

Incidencia de los factores espaciales en la eficiencia de la dimensión salud del índice de desarrollo humano en México, 1990-2015

Incidence of spatial factors in the efficiency of the health dimension of the human development index in Mexico, 1990-2015

Francisco Javier AYVAR-CAMPOS [1](#); José César Lenin NAVARRO-CHÁVEZ [2](#); Víctor Manuel GIMÉNEZ-GARCÍA [3](#)

Recibido: 23/03/2018 • Aprobado: 01/05/2018

Contenido

- [1. Introducción](#)
- [2. Metodología](#)
- [3. Resultados](#)
- [4. Conclusiones](#)

[Referencias bibliográficas](#)

RESUMEN:

En el artículo se estudia la incidencia que tuvieron los factores espaciales en la eficiencia de la dimensión salud del Índice de Desarrollo Humano (IDH) en México, durante el período 1990-2015. Para esto, se instrumentó la metodología del Análisis de la Envolvente de Datos (DEA) y de la Econometría Espacial. Los resultados muestran que la eficiencia de las entidades mexicanas estuvo influenciada por la proximidad geográfica a estados que tuvieron elevados promedio de escolaridad y bajos niveles de deuda.

Palabras-Clave: Salud, DEA, Econometría Espacial, México.

ABSTRACT:

The article studies the effects of spatial factors on the efficiency of the health dimension of the Human Development Index (HDI) in Mexico, during the period 1990-2015. For this, the methodology of Data Envelopment Analysis (DEA) and Spatial Econometrics is implemented. The results show that the efficiency of the Mexican entities was influenced by the geographical proximity to states that had high average schooling and low debt levels.

Keywords: Health, DEA, Spatial econometrics, Mexico.

1. Introducción

Se concibe al desarrollo humano como el proceso por el cual se expanden las opciones, oportunidades y el bienestar del individuo (McGillivray & White, 1993; Harttgen & Klasen, 2012). En la medición del concepto destaca el Índice de Desarrollo Humano (IDH), elaborado por el Programa de Naciones Unidas para el Desarrollo (PNUD). El IDH considera

tres dimensiones: el ingreso, la salud y la educación (Alkire, 2002). Debido a sus características técnicas el IDH es el indicador sintético más aplicado en la medición del desarrollo humano y el bienestar social (PNUD, 2017a).

Los indicadores de salud en México, durante el período 1990–2015, tuvieron variaciones positivas que permitieron que el índice de salud del IDH tuviera un crecimiento del 9.5% (INEGI, 2017; Secretaría de Salud, 2017a, 2017b). De las tres dimensiones que componen el IDH, es la dimensión salud la que más incidió positivamente en el comportamiento del IDH nacional, durante el período de estudio (PNUD, 2017b). Sin embargo, el comportamiento de las variables de mortalidad, pobreza e inequidad revelan que aún se requieren mayores esfuerzos en la dimensión salud del desarrollo humano en México (CONEVAL, 2017a, 2017b; Secretaría de Salud, 2017a). La incidencia que tiene la salud en el desarrollo humano es directa, ya que de fortalecer el estado de salud de la población se fomenta el crecimiento económico y el bienestar social (London *et al.*, 2009; Monterubbianesi, 2014).

La presente investigación analiza la incidencia de los factores espaciales en la eficiencia de la dimensión salud del IDH en los 32 estados de México, durante el período 1990–2015. La herramienta que se utilizó para medir la eficiencia técnica fue el Análisis de la Envoltente de Datos (DEA, por sus siglas en inglés). Se considera un Modelo DEA con orientación al *output*, estructurado bajo rendimientos variables a escala, con la presencia de *bad outputs* e incluyendo la incidencia de factores no controlables. Se tiene como *output* a la esperanza de vida al nacer; como *bad output* la carencia por acceso a los servicios de salud; como *inputs* controlables la cantidad de médicos y el número de unidades médicas disponibles; y, como *input* no controlable el coeficiente de Gini. Por otro lado, para determinar la influencia de los factores espaciales sobre los resultados de eficiencia se empleó la Econometría Espacial (EE). Se trabaja un modelo de correlación espacial mediante la aproximación de máxima verosimilitud. Siendo la variable dependiente de este modelo de regresión el promedio de los resultados de eficiencia, y las variables independientes el promedio de deuda pública y el grado promedio de escolaridad, del período 1990–2015.

El artículo se encuentra estructurado en tres apartados, en el primero, se presentan los elementos teórico-metodológicos de los modelos DEA y EE, así como el proceso y definición de las variables para cada uno de ellos. En el segundo apartado, se muestran los resultados de la eficiencia y de la incidencia espacial. Finalmente, se establecen las conclusiones del estudio.

2. Metodología

En este apartado se presentan los rasgos teórico-metodológicos del modelo eficiencia, considerando la presencia de *bad outputs* y la incidencia de factores no controlables. De igual manera, se abordan los elementos teóricos-metodológicos del modelo de econometría espacial, desarrollado a fin de identificar la influencia de los factores espaciales en la eficiencia.

2.1. El análisis de la envoltente de datos

La conceptualización de eficiencia de Farrell (1957), se aplica empíricamente mediante la estimación de fronteras estocásticas y el Análisis de la Envoltente de Datos. DEA es una técnica aplicada en la cuantificación de la eficiencia de agentes homogéneos o Unidades de Toma de Decisión (DMU, por sus siglas en inglés). Partiendo de los *inputs* y *outputs*, este método proporciona una clasificación de las DMU, otorgándoles una puntuación de eficiencia relativa. Es así, como aprovechando el *know how* de las DMU eficientes, realiza un análisis de *slacks* estableciendo las mejoras que requieren las DMU consideradas como ineficientes. A su vez, los modelos DEA pueden ser elaborados con Rendimientos Constantes a Escala (CRS, por sus siglas en inglés), Rendimientos Variables a Escala (VRS, por sus siglas en inglés), aditivos y multiplicativos. De igual forma, es factible que tengan dos orientaciones, hacia la combinación óptima de *inputs* o hacia la optimización de la producción de *outputs* (Cooper *et al.*, 2007). Sin embargo, salidas indeseables (*bad outputs*) se producen a menudo

conjuntamente con resultados deseables (*outputs*). En este sentido, Pittman (1983) introdujo el tratamiento de los *bad outputs* dentro de los análisis DEA. El resultado de este nuevo enfoque permite deducir una medida de eficiencia en la cual, con orientación al *output*, busque maximizar la salida de los *good outputs* y a la par minimizar los *bad outputs* (Seiford & Zhu, 2002).

Gran parte de las investigaciones basadas en el DEA se focalizan en el análisis de la gestión de los productores; sin considerar la influencia de los factores exógenos al proceso de producción, pero que inciden en la generación de *outputs*. La inclusión de estos factores no controlables permite que los resultados de eficiencia muestren si el productor clasificado como ineficiente lo es realmente o si aun haciendo todo lo que está en su mano, hay factores que le imposibilitan lograr la producción que otros si obtienen (Cordero *et al.*, 2005). Recientemente diversos estudios incorporan en las mediciones de eficiencia (DEA) a las variables no controlables, estableciendo así distintas propuestas metodológicas. A fin de simplificar la presentación de estas alternativas metodológicas se han conformado tres categorías, como son (Cordero *et al.*, 2005): a) Modelos de Separación de Frontera, b) Modelos de Una Etapa, y c) Modelos de Varias Etapas. Los Modelos de Varias Etapas, a su vez, se pueden subdividir en dos grupos, que son: a) Modelos de Segunda Etapa, y b) Modelos de Valores Ajustados. Derivándose de estos últimos los Modelos de Tres Etapas, y los Modelos de Cuatro Etapas.

