

CENTRO DE INVESTIGACIÓN Y DOCENCIA ECONÓMICAS, A.C.



**DETERMINANTES CLAVES EN LA ASIGNACIÓN DE PRECIOS DE AIRBNB EN
LA CIUDAD DE MÉXICO: UN ANÁLISIS ESPACIAL**

**TESINA
QUE PARA OBTENER EL TÍTULO DE
LICENCIADO EN ECONOMÍA**

**PRESENTA
EDGAR ROBLES DÍAZ**

DIRECTOR DE LA TESINA: MTRO BENJAMÍN OLIVA VÁZQUEZ

Agradecimientos

A mis padres, Claudia y Edgar, quienes con su amor, paciencia y determinación me han permitido superar todas las barreras y cumplir con un sueño más. Y a mi hermana, Ximena, por el apoyo, los consejos y los memes. Agradezco tenerlos en mi vida y por estar a mi lado en las buenas y en las malas. Los amo.

Al maestro Benjamín Oliva, por guiarme en el desarrollo de este trabajo. Gracias por las pláticas, consejos y orientación que dieron rumbo a las ideas detrás de esta investigación. Te admiro y agradezco todo el esfuerzo.

Al Dr. Antonio Jiménez por el apoyo constante para que este trabajo viera la luz. Su reconocimiento y retroalimentación me hicieron esforzarme para que esta tesina fuera en verdad un trabajo del cual sentirme orgulloso. Gracias, profesor.

A Daniel, mi mejor amigo y hermano. Por los consejos, las pláticas, las risas y el apoyo incondicional, te agradezco siempre. A Andrea, mi novia, confidente y soporte. Fuiste el catalizador máximo que dio paso a la culminación de este trabajo. Te agradezco por tantas ayudas y aportes no solo para el avance de mi tesina, sino además para mi vida; eres mi inspiración y mi razón, te amo.

A Alejandro, Daniel, Daniela y Yael, por hacer más fácil lo difícil. Gracias por cada sesión de estudio, cada plática en el comedor y cada salida, que fortuna tenerlos en mi vida.

A Alexandra Elbakyan, por su infinita contribución a la ciencia.

Resumen

El surgimiento de la economía colaborativa en mercados digitales ha afectado numerosas industrias en la última década. En particular, Airbnb ha transformado el sector de alojamiento al ofrecer una plataforma de alojamiento compartido, permitiendo a visitantes acceder a experiencias de viaje locales a bajo costo. Este trabajo examina el impacto de diversas características en los precios de 6,131 departamentos enlistados en Airbnb en la Ciudad de México con modelos de precios hedónicos que incluyen efectos espaciales. Las estimaciones indican que los atributos de tamaño, amenidades, reputación, reglas y ubicación afectan a los precios de los departamentos listados. Asimismo, los resultados confirman la existencia de efectos de propagación espacial entre los precios de las propiedades publicadas.

I. Contenido

<u>1. Introducción</u>	<u>1</u>
<u>2. Revisión de Literatura</u>	<u>5</u>
2.1. Economía compartida	5
2.2. Airbnb	6
2.3. Estrategia precios dinámicos Airbnb	7
2.4. Modelos de precios hedónicos	8
2.5. Determinantes de los precios en la industria del alojamiento compartido.....	8
<u>3. Descripción de los datos.....</u>	<u>13</u>
3.1. Zona del estudio.....	13
3.2. Datos y construcción de variables.....	14
<u>4. Metodología</u>	<u>21</u>
4.1. Modelo precios hedónicos	21
4.2. Modelos de Autocorrelación y Error espacial	22
4.3. Efectos directos e indirectos	24
4.4. Modelo de error espacial.....	25
4.5. Matriz de pesos espaciales	26
4.6. Pruebas de autocorrelación espacial	27
4.7. Especificación	32
<u>5. Resultados</u>	<u>34</u>
<u>6. Conclusión.....</u>	<u>41</u>
<u>7. Bibliografía.....</u>	<u>42</u>
<u>8. Anexos.....</u>	<u>48</u>

II. Mapas, gráficos, ilustraciones y tablas

Mapa 1 : Distribución de precios de departamentos de Airbnb en la Ciudad de México	18
Mapa 2: Índice de Moran local de los precios de los departamentos publicados en Airbnb en la Ciudad de México.....	31
Gráfico 1:Valores de R2 y AIC para diferentes valores de k-vecinos cercanos.....	27
Gráfico 2: Índice I de Moran sobre la dispersión de precios.....	29
Gráfico 3. Mapa de calor de variables explicativas (correlación)	48
Gráfico 4. Dispersión de residuales y valores estimados	49
Gráfico 5. Distribución de precios publicados en Airbnb en CDMX	49
Ilustración 1. Modelo de rezago espacial	23
Ilustración 2. Modelo de errores espaciales.....	26
Tabla 1:Resumen de revisión literatura sobre determinantes de precios en Airbnb	9
Tabla 2: Estadística descriptiva	20
Tabla 3: Resultados	35
Tabla 4:Efectos directos, indirectos y totales (SAR).....	39

1. Introducción

Uno de los factores estratégicos de mayor relevancia en el sector del alojamiento es la asignación de precios. Actualmente, los consumidores cuentan con la información suficiente para diferenciar este tipo de bienes y servicios. Por lo tanto, pueden escoger aquel que cumpla sus expectativas respecto al valor ofrecido de estos bienes. Este fenómeno no solo aplica a este sector sino a numerosas industrias, tales como en la industria restaurantera con la introducción del *food delivery* y transporte vía *ridesharing* donde el precio se ha vuelto un factor de diferenciación decisivo.

El surgimiento de plataformas digitales o mercados de dos lados ha sido el principal elemento que explica el mayor rol de los precios como elemento estratégico. De acuerdo con David Evans, un mercado de dos lados se define como la plataforma donde se coordinan las demandas de múltiples grupos de consumidores y se genera valor a través de esta (Evans 2009). Las demandas de estos grupos están interrelacionadas, es decir, conforme crezca el número de participantes de un grupo, la demanda del contrario aumentará y viceversa. Este modelo de mercados de dos lados ha proliferado en numerosas industrias, desde la industria publicitaria en firmas *big tech* tales como Google y Facebook, servicios B2B como es el caso de Alibaba en China y el mercado de transporte transformado por servicios de *ridesharing* como Uber. La diferencia fundamental de este nuevo modo de intercambio respecto de los mercados de un solo lado radica en los avances tecnológicos. Gracias al desarrollo de las telecomunicaciones, computación móvil a través de teléfonos inteligentes, nuevos y mejores lenguajes de programación, así como la difusión de la *World Wide Web* es posible fomentar la confianza y la comunicación entre diversos grupos de consumidores a gran escala, que bajo otras circunstancias sería imposible llevar a cabo.

En la industria del alojamiento, Airbnb se ha posicionado como una de las plataformas dominantes. Con más de cinco millones de alojamientos distribuidos a nivel global en más de cien mil ciudades, la plataforma ha rediseñado a la industria y ha puesto en alerta a competidores en mercados tradicionales. La propuesta de valor de Airbnb radica en la utilización de la vivienda tradicional como espacio de alojamiento compartido, es decir, aquellas personas con propiedades (anfitriones) pueden publicarlas en la plataforma y recibir a turistas y viajeros (huéspedes) a cambio de una tarifa diaria.

Este modelo conlleva beneficios para todos los agentes involucrados que bajo otras condiciones no serían posibles. Por un lado, los anfitriones reciben una remuneración económica por publicar sus propiedades, sin llevar a cabo cuantiosas inversiones ni contratos de renta a largo plazo, lo cual impacta en los ingresos totales generados. Este nuevo modelo cambió el paradigma de una vivienda, reajustando su estatus de un bien subutilizado a un bien que puede generar ingresos adicionales para su propietario. Por otro lado, los huéspedes cuentan con una variedad de alojamientos diversos a precios asequibles y reciben una experiencia de alojamiento con un mayor contacto local, que en la industria tradicional no recibirían. Por lo tanto, las oportunidades de experimentar un contacto con las culturas locales son mayores que antes, lo cual conlleva a una mayor atracción de turistas y viajeros. En consecuencia, las comunidades se benefician con la derrama económica del turismo que puede permanecer dentro de estas comunidades, lo cual propicia su desarrollo económico. Finalmente, para los gobiernos, una mayor oferta turística, sin la necesidad de cuantiosas inversiones en espacios físicos, implica mayores ingresos fiscales. Ante estas circunstancias surge la necesidad de identificar los atributos que componen o explican los precios de los listados de Airbnb. Esto con el fin de establecer cómo un precio puede satisfacer las necesidades del consumidor, procurando también los ingresos generados a los anfitriones. Numerosos estudios se han llevado a cabo para entender la estructura de los precios en la industria del alojamiento en mercados tradicionales. Bajo un modelo de precios hedónicos, es decir, un análisis de la valoración de un bien a través de sus atributos se ha encontrado que elementos como el número de habitaciones, ratings, y amenidades son elementos explicativos del precio de alojamiento en los hoteles. Estudios similares se han llevado a cabo para el caso de la industria del alojamiento compartido, donde además de estos factores, el tipo de listado (habitación privada vs. vivienda entera), el número de reseñas, la distancia a puntos de interés y la capacidad de reservación instantánea son elementos que explican los precios de Airbnb.

Sin embargo, el estudio de estos factores conlleva algunos desafíos y áreas de oportunidad. En primer lugar, la heterogeneidad de la oferta de viviendas publicadas en la plataforma dificulta no solo el entendimiento en los precios, sino en la estimación de la demanda en general. A diferencia del sector de alojamiento tradicional, es posible encontrar una serie de listados significativamente distintos (iglús, tiendas de campaña, departamentos, *bungalows*, casas de

campana, casas de campo, entre otros). Por lo tanto, es necesario tomar en cuenta la heterogeneidad de estos listados para entender la composición de los precios.

En segundo lugar, varios de los estudios previos no incorporan el factor de ubicación ni la proximidad con otros inmuebles cercanos listados en la misma plataforma. El factor de ubicación contribuye a entender la relación que guardan los listados publicados respecto a sus alrededores, en particular, hacia los puntos de interés de una ciudad en particular. La relación entre estos es de suma importancia, ya que entre más próximo esté un listado, más demandado será entre los demás. Si bien existen trabajos que incorporan este factor, se limitan a utilizar el centro de la ciudad como referencia. Con más información sobre la dispersión espacial de los puntos de interés, será posible entender con mayor certeza la relación entre precio y ubicación. Asimismo, la relación que guardan los listados con sus pares cercanos es un factor interesante por entender. Dada la competencia subyacente por huéspedes entre las propiedades listadas, resulta necesario comprender si existe alguna relación entre la asignación de precios de un listado y asignaciones aledañas.

Finalmente, todos los estudios previos realizados sobre los precios de Airbnb se han llevado a cabo con información de ciudades de Norteamérica y Europa; existe poca o nula literatura sobre los factores que impactan los precios en México y Latinoamérica en general. Dada la composición de las ciudades, la distribución de sus zonas turísticas, la oferta actual de vivienda y la creciente demanda por estos servicios, es necesario entender de igual manera la valoración de los listados y como estos podrían afectar tanto el ingreso de los anfitriones, así como la composición espacial de los listados.

Por lo tanto, el objetivo de esta investigación es atender a los desafíos previamente mencionados y responder a la siguiente pregunta, ¿Cuáles son los atributos intrínsecos y espaciales que determinan la asignación de precios de departamentos en Airbnb en la Ciudad de México? Mi argumento radica en que atributos físicos de la vivienda, tales como el tamaño, habitaciones y amenidades, así como características del listado como políticas de cancelación, número de reseñas y las calificaciones son determinantes de los precios publicados en la plataforma. Asimismo, la incorporación de efectos espaciales tales como la distancia hacia puntos de interés, distancia hacia puntos de transporte y la asignación de precios de viviendas cercanas también son elementos significativos que explican el comportamiento de los precios dentro de la plataforma.

Utilizando un enfoque espacial, los modelos de auto regresión y errores espaciales (SAR y SEM, por sus siglas en inglés) permitirán el estudio de factores de ubicación y relación entre vecinos sobre la estimación de los precios. El trabajo seguirá la siguiente estructura. Se revisará la literatura previa sobre Airbnb y la asignación de precios dinámicos utilizada en 2016. Asimismo, se dará revisión a los estudios previos sobre los determinantes de los precios de Airbnb y el grado de influencia que existe sobre estos. En las siguientes secciones se establecerá la zona del estudio, así como la estadística descriptiva detrás de las principales variables a estudiar. Después, se revisará la metodología espacial y se hará un estudio previo para corroborar la estructura espacial subyacente en los precios. Finalmente se presentarán los resultados de este estudio, así como un análisis de estos y la conclusión de este trabajo.

2. Revisión de Literatura

2.1. Economía compartida

La economía colaborativa es un sistema socioeconómico que permite la compra, intercambio o distribución de diversos productos o servicios entre usuarios gracias a los mercados digitales *peer-to-peer* (P2P) (Yoo 2020).

Estos mercados o plataformas digitales surgieron gracias al desarrollo tecnológico en varias actividades como las telecomunicaciones, el procesamiento y almacenamiento de datos, *software*, entre otras (Evans 2017). Los mercados digitales han permitido la distribución de bienes y activos, subir contenido a la Web y realizar transacciones. Gracias a esto, industrias emergentes como el *ridesharing* y la industria del alojamiento compartido pueden incorporar a varios grupos previamente distanciados y aumentar el tamaño de sus plataformas a un bajo costo marginal y generar externalidades de red.

