

學術論著

## 結合時空因子的大量估價模型應用： 桃園蛋白、蛋黃、邊緣區的分析比較

### Application of Mass Appraisal Models with Time and Space Factors: Analysis and Comparison of Core, Inner Suburbs, and Outer Suburbs of Residential Properties

周淑卿\* 王怡婷\*\* 江明珠\*\*\*

Shu-Ching Chou\*, Yi-Ting Wang\*\*, Ming-Chu Chiang\*\*\*

#### 摘 要

本文以桃園市中古住宅大樓2018年至2020年的房產交易資料為對象，應用地理加權迴歸時間數列法(geographical weighted regression-time series, GWR-TS)建立房價特徵模型(Fotheringham et al., 2015)。首先，觀察特徵的隱含價格在蛋白、蛋黃、邊緣區的時、空分佈差異，再預測桃園市未來的房價，與傳統的最小平方法(ordinary least square, OLS)估計之特徵估價模型比較，並檢驗兩模型的預測表現。研究結果發現，蛋黃區、蛋白區及邊緣區房價的差異主要是受區域因素的影響。其次，住宅特徵的隱含價格會隨時間而變化，並受住房市場景氣影響，數值在空間中出現收斂的漣漪現象。實證結果證實GWR-TS模型的預測能力及配適度均優於OLS模型。

關鍵詞：房價、空間異質性、地理加權迴歸、特徵估價模型

(本文於2021年10月4日收稿，2021年12月20日審查通過，實際出版日期2023年6月)

\* 國立雲林科技大學財務金融系教授

Professor, Department of Finance, National Yunlin University of Science & Technology, Yunlin, Taiwan.

E-mail: chouc@yuntech.edu.tw

\*\* 國立雲林科技大學財務金融系碩士

Department of Finance, National Yunlin University of Science & Technology.

E-mail: y28861858@gmail.com

\*\*\* 國立雲林科技大學財務金融系教授，通訊作者

Professor, Department of Finance, National Yunlin University of Science & Technology, Yunlin, Taiwan.

E-mail: mingchuc@gemail.yuntech.edu.tw

本篇論文承蒙科技部專題研究計劃「109-2410-H-224-030-」補助，特此感謝；作者感謝感謝主編及匿名審查委員提供的寶貴意見，文中若有任何謬誤當屬筆者之責。

## ABSTRACT

This paper studies the real estate transaction data of Taoyuan City from 2018 to 2020 and applies geographic weighted regression with time series (GWR-TS) approach (Fotheringham, Crespo, & Yao, 2015) in modelling the hedonic housing price. This paper observes the temporal and spatial differences of the implied prices in the core, inner suburb, and outer suburb and forecasts the future housing prices. Then the prediction performance of hedonic model applying GWR-TS and OLS are compared. The empirical results show that, first, the difference in housing prices in the core, inner suburbs, and outer suburbs is mainly affected by regional factors. Second, the implicit price of the hedonic model changes over time. The values which may be related to the rapid cooling of the housing market appear to converge during study period, a phenomenon that is similar to ripples effect. Finally, the model prediction ability and goodness-of-fit of GWR-TS are superior to the traditional OLS hedonic model.

**Key words: House prices, Spatial heterogeneity, Geographical weighted regression, Hedonic model**

### 一、前言

準確訂價是不動產市場永續發展的先決條件，為活絡不動產相關活動及促進決策效率的基礎，因此提供正確、迅速的價格評估模型至關重要。傳統的估價模型是根據Lancaster(1966)新消費者需求理論的概念為基礎而建構，Rosen(1974)同時考慮消費者與生產者行為，據以發展出特徵價格理論(hedonic price model)，此為不動產價格估計的基礎。傳統的特徵價格模型將各住房特徵的隱含價格視為靜態的常數，在一般迴歸的全域(global)架構中，若研究樣本資料間的關係會隨空間而變化，則模型的估計值的標準誤會偏大而缺乏效率，殘差項之間就會出現顯著的空間自我相關現象(spatial autocorrelation) (Cliff et al., 1981; Basu & Thibodeau, 1998)。

殘差間具空間自我相關的原因與空間異質性(spatial heterogeneity)有關。空間異質性是指樣本資料間的關係會因位置改變，無法由簡單的全域模型完全解釋的現象(Brunsdon, Fotheringham, & Charlton, 1996)。Brunsdon et al.(1996)發展了一個屬於局部(local)空間統計技術的地理加權迴歸(geographical weighted regression, GWR)模型，來捕捉資料間的空間關係，以解決在簡單的全域模型中存在、卻無法解釋的空間異質性現象。由於GWR估計的參數及其權重會根據資料點所在的空間位置而修正，就可從觀察參數估計值在局部空間中的變化，判斷自變數對房價在空間中差異的影響，提供更有意義的空間資訊，此為GWR的重要優勢之一。

GWR針對住房資料基於「局部」觀點的估計方式，也類似住房「次市場」概念的應用。因為GWR的「局部」估計是基於距離接近之住房單元資訊，這些住房單元通常具有類似的區域、鄰里…等特徵，能提供更多的資訊來估算住房特徵的邊際價格，並提高估價的正確性與參考性。這與不動產估價的比較法以數個近鄰地區比較標的為出發，估計特定勘估標的價格水準概念一致。因此，相較於一般「全域」特徵價格模型賦予每一住房特徵之邊際價格固定的值，GWR的參數估計會順應空間(次市場)的變動而調整，將能提供更合乎估價實務觀點的估計結果，此為應用GWR法的優點。GWR的另一個優點是，在以預測住房價格時，即便樣本外資料與樣本內資料之所在位置不同，但基於樣本外資料所在位置的局部估計值仍可以透過GWR的外插法得到 (Harris, Fotheringham, Crespo, & Charlton, 2010)，因此GWR可以如同傳統

特徵價格模型，在給定的住房特徵及空間位置條件下預測住房價格。

過去在房價模型上的文獻，不是僅從空間架構(e.g. Osland, 2010; Li & Saphores, 2012; de Araujo & Cheng, 2017)或是由時間架構(e.g. Sheppard, 1999; Cebula, 2009; Lisi, 2019)來建立房價模型。然而，房價走勢、房價上漲率、以及和屋齡有密切關係的折舊率…等都會使住房價格隱含了時間效果(Dombrow, Knight, & Sirmans, 1997)，房價模型應同時考量時間與空間因素，才能合適的捕捉房價變化的過程。過去學者提出納入時間與空間因素的全域模型(e.g. Pace, Barry, Gilley, & Sirmans, 2000; Helbich, Brunauer, Vaz, & Nijkamp, 2014)，而應用GWR相關方法建立的局部房價模型，國外文獻已有許多證據(Bitter, Mulligan, & Dall'erna, 2007; Osland, 2010; McCord, Davis, Haran, McGreal, & McIlhatton, 2012; Lu, Charlton, Harris, & Fotheringham, 2014; Fullerton & Bujanda, 2018; Cao et al., 2018; Cajias & Ertl, 2018)，本文將應用同時考慮時間與空間因素的GWR-TS局部模型，提供實證研究結果以補足台灣房市的證據。本研究欲使用2018年至2020年間桃園區中古大樓住房交易資料為對象，應用GWR-TS模型建立桃園市房價模型，並與一般普通最小平方方法(ordinary least square, OLS)估計的特徵價格模型比較，以討論模型的配適度及預測績效。

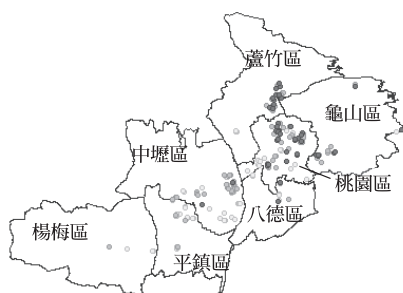
本文以桃園為研究對象的第一個原因是，桃園具有六都中少見的差異發展特性。桃園市於2014年底升格為直轄市後，在機場捷運陸續完工、台商回流使工業區使用率大增，加上近年持續進行的航空城計劃，種種的發展使桃園市近年發展產生重大變化。桃園市為台灣的工業重鎮，其發展大致可以分為南、北兩大區域，北桃園(註1)靠近台北市，隸屬首都生活圈的範圍；南桃園則接近新竹，屬於桃竹苗生活圈，這兩大區域分別和其臨近的都市互動密切，使桃園市之南、北發展呈現差異的樣貌。上述差異若以全域的特徵價格模型執行估價，則僅能顯示模型中各特徵的“平均”邊際價格，而無法考量因為區域的差異而會有的空間不恆定性。

其次，桃園市臨近大台北都會區，與以商業為主的大台北地區間的關係，原本類似台南市和高雄市，各自發展的態勢，不像新北市長期以來在人口流動及經濟、投資的發展上，如同台北市的衛星城市一般，與台北市關係密切。然而近年來，由於雙北地區房價高漲，桃園市由於高鐵、捷運等重大交通建設縮短與大台北都會區的距離，吸引雙北人口往桃園移入，促成近幾年桃園房市交易的熱絡。在研究期間內，桃園市住房市場從復甦到熱絡，卻因疫情影響而急凍。

