

學術論著

應用類神經網路於電腦輔助大量估價之研究*

Applying the Artificial Neural Network in Computer-assisted Mass Appraisal*

賴碧瑩**

Peddy, Pi-Ying Lai**

摘要

政府機關之不動產估價作業主要是提供課稅地價為目的而衍生之行政工作，目前台灣主要以路線估價作業方式處理公部門地價，因此往往需要投入大量的人力、經費。此與歐美等國普遍應用的電腦輔助大量估價作業(computer assisted mass appraisal, CAMA)有極大差異。90年代初期，由於資訊產業的快速成長，利用電腦模擬人類思考模式，而發展出來的類神經網路(artificial neural network, ANN)演算方法被廣泛地運用於各種不同層面的研究。直到90年代後期才慢慢的被運用在不動產估價。

本研究將分別運用特徵價格及倒傳遞類神經網路預測高雄市不動產價格，試圖建立一套大量估價模型。經研究實證分析得知，在總體樣本數時，倒傳遞類神經網路預測較特徵價格法之預測能力較佳。但是如果將樣本區分為90%樣本內及10%樣本外資料，特徵價格法之預測能力較佳，而這樣的實證結果說明，在運用各式估價模型時，可以進行交互驗證並且從中找出最適估價模型。

關鍵詞：電腦輔助大量估價、類神經網路、特徵價格、房價

ABSTRACT

In early times, the land value assessments in Taiwan were made manually and wasted too much manpower, which was very different from the computer-assisted mass appraisal approach adopted in Western countries. In the early 1990's, due to the development of information technology, many researchers imitated the functioning of the human brain to develop the neural network and it was applied in different areas. In the late 1990s, the back-propagation neural network (BPN) was applied to real estate appraisal.

This study applies the back-propagation neural network and hedonic price method to predict real estate prices in Kaohsiung city. We evaluate the model performance of the BPN and hedonic price in forecasting Kaohsiung's property prices. Two criteria are used, namely, the mean absolute percentage error (MAPE) and the forecasting error (FE). Regardless of which of the BPN approach or the hedonic price model is used, both are found to have similar forecasting power.

Key words: computer assisted mass appraisal (CAMA), artificial neural network (ANN), back-propagation neural network (BPN), hedonic price, property price

(本文於2007年4月2日收稿，2007年9月13日審查通過，實際出版日期2007年12月)

* 本文感謝兩位匿名審查委員的寶貴意見與指正，使得本文內涵更加豐富充實。

** 國立屏東商業技術學院不動產經營系(所)副教授。

Associate Professor, Department of Real Estate Management, National Pingtung Institute of Commerce, Pingtung, Taiwan, R.O.C.

一、前言

根據內政部統計處顯示，2004年國內已登記土地總計1千4百多萬筆，而課稅土地亦高達1千3百多萬筆，在這龐大資料下，如何採取一個有效且經濟的估價模式，對政府機構而言，其重要性不言可喻。一般而言，不動產估價主要作為土地交易買賣價格、抵押貸款、法院拍賣底價訂定、法院訴訟、土地徵收、不動產課稅、不動產投資、會計帳資產價值、都市更新權利轉換、不動產證券化等價格參考依據之用。其中，土地估價作業量體相當地龐大，因此過去有相當多學者致力於電腦系統、統計分析、地理資訊系統等輔助工具協助課稅估價作業，由於這些作業不易且資料複雜，因此私部門涉獵情形較不普遍。

事實上，從1996年代開始外國即逐步推展電腦輔助大量估價(computer assisted mass assessment, CAMA)近年來CAMA已成為許多國家稅務上的輔助工具，且越來越多國家加入此一趨勢。台灣1990年代初期進行過相關研究後，再也沒有推動的跡象，至今已逾十年。近年來內政部則擬學習日本「標準宗地」制度推動「基準地」，作為台灣評定地價制度之作法。標準宗地發源地之日本亦加強利用電腦與地理資訊系統GIS之協助進行大量估價。而在美國電腦大量估價不僅為公部門所用，同時也發展成為輔助房貸授信時的自動估價系統(automated valuation model, AVN)。何謂電腦輔助大量估價(computer assisted mass assessment, CAMA)?國際不動產估價協會(International Association of Assessing Office, IAAO)於2000年之定義指出電腦輔助大量估價是利用電腦來輔助提供依標準化程序，進行大量的不動產估價，而非僅是藉電腦做資料處理。因此，電腦輔助大量估價與國內目前利用電腦輔助計算各宗地的公告現值與公告地價之所謂的「大量估價」顯有不同。(華昌宜等，2004)(註1)。

90年代初期，由於資訊產業的快速成長，利用電腦模擬人類思考模式，而發展出類神經網路(artificial neural network, ANN)演算法被廣泛運用於各種不同層面的研究。倒傳遞類神經網路是由McClelland & Rumelhart於1986年所共同發表，是一種監督式的類神經網路。爾後，許多學者紛紛開始探討將其運用在財務領域的可行性，嘗試進行預測。90年代早期並沒有不動產研究人員重視，直到90年代後期才慢慢地被運用在不動產估價。

本研究欲運用類神經網路模型及特徵價格模型分析高雄市地政處之買賣交易實例個案。並輔以相關檢測指標探索兩個模型間的預測能力。本研究總共分為五大部分，一為前言；二為相關文獻回顧；三為類神經網路理論說明；四為倒傳遞類神經網路及特徵價格模型建立與預測分析；五為研究結論與建議。

二、相關文獻回顧

國外推動電腦輔助大量估價已行之有年，根據過去研究文獻得知，多數學者在研究電腦輔助大量估價時多採多元迴歸模式進行分析，並進一步與倒傳遞類神經網路模型分析比較之，根據過往研究結果顯示，多數研究結果顯示類神經網路較多元迴歸分析較為準確(McGreal et al., 1998; Din et al., 2001; Wong et al., 2001)；不過也有一些研究顯示多元迴歸在大樣本與變異數一致情況下其預測效果較倒傳遞類神經網路好(Markham & Rakes, 1998)。甚至有些學者主張採取例如演化策略法、遺傳演算法來改善倒傳遞類神經網路學習模組(Chen et al., 2000)，對此，我們將分析國內外過去有關類神經網路不動產價格模式研究的情形，以利更深入之比較

分析工作。

Tay & Ho(1991)運用類神經網路與多元迴歸分析方法在新加坡公寓類型不動產價格預測，其訓練範例822筆，測試範例為222筆，其研究顯示類神經網路模型之絕對誤差為3.9%；多元迴歸模型之絕對誤差為7.5%，實證結果指出類神經網路優於多元迴歸。同樣地，Do & Grundnitski(1993)使用美國105筆住宅不動產交易資料進行測試，研究顯示類神經網路模型預測能力較多元迴歸分析好，其絕對誤差分別為6.9%與11.3%。Evans et al.(1992)使用英國住宅類型不動產價格進行預測，其有效樣本為34筆，其研究結果顯示類神經網路之絕對誤差為13.48%，Evans et al.(1992)認為類神經網路雖可以輔助估價人員進行大量估價，但必須謹慎篩選訓練資料。

Worzala et al. (1995)提出了關於傳統迴歸分析與類神經網路之說明，他認為不同電腦軟體預測相同類神經網路模型時，結果會不一致，再者，具相同類神經網路模型，如再重新操作其結果也會不同，因為類神經網路模型每次的原始訓練隱藏層的節點原始權值是隨機產生，而且樣本位於同一地區來進行測試，這些均有助於類神經網路預測準確度，所以作者認為類神經網路預測穩定度並不一定優於多元迴歸模型。McCluskey et al.(1997)以北愛爾蘭之416筆住宅價格進行網路訓練，類神經網路模型之絕對誤差為15.7%，正確率為72%；然而經刪除異常值後絕對誤差為7.75%正確率為93.6%。McCluskey認為類神經網路對於直接或間接決定住宅影響因子之價格模型有其優越性。