La adopción de la economía compartida también se debe a cambios recientes en las preferencias y modo de consumir de las personas. A partir de la caída en los ingresos en choques y recesiones económicos recientes, las perspectivas de los consumidores cambiaron en función de aprovechar sus bienes de forma rentable. Esta nueva mentalidad ha contribuido a una reflexión sobre preocupaciones adicionales en torno a la sobreproducción, efectos ambientales y un consumo excesivo (Liu y Chen 2020). Ante dichas circunstancias, los mercados digitales derivados de este nuevo sistema han permitido que se aprovechen numerosos activos que se encuentran subutilizados en un contexto tradicional. En particular, el uso de automóviles y la provisión de bienes inmuebles para servicios de alojamiento han sido dos principales recursos que han beneficiado a varios de sus propietarios gracias a la existencia de plataformas digitales. Un estudio de Gene Sperling encontró que, gracias a estas plataformas, los dueños de propiedades en Estados Unidos han percibido un aumento en sus ingresos, contrarrestando la caída de estos en los últimos quince años (Sperling 2015).

Datos recientes del Foro Económico Global estiman que la economía compartida tiene un valor de 15 billones de dólares y se espera que este valor aumente a 355 billones en los próximos años (WEF 2019). La economía colaborativa ha impactado a varias industrias a tal grado que varias de las compañías con mayor valuación en mercados accionarios operan bajo este esquema económico (Evans 2017).

Sin embargo, numerosos gobiernos, firmas en industrias tradicionales afectadas e instituciones no gubernamentales han señalado algunos efectos adversos derivados de la economía compartida. Con el fin de evitar afectaciones en espacios públicos, el estado de California, en EE. UU ha formulado regulaciones de vivienda para las plataformas de alojamiento, limitando la oferta de estos. Varias ciudades en Europa como el caso de París y Barcelona también han puesto límites a la oferta, respectivamente.

En términos de política de competencia, el crecimiento de nuevas plataformas en diversos mercados ha propiciado una concentración de mercado, así como un desplazamiento de empresas en varios segmentos. Ante ello, los reguladores y *policymakers* están en un constante proceso de modificación y replanteamiento de herramientas regulatorias para asegurar que el proceso de competencia se mantenga en buen estado bajo este nuevo marco económico (Evans 2017 y OCDE 2018).

Otros efectos están asociados con temas de privacidad de los datos personales de los usuarios. Los mercados digitales han facilitado la recolección y la generación de bases de datos personales, que ha aumentado de manera masiva. Así, las firmas detrás de estas plataformas compiten constantemente por esta información. Ya sea para alimentar modelos y algoritmos de recomendación, diseño de subastas o precios, la información de los consumidores es un elemento estratégico vital y, por ello, varios gobiernos y organizaciones han implementado regulaciones con el fin de proteger los datos de los consumidores (WEF 2019).

2.2. Airbnb

Una de las industrias que se ha visto fuertemente afectada por el surgimiento de la economía compartida es el de la hotelería y alojamiento. Airbnb surgió como una plataforma de alojamiento compartido, donde dueños de propiedades pueden publicar sus inmuebles en una plataforma para ser rentados por viajeros y turistas que desean una experiencia local auténtica y a un bajo costo. La plataforma, fundada por Brian Chesky, comenzó sus servicios en 2007. De acuerdo con un reporte de la industria, Airbnb cuentan con más de siete millones de propiedades publicadas, ubicados en más de cien mil ciudades a escala global (Airbnb 2020). Actualmente, es la plataforma líder en este segmento, con una participación de mercado de 80% en varias regiones del mundo (STR 2016). En 2019, la compañía anunció una oferta pública inicial para salir a mercados de valores y cuya valuación como empresa alcanzó los 35 mil millones de dólares. A pesar de la aparición de la pandemia en 2020 y un cierre temporal de las actividades

producto de la cuarentena, la plataforma sigue en proceso de cotizar en mercados accionarios (Forbes 2020).

Esta compañía ha llamado la atención de la academia debido a los diversos efectos que tenido en varias dimensiones y en numerosas industrias. Georgios Zervas investigó los efectos que tiene el aumento de listados en el nivel de ocupación, ingresos y precio de la industria hotelera y encontró efectos significativos en torno a la sustitución (Zervas et al. 2017). De forma similar, otros estudios encontraron efectos positivos del aumento de listados en los precios de la renta en varias ciudades, así como en la industria de bienes raíces (King y Proserpio 2018; Ferrando 2020).

En consecuencia, en diversas ciudades se han llevado a cabo regulaciones con el fin de disminuir o evitar los efectos negativos observados con el incremento de listados en esta plataforma. En la ciudad de San Francisco, la oficina de planeación urbana impuso limitaciones al número de listados que están disponibles para renta a largo plazo. En el caso de la ciudad de Nueva York también se implementó una norma similar, además de que se fiscalizaron los ingresos percibidos en la plataforma. Asimismo, en otra Barcelona, está fiscalizado y se requiere de una licencia para operar (Universal 2019).

Otros estudios previos se han realizado en torno a los determinantes de la demanda (Onder y Gunter 2020), así como los factores que determinan la ubicación de los listados (Eugenio-Martin 2019).

2.3. Estrategia precios dinámicos Airbnb

Uno de los objetivos de Airbnb es el de ofrecer experiencias de alojamiento locales a un precio accesible a todos los viajeros y turistas a escala global (Airbnb 2020). Por ello, la plataforma cuenta con una estrategia de precios dinámicos que apoya a los anfitriones de alojamientos para establecer de forma adecuada sus precios. Un artículo presentado por Airbnb revela cómo funciona dicha estrategia (Ye et al. 2016). Con base en los atributos de los listados, la temporalidad en las tasas de ocupación y en las interacciones entre usuarios y anfitriones, se fija una banda de precios óptimos que maximizarían tanto el tiempo de ocupación de los listados, así como un precio accesible a los huéspedes. La recomendación final es una banda de precios que el anfitrión puede adoptar o no. (Ye et al. 2016). Sin embargo, este no es un problema trivial debido a tres factores, la temporalidad en la demanda, la heterogeneidad entre los listados

ofertados y la adopción parcial de las estrategias de precios dinámicos de la plataforma, lo cual agrega complejidad al problema de fijación de precios.

Ante esto, es importante que los dueños de los listados publicados en Airbnb tengan un entendimiento sobre sus propiedades y sobre como los atributos que cuentan influyen en los precios finales publicados. Esto con el fin de minimizar asimetrías de información y fomentar mejores estrategias de precios para los huéspedes.

2.4. Modelos de precios hedónicos

Para conocer a fondo los atributos determinantes de los precios en esta industria, varios académicos han estimado los precios en función a un modelo de regresión de precios hedónicos. De acuerdo con Sherwin Rosen, la formulación de un modelo de precios hedónicos tiene como objetivo determinar la valoración de un bien en términos de sus características. (Rosen 1974). En varias industrias se ha aplicado este modelo para estimar los factores que más afectan los precios de los productos. En particular, este modelo se ha implementado en la industria hotelera, así como en la industria de los bienes raíces (Ramírez de la Cruz 2018). Con base en estas industrias, así como estudios previos sobre Airbnb, en esta Tesina se construirá un modelo de precios hedónicos para listados en la Ciudad de México.

2.5. Determinantes de los precios en la industria del alojamiento compartido

Varios estudios han desarrollado modelos de precios hedónicos tomando como base de referencia los atributos de la industria hotelera tradicional. Con base en estos análisis, otros estudios han buscado entender los atributos que pueden explicar los precios en la industria del alojamiento compartido. De acuerdo con la revisión de análisis previos, en total, los determinantes de precios en este sector se pueden dividir en seis categorías: 1) ubicación, 2) características físicas del inmueble, 3) características de la publicación, 4) amenidades/servicios, 5) reglas del lugar, 6) características del anfitrión y su reputación. La Tabla 1 resume los resultados de estos trabajos previo.

Tabla 1: Resumen de revisión literatura sobre determinantes de precios en Airbnb

Categoría	Variables o atributos	Efecto encontrado	Referencia
Ubicación	Distancia al centro	Negativo	Chica – Olmo 2020; Ramírez de la Cruz 2018; Wang y Nicolau 2017; Zhang et al 2017
	Distancia al centro de transporte		
Características físicas	Número de cuartos	Positivo	Pérez-Sánchez et al. 2018; Chica-Olmo et al. 2020; Wang y Nicolau 2017
	Número de baños		
	Número de huéspedes alojados		
Características listado	Reservación inmediata (<i>Instant book</i>)	Negativo	Pérez-Sánchez et al. 2018; Chica-Olmo et al. 2020; Wang y Nicolau 2017; Gibbs, Guttentag y Ulrike 2018; Hong y Yoo 2020
	Antigüedad del listado	Positivo	
Amenidades	Estacionamiento, gimnasio, bañera, piscina, elevador	Positivo	Gibbs, Guttentag y Ulrike 2018; Chica-Olmo et al. 2020; Wang y Nicolau 2017
	Desayuno	Mixto	
Reglas	Política de cancelación estricta	Positivo	Wang y Nicolau 2017; Che y Xie 2017, Pérez Sánchez et al. 2018
	Mascotas permitidas	Negativo	
	Fumar permitido	Negativo	
Características anfitrión	<i>Superhost</i>	Positivo	Wang y Nicolau 2017; Che y Xie 2017; Gibbs, Guttentag y Ulrike 2018; Hong y Yoo 2020
	Anfitrión con más de un listado publicado		
Reputación	Número de reseñas	Negativo	Zhang 2017; Gibbs, Ulrike, et al. 2018; Hong y Yoo 2020
	Rating	Mixto	
			Positivo: Wang y Nicolau 2017; Che y Xie, 2017; Cavar y Nikolic 2017
			Negativo: Zhang 2017; Chica-Olmo 2020; Hong, y Yoo 2020

Fuente: Elaboración propia con información de Zhang, Zhihua, Chen, Rachel, Han, Lee & Yang, Lu (2017).

La ubicación, al igual que en la industria tradicional, es un factor fundamental en el modelado de precios hedónicos de propiedades listadas en plataformas de alojamiento compartido (Ramírez de la Cruz 2018; Zhang 2017; Chica – Olmo 2020). En este sentido, varios autores encuentran que la ubicación relativa al centro de las ciudades es un factor relevante en el establecimiento de precios, ya que existe una relación inversa entre la distancia y los precios. Es decir, a menor distancia entre el punto de interés de una ciudad (en este caso, del centro de las ciudades) y un listado, mayores serán los precios de estos (Wang y Nicolau 2017; Dogru y Osman 2017; Hong y Yoo 2020; Gibbs, Guttentag y Ulrike 2017; Zhang et al. 2017).

Asimismo, algunos trabajos resaltan la importancia de la accesibilidad a medios de transporte como factor relevante en los precios. En su estudio, Honglei Zhang (2017) incorporó la distancia

de cada listado al centro de transporte principal en el área metropolitana de Nashville, Tennessee y encontró que existe una relación negativa entre la distancia y los precios.

La funcionalidad señalada en los espacios o inmuebles publicados en Airbnb, en términos de su tamaño, tiene efecto positivo y significativo en los precios publicados. En este sentido, el tipo de cuarto publicado (Casa/Departamento entero o Cuarto privado), el número de habitaciones y baños provistos, así como el número de huéspedes que aloja la unidad, son elementos fundamentales que determinan los precios de los listados de forma positiva (Perez-Sánchez et al. 2018; Chica-Olmo et al. 2020; Wang y Nicolau 2017; Gibbs, Guttentag y Ulrike 2018).

Respecto a los factores asociados con las características de los anuncios publicados, (Gibbs 2017; Chica-Olmo et al. 2020; Wang y Nicolau 2017), encuentran en sus respectivos estudios, que la característica de reservación inmediata (*Insta book*¹) tiene efecto negativo en los precios publicados. Nicolau detalla que dicho mecanismo obedece a una estrategia de maximización de la ocupación por parte de los anfitriones. Esta función ayuda a los huéspedes a planear de manera más eficiente sus viajes, esto, en conjunto con precios bajos, hacen más atractivos los listados para ser ocupados con mayor frecuencia (Wang y Nicolau 2017).

La duración de una publicación también influye de manera positiva en el precio de las propiedades publicadas. (Hong y Yoo 2020) realizaron un estudio espacial de precios de Airbnb en Los Ángeles y Nueva York. Encontraron que, a medida que un listado cuenta con mayor antigüedad en la plataforma, los anfitriones establecen precios mayores. En un contexto similar, Zhang, encuentra que los efectos de antigüedad de la publicación también son positivos. Intuitivamente, aquellos listados con mayor antigüedad señalizan mayor confianza gracias al historial de calificaciones y reseñas que en contraste, los listados más recientes no tienen dicho historial. Debido a esto, los huéspedes valoran la experiencia de estos listados y los anfitriones pueden establecer mayores precios como un *Premium* (Zhang 2017).

