

Modelación de la sobrepoblación relativa en el estado de Chiapas: análisis espacial bayesiano

Modeling the relative overpopulation in the state of Chiapas: bayesian spatial analysis

CUAUHTÉMOC CALDERÓN VILLARREAL*

GERARDO NÚÑEZ MEDINA*

LETICIA HERNÁNDEZ BIELMA*

Abstract

The objective of this paper was to identify spatial distribution patterns of relative overpopulation, measured through the economically active population and migration in localities of the state of Chiapas in the year 2020. Exploratory spatial data analysis techniques and latent Gaussian models were applied, and the immigration rate was used as a covariate in two different empirical models. The models were fitted using the R-INLA package. The results suggest the existence of a set of spatial clusters and/or groupings of EAP around the capital of the state of Chiapas.

Keywords: labor market, gaussian models, spatial distribution, Chiapas.

Resumen

El objetivo de este trabajo es identificar patrones de distribución espacial de la sobrepoblación relativa, medida por la Población Económicamente Activa y la migración, en localidades del estado de Chiapas en 2020. Se aplican técnicas de análisis exploratorio de datos espaciales y modelos gaussianos latentes y se utiliza la tasa de inmigración como covariable en dos modelos empíricos distintos. El ajuste de dichos modelos se realiza empleando el paquete R-INLA. Los resultados parecen indicar la existencia de un conjunto de conglomerados y agrupaciones espaciales de PEA alrededor de la capital del estado de Chiapas.

Palabras clave: oferta laboral, modelos gaussianos, distribución espacial, Chiapas.

* El Colegio de la Frontera Norte, correos-e: calderon@colef.mx, gnunez@colef.mx y leticiah@colef.mx

Introducción

En las últimas décadas, el estado mexicano de Chiapas se ha convertido no sólo en expulsor de fuerza laboral sino también en sitio de tránsito de flujos de fuerza de trabajo que se dirigen a los Estados Unidos de América provenientes, principalmente, de Centroamérica y del Caribe; de esta manera, la sobrepoblación relativa ha aumentado y se ha distribuido a lo largo del territorio de acuerdo con patrones espaciales específicos que modifican la estructura del mercado laboral de la región transfronteriza entre México y Guatemala (Castillo y Vázquez-Olivera, 2010; Morales Gamboa, 2016; Nájera-Aguirre, 2017); aunque hasta el momento este fenómeno ha sido poco estudiado y documentado, su análisis permitirá comprobar la existencia de un mercado laboral transfronterizo dinámico –nutrido de los flujos de migrantes provenientes de Centroamérica y del Caribe– entre México y Guatemala.

El objetivo principal de este trabajo es identificar y modelar los patrones de distribución espacial de la sobrepoblación relativa en el estado de Chiapas a partir del comportamiento de la Población Económicamente Activa (PEA) y la migración, esto con el fin de identificar dichos patrones y los cambios en el mercado laboral para la totalidad de localidades reportadas como habitadas por el Censo de Población y Vivienda 2020, levantado por el Instituto Nacional de Estadística y Geografía (Inegi).

En primer lugar se realizó un análisis exploratorio de datos con la finalidad de obtener evidencia acerca de la existencia de una estructura espacial generada por la correlación entre la PEA, la migración y el espacio geográfico, lo que permitió describir, visualizar y analizar espacialmente las variables; en segundo lugar se modelaron los patrones espaciales a partir de la formulación, estimación y contraste de dos modelos gaussianos latentes; la aplicación de este tipo de modelos fue fundamental, ya que permitió cuantificar el efecto que ejercen los flujos de población migrante sobre el comportamiento de la Población Económicamente Activa (PEA).

El artículo está integrado por cuatro secciones: en la primera se abordan las definiciones y conceptos teóricos sobre el mercado laboral, la PEA y la inmigración; en la segunda se realiza un análisis exploratorio espacial de las variables; en la tercera se lleva a cabo la modelización geoestadística de la sobrepoblación relativa y en la última se presentan y discuten los principales hallazgos y resultados del trabajo.

1. Mercado laboral, Población Económicamente Activa y tasa de inmigración

La estructura espacial específica de los mercados laborales regionales está determinada por la oferta (crecimiento de la población, flujos migratorios, pirámide de edades, escolaridad y PEA) y la demanda (estructura económica estatal, sectorial y regional, nivel de inversión, Formación Bruta de Capital Fijo (FBKF), perfil contractual y perfil salarial); los flujos migratorios y la distribución espacial del empleo regional (o estatal) están determinados por los factores de la demanda (Acemoglu y Autor, 2011; Keynes, 1943; Nurkse, 1960).

Así, el comportamiento y los desequilibrios del mercado laboral dependen de la estructura económica, del nivel de inversión, de la acumulación del capital y del nivel de desarrollo económico regional (Ross, 2010; Aleksynska, 2014). La demanda laboral está dada por el conjunto de empresas que utilizan fuerza de trabajo para la producción de bienes o servicios en los diferentes sectores y ramas de la economía, y que buscan maximizar su tasa de ganancia (Krusell *et al.*, 2000; Acemoglu, 2002).

Del lado de la oferta laboral, la PEA define la capacidad del trabajo (o trabajo potencial) a partir de la edad, del sexo, del nivel educativo y del grado de calificación y experiencia (Katz y Murphy, 1992; Becker *et al.*, 1999), y depende fundamentalmente de la dinámica de la inversión. La PEA se clasifica como ocupada y desocupada (desempleada), según el Inegi (2020), la primera se integra por personas de 12 años o más quienes realizaron alguna actividad económica durante al menos una hora en la semana, lo que incluye a los que desarrollaron una actividad económica sin recibir un salario, así como a aquéllos que, por alguna razón, dejan de trabajar temporalmente sin perder el vínculo laboral. La PEA desocupada está compuesta por las personas que durante la semana de referencia no trabajaron ni contaban con un trabajo, y que declararon haber desarrollado al menos uno con anterioridad (Inegi, 2021).

Las tasas de inmigración por localidad se definen como el cociente de la población que durante los últimos cinco años llegó a vivir a la localidad, población de cinco años y más residente en la misma (Kuznets, 1971; Borjas, 1994). En este caso, el uso de tasas permite identificar un patrón de distribución espacial de inmigración y definir los flujos migratorios.

2. Análisis exploratorio de datos espaciales

De acuerdo con la literatura, el análisis exploratorio de datos espaciales permite identificar correlaciones y descubrir la presencia de estructuras susceptibles de ser modeladas (Cressie, 1985; Acevedo Bohórquez y

Velásquez Ceballos, 2008). De acuerdo con Chasco (2003), las técnicas econométricas espaciales permiten demostrar la existencia de autocorrelación espacial entre variables e identificar las agrupaciones espaciales, los clústeres o los conglomerados surgidos a partir del llamado efecto *spillover*, o efecto de desbordamiento espacial, que se da cuando los valores altos de una variable son rodeados por valores altos de la misma. Dicho efecto implica la existencia de una autocorrelación espacial positiva entre la variable analizada y el espacio.