爾後，McGreal et al.(1998)利用英國Belfast，1992及1993年資料，共1026筆住宅價格分析，其研究結果認為同一屬性之資料有助於產生較精準結果；但因類神經網路模型在學習過程具有黑箱特性，此為其主要缺點；當樣本數越大越有助於類神經網路的準確性。Nguyen & Cripps(2001)明確表示類神經網路與多元迴歸之差異，作者認為當樣本數越大時，類神經模型之預測優於多元迴歸分析，反之，多元迴歸分析較佳，其次，如果類神經網路之參數設定較複雜時，其訓練範例也必須增加，如此一來模型才能較多元迴歸分析佳。

Wong et al.(2002)分析香港房價，作者利用總樓地板面積、樓層高度、房間/浴室之比率、客廳數、主臥房景觀、建築物之視野、樓層、公共設施距離、花園景觀、購物中心距離、政府機關距離、公園距離等12個變數，進行特徵價格分析及類神經網路，其研究結果顯示：特徵價格法與類神經網路其預測平均準確度極為相近，但類神經網路雖具有較小的預測錯誤之標準差；特徵價格法可求得各變數之參數值，進而推算出公寓價格，但類神經網路必無此參數可供參考；類神經網路訓練過程較耗時。

國內有關類神經網路對於不動產價格之研究，如蔡瑞煌等(1998)利用台北市房屋價格有效樣本2787筆資料，以倒傳遞類神經網路、理解倒傳遞類神經網路、特徵價格法，分別進行預測比較，當樣本較大時，理解倒傳遞類神經網路與倒傳遞類神經網路皆優於特徵價格法。

李曉隆(2002)採用台北市680間出租公寓，以迴歸分析模型與類神經網路模型分析租金價格模型，其研究結果顯示大樣本時類神經網路的預測結果較複迴歸模型為佳；若樣本數量不大時，則複迴歸模型的結果較好。同樣也是以台北不動產價格進行在魏如龍(2003)研究上面，其利用文山區與大同區中古屋交易資訊，以多層感知機(multilayer perceptrons)類神經網路模式分析，其研究結果發現在年訓練資料的測試結果中，不動產交易價格波動變化穩定之狀況下的預估效果較佳，不論年月季分析，以一年期訓練資料預估結果較佳。此外，李佳璋(2004)也

運用類神經網路模式分析台南市東區虎尾寮及北區鄭子寮重劃區之影響價格因素，其研究顯示倒傳遞類神經有其一定效果的預測能力，且隨著學習循環次數的增加，所得之平均誤差值越小，所得模式越佳。

近年來也有學者結合地理資訊系統(GIS)進行不動產估價，Din et al.(2001)在評估不動產價格時，運用GIS功能建立影響該不動產之環境影響因子，其影響因子之衡量有別於一般常用之順序尺度(ordinal variable)，GIS可對環境影響因子進行量化分析，其研究顯示：使用GIS資料庫在線性之架構下，發現特徵價格法對環境影響因子所採用的順序變數(ordinal variable)與GIS對環境影響因子所採用的量化分析對預測房價指數相互差異很小。亦即特徵價格法所採用的順序變數對環境影響因子之衡量方式不是一個適合的方法。

由上述之國內外相關文獻研究發現類神經網路分析與特徵價格分析各有其優缺點，很多研究者(McGreal et al.(1998)、Nguyen&Cripps(2001)、李佳璋(2004)、李曉隆(2002)、蔡瑞煌等(1998))認為當所訓練的樣本數量小時，類神經網路分析有較佳的學習效果，而當樣本小時，特徵價格分析有較好的預測能力。然而所謂的大樣本在各相關研究中似乎很難有一個明確的界定。另一方面，類神經網路預測效果好壞的關鍵，在於訓練範例資料大小、資料的代表性、類神經網路參數的調整在不同國家、不同區域，由於影響不動產的屬性明顯都不太相同，所以訓練出來的類神經網路與特徵價格分析也會有所差異。

三、類神經網路理論基礎

類神經網路(artificial neural networks, ANN)是指模擬生物神經網路的資訊處理系統。它使用大量簡單的相連人工神經元模仿生物神經網路的能力。人工神經元是模擬生物神經元原理而來，當人工神經元取得外界資訊，並加以運算，將輸出結果傳送到外界或其他人工神經元。類神經網路具有下列特性：高速計算力、高容記憶能力、學習能力及容錯力。

類神經網路其網路架構主要有三層：處理單元(processing element, PE)、層(layer)及網路(network)。所謂處理單元為類神經網路的基本組成單位。處理單元與其輸出值與輸入值的關係式，一般以輸入值的加權乘積和之函數表示(葉怡成，2003)(註2)。如下所示：

$$Y_j = f(\text{net}_j)$$

$$\text{net}_j = \sum(W_{ij}X_i - \theta_j) \dots \dots \dots (1)$$

Y_j = 輸出層第j個輸出單元的推論值

$f()$ = 轉換函數。是將處理單元輸入的加權值轉換成處理單元輸出值的數學公式。

W_{ij} = 第i個隱藏層單位元與第j個隱藏層單位元間的連結加權值，為第i個處理單元對第j個處理單元之影響強度。

X_i = 輸入層第i個輸入單元之輸入值


θ_j = 第j個隱藏單位的偏權值(或稱閾值)

倒傳遞類神經網路(back-propagation neural network, BPN)是目前類神經網路學習模式中最廣被使用之一，網路架構是前向式類神經網路，其學習方式是屬於監督式學習，即為根據目標輸出值(真實值)與推論值之間的差異，可得一誤差函數，用來表示其學習品質，然後利用最

陡坡法(the gradient steepest decent method)觀念將誤差函數予以最小化。也就是經由修正網路連結上的權重值來使其誤差函數最小化。

換言之，倒傳遞網路演算法是利用誤差均方(root mean square error, RMSE)作為訓練網路的基準，利用這基準調整加強權值與偏權值，使推論輸出值與目標值之間的誤差最小化，它是廣義化的Delta規則(generalize delta rule)。

基本上，使用此一方法一開始要先確認類神經網路之輸入層(影響房價之因素)、神經單元數與輸出層神經單元(房價)數目，如圖一示意說明。一般而言，我們可以根據問題複雜度決定隱藏層層數多寡，一般是以一層為主。當這些基本資料予以決定後，模型即可開始進行試算，也就是進行學習。



圖一 倒傳遞類神經網路架構示意圖

四、倒傳遞類神經網路及特徵價格模型建立與預測

(一) 資料分析與變數選擇

本文的研究目的在建立不動產價格模型及預測分析，實證範圍乃依據「中華民國主要都市地區房地產交易價格簡訊」內所蒐集之樣本作為資料來源，在時間上定位在2001年至2004年之高雄市11個行政區之中古屋買賣交易資料，共計2471筆資料。表一為樣本之基本統計說明。

為測試模型之預測程度之優劣，本研究除將全部樣本進行模型建立外，並於全部樣本數中隨機取樣10%作為樣本外(outsample)，以作為測試之用；另外其餘的90%部分則作為實證模型中之樣本內資料，其筆數分配如表二所示。爾後將該90%樣本內資料建立模型後，再運用10%之outsample值放入模型中進行預測，以判斷出該預測模型之優劣程度。