La incorporación de amenidades, como mecanismo de calidad, es igual de importante tanto para la industria del alojamiento compartido, así como en la industria hotelera tradicional. Los consumidores valoran elementos y servicios adicionales en su estancia y esto tiene una repercusión en los precios. En este sentido, varios autores incluyen en sus investigaciones el efecto que tienen diversas amenidades. Los estudios muestran que la provisión de gimnasios,

¹ Característica que permite a los huéspedes que cumplan los requisitos del anfitrión reservar sin tener que enviar una solicitud de aprobación.

piscina y estacionamientos tienen efectos positivos y significativos en los precios diarios de los listados de Airbnb en varias ciudades en Canadá (Gibbs, Guttentag y Ulrike 2018). Otros autores también encontraron que la inclusión de estacionamientos y elevadores son factores con efecto positivo y significativo (Wang y Nicolau 2017; Chica-Olmo 2020). La provisión de servicios de lujo como jacuzzis y piscinas también tienen un efecto positivo y significativo en los precios (Chica-Olmo 2020). Finalmente, los servicios de desayuno incluido cuentan con efectos diversos entre ciudades. Por un lado, algunos autores encontraron que la provisión de desayunos tiene un efecto positivo en los precios (Dogru y Osman 2017), mientras que otros encuentran un efecto contrario, sin embargo, significativo (Wang y Nicolau 2017).

Además de los atributos físicos de las viviendas publicadas en la plataforma, las reglas definidas por el anfitrión pueden determinar la valoración de los listados. En primer lugar, la política de cancelación que cuenta un listado, es decir, la flexibilidad o las restricciones que pueden existir en las cancelaciones de las reservaciones de un listado tienen un efecto positivo y significativo en los precios (Wang y Nicolau 2017; Che y Xie 2017; Pérez Sánchez et al. 2018). En consecuencia, los departamentos publicados con políticas de cancelación estrictos cuentan con un precio mayor en contraste a aquellos con políticas flexibles. La libertad para fumar, en segundo lugar, también es un factor relevante para los precios de los listados, en particular, esta regla tiene un efecto negativo en los precios publicados (Wang y Nicolau 2017; Chica Olmo 2020). Dado que esta política puede limitar la demanda de los posibles huéspedes, ya que puede generar insatisfacción, los anfitriones deciden bajar los precios como medida compensatoria. Finalmente, la libertad de alojar mascotas es un elemento que muchos viajeros locales consideran importante. Estudios previos encontraron un efecto negativo en este ramo (Chica Olmo 2020). Sin embargo, no se encontró que estos fueran significativos para algunos autores (Cavar y Nikolic 2017; Dogru y Osman 2017).

Finalmente, el esfuerzo de los anfitriones es otro factor que contribuye a una mayor valoración por parte de los consumidores y a la vez que disminuye la asimetría de información entre los usuarios. Por lo tanto, se espera que estos factores adicionales repercutan en los precios finales. En primer lugar, Airbnb cuenta con una distinción de anfitriones especiales denominada *Super Host*. Esta es una categoría 'elite' de anfitriones que cuentan con al menos 10 reservaciones, un 90% de ratings, 5 estrellas en un 80% de las visitas y una baja tasa de cancelación (Airbnb, 2020). Ante esta señalización de esfuerzo, varios estudios han señalado una fuerte influencia

positiva en los precios de los listados (Wang y Nicolau 2017; Che y Xie 2017; Gibbs, Guttentag y Ulrike 2018; Hong y Yoo 2020).

Otra señalización de un anfitrión profesional se manifiesta en el número de listados publicados en la plataforma. Esto distingue a anfitriones casuales que publican sus listados individuales y a aquellos que incorporan sus propiedades en Airbnb en una estrategia de negocio comercial y con el fin de proveer una mejor experiencia a viajeros y turistas. Se ha encontrado que a medida que un anfitrión cuente con más listados, el impacto en precios irá en aumento (Chica-Olmo 2020; Wang y Nicolau 2017; Dogru y Osman 2017; Gibbs, Ulrike y Guttentag 2018).

La reputación también forma parte del estudio de plataformas de alojamiento compartido (Wang, Nicolau 2017). En particular se consideran dos medidas de reputación, el número de reseñas que ha recibido el listado y la calificación de estos. Si bien la mayoría de los estudios previos han encontrado que el número de reseñas tiene un efecto negativo en los precios (Zhang 2017; Gibbs, Ulrike, et al. 2018; Hong y Yoo 2020), encontraron efectos mixtos en las calificaciones de los listados. Por un lado, estas reseñas reflejan la calidad de un listado y ayuda a eliminar asimetrías de información, por lo tanto, se espera que el efecto en precios sea positivo (Wang, Nicolau 2017; Che, Xie 2017; Cavar, Nikolic 2017). Sin embargo, la naturaleza de las calificaciones de los listados es diferente para plataformas de alojamiento compartido, debido a que la mayoría de las calificaciones son, en promedio, muy altas en contraste con la industria tradicional (Cox 2020). Ante la presencia de precios más bajos las expectativas de los consumidores disminuyen y son más propensos a dar mejores calificaciones, por lo tanto, se ha encontrado este efecto en ciudades de varios estudios (Zhang 2017; Chica-Olmo 2020; Hong y Yoo 2020).

3. Descripción de los datos

3.1. Zona del estudio

México es uno de los principales destinos turísticos a nivel global. De acuerdo con el Barómetro de la Organización Mundial del Turismo, México es el séptimo destino turístico más visitado en el mundo y alojó a más de 41 millones de visitantes de acuerdo con las cifras de 2018 (OMT 2019). La industria del turismo es uno de los principales motores de la economía mexicana, ya que este representa aproximadamente el 8.7% del Producto Interno Bruto del país y dejó una derrama económica de \$24 mil 816 millones de pesos (DATATUR 2020).

Al interior del país, la Ciudad de México es uno de los principales destinos turísticos tanto para viajeros nacionales como internacionales, ya que es la capital del país, alberga diversos lugares históricos al igual que tres sitios catalogados como Patrimonio de la Humanidad de la UNESCO. De acuerdo con cifras de la Secretaría de Turismo de la Ciudad de México, en 2019 se alojaron más de 13.9 millones de turistas en hoteles, de los cuales, más de 3.7 millones son de procedencia extranjera (DATATUR 2020).

En este contexto, no sólo la industria hotelera se beneficiado del crecimiento del sector turístico, también las plataformas de alojamientos compartidos se han expandido. En particular, Airbnb expandió su oferta de listados en la capital. En 2016, la plataforma contaba con 6,000 listados en la capital y para marzo de 2020 cuenta ya con más de 21,000 (IMCO 2016; Cox 2020).

Gracias a la entrada de las plataformas de economía compartida y sus nuevos modos de transacciones entre usuarios, la accesibilidad al turismo está en crecimiento, ya que la baja en precios, una de sus principales filosofías, ha permitido que visitantes nacionales tengan la oportunidad de viajar y conocer nuevos destinos turísticos, en particular, la Ciudad de México. De igual manera, respecto a la oferta en zonas especiales, Airbnb ha permitido la oportunidad de tener experiencias únicas donde el sector hotelero aún no ha penetrado. Por ejemplo, el centro histórico de Coyoacán es una zona con un alto valor cultural e histórico, sin embargo, donde no se permite el desarrollo de complejos hoteleros. En este contexto, la oferta de Airbnb ha permitido tanto a huéspedes como anfitriones aprovechar los beneficios de la economía local que de otra manera no existirían (IMCO 2016).

Finalmente, llama la atención el caso de la Ciudad de México, ya que esta fue una de las primeras ciudades en Latinoamérica en crear una regulación para este tipo de servicios digitales. Si bien

los beneficios de la presencia de Airbnb tanto en experiencias como en ingresos han mejorado las circunstancias del mercado turístico, es cierto que existen diversas preocupaciones para los *policymakers* de la ciudad. El uso de propiedades a largo plazo, las externalidades negativas provocadas por los huéspedes, la aplicación de licencias y la respuesta regulatoria ante la constante innovación de este sector ha impulsado la aplicación de regulaciones en la Ciudad. En 2017, se anunció un impuesto al hospedaje a las plataformas de alojamiento compartido equivalente al 3% del valor de la transacción (Deloitte s.f.). Asimismo, en 2019 se fomentó una reforma fiscal que busca la fiscalización de los alojamientos a nivel federal (Forbes 2020).

3.2. Datos y construcción de variables

La información de los listados publicados en la Ciudad de México se obtuvo a través de Inside Airbnb, una página que captura la información de Airbnb vía *webscraping* y alberga bases de datos públicas de listados de la plataforma en diferentes ciudades del mundo (Cox 2020).

Para este estudio se seleccionó la información de la Ciudad de México para julio de 2019, ya que es durante este mes cuando se presenta la mayor actividad turística en el año (DATATUR 2020). Además, en vista de la reciente emergencia sanitaria, tanto las tasas de ocupación, así como los precios publicados se vieron afectados, por lo tanto, se seleccionó la información del año previo para obtener resultados libres de choques exógenos en la industria (Forbes 2020).

Del total de listados publicados se seleccionaron solamente a aquellos listados que se encuentran activos. Si bien no se cuentan con registros de transacciones, las reseñas recibidas sirven como aproximación de la actividad de los listados (Sheppard y Udell 2016). Por lo tanto, se eliminaron de la muestra las publicaciones que no cuentan con reseñas o cuya última tenga una antigüedad mayor a seis meses (Casanova 2019). Asimismo, no todos los listados cuentan con información precisa de la ubicación. Por fines de privacidad, varios anfitriones deciden publicar la ubicación dentro de un radio de 150 metros, sin embargo, para estimar efectos de difusión entre vecinos cercanos es necesario contar con información granular en este aspecto. En consecuencia, también se eliminaron de la muestra aquellos listados que no cuenten con información de ubicación precisa de la propiedad.

La plataforma de alojamiento cuenta con una gama de propiedades con distintas características y servicios. Por lo tanto, para estimar efectos precisos, es necesario estudiar estos efectos en los precios por tipo de propiedad. Para este estudio, se seleccionó el tipo de propiedad que corresponde solamente a los departamentos listados en la plataforma.

Una de las principales razones de esto es que la Ciudad de México es una zona metropolitana altamente verticalizada. Así, se espera que varios de los alojamientos listados pertenezcan a este grupo. La información recabada por Cox confirma esto, puesto que el 70% de los listados publicados corresponde a la categoría de departamentos. Esto nos deja con una muestra final de 6,131 listados publicados en Airbnb con ubicación precisa en la Ciudad de México

La información respecto a las variables relevantes para este estudio se ubica en la Tabla 2. La base de datos de Inside Airbnb contiene las variables utilizadas en la literatura previa en siete aspectos: precio, tamaño, características de la publicación, amenidades, reglas, características del anfitrión y reputación.

Para el precio se observa una alta presencia de datos aberrantes. Si bien la media de los precios es de \$1,100 MXN, existen listados que superan esta cifra e inclusive llegan hasta los \$34,000 MXN, lo cual puede sesgar los resultados generados en nuestra especificación econométrica. Revisando la distribución de los precios se realizaron dos acciones, la primera, remover aquellos listados que se presentan como datos aberrantes en precios y la segunda, transformar la variable en términos de logaritmo natural para que la variable de interés tenga un comportamiento que se aproxime a la distribución normal.

En la primera categoría de variables explicativas o atributos se incluyen las variables de número de habitaciones (*bedrooms*), número de baños (*bathroom*) y número de huéspedes alojados (*accommodates*) para representar a las características físicas de los listados. En la sección de características de la publicación, se seleccionaron variables que otorgan información sobre la antigüedad de la publicación en meses (*ad_duration*), así como la capacidad de reservación inmediata (*insta_book*).

Las amenidades incluyen los servicios o características adicionales que ofrecen los anfitriones en el servicio de alojamiento. La selección de estas corresponde con las principales amenidades seleccionadas por varios autores en la revisión de la literatura (Chica Olmo 2020; Wang, Nicolau 2017) e incluye a la disponibilidad de estacionamiento (*parking*), servicios de desayuno (*breakfast*), gimnasio (*gym*), piscina (*pool*), jacuzzi (*hot tub*) y elevador (*elevator*). Esta selección tiene como finalidad evaluar el grado de influencia que tiene sobre los precios la inclusión de estas amenidades extras y como se valoran en el mercado capitalino, se espera que tanto las variables de amenidades, así como las de tamaño tengan un efecto positivo en los precios de los listados.

Por su parte, las variables cancelación flexible (*flexible_cancel*), mascotas permitidas (*pets_allowed*) y si se permite fumar (*smoking_allowed*) representan variables de reglas que establece el anfitrión del listado previo a la transacción, para las cuales la literatura revisada muestra resultados mixtos.

Este estudio también incluye factores asociados al anfitrión, el primero es si el anfitrión tiene la categoría *Super Host* (Categoría ‘elite’ de anfitriones que cuentan con al menos 10 reservaciones, cuentan con un 90% de ratings, 5 estrellas en un 80% de los casos y una baja tasa de cancelación, (Airbnb 2020)). También incluye información respecto al número de listados y se creó una variable dicotómica que indica si el anfitrión es profesional y cuenta con más de un listado publicado (Tipo Listado) y si este cuenta con la identidad verificada (*host_identity_verified*).