Nuestra área geográfica de estudio es el estado de Chiapas, que tiene una extensión territorial de poco más de 73,000 kilómetros cuadrados, divididos políticamente en 124 municipios y 26,404 localidades. Se ubica entre las coordenadas extremas norte 17°59', sur 14°32' de latitud norte y este 90°22', oeste 94°14' de longitud oeste, dentro de la región sureste de la república mexicana; colinda al norte con el estado de Tabasco, al sur con la República de Guatemala y el Océano Pacífico, al este con la República de Guatemala y al oeste con el Océano Pacífico y los estados de Oaxaca y Veracruz (anexo 1).

En particular, se busca analizar la capacidad estructural de las localidades de Chiapas para generar empleo y atraer una mayor cantidad de Población Económicamente Activa. La hipótesis se estructura bajo el supuesto de que la demanda de trabajo va a permitir identificar patrones espaciales de inmigración, en el entendido de que las localidades con bajas tasas de inmigración serán aquellas donde la actividad económica es menor o menos atractiva. Específicamente, se tiene como objetivo medir el efecto de la inmigración sobre la distribución espacial de la PEA por localidad.

Es importante señalar que los datos utilizados para estimar, tanto la proporción de PEA como las tasas de inmigración municipal, provienen del Censo de Población y Vivienda 2020 levantado por el Inegi. En este caso, se utilizó información relativa a la Población Económicamente Activa y a la población que declaró habitar en otra localidad hace cinco años o más (i.e. la población que inmigró a la localidad durante el quinquenio 2015-2020). Los datos recabados hacen referencia a un total de 21,157 localidades habitadas en Chiapas al 2020.


En términos generales, es de esperarse que la sobrepoblación relativa provoque el desarrollo de patrones de distribución espacial que incentiven el surgimiento y consolidación de conglomerados constituidos a partir de criterios de vecindad, basados en los niveles observados (altos y bajos) de PEA entre localidades, esto implicaría que la sobrepoblación relativa estaría asociada a una estructura de vecindades, donde la posición geográfica de una localidad, asociada a aspectos como la proximidad a la cabecera municipal o el número de vecinos, desempeña un papel fundamental en la definición del nivel medio de la PEA existente en la localidad.

Para modelar el comportamiento espacial de la PEA se estudió su distribución en función de la tasa de inmigración por localidad para el periodo 2015-2020, que comprende los flujos nacionales e internacionales (Pressat, 1967). Es de esperar que las variaciones espaciales registradas en el nivel de inmigración, observadas en cada localidad, ejerzan un efecto importante sobre el comportamiento de la oferta laboral disponible por localidad. La variable x_i captura la tasa de inmigración durante el periodo 2015-2020 (Delaunay, 2007).

La detección de patrones de autocorrelación espacial (univariada y bivariada) para las variables señaladas se efectuó mediante el uso de variogramas y técnicas de interpolación espacial como *kriging*. En general, un variograma se define en términos de la varianza $\text{var}[z(s_i), z(s_o)]$ de la variable observada z en las localidades s_i y s_o para determinar la similitud entre observaciones. En presencia de autocorrelación espacial el variograma presenta magnitudes pequeñas cuando la distancia entre s_i y s_o es pequeña y magnitudes mayores cuando la distancia se incrementa (Anselin, 1995; Ord, 1975).

Las figuras 1, 2 y 3 muestran la dispersión espacial de cada una de las localidades de Chiapas respecto al porcentaje de PEA (figura 1); al porcentaje de población inmigrante (figura 2) y al porcentaje de la relación

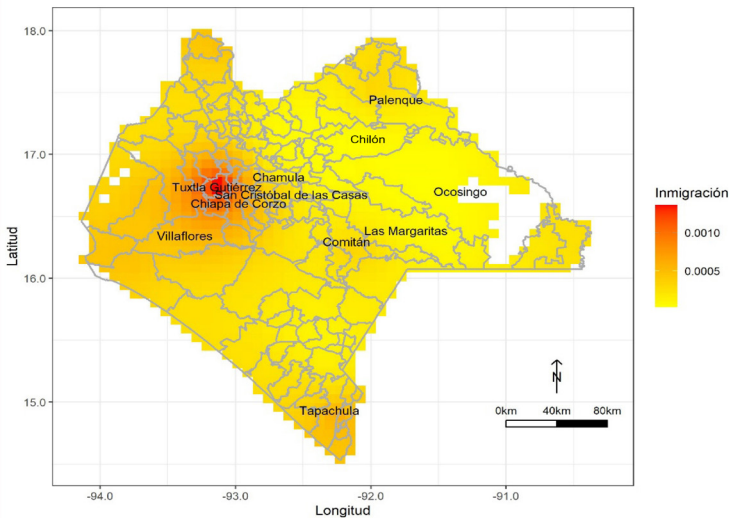
Figura 1
Interpolación espacial univariada de la PEA en localidades de Chiapas 2020



Fuente: elaboración propia con datos del Censo de Población y Vivienda 2020 (Inegi, 2020).

PEA-población inmigrante (figura 3). La escala de la figura 1 va del porcentaje relativo más bajo (menor al 3% de la PEA), con tonalidades amarillas, al más alto (con porcentajes superiores al 5%), con tonalidades rojas, a partir de lo cual es posible identificar un conglomerado de localidades con alta (o baja) densidad de la PEA, que de acuerdo con la figura 1 corresponde a aquellas localidades ubicadas alrededor del municipio de Tuxtla Gutiérrez, Chiapas, capital del estado.

Figura 2
Interpolación espacial de la tasa de inmigración, Chiapas 2020

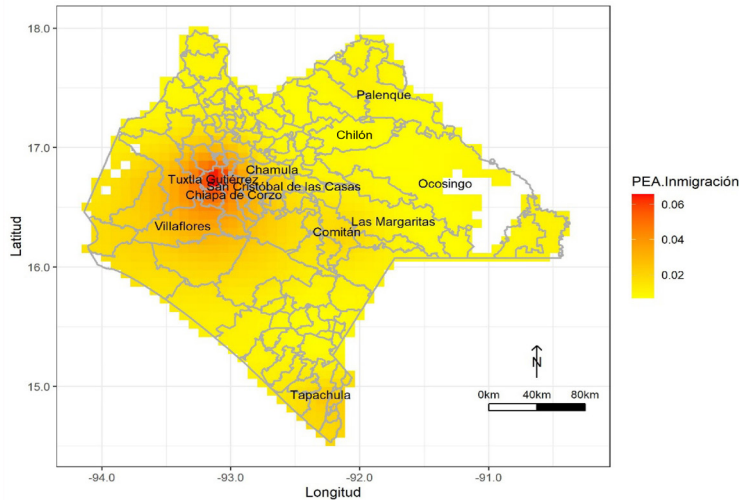


Fuente: elaboración propia con datos del Censo de Población y Vivienda 2020 (Inegi, 2020).

