



UNIVERSIDAD DE CARABOBO
FACULTAD DE CIENCIAS ECONÓMICAS Y SOCIALES
ESCUELA DE ECONOMÍA
CAMPUS BÁRBULA



**DETERMINANTES DE LOS PRECIOS DE LA VIVIENDA EN ENTORNOS
URBANOS: APLICACIÓN DE LA REGRESIÓN GEOGRÁFICAMENTE
PONDERADA**

Autor:

Jonathan José Mora Alvarado

Bárbula, marzo del 2024

**Determinantes de los Precios de la Vivienda en Entornos Urbanos:
Aplicación de la Regresión Geográficamente Ponderada¹**

**Determinants of Housing Prices in Urban Environments: Application of
Geographically Weighted Regression**

Autor:

Jonathan José Mora Alvarado

Estudiante de Economía

Universidad de Carabobo

Carabobo - Venezuela

¹ Esta investigación se presenta como trabajo de grado para la carrera de Economía de la Facultad de Ciencias Económicas y Sociales de la Universidad de Carabobo. Este trabajo contó con la tutoría del Dr. Domingo Sifontes.



ACTA VEREDICTO DE TRABAJO DE GRADO

Los suscritos, profesores miembros del Jurado Evaluador designado por el Consejo de Escuela en su Sesión Extraordinaria Nº 746, hacemos constar que el trabajo titulado:

DETERMINANTES DE LOS PRECIOS DE LA VIVIENDA EN ENTORNOS URBANOS: APLICACIÓN DE LA REGRESION GEOGRAFICAMENTE PONDERADA

Elaborador y presentado por:

MORA ALVARADO JONATHAN JOSE

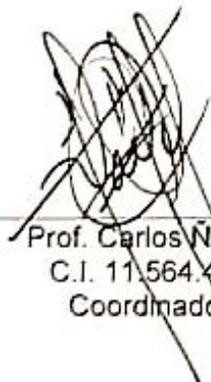
C.I. Nº V- 27.014.808

Reúne los requisitos exigidos para optar al título de ECONOMISTA, de acuerdo a lo establecido en las Normas Internas de Trabajo de Grado de FACES, consideramos que merece la calificación de:

APROBADO

REPROBADO

NO PRESENTO


Prof. Carlos Nañez
C.I. 11.564.442
Coordinador


Prof. Domingo Sifontes
C.I. 13.770.794
Tutor


Prof. Prof. Pablo Polo
C.I. 8.846.654
Jurado (Sup)


Prof. Ana Isabel Belmonte
C.I. 8.601.404
Jurado



República Bolivariana de Venezuela
Universidad de Carabobo
Facultad de Ciencias Económicas y Sociales
Escuela de Economía



CARTA DE APROBACION DEL TUTOR

En mi carácter de Tutor del Trabajo de Grado presentado por el ciudadano: JONATHAN JOSE MORA ALVARADO, cedula de identidad 27.014.808, para optar al Grado de Economista titulado: **“DETERMINANTES DE LOS PRECIOS DE LA VIVIENDA EN ENTORNOS URBANOS: APLICACIÓN DE LA REGRESION GEOGRAFICAMENTE PONDERADA”**, considero que dicho trabajo reúne los requisitos y méritos suficientes para ser sometidos a la presentación pública y evaluación por parte del jurado designado.

En la ciudad de Valencia a los 12 días del mes de marzo de 2024

Dr. Domingo Sifontes

C.I. V-13.770.794

(Firma)

Determinantes de los Precios de la Vivienda en Entornos Urbanos: Aplicación de la Regresión Geográficamente Ponderada

Resumen

Los autores dedicados al estudio del mercado inmobiliario han determinado que los precios de las viviendas varían de forma continua en función de las características, tanto físicas como espaciales. En este estudio se comparan dos técnicas para examinar la influencia que puede tener en el precio de la vivienda la cercanía de un comercio minorista “Mercadona” en la ciudad de Madrid, España. Siendo estas la regresión por mínimos cuadrados ordinarios (OLS) y la regresión geográficamente ponderada (GWR). Los resultados indican que la cercanía a “Mercadona” cumple con el signo esperado, pero estadísticamente no resultó ser una variable lo suficientemente determinante para el modelo; sin embargo, se demostró que la relación de esta variable con el precio de las viviendas puede variar significativamente en diferentes ubicaciones de la ciudad. También los resultados evidencian una superioridad por parte del modelo GWR en términos de poder explicativo.

Palabras clave: Mercado Inmobiliario, Precios Hedónicos, Regresión Geográficamente Ponderada, Mercadona, Madrid.

Abstract

Authors dedicated to the study of the real estate market have determined that housing prices vary continuously depending on characteristics, both physical and spatial. In this study, two techniques are compared to examine the influence that the proximity of a “Mercadona” in the city of Madrid, Spain, can have on housing prices. These are ordinary least squares regression (OLS) and geographically weighted regression (GWR). The results indicate that proximity to Mercadona meets the expected sign, but statistically it did not turn out to be a sufficiently determining variable for the model; However, it was shown that the relationship of this variable with housing prices can vary significantly in different locations of the city. The results also show superiority on the part of the GWR model in terms of explanatory power.

Keywords: Real Estate Market, Hedonic Prices, Geographically Weighted Regression, Mercadona, Madrid.

1. Introducción

El análisis de los factores que influyen en los precios del mercado inmobiliario ha llamado la atención de muchos investigadores, siendo Rosen (1974) con su modelo de precios hedónicos el que trajo un carácter estadístico y econométrico al estudio de este sector. Y es que, al establecer que el precio de la vivienda está en función del conjunto de atributos que caracterizan a la vivienda, abrió un nuevo panorama para el estudio de los fenómenos urbanos.

En un principio, para estudiar los modelos hedónicos se utilizaba la técnica de regresión por mínimos cuadrados ordinarios. Sin embargo, a pesar de su gran utilidad y aplicación, autores como Can (1992) define los tipos de atributos que deberían tomarse en cuenta para la estimación de este tipo de modelos, mencionando entre ellos, los efectos espaciales. Y es que, el avance de la econometría espacial impulsado por estudios como el de Anselin (1988), dieron un nuevo enfoque a los estudios de los modelos hedónicos, tomando en cuenta desde ese momento a las características espaciales de la vivienda como nuevas variables a tomarse en consideración. Sin embargo, la inclusión de estas nuevas variables trajo los llamados “efectos de locación” por Can (1992) conocidos en la literatura como autocorrelación y heterogeneidad espacial. Para solventar estos problemas espaciales, surge el modelo de regresión geográficamente ponderado desarrollado por Brunson et al (1996) el cual corrige estos efectos al tomar en cuenta las relaciones que varían espacialmente entre las variables, posicionándose, así como una alternativa a los modelos econométricos tradicionales.

En esta investigación se utilizan modelos econométricos tradicionales y modelos de regresión geográficamente ponderados para analizar si las variables espaciales, en este caso la distancia a comercios minoristas (Mercadona), influyen en el precio de las viviendas en la ciudad de Madrid, España.