2.2. El modelo DEA considerando *bad outputs* y factores no controlables

Con la intención de incorporar la incidencia de los factores no controlables en la eficiencia se desarrolló un modelo de cuatro etapas, considerando la presencia de *bad outputs*. Es así como, partiendo de los postulados de Cordero *et al.* (2005), el modelo se elaboró de la siguiente manera (Ayvar-Campos *et al.*, 2017):

- 1) Primera Etapa. Se realizó un DEA estándar con *bad outputs*, incluyendo solamente los *inputs* controlables, orientado al *output* y considerando VRS. Partiendo de la premisa de que en los *slacks* totales (radiales y no radiales) se encuentra el efecto de los factores no controlables. La expresión matemática de este primer modelo es la siguiente (Seiford & Zhu, 2002; Sueyoshi & Goto, 2010; Wang, Yu & Zhang, 2013):

$$Max = \phi + \varepsilon (\sum_{i=1}^I s_i^+ + \sum_{d=1}^D s_d^- + \sum_{z=1}^Z s_z^+) \quad (1)$$

s.a.

$$\sum_{j=1}^N \lambda_j x_{ij} + s_i^+ = x_{io} \quad i = 1, \dots, I$$

$$\sum_{j=1}^N \lambda_j y_{dj} + s_d^- = (1 + \phi) y_{do} \quad d = 1, \dots, D$$

$$\sum_{j=1}^N \lambda_j d_{zj} + s_z^+ = (1 - \phi) b_{zo} \quad z = 1, \dots, Z$$

$$\sum_{j=1}^N \lambda_j = 1$$

$\lambda_j, s_d^+, s_z^+, s_i^+ \geq 0, \phi$ sin restricción de signo

donde se supone que $j=(1...N)$ son las n DMU, cada una de las cuales puede utilizar i *inputs* ($i = 1, \dots, I$) para producir d *good outputs* ($d = 1, \dots, D$) y z *bad outputs* ($z = 1, \dots, Z$). Asignándole al vector x_{ij} la cantidad de *input* i utilizado por la DMU j , al vector y_{dj} el número de *good output* d producido por la DMU j , y al vector d_{zj} el monto de *bad output* z producido por la DMU j . Siendo ε una constante no-arquimediana; ϕ el máximo incremento/decremento radial para el *good* y *bad output*, respectivamente; s la *slack* de las variables; y λ_j el vector de intensidad. La restricción $\sum_{j=1}^N \lambda_j = 1$ se incorpora para asumir que la tecnología exhibe VRS.

- 2) Segunda Etapa. En esta fase se aplicaron modelos econométricos con *bootstrap*, con el propósito de separar el efecto del entorno de la eficiencia pura de gestión. Para ello, se estimaron dos modelos econométricos uno para el *output* y otro para el *bad output*. La formulación de estos modelos es la siguiente (Fried, Schmidt, & Yaisawarnng, 1999):

$$SO_j^k = f(Z_j^k, \beta_j, \mu_j^k) \quad \begin{matrix} j = 1, \dots, N \\ k = 1, \dots, K \end{matrix} \quad (2)$$

donde SO_j^k representa el *slack* total de la DMU (k) para el *output/bad output* (j), resultado de la primera etapa; Z_j^k es el vector de los *inputs* no controlables de la DMU (k) que pueden estar afectando la producción del *output/bad output* (j); β_j es el vector del coeficiente, y μ_j^k es el término de error.

- 3) Tercera Etapa. A partir de los coeficientes obtenidos en la etapa anterior se determinaron, en esta fase, los nuevos *slacks* totales del *output* y del *bad output* para cada DMU. Los cuales representan las holguras permitidas tomando en consideración la proporción de *inputs* no controlables de cada DMU. Con los nuevos *slacks* se ajustaron los valores originales del *output/bad output* de cada DMU. Las adecuaciones se realizaron substrayendo del *output/bad output* originales la diferencia entre el mayor valor predicho de la *slack* del *output/bad output* y el valor predicho de la *slack* del *output/bad output* de cada unidad. La representación matemática del ajuste es la siguiente (Fried *et al.*, 1999):

$$Y_j^k adj = Y_j^k - [\max^k\{SO_j^k\} - SO_j^k] \quad \begin{matrix} j = 1, \dots, N \\ k = 1, \dots, K \end{matrix} \quad (3)$$

donde $Y_j^k adj$ representa el valor ajustado del *output/bad output*; Y_j^k simboliza el valor original del *output/bad output*; $\max^k\{SO_j^k\}$ alude al mayor valor predicho del *slack* total del *output/bad output*; y SO_j^k hace referencia al valor predicho del *slack* total del *output/bad output*. Esta adecuación supone tomar como referencia la sustitución de la DMU más perjudicada por el efecto de los *inputs* no controlables. Así la DMU en mejor posición no sufre ningún tipo de alteración en el valor de su *output/bad output*, mientras que el resto incrementa el valor de su *output/bad output*.

- 4) Cuarta Etapa. Con los valores ajustados del *output/bad output*, en esta fase, se desarrolló un modelo DEA similar al aplicado en la primera etapa. A partir de la aplicación del modelo de cuatro etapas se obtuvo un índice que, al restar la incidencia de los factores no controlables, expresa exclusivamente el nivel de eficiencia pura de gestión de las DMUs.

El *output* del modelo de eficiencia fue la esperanza de vida al nacer y el *bad output* la población con carencia de acceso al sistema de salud, la razón de haberlos retomados es por la representatividad teórica que tienen para explicar el bienestar social. La selección de *inputs* controlables y no controlables se fundamentó, en primera instancia, en las bases teóricas que explican el comportamiento de la dimensión salud del IDH (Kirigia *et al.*, 2004; Nevárez-Sida *et al.*, 2007; Mirzosaid, 2011; De Nicola *et al.*, 2012; Iñiguez *et al.*, 2012; Hadad *et al.*, 2013; Varabyova & Schreyögg, 2013; Asandului *et al.*, 2014; Cheng & Zervopoulos, 2014; Davutyan & Bilsel, 2014; Cordero *et al.*, 2016; Jakovljevic *et al.*, 2016). Debido a las limitaciones de información en las bases estadísticas oficiales del país el número de *inputs* se redujo. Con los indicadores restantes se aplicó un análisis factorial,

para cada tipo de *input* (controlable y no controlable), empleando como método de extracción los componentes principales. A partir de los resultados de la matriz de componentes se determinó que los *inputs* controlables del modelo de eficiencia serían los médicos y las unidades médicas disponibles; y el *input* no controlable sería el coeficiente de Gini (Ver Tabla 1).

