



# EL COLEGIO DE MÉXICO

## CENTRO DE ESTUDIOS ECONÓMICOS

### **MAESTRÍA EN ECONOMÍA**

TRABAJO DE INVESTIGACIÓN PARA OBTENER EL GRADO DE  
MAESTRA EN ECONOMÍA

### **IMPACTO DE LA PANDEMIA EN EL MERCADO INMOBILIARIO DE LA CIUDAD DE MÉXICO**

**ANGIE FAEL PÉREZ PEÑA**

**PROMOCIÓN 2020-2022**

**ASESOR:**

**DR. EDWIN VAN GAMEREN**

AGOSTO 2022



# Resumen

Como bien es sabido, el mercado inmobiliario es una fuente importante de empleo y de riqueza de las familias, pese a esto, el comportamiento de los patrones espaciales y los cambios en el precio de vivienda en periodos de crisis sanitarias no es un tema ampliamente estudiado. El presente trabajo estudia el comportamiento del mercado inmobiliario en la Ciudad de México durante el periodo 2016-2021 que abarca el inicio de la crisis pandémica de Covid-19, para ello, se propone un modelo econométrico no lineal de efectos fijos con temporalidad mensual que incluye variables dummy de tiempo y características relevantes a nivel alcaldía. Se encuentra que la pandemia tuvo efectos diferenciados a lo largo de la distribución de los precios afectando principalmente a los deciles inferiores y que los precios mensuales de vivienda se redujeron en 4.5% en el año 2021.

**Palabras clave:** Mercado inmobiliario, densidad poblacional, índice de marginación, avales, efectos fijos, pandemia, Covid-19.



# Índice general

Resumen . . . . .	I
<b>1. Introducción</b>	<b>1</b>
<b>2. Revisión de Literatura</b>	<b>3</b>
<b>3. Datos y Estrategia Empírica</b>	<b>9</b>
3.1. Fuentes de datos . . . . .	9
3.2. Modelo de efectos fijos . . . . .	10
3.3. Análisis descriptivo . . . . .	11
<b>4. Resultados</b>	<b>17</b>
<b>5. Outliers y efectos por deciles</b>	<b>21</b>
<b>6. Conclusiones</b>	<b>25</b>
<b>A. Modelos econométricos</b>	<b>27</b>
A.1. Métodos para datos panel . . . . .	27
A.2. Regresión cuantil . . . . .	30
<b>Bibliografía</b>	<b>33</b>
<b>Índice de tablas</b>	<b>35</b>
<b>Índice de figuras</b>	<b>37</b>



# Capítulo 1

## Introducción

La pandemia ha tenido fuertes efectos socioeconómicos en todo el mundo, cambiando la forma de vida de la población, las condiciones de trabajo y afectando de manera desigual los sectores de la economía, por tanto, hay un creciente interés en la investigación de sus consecuencias; sin embargo, dado que las emergencias sanitarias no pueden ser controladas y son impredecibles, su análisis es complejo. La presencia de Covid-19 está provocando la inactividad involuntaria de muchos sectores productivos y una nueva propensión de las familias que probablemente darán prioridad al ahorro, esto, aunado a la drástica reducción del consumo, la disminución del ingreso per cápita de los trabajadores y el incremento en el desempleo. Por otro lado, aunque es claro que el desarrollo económico está ampliamente relacionado con el comportamiento de los mercados y específicamente con el mercado inmobiliario, los efectos de la pandemia y de emergencias de salud en el mercado inmobiliario han sido poco explorados en la literatura. Varios investigadores a nivel internacional han intentado abordar esta relación en países como Estados Unidos, China, Italia y Australia utilizando diferentes métodos de estimación.

De acuerdo con la literatura internacional el impacto de las emergencias sanitarias en el mercado de vivienda depende de la densidad poblacional, las medidas implementadas por las autoridades sanitarias, los cambios en variables económicas como consumo y empleo, entre otras.

En México, no se han desarrollado estudios previos que reflejen el comportamiento de este mercado a partir de un enfoque causal que utilice técnicas econométricas. El propósito de este trabajo es estudiar el impacto de la pandemia en el mercado inmobiliario utilizando avalúos individuales de 15 alcaldías de la Ciudad de México en el periodo 2016-2021.

El trabajo está organizado como sigue: la siguiente sección menciona trabajos relevantes

---

y mecanismos de transmisión; el capítulo 3 describe los datos y los modelos a utilizar; el capítulo 4 especifica los resultados empíricos; el capítulo 5 presenta pruebas de robustez y finalmente, el capítulo 6 presenta la conclusiones.

# Capítulo 2

## Revisión de Literatura

En esta sección se hace referencia a los mecanismos de transmisión de las pandemias en el mercado inmobiliario y se citan algunos de los estudios realizados para diferentes países alrededor del mundo, con el objetivo de entender las estrategias empíricas utilizadas. Además, se presenta una breve descripción del mercado inmobiliario mexicano.

### **Mecanismos de transmisión e implicaciones**

Siguiendo a Francke & Korevaar (2021) existen cuatro mecanismos importantes de la respuesta de los mercados de vivienda urbana a una pandemia: El primero es el más directo e inmediato, ocurre a través del aumento en la mortalidad y la turbulencia económica y social que dan como resultado reducciones en los precios de alquiler y de vivienda inmediatamente después de un brote. El impacto del choque demográfico depende de la elasticidad de los precios de vivienda respecto a la población, esto es, de la caída en la demanda de vivienda debido al incremento en la mortalidad. Las reducciones en la actividad económica puede contribuir incluso a una mayor disminución de la demanda de vivienda. Las reducciones en la demanda de vivienda también podrían haber sido fortalecidas por la emigración, especialmente de personas adineradas. No obstante, Alfani & Percoco (2019) en su estudio de los efectos de la peste en las tendencias económicas italianas, encuentra que aunque hay grandes pérdidas en las poblaciones urbanas, las grandes epidemias y sus correspondientes choques demográficos, no parecen afectar la trayectorias de crecimiento a largo plazo de las grandes ciudades, aunque, dichos efectos podrían ser diferentes en ciudades menos desarrolladas, o en áreas rurales. El segundo, hace referencia a la existencia de un aumento temporal de la percepción al riesgo o la aversión al riesgo y las primas de riesgo correspondientes por parte de los inversionistas ocasionado por su pesimismo acerca del futuro que conduce a una caída comparativamente grande a corto plazo de la demanda de inversión de vivienda que es mayor

---

que la demanda de servicios de vivienda medida por los precios de alquiler especialmente en las áreas afectadas. Este mecanismo, se confirma en el trabajo de psicología de Viscusi (1990) que proporciona una encuesta de la percepción al riesgo e ilustra que al estar sesgada hacia arriba provoca un aumento más pronunciado en la compensación. En tercer lugar, los efectos de los precios y los alquileres de vivienda en el largo plazo no son importantes debido a la resiliencia de las ciudades ante grandes impactos. Los trabajos que respaldan esta hipótesis son en general, los realizados para estudiar el impacto en la actividad económica de bombardeos, guerras o incendios tales como el de Davis & Weinstein (2002) o Hornbeck & Keniston (2017). Por último, Francke & Korevaar (2021), destacan el papel de la política urbana ante grandes perturbaciones, por ejemplo, introducir calles más anchas, limpiar las viviendas en barrios marginales y permitir el acceso a agua potable podría contribuir a mejorar las valoraciones de las propiedades nuevas y antiguas. Además, la expansión del suministro de viviendas limita el crecimiento de precio a largo plazo y refuerza la migración a las ciudades.

### **Evidencia de emergencias sanitarias anteriores**

El primer estudio que estima el impacto de las emergencias sanitarias en el mercado de vivienda es el de Wong (2008) quien utilizó un conjunto de datos panel de 44 complejos de vivienda a gran escala en Hong Kong-China con el fin comparar la variación de los cambios en el volumen y precios de transacciones finales de vivienda resultado del brote del Síndrome Respiratorio Agudo Grave (SARS) en el año 2003. El riesgo de SARS fue medido por el nivel de tasa de infección, las noticias relacionadas y los anuncios gubernamentales de las infecciones; para el precio, se utilizaron datos de los precios promedios semanales hedónicos ajustados para cada uno de los complejos de vivienda. Los datos abarcan 64 semanas, 25 antes del comienzo la epidemia y 25 después del final. En el modelo también se incluyen variables de control adicionales para cada complejo que podrían estar relacionadas con la propagación del SARS tales como: la población, el número total de departamentos, el número de pisos, el número de departamentos por piso y el tiempo de viaje al centro de la ciudad.

Entre los resultados se encontró que el precio promedio de la vivienda se redujo en 1.6 % en todas las viviendas aunque hubo una caída adicional de menos del 3 % para aquellas en las que se sabía públicamente que habían tenido casos de SARS o donde los casos fueron mencionados en los periódicos. El autor concluyó que no hubo evidencia de una reacción exagerada en los precios de vivienda dadas las características inminentes del mercado inmobiliario.

