臺大管理論叢 2007/6
第17卷第2期 107-132

以單變量 ARIMA 模式、類神經網路、灰色 GM (1,1) 模型預測高雄港貨櫃吞吐量

Prediction of Container Throughput in Kaohsiung Port Using Univariate ARIMA, Neural Network, and GM (1,1) Models

郭英峰 / 國立高雄大學資訊管理學系教授
Ying-Feng Kuo, Professor, Department of Information Management, National University of Kaohsiung

陳邦誠 / 樹德科技大學經營管理研究所碩士
Pang-Cheng Chen, MBA, Graduate School of Business and Administration, Shu-Te University

Received 2005/6, Final revision received 2007/2

摘要

貨櫃吞吐量對台灣經濟扮演著舉足輕重的角色，且能帶動國家整體的經濟發展，因此建構未來貨櫃吞吐量需求模型，以提供足夠的資訊，做為政策研擬及港埠發展規劃之用，為當前重要的課題。本研究以單變量 ARIMA 模式、類神經網路及灰色 GM (1,1) 模型三種預測模型應用於高雄港貨櫃吞吐量之預測，且透過 MAPE、RMSPE 與 THEIL 三種評鑑指標加以評估其效能。研究結果顯示各預測模型均有高度之精準度，其中又以灰色 GM (1,1) 模型有最佳的適配能力，其次為單變量 ARIMA 模式，最後為類神經網路。

【關鍵字】單變量 ARIMA 模式、類神經網路、灰色 GM (1,1) 模型

Abstract

The container throughput plays an important role in Taiwanese economic and it is able to enhance national economic development. To provide the sufficient information for policy making and development planning of ports, building the future demand model of container throughput is a very important issue. This study uses univariate ARIMA, neural network, and GM (1,1) models to predict the container throughput in Kaohsiung port and uses MAPE, RMSPE and THEIL evaluation index to evaluate their efficacy. The analytical results show the predicting models are with high accuracy. The GM (1,1) model is the best for predicting container throughput, followed by univariate ARIMA and neural network.

【Keywords】univariate ARIMA, neural network, GM (1,1)

臺灣大學學術期刊資料庫

壹、緒論

近年來隨著全球海運市場由北美與西歐地區轉移至亞太地區，使得亞太地區各國際商港扮演著舉足輕重的角色，因此港埠進出口績效顯得格外重要。高雄港為台灣最大的國際商港亦為最大吞吐門戶，且具天然深水港的優勢，加上港埠設施完善，定期航線密集有利於轉口業務等優勢，曾為東亞第二大商港，以及全球第三大貨櫃港，對於經濟發展主要依靠對外貿易的台灣而言，無疑的為台灣之產業經濟成長帶來莫大的貢獻。

港埠運量預測主要目的是為了能有效地進行港埠設施規劃與營運管理工作，以為未來港埠經營與管理做適當的調整與改進，並可供財政單位預估稅收以及提供研究產業經濟活動之用 (魏健宏、楊雨青，1999；黃文吉、吳勝傑、程培倫、尤仁弘，2003)。港埠運量之預測方法若以變數多寡來分類，可分為二大類：多變數與單變量模式。其中，多變數模型均利用總體外生變數與貨櫃吞吐量間之關係，構建未來貨櫃吞吐量需求模型。其優點為可掌握貨櫃吞吐量的重要影響因素，但相對的所需花費的時間與成本也較高，且其主要影響變數亦難蒐集與判斷。單變量預測模型之優點為較不易受到其他外生因素所影響而產生偏誤；其中單變量 ARIMA 模式、類神經網路、灰色 GM (1,1) 模型應用之層面相當廣泛，諸如經濟、商業、金融、工程、農業等學科，皆有文獻支持其預測之成效，而 Lam、Ng、Seabrooke 與 Hui (2004) 認為以類神經網路預測月期資料預測較年期佳。因此本研究以高雄港貨櫃吞吐量為預測變數，利用單變量 ARIMA 模式、類神經網路、灰色 GM (1,1) 模型三種方法針對 1986 年 1 月至 2004 年 7 月為止共 223 筆高雄港貨櫃吞吐量之資料，建構高雄港貨櫃吞吐量之預測模式，並比較此三種預測方法之預測效果與適應性，以尋求貨櫃吞吐量之最佳預測模型，期能提供足夠的資訊，做為政策研擬及港埠發展規劃之用。

本研究主要分為五部分；在第一部分中，說明本研究之動機與目的；第二部份為與港埠運量預測相關之文獻探討；第三部分主要介紹單變量 ARIMA 模式、類神經網路、灰色 GM (1,1) 模型之基本架構及預測模式之建構流程；在第四部份中，則以高雄港貨櫃吞吐量之資料，分別就上述三種預測方法，建構其預測模式，並加以分析評估，並整合三種預測方法之預測績效；最後在第五部分中，則根據研究之結果提出說明及建議。

貳、文獻探討

關於港埠運量預測最佳模式已有不少學者曾經探討，其中邱振崑 (1996) 認為 ARIMA 預測乃是針對複雜且基本型態變化莫測的時間數列，故其認為類似港埠營運量這種數列，便可考慮使用此一方法，在其預測台灣各國際港口 (基隆、台中、高雄、花蓮) 之進出船舶總噸數、旅客人數、進出港貨物量、環島貨運量、倉棧進出倉

臺灣大學學術 期刊資料庫

總量及國輪承運量的預測線及配適線也都得到非常完美的結果。Klein (1996) 則以 ARIMA 透過 Box-Cox 轉換、涉入模型及 22 種貨物運輸量加以預測安特衛普 (Antwerp) 海上的運輸量；顏進儒與林永山 (1997) 則使用多元迴歸分析法以台灣經濟成長率、美元對台幣匯率等五項因變數預測台灣港埠之運量。周文賢、張隆憲與古金英 (1999) 利用 ARIMA 模型經由全球國民生產毛額、台灣實質國民生產毛額等五項變數，透過 Box-Cox 轉換得到進口函數屬於 ARIMA (0,1,1)，出口函數屬 ARIMA (2,1,0) 模式。魏健宏與楊雨青 (1999) 利用貢獻圖的概念，得到影響性較為顯著的因素，再經由敏感度分析，並藉由類神經網路的建構及運算，預測高雄港貨櫃運量，研究結果發現在無時間序列特性下選擇經濟成長率、工業生產指數、躉售物價指數及在有時間序列特性下選擇國內生產毛額、經濟成長率、工業生產指數、平均國民所得、躉售物價指數、平均國民生產毛額為輸入變數時具較佳之預測成效。Fung (2001) 以向量錯誤改正模型預測香港港埠貨物吞吐量；Babcock 與 Lu (2002) 則使用 ARIMAX 預測密西西比河糧食運送總公噸數；Fung (2002) 則以錯誤修正模型預測香港港埠貨物吞吐量。周建張 (2003) 以國內生產毛額及進、出口貨櫃量計算出放大係數，並透過改良型迴歸預測模式加以預測，結果較傳統迴歸預測佳。周明道、林光與李選士 (2003) 以 SARIMA 的模式預測基隆港每月出口量，在三種候選預測模式中以 ARIMA 為最佳之預測模式。黃文吉 et al. (2003) 針對台灣地區進、出口運量，以灰色 GM (1,1) 模式，採不同資料年期 (4 年至 15 年) 建模，分析結果發現，於生命週期成熟期預測之準確度較佳，而在 S 曲線轉折點時，則建議以極短期預測較為準確。而梁金樹與周聰佑 (2003)以結合模糊理論及傳統迴歸分析的概念，建構出模糊迴歸模式，在決策者對於未來整體經濟環境的樂觀與否，透過不同的切割分式更為貼近現實。Seabrooke、Hui、Lam 與 Wang (2003) 以多元迴歸模式預測香港港埠貨物吞吐量；周惠 (2004) 以青島港月期資料透過 SARIMA 模式建立青島港貨運吞吐量，其預測最佳模式為 ARIMA (4,1,1) (1,1,1)。Lam et al. (2004) 以包含三隱藏層之倒傳遞演算法中的多層前饋網路對數雙彎曲激發函數做為轉換函數，從 17 種貨物中找出何者對香港港埠貨物吞吐量具較佳之預測能力，其亦提出建議以月期資料做更多次的訓練以達到更好的預測效果。楊神化與關克平 (2005) 利用正交函數做最小二乘擬合模型再以試算表 (Spreadsheet) 建模預測南通港貨運吞吐量，雖得到不錯的預測效果，但亦指出此法不宜作為長期預測之模式。彭文怡與朱經武 (2006) 比較四種常見使用之單一變數預測方法，包括古典分解法、三角函數迴歸、季節性虛擬變數及灰預測，利用實證分析，以驗證何者可提供預測進口貨櫃量最佳之精確度，結果發現，基隆港以古典分解法，台中港以古典分析法與灰預測，高雄港以灰預測的預測能力最佳。劉燕與陳一梅 (2006) 則針對淮南市港口吞吐量加以預測，其認為對於短期預測應以 GM (1,1) 與 Verhulst 組合模型加以預測，而在做長期的預測時應使用 Verhulst 模型並以 GM (1,1) 模型對其殘