(二) 倒傳遞類神經網路模型設計

由於倒傳遞類神經網路在運算時，類似一個黑箱作業，在經由不斷學習訓練時，網路中具有較大影響力的處理單元賦與較大權重值，而對網路中較無影響力的處理單元賦予較小的權重值，藉此找出輸入單元與輸出單元間的關係。因此倒傳遞類神經網路不需要考慮輸入變

表一 高雄市買賣交易案例之基本統計分析

	單位	全體樣本(2471)				90%樣本(2224)			
		最小值	最大值	平均數	標準差	最小值	最大值	平均數	標準差
路寬	尺	3	60	16.560	9.133	3	60	16.530	9.092
屋齡	年	1	56	20.860	13.130	1	56	20.960	13.190
建物面積	m ²	19.56	638	157.570	79.900	19.56	638	157.010	80.240
總樓層數	層	1	5	2.652	1.710	1	5	2.640	1.160
不動產交易價格	萬元	103.54	2980.95	536.310	325.770	103.54	2980.95	462.520	185.680
貸款利率	%	1.75	4.79	2.343	8.891	1.75	4.79	2.348	8.838
物價指數	%	101.5	103.2	102.300	54.890	101.5	103.2	102.300	72.000

資料來源：本研究整理(註3)

表二 樣本數分配說明

			類神經網路模型					特徵價格模型		
全體樣本	樣本內	樣本外	全體樣本		樣本內		樣本外	全體樣本	樣本內	樣本外
			訓練範例	測驗範例	訓練範例	測驗範例				
2471	2224	247	1730	741	1560	664	247	2471	2224	247

資料來源：本研究整理

數間是否具有共線性(co linearity)存在，相反地，如果給予網路訊息愈多，則其預測的能力就會愈好。有關類神經網路模型建立架構說明如下：

1. 輸入層

類神經網路的輸入變數，其處理單元數目則依問題而定。本研究的輸入變數有12個，針對影響高雄市不動產價格之區位、路寬、臨街關係、使用類別、建築結構、屋齡、總樓層數、土地使用分區、建物總面積、貸款利率、物價指數等變數予以輸入。

2. 隱藏層

(1) 網路隱藏層層數

本文採取類神經網路係運用PCN4.0軟體(註4)之求取倒傳遞類神經網路模型，由於類神經網路之架構選擇上，最主要包含隱藏層層數、隱藏層處理單位之個數和轉換函數之決定。在隱藏層層數方面，通常隱藏層之數目為一層或二層有最好的收斂效果，而少於一層或是多於兩層時誤差會逐漸升高，原因在於網路中缺乏隱藏層時網路結構就不能表達課題中輸入因子和輸出值之非線性關係，固有較大之誤差存在，而一層或是二層已經足以反應輸入因子間的交互作用，由過去有關類神經網路之相關研究中顯示，單一隱藏層之類神經網路已足夠達到所要求之準確度，且近似複雜之非線性函數(Hornik et al., 1989; Zhang et al., 1998; 葉怡成, 2003)，因此本研究之隱藏層層數之設定以一層為之。

(2) 網路隱藏層處理單位(註5)

一般而言，隱藏層處理單位的數目越多收斂越慢，但是可以達到更小的誤差值，當隱藏層處理單位過多時，對於降低測試範例之誤差值幾乎沒有任何助益，同時有可能會有過渡學習狀況，在隱藏層處理單位之決定目前並未有一定之法則可以依循，不過過去之研究較常採用之方法為Masters(1993)建議之對一個具有 n 個輸入處理單元， m 個輸出處理單元之類神經網路，其隱藏層處理單位計算為 $\frac{\sqrt{n \times m}}{2} \leq \text{隱藏層處理單位} \leq \sqrt{n \times m}$ ，或是採取試誤法決定。因此本研究擬參考Masters方法進行測試並採用試誤法試圖找出最佳模型。經研究後本研究之隱藏層處理單位設定為3。


(3) 參數設定

在類神經網路的隱藏層和輸出層為非線性轉換函數，其中最常被使用的轉換函數是雙彎曲函數(sigmoid function)，其表示公式如下所示。雙彎曲函數其輸入與輸出向量介於0與1之間，而輸出層採線性轉換函數，使網路學習能夠取任意值。