Tabla 1
Variables del modelo DEA de cuatro etapas

Variable	Tipo	Definición	Unidad de Medida	Fuente
Esperanza de Vida al Nacer	Output	Número de años que en promedio se espera que viva una persona después de nacer.	Años	Secretaría de Salud (2017 b)
Carencia de Acceso al Sistema de Salud	Bad Output	Población que no cuenta con adscripción o derecho a recibir servicios médicos de alguna institución que los presta, incluyendo el Seguro Popular, las instituciones públicas de seguridad social (IMSS, ISSSTE federal o estatal, Pemex, Ejército o Marina) o los servicios médicos privados.	Personas	CONEVAL (2017a)
Médicos	Input Controlable	Médicos disponibles en instituciones públicas de salud en contacto con el paciente.	Personas	INEGI (2017)
Unidades Médicas	Input Controlable	Unidades médicas disponibles de cada institución pública de salud (IMSS, ISSSTE federal o estatal, Pemex, Ejército o Marina).	Establecimientos	Secretaría de Salud (2017a)
Coeficiente de Gini	Input No Controlable	Mide la desigualdad económica de una sociedad, mediante la exploración del nivel de concentración que existe en la distribución de los ingresos entre la población. El coeficiente de Gini toma valores entre 0 y 1; un valor que tiende a 1 refleja mayor desigualdad en la distribución del ingreso. Por el contrario, si el valor tiende a cero, existen mayores condiciones de equidad en la distribución del ingreso.	Coeficiente	CONEVAL (2017b)

Fuente: Elaboración propia.

2.3. La econometría espacial

El desarrollo de la ciencia regional planteó la necesidad de diferenciar la economía tradicional de la economía espacial o regional, así como también de disociar los instrumentos que se utilizan para tal fin. Este proceso de distinción ha sido permanente, ya que desde sus orígenes el análisis regional destaca la importancia de establecer marcos analíticos regionales integrados que permitan sintetizar las diferentes herramientas y técnicas vinculadas a subsistemas regionales bajo un mismo marco teórico (Isard, 1960; Meyer, 1965). En esta evolución se han elaborado diversos trabajos que estiman y evalúan a la región bajo modelos econométricos (econometría espacial multirregional y modelos de econometría einsumo producto). La Econometría Espacial (EE) se presenta así como una

opción a la econometría estándar para tratar con datos referenciados espacialmente y contrastar fenómenos económicos (Paelinck & Klaassen, 1979). De esta forma, y de acuerdo con Anselin (1988) la EE es "la colección de técnicas que tratan con las peculiaridades causadas por el espacio en el análisis estadístico de los modelos de la ciencia regional" (Moreno y Vayá, 2002, p. 2).

La EE reconoce dos tipos de efectos espaciales: la heterogeneidad y la dependencia espacial (Anselin & Florax, 1995). El primer efecto aparece cuando se utilizan datos de unidades espaciales muy distintas para explicar un mismo fenómeno. En este caso, aparecen problemas como la heterocedasticidad o la inestabilidad estructural, los cuales pueden ser resueltos mediante las técnicas econométricas existentes para series temporales. Por otro lado, la dependencia o autocorrelación espacial surge siempre que el valor de una variable en un lugar del espacio está relacionado con su valor en otro u otros lugares del espacio. La dependencia espacial no puede ser tratada con econometría estándar, debido a la multidireccionalidad que denomina las relaciones de interdependencia entre unidades espaciales, por lo que se utiliza la EE (Moreno y Vayá, 2000, 2002).

2.4. Rasgos del modelo de la econometría espacial

El modelo de EE en el que se sustentó la presente investigación, parte del establecimiento de la matriz de pesos basada en una contigüidad física de tipo Reina o Queen y de primer orden. Este tipo de contigüidad establece que serán vecinas de i las regiones que compartan algún lado o vértice con j . La representación de la matriz de pesos espaciales (W), es (Anselin & Rey, 2014):

$$W_{ij} = d_{ij}^{-a} \beta_{ij}^b \quad (4)$$

donde d_{ij} es la distancia que separa a las unidades i y j , y β_{ij} la longitud relativa de la frontera común entre i y j con relación al perímetro de i , siendo a y b parámetros a estimar.

Posteriormente, se determinó el operador del retardo espacial, que se obtiene como el producto de la matriz de pesos espaciales por el vector de observaciones de una variable aleatoria y , es decir, Wy . Siendo la expresión matemática la siguiente (Anselin & Rey, 2014):

$$\sum_j w_{ij} y_j \quad (5)$$

donde w_{ij} es la matriz de pesos espaciales. Es así como cada elemento del retardo espacial es igual a un promedio ponderado de los valores de la variable en el subgrupo de observaciones vecinas S_i , dado que $w_{ij}=0$ para $j \notin S_i$. Una vez establecido (4) y (5) se efectuó el Análisis Exploratorio de Datos Espaciales (AEDE), a partir, de los contrastes globales y locales (la I de Moran, la $G(d)$ de Getis y Ord, el estadístico local de Moran y los test $New-G_i(d)$ y $New-G_i^*(d)$), con la finalidad de identificar los efectos espaciales. La función matemática de la I de Moran es la siguiente (Moreno y Vayá, 2000, 2002):

$$I = \frac{N}{S_0} \cdot \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (X_i - \bar{X})(X_j - \bar{X})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad i \neq j \quad (6)$$

donde N es el tamaño muestral, w_{ij} son los pesos espaciales de las regiones i y j ; $S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij}$ es la suma de los elementos de la matriz de pesos espaciales, que cuando esta estandarizada es N ; X_i, X_j son las variables X para las regiones i y j ; \bar{X} es la media muestral de la variable X .

Es así, como a partir de la distinción de presencia de autocorrelación espacial en las variables, se elaboró un modelo de regresión. Este modelo, en primera instancia, se calculó con Mínimos Cuadrados Ordinales (MCO) aplicando los test econométricos tradicionales de multicolinealidad, Jaque-Bera y heterocedasticidad (Breusch-Pagan, Koenker-Bassett y White), así como de dependencia espacial (test de I Moran, test Lagrange Multiplier (lag), test Lagrange Multiplier (error) y test Lagrange Multiplier (SARMA)). La expresión matemática del modelo MCO es la siguiente (Anselin & Rey, 2014; Moreno y Vayá, 2000, 2002):

$$y = \rho W_y + X\beta + u \quad (7)$$

$$u \sim N(0, \sigma^2 I)$$

donde y es un vector ($N \times 1$); W_y el retardo espacial de la variable y ; X una matriz de K variables exógenas; u un término de perturbación ruido blanco; N el número de observaciones; y, por último, ρ el parámetro espacial autorregresivo que recoge la intensidad de las interdependencias entre las observaciones muestrales.