La interpretación de las figuras 2 y 3 es similar a la realizada para la figura 1. En el caso de las figuras 2 y 3, de acuerdo con sus respectivas escalas, se revela el mismo comportamiento, con presencia de conglomerados espaciales de alta densidad alrededor de la capital del estado, lo cual pone de manifiesto un comportamiento espacial análogo en las variables analizadas.

La figura 2 identifica un patrón espacial de inmigración en el que, básicamente, las localidades ubicadas en la capital de Chiapas (Tuxtla Gutiérrez) y sus alrededores reciben flujos significativos de inmigrantes y constituyen un conglomerado de alta concentración que se observa en color rojo. Además, existen tres concentraciones medias a bajas, en color amarillo-naranja, ubicadas alrededor de las ciudades de Tapachula, Comitán y Palenque. El resto de la entidad tiene tasas de inmigración relativa-

Figura 3
Correlación espacial bivariada de la PEA y la tasa de inmigración por localidad, Chiapas 2010



Fuente: elaboración propia con datos de Inegi (2020) y Conapo (2018).

mente bajas que configuran un gran conglomerado de baja atracción migratoria, presentado en color amarillo claro.

A partir del método Kriging se interpola el valor de una variable considerando un conjunto de puntos seleccionados dentro de un campo espacial y se estima la estructura de covarianza de los puntos observados por medio de un variograma (Cressie, 1985; Chasco, 2003). Las principales ventajas de este método, sobre el resto de los estadísticos tradicionales, son que incorpora la autocorrelación espacial y mide el grado de la precisión de las estimaciones resultantes, mientras que su principal desventaja radica en la necesidad de que el semivariograma sea estacionario.

Por otra parte, el uso de la correlación espacial bivariada permite identificar patrones espaciales generados a partir de la interacción de dos variables con el espacio. La figura 3 presenta la correlación de la oferta laboral y la tasa de inmigración e identifica conglomerados donde ambas variables alcanzan niveles bajos o altos, lo que se representa como el porcentaje conjunto de PEA e inmigración por localidad. De esta forma, la figura 3 muestra un importante conglomerado con altos niveles de correlación espacial (en color rojo) ubicado en torno al municipio de Tuxtla Gutiérrez, mientras que en prácticamente el resto del territorio chiapaneco se observa un gran conglomerado con bajos niveles de correlación espacial entre las tasas de inmigración y la oferta laboral (en color amarillo).

Es importante señalar que los métodos de interpolación espacial tipo kriging ajustan el comportamiento de la(s) variable(s) analizada(s) en relación con el espacio geográfico, pero evidentemente este tipo de métodos no generan estimaciones sobre el valor esperado en áreas donde no se proporcionó información o donde se carece de datos, como es el caso de algunas localidades ubicadas en los municipios de Ocosingo y Cintalapa, observadas en las figuras 1, 2 y 3, en las cuales –debido a la falta de información originada por la ausencia de localidades en dichos municipios– pueden verse espacios blancos, tal como lo confirma la distribución de localidades presentada en la figura 4.

3. Modelación geoestadística

La estimación de los parámetros del modelo gaussiano latente, que considera a la PEA como la variable dependiente y la tasa de inmigración como variable independiente, se realizó empleando el paquete R-INLA, mientras que los variogramas de correlación espacial univariados y bivariados realizados en el apartado anterior fueron ajustados utilizando el paquete gstat, ambos disponibles en el lenguaje de programación R (R Core Team, 2018).

La modelación espacial de la oferta laboral, medida a partir de los datos de la PEA de las localidades de Chiapas, tiene por objeto identificar los mecanismos y el proceso subyacente que da origen a los datos observados, además estima el valor de los componentes paramétricos que especifican su distribución espacial, para lo cual, la variable respuesta Y_i representa la proporción de Población Económicamente Activa en cada localidad del estado de Chiapas, al año 2020, proporción que es referenciada al punto $i \in \mathbb{R}^2$ a partir de las coordenadas (latitud, longitud), mismas que definen el dominio espacial del proceso estocástico de generación de los datos (Blangiardo y Cameletti, 2015; Getis y Ord, 1992).

La distribución de probabilidad asociada a los datos observados Y_i está en función de la distribución del vector θ de parámetros y al vector ψ de hiperparámetros, y se define a partir de:

$$Y \mid \theta, \psi \sim \prod_i f(y_i \mid \theta, \psi, \eta_i)$$

donde los vectores θ y ψ de la distribución Y son definidos a partir del valor esperado:

$$E(Y \mid \eta) = f^{-1}(\eta).$$

De manera que la respuesta media Y_i se mapea mediante una función de enlace al predictor lineal η , que toma la forma de un modelo de regresión aditivo estructurado (Rue y Lindgren, 2015), también conocido como modelo gaussiano latente, cuya forma está dada por:

$$\eta_i = \beta_0 + \sum_{m=1}^M \beta_m x_{mi} + \xi_i + u_i \quad (1)$$

donde la i -ésima observación y_i sigue una distribución de la forma:

$$y_i \sim \text{Normal}(\eta_i, \sigma_e^2)$$

σ_e^2 es la varianza del error e_i , que se supone independiente de e_j cuando $i \neq j$, y se conoce como efecto pepita (o efecto *nugget* en inglés) (Ingebrigtsen *et al.*, 2014).

El término

$$\beta_0 + \sum_{m=1}^M \beta_m x_{mi}$$

representa el predictor lineal de efectos fijos, mientras que el término representa la i -ésima observación registrada de un campo aleatorio gaussiano latente, cuya finalidad es capturar el efecto de las covariables no incluidas explícitamente en el modelo, pero que impactan sobre el valor de la respuesta observada a través de variaciones espacialmente estructuradas (Rozanov, 1982). La función de distribución de ξ está dada por:

$$\xi \mid \psi \sim MN(0, Q^{-1}(\psi))$$

donde $Q(\psi)$ se modela a partir de la función de covarianza espacial de Matérn, definida como:

$$C(\Delta_{ij}) = \frac{1}{\Gamma(\alpha)2^{\alpha-1}} (\kappa \Delta_{ij})^\alpha K_\alpha(\kappa \Delta_{ij}) \quad (2)$$

la cual depende de la distancia euclidiana entre dos observaciones dadas cualquiera:

$$\Delta_{ij} = ||s_i - s_j||.$$

El parámetro K_α denota la función de Bessel modificada de segundo orden (Rue y Held, 2005) y el parámetro $\alpha = r - d/2$ mide el grado de suavizamiento del proceso espacial, cuya varianza marginal se define como:

$$\sigma^2 = \frac{\Gamma(\alpha)}{\Gamma(r)(4\pi)^{d/2} \kappa^2 \alpha \tau^2}$$

$k > 0$ es un parámetro de escalamiento relacionado con la distancia a partir de la cual la correlación espacial tiende a anularse (Rue *et al.*, 2009).