因此，由於桃園市存在六都中少見的差異發展特性，以及景氣的急劇變化，成為應用地理加權迴歸模型來驗證空間異質性，並觀察住房特徵在時間及空間內變化的最佳對象。因為桃園市在研究期間的發展及房市景氣的變化極大，本文也比較住房特徵在桃園市蛋黃區、蛋白區及邊緣區的差異及變化，期望能以桃園房市的證據，勾勒出都市發展的樣貌。由於桃園市是大台北都會區的次核心都市，相關的研究證據也可以做為都會區次核心城市房市發展的參考。例如，臨近台中市的彰化，以及臨近高雄市屏東，未來可能因捷運或高鐵等交通設施的連結，而受直轄市人口及經濟的外溢效果的影響，因此桃園市住房市場的研究證據，也可供政府未來都市規劃，或制定房價政策參考。

圖一取桃園市人口密集的7個行政區10-20年屋齡之中古屋價格進行分析，將房屋價格區分成高、中、低三個區間，比較研究期間7個行政區的平均房價分佈，其中，顏色愈深的點代表高價位，顏色愈淡為低價位，從圖中可以發現，高價、中價區出現在某些特定區域，例如，

高價區(蛋黃區)分別聚集在桃園區、蘆竹區南邊、接近桃園區的龜山區邊界及中壢區，這些群聚點所在的位置相當接近桃園機場捷運週邊及重劃區，代表區域因素可能是造成同一群聚間房價相近的原因。而中價區(蛋白區)住房約分佈於高價位住房外緣的八德區、平鎮區，資料點亦明顯在空間中有群聚現象。低價位住房的分佈似乎較為分散，在中壢區南邊靠近八德區，龜山區等有比較明顯的低價位群聚。這些證據都指出，房價在空間中的分佈非恆定，而會隨著位置不同，住房價格間的關係也會不同，因此從空間角度來建立估價模型有其必要性。



圖一 2018年至2020年桃園市平均房價走勢分佈圖

說明：顏色愈深的點代表高價位，顏色愈淡為低價位

根據Wang & Li(2019)，不動產的“大量估價2.0”正朝向3I：結合人工智慧(Ai)、地理資訊系統(GIS)及混合模型(mix-model)的趨勢發展。GWR模型是以GIS為基礎的模型，本文透過GWR加上時間數列估計法的組合模型進行研究，希冀此一嘗試能延伸出更多的應用。然而，本研究為顧及資料的完整性及正確性，經由人工過濾及收集之桃園市中古大樓交易資料仍有限，日後交易資料益趨龐大後，考慮影響住房價格變數的動態行為，應適切地納入人工智慧(Ai)輔助估價，將有助於提升模型預測的精確度。此為本文之研究限制及未來之研究方向。

本文結構如下，第一章為前言，第二章為文獻探討，第三章為研究方法，第四章為實證結果，最後為結論。

## 二、文獻回顧

不動產特徵價格模型之概念源自Lancaster(1966)之新消費者理論，Lancaster認為產品本身對消費者不會產生直接效用，效用乃是從產品蘊含的各項特徵產生。Rosen(1974)在同樣的概念下建立特徵價格理論，他指出，因產品由許多不可分割的特徵所組成，可藉由這些不可分割的特徵來估計不動產的價格。許多研究紛紛根據上述兩位學者的理論架構，建立不動產價格模型，來估計。特徵價格理論的優點是使用上簡便：在以迴歸係數值代表偏好的結構的假設下，只需給定住房價格、住房特徵，定義兩者間的關係式即可直接進行估計的方法，而每一特徵的迴歸係數值表徵的邊際價格，是在其他條件不變之下，代表該特徵對房價的個別效果。然而，特徵估價模型應用於住房市場是取決於幾個關鍵假設。首先，住房產品必需是同質的(homogeneous)；其次，住房市場需為完全競爭的型態；最後，特徵模型適用於住房市場



處於均衡狀態時，且特徵的隱含價格為常數，不會因房型和區域的不同而改變(Chau & Chin, 2003)。

顯然，住房市場的特性推翻上述關鍵假設，首先，住房是眾所周知的異質性(heterogeneous)的商品，住房市場並非完全競爭市場。另外，特徵的隱含價格為常數也受到質疑。一般傳統的特徵估價模型是在全域(global)架構下，不考慮空間屬性，以OLS估計的，因此固定的係數值在本質上即是空間中所有位置之參數的“平均值”。此外，OLS估計一般傳統的特徵估價模型建立在觀測值互相獨立的假設，若樣本資料間的關係會隨空間而變化，則模型的估計值的標準誤會偏大而缺乏效率，殘差項之間就會出現顯著的空間自我相關現象(spatial autocorrelation) (Cliff et al., 1981; Basu & Thibodeau, 1998)，Basu & Thibodeau(1998)認為，房價中存在空間自我相關性可以由住房之區域環境相同來解釋。因為同區域之住房常是同時開發，會傾向具有相似的房屋特徵，而且近鄰地區之住房的共用公共設施相同，而有類似的區域環境。這代表同一區域或同一次市場內的住房特徵及價格間的關係密切，而隨著空間距離越遠，住房資訊間的關聯性下降甚至消失，特徵的隱含價格將會隨著空間而變化的現象即為空間異質性(Brunsdon et al, 1996)。若特徵價格模型未能考量此特性，不僅將導致有偏誤的係數和解釋力的喪失，還可能掩蓋與住房市場運行相關的重要動態(Bitter, Mulligan, & Dall’erba, 2007)。Yu, Wei, & Wu(2007)認為，若特徵價格模型忽略空間資訊，將會誇大結構屬性和鄰里屬性對住房價格的重要性，也會忽略影響住房價格的攸關位置屬性，因為高估的係數值其實混合著住房屬性與空間資訊的影響。

Brunsdon et al.(1996)發展了一個屬於局部空間統計技術的GWR模型來捕捉樣本資料間的空间異質性，解決在簡單的全域模型中存在、卻無法解釋的空間異質性現象。GWR是每次以一個資料點為搜尋視窗，以該點與其他相近的資料點之距離為加權估計迴歸模型，因此GWR並非以一個趨勢平面來配適模型，而是允許空間中每一個資料點的參數實際地被估計和投影。他們應用GWR討論1991年英國新堡市的汽車擁有率與男性失業率及高社經地位家庭的比率的關係。Brunsdon, Fotheringham, & Charlton(1999)最早將GWR應用於房價模型，他們以英國肯特郡房價資料庫為樣本，討論一些參數在全域範圍內是固定的，但其他參數在地理上(局部)有所差異的“混合”GWR模型之配適結果，並提出檢定模型顯著性的統計方法。其後，由於GWR模型具有空間分析能力，能修正特徵估價理論並改善模型估計的精確度，GWR遂應用於建立各國的房價模型。

過去研究結果顯示，GWR與普通最小平方方法的傳統特徵價格模型相比，有較好的模型配適度與預測精確度，與其他空間迴歸模型相較，GWR也有不錯的績效表現。例如，Yu, Wei, & Wu(2007)以一般傳統的特徵價格模型和兩種加入空間資訊的模型，包括空間迴歸與GWR，檢驗空間自我相關如何影響住房價格模型，討論模型中的住房屬性和房價在空間中的關係，以及了解各種特徵模型的績效和預測能力。他們以2003年美國密爾瓦基市住房市場資料實證發現，與普通最小平方方法的傳統特徵價格模型相比，加入空間資訊的模型在模型績效和預測準確性方面表現得更好。Bitter, Mulligan, & Dall’erba(2007)則使用2000年美國亞歷桑維州的房價資料為樣本，比較GWR與空間擴展方法(expansion method)對房價的估計效率，實證結果是支持關鍵住房特徵的邊際價格會隨空間變化，且GWR在解釋能力和預測準確性均優於空間擴展方法。McCord, Davis, Haran, McGreal, & McIlhatton(2012)使用2010年英國貝爾法斯特的房地資

料，應用GWR討論住房價格的顯著影響因素，實證支持GWR在預測住房邊際價格上，比傳統的特徵估價模型有更高的準確性。Fullerton & Bujanda(2018)將GWR應用於商用不動產價格的評估，他們以105,611個美國德州埃爾帕索的商用不動產資料為樣本，使用GWR的實證分析結果證實，交通設施的鄰近性和可及性會提高商用不動產的價值，GWR模型之估計結果有更高的效率及正確性。

在亞洲房市的應用方面，Cao et al.(2018)則建立了三個特徵價格模型來探討新加坡公屋價格的空間變異，這三個模型包括普通最小平方法(OLS)模型，歐基里德距離為基礎的GWR，以及由旅行時間為距離的GWR。他們以2011年新加坡公屋交易資料之研究顯示，GWR模型均較傳統的特徵價格模型具有最佳的模型配適度。Wen, Jin, & Zhang(2017)以中國杭州2014年603個住宅小區的住房資料進行實證，發現住房特徵的隱含價格具空間異質性，也發現空間擴展模型和GWR模型均具有很好的模型配適度。

Bidanset & Lombard(2014)則從實務觀點來分析GWR的預測績效，他們根據國際評價者協會(International Association of Assessing Officers, IAAO)對不動產估價模型建立的標準，以分散係數(coefficient of dispersion, COD)和與價格相關的差異(price-related differential, PRD)衡量不動產估價之準確性和公平性。在比較GWR和空間落後模型(Spatial Lag Model, SLM)對美國維吉尼亞州諾福克2010年至2012年的單戶住宅資料估計結果後，發現GWR整體上比SLM有更一致的估計結果(GWR的COD更低)，並且兩模型都比未考慮空間資訊的全域模型有更好的一致性。

