

學術論著

預測台灣房地產市場趨勢之模型---應用深度學習技術

Prediction Model for the Trend of Taiwan's Real Estate Market—Applying Deep Learning Technology

蔡繡容* 夏政瑋**

Hsiu-Jung Tsai*, Cheng-Wei, Hsia**

摘要

本文以人工智慧之深度學習技術，預測台灣房地產之趨勢，除了採用總體經濟變數外，亦運用網路搜尋量與人口結構變數以進行房地產市場之預測，透過LSTM (Long Short-Term Memory)預測房地產市場之趨勢，並與GARCH (Generalized Autoregressive Conditional Heteroskedasticity)模型進行預測能力準確度之衡量。結果顯示LSTM模型對台灣房地產市場之預測結果優於GARCH模型，證實LSTM預測模型具有預測房地產市場趨勢之可行性。最後，採用滾動視窗逐年調整LSTM模型參數，在台灣房價指數與成交量指數預測之準確度分別提升至97%與76%，更能有效提高其模型預測能力，經過滾動視窗之調整後，亦具備與時俱進之效果，預測結果能更貼近現實狀況。

關鍵詞：房地產市場、深度學習、網路搜尋量、人口結構、長短期記憶模型

ABSTRACT

This study used artificial intelligence deep learning technology to forecast the real estate trends in Taiwan. Economic variables, internet search volume, and demographic variables are utilized to forecast the real estate market. Furthermore, the real estate market trends were predicted based on the Long Short-Term Memory (LSTM) model and the accuracy of the predictions was evaluated using the Generalized Autoregressive Conditional Heteroskedasticity (GARCH) model. The results reveal that the LSTM model predicted the Taiwan real estate market better than the GARCH model, thus verifying the feasibility of the LSTM model in forecasting the trend of real estate markets. Furthermore, a rolling window was used to adjust the parameters of the LSTM model annually. Therefore, the prediction accuracy of Taiwan's house price and transaction volume indices improved to 97% and 76%, respectively, thereby enhancing its model prediction ability. Moreover, adjusting the rolling window also enabled the advancements over time; therefore, the predicted results were closer to the practical situation.

Key words: Real Estate Market, Deep Learning, Searching Volume, Demographic Variables, Long Short-Term Memory Model

(本文於2022年5月16日收稿，2022年10月25日審查通過，實際出版日期2023年12月)

* 聯絡作者，國立高雄科技大學財務管理系副教授

Corresponding author, Associate professor, Department of Finance, National Kaohsiung University of Science and Technology, Kaohsiung, Taiwan. E-mail: sharon@nkust.edu.tw

** 國立高雄科技大學財務管理系碩士

Master, Department of Finance, National Kaohsiung University of Science and Technology, Kaohsiung, Taiwan. E-mail: F108126104@nkust.edu.tw

感謝國科會研究計畫經費補助(計畫編號：109-2410-H-992-036- 與108-2410-H-992-036-)

一、緒論

長期以來，房地產被各國視為經濟成長的火車頭，房地產業的熱絡，可帶動營建(造)、建材、金融、不動產經紀、傢俱與裝潢等產業的發展。另一方面房地產熱度上升，移轉棟數增加可帶動房價上漲，則民眾資產價值增加，刺激消費與經濟景氣，可謂是國家經濟發展的重要指標，且房地產市場的供需平衡，一直以來是政府與房地產相關業者非常關心的問題，其中，建商在進行推案規劃時，須了解目前房地產市場的供需處於「供過於求」或「供不應求」？才能制訂何時推案與推案數量等，因此，房地產趨勢之預測不僅具有經濟價值，且具有社會心理特徵。

由於房地產之熱度，對於許多現代經濟體而言，是整體經濟的催化劑，從經濟成長數據中可見一斑，例如美國住宅房市之資本投資高於新企業的投資(Greenwood & Hercowitz, 1991)，房地產市場亦是國家經濟的重要指標，對國家貨幣政策產生積極的影響(Hwang & Quigley, 2006; Vargas-Silva, 2008; Xu & Chen, 2012)。然而，民眾對房地產市場趨勢之預測，乃是影響房價變動之主因，政府當局應定期預測與估算未來房地產之趨勢，可及早偵測房地產市場的榮景與泡沫，此將有助於總體經濟穩定與審慎政策之擬定。過去許多學者、專家、購屋者與投資客等，皆希望可以準確預測未來房地產之趨勢，儼然成為各方所關切議題之一。

關於影響房地產市場榮枯之因素，至今學術界與政府決策者仍有許多歧見。部分學者認為房地產交易熱絡係因全球低利率、貨幣政策太寬鬆或儲蓄過剩所導致(Taylor, 2007; Del Negro & Otrok, 2007; Ferrero, 2015)，但Favilukis et al.(2017)卻指出只有放寬融資限制，如增加貸款成數，將買房頭期款降低，才是推升房地產榮景之主因，並非低利率所導致的。另外，貨幣政策是影響房地產市場供給與需求之重要變數，若政府實施寬鬆貨幣政策，貨幣供給增加有利於房地產供需雙方向銀行取得較低之興建成本及購屋成本，同時推升供給面及需求面同步上揚，導致房地產市場熱度飆升，也有許多學者支持貨幣供給額對房地產市場有正向影響(Adams & Füss, 2010; Xu & Chen, 2012)。但蔡怡純、陳明吉(2004)表示若貨幣政策過於寬鬆，則房地產市場的「量與價」會逐漸偏離均衡水準。

過去學者在探討房地產價量關係，或者預測未來房地產價格時，大多採用總體經濟面與貨幣政策之數據，如經濟成長、貨幣供給總額、物價指數、房價所得比、貸款利率、消費者信心指數等(Malpezzi, 1999; Chan, 2001; Aoki, et al., 2004; Yue & Hongyu, 2004; Otrok & Terrones, 2005; Lacoviello, 2005; Yunfang & Tiemei, 2007; Bagliano & Morana, 2012; Addae-Dapaah, 2014)，其中Aoki, et al.(2004)實証結果貨幣供給總額對房地產價格具顯著影響力，但Yue & Hongyu(2004)卻發現長期而言，貨幣供給總額相較貸款利率較不影響房價。Addae-Dapaah(2014)指出從長期來看，房屋貸款金額與房價、經濟成長率呈正相關，但與利率呈負相關，而短期來看房屋貸款金額與房價之間並沒有相關性。另外，有些學者在探討房地產價格與景氣時，除了上述總體經濟與貨幣政策變數外，同時引用房地產市場特有的數據，包含營建工程物價指數、建築貸款餘額、議價率與房屋存量等。Marcato & Nanda(2016)研究發現，購屋者面對房地產不同景氣時，議價率的態度也會不同，且在房地產不景氣時發揮更顯著的作用，認為購屋者對於房價議價的幅度，能預測房地產市場未來供需的概況。彭建文(2015)指出建築貸款餘額可視為判斷房地產供給多寡之指標，它與房價相關程度高達0.9以上，故本

研究亦將房地產特有變數納入預測模型中。然而針對房地產交易量之研究則偏重於價量關係(高慈敏, 2014; Leung & Feng, 2005; Charles et al., 2002; Beracha & Wintoki, 2013; Tsai, 2018, 2019), 其中, Tsai(2019)指出房地產在繁榮或低迷時期, 房價與成交量存在領先-落後的關係; Tsai(2018)探討房價與成交量之間的連鎖效應, 結果顯示在區域房地產之成交量的連鎖反應遠大於房價, 而兩種連鎖效應呈負相關。除此之外, 因網路科技之發達, 帶動了指尖經濟興起, 亦有學者利用網路搜尋量預測房市成交量(林左裕, 2019; Wu & Brynjolfsson, 2015; Huarng, et al., 2020), 其中, 林左裕(2019)利用網路搜尋量指數, 探討房市交易量與價格間的關係, 結果顯示網路搜尋量指數對於房市價格與成交量存在領先之關係。Huarng, et al.(2020)實証結果表示增加網路搜尋量指數之變數, 可提高預測模型之準確度, 且可預測當季房市之成交量。

綜合上述, 甚少文獻同時對房地產市場之價格與成交量建立預測模型, 本文跳脫過往的研究, 除了總體經濟數據外, 同時結合人口結構變數與網路搜尋量指數等非經濟面數據, 利用深度學習模型預測未來房地產之趨勢, 補足現有文獻之缺口, 其論點大致如下:

近年來, 各國探討的熱門議題, 便是「人口紅利消失」(Cai, 2010; Han, 2019), 台灣目前面臨生育率逐年下滑, 加上醫藥科技日新月異, 台灣人口總數因少子化與高齡化的雙重影響下, 台灣人口自然增加數於2020年由正轉為負, 至2022年已連續兩年呈現負成長。如此一來, 人口紅利逐漸消失的環境下, 對未來房地產之需求是否會隨之減少? 高齡化社會已經到來, 以及人口零成長甚至負成長, 對房地產之影響不容小覷, 值得我們深入探討。目前的文獻針對人口結構對房價之影響, 其論述雖不一致, 但Mankiw & Weil(1989)、Jud & Winkler(2002)、Yi & Zhang(2010)、彭建文、蔡怡純(2017)等文獻皆認為人口結構改變與房價存在密切的關係。例如: Mankiw & Weil(1989)研究指出美國於1970年代的房價上漲的原因, 起因於嬰兒潮那一世代的人開始購屋所導致的結果, 並預測未來人口比例下降時, 其住房需求也跟著下降, 將使未來的房價大幅下降。彭建文、蔡怡純(2017)實証結果顯示房價會和生育率、扶老率有長期的整合關係, 生育率上升會帶動房價的上漲, 相反地, 扶老率增加則會降低房價。目前政府所有的計畫都忽視人口減少和超高齡化的現實, 仍以人口增加為前提, 制定錯誤的政策。故本研究亦將人口變數問題納入預測模型中, 冀望透過本研究瞭解台灣人口結構面臨負成長時, 對未來房地產榮枯之影響。