$$f(\text{net}_j) = \frac{1}{1 + \exp^{-\text{net}_j}} \dots\dots\dots (2)$$

net_j ：輸出層第 j 個神經元的加權乘積和

f ：隱藏層及輸出層的轉換函數



圖二 雙彎曲函數

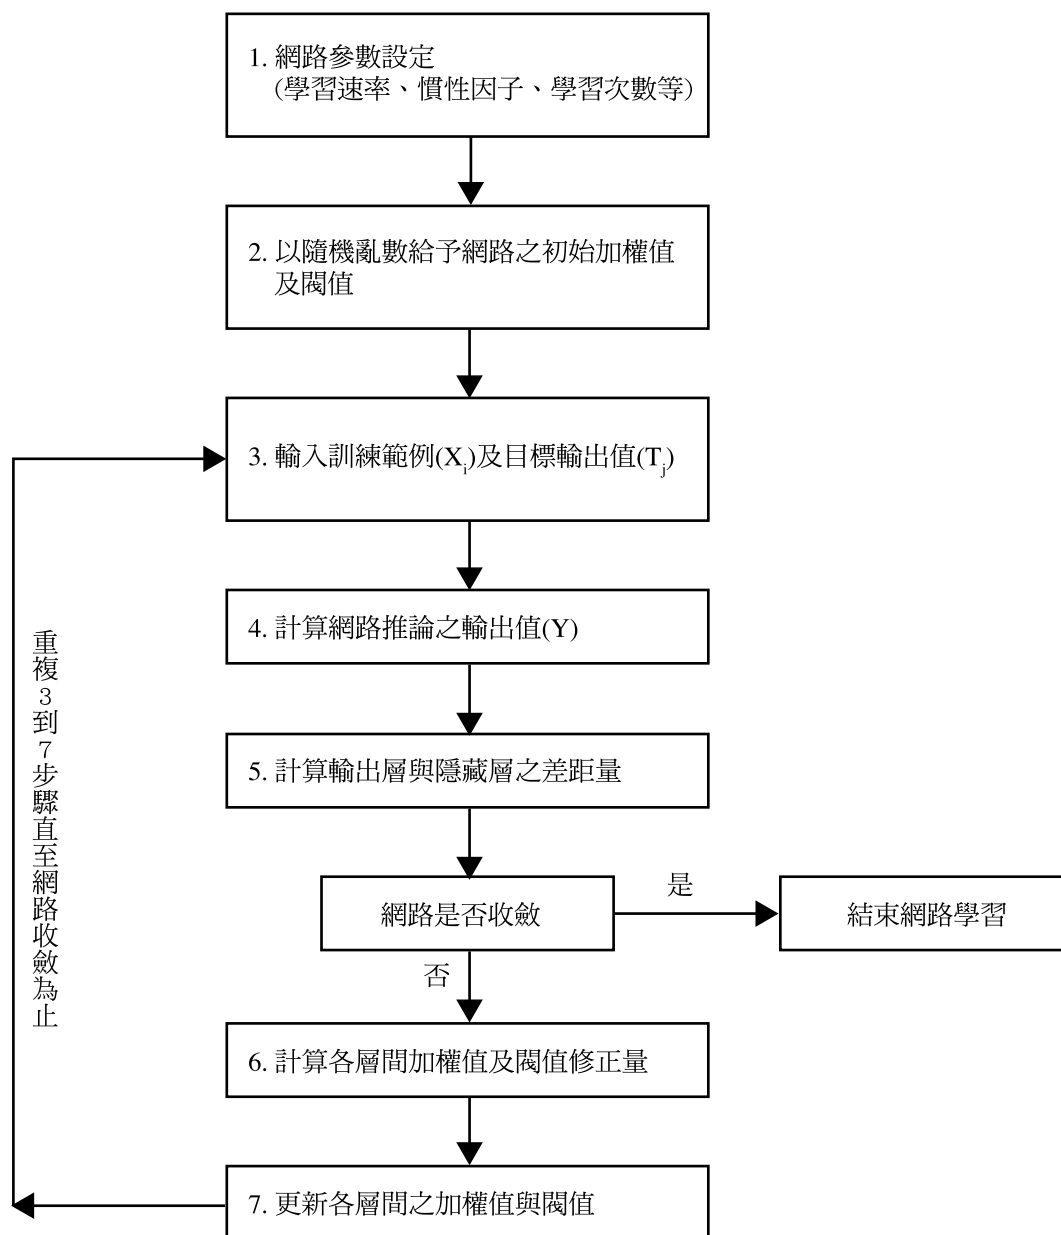
(4) 網路運作過程

倘若在運算時採取單層隱藏層的層狀類神經網路，則倒傳遞演算法將應用一個訓練範例(training examples)的一組輸入值，與一組目標輸出值，修正網路連結強度權值與閾值。

在類神經網路參數之設定方面，主要是在網路學習演算法之選擇，網路學習過程中一次一個訓練範例方式進行直到學習完所有的訓練範例樣本，稱為一個學習循環(learning cycle)。過程中對於所有的訓練範例必須不斷地反覆學習到達收斂為止，訓練停止標準為當一推論目標輸出值與目標輸出值間誤差為小於0.1時，停止該筆學習樣本訓練，進行下一筆樣本訓練，直到所有的樣本訓練完成，如圖三所示。為瞭解是否有過渡學習現象以及學習循環次數對網路學習效果的影響，本文所採用的學習循環次數分別為100、200、300、400及500次，希望可以觀察到各種學習循環次數下之誤差，以使得訓練範例之誤差小於測試範例誤差，同時避免產生過渡學習現象。

(5) 樣本設定

倒傳遞類神經網路輸入單元樣本筆數可以分為二種：訓練範例及測試範例，樣本分佈



圖三 倒傳遞類神經網路訓練流程圖

對於整個網路學習效果有很大的影響，當訓練範例分佈均勻時，類神經網路的學習能力佳，反之分佈不均衡時類神經網路的學習能力會跟著降低。為了使得訓練範例分佈均勻且取樣客觀，過去研究採取之方式有以4:1 (林明宏等，2004)或是7:3 (葉怡成，2003)比例分成訓練範例與測試範例筆數。本研究在幾經測試為求取較小誤差因此採取7:3分配樣本比例。有關本研究之參數設定如表六所示。

3. 輸出層

此為網路的輸出變數，其處理單元數目依問題而定。使用非線性轉換函數，以表示結果之輸出，本研究之輸出層為不動產價格。

(三) 模型預測誤差評估指標

1. 模式整體之評估誤差指標

本研究採用了平均絕對誤差百分比(mean absolute percentage error; MAPE)，作為衡量整體評估誤差效果的準則，其模型所推估出不動產價格預測值與實際交易價格可能存在的誤差程度，以百分比表示，當MAPE值越小，表示整體模式推估偏差越小。(Nguyen&Cripps, 2001)

$$MAPE = \left[\sum \left| \frac{P_i - T_i}{T_i} \times 100 \right| \right] \div n \dots\dots\dots (3)$$

P_i ：預測價格 T_i ：實際價格 n ：樣本數

2. 模式單一個體之評估誤差指標

採用預測誤差(forecasting error; FE) (Nguyen & Cripps, 2001)作為衡量單一案例預測誤差效果準則，預測誤差值低於一定可容忍誤差值內之樣本數佔所有樣本的比例，作為衡量每個預估個案是否在容許的誤差範圍，本研究將預測誤差樣本分為三類(1)預測誤差小於5% ($FE \leq 5\%$)，當 $FE \leq 5\%$ ，本研究將計算小於5%的的樣本數 n ，當 n 的個數越多，或者是其 n/N 的百分比高，代表其預測誤差小，預測準確高。(2)預測誤差5%–15%以內($5\% \leq FE \leq 15\%$)，當預測誤差5%–15%的樣本數 n 較多時，或者是其 n/N 的百分比高，表示其預測誤差稍微高些，準確度較低。(3)預測誤差超過15%以上($FE > 15\%$)，當預測誤差 $FE > 15\%$ 的樣本數 n 較多時，或者是其 n/N 的百分比高，表示其預測效果不佳，準確度很低。一般而言，預測誤差在5%以內為可接受範圍之誤差，其預測效果佳。如為預測誤差在5%–15%間為模糊範圍，預測尚可；如果誤差超過15%範圍以上為不可接受範圍。

$$E_i = \left[\left| \frac{P_i - T_i}{T_i} \times 100 \right| \right] \dots\dots\dots (4)$$

P_i ：預測價格 T_i ：實際價格

$$FE\% = \frac{n}{N} \times 100\% \dots\dots\dots (5)$$

n ：預測誤差範圍之樣本相加次數。 N ：總樣本數

n 乃根據預測誤差百分比小於5%、5%~15%、大於15%之樣本數，分別予以加總而得，並且分別將此一類樣本數 n 除以全體總樣本數 N ，據以瞭解模型預測效果。如果預測誤差小於5%的FE百分比越高，代表預測值與實際值之差異小於5%的樣本所佔比例高，即模型的預測能力好。

(四) 實證分析

1. 變數說明

(1) 因變數(dependent variable)

一般的特徵價格模型應變數通常採用住宅價格總價，或是住宅每坪單位價格，本研究為

了估計每個影響因子對不動產價格的影響，故在因變數的選擇上採用不動產總價而非不動產每坪單位價格。並且針對不動產價格(Y)採取自然對數形式 $\ln Y$ (註6)，研究分析區位、路寬、臨街關係、使用類別、建築結構、屋齡、總樓層數、土地使用分區、建物總面積、貸款利率、物價指數等自變數對於不動產價格之影響。

(2) 自變數(independent variables)

不動產特徵因子的選取對於不動產價格模型之建立有決定性的影響，本研究經由前述之相關文獻歸納出各個自變數(詳見表三說明)，關於變數定義與變數說明如下：

- A. 區位：高雄市則劃分為11個行政區，且亦區分為郊區及市區。其中郊區包含左營、楠梓、旗津、小港等四個行政區。市區包含鹽埕、鼓山、三民、新興、前金、苓雅、前鎮等七個行政區。並將郊區以虛擬變數0帶入、市區以1帶入。由於市區之便利性且人口大都集中於此，依據此虛擬變數的假設下，故預期其對不動產價格具有正向影響。
- B. 路寬：臨街路寬為各住宅所面臨的道路寬度，以建物門口所面臨的道路為主，並以該面臨道路的寬度為變數，單位為公尺，當面臨道路越寬時，住宅的價格會越高，因此本研究預期不動產價格與臨街道路寬度為可能正相關，其係數符號為正。
- C. 臨街關係：分為路角地、臨街地、袋地、裡地，各臨街關係各有其特色，價值也會因需求不同而有不同價格，其中路角地、臨街地設為1；袋地、裡地設為0。依據此假設下，本研究預期不動產價格與臨街關係為可能正相關，其係數符號為正。
- D. 使用類別：依據一般住宅型態分類，本研究將住宅型態劃分為透天住宅、公寓大樓與店舖，三種類型，其中透天、公寓設為1；店舖設為0。一般而言，店舖價格往往高於透天與公寓住宅，依據此虛擬變數的假設下，本研究預期不動產價格與使用類別為負