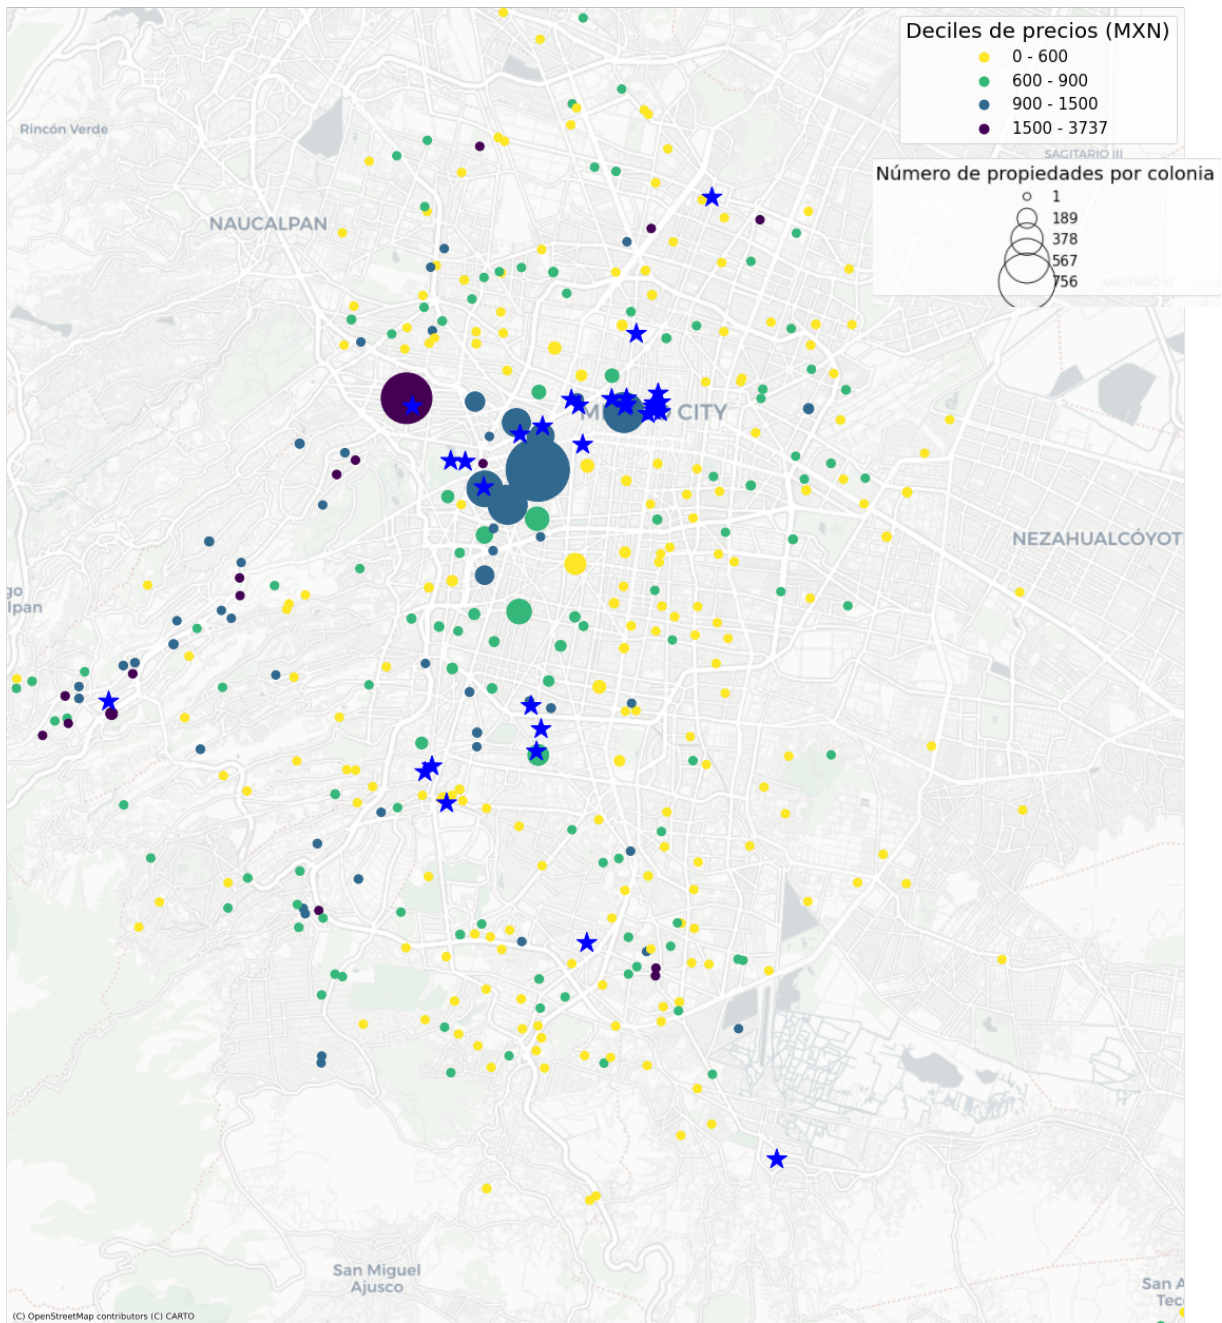
Finalmente, se incluyen variables de reputación que podrían afectar los precios de las publicaciones de Airbnb, en particular se consideran dos variables, la primera es el número de reseñas del listado (*num_of_reviews*) y la segunda, la calificación del listado en general, en una escala de 0-100.

Además de utilizar la información recabada de Airbnb, en este trabajo se utilizaron otras fuentes para incorporar los efectos de la ubicación de la propiedad en los precios de los listados. En primer lugar, se incluyó la información de los principales puntos de interés de la Ciudad de México, en particular su ubicación. A partir de la información de Trip Advisor se seleccionaron los principales destinos turísticos de la Ciudad de México con base en el número de reseñas de sus usuarios, así como por las calificaciones otorgadas, se extrajo la ubicación de cada uno y se calculó la distancia (semiverseno) de cada listado al punto de interés más cercano (Chica-Olmo 2020). Los puntos de interés incluyen destinos populares en el centro histórico (Zócalo, Torre Latinoamericana, Hotel de México), Reforma (Reforma 222, Monumento a la Independencia, Bosque y Castillo de Chapultepec y la Alameda Central), zonas de entretenimiento y actividad nocturna (Polanco, Condesa), sitios religiosos (Basílica de Guadalupe) y puntos de interés en el sur de la ciudad (Coyoacán, San Jacinto, Ciudad Universitaria, Estadio Azteca y la Cineteca Nacional). Los resultados de la medición de estas distancias se incluyen en la variable *pi_dist* y se espera que exista un efecto negativo, es decir, entre más lejos se encuentre un listado a un punto de interés cercano, los precios disminuirán.

El **Mapa 1** muestra la distribución espacial de los listados, asimismo ilustra la ubicación de los puntos de interés (en estrellas azules). Como se puede apreciar, la mayoría de los listados se concentran en áreas urbanas verticalizadas (por ejemplo, colonias como Condesa, Roma, Planco, Reforma). Este también destaca que los precios altos se concentran en estas zonas ya que es en estas donde se concentra gran parte de la actividad turística de la Ciudad de México. Además, existe la oferta de bienes raíces para satisfacer al mercado turístico de la ciudad. En términos de precios, es en estas zonas donde se observa una tendencia de precios mayor que en zonas al sur de la ciudad, así como el poniente. La agrupación de precios también es clara en este caso, las zonas de Condesa, Roma, Reforma y aledañas cuentan con precios altos mientras que todo lo que rodea por fuera de estas zonas cuentan con precios menores.

Otra variable de ubicación y accesibilidad que se considera relevante para este estudio y que ha sido utilizado en otros trabajos (Zhang 2017), es la accesibilidad a centros de transporte. En este contexto, se incluirá la ubicación de las estaciones de la red del Sistema de Transporte Colectivo Metro para incluir los efectos de la accesibilidad a este servicio en los precios de los listados. De igual manera que en la variable *pi_dist*, se calculará la distancia de cada listado hacia la estación más cercana. Los resultados se alojan en la variable *metro_distance*.

Mapa 1 : Distribución de precios de departamentos de Airbnb en la Ciudad de México



Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)

Finalmente, se incluye la variable $W_{ln(price)}$, una variable formulada en el modelo de autocorrelación espacial (SAR, por sus siglas en inglés) detallada en la siguiente sección. Esta representa el promedio de precios de listados vecinos especificados por la matriz de pesos W (detallada en la siguiente sección) e indica la posible asociación que existe entre los precios de un listado y sus vecinos a partir de un efecto de difusión. En otras palabras, si el efecto de esta variable es positivo, entonces las decisiones de precio de los anfitriones se ven influenciada por las estrategias de sus vecinos más cercanos. Para verificar que, efectivamente existe una agrupación de los listados en torno a los precios, es necesario revisar la especificación econométrica para estimar efectos de autocorrelación espacial. En particular, se especificará una matriz de pesos W que identifique la región de vecinos cercanos para cada observación.

La Tabla 2 muestra las estadísticas descriptivas de las variables antes descritas.

Tabla 2: Estadística descriptiva

	Media	Desv. est.	Mín	Máx	Descripción
Precio diario	\$1,103.80	\$1,166.79	\$152.00	\$34,147	Precio diario de departamento listado en Airbnb en pesos mexicanos (MXN)
Tamaño					
bedrooms	1.45553743	0.778654714	0	24	Número de recámaras
bathrooms	1.329962486	0.542859009	0	4.5	Número de baños
accommodates	3.337302235	1.844194585	1	16	Número de huéspedes alojados
Entire home/apt	0.694177133	0.460792658	0	1	Variable "dummy". 1 si se renta la propiedad entera, 0 cuarto privado
Características publicación					
insta_book	0.611971946	0.487340765	0	1	Variable "dummy". 1 si el anfitrión permite reservaciones inmediatas
ad_duration	16.18632224	15.20295564	0.032854884	94.06353313	Antigüedad de la publicación en meses
Ubicación					
pi_dist	1.543617693	1.618021956	0.016727648	11.81904338	Distancia al punto de interés más cercano en kilómetros
metro_distance	0.893961215	1.349838367	0.009793088	11.74410092	Distancia a la estación de STC Metro más cercano en kilómetros
Amenidades					
parking	0.723536128	0.447285402	0	1	Variable "dummy". 1 si existe disponibilidad de estacionamiento
breakfast	0.063284945	0.243494623	0	1	Variable "dummy". 1 si el listado cuenta con servicio de desayuno
gym	0.142391127	0.349479348	0	1	Variable "dummy". 1 si el listado cuenta con gimnasio
pool	0.069646061	0.254570339	0	1	Variable "dummy". 1 si el listado cuenta con piscina
hot_tub	0.051215136	0.220454242	0	1	Variable "dummy". 1 si el listado cuenta con tina caliente
elevator	0.468928397	0.499074324	0	1	Variable "dummy". 1 si el listado cuenta con elevador
Reglas					
flexible_cancel	0.369434024	0.482690924	0	1	Variable "dummy". 1 si la política de cancelación es flexible, 0 si es moderada/estricta
pets_allowed	0.15576578	0.362662728	0	1	Variable "dummy". 1 si el anfitrión permite mascotas
smoking_allowed	0.259337792	0.438307011	0	1	Variable "dummy". 1 si el anfitrión permite fumar
Características anfitrión					
host_is_superhost	0.469417713	0.499104552	0	1	Variable "dummy". 1 si el anfitrión es superhost
Tipo Listado	0.612135051	0.487303255	0	1	Variable "dummy". 1 si el anfitrión cuenta con más de un listado (profesional)
host_identity_verified	0.373674768	0.483818267	0	1	Variable "dummy". 1 si el anfitrión verificó su identidad (teléfono, correo, Facebook)
Reputación					
review_scores_rating	95.64540858	6.866913821	20	100	Calificación general del listado, escala (0-100)
number_of_reviews	34.96542163	44.37545702	1	362	Número de reseñas del listado

N = 6131 (número de listados publicados en Airbnb)

Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)

4. Metodología

A través de un modelo de precios hedónicos, este trabajo estudia la relación entre los precios de los departamentos publicados en Airbnb en la Ciudad de México y sus características. Igualmente, el trabajo incorpora características espaciales de las propiedades con el fin de encontrar el impacto que tiene la ubicación de un departamento, así como la presencia de listados similares en el área y otros puntos de interés y de transporte. A continuación, en primer lugar, daré un breve repaso sobre la implementación de los modelos de precios hedónicos, estructura y propiedades. En segundo lugar, discutiré sobre la incorporación de efectos espaciales, su relevancia y desafíos empíricos asociados con esta característica. Después, se abordará la especificación de los modelos espaciales que se utilizarán en este estudio. Finalmente, se aplicará esta metodología sobre la distribución de precios para elucidar la estructura espacial de los precios publicados en Airbnb.

4.1. Modelo precios hedónicos

El estudio de los precios de bienes y servicios a través de la metodología de precios hedónicos ha surgido en décadas recientes como una técnica útil para la valuación de bienes y servicios. Este enfoque permite analizar el precio de un bien o servicios en función de sus características o atributos internas, y determinar el impacto que estos tienen en el precio final de los bienes. Dicha metodología tiene una serie de aplicaciones en diversas industrias, y, en particular, en la industria de bienes raíces, donde elementos físicos, ambientales, sociales, culturales y económicos pueden alterar los precios observados en este mercado. Sherwin Rosen (1974) desarrolló este modelo en términos de un modelo de equilibrio de mercado, donde la utilidad de un consumidor se puede interpretar en función de las características del bien específico y, por otro lado, los costos del productor dependen en las características del bien. Para llevar a cabo la estimación, se computa una función de precios hedónicos en términos de las principales características de un bien. En el contexto de la industria de bienes raíces esta estimación incorpora características físicas (número de habitaciones, tamaño, tipo de materiales utilizados), ambientales (polución, tráfico, accesibilidad) y ubicación. Los parámetros estimados se interpretan como el precio marginal de cada característica, es decir, la propensión marginal a pagar por cada elemento detrás de la vivienda. (Anselin y Lozano 2009).