另一方面, 受惠於網際網路蓬勃發展與智慧通訊設備的普及化之下, 台灣民眾在進行購買決策時, 會採取線上和線下的搜尋與研究, 根據Statcounter機構統計, 全球至2022年3月為止, Google Chrome的使用比率約67.29%, 這便意味著Google公司每日需處理數以億萬計的資料, Google公司將這些資料經過統計與分析後, 使用者便可以透過Google Trend免費查詢其所關注的議題。Google Trend除了可以分析各國流行的議題外, 亦可以深入辨認所查詢之議題於各地區的差異。Ginsberg et al.(2009)利用Google Trends之搜尋量指數(Searching Volume Index, SVI)以預測流行性感冒爆發區間; Choi & Varian(2012)利用SVI指數預測汽車銷售、失業補助及消費者信心指數等議題, 研究結果顯示搜尋量指數能有效提升傳統模型解釋力, 當預測模型加入SVI指數後, 相較簡單自迴歸模型(Auto Regression, AR)提升5%至20%之預測能力; Toth & Hajdu(2012)應用SVI指數對匈牙利之不動產市場以及汽車市場進行趨勢預測, 研究結果顯示SVI指數在預測匈牙利不動產市場及汽車市場有不錯的表現, 相較於過去研究使用落後資訊之經濟性指標而言, 有更好的預測能力; Wu & Brynjolfsson(2009)利用網路搜尋指數預測房地產

之價格與交易量，結果顯示網路搜索指數每增加1%，則下一季度房地產將增加121,400套之成交量，代表此種方法亦可以應用於房地產之預測。Nelson(1970)指出消費者面臨龐大金額之購買決策時，會從事較多之搜尋行為；而網路搜尋行為可以用來揭露消費者之意圖，並預測購買結果(Kuruzovich et al., 2008)。購屋對個人或家庭而言是牽涉龐大金額之重要購買決策，購屋者會進行更多的購屋前資訊搜尋行為，因此本文加入網路搜尋量指數，以提高預測房地產之趨勢之準確度。

本研究彙整過去文獻預測房地產市場之模型，大多以市場比較法(Sales Comparison Approach)、整合移動平均自回歸模型(Autoregressive Integrated Moving Average; ARIMA)、一般自我迴歸條件異質變異模型(Generalized Autoregressive Conditional Heteroskedasticity; GARCH)、特徵價格法(Hedonic Price Method)、決策樹(Decision Tree)、隨機森林(Random Forest)及類神經網路(Neural Network)等方法預測房地產市場(Can, 1992; Raymond, 1997; Wallace & Meese, 1997; Limsombunchai, 2004; Fan et al., 2006; Hansen, 2009; Selim, 2009; Özsoy & Şahin, 2009; Park & Bae, 2015; Anundsen et al., 2016; Rai, 2017)。早期文獻大多以市場比較法與ARIMA最被廣為運用的方法(Crone & Voith, 1992; Atteberry & Rutherford, 1993; Dubin, 1998)，前者是易受個人主觀因素及其調整方法而產生誤差，而後者則缺點為只能捕捉線性關係，而不能捕捉非線性關係。爾後Bollerslev(1986)提出GARCH模型，指出GARCH模型在於進行條件變異數之調整彈性有比較優異的表現，不少學者將其應用於房地產價格與波動之預測(蔡怡純、陳明吉, 2008; Dolde & Tirtiroglu, 1997; Crawford & Fratantoni, 2003; Guirguis, et al., 2005; Wang, 2009; Chang, 2010)，其中，Guirguis, et al.(2005)採用美國房地產資料，以Rolling-GARCH模型進行預測，結果顯示預測未來1-4季之房價呈現高度準確度；蔡怡純、陳明吉(2008)提出在控制結構性轉變對條件平均數方程式之影響下，可利用GARCH(1,1)預測預售屋價格之波動。而特徵價格法則以電腦自動化大量估價，但因需要海量資料建立模型，又無法精確處理複雜非線性之特徵，在此情況下也有可能發生偏差。因此衍生出類神經網路技術進行預測，但類神經網路與特徵價格法相同以電腦運算進行預測，但缺點是會因小部分離群值而影響模型準確度。

近年來隨著資訊科技迅速蓬勃發展，各領域之專家學者嘗試利用電腦模擬人類思考模式，進而發展類神經網路模型廣泛地應用於各種不同領域。由於機器學習為一種利用疊代學習技術，可以依據輸入資料，並透過給定特定之特徵(Feature)對輸入資料進行分析預測。深度學習(Deep Learning)則為機器學習更進一步之類神經網路之技術，深度學習除了具備機器學習之功能外，其中還具備自動抽取特徵(Feature Extraction)的能力，深度學習能夠透過輸入資料中自動擷取出足以代表資料特性之特徵的能力，而其中技術是透過模型在預測過程中不斷進行訓練與學習，並利用訓練過程中得到之特徵進行下一步之計算與預測，而此技術稱為特徵學習(Feature Learning)。近幾年相關的研究文獻猶如雨後春筍般發表於各學術領域中，如影像辨識、語音辨識、生技醫療資訊、預測病患住院天數與死亡率、天氣預報以及股價的預測等(Choi, et al., 2018; Chou & Nguyen, 2018; Krittanawong, 2018; Parreco, et al., 2018; Varian, 2018; Bao & My, 2019)，另外各大科技公司，如Apple、Amazon與Microsoft等，亦紛紛投入大量資金開發研究，導致近幾年皆可以觀察到生活週遭事物與深度學習技術的結合運用。

本研究採用遞歸神經網路(Recurrent Neural Network, RNN)之長短期記憶(Long Short-Term Memory, LSTM)模型，建構深度神經網路以預測未來房地產之趨勢。目前已有學者採用RNN

與LSTM模型進行股票價格之預測(Xiong et al., 2015; Rather et al., 2015; Nelson, et al., 2017)。其中，Xiong et al.(2015)採用長期短期記憶神經網路，模擬標準普爾500指數的波動性，結果顯示平均絕對誤差(MAE)低於傳統GARCH模型至少31%；Nelson et al.(2017)根據技術指標，採LSTM模型進行訓練與測試，建構一個預測模型，其準確度達到55.9%高於其他機器學習之方法。另外，Song et al.(2020)指出LSTM預測模型較能捕捉預測標的受多因素影響下的複雜波動之規律，故採用傳統的神經網路、遞減曲線分析與時間序列等模型進行石油產量之預測，結果顯示LSTM模型優於其他模型。而在房地產相關之文獻也有學者採用深度學習之模型進行預測(Yu et al., 2018; Wang et al., 2019; Milunovich, 2020; Lee & Park, 2020; Ayan & Eken, 2021)，其中，Ayan & Eken(2021)採用LSTM模型預測伊斯坦堡房地產市場之泡沫化，實証結果顯示LSTM模型可用於房地產之泡沫偵測與監控，以建立預警制度。Yu et al.(2018)建構邏輯迴歸、卷積神經網路(CNN)與LSTM模型等預測北京房價，結果發現CNN與LSTM在增加訓練次數下可減少誤差，而LSTM模型在時間序列數據之預測有較高之準確度，因此本研究採用LSTM模型預測房地產市場之未來趨勢。

綜合上述，本研究以傳統經濟面數據，並結合非經濟面數據(人口結構與網路搜尋指數)建構房地產市場之預測模型，並利用深度學習之長短期記憶(LSTM)方法進行模型之訓練與驗證，以提高房地產市場預測模型之準確度，實証結果顯示採用LSTM模型對台灣房地產市場之預測，結果皆優於GARCH模型，在台灣房價指數與成交量指數之準確度分別提升93%與99%，證實LSTM預測模型具有預測未來房地產市場趨勢之可行性。本研究與過去文獻最大的差異為：(1)跳脫過往預測房價與估價模型，納入人口結構變數與網路搜尋量變數，建構房地產趨勢之預測模型，房地產市場之榮枯，可謂是國家經濟發展的重要指標，政府當局亦需審慎考量實施總體政策之時機與強度，以防止可能助長房價飆漲或過度抑制房地產而損及經濟成長等；(2)本研究首次以深度學習建立房地產預測模型，將人工智慧之技術應用於房地產市場之研究，冀望能擴增房地產領域之研究能量，為現有文獻做出重要貢獻，同時可以提供政府與業者制定決策時之參考。

二、研究方法

Worzala et al.(1995)表示傳統類神經網路相較於非時間序列之數據具有較佳預測能力，然而遞歸式類神經網路(RNN)與長短期記憶(LSTM)模型則較擅長於對時間序列之數據資料建立良好預測(Xiong et al., 2015; Song et al., 2020)，因此，本研究採用深度學習之LSTM模型，透過傳統經濟面數據與非經濟面數據(人口結構變數與網路搜尋量)，建立一個全新的房地產市場之預測模型。另外，過去文獻指出房地產市場景氣容易受到政府政策與全球經濟景氣之影響(Kim & Kim, 2000)，若能定期調整預測模型，使得模型能更配適當前房地產市場極其重要，因此，本研究將最後兩年測試集資料利用滾動視窗(Rolling Window)逐年調整模型之最佳參數，使預測模型能與時俱進更貼近現實房地產市場。最後利用均方根誤差(Root Mean Square Error, RMSE)與傳統時間序列預測模型GARCH進行準確度分析比較。

機器學習模型於訓練與學習之過程中，輸入之數據資料的資料型態雖然不會影響模型之進行，然而數據資料之間的差異性，卻會影響模型之預測結果。本研究為提升預測模型之精準度以及避免因資料型態之差異而造成研究偏誤，在進行機器學習之前，本研究將資料正規


化(Normalization)，採用最常見的平均值正規化(Mean Normalization)使本研究之變數資料收斂為同一種型態後，再進行後續之實證研究。如式(1)所示，其中 X_t 為時點 t 之 X 變數值、 μ 為變數之平均值、 X_{max} 及 X_{min} 個別為變數之最大與最小值。

$$X_{t,nom} = \frac{X_t - \mu}{X_{max} - X_{min}} \in [-1, 1] \dots \dots \dots (1)$$

人工神經網路(Artificial Neural Network, ANN)或稱類神經網路，主要是透過模擬人類大腦中的結構使得機器達到學習、記憶、推理、理解等，有如人類般的行為表現，現今機器將展現有別於人類的識別、決策、預測、判斷等卓越表現，將透過數學運算的方式來模擬人類神經元(Neural)的運作過程。本文介紹時間序列資料常被採用的遞歸類神經網路(Recurrent Neural Network, RNN)與長短期記憶(Long Short-Term Memory Network, LSTM)。

(一) 遞歸類神經網路(Recurrent Neural Network, RNN)

利用機器學習解決變數具有時間序列之問題，例如自然語言處理(Natural Language Processing, NLP)需要理解前後之間的關係、氣象觀測資料、股票市場與總體經濟等資料，皆具有與時俱進的關係。簡單的類神經網路模型，其內部運作的方式，將參數從輸入層向輸出層單向的傳遞，這類型的網路又稱為前饋神經網路(Feedforward Neural Network, FNN)。因此，遞歸類神經網路(Recurrent Neural Networks, RNN)將神經元的傳遞做了改變，將輸出端的結果再傳回輸入端，進而具有記憶的功能，如圖一所示。