有鑑於住房價格是同時具有空間及時間特性的資料，房價走勢、房價上漲率、以及和屋齡有密切關係的折舊率…等都會使住房價格隱含了時間效果，而使價格極受市場近期事件或類似房產之前期價格的影響(Dombrow et al., 1997)。因此，為了考量房價的空間與時間特性，學者們延伸了GWR模型，將GWR一般化的擴展到時、空架構中。為同時捕捉空間和時間的異質性，Huang et al.(2010)將所有觀測值的住房價格以折現或複利調整到一個相同的日期做為時間變數，在加權矩陣中加入此時間變數，發展出地理及時間加權迴歸(geographically and temporally weighted regression, GTWR)。Huang et al.(2010)以2002年到2004年間，加拿大卡爾加里市住宅銷售資料討論包括了全域普通最小平方法、TWR、GWR和GTWR等四種模型的配適度，研究結果顯示，在測試樣本中，GTWR的絕對誤差(absolute error)為模型中最小、配適度最佳。

Fotheringham et al.(2015)則提出了一種結合多變量GWR和單變量時間序列(time series, TS)預測技術的新方法GWR-TS，他們使用數年的資料逐年以GWR估計特徵價格模型的局部參數，再使用Holt's指數平滑模型(exponential smoothing approach)來預測局部參數的未來值，再進一步預測未來的房價。他們在實證上使用倫敦1980至1997年的房價資料為樣本內資料，估計GWR的局部參數，了解倫敦住房價格之重要影響因素的時空變化，一個有趣的結果是，在研究期間內，局部參數估計值(也就是特徵的隱含價格)之高值或低值的群聚，傾向於在空間中逐漸擴大或緊縮，Fotheringham et al.(2015)認為這種類型的空間趨勢可以視為一種次市場自然的成長或萎縮，主要是受到住房市場的繁榮或蕭條之影響。Fotheringham et al.(2015)從單變量時間數列所預測的特徵的隱含價格為出發，進一步預測未來的房價的作法，具有兩種優勢，第一，可以避免Huang et al.(2010)之GTWR中，為了考量時間因素而可能錯誤定義加權矩陣格式，因為時間和空間屬於截然不同的兩個構面，能同時涵蓋兩個構面的核函數仍未知，這將影響GWR中加權矩陣的定義。Fotheringham et al.(2015)採用的單變量指數平滑方法，一方

面是因為此法能簡易地配適非季節性資料，同時此法在建立狀態空間模型時具統計上的穩健性，特別是針對短期預測時(Chatfield, 2004; Gardner, 2006)。

過去，國內學者以特徵價格模型為基礎，提出不同的模型改善建議來提高估價模型配適度，或是建立大量估價模型，使用大樣本的住房資料來觀察模型的預測表現。例如，廖咸興、張芳玲(1997)以市場比較法與特徵價格法概念結合的逼近調整法，與特徵價格法比較估價績效，研究結果顯示結合兩種方法的逼近迴歸調整法績效略優。張怡文等(2009)使用分量迴歸估計的特徵價格模型分辨台北市高總價豪宅和低總價小套房各特徵定價的差異，研究發現分量迴歸對於兩側尾端樣本有較佳的預測能力。陳樹衡等(2007)以決策樹中的Cubist迴歸樹建立住房價格模型，以台灣2002年至2004年間45,149筆住房資料為對象，研究發現特徵變數與住房價格之間存在非線性關係，Cubist迴歸樹不但有優於一般的特徵估價複迴歸模型的配適能力，也比其他無母數估計法還更具運算效率。賴碧瑩(2007)應用特徵價格及倒傳遞類神經網路建立估價模型，用以預測高雄市不動產價格。對總體樣本的配適方面，以倒傳遞類神經網路表現較佳，若先以樣本內資料估計之參數預測樣本外住房資訊，則特徵價格模型的績效較好。林祖嘉、馬毓駿(2007)以商業銀行在2002至2004年40,815筆總時價及18,637筆買賣成交價的資料為樣本，採用特徵方程式建立大量估價模型，並以絕對平均百分比誤差(MAPE)及命中率(hit-rate, HR)等指標來檢驗模型配適能力。結果發現，建物面積為決定住房價格的主要因素，在估計過程若未考慮時間因素，預測誤差將明顯加大。上述研究是於模型式中設定虛擬變數以顯示區域的差異，並未直接考量空間因素對住房價格的影響，此一設定顯然無法完全捕捉空間異質現象。

在國內研究中，李春長、童作君(2010)首先指出傳統的線性迴歸模型中忽略的空間的效果。他們以階層線性模型(hierarchical linear model)的研究發現，住房的建物特徵與價格的關係會隨著空間(縣市)不同而差異，未考量空間效果的模型將低估參數估計值的標準誤。林祖嘉、馬毓駿(2012)則是使用多層次貝式模型進行研究，他們同樣發現，住房特徵與住房價格間的關係會因所在區位而異，需要在模型中考量空間因素才能提高估價的精確度。鄒克萬等(2013)則是首先應用空間計量中的全域模型—空間誤差模式(spatial error model)在住房市場，討論高鐵營運對地價指數漲幅之影響，研究結果亦指出，高鐵周邊住房價格雖與場站距離呈反比，卻更受到場站周邊區域之發展的影響。

雖然國內文獻已具相當的特徵估價模型的實證證據，卻大部是從時間觀點，少有從空間計量的角度建立模型，特別是少見應用考慮空間變異及時間因素的局部特徵價格模型在住房市場中。因此本研究欲應用Fotheringham et al.(2015)發展的，屬於局部模型的GWR-TS來建立桃園區大樓住房交易資料估價模型並預測房價，將參數估計值的空間特性和模型的預測表現與一般OLS估計的特徵價格模型進行比較，以補足相關實證研究證據。

### 三、研究方法

自從Lancaster(1966)及Rosen(1974)為特徵估價模型建立了理論基礎後，此一特徵價格理論也大量被應用在住房的估價模型上。在過去文獻中，房價的特徵價格模型包括線性函數(linear)、半對數模型(semi-log model)、逆半對數模型(inverse semi-log model)及雙對數函數(double-log model)等函數型態。其中，Follain & Malpezzi(1980)所提出的半對數模型，其模型



的解釋較具經濟意涵，代表隱含價格的係數值，可解釋為該特徵變動一單位而導致房價變動的百分比，半對數模型還能改善變異數不齊一的問題。因此本研究特徵價格函數之形式是以半對數模型來設定。

以房屋交易總價取對數作為應變數，傳統的全域特徵估價模型如下所示：

$$y_i = \beta_0 + \sum_k \beta_k x_{ik} + \varepsilon_i \dots\dots\dots (1)$$

其中， $y_i$ 為第筆交易的總價取對數， $i = 1 \cdots n$ ， $\beta_0$ 為截距項； $\beta_k$ 為第*i*筆資料的第*k*個特徵之迴歸係數； $x_{ik}$ 為第筆資料的第*k*個自變數； $\varepsilon_i$ 為第筆*i*資料的誤差項向量。

根據Brunsdon et al.(1996)，GWR是擴展式(1)來估計模型的局部參數，模型如下所示：

$$y_i = \beta_0(u_i, v_i) + \sum_k \beta_k(u_i, v_i) x_{ik} + \varepsilon_i \dots\dots\dots (2)$$

其中， $(u_i, v_i)$ 為*i*筆資料在空間的經緯度座標； $\beta_k(u_i, v_i)$ 為第*i*筆資料的第*k*個特徵之迴歸係數，此係數值會隨空間座標而變化，可用以衡量空間的異質性。GWR的參數是根據在空間上接近*i*資料點所組成的局部校準子集(local calibration subset)估計而得，在參數估計前需要先有代表資料點間之空間相關性的權重矩陣，而權重矩陣乃是用資料點坐標計算之距離代入核函數計算而得。估計GWR時存在偏誤-標準間的抵換關係(bias and standard error trade-off)，意即，若估計參數時選擇距離越接近資料點*i*之位置的資料，將可以降低參數估計值的偏誤，然而，因距離越接近，有效樣本數下降，而提高參數估計值的標準誤，因此，有必要決定最適帶寬(optimal bandwidth)，即決定局部校準子集的資料點數量，來考慮此一抵換關係的影響。以矩陣表示的參數估計值計算如下所示：

$$\hat{\beta}(u_i, v_i) = [X^T W(u_i, v_i) X]^{-1} X^T W(u_i, v_i) y \dots\dots\dots (3)$$

其中， $W(u_i, v_i)$ 為 $n \times n$ 的對角線矩陣，對角線為每一*i*資料點的地理權重。

最適帶寬可以用極小化修正AIC (corrected Akaike information criterion,  $AIC_c$ )來選擇， $AIC_c$ 是根據最小化應變數的估計誤差而計算，為模型配適度與複雜度間的權衡，GWR的 $AIC_c$ 計算式如下：

$$AIC_c = 2n \log(\hat{\sigma}) + n \log(2\pi) + n \left( \frac{n + \text{trace}(\mathbf{H})}{n - 2 - \text{trace}(\mathbf{H})} \right) \dots\dots\dots (4)$$