臺灣大學學術 期刊資料庫

差進行修正，會有較佳的預測結果。劉勇南 (2006) 以年期資料，使用灰色 GM (1,1) 預測東莞市港口貨物吞吐量，其指出雖然灰色 GM (1,1) 能滿足一般港口貨物吞吐量預測的要求，而並非所有港口貨物吞吐量預測都能應用灰色 GM (1,1) 達到理想的預測效果，若港口吞吐量依 S 型曲線增長或處於飽和階段時，其預測精度便將受到考驗。本研究茲將國內外港埠運量預測文獻彙整如表 1、2 所示。

表 1 台灣港埠運量預測文獻彙整表

作 者	預測方法	資料時間	變 數	備 註
邱振崑 (1996)	ARIMA	1969-1994	年期	預測台灣各國際港口(基隆、台中、高雄、花蓮)進出船舶總噸數、旅客人數、進出港貨物量、環島貨運量、倉棧進出倉總量及國輪承運量
顏進儒與林永山 (1997)	多元迴歸分析法	1981-1995	台灣經濟成長率、美元對台幣匯率、國內生產毛額、日本經濟成長率、大陸國內生產毛額	預測台灣港埠之運量
周文賢 et al. (1999)	ARIMA 轉移函數模式	1980-1996	全球國民生產毛額、台灣實質國民生產毛額、有效關稅率、買進匯率、賣出匯率	預測進出口貨櫃量
魏健宏與楊雨青 (1999)	倒傳遞類神經網路	1973-1996	國內生產毛額、經濟成長率、工業生產指數、平均國民所得、躉售物價指數、平均國民生產毛額、工業生產毛額、前期轉口貨櫃量	預測高雄港轉口貨櫃運量
周建張 (2003)	改良式迴歸分析	1987-1999	國內生產毛額	預測台灣港埠貨櫃量
周明道 et al. (2003)	SARIMA	1994-2002	基隆港每月出口貨櫃量	預測基隆港出口貨櫃量
黃文吉 et al. (2003)	滾動式GM (1,1)	1973-2001	年期	預測台灣港埠貨櫃運輸需求
梁金樹與周聰佑 (2003)	模糊迴歸	1987-2002	國內生產毛額、經濟成長率、匯率、國民生產毛額、躉售物價指數、台灣總人口數、工業生產毛額、貨幣供給額、工業生產指數	預測台灣海運進出口貨物運量

臺灣大學學術期刊資料庫

彭文怡與朱經武 (2006)	三角函數迴歸、古典分解法、季節性虛擬變數及GM (1,1)	2001-2004	月期	預測台灣地區三大國際港埠 (基隆港、台中港與高雄港) 進口之貨櫃量

資料來源：本研究

表 2 國外港埠運量預測文獻彙整表

作 者	預測方法	資料時間	變 數	備 註
Klein (1996)	SARIMANT	1971-1982	月期、22 種貨物運輸量	預測 Antwerp 海上的運輸量
Fung (2001)	向量錯誤改正模型	1986-1997	季期、各港口總貨櫃量、各港口關稅	預測香港港埠貨物吞吐量
Babcock & Lu (2002)	ARIMAX	1989-1999	季期	預測密西西比河糧食運送總公噸數
Fung (2002)	錯誤修正模型	1986-1997	季期、年期、關稅、對外貿易量	預測香港港埠貨物吞吐量
Seabrooke et al. (2003)	多元迴歸分析	1983-1999	進出口貿易值、國內生產毛額、人口數、營建支出、電力需求、轉口價格、國內出口價格	預測香港港埠貨物吞吐量
Lam et al. (2004)	倒傳遞類神經網路	1983-2000	17 種貨物流量	預測香港港埠貨物吞吐量
周惠 (2004)	SARIMA	1999-2003	月期	預測青島港貨運吞吐量
楊神化與關克平 (2005)	正交函數系最小二乘擬合法及 Spreadsheet	2001-2003	月期	預測南通港貨運吞吐量
劉燕與陳一梅 (2006)	灰色 Verhulst	1997-2004	年期	預測淮南市港口吞吐量
劉勇南 (2006)	GM (1,1)	1993-2003	年期	預測東莞市港口貨物吞吐量

資料來源：本研究

臺灣大學學術期刊資料庫

預測方法發展至今已出現許多模型，以往關於時間數列預測的研究中，大多是利用 ARIMA 當作主要的預測工具，其中不乏有卓越的研究成果，但有兩大困難無法克服：須蒐集大量的歷史樣本資料，及對研究樣本之母體分配做許多嚴格假設。而類神經網路及灰色預測模型之共同點，在於毋須對研究樣本之母體分配做許多嚴格假設。類神經網路預測模型為一種非線性運算模型且具資料平行輸入運算的特性，可根據歷史資料的型態，萃取出實證資料之間複雜的函數關係。而灰色預測模型之最大優勢便為僅需四筆樣本資料，即可得到可靠之預測結果。由表 1 及表 2 可知某些研究以多變量的模型加以預測，但變數的選取卻不盡相同，有鑑於變數搜尋為預測中最困難的一環，加上多變數預測在於變數選取時可能發生主觀及共線性之問題，進而導致預測出之結果有所偏差，且在選擇變數及蒐集變數數據時較為費時，因此為避免此一問題本研究採取較單純且易取得之貨櫃吞吐量歷年數值為預測變數，並以目前發展較成熟且被廣為利用之單變量 ARIMA、類神經網路及灰色 GM (1,1) 模型三種預測方法來預測高雄港貨櫃吞吐量，藉此以瞭解高雄港未來之貨櫃吞吐量之趨勢以及比較三種預測模式之適應性，增加預測的效率以便一般實務上之使用。