圖一 遞歸類神經網路之結構示意圖

資料來源：改繪自Bao et al.(2017)

其中神經元的設計 X 在神經網路中表示為輸入， Y 表示為輸出，而 U 、 W 、 V 為神經網路的參數設定，代表各種特徵訊號之權重值參數， h 表示神經網路隱藏的狀態，也代表著記住的特徵值，若將時間軸展開，則 X_t 表示為在 t 時點之神經網路數據輸入， Y_t 則表示為輸出結果。因

此，經過每次訓練後，模型都會學習並記憶神經元內部狀態，以及前一次所學習到的狀態，此狀態會如迴圈般不斷循環並直至訓練結束，RNN之函數說明如下：

因RNN考慮前一期的關係，將簡單迴歸式(2)，改寫成以式(3)。

$$Y = W * X + b \dots\dots\dots (2)$$

$$h_t = W * h_{t-1} + UX + b \dots\dots\dots (3)$$

其中， h 為隱藏層之值，在RNN模型中最常用激勵函數(Activation Function)為 \tanh ，加入激勵函數後，如式(4)。

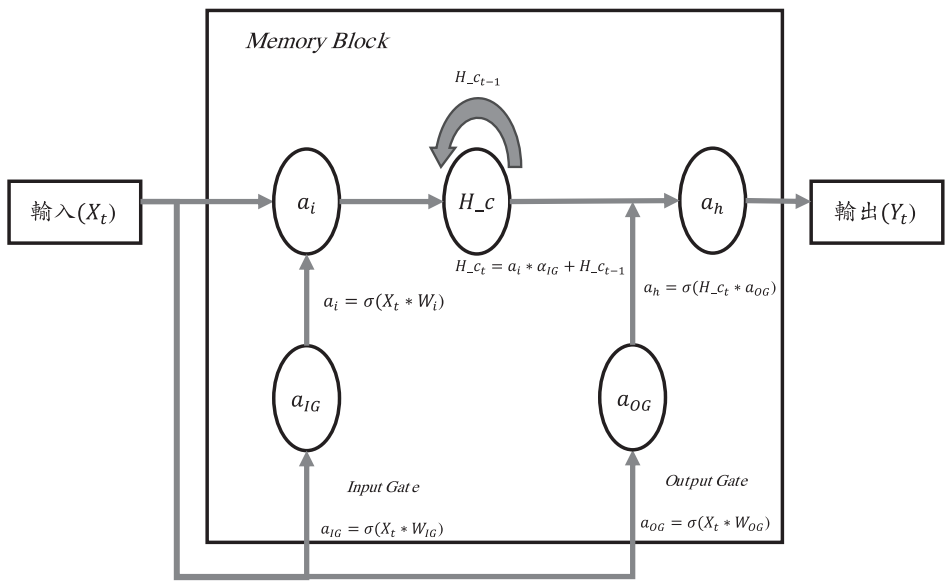
$$Y_t = \tanh(V * h_t) \dots\dots\dots (4)$$

$$\tanh = \frac{e^x - e^{-x}}{e^x + e^{-x}} \dots\dots\dots (5)$$

公式(5)函數 \tanh 可以用其他的方式替代，例如邏輯斯諦函數(Logistic function)或是線性整流函數(Rectified Linear Unit, ReLU)。因為RNN能夠處理長度不固定的輸入，因此可以真正擴展可以使用的類神經網路來計算的可能性，例如：不同長度的序列或是不同大小的圖片。

(二) 長短期記憶(Long Short-Term Memory Network, LSTM)

長短期記憶是遞歸類神經網路(RNN)的一種型態，在類神經網路中，其輸出層或隱藏層的輸出可以回饋到輸入層，或者神經元可以只有一層而且不分層次排列，各神經元均可相互的連結，稱為遞歸類神經網路，但當預測時間序列間隔延遲非常長時，易發生權重指數膨脹或消失，分別稱為梯度膨脹(Gradient Exploding)與梯度消失(Vanishing gradient)。而Hochreiter & Schmidhuber(1997)提出長短期記憶類神經網路來解決該問題，如圖二所示。



圖二 Hochreiter & Schmidhuber(1997) Memory Block架構圖
資料來源：改繪自Hochreiter & Schmidhuber(1997)

將原始神經元替換為記憶區塊，增加輸入閥(Input Gate)與輸出閥(Output Gate)。除了原本輸入層作為輸入，亦同時輸入閥與輸出閥皆通過雙彎曲函數(sigmoid function)，即能夠控制輸入值及輸出值，使得自我遞迴(Self-Loop)的權重係數是有變化的，如此一來在輸入值固定的情況下，不同時間點可以動態改變權重係數，解決梯度消失與梯度膨脹的問題。公式說明如下：

$$a_i = \sigma(X_t * W_t) \dots\dots\dots (6)$$

$$a_{IG} = \sigma(X_t * W_{IG}) \dots\dots\dots (7)$$

$$H_c = a_i * a_{IG} + H_{c_{t-1}} \dots\dots\dots (8)$$

$$a_{OG} = \sigma(X_t * W_{OG}) \dots\dots\dots (9)$$

$$a_h = \sigma(H_c * a_{OG}) \dots\dots\dots (10)$$

其中， a_i 為Input的輸入； a_{IG} 為輸入閥(Input Gate)之輸出； a_{OG} 為輸出閥(Output Gate)之輸出； H_c 為輸入閥與遺忘閥之輸出； a_h 為記憶區之輸出值。其中 X_t 為變數資料輸入； W_t 為輸入變數權重； W_{IG} 為輸入閥權重； W_{OG} 為輸出閥權重， σ 為雙彎曲函數如公式(11)所示。

$$\sigma = \frac{1}{1+e^{(-x)}} \dots\dots\dots (11)$$

另外，Gers & Schmidhuber(2000)增加遺忘閥(Forget Gate)，代表LSTM模型訓練時，會透過三個控制閥(輸入閥、遺忘閥、輸出閥)將當前影響房地產的資訊記憶下來，而對於不具影響力的資訊選擇不被記憶，隨著時間更新，模型會透過遺忘閥與輸入閥的資料，來決定是否更新記憶。簡而言之，LSTM模型是透過運算決定哪些數據該被遺忘，而哪些數據該被輸出至下一個神經元，模型會記憶每個神經元的狀態，以達到長期記憶的效果，以利進行預測。爾後Zaremba et al.(2014)在此架構下，增加前一次 X_{ht-1} 輸出結果作為下一次之輸入，並在原先輸入層雙彎曲函數(Sigmoid Function)改為雙曲正切函數(\tanh)作為激勵函數(Activation Function)，代表下一期的輸入閥會同時有模型的預測值與真實值的數據，因此模型在下次訓練學習時便可以修正誤差，如此一來，模型經由不斷的訓練與學習將誤差收斂至最小，以達到最佳的預測效果。

本研究採用Zaremba et al.(2014)之LSTM架構，建構房地產市場之預測模型，如圖三所示，公式說明詳見式(12)至式(16)。圖三與圖二之差異在於增加一個記憶分支，稱為遺忘閥，該層會將記憶相關資訊，刪除不相關的資訊，同時將前一次之預測值，於下次訓練時參考，模型會藉由數據驅動自我學習與記憶的能力，讓預測結果更貼近實際值，達到有效之預測能力。

$$a_i = \tanh(X_t * W_i + X_{ht-1} * W_{hi}) \dots\dots\dots (12)$$

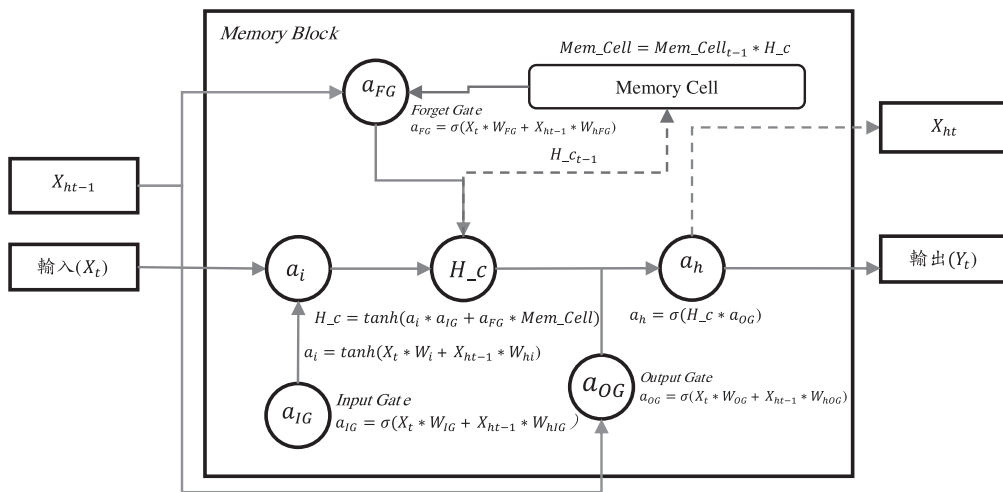
$$a_{IG} = \sigma(X_t * W_{IG} + X_{ht-1} * W_{hIG}) \dots\dots\dots (13)$$

$$a_{FG} = \sigma(X_t * W_{FG} + X_{ht-1} * W_{hFG}) \dots\dots\dots (14)$$

$$a_{OG} = \sigma(X_t * W_{OG} + X_{ht-1} * W_{hOG}) \dots\dots\dots (15)$$

$$H_c = \tanh(a_i * a_{IG} + a_{FC} * Mem_Cell) \dots\dots\dots (16)$$

其中， a_{FG} 為遺忘閥(Forget Gate)之輸出； X_{ht-1} 為前一期輸出的結果； W_{FG} 為遺忘閥權重； W_{hi} 為前一期輸入值權重； W_{hIG} 前一期輸入閥權重； W_{hFG} 為前一期遺忘閥權重； W_{hOG} 為前一期輸出閥權重。



圖三 本研究LSTM模型Memory Block架構圖

資料來源：改繪自Zaremba et al.(2014)