Otro estudio histórico importante acerca de cómo afectan las pandemias a los mercados inmobiliarios urbanos es el de Francke & Korevaar (2021) que estudia brotes históricos de peste en Amsterdam durante el siglo XVI y XVII y de cólera en Paris en 1832 y 1849, ambos

---

países tenían mercados inmobiliarios altamente desarrollados, y datos a nivel micro de las transacciones de vivienda. Para París, observan la variación dentro de la ciudad a nivel barrio en la exposición al cólera. Para Amsterdam el lapso de tiempo es más largo y contiene un gran número de brotes de peste (diez brotes, siglos XVI-XVII). Utilizan datos de mortalidad y del precio de venta y alquiler de registros administrativos y estiman un modelo modificado de ventas repetidas en ambos países. Muestran que los brotes dan como resultado grandes caídas en el precio de vivienda durante los primeros seis meses principalmente en las áreas más afectadas y menores caídas en los precios de alquiler. Los choques fueron transitorios ya que el precio de vivienda de ambas ciudades volvió rápidamente a su nivel inicial.

### **Evidencia de la pandemia Covid-19**

Respecto a los estudios del mercado inmobiliario de China en el marco del Covid-19, Qian et al. (2021) y Chong & Liu (2020) estudiaron los cambios en los precios promedio mensuales de vivienda en 2019-2020 y encontraron que se redujeron significativamente.

Qian et al. (2021) utilizaron el método de diferencias en diferencias con datos de comunidades residenciales con casos confirmados y como grupo de control, seleccionaron las comunidades más cercanas que no presentaron casos. El modelo utiliza efectos fijos por comunidad, efectos fijos mensuales e incluye una variable dummy que equivale a 1 en los meses después de que la comunidad tuvo casos confirmados de Covid-19 y cero en otro caso, también controla por un conjunto de características a nivel comunidad y nivel ciudad incluida la densidad poblacional, ingreso per cápita, monto de inversión en el sector inmobiliario, tipo de edificio, calidad de la educación, proporción de la superficie construida, la proporción de zonas verdes, la antigüedad de la vivienda, los servicios y derechos de propiedad y el tipo de construcción. Sus resultados de estimación sugieren que el precio promedio mensual de vivienda de una comunidad con casos confirmados se redujo en 2.47% de octubre de 2019 a abril de 2020. Este impacto puede persistir tres meses pero su magnitud es mayor a medida que pasa el tiempo y, solo existe en las regiones con mayor nivel de infección de Covid-19 o peores condiciones médicas.

Por su parte, Chong & Liu (2020) utilizaron un modelo de efectos fijos de dos vías para investigar la relación no lineal entre el número de muertes por Covid-19 y el cambio porcentual del precio promedio de vivienda de 92 ciudades, divididas en tres grupos de acuerdo con el *Ranking of Cities Business Attractiveness*, para ello, utilizaron datos de panel mensuales de diciembre de 2019 a mayo de 2020. Las variables de control para estimar el cambio en el precio son: el producto regional bruto anual y el porcentaje de la industria terciaria, el número de camas de hospitales, el número de instituciones regulares de educación superior, el volumen de bienes importados y la población de las ciudades. Las variables relacionadas

---

con la pandemia son el número de casos confirmados y el número de muertes por Covid-19 en cada ciudad, estas se incluyeron separadamente dada su estrecha correlación (0.833). El modelo incluye una variable dummy para cada mes con el fin de tener en cuenta los efectos específicos individuales y reducir el sesgo de variable omitida. Adicionalmente, se divide la muestra en tres periodos: periodo pre-covid, corresponde a los meses antes de 2020; periodo de covid, que son los meses de enero a marzo de 2020 con la ola más severa de la pandemia y, periodo post-covid,<sup>1</sup> correspondiente a los meses de abril y mayo de 2020 caracterizados por tener menos casos y ser más estables. Los autores encuentran que para la muestra completa la relación existente entre las variables de estudio tiene “forma de U,” esto es, los precios varían menos cuando hay pocas muertes mensuales por Covid-19 y la relación se invierte si las muertes aumentan. El efecto del número de confirmados en el precio es similar. Además, muestran que los mercados de vivienda en las ciudades de primer nivel (ciudades comparativamente más desarrolladas) fueron más sensibles a la pandemia lo cual indica que los efectos difieren entre los grupos.

En Europa y Oceanía se han realizado estudios de Italia y Australia. En Campania-Italia, Del Giudice et al. (2020) desarrollaron un modelo de regresión múltiple de precios inmobiliarios medido a nivel regional y provincial que varía semestralmente en un panel de 15 años y sirve para evaluar los efectos del Covid-19 a corto y mediano plazo. Los resultados muestran una reducción de los precios de la vivienda del 4.16 % en el corto plazo y del 6.49 % en el mediano plazo. En Australia, Hu et al. (2021) utilizan un índice hedónico de precios de vivienda para cinco capitales de los principales estados y encuentran que las medidas relacionadas con el confinamiento no tienen efecto significativo en los rendimientos diarios de la vivienda, además encuentran que la prevalencia del virus tiene un impacto negativo en el mercado inmobiliario pues el rendimiento anual de la vivienda cae 1.26 puntos porcentuales por cada duplicación de casos confirmados.

Para Estados Unidos, Li & Zhang (2021) exploraron los patrones espaciales y la distribución heterogénea de las tasas de cambio de los precios de vivienda en 2,856 condados del país durante la pandemia, encontraron que aunque los precios de vivienda tuvieron una tendencia al alza, en muchas ciudades hubo una caída temporal de 5 % en la primera parte de la crisis (abril o mayo de 2020), explicada por la reconsideración de los planes de venta y compra de vivienda pues muchos vendedores retiraron sus casas de las listas de oferta para evitar el riesgo de contraer la enfermedad y, los compradores dejaron de visitar viviendas por las órdenes de quedarse en casa. Los precios se recuperaron rápidamente y tuvieron un fuerte aumento en el período posterior en respuesta al cambio en las expectativas de la población, las

---

<sup>1</sup>China continua con estrictas medidas de confinamiento debido al rebrote de casos positivos por la variante Ómicron y su política de “cero covid.”

---

políticas comerciales de reapertura y el crecimiento económico. En cuanto a la distribución espacial, los cambios principalmente en la demanda provocaron que los precios de vivienda en los centros urbanos tuvieron precios más bajos o ningún aumento significativo, mientras que las casas alrededor de las ciudades tenían normalmente precios aumentados incluso en 29%. Estos resultados son consistentes con el trabajo de Liu & Su (2021) que muestra que hubo un cambio espacial en la demanda de vivienda en Estados Unidos resultado de la reducción de la necesidad de vivir cerca del lugar de trabajo, de lugares densamente poblados o de barrios en el centro de la ciudad, en consecuencia las ciudades y los vecindarios con valores de vivienda más altos antes de Covid-19 presenciaron una mayor disminución de su precio.

Otro estudio realizado para Estados Unidos es el de D'Lima et al. (2022), este es novedoso pues da un enfoque diferente al análisis del mercado inmobiliario en el periodo de pandemia proporcionando evidencia de los efectos en la fijación de precios en el mercado inmobiliario debido a la orden de cierre del gobierno para reducir la propagación del Covid-19. Para su desarrollo, utilizan datos a micro nivel sobre más de dos millones de transacciones de propiedades residenciales de la mayoría de estados de Estados Unidos y el Distrito de Columbia entre junio de 2019 y diciembre de 2020. Encuentran que los precios se reducen más si en el vecindario una alta proporción de la población cuenta con estudios universitarios y aumentan en vecindarios que están compuestos en su mayoría por personas que se identifican como negras o afroamericanas; la variación de los precios también difiere por la densidad poblacional y estructural ya que el precio promedio cayó más en lugares densamente poblados que están por ejemplo cerca de los subcentros de empleo o del centro de la ciudad y el valor promedio de las propiedades con baja densidad estructural aumentó. Por todo esto, los autores concluyen que los cierres colectivos dieron lugar a un cambio en las preferencias y el comportamiento del consumidor debido a que la disposición a pagar por vivir cerca al lugar de trabajo o tener espacios más amplios se modificó.

### **Evidencia para México**

Según Sobrino (2014), el precio de vivienda de la Ciudad de México está determinado por una combinación de las características físicas de la vivienda, las externalidades del vecindario que incluye el acceso al agua y la calidad de escuelas primarias y, la accesibilidad medida por la distancia lineal al hospital más cercano y al Zócalo de la Ciudad. También muestra que la calidad relacionada con el equipamiento de vivienda como cocina o baños, es más importante que el tamaño de la vivienda en la determinación del precio.