Para el caso de los estudios de la vivienda y otras industrias, se han observado una serie de dependencias e interacciones en el plano espacial, es decir, la distribución de las variables observadas obedece a un ordenamiento espacial (Anselin y Lozano 2009). En el marco de la geografía, esta dependencia se le conoce como la primera ley de Tobler: *“Todas las cosas están relacionadas entre sí, pero las cosas más próximas en el espacio tienen una relación mayor que las distantes”* (Miller 2004). Esto implica que exista una serie de relaciones en múltiples direcciones entre un elemento y sus pares cercanos, lo cual puede sesgar los resultados obtenidos mediante un modelo hedónico si no se incorporan estos efectos. Por lo tanto, para obtener un modelo robusto es necesario que en la especificación se incorpore a) las interacciones entre observaciones cercanas y b) la estructura espacial subyacente en los errores.

4.2. Modelos de Autocorrelación y Error espacial

Luc Anselin desarrolló dos modelos principales que permiten estimar efectos espaciales que resuelven las problemáticas planteadas anteriormente: el modelo de autocorrelación espacial y el modelo de error espacial, SAR y SEM por sus siglas en inglés, respectivamente. El primero incorpora efectos de difusión entre vecinos cercanos y evita el sesgo en los estimadores en los modelos lineales. Este modelo tiene como finalidad incorporar efectos de interacción entre vecinos cercanos de acuerdo con la primera ley de Tobler. El segundo modelo captura la relación espacial que existe en la estructura de los residuales del modelo propuesto con el fin de evitar la inconsistencia de los estimadores derivado de una especificación que no incorpore procesos de autocorrelación espacial. Para este trabajo utilizo ambos modelos con el objetivo de encontrar el efecto preciso de la ubicación de los departamentos en sus precios.

El objetivo del primer modelo es elucidar las interacciones espaciales, en particular la difusión espacial entre las observaciones. Ante esto, el modelo de autocorrelación espacial permite estimar los efectos que tienen los vecinos más cercanos en la variable dependiente.

Si bien el modelo de rezago espacial puede eliminar el proceso de correlación espacial y generar resultados eficientes, es posible que este efecto no se pueda eliminar. Se pueden manifestar efectos espaciales en otras variables explicativas que se reflejen en la estructura de los residuales. Ante esto, es necesario especificar un modelo que considere la dependencia espacial de los errores para mejorar la especificación del modelo propuesto. El modelo de errores espaciales resuelve este problema y, en consecuencia, los estimadores generados serán consistentes.

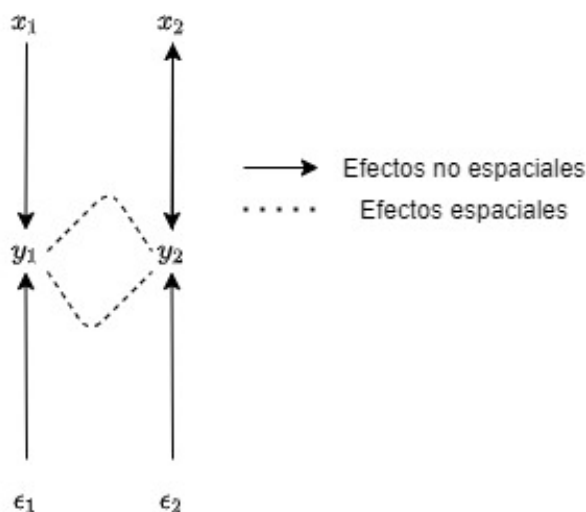
El modelo de autocorrelación espacial se caracteriza por la inclusión del rezago espacial (*spatial lag*) de la variable de interés y . Esta tiene como finalidad capturar los efectos de interacción entre los vecinos más cercanos.

Modelo de rezago espacial se especifica como:

$$y = \alpha + \rho W y + X\beta + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2 I)$$

Donde y es un vector de dimensión $n \times 1$ que representa a la variable dependiente, X es una matriz de dimensión $n \times k$ que representa a las variables explicativas que afectan a la variable dependiente. W es una matriz cuadrada de pesos espaciales de tamaño $n \times n$ ($n = 6131$), donde cada elemento w_{ij} corresponde a la influencia espacial entre los elementos j de una observación i . El coeficiente ρ indica el grado de influencia que tienen los valores de los vecinos sobre la variable dependiente de cada observación, y se puede entender como el coeficiente de autocorrelación espacial de los vecinos cercanos. Si el coeficiente es alto y significativo, es posible que exista un efecto *spillover* y, en consecuencia, un efecto espacial entre las observaciones y su respectiva vecindad. Por su parte, β es el vector de dimensión $k \times 1$ que representa a los coeficientes asociados a las variables explicativas; y ε es el vector $n \times 1$ de errores distribuidos idéntica e independientemente (Anselin 1988). La Figura 1 representa el funcionamiento de este modelo propuesto.

Ilustración 1. Modelo de rezago espacial



Fuente: Elaboración propia con información de Meng et al. (2009)

La matriz W se puede interpretar como la relación que existe entre las observaciones y sus respectivos vecinos. Si dos regiones están conectadas espacialmente el valor w_{ij} será positivo y

cero si no existe dicha relación. Los elementos diagonales representan las conexiones de un elemento consigo mismo, por lo tanto, los valores en esta sección serán cero. Gracias a esta matriz, es posible modelar el rezago espacial de vecinos cercanos en la variable dependiente a través de la forma Wy descrita en la ecuación anterior. En otras palabras, esta expresión representa un promedio ponderado de la variable dependiente.

4.3. Efectos directos e indirectos

Es necesario resaltar que la interpretación de los parámetros estimados debe manejarse con cuidado. En caso de que el coeficiente ρ de *spillover* espacial sea diferente de cero, las observaciones no serán independientes y los coeficientes generados incluirán información de las regiones adyacentes (Le Sage 2009). Debido a la especificación, señalamos la existencia de un efecto de difusión que se da entre los elementos más cercanos a un punto dado. Por lo tanto, un cambio en un coeficiente afectará el resultado de una observación inicial, la cual tendrá efectos en sus alrededores y, en consecuencia, sus valores finales se verán afectados lo cual repercutirá en los resultados finales de la observación y así sucesivamente. Esta retroalimentación positiva afecta la interpretación de los resultados finales y debe tomarse en cuenta para interpretar correctamente los resultados de este modelo (Golgher, Voss 2015).

Para atender esta problemática es necesario encontrar un estimador que incorpore la variabilidad regional de los resultados. Pace y LeSage desarrollaron una forma para encontrar el impacto promedio de estos efectos.

Para calcular estos efectos es necesario eliminar la endogeneidad de este modelo y convertir la forma funcional en su versión reducida con el fin de expresar el modelo en función de términos exógenos. A partir de la versión inicial del modelo estimamos la versión reducida.

$$y = (I - \rho W)^{-1}(\alpha + X\beta + \varepsilon)$$

Para esta estimación asumimos que la matriz $(I - \rho W)^{-1}$ es invertible. Con esta versión estimamos el valor esperado de y condicionado en las variables explicativas y generamos el siguiente resultado.

$$E[y|X, W] = E[(I - \rho W)^{-1}(\alpha + X\beta + \varepsilon)]$$

$$E[y|X, W] = (I - \rho W)^{-1}E[(\alpha + X\beta + \varepsilon)]$$

$$E[y|X, W] = (I - \rho W)^{-1}(\alpha + X\beta)$$

Así, los efectos marginales se obtienen a partir de las derivadas parciales de la expresión para alguna variable exógena k :

$$\begin{pmatrix} \frac{dy_1}{dx_{1k}} & \dots & \frac{dy_1}{dx_{nk}} \\ \vdots & \ddots & \vdots \\ \frac{dy_n}{dx_{1k}} & \dots & \frac{dy_n}{dx_{nk}} \end{pmatrix} = (I - \rho W)^{-1} \begin{pmatrix} \beta_k & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \beta_k \end{pmatrix}$$

$$= \beta_k (I - \rho W)^{-1}$$

La expresión $(I - \rho W)^{-1}$ se puede interpretar como el proceso de difusión global que existe en la muestra. En otras palabras, un cambio, en la variable independiente afectará no solo a los valores dentro de su vecindad, sino a todos los demás valores en la muestra, independientemente del tipo de matriz espacial especificada.

Para elucidar la diferencia entre efectos directos, indirectos y totales, es necesario analizar la matriz de derivadas parciales generada. LeSage y Pace (2009), estiman que la media de los elementos de la diagonal de la matriz de derivadas parciales representa los efectos directos. Asimismo, encuentran que los efectos indirectos se encuentran en los elementos que se encuentran fuera de la diagonal de dicha matriz. Este efecto se mide como una suma de los elementos fuera de la diagonal y se divide entre el número de renglones, es decir, se obtiene un promedio de los elementos.

En consecuencia, el efecto total que captura el efecto de difusión global se puede interpretar como la suma del efecto directo e indirecto.

4.4. Modelo de error espacial

Si bien las interacciones entre vecinos que modela el rezago espacial generan entendimiento sobre la variable dependiente, es posible que existan procesos espaciales no observados que afecten los resultados de las estimaciones. De esta manera, dichos resultados no serían consistentes, ya que el término de error estaría correlacionado. El segundo modelo que presentaré atiende este fenómeno al incorporar la misma matriz de pesos espaciales en la estructura de los errores. La estructura de la especificación se obtiene a partir de los estudios econométricos obtenidos por Kelejian y Robinson (1992) y se puede representar gráficamente en la Figura 2:

$$y = \alpha + X\beta + \mu$$

con:

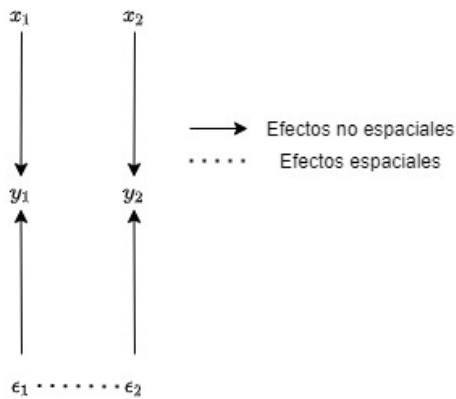
$$\mu = \lambda W\mu + \varepsilon,$$

Al igual que en el modelo de rezago espacial, y representa a la variable dependiente, el vector X representa a las variables explicativas y el vector β a los coeficientes asociados a las variables explicativas. Como señala la ecuación previa, el vector de errores μ está en función de un rezago espacial sobre los errores adyacentes, expresados con la forma $W\mu$, donde el parámetro λ puede interpretarse como el coeficiente autorregresivo espacial de los errores. Finalmente, ε , simboliza el error bajo una distribución i.i.d.

En la forma reducida generamos el siguiente resultado:

$$y = \alpha + X\beta + (I - \lambda W)^{-1}\varepsilon$$

Ilustración 2. Modelo de errores espaciales



Fuente: Elaboración propia con información de Meng et al. (2009)

4.5. Matriz de pesos espaciales

Para medir los efectos espaciales es necesario calcular una matriz de pesos que incluya el efecto de las observaciones sobre cada listado. Por lo tanto, se proponen diferentes especificaciones de dicha matriz, cada una con diferentes interpretaciones. En primer lugar, se empleará una matriz de distancia inversa computa la distancia inversa que existe hacia cada una de las observaciones. Ante una menor distancia entre listados, el efecto será mayor y viceversa.

Una segunda especificación resalta una relación más gravitacional entre las observaciones, es decir, a aquellos puntos más cercanos se les otorgará un valor mayor que aquellos que se


encuentren más distanciados. Esta matriz la denominaremos una matriz de distancia inversa cuadrada.

En una tercera especificación, también calculada como la distancia inversa de forma similar al primer caso, se impone un corte bajo cierto umbral. Este umbral se define dentro de un rango de 340 metros, ya que, en este corte, todos los listados contarán con al menos, una observación como vecina. En caso de que los puntos se encuentren fuera de este rango, se le asignará un valor de 0 a ese punto individual.

Finalmente, se calculará la matriz de pesos como una matriz de k-vecinos más cercanos (KNN, por sus siglas en inglés). La determinación del número de vecinos se basa en aquel arreglo que maximiza el valor de la R^2 y minimiza el Criterio de Información de Akaike (AIC). En otras palabras, el número de vecinos que explique mejor la variación de los precios será computado en la matriz de pesos final.

Se evaluaron diferentes configuraciones en el modelo de autocorrelación espacial que incluye todas las variables de interés en el modelo. Por lo tanto, como lo indica el gráfico 1, la matriz con 35 vecinos más cercanos cuenta con una R^2 más grande y el menor AIC, por lo tanto, se utilizará esta versión en el modelo final. El Gráfico 1 ilustra los resultados mencionados.

Gráfico 1: Valores de R^2 y AIC para diferentes valores de k-vecinos cercanos



Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)

4.6. Pruebas de autocorrelación espacial

Para corroborar que los precios de los listados pertenecen a un proceso de dependencia espacial, es necesario realizar una evaluación estadística. El Índice I de Moran (Cliff y Ord, 1969) indicará si existe un grado de asociación espacial entre las observaciones a nivel global.

El estadístico de autocorrelación espacial (Índice de Moran I) se expresa de la siguiente forma:

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{i,j} z_i z_j}{S_0 \sum_{i=1}^n z_i^2}$$

Donde los parámetros $z_i z_j$ representan desviaciones simples de la variable de interés, $w_{i,j}$ es la ponderación espacial entre las observaciones i y j , n es el número total de observaciones y S_0 representa la suma de los ponderadores w_i y w_j :

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{i,j}$$

En concreto, este estadístico calcula un producto cruzado entre la observación y las observaciones vecinas expresado en desviaciones de la media.