其中， $\hat{\sigma}$ 是誤差的估計標準差， $\mathbf{H}$ 是帽子矩陣，矩陣的跡(trace)是矩陣對角元素之和。計算 $\hat{\sigma}$ 與 $\mathbf{H}$ 時會使用核帶寬， $\mathbf{H}$ 的每一行定義為：

$$H_i = X_i (X^T W_i X)^{-1} X^T W_i \dots\dots\dots (5)$$

而誤差的估計變異數為：

$$\hat{\sigma}^2 = \frac{\sum_k (y_i - \hat{y}_i)^2}{\{n - [2\text{trace}(\mathbf{H}) - \text{trace}(\mathbf{H}^T \mathbf{H})]\}} \dots\dots\dots (6)$$

$AIC_c$ 同時也是用以衡量模型配適度，可用以比較全局模型和GWR模型的表現。



以GWR得到局部參數估計值後，即可應用這些估計值來預測其未來值與房價，根據Fotheringham et al.(2015)的GWR-TS，參數的未來值是以Holt's單變量指數平滑法(exponential smoothing)計算，此法能簡易地配適非季節性資料，並且在建立狀態空間模型時具統計上的穩健性，特別是針對短期預測方面(Chatfield, 2004; Gardner, 2006)。指數平滑法之時間數列為：

$$S_t = \theta y_t + (1 - \theta) S_{t-1} \dots\dots\dots (7)$$

其中， $S_t$ 為時間 $t$ 的指數平滑值， $y_t$ 是時間 $t$ 的房價， $\theta$ 為參數平滑常數， $0 < \theta < 1$ 。時間數列的趨勢 $T_t$ 可表示為：

$$T_t = \gamma + (S_t - S_{t-1}) + (1 - \gamma) T_{t-1} \dots\dots\dots (8)$$

其中， $\gamma$ 是參數平滑常數， $0 < \gamma < 1$ 。 $\gamma$ 和 $\alpha$ 的最適值是透過最小化實際值及預測值間的平方誤差(squared error term)來確定。決定 $\gamma$ 和 $\theta$ 的最適值後，則 $h$ 期後之局部參數未來值計算如下：

$$\hat{y}_i(h) = S_i + hT_i \dots\dots\dots (9)$$

在驗證模型預測精確度方面，本文以絕對平均百分誤差(mean absolute percentage error, MAPE)來進行檢測，測試樣本的期間為2021年1月至4月，絕對平均百分誤差的定義為：

$$MAPE = \frac{\sum_{i=1}^n |e_i / y_i|}{n} \times 100\% \quad (y_i \neq 0)$$

$$e_i = y_i - \hat{y}_i \dots\dots\dots (10)$$

MAPE是衡量每一預測值與實際值差距相較於實際值的比例，在取絕對值後再加總並平減樣本數，最後以百分比的方式表示，此數值越大表示模型預測較差，其離散程度較大。

## 四、實證結果

### (一) 變數說明與資料初步分析


本文實證資料來自內政部實價登錄網站，包括從2018:Q1至2021:Q1的桃園市住房交易資料，在初步選出建物型態為大樓、屋齡約10-20年之資料後，再剔除非正常價格交易、有車位及異常值，共477筆中古住宅大樓交易資料。桃園市2018 - 2020年間平均房價與平均總價如表一。在研究期間內，桃園市中古住宅大樓交易的平均房價及總價均呈現上升趨勢，然而樣本數量代表的交易量卻逐年遞減，顯示交易量減少不影響房價的漲勢，推測交易量驟減可能是受到新冠肺炎疫情的衝擊。

表一 桃園市2018-2020年房價資料

年份	樣本數	平均房屋單價(萬)	平均房屋總價(萬)
2018	203	16.99	658.06
2019	176	17.13	660.76
2020	98	18.38	714.92

說明：樣本資料僅包含蘆竹、龜山、桃園、中壢、八德、平鎮及楊梅區之中古住宅大樓屋齡10-20年之資料，並剔除非正常價格交易、有車位及各變數之異常值。

若將樣本資料涵蓋的行政區以人口分佈的多寡分為蛋黃、蛋白及邊緣區，(註2)則三區在研究期間內之平均房屋單價趨勢如圖二。圖二顯示，三區的房價趨勢截然不同，蛋黃區的平均房屋單價為三區中最高，且蛋黃區和蛋白區的房價趨勢於2020年達到最高，型態較為接近，而邊緣區之房價趨勢從2018年的\$18.37萬略降至2019年的\$17.86萬再上漲至2020年的\$20.41萬，比較特別的是，2018及2019年邊緣區的平均房價都高於蛋白區，但至2020年，蛋白區的房價漲到\$17.26萬，超越邊緣區\$16.49萬漲幅約17%，為三區內最大。推測可能與邊緣區內工作機會增加，公共建設的日漸完備造成生活圈的擴展，及桃園航空城計劃…等因素的影響，造成購屋者往這些邊緣區移動所致。



圖二 蛋黃、蛋白及邊緣區之平均房屋單價

說明：蛋黃區包括桃園區、中壢區；蛋白區包括八德區、平鎮區；邊緣區包括楊梅區、蘆竹區、龜山區。

逐年分蛋黃、蛋白、邊緣區的樣本敘述統計資料如表二所示。整體而言，研究期間的住房樣本之平均總價與單價自2018年以來逐年上漲，以2018年的蛋白區為例，平均屋齡約為16.65年，平均建坪約為41.47坪，平均地坪約為6.52坪，平均移轉樓層約為8.00樓，平均臨路數約為2.44，臨路寬度平均為11.92公尺。

本文除了參考了過去文獻來決定住房特徵變數外，還以每一住房步行10分鐘(約900公尺內)內是否有迎毗與鄰避設施，設定鄰里和區域等屬性的虛擬變數，模型變數的定義如表三。

## (二) 模型估計結果

表四～表六為2018至2020年分別以OLS與GWR之模型估計結果。實證結果顯示，不僅房地個別的個因素顯著地影響房價，區域因素同樣也顯著地決定房價。從全域的OLS模型估價結果可知，首先，整體而言，房地個別因素中以建物移轉面積係數值在研究期間內均顯著為正，符合原先預期的影響，估計值約介於0.011至0.012，相當的穩健，代表住房建坪每增加1坪，總價會上漲約1.1%。而區域因素方面，則以是否有醫院、是否有消防隊對房價有負面的顯著影響，而且此兩種鄰避設施對房價的負向影響在2018年後幾乎是翻倍。例如，若住宅周圍900公尺內有醫院及消防隊，將使2018年的房價分別下跌8.5%及5.6%，而跌幅在2020年分別擴大至16.8%及14.8%。此外，實證結果也指出，住宅周圍900公尺內有捷運將會顯著提高房價，此一

表二 樣本敘述性統計

	房屋總價 (萬)	房屋單價 (萬)	屋齡 (年)	建築面積 (坪)	土地面積 (坪)	移轉 樓層	臨路數	臨路 寬度	
2018	<b>蛋黃區</b>								
	平均數	675.43	18.37	15.30	37.76	5.36	7.44	2.46	13.27
	標準差	106.38	3.52	2.89	7.83	2.21	4.12	0.98	6.09
	最小值	500.00	11.10	10.00	23.11	2.69	1.00	1.00	6.00
	最大值	940.00	25.10	20.00	63.66	11.51	16.00	4.00	30.00
	<b>蛋白區</b>								
	平均數	591.54	14.42	16.65	41.47	6.52	8.00	2.44	11.92
	標準差	66.62	1.83	2.95	5.66	1.64	4.20	0.66	6.39
	最小值	500.00	11.10	10.00	30.43	3.32	1.00	1.00	6.00
	最大值	800.00	19.20	20.00	65.17	9.10	18.00	4.00	30.00
	<b>邊緣區</b>								
	平均數	692.76	17.21	15.47	41.56	7.12	7.43	2.66	13.07
	標準差	98.48	3.87	2.22	7.91	2.81	3.70	0.83	5.24
	最小值	500.00	10.20	11.00	19.80	2.29	1.00	1.00	8.00
	最大值	900.00	29.00	20.00	55.61	13.04	14.00	4.00	35.00
2019	<b>蛋黃區</b>								
	平均數	664.60	17.86	15.27	38.11	5.30	6.63	2.28	13.07
	標準差	108.30	3.51	2.57	7.38	2.04	4.05	0.92	6.40
	最小值	500.00	10.40	10.00	28.42	2.39	1.00	1.00	8.00
	最大值	950.00	25.70	20.00	64.46	13.33	17.00	4.00	30.00
	<b>蛋白區</b>								
	平均數	607.31	14.68	18.11	41.59	6.84	6.91	2.31	13.06
	標準差	64.58	1.61	2.07	4.11	1.84	3.91	0.63	8.16
	最小值	510.00	12.00	13.00	34.29	3.32	1.00	2.00	4.00
	最大值	760.00	18.00	20.00	48.98	9.10	14.00	4.00	30.00
	<b>邊緣區</b>								
	平均數	693.48	17.51	15.28	41.17	7.15	6.43	2.70	16.41
	標準差	108.05	4.50	1.76	8.07	2.22	3.38	0.70	7.51
	最小值	500.00	10.20	11.00	19.80	2.29	1.00	1.00	8.00
	最大值	976.00	33.50	19.00	55.61	12.59	13.00	4.00	35.00
2020	<b>蛋黃區</b>								
	平均數	751.87	20.41	15.51	37.25	5.26	6.64	2.07	13.80
	標準差	120.74	3.34	1.67	5.93	1.88	4.07	0.86	5.40
	最小值	558.00	12.10	13.00	30.39	2.93	1.00	1.00	12.00
	最大值	1000.00	30.00	20.00	60.91	10.67	17.00	4.00	30.0
	<b>蛋白區</b>								
	平均數	602.09	17.26	14.36	34.88	4.72	8.91	2.91	17.82
	標準差	74.78	2.05	1.03	1.62	1.10	4.13	0.94	6.63
	最小值	510.00	15.20	13.00	32.22	3.11	3.00	2.00	6.00
	最大值	750.00	21.00	16.00	37.00	7.07	14.00	4.00	25.00
	<b>邊緣區</b>								
	平均數	704.88	16.49	16.88	44.15	7.94	7.21	2.60	12.83
	標準差	105.12	3.95	1.71	8.16	2.31	4.28	0.89	4.04
	最小值	505.00	10.20	11.00	23.17	2.71	1.00	1.00	8.00
	最大值	995.00	29.80	20.00	64.54	13.28	14.00	4.00	25.00