En cuanto a los estudios realizados para el mercado inmobiliario mexicano en un contexto de pandemia, las investigaciones son pocas y los análisis son en general de carácter descrip-

---

tivo. Molina-Torres et al. (2021) realizaron un análisis comparativo del desarrollo urbano, nivel económico y número de casos activos en la Ciudad de México. Para ello, construyeron un índice de comparabilidad (IC) calculado como la multiplicación del promedio ponderado de tres variables: densidad poblacional, índice de ingreso per cápita e índice de ocupación de vivienda, por el número de casos de Covid-19 de cada municipio. La contribución de cada variable se asume uniforme. Los resultados son consistentes con trabajos realizados para otros países ya que muestran que los municipios con mayor densidad poblacional, bajo ingreso per cápita y alto índice de ocupación tenían un IC alto, y por tanto una alta tasa de infecciones.

# Capítulo 3

## Datos y Estrategia Empírica

### 3.1. Fuentes de datos

La fuente principal de datos sobre los precios del mercado inmobiliario son los avalúos individuales solicitados de manera particular a la Sociedad Hipotecaria Federal (SHF)<sup>1</sup>, que es un Banco de Desarrollo de segundo piso cuyo objetivo es impulsar los mercados primario y secundario de crédito a la vivienda. Los avalúos individuales están a precios constantes y no tienen en cuenta las características específicas de la vivienda tales como el tipo de inmueble, el estado de conservación o si es nueva/usada por lo que su valor podría diferir de los precios reales del mercado.

Los datos del número total de casos confirmados de Covid-19 y el número total de defunciones se obtuvieron de las cifras diarias publicadas por la Secretaria de Salud del Gobierno de México<sup>2</sup>, las cifras reportadas son el conjunto de casos que tienen resultado de muestra positivo o que se clasifiquen positivos por asociación epidemiológica o por dictaminación para defunciones en cada alcaldía.

Las cifras de la población y el índice de marginación de cada alcaldía se obtuvieron de los datos publicados por el Consejo Nacional de Población (CONAPO)<sup>3</sup>, para los datos de la población se utilizaron las proyecciones poblacionales de los municipios publicadas en el año 2019 que son útiles para calcular la densidad poblacional de cada alcaldía; los datos del índice de marginación, corresponden a los años 2015 y 2020. El índice de marginación es una medida continua basada en datos censales que puede tomar valores positivos o negativos, el

---

<sup>1</sup><https://www.gob.mx/shf>

<sup>2</sup><https://coronavirus.gob.mx/>

<sup>3</sup><https://www.gob.mx/conapo>

valor más elevado y el más bajo representan las situaciones de mayor y menor marginación, respectivamente; pero el cero no necesariamente indica marginación media. El índice aumenta de valor en cuanto sea mayor el porcentaje de la población que vive en localidades pequeñas, con ingresos monetarios reducidos, en viviendas inadecuadas y con falta de acceso a la educación, por tanto, es utilizado para identificar unidades territoriales con mayores carencias estructurales y para poder focalizar la política social.

Los datos se prepararon de tal forma que pudieran ser usados en modelos de efectos fijos con una dimensión temporal mensual, no siguen una estructura de datos panel dado que los avalúos individuales son diferentes en cada alcaldía mes a mes. Se estudian 15 de las 16 alcaldías de la Ciudad de México, la alcaldía faltante, Milpa Alta, no se incluye por falta de datos en la mayoría del periodo, aún así, se espera que los resultados no presenten sesgos importantes dado que es la alcaldía menos poblada.

Cabe mencionar que aunque las variables se incluyeron a partir de los estudios realizados en otros países, estas pueden omitir características tanto de las viviendas como de las alcaldías, que podrían ser importantes en la construcción del modelo.

## 3.2. Modelo de efectos fijos

El primer modelo para medir el impacto de la pandemia en el mercado inmobiliario de la Ciudad de México es un modelo de efectos fijos por alcaldía que utiliza el método de transformaciones intragrupalas (Ver en Apéndice). En este caso, la estructura de los datos corresponde a un modelo de datos panel.

$$\log(P_{it}) = \alpha_1 T1_t + \alpha_2 T2_t + \beta_1 Conf_{it} + \beta_2 Dens_{it} + \beta_3 IMM_{it} + \epsilon_{it}$$

El segundo modelo es utilizado para aprovechar la variabilidad de los avalúos individuales dentro de cada alcaldía, ampliar la muestra y obtener una mejor estimación. Al igual que en el caso anterior se utiliza el método de transformaciones intragrupalas para realizar la estimación. El modelo no corresponde a un modelo de datos panel tradicional debido a que se analizan dentro de cada alcaldías diferentes viviendas en cada período.

$$\log(P_{jit}) = \alpha_1 T1_t + \alpha_2 T2_t + \beta_1 Conf_{it} + \beta_2 Dens_{it} + \beta_3 IMM_{it} + \epsilon_{jit}$$

Ambos modelos incluyen las mismas variables, se diferencian en los subíndices. En las ecuaciones se puede observar que el segundo modelo adiciona el subíndice  $j$  en la variable

dependiente, en este caso  $P_{ijt}$  es el precio de un avalúo en el mes  $t$  de una propiedad  $j$  ubicada la alcaldía  $i$ ; por su parte, el primer modelo incluye  $P_{it}$  que es el precio promedio de los avalúos de las alcaldías en el tiempo  $t$ .

Los modelos incluyen dos variables dummies para tener en cuenta el efecto diferenciado de la pandemia a lo largo del tiempo,  $T1_t$  es una variable dummy que toma valor de 1 en el año 2020 y 0 el resto del periodo y  $T2_t$  es una variable dummy que toma valor de 1 en el año 2021 y 0 el resto del periodo.  $Conf_{it}$  son el total de casos confirmados de la alcaldía  $i$  en el mes  $t$ ;  $Dens_{it}$  es la densidad poblacional de la alcaldía  $i$  en el mes  $t$  y  $IMM_{it}$  es el índice de marginación de la alcaldía  $i$  en el periodo  $t$ , para los años 2016-2019 se utilizó el valor del índice del año 2015 y para los años 2020 y 2021 se utilizaron las cifras que este tomó en el año 2020. El modelo también incluye  $\epsilon_{it}$  (o  $\epsilon_{jit}$ ) que son factores no observados que afectan el precio de vivienda.

### 3.3. Análisis descriptivo

En esta sección se va a realizar un análisis descriptivo de las variables que conforman los dos modelos. En la primera parte, no se distingue por alcaldías y se presentan resultados agregados. En la segunda parte, se realiza un análisis comparativo de las variables teniendo en cuenta su distribución espacial.

Tabla 3.1: Estadísticas descriptivas periodo pre-covid (2016-2019)

Statistic	N	Mean	St. Dev.	Min	Max
$P_{jt}$	106,032	3,607,147	4,198,294	128,540.4	82,514,703
$Conf_t$	106,032	0	0	0	0
$Dens_t$	106,032	12,240.9	4,684.5	1,989.6	17,029.8
$IMM_t$	106,032	-1.908	0.201	-2.228	-1.527

Tabla 3.2: Estadísticas descriptivas periodo covid (2020 en adelante)

Statistic	N	Mean	St. Dev.	Min	Max
$P_{jt}$	54,427	3,311,011	4,015,351	131,213.6	70,541,993
$Conf_t$	54,427	2,921	3,622	0	24,925
$Dens_t$	54,427	11,736.3	4,874.9	2,005.8	16,956.7
$IMM_t$	54,427	-1.706	0.245	-2.162	-1.179

En las tablas 3.1 y 3.2 se muestran las estadísticas básicas de las variables de estudio en el periodo pre-covid(de 2016 a 2019) y covid(2020 en adelante). Se evidencia que el precio promedio se redujo pasando de 3,607,147 millones de pesos en 2016-2019 a 3,311,011 millones de pesos de 2020 a mediados del año 2021. Hubo en promedio 2,921 casos confirmados de Covid-19 y la dispersión es alta, reflejando gran variabilidad en la cantidad mensual de casos confirmados. Los datos de la densidad poblacional y el índice de marginación no presentan cambios significativos en cuando a la media y la desviación estándar.