(三) GARCH預測模型

Bollerslev(1986)提出GARCH模型以彌補Engle(1982)提出之ARCH模型缺陷，並指出GARCH模型在於進行條件變異數之調整彈性有比較優異的表現。過去許多文獻表示時間序列資料，經常會因為具有時變性而造成厚尾的高狹峰分配(Leptokurtic)及波動叢聚現象(Volatility Cluster)，當數據中的離群值數量大於常態分配下的機率則容易造成高狹峰分配，然而波動叢聚現象，表示為大的衝擊通常伴隨大波動，則小衝擊通常伴隨小波動。雖然GARCH(p,q)模型擁有許多不同的設定方式，然而GARCH(1,1)模型具有最精簡(parsimonious)之特性，因此許多專家學者普遍採用GARCH(1,1)模型進行實證研究。故此本研究亦採用GARCH(1,1)模型建構房地產市場預測模型並進行預測。GARCH(p,q)模型方法定義如下：

$$y_t | \Omega_t \sim N(X_t, a, \sigma_t^2) \dots\dots\dots (17)$$

$$\varepsilon_t = y_t - X_t a \dots\dots\dots (18)$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \dots\dots\dots (19)$$

其中， X_t 表示為 t 期之 X 變數， a 表示係數， ε_t 表示 t 期之殘差， σ_t^2 表示殘差變異數， q 表示殘差之落後期數， p 表示殘差變異數之落後期數，倘若 $p = 0$ 則表示為ARCH(q)模型。

三、建構房地產市場之預測模型

(一) 資料結構與來源

本研究地區為台灣與雙北地區共3個地區，研究期間為2005Q1至2020Q3共63筆季資料，採用近年來膾炙人口的議題人工智慧技術，並利用其中之深度學習建立房地產市場趨勢之預測模型，變數結合總體經濟變數、網路搜尋量變數、貨幣政策變數、人口結構變數與房地產特有的變數，本研究之輸入變數包括：總體經濟變數、貨幣政策變數、房地產變數、人口結構變數與網路搜尋量變數；預測變數(輸出變數)為國泰房地編制之房價指數(HP)與成交量指數(VOL)。輸入變數彙整如表一所示。

(二) 建構預測房地產市場模型--深度學習

本研究期間為2005Q1至2020Q3共63筆季資料，採用Google Brain開發的Tensorflow機器學習框架，並使用其中Keras來建立房地產市場之預測模型。首先本研究將資料2005Q1至2018Q3共55筆季資料，為深度學習模型之學習資料，並以8:2之常見資料分割將其分成訓練與驗證資料，其中訓練資料為2005Q1至2015Q4共44筆季資料，驗證資料為2016Q1至2018Q3共11筆季資料。

表一 輸入變數彙整表

變數名稱	資料來源	變數名稱	資料來源
經濟變數		非經濟變數	
1.總體經濟變數 消費者信心指數(CSI) 經濟成長率(GDP) 國民可支配所得(PDI) 房價所得比(RHPI) 加權股價指數(TAIEX) 失業率(UR)	台灣經濟新報TEJ	4.人口結構變數 扶養比(DR) 勞動人口數(LF) 淨人口移入數(NI) 總人口數(POP) 家戶人口數(PPH)	中華民國統計資訊網
2.貨幣政策變數 貨幣供給額(M1B) 消費者物價指數(CPI) 房屋貸款利率(HIR)	台灣經濟新報TEJ	5.網路搜尋量變數 公寓與住宅出租類別(ARR) 信用與貸款類別(CL) 房地產類別(RE) 房地產代理商類別(REA)	Google Trend
3.房地產變數 議價率(BR) 建築貸款餘額(CBL) 營造工程指數(CCI) 住宅存量(HS) 所有權登記移轉棟數(NTO) 銷售率(SR)	國泰房地產指數 內政部不動產資訊平台 台灣經濟新報TEJ 內政部不動產資訊平台 台灣經濟新報TEJ 國泰房地產指數		

資料來源：本研究整理

料，最後將2018Q4至2020Q3共8筆季資料作為測試資料，本採用之方式逐年(四季)學習並測試下一季房地產市場之趨勢，每次學習或測試一季，結束後將每次預測的原始資料放回學習與訓練資料中，如圖四所示。

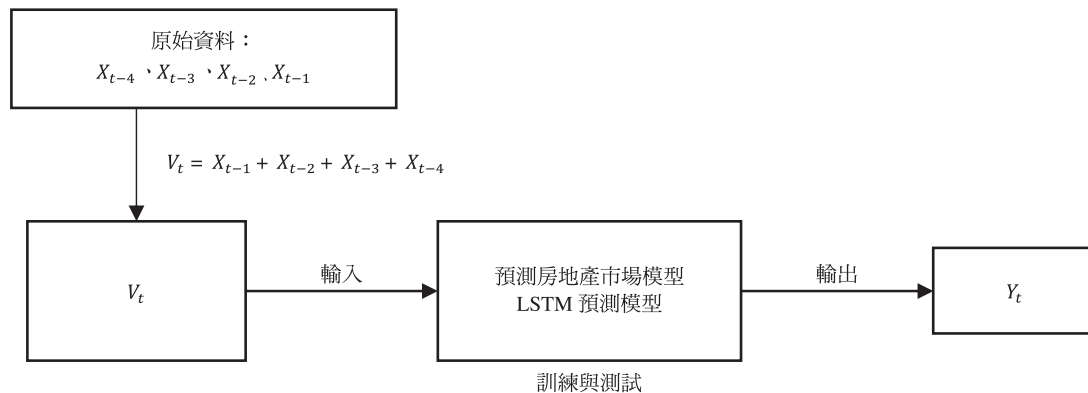
為評估模型之準確性，本研究之實證結果使用兩部分測試，第一部分將測試資料輸入預測模型，並得到預測之結果，而不進行模型之參數調整，第二部分則是將測試資料輸入預測模型，並使用滾動視窗(Rolling Window)與試誤法(Trail & Error)等方法調整模型之參數，如神經元個數或訓練次數等，最後並採用誤差最小之結果為本研究之實證結果。圖五為本研究所建置預測房地產趨勢之模型，其中房價指數與成交量指數預測模型分述如式(20)與式(21)所示。

$$HP_t = \alpha^{HP} + \sum_{i=1}^4 B_i X_{t-i} + \mu_t^{HP} \dots\dots\dots (20)$$

其中， X_t 包含 $BR_t, SR_t, Vol_t, RE_t, REA_t, ARR_t, CL_t, HS_t, POP_t, PPH_t, NI_t, LF_t, DR_t, GDP_t, PDI_t, CSI_t, UR_t, TAIEX_t, MIB_t, CPI_t, HIR_t, CCI_t, CBL_t, NIO_t, RHPI_t$ ； i 為落後期數1,2,3,4。

$$Vol_t = \alpha^{Vol} + \sum_{i=1}^4 B_i X_{t-i} + \mu_t^{Vol} \dots\dots\dots (21)$$

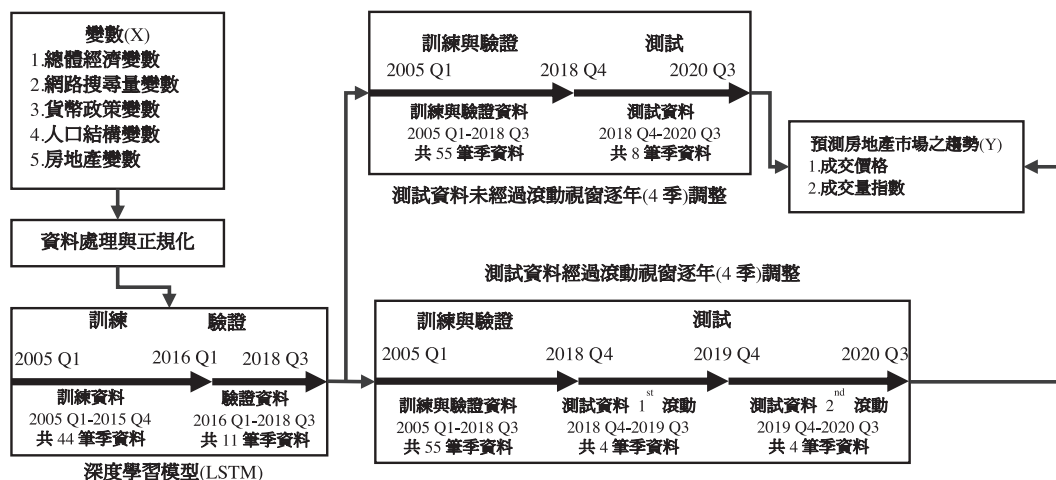
其中， X_t 包含 $BR_t, SR_t, HP_t, RE_t, REA_t, ARR_t, CL_t, HS_t, POP_t, PPH_t, NI_t, LF_t, DR_t, GDP_t, PDI_t, CSI_t, UR_t, TAIEX_t, MIB_t, CPI_t, HIR_t, CCI_t, CBL_t, NIO_t, RHPI_t$ ； i 為落後期數1,2,3,4。