表三 變數定義與變數說明

變數	變數代碼	預期符號	說明	單位
不動產價格	HP		不動產買賣交易總價	萬
區位	LOCATION	+	前金區、苓雅區、三民區、前鎮區、鹽埕區、新興區、鼓山區(1)左營區、楠梓區、旗津區、小港區(0)	虛擬變數
路寬	ROAD-W	+	連續變數	公尺
臨街關係	ROAD-S	+	路角地、臨街地(1)，裡地、袋地(0)	虛擬變數
使用類別	TYPE	-	透天、公寓(1)店舖(0)	虛擬變數
建築結構	STRUCT	+	鋼筋混泥土造、鋼鐵造、鋼骨(1)磚造、加強磚造(0)	虛擬變數
屋齡	AGE	-	連續變數	年
總樓層數	TOTFLOR	+	連續變數	層
土地使用分區	ZOING	+	商業區(1)，住宅區(0)	虛擬變數
建物總面積	BUILAREA	+	連續變數	平方公尺
貸款利率	RATE	+ -	連續變數	%
物價指數	CPI	+	連續變數	%

相關，其係數符號為負。

- E. 構造類別：可分為鋼筋混凝土造、鋼鐵造、鋼骨、磚造、加強磚造等。而鋼骨建築相對於鋼筋混凝土建築而言，因其採預鑄方式，且鋼材品質穩定，樑柱接頭易處理，故其耐震性是較強，並將鋼筋混凝土造、鋼鐵造、鋼骨設為1；磚造、加強磚造設為0，據此，預期構造類別與不動產價格應呈現正向關係。
- F. 屋齡：屋齡是直接反應房地產價格之折舊及維修狀況，如一般RC 結構耐用年數為50~60年，且其結構強度是在完工兩三年內達到最高，以後會逐漸走下坡。因此預期屋齡將與不動產價格成反向關係。
- G. 總樓層數：以透天住宅而言，總樓層代表建築成本，總樓層的多寡影響建築成本的高低，成本越高不動產價格也會越高。
- H. 土地使用分區：不同土地使用分區管制劃分如住宅、商業、工業區等給予之使用強度限制不同，容積率、建蔽率管制亦不相同。強度管制主要目的是要控制人口及建築密度，並解決土地使用時所產生之外部性問題，為便於比較，本研究將土地使用分區劃分為住宅區與商業區兩類，其中商業區設為1，住宅區設為0，依據此虛擬變數假設，預期使用分區將與不動產價格應呈現正向關係。
- I. 建物面積：建物面積越大，建築成本越高，相對地其售價也會跟著提高，因此不動產價格也會升高，所以建物面積將與不動產價格呈現正向關係。
- J. 貸款利率：利率水準的高低，除了影響儲蓄意願外，也與房地產經營成本息息相關，當貸款利率走高時，除會增加房貸利息外，亦會造成建商對建物成本增加，消費者需求會減少，故貸款利率對不動產價格影響未定。
- K. 消費者物價指數：房地產具有保值與投資的功能，物價上漲率愈高時，在預期心理之下對不動產價格有正向影響。

2. 特徵價格模式

從表四可知，特徵價格模型之調整後的 R^2 為0.732，整體模型解釋能力為73.2%。大多數變數預期符號與研究結果相符，但觀察得知屋齡與不動產價格呈現拋物曲線關係，表示房價會隨著屋齡越高其價格越低，但其屋齡下至某一價格會開始呈現上升趨勢，也就是高雄市某些不動產價格會與區位、面積有關，但與屋齡相關性不大。

倘若就樣本內資料建構預測模型，從表五可知，特徵價格模型判定係數為稍微下降，整體模型解釋能力為72.83%。且變數預期符號與研究結果、總體樣本一樣。此外，臨街關係、使用類別及物價指數與不動產價格關係較為明顯。

3. 倒傳遞類神經網路模式

有關本研究之倒傳遞類神經網路之基本參數值如表六所示，另由圖四之倒傳遞類神經網路訓練分佈圖可知樣本間的差異並無極端值出現。。在交叉驗證測試後，當隱藏層單位數為3時，學習循環數為200次，RMSE=0.286最小值，整個模型建構完成。

敏感度分析(sensitivity analysis)主要目的是可從連結上的權重值分析網路個別輸入單位與個別輸出單位的敏感度分析。敏感度分析可以觀察各個變數對於建物面積影響最大的敏感性，當敏感度正值越大表示二者間的正相關越大，負值越大表示二者間的負相關越大。如表所示高雄市影響不動產價格之特徵因子當中「建物面積」其正相關程度最大；「總樓層數」負相關程度最大。

表四 整體總樣本特徵價格模型分析

變數	預期符號	β 值	T值	P-value值
(常數)		-0.963	-7.134	.000***
區位	+	0.132	10.354	.000***
路寬	+	0.004	6.755	.000***
臨街關係	+	0.263	20.519	.000***
使用類別	-	-0.142	-7.201	.000***
建築結構	+	0.040	2.574	.010***
屋齡	-	-0.008	-5.479	.000***
屋齡平方	+	0.001	7.871	.000***
總樓層數	+	0.078	12.451	.000***
土地使用分區	+	0.093	6.706	.000***
建物面積	+	0.004	38.424	.000***
貸款利率	+	0.068	10.535	.000***
物價指數	+	0.117	12.167	.000***
R-Square			0.733	
Adj R-Square			0.732	

*顯著水準為0.1時，相關顯著；**在顯著水準為0.05時，相關顯著；***在0.01時，相關顯著。

資料來源：本研究整理

表五 90%樣本內之特徵價格模型分析

變數	預期符號	β 值	T值	P-value值
(常數)		-6.49860	-6.27086	.000***
區位	+	0.13578	10.00109	.000***
路寬	+	0.00418	6.54829	.000***
臨街關係	+	0.26224	19.28466	.000***
使用類別	-	-0.15224	-7.32906	.000***
建築結構	+	0.03661	2.21091	.027***
屋齡	-	-0.00827	-5.63849	.000***
屋齡平方	+	0.00029	7.82389	.000***
總樓層數	+	0.07870	11.80022	.000***
土地使用分區	+	0.08919	6.02797	.000***
建物面積	+	0.00354	36.04064	.000***
貸款利率	+	0.06777	9.85440	.000***
物價指數	+	0.11249	11.03828	.000***
R-Square			0.7298	
Adj R-Square			0.7283	

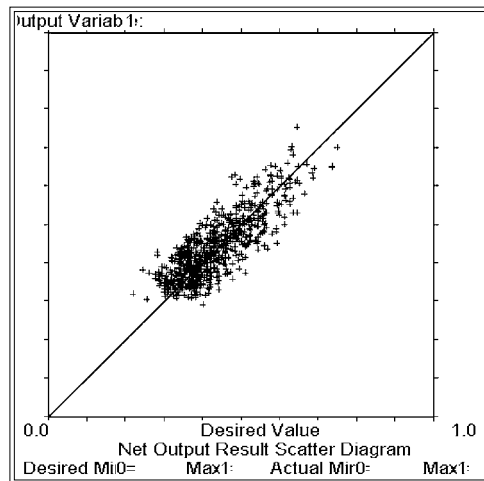
*顯著水準為0.1時，相關顯著；**在顯著水準為0.05時，相關顯著；***在0.01時，相關顯著。

