

CONTABILIDAD Y FINANZAS

PREDICCIÓN DE LA VARIACIÓN DE LOS PRECIOS INMOBILIARIOS EN EL ÁREA METROPOLITANA DEL GRAN CONCEPCIÓN, CHILE**PREDICTION OF THE VARIATION OF REAL ESTATE PRICES IN THE METROPOLITAN AREA OF GRAN CONCEPCIÓN, CHILE**

[Roberto Parra Sepúlveda](#), [Luis Améstica-Rivas](#), [Héctor Gaete Feres](#)¹

¹Universidad del Bío-Bío, Chile.

Recibido: 30/06/2021

Aceptado: 24/08/2021

RESUMEN

La imposibilidad de poder predecir con exactitud los precios de los activos financieros sigue siendo un desafío para cualquier inversionista. Existiendo a su vez, distintos enfoques que intentan a los menos predecir la dirección que pueden presentar los precios de los activos, con el objetivo de anticiparse al comportamiento del mercado y poder obtener ganancias extraordinarias. En este contexto, se propone utilizar un modelo predictivo basado en autómatas celulares para el mercado inmobiliario que permita predecir el incremento o disminución futura de los precios del suelo urbano, y así poder ganarle al mercado. La investigación se aplicó a las variaciones de precios mensuales y trimestrales entre los años 2010-2018 de diversos sectores y comunas del área metropolitana del llamado Gran Concepción, segunda capital en importancia de Chile, ubicada al sur del país. Destaca entre los resultados obtenidos para distintas ventanas de tiempo, un porcentaje de acierto de predicción (PPS) promedio superior al 50%, siendo 58,5% para el autómata de mejor predicción, con capacidad predictiva estadísticamente significativa en dos de los cuatro autómatas finalmente considerados. Sin embargo, aunque el signo esperado fue acertado y muestra la capacidad predictiva del modelo, por un criterio de significancia estadística esto puede ser considerado insuficiente, abriendo una nueva etapa de estudio.

PALABRAS CLAVE: mercado inmobiliario, modelo de predicción, autómata celular.

ABSTRACT

The impossibility of being able to accurately predict the prices of financial assets remains a challenge for any investor. In turn, there are different approaches that try to at least predict the direction that asset prices may take, with the aim of anticipating market behavior and obtaining extraordinary profits. In this context, it is proposed to use a predictive model based on cellular automata for the real estate market to predict the future increase or decrease of urban land prices, and thus be able to beat the market. The research was applied to monthly and quarterly price variations between the years 2010-2018 of various sectors and communes of the metropolitan area of the so-called Gran Concepción, the second most important capital of Chile, located in the south of the country. It stands out among the results obtained for different time windows, an average prediction success percentage (PPS) higher than 50%, being 58.5% for the best prediction automaton, with statistically significant predictive capacity in two of the four

automatons finally considered. However, although the expected sign was correct and shows the predictive capacity of the model, by a criterion of statistical significance this can be considered insufficient, opening a new stage of study.

KEY WORDS: real-estate market, prediction model, celular automata

ÑEMOMBYKY

Ndaikatúiva oñemombe'u mba'éichaitépa oñembohepýta umi viru porurã, ha'e akóinte peteĩ ñorairõ oimeraëva viruporuharkuérape. Oĩrõ jepe heta ñema'ẽ oñeha'áva omombe'u haña mba'eichaitépa ikatu ojehu viru repy, oñemotenondeségui viru reko ñemuhaguasúpe ha ikatu hañaicha ohupyty tembiaporepy iporãvéva. Kóva ko moirũmbýpe oje'e ojeporútaha peteĩ jesarekorã ohechakakuaáva mba'éichapa ojuhúta jesareko mohendagua hekojeheguíva rupi ñemuha yvy kuave'ẽha ñevendépe ñuara ikatúva omombe'u ojupítarõ térã ogejýtarõ mba'e repy Távarupigua, ikatu hañaicha oñemotenonde ñemuhápe. Ojejapo tembikuaareka umi tepy oñemoambuéva peteĩ jasy ha mbohapy jasy jave ary 2020-2018 opaichagua aty vorekuéra ha tavaróga oĩva Táva jerére oñehenóiva Gran Concepción, Chile rire Táva tuichavéva, opyta tetã yvy gotyo. Ojekuaave tembiapokue apytépe ára rovetãkuérape ñuara, peteĩ porcentaje ojejavý'ỹre omombe'u ojuhútare (PPS) papy hetavéva 50 % guí ha'e 58,5% mohendagua hekojeheguíva hesapysovévape ñuara, pe ikatupyryvéva ñe'ẽaemby ha ñemohenda papapy rupive mokõime umi irundygui ojehechakuaave ipahápe. Ha katu, jepémo ñemombe'utechauhaha oñeha'arõva añetekuri ha ohechauka katupyry ñe'ẽaemby techaukarã, peteĩ monei ñemohenda papapy he'isehaichaité ko'áva ikatu oje'e michĩtaha, oñepyrũ jeyta peteĩ tembiapo jeporeka pyahu.