La distribución de las observaciones se define en términos de la función de verosimilitud dado el vector de parámetros $\theta = \{\beta_0, \beta_p, \xi\}$, y el vector de hiperparámetros ψ , de manera que:

$$P(\tilde{Y}|\theta, \tilde{\psi}) = \prod_{i=1}^n P(y_i|\tilde{\theta}_i, \tilde{\psi}) \quad (3)$$

Adicionalmente, el modelo incluye un efecto aleatorio espacial no estructurado, u_i , que captura los efectos de las características no medidas que afectan el nivel medio de PEA en las localidades (Rue y Lindgren, 2015), donde cada uno de los u_i sigue una distribución gaussiana independiente, con media cero y precisión τ_u .

3.1. Implementación del modelo

La modelación de un campo aleatorio gaussiano continuo (GF) se complejiza al incrementar el número de observaciones, por lo que la forma más utilizada para simplificar dicho problema es el enfoque basado en ecuaciones diferenciales parciales estocásticas (SPDE), donde un campo gaussiano continuo (GF) es representado a través de un campo aleatorio gaussiano markoviano discreto (GMRF), dada la triangulación del dominio espacial (Lindgren *et al.*, 2011); el GMRF captura las dependencias espaciales sobre una malla triangular que permite definir una estructura de vecindades.

La triangulación del dominio espacial donde se localiza la totalidad de datos analizados se hace a partir del enfoque SPDE (Rue y Lindgren, 2015), mismo que utiliza una serie de combinaciones lineales de funciones tipo *spline* sobre las ubicaciones de los vértices de la triangulación para representar el campo aleatorio discreto GMRF dada la ecuación:

$$\xi(s) = \sum_{g=1}^G \varphi_g(s) \tilde{\xi}_g \quad (4)$$

Donde G es el número total de vértices en la triangulación, $\{\varphi_g\}$ es un conjunto de funciones lineales básicas, y $\{\tilde{\xi}_g\}$ representa un conjunto de ponderadores espaciales gaussianos con media cero (Fuglstad *et al.*, 2015). En general, la función base $\{\varphi_g\}$ es igual a 1 en el vértice g y 0 en los demás vértices, tal y como se muestra en la figura 4.


Una vez que el campo aleatorio (GF) es descrito en términos de la ecuación 4, se obtiene un mapeo de la función de covarianza (ecuación 2) del campo gaussiano a la matriz de precisión Q , de modo que el modelo espacial puede reescribirse en términos de un GMRF (Rue *et al.*, 2009). La matriz de precisión Q se define de forma que para cualquier localidad i distinta de j se tiene:

$$i \notin \text{vecindad}\{j\} \Leftrightarrow Q_{ij} = 0$$

Por lo que la dependencia condicional basada en esta estructura de vecindades genera una matriz Q dispersa, con importantes ventajas computacionales (Blangiardo y Cameletti, 2015; Lindgren *et al.*, 2011).

Con la finalidad de obtener una buena definición del modelo, durante el proceso de triangulación se definen triángulos de tamaño y forma regular, además se extiende la triangulación más allá de los límites del dominio espacial con la finalidad de evitar el llamado efecto límite, cuya consecuencia resulta en una sobreestimación artificial de la varianza en los puntos cercanos a la frontera (figura 4) (Lindgren *et al.*, 2011). La triangulación del

Figura 4
Triangulación de la PEA, localidades de Chiapas 2020



Fuente: elaboración propia con datos del Censo de Población y Vivienda 2020 (Inegi, 2020).

dominio espacial para todas las localidades de Chiapas puede también verse en la figura 4, la cual contiene un total de 346 vértices.

Así, la figura 4 presenta tanto la distribución espacial de todas las localidades de Chiapas, al 2020, como la partición del territorio chiapaneco (entendido como un campo espacial continuo) mediante una sucesión de triángulos que permite transformar un espacio continuo en uno discreto y, por lo tanto, es capaz de capturar las dependencias espaciales mediante una estructura de vecindades homogénea.

Es importante señalar que los métodos de interpolación tipo kriging ajustan el comportamiento espacial de la(s) variable(s) analizada(s) en relación con el espacio geográfico, sin embargo, como se planteó, no genera estimaciones sobre el valor esperado en áreas donde no existe información.

3.2. Parámetros e hiperparámetros

El último elemento de la definición del campo aleatorio gaussiano markoviano discreto se obtiene al fijar los valores iniciales del vector de parámetros $\theta = \{\beta_0, \beta_r, \xi\}$, y del vector de hiperparámetros $\psi = \{\sigma_e^2, k, \sigma_{rf}^2\}$, donde k y σ_{rf}^2 son parámetros de la función de covarianza de Matérn, definidos en la ecuación 2 (Fuglstad *et al.*, 2015). La representación interna en R-INLA para la aproximación SPDE de los parámetros establece las especificaciones previas de las distribuciones en términos de:

$$\sigma^2 \approx \frac{1}{4\pi\kappa^2\tau^2}$$

$$r \approx \frac{\sqrt{8}}{\kappa}$$

Los valores iniciales asignados fueron: $k=0.75$ y $\alpha=2$, para el vector de parámetros, mientras que los valores asignados a la distribución inicial del vector de parámetros fueron: $\beta_0 \sim N(0, \tau^1)$, y la especificación del componente de efectos fijos $\beta_1 \sim N(0, 1/0.001)$.

La especificación previa del vector de pesos espaciales $\xi = (\xi_1, \dots, \xi_n)'$ se asignó a una distribución gaussiana $\xi \sim N(0, Q^{-1})$, donde Q es una matriz de precisión dispersa que depende de la función de covarianza Matérn, dada por la ecuación 2.

3.3. Ajuste y selección de modelos

Uno de los principales objetivos del campo aleatorio gaussiano markoviano discreto es la predicción del nivel medio de la PEA para las localidades

donde no se dispone de información o para localidades de nueva creación. A partir del marco teórico establecido y de las correlaciones espaciales observadas entre la PEA y la covariable x_i (tasa de inmigración), se construyeron dos modelos: uno nulo y uno de efectos fijos dado por la ecuación 1.

Los modelos comprenden un modelo sin covariables o modelo nulo y un modelo con la covariable PEA, éstos se numeraron como M0 y M1 de acuerdo con la definición, el modelo M0 es de efectos aleatorios, que ajusta el comportamiento de la PEA sólo en función del efecto espacial y es el modelo de comparación o nulo, mientras que el modelo M1 se conformó con la covariable tasa de inmigración como efecto fijo, más la parte de efecto espacial.

Los modelos propuestos fueron ajustados utilizando el método “integrated nested Laplace approximation” (INLA por sus siglas en inglés), implementado en el paquete R-INLA desarrollado para su utilización en el lenguaje de programación R-project en su versión 3.15. La utilización de R-INLA permitió realizar una inferencia bayesiana rápida y eficiente de los modelos gaussianos latentes propuestos (Martins *et al.*, 2013).