資料來源：本研究整理

表六 倒傳遞類神經網路模式之參數值

整樣本數		90%樣本數	
設定參數	說明	設定參數	說明
1.輸入處理單元數目	12	1.輸入處理單元數目	12
2.第一隱藏層處理單位數數目	3	2.第一隱藏層處理單位數數目	3
3.輸出處理單元數數目	1	3.輸出處理單元數數目	1
4.訓練範例數目	1730	4.訓練範例數目	1560
5.測試範例數目	741	5.測試範例數目	664
6.學習循環數目	200	6.學習循環數目	200
7.學習速率	1-0.1	7.學習速率	1-0.1
8.慣性因子	0.5-0.1	8.慣性因子	0.5-0.1

資料來源：本研究整理



圖四 全體總樣本之倒傳遞類神經網路散佈圖

經實證結果分析得知，倒傳遞類神經網路之敏感度分析如表七所示，不論是全部樣本或是90樣本內資料，其中以建物面積對於不動產價格影響最大，其次是臨街關係對於不動產價格影響。而使用類別、屋齡與不動產價格呈反比，換言之變數間呈現負相關，其他變數皆與不動產價格成正比。

4. 模型預測效果分析

(1) 全部樣本配適效果

總樣本數之特徵價格模型之平均絕對誤差百分MAPE值24.65%，預測誤差(FE)小於5%共計12%、5%-15%共26%、大於15%共62%；倒傳遞類神經網路模型之測試範例其平均絕對誤差百分MAPE值24.48%。預測誤差(FE)小於5%共14%，5%-15%共26%、大於15%共60%，如表八所示。根據全部樣本數之實證結果顯示，倒傳遞類神經網路模型配適效果優於特徵價格模型。

表七 倒傳遞類神經網路敏感度分析

總樣本		90%樣本	
變數名稱	敏感度分析	變數名稱	敏感度分析
區位	0.423	區位	0.601
路寬	0.313	路寬	0.361
臨街關係	1.014	臨街關係	1.265
使用類別	-0.411	使用類別	-0.258
建築結構	0.276	建築結構	0.172
屋齡	-0.561	屋齡	-0.196
屋齡平方	0.909	屋齡平方	0.755
總樓層數	0.309	總樓層數	0.243
土地使用分區	0.331	土地使用分區	0.212
建物面積	2.087	建物面積	1.890
房貸利率	0.481	房貸利率	0.398
消費者物價指數	0.464	消費者物價指數	0.490

表八 預測誤差評估指標分析說明

預測效果	模型類別	樣本數 總樣本(2471)預測樣本(741)		90%樣本(2224) 預測10%樣本(247)	
		倒傳遞類神經網路	特徵價格	倒傳遞類神經網路	特徵價格
MAPE		24.48%	24.65%	20.41%	20.20%
	<5%以下(n1/N)	14%	12%	14%	17%
FE%	5%-15%(n2/N)	26%	26%	28%	29%
	>15%以上(n3/N)	62%	62%	58%	54%

資料來源：本研究整理

(2) 區分90%樣本內及10%樣本外之預測效果

本研究將樣本數區分為樣本內及樣本外，利用90%樣本取得之模型，預測10%樣本外(outsample)價格，根據實證預算結果顯示，特徵價格模型之MAPE值為20.20%，倒傳遞類神經網路之MAPE值為20.41%，顯然特徵價格模型之預測能力較倒傳遞類神經網路模型好一些。換言之，如果採取全部樣本進行推估，類神經網路優於特徵價格0.17%之MAPE，但是如果樣本外類神經網路則輸了0.21%。顯然類神經網路的預測效果不一定比迴歸分析準確，關於這一點的研究結果，Markham et al.(1998)曾經實驗過，他們認為當樣本符合線性迴歸模型假設(model assumptions)，在樣本數多且變異數不大情況下，迴歸分析的預測效果會比類神經網路好，反之則類神經網路預測效果好。

五、結論與建議

高雄市未來交通網路，在市區鐵路地下化、大眾捷運系統、快速道路、高速鐵路相繼興建後，高雄市陸運交通會更佳便捷，預期房地產景氣會持續攀升，不動產市場會更佳活絡，因此公、私部門房地產估價業務也會持續加重，如何建立一套大量估價系統為其當務之急，然而一般傳統估價方法為人所爭議的原因，不外是太多的主觀判斷居多，缺少一套公正客觀的估價系統，本研究利用類神經網路不斷的測試與學習，建立高雄市不動產價格之估價模型。

就特徵價格模型而言，各個變數以臨街關係、總樓層數及建物面積之t值較大，顯示這些變數對於模型的影響較為顯著。而倒傳遞類神經網路之實證結果顯示以建物面積、臨街關係及屋齡為主，其中總體經濟變數之房貸利率及物價指數均與房價成現正比關係，換言之利率上升房價也跟著上升，此一結果顯示當房價高漲，政策也將房貸利率提高，結果使得利率與房價同方向調整變化。

由誤差衡量指標可以得到高雄市不動產價格預測效果，倒傳遞類神經網路預測效果遠較特徵價格法為佳，平均絕對誤差百分比MAPE值為24.48%、24.65%。此一結果與McGreal et al., 1998、Din et al., 2001、Wong et al., 2001、Visit et al., 2004的實證結果一致。也就是說，當採用相同變數、相同樣本時，類神經網路模型之預測效果比特徵價格模型預測效果精準。

但是本研究如果進一步將測試模型樣本數中隨機取樣10%作為outsample測試；並以其餘90%建立特徵價格及類神經網路模型中之樣本，待後將該90%樣本建構模型後，再將10%之outsample樣本放入模型預測，以判斷該預測模型之優劣程度。經實證結果顯示，特徵價格模型式之MAPE值為20.20%較倒傳遞類神經網路之20.41%為佳，類神經網路優於特徵價格0.17%，但是如果區隔90%樣本內及10%樣本外，此時，類神經網路則輸特徵價格模型0.21%。

此一結果說明，高雄市在目前所蒐集到之買賣實例進行模型建構時，可以採取特徵價格模式進行價格預測。不過對於採取特徵模式處理時，研究者必須注意特徵價格模式必須符合一些假設條件，包括：1.常態分配：自變數與因變數合乎常態分配。2.獨立性：任一個自變數彼此間相互獨立，某一個觀測值不會影響另一筆觀測值，自變數彼此間沒有關連。3.直線性：因變數是各個變數間的線性函數。4.同質性：自變數的任一個線性組合其因變數的變異數不變，若殘差項不呈隨機分布，則表示因變數Y的變異數不一致。5.殘差項：殘差項必須獨立且必須是常態分配。也就是說，研究者可以先對原始資料進行檢視，瞭解其是否符合特徵價格假設條件。

相較於這些假設條件，類神經網路模仿生物神經系統方式，在面對複雜且非線性的問題，則不需這些擔心這些假設條件，而是透過學習(learn)、回想(recall)及歸納推演(generalize)等訓練達到最佳化結果，這也就是近年來多數學者運用此一方法進行各式各樣問題的預測、分類。因此，本文的倒傳遞類神經網路在樣本外預測結果較迴歸分析差，但是其高度容錯能力以及適應性學習，是其不容忽視的效果。尤其是國內在公告土地現值議題上，有筆數多、需要在短時間內、問題很難命題完整的前提下，採用此一模式不失為一個可以考慮的估價模式。