La investigación se estructura de la siguiente forma: la sección 2 se comprende de una extensa revisión de la literatura referente al tema de la investigación; la sección 3 trata el caso de estudio, los datos recopilados y utilizados, y la metodología desarrollada; en la sección 4 se exponen y discuten los resultados obtenidos y, por último, en la sección 5, se presentan las conclusiones.

2. Revisión de la Literatura

El mercado inmobiliario es un sistema complejo en el que diversos factores influyen para determinar las preferencias de los demandantes de vivienda y, en consecuencia, los precios de las mismas. Estos factores han sido ampliamente estudiados durante el siglo XX, Lancaster (1966) propuso en su publicación “A New Approach to Consumer Theory” que la utilidad de los bienes se deriva de sus características. Y si bien el autor no abordó explícitamente cuestiones relacionadas con el mercado inmobiliario en su publicación, su propuesta si fue inspiradora para futuras investigaciones relacionadas a la vivienda. Siendo este el caso de Rosen (1974) en el que basa su modelo de precios hedónicos en que las características de los bienes son los determinantes de su precio. En el caso de la vivienda, siendo las características como el tamaño, la antigüedad, el barrio en que se ubican, etc. Las que explican el precio de la vivienda.

Las características como determinantes de los precios ha sido uno de los focos principales de estudio, y es que Can (1992) explicaba que los precios de la vivienda están relacionados con dos clases de atributos (características). En consecuencia, en el marco del modelo hedónico de precios, el valor o precio de la vivienda puede entenderse en función de las características estructurales de la vivienda, las características de vecindad y los errores residuales.

Según Can (1992) la primera clase incluye las características físicas de la vivienda (Tamaño, antigüedad, número de habitaciones y baños, etc.). Y la segunda clase, a la cual llama efectos de locación, abarca las externalidades, tanto positivas como negativas, asociadas a la ubicación geográfica de la vivienda.

En los efectos de locación, el autor distingue entre dos niveles, el primero abarca los “efectos del vecindario” que sería el impacto de las características del vecindario que una vivienda comparte con las demás viviendas de una misma zona. El segundo nivel se refiere a los “efectos de adyacencia” que sería el impacto en el precio que tienen las estructuras cercanas a una vivienda.

Los efectos de locación, trajeron un nuevo desafío para el estudio de los mercados inmobiliarios, esto debido a que la econometría tradicional no funciona correctamente para este tipo de modelo (hedónicos) debido a la aparición de los efectos espaciales, generados por la ubicación de las viviendas, siendo el primero de estos efectos la autocorrelación espacial, y el segundo, la heterogeneidad espacial.

La autocorrelación espacial, Anselin (1988) la define como la “coincidencia de similitud de valor con similitud de ubicación”. También Goodchild (1987) la define como la concentración o dispersión de los valores de una variable en un mapa, es decir, refleja el grado en que un objeto (vivienda) en una unidad geográfica es similar a otros objetos (viviendas) en unidades geográficas cercanas. Llevando esto al contexto de los mercados inmobiliarios, Yu et al (2007) indica que la autocorrelación espacial, significa que las casas que se encuentran en ubicaciones cercanas unas de las otras tienden a tener precios similares.

Y es que este efecto espacial, describe en parte el funcionamiento de los mercados inmobiliarios de las ciudades, ya que normalmente las viviendas de un área específica tendrán tamaño, diseño y antigüedad similar, además de compartir las mismas externalidades, tanto positivas como negativas. Al existir autocorrelación espacial en los precios de la vivienda Anselin (1988) afirma que este hecho rompe con los supuestos de independencia de las observaciones en un estimador de regresión OLS tradicional, causando que la estimación se vuelva sesgada, y por ende, los coeficientes estimados de las características de las viviendas podrían ser incorrectos.

Por otro lado, Yu et al (2007) define la heterogeneidad espacial en fenómenos urbanos como un proceso no estacionario en el espacio, que describe un fenómeno operativo del mercado inmobiliario en el que las características de la vivienda generan precios variados en las diferentes áreas examinadas. Esto nos quiere decir que un mismo conjunto de características de la vivienda puede generar diferentes precios de vivienda en diferentes partes del área estudiada. Ignorar este efecto espacial según Anselin (1988) puede llevar a obtener estimaciones de parámetros sesgados e inconsistentes, debido a que se podrían estar omitiendo importantes relaciones que varían espacialmente entre las variables, lo que llevaría a estimaciones inexactas.

Para resolver estos efectos espaciales, ha surgido la técnica de regresión geográficamente ponderada (GWR, por sus siglas en inglés) la cual permite construir modelos en los que se pueden incluir estos efectos que se encuentran presentes en el mercado inmobiliario. La funcionalidad y aplicaciones del modelo GWR son exploradas por Fotheringham et al (2002) definiendo al mismo como una técnica de regresión espacial que permite examinar las relaciones que varían espacialmente entre las variables, diferenciándose así de los modelos tradicionales. Dado a esta capacidad del modelo para corregir los efectos espaciales, los autores afirman su gran utilidad para examinar cómo cambia la relación de las variables en el espacio, siendo esta

una de las razones por las que este modelo se ha utilizado en diferentes ocasiones para analizar fenómenos urbanos.

Uno de los primeros estudios del mercado inmobiliario empleando el modelo GWR fue el de Yu et al (2004) el cual realizó un análisis del mercado inmobiliario de Milwaukee, Wisconsin. El autor utilizó datos provenientes del Master Property (MPROP) del año 2003. Su base de datos contaba con más de 68 mil registros de viviendas, pero debido a las limitaciones computacionales de la época, optaron por seleccionar un conjunto de 1821 muestras aleatorias para la construcción del modelo. El modelo especifica que el precio de la vivienda está explicado por variables como el tamaño de la vivienda, su antigüedad, si posee chimenea, si cuenta con aire acondicionado, la cantidad de baños. Los resultados de la investigación concluyen que al utilizar el modelo GWR, las relaciones entre los valores y atributos no son invariantes en el espacio, lo cual afirman que concuerda con los hallazgos de Can (1992). También descubren que la edad de las viviendas en algunos casos puede reducir el valor de la propiedad, y en otros, lo puede aumentar debido al valor histórico de la propiedad. En cuanto a las demás características, afirman que estas pueden ser estadísticamente significativas, o no, dependiendo de la ubicación de la vivienda.

Un par de años después, Bitter et al (2006) hicieron un estudio del mercado inmobiliario de Tucson, Arizona, partiendo de una base de datos de más de 11.000 datos, procedentes de registros de venta de viviendas de la ciudad para el año 2000. Realizaron una comparación entre los modelos de expansión y GWR. Especificaron que el precio de la vivienda está explicado por el tamaño de la propiedad, su área de construcción, la calidad estructural, el número de pisos y la antigüedad de la vivienda. Los resultados arrojaron que cada una de las variables son significativas, siendo el modelo GWR superior para este tipo de estimación debido a que posee un mayor poder explicativo y mejor exactitud de la estimación. Un importante hallazgo es que el P-value Monte Carlo indica que la variación espacial en las siete variables es significativa, lo cual supone una fuerte evidencia de que los precios marginales de estas características no son constantes, y, por lo tanto, varían según la zona geográfica en la que se encuentren. Reflejando así la importancia de las influencias espaciales dentro del mercado inmobiliario de Tucson.