El resultado se puede interpretar de la siguiente manera. Si el valor de una observación y el de las entidades vecinas son mayores que la media, entonces las desviaciones y el producto cruzado serán positivos. Lo mismo ocurre en el sentido opuesto. En este sentido, si los valores altos se agrupan cerca de otros valores altos y los valores bajos se agrupan cerca de otros valores bajos, el índice de Moran será positivo.

Cuando los valores presentan dispersión, es decir, cuando el producto cruzado es negativo (los valores altos se agrupan con valores bajos o viceversa), entonces el índice de Moran será negativo.

El resultado de los productos cruzados está normalizado por la varianza con el fin de que el índice se encuentre en un rango de valores entre (-1,1). Los datos estudiados encuentran un valor para este índice de 0.27, lo cual indica una relación positiva entre los precios.

Para visualizar este fenómeno a detalle, se presenta la siguiente gráfica de puntos de del Índice local de Moran. Este gráfico muestra la relación entre el precio de los listados en el eje de las abscisas y el valor de su vecindad en las ordenadas. En esta estimación la pendiente es el estadístico de Moran. Una ventaja de esta visualización es que nos permite distinguir la autocorrelación espacial de los listados en cuatro cuadrantes.

Gráfico 2: Índice I de Moran sobre la dispersión de precios



Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)

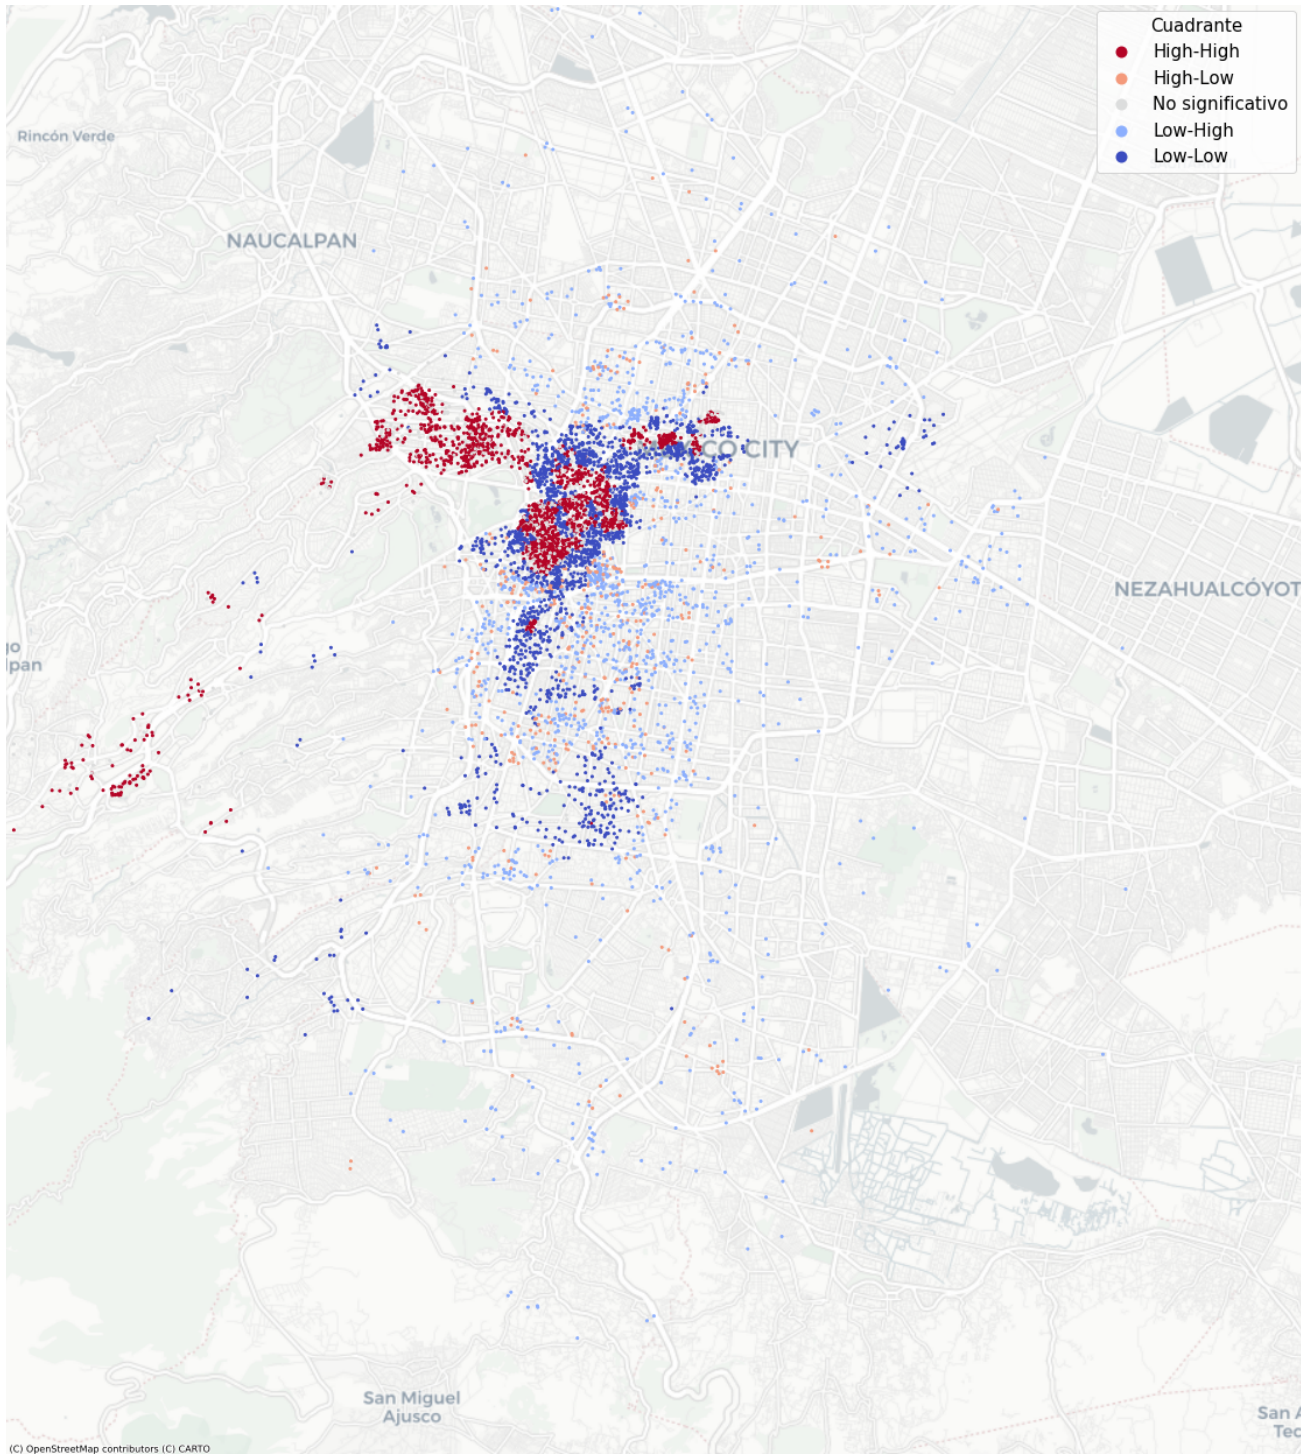
Los cuadrantes superior derecho e inferior izquierdo representan los valores con autocorrelación espacial positiva, es decir, valores de precios superiores a la media cuyos vecinos cuentan con valores similares. Por su parte, los cuadrantes superior izquierdo e inferior derecho presentan autocorrelación espacial negativa, donde los precios de las observaciones y de los vecinos difieren.

Si bien el estadístico I de Moran nos da una noción sobre el grado de autocorrelación, esta se mide en un contexto global. Para comprender el grado de asociación local, se computó el índice I para todas las observaciones de la muestra y aquellos valores con un color asignado, representan observaciones donde el Índice resulta significativo (a un nivel de 5%). Los colores representan el cuadrante al que pertenece la observación. Los colores azules y rojo oscuro indican valores con autocorrelación espacial positiva mientras que las versiones en color pastel la autocorrelación negativa (dispersión).

A partir de esto, podemos visualizar en el Mapa 2 el grado de agrupación que existe en los listados de la Ciudad de México. La siguiente figura muestra la asociación de los listados en la ciudad cuyo Índice de Moran local resultó significativo. En esta visualización, podemos observar que los listados que se encuentran en la parte norte de la ciudad, en particular la zona

de Polanco cuenta con una asociación positiva en precios, donde precios altos corresponden con precios de la vecindad en un mismo nivel. Lo mismo ocurre en el área occidental de la ciudad, Santa Fe y en la zona del centro, las colonias Condesa y Roma. Es claro que en estos puntos se da este fenómeno ya que son zonas de alto poder adquisitivo, con disponibilidad de vivienda y cercanía a varios puntos históricos, excepto por el caso de Santa Fe.

Mapa 2: Índice de Moran local de los precios de los departamentos publicados en Airbnb en la Ciudad de México



Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)

Asimismo, el estadístico muestra que, en el resto de la ciudad, existen varios puntos donde existe una asociación entre precios bajos entre observaciones y lugares cercanos. Debido a la

naturaleza de la plataforma cuyo objetivo principal es procurar alojamiento a precios accesibles, no es sorpresa que los anfitriones sigan una estrategia de precios que atraiga a los consumidores con esta filosofía, además que la decisión de precios se vea influenciada por las decisiones de otros anfitriones. Por lo tanto, en la Ciudad de México, existen fuertes agrupaciones espaciales que pueden influir en la decisión de precios.

4.7. Especificación

En la tabla 3, se presentan las estimaciones del modelo tradicional utilizando el método de mínimos cuadrados ordinarios de precios hedónicos. Se realizó una prueba de multicolinealidad con el estadístico VIF y se encontró que ninguna de las variables rebasa el umbral de 10 que indica multicolinealidad alta entre los regresores. Asimismo, se realizaron pruebas estadísticas para medir la existencia de autocorrelación espacial dentro de los errores del modelo. En primer lugar, se realiza una prueba Z_I de Moran para los estimadores y encuentra un índice alto que rechaza la hipótesis nula de aleatoriedad en la distribución de los errores.

Para decidir qué especificación (SEM/SAR) se acopla mejor a los datos de Airbnb se realizaron dos pruebas de dependencia espacial medidas con multiplicadores de Lagrange (LM-Lag y LM-Error). Por un lado, se analiza la estructura del error en el modelo SEM. La prueba evalúa la hipótesis nula que estipula que el valor del coeficiente λ es igual a cero. En la especificación, el estadístico rechaza dicha hipótesis y encuentra que el valor es distinto a cero y es significativo. Por otro lado, se estudia el coeficiente ρ de la variable de rezago W y en la estructura del modelo de rezago espacial y encuentra que este valor también rechaza la hipótesis nula a un nivel significativo. Si bien ambos modelos resultan significativos, la versión robusta de estos modelos (RLM-Lag y RLM-Error), que incorporan efectos asintóticos, puede elucidar que modelo resulta más factible para los datos de Airbnb. De acuerdo con los resultados de la **tabla 3** se encontró que ambas pruebas dieron resultados significativos, sin embargo, el valor de la prueba para los errores resultó mayor. Esto no significa que se debería descartar el modelo de autocorrelación espacial en favor del modelo con errores espaciales, se computarán ambos modelos para evaluar los resultados que tienen los efectos de difusión entre vecinos y estructura de los errores sobre los precios de la plataforma.

Si bien se ajustó la variable dependiente para que la distribución de los errores en los modelos siguientes fuera normal, se rechazó la hipótesis nula de normalidad en el test de Jarque Bera.

Esto puede afectar los coeficientes de los modelos si se computa bajo un método de máxima verosimilitud. Este asume que la distribución del error sea normal para arrojar consistencia en los estimadores, y, en consecuencia, buenas inferencias estadísticas. Para computar un modelo con estimadores consistentes, se utilizará el método de momentos en dos etapas, el cual es robusto ante la violación del supuesto de normalidad en los errores. (Kelejian, Pruha 1999).

5. Resultados

Los resultados de los modelos de mínimos cuadrados ordinarios (OLS) así como sus versiones espaciales, autocorrelación espacial (SAR) y errores espaciales (SEM) están reportados en la tabla 3. Comparando el poder explicativo de los modelos a través de la R^2 ajustada, la incorporación de un modelo que incorpora una estructura de errores no aumenta el poder explicativo en contraste con la versión original. Lo contrario sucede con el modelo SAR, en este, el valor de la R^2 aumenta considerablemente en respecto al modelo tradicional.

Respecto a los coeficientes de las variables explicativas, la mayoría resultaron significativos salvo por la provisión de gimnasios, piscinas, estacionamientos, cancelación flexible y la regla de mascotas permitidas. En el caso de la distancia del metro, la variable resultó significativa en el modelo tradicional solamente.

Todas las variables en el modelo cuentan con los signos esperados salvo por dos variables, la distancia a la estación de metro más cercano y la identidad verificada de los anfitriones.

Considerando el efecto de derrama (o *spillover*), este estudio encontró que el efecto es positivo y significativo. En conjunto con las pruebas de autocorrelación espacial (I de Moran) y las pruebas de autocorrelación espacial en los errores del modelo (LM-Lag y LM-Error tests) se comprobó que las estrategias de precios de los anfitriones en Airbnb están fuertemente influenciadas por factores de ubicación dadas por los vecinos más cercanos.