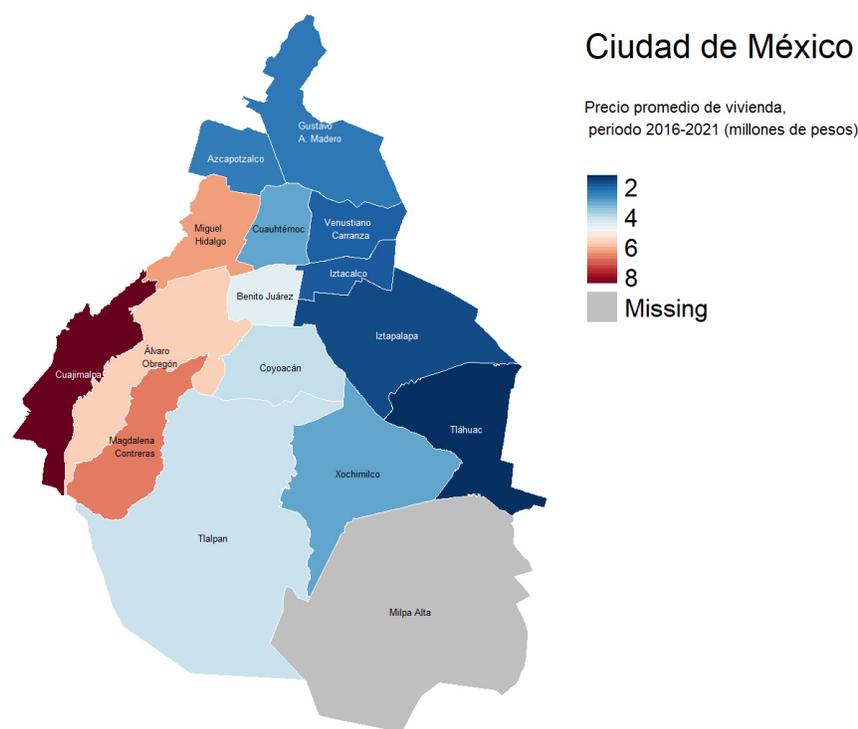


Figura 3.1: Precio promedio de vivienda 2016-2021

Ahora, la distribución espacial de las variables es importante para entender las diferencias en las características de las alcaldías que pueden incidir en el comportamiento de los precios en un contexto de pandemia.

El mapa 3.1 presenta la media del promedio individual de los avalúos de cada alcaldía en todo el periodo de estudio. Se evidencia que los precios varían considerablemente entre alcaldías con diferencias incluso de más de 5 millones de pesos mexicanos, esto podría deberse a factores como la seguridad y el acceso a servicios públicos. Las alcaldías con precios más

altos son Cuajimalpa de Morelos y La Magdalena Contreras y, las que tienen precios más bajos son Tláhuac e Iztapalapa.

Un mapa similar es el mapa 3.2 que presenta la distribución del cambio porcentual en el precio promedio de vivienda de diciembre de 2019 (último mes pre-covid) y de diciembre de 2020 (primer año de pandemia) de las 15 alcaldías de estudio en la Ciudad de México. Podemos observar que aunque en la mayoría de las alcaldías el precio de vivienda se redujo, hubo algunas excepciones como ocurrió en la alcaldía de Cuajimalpa de Morelos en el que el precio se incrementó en 28.1 %. Caso contrario es el de la alcaldía de La Magdalena Contreras y la alcaldía de Xochimilco en las que hubo reducciones de -35.9 % y -37.6 % respectivamente.

Los siguientes mapas reflejan la distribución espacial de las variable independientes. La figura 3.3 muestra los confirmados totales por cada 10 mil habitantes en el año 2020 de las alcaldías en estudio, se observa que las alcaldías más afectadas por la pandemia fueron la alcaldía de Iztapalapa y Gustavo A. Madero.

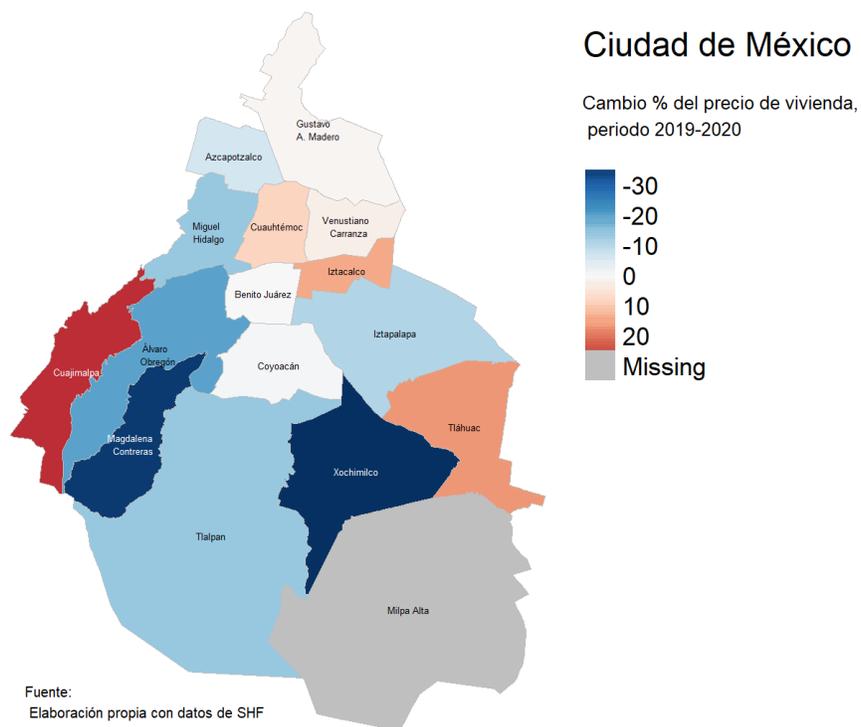


Figura 3.2: Variación porcentual del precio de vivienda 2019-2020

La distribución de la densidad poblacional y el índice de marginación del año 2020 se pre-

señala en los mapas 3.4 y 3.5. Las alcaldías con mayor densidad fueron Cuauhtémoc, Benito Juárez, Iztacalco e Iztapalapa y, las alcaldías con menos densidad fueron Tlalpan, Cuajimalpa, La Magdalena Contreras y Xochimilco. Por otro lado, el mapa del Índice de Marginación permite evidenciar que la mayoría de las alcaldías tuvieron valores muy negativos lo que indica que el nivel de marginación de la ciudad fue bajo, las alcaldías con menor y mayor carencia estructural en ese año fueron la de Benito Juárez y la de Xochimilco.

Lo anterior sugiere que el mercado inmobiliario de la alcaldía de Cuajimalpa de Morelos, que es la alcaldía con mayor precio promedio de vivienda, fue el menos afectado por la pandemia ya que el precio se incrementó considerablemente. Esta relación no se presentó en la alcaldía La Magdalena Contreras que pese a presentar precios promedio altos, la variación de los precios fue negativa. Por otro lado, el análisis espacial muestra que, como era de esperarse, dadas las características del virus, existe una relación estrecha y positiva entre la densidad poblacional y el número total de confirmados totales. La relación existente entre el número de confirmados totales y el precio promedio de vivienda no es clara.