En su estudio Lu et al (2011) utilizan un modelo GWR para analizar el precio de la vivienda con distancias no euclidianas con fin de determinar si de esta forma se puede mitigar el impacto de barreras naturales o físicas cuando se utilizan distancia en línea recta (euclidianas). Para el

análisis se utilizaron datos de 372 propiedades vendidas en Londres durante 2001, y un punto importante, es que el área de estudio está dividida por el río Támesis lo que crea la barrera natural para alcanzar el objetivo de estudio. Los resultados del estudio señalan que existe una modesta mejoría en las estimaciones del modelo al utilizar distancias no euclidianas.

En otro estudio, Lu et al (2013) utilizó información de 2108 transacciones de vivienda en Londres, obtenida de la Nationwide Building Society. El investigador empleó diversos modelos de GWR, cada uno calibrado con distintas medidas de distancia, como la distancia euclidiana (ED), la distancia de la red de carreteras y el tiempo de viaje. Los hallazgos demuestran que la utilización de una métrica no euclidiana para la calibración del GWR no solo mejora la adecuación del modelo, sino que también proporciona información complementaria y valiosa sobre la naturaleza de las diferentes relaciones dentro del conjunto de datos sobre los precios de la vivienda.

Por otro lado, en Latinoamérica Duque et al (2011) en su estudio emplean modelos econométricos tradicionales y modelos de regresión ponderados geográficamente para examinar y comparar el posible impacto de una estación de metro en los precios de la vivienda en la ciudad de Medellín, Colombia. La estación de metro de la comuna San Javier sirve como punto de referencia, con 89 registros de precios de viviendas proporcionados por la base de datos de la Lonja de Propiedad Raíz de Medellín y Antioquia. Los resultados del estudio revelan que los modelos GWR son los más adecuados para este tipo de análisis. Además, demuestra una correlación positiva entre la proximidad de las propiedades residenciales a la estación de metro de San Javier, específicamente en el caso de las viviendas ubicadas en un radio de 600 metros.

Una investigación realizada por Salado et al (2018) realiza una comparación entre la regresión por mínimos cuadrados ordinarios (OLS) y la regresión geográficamente ponderada (GWR) con el objetivo de determinar cuál es el modelo más eficaz para el estudio del mercado inmobiliario. Para esto fue seleccionado el municipio de Caguas, Puerto Rico, como área de estudio de la investigación. Los hallazgos de los autores demuestran que el modelo GWR funciona mejor que la regresión OLS en términos de precisión de predicción al modelar los valores de las propiedades, concluyendo los mismos, que el modelo GWR es una técnica superior en comparación con la regresión OLS para predecir los valores de las propiedades.

En el mismo año, Arias (2018) analiza un fenómeno de expansión urbana que se ha presentado en el sur y oeste de Cali, Colombia. Para este estudio, se utilizaron datos de nuevas construcciones residenciales de la Cámara Colombiana de la Construcción (CAMACOL) del periodo de 2006 hasta mayo del 2017. Se realizó un modelo GWR para poder identificar la distribución espacial de los precios de las nuevas viviendas y explicar sus posibles determinantes. Los resultados obtenidos indican, por un lado, que variables como el número de baños o habitaciones, siempre afectan de manera directa y positiva en el precio de las viviendas, pero la variación del precio es más sensible en la zona norte de la ciudad. Por otro lado, los resultados con respecto a la accesibilidad de las viviendas a carreteras principales de la ciudad indica que el precio de las viviendas es sensible de forma negativa a la distancia entre la vivienda y la carretera principal más cercana, es decir, que a medida que la distancia se incrementa, se verá afectado negativamente el precio de la vivienda.

En un estudio sobre externalidades Correa (2022) aplica un modelo GWR, con el fin de determinar si existe una relación entre la localización de una planta de tratamiento de aguas residuales (PTAR) “Aguas Blancas” y el valor por metro cuadrado de las zonas residenciales cercanas, ubicada en el municipio Bello, de la ciudad de Medellín, Colombia. El estudio se realizó con una base de datos compuesta por 132 registros de viviendas que se encontraban dentro de un área de 1500 metros a la redonda de la planta “Aguas Blancas”. Los resultados del estudio demostraron que la distancia a la PTAR obtuvo el signo esperado pero el coeficiente de la variable no resultó ser estadísticamente significativo, pero sí mostró ser un predictor fuerte del valor por metro cuadrado principalmente en las Urbanizaciones Ceiba del Norte y Hacienda Niquía, donde más se disminuye el valor por metro cuadrado con relación a esta variable.

En un estudio realizado en Madrid por Molinero-Parejo et al. (2021), se llevó a cabo una investigación para determinar los factores que influyeron en la distribución espacial de la zonificación urbana en el “Corredor del Henares”, que sirve de enlace entre las ciudades de Madrid y Guadalajara, España. Para lograr este objetivo, los investigadores emplearon un modelo de regresión ponderado geográficamente (GWR), que permitió un análisis espacial de las relaciones entre los factores explicativos que no se pueden examinar mediante modelos tradicionales, como los mínimos cuadrados ordinarios (OLS). Los resultados del modelo GWR revelaron que ciertas variables seleccionadas como la altitud, la pendiente y la distancia a las

principales rutas de comunicación, desempeñaron un papel importante a la hora de analizar los patrones de crecimiento urbano. Este hallazgo resalta la importancia de tener en cuenta el contexto local y las variaciones espaciales al tratar de comprender y predecir la distribución del uso del suelo en los escenarios futuros.

3. Metodología

Inicialmente, se planeó que el estudio se ubicara en la ciudad de Valencia, Venezuela. Para llevar a cabo la investigación en esta ubicación, se buscó un establecimiento comercial que tuviese una fuerte presencia en la ciudad y fuese conocida y frecuentada por los habitantes de Valencia, es por razón que se seleccionó a la cadena de farmacias “Farmatodo” como la más idónea para ser la variable de referencia para el estudio, el cual busca explicar como el acceso cercano a bienes y servicios puede influir en los precios de la vivienda.