表三 模型變數定義

應變數	變數名稱	定義	預期影響	類型
	HOUSEPRICE	房屋總價取自然對數		Numerical
	LAND	以坪計算之土地移轉面積	+	Numerical
	BUILDING	以坪計算之建物移轉面積	+	Numerical
	FLOOR^2	所在樓層數之平方	+/-	Numerical
個別因素	AGE	屋齡	-	Numerical
	ROAD	臨路數	+	Numerical
	ROAD_WIDTH	臨路寬度	+	Numerical
	VIEW_D	是否為景觀棟	+	Dummy
自變數	SC_1	是否有國小	+	Dummy
	SC_2	是否有國中	+	Dummy
	PARK	是否有公園	+	Dummy
	HOSPITAL	是否有醫院	-	Dummy
區域因素	TEMPLE	是否有廟宇	-	Dummy
	GAS	是否有加油站	-	Dummy
	MARKET	是否有早市或黃昏市場	+/-	Dummy
	FIRE_DE	是否有消防局	-	Dummy
	TRAIN	是否有火車站	+/-	Dummy
	MRT	是否有捷運	+	Dummy

說明：區域因素中的變數從SC\_1至MRT為每一住房步行10分鐘(約900公尺內)內是否有該設施。

區域特徵的隱含價格在所有估計係數值中為最大，而且從初捷運試營運的2018年約17.8%，上升到2019年的48.6%及2020年的43.3%，這突顯交通可及性對房價的重要影響。另外，屋齡與房價的負向關係(兩年均約1.2%)僅存在於2018年及2019年，令人訝異的是，住宅步行10分鐘內有公園會降低2018年(係數值為9.1%)及2019年(係數值為11%)的房價，與原先預期不吻合。

由於GWR是以一筆住房交易資料為搜尋視窗，以該資料點與其他相近的資料點之距離為加權來進行參數估計的，因此若一年內有m筆住房交易資料，則在當年度影響房價的每一特徵均會有m筆估計值，表四至表六即是報導當年度各個特徵估計值之最小值、中位數值及最大值。表四、表五、表六分別代表2018年、2019年、2020年的GWR估計結果。比較各年度係數估計值的最大值及最小值的差距可以發現，區域因素之隱含價格的離散程度幾乎都比個別因素還大，這意謂著住房交易資料之間存在空間異質性，且在住房的區域因素更具異質性。此外，整體而言，代表區域因素的特徵比代表個別因素的特徵有更高的係數絕對值，代表區域因素在研究期間內對房價的影響大於個別因素之影響。

表四之2018年估計結果顯示，「有無捷運」似乎是影響房價最重要的區域因素，其最大的隱含價格甚至高達51%，代表若在離住宅10分鐘路程內有捷運，最高可以使總價漲51%，而從隱含價格的中位數來看，捷運亦會提高總價約20%，這樣的影響高於OLS的估計結果(約17.8%)。此外，離住宅900公尺內有醫院，最多會使總價降36.2%，遠高於OLS全域模型估計的8.45%。這是因為OLS的估計值是顯示模型中各特徵的“平均”邊際價格，並無法考量因為區域

表四 2018年OLS與GWR模型估計結果

	Min.	Medium (GWR)	Max.	Global (OLS)		
截距	5.8362	6.3799	6.5059	6.5029	(<2e-16)	***
土地移轉面積	<b>-0.0895</b>	-0.0206	-0.0098	<b>-0.0204</b>	(0.0055)	**
建物移轉面積	0.0084	0.0128	0.0232	0.0114	(0.0000)	***
所在樓層數	-0.0048	-0.0005	0.0054	0.0000	(0.9934)	
屋齡	-0.0171	-0.0135	-0.0045	-0.0117	(0.0033)	**
臨路數	-0.0036	0.0101	<b>0.0653</b>	0.0055	(0.6474)	
臨路寬度	-0.0059	0.0013	0.0078	-0.0042	(0.0242)	*
是否為景觀棟	-0.0015	<b>0.0244</b>	0.0467	0.0224	(0.3641)	
有無國小	-0.0002	0.0641	0.1147	0.0172	(0.8094)	
有無國中	-0.2653	-0.0784	0.0492	-0.0450	(0.0803)	
有無公園	-0.1211	-0.0602	0.1273	-0.0908	(0.0002)	***
有無醫院	<b>-0.3620</b>	-0.1300	0.0244	-0.0845	(0.0067)	**
有無廟宇	-0.0564	-0.0238	0.0562	-0.0129	(0.6012)	
有無加油站	-0.1419	-0.0628	0.0941	-0.0191	(0.3929)	
有無市場	-0.0552	-0.0071	0.2452	-0.0376	(0.1142)	
有無消防局	-0.2019	-0.0735	0.0913	-0.0560	(0.0469)	*
有無火車站	-0.2219	-0.1462	0.0688	-0.0610	(0.2445)	
有無捷運	-0.0209	<b>0.1934</b>	<b>0.5140</b>	<b>0.1775</b>	(0.0048)	**

說明：( )內為OLS模型之p值，\*、\*\*、\*\*\*為信賴水準90%、95%、99%下為顯著。Global代表以OLS之全域模型估計結果。Min、Medium、Max分別為GWR參數估計值的極小值、中位數、極大值。白底、灰底各代表個別及區域因素特徵估計結果。粗體字代表該類特徵是係數絕對值最大者，是對房價影響最鉅的兩個因素；而OLS中的粗體字代表該類特徵的係數值為顯著者中最大及次大者。

的差異而會有的空間異質性。土地移轉面積之隱含價格約為-9%，為個別因素的特徵中對價格影響最大者，此估計結果為負，與直覺似有差異。然而對照建物移轉面積的估計值，是合乎預期且隱含價格為正。推測可能是屋齡10-20年的大樓中古屋通常有較低的公設比，擁有的土地持分也相對較多，然而較多地坪帶來之好處低於建物折舊的負面影響，因此負的隱含價格可能代表中古大樓的折舊效果。

表五為2019年之估計結果顯示，捷運還是影響房價最重要的區域因素，其最大的隱含價格甚至接近60%，代表捷運可以使住房總價多60%，而隱含價格的中位數及最小值均高於2018年水準，捷運最少會讓總價增加約18%，因為所在區域差異的影響，這些數字是從OLS的估計結果(約49%)無法觀察得到。「是否有景觀棟」能讓總價最多增加約一成(約10.5%)，是2018年之估計結果(最多約5%)的兩倍。此結果指出，住房資料中因時間而產生的變化是不可忽略的。相較於2018年之土地移轉面積隱含價格約為-9%，在2019年此特徵的隱含價格降為約-4%，對於住房總價的負向影響似乎降低。

表五 2019年OLS與GWR模型估計結果

	Min.	Medium (GWR)	Max.	Global (OLS)		
截距	6.0943	6.3513	6.5202	6.2897	(<2e-16)	***
土地移轉面積	<b>-0.0417</b>	-0.0151	0.0006	-0.0042	(0.5916)	
建物移轉面積	0.0039	0.0134	0.0189	0.0110	(0.0000)	***
所在樓層數	-0.0056	-0.0027	0.0026	-0.0050	(0.0708)	
屋齡	-0.0216	-0.0113	0.0115	<b>-0.0116</b>	(0.0171)	*
臨路數	-0.0231	<b>0.0417</b>	0.0619	0.0181	(0.1918)	
臨路寬度	-0.0037	-0.0007	0.0034	0.0008	(0.6082)	
是否為景觀棟	0.0082	0.0344	<b>0.1051</b>	0.0356	(0.1924)	
有無國小	-0.2335	0.0125	0.1005	0.0266	(0.7361)	
有無國中	-0.0831	0.0125	0.0631	0.0449	(0.0766)	
有無公園	-0.1106	-0.0654	0.0377	-0.1103	(0.0000)	***
有無醫院	-0.1747	-0.1243	0.0574	-0.1351	(0.0001)	***
有無廟宇	-0.0482	0.0095	0.0445	0.0085	(0.7424)	
有無加油站	-0.1102	-0.0426	0.0553	0.0334	(0.1893)	
有無市場	-0.0969	-0.0430	0.0458	-0.0328	(0.2910)	
有無消防局	-0.1618	-0.0941	-0.0154	-0.1247	(0.0000)	***
有無火車站	0.0018	0.1277	0.1889	0.0187	(0.8221)	
有無捷運	<b>0.1760</b>	<b>0.3612</b>	<b>0.5938</b>	<b>0.4856</b>	(0.0000)	***

