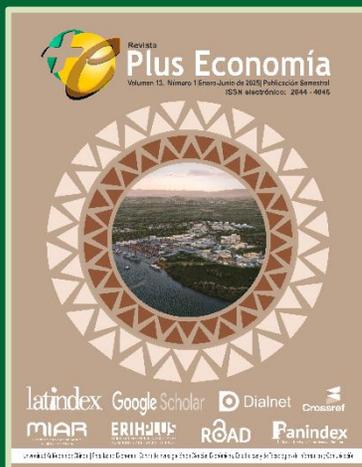




Revista Plus Economía

República de Panamá
Universidad Autónoma de Chiriquí (UNACHI)
Facultad de Economía
Centro de Investigación en Ciencias Económicas, Estadísticas y de Tecnologías de Información
y Comunicación (CICEETIC)
pluseconomia@unachi.ac.pa



ISSN electrónico: 2644-4046

LA REGRESIÓN PONDERADA GEOGRÁFICAMENTE: UN ANÁLISIS DEL CAPITAL HUMANO Y SUS EFECTOS SOBRE LAS NECESIDADES BÁSICAS INSATISFECHAS

*Geographically weighted regression: An analysis
of human capital and its effects on unsatisfied
basic needs*

Vol. 13, Núm. 1 | Enero-Junio de 2025 | pp. 39-53

Cristian Rabanal

Consejo Nacional de Investigaciones
Científicas y Técnicas (CONICET).
Universidad Nacional de Río Cuarto (UNRC).
Universidad Nacional de Villa Mercedes
(UNViMe), Argentina.



LA REGRESIÓN PONDERADA GEOGRÁFICAMENTE: UN ANÁLISIS DEL CAPITAL HUMANO Y SUS EFECTOS SOBRE LAS NECESIDADES BÁSICAS INSATISFECHAS.

DOI: 10.59722/pluseconomia.v13i1.864

Fecha de recepción: 14/10/2024

Fecha de aprobación: 10/12/2024

Autor

Cristian Rabanal

 <https://orcid.org/0000-0003-1608-2277>

cristianrabanal@conicet.gov.ar

Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET).
Universidad Nacional de Río Cuarto (UNRC). Universidad Nacional de Villa Mercedes (UNViMe), Argentina.

Resumen

En la modelización de los datos espaciales es habitual que los fenómenos estudiados presenten derivas espaciales o inestabilidad estructural en los parámetros. Cuando esto ocurre, el análisis paramétrico global resulta inadecuado dada su imposibilidad de capturar dichas situaciones. Uno de los procedimientos que permiten corregir los contextos mencionados, y que ha ido ganando terreno en el campo académico durante la última década, es la Regresión Ponderada Geográficamente -RPG- (más conocida por sus siglas en inglés GWR -Geographically Weighted Regression-). El objetivo del presente trabajo es describir los principales aspectos metodológicos de dicha técnica y presentar una aplicación de la misma con datos censales. Se estudia el impacto del capital humano representado por el porcentaje de personas que cursan o cursaron estudios universitarios sobre las necesidades básicas insatisfechas. Los resultados permiten obtener resultados diferenciados por zonas geográficas del capital humano sobre las distintas regiones geográficas.



Palabras clave

Regresión ponderada geográficamente, regresión local, capital humano, necesidades básicas insatisfechas.

GEOGRAPHICALLY WEIGHTED REGRESSION: AN ANALYSIS OF HUMAN CAPITAL AND ITS EFFECTS ON UNSATISFIED BASIC NEEDS

Abstract: In spatial data modeling, it is common for the studied phenomena to exhibit spatial drifts or structural instability in the parameters. When this occurs, global parametric analysis becomes inadequate due to its inability to capture such situations. One of the procedures that can correct the mentioned contexts, which has gained traction in the academic field over the last decade, is Geographically Weighted Regression (GWR). The aim of this work is to describe the main methodological aspects of this technique and present an application of it using census data. The impact of human capital, represented by the percentage of people currently pursuing or who have completed university studies, on unmet basic needs is being studied. The results allow for differentiated insights by geographic areas regarding human capital across different regions.

Keywords: Geographically weighted regression, local regression, human capital, unmet basic needs.

Introducción

La Regresión Ponderada Geográficamente (RPG) constituye una técnica propicia para el tratamiento y modelización de aquellos fenómenos en los que existe deriva espacial en los parámetros o inestabilidad estructural de los mismos, siendo este último caso

fuente habitual de heterocedasticidad en los residuos de modelos espaciales (Baronio, Vianco y Rabanal, 2012). En otras palabras, el procedimiento permite una adecuada modelización de aquellas situaciones en las cuales los parámetros no permanecen constantes en el espacio (no estacionariedad



espacial), tal como se considera en la teoría clásica.