Los datos de vivienda necesarios para la realizar la investigación serían provenientes de una página inmobiliaria venezolana llamada “www.conlallave.com”. Sin embargo, se presentaron dos dificultades que impidieron poder continuar con la investigación en la ciudad de Valencia. En primer lugar, los propietarios de viviendas que aparecían en la página inmobiliaria seleccionada no describen claramente la ubicación de sus propiedades, por motivos de seguridad, lo que supone un gran obstáculo, ya que sin información geográfica precisa no se puede calcular correctamente la distancia entre las viviendas y el “Farmatodo” más cercano, lo cual es fundamental para el estudio. En segundo lugar, el cierre de la página inmobiliaria “www.conlallave.com”, la cual contenía el mayor número de anuncios de viviendas de la ciudad de Valencia, supuso un obstáculo insuperable, ya que, aunque se habían extraído datos de la página para hacer pruebas preliminares del modelo, no se contaba con la cantidad suficiente para el estudio. Otra opción fue la extracción de datos de otras páginas inmobiliarias en Venezuela, pero al realizar la búsqueda de un posible sustituto, no se encontró ninguna página que contará con los datos suficientes para llevar a cabo la investigación

Dados estos obstáculos, se contempló la posibilidad de trasladar la investigación a otra ciudad, con opciones como Ciudad de México y Madrid. Finalmente, se eligió Madrid debido a su estructura urbana, caracterizada por una alta movilidad peatonal, y a la facilidad de acceso a los

medio de transporte. Bajo este contexto, es lógico pensar que los residentes de Madrid al momento de querer adquirir algún bien o servicio, opten principalmente por opciones cercanas a su vivienda, y es que sería también lógico pensar que, al momento de escoger una nueva vivienda, se tenga preferencia por las viviendas que tienen de forma más cercana el acceso a bienes y servicios.

Partiendo de estos supuestos, esta investigación busca determinar si esa supuesta preferencia por parte de los demandantes de vivienda, en relación al acceso cercano de bienes y servicios, puede influir en el precio de las viviendas. Para este caso de estudio, se utilizará como variable de referencia la cadena de supermercados española “Mercadona”. Este supermercado, aparte de tener aproximadamente unos 198 supermercados en la Comunidad Autónoma de Madrid, posee un modelo denominado comercio urbano de proximidad, que no es más que la práctica tradicional de acudir a los establecimientos que se encuentran en el entorno más próximo.

Este modelo de negocio, calza con el supuesto preferencia descrito, y es por esta razón, que este establecimiento fue escogido como variable para determinar si su presencia afecta, o no, a los precios de las viviendas en Madrid.

Datos

Para realizar esta investigación se utilizaron datos extraídos de la página inmobiliaria Idealista <https://www.idealista.com>, siendo esta una de las más populares del país. La recolección de los datos fue realizada a través de la técnica de extracción de datos llamada Web Scraping, la cual permite la extracción sistemática y estructurada de datos de páginas web mediante el uso de scripts² personalizados. Esta técnica es muy utilizada para obtener información sobre precios de productos, reseñas de clientes, etc. y en este caso, será utilizada para obtener toda la información de las viviendas ofertadas en la página inmobiliaria Idealista.

Se realizó una delimitación espacial para poder realizar una extracción de datos más estructurada, la cual consistió en solo extraer datos de viviendas que se encuentre dentro de los límites que marca la autopista de circunvalación M-30, la cual puede considerarse como la delimitación

² Es un conjunto de instrucciones escritas en un lenguaje de programación que se utiliza para automatizar tareas o realizar acciones específicas en un sistema informático.

geográfica que separa el centro de la periferia de la ciudad de Madrid. Esta separación se puede visualizar en el Mapa 2, siendo la zona de color naranja el área de estudio.



Mapa 2. Mapa de la Ciudad de Madrid

Utilizando el lenguaje de programación Python y las librerías Beautiful Soup y Requests se programó el script necesario para extraer los datos de las viviendas ofertadas en la página Idealista durante el mes de octubre del año 2023. Aplicando esta técnica se extrajeron un total de 8662 registros de viviendas ofertadas en la página web dentro de los límites ya establecidos para esta investigación. De estos registros fueron extraídos datos como el precio de las viviendas, su tamaño expresado en m², el número de habitaciones y de baños, además de la ubicación geográfica de las propiedades.

Utilizando las herramientas de Google, Google Maps y Google Sheets, a través de la extensión Apps Script³, se generó un script capaz de obtener las coordenadas geográficas de cada uno de los registros de vivienda antes conseguidos, logrando así completar la recolección de todos los datos necesarios para la construcción del modelo.

³ Es una plataforma de desarrollo en la nube ofrecida por Google que permite a los usuarios crear aplicaciones y automatizar tareas en los productos de Google Workspace, como Google Sheets, Google Maps, Google Forms y otros.

Modelo de Regresión Geográficamente Ponderado

Para la creación de un modelo de regresión hedónico, Can (1992) y Fotheringham et al (2000) concuerdan con que se debe implicar la especificación del precio de venta mediante un conjunto de características de la vivienda, siendo esta formulada de la siguiente manera:

$$y_i = \beta_0 + \sum_{k=0}^n \beta_k x_{ik} + \varepsilon_i$$

En donde y_i representa la i ésima observación de la variable dependiente, x_{ik} representa la i ésima observación de la k ésima variable independiente y ε_i es el i ésimo término de error. En cambio, para la especificación de modelo GWR se estiman coeficientes únicos para cada punto de la observación:

$$y_i = \beta_0(u_i, v_i) + \sum_{k=0}^n \beta_k(u_i, v_i) x_{ik} + \varepsilon_i$$

En donde (u_i, v_i) son las coordenadas del punto en el espacio y $\beta_k(u_i, v_i)$ es la realización de la función continua $\beta_k(u, v)$ en el punto i . En notación matricial, los parámetros del modelo GWR se estiman de la siguiente manera:

$$\beta(u_i, v_i) = [X^T W(u_i, v_i) X]^{-1} X^T W(u_i, v_i) Y$$

donde $W(u_i, v_i)$ es una matriz de ponderación espacial. Empleamos una función gaussiana en la que la variable d indica la distancia euclidiana entre el punto de regresión y el punto de observación, mientras que la variable h indica el ancho de banda, como se describe a continuación:

$$W_i(u_i, v_i) = \exp(-d/h)^2$$

El ancho de banda, que es la banda de distancia o la cantidad de vecinos utilizadas para cada ecuación de regresión local, Fotheringham et al (2000) señala que su elección es muy importante, debido a que los resultados del modelo son muy sensibles a variaciones del mismo. En este sentido, el autor recomienda utilizar un ancho de banda adaptativo que permite la variación del

mismo según la densidad, en este caso, de precios de vivienda que se encuentren alrededor de cada punto de la regresión.

Especificación de Modelo

Partiendo de los registros de vivienda obtenidos de la página inmobiliaria <https://www.idealista.com>, la base de datos del modelo se construyó de la siguiente manera: primero se seleccionaron 24 sucursales de Mercadona que se encontraban dentro del área de estudio delimitada, y a partir de estas 24 sucursales se delimitaron 15 zonas de influencia, con el fin de hacer diferenciaciones entre zonas con mayor y menor niveles renta.

Cada uno de los registros de vivienda contienen información correspondiente al precio de la vivienda, tamaño de la vivienda expresado en m², número de habitaciones, número de baños, la antigüedad de la propiedad, sus coordenadas geográficas y la distancia, expresada en metros, que tiene la vivienda hasta el Mercadona más cercano. Estas son las variables empleadas para desarrollar el estudio, las cuales en la Tabla 1 son descritas y se detallan los signos esperados.

Tabla 1. Descripción de las variables independientes utilizadas.