Finalmente, una vez identificado donde se encontraba la dependencia espacial (en las variables independientes o en el error), se efectuó la contrastación espacial. Para tal fin, se determinó el modelo de dependencia espacial mediante la aproximación de máxima verosimilitud, empleando los tests de R cuadrada, de heterocedasticidad de Breusch-Pagan y el test de *Likelihood Ratio*. La función matemática de este modelo es la siguiente (Anselin & Rey, 2014; Moreno y Vayá, 2000):

$$LnL_c = cte + ln|I - \rho W| - \frac{N}{2} ln \left[\frac{(e_o - \rho e_L)'(e_o - \rho e_L)}{N} \right] \quad (8)$$

donde cte recoge la constante usual; I es el estadístico I de Moran; y, e_o y e_L son, respectivamente, los residuos de las regresiones de y y Wy .

La variable dependiente del modelo de EE fue el valor promedio de los resultados de eficiencia del Modelo DEA de Cuatro Etapas. La selección de variables independientes se basó, en primera instancia, en la incidencia que tienen las variables económicas, sociales y de salud para explicar el comportamiento de la eficiencia (Idrovo, 2005; Nevárez-Sida *et al.*, 2007; Álvarez, 2009; London *et al.*, 2009; Barahona-Urbina, 2011; Cardona *et al.*, 2013; Pinzón *et al.*, 2014). Dadas las limitaciones de información estadística en las bases oficiales el número de variables se redujo. Con estos datos se efectuaron ensayos factoriales, empleando como método de extracción los componentes principales. Los resultados del análisis factorial mostraron que las variables independientes son el promedio de deuda pública y el grado promedio de escolaridad del período 1990–2015, para los 32 estados (Ver Tabla 2A).

Tabla 2
Variables del modelo de econometría espacial

Variable	Tipo	Definición	Unidad de Medida	Fuente
Eficiencia de la dimensión salud	Variable Dependiente	Promedio de los resultados de eficiencia técnica de gestión en la generación de bienestar en salud y reducción de la inequidad, del período 1990–2015.	Score	Tabla 3A.

Durango	0.979	0.989	0.994	0.994	0.977	0.994	0.988
Guanajuato	0.965	0.976	0.979	0.979	0.982	0.989	0.978
Guerrero	0.943	0.942	0.942	0.944	0.947	0.954	0.945
Hidalgo	0.960	0.962	0.966	0.968	0.971	0.974	0.967
Jalisco	0.976	0.976	0.977	0.979	0.984	0.988	0.980
México	0.961	0.971	0.974	0.975	0.981	0.985	0.974
Michoacán	0.966	0.969	0.970	0.970	0.972	0.980	0.971
Morelos	0.984	0.985	0.988	0.991	0.987	0.994	0.988
Nayarit	1.000	0.991	0.988	0.987	0.976	0.986	0.988
Nuevo León	0.996	1.000	1.000	1.000	1.000	1.000	0.999
Oaxaca	0.919	0.931	0.938	0.942	0.945	0.954	0.938
Puebla	0.954	0.958	0.960	0.963	0.972	0.973	0.963
Querétaro	0.973	0.975	0.984	0.986	0.986	0.989	0.982
Quintana Roo	0.988	0.987	0.990	0.992	0.993	0.992	0.990
San Luis Potosí	0.962	0.967	0.972	0.973	0.972	0.980	0.971
Sinaloa	1.000	0.991	0.993	0.994	0.977	0.988	0.990
Sonora	0.963	0.972	0.981	0.986	0.986	0.987	0.979
Tabasco	0.975	0.971	0.973	0.973	0.974	0.981	0.974
Tamaulipas	0.978	0.990	0.992	0.992	0.987	0.992	0.989
Tlaxcala	0.973	0.974	0.980	0.985	0.984	0.992	0.981
Veracruz	0.958	0.956	0.953	0.955	0.963	0.968	0.959
Yucatán	1.000	0.988	0.985	0.987	0.990	0.988	0.990
Zacatecas	0.975	0.977	0.983	0.987	0.982	0.986	0.982
Nacional	0.973	0.975	0.978	0.980	0.977	0.983	0.977

Fuente: Elaboración propia con base en datos de la Secretaría de Salud (2017a, 2017b), CONEVAL (2017a, 2017b), e INEGI (2017); y, utilizando los programas SPSS, Eviews y MaxDea.

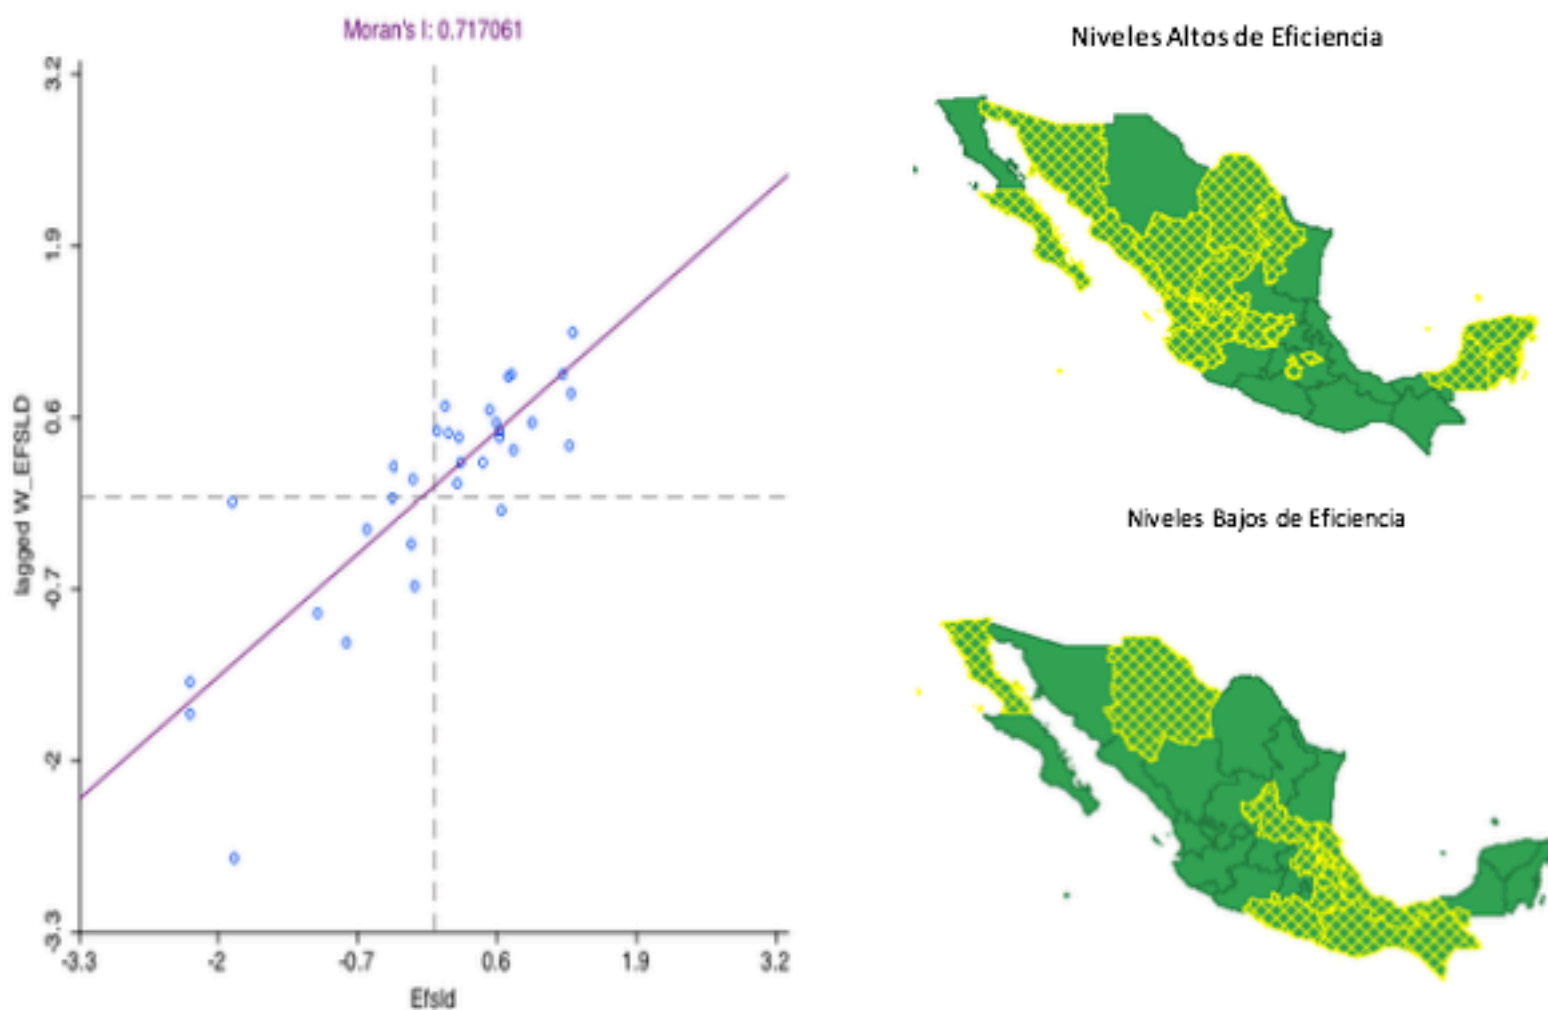
3.2. Determinación de la incidencia de los factores espaciales