El enfoque INLA resulta ser una alternativa computacionalmente eficiente y por lo tanto menos costosa que el método tradicional MCMC (Gamerman y Lopes, 2006). El uso de INLA permite aproximar los marginales posteriores del campo gaussiano latente en tres pasos:

- 1) Ajusta la distribución posterior de θ utilizando la aproximación de Laplace a partir de la ecuación 3.
- 2) Utiliza una versión simplificada de Laplace para estimar la distribución del GMRF, dados los valores estimados de θ , lo que mejora la aproximación gaussiana establecida en la ecuación 4.
- 3) Estima los parámetros restantes a partir de la siguiente ecuación:

$$P(\theta, \tilde{\psi} | Y) \propto P(\tilde{\psi}) \times |Q(\psi)|^{\frac{1}{2}} \cdot \exp\left(-\frac{\theta^t}{2} Q(\psi) \theta + \sum_{i=1}^n \log(P(y_i | \theta_i))\right) \quad (5)$$

que combina las ecuaciones 3 y 4 mediante el uso de métodos de integración numérica (Cressie, 1993). El modelo supone independencia condicional entre el campo gaussiano latente y el vector de parámetros θ .

Una vez estimados los modelos M0 y M1, la forma de identificar el modelo que presenta la combinación de variables más adecuada para explicar el comportamiento de la PEA es a través del criterio de información de Akaike (AIC). Se optó por el uso del criterio de selección AIC, dado que permite ponderar entre la complejidad y la capacidad explicativa de cada modelo, al utilizar la función de máxima verosimilitud y el número de parámetros ajustados por cada modelo como medidas de bondad de ajuste.

El criterio AIC selecciona el modelo que alcanza el AIC más pequeño en términos de:

$$AIC = -2l(\hat{\theta}) + 2k$$

donde $l(\hat{\theta})$ es la función de máxima de log-verosimilitud y k es el número de parámetros estimados del modelo (Blangiardo y Cameletti, 2015). Los resultados de las estimaciones para ambos modelos se presentan en la tabla 1; donde, bajo el criterio AIC, el mejor ajuste para el comportamiento espacial de la PEA en las localidades de Chiapas al 2020, lo presenta el modelo M1.

4. La sobrepoblación relativa en localidades de Chiapas

4.1. Modelos

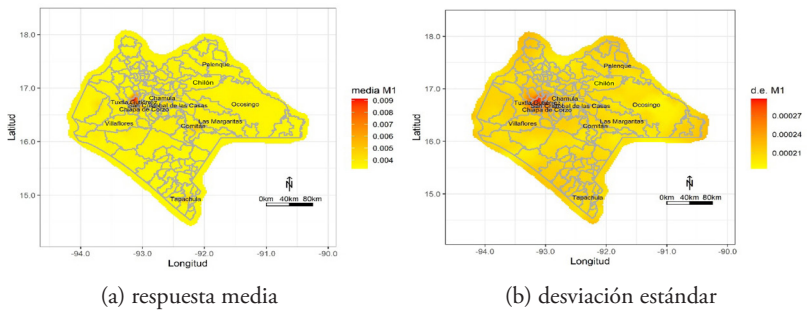
El proceso de estimación bayesiano del campo aleatorio gaussiano markoviano discreto permitió obtener estimaciones del comportamiento espacial de la oferta laboral por localidad, las cuales pueden verse en la figura 5 (a y b). Las figuras representan la distribución estimada del predictor lineal 5(a) y su desviación estándar 5(b), según el modelo nulo M0, mientras que las figuras 6 (a y b) representan la distribución posterior de la oferta laboral y su desviación estándar respectivamente, según las estimaciones obtenidas por el modelo M1.

El modelo M1, presentado en la tabla 2, tiene como finalidad estimar el comportamiento espacial del campo aleatorio (GF), mismo que se muestra en la figura 5(a). M1 supone que la media posterior del predictor lineal tiene una distribución normal multivariada a partir de la cual se estima la respuesta media presentada en el gráfico espacial, en escala natural (Krainski *et al.*, 2016; Nychka *et al.*, 2013), mientras que la parte de efectos fijos del modelo M1 evalúa el efecto que la covariable (x_i) tasa de inmigración ejerce sobre los niveles de la oferta laboral local. La estimación de los efectos fijos del modelo M1 puede observarse con mayor detalle en la tabla 2.

Los resultados de las estimaciones obtenidas para la parte de efectos fijos de los modelos M0 y M1 pueden observarse en la tabla 1, en la cual se presenta el valor estimado del estadístico derivado del criterio de información AIC alcanzado para cada modelo; valor que permite identificar el mejor modelo M1 para el ajuste de los niveles de PEA por localidad. Además, la elección de M1 se basó en los criterios siguientes: 1. la variable tasa de inmigración demostró ejercer un importante efecto sobre el comportamiento de la PEA por localidad y 2. la diferencia absoluta del AIC entre ambos modelos es superior a los mil puntos.

La figura 5(a) muestra la distribución espacial de la PEA en el mismo sentido que la figura 1, sin embargo, la primera incluye los efectos fijos y los efectos espaciales incorporados por el modelo M1. En la figura 5(a) se observa un patrón de localidades donde la oferta laboral es alta, lo que dibuja un conglomerado de color rojo alrededor de la capital Tuxtla Gutiérrez, el cual coincide con la concentración de población y población activa del estado, junto con pequeñas concentraciones en los municipios de Tapachula y Comitán.

Figura 5
Respuesta media estimada y desviación estándar de la PEA,
según modelo M1



Fuente: elaboración con datos de Inegi (2020) y Conapo (2018).

Se debe resaltar que el uso de modelos espaciales bayesianos permite estimar el valor esperado de la proporción relativa de PEA, a pesar de que en ciertas áreas geográficas no exista la información correspondiente al nivel de la(s) variable(s) analizada(s). Esto se explica debido a que los modelos señalados amplían el concepto de *interpolación espacial* al incorporar estructuras de dependencias espaciales que incluyen el uso de efectos aleatorios espaciales estructurados y no estructurados y el uso de covariables. Lo anterior permite a estos modelos obtener distribuciones posteriores y distribuciones predictivas capaces de producir estimaciones más realistas y precisas que las obtenidas a partir del uso de metodologías estadísticas tradicionales; de este modo, no es extraño que las estimaciones posteriores realizadas por el predictor lineal de los modelos M0 y M1 permitan completar la ausencia de datos observada en los municipios de Ocosingo y Cintalapa, presente en las figuras 1, 2 y 3 por la ausencia de localidades reportadas en la figura 4.

Tabla 1
Modelos espaciales bayesianos M0 y M1

<i>Modelo</i>	<i>b0</i> <i>(Intercepto)</i>	<i>x1</i> <i>(Tasa de inmigración)¹</i>	<i>AIC²</i>
M0	0.0000		-83373.96
M1	-0.0009	3.5032	-84641.00

¹ x1: variable independiente, tasa de inmigración por localidad (por cada 100 habitantes).

² AIC (Akaike Information Criterion): Criterio de Información de Akaike, mide la calidad de ajuste del modelo en relación con los datos observados, el criterio selecciona el modelo con el menor valor del estadístico alcanzado.

Fuente: elaboración propia con base en datos del Censo de Población y Vivienda 2020 (Inegi, 2020).