Dado que los coeficientes de este modelo están especificados como una semi elasticidad, es necesario recalcar que los efectos de las variables numéricas se interpretan en términos porcentuales, mientras que, en el caso de las variables dicotómicas, la interpretación se hace respecto a la siguiente fórmula: $(e^\beta - 1)$

Tabla 3: Resultados

	OLS	p-value	SAR - KNN(35)	p-value	SEM - KNN(35)	p-value
Constante	5.5388	0.000	1.662	0.000	5.569	0.000
Tamaño						
Propiedad entera	0.7141	0.000	0.6680	0.000	0.6713	0.000
Número de recámaras	0.0555	0.002	0.0579	0.000	0.0518	0.000
Número de baños	0.1816	0.000	0.1493	0.000	0.1319	0.000
Número de huéspedes alojados	0.0550	0.000	0.0668	0.000	0.0669	0.000
Características listado						
Reservación inmediata	-0.0379	0.000	-0.0266	0.005	-0.0228	0.015
Antigüedad del listado	0.0023	0.000	0.0017	0.000	0.0017	0.000
Ubicación						
Distancia al punto de interés más cercano	-0.1128	0.000	-0.0241	0.000	-0.0835	0.000
Distancia a estación STC						
Metro más cercano	0.0259	0.000	-0.0054	0.1451	0.0087	0.489
Amenidades						
Estacionamiento	-0.0190	0.121	-0.0047	0.664	0.0027	0.799
Desayuno	0.0927	0.000	0.0805	0.000	0.0775	0.000
Gimnasio	-0.0240	0.222	-0.0279	0.113	0.0346	0.064
Piscina	0.0473	0.079	0.0345	0.167	0.0755	0.005
Bañera caliente	0.1654	0.000	0.1103	0.000	0.1011	0.000
Elevador	0.1330	0.000	0.0849	0.000	0.098	0.000
Reglas						
Cancelación flexible	-0.006	0.597	0.0062	0.5469	0.0093	0.5356
Mascotas permitidas	0.0031	0.835	-0.0035	0.785	0.0020	0.873
Fumar permitido	-0.068	0.000	-0.0387	0.000	-0.0384	0.000
Características anfitrión						
Superhost	0.0352	0.001	0.0391	0.000	0.0414	0.000
Anfitrión con más de un listado publicado	0.0833	0.000	0.0577	0.000	0.0524	0.000
Requisito verificación de identidad	-0.0161	0.154	-0.023	0.024	-0.025	0.011
Reputación						
Rating reseñas	0.0007	0.476	0.0009	0.1790	0.0009	0.202
Número de reseñas	-0.0007	0.000	-0.0009	0.000	-0.0009	0.000
Autocorrelación espacial (rho) y error espacial (lambda)						
Spillover espacial			0.5747	0.000		
Error espacial					0.812	0.000
Tests de autocorrelación espacial						
I de Moran (residuales)	74.71	0.000				
LM-Lag	3128.177	0.000				
LM-LAG (robusto)	440.730	0.000				
LM-Error	5376.012	0.000				
LM-Error(robusto)	2688.565	0.000				
R² (ajustada)	0.66		0.726		0.654	

Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)

Tamaño

Respecto a las variables de tamaño todas cuentan con el efecto esperado, de acuerdo con la revisión de la literatura. El efecto mayor se da en el tipo de propiedad y en el número de baños, con un aumento de 66% y 15% en los precios, respectivamente en el modelo espacial. En torno al número de habitaciones se espera un aumento de 6% en los precios conforme un listado cuente con más habitaciones.

Características de la publicación

Se esperaba que la característica de reservación instantánea tuviera efectos negativos en los precios, con un efecto de 3.7% en MCO y 2.2% en el modelo de errores espaciales, tal y como en estudios previos. Gibbs, Guttentag y Ulrike apuntan a que este comportamiento se debe a las estrategias de los anfitriones. Para mantener una tasa de ocupación alta, los dueños de los listados aplican precios bajos para atraer a la demanda de alojamiento, al mismo tiempo, facilitan el proceso de ocupación al permitir una reservación inmediata. Con esta estrategia garantizan mayores tasas de ocupación para departamentos vacíos y aseguran un mayor ingreso.

Asimismo, los consumidores valoran más aquellos listados más antiguos. Conforme el listado tenga más tiempo, más confianza se va a generar dentro de la plataforma, esto, en consecuencia, otorga a los anfitriones la oportunidad de cobrar un precio mayor por cerrar barreras de información.

Ubicación

Efectivamente, existe un efecto negativo entre la distancia hacia el punto de interés más cercano y los precios. Ante un cambio en la distancia, se espera una disminución del 11% para MCO y una disminución de 8% en el modelo de errores espaciales, de acuerdo con lo observado en otros estudios de índole similar (Chica-Olmo 2020).

Llama la atención el hecho de que el coeficiente de distancia hacia el metro más cercano resulte positivo, sin embargo, este no es significativo en el modelo de autocorrelación espacial. Esto puede obedecer a la distribución del sistema de transporte en la CDMX. A diferencia de estudio previos que solo incorporan la distancia a un centro de transportación, este modelo calcula la distancia hacia el punto más cercano. Debido a que el sistema está distribuido a lo largo de la Ciudad de México, varios de los listados publicados cuentan con una estación de metro cercana, independiente de los precios de los listados. Si bien el coeficiente es negativo e intuitivo en el modelo de rezago espacial, este sigue siendo no significativo

Amenidades

Todas las variables de amenidades resultaron no significativas para todos los modelos salvo la provisión de desayuno, bañera caliente y elevador, con un cambio en los precios de 9.7% para el modelo de MCO y 8% para los modelos espaciales, un cambio de 16% y 10% en los modelos espaciales y un cambio de 11.3% en MCO, 8.8% en rezago espacial y 10.3% en el de errores espaciales, respectivamente. La no significancia de la provisión de gimnasios y piscina pueden obedecer a dos factores. En primer lugar, la proporción de listados que ofrecen estos servicios es bastante bajo con solo el 6% dedicado a esta actividad. En el caso de las piscinas es entendible que no sea un determinante de los precios ya que la Ciudad de México no es un destino turístico cuyo clima favorezca la adopción de este servicio, por lo tanto, no tiene un valor fuerte en el mercado capitalino.

Reglas

Salvo por la admisión de fumar, todas las variables de reglas resultaron poco influyentes en los precios. En el modelo tradicional se calculó una caída de 6% con esta regla y 3.8% para los modelos espaciales. En este escenario, los consumidores anfitriones ofrecen un descuento implícito dado que esta regla puede ser no satisfactoria para algunos huéspedes. Por lo tanto, un precio más bajo con reglas más ligeras aseguraría el alojamiento de estas viviendas publicadas. La política para fumar, al ser excluyente, relaja la demanda de los consumidores, lo cual es un efecto esperado en conjunto con lo que se investigó en estudios previos. Dan Wang encontró un efecto negativo y lo asoció con una devaluación de la propiedad como producto de la empatía de los anfitriones hacia los huéspedes. Por lo tanto, la liberación de esta regla influye negativamente en los precios (Wang y Nicolau 2017).

Características anfitrión

Respecto a las características del anfitrión, todas las variables tuvieron el efecto positivo esperado salvo por la identidad verificada de los anfitriones. En contraste con datos de la literatura previa, en el contexto capitalino, la tasa de anfitriones con la identidad verificada es del 34%. Si bien esto es un indicio de calidad y señalización de confianza de los anfitriones, esto no es un factor que afecte positivamente los precios de los listados. En un contexto similar a aquellos anfitriones cuya política de cancelación es flexible, se trata de anfitriones relajados que no buscan ni entablan estrategias profesionales de precios. En particular, buscan un precio justo por el listado a cambio de un ingreso adicional.

En el caso de la categoría de los huéspedes, contar con más de un listado señala a los anfitriones con mayor compromiso y confianza, así como un comportamiento profesional con el cual, los anfitriones capitalizan.

Reputación

En término de reputación, también se encontraron signos esperados, no obstante, marginales. Por un lado, para la calificación de los listados, a pesar de que las calificaciones tengan un sesgo a valores altos (Cox 2020) aún indican una señal de calidad en la calificación de los listados con un aumento de 0.2% conforme la calificación aumente en un punto. Por otro lado, se encontró que el número de reseñas de los listados cuentan con un signo negativo. Si bien esto puede sonar contraintuitivo en un principio, la razón de esto se atribuye a una lógica similar en la incorporación de reservaciones inmediatas. Los anfitriones establecen precios bajos para aumentar sus tasas de ocupación, por lo tanto, al tener más huéspedes y visitantes, el listado contará con un mayor número de reseñas. Por lo tanto, se puede asociar esto como un factor negativo en los precios de los listados.

Efectos directos e indirectos

Si bien, los coeficientes de los modelos tradicional y de errores espaciales se pueden interpretar directamente de la tabla de resultados, este no es el caso para el modelo de autocorrelación espacial (SAR). Debido a los efectos de difusión entre los precios de los listados cercanos, se debe incorporar el efecto indirecto que existe ante un cambio en variables explicativas sobre los precios de los listados vecinos y cómo su cambio en precios derivado de esto afecta los precios finales del listado en particular.

Se puede apreciar en la **Tabla 4** que el efecto de derrama o difusión que existe en los efectos indirectos son bastante altos, de hecho, la magnitud de los efectos directos es solo una proporción de los efectos indirectos ocasionados por cambios en los precios de los vecinos más cercanos, lo cual es un indicador de la existencia de efectos de difusión. En comparación con el modelo tradicional, así como el modelo de errores espaciales, los efectos totales del modelo de autocorrelación espacial son, en efecto, superiores.

Tabla 4: Efectos directos, indirectos y totales (SAR)

Variable	Efecto directo	Efecto indirecto	Efecto total
Constante	1.685	2.224	3.910
Número de recámaras	0.059	0.077	0.136
Número de baños	0.151	0.200	0.351
Número de huéspedes alojados	0.062	0.081	0.143
Propiedad entera	0.677	0.894	1.571
Reservación inmediata	-0.027	-0.036	-0.063
Antigüedad	0.002	0.002	0.004
Distancia al punto de interés más cercano	-0.024	-0.032	-0.057
Distancia a estación STC Metro más cercano*	-0.005	-0.007	-0.013
Estacionamiento*	-0.005	-0.006	-0.011
Desayuno	0.082	0.108	0.189
Gimnasio*	-0.028	-0.037	-0.066
Piscina*	0.035	0.046	0.081
Bañera caliente	0.112	0.148	0.259
Elevador	0.086	0.114	0.200
Cancelación flexible*	0.006	0.008	0.014
Mascotas permitidas*	-0.004	-0.005	-0.008
Fumar permitido	-0.039	-0.052	-0.091
Superhost	0.040	0.052	0.092
Anfitrión con más de una propiedad publicada	0.059	0.077	0.136
Verificación de identidad	-0.023	-0.031	-0.054
Rating reseñas*	0.001	0.001	0.002
Número de reseñas	-0.001	-0.001	-0.002

* Valores no significativos (p-value > 0.05)

Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)

Implicaciones teóricas

Esta investigación formuló un modelo de precios hedónicos con el fin de entender la composición de los precios de Airbnb en la Ciudad de México utilizando una metodología de precios hedónicos. Si bien esta aproximación nos permite entender la valuación de los departamentos publicados en función de sus atributos, es necesario entender a fondo la estructura de precios de la plataforma. La lógica de asignación de precios en este nuevo contexto difiere significativamente de los análisis aplicados a firmas tradicionales. Entender el dinamismo de la plataforma es esencial para arrojar predicciones precisas sobre la asignación de precios.

Implicaciones prácticas

Este trabajo encontró que, efectivamente, las decisiones de precios de los anfitriones cercanos influyen en las decisiones individuales de los anfitriones en la Ciudad de México. Si bien, esta característica se cumple en otras ciudades vale la pena mencionar que este caso no se puede generalizar para todas las ciudades. Es posible que la asignación de precios no sea en función solamente de factores de distancia entre vecinos, sino que otros elementos adicionales como la presencia de grupos étnicos específicos, accesibilidad, facilidad de movimiento, índices de criminalidad, entre otros, impacten en la asignación de precios finales. Con más información sobre estas variables será posible entender en mayor grado la asignación.

Otro factor para considerar está relacionado con la adopción de la recomendación de precios por parte de la plataforma. No hay forma de conocer si un anfitrión aceptó la recomendación de precios, en ese caso, es necesario estudiar más a detalle cómo afecta en la generación de ingresos la no adopción de esta recomendación y qué tan efectiva es la recomendación de Airbnb versus una estrategia tradicional.

Finalmente, cabe resaltar que a pesar de que nuestra metodología espacial aumentara la capacidad predictiva de los precios, aún es necesario contar con más y mejor información respecto a la plataforma para poder generar mejores estimaciones. Detalles sobre las reseñas, a través de análisis de texto, o el número de búsquedas, mensajes o llamadas recibidas podrían estimar los precios y la ocupación de esta plataforma.

6. Conclusión

En suma, este trabajo tuvo como objetivo, encontrar los determinantes de los precios de los departamentos enlistados en Airbnb en la Ciudad de México con base en atributos internos del listado, del anfitrión, efectos de reputación, así como de ubicación. el tamaño del efecto y si existe alguna clase de dependencia espacial entre los listados. Gracias a pruebas estadísticas de Moran, y modelos de autocorrelación y errores espaciales se encontró que los factores internos y de reputación, así como las características del anfitrión y la ubicación son elementales para las decisiones de precios de Airbnb. Asimismo, se comprobó que efectivamente existe un efecto de *spillover* entre los precios y las características de los listados vecinos, lo cual es un factor que tanto los anfitriones como la plataforma deben tomar en cuenta al momento de fijar precios. Esta actividad es de suma importancia ya que determina la supervivencia de una plataforma, establece las formas de interactuar entre los agentes que la conforman y permite a gobiernos locales estimar que factores determinan los precios en las ciudades.