圖四 預測房地產市場之資料處理方法
資料來源：本研究整理

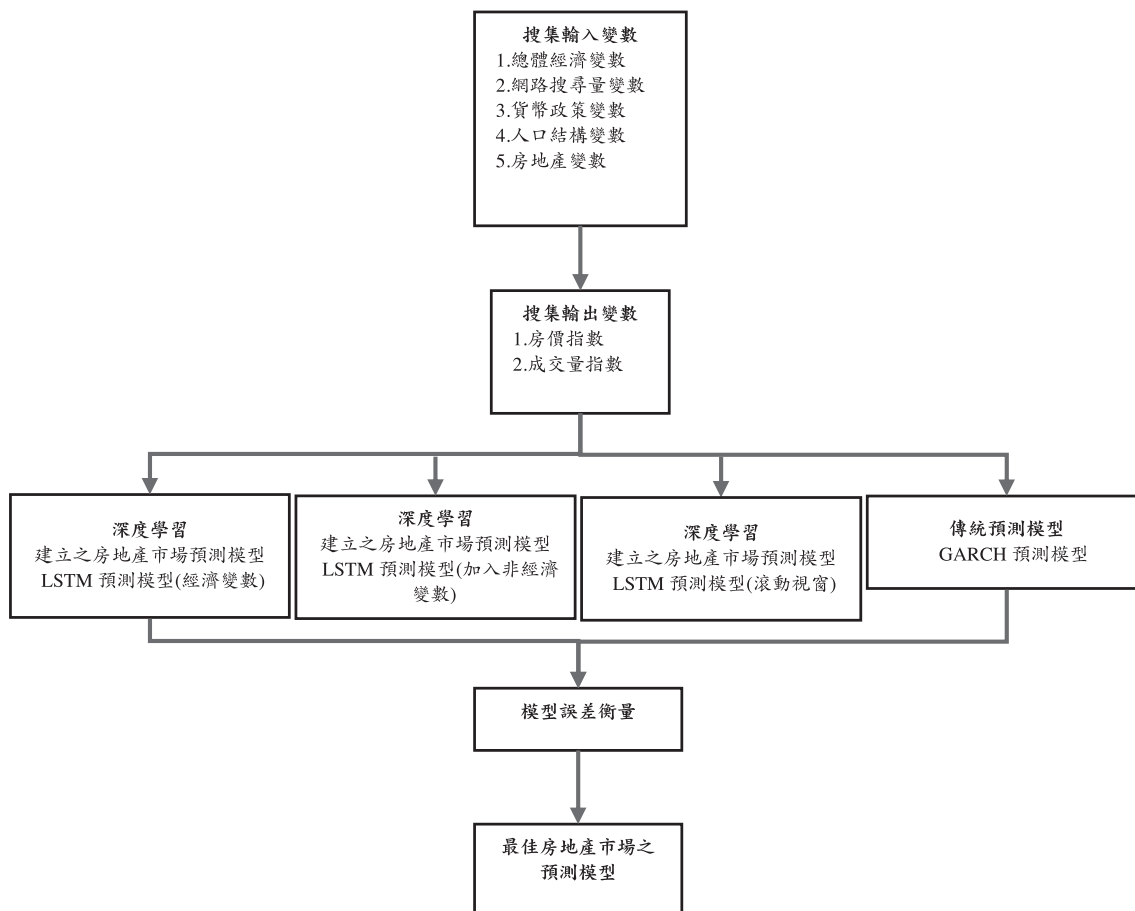
(三) 預測房地產市場模型之衡量

本研究以人工智慧之深度學習技術，結合總體經濟、貨幣政策、房地產特有的變數、人口結構變數與網路搜尋量變數等建構房地產市場趨勢之預測模型，並另外進行滾動視窗逐年(四季)調整模型參數，最後進行LSTM模型、LSTM-滾動視窗模型與GARCH預測模型以RSEM進行比較與分析，以確認本研究所建構模型之穩健性。如圖六所示，為本研究之預測房地產模型之衡量流程圖。



圖五 建構預測房地產市場之深度學習模型

資料來源：本研究整理



圖六 預測房地產模型之衡量流程圖

資料來源：本研究整理

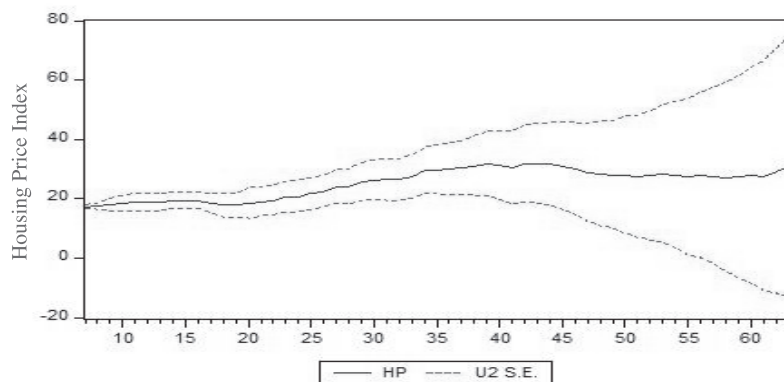
四、實證結果分析

(一) GRACH預測模型

過去深度學習技術尚未像現今被普及運用於各領域時，學者們靈活運用了許多經典的傳統預測模型於各大領域進行研究。為了驗證深度學習是否應用於預測房地產市場，因此，本研究首先採用傳統GARCH模型預測房地產市場後，再進一步與深度學習之LSTM模型進行分析比較，以確立深度學習預測房地產市場之可行性。


本研究在進行GARCH預測模型之前，將所有變數資料透過單根檢定後，將非定態資料進行差分確認為定態資料後，並將所有變數資料基於與深度學習模型相同以落後4季之資料預測下一季之房價指數與成交量指數之方法建構本研究之GARCH預測模型。其結果如圖七至圖十二所示(註1)，其中，圖七至圖九為台灣、台北與新北之房價指數實證結果，顯示由於房價本身具有僵固性的特質，因此各地區於初期皆有優異之預測能力表現，然而由於GARCH模型無法透過不斷的自我學習並記憶，因此於預測後期則因誤差值逐漸放大而逐漸與現實偏離(註2)；此外，圖十至圖十二為台灣、台北與新北之成交量指數實證結果，由於房地產市場成交量容易受到政府政策(如房地合一稅)與其他經濟因素(如金融風暴)等影響而造成成交量指數不易進行預測，且又因GARCH模型無法透過不斷的自我學習並記憶，使得預測結果與現實結果之間誤差隨時間移動而逐漸放大。

綜合上述，雖然GARCH模型不具有訓練與學習之特性，但是房價指數與成交量指數之預測結果仍然具有良好的預測能力，由此證實過去文獻以傳統預測模型GARCH模型於預測房地產市場之可信度。




圖七 台灣地區：GARCH模型預測房價指數之結果

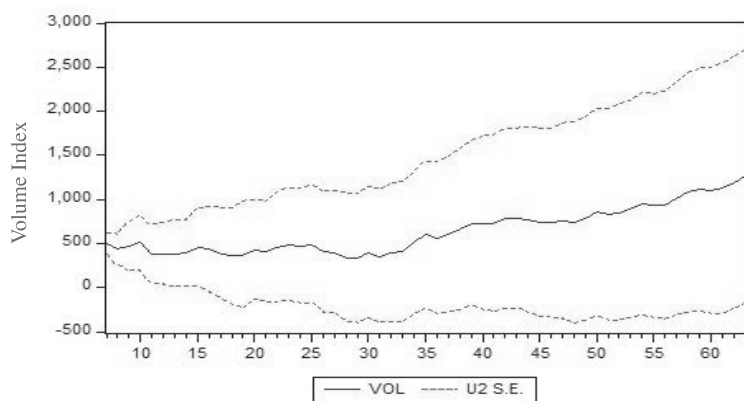
資料來源：本研究實證結果




圖八 台北地區：GARCH模型預測房價指數之結果
資料來源：本研究實證結果




圖九 新北地區：GARCH模型預測房價指數之結果
資料來源：本研究實證結果



圖十 台灣地區：GARCH模型預測成交量指數之結果
資料來源：本研究實證結果



圖十一 台北地區：GARCH模型預測成交量指數之結果
資料來源：本研究實證結果



圖十二 新北地區：GARCH模型預測成交量指數之結果
資料來源：本研究實證結果

(二) LSTM預測模型


本研究除了以經濟變數之LSTM模型預測房地產市場之趨勢外，也因現今網路資訊發達，購屋者於購屋前搜集資料之行為，以及台灣所面臨少子化與高齡化的問題，故將LSTM預測模型加入非經濟變數(人口結構變數與網路搜尋量變數)進行預測，最後針對兩者的實證結果進行分析與比較。

預測模型進行學習訓練過程中，因為輸入之變數資料之間差異過大，進而造成影響實證之結果，因此本研究將所有變數進行平均值正規化處理，將變數資料(包含輸入與輸出資料)之數值經過正規化處理成同為浮點數之資料型態(註3)，再進行深度學習模型之學習、驗證與訓練。

本研究研究區間為2005年Q1至2020年Q3合計共63筆季資料，首先將本研究區間2005Q1至2018Q3共55筆季變數資料做為模型之學習資料與2018Q4至2020Q3共8筆季資料作為測試資料；採用8:2之常見資料分割方法將學習資料分成訓練與驗證資料，其中訓練資料為2005Q1至2015Q4共44筆季資料，驗證資料為2016Q1至2018Q3共11筆季資料，最後輸入測試資料並透過試誤法的方式逐步測試以誤差最小之值作為最佳實證結果。


1. LSTM預測模型—經濟變數

過去學者常以經濟變數以進行房地產市場之研究，本研究採用過去常被使用之經濟變數，並以LSTM模型預測房地產市場價格指數與成交量指數之趨勢，圖十三至圖十八為LSTM模型預測各地區之結果，顯示預測值與實際值呈現相同之趨勢，證實LSTM模型可應用於預測房地產市場的可行性。且當兩者出現偏離時，因LSTM模型具有訓練與學習的特性，偏離幅度亦會逐漸收斂。本研究採用之經濟變數大多為台灣總體經濟數據，所建構之LSTM預測模型對於整體房地產市場較區域性市場更具有預測能力；其中，台北市為台灣之首都，也是經濟發展之中樞，且人口密度位居台灣第一，故台北地區房價指數與成交量指數之走勢與台灣整體房地產市場雷同，預測結果也相似。新北地區預測結果，一開始呈現偏離較大的現象，但隨著時間經過逐漸收斂，其收斂速度大於台灣地區與台北地區，但此小節僅以經濟變數進行預測，表示此結果與經濟發展趨勢有關，因新北地區近年來產業發展的日新月異，加上人口大量移入而帶動房地產的發展，整體之經濟發展已具有舉足輕重之地位。




圖十三 台灣地區：經濟變數之LSTM模型預測房價指數之結果

資料來源：本研究實證結果

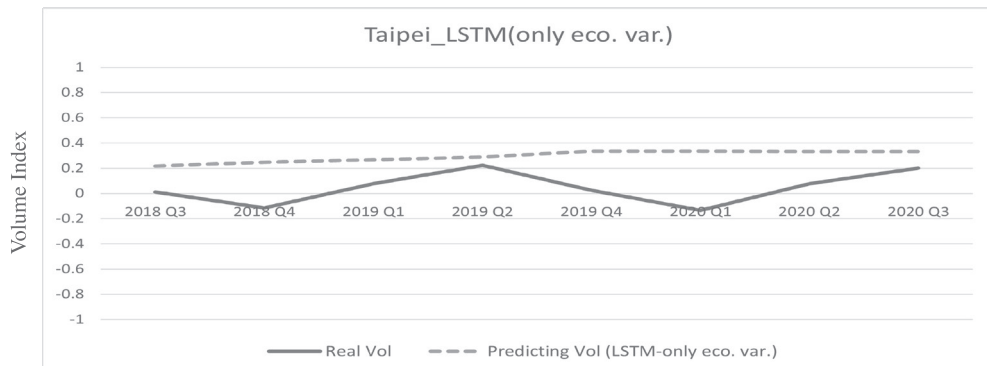


圖十四 台灣地區：經濟變數之LSTM模型預測成交量指數之結果


資料來源：本研究實證結果




圖十五 台北地區：經濟變數之LSTM模型預測房價指數之結果
資料來源：本研究實證結果



圖十六 台北地區：經濟變數之LSTM模型預測成交量指數之結果
資料來源：本研究實證結果



圖十七 新北地區：經濟變數之LSTM模型預測房價指數之結果
資料來源：本研究實證結果




圖十八 新北地區：經濟變數之LSTM模型預測成交量指數之結果

資料來源：本研究實證結果

2. LSTM預測模型—加入非經濟變數


近幾年因資訊科技的蓬勃發展，相較於過去資訊不發達的年代，消費者接收商品資訊更多元，更能獲得大量網路之相關資訊，因此改變消費者之購買習慣，在消費前先搜尋商品資訊與評價後，再進行購買決策；另外，許多國家因出生率下降及人口老化之問題，紛紛提出相對應之人口政策，如生育補助、中國取消一胎化政策等，台灣也因出生率逐年創新低與人口迅速老化而面臨人口負成長之趨勢。本研究基於科技網路迅速發展與人口結構改變之情況，除了採用常見之經濟變數外，進一步加入網路搜尋量變數與人口結構變數，建構LSTM模型預測房地產市場之趨勢。