sobre la eficiencia

El AEDE de contraste global permitió identificar la existencia de una autocorrelación espacial positiva en la variable dependiente, con una I de Moran de 0.7170. Estos resultados ponen de manifiesto que la evolución de la distribución de la eficiencia en salud se ha producido de forma agrupada en el espacio. Lo que implica que los estados con valores de eficiencia relativamente altos/bajos tienden a estar rodeados de entidades con valores de eficiencia similares. Es decir, los resultados de eficiencia no son observaciones independientes, sino que están influenciadas por el espacio (Ver Figura 1). Por su parte el AEDE de contraste local (LISA) identifica la existencia de un clúster regional significativo de valores altos de eficiencia en salud entre Jalisco, Aguascalientes, Zacatecas y Coahuila, así como entre Quintana Roo y Yucatán; y de valores bajos de eficiencia entre Guerrero, Oaxaca, Chiapas y Veracruz (Ver Figura 2). Asociaciones espaciales que corresponden con el desempeño de sus indicadores socioeconómicos y de sus niveles de bienestar social (CONEVAL, 2017a, 2017b; INEGI, 2017; PNUD, 2017b; Secretaría de Salud, 2017a, 2017b; SEP, 2017; SHCP, 2017).

Figura 1

Diagrama de dispersión de moran y mapas de eficiencia 1990–2015



Fuente: Elaboración propia con base en datos de la Secretaría de Salud (2017a, 2017b), CONEVAL (2017a, 2017b), INEGI (2017), SEP (2017) y SHCP (2017); y, utilizando el programa GeoDa.

Figura 2

Mapas Lisa de agrupamiento de la eficiencia 1990–2015

LISA Significance MAP



LISA Cluster MAP



Fuente: Elaboración propia con base en datos de la Secretaría de Salud (2017a, 2017b), CONEVAL (2017a, 2017b), INEGI (2017), SEP (2017) y SHCP (2017); y, utilizando el programa GeoDa.

Una vez detectada la existencia de autocorrelación espacial fue necesario realizar la estimación de MCO del modelo y analizar la existencia de efectos espaciales. De esta forma, en la Tabla 4 es posible observar que los resultados del modelo de regresión espacial con MCO muestran que existe una correlación espacial positiva entre la variable dependiente (eficiencia en salud) y las variables independientes (niveles de deuda pública y grado promedio de escolaridad) con una I de Moran de 2.5981, y una probabilidad de 0.0937. Conviene subrayar que el ajuste del modelo MCO es alto ya que: las variables explicativas son significativas, se puede aceptar la hipótesis de homocedasticidad y de normalidad, y no existen problemas de multicolinealidad. Así mismo, los resultados del test Lagrange Multiplier (error) son mayores que el de Lagrange Multiplier (lag) en las diferentes especificaciones, lo que significa que el modelo debe reespecificarse incluyendo un retardo espacial en el error. Esto se debe a la posible omisión de variables no cruciales para el modelo pero que podrían encontrarse correlacionadas espacialmente con la variable dependiente.

Tabla 4
Modelo espacial con mínimos cuadrados ordinarios

Data set	mge2015v6_2			
Dependent Variable	Efsld	Number of Observations	32	
Mean dependent var	0.977778	Number of Variables	3	
S.D. dependent var	0.0170255	Degrees of Freedom	29	
R-squared	0.638757	F-statistic	25.6392	
Adjusted R-squared	0.613843	Prob(F-statistic)	3.87344e-07	
Sum squared residual	0.0033508	Log likelihood	101.223	
Sigma-square	0.000115545	Akaike info criterion	-196.445	
S.E. of regression	0.0107492	Schwarz criterion	-192.048	
Sigma-square ML	0.000104712			
S.E of regression ML	0.0102329			
Variable	Coefficient	Std. Error	t-Statistic	Probability
CONSTANT	0.8449842	0.01866719	45.26574	0
Deuda	-1.069237e-06	3.062831e-07	-3.491008	0.00156
Esc	0.01800212	0.002515105	7.1576	0
REGRESSION DIAGNOSTICS				
MULTICOLLINEARITY CONDITION NUMBER		22.665674		
TEST ON NORMALITY OF ERRORS				
	TEST	DF	VALUE	PROB
Jarque-Bera		2	4.8611	0.08799
DIAGNOSTICS FOR HETEROSKEDASTICITY				
RANDOM COEFFICIENTS				
	TEST	DF	VALUE	PROB
Breusch-Pagan test		2	0.0395	0.98046
Koenker-Bassett test		2	0.0271	0.98652
DIAGNOSTICS FOR SPATIAL DEPENDENCE				
FOR WEIGHT MATRIX: mge2015v6_2.gal				
(row-standardized weights)				
	TEST	MI/DF	VALUE	PROB
Moran's I (error)		0.3144	2.5981	0.00937
Lagrange Multiplier (lag)		1	2.8203	0.09308
Robust LM (lag)		1	0.0256	0.87288
Lagrange Multiplier (error)		1	4.4436	0.03503
Robust LM (error)		1	1.6489	0.19911
Lagrange Multiplier (SARMA)		2	4.4692	0.10704

Fuente: Elaboración propia con base en datos de la Secretaría de Salud (2017a, 2017b), CONEVAL (2017a, 2017b), INEGI (2017), SEP (2017) y SHCP (2017); y, utilizando el programa GeoDa.