ÑE'Ë REKOKATU: yvy ñemuha (inmobiliaria) ñe'ẽaemby techaukarã (modelo de predicción) mohendagua hekojeheguíva (autómata celular)

RESUMO

A incapacidade de prever com precisão os preços dos ativos financeiros continua sendo um desafio para qualquer investidor. Por sua vez, existem diferentes abordagens que procuram pelo menos prever a direção que os preços dos ativos podem apresentar, com o objetivo de antecipar o comportamento do mercado e poder obter lucros extraordinários. Neste contexto, propõe-se a utilização de um modelo preditivo baseado em autômatos celulares para o mercado imobiliário que permite prever a subida ou descida futura dos preços dos terrenos urbanos e, assim, ser capaz de vencer o mercado. A pesquisa foi aplicada às variações de preços mensais e trimestrais entre os anos 2010-2018 de vários setores e comunas da área metropolitana da chamada Gran Concepción, a segunda capital mais importante do Chile, localizada no sul do país. Dentre os resultados obtidos para diferentes janelas de tempo, destaca-se um percentual médio de precisão de predição (PPS) superior a 50%, sendo 58,5% para o autômato com melhor predição, com capacidade preditiva estatisticamente significativa em dois dos quatro autômatos. Porém, embora o sinal esperado estivesse correto e mostrasse a capacidade preditiva do modelo, por um critério de significância estatística este pode ser considerado insuficiente, abrindo uma nova etapa do estudo.

PALAVRAS-CHAVE: mercado imobiliário, modelo de previsão, autômato celular

AUTOR CORRESPONDIENTE: Luis Améstica-Rivas. Departamento de Gestión Empresarial, Facultad de Ciencias Empresariales, Universidad del Bío-Bío, Chile. E-mail: lamestica@ubiobio.cl

INTRODUCCIÓN

La estimación de precios de inmuebles mediante diversos métodos es de interés para compradores, vendedores e inversionistas. La valoración inmobiliaria es una de las que más frecuentemente afecta a los ciudadanos, dado que se encuentra presente en una multitud de situaciones cotidianas como, por ejemplo, la compra de un inmueble, las tasaciones para la solicitud de préstamos hipotecarios, el pago de impuestos, entre otros. Desde una perspectiva de negocio, el mercado de los bienes raíces representa un instrumento de inversión viable para obtener ganancias, independientemente de la poca liquidez que se podría dar en ciertos mercados en el corto plazo.

Es así, como en esta búsqueda de modelos predictivos del valor del suelo se encuentra una metodología alternativa como son los autómatas celulares de Von Neuman y Ulam (Barrios, 2016). Su aplicación al mercado inmobiliario se sustenta en la creencia que los cambios posibles y esperados en los precios ofertados en el mercado de bienes raíces se explicaría en gran parte a los cambios en las expectativas que poseen los inversionistas del sector, y que estas expectativas, tienen como principal insumo la información obtenida de la interacción con el medio (Cavada, 2007). De esta forma, los autómatas celulares podrían capturar el contagio de expectativas en este mercado, ya que se caracterizan por modelar sistemas complejos y considerando que los inversionistas van actualizando e incorporando nueva información y de este modo van adaptando su esquema y estructura de toma de decisiones.

Ahora bien, la aplicación en las finanzas de los autómatas celulares se ha dado especialmente en el comportamiento del mercado accionario (Talero-Sarmiento, et al., 2017). Por ello, intentar aplicarla, en el mercado inmobiliario y en particular en el precio de los terrenos, significa considerar el supuesto que los autómatas son básicamente una teoría de contagio, en particular, entre células vecinas, por lo que es fácil imaginar esta similitud, que se podría dar entre los precios de terrenos aledaños en un territorio (Barrios, 2016). Sin embargo, se puede constatar que en sector inmobiliario los autómatas celulares han sido usados para modelar procesos de expansión urbana, como técnica de modelamiento espacial para determinación el cambio de uso de suelo, para apoyar modelos de predicción del crecimiento urbano mediante sistemas de información geográfica, entre otros (Henríquez y Azócar, 2006; Padilla et al., 2015), pero con escasa aplicación en determinación de precios.