Variable	Descripción	Signo Esperado
Área	Área de la vivienda medida en metros cuadrados.	Positivo. A mayor área mayor precio.
Habitaciones	Número de habitaciones de la vivienda.	Positivo. A mayor número de habitaciones mayor precio.
Baños	Número de baños de la vivienda.	Positivo. A mayor número de baños mayor precio.
AñoConstruc	Antigüedad de la vivienda en años.	Negativo. A mayor cantidad de años de antigüedad menor precio.
Distancia	Distancia entre la vivienda y el Mercadona más cercano medida en metros.	Negativo. En la medida que la vivienda esté más alejada del Mercadona debe tener un valor menor.

Los estadísticos descriptivos que figuran en la Tabla 2 ilustran la heterogeneidad de la vivienda en la ciudad de Madrid. Estas estadísticas abarcan un amplio espectro de residencias, con edades de construcción que van desde un año hasta más de ciento cincuenta años. Además, las dimensiones de estas viviendas varían entre un mínimo de quince metros cuadrados y un máximo de cuatrocientos metros cuadrados. Además, la proximidad de estas viviendas al Mercadona más

cercano oscila entre una distancia mínima de veinte metros y una distancia máxima de dos mil metros.

Tabla 2. Estadísticas de las variables utilizadas.

	Máximo	Mínimo	Promedio
Precio (miles de euros)	1.185,00	99,90	492,28
Área (m²)	400	17	94,72
Habitaciones	5	1	3
Baños	4	1	2
AñoConstruc (años)	123	1	69
Distancia (metros)	2400	17	664,46

El dataset final utilizado para el estudio, después de realizar una limpieza exhaustiva de registros duplicados, incompletos y/o atípicos, contó con un total de 2564 registros de viviendas de la ciudad de Madrid.

Con la base de datos terminada, se procedió a realizar las primeras pruebas en el software GWR4, en su versión más actualizada, el cual fue desarrollado por un equipo conformado por Tomoki Nakaya (Department of Geography, Ritsumeikan University), Martin Charlton, Chris Brunson, Paul Lewis (National Centre of Geocomputation, National University of Ireland), Jing Yao (School of Social and Political Sciences, University of Glasgow) y A. Stewart Fotheringham (School of Geographical Sciences & Urban Planning, Arizona State University). GWR4 fue creado como una herramienta para el modelado de regresiones geográficamente ponderadas, siendo el artículo de Nakaya (2005) y en el libro Fotheringham (2002), las principales bases teorías para la creación del software, y es en el manual de usuario de Nakaya (2009) donde se explica detalladamente su funcionamiento, el tipo de dataset que se debe utilizar y los diferentes test que se pueden realizar.

4. Resultados

Regresión por Mínimos Cuadrados Ordinarios (OLS)

En primer lugar, y de acuerdo con la literatura, debe ser especificado un modelo de regresión OLS el cual se ajuste de forma adecuada a los datos, para después se puedan emplear las mismas variables para realizar el modelo GWR. Teniendo esto en cuenta, se realizaron un total de cinco modelos de regresión por mínimos cuadrados ordinarios para lograr un análisis más completo, los resultados aparecen reflejados en la Tabla 3.

Tabla 3. Resultados de los Modelos OLS.

	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
Área	3.85666*** 0.0756	3.270227*** 0.1262	3.036568*** 0.1262	3.085284*** 0.13154	3.092767*** 0.13158
Habitaciones		35.24144*** 6.091	4.728956 8.2752	12.699081*** 8.26564	12.635349 8.26564
Baños			57.921943*** 10.7021	50.941646*** 10.63871	50.449693*** 10.63971
AñoConstruc				0.723018*** 0.09945	0.710487*** 0.09972
Distancia					-0.015308 0.00947
AICc	33,470.09	33,438.80	33,411.64	33,361.23	33,360.62
R2	0.5039	0.5103	0.5158	0.5256	0.5261
R2 Ajustado	0.5035	0.5097	0.5151	0.5247	0.5250

*** Significativo al 99%

** Significativo al 95%

* Significativo al 90%

El Modelo 1 especifica una regresión OLS que toma “Precio” como variable dependiente y “Área” como variable independiente, el resultado indica que el coeficiente para la variable Área presenta el signo esperado, además de ser estadísticamente significativa. En cuanto al R2 y R2 ajustado, presentó niveles de 0.5039 y 0.5035 respectivamente, lo que explica el 50.39% de la variación de los precios de la vivienda.

Por su parte, el Modelo 2 agrega como variable independiente “Habitaciones” a las variables ya utilizadas en el Modelo 1 dando como resultado que los coeficientes de ambas variables presentan el signo esperado y son estadísticamente significativas. Siendo los valores del R2 y R2 ajustado de 0.5103 y 0.5097 respectivamente.

Para el Modelo 3, se incluye “Baños” como variable explicativa, las variables “Área” y “Baños” están positivamente asociadas con la variable dependiente y son estadísticamente significativas. Sin embargo, la variable "Habitaciones" no parece ser estadísticamente significativa en este modelo, a pesar de si tener el signo esperado. Por otro lado, el R2 y R2 ajustado de 0.5103 y 0.5097 respectivamente.

El Modelo 4 incluye la variable “AñoConstruc” que corresponde a la edad de la vivienda, para este modelo los resultados indican que todas las variables independientes son estadísticamente significativas, sin embargo, todas las variables exceptuando “AñoConstruc” presentan el signo esperado. Siendo el R2 y R2 ajustado de 0.5256 y 0.5247 respectivamente.

Por último, el Modelo 5 agrega la variable “Distancia” correspondiente a la distancia de una vivienda al Mercadona más cercano, la cual se busca determinar su capacidad explicativa. Los resultados de este modelo muestran que, por un lado, solo las variables “Área”, “Baños” y “Distancia”, y, por otro lado, todas las variables excepto “AñoConstruc” presentan el signo esperado. Mientras que el R2 y R2 ajustado de 0.5261 y 0.5250 respectivamente.

De los resultados de los modelos se puede apreciar, en la Tabla 3, que a medida que se agregan más variables, el R2 y el R2 ajustado tiende a aumentar, lo que sugiere una mejora en la capacidad explicativa del modelo. La variable “Distancia” utilizada en el Modelo 5 presenta un coeficiente negativo, lo que indica que hay una relación inversa entre la distancia a Mercadona y el valor de la propiedad. Es decir, a medida que la distancia aumenta, el valor de la propiedad

tiende a disminuir, aunque el efecto es relativamente pequeño, por lo tanto, no contribuye significativamente para explicar los precios de las viviendas en la ciudad de Madrid.

Regresión Geográficamente Ponderada (GWR)

Mediante el software GWR4 se estimaron cinco regresiones geográficamente ponderadas. Se aplicó Bandwidth (Ancho de Banda) adaptativo, el cual es recomendado por Fotheringham et al (2000) debido a que permite que los núcleos espaciales se adapten a las variaciones en la densidad de los datos. Además, también se tomó como test el criterio de minimización de Akaike para todos los modelos.