Propuesto inicialmente por Brunson et. al. (1996), los autores diferencian este enfoque del método de Filtrado Espacial Adaptativo (SAF - Spatial Adaptive Filtering-) presentado por Foster y Gorr (1986), el Modelo de Coeficientes Aleatorios (Aitken, 1996) y la Modelización Multinivel (Goldstein, 1987).

En el marco de la economía, su aplicación es variada y abarca desde temas relacionados a problemáticas urbanas como la pobreza y la determinación del precio de los inmuebles, hasta cuestiones vinculadas a la macroeconomía internacional. De esta manera, la implementación de la Regresión Ponderada Geográficamente facilita la estimación de modelos cuyos parámetros pueden variar en el espacio, en lugar de mantenerse fijos para toda la muestra. En consecuencia, la técnica no sólo puede atraer interés científico, sino que también puede ser una herramienta de diagnóstico importante para la implementación de las políticas públicas.

En este contexto, y dado que se enmarca en los modelos locales no paramétricos, la técnica puede resultar de especial utilidad cuando se está analizando un conjunto de datos con el propósito de establecer relaciones entre variables de subconjuntos muestrales, dado que permite evitar la denominada paradoja de Simpson, situación que se presenta cuando al analizar subconjuntos de datos se revierten los resultados obtenidos de manera global (Fotheringham, et. al. 2002).

El objetivo del trabajo es presentar el esquema teórico del procedimiento y realizar una aplicación de la misma para modelizar las Necesidades Básicas Insatisfechas en la provincia de Córdoba República Argentina, a partir de datos del Censo Nacional 2010 presentados a nivel de radios censales. En este sentido, se espera a priori encontrar diferencias en los valores estimados según estos se refieran a áreas urbanas o rurales.

Además de esta sección, el trabajo presenta otras cuatro. En la segunda, se analiza la justificación teórica de su empleo, como así también las posibles debilidades del enfoque. En la tercera se realiza una explicación



metodológica de la técnica. La cuarta sección presenta los resultados. Finalmente, se exponen las principales conclusiones.

Materiales y métodos

La RPG es una técnica no paramétrica (Páez, 2002) que comparte una gran cantidad de principios con la técnica de Regresión Ponderada Localmente introducida por Cleveland (1979).

En términos generales, una regresión no paramétrica, a diferencia de la regresión lineal clásica, parte de considerar una relación entre una variable a explicar y_i y un conjunto de variables explicativas x_1, x_2, \dots, x_k pero sin establecer el supuesto de linealidad sobre la función que las relaciona, $g(x_i)$, sino más bien considerando que el valor promedio de $g(x_i)$ es una función de regresión suavizada sin especificar una forma analítica para la misma. De esta forma, la regresión no paramétrica permite considerar fenómenos no lineales, proporcionando un herramienta valioso para muchos fenómenos económicos y sociales. En el contexto de la economía, la no linealidad y la

teoría del caos son temas que han tomado gran impulso, particularmente desde la década de los noventa (Brock y Dechert (1991), Brock (1993), Kiel y Elliotts (1997)) y fundamentalmente en el campo de las series de tiempo.

El aspecto relevante se centra entonces en el suavizado. Una de las posibilidades más extendidas tiene que ver con el método de promedios locales. De acuerdo con Servy et. al. (2006), esta técnica considera que existe una muestra grande y divide el rango de los regresores en intervalos que pueden sobreponerse, a los que se denominan ventanas. Los centros de dichas ventanas se denominan focos. En consecuencia, la función $g(x_i)$ se podría estimar para un gran número de valores focales, pero para ello será preciso establecer un criterio para determinar el ancho de la ventana. Una posibilidad pasa por considerar una amplitud (h) fija para todas las ventanas. La alternativa consiste en tomar en consideración un ancho que se ajusta, para que todas incluyan el mismo número de observaciones.