Invertir en inmuebles o bienes raíces es una opción conveniente y confiable para generar dividendos o ganancias de capital. Si bien es cierto, la bolsa y la inversión inmobiliaria son difícilmente comparables dada su diferente naturaleza, condiciones de entorno que definen los

parámetros de medición de cada una de estas, factores como la liquidez, la volatilidad en los precios, la ausencia de series de datos homogéneas, entre otros.

Pese a ello, comúnmente tienen rendimientos similares, con la diferencia de que en el mercado inmobiliario el riesgo suele ser menor. En Chile, un estudio realizado por Colliers International (2019) comparó la rentabilidad promedio de los últimos cinco años que registraron los mercados inmobiliario y bursátil, donde, al analizar la rentabilidad promedio de la inversión en renta inmobiliaria versus la inversión en el mercado bursátil entre el periodo 2014-2019, se aprecia que invertir en un inmueble es un medio muy conveniente y confiable, rentando un promedio de 6,8% anual frente a un 5,6% del promedio del índice bursátil IPSA (Índice de Precio Selectivo de Acciones), presentando esta además mayor volatilidad, lo que se traduce en mayor riesgo.

Sin embargo, no hay que desconocer que los bienes raíces presentan poca liquidez. Pese a lo anterior, se ha demostrado que a través del tiempo que la rentabilidad de los bienes inmuebles no se ve afectada, puesto que en el largo plazo los retornos para los inversionistas son altos, haciéndolo más atractivo.

En este contexto, de inversiones inmobiliarias, resulta importante poder encontrar métodos para predecir o analizar los movimientos del precio del suelo, ya que es uno de los componentes más importantes a la hora de fijar el precio de las mismas. Ahora bien, no se puede desconocer que existen otros factores que podrían distorsionar los precios, ejemplo de ello, la existencia de la llamada burbuja racional en el mercado de la vivienda, situación no ajena a la realidad chilena, donde los precios de las viviendas se encuentran muy alejados de los componentes esenciales que fijan sus precios, tales como costos de construcción, valor de suelo, capacidad de pago de los hogares y desarrollo económico (Gil-Alana et al., 2019).

No hay que desconocer, que precisamente el valor del suelo constituye uno de los factores que se indica como indicador de posibles burbujas inmobiliarias, a través de su relación con las viviendas. Se asume que, cuando no hay burbuja, el precio del suelo y de la vivienda se moverá de forma similar o en la misma dirección. Es decir, los terrenos se adquieren en tiempos similares a aquellos en que se ejecutan proyectos de venta. En cambio, cuando existe especulación debido a que se adquieren terrenos y se mantienen con la intención de obtener un mayor valor con el paso del tiempo, debería ocurrir que las pendientes de las curvas de los precios varíen significativamente y el precio de suelo aumente más rápido que el precio de la vivienda (Barrios, 2016).

Según datos de la Cámara Chilena de la Construcción de Chile (2019), los valores de los suelos se mueven con correlación positiva. Sin embargo, se evidencia falta de información al respecto,

haciendo necesario un sistema de seguimiento público del valor comercial del suelo para saber qué realmente está pasando con este indicador, y así poder mejorar eventuales predicciones, más aún cuando el mercado inmobiliario es un componente importante y dinámico dentro de la economía chilena, donde la industria de la construcción es uno de los sectores más importantes de la economía del país, alcanzado un 6,5% del Producto Interno Bruto (PIB), según información del Banco Central de Chile (2019).

El alza en los precios de las viviendas en Chile en la última década, con saltos de precios en torno a 100%, ha generado la lógica preocupación por parte de los agentes económicos y de la población. El Informe de Estabilidad Financiera (Banco Central de Chile, 2019), donde se monitorean los principales riesgos financieros para la economía local, y la posibilidad que se esté incubando una posible burbuja en algún mercado en particular, el ente emisor fue categórico al concluir que los precios alcanzados por las propiedades se debían al aumento del ingreso de los hogares y la escasez de suelo existente. Asimismo, distintos especialistas indican que no existe burbuja inmobiliaria en el país, justificando su apreciación en que la razón del alza de precios no es especulativa, sino que tiene que ver básicamente con el alza del valor del suelo.