說明：( )內為OLS模型之p值，\*、\*\*、\*\*\*為信賴水準90%、95%、99%下為顯著。Global代表以OLS之全域模型估計結果。Min、Medium、Max分別為GWR參數估計值的極小值、中位數、極大值。白底、灰底各代表個別及區域因素特徵估計結果。粗體字代表該類特徵是係數絕對值最大，是對房價影響最鉅的兩個因素；而OLS中的粗體字代表該類特徵的係數值絕對值為顯著者中最大及次大者。

表六顯示2020年的估計結果，捷運仍舊為影響桃園房價的最重要區域因素，其隱含價格(約在42.4% ~ 44%之間)代表捷運可以使住房總價多至少四成，此數值雖低於2019年水準，但分佈較集中的估計值則意謂著，捷運之隱含價格可能變得較不具空間異質性，數值會接近OLS的估計結果(約44%)。過去文獻在捷運線對房價的影響之結論不一，例如，McMillen & McDonald(2004)以特徵價格模型法及重覆銷售法討論芝加哥捷運線的影響，其實證發現，房價會過熱的反應新的捷運路線的效益，隨著到捷運線車站距離每增加1英里會使房價減4.2%，而路線開通後5年則減19.4%。而Liou, Yang, Chen, & Hsieh(2016)應用兩階層的特徵價格模型，發現台北市捷運站距離對房價和房價上漲的影響均不顯著。而綜觀本文以地理加權迴歸法的估計結果，捷運在2018年至2020年均顯著地影響桃園市房價的成長率，與過去文獻的研究結論不同。此一結果可能意謂著，能考量空間異質性的模型才能合適的捕捉交通建設對房價的效益。



表六 2020年OLS與GWR模型估計結果

	Min.	Medium (GWR)	Max.	Global (OLS)		
截距	6.4848	6.4980	6.5251	6.5069	(<2e-16)	***
土地移轉面積	-0.0142	-0.0139	-0.0128	-0.0139	(0.2014)	
建物移轉面積	0.0117	0.0122	0.0123	0.0121	(0.0008)	***
所在樓層數	-0.0054	-0.0053	-0.0050	-0.0055	(0.1088)	
屋齡	-0.0091	-0.0087	-0.0078	-0.0084	(0.3415)	
臨路數	<b>-0.0429</b>	<b>-0.0384</b>	<b>-0.0374</b>	<b>-0.0417</b>	(0.0469)	*
臨路寬度	-0.0012	-0.0009	-0.0008	-0.0010	(0.7589)	
是否為景觀棟	0.0135	0.0139	0.0224	0.0180	(0.5866)	
有無國小	0.0757	0.1027	0.1031	0.0906	(0.2534)	
有無國中	-0.0043	0.0141	0.0144	0.0057	(0.8817)	
有無公園	-0.0528	-0.0518	-0.0506	-0.0513	(0.1726)	
有無醫院	-0.1716	-0.1709	-0.1618	-0.1684	(0.0002)	***
有無廟宇	-0.0678	-0.0666	-0.0655	-0.0666	(0.0542)	
有無加油站	-0.0491	-0.0487	-0.0328	-0.0397	(0.3210)	
有無市場	0.0903	0.0924	0.1129	0.1021	(0.0161)	*
有無消防局	-0.1531	-0.1441	-0.1437	-0.1483	(0.0007)	***
有無火車站	-0.2734	-0.2722	-0.2667	-0.2707	(0.0179)	*
有無捷運	0.4244	<b>0.4255</b>	<b>0.4384</b>	<b>0.4338</b>	(0.0028)	**

說明：( )內為OLS模型之p值，\*、\*\*、\*\*\*為信賴水準90%、95%、99%下為顯著。Global代表以OLS之全域模型估計結果。Min、Medium、Max分別為GWR參數估計值的極小值、中位數、極大值。白底、灰底各代表個別及區域因素特徵估計結果。粗體字代表該類特徵是係數絕對值最大者，是對房價影響最鉅的兩個因素；而OLS中的粗體字代表該類特徵的係數值絕對值為顯著者中最大及次大者。

在個別因素方面，住宅所在大樓的臨路數是最影響房價的個別因素，其對總價的影響為負(約-4.3% ~ -3.7%)，與前兩年之估計值略有差異。推測可能是臨路數多則道路往來車輛更多、住宅大樓居住環境更為吵雜，但隨著都市越發展、所得水準提高，居住品質越受重視，是以臨路數多反不利於住房價格。

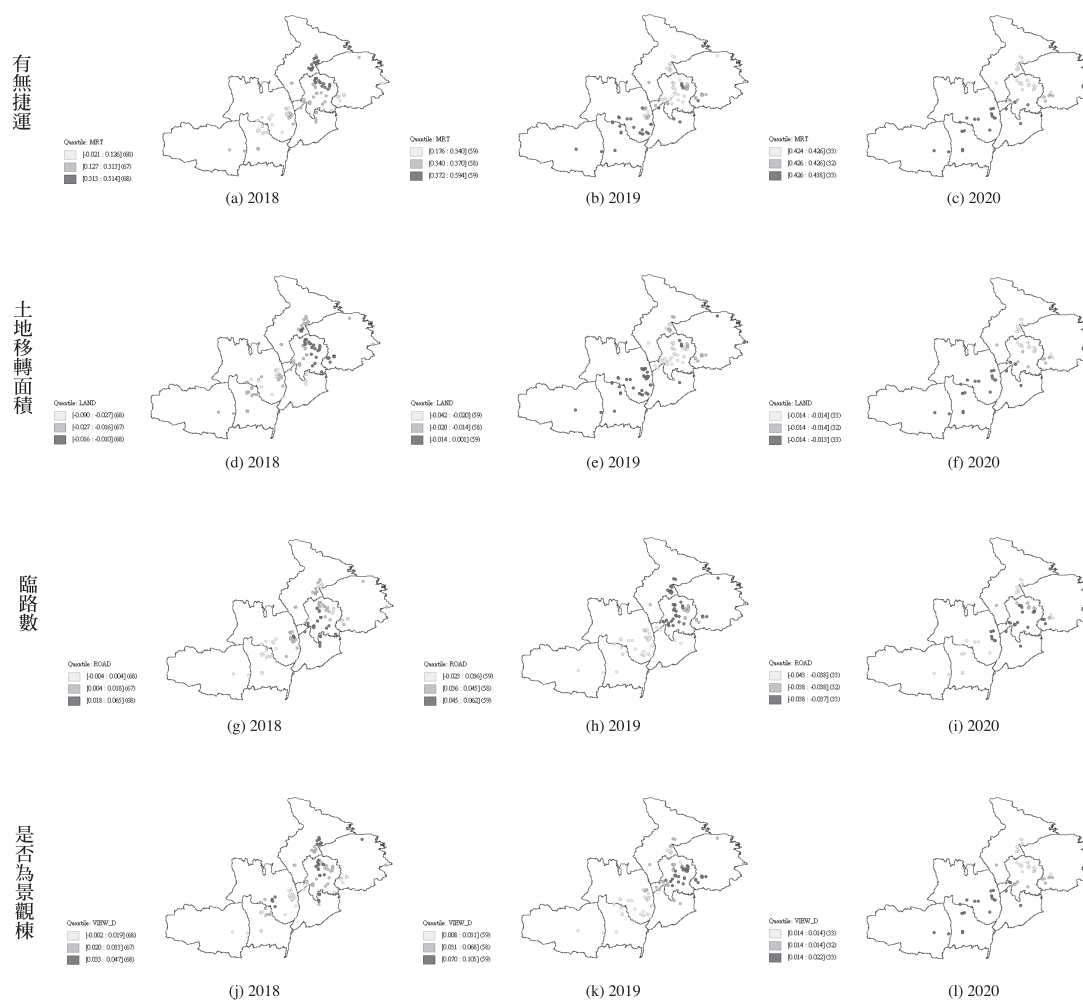
本文比較以OLS及GWR估計的模型配適度，結果如表七。從AIC<sub>c</sub>和R<sup>2</sup>值顯示GWR有較小的AIC<sub>c</sub>和較高的R<sup>2</sup>，對研究期間的房價資料之配適度更優。

GWR的另一個優勢是，能將參數的估計結果投影成圖，提供更多有意義的空間資訊。因此，本文接下來將以圖面分析來呈現房市空間異質性，選擇隱含價格數值較高、對房價影響程度較大的特徵進行討論。本文將估計的係數值以分位數分成三組，高值組以紅色點代表，中值組為橙色，低值為黃色，數值的空間及時間分佈繪製如圖三。

表七 模型之AIC<sub>C</sub>與判定係數(R<sup>2</sup>)

		2018	2019	2020
OLS	AIC <sub>C</sub>	-274.31	-242.48	-92.76
	R <sup>2</sup>	0.2477	0.2799	0.3904
GWR	AIC <sub>C</sub>	-288.96	-258.16	-106.03
	R <sup>2</sup>	0.6794	0.7381	0.5331

說明：AIC<sub>C</sub>定義如式(4)。



圖三 2018-2020年間特徵之隱含價格在空間中的變化

說明：樣本資料包括桃園區、中壢區、八德區、平鎮區、楊梅區、蘆竹區、龜山區。估計的係數值以分位數分成三組，數值最大一組以紅色點代表，數值居中的一組為橙色，數值最小組為黃色。