Los resultados, presentados en la tabla 2, indican que un incremento relativo de un punto porcentual en la tasa de inmigración por localidad resultaría en un aumento de 3.5 puntos porcentuales en los niveles de la oferta laboral local, una vez descontado el efecto espacial. El predictor lineal se genera a través de las variaciones provocadas por los efectos aleatorios del campo espacial discreto y representa la estimación del nivel medio esperado de oferta laboral disponible en cada localidad.

Tabla 2
Modelo espacial bayesiano M1

	<i>Media</i>	<i>d.e.¹</i>	<i>1er cuartil²</i>	<i>Mediana³</i>	<i>3er cuartil⁴</i>
b0 (intercepto)	-0.0009	0.0003	-0.0015	-0.0009	-0.0004
x1 (inmigración)	3.5032	0.0102	3.4832	3.5032	3.5232

¹ d.e. (desviación estándar): mide la desviación de la variable respecto de la media.

² 1er cuartil: punto en donde la distribución concentra hasta 25% de los datos.

³ Mediana: punto de la distribución donde se concentra 50% de los datos.

⁴ 3er cuartil: punto de la distribución donde se concentra hasta 75% de los datos.

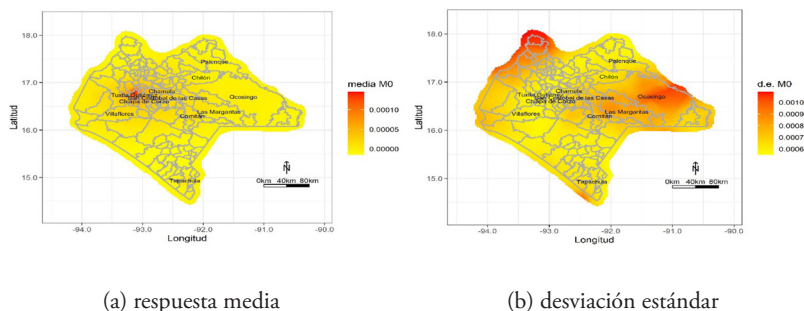
Fuente: elaboración propia con base en datos del Censo de Población y Vivienda 2020 (Inegi, 2020).

La oferta laboral de las localidades de Chiapas, modelada como un campo gaussiano, se presenta en la figura 6(a); en la misma se observa la presencia de un patrón espacial para la oferta laboral, donde la zona roja que rodea la capital de Chiapas –y que incluye los municipios de San Cristóbal de las Casas, Ocozocuatla, Berriozabal y Chiapa de Corzo– presenta los mayores niveles de oferta laboral en la entidad, seguida por Tapachula y Comitán, pero que al ser localidades únicas no consiguen constituirse en un conglomerado. En contraparte se observa una gran zona amarilla que representa las localidades de muy baja oferta laboral y que cubre el resto del estado de Chiapas.

Es importante señalar que el conglomerado amarillo de mayor tamaño en muchos casos corresponde con áreas poco pobladas, con un alto porcentaje de población habitante de lenguas indígenas o se trata de zonas que coinciden con reservas ecológicas, como puede ser la Selva Lacandona.

La figura 6(b) muestra la varianza de la respuesta media del modelo M0, en la que se observa una magnitud similar a la presentada por la varianza del GMRF para la mayor parte del dominio espacial estimado, como se observa en la figura 5(b), lo que indica que la incertidumbre asociada al proceso que da origen a los datos presenta una escala de varianza similar a la alcanzada por el modelo M1, escala atribuible a la capacidad explicativa de la covariable agregada.

Figura 6
Respuesta media estimada y desviación estándar de la PEA,
modelo M0



Fuente: elaboración con datos de Inegi (2020) y Conapo (2018).

4.2. Dependencia espacial de la PEA

El uso de modelos espaciales bayesianos proporciona un enfoque robusto y flexible, especialmente útil, para analizar el comportamiento de fenómenos socioeconómicos que interactúan con el entorno geográfico. Se trata de modelos que ponderan la importancia de la estructura espacial con la complejidad y capacidad de inferencia del comportamiento y distribución de los fenómenos estudiados. Una de las principales ventajas al implementar el enfoque SPDE es que permite pasar de la complejidad de estimar el comportamiento de un campo aleatorio continuo (GF) a la tarea de ajustar un campo aleatorio discreto (GMRF), lo que permite la aplicación de métodos numéricos eficientes.

Es importante destacar la presencia de un conglomerado de localidades con alta proporción de Población Económicamente Activa que espacialmente corresponde a zonas donde existe un alto porcentaje de

población inmigrante (figuras 5 y 6), lo que coincide con el análisis exploratorio de datos espaciales previo (figuras 1 y 2). Cabe destacar que esta zona se encuentra situada alrededor de la capital de Chiapas, cuya densidad poblacional es superior a la observada en el resto de la entidad. Fuera de este conglomerado, el resto de las localidades presentan una baja o muy baja proporción de oferta laboral y, además, la tasa de inmigración es baja, lo que pudiera explicarse a partir de su ubicación geográfica y a sus precarias condiciones socioeconómicas.

Conclusiones

La estimación de los modelos gaussianos latentes permitió analizar la variación de la distribución espacial de la sobrepoblación relativa presente en las localidades de Chiapas al 2020; identificar un campo aleatorio gaussiano markoviano discreto, que incluyó la estimación de efectos espaciales, efectos aleatorios y fijos; e identificar algunos conglomerados consistentes con el patrón espacial mostrado por el análisis exploratorio de datos espaciales.

Se encontró, asimismo, evidencia de que existe una relación causal directa entre los niveles de la PEA observados en las localidades y la covariable tasa de inmigración. El análisis de efectos espaciales del modelo M1 permitió conocer el comportamiento espacial de la PEA e identificar los conglomerados con altos porcentajes en las zonas con mayor densidad poblacional. Estos resultados pueden constituir una herramienta útil para la formulación de políticas públicas destinadas a mejorar las condiciones de la PEA.

Cuando los niveles de pobreza comienzan a incrementarse, la diferencia en términos absolutos de la PEA y la población ocupada tiende a desaparecer, lo que pone de manifiesto que el empleo y su ingreso asociado es un elemento fundamental para la subsistencia de las personas; de esta forma, una gran proporción de la PEA en Chiapas se encuentra clasificada como ocupada, lo que coincide con la alta proporción de PEA en condiciones de informalidad, cerca de 80%. En este sentido, la intención del estudio no es generar conclusiones definitivas sobre el comportamiento espacial de la PEA, sino evidenciar la capacidad de diferentes metodologías para capturar el comportamiento de la PEA y poner de relieve la importancia del uso de covariables.

Finalmente, el modelo M1 proporcionó evidencia estadística para demostrar la existencia, en localidades de Chiapas, de una relación directa entre las proporciones de la PEA y la tasa de inmigración, donde la presencia de altas tasas de inmigración se encuentran espacialmente correla-

cionadas con altos niveles de oferta laboral. De esta manera localidades con altas (bajas) proporciones de PEA se constituyen en polos de alta (baja) atracción de población inmigrante.