MATERIALES Y MÉTODOS

Esta investigación busca poder predecir, mediante autómatas celulares (Barrios, 2016), las variaciones del valor del metro cuadrado de suelo urbano en el Gran Concepción de Chile, segunda área metropolitana más grande del país, para el periodo 2010-2018. Este territorio ha experimentado una expansión urbana considerable en las últimas décadas.

Por un lado, se ha producido un proceso de densificación sostenido, concentrado en las comunas centrales, y por otro, se ha expandido territorialmente por medio de la construcción de viviendas ubicadas en la periferia de la ciudad. En el sector nororiente, ha predominado la construcción de suburbios de baja densidad y condominios cerrados, y en los sectores norponiente, surponiente y suroriente ha habido a un fuerte incremento en la construcción de viviendas sociales y de estratos de niveles medios (Gaete, 2021).

El Gran Concepción es una conurbación ubicada en la zona centro sur de Chile, compuesta por diez comunas: Concepción, Coronel, Chiguayante, Hualpén, Hualqui, Lota, Penco, San Pedro de la Paz, Talcahuano y Tomé, todas ellas pertenecientes a la provincia de Concepción, ubicada en la denominada octava región del Bío Bío. Según el censo de 2017, levantado por el Instituto Nacional de Estadísticas (INE), la población del área metropolitana de Concepción alcanzó los

971.285 habitantes, lo cual representa el 5,53 % del total de la población del país, y contempla un crecimiento de un 10% aproximadamente en relación con el censo del año 2002.

Los datos del Censo muestran un aumento de más de 300 mil viviendas en los últimos 15 años, pasando de cerca 2 millones en 2002 a 2.3 millones en 2016. Sin embargo, el crecimiento ha sido dispar entre las distintas comunas (Instituto Nacional de Estadísticas, 2017).

Tal como se señaló, se plantea un modelo basado en los autómatas celulares (Barrios, 2016; Cepeda y González, 2009) para proyectar el signo de las variaciones del valor de suelo urbano. El diseño del modelo considera redes de autómatas simples conectados localmente. Cada autómata simple produce una salida a partir de varias entradas, modificando en el proceso su estado según una función de transición denominada regla, donde un enrejado uniforme y regular, que es por lo regular extenso con una variable discreta para cada sitio, denominada célula, ve afectado el valor del sitio de la variable por el valor de una variable que se encuentra en una vecindad en previos tiempos determinados (Barrios, 2016).

Las vecindades son los sitios alrededor de cierta célula, las variables de cada sitio están sincronizadas, basadas en los valores de las variables en sus vecindades y prescindiendo del tiempo. En principio, se busca evaluar distintos periodos de tiempo, verificando cual entrega una mejor predicción. Además, debido a que la base de datos posee ciertas limitaciones en cuanto a datos mensuales, se realizan diversas pruebas.

Se considera para cada prueba antes mencionada, primero la variación porcentual y luego la variación por diferencia, con el fin de verificar la mejor forma de predicción. Es decir, dados los valores, se calculan las variaciones mensuales o trimestrales que servirán como inputs dentro del modelo. Como variación porcentual se debe entender el cambio porcentual que experimentó el precio de un mes a otro, o de un trimestre a otro. Y como variación por diferencia se debe entender la simple diferencia en el valor de un mes a otro.

Realizadas algunas pruebas, para buscar mejorar la predicción y fiabilidad de los resultados, se utiliza las variaciones reales de un mes a otro. En aquellos periodos en donde no se encuentren datos, se dejarán vacíos y no se considerarán en la predicción ni en el cálculo de acierto. Por tanto, el modelo busca proyectar el signo de las variaciones del valor de suelo. Cada observación, es decir, cada variación ya sea mensual o trimestral, se considera como una celda. Cada una de estas celdas puede adoptar dos posibles estados: positivo o negativo según haya sido el signo de la variación.

Los datos utilizados corresponden al valor mensual de los distintos sectores del territorio urbano del gran Concepción, los cuales corresponden a: Concepción, Talcahuano, Hualpén, Chiguayante, San Pedro y Penco – Lirquén (tabla 1).

Tabla 1. Sectores por comuna Gran Concepción, Chile.

Comuna		Sector	
I	Concepción	I	Centro
		II	Norte
		III	Lorenzo Arenas
		IV	Costanera
		V	Camino a Penco
		VI	Nonguén
II	San Pedro	VII	San Pedro
		VIII	Boca Sur
III	Chiguayante	IX	Chiguayante
		X	Lonco
IV	Penco	XI	Penco
		XII	Lirquén
V	Talcahuano	XIII	Talcahuano Centro
		XIV	San Vicente
		XV	Higueras / Las Salinas
VI	Hualpén	XVI	Hualpén

Fuente: elaboración propia en base a los datos de la Universidad del Bío-Bío de Chile.