或者，研究者可以根據先驗知識，以適當的迴歸模式尋求主要影響變數，然後再利用類神經網路模式建構預測網路，如此可達到最佳效能之改良式類神經網路預測模式。亦或者

研究者可以嘗試其他類神經演算模式，例如演化策略法類神經網路(evolution strategies neural networks, ESNN)、遺傳類神經網路(genetic neural networks, GNN)藉此提高其模式的準確度能力。

此外，關於變數選取方面，礙於買賣交易實例所提供之變數不多，因此本研究僅篩選12個重要影響因子進行研究，未來研究者或許可以增加更多的影響因子如地價區段面積大小、不動產市場景氣好壞等因素等進行深入研究分析，藉以擴大研究範圍。

註 釋

註 1：華昌宜、林秋瑾、賴碧瑩(2004)，「電腦大量估價實證模型建構」，財團法人台灣不動產資訊中心研究計畫，經建會委託，p1。CAMA(IAAO, 2000)定義則更新自 John L. Mikesell(Speech), 2004, State Administration of Taxation, Lincoln Institute of Land Policy Joint Training Course, May演講稿及<http://www.adaweb.net/departments/assessor/AppraisalGlossary.asp>網址

註 2：有關詳細的倒傳遞網路演算法公式，為節省篇幅及讓本文更為精簡，讀者如有需要可以參閱，葉怡成(2003)之「應用類神經網路」一書第二章說明及相關文獻所示。有關倒傳遞演算過程，如下所列。

當在運算時採取單層隱藏層的層狀類神經網路，則倒傳遞演算法將應用一個訓練範例(training set)的一組輸入值，與一組目標輸出值，修正網路連結加強權值與閾值。

首先，應用訓練範例的輸入單元的輸入值X，計算隱藏層處理單元的輸出值H如下所示。H_k為隱藏層第k個隱藏處理單元間的連結強度。f為轉換函數。

$$H_k = f(\text{net}_k) = f(\sum W_{ik} X_i - \theta_k) \dots \dots \dots (1)$$

接著，應用隱藏層處理單元的輸出值H_k，計算輸出層處理單元的推論輸出值Y_j。

$$Y_j = f(\text{net}_j) = f(\sum W_{jk} H_k - \theta_j) \dots \dots \dots (2)$$

運用推得的「推論輸出值」與訓練範例原有的「目標輸出值」可以得到網路誤差值。網路即利用此誤差最為修正連結中的加權值的依據，以從訓練範例中建立系統模型，其誤差函數方程式如下：

$$E = (1/2) \sum (T_j - Y_j)^2 \dots \dots \dots (3)$$

T_j：為訓練範例之輸出層第j個輸出單元的目標輸出值

Y_j：為訓練範例之輸出層第j個輸出單元的推論輸出值

因為誤差函數是類神經網路連結上加權值的函數，所以使用(最陡坡降法)使其誤差函數最小化，即每當輸入一個訓練範例，類神經網路即小幅度調整連結加權值，調整的幅度和誤差函數對該加權值的敏感度成正比，即與誤差函數對加權值的偏微分值大小成正比：

$$\Delta W = -\eta \frac{\partial E}{\partial W} \dots \dots \dots (4)$$

其中η稱為學習速率(learning rate)，是控制每次加權值修改的幅度；W為處理單元間的連結加權值；E為誤差函數。可透過連鎖定律可將 $\frac{\partial E}{\partial W}$ 化解成為 $\frac{\partial E}{\partial W} = \left(\frac{\partial E}{\partial \text{net}}\right) \times \left(\frac{\partial \text{net}}{\partial W}\right)$ ，權重修正量。

至於隱藏層與輸出層之間連結加權值計算則如(6)式所示。

$$\frac{\partial E}{\partial W} = \left(\frac{\partial E}{\partial net}\right) \times \left(\frac{\partial net}{\partial W}\right) \dots\dots\dots (5)$$

等號右邊第三項可由 $net_j = \sum W_k H_k$ 代入，得到(8)式

$$\frac{\partial net_j}{\partial W_{kj}} = \frac{\partial}{\partial W_{kj}} (\sum W_{kj} H_k) = H_k \dots\dots\dots (6)$$

等號右邊第二項可由 $Y_j = f(net_j)$ 代入，得到(8)式

$$\frac{\partial Y_j}{\partial net_j} = \frac{\partial}{\partial net_j} f(net_j) = f'(net_j) \dots\dots\dots (7)$$

將等號右邊第一項可由代入得 $E = \frac{1}{2} \sum (T_j - Y_j)^2$ 代入，得到(9)式

$$\frac{\partial E}{\partial Y_j} = \frac{\partial}{\partial Y_j} \left(E = \frac{1}{2} \sum (T_j - Y_j)^2\right) = (T_j - Y_j) \dots\dots\dots (8)$$

由上述可推得

$$\frac{\partial E}{\partial W_{kj}} = \left(\frac{\partial E}{\partial Y_j}\right) \left(\frac{\partial Y_j}{\partial net_j}\right) \left(\frac{\partial net_j}{\partial W_{kj}}\right) = -(T_j - Y_j) \times f'(net_j) \times H_k = -\delta_j \times H_k \dots\dots\dots (9)$$

其中

$$\delta_j = (T_j - Y_j) \times f'(net_j) \dots\dots\dots (10)$$

δ_j 為輸出層第 j 個輸出處理單元的誤差量，則隱藏層與輸出層間的連結加權值 W_{kj} 之修正量如下：

$$\Delta W_{kj} = \eta \times \delta_j \times H_k \dots\dots\dots (11)$$

輸入層與隱藏層之間連結權值

$$\frac{\partial E}{\partial W_{ik}} = \left(\frac{\partial E}{\partial H_k}\right) \left(\frac{\partial H_k}{\partial net_k}\right) \left(\frac{\partial net_k}{\partial W_{ik}}\right) \dots\dots\dots (12)$$

第三項可由 $net_k = \sum W_{ik} X_i$ 代入，得到下式：

$$\frac{\partial net_k}{\partial W_{ik}} = \frac{\partial}{\partial W_{ik}} (\sum W_{ik} X_i) = X_i \dots\dots\dots (13)$$

等號右邊第二項可由 $H_k = f(net_k)$ 代入得(16)

$$\frac{\partial H_k}{\partial net_k} = \frac{\partial}{\partial net_k} f(net_k) = f'(net_k) \dots\dots\dots (14)$$

等號右邊第一項可由連鎖定律得到下式：

$$\frac{\partial E}{\partial H_k} = \sum_j \left(\frac{\partial E}{\partial net_j} \frac{\partial net_j}{\partial H_k} \right) = \sum_j \left(\frac{\partial E}{\partial Y_j} \times \frac{\partial Y_j}{\partial net_j} \times \frac{\partial net_j}{\partial H_k} \right) \dots\dots\dots (15)$$

其式中的第三項可分解成下式：

$$\frac{\partial net_j}{\partial H_k} = \frac{\partial}{\partial H_k} (\sum W_{ik} H_k) = W_{kj} \dots\dots\dots (16)$$