參、預測方法之介紹

預測是估計未來企業所無法控制的事件或情況，並提供管理者做為規劃的基礎 (Herbig, Milewicz, & Golden, 1993)。企業進行預測以建構未來的藍圖，並在企業功能上扮演重要的角色，因此預測為決策過程中的主要成分。預測具備以下性質 (Lebell & Krasner, 1977)：

1. 預測程序的持續性：環境的變遷，將對預測造成不同程度的影響。因此預測者須熟悉此種情況，並適時的加以修正。
2. 預測情況的不定性：由於難以控制預測相關因素的變動，加上彼此相互衝擊的程度亦難測量，因此未來情況的不定性乃是必然的結果。
3. 預測事項的連續性：當預測事件持續出現，才可將其做為預測基礎的資料。且唯有此種資料才能構成一定的型態 (Pattern)，藉由對此型態的了解，才能推演未來可能的型態。
4. 預測結果的錯誤性：由於未來情況存在不確定性，預測結果必定存在著某種程度的誤差，使得預測結果幾乎不可能與事實真相完全吻合。

有關本研究所採用之預測模式、模式效能評估與評鑑指標茲分別介紹如下：

一、單變量ARIMA模式

Box 與 Jenkins (1970) 提出一套時間序列分析方法，其認為影響時間序列資料變動的主要因素可分為兩種，其中可藉由序列中的歷史資料來推估未來的趨勢，稱此序

臺灣大學學術 期刊資料庫

列符合自我迴歸過程 (Autoregressive Process；AR Process)；若現期的不規則變異可以藉由過去的不規則變異所估計出，則稱此序列符合移動平均過程 (Moving Average Process；MA Process)。其認為時間序列是由資料的過去實際值和隨機振動 (Random Vibration) 所組成，稱為自我迴歸整合移動平均模式 (Autoregressive Integrated Moving Average Model；ARIMA) 理論。ARIMA 模式的建立是系統化辨識、估計、診斷和預測時間序列之方法論，實際資料全部被用來將一個時間序列分解成三個 ARIMA 成份。ARIMA (p, d, q) 模型表示如下：

$$\phi_p(B)Y_t = c + \theta_q(B)e_t,\ \ e_t \overset{iid}{\sim} N(0,\sigma^2), \tag{1}$$

其中 B 為後移運算子 (Backward Shift Operator)，$BY_t = Y_{t-1}$，

Y_t 為一穩定 (Stationary)狀態的時間序列值，

c 為常數項，

e_t 為干擾項，且符合白色干擾 (White Noise) 的假設，即期望值為零，變異數為一固定常數之假設。

而 $\phi_p(B)$ 及 $\theta_q(B)$ 分別代表 B 之多項式，可表示如下：

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \cdots - \phi_p B^p \ , \tag{2}$$

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_q B^q \ 。 \tag{3}$$

在 ARIMA 分析中，其目的為由時間序列中取出所有可能的資訊，使得誤差項的分配為白色干擾 (White Noise)，並找出可精確代表一時間序列之過去和未來模型之模式。以下列表示：

實際值 = 模型 + 誤差值

列中模型部分可以是隨機、季節性、趨勢、循環等之組合。根據 Box 與 Jenkins (1970) 的方法論，建構 ARIMA 模型的流程如 圖 1 所示，並說明如下：

臺灣大學學術期刊資料庫

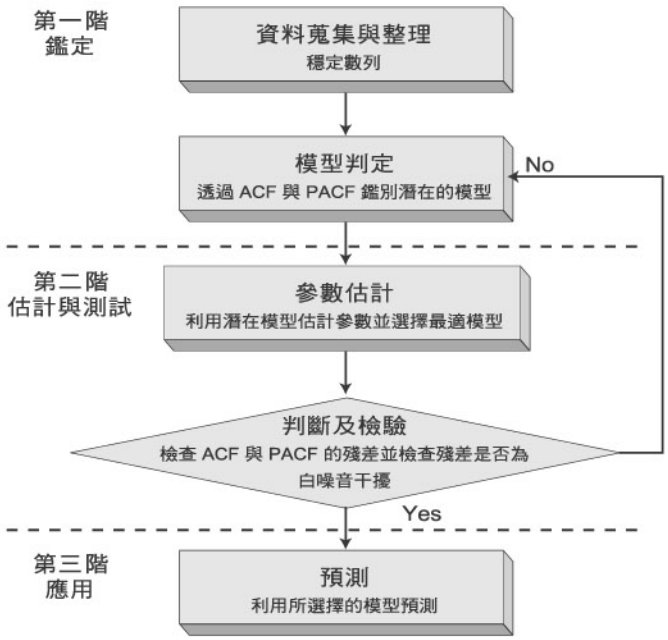


圖 1 ARIMA 時間序列模式建構流程圖

1. 資料蒐集與整理

針對研究變數，蒐集整理其歷史性時間序列資料。

2. 模型判定

ARIMA (p, d, q) 模式建構的第一步，須先決定差分的階次 d；接著再決定自我迴歸之落差期數，若落差 p 期，則記為 AR (p)；同時也需決定移動平均期數，若落差 q 期，則記為 MA (q)。操作上，首先將蒐集整理完成之時間序列資料繪製出原始資料之時間序列圖，並判定是否為穩態 (Stationary)，若呈現不平穩的狀況，則對資料進行差分或數學轉換直至呈現平穩為止，並據以決定模式階次。此外，計算時間序列資料之自我相關函數 (Autocorrelation Function；ACF)，以及偏自我相關函數 (Partial Autocorrelation Function；PACF)，利用 ACF 與 PACF 來判定模型中 AR (p) 和 MA (q) 的可能階數。其判定方式如表 3 所示。

表 3 ACF 及 PACF 之判定方式

模型	ACF	PACF
AR (p)	呈現指數下降或正負相間遞減的趨勢	自 p 期後不顯著
MA (q)	自 q 期後不顯著	呈現指數下降或正負相間遞減的趨勢
ARMA (p,q)	呈現指數下降或正負相間遞減的趨勢	呈現指數下降或正負相間遞減的趨勢

臺灣大學學術期刊資料庫

3. 參數估計

將 $\phi_p(B)\,Y_t = c + \theta_q(B)\,e_t$ 改寫成 $e_t = \theta_q^{-1}(B)\,[\phi_p(B)\,Y_t - c]$，如果存在移動平均項，則 $e_t = \theta_q^{-1}(B)\,[\phi_p(B)\,Y_t - c]$ 的參數將為非線性，因此須使用非線性估計法來找到一組自我迴歸參數 ($\hat{\phi}_1,\ldots,\hat{\phi}_p$) 和一組移動平均參數 ($\hat{\phi}_1,\ldots,\hat{\phi}_q$)，使得 $\sum \hat{e}_t^2$ 有最小值。

4. 判斷及檢驗

在估計一個時間序列模型的參數後，必須診斷此種設定是否合適，診斷方法的基礎是依據實際模型之隨機誤差項 e_t 為常態分配且彼此獨立，因此如果模型的判定正確，則 $\hat{e}_t$ 應該是類似白噪音過程。若以 $\hat{\gamma}_k$ 表示 $\hat{e}_t$ 的樣本 ACF，兩種常用的檢定法如下：