La estimación del modelo espacial con retardo en el error se efectuó mediante la aproximación de Máxima Verosimilitud (MV). En la Tabla 5 del anexo se observa que bajo este esquema se obtiene un modelo econométrico con una R cuadrada de 0.700594; un test de Breusch-Pagan de 0.0088 con una probabilidad de 0.9956; y, un test de Lakelihood Ratio de 4.2313 con una probabilidad de 0.03969. Datos que dan cuenta de la viabilidad estadística del modelo espacial, y que prueban la relación de dependencia espacial entre la variable dependiente y las independientes. Es a partir de estos resultados, que se argumenta que el uso eficiente de los recursos de los estados mexicanos durante el período 1990–2015, para generar bienestar en salud y a la par reducir la inequidad, restando la incidencia de factores no controlables, estuvo influenciado por la proximidad geográfica a entidades con altos grados promedio de escolaridad y bajos niveles de deuda. Lo que implica que la eficiencia depende tanto de la gestión de los recursos como de factores espaciales, argumento que concuerda con los postulados de Schaffer *et al.* (2011), Liu *et al.* (2014), Sun *et al.* (2014), Adetutu *et al.* (2015), Guan y Xu (2016), y Vidoli y Canello (2016).

Tabla 5
Modelo espacial bajo máximo verosímil residual

Data set	mge2015v6_2			
Spatial Weight	mge2015v6_2.gal			
Dependent Variable	Efsld	Number of Observations	32	
Mean dependent var	0.977778	Number of Variables	3	
S.D. dependent var	0.0170255	Degrees of Freedom	29	
Lag coeff. (Lambda)	0.3872			
R-squared	0.700594	R-squared (BUSE)	-	
Sq. Correlation	-	Log likelihood	103.365853	
Sigma-square	8.67E-05	Akaike info criterion	-200.732	
S.E of regression	0.00930932	Schwarz criterion	-196.334	
Variable	Coefficient	Std. Error	t-Statistic	Probability
CONSTANT	0.8461789	0.0189073	44.75409	0
Deuda	-1.002361e-06	2.5445e-07	-3.939325	0.00008
Esc	0.01777741	0.002487257	7.147396	0
LAMBDA	0.3871995	0.1701343	2.275847	0.02286
REGRESSION DIAGNOSTICS				
DIAGNOSTICS FOR HETEROSKEDASTICITY				
RANDOM COEFFICIENTS				
TEST	DF	VALUE	PROB	
Breusch-Pagan test	2	0.0088	0.9956	
DIAGNOSTICS FOR SPATIAL DEPENDENCE				
SPATIAL ERROR DEPENDENCE FOR WEIGHT MATRIX: mge2015v6_2.g				
TEST	DF	VALUE	PROB	
Likelihood Ratio Test	1	4.2313	0.03969	

Fuente: Elaboración propia con base en datos de la Secretaría de Salud (2017a, 2017b), CONEVAL (2017a, 2017b), INEGI (2017), SEP (2017) y SHCP (2017); y utilizando el programa GeoDa.

4. Conclusiones

La presente investigación constituye un aporte empírico al análisis de los determinantes espaciales de la eficiencia en la generación de bienestar en salud y en la reducción de la inequidad en el acceso al servicio de salud. El objetivo fue determinar la incidencia de los factores espaciales en la eficiencia de la dimensión salud del IDH en México, durante el período 1990–2015. Para esto, se consideraron los postulados teórico–metodológicos de los Modelos de Cuatro Etapas del DEA con la presencia de *bad outputs* y de autocorrelación espacial de los modelos de EE.

El Modelo del DEA de Cuatro Etapas fue diseñado con orientación al *output*, estructurado bajo rendimientos variables, con la existencia de *bad outputs* y la incidencia de factores no controlables. Se tiene entonces como *output* la esperanza de vida al nacer; como *bad output* la carencia de acceso a los servicios de salud; como *inputs* controlables la cantidad de médicos y el número de unidades médicas disponibles; y, como *input* no controlable el coeficiente de Gini. La finalidad de este modelo fue la de obtener una medida de eficiencia técnica de gestión que refleje el uso eficiente de los recursos en la generación de bienestar en salud y en la reducción de la inequidad.

Para identificar la incidencia de los factores espaciales sobre los niveles de eficiencia se elaboró un modelo de correlación espacial. Este modelo partió del establecimiento de una matriz de pesos, basada en una contigüidad tipo Queen y de primer orden; de la definición del operador del retardo espacial; de la aplicación del AEDE; de la elaboración del modelo de MCO; y de la aplicación del modelo MV. La variable dependiente del modelo de EE fue el valor promedio de los resultados de eficiencia del modelo DEA; y, las variables independientes fueron el promedio de deuda pública y el grado promedio de escolaridad del período 1990–2015.

Los resultados obtenidos del modelo DEA muestran que durante el período 1990–2015 los estados de Baja California Sur, de Quintana Roo y de Colima tuvieron los mayores niveles de eficiencia. Es decir, fueron las entidades que hicieron el mejor uso de sus recursos (médicos y unidades médicas disponibles) para generar bienestar en salud (esperanza de vida al nacer) y reducir la inequidad (carencia de acceso al servicio de salud), sustrayendo la

incidencia de los factores no controlables (coeficiente de Gini). Resultados que dejan ver que los estados que más percibieron recursos en la dimensión salud del IDH (Distrito Federal, el Estado de México, Jalisco, Guanajuato, Nuevo León, Puebla, Baja California, Tamaulipas y Veracruz) no siempre fueron los más eficientes.

En los resultados del modelo de EE se observa que el uso eficiente de los recursos de los estados mexicanos durante el período 1990–2015, para generar bienestar en salud y a la par reducir la inequidad, restando la incidencia de factores no controlables, estuvo influenciada por la proximidad geográfica a entidades con altos grados promedio de escolaridad y bajos niveles de deuda. Esta información hace evidente la necesidad de una gestión más adecuada de los recursos; y que el desempeño adecuado en áreas económicas y sociales ajenas a las variables propias de la dimensión salud del IDH en los estados vecinos favorecen la eficiencia. Lo que implica el desarrollo de políticas públicas focalizadas por entidad federativa que fomenten el uso eficiente de los recursos, y la generación de clústeres espaciales que fortalezcan el bienestar social.