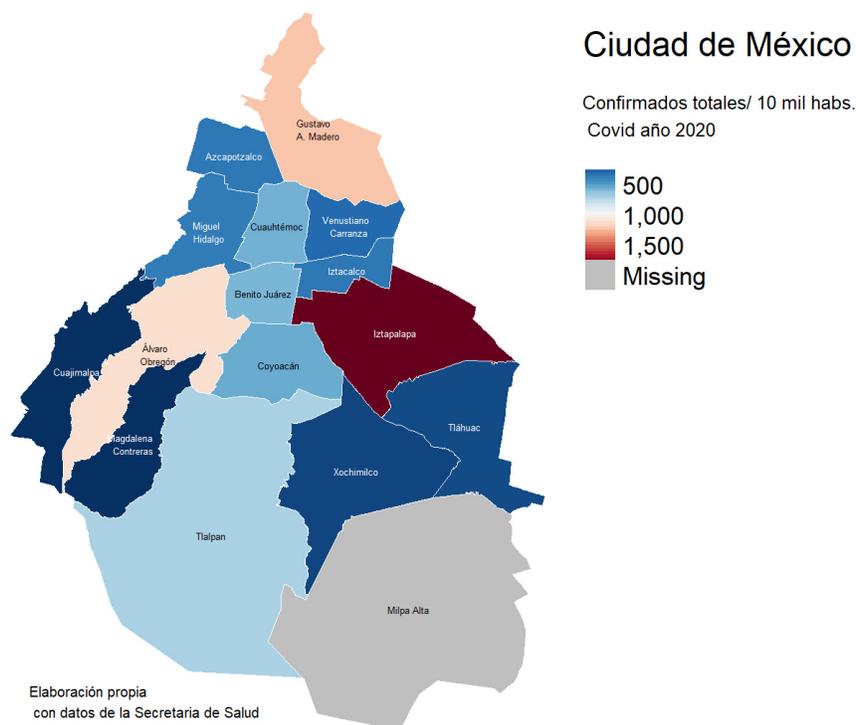


Figura 3.3: Confirmados totales de Covid-19 en el año 2020

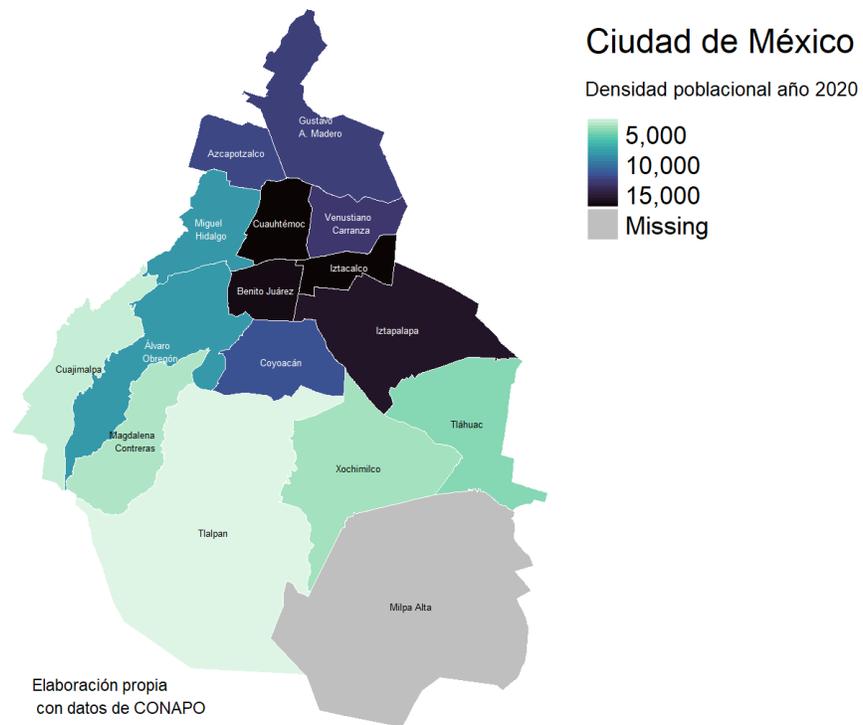


Figura 3.4: Densidad poblacional en el año 2020

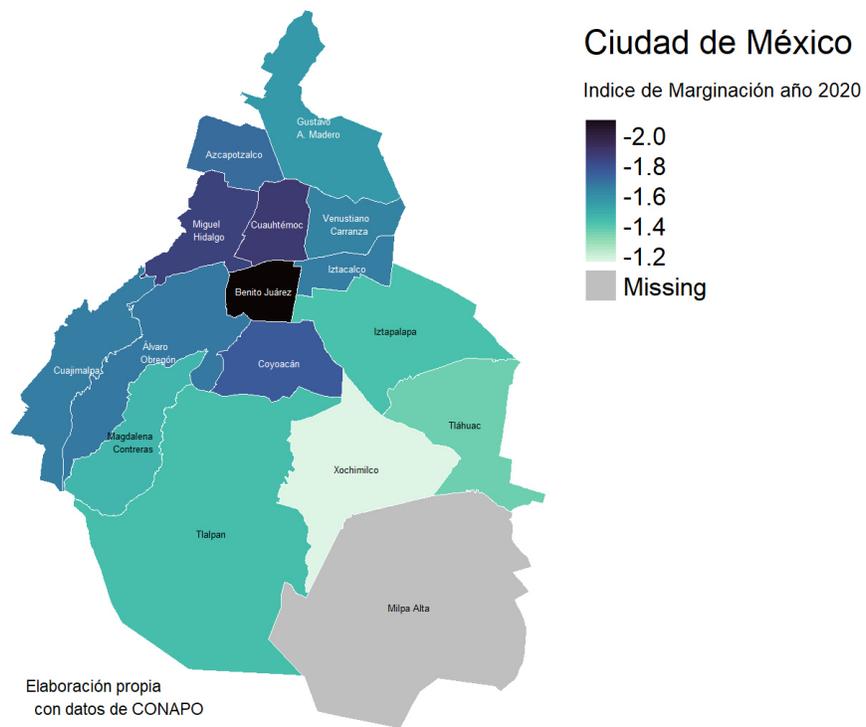


Figura 3.5: Índice de marginación en el año 2020

# Capítulo 4

## Resultados

El modelo seleccionado contiene cinco variables independientes (confirmados totales, variables dummies de tiempo, densidad poblacional e índice de marginación) y la variable dependiente (avalúos) que está expresada en términos logarítmicos. Para su estimación, se utilizó el método de transformaciones intragrupalas explicado en el apéndice. Los datos de confirmados y de densidad poblacional se incorporaron en la regresión divididos por mil para que los resultados sean más claros.

La tabla 4.1 presenta la estimación del modelo utilizando el promedio mensual de los avalúos individuales dentro de cada alcaldía. En este caso, la estructura de los datos corresponde a un modelo de datos panel.

Los resultados muestran que la variable de confirmados al mes no es significativa y tiene el signo opuesto a lo que se esperaría teóricamente; las variables dummies,  $T1$  y  $T2$ , pese a ser estadísticamente significativas al 1% y 10% respectivamente, también tienen el signo opuesto al esperado ya que indican que los precios de vivienda presentaron un aumento en los años 2020 y 2021 que corresponden al periodo de la pandemia. Las variables de densidad poblacional e índice de marginación tienen los signos esperados y son estadísticamente significativas al 10% y 1%. Por último, las variables son conjuntamente significativas de acuerdo con la prueba F. Si bien, estas estimaciones pueden ser útiles para tener un primer acercamiento de los efectos que tuvo la pandemia en el mercado inmobiliario, los resultados no son claros porque ocultan aspectos relevantes referentes al tamaño de mercado, la cantidad de información existente y el número posible de transacciones dentro de las alcaldías.

La tabla 4.2 presenta el modelo estimado teniendo en cuenta los avalúos individuales que varían dentro de cada alcaldía. Este no es un modelo de datos panel porque se analizan diferentes viviendas en cada período lo cual permite contar con una mayor cantidad de datos

Tabla 4.1: Precio de vivienda y covid-19 (panel tradicional)

	<i>Dependent variable:</i>
	$\log(P_{it})$
T1	0.076*** (0.027)
T2	0.051* (0.030)
Conf	0.003 (0.003)
Dens	-0.108* (0.061)
IMM	-0.850*** (0.131)
Observations	990
R <sup>2</sup>	0.108
Adjusted R <sup>2</sup>	0.090
F Statistic	23.396*** (df = 5; 970)
<i>Note:</i>	*p<0.1; **p<0.05; ***p<0.01

y mayor variabilidad de los mismos. Los resultados son consistentes con la teoría ya que todas las variables tienen los signos esperados. La densidad poblacional es estadísticamente significativa al 5 % indicando que entre mayor cercanía exista entre la población, el precio de vivienda se reduce. El índice de marginación es estadísticamente significativo al 1 %, la estimación muestra que un incremento de una unidad en el índice es asociado con una reducción del 27 % en el precio de vivienda.

Tabla 4.2: Precio de vivienda y covid-19

<i>Dependent variable:</i>	
	$\log(P_{jit})$
T1	-0.007 (0.009)
T2	-0.045*** (0.010)
Conf	-0.001 (0.001)
Dens	-0.036** (0.017)
IMM	-0.266*** (0.048)
Observations	160,459
R <sup>2</sup>	0.003
Adjusted R <sup>2</sup>	0.003
F Statistic	100.982*** (df = 5; 160439)
<i>Note:</i>	*p<0.1; **p<0.05; ***p<0.01

Respecto a las variables incluidas para tener en cuenta el efecto de la pandemia, los resultados muestran que la variable de confirmados totales y la variable dummy *T1* correspondiente al año 2020 no son estadísticamente significativas y el efecto sobre los precios es pequeño, lo cual sugiere que los precios de vivienda no variaron por la intensidad de la pandemia, pues las alcaldías con mayor número de confirmados no presentaron reducciones y a su vez, sugiere que el efecto de la pandemia no fue inmediato. Por el contrario, la variable *T2* que indica el cambio de los precios en el año 2021 es negativa y estadísticamente significativa al 1 %, es decir, una vez los mercados reaccionaron ante la pandemia, hubo una reducción

---

en el precio de vivienda de la Ciudad de México de 4.5 % en el año 2021.