Naturalmente, en el campo de la econometría espacial el concepto de ventana local refiere a una región, por lo

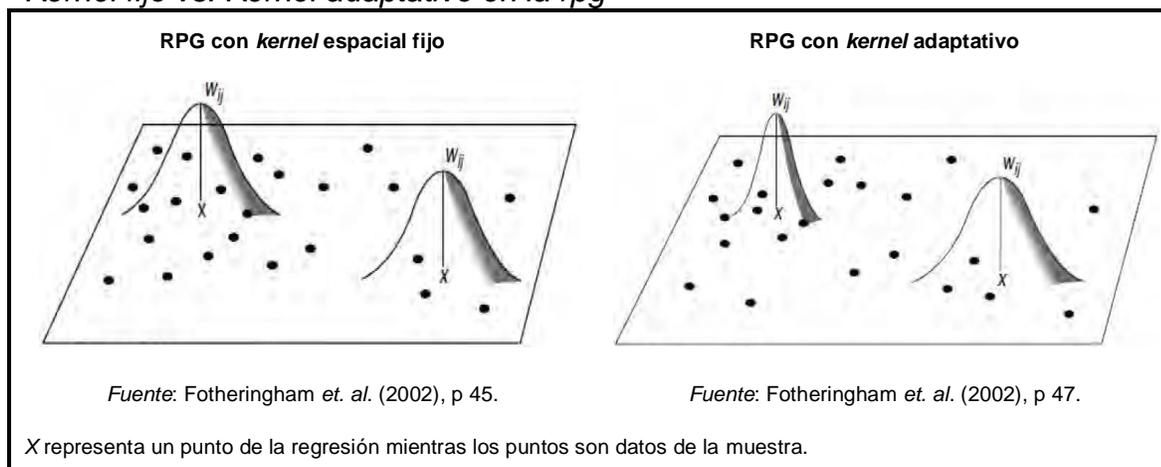


que el propósito de la RPG es generar un modelo para cada región. La característica central de la RPG es que las observaciones que forman parte del modelo serán ponderadas en función de su localización geográfica. Esto marca una importante diferencia con los métodos de Regresión Lineal Múltiple de la teoría clásica, que involucran a observaciones en un plano “global” (Fotheringham et. al., 1997). En concreto, la teoría clásica presupone la obtención de un parámetro es el resultado de ponderar a todas las observaciones por igual, lo que equivale

a decir que el modelo aplica por igual para toda el área geográfica del estudio, mientras que la RPG estima parámetros locales dentro de una distancia establecida a priori y con ponderaciones más altas para las observaciones más próximas.

Las técnicas de suavizado comúnmente utilizadas en el campo espacial están vinculadas con la estimación mediante núcleos (kernels) - kernel smoother-. La figura 1 ilustra el caso de los núcleos fijos y los adaptativos.

Figura 1
Kernel fijo vs. Kernel adaptativo en la rpg



El caso del núcleo espacial fijo, representa una situación en la que todos los núcleos tienen el mismo

ancho de banda (*bandwith*). En cada uno de ellos, los puntos muestrales próximos al punto de la regresión tendrán mayor ponderación. Sin



embargo, algunos autores como Fabián (2014) alertan que la RPG en muchos casos no es sensible a la ponderación, sino al impacto del ancho de banda utilizado para la ponderación.

Por otra parte, otro inconveniente puede presentarse cuando existen partes del área donde los datos muestrales se encuentran muy distanciados. Esta situación, en el marco de modelos locales, puede inducir a un error mayor o directamente a la imposibilidad de estimar algunos parámetros debido a un número de observaciones insuficientes. En este contexto, se tornan valiosas las suavizaciones efectuadas a partir de núcleos adaptativos, ya que los mismos presentan un ancho de banda que se modifica (adapta) al número de observaciones muestrales. En este sentido, la figura 1 muestra cómo una mayor dispersión (i.e. regiones más extensas) de datos muestrales conduce a un mayor ancho de banda, mientras que una mayor concentración implica un menor ancho de banda.

Naturalmente, la elección de un procedimiento u otro es uno de los aspectos más discutibles del procedimiento, razón por la cual la

estimación con cada uno de los procedimientos suele ser una recomendación usual.

Por otra parte, respecto a la especificación de la RPG y modelos combinado, de acuerdo con Brudson *et. al.* (1996), podemos partir de considerar una variable dependiente, y , y un conjunto de m variables independientes x_k ($k=1,2,\dots,m$) para cada una de las n observaciones para representar una RPG como sigue:

$$y_i = \beta_{0i}(\mathbf{u}) + \beta_{1i}(\mathbf{u})x_{1i} + \beta_{2i}(\mathbf{u})x_{2i} + \dots + \beta_{mi}(\mathbf{u})x_{mi} + \varepsilon_i, \quad i = 1, 2, \dots, n \quad (1)$$

donde $\beta_{mi}(\mathbf{u})$ indica la dependencia de los parámetros a una localización específica \mathbf{u} , que refiere a un vector de coordenadas.