Antes de realizar el modelo GWR, primero se debe realizar un proceso de iteración para bandwidth adaptativo que mejor se ajuste a los datos. El proceso comienza con la selección de un ancho de banda inicial determinado por el software GWR4. El software ajusta el modelo de regresión GWR inicial en función de los parámetros especificados y calcula los residuos del modelo en cada punto. Basándose en los residuos calculados en la primera iteración, el software ajusta el ancho de banda adaptativo para la siguiente iteración. Esto implica calcular un nuevo ancho de banda para cada punto en función de la distribución de los residuos y la configuración de ajuste especificada. El software repite el proceso de ajuste del modelo GWR y cálculo del ancho de banda adaptativo en cada iteración. Este proceso se repite hasta que se cumpla un criterio de convergencia predefinido, como un número máximo de iteraciones o una mejora mínima en la bondad de ajuste del modelo. Una vez que se logra la convergencia, el software evalúa el modelo GWR final y el ancho de banda adaptativo. En las Tablas, 4, 5, 6, 7 y 8, se presentan los resultados de todas las iteraciones realizadas para alcanzar el ancho de banda óptimo para cada modelo.

Tabla 4. Bandwidth Modelo GWR 1.

Iteraciones	Bandwidth	AICc	Diferencia
1er	97.64	31,804.94	-
2da	77.15	31,772.01	20.49
3ra	64.49	31,753.31	12.66
4ta	56.66	31,739.29	7.83
5ta	51.83	31,731.51	4.84
6ta	48.84	31,731.11	2.99
7ma	46.99	31,728.85	1.85
8va	45.85	31,728.58	1.14

Tabla 5. Bandwidth Modelo GWR 2.

Iteraciones	Bandwidth	AICc	Diferencia
1er	99.60	31,671.17	-
2da	79.13	31,669.71	20.47
3ra	79.13	31,669.71	12.65
4ta	86.95	31,667.84	7.82
5ta	86.95	31,667.84	4.83
6ta	86.95	31,667.84	2.99
7ma	86.95	31,667.84	1.85
8va	86.95	31,667.84	1.14
9na	86.95	31,667.84	0.71

Tabla 6. Bandwidth Modelo GWR 3.

Iteraciones	Bandwidth	AICc	Diferencia
1er	188.21	31,696.79	-
2da	134.66	31,662.27	53.56
3ra	101.56	31,658.64	33.10
4ta	101.56	31,658.64	20.46
5ta	114.20	31,658.07	12.64
6ta	122.01	31,657.89	7.81
7mo	122.01	31,657.89	4.83
8vo	119.03	31,657.45	2.99
9no	119.028	31,657.45	1.845
10mo	119.028	31,657.45	1.14
11vo	119.028	31,657.45	0.705

Tabla 7. Bandwidth Modelo GWR 4.

Iteraciones	Bandwidth	AICc	Diferencia
1er	190.10	31,591.25	-
2da	136.59	31,556.39	53.51
3ra	103.51	31,554.13	33.07
4ta	103.51	31,554.13	20.44
5ta	116.15	31,552.92	12.63
6ta	123.95	31,552.37	7.81
7mo	123.95	31,552.37	4.83
8vo	123.95	31,552.37	2.98
9no	123.95	31,552.37	1.843
10mo	123.95	31,552.37	1.139
11vo	123.95	31,552.37	0.704

Tabla 8. Bandwidth Modelo GWR 5.

Iteraciones	Bandwidth	AICc	Diferencia
1er	191.99	31,578.71	-
2da	138.52	31,561.89	53.47
3ra	138.52	31,561.89	33.05
4ta	158.94	31,561.33	20.42
5ta	158.94	31,561.33	12.62
6ta	151.14	31,558.75	7.80
7mo	151.14	31,558.75	4.82
8vo	151.14	31,558.75	2.98
9no	149.30	31,558.54	1.842
10mo	149.30	31,558.54	1.138
11vo	149.30	31,558.54	0.703
12vo	149.30	31,558.54	0.435

Tabla 9. Resultados de los Modelos GWR.

	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
Área	4.024141*** 1.34219	3.279244*** 1.53479	3.022008*** 1.487918	2.9896*** 1.43183	2.988509*** 1.36136
Habitaciones		42.816483*** 64.682	19.660956 50.54744	17.714521*** 48.88342	17.802235 8.26564
Baños			48.663937*** 68.45361	48.698392*** 66.75674	44.7074*** 63.40972
AñoConstruc				-0.609155*** 1.07965	-0.650012*** 0.95992
Distancia					-0.236959 0.09385
AICc	31,727.48	31,667.84	31,657.45	31,552.37	31,558.54
R2	0.8072	0.7975	0.7963	0.8117	0.8095
R2 Ajustado	0.7720	0.7706	0.7707	0.7832	0.7821

*** *Significativo al 99%*

** *Significativo al 95%*

* *Significativo al 90%*

El Modelo 1, como lo fue su versión OLS, tendrá como variable dependiente el precio de las viviendas y como término independiente la variable “Área”, y en este caso, los modelos posteriores seguirán la misma secuencia de la ya antes realizada por los modelos OLS. Los resultados de modelo indican que fueron necesarias ocho iteraciones después, de las cuales, seleccionó el bandwidth más bajo como el óptimo, el cual se encuentra indicado en la Tabla 4.

En la Tabla 9, se aprecia que el coeficiente para la variable independiente “Área” si cumple con el signo esperado, y su vez, la variable es estadísticamente significativa. Las estadísticas

referentes a R² y R² ajustado indican valores de 0.8072 y 0.7720 respectivamente, lo cual sugiere un buen ajuste del modelo a los datos.

Para el Modelo 2, se agrega como variable explicativa “habitaciones” a las otras variables ya antes mencionadas. La Tabla 5 indica que fueron necesarias un total de nueve iteraciones para lograr alcanzar el bandwidth que mejor se ajustara al modelo.

En cuanto a los coeficientes del modelo, en la Tabla 9 podemos observar que tanto la variable “Área” como la variable “Habitaciones” obtuvieron el signo esperado, y ambas fueron estadísticamente significativas. En cuanto al R² y el R² ajustado 0.7975 y 0.7706 respectivamente. Estos valores indican la proporción de la variabilidad en la variable dependiente que es explicada por el modelo.

Por su parte, el Modelo 3 incluye “Baños” como una nueva variable independiente a las ya existentes. En la Tabla 6 se aprecia el número total de iteraciones requeridas para poder alcanzar un bandwidth óptimo para el modelo. En este caso, los resultados arrojados por el modelo indican que todas las variables tuvieron el signo esperado, pero solo las variables “Área” y “Baños” lograron ser estadísticamente significativas. Y como se puede observar en la Tabla 9, los resultados del R² y R² ajustado fueron de 0.7963 y 0.7707 respectivamente, lo que da señales positivas en cuanto al ajuste del modelo.

En el Modelo 4 se agrega la variable explicativa “AñoConstruc” representativa de la edad de las viviendas. Para este modelo fueron necesarias once iteraciones para poder aproximarse al bandwidth más bajo, y, por ende, óptimo. El cual se puede visualizar en la Tabla 7.