Agradecimientos

Apoyos o financiamientos: investigación realizada en el marco del proyecto Región Transfronteriza México Guatemala (RTMG) del Centro de Investigación y Docencia Económicas, A.C. y financiado por el Consejo Nacional de Ciencia y Tecnología (Conacyt).

Anexo 1

Georeferenciación de los municipios de Chiapas



Fuente: Marco Geoestadístico Nacional 2020 (Inegi, 2020). Elaboración: Unidad de Servicios Estadísticos y Geomática (USEG)-El Colegio de la Frontera (Colef).

Fuentes consultadas

- Acemoglu, Daron y Autor David (2011), “Skills, tasks and technologies: implications for employment and earnings”, en David Card y Orley Ashenfelter (eds.), *Handbook of Labor Economics*, vol. 4, Ámsterdam, North Holland, pp. 1043-1171.
- Acemoglu, Daron (2002), “Technical Change, Inequality and the Labor Market”, *Journal of Economic Literature*, 40 (1), Nashville, American Economic Association, pp. 7-72, doi: <http://dx.doi.org/10.1257/0022051026976>
- Acevedo Bohórquez, Ingrid y Velásquez Ceballos, Ermilson (2008), “Algunos conceptos de la econometría espacial y el análisis exploratorio de datos espaciales”, *Ecos de Economía*, 12 (27), Medellín, Universidad EAFIT, pp. 9-34.
- Aleksynska, Mariya (2014), “Deregulating labour markets: how robust is the analysis of recent IMF working papers?”, *Conditions of work and employment series*, núm. 47, Ginebra, International Labour Organization, <<https://acortar.link/3QKiFM>>, 5 de noviembre de 2021.
- Anselin, Luc (1995), “Local Indicators of Spatial Association—LISA”, *Geographical Analysis*, 27 (2), Columbus, Wiley, pp. 93-111, doi: <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Becker, Gary; Glaeser, Edward y Murphy, Kevin (1999), “Population and Economic Growth”, *American Economic Review*, 89 (2), Nashville, American Economic Association, pp. 145-149.
- Blangiardo, Marta y Cameletti, Michela (2015), *Spatial and Spatio-temporal Bayesian Models with R-INLA*, Chichester, Wiley.
- Borjas, George J. (1994), “The Economics of Immigration”, *Journal of Economic Literature*, vol. 32, Nashville, American Economic Association, pp. 1667-1717.
- Castillo, Manuel Ángel y Vázquez Olivera Mario (2010), “Los inmigrantes guatemaltecos en México: antecedentes históricos y situación actual”, en Ernesto Rodríguez Chávez (coord.), *Extranjeros en México: continuidades y nuevas aproximaciones*, Ciudad de México,

Instituto Nacional de Migración/Centro de Estudios Migratorios/
DGE Ediciones, pp. 237-273.

Chasco, Coro (2003), *Econometría espacial aplicada a la predicción-extrapolación de datos microterritoriales*, Madrid, Consejería de Economía e Innovación Tecnológica.

Conapo (Consejo Nacional de Población) (2018) “Proyecciones de la población de México y de las entidades federativas, 2016-2050”, Ciudad de México, Conapo-Secretaría de Gobernación, <<https://acortar.link/mlXi5s>>, 12 de octubre de 2022.

Cressie, Noel (1985), “Fitting variogram models of weighted least squares”, *Journal of the International Association of Mathematical Geology*, núm. 17, Springer, 563-586, doi: <https://doi.org/10.1007/BF01032109>

Cressie, Noel (1993), *Statistics for spatial data*, Nueva York, Wiley.

Delaunay, Daniel (2007), “Relaciones entre pobreza, migración y movilidad: dimensiones territorial y contextual”, *Notas de Población*, núm. 84, Santiago de Chile, Cepal, pp. 87-130, <<https://acortar.link/kldUBN>>, 7 de noviembre de 2021.

Fuglstad, Geir-Arne; Simpon, Daniel; Lindgren, Finn y Rue, Håvard (2015), “Interpretable priors for hyperparameters for gaussian random fields”, documento de trabajo núm. 15-03, Coventry, University of Warwick.

Gamerman, Dani y Lopes, Hedibert F. (2006), *Markov Chain Monte Carlo: Stochastic Simulation for Bayesian Inference*, Nueva York, Chapman y Hall/CRC.

Getis, Arthur y Ord, J.K. (1992), “The analysis of spatial association by use of distance statistic”, *Geographical Analysis*, 24 (3), Columbus, Wiley, pp. 189-206, doi: <https://doi.org/10.1111/j.1538-4632.1992.tb00261.x>

Inegi (Instituto Nacional de Estadística y Geografía) (2021), “PEA, ocupación, empleo y remuneraciones”, Aguascalientes, Inegi, <<https://acortar.link/DGUQ3O>>, 15 de junio de 2021.

- Inegi (Instituto Nacional de Estadística y Geografía) (2020), “Resultados del Censo Nacional de Población y Vivienda 2020”, Aguascalientes, Inegi, <<https://acortar.link/0tL77>>, 11 de junio de 2021.
- Ingebrigtsen, Rikke; Lindgren, Finn y Steinsland, Ingelin (2014), “Spatial models with explanatory variables in the dependence structure”, *Spatial Statistics*, vol. 8, Somerset, Universidad de Bath, pp. 20-38, doi: <https://doi.org/10.1016/j.spasta.2013.06.002>
- Katz, Lawrence F. y Murphy, Kevin M. (1992), “Changes in Relative Wages: Supply and Demand Factors”, *The Quarterly Journal of Economics*, 107 (1), Oxford, Oxford University Press, pp. 35-78, <<https://acortar.link/qSF6h1>>, 21 de julio de 2021.
- Keynes, John M. (1943), *Teoría general de la ocupación, el interés y el dinero*, México, Fondo de Cultura Económica.
- Krainski, Elias; Lindgren, Finn; Simpson, Daniel y Rue, Håvard (2016), “The R-INLA tutorial on SPDE models”, <<https://bit.ly/3BuWENX>>, 14 de junio del 2021.
- Krusell, Per, Ohanian, Lee E., Ríos-Rull, Jose-Víctor y Violante Giovanni, L. (2000), “Capital-Skill Complementarity and Inequality: A Macroeconomic Analysis”, *Econometrica*, 68 (5), Cleveland, The Econometric Society, pp. 1029-1053.
- Kuznets, Simon (1971), “The Contribution of Immigration to the Growth of Labor Force”, en Stanley L. Fogel y Robert William Engerman (eds.), *The Reinterpretation of American Economic History*, Nueva York, Harper & Row.
- Lindgren, Finn; Rue, Håvard y Lindström, Johan (2011), “An explicit link between gaussian fields and gaussian markov random fields: the stochastic partial differential equation approach”, *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, núm. 73, London, The Royal Statistic Society, pp. 423-498, doi: <https://doi.org/10.1111/j.1467-9868.2011.00777.x>
- Martins, Thiago; Simpson, Daniel; Lindgren, Finn y Rue, Håvard (2013), “Bayesian computing with INLA: New features”, *Computational Statistics and Data Analysis*, núm. 67, Londres, Computational and Methodological Statistics, pp. 68-83, doi: <https://doi.org/10.1016/j.csda.2013.04.014>