圖十九至圖二十四為LSTM模型預測各地區進房地產市場之趨勢結果，結果顯示過程中偶爾出現偏離的現象，但是由於LSTM預測模型具有訓練與學習之特性，因此會快速修正並收斂至與現實市場趨勢一致。台灣地區之實證結果房價指數與成交量指數除呈現與現實市場產生交會外，並與實際房價指數與成交量指數穩合。




圖十九 台灣地區：加入非經濟變數之LSTM模型預測房價指數之結果


資料來源：本研究實證結果




圖二十 台灣地區：加入非經濟變數之LSTM模型預測成交量指數之結果
資料來源：本研究實證結果




圖二十一 台北地區：加入非經濟變數之LSTM模型預測房價指數之結果
資料來源：本研究實證結果



圖二十二 台北地區：加入非經濟變數之LSTM模型預測成交量指數之結果
資料來源：本研究實證結果



圖二十三 新北地區：加入非經濟變數之LSTM模型預測房價指數之結果
資料來源：本研究實證結果



圖二十四 新北地區：加入非經濟變數之LSTM模型預測成交量指數之結果
資料來源：本研究實證結果

最後，本研究以RMSE方法衡量上述兩個預測模型之準確度，表二結果顯示LSTM預測模型於台灣地區加入非經濟變數後，其房價指數與成交量指數之RMSE分別下降約0.033與0.003，準確度則分別提升約22%與6%；台北地區分別下降約0.018與0.002，準確度則分別提升約42%與10%；新北地區則分別下降約0.053與0.018，準確度則分別提升約72%與60%。結果證實外在經濟環境的改變亦會影響房地產市場未來走勢，表示加入網路搜尋變數與人口結構變數能有效提升LSTM預測模型之準確性，與Mankiw & Weil(1989)、Wu & Brynjolfsson(2009)、Toth & Hajdu(2012)、彭建文、蔡怡純(2017)等研究結果相符。故本文後續實證皆以加入非經濟變數之LSTM預測模型，進行後續實證分析。

表二 LSTM預測模型(經濟變數v.s. 加入非經濟變數)之RMSE比較分析結果

	LSTM-only eco. var.	LSTM-add non-eco. var.
台灣地區		
HP	0.151	0.118
VOL	0.052	0.049
台北地區		
HP	0.043	0.025
VOL	0.021	0.019
新北地區		
HP	0.074	0.021
VOL	0.030	0.012

1.HP為預測房價指數的均方根誤差。

2.VOL為預測成交量指數的均方根誤差。

資料來源：本研究實證結果

3.LSTM預測模型—滾動視窗


本研究為提升LSTM預測模型之準確度，採用滾動視窗(Rolling Window)之方法逐年(4季)調整模型參數，故將測試資料在分成兩個部分，將本研究區間2018Q4至2020Q3之變數資料分成2018Q4至2019Q3共4筆季資料，作為測試1st資料；2019Q4至2020Q3共4筆季資料作為測試2nd資料。

首先本研究輸入測試1st資料並採用驗證資料之模型參數，以試誤法的方式逐步測試並進行模型參數調整，如神經元個數、神經層數與神經元個數等，最後並以誤差最小之值作為房地產市場之趨勢預測結果，而後續使用此模型參數進行測試2nd資料之實證結果。圖二十五至圖三十為LSTM預測模型於各地區經過滾動視窗調整後之實證結果，結果顯示LSTM預測模型經過定期滾動視窗之調整後，能夠使LSTM預測模型之結果與現實更貼近；LSTM預測模型於台灣地區之實證結果，結果顯示房價指數與成交量指數之預測結果除具有與現實相符外，且其預測趨勢則更能與現實貼近；且雙北地區之實證結果，顯示房價指數與成交量指數皆因定期調整，使得預測結果收斂並且更加貼近於現實結果。因此本研究證實LSTM模型雖然已具備訓練與學習之特性，但若更能與時俱進的定期調整模型參數，則預測結果會更加與實際市場之指數相符。




圖二十五 台灣地區：LSTM預測模型(滾動視窗)房價指數之結果


資料來源：本研究實證結果



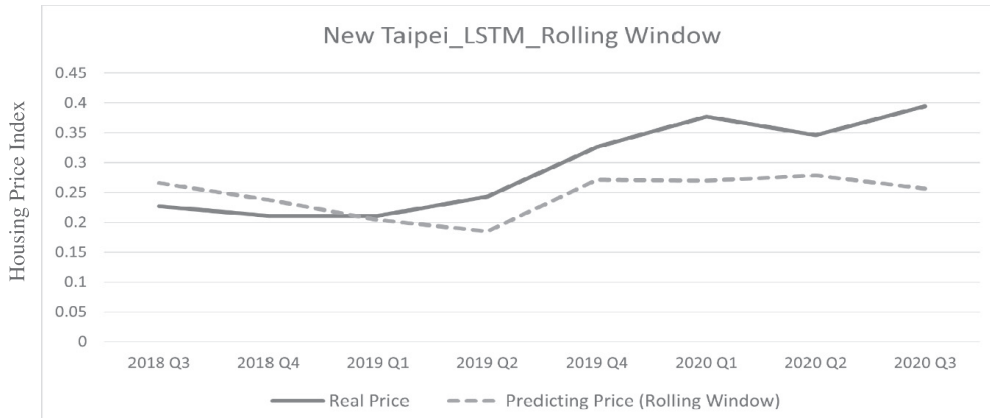
圖二十六 台灣地區：LSTM預測模型(滾動視窗)交易量指數之結果
資料來源：本研究實證結果



圖二十七 台北地區：LSTM預測模型(滾動視窗)房價指數之結果
資料來源：本研究實證結果




圖二十八 台北地區：LSTM預測模型(滾動視窗)交易量指數之結果
資料來源：本研究實證結果



圖二十九 新北地區：LSTM預測模型(滾動視窗)房價指數之結果

資料來源：本研究實證結果




圖三十 新北地區：LSTM預測模型(滾動視窗)交易量指數之結果

資料來源：本研究實證結果

4. LSTM預測結果之分析比較


本節針對加入非經濟變數的LSTM模型與LSTM滾動視窗模型進行實證分析比較，因文章長度有限，僅以台灣地區實證結果進行說明，最終顯示房價指數於2019Q2後，若沒有經過滾動視窗調整模型參數，則其預測結果將會大幅度與現實偏離，如圖三十一所示；此外成交量指數預測模型已具有優秀預測能力，但是經過滾視窗調整參數後，其預測結果則相較於先前之未滾動模型更加貼近現實進而提升模型準確度，如圖三十二所示。

本研究在加入非經濟變數之LSTM預測之實證結果雖比僅以經濟變數之準確度高，但可能因現實環境的政府政策或是發生經濟事件等因素，如：2008年金融海嘯、2016房地合一稅與2019年新冠肺炎等，導致不論是股票市場與房地產市場之嚴重震盪，而出現與現實結果偏離之現象，但經過滾動視窗定期調整模型內參數設定，可以將原本偏離之結果收斂，使其更加接近現實市場之指數。因此結果可以說明，深度學習模型雖然可以透過訓練與學習之特性預測未來房地產市場之趨勢，倘若能與時俱進的定期調整模型參數，則能夠擁有更加優異的預測能力，並大幅度地提升模型之準確度。



圖三十一 台灣地區：LSTM預測房價指數之實證分析

資料來源：本研究實證結果



圖三十二 台灣地區：LSTM預測成交量指數之實證分析

資料來源：本研究實證結果

(三) 預測模型之準確度衡量

經過模型建構與預測後，進一步採用均方根誤差(RMSE)進行深度學習LSTM預測模型與傳統GARCH預測模型之準確度衡量，以證明LSTM模型之可行性。

表三顯示LSTM模型與GARCH模型之RMSE有明顯差異，台灣地區房價指數與成交量之兩預測模型RMSE誤差值分別相差-1.639與-519.466，表示準確度分別提升約93%與99%、台北地區房價指數與成交量之兩預測模型RMSE分別相差-9.746與-172.416，則表示準確度兩者皆提升約99%，新北地區房價指數與成交量之兩預測模型RMSE分別相差-3.89與-230.185，結果與台北地區一樣皆提升約99%，由此證實LSTM預測模型之預測能力優於GARCH預測模型，結果和Xiong et al.(2015)與Song et al.(2020)一致，且具有預測未來房地產市場趨勢之可行性。

此外，本研究為提升LSTM預測模型之準確性，利用滾動視窗(Rolling Window)之方法逐年(4季)調整模型參數，並採用預測誤差最小值作為預測結果，結果表明LSTM預測模型經過滾動視窗調整後於各地區之房地產市場預測結果相較於未滾動模型尤佳，其中加入非經濟變數之LSTM預測模型與滾動視窗LSTM預測模型之均方根誤差(RMSE)有明顯下降，表三顯示台灣地區房價指數與成交量之RMSE分別下降了0.11及0.03，準確度則分別提升約93%與61%、台北

地區房價指數與成交量之RMSE分別下降了0.022與0.013，準確度則分別提升約88%與68%新北地區房價指數與成交量之RMSE分別下降了0.019與0.008，準確度則分別提升約90%與67%。

其次，經過第二次滾動視窗調整後，各地區之RMSE相較第一次滾動亦有優秀之預測能力表現，台灣地區房價指數與成交量之RMSE分別收斂了0.004及0.007，相較第一次滾動準確度則分別提升50%與37%、台北地區房價指數與成交量之RMSE分別收斂了0.001與0.001，準確度則分別提升33%與17%，新北地區房價指數與成交量之RMSE分別收斂了0.001與0.001，準確度則分別提升50%與25%，由此可知LSTM預測模型經過滾動視窗調整後，其預測結果能夠更加趨近現實。