Referencias bibliográficas

- Adetutu, M., Glass, A. J., Kenjegalieva, K., & Sickles, R. C. (2015). The effects of efficiency and TFP growth on pollution in Europe: a multistage spatial analysis. *Journal of Productivity Analysis*, 43(3), 307–326. <http://doi.org/10.1007/s11123-014-0426-7>
- Alkire, S. (2002). Dimensions of human development. *World Development*, 30(2), 181–205. [http://doi.org/10.1016/S0305-750X\(01\)00109-7](http://doi.org/10.1016/S0305-750X(01)00109-7)
- Álvarez Castaño, L. S. (2009). Los determinantes sociales de la salud: Más allá de los factores de riesgo. *Revista Gerencia y Políticas de Salud*, 8(17), 69–79.
- Anselin, L. (1988). *Spatial Econometrics: Methods and Models* (1 st. ed., Vol. 4). Amsterdam, Netherlands: Springer. <http://doi.org/10.1007/978-94-015-7799-1>
- Anselin, L., & Florax, R. (1995). *New Directions in Spatial Econometrics*. (1 st. ed.). Berlin, Heidelberg: Springer. <http://doi.org/10.1007/978-3-642-79877-1>
- Anselin, L., & Rey, S. J. (2014). *Modern Spatial Econometrics In Practice: A guide to GeoDa, GeoDaSpace and PySAL* (1st. ed.). Chicago, IL., USA: GeoDa Press.
- Asandului, L., Roman, M., & Fatulescu, P. (2014). The Efficiency of Healthcare Systems in Europe: A Data Envelopment Analysis Approach. *Procedia Economics and Finance*, 10, 261–268. [http://doi.org/10.1016/S2212-5671\(14\)00301-3](http://doi.org/10.1016/S2212-5671(14)00301-3)
- Ayvar-Campos, F. J., Navarro-Chávez, J. C. L., y Giménez-García, V. M. (2017). La eficiencia de la dimensión ingreso del IDH en México The Efficiency of the Income Dimension of the HDI in Mexico Información del artículo Resumen. *Ensayos Revista de Economía*, 36(362), 95–122.
- Barahona-Urbina, P. (2011). Factores determinantes de la esperanza de vida en Chile. *Anales de La Facultad de Medicina*, 72(4), 255–259.
- Cardona, D., Acosta, L. D., y Bertone, C. L. (2013). Inequidad en salud entre países de Latinoamérica y el Caribe (2005-2010). *Gaceta Sanitaria*, 27(4), 292–297. <http://doi.org/10.1016/j.gaceta.2012.12.007>
- Cheng, G., & Zervopoulos, P. D. (2014). Estimating the technical efficiency of health care systems: A cross-country comparison using the directional distance function. *European Journal of Operational Research*, 238(3), 899–910. <http://doi.org/10.1016/j.ejor.2014.05.007>
- CONEVAL. (2017a). Evolución de Dimensiones de la Pobreza. Recuperado el 24 de Abril de 2017 de <http://www.coneval.org.mx/Medicion/EDP/Paginas/Datos-del-Modulo-de-Condiciones-Socioeconomicas.aspx>
- CONEVAL. (2017b). Informe de Pobreza en México 2014. Recuperado el 24 de Abril de 2017 de <http://www.coneval.org.mx/InformesPublicaciones/Documents/Informe-pobreza-Mexico-2014.pdf>
- Cooper, W. W., Seiford, L. M., & Tone, K. (2007). *Data Envelopment Analysis*. A

Comprehensive Text with Models, Applications, References and DEA-Solver Software (2nd ed.). New York, USA: Springer Science & Business Media. <http://doi.org/10.1007/978-0-387-45283-8>

Cordero, J. M., Nuño-Solinís, R., Orueta, J. F., Polo, C., del Río-Cámara, M., y Alonso-Morán, E. (2016). Evaluación de la eficiencia técnica de la atención primaria pública en el País Vasco, 2010-2013. *Gaceta Sanitaria*, 30(2), 104–109. <http://doi.org/10.1016/j.gaceta.2015.11.002>

Cordero Ferrera, J. M., Pedraja Chaparro, F., y Salinas Jiménez, J. (2005). Eficiencia en educación secundaria e inputs no controlables: Sensibilidad de los resultados ante modelos alternativos. *Hacienda Pública Española*, 2(173), 61–83.

Davutyan, N., & Bilsel, M. (2014). Efficiency of Turkish Provincial General Hospitals with Mortality as Undesirable Output. In I. H. Osman, A. L. Anouze, & A. Emrouznejad (Eds.), *Handbook of Research on Strategic Performance Management and Measurement Using Data Envelopment Analysis* (1st. ed., pp. 426–436). Hershey, USA: ALMOS.

De Nicola, A., Gitto, S., & Mancuso, P. (2012). Uncover the predictive structure of healthcare efficiency applying a bootstrapped data envelopment analysis. *Expert Systems with Applications*, 39(12), 10495–10499. <http://doi.org/10.1016/j.eswa.2012.02.074>

Farrell, M. J. (1957). The measurement of productive efficiency. *Journal of the Royal Statistical Society. Series A (General)*, 120(3), 253–290. <http://doi.org/10.2307/2343100>

Fried, H. O., Schmidt, S. S., & Yaisawarng, S. (1999). Incorporating the operating environment into a nonparametric measure of technical efficiency. *Journal of Productivity Analysis*, 12(3), 249–267. <http://doi.org/10.1023/A:1007800306752>

Guan, W., & Xu, S. (2016). Study of spatial patterns and spatial effects of energy eco-efficiency in China. *Journal of Geographical Sciences*, 26(9), 1362–1376. <http://doi.org/10.1007/s11442-016-1332-x>

Hadad, S., Hadad, Y., & Simon-Tuval, T. (2013). Determinants of healthcare system's efficiency in OECD countries. *The European Journal of Health Economics*, 14(2), 253–265. <http://doi.org/10.1007/s10198-011-0366-3>

Harttgen, K., & Klasen, S. (2012). A household-based human development index. *World Development*, 40(5), 878–899. <http://doi.org/10.1016/j.worlddev.2011.09.011>

Idrovo, Á. J. (2005). Desigualdad en el ingreso, corrupción y esperanza de vida al nacer en México. *Revista de Salud Pública*, 7(2), 121–129.

INEGI. (2017). Número de médicos en instituciones públicas de salud en contacto con el paciente. Recuperado el 26 de Abril de 2017 de http://www3.inegi.org.mx/sistemas/cni/seriesestadisticas.aspx?idOrden=1.1&IndBase=6200009719*6300000266&indCve=6200009720&gen=595&d=n

Iñiguez, P. A., Ferreyra, E. L., Arburua, M., Hernández, M. S., y Iñiguez, A. L. (2012). La eficiencia del sistema de salud en las provincias. Un análisis con variables discrecionales y no discrecionales. *Cuadernos Del CIMBAGE*, 14(1), 73–87.

Isard, W. (1960). *Methods of Regional Analysis: An introduction to regional science*. (W. Isard, D. F. Bramhall, G. A. P. Carrothers, J. H. Cumberland, L. N. Moses, D. O. Price, & E. W. Schooler, Eds.) (1 st. ed.). Cambridge, Massachusetts: The M.I.T. Press.