(1) 樣本 ACF 檢定

$\hat{\gamma}_k \sim N(0, \frac{1}{T})$，T為觀測樣本數。

(2) Q 檢定

在檢定白色干擾時，Box 與 Pierce (1970) 提出在大樣本時，

$$Q_{BP} = T\sum_{k=1}^{m} \hat{\gamma}_k^2 \sim \chi_m^2 \text{ 。} \tag{4}$$

Ljung 與 Box (1978) 修正 Q_{BP} 使其更近似卡方分配並且適用於小樣本，修正後的檢定統計量為

$$Q_{LB} = T(T+2)\sum_{k=1}^{m} (\frac{1}{T-k})\hat{\gamma}_k^2 \sim \chi_m^2 \text{ 。} \tag{5}$$

5. 應用模型進行預測

完成適當模型後，即可利用模型進行預測分析，並進行樣本外的推測。

二、類神經網路

類神經網路 (Artificial Neural Networks；ANN) 是指模仿生物神經網路的資訊處理系統，主要使用簡單且大量的相連人工神經元 (Neurons) 來模仿生物神經網路的能力。其最大的優點為可應用於建構非線性之模式，及彌補多元迴歸及 ARIMA 模式建構時須設立許多假設條件之缺點。由於類神經網路可以建構非線性的模型，故應用的

臺灣大學圖書館 期刊資料庫

領域相當廣泛，且具良好的推廣性，對於未知的輸入亦可得到準確的輸出；更可接受不同種類的變數作為輸入，適應性強 (葉怡成，1997)。但是其缺點為以迭代方式更新鍵結值與閥值，計算量大，相當耗費電腦資源；類神經網路的解有無限多組，無法得知哪一組的解為最佳解；類神經網路訓練的過程中無法得知需要多少神經元個數，太多或太少的神經元均會影響系統的準確性，因此往往需以試誤的方式得到適當的神經元個數。

類神經網路有多種網路型態，其中又以倒傳遞 (Back Propagation Network；BPN) 類神經網路最具代表性。BPN 屬於監督式學習 (Supervised Learning) 網路模式，並採用轉換函數處理輸入輸出間之映射關係，通常使用雙彎曲函數 (Sigmoid Function)，其網路結構通常包含三層神經元：輸入層 (Input Layer)、隱藏層 (Hidden Layer) 及輸出層 (Output Layer)。一般而言，輸入層神經元的數目即為欲輸入變數之數目；輸出層神經元的數目則為欲得之結果變數個數；而在隱藏層方面，通常包含一個或多個隱藏層。類神經網路對於變數的選取有較大的自由度，沒有如迴歸分析般的限制。而隱藏層之數目、隱藏層中神經元數目、訓練的學習率 (Learning Rate) 等等，並無一固定的定理可遵循。但需注意的是，若隱藏層所包含神經元的個數太少時，會限制網路結構的發展能力；太多時則會造成過度學習。

BPN 的演算流程是由輸入層將資料傳給隱藏層，經計算與轉換後送到輸出層，計算與實際值 (Target) 的差距後，回傳給隱藏層去修正連接鍵的權數，使得輸出值與真實值的均方誤差 (MSE) 最小，訓練過程採用最陡坡降法 (The Gradient Steepest Descent Method) 加以調整。

本研究採用古典最佳化中二階梯度法之 Levenberg-Marquardt 演算法加以運算，其主要特色為當 $\mu = 0$ 時，便是使用近似化 Hessian 矩陣的牛頓法。而當 μ 值很大時，便為具有小步階之梯度下降。為了快速的移向牛頓法，在每個步階內性能函數降低後，μ 值亦隨之下降，只有當一個暫時的步階將增加性能函數時才增加 μ 值。在此方式下，性能函數在此演算法的每個迭代上總是會被降低。

三、灰色GM (1,1) 模型 (Grey Model)

灰色系統理論 (Grey Theory) 由 Deng (1982) 提出，主要用於控制領域，發展至今已被應用於其他各個領域，其中包含管理決策、社會經濟、氣象、生態、生物、水利等。該模式主要應用於系統模型在信息不完全、行為模式不明確、運作機制不清楚之狀況下，可對系統的發展變化進行全面性的分析及觀察，並做出長期的預測。其最大的特色為，只要有四筆以上的資料即可建立模型，且毋須對研究樣本之母體分配做許多嚴格假設。

灰色 GM (1,1) 模型建模步驟如下：

臺灣大學學術期刊資料庫

(1) 假設原始數列為，$x^{(0)}$ ，$x^{(0)}=\left\{x^{(0)}(1),x^{(0)}(2),\cdots,x^{(0)}(n)\right\}$，　(6)

(2) 建立累加生成數列，由 $x^{(0)}$ 經累加生成 (Accumulated Generating Operation；AGO) 形成新數列 $x^{(1)}$，$x^{(1)}=\{x^{(1)}(1),x^{(1)}(2),\cdots x^{(1)}(n)\}$，其中

$$x^{(1)}(k)=\sum_{i=1}^{k}x^{(0)}(i)\ ，\ k=1,2,\cdots,n\ 。 \tag{7}$$

(3) 建立灰微分方程式，由 $x^{(1)}$ 建立灰微分方程式為：

$$\frac{dx^{(1)}(k)}{dk}+az=b\ ，其中，\ z=\frac{\left[x^{(1)}(k)+x^{(1)}(k+1)\right]}{2}\ ，\ k=1,2,\cdots,n-1\ 。 \tag{8}$$

(4) 建立參數矩陣，並利用最小平方法 (Least Square Method) 求解待定參數 a、b：

$$B=\begin{bmatrix}-\dfrac{x^{(1)}(1)+x^{(1)}(2)}{2} & \cdots & 1\\ -\dfrac{x^{(1)}(2)+x^{(1)}(3)}{2} & \cdots & 1\\ \vdots & \ddots & \vdots\\ -\dfrac{x^{(1)}(k)+x^{(1)}(k+1)}{2} & \cdots & 1\end{bmatrix}, \tag{9}$$

$$Y=\begin{bmatrix}x^{(0)}(2)\\ x^{(0)}(3)\\ \vdots\\ x^{(0)}(k)\end{bmatrix}, \tag{10}$$

$$\hat{\theta}=\begin{bmatrix}a\\ b\end{bmatrix}=(B^TB)^{-1}B^TY\ 。 \tag{11}$$

(5) 解微分方程式，依微分方程式求解公式解，可求得白化響應函數 (Response Function)為：

$$\hat{x}(k+1)=\left[x^{(0)}(1)-\frac{b}{a}\right]\cdot e^{-ak}+\frac{b}{a}\ ，其中，\ x^{(1)}(1)=x^{(0)}(1)\ 。 \tag{12}$$

經由逆累加生成 (Inverse Accumulated Generating Operation；IAGO) 還原預測之數據，即

臺灣大學學術期刊資料庫

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1) = \left[x^{(0)}(1) - \frac{b}{a} \right] \cdot (1 - e^{a}) \cdot e^{-a(k-1)} \text{ ，} k = 1,2,\cdots,n \text{ 。} (13)$$

上述預測模型所得之預測值須經檢驗，才可得知預測結果是否可採信，因此，本研究以鄧聚龍 (1986) 及鄧聚龍與郭洪 (1996) 所提之殘差檢驗 (Residual Checking) 及後驗差檢驗 (Posterior Check) 進行預測模型精度檢驗。

另外，$\hat{x}_{k+1}$ 可與實際值 x_{k+1} 進行精確度檢測，其殘差值 ε 為

$$\varepsilon = \left| \frac{\hat{x}_{k+1} - x_{k+1}}{x_{k+1}} \right| \times 100\% \text{ ，} \quad (14)$$