由上述可以推得

$$\begin{aligned} \frac{\partial E}{\partial W_{ik}} &= (\sum -(T_j - Y_j) \times f'(net_j) \times W_{kj}) \times f'(net_k) \times X_i \\ &= -\left(\sum_j \delta_j \times W_{ij} \right) \times f'(net_k) \\ &= -\delta_k \times X_i \dots\dots\dots (17) \end{aligned}$$

$$\delta_k = -\left(\sum_j \delta_j \times W_{ij} \right) \times f'(net_k) \dots\dots\dots (18)$$

δ_k 為輸出層第k個輸出單元的差距量，則輸入層與隱藏層間的連結加權修正量如下：

$$\Delta W_{ik} = \eta \times \delta_k \times X_i \dots\dots\dots (19)$$

本文轉換函數採用雙曲函數，則

$$f(net) = f(net_j) \times [1 - f(net_j)] \dots\dots\dots (20)$$

$$f'(net_j) = f(net_j) \times [1 - f(net_j)] = Y_j(1 - Y_j) \dots\dots\dots (21)$$

$$f'(net_k) = f(net_k) \times [1 - f(net_k)] = H_k(1 - H_k) \dots\dots\dots (22)$$

將(21)及式(22)代入式(10)及(18)即可分別得到輸出層與隱藏層間及隱藏層與輸入層間的誤差量：

$$\delta_j = (T_j - Y_j) \times Y_j \times (1 - Y_j) \dots\dots\dots (23)$$

$$\delta_k = \left[\sum_j \delta_j \times W_{kj} \right] \times H_k(1 - H_k) \dots\dots\dots (24)$$

輸出層與隱藏層間及隱藏層與輸入層間的加權更新值分別如下：

$$W_{kj}(t+1) = W_{kj}(t) + \Delta W_{kj}(t)$$

$$W_{ik}(t+1) = W_{ik}(t) + \Delta W_{ik}(t) \dots\dots\dots (25)$$

註 3：本研究之實證資料感謝高雄市政府地政處地價科提供資料研究助理許世雄之費心蒐集初步處理。

註 4：感謝葉怡成教授在在實驗過程中提供PCN4.0的技術及觀念協助。

註 5：有些研究文章或書籍將處理神經單位(元)稱為處理節點或是神經單元數。

註 6：模式形式表示為： $\text{Ln}Y = \beta X + \mu$

參考文獻

李曉隆

- 2002 《出租公寓之租金價格預測—複迴歸分析與類神經網路之比較》碩士論文，國立台灣科技大學。

李佳璋

- 2004 《重劃區住宅價格之調查研究—以台南市虎尾寮及鄭子寮為例》碩士論文，長榮大學。

林明宏、張順孔、李德河、方世杰

- 2004 〈類神經網路應用在阿里山公路崩壞潛能評估之研究〉《2004 全國災害危機處理學術研討會論文集》台南，2-102-2-109。

信義房屋

- 2004 《信義不動產論評論》第八期：15。

高明志

- 1997 《類神經網路應用於房地產估價之研究》碩士論文，國立政治大學。

楊雅媛

- 2002 《迴歸分析與類神經網路預測能力之比較》碩士論文，國立政治大學。

陳韋龍

- 2004 《應用類神經網路建立台北市房價區位特性之研究》碩士論文，中國文化大學。

陳耀茂、殷純淵編著

- 2004 《類神經網路 PCNeuron 使用手冊》鼎茂。

張斐章、張麗秋、黃浩倫

- 2003 《類神經網路理論與實務》初版：東華。

華昌宜、林秋瑾、賴碧瑩

- 2004 《電腦大量估價實證模型建構》財團法人台灣不動產資訊中心研究計畫，經建會委託。

葉怡成

- 2003 《應用類神經網路》八版：儒林。

蔡瑞煌、高志明、張金鸚

- 1998 〈類神經網路應用於房地產估價之研究〉《住宅學報》8：1-20。

魏如龍

- 2003 《類神經網路應用於不動產估價預估效果之研究》碩士論文，國立政治大學。

Chen, C. L., D. B. Kaber & P. G. Dempsey

- 2000 “A New Approach to Applying Feed-Forward Neural Networks to the Predication of Musculoskeletal Disorder Risk,” *Applied Economics*. 3:269-282.

Do, A.Q. & G. Grundnitski

- 1992 “A Neural Network Approach to Residential Property Appraisal,” *The Journal of Real*

Estate Research. 58(3): 38-45.

Do, A.Q. & G. Grundnistski

1993 "A Neural Network Analysis of the Effect of the Age on Housing Values," *Journal of Real Estate Research*. 8:253-264.

Din, A., M. Hoesli & A. Bender

2001 "Environmental Variables and Real Estate Prices," *Urban Studies*. 38(11): 1989-2000.

Evans, A., H. James & A. Collins

1992 "Artificial Neural Network: An Application to Residential Valuation in the UK," *The Real Estate Research*. December. 58:38-45.

Hua, Gog Bee

1996 "Residential Construction Demand Forecasting Using Economic Indicators: a Comparative Study Of Artificial Neural Network and Multiple Regression," *Construction Management and Economics*. 14:25-34.

Hornik, K., M. Stinchcombe & H. White

1989 "Multilayer Feed Forward Networks are Universal Approximates" *Neural Networks*. 2(5):359-366.

McCluskey, W. J. & R. A. Borst

1997 "An Evaluation of MRA, Comparable Sales Analysis and ANNs for the Mass Appraisal of Residential Property in Northern Ireland," *Assessment Journal*. 4(1):47-55.

McCluskey, W. J., K. S. Dyson, Anand & D. Mcfall

1997 "The Mass Appraisal of Residential Property in Northern Ireland," *Computer Assisted Mass Appraisal*. London: Chapter 3:59-77.

McGreal, S., A. Adair, D. McBurney & D. Patterson

1998 "Neural Networks: the Prediction of Residential Values," *Journal of Property Valuation & Investment*. 16(1):57-70.

Markham, I. S. & T. R. Rates

1998 "The Effect of Sample Size and Variability of Data on the Comparative Performance of Artificial Neural Networks and Regression," *Computer Operation Research*. 25(4):251-263.

Masters, T.

1993 *Practical Neural Network Recipes in C++*. Boston: Academic Press.

Nguyen, N. & A. Cripps

2001 "Predicting Housing Value: A Comparison of Multiple Regression Analysis and Artificial Neural Network," *The Journal of Real Estate Research*. 22(3):313-336.

Palmquist, R. B.

1989 "Land as a Different Factor of Production," *Land Economics*. 65(1):23-28.

Rumelhart D. E., G. E. Hinton & R. J. Williams

1986 "Learning Internal Representation by Error Propagation," in *Parallel Distributed*

Processing: Explorations in the Microstructure of Cognition. 318-362. ed. Rumelhart D. E. & J. L. McClelland, Cambridge: Massachusetts Institute of Technology Press.

Tay, D.P. & D.k. Ho

1991 "Artificial Intelligence and the Mass Appraisal of Residential Apartments," *Journal of Property Valuation & Investment*. 10:525-540.

Zhang, G. & M.Y. Hu

1988 "Neural Network Forecasting of the British Pound/ US Dollar Exchange Rate," *Omega Int. Journal Magazine Science*. 26(4):495-506.

Visit L., G. Christopher & M. Lee

2004 "House Price Predication: Hedonic Price Model vs. Artificial Neural Network," *American Journal of Applied Science*. 3:193-201.

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.

Wong, K.C., A. P. So & Y. C. Hung

2001 "Neural Network vs. Hedonic Price Model: Appraisal of High-density Condominiums," in *Real Estate Valuation Theory*. 181-198. ed. K. Wang & M. L. Wolvertom, American Real Estate Society (ARES) Monograph, Vol. 8.