整體而言，圖三顯示住房特徵隱含價格之高值或低值的群聚，在空間中逐漸擴大或緊縮，在時間中變化，與Fotheringham et al.(2015)的研究發現一致，他們建議，這種類型的空間趨勢是因住房市場的繁榮或蕭條所致之次市場的成長或萎縮。圖三(a)-(c)為“有無捷運”在三年間之隱含價格的變化，圖形可觀察到明顯的時間及空間的異質性，這是以OLS估計的模型無法捕捉的現象。桃園捷運機場線是從大園區往東南通過蘆竹區、龜山區，同時往西南至中壢區，捷運綠線連接機場線再經過蘆竹區、桃園區、龜山區、八德區，三心六線的路網涵蓋了本文研究的桃園市主要區域。從圖中可以觀察到捷運從2018年底通車開始，捷運對房價的效益從桃園機場沿著捷運線向外擴散，2020年更沿著捷運的計劃路線對房價有貢獻，特別是在屬於蛋黃的桃園區、中壢區及八德區、平鎮區等蛋白區。隱含價格的水準在研究期間內不分組別地逐年增加，各組間的價格差距也縮小，至2020年止，不分蛋黃、蛋白及邊緣區，900公尺內有捷運對總價的貢獻平均約達43%。

圖三(d)-(f)是“土地移轉面積”之隱含價格變化，雖然研究期間之住房價格隨土地移轉面積增加而下跌，但影響程度因住房所處之區位及住宅市場景氣而不同，因此圖形上資料點的分佈出現明顯的時間及空間的異質性。在2018年，高值及中值(價格下跌幅度較小)的群聚出現在蛋黃區的桃園區及中壢區，以及與桃園區接壤的蘆竹區及龜山區邊緣，隨著房市繁榮，2019年高值資料點群聚往中壢區擴散，截至2020，因地坪增而致房價下跌的影響幅度在蛋黃、蛋白、邊緣區趨於一致，推測可能是2020年景氣急凍之影響(Fotheringham et al., 2015)。

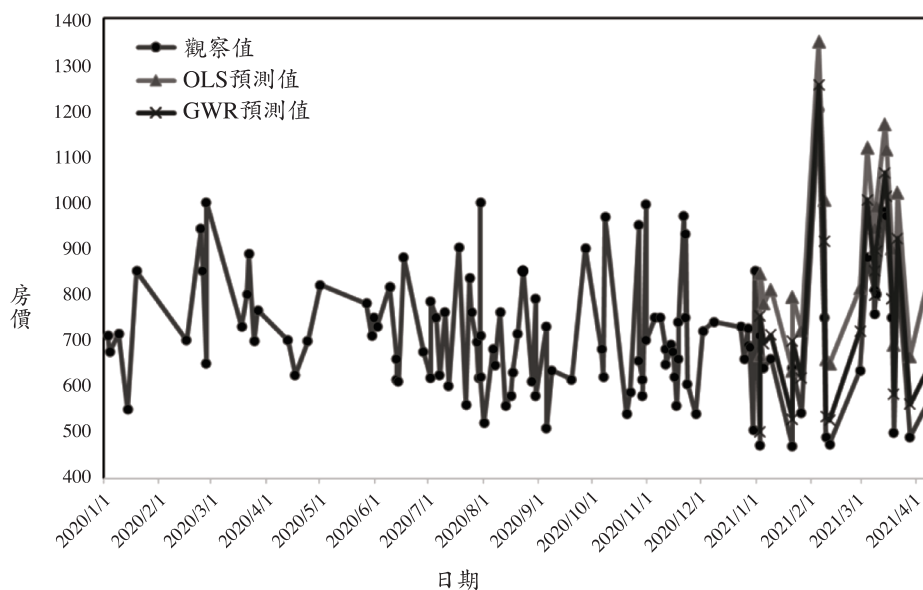
“臨路數”對房價的影響程度繪製於圖三(g)-(i)，仍可看出資料點群聚的空間異質現象，集中在蛋黃區的桃園區，而且臨路數和房價的關係亦隨時間而變化，在2018及2019年景氣相對繁榮期間，兩者大部份為正向關係，且對在位於蛋黃區的住房之價格貢獻程度最高。在景氣衰退的2020年，臨路數對房價的負向影響出現，此時研究區域之隱含價格收斂，且對於蛋黃區之負面影響為最小。

最後，“是否為景觀棟”方面，圖三(j)-(l)顯示，在2018年，此特徵係數之中、高值出現在蛋黃的桃園區及接近桃園區的龜山區邊緣，此數值在2019年上升，但於2020年仍為正數值卻下跌且高、中、低值組之數值趨於收斂。總結來說，上述特徵的隱含價格會隨時間而變化，特別是在景氣轉變的2020年，出現隱含價格數值下跌或符號改變的現象。此外，“土地移轉面積”、“臨路數”及“是否為景觀棟”等住房個別因素之隱含價格的變化軌跡，似乎是先從蛋黃區(如：桃園區)出現對價格較大的影響，隨時間的經過，此影響往蛋白區及邊緣區擴散，而至各區數值水準趨於接近的現象。

### (三) 房價預測與模型預測精確度

根據Fotheringham et al.(2015)的GWR-TS，先以GWR得到2018-2020年的局部參數估計值後，再應用Holt's單變量指數平滑法來計算估計值在下一季之未來值，並據以預測2021年第一季的中古屋房價。為便於比較，本文同時以指數平滑法預測OLS模型之全域參數值之未來值及據以預測房價。圖四繪製根據GWR及OLS參數估計值為基礎的房價預測值，與房價之實際值之比較結果。圖三可以看出，GWR模型預測值與實際值之配適度較優。在驗證模型預測精確度方面，以絕對平均百分誤差(mean absolute percentage error, MAPE)檢測兩模型的結果如表八。由於MAPE數值越大表示模型預測較差，其離散程度較大，因此GWR模型的預測表現優於OLS模型。





圖四 GWR與OLS對2021第一季之房價預測

表八 模型預測之絕對平均百分誤差

	GWR模型	OLS模型
MAPE	12.43%	14.78%

## 五、結論與建議

本文以桃園市的房地交易資料為對象，應用GWR來估計房價特徵模型。考慮桃園市近年來之各區域發展的差異極大，以及此研究期間內，桃園住房市場的景氣變化甚大，市場景氣狀況前後差異甚大，因此有必要考量空間的差異，在估價模型中納入空間異質性(spatial heterogeneity)的特性，以及時間因素對價格的影響。本文使用結合時空因子的GWR-TS模型，探討桃園市房價在時空上的變化。

研究結果顯示，首先，與房地的個別因素相較，區域因素的特徵更為顯著地決定房價，這意謂著蛋黃區、蛋白區及邊緣區之房價的差異主要是受區域因素的影響。其次，特徵的隱含價格隨著時間而變化，特別是在2020年出現係數值下跌或符號改變的現象，可能與研究期間住房市場景氣的急劇變化有關。再者，特徵隱含價格之高、低值出現群聚，且隨著住房市場的景氣或衰退，傾向於在空間中逐漸擴大或緊縮，且數值出現收斂，而近似漣漪的現象。意即，市場的景氣熱絡會使蛋黃區較高的隱含價格水準往蛋白及邊緣區擴散，而使區域間的價格日趨接近。例如，捷運的隱含價格不分蛋黃、蛋白及邊緣區而逐年增加，各組間的價格差距也逐減縮小，至2020年止，900公尺內有捷運對總價的貢獻平均約達43%。另外，觀察「土地移轉面積」、「臨路數」及「是否為景觀棟」等個別因素之隱含價格的變化軌跡，可以發現顯著的高值首先出現在蛋黃區(如：桃園區)，隨著房市的熱絡，高值往蛋白區及邊緣區

擴散，呈現各區數值水準趨於接近的現象。最後，GWR-TS模型的預測能力及配適度均優於OLS模型。

本文的研究結果具有以下意涵：第一，OLS的估計結果未能合適捕捉住房交易資訊的時間及空間異質性，不動產估價的模型有必要同時考量時間與空間因素。第二，區域因素特徵的重要性突顯出空間因素的重要性，應用地理資訊系統(GIS)以合適的捕捉空間變數，會是不動產估價的重要趨勢。因模型估計的特徵隱含價格受系統性因素(如：景氣)而具有時間及空間的動態，在交易資料更為巨量時，未來在模型中適切地納入人工智慧(Ai)輔助估價，將有助於提升預測精確度，此為未來的發展方向。

### 註 釋

註1：北桃園包括：桃園區、龜山區、八德區、大溪區、蘆竹區、大園區；南桃園包括：中壢區、楊梅區、平鎮區、龍潭區、觀音區、新屋區(資料來源：桃園市衛生局官網)

註2：蛋黃區包括桃園區、中壢區；蛋白區包括八德區、平鎮區；邊緣區包括楊梅區、蘆竹區、龜山區。



## 參考文獻

### 中文部份

李春長、童作君

2010 〈住宅特徵價格模型之多層次分析〉《經濟論文叢刊》38(2)：289-325。

Lee, C. C. & T. C. Ton

2010 “Multilevel Analysis of a Housing Hedonic Price Model,” *Taiwan Economic Review*, 38(2): 289-325.

林祖嘉、馬毓駿

2007 〈特徵方程式大量估價法在台灣不動產市場之應用〉《住宅學報》16(2)：1-22。

2012 〈貝氏多層次模型在台灣不動產市場估價之應用—以台北市住宅建物為例〉《住宅學報》21(1)：1-18。

Lin, C. C. & Y. C. Ma

2007 “An Application of Mass Appraisal and the Hedonic Equation in the Real Estate Market in Taiwan,” *Journal of Housing Studies*, 16(2):1-22.