Jakovljevic, M. B., Vukovic, M., & Fontanesi, J. (2016). Life expectancy and health expenditure evolution in Eastern Europe—DiD and DEA analysis. *Expert Review of Pharmacoeconomics & Outcomes Research*, 16(4), 537–546. <http://doi.org/10.1586/14737167.2016.1125293>

Kirigia, J. M., Emrouznejad, A., Sambo, L. G., Munguti, N., & Liambila, W. (2004). Using Data Envelopment Analysis to Measure the Technical Efficiency of Public Health Centers in Kenya. *Journal of Medical Systems*, 28(2), 155–166. <http://doi.org/10.1023/B:JOMS.0000023298.31972.c9>

Liu, B., Wang, X., & Huo, T. (2014). Spatial Econometric Analysis of the Energy Efficiency of the Chinese Regional Construction Industry. In J. Wang, Z. Ding, L. Zou, & J. Zuo (Eds.),

- Proceedings of the 17th International Symposium on Advancement of Construction Management and Real Estate* (1st. ed., pp. 697–708). Berlin, Heidelberg: Springer Berlin Heidelberg. http://doi.org/10.1007/978-3-642-35548-6_72
- London, S., Temporelli, K., y Monterubbianesi, P. D. (2009). Vinculación entre salud, ingreso y educación: Un análisis comparativo para América Latina. *Economía Y Sociedad*, XIV(23), 125–146.
- McGillivray, M., & White, H. (1993). Measuring development? The UNDP's Human Development Index. *Journal of International Development*, 5(2), 183–192. <http://doi.org/10.1002/jid.3380050210>
- Meyer, J. R. (1965). Regional Economics: A Survey. In American Economic Association (Ed.), *Surveys of Economic Theory Vol. II* (1 st., pp. 240–271). London, U. K.: Palgrave Macmillan UK.
- Mirzosaid, S. (2011). Health Expenditure Efficiency in the Commonwealth of Independent States: A Data Envelopment Analysis Approach. *Transition Studies Review*, 18(2), 384–404. <http://doi.org/10.1007/s11300-011-0204-4>
- Monterubbianesi, P. D. (2014). El rol de la salud en el proceso de crecimiento económico: una revisión de la literatura. *Cuadernos de Economía*, 33(62), 91–121. <http://doi.org/10.15446/cuad.econ.v33n62.43667>
- Moreno Serrano, R., y Vayá Valcarce, E. (2000). *Técnicas econométricas para el tratamiento de datos espaciales: La econometría espacial* (1 st.). Barcelona, España: Edicions de la Universitat de Barcelona.
- Moreno Serrano, R., y Vayá Valcarce, E. (2002). Econometría espacial: nuevas técnicas para el análisis regional. Una aplicación a las regiones europeas. *Investigaciones Regionales*, 1, 83–106.
- Nevárez-Sida, A., Constantino-Casas, P., y García-Contreras, F. (2007). Comparación de la eficiencia técnica de los sistemas de salud en países pertenecientes a la OMS. *Economía, Sociedad Y Territorio*, VI(24), 1071–1090.
- Paelinck, J. H. P., & Klaassen, L. H. (1979). *Spatial Econometrics* (1 st.). Farnborough: Saxon House.
- Pinzón Florez, C. E., Reveiz, L., Idrovo, A. J., y Reyes Morales, H. (2014). Gasto en salud, la desigualdad en el ingreso y el índice de marginación en el sistema de salud de México. *Revista Panamericana de Salud Pública*, 35(1), 1–7.
- Pittman, R. W. (1983). Multilateral productivity comparisons with undesirable outputs. *The Economic Journal*, 93(372), 883–891. <http://doi.org/10.2307/2232753>
- PNUD. (2017a). Human Development Data (1990-2015). Recuperado el 3 de Mayo de 2017 de <http://hdr.undp.org/en/data>
- PNUD. (2017b). Sobre el desarrollo humano. Recuperado el 15 de Febrero de 2017 de <http://hdr.undp.org/es/content/sobre-el-desarrollo-humano>
- Schaffer, A., Simar, L., & Rauland, J. (2011). Decomposing regional efficiency. *Journal of Regional Science*, 51(5), 931–947. <http://doi.org/10.1111/j.1467-9787.2011.00731.x>
- Secretaría de Salud. (2017a). Cubo Dinámico. Recuperado el 24 de Abril de 2017 de http://www.dgis.salud.gob.mx/contenidos/basesdedatos/bdc_recursos_gobmx.html
- Secretaría de Salud. (2017b). Esperanza de Vida al Nacer por Entidad Federativa. Recuperado el 24 de Abril de 2017 de http://www.dgis.salud.gob.mx/contenidos/sinais/indica_gral_gobmx.html
- Seiford, L. M., & Zhu, J. (2002). Modeling undesirable factors in efficiency evaluation. *European Journal of Operational Research*, 142(1), 16–20. [http://doi.org/10.1016/S0377-2217\(01\)00293-4](http://doi.org/10.1016/S0377-2217(01)00293-4)
- SEP. (2017). Indicadores y Pronósticos Educativos. Recuperado el 25 de Abril de 2017 de http://www.sniesep.gob.mx/indicadores_pronosticos.html
- SHCP. (2017). Indicadores de Obligaciones de Entidades Federativas y Municipios 2015.

Recuperado el 25 de Abril de 2017 de

http://obligaciones_entidades.hacienda.gob.mx/es/OBLIGACIONES_ENTIDADES/2015

Sueyoshi, T., & Goto, M. (2010). Should the US clean air act include CO2 emission control?: Examination by data envelopment analysis. *Energy Policy*, 38(10), 5902–5911.

<http://doi.org/10.1016/j.enpol.2010.05.044>

Sun, C., Zhao, L., Zou, W., & Zheng, D. (2014). Water resource utilization efficiency and spatial spillover effects in China. *Journal of Geographical Sciences*, 24(5), 771–788.

<http://doi.org/10.1007/s11442-014-1119-x>

Varabyova, Y., & Schreyögg, J. (2013). International comparisons of the technical efficiency of the hospital sector: Panel data analysis of OECD countries using parametric and non-parametric approaches. *Health Policy*, 112(1–2), 70–79.

<http://doi.org/10.1016/j.healthpol.2013.03.003>

Vidoli, F., & Canello, J. (2016). Controlling for spatial heterogeneity in nonparametric efficiency models: An empirical proposal. *European Journal of Operational Research*, 249(2), 771–783. <http://doi.org/10.1016/j.ejor.2015.10.050>

Wang, K., Yu, S., & Zhang, W. (2013). China's regional energy and environmental efficiency: A DEA window analysis based dynamic evaluation. *Mathematical and Computer Modelling*, 58(5–6), 1117–1127. <http://doi.org/10.1016/j.mcm.2011.11.067>

1. Profesor-Investigador. Instituto de Investigaciones Económicas y Empresariales. Universidad Michoacana de San Nicolás de Hidalgo. Doctor en Ciencias del Desarrollo Regional por la UMSNH. fayvar@umich.mx

2. Profesor-Investigador. Instituto de Investigaciones Económicas y Empresariales. Universidad Michoacana de San Nicolás de Hidalgo. Doctor en Ciencias del Desarrollo Regional por la UMSNH. cesar126@hotmail.com

3. Profesor-Investigador. Departamento de Empresa. Universidad Autónoma de Barcelona. Doctor en Ciencias Económicas y Empresariales por la UAB. victor.gimenez@uab.cat

Revista ESPACIOS. ISSN 0798 1015

Vol. 39 (Nº 37) Año 2018

[Índice]

[En caso de encontrar un error en esta página notificar a [webmaster](#)]

©2018. revistaESPACIOS.com • ®Derechos Reservados