Estos datos fueron entregados por el Laboratorio de Estudios Urbano del Departamento de Planificación y Diseño Urbano de la Universidad del Bío-Bío de Chile, y consta de 108 observaciones mensuales para cada sector antes individualizado, 36 observaciones trimestrales, correspondidas entre los periodos de enero del año 2010 y diciembre del año 2018.

Para poder llevar a cabo la metodología, se calculó las variaciones entre un mes y otro, y entre un trimestre y otro, para cada sector y comuna. Con esto se obtuvieron 107 y 35 observaciones respectivamente. La fórmula de cálculo se muestra en la ecuación (1), obteniendo variaciones mensuales/trimestrales porcentuales.

$$\text{Variación del Precio} = \frac{P_{n-1} - P_n}{P_{n-1}} \quad (1)$$

Dónde:

- P: precio del metro cuadrado.
- n: corresponde al mes.

Las condiciones iniciales del modelo están dadas por las variaciones del primer mes o trimestre de la serie histórica de observaciones que se considera para el estudio. El estado futuro de la celda está representado por el signo de la variación proyectada para ese mismo activo. Es decir, todos los sectores/comunas son vecinos(as) de todos y, por lo tanto, todos ejercerán influencia. Del total de observaciones que componen la muestra, se obtienen las variaciones de los sectores o comunas, de las cuales se deben promediar los resultados obtenidos entre las vecindades, para obtener un porcentaje de predicción, y así ser transformadas a “estados”, los que se definirán de la siguiente manera:

- Si el promedio de la vecindad es mayor a cero, entonces el estado correspondiente será a 1. Lo que indica que la variación en el precio ha estado al alza con respecto al periodo anterior.
- Si el promedio de la vecindad es menor a cero, entonces el estado correspondiente será a 0. Lo que indica que la variación en el precio ha estado a la baja, o se mantuvo, con respecto al periodo anterior.

En los siguientes modelos se utiliza como función de contagio lo que se hace es contar el número de variaciones positivas y negativas que se encuentran en las celdas vecinas respectivas de cada modelo, y para cada una de las celdas que representan las variaciones (Barrios, 2016). Con la finalidad de optimizar los resultados, se probaron todas las combinatorias de reglas posibles a través de un algoritmo.

Entonces, la aplicación de Autómatas Celulares a una muestra entregaría evidencia de que existe cierto grado de contagio por expectativas que explicaría en parte las variaciones de los precios. Las condiciones necesarias para aceptar las hipótesis planteadas en la investigación son (Barrios, 2016):

- Obtener un indicador de predicción de signo (PPS) promedio mayor a 50%.
- El porcentaje de predicción de signo debe cumplir con un criterio de significancia estadística. Para esto será considerado el test de significancia el Test de acierto Direccional planteado por Pesaran y Timmerman (1992).

La evaluación de la capacidad de predicción se realizará en función del porcentaje de predicción de signo (PPS) extramuestral alcanzado. Para calcular el PPS, se compara el signo de la variación proyectada con el signo de la variación observada real en cada t-ésimo período proyectado, comenzando desde t+1. Si los signos de la variación proyectada y la variación observada son los mismos, entonces se anota un 1, lo cual representa un acierto o *hit*. En caso contrario, se anota un 0, lo que señala un error de predicción del modelo. Si los signos coinciden aumentan la efectividad del modelo y en caso de no existir coincidencia, aumenta el error de la predicción. Luego, se calcula el porcentaje de aciertos del total de predicciones evaluadas.

El test anteriormente enunciado compara el signo de la proyección con el del valor observado para cada i -ésima observación del conjunto extramuestral; donde el signo indica la dirección en que se moverá el mercado inmobiliario: al alza, si es positivo, o a la baja, si es negativo. Si los signos coinciden, aumentan la efectividad del autómata, y en caso de no existir coincidencia, aumenta el error de predicción.

Luego, se calcula un ratio de éxito (SR) que se define en la ecuación (2):

$$SR = m^{-1} \sum_{i=1}^m I_i [y_i, \hat{y}_i > 0] \quad (2)$$

Dónde:

- M: es el número de observaciones.
- I : es una función indicador que toma valor “1”, cuando el argumento es cierto y “0” cuando el argumento es falso.
- Y_i : variación observada.
- \hat{y}_i : variación proyectada.