表三 房地產市場預測模型之RMSE比較分析結果

	GARCH	LSTM	LSTM-1 st Rolling Window	LSTM-2 nd Rolling Window
台灣地區				
HP	1.757	0.118	0.008	0.004
VOL	519.515	0.049	0.019	0.012
台北地區				
HP	9.771	0.025	0.003	0.002
VOL	172.435	0.019	0.006	0.005
新北地區				
HP	3.911	0.021	0.002	0.001
VOL	230.197	0.012	0.004	0.003

1. HP為預測房價指數的均方根誤差。

2. VOL為預測成交量指數的均方根誤差。

資料來源：本研究實證結果

五、結論與建議

本研究主要為探討人工智慧之深度學習技術於預測房地產市場趨勢之可行性，首先除了採用經濟變數外，因近年科技蓬勃發展民眾接收資訊習慣也隨之改變，故採用Google Trend所提供之搜尋量指數，以購屋者對於房地產市場搜尋之相關資訊建立網路搜尋變數；此外，台灣正面臨人口逐年老化與出生率逐年下降等人口結構問題，故同時納入人口結構等非經濟變數進行預測。實證結果顯示LSTM預測模型加入網路搜尋量與人口結構等非經濟變數後，其預測能力優於僅利用經濟變數之LSTM預測模型，其中，台灣地區房價指數與成交量指數之RMSE分析結果顯示分別下降約0.033與0.003，準確度分別提升22%與6%，故證實加入非經濟變數LSTM預測模型於房地產市場具有更加優秀的預測能力。

此外，本研究為提升LSTM預測模型之準確度，利用滾動視窗方式調整模型參數以提升模型之準確度，LSTM模型雖然已具有訓練與學習之特性，若可適時與時俱進執行參數調整，則可得到更加優異之預測能力；本研究結果發現經過兩次滾動視窗調整後，台灣、台北及新北地區房價指數與成交量指數之RMSE結果，皆具收斂效果，相較未調整之LSTM模型準確度分別提升至97%與76%，故證實LSTM預測模型加入逐年滾動視窗參數調整後，相較於未滾動之

LSTM模型，更能使偏離有效地收斂，並接近實際指數之結果。

最後本研究比較LSTM模型與傳統GARCH模型於房地產市場趨勢之預測能力，因LSTM深度學習模型具有訓練與學習之特性，因此所預測結果與現實情況更為接近，其中台灣、台北及新北地區房價指數與成交量指數之RMSE分析，台灣地區兩者相差1.639與519.466、台北地區兩者相差9.746與172.416及新北地區兩者相差3.89與230.185，故證實LSTM預測模型預測值優於GARCH預測模型，且具有預測未來房地產市場趨勢之可行性。

綜合上述，當LSTM預測模型加入非經濟變數，使其具有因應非總體經濟影響市場變化之能力，進而提升其預測效果。且LSTM預測模型之實證結果相較於GARCH預測模型有著優異的預測表現，因LSTM預測模型雖然具有訓練與學習之特性。且模型經過滾動視窗之逐年調整後，其預測結果更加符合現實情況，因此本研究證實LSTM預測模型經過定期調整其參數後，則能夠大幅度地提升其預測能力，並可運用於預測房地產之房價指與成交量指數；證明人工智慧預測模型可落地應用於房地產市場，除了對政府在制定房地產政策有貢獻外，亦可提供房地產業者在購地規劃、推案規劃與推案數量等決策之參考。

註 釋

- 註1：本研究透過單根檢定後，將非定態資料進行差分，確認為定態資料後再進行GARCH模型預測，圖七至圖十三之Y軸呈現之數字為差分後數字。
- 註2：圖七至圖十二所顯示之U2 S.E.，為標準不確定度(Uncertainty Coefficient in 2 Standard Error)，表示未來預測結果將落在此區間之中。
- 註3：本研究在深度學習模型學習、驗證與訓練之前，將所有變數以平均值正規化處理，故圖形十三至三十二之Y軸呈現之數字為正規化後數字。

參考文獻

一、中文部份

林左裕

2019 〈應用網路搜尋行為預測房地產市場〉《應用經濟論叢》105：219-254。

Lin, C. T.

2019 “Predicting Housing Markets through the Searching Behavior on Internet,” *Taiwan Journal of Applied Economics*. 105: 219-254.

高慈敏

2014 〈經濟波動與房地產交易之價量關係：搜索模型之應用〉《住宅學報》23(2)：21-55。

Kao, T. M.

2014 “Economic Fluctuations, Prices and Trading Volume in the Housing Markets: An Application of a Search Model,” *Journal of Housing Studies*. 23(2): 21-55.

彭建文

2015 〈總體政經與房地產關聯分析〉《2015年台灣房地產年鑑》台北：行義文化出版有限公司。

Peng, C. W

2015 “An analysis of the connections between general politics, economics, and real estate,” *2015 Taiwan Real Estate Almanac*. Taipei: Hsing Yi Culture Publishing Co., Ltd.

彭建文、蔡怡純

2017 〈人口結構變遷對房價影響分析〉《經濟論文叢刊》45(1)：163-192。

Peng, C. W. & I. C. Tsai

2017 “The Effects of Demographic Structure Change on Housing Prices,” *Taiwan Economic Review*. 45(1): 163-192.

蔡怡純、陳明吉

2004 〈台北地區住宅市場結構性轉變與價格均衡調整〉《都市與計劃》31(4)：365-390。

2008 〈台北地區不動產價格波動之不對稱性探討〉《住宅學報》17(2)：1-11。

Tsai, I. C. & M. C. Chen

2004 “Structural Change in the Taipei Housing Market and Price Equilibrium Adjustment,” *City and Planning*. 31(4): 365-390.

2008 “An Analysis of the Asymmetric Volatility of Real Estate Price in the Taipei Area,” *Journal of Housing Studies*. 17(2): 1-11.

二、英文部份

Addae-Dapaah, K.

2014 “Housing Loan and the Price of Housing in Singapore,” *Journal of Business and Economics*. 5(9): 1513-1524.

- Adams, Z. & R. Füß
- 2010 “Macroeconomic determinants of international housing markets,” *Journal of Housing Economics*. 19(1): 38-50.
- Anundsen, A. K., K. Gerdrup, F. Hansen & K. Kragh-Sørensen
- 2016 “Bubbles and Crises: The Role of House Prices and Credit,” *Journal of Applied Econometrics*. 31(7): 1291-1311.
- Aoki, K., J. Proudman & G. Vlieghe
- 2004 “House Prices, Consumption, and Monetary Policy: A Financial Accelerator Approach,” *Journal of Financial Intermediation*. 13(4): 414-435.
- Atteberry, W. & R. Rutherford
- 1993 “Industrial Real Estate Prices and Market Efficiency,” *Journal of Real Estate Research*. 8(3): 377-385.
- Ayan, E. & S. Eken
- 2021 “Detection of Price Bubbles in Istanbul Housing Market Using LSTM Autoencoders: A District-Based Approach,” *Soft Computing*. 25(12): 7957-7973.
- Bagliano, F. C. & C. Morana
- 2012 “The Great Recession: US Dynamics and Spillovers to The World Economy,” *Journal of Banking & Finance*. 36(1): 1-13.
- Bao, T. Q. & B. T. T. My
- 2019 “Forecasting Stock Index Based on Hybrid Artificial Neural Network Models,” *Science & Technology Development Journal-Economics-Law and Management*. 3(1): 52-57.
- Bao, W., J. Yue & Y. Rao
- 2017 “A deep learning framework for financial time series using stacked autoencoders and long-short term memory.” *PloS one*, 12(7), e0180944.
- Beracha, E. & M. B. Wintoki
- 2013 “Forecasting residential real estate price changes from online search activity,” *Journal of Real Estate Research*. 35(3): 283-312.
- Bollerslev, T.
- 1986 “Generalized Autoregressive Conditional Heteroskedasticity,” *Journal of Econometrics*. 31(3): 307-327.
- Cai, F.
- 2010 “Demographic Transition, Demographic Dividend, and Lewis Turning Point in China,” *China Economic Journal*. 3(2): 107-119.
- Can, A.
- 1992 “Specification and Estimation of Hedonic Housing Price Models,” *Regional Science and Urban Economics*. 22(3): 453-474.
- Chan, S.
- 2001 “Spatial Lock-In: Do Falling House Prices Constrain Residential Mobility?” *Journal of Urban Economics*. 49(3): 567-586.

Chang, K. L.

- 2010 “House Price Dynamics, Conditional Higher-Order Moments, and Density Forecasts,” *Economic Modelling*. 27(5): 1029-1039.

Charles, L., L. Garion & L. Youngman

- 2002 “Testing Alternative Theories of The Property Price-Trading Volume Correlation,” *Journal of Real Estate Research*. 23(3): 253-264.

Choi, H. & H. Varian

- 2012 “Predicting the present with Google Trends,” *Economic record*. 88: 2-9.

Choi, J. H., H. K. Park, J. E. Park, C. M. Lee & B. G. Choi

- 2018 “Artificial Intelligence to Forecast New Nurse Turnover Rates in Hospital,” *Journal of the Korea Convergence Society*. 9(9): 431-440.

Chou, J. S. & T. K. Nguyen

- 2018 “Forward Forecast of Stock Price Using Sliding-Window Metaheuristic-Optimized Machine-Learning Regression,” *Transactions on Industrial Informatics*. 14(7): 3132-3142.

Crawford, G. W. & M. C. Fratantoni

- 2003 “Assessing the Forecasting Performance of Regime-Switching, ARIMA and GARCH Models of House Prices,” *Real Estate Economics*. 31(2): 223-243.

Crone, T. M. & R. P. Voith

- 1992 “Estimating House Price Appreciation: A Comparison of Methods,” *Journal of Housing Economics*. 2(4): 324-338.

Engle, R. F.

- 1982 “Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation,” *Journal of The Econometric Society*. 50(4): 987-1007.

Del Negro, M. & C. Otrok

- 2007 “Monetary Policy and The House Price Boom Across US States,” *Journal of Monetary Economics*. 54(7): 1962-1985.

Dolde, W. & D. Tirtiroglu

- 1997 “Temporal and Spatial Information Diffusion in Real Estate Price Changes and Variances,” *Real Estate Economics*. 25(4): 539-565.

Dubin, R. A.

- 1998 “Predicting House Prices Using Multiple Listings Data,” *The Journal of Real Estate Finance and Economics*. 17(1): 35-59.