# Capítulo 5

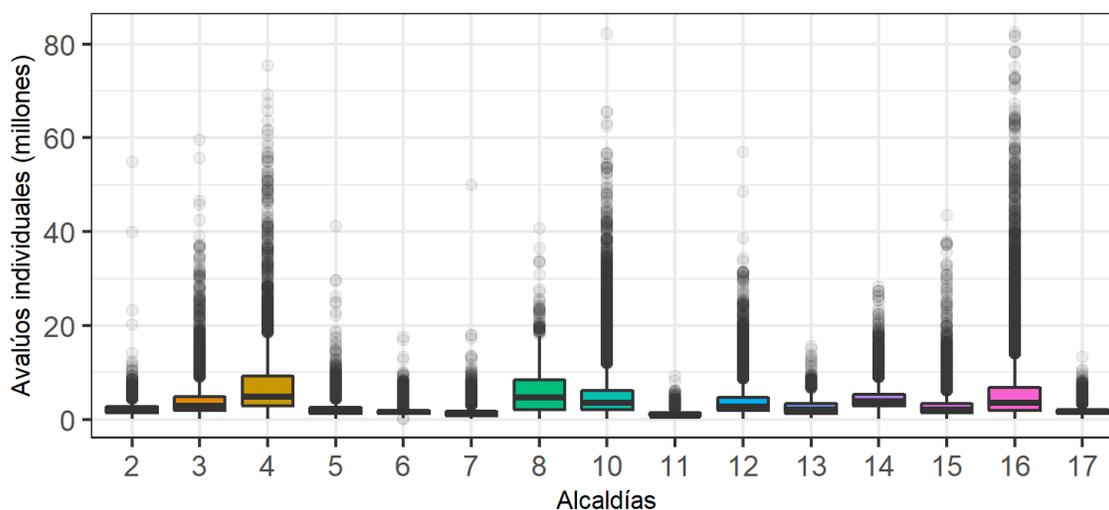
## Outliers y efectos por deciles

La dispersión de los datos es importante ya que la existencia de valores atípicos puede afectar la estimación de los parámetros de modo que, se subestimen o sobrestimen los efectos de la pandemia en el mercado inmobiliario de la Ciudad de México. La figura 5.1 es un diagrama de cajas que permite identificar, a través de los cuartiles, la distribución y los valores atípicos de los avalúos individuales de las 15 alcaldías en estudio. Se evidencia que existe una gran cantidad de valores atípicos especialmente en las alcaldías con precios de vivienda altos. La mayor dispersión ocurre en las alcaldías Cuajimalpa de Morelos (4), Alvaro Obregón (10) y Miguel Hidalgo (16) y, la menor dispersión se presenta en las alcaldías Azcapotzalco (2) y Tláhuac (11) cuyos precios promedio oscilaron entre uno y dos millones de pesos.

Con el fin de complementar el análisis y robustecer los resultados encontrados, se va a reestimar el modelo pero, ahora, eliminando los outliers de los avalúos individuales en las 15 alcaldías. El método utilizado para eliminarlos es el de la Regla de Tukey que utiliza cuartiles, no requiere normalidad en la distribución de los datos y es adecuada en muestras grandes. Fueron eliminados 10365 observaciones de los datos originales.

## Dispersión de precios individuales entre alcaldías

Periodo 2016-2021



Fuente: Elaboración propia con datos de SHF

Figura 5.1: Bloxpot: Dispersión avalúos individuales

En la tabla 5.1 se presentan los resultados de la estimación. Los resultados son parecidos a los calculados inicialmente, salvo que, los precios presentan una reducción significativa de 2.2% en el año 2020, esta reducción, sin embargo, es menor a la que se presentó en el año 2021, 5.4%. La variable confirmados al igual que antes, no es significativa, esto reafirma que los precios de vivienda no variaron por la intensidad de pandemia en las alcaldías. Las otras dos variables presentaron valores similares a los estimados en el modelo inicial y los signos son los mismos. Ahora bien, dicho lo anterior, se evidencia que al quitar los outliers (concentrados en la parte alta de la distribución), la pandemia tiene efectos tanto en el año 2020 como en el año 2021. Por esto, se realizó nuevamente la estimación del modelo inicial (con outliers) pero ahora, utilizando el método regresión cuantil con el fin de tener en cuenta la diferencia de los impactos en los segmentos más altos y más bajos del mercado inmobiliario.

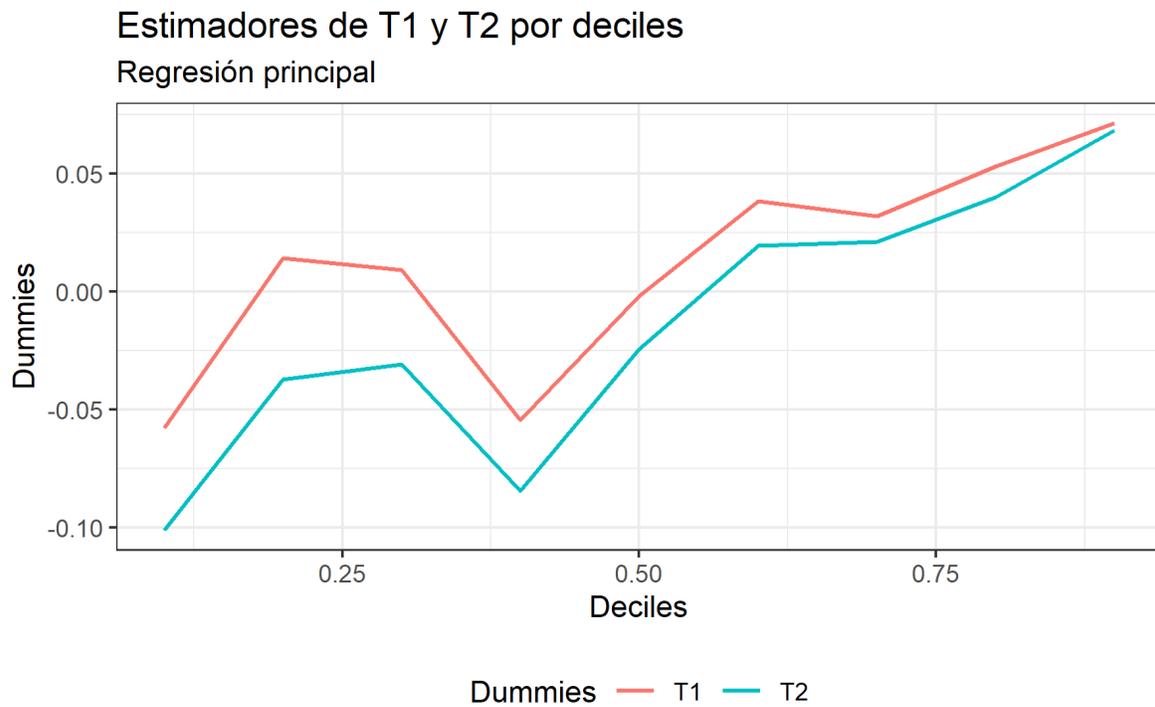
En la figura 5.2, se presenta la estimación de las dos variables dummies de tiempo, T1 y T2. El comportamiento de los precios en los dos años pese a ser similar en toda la distribución, es posible notar que antes de la mediana, los precios tuvieron mayor variación entre grupos y casi siempre fueron negativos, posteriormente, los precios aumentaron especialmente en los deciles superiores lo que indica que las viviendas mejor valoradas por el mercado presentaron

---

un incremento de los precios durante la pandemia.

Tabla 5.1: Precio de vivienda y covid-19 corregidos por outliers

	<i>Dependent variable:</i>
	$\log(P_{jit})$
T1	-0.022*** (0.008)
T2	-0.054*** (0.008)
Conf	-0.0002 (0.001)
Dens	-0.035** (0.014)
IMM	-0.171*** (0.041)
Observations	150,094
R <sup>2</sup>	0.004
Adjusted R <sup>2</sup>	0.004
F Statistic	115.907*** (df = 5; 150074)
<i>Note:</i>	*p<0.1; **p<0.05; ***p<0.01



Fuente: Elaboración propia

Figura 5.2: Estimadores variables dummies de tiempo

# Capítulo 6

## Conclusiones

La presente investigación aporta a la literatura de impactos de eventos extremos en el mercado inmobiliario de países en vía de desarrollo.

Utilizando un modelo econométrico con efectos fijos se encontró que la reciente pandemia de Covid-19 tuvo un efecto negativo importante en el mercado inmobiliario de la Ciudad de México, especialmente en el segundo año en el que los precios mensuales se redujeron en 4.5%, esta caída es similar a la que se presentó en países como Estados Unidos(5%) y China(2.47%). Además, en relación con otros países, los efectos encontrados para el caso mexicano fueron más tardíos porque se presentaron un año después del inicio de la pandemia y no en los primeros meses, lo cual puede ser explicado por la forma en que se contruyó el modelo ya que la valoración de las viviendas efectuada por la SHF puede reaccionar más lentamente que los precios reales del mercado.

Por otro lado, se encontró que el impacto que tuvo el Covid-19 en los precios de vivienda fue general y no dependió de la intensidad de la misma pues no hubo una reducción estadísticamente significativa al incorporar el número total de casos confirmados por alcaldía. También fue posible identificar que la concentración de la población medida por la densidad poblacional y el nivel de desarrollo de cada alcaldía medido por el Índice de Marginación inciden en el comportamiento de los precios de manera negativa.