預測模式之精確度為 $1-\varepsilon$ ，當平均精確度大於 90% 時，表示模式之預測效能為優 (如表 4 所示) (鄧聚龍、郭洪，1996)。

表 4 殘差等級區分表

ε %	≤10 %	(10 %, 20 %]	(20 %, 30 %]	>30%
等級	優	良	及格	不合格

後驗差檢驗乃利用後驗差比 C 與誤差頻率 p 來衡量預測模型精度，其計算方式為， $C = \frac{S_1}{S_2}$ ，其中， (15)

ε 的離差 $S_1^2 = \frac{1}{n}\sum_{k=1}^{n}(\varepsilon(k) - \bar{\varepsilon})^2$，殘差序列 $\varepsilon(k) = x^{(0)}(k) - \hat{x}^{(0)}(k)$ ，殘差均值 $\bar{\varepsilon} = \frac{1}{n}\sum_{k=1}^{n}\varepsilon(k)$ ，

$x^{(0)}$ 的離差 $S_2^2 = \frac{1}{n}\sum_{k=1}^{n}(x^{(0)}(k) - \bar{x})^2$ ，原始序列均值 $\bar{x} = \frac{1}{n}\sum_{k=1}^{n}x^{(0)}(k)$ 。

當 C 值越小表示原始數據離散性越大，而殘差之離散度小，預測精度高；

誤差頻率， $p = P(|\varepsilon(k) - \bar{\varepsilon}| < 0.6745S_2)$ ，

而 p 越大表示殘差與殘差平均值之差小於 $0.6745S_2$ 之數據越多，故 p 越大越好，後驗差等級區分如表 5 所示。

臺灣大學圖書館 期刊資料庫

表 5 預測精度指標等級表

預測精度指標 / 等級	*P*	*C*
好 (Good)	> 0.95	< 0.35
合格 (Qualified)	> 0.8	< 0.5
勉強 (Just)	> 0.7	< 0.65
不及格 (Unqualified)	≤ 0.7	≥ 0.65

四、模式效能評估及評鑑指標

為了比較建立模式間之差異及效能，本研究使用以下三種指標來表示各模型之適配程度：

(1) 平均絕對誤差率 (Mean Absolute Percentage Error；MAPE)

$$MAPE = \left(\frac{1}{N} \sum_{t=1}^{N} \frac{\left| X_t - \hat{X}_t \right|}{X_t} \right) \times 100\% \text{，} \tag{16}$$

其中 N = 資料總數，X_t = 監測值，$\hat{X}_t$ = 預測值。

(2) 平均平方根誤差率 (Root Mean Square Percentage Error；RMSPE)

$$RMAPE = \left(\frac{1}{N} \sqrt{\sum_{t=1}^{N} \left(\frac{X_t - \hat{X}_t}{X_t} \right)^2} \right) \times 100\% \text{。} \tag{17}$$

Lewis (1982) 依據 MAPE 及 RMSPE 大小將模式預測能力分為四種等級，如表 6 所示。

表 6 模式預測能力等級表

MAPE 與 RMSPE	預測能力
<10%	高精確度
10% ~ 20%	良好
20% ~ 50%	合理
> 50%	不正確

(3) 泰爾不等係數 (Theil's Inequality Coefficient；THEIL)

臺灣大學學術期刊資料庫

$$THEIL = \frac{\sqrt{\sum_{t=1}^{N}(X_t - \hat{X}_t)^2 / N}}{\sqrt{\sum_{t=1}^{N}(X_t)^2 / N}}。 \quad (18)$$

McNees (1979) 指出 THEIL 之值小於 0.55 時模型為良好。

肆、研究分析與結果

一、資料來源

本研究主要以物流資訊網 (http://link.disc.com.tw) 所公佈之高雄港貨櫃吞吐量為預測變數，期間自 1986 年 1 月至 2004 年 7 月為止共 223 筆資料，單位為百萬噸，其趨勢圖如圖 2 所示，圖 2 中顯示此時間數列具波動性及上昇的趨勢。本研究先以前 183 筆資料 (1986 年 1 月至 2001 年 3 月) 建立模型，待模型確立後再應用於預測後 40 筆資料 (2001 年 4 月至 2004 年 7 月)，並與實際值進行測試，以下分別說明此三種方法之分析流程及結果。

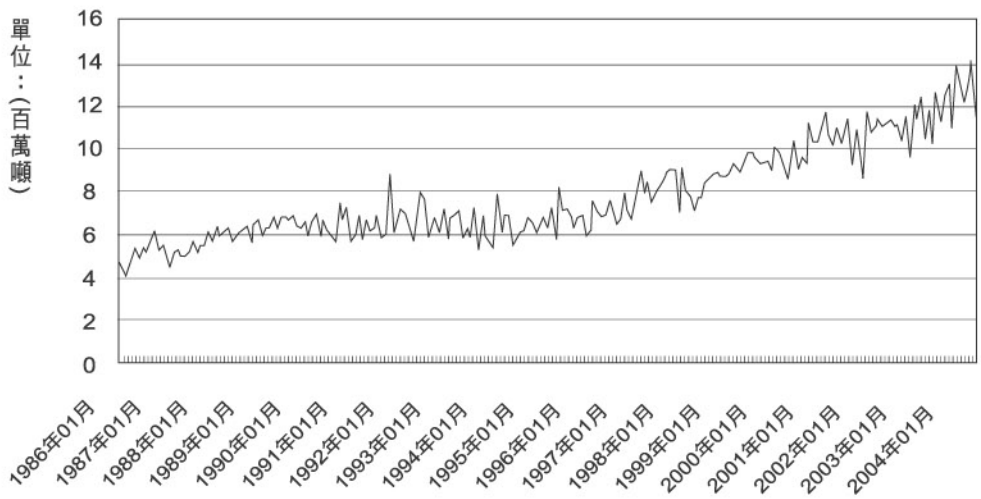


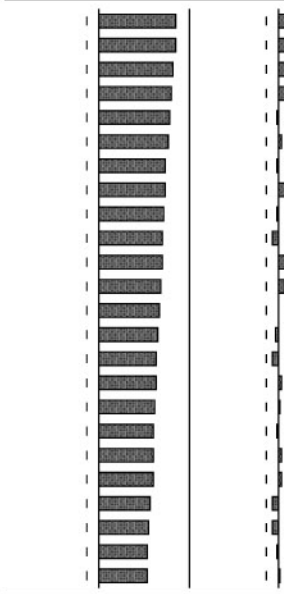
圖 2 高雄港 (1986 年 1 月～ 2004 年 7 月) 貨櫃吞吐量趨勢圖

二、單變數 ARIMA 模式預測

在本研究中使用 EViews 4.0 套裝軟體，來協助建立 ARIMA 預測模式，首先繪出原始數列之 ACF 與 PACF 圖形 (圖 3)。

臺灣大學學術期刊資料庫

Date: 12/29/04 Time: 14:17
Sample: 1986:01 2004:07
Included observations: 223



	AC	PAC	Q-Stat	Prob
1	0.891	0.891	179.38	0.000
2	0.880	0.419	355.28	0.000
3	0.859	0.174	523.39	0.000
4	0.841	0.090	685.49	0.000
5	0.813	-0.020	837.53	0.000
6	0.797	0.025	984.56	0.000
7	0.772	-0.019	1123.1	0.000
8	0.774	0.122	1262.8	0.000
9	0.748	-0.013	1394.2	0.000
10	0.724	-0.072	1517.8	0.000
11	0.725	0.094	1642.3	0.000
12	0.717	0.065	1764.6	0.000
13	0.701	-0.003	1882.1	0.000
14	0.687	-0.031	1995.3	0.000
15	0.666	-0.061	2102.4	0.000
16	0.662	0.037	2208.7	0.000
17	0.649	0.013	2311.2	0.000
18	0.630	-0.015	2408.3	0.000
19	0.624	0.026	2504.1	0.000
20	0.620	0.035	2599.2	0.000
21	0.596	-0.066	2687.3	0.000
22	0.578	-0.062	2770.7	0.000
23	0.563	-0.017	2850.2	0.000
24	0.553	0.015	2927.4	0.000