Si no hay coincidencia entre el signo proyectado y el signo observado, el producto entre ambos será negativo y, en consecuencia, el modelo evidenciará un error en el pronóstico por lo que la función tomará el valor de 0. Luego, al aplicar sumatoria se tendrá como resultado el número total de aciertos en la proyección de signo. Finalmente, al dividir la suma en el número de pronósticos realizados, se obtiene el ratio de éxito y que puede ser interpretado como la probabilidad de que el modelo acierte en la predicción de signo.

Por otra parte, el ratio de éxito en el caso de independencia de \hat{y} e y , está dada por la ecuación siguiente (3):

$$SRI = P * \hat{P} + (1 - P) * (1 - \hat{P}) \quad (3)$$

Dónde:

- P: número de variaciones observadas con signo positivo.
- \hat{P} : número de variaciones proyectadas con signo positivo.

Cuya varianza será la ecuación (4):

$$VAR(SRI) = m^{-2} [m(2\hat{P} - 1)^2 P(1 - P) + m(2P - 1)^2 \hat{P}(1 - \hat{P}) + 4P\hat{P}(1 - P)(1 - \hat{P})] \quad (4)$$

Por su parte, la varianza del ratio de éxito (SR) se define como:

$$VAR(SR) = m^1 * SRI * (1 - SRI) \quad (5)$$

Finalmente, el test DA de Pesaran & Timmermann (1992) está dado por:

$$DA = \left[(VAR(SR) - VAR(SRI))^{-\left(\frac{1}{2}\right)} * (SR - SRI) \right] \quad (6)$$

Como dicho test sigue una distribución normal estándar. Es decir, si el valor DA está entre los valores de rechazo, no se rechaza la hipótesis nula de que las variaciones observadas están independientemente distribuidas de las variaciones proyectadas.

RESULTADOS Y DISCUSIÓN

Los resultados obtenidos de la aplicación de los autómatas celulares anteriormente descritos se pueden apreciar en las tablas, utilizando variaciones de valores mensuales y trimestrales, respectivamente. En la tabla 2 se muestra el modelo utilizando variaciones mensuales agrupadas por cada comuna. Asimismo, se consideró aquellos meses donde no existen datos se consideró como 0 en la variación.

Tabla 2. Resultados del modelo 0

Comunas	PPS	Test DA	
Concepción	55,5%	3,40364	Rechaza
San Pedro	55,3%	-1,04621	No Rechaza
Chiguayante	55,8%	5,01130	Rechaza
Penco	66,0%	-1,15533	No Rechaza
Talcahuano	62,3%	4,75079	Rechaza
Hualpén	66,0%	-1,98431	Rechaza
61,1%			

Fuente: elaboración propia en base a los datos recabados para la investigación.

En tanto, en la Tabla 3, se explicita el modelo utilizando variaciones trimestrales agrupadas por cada comuna. Se construye dos tipos. Modelo 1: donde se explicita función de evolución considera promedio de las variaciones en la vecindad de cada célula El Modelo 2: Función de evolución considera 25 reglas de evolución. Para ambos casos sólo se consideran datos de variaciones reales. En los periodos donde no se presentan datos, se deja como espacio en blanco, no incluyéndolos en el cálculo.

Tabla 3. Resultados de los modelos 1 y 2

Comunas	Modelo 1			Modelo 2		
	PPS	Test DA		PPS	Test DA	
Concepción	64,7%	1,7414	No Rechaza	47,1%	-1,5202	No Rechaza
San Pedro	64,5%	1,7458	No Rechaza	45,2%	-3,2637	Rechaza
Chiguayante	55,9%	0,7077	No Rechaza	47,6%	-1,7636	No Rechaza
Penco	22,2%	-3,2552	Rechaza	13,3%	-21,9181	Rechaza
Talcahuano	59,4%	1,1143	No Rechaza	51,3%	1,6895	No Rechaza
Hualpén	50,0%	0,0000	No Rechaza	40,0%	-5,9546	Rechaza
	52,8%			40,7%		

Fuente: elaboración propia en base a los datos recabados para la investigación.

En la tabla 4, se presenta el modelo utilizando variaciones trimestrales agrupadas por cada comuna, eliminando comunas con menor cantidad de datos. Modelo 3: Se elimina la comuna de Hualpén. Modelo 4: Se elimina, además de la comuna de Hualpén, la comuna de Penco. En este caso, se consideraron datos de variaciones reales. En los periodos donde no se presentan datos, se deja como espacio en blanco, no incluyéndolos en el cálculo.