Fan, G. Z., S. E. Ong & H. C. Koh

- 2006 “Determinants of House Price: A Decision Tree Approach,” *Urban Studies*. 43(12): 2301-2315.

Favilukis, J., S. C. Ludvigson & S. Van Nieuwerburgh

- 2017 “The Macroeconomic Effects of Housing Wealth, Housing Finance, and Limited Risk Sharing in General Equilibrium,” *Journal of Political Economy*. 125(1): 140-223.

- Ferrero, A.
 2015 “House Price Booms, Current Account Deficits, and Low Interest Rates,” *Journal of Money, Credit and Banking*. 47(S1): 261-293.
- Gers, F. A. & J. Schmidhuber
 2000 “*Recurrent Nets That Time and Count*,” International Joint Conference on Neural Networks.
- Ginsberg, J., M. H. Mohebbi, R. S. Patel, L. Brammer, M. S. Smolinski & L. Brilliant
 2009 “Detecting Influenza Epidemics Using Search Engine Query Data,” *Nature*. 457(7232): 1012-1014.
- Greenwood, J. & Z. Hercowitz
 1991 “The Allocation of Capital and Time Over the Business Cycle,” *Journal of political Economy*. 99(6): 1188-1214.
- Guirguis, H. S., C. I. Giannikos & R. I. Anderson
 2005 “The US Housing Market: Asset Pricing Forecasts Using Time Varying Coefficients,” *The Journal of real estate finance and economics*. 30(1): 33-53.
- Han, Q.
 2019 “Research on Demographic Dividend, Lewis Turning Point, Saving and Economic Growth,” *International Journal of Business and Social Science*. 10(6): 20-34.
- Hansen, J.
 2009 “Australian House Prices: A Comparison of Hedonic and Repeat-Sales Measures,” *Economic Record*. 85(269): 132-145.
- Hochreiter, S. & J. Schmidhuber
 1997 “Long Short-Term Memory,” *Neural computation*. 9(8): 1735-1780.
- Huang, K. H., Y. T. Hui-Kuang & M. Rodriguez-Garcia
 2020 “Qualitative Analysis of Housing Demand Using Google Trends Data,” *Economic research-Ekonomska istraživanja*. 33(1): 2007-2017.
- Hwang, M. & J. M. Quigley
 2006 “Economic Fundamentals in Local Housing Markets: Evidence from US Metropolitan Regions,” *Journal of Regional Science*. 46(3): 425-453.
- Jud, G. D. & D. T. Winkler
 2002 “The Dynamics of Metropolitan Housing Prices,” *The Journal of Real Estate Research*, 23(1/2): 29-46.
- Kim, C. H. & K. H. Kim
 2000 “The Political Economy of Korean Government Policies on Real Estate,” *Urban Studies*. 37(7): 1157-1169.
- Krittanawong, C.
 2018 “The Rise of Artificial Intelligence and the Uncertain Future For Physicians,” *European Journal of Internal Medicine*. 48: 13-14.

- Kuruzovich, J., S. Viswanathan, R. Agarwal, S. Gosain & S. Weitzman
2008 “Marketspace or Marketplace? Online Information Search and Channel Outcomes in Auto Retailing,” *Information Systems Research*. 19(2): 182-201.
- Lacoviello, M.
2005 “House Prices, Borrowing Constraints, and Monetary Policy in The Business Cycle,” *American Economic Review*. 95(3): 739-764.
- Lee, C. & K. K. H. Park
2020 “Representing Uncertainty in Property Valuation Through A Bayesian Deep Learning Approach,” *Real Estate Management and Valuation*. 28(4): 15-23.
- Leung, C. K. Y., & D. Feng
2005 “What Drives the Property Price-Trading Volume Correlation? Evidence from A Commercial Real Estate Market,” *The Journal of Real Estate Finance and Economics*. 31(2): 241-255.
- Limsombunchai, V.
2004 “House Price Prediction: Hedonic Price Model Vs. Artificial Neural Network,” New Zealand Agricultural and Resource Economics Society Conference.
- Malpezzi, S.
1999 “A Simple Error Correction Model of House Prices,” *Journal of Housing Economics*. 8(1): 27-62.
- Mankiw, N. G. & D. N. Weil
1989 “The Baby Boom, the Baby Bust, and the Housing Market,” *Regional Science and Urban Economics*. 19(2): 235-258.
- Marcato, G. & A. Nanda
2016 “Information content and forecasting ability of sentiment indicators: case of real estate market,” *Journal of Real Estate Research*. 38(2): 165-203.
- Milunovich, G.
2020 “Forecasting Australia’s Real House Price Index: A Comparison of Time Series and Machine Learning Methods,” *Journal of Forecasting*. 39(7): 1098-1118.
- Nelson, P.
1970 “Information and Consumer Behavior,” *Journal of Political Economy*. 78(2): 311-329.
- Nelson, D. M., A. C. Pereira & R. A. de Oliveira
2017 “Stock market’s price movement prediction with LSTM neural networks,” 2017 International joint conference on neural networks.
- Otrok, C. & M. E. Terrones
2005 “House Prices, Interest Rates and Macroeconomic Fluctuations: International Evidence,” International Monetary Fund.

Özsoy, O. & H. Şahin

- 2009 “Housing Price Determinants in Istanbul, Turkey: An Application of The Classification and Regression Tree Model,” *International Journal of Housing Markets and Analysis*. 2(2):167-178.

Park, B. & J. K. Bae

- 2015 “Using Machine Learning Algorithms for Housing Price Prediction: The Case of Fairfax County, Virginia Housing Data,” *Expert Systems with Applications*. 42(6): 2928-2934.

Parreco, J., A. Hidalgo, R. Kozol, N. Namias & R. Rattan

- 2018 “Predicting Mortality in the Surgical Intensive Care Unit Using Artificial Intelligence and Natural Language Processing of Physician Documentation,” *The American Surgeon*. 84(7): 1190-1194.

Rai, B.

- 2017 “Feature Selection and Predictive Modeling of Housing Data Using Random Forest,” *International Journal of Industrial and Systems Engineering*. 11(4): 5.

Rather, A. M., A. Agarwal & V. N. Sastry

- 2015 “Recurrent Neural Network and A Hybrid Model for Prediction of Stock Returns,” *Expert Systems with Applications*. 42(6): 3234-3241.

Raymond, Y. C.

- 1997 “An Application of the ARIMA Model to Real-Estate Prices in Hong Kong,” *Journal of Property Finance*. 8(2): 152-163.

Selim, H.

- 2009 “Determinants of House Prices in Turkey: Hedonic Regression Versus Artificial Neural Network,” *Expert systems with Applications*. 36(2): 2843-2852.

Song, X., Y. Liu, L. Xue, J. Wang, J. Zhang & Z. Cheng

- 2020 “Time-Series Well Performance Prediction Based on Long Short-Term Memory (LSTM) Neural Network Model,” *Journal of Petroleum Science and Engineering*, 186: 106682.

Taylor, J. B.

- 2007 “*Housing and monetary policy*,” National Bureau of Economic Research.

Toth, I. J. & M. Hajdu

- 2012 “*Google as A Tool for Nowcasting Household Consumption: Estimations on Hungarian Data*,” Proceedings of the 31th Conference of Centre for International Research on Economic Tendency Surveys.

Tsai, I C.

- 2018 “The Cause and Outcomes of the Ripple Effect: Housing Prices and Transaction Volume,” *The Annals of Regional Science*. 61(2): 351-373.
- 2019 “Dynamic Price–Volume Causality in the American Housing Market: A Signal of Market Conditions,” *The North American Journal of Economics and Finance*. 48: 385-400.

Vargas-Silva, C.

- 2008 “Monetary Policy and the US Housing Market: A VAR Analysis Imposing Sign Restrictions,” *Journal of Macroeconomics*, 30(3): 977-990.

Varian, H.

- 2018 “*Artificial Intelligence, Economics, and Industrial Organization*,” National Bureau of Economic Research.

Wallace, N. E. & R. A. Meese

- 1997 “The Construction of Residential Housing Price Indices: A Comparison of Repeat-Sales, Hedonic-Regression, And Hybrid Approaches,” *The Journal of Real Estate Finance and Economics*. 1(14): 51-73.

Wang, F., Y. Zou, H. Zhang, & H. Shi

- 2019 “*House Price Prediction Approach Based on Deep Learning and ARIMA Model*,” 2019 IEEE 7th International Conference on Computer Science and Network Technology.

Wang, Y. H.

- 2009 “Nonlinear Neural Network Forecasting Model for Stock Index Option Price: Hybrid GJR-GARCH Approach,” *Expert Systems with Applications*. 36(1): 564-570.

Worzala, E., M. Lenk & A. Silva

- 1995 “An Exploration of Neural Networks and Its Application to Real Estate Valuation,” *Journal of Real Estate Research*. 10(2): 185-201.

Wu, L. & E. Brynjolfsson

- 2009 “*The Future of Prediction: How Google Searches Foreshadow Housing Prices and Quantities*,” International Conference on Information Systems.

- 2015 “*The Future of Prediction: How Google Searches Foreshadow Housing Prices and Sales*,” In *Economic analysis of the digital economy*. Chicago: University of Chicago Press.

Xiong, R., E. P. Nichols & Y. Shen

- 2015 “*Deep Learning Stock Volatility with Google Domestic Trends*,” *Arxiv Preprint: 1512.04916*. (<https://arxiv.org/abs/1512.04916>)

Xu, X. E. & T. Chen

- 2012 “The Effect of Monetary Policy on Real Estate Price Growth In China,” *Pacific-Basin Finance Journal*. 20(1): 62-77.

Yi, J. & J. Zhang

- 2010 “The Effect of House Price on Fertility: Evidence from Hong Kong,” *Economic Inquiry*. 48(3): 635-650.

Yu, L., C. Jiao, H. Xin, Y. Wang & K. Wang

- 2018 “Prediction on Housing Price Based on Deep Learning,” *International Journal of Computer and Information Engineering*. 12(2): 90-99.

Yue, S. & L. Hongyu

2004 “Housing Prices and Economic Fundamentals: A Cross City Analysis of China for 1995-2002,” *Economic Research Journal*. 6: 78-86.

Yunfang, L. & G. Tiemei

2007 “Empirical Analysis on Real Estate Price Fluctuation in Different Provinces of China,” *Economic Research Journal*. 8: 133-142.

Zaremba, W., I. Sutskever & O. Vinyals

2014 “*Recurrent Neural Network Regularization*,” Arxiv Preprint:1409.2329. (<https://arxiv.org/abs/1409.2329>)