圖 3 原始數列之 ACF 與 PACF

接著以單根 (Unit Root) 檢定來檢定數列是否穩態 (Stationary)，由於 ADF 的 t 值 = -0.159，p 值 = 0.940 並未達顯著水準 (表 7)，所以不拒絕虛無假設，亦即數列有單根而非穩態 (Non-stationary)，因此進行一階差分，讓此數列成為平穩數列。

表 7 原始數列單根檢定表

Null Hypothesis: TUTO has a unit root
Exogenous: Constant
Lag Length: 3 (Automatic based on SIC, MAXLAG = 14)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		**-0.158745**	**0.0000**
Test critical values:	1% level	-3.460173	
	5% level	-2.874556	
	10% level	-2.573784	

*MacKinnon (1996) one-sided p-values.

臺灣大學學術期刊資料庫

由表 8 得知一階差分後 ADF 的 t 值 = -14.828，p 值 = 0.000 達顯著水準，所以拒絕虛無假設，亦即數列沒有單根，此時數列呈穩態，圖形如圖 4 所示。

表 8 一階差分後數列單根檢定表

Null Hypothesis: D (TUTO) has a unit root
Exogenous: Constant
Lag Length: 2 (Automatic based on SIC, MAXLAG=14)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		**-14.82821**	**0.0000**
Test critical values:	1% level	-3.460173	
	5% level	-2.874556	
	10% level	-2.573784	

*MacKinnon (1996) one-sided p-values.

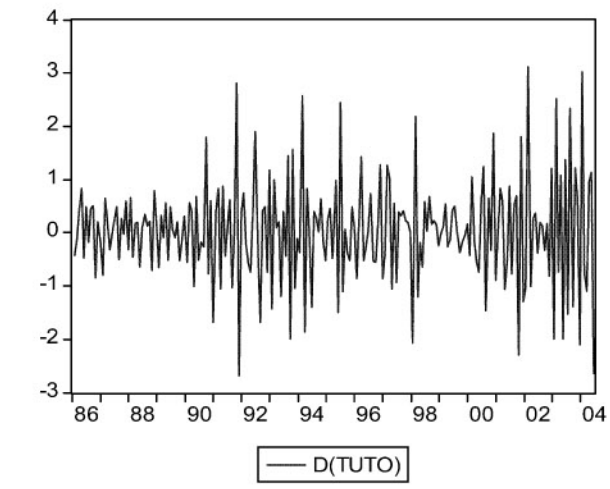
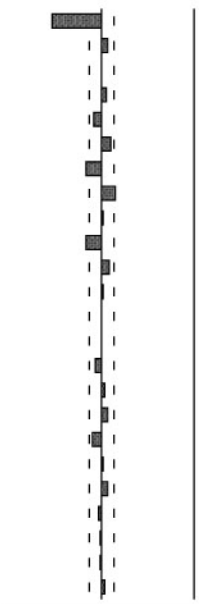


圖 4 一階差分後數列分佈型態

一旦數列呈穩態之後，再透過 ACF 與 PACF 判斷初步模型 (圖 5)。由於上列的 ACF 圖只有 lag1 突出，而 PACF 圖呈指數型態下降，故應為 MA (1) 模型，加上此為一階差分過後之結果，所以判斷初步模型為 ARIMA (0,1,1)，方程式可表示為 $(1-B)\ TUTO_t = c+(1-\theta_1 B)\ e_t$，其中 $TUTO_t$ 為高雄港貨櫃吞吐量；c 為常數項；為 e_t 白色干擾。在模型參數估計與檢定的部分如表 9 所示，常數項及 ARIMA (0,1,1) 模式下之 p 值皆落於接受域。

臺灣大學學術期刊資料庫

Date: 12/29/04 Time: 14:37
Sample: 1986:01 2004:07
Included observations: 222



Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
		1	-0.560	-0.560	70.608	0.000
		2	0.074	-0.350	71.844	0.000
		3	0.001	-0.231	71.844	0.000
		4	0.048	-0.074	72.367	0.000
		5	-0.090	-0.120	74.205	0.000
		6	0.111	0.015	77.047	0.000
		7	-0.177	-0.181	84.303	0.000
		8	0.153	-0.083	89.749	0.000
		9	0.024	0.099	89.880	0.000
		10	-0.168	-0.105	96.524	0.000
		11	0.090	-0.109	98.453	0.000
		12	0.010	-0.098	98.476	0.000
		13	0.004	-0.010	98.480	0.000
		14	0.001	0.026	98.481	0.000
		15	-0.063	-0.085	99.435	0.000
		16	0.032	-0.086	99.683	0.000
		17	0.070	-0.022	100.86	0.000
		18	-0.101	-0.049	103.35	0.000
		19	0.021	-0.060	103.45	0.000
		20	0.081	0.027	105.08	0.000
		21	-0.028	0.083	105.28	0.000
		22	-0.022	0.052	105.40	0.000
		23	-0.017	0.004	105.47	0.000
		24	0.032	0.039	105.73	0.000

圖 5 一階差分後之 ACF 與 PACF

表 9 參數估計與檢定表

Sample(adjusted): 1986:02 2001:03
Included observations: 182 after adjusting endpoints
Convergence achieved after 6 iterations
Backcast: 1986:01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
c	**0.031085**	0.009030	3.442544	**0.0007**
MA (1)	**-0.814399**	0.044438	-18.32665	**0.0000**

R-squared	0.416370	Mean dependent var	0.035805
Adjusted R-squared	0.413127	S.D. dependent var	0.832427
S.E. of regression	0.637702	Akaike info criterion	1.949038
Sum squared resid	73.19955	Schwarz criterion	1.984247
Log likelihood	-175.3624	F-statistic	128.4145
Durbin-Watson stat	2.056259	Prob (F-statistic)	0.000000
Inverted MA Roots	.81		

臺灣大學學術期刊資料庫

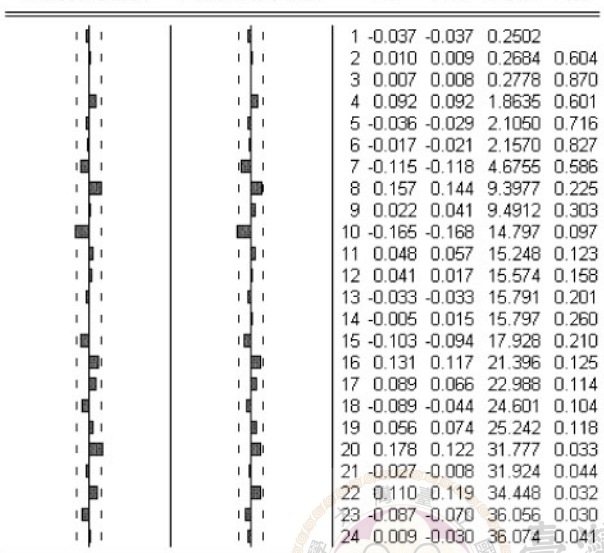
由於常數項 c 與 MA (1) 的參數估計 t 值皆達顯著水準，因此模型中含有常數項與 MA 項，整理如表 10。