Los resultados arrojados por este modelo, los cuales se detallan en la Tabla 9, muestran que todas las variables ellas presentan los signos esperados, y a su vez, todas ellas presentan los poseen significancia estadística. Contando con un R² y R² ajustado de 0.8117 y 0.7832 respectivamente, lo cual señala que el modelo tiene la capacidad sustancial para explicar la variable dependiente.

Por último, el Modelo 5 incluye la variable de estudio de la investigación como variable independiente, que sería “Distancia” la cual se describe brevemente como la distancia entre una vivienda y el Mercadona más cercano. En la Tabla 8, tenemos los resultados del modelo, y en los mismos se observa que se ha requerido de un total de doce iteraciones para lograr alcanzar el bandwidth más adecuado para el modelo.

En cuanto a los resultados de los coeficientes expuestos en la Tabla 9, estos nos indican que todas las variables independientes obtuvieron el signo esperado, pero tanto la variable “Habitaciones” como la variable “Distancia” no llegaron a ser estadísticamente significativas. Por otro lado, los resultados del R² y R² ajustado indicaron valores de 0.87095 y 0.7821 respectivamente, lo cual sugiere que la capacidad importante para explicar la variación de la variable dependiente.

El análisis de los resultados reflejados en la Tabla 9, nos permite ver las capacidades de los modelos GWR para capturar las variaciones espaciales. Estos resultados, nos han permitido conocer que la relación entre la distancia a Mercadona y el precio de las viviendas presenta un signo negativo, el cual está acorde con la teoría, pero los coeficientes de la variable no son lo suficientemente relevante estadísticamente. Los resultados también indican que la relación entre estas variables no es uniforme en el espacio, sin embargo, también indica que, en algunas áreas, la distancia a Mercadona puede tener un efecto significativo en el valor de la propiedad, mientras que en otras áreas este efecto puede ser menos relevante o incluso contrario.

Análisis Comparativo del Modelo OLS y el Modelo GWR

A continuación, se realiza un análisis comparativo de los modelos OLS y GWR, con el fin de identificar qué modelo econométrico se adapta mejor y obtiene mejores resultados ante bases de datos con características de precios hedónicos.

Si comparamos los resultados reflejados en la tabla 10, se puede apreciar que los coeficientes de determinación R² y R² Ajustado obtenidos por los modelos GWR demostraron un mejor desempeño con respecto a los modelos OLS, por lo tanto, se puede decir que utilizando la técnica de regresión geográficamente ponderada las variables independientes explican mejor a la variable dependiente. En cuanto a la prueba de Akaike (AICc) los modelos que presentan el AICc más bajo son GWR, lo que quiere decir, que son los modelos que se ajustan mejor a los datos. Correa (2022) hace énfasis en el valor de comparar los resultados de estas pruebas, ya que es una forma de evaluar los beneficios de cambiar de un modelo OLS a un modelo GWR.

Esto sugiere que el modelo GWR es más efectivo para capturar la variabilidad espacial en los datos y explicar la relación entre las variables. Por otro lado, los coeficientes de regresión locales en el modelo GWR muestran una variabilidad significativa a nivel geográfico. Por ejemplo, mientras que el coeficiente para el número de habitaciones puede ser alto en algunas áreas, puede

ser bajo en otras. Esto indica que la relación entre las variables independientes y la dependiente varía según la ubicación geográfica, lo cual es capturado de manera efectiva por el modelo GWR pero no por el modelo OLS.

Tabla 10. Comparación de los resultados de los modelos OLS y GWR

	Modelo 1		Modelo 2		Modelo 3		Modelo 4		Modelo 5	
	OLS	GWR	OLS	GWR	OLS	GWR	OLS	GWR	OLS	GWR
Área	3.8566*** 0.0756	4.0241*** 1.34219	3.2702*** 0.1262	3.2792*** 1.53479	3.0365*** 0.1262	3.0220*** 1.487918	3.0852*** 0.13154	2.9896*** 1.43183	3.0927*** 0.13158	2.9885*** 1.36136
Habitaciones			35.2414*** 6.091	42.8164*** 64.682	4.7289 8.2752	19.6609 50.54744	12.6991*** 8.26564	17.7145*** 48.88342	12.6353 8.26564	17.8022 8.26564
Baños					57.9219*** 10.7021	48.6639*** 68.45361	50.9417*** 10.63871	48.6984*** 66.75674	50.4497*** 10.63971	44.7074*** 63.40972
AñoConstruc							0.7230*** 0.09945	-0.6092*** 1.07965	0.7105*** 0.09972	-0.6500*** 0.95992
Distancia									-0.0153 0.00947	-0.2370 0.09385
AICc	33,470.09	31,727.48	33,438.80	31,667.84	33,411.64	31,657.45	33,361.23	31,552.37	33,360.62	31,558.54
R2	0.5039	0.8072	0.5103	0.7975	0.5158	0.7963	0.5256	0.8117	0.5261	0.8095
R2 Ajustado	0.5035	0.7720	0.5097	0.7706	0.5151	0.7707	0.5247	0.7832	0.5250	0.7821

*** Significativo al 99%

** Significativo al 95%

* Significativo al 90%

El hecho de que el modelo GWR proporcione coeficientes de regresión locales significa que la ubicación geográfica juega un papel crucial en la relación entre las variables. Esto puede deberse a diferencias en las características socioeconómicas, geográficas o culturales de las diferentes áreas, que impactan en cómo se relacionan las variables.

5. Conclusiones

Este trabajo busca determinar la influencia que tienen las variables espaciales en el precio de la vivienda. Para lograr este objetivo, fue utilizado la cadena de supermercados “Mercadona” como variable espacial, para determinar si la cercanía de esta a una vivienda puede influir positivamente en su precio. La importancia de este estudio radica en que permite conocer cómo el acceso cercano a bienes y servicios puede influir en las preferencias de los demandantes de vivienda, y como consecuencia, está verse reflejada en los precios de la vivienda.

En la comparación de las técnicas de regresión se encontró gran diferencia en cuanto a los ajustes de los modelos OLS y GWR. Mientras que el modelo OLS ofrece una visión general de las relaciones entre las variables, el modelo GWR proporciona una comprensión más profunda al considerar la variabilidad espacial. Por lo tanto, para análisis espaciales y decisiones basadas en la ubicación, el modelo GWR es más apropiado, ya que captura las complejidades geográficas y proporciona una visión más precisa de cómo las variables influyen en la variable dependiente en diferentes áreas.

La variable “Distancia” propuesta para el estudio, presenta un signo negativo, lo cual está acorde con la teoría, pero los coeficientes de la variable no son lo suficientemente relevantes estadísticamente, sin embargo, se demostró que la relación entre la distancia y el valor de la propiedad puede variar considerablemente en diferentes ubicaciones geográficas. Esto deja entrever, que es necesario realizar un análisis más detallado a nivel local para comprender cómo la distancia a diferentes puntos de referencia afecta el valor de la propiedad en cada área específica.