El estimador es similar al que se obtendría con Mínimos Cuadrados Ponderados, sólo que en este caso los estimadores están condicionados a \mathbf{u} (Charlton *et. al.*, 2009):

$$\hat{\beta}(\mathbf{u}) = (X^T W(\mathbf{u}) X)^{-1} X^T W(\mathbf{u}) Y \quad (2)$$



La matriz $W(\mathbf{u})$ resultante será la siguiente:

$$\begin{bmatrix} w_1(\mathbf{u}) & 0 & 0 & 0 \\ 0 & w_2(\mathbf{u}) & 0 & 0 \\ 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & w_n(\mathbf{u}) \end{bmatrix}$$

(3)

En este punto es donde cobra importancia el concepto de kernel o núcleo como esquema de ponderación. Si bien existen diversas formulaciones, los más habituales son el de tipo Gaussiano y el bicuadrático, siendo sus formulaciones respectivamente las siguientes:

$$w_i(\mathbf{u}) = e^{-0.5 \left(d_i(\mathbf{u})/h \right)^2}$$

(4)

$$w_i(\mathbf{u}) = \left(1 - \left(d_i(\mathbf{u})/h \right)^2 \right)^2$$

(5)

donde $w_i(\mathbf{u})$ es el peso de la i -ésima observación en relación a la localización y $d_i(\mathbf{u})$ una medida de distancia entre la observación i -ésima en relación a la localización \mathbf{u} , y h el ancho de banda. Resulta evidente que cuanto mayor sea el ancho de banda considerado más se aproximará la estimación local lograda

por un modelo de RPG a una estimación global obtenida a partir de un modelo de MCO. En el caso extremo que d sea igual a la máxima distancia entre puntos, los parámetros obtenidos por RPG serán iguales a los de MCO.

Una alternativa a los modelos como el expresado en la ecuación (1), consiste en realizar una combinación del mismo con uno general. Es decir, es posible explicar una variable a partir de términos locales y de términos globales. En términos generales, esto equivale a lo siguiente:

$$y_i = \beta_{0i}(\mathbf{u}) + \beta_{1i}(\mathbf{u})x_{1i} + \beta_{2i}(\mathbf{u})x_{2i} + \dots + \beta_{mi}(\mathbf{u})x_{mi} + \alpha_{1i}z_{1i} + \alpha_{2i}z_{2i} + \dots + \alpha_{ni}z_{ni} + \varepsilon_i, \quad i = 1, 2, \dots, n$$

(6)

donde los betas representan los términos locales y los alfa los términos globales. Esto es particularmente útil en aquellos casos que existan variables para las que el investigador no espera que existan diferencias en función de la localización.

(tipo de estudio, población y diseño muestral, técnicas e instrumentos para



la recolección de datos, técnicas de análisis).

Resultados

En esta sección se presentará una aplicación de la técnica a partir de datos del Censo Nacional 2010 presentados a nivel de radios censales para la provincia de Córdoba, lo que permite contar con 4752 observaciones y cuya fuente de información es el *Instituto Nacional de Estadísticas y Censos (INDEC)*. El *software* con el que se procesará la información es *GWR4*¹ (*Geographically Weighted Regression*).

En particular, a partir de dicha información se calculan tres variables: *Porcentaje de hogares con Necesidades Básicas Insatisfechas (HNBI)*, *Porcentaje de personas que cursan o cursaron estudios universitarios (EUNIV)* y *Tasa de desempleo (TDES)* como variable de control. Con estas variables, se postula un modelo simple como el siguiente:

$$HNBI_i = \beta_{0i} + \beta_{1i}EUNIV_i + \beta_{2i}TDES_i + \varepsilon_i \quad (7)$$

Esto es, se intentará explicar la variable *HNBI* en función de *EUNIV* y *TDES*. Se espera *a priori* un signo negativo para β_{1i} y un signo positivo para β_{2i} . La selección de variables explicativas ha sido ampliamente estudiado en el campo teórico y empírico (Rivas *et. al.*, 2017), por lo que más allá de los signos, el interés se centra en la posibilidad de encontrar diferencias significativas para los betas en función de la localización.

A los efectos de ilustrar las mejoras que la RPG puede incorporar, se estima (7) en primer lugar de manera global y por MCO. Dichos resultados se presentan en la Tabla 1.

¹ Desarrollado por Tomoki Nakaya (Department of Geography, Ritsumeikan University), Martin Charlton, Chris Brunsdon, Paul Lewis (National Centre of Geocomputation, National University of Ireland), Jing Yao (School of Social and Political Sciences, University of Glasgow), y Stewart Fotheringham (School of Geographical Sciences & Urban Planning, Arizona State University).