Tabla 4. Resultado de los modelos 3 y 4

Comunas	Modelo 3			Modelo 4		
	PPS	Test DA		PPS	Test DA	
Concepción	52,2%	1,4994	No Rechaza	57,8%	3,6887	Rechaza
San Pedro	46,8%	-1,9237	No Rechaza	48,4%	-0,9588	No Rechaza
Chiguayante	49,3%	-0,6943	No Rechaza	48,0%	-1,0232	No Rechaza
Talcahuano	52,3%	2,0980	Rechaza	57,3%	3,6316	Rechaza
Penco	13,9%	-17,6438	Rechaza	-	-	-
	42,9%			52,9%		

Fuente: elaboración propia en base a los datos recabados para la investigación.

Como se puede apreciar en los resultados anteriormente expuestos, el mayor nivel de acierto en la predicción (PPS) se obtiene con el primer modelo, donde la media alcanza un 61,1%, con 64% para la comuna con mejor resultado. Además, se obtiene buena capacidad predictiva según el test de acierto direccional. Sin embargo, estos resultados probablemente no reflejen la realidad del modelo, debido a que, como en la base de datos existen vacíos, estos fueron considerados como valor 0, mismo valor que se le asignó a las variaciones negativas. Es por esto que se buscó otras formas de predicción para poder obtener resultados más fiables.

Al analizar los otros modelos realizados, podemos observar que para el Modelo 1, el cuál agrupa las variaciones de cada comuna por trimestres con la finalidad de mejorar la base de datos y reducir los *falsos positivos*, y donde se consideró el promedio de la vecindad versus el promedio de la célula para determinar el estado futuro, se obtuvo un valor de predicción promedio sobre el 50%, pero con muy malos resultados en cuanto a significancia estadística en un nivel de confianza del 5%. Esto reafirma que, pese a mejorar la base, siguen existiendo problemas debido a la cantidad de datos.

Por otro lado, el modelo 2, donde se utilizan 25 reglas de evolución para optimizar los valores obtenidos, consigue mejores niveles de capacidad predictiva pero con niveles de acierto inferiores, lo que se puede explicar dado que existen comunas como Penco y Hualpén donde la cantidad de observaciones es muy baja, influyendo negativamente en las otras comunas y en los resultados del modelo.

Por lo anterior es que se decide probar quitando comunas del modelo 2 para así evaluar los resultados buscando mejoría evitando que la falta de datos afecte a las comunas con bases de datos más contundentes. Siguiendo lo anterior, es que en el Modelo 3 se quitó la comuna de Hualpén, provocando mejores niveles de predicción pero aún bajos índices de capacidad predictiva, por lo que el modelo sigue siendo poco fiable.

Finalmente, en el Modelo 4 se quita además la comuna de Hualpén, logrando nuevamente un alza en los porcentajes de predicción, superando el 50% promedio, con 57% aproximadamente para las comunas de Concepción y Talcahuano, coincidentemente las comunas en las que se cuenta con mayor cantidad de datos, obteniendo además buenos resultados en el test de acierto direccional, teniendo estos dos autómatas la capacidad de predecir el signo en las variaciones de precio de suelo.

CONCLUSIONES

Tras el análisis de las variaciones del valor promedio del metro cuadrado de suelo perteneciente al Gran Concepción, para las comunas de Concepción, Penco, Hualpén, San Pedro,

Chiguayante y Talcahuano, mediante el modelo predictivo basado en autómatas celulares, una de las conclusiones que se pueden exponer es el hecho de que mientras mayor es la cantidad de información, mejores son los resultados. Sin embargo, también se apreció que mientras más grande la base de datos más fiable es la predicción, lo que contrastó con los últimos modelos utilizados, ya que al agrupar las variaciones por trimestre se redujo considerablemente la extensión de la misma.

Dentro de las posibles explicaciones a los resultados obtenidos en la mayoría de las pruebas, es principalmente, como ya se ha mencionado, la falta de datos, debido a que la fuente de información no es constante para cada mes, existiendo muchos vacíos que afectan a la aplicabilidad del modelo, por lo que lo ideal sería mejorar este aspecto para evaluar nuevamente, esperando obtener mejores valores de predicción.

Sin embargo, esto no necesariamente rechaza la hipótesis de este trabajo, ya que no se cuenta actualmente con una base de datos completa con los precios, por lo que estos resultados podrían deberse a un problema por falta de datos más que en la metodología empleada, además otro posible problema es que no se consideraron otras variables para el contagio de las variaciones, tales como podría ser: la distancia entre las comunas, el tamaño geográfico, entre otras cualidades, lo cual daría para nuevas investigaciones.