2012 “An Application of Bayesian Inference in the Real Estate Market - A Case Study of Taipei Collective Housing,” *Journal of Housing Studies*, 21(1): 1-18.

陳樹衡、郭子文、棗厥庸

2007 〈以決策樹之迴歸樹建構住宅價格模型—台灣地區之實證分析〉《住宅學報》16(1)：1-20。

Chen, S. H., T. W. Kuo & C. Y. Tsao

2007 “Regression Trees for Housing Price Models: An Empirical Study on Taiwan,” *Journal of Housing Studies*, 16(1): 1-20.

張怡文、江穎慧、張金鸚

2009 〈分量迴歸在大量估價模型之應用 - 非典型住宅估價之改進〉《都市與計劃》36(3)：281-304。

Chang, Y. W., Y. H. Chiang, & C. O. Chang

2009 “Quantile Regression Analysis of Residential Mass Appraisal Models-Improvement in Atypical Housing Appraisal,” *Journal of City and Planning*, 36(3): 281-304.

鄒克萬、鄭皓騰、郭幸福、與楊宗名

2013 〈應用空間特徵價格模型評估高速鐵路對土地價格影響之時空特性—以臺灣高鐵為例〉《建築學報》14(1)：47-66。

Tsou, K. W., H. T. Cheng, H. F. Kuo, & T. M. Yang

2013 “Applying Spatial Hedonic Price Model to Explore the Effects of Taiwan High Speed Railway on Land Price,” *Journal of Architecture*, 14(1): 47-66.

廖咸興、張芳玲

1997 〈不動產評價模式特徵價格法與逼近調整法之比較〉《住宅學報》(5)：17-35。

Liao, H. H. & F. L. Chang

- 1997 "On the Comparison between Hedonic Regression and Grid-Adjustment Techniques in Real Estate Appraisal," *Journal of Housing Studies*. (5): 17-35.

賴碧瑩

- 2007 〈應用類神經網路於電腦輔助大量估價之研究〉《住宅學報》16(2)：43-65。

Lai, P. Y.

- 2007 "Applying the Artificial Neural Network in Computer-assisted Mass Appraisal," *Journal of Housing Studies*. 16(2): 43-65.

### 英文部份

Basu, S. & T. G. Thibodeau

- 1998 "Analysis of Spatial Autocorrelation in House Prices," *Journal of Real Estate Finance and Economics*. 17(1): 61-85.

Bidanset, P. E., & J. R. Lombard

- 2014 "Evaluating Spatial Model Accuracy in Mass Real Estate Appraisal: A Comparison of Geographically Weighted Regression and the Spatial Lag Model," *Cityscap*. 16(3): 169-182.

Bitter, C., G. F. Mulligan, & S. Dall'erba

- 2007 "Incorporating Spatial Variation in Housing Attribute Prices: a Comparison of Geographically Weighted Regression and the Spatial Expansion Method," *Journal of Geographical Systems*. 9(1): 7-27.

Brunsdon, C., A. S. Fotheringham, & M. Charlton

- 1996 "Geographically Weighted Regression: a Method for Exploring Spatial Nonstationarity," *Geographical Analysis*. 28(4): 281-298.
- 1999 "Some Notes on Parametric Significance Tests for Geographically Weighted Regression," *Journal of Regional Science*. 39(3): 497-524.

Cajias, M., & S. Ertl

- 2018 "Spatial Effects and Non-Linearity in Hedonic Modeling: Will Large Data Sets Change Our Assumptions?," *Journal of Property Investment & Finance*.

Cao, K., M. Diao, & B. Wu

- 2018 "A Big Data-Based Geographically Weighted Regression Model for Public Housing Prices: A Case Study in Singapore," *Annals of the American Association of Geographers*. 109(1): 173-186.

Cebula, R. J.

- 2009 "The hedonic pricing model applied to the housing market of the city of Savannah and its Savannah historic landmark district," *Review of Regional Studies*. 39(1): 9-22.

Chau, K. W., & T. L. Chin

- 2003 "A Critical Review of Literature on the Hedonic Price Model," *International Journal for Housing Science and Its Applications*. 27(2): 145-165.

- Cliff, A. D., J. K. Ord, P. Haggett, & G. R. Versey  
1981 *Spatial Diffusion: an Historical Geography of Epidemics in an Island Community*: CUP Archive.
- De Araujo, P., & K. Cheng  
2017 “Do preferences for amenities differ among home buyers? A hedonic price approach,” *Review of Urban & Regional Development Studies*. 29(3): 165-184.
- Dombrow, J., J. R. Knight, & C. Sirmans  
1997 “Aggregation Bias in Repeat-Sales Indices,” *The Journal of Real Estate Finance and Economics*. 14(1): 75-88.
- Follain, J. R., & S. Malpezzi  
1980 *Dissecting Housing Value and Rent: Estimates of Hedonic Indexes for Thirty-Nine Large SMSAs*: Urban Institute Press.
- Fotheringham, A. S., R. Crespo, & J. Yao  
2015 “Exploring, Modelling and Predicting Spatiotemporal Variations in House Prices,” *The Annals of Regional Science*. 54(2): 417-436.
- Fullerton, T. M., & A. Bujanda  
2018 “Commercial Property Values in a Border Metropolitan Economy,” *Asia-Pacific Journal of Regional Science*. 2(2): 337-360.
- Gardner Jr, E. S.  
2006 “Exponential Smoothing: The State of the Art—Part II,” *International Journal of Forecasting*. 22(4): 637-666.
- Harris, P., A. Fotheringham, R. Crespo, & M. Charlton  
2010 “The Use of Geographically Weighted Regression for Spatial Prediction: an Evaluation of Models Using Simulated Data Sets,” *Mathematical Geosciences*. 42(6): 657-680.
- Helbich, M., W. Brunauer, E. Vaz, & P. Nijkamp  
2014 “Spatial heterogeneity in hedonic house price models: The case of Austria,” *Urban Studies*. 51(2): 390-411.
- Huang, B., B. Wu, & M. Barry  
2010 “Geographically and Temporally Weighted Regression for Modeling Spatio-Temporal Variation in House Prices,” *International Journal of Geographical Information Science*. 24(3): 383-401.
- Lancaster, K.  
1966 “A new approach to consumer theory,” *Journal of political economy*. 74(2): 132-157.
- Li, W., & J.-D. Saphores  
2012 “A Spatial Hedonic Analysis of the Value of Urban Land Cover in the Multifamily Housing Market in Los Angeles, CA,” *Urban Studies*. 49(12): 2597-2615.

Liou, F. M., S. Y. Yang, B. Chen, & W. P. Hsieh

- 2016 “The Effects of Mass Rapid Transit Station on the House Prices in Taipei: The Hierarchical Linear Model of Individual Growth,” *Pacific Rim Property Research Journal*. 22(1): 3-16.

Lisi, G.

- 2019 “Property valuation: the hedonic pricing model—location and housing submarkets,” *Journal of Property Investment & Finance*. 37(6): 589-596.

Lu, B., M. Charlton, P. Harris, & A. S. Fotheringham

- 2014 “Geographically Weighted Regression With a non-Euclidean Distance Metric: a Case Study Using Hedonic House Price Data,” *International Journal of Geographical Information Science*. 28(4): 660-681.

McCord, M., P. Davis, M. Haran, S. McGreal, & D. McIlhatton

- 2012 “Spatial Variation as a Determinant of House Price: Incorporating a Geographically Weighted Regression Approach within the Belfast Housing Market,” *Journal of Financial Management of Property and Construction*, *Journal of Financial Management of Property and Construction*. 17(1): 49-72.

McMillen, D. P., & J. McDonald

- 2004 “Reaction of House Prices to a New Rapid Transit Line: Chicago’s Midway Line, 1983–1999,” *Real Estate Economics*. 32(3): 463-486.

Osland, L.

- 2010 “An Application of Spatial Econometrics in Relation to Hedonic House Price Modeling,” *Journal of Real Estate Research*. 32(3): 289-320.

Pace, R. K., R. Barry, O. W. Gilley, & C. F. Sirmans

- 2000 “A Method for Spatial–Temporal Forecasting With an Application to Real Estate Prices,” *International Journal of Forecasting*. 16(2): 229-246.

Rosen, S.

- 1974 “Hedonic Prices and Implicit Markets: Product Differentiation in Pure Competition,” *Journal of Political Economy*. 82(1): 34-55.

Sheppard, S.

- 1999 “Hedonic analysis of housing markets,” *Handbook of Regional and Urban Economics*. 3: 1595-1635.

Wang, D., & V. J. Li

- 2019 “Mass Appraisal Models of Real Estate in the 21st Century: A Systematic Literature Review,” *Sustainability*. 11(24): 7006.

Wen, H., Y. Jin, & L. Zhang

- 2017 “Spatial Heterogeneity in Implicit Housing Prices: Evidence From Hangzhou, China,” *International Journal of Strategic Property Management*. 21(1): 15-28.

Yu, D., Y. D. Wei, & C. Wu

- 2007 “Modeling Spatial Dimensions of Housing Prices in Milwaukee, WI,” *Environment and Planning B: Planning and Design*. 34(6): 1085-1102.