Los resultados del modelo principal son robustos al eliminar valor atípicos. Al eliminar los outliers que se encuentran principalmente en la parte alta de la distribución (viviendas de precios altos), los efectos se intensifican en el año 2020, los precios muestran una reducción significativa de 2.2% frente a una reducción que no es significativa de 0.7% en la regresión original. En otras palabras, el impacto negativo del Covid-19 en el mercado inmobiliario fue desigual y afectó principalmente a la población que vive en viviendas de precios bajos.

---

Respecto a las limitaciones del estudio, la principal limitación fue la disponibilidad de datos. No fue posible incluir variables importantes que permitieran medir las características de las viviendas y de las alcaldías para construir un modelo de precios hedónicos y mejorar la estimación. Por tanto, se mantiene prudencia respecto a la posibilidad de generalizar los resultados para otras ciudades del país. Sin embargo, reconocer dichas limitaciones podría presentar una posibilidad para estudios posteriores relacionados o para trabajos que busquen cómo complementar las fuentes de datos oficiales.

# Anexo A

## Modelos econométricos

### A.1. Métodos para datos panel

La explicación de los métodos para trabajar con datos panel es tomada del libro *Introducción a la econometría: un enfoque moderno* de Wooldridge (2009).

Según el autor, una opción para usar datos panel es clasificar los factores no observables, que influyen en la variable dependiente, en dos tipos: aquellos que son constantes y aquellos que varían con el tiempo. Considerando que  $i$  es la unidad de corte transversal y  $t$  el tiempo, se puede escribir un modelo de efectos fijos de dos periodos con una sola variable explicativa observada como:

$$y_{it} = \beta_0 + \delta_0 d2_t + \beta_1 x_{it} + a_i + u_{it}, \quad t = 1, 2 \quad (\text{A.1})$$

En la notación  $y_{it}$ ,  $i$  denota la persona, empresa, ciudad, etc., y  $t$  indica el periodo. La variable  $d2_t$  es una variable binaria que es igual a cero cuando  $t = 1$  y a uno cuando  $t = 2$ ; no cambia en  $i$ , razón por la cual no tiene subíndice  $i$ . La variable  $a_i$  captura todos los factores inobservables, constantes en el tiempo, que influyen en  $y_{it}$ , se conoce como efecto inobservable o efecto fijo y el error  $u_{it}$  representa factores inobservables que cambian con el tiempo e influyen en  $y_{it}$ .

Para estimar el parámetro de interés  $\beta_1$  con dos años de datos panel hay varias alternativas. Una es combinar los dos años y utilizar MCO. Para hacerlo, se debe suponer que el efecto inobservable  $a_i$ , no se correlaciona con  $x_{it}$ , de lo contrario, la estimación será sesgada e inconsistente. En la mayoría de las aplicaciones, la razón principal para reunir datos de panel es permitir que el efecto inobservable,  $a_i$ , se correlacione con las variables explicativas.

Como  $a_i$  es constante en el tiempo se pueden diferenciar los datos a lo largo de los dos años de modo que se obtiene la **ecuación en primera diferencia**:

$$\Delta y_i = \delta_0 + \beta_1 \Delta x_i + \Delta u_i \quad (\text{A.2})$$

donde  $\Delta$  denota el cambio de  $t = 1$  a  $t = 2$ . El efecto inobservable,  $a_i$  se elimina por diferenciación y  $\delta_0$  es el cambio en el intercepto de  $t = 1$  a  $t = 2$ . Debe cumplir supuestos clave. El más importante es que  $\Delta u_i$  no esté serialmente correlacionado con  $\Delta x_i$ , es decir, el error idiosincrático en cada tiempo  $t$ ,  $u_{it}$ , no se debe correlacionar con la variable explicativa en ambos periodos.

Otra condición crucial es que  $\Delta x_i$  debe tener cierta variación en  $i$ , dicha variación es en general reducida por la diferenciación empleada para eliminar  $a_i$ . Este requisito no se cumple si la variable explicativa no cambia en el tiempo para cualquier observación de corte transversal, o si cambia la misma cantidad para cada observación. El otro supuesto necesario para aplicar a los estadísticos usuales de MCO es que la ecuación satisfaga el supuesto de homocedasticidad.

También es posible utilizar la diferenciación con más de dos periodos. En el caso de  $T = 3$  se resta el periodo uno del periodo dos y el periodo dos del periodo tres:

$$\Delta y_{it} = \delta_2 \Delta d2_t + \delta_3 \Delta d3_t + \beta_1 \Delta x_{it1} + \dots + \beta_k \Delta x_{itk} + \Delta u_{it}, \quad t = 2, 3 \quad (\text{A.3})$$

Si la anterior ecuación satisface los supuestos del modelo lineal clásico, entonces la estimación combinada por MCO arroja estimadores insesgados, y los estadísticos  $t$  y  $F$  son válidos para probar hipótesis. La ecuación no contiene un intercepto. Es mejor estimarla en primera diferencia con un intercepto y una sola variable binaria de periodo, por lo general para el tercero. La ecuación se vuelve:

$$\Delta y_{it} = \alpha_0 + \alpha_3 d3_t + \beta_1 \Delta x_{it1} + \dots + \beta_k \Delta x_{itk} + \Delta u_{it}, \quad t = 2, 3 \quad (\text{A.4})$$

Las estimaciones de  $\beta_j$  son idénticas en cada formulación. Con más de tres periodos, las cosas son similares.

Siguiendo a Wooldridge (2009), otros métodos que sirven para estimar modelos de datos de panel de efectos inobservables que son al menos tan comunes como aplicar la primera diferencia pues eliminan el efecto fijo  $a_i$  son:

**Metódo de transformación de efectos fijos o de transformaciones intragrupales (within)** que aplica la deducción del tiempo a cada variable explicativa, incluyendo a factores como las variables binarias temporales, y luego se realiza una regresión combinada de MCO utilizando todas las variables con el tiempo deducido. La ecuación general con el tiempo deducido para cada  $i$  se estima por MCO combinados y es:

$$\ddot{y}_{it} = \beta_1 \ddot{x}_{it1} + \beta_2 \ddot{x}_{it2} + \dots + \beta_k \ddot{x}_{itk} + \ddot{u}_{it}, \quad t = 1, 2, \dots, T, \quad (\text{A.5})$$

donde  $\ddot{y}_{it} = y_{it} - \bar{y}_i$  y  $\bar{y}_i = T^{-1} \sum_{t=1}^T y_{it}$ .

Para cada variable explicativa se realiza la misma transformación.

Bajo el supuesto de exogeneidad estricta sobre las variables explicativas, el estimador de efectos fijos es insesgado: aproximadamente, el error idiosincrático  $u_{it}$  no debe correlacionarse serialmente con ninguna variable explicativa en todos los periodos. El estimador de efectos fijos permite la correlación arbitraria entre  $a_i$  y las variables explicativas en cualquier periodo, al igual que con las primeras diferencias. El otro supuesto necesario para que un análisis por MCO directo sea válido es que los errores  $u_{it}$  sean homocedásticos y no estén serialmente correlacionados (en  $t$ ).

**Regresión con variables binarias** es utilizado cuando se supone que el efecto inobservable,  $a_i$ , es un parámetro que debe estimarse para cada  $i$ . Para ello, se asigna una variable binaria para cada observación de corte transversal. Aun cuando  $N$  no es muy grande, da por resultado muchas variables explicativas lo cual no es muy práctico para conjuntos de datos de panel con numerosas observaciones de corte transversal. No obstante, el método provee exactamente las mismas estimaciones de las  $\beta_j$  que se obtendrían de la regresión con el método within y, los errores estándar y otros estadísticos importantes también son idénticos.

Cabe resaltar que algunos paquetes econométricos reportan un “intercepto,” que surge de considerar las  $a_i$  como parámetros a estimar. Comúnmente, el intercepto reportado es el promedio en  $i$  de las  $\hat{a}_i$ . En otras palabras, el intercepto general es, en realidad, el promedio de los interceptos específicos individuales, el intercepto será un estimador insesgado y consistente de  $\alpha = E(a_i)$ .

En la mayor parte de los estudios, las  $\hat{\beta}_j$  son de interés y, por tanto, se utilizan ecuaciones con variables con el tiempo deducido para obtener estas estimaciones. Además, por lo común resulta mejor considerar las  $a_i$  como variables omitidas que se controlan mediante la transformación intragrupal. En general, el sentido en que se estima  $a_i$  es débil. De hecho, aun cuando  $\hat{a}_i$  sea insesgada, no es consistente para un  $T$  fijo cuando  $N \rightarrow \infty$ . Con  $T$  grande, se

obtienen mejores estimaciones de  $a_i$ , pero la mayoría de los conjuntos de datos de panel son del tipo en que  $N$  es grande y  $T$  es pequeño.