REFERENCIAS BIBLIOGRÁFICAS

- Banco Central de Chile. (2019). Informe de Estabilidad Financiera. Santiago. Link: <https://www.bcentral.cl/contenido/-/detalle/informe-de-estabilidad-financiera-segundo-semester-2019>
- Barrios, M. (2016). Análisis de las variaciones de precio en el mercado inmobiliario del Gran Concepción para el periodo 2010 – 2015, a través del modelo predictivo autómatas celulares. Facultad de Ciencias Empresariales, Universidad del Bío Bío, Chillán de Chile, 101 pág.
- Cámara Chilena de la Construcción. (2019). Índice de Acceso a la Vivienda, CCHC. Santiago.
- Cavada, C. (2007). Aplicación de autómatas celulares en la predicción del movimiento de precios de bienes raíces. Facultad de Economía y Negocios, Universidad de Chile, Santiago de Chile, 26 pág.
- Cepeda, A. y Gonzáles, G. (2009). Predicción de variaciones de precio en el mercado inmobiliario mediante autómatas celulares. Facultad de Economía y Negocios, Universidad de Chile, Santiago de Chile, 28 pág.

- Colliers International (2019). Colliers International. Link: <https://www2.colliers.com/es-CL/News/Santiago/Rentabilidad>
- Encinas, F., Truffello, R., Aguirre, C., & Hidalgo, R. (2019). Especulación, renta de suelo y ciudad neoliberal. O por qué con el libre mercado no basta. ARQ (Santiago), (102), 120-133. <https://dx.doi.org/10.4067/S0717-69962019000200120>
- Gaete, H. (2021). Tendencias del mercado de suelo urbano en periodo largo. Concepción, Chile. 1989-2018. ACE: Architecture, City and Environment, 16(46), 9946. DOI: <http://dx.doi.org/10.5821/ace.16.46.9946>
- Gasic, I. (2018). Inversiones e intermediaciones financieras en el mercado del suelo urbano. Principales hallazgos a partir del estudio de transacciones de terrenos en Santiago de Chile, 2010-2015. EURE (Santiago), 44(133), 29-50. <https://dx.doi.org/10.4067/s0250-71612018000300029>
- Gil-Alana, L., Dettoni, R., Costamagna, R., & Valenzuela, M. (2019). Rational bubbles in the real housing stock market: Empirical evidence from Santiago de Chile. Research in International Business and Finance, 49, 269-281. <https://doi.org/10.1016/j.ribaf.2019.03.010>
- Henríquez, Cristián, & Azócar, Gerardo. (2006). Cambio de uso del suelo y escorrentía superficial: aplicación de un modelo de simulación espacial en Los Ángeles, VIII Región del Biobío, Chile. Revista de geografía Norte Grande, (36), 61-74. <https://dx.doi.org/10.4067/S0718-34022006000200004>
- Instituto Nacional de Estadísticas. (2017). Censo de población y vivienda, INE Chile.
- López-Morales, E., Sanhueza, C., Espinoza, S., & Órdenes, F. (2019). Verticalización inmobiliaria y valorización de renta de suelo por infraestructura pública: un análisis econométrico del Gran Santiago, 2008-2011. EURE (Santiago), 45(136), 113-134. <https://dx.doi.org/10.4067/S0250-71612019000300113>
- Padilla, O., Pérez, P., Cruz, M., Huilcamaigua, S., & Astudillo, S. (2015). Utilización de autómatas celulares como técnica de modelamiento espacial para determinación el cambio de uso de suelo y cobertura vegetal. Ciencias Espaciales, 8(1), 310–326. <https://doi.org/10.5377/ce.v8i1.2055>
- Pesaran, M.H. & Timmermann, A. (1992). A Simple non Parametric Test of Predictive Performance, Journal of Business and Economic Statistics, 10 (4), pp. 461-65 DOI: [10.1080/07350015.1992.10509922](https://doi.org/10.1080/07350015.1992.10509922)
- Talero-Sarmiento, L. H., Duarte-Duarte, J. B., & Garcés-Carreño, L. D. (2017). La complejidad del mercado bursátil latinoamericano a partir de un modelo autómatas celular

conductual. Apuntes del CENES, 36(64), 199-223.
<https://doi.org/10.19053/01203053.v36.n64.2017.5421>

Vergara-Perucich, J. F. (2021). Determinantes urbanos del precio de la vivienda en Chile: una exploración estadística. Urbano, 24(43), 40 - 51.
<https://doi.org/10.22320/07183607.2021.24.43.04>