En cuanto al uso de softwares para el estudio, GWR 4 aunque es un software bastante intuitivo y de fácil aprendizaje, para estudios más exhaustivos que conlleven visualización de las variaciones de los residuos en el espacio, presenta limitaciones, debido a que no tiene la capacidad de visualización de datos. Por esa razón, se recomiendan otro tipo de software como lo

podrían ser R, con su librería “spgwr”, o ArcGIS Pro, el cual es el software por excelencia para el tratamiento de datos en el campo de los sistemas de información geográfica.

Es aconsejable que para este tipo de estudios primeramente se consideren un número considerable de variables, para después de probar diferentes combinaciones de las mismas, se escojan las mejores para tener un modelo OLS bien especificado, para luego poder utilizar las mismas variables para el modelo GWR.

En este sentido, posibles extensiones de esta investigación pueden tomar, por un lado, el aumento de las variables a considerar en los modelos, para así poder aumentar el poder de explicación de los mismos. Por otro lado, a pesar que la relación entre la distancia y el precio de la vivienda no es significativa estadísticamente hablando en su conjunto, también se demostró que esta relación puede variar fuertemente en diferentes zonas de la ciudad, por lo que, sería interesante profundizar si estas variaciones geográficas se pueden deber a las variaciones de los diferentes niveles de renta que existen en los distintos distritos de la ciudad de Madrid.

La batuta y los avances en este tipo de estudios, han venido en su mayor parte de profesionales y académicos de áreas como la geología, geografía y el urbanismo, dándole a los estudios un carácter multidisciplinario. En este sentido, surge la pregunta de ¿Qué puede ofrecer la teoría económica para enriquecer el análisis de las variables espaciales presentes en los fenómenos urbanos?

La teoría económica proporciona un marco teórico sólido para comprender los mecanismos por los cuales las variables espaciales influyen en los fenómenos urbanos. Un ejemplo de esto sería la teoría del consumidor, la cual explica cómo las preferencias de los individuos por diferentes bienes y servicios, como lo puede ser la proximidad a supermercados, escuelas o parques, se reflejan en los patrones espaciales de precios. Además, la teoría económica también abarca el análisis de externalidades, tanto positivas como negativas, y como los efectos de estas pueden influir, en este caso, en los precios de la vivienda. Fotheringham et al. (2002) en su libro afirma que los modelos GWR son una técnica esencial para el análisis de fenómenos urbanos, ya que permite comprender la complejidad de las relaciones espaciales en las ciudades. En este sentido se puede observar como la teoría económica ofrece un marco conceptual y un conjunto de herramientas valiosas para enriquecer el análisis de modelos GWR en el estudio de fenómenos urbanos. Al integrar la teoría económica con los modelos GWR, podemos obtener una

comprensión más profunda de cómo las características espaciales influyen en las ciudades, y, por ende, en la vida de las personas.

6. Referencias

Anselin, L. (1988). Spatial Econometrics: Methods and models. En *Studies in operational regional science*. <https://doi.org/10.1007/978-94-015-7799-1>.

Arias Martínez, M. A. (2018). Determinantes y distribución del precio de la vivienda nueva en Cali a través de un modelo GWR. *Tesis de Grado - Universidad del Valle*, <https://hdl.handle.net/10893/13276>.

Bitter, C., Mulligan, G. F., & Dall'erba, S. (2006). Incorporating spatial variation in housing attribute prices: A comparison of geographically weighted regression and the spatial expansion Method. *Journal of Geographical Systems*, 9(1), 7-27.

Can, A. (1992). Specification and estimation of hedonic house price models'. *Regional Science and Urban Economics* 22 453 ^ 474.

Correa Sierra, J. D. (2022). Planta de Tratamiento de Aguas Residuales (PTAR) Aguas Claras del municipio de Bello y su relación con los precios de la vivienda en las unidades residenciales aledañas; una aplicación de la valoración hedónica mediante la Regresión Geográficamente Ponderada (GWR). *Institución Universitaria Esumer*, <http://repositorio.esumer.edu.co/jspui/handle/esumer/2695>.

Fotheringham, A. S., Charlton, M., & Brunsdon, C. (1996). The Geography of Parameter Space: An investigation of Spatial Non-stationarity. *International journal of geographical information systems*, 10(5), 605-627. <https://doi.org/10.1080/026937996137909>

Fotheringham, A. S., Charlton, M., & Brunson, C. (1998). Geographically Weighted Regression: A Natural Evolution of the Expansion Method for Spatial Data Analysis. *Environment and Planning A*, 30(11), 1905-1927. <https://doi.org/10.1068/a301905>.

Fotheringham, A. S., Brunson, C., & Charlton, M.. (2000). Quantitative geography : perspectives on spatial data analysis. SAGE.

Fotheringham, A. S., Brunson, C. & Charlton, M., (2002). Geographically Weighted Regression: The Analysis of Spatially Varying Relationships.

Goodchild, M. F. (1987). A Spatial Analytical perspective on Geographical Information systems. *International journal of geographical information systems*, 1(4), 327-334. <https://doi.org/10.1080/02693798708927820>

Lancaster, K. J. (1966). A New Approach to Consumer Theory. The University of Chicago Press.

Lu, B., Charlton, M., & Fotheringham, A. S. (2011). Geographically weighted regression using a Non-Euclidean distance metric with a study on London house price data.

Molinero-Parejo, R., Benavente, F. A., & Delgado, M. G. (2021). Regresión Logística Geográficamente Ponderada para identificar los factores explicativos de la distribución de usos de suelo en escenarios futuros de crecimiento urbano. *Boletín de la Asociación de Geógrafos Españoles*, 88. <https://doi.org/10.21138/bage.3052>

Nakaya, T., Charlton, M., Brunson, C., Lewis, P., Yao, J., & Fotheringham, A. S. (2009). GWR4 Windows Application for Geographically Weighted Regression Modelling. *GWR4.09 User Manual*.

- Nakaya, T., Fotheringham, A. S., Brunson, C., & Charlton, M. (2005).** Geographically weighted Poisson regression for disease association mapping. *Statistics In Medicine*, 24(17), 2695-2717. <https://doi.org/10.1002/sim.2129>
- Rosen, S. (1974).** Hedonic prices and implicit markets: product differentiation in pure competition. *Journal of Political Economy*, 82(1), 34-55. <https://doi.org/10.1086/260169>
- Salado, M. J., & Matos, R. (2018).** El Componente Espacial en la Valoración de Inmuebles Residenciales: Uso de la Regresión Geográficamente Ponderada. *Universidad de Alcalá*.
- Sirmans, G. S., MacDonald, L., Macpherson, D. A., & Zietz, E. N. (2006).** The Value of Housing Characteristics: A Meta Analysis. *The Journal of Real Estate Finance and Economics*, 33(3), 215-240. <https://doi.org/10.1007/s11146-006-9983-5>.
- Yu, D., Wei, Y. D., & Wu, C. (2007).** Modeling spatial dimensions of housing prices in Milwaukee, WI. *Environment and Planning B: Planning and Design*, 34(6), 1085-1102. <https://doi.org/10.1068/b32119>