表 10 參數之估計與檢定

參數	估計值	Std. Error	t 值	p-value
c	0.031085	0.009030	3.442544	0.0007
θ_1	-0.814399	0.044438	-18.32665	0.0000
Adjusted R-squared = 0.413127				

在模式檢定上，則針對模式的殘差做檢驗 (如圖 6)，藉以判斷模型之優劣。結果發現其值均無超過 2 倍標準差，且殘差之 ACF 曲線並無顯示自我相關以及殘差值均呈現常態分配，因此殘差項數列可被視為白色干擾，故判斷該模式可被接受。另外，圖 6 似乎有季節性因素存在，因此本研究為謹慎起見，再次針對季節性模式做殘差檢驗。結果顯示季節性模式之預測效果較無季節性模式差，因此本研究最終選用 ARIMA (0,1,1) 之模式做為 ARIMA 模式之使用模型。

Date: 12/29/04 Time: 14:47
Sample: 1986:02 2001:03
Included observations: 182
Q-statistic probabilities adjusted for 1 ARMA term(s)



Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
		1	-0.037	-0.037	0.2502	
		2	0.010	0.009	0.2684	0.604
		3	0.007	0.008	0.2778	0.870
		4	0.092	0.092	1.8635	0.601
		5	-0.036	-0.029	2.1050	0.716
		6	-0.017	-0.021	2.1570	0.827
		7	-0.115	-0.118	4.6755	0.586
		8	0.157	0.144	9.3977	0.225
		9	0.022	0.041	9.4912	0.303
		10	-0.165	-0.168	14.797	0.097
		11	0.048	0.057	15.248	0.123
		12	0.041	0.017	15.574	0.158
		13	-0.033	-0.033	15.791	0.201
		14	-0.005	0.015	15.797	0.260
		15	-0.103	-0.094	17.928	0.210
		16	0.131	0.117	21.396	0.125
		17	0.089	0.066	22.988	0.114
		18	-0.089	-0.044	24.601	0.104
		19	0.056	0.074	25.242	0.118
		20	0.178	0.122	31.777	0.033
		21	-0.027	-0.008	31.924	0.044
		22	0.110	0.119	34.448	0.032
		23	-0.087	-0.070	36.056	0.030
		24	0.009	-0.030	36.074	0.041

圖 6 殘差之 ACF 與 PACF 檢定圖

臺灣大學學術期刊資料庫

三、類神經網路預測

本研究利用 Matlab 6.5 套裝軟體進行類神經網路之預測，並採用目前類神經網路學習模式中，最具代表性且應用最普遍的模式，即包含單一隱藏層之倒傳遞演算法中的多層前饋網路對數雙彎曲激發函數做為轉換函數 (Transfer Function)。

本研究利用試誤法決定最佳模式，通常隱藏層之數目為一層或兩層時會有最佳收斂性質，而少於一層或多於兩層時，誤差逐漸增高。當資料筆數較少、雜訊較多、非線性程度低時可取一層隱藏層，反則取兩層隱藏層 (葉怡成，1997)，因此本研究將隱藏層神經元個數設為一層；學習次數訂為 500 次，性能目標設定為 0，降低記憶體需求量之係數設為 1，最小性能梯度為 10,000,000,000，動量初始值則為 0.001，動量減少及增加係數分別設為 0.1 及 10，訓練所需時間則設為最大，之後並比較各種輸入資料筆數 (1 ~ 6 筆) 搭配下所產生之最佳預測值，其中函數 trainlm 之訓練參數如表 11 所示，而詳細之訓練參數設定請參考附錄一。

表 11 函數 trainlm 之訓練參數

訓練參數	設定值	描述
net.trainParam.mem_reduc	1	用於記憶/速度交換的係數
net.trainParam.mu	0.001	μ 的初始值
net.trainParam.mu_dec	0.1	μ 的減少係數
net.trainParam.mu_inc	10	μ 的增加係數
net.trainParam.mu_max	10,000,000,000	μ 的最大值

性能函數降低時，mu 值就會乘上 mu_dec。當性能函數增加時，mu 值就會乘上 mu_inc。如果 mu 比 mu_max 大時，此演算法將停止。研究分析結果彙整如表 12 所示。

表 12 BPN 不同組合模式預測結果

輸入值	轉換函數-雙彎曲函數之 MSE	
	訓練資料	測試資料
1	0.0872	0.1184
2	0.0502	0.0673
3	0.0733	0.0943
4	0.0729	0.1046
5	0.0722	0.1039
6	0.0725	0.1022

<隱藏層：1；學習次數：500>

臺灣大學學術期刊資料庫

由於在輸入值為 2 時之 MSE 為最小，其網路架構及訓練趨勢圖分別如圖 7 與圖 8 所示。由圖 7 可知，本研究之網路架構之輸入層為兩層，在轉移函數分為兩階段，第一階段為 logsig (對數雙彎曲轉移函數) 而第二階段則使用 purelin (線性轉移函數)；而由圖 8 中則可明顯的看出在第 50 次訓練之前就已趨於穩定。

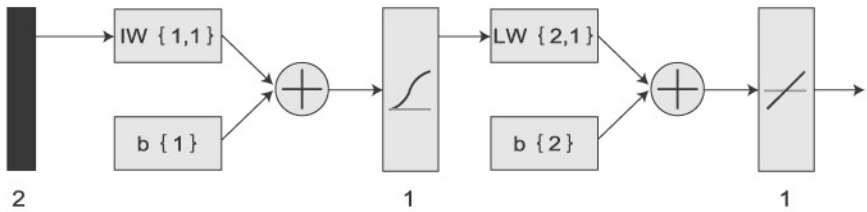


圖 7 類神經網路架構

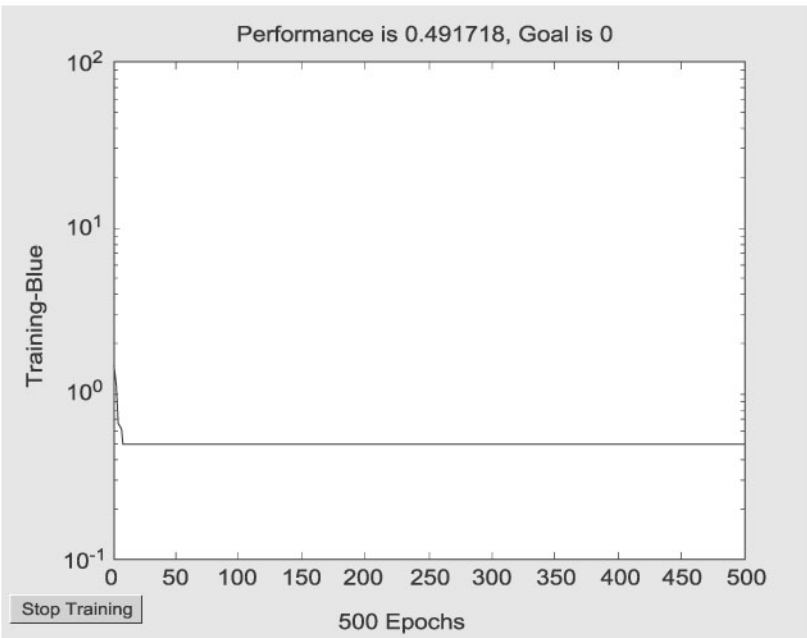


圖 8 類神經網訓練趨勢圖

四、灰色 GM (1,1) 模型

經分析結果，求得灰預測模型之參數 a = -0.0041，b = 4.7051，據以求得灰色預測模式為

臺灣大學學術期刊資料庫

$$\hat{x}^{(0)}(k)=\left(4.6234+\frac{4.6234}{0.0041}\right)\left(1-e^{-0.0041}\right)e^{0.0041(k-1)}\ 。$$