Respecto a cuál método elegir, cuando  $T = 2$  las estimaciones de EF (efectos fijos) y PD (primera diferencia), así como todos los estadísticos de prueba, son idénticos. Cuando  $T \geq 3$ , los estimadores de EF y PD no son los mismos. En virtud de que ambos son insesgados, con base en los supuestos y ambos son consistentes (con  $T$  fijo cuando  $N \rightarrow \infty$ ), para  $N$  grande y  $T$  pequeño, la elección entre estimadores de EF y PD depende de su eficiencia relativa, determinada por la correlación serial de los errores idiosincráticos,  $u_{it}$ . Cuando las  $u_{it}$  no se correlacionan serialmente, los estimadores de efectos fijos son más eficientes que los de primera diferencia. Y, dado que el modelo de efectos fijos casi siempre se establece con errores idiosincráticos no correlacionados serialmente, el estimador de EF se emplea más a menudo. Aún así, la inferencia con el estimador de efectos fijos es potencialmente más sensible a la no normalidad, la heterocedasticidad y la correlación serial en los errores idiosincráticos.

Otro modelo para trabajar datos de panel, es el modelo de efectos aleatorios que da por sentado que el efecto inobservable  $a_i$  no se correlaciona con ninguna variable explicativa. Por tanto,  $a_i$  se deja en el término de error y se resuelve la correlación serial resultante en el tiempo mediante la estimación de mínimos cuadrados generalizados. En el modelo de efectos aleatorios no se profundizará en esta sección dado que no fue utilizado en el estudio ya que es posible que en el modelo propuesto exista relación entre las variables incluidas y algunas variables constantes en el tiempo como lo son, el número de bibliotecas o de universidades por alcaldía.

## A.2. Regresión cuantil

La regresión cuantílica se utiliza cuando se busca estimar el efecto que tienen los predictores sobre cualquier parte de la distribución de la variable dependiente. Angrist & Pischke (2009) explican el la regresión cuantil partiendo de la función cuantil condicional (CQF) definida como:

$$Q_\tau(Y_i|X_i) = F_y^{-1}(\tau|X_i) \tag{A.6}$$

donde  $F_y(y|X_i)$  es la función de distribución para  $Y_i$  en  $y$  condicionada en  $X_i$ . Donde  $\tau = .10$ , por ejemplo,  $Q_\tau(Y_i|X_i)$  describe el decil más bajo de  $y_i$  dado  $X_i$ .

CQF resuelve el siguiente problema de minimización:

$$Q_\tau(Y_i|X_i) = \arg \min_{q(X)} E[\rho_\tau(Y_i - q(X_i))] \quad (\text{A.7})$$

donde  $\rho_\tau(u) = (\tau - 1(u \leq 0)) |u|$  es la “check function.”

Si  $\tau = .5$ ,  $Q_\tau(Y_i|X_i)$  es la mediana condicional que minimiza las desviaciones absolutas. De lo contrario, la “check function” pondera los términos positivos y negativos de forma asimétrica que genera un mínimo que resalta los cuantiles condicionales:

$$\rho_\tau(u) = 1(u > 0) \cdot \tau |u| + 1(u \leq 0) \cdot (1 - \tau) |u| \quad (\text{A.8})$$

Con  $X_i$  continuo o de alta dimensión, el CQF puede ser difícil de estimar. La regresión cuantil logra reducir esta función a un conjunto de números pequeño, uno para cada elemento de  $X_i$ , sustituyendo un modelo lineal por  $q(X_i)$  en la ecuación A.7, generando el estimador de regresión cuantil:

$$\beta_\tau \equiv \arg \min_b E[\rho_\tau(Y_i - X_i' b)] \quad (\text{A.9})$$

Al igual que MCO que ajusta un modelo lineal a  $Y_i$ , al minimizar el error cuadrático, la regresión cuantil ajusta un modelo lineal a  $Y_i$  usando la función de pérdida asimétrica,  $\rho_\tau(u)$ .



# Bibliografía

- Alfani, G., & Percoco, M. (2019). Plague and long-term development: The lasting effects of the 1629–30 epidemic on the Italian cities. *The Economic History Review*, 72(4), 1175–1201. <https://doi.org/10.1111/ehr.12652>
- Angrist, J., & Pischke, J.-S. (2009). Mostly Harmless Econometrics: An Empiricist’s Companion. In *Mostly Harmless Econometrics: An Empiricist’s Companion*.
- Chong, T. T. L., & Liu, H. (2020). *How does the COVID-19 pandemic affect housing prices in China?* (No. 102103). University Library of Munich, Germany. <https://ideas.repec.org/p/pramprapa/102103.html>
- D’Lima, W., Lopez, L. A., & Pradhan, A. (2022). COVID-19 and housing market effects: Evidence from U.S. Shutdown orders. *Real Estate Economics*, 50(2), 303–339. <https://doi.org/10.1111/1540-6229.12368>
- Davis, D. R., & Weinstein, D. E. (2002). Bones, Bombs, and Break Points: The Geography of Economic Activity. *American Economic Review*, 92(5), 1269–1289. <https://doi.org/10.1257/000282802762024502>
- Del Giudice, V., De Paola, P., & Del Giudice, F. P. (2020). COVID-19 Infects Real Estate Markets: Short and Mid-Run Effects on Housing Prices in Campania Region (Italy). *Social Sciences*, 9(7), 114. <https://doi.org/10.3390/socsci9070114>
- Francke, M., & Korevaar, M. (2021). Housing markets in a pandemic: Evidence from historical outbreaks. *Journal of Urban Economics*, 123, 103333. <https://doi.org/10.1016/j.jue.2021.103333>
- Hornbeck, R., & Keniston, D. (2017). Creative Destruction: Barriers to Urban Growth and the Great Boston Fire of 1872. *American Economic Review*, 107(6), 1365–1398. <https://doi.org/10.1257/aer.20141707>
- Hu, M. R., Lee, A. D., & Zou, D. (2021). COVID-19 and Housing Prices: Australian Evidence with Daily Hedonic Returns. *Finance Research Letters*, 43, 101960. <https://doi.org/10.1016/j.frl.2021.101960>
- Li, X., & Zhang, C. (2021). Did the COVID-19 Pandemic Crisis Affect Housing Prices Evenly in the U.S.? *Sustainability*, 13(21), 12277. <https://doi.org/10.3390/su132112277>
- Liu, S., & Su, Y. (2021). The impact of the COVID-19 pandemic on the demand for density: Evidence from the U.S. Housing market. *Economics Letters*, 207, 110010. <https://doi.org/10.1016/j.econlet.2021.110010>
- Molina-Torres, R., Nolasco-Jáuregui, O., Rodriguez-Torres, E. E., Itzá-Ortiz, B. A., & Quezada-Téllez, L. A. (2021). A comparative analysis of urban development, economic level, and COVID-

- 19 cases in Mexico City. *Journal of Urban Management*, 10(3), 265–274. <https://doi.org/10.1016/j.jum.2021.06.007>
- Qian, X., Qiu, S., & Zhang, G. (2021). The impact of COVID-19 on housing price: Evidence from China. *Finance Research Letters*, 43, 101944. <https://doi.org/10.1016/j.frl.2021.101944>
- Sobrinho, J. (2014). Precios de la vivienda y submercados en la Ciudad de México: Una evaluación hedónica. *Estudios Económicos de El Colegio de México*, 57–84. <https://doi.org/10.24201/ee.v29i1.74>
- Viscusi, W. K. (1990). Sources of Inconsistency in Societal Responses to Health Risks. *The American Economic Review*, 80(2), 257–261. <https://www.jstor.org/stable/2006580>
- Wong, G. (2008). Has SARS infected the property market? Evidence from Hong Kong. *Journal of Urban Economics*, 63(1), 74–95. <https://doi.org/10.1016/j.jue.2006.12.007>
- Wooldridge, J. M. (2009). *Introductory econometrics: A modern approach* (4. ed). South Western cengage learning.

# Índice de tablas

3.1. Estadísticas descriptivas periodo pre-covid (2016-2019) . . . . .	11
3.2. Estadísticas descriptivas periodo covid (2020 en adelante) . . . . .	11
4.1. Precio de vivienda y covid-19 (panel tradicional) . . . . .	18
4.2. Precio de vivienda y covid-19 . . . . .	19
5.1. Precio de vivienda y covid-19 corregidos por outliers . . . . .	23



# Índice de figuras

3.1. Precio promedio de vivienda 2016-2021 . . . . .	12
3.2. Variación porcentual del precio de vivienda 2019-2020 . . . . .	13
3.3. Confirmados totales de Covid-19 en el año 2020 . . . . .	14
3.4. Densidad poblacional en el año 2020 . . . . .	15
3.5. Índice de marginación en el año 2020 . . . . .	16
5.1. Bloxpot: Dispersión avalúos individuales . . . . .	22
5.2. Estimadores variables dummies de tiempo . . . . .	24

