metrics*, 20(1), 22. <https://doi.org/10.1186/s12963-022-00286-3>
- (26) Newhouse, D., Ramakrishnan, A., Swartz, T., Merfeld, J. & Lahiri, P. (2022). *Small area estimation of monetary poverty in Mexico using satellite imagery (Policy Research Working Paper N.º 10123)*. Banco Mundial. <https://doi.org/10.1111/obes.12678>
- (27) Possolo, A. (2023). Tracking truth through measurement and the spyglass of statistics. *Statistical Science*, 38(4), 655–671. <https://doi.org/10.1214/23-STS899>
- (28) Purwa, T., Rumiati, A. T. & Zain, I. N. (2019). Small area estimation with bivariate hierarchical Bayes (HB) approach to estimate monthly average per capita expenditure of food and non-food commodities in Province of Bali. *IOP Conference Series: Materials Science and Engineering*, 546(5), 052054. <https://doi.org/10.1088/1757-899X/546/5/052054>
- (29) Rao, J. N. K. & Molina, I. (2015). *Small area estimation* (2.<sup>a</sup> ed.). John Wiley & Sons. <https://doi.org/10.1002/9781118735855>
- (30) Rue, H., Martino, S. & Chopin, N. (2009). Approximate Bayesian inference for latent Gaussian models by using integrated nested Laplace approximations. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 71(2), 319–392. <https://doi.org/10.1111/j.1467-9868.2008.00700.x>
- (31) Saeed, M. & Salvati, N. (2024). Spatial autocorrelation and business-cycle effects on regional poverty mapping. *Spatial Economic Analysis*, 19(2), 201–224. <https://doi.org/10.3390/ijgi12120501>
- (32) Simpson, D. P., Rue, H., Riebler, A., Martins, T. G. & Sørbye, S. H. (2017). Penalising model component complexity: A principled, practical approach to constructing priors. *Statistical Science*, 32(1), 1–28. <https://doi.org/10.1214/16-STS576>