- Morales Gamboa, Alberto (2016), “Migraciones laborales y la integración en los mercados de trabajo regionales”, en Carlos Heredia Zubieta (coord.), *El sistema migratorio mesoamericano*, Tijuana, El Colegio de la Frontera Norte/Centro de Investigación y Docencia Económicas, pp. 63-97.
- Nájera Aguirre, Jéssica N. (2017), “Migración, fuerza de trabajo y familia, elementos en la definición del espacio transfronterizo México-Guatemala”, *EntreDiversidades. Revista de Ciencias Sociales y Humanidades*, núm. 8, Tuxtla Gutiérrez, Universidad Autónoma de Chiapas, pp. 119-150.
- Nurkse, Ragnar (1960), *Problemas de formación de capital*, Ciudad de México, Fondo de Cultura Económica.
- Nychka, Doug; Hammerling, Dorit; Sain, Stephan y Lenssen, Nathan (2013), “LatticeKrig: Multiresolution Kriging based on Markov Random Fields”, Berlín, ResearchGate GmbH, <<https://acortar.link/9rU3VZ>> 28 de junio de 2021.
- Ord, Keith (1975), “Estimation Methods for Models of Spatial Interaction”, *Journal of the American Statistical Association*, 70 (349), Alexandria, American Statistical Association, Taylor & Francis Ltd, pp. 120-126, doi: <https://doi.org/10.2307/2285387>
- Pressat, Roland (1967), *El análisis demográfico: métodos, resultados, aplicaciones*, Ciudad de México, Fondo de Cultura Económica.
- R Core Team (2018), “R: A language and environment for statistical computing”, Vienna, R Foundation for Statistical Computing, <<https://acortar.link/QLqeoN>>, 10 de julio de 2021.
- Ross, Jhon (2010), “The Transition from Labour-Intensive to Capital-Intensive Growth During Economic Development”, *Key Trends in Globalisation*, 29 de agosto del 2010, <<https://bit.ly/3UQCpJ>>, 12 de julio del 2021.
- Rozanov, Yu A. (1982), *Markov Random Fields*, Nueva York, Springer-Verlag, doi: 10.1007/978-1-4613-8190-7_2
- Rue, Håvard y Lindgren, Finn (2015), “Bayesian Spatial Modelling with R-INLA”, *Journal of Statistical Software*, 63 (19), Innsbruck,

Universidad de Innsbruck, doi: <https://doi.org/10.18637/jss.v063.i19>

Rue, Håvard, Martino, Sara y Chopin, Nicolas (2009), "Approximate Bayesian inference for latent Gaussian models using integrated nested Laplace approximations", *Journal of the Royal Statistical Society*, 71 (2), Londres, The Royal Statistical Society, pp. 319-392, doi: <https://doi.org/10.1111/j.1467-9868.2008.00700.x>

Rue, Håvard y Held, Leonhard (2005), *Gaussian Markov Random Fields: Theory and Applications*, Nueva York, Chapman & Hall, doi: <https://doi.org/10.1201/9780203492024>

Recibido: 7 de septiembre de 2021.

Reenviado: 12 de noviembre de 2021.

Aceptado: 18 de abril de 2022.

Cuauhtémoc Calderón Villarreal. Doctor en Ciencias Económicas por la Universidad de Niza Sophia Antípolis en Francia. Actualmente es investigador titular del Departamento de Estudios Económicos de El Colegio de la Frontera Norte, miembro del Sistema Nacional de Investigadores, nivel III y miembro de la Academia Mexicana de Ciencia A. C. Fue integrante de la Comisión dictaminadora del SNI del Área V (2014-2016). Sus líneas de investigación son integración económica, crecimiento y desarrollo económico, economía de la desigualdad, economía fronteriza-regional-espacial, mercado laboral, migración y remesas, macroeconomía abierta, economía sectorial y política industrial. Entre sus publicaciones más recientes se encuentran, como coautor: "Crecimiento industrial y aumento de los precios de los bienes de consumo en México: un análisis econométrico", *Revista de la Cepal*, núm. 129, Santiago de Chile, Cepal, pp. 191-215 (2019); "Mexico and China in the US manufacturing market: An empirical analysis", *Contaduría y Administración*, 65 (4), Ciudad de México, Universidad Nacional Autónoma de México-Facultad de Contaduría y Administración, pp. 1-26 (2020), y "Human capital formation and Economic growth across the world: a panel data econometric approach", *Economía, Sociedad y Territorio*, 20 (62), Zinacantepec, El Colegio Mexiquense, pp. 25-54 (2020).

Gerardo Núñez Medina. Doctor en demografía por la Universidad Autónoma de Barcelona. Actualmente es profesor-investigador en el Departamento de Estudios de Población de El Colegio de la Frontera Norte. Es miembro del Sistema Nacional de Investigadores, nivel I. Sus

líneas de investigación son el análisis espacial de fenómenos sociodemográficos y demografía estadística. Entre sus publicaciones más recientes se encuentran: “Modelo de transición logística aplicado a la población de México”, *Notas de Población*, núm. 101, Santiago de Chile, Naciones Unidas/Cepal, pp. 11-36 (2015); “Bayesian modeling of spatiotemporal patterns of the cumulative incidence of covid-19 in municipalities of Mexico”, *RELAP-Revista Latinoamericana de Población*, 15 (28), Cuernavaca, Latin American Population Association, pp. 160-178 (2019); como coautor: “Pobreza, desigualdad, poblaciones indígenas y covid-19 en Chiapas”, en Gerardo Núñez Medina y Jiménez (coord.), *El Sistema de Salud de Chiapas ante la pandemia de la covid-19*, Tuxtla Gutiérrez, Universidad Autónoma de Chiapas, pp. 149-184 (2021).

Leticia Hernández Bielma. Doctora en ciencias económicas por la Universidad de Nice Sophia Antípolis, Francia. Actualmente es profesora-investigadora del Departamento de Estudios Económicos, en El Colegio de la Frontera Norte. Es miembro del Sistema Nacional de Investigadores, nivel II. Su línea de investigación actual es desarrollo económico. Entre sus más recientes publicaciones destacan, como coautora: “Exchange rate pass-through and monetary policy in emerging markets: Mexico and South Korea as case study”, *Contaduría y Administración*, 67 (1), Ciudad de México, Universidad Nacional Autónoma de México, pp. 119-148 (2022); “Efecto Pass-Through en México en condiciones de alta y baja volatilidad”, *Revista Mexicana de Economía y Finanzas Nueva Época*, 15 (1), Tijuana, El Colegio de la Frontera Norte, pp. 57-80 (2020), y “La desigualdad salarial en la industria manufacturera de la frontera de México y los Estados Unidos 1994-2014”, *Nóesis, Revista de ciencias sociales*, 27 (53-1), Ciudad Juárez, Universidad Autónoma de Ciudad Juárez-Instituto de Ciencias Sociales y Administración, pp. 30-50 (2018).