Tabla 1
Estimación global por MCO

Coficiente	Coficiente	Error Estándar	Estadístico t	Probabilidad
Intercepto	0.0961093	0.00160712	59.8023	0.00000
EUNIV	-0.458084	0.0159409	-28.7363	0.00000
TDES	0.486806	0.0285786	17.0339	0.00000
<hr/>				
R cuadrado		0.199518	Akaike IC	-10789.5
R cuadrado ajustado		0.199181	Schwarz C	-10770.1
Suma de los residuos al cuadrado		28.69346		
Estadístico F		591.8360		
Probabilidad de Estadístico F		0.000000		
<hr/>				
Multicolinealidad	<i>Número de condición:</i>		2.471323	
Normalidad	<i>Jarque Bera</i>		40815.6200 (0.00000)	
Heterocedasticidad	<i>Breusch-Pagan</i>		2970.3549 (0.00000)	
	<i>Koenker-Bassett</i>		384.4222 (0.00000)	
Dependencia espacial	<i>LM robusto (lag)</i>		0.2347 (0.62805)	
	<i>LM robusto (error)</i>		58.3531 (0.0000)	
	<i>LM SARMA</i>		371.9604 (0.0000)	

Fuente: elaboración propia

Desde dicha estimación se pueden extraer varias implicancias preliminares. Primero, los coeficientes de las variables explicativas son individual y conjuntamente significativas, muestran signos esperados y su variación conjunta permiten explicar cerca del veinte por ciento de las variaciones de la variable *HNBI*. Segundo, el número de condición resultante es muy bajo, por lo que se descarta la multicolinealidad

entre las variables explicativas². Tercero, existe un problema de normalidad de residuos. Cuarto, existe un problema de heterocedasticidad. Y finalmente, el análisis de dependencia espacial sugiere la posibilidad de que los datos se ajusten a un modelo de error espacial³. En este último caso, a

² Se adopta el criterio de Gujarati (2010), según el cual existe multicolinealidad si el número de condición es un valor igual o mayor a cien.

³ En este caso el modelo de error espacial sería el siguiente:

$$HNBI_i = \beta_{0i} + \beta_{1i}EUNIV_i + \beta_{2i}TDES_i + \varepsilon_i$$

$$\varepsilon_i = \lambda W \varepsilon_i + \mu_i$$



pesar de que mejora el nivel de explicación, el coeficiente de lambda es significativo y mejora el nivel de explicación, el problema de heterocedasticidad persiste, lo cual podría ser indicio de inestabilidad estructural de los parámetros, lo que habilita a realizar la estimación de la ecuación (7) a nivel local mediante la técnica de RPG.

Antes de realizar la estimación utilizando la RPG es necesario adoptar un criterio en relación a la elección de un tipo de *kernel*, algo que naturalmente debe estar basado en las características de la dispersión de datos. Dado que los radios censales de Córdoba en general no difieren de manera significativa en extensión podría ser conveniente la elección de un *kernel* fijo, tanto en sus variantes Gaussiano y bicuadrático. Sin embargo, y dado que existen al norte y oeste de la provincia algunos radios algo más extensos, y en orden a obtener resultados más robustos, se realizará también la estimación mediante un *kernel* adaptativo, en ambas versiones al igual que el fijo.

Los resultados de dichas estimaciones se muestran en la Tabla 2, a continuación.

Tabla 2
Estimación RPG

Tipo de Kernel	Medida	Intercepto	EUNIV	TDES
Gaussiano Fijo	<i>Mínimo</i>	-0,005705	- 6,767147	-4,807010
	<i>Menor cuartil</i>	0,085026	- 0,983418	0,282505
	<i>Mediana</i>	0,113642	- 0,858826	0,315600
	<i>Mayor cuartil</i>	0,117976	- 0,452199	0,743324
	<i>Máximo</i>	0,415437	1,132171	8,083587
Bicuadrático Fijo	<i>Mínimo</i>	0,006880	- 6,042556	-4,214252
	<i>Menor cuartil</i>	0,084779	- 0,916587	0,303899
	<i>Mediana</i>	0,111003	- 0,788309	0,316286
	<i>Mayor cuartil</i>	0,115421	- 0,466870	0,815343
	<i>Máximo</i>	0,391284	0,837425	7,740748
Gaussiano Adaptativo	<i>Mínimo</i>	0,046486	- 2,589035	-1,076328
	<i>Menor cuartil</i>	0,085199	- 1,087539	0,240669
	<i>Mediana</i>	0,108064	- 0,747656	0,550736
	<i>Mayor cuartil</i>	0,128396	- 0,400124	0,904162
	<i>Máximo</i>	0,187613	- 0,164425	3,190814
Bicuadrático Adaptativo	<i>Mínimo</i>	0,017395	- 3,814672	-6,227546
	<i>Menor cuartil</i>	0,078195	- 1,167566	0,030449
	<i>Mediana</i>	0,105079	- 0,757341	0,565447
	<i>Mayor cuartil</i>	0,130920	- 0,426200	1,156516
	<i>Máximo</i>	0,280642	0,020473	10,593568
	<i>MCO</i>	0,106368	- 0,769826	0,676635