7. Bibliografía

- Airbnb. 2020. "About Us". *Airbnb Newsroom*. Consultado el 5 de julio de 2020. <https://news.airbnb.com/about-us/>.
- Anselin, Luc. 1988. "Lagrange multiplier test diagnostics for spatial dependence and spatial heterogeneity". *Geographical analysis* 20 (1): 1-17.
- Anselin, Luc. 2017. "Spatial Regression 10. Specification Tests (2)". Presentación de PowerPoint, Slides for Spatial Regression Analysis (Spring 2017), The University of Chicago. https://spatial.uchicago.edu/sites/spatial.uchicago.edu/files/10_specification_tests_2_slides.pdf.
- Anselin, Luc. 2017. "Spatial Regression 11. Spatial Two Stage Least Squares". Presentación de PowerPoint, Slides for Spatial Regression Analysis (Spring 2017), The University of Chicago. https://spatial.uchicago.edu/sites/spatial.uchicago.edu/files/11_spatial2sls_slides.pdf.
- Anselin, Luc y Nancy Lozano-Gracia. 2009. "Spatial hedonic models". En *Palgrave handbook of econometric*, 1213-1250. London: Palgrave Macmillan.
- Anselin, Luc, Pedro V. Amaral y Daniel Arribas-Bel. 2012. "Technical Aspects of Implementing GMM Estimation of the Spatial Error Model in PySAL and GeoDaSpace". GeoDa Center for Geospatial Analysis and Computation.
- Aznar, Pedro, Josep Maria Sayeras, Guillem Segarra y Jorge Claveria. 2018. "Airbnb Competition and Hotels' Response: The Importance of Online Reputation". *Athens Journal of Tourism* 5 (1): 7-20.
- Barron, Kyle, Edward Kung y Davide Proserpio. 2020. "The effect of home-sharing on house prices and rents: Evidence from Airbnb". *Marketing Science* 40(1): 23-47.
- Blal, Inès, Manisha Singal y Jonathan Templin. 2018. "Airbnb's effect on hotel sales growth". *International Journal of Hospitality Management* 73, 85-92.
- Budget and Legislative Analyst's Office. 2015. *Policy Analysis Report*. City of San Francisco, Board of Supervisors.
- Chen, Yong, Karen Xie. 2017. "Consumer valuation of Airbnb listings: a hedonic pricing approach". *International Journal of Contemporary Hospitality Management* 29, 2405-2424.

- Chica-Olmo, Jorge, Juan Gabriel González-Morales y José Luis Zafra-Gómez. 2020. “Effects of location on Airbnb apartment pricing in Málaga”. *Tourism Management* 77.
- Cliff, A.D. y J. K. Ord. 1969. “The problem of Spatial autocorrelation”. *London Papers in Regional Science I, Studies in Regional Science*, 25–55.
- Darmofal, David. 2015. “Spatial Lag and Spatial Error Models”. En *Spatial Analysis for the Social Sciences*, 96–118. Cambridge University Press.
- DATATUR. 2020. “Compendio estadístico del turismo en México 2019”, Secretaría de Turismo. Consultado el 7 de junio de 2021. <https://www.datatur.sectur.gob.mx/SitePages/CompendioEstadistico.aspx>.
- Deloitte. s.f. “Regulación del alojamiento compartido, un servicio de hospedaje en la CDMX | D.Noticias”. Consultado el 6 de abril de 2021. <https://www2.deloitte.com/mx/es/pages/dnoticias/articles/airbnb-paga-impuestos-cdmx.html>.
- Dogru, Tarik y Osman Pekin. 2017. “What do guests’ value most in Airbnb accommodations? An application of the hedonic pricing approach.” *Boston Hospitality Review* 5, 1-13. <http://www.bu.edu/bhr/2017/06/07/airbnb-guest-pricing-value/>.
- Eugenio-Martin, Juan L, José M Cazorla-Artiles y Christian González-Martel. 2019. “On the Determinants of Airbnb Location and Its Spatial Distribution.” *Tourism Economics* 25 (8): 1224–44.
- Evans, David S. 2003. “Some Empirical Aspects of Multi-Sided Platform Industries”. *Review of Network Economics (RNE)* 2 (3).
- Evans, David S. 2013. “The Consensus Among Economists on Multisided Platforms and its Implications for Excluding Evidence that Ignores It”. *SSRN*, 2249817.
- Ferrando, Jorge Luis Casanova. 2019. *The Airbnb Effect on the Rental Market: The Case of Madrid, Studies on the Spanish Economy*. FEDEA. <https://documentos.fedea.net/pubs/eee/eee2019-34.pdf>.
- Gibbs, Chris, Daniel Guttentag, Gretzel Ulrike, Jym Morton y Alasdair Goodwill. 2018. “Pricing in the sharing economy: a hedonic pricing model applied to Airbnb listings”. *Journal of Travel & Tourism Marketing*, 1-11.
- Golgher, André Braz y Paul. R. Voss. 2016. “How to Interpret the Coefficients of Spatial Models: Spillovers, Direct and Indirect Effects”. *Spat Demography* 4, 175–205.

- Goree, Katherine. 2016. "Battle of the Beds: The Economic Impact of Airbnb on the Hotel Industry in Chicago and San Francisco". *Scripps Senior Theses*.
- Gunter, Ulrich, Irem Önder y Bozana Zekan. 2020. "Modeling Airbnb demand to New York City while employing spatial panel data at the listing level". *Tourism Management* 77, 104000.
- Gunter, Ulrich e Irem Önder. 2018 "Determinants of Airbnb Demand in Vienna and Their Implications for the Traditional Accommodation Industry." *Tourism Economics* 24 (3): 270–93.
- Haywood, Jessica, Patrick Mayock, Jan Freitag, Kwabena Akufoo Owoo, Blasé Fiorilla. 2016. "Airbnb & Hotel Performance". Smith Travel Research.
- Hernández Armenta, Mauricio. 2020. "Airbnb detalla su 'nueva normalidad' en impuestos y reactivación del turismo en México." *Forbes México*, 15 de junio de 2020. <https://www.forbes.com.mx/tecnologia-airbnb-nueva-normalidad-impuestos-turismo/>.
- Hong, Insu y Changsok Yoo. 2020. "Analyzing Spatial Variance of Airbnb Pricing Determinants Using Multiscale GWR Approach". *Sustainability* 12 (11): 4710.
- Horn, Keren, Mark Merante. 2017 "Is home sharing driving up rents? Evidence from Airbnb in Boston". *Journal of Housing Economics* 38, 14-24.
- IMCO. 2016. *Airbnb in Mexico City: Closing the Income Gap and Expanding the Economic Benefit of Tourism: Mexico City Case Study*. IMCO. https://imco.org.mx/wp-content/uploads/2018/02/DocumentoAIRBNBIngles_26-02-18.pdf.
- Kelejian, Harry y Dennis Robinson. 1992. "Spatial autocorrelation: A new computationally simple test with an application to per capita county police expenditures". *Regional Science and Urban Economics* 22 (3): 317-331.
- Kelejian, Harry e Ingmar Prucha. 1999. "A generalized moments estimator for the autoregressive parameter in a spatial model". *International economic review* 40 (2): 509-533.
- Kelejian, Harry e Ingmar Prucha. 2010. "Specification and estimation of spatial autoregressive models with autoregressive and heteroskedastic disturbances". *Journal of econometrics* 157 (1): 53-67.

- Lagonigro, Raymondo, Joan Carles Martori y Philippe Apparicio. 2020. "Understanding Airbnb spatial distribution in a southern European city: The case of Barcelona". *Applied Geography* 115, 102136.
- LeSage, James y Robert Kelley Pace. 2009. *Introduction to spatial econometrics*. Chapman and Hall/CRC.
- Li, Hui y Kannan Srinivasan. 2019. "Competitive dynamics in the sharing economy: An analysis in the context of Airbnb and hotels". *Marketing Science* 38 (3): 365-391.
- Liu, Xufeng y Hongmin Chen. 2020. "Sharing economy: promote its potential to sustainability by regulation". *Sustainability* 12 (3): 919.
- Meng, Qingmin, Chris J. Cieszewski, Mike R. Strub y Bruce E. Borders. 2009. "Spatial regression modeling of tree height–diameter relationships". *Canadian journal of forest research* 39 (12): 2283-2293.
- Miller, Harvey J. 2004. "Tobler's first law and spatial analysis". *Annals of the Association of American Geographers* 94 (2): 284-289.
- Nieuwland, Shirley y Rianne Van Melik. 2020. "Regulating Airbnb: how cities deal with perceived negative externalities of short-term rentals". *Current Issues in Tourism* 23 (7): 811-825.
- Nikolić, Domagoj, Filip Čavar. 2020. "Hedonic Price Attributes of Airbnb Listings in Split". Management, Knowledge and Learning International Conference 2020. <http://www.toknowpress.net/ISBN/978-961-6914-26-0/113.pdf>.
- Organización para la Cooperación y Desarrollo Económicos. 2018. "Rethinking Antitrust Tools for Multi-Sided Platforms". www.oecd.org/competition/rethinking-antitrust-tools-for-multi-sided-platforms.htm.
- Organización Mundial de Turismo. 2019. *Panorama del turismo internacional: edición 2019*. Madrid: UNWTO. <https://www.e-unwto.org/doi/pdf/10.18111/9789284421237>.
- Perez-Sanchez, V. Raúl, Leticia Serrano-Estrada, Pablo Marti y Raúl Tomas Mora-Garcia. 2018. "The what, where, and why of Airbnb price determinants". *Sustainability* 10 (12), 4596.
- Ramírez de la Cruz, Edgar, Manlio Felipe Castillo Salas, José Antonio Sánchez Cetina, David Pavel Gómez Granados. 2018. *Formulación de modelos de precios hedónicos para la vivienda en la Ciudad de México*. Consejo Económico y Social de la Ciudad de México.

- Rey, Sergio J. y Luc Anselin. 2010. PySAL: A Python library of spatial analytical methods. In *Handbook of applied spatial analysis*, 175-193. Berlin, Heidelberg: Springer.
- Rochet, Jean-Charles, Jean Tirole. 2004 “Two-Sided Markets: An Overview”. En *14.271 Industrial Organization I*. Massachusetts Institute of Technology.
- Rosen, Sherwin. 1974. “Hedonic prices and implicit markets: product differentiation in pure competition”. *Journal of political economy* 82 (1): 34-55.
- Sheppard, Stephen y Andrew Udell. 2016. “Do Airbnb properties affect house prices”. *Williams College Department of Economics Working Papers* 3 (1): 43.
- Smith, Tony. 2020. “III. Aerial Data analysis: 2. Modeling the Spatial Structure of Areal Units”. En *Spatial Data Analysis*.
- Sperling, G. 2015. *How Airbnb combats middle class income stagnation: Airbnb*. https://www.stgeorgeutah.com/wp-content/uploads/2015/07/MiddleClassReport-MT-061915_r1.pdf.
- Suárez-Vega, Rafael y Juan M. Hernández. 2020. “Selecting prices determinants and including spatial effects in peer-to-peer accommodation”. *ISPRS International Journal of Geo-Information* 9 (4): 259.
- Wang, Dan y Juan Luis Nicolau. 2017. “Price determinants of sharing economy-based accommodation rental: A study of listings from 33 cities on Airbnb.com”. *International Journal of Hospitality Management* 62, 120-131.
- Wolf, L. J. 2019. *Learn About Spatial Lag of X (SLX) Models in Python Using Airbnb Data in Dublin (2018)*. SAGE Publications, Limited.
- World Economic Forum. 2019. “Does the Sharing Economy Truly Know How to Share?”. <https://www.weforum.org/agenda/2019/01/does-the-sharing-economy-truly-know-how-to-share/>.
- Xu, Feifei, Mingxing Hu, Liqing La, Jialin Wang, Chao Huang. 2020. “The influence of neighbourhood environment on Airbnb: a geographically weighed regression analysis”. *Tourism Geographies* 22 (1): 192-209.
- Ye, Peng, Julian Qian, Jieying Chen, Chen-hung Wu, Yiton Zhou, Spencer De Mars... Li Zhang. 2018. “Customized regression model for Airbnb dynamic pricing”. In *Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining*, 932-940.


- Zervas, Georgios, Davide Proserpio y John W. Byers. 2017. "The rise of the sharing economy: Estimating the impact of Airbnb on the hotel industry". *Journal of marketing research* 54 (5): 687-705.
- Zhang, Honglei, Jie Zhang, Shaojing Lu y Shaowen Cheng. 2011. "Modeling hotel room price with geographically weighted regression". *International Journal of Hospitality Management* 30 (4): 1036-1043.
- Zhang, Zhihua, Rachel J. Chen, Lee D. Hang y Lu Yang. 2017. "Key factors affecting the price of Airbnb listings: A geographically weighted approach". *Sustainability* 9 (9): 1635.

Base de datos (pública)

- Cox, Murray. 2020. *Get the data*. Inside Airbnb. Consultado el 22 de junio de 2020. <http://insideairbnb.com/get-the-data.html>.


8. Anexos

Gráfico 3. Mapa de calor de variables explicativas (correlación)




Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)

Gráfico 4. Dispersión de residuales y valores estimados



Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)

Gráfico 5. Distribución de precios publicados en Airbnb en CDMX



Fuente: Elaboración propia con datos de Inside Airbnb (Cox 2020)