Fuente: elaboración propia

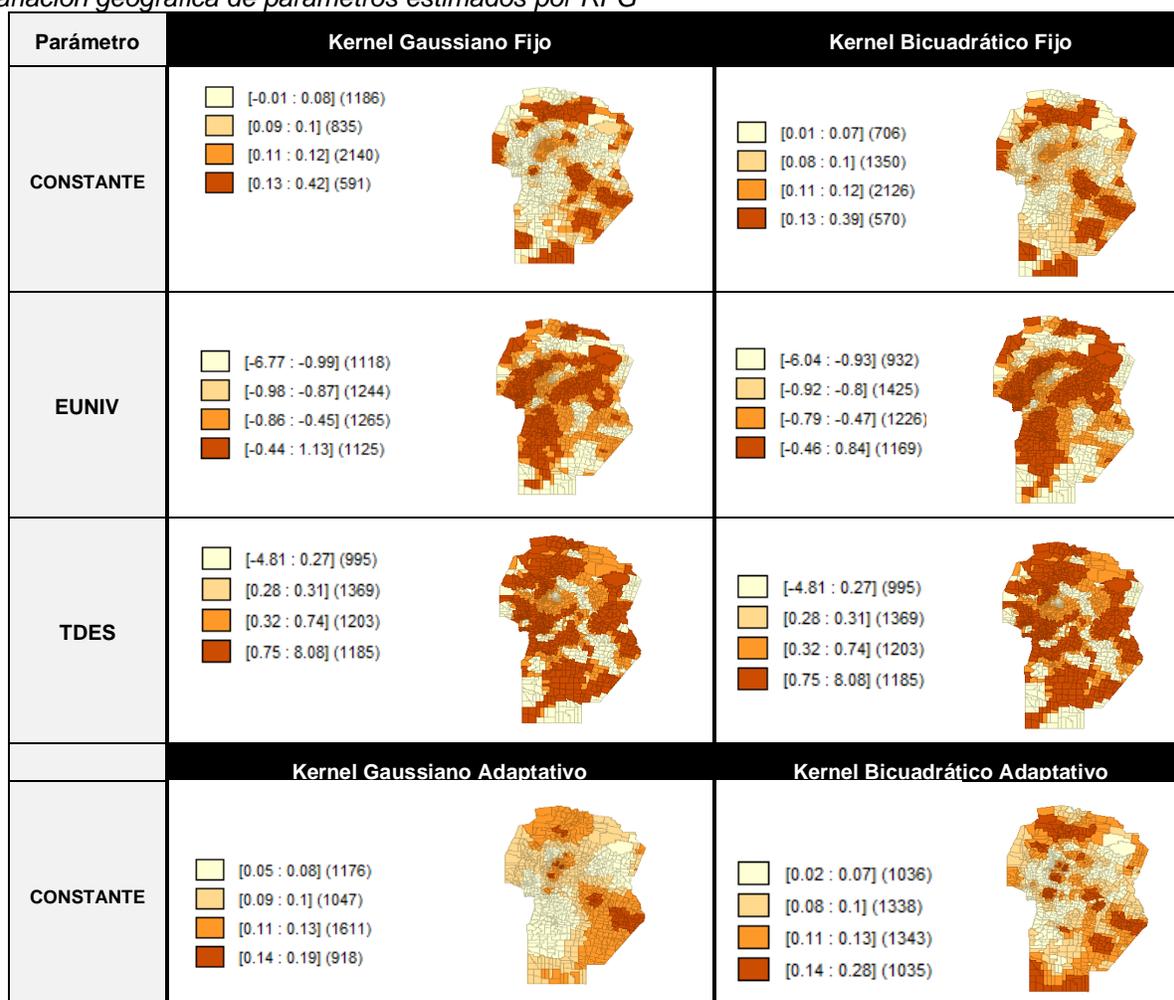
Los resultados permiten dar cuenta no sólo de variabilidad de los parámetros cuando estos no son

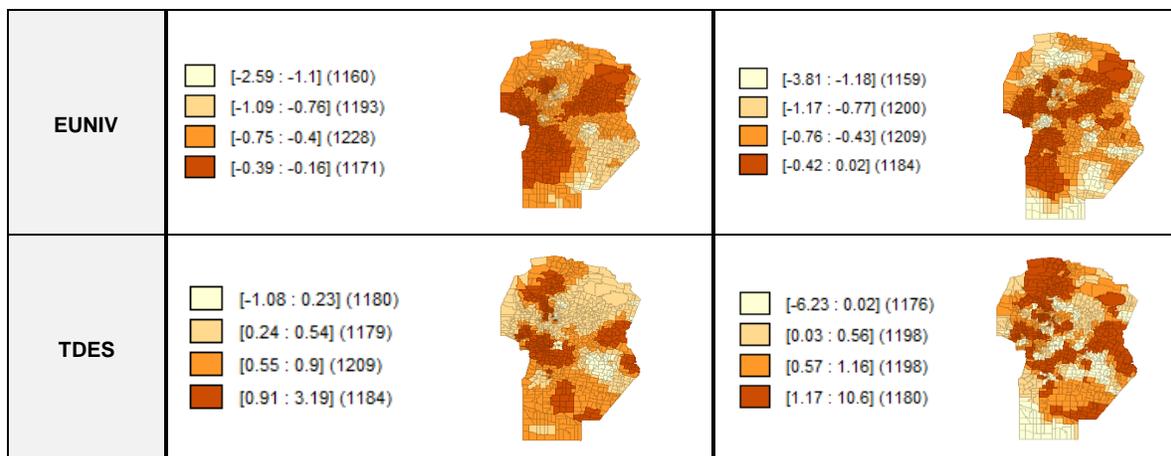


estimados de manera global (*MCO*), sino casos en los cuales pueden asumir valores de signos contrarios, siendo el caso más emblemático el coeficiente de la variable *TDES*. La relevancia de este aspecto es fundamental, y cualquier modelo que pretenda reflejar mayor exactitud en la medición debe considerarlo, ya que está dando cuenta que la estructura económica varía en

función de las localizaciones. Asimismo, las estimaciones realizadas con *kernel bicuadrático* de ancho de banda adaptativo, presentan en general la performance caracterizada por tener asociados los mayores rangos intercuartílicos. La figura 2 ilustra la variación geográfica de los parámetros para cada uno de los tipos de *kernels* seleccionados.

Figura 2
Variación geográfica de parámetros estimados por RPG





Fuente: elaboración propia

Tabla 3
Elección de modelos de RPG

	Kernel Gaussiano Fijo	Kernel Bicuadrático Fijo	Kernel Gaussiano Adaptativo	Kernel Bicuadrático Adaptativo
R²	0,376542	0,336911	0,376760	0,484348
R² ajustado	0,319130	0,300409	0,348466	0,416537
Criterio de Información de Akaike	-11379,415	-11300,988	-11682,323	-12042,860
Suma de residuos al cuadrado	22,347991	23,768578	22,340168	18,483649

Fuente: elaboración propia

Finalmente, se realiza la elección del mejor modelo en término de los indicadores usuales. En este sentido, de acuerdo con los resultados reportados en la Tabla 3, el modelo basado en el kernel bicuadrático adaptativo⁴ es el que muestra los mejores resultados, ya que ofrece el mayor nivel de explicación reduciendo la suma de los residuos al cuadrado. La característica central de este modelo es que es el que exhibe un

mayor rango intercuartílico para la variable *TDES*.

Resulta importante notar que este modelo duplica el nivel de explicación obtenido por el modelo clásico (MCO), al tiempo que permite recoger diferencias provenientes de las localizaciones de las diferentes observaciones. En este sentido, puede observarse por ejemplo, que las localizaciones próximas a centros urbanos tienen en general un menor

⁴ El reporte final del modelo se muestra en el Anexo único.



porcentaje de hogares con necesidades básicas insatisfechas, independientemente de las variables explicativas. Nótese en el mapa correspondiente a la constante que los valores para las observaciones próximas a los límites presentan en general valores mayores⁵.

Discusión

El trabajo presenta una aplicación de la técnica de *Regresión Ponderada Geográficamente* a datos censales. En particular, refleja las mejoras que este tipo de modelización incorpora cuando se enfrentan problemas de inestabilidad estructural.

A partir de datos del censo 2010 de la República Argentina, se presentó un modelo para la provincia de Córdoba en el que se explica el porcentaje de hogares con necesidades básicas insatisfechas en función del porcentaje de personas que cursan o cursaron estudios universitarios y la tasa de desempleo como variable de control.

Aunque el modelo global presenta los signos esperados para los

coeficientes, la modelización mediante la RPG permitió corregir el problema de heterocedasticidad evidenciando las diferentes estructuras de cada una de las regiones.

En orden a obtener la mejor estimación, se incluyeron en primera instancia los cuatro tipos de kernels disponibles, para luego elegir el mejor modelo en términos a las medidas usuales (R^2 ajustado y Criterio de Información de Akaike, entre otras). En este sentido, el modelo con kernel bicuadrático adaptativo resultó ser el de mejor performance, que implicó una mejora del R^2 ajustado de más del cien por ciento, siendo de 0,42 (vs. el 0.20 del modelo global).

Este trabajo podría ser ampliado un mayor número de provincias, incluyendo también un mayor número de variables. Por otra parte, otras formulaciones de tipo mixta podrían también ser consideradas.

Referencias

Aitkin, M. (1996). A General Maximum Likelihood Analysis of Overdispersion in Generalized Linear Models. *Statistics and*

⁵ El sector oeste no refleja esta afirmación, en función de que existe un zona de sierras escasamente poblada “en el borde”.



- Computing, 6(3), 251–262.
doi:10.1007/bf00140869
- Brock, W. A. (1993). Pathways to Randomness in the Economy: Emergent Nonlinearity and Chaos in Economics and Finance. *Estudios Económicos*, 3-55.
- Brock, W. A., & Dechert, W. D. (1991). Chapter 40 Non-linear dynamical systems: Instability and chaos in economics. *Handbook of Mathematical Economics*, 2209–2235. doi:10.1016/s1573-4382(05)80015-3
- Brunsdon, C., Fotheringham, A. S., & Charlton, M. E. (2010). Geographically Weighted Regression: A Method for Exploring Spatial Nonstationarity. *Geographical Analysis*, 28(4), 281–298. doi:10.1111/j.1538-4632.1996.tb00936.x
- Charlton, M., Fotheringham, S., y Brunsdon, C. (2009). Geographically weighted regression. White paper. National Centre for Geocomputation. National University of Ireland Maynooth.
- Cleveland, W. S. (1979). Robust Locally Weighted Regression and Smoothing Scatterplots. *Journal of the American Statistical Association*, 74(368), 829–836. doi:10.1080/01621459.1979.10481038
- Fábián, Z. (2014). Method of the Geographically Weighted Regression and an Example for its Application. *Regional Statistics*, 4(1), 61–75. doi:10.15196/rs04105
- Foster, S. A., y Gorr, W. L. (1986). An Adaptive Filter for Estimating Spatially-Varying Parameters: Application to Modeling Police Hours Spent in Response to Calls for Service. *Management Science*, 32(7), 878–889. doi:10.1287/mnsc.32.7.878
- Fotheringham, A. S., Brunsdon, C. y Charlton, M. E. (2002). Geographically Weighted Regression, the Analysis of Spatially Varying Relationships. University of Newcastle, Newcastle.
- Fotheringham, A. S., Charlton, M., y Brunsdon, C. (1997). Measuring



- Spatial Variations in Relationships with Geographically Weighted Regression. *Recent Developments in Spatial Analysis*, 60–82. doi:10.1007/978-3-662-03499-6_4
- Goldstein, H. (1987). *Multilevel Models in Educational and Social Research*. London: Oxford University Press.
- Gujarati, D., y Porter, D. (2010). *Econometría* (quinta edición). Mc Graw Hill.
- Instituto Nacional de Estadísticas y Censos: www.indec.gov.ar. Último acceso: Octubre de 2024.
- Kiel, L., & Elliott, E. (Eds.). (1996). *Chaos Theory in the Social Sciences*. doi:10.3998/mpub.14623
- Paez, A. (2002). Spatial Parametric Non-Stationarity: a Variance Heterogeneity Approach. In 49th North American Meetings of the Regional Science Association International. San Juan de Puerto Rico (pp. 14-16).
- Torres Rivas, E., Jiménez, M., & Luzardo, M. (2017). Determinantes de la pobreza en Venezuela y Colombia: estudio comparativo 2010-2014. *Semestre Económico*, 20(43), 81–109. doi:10.22395/seec.v20n43a4
- Servy, E., García, M. del C., y Paccapelo, V. (2006). Regresión no paramétrica: una aplicación. X Jornadas de Investigaciones en la Facultad. Facultad de Ciencias Económicas y Estadísticas. Universidad Nacional de Rosario. Lugar: Rosario.