上述灰 GM (1,1) 預測模型所得之預測值須經檢驗，方可得知預測結果是否可採信。本研究以後驗差檢驗 (Posterior Check) 方法，進行預測模型精度檢驗。檢驗結果如表 13 所示，其精度高達 90.6215%，後驗差比 C 為 0.2272、誤差頻率 p 為 0.9865，等級皆為好。

表 13 灰色 GM (1,1) 模型之預測結果

ε	9.3785% (等級：優)
精度	90.6215%
C	0.2272 (等級：好)
p	0.9865 (等級：好)

本研究依照各種建模方法，呈現不同之預測結果比較資料，再利用三種評鑑指標加以評估其效能。研究結果 (表 14) 顯示，各預測方法之預測值與實際值之模式效能評鑑指標 MAPE 及 RMSPE 皆達到高精確度的水準，而 THEIL 亦達良好的水準，由此可知本研究所使用之三種預測模式在預測高雄港貨櫃吞吐量之效能是值得肯定的，這同時亦顯示本研究所使用之三種預測方法預測高雄港貨櫃吞吐量之適應性是存在的。其中又以灰色 GM (1,1) 模型有最佳的配適能力，其次為單變量 ARIMA，最後才是類神經網路。

表 14 各模式預測誤差結果比較

模式	測試資料 MAPE	測試資料 RMSPE	測試資料 THEIL
ARIMA (0,1,1)	6.7927% (高精確度)	1.3509% (高精確度)	0.0850 (良好)
類神經網路	9.4089% (高精確度)	2.0118% (高精確度)	0.1217 (良好)
灰色 GM (1,1)	**3.6438%** (高精確度)	**1.0625%** (高精確度)	**0.0701** (良好)

而在灰色 GM (1,1) 模型、單變量 ARIMA 及類神經網路的預測趨勢圖 (圖 9) 中可發現，灰色 GM (1,1) 模型之趨勢線較為平緩，單變量 ARIMA 之趨勢線其震盪明顯

臺灣大學學術 期刊資料庫

的較大，而類神經網路的預測趨勢則有上昇的趨勢。

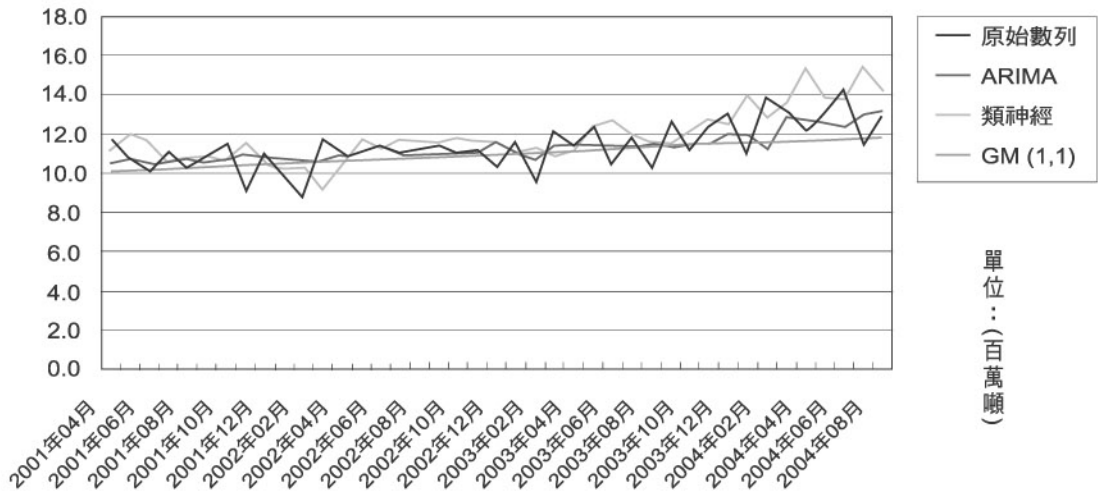


圖 9 各預測模式測試資料

伍、結論

高雄港本身位居東南亞之海運要道，且港域遼闊，氣候良好，航道迴船水域充足，可供第四代貨櫃船停靠，因此具國際商港之優勢，為配合全球化及國際物流之發展趨勢，高雄港已於 2005 年 1 月 1 日起啟運自由貿易港區，而自由貿易港區提供商品免稅自由進出之優惠，不受海關繁複程序之檢查，因此具有貨物與人員自由進出，資金自由流動，貿易自由化與全球化之功能，有效吸引外資投資開發，提昇空海港口之服務效能與競爭力，達到促進經濟發展與繁榮之目的；而高雄本身工商機能完善，藉由這些優勢將使高雄港未來深具航運利基，這同時也與高雄港貨櫃吞吐量的成長趨勢相呼應。然而值得注意的是，相對於中國大陸主要港口驚人的成長速度，其潛力更是不容忽視，同時也為高雄港最主要的競爭威脅。貨櫃吞吐量為貿易型國家經濟的重要指標之一，影響經濟發展甚鉅，而實用且準確性高之預測模式，除了可做為航運業訂定經營策略之參考外，對於在競爭日益激烈的國際商港各項設施興建與改善等工程之資源規劃，或營運管理策略方向的擬定亦有相當大的助益 (梁金樹、周聰佑，2003)。然而影響貨櫃吞吐量之因素相當多，有些是已知的，有些是無法轉換成數據或是未知的因素。目前大部分的研究主要集中於以多變量的模型加以預測，由於多變數預測在於變數選取時可能發生主觀及共線性之問題，進而導致預測出之結果有所偏差，加上在選擇變數及蒐集變數數據時較為費時，為避免此一問題，因此本研究嘗試以較單純且易取得之貨櫃吞吐量歷年數值為預測變數，且以目前被廣為利用之單變量

臺灣大學圖書館

ARIMA、類神經網路、灰色 GM (1,1) 模型三種預測方法來預測高雄港貨櫃吞吐量以及比較三種預測模式之適應性。

研究結果顯示，利用單變量 ARIMA、類神經網路、灰色 GM (1,1) 模型來預測高雄港貨櫃吞吐量之誤差水準皆在高精準度的範圍之內，由此可知此三種預測方法之適應性是存在的。其中灰色 GM (1,1) 模型在預測高雄港貨櫃吞吐量的適配能力為三種方法中最佳，此結論與彭文怡與朱經武 (2006) 之研究結果吻合。這可能是由於灰色 GM (1,1) 模型為以四筆資料即可做為建模資料，之後可再由新的數據的加入做調整，使其預測值不會與實際質差距太大，因此以此模式預測高雄港未來之貨櫃吞吐量之數據應較其他兩模式來得準確。另外由於本研究之時間序列亦無呈現 S 型曲線之特質，故本研究結果亦符合黃文吉 et al. (2003) 及劉勇南 (2006) 之論點。而單變量 ARIMA 模式相較於灰色 GM (1,1) 的適配度差，主要是由於港口吞吐量數據的產生是隨機且不確定的，並且大多數之數據都含有白噪音，而 ARIMA 為一種線性模型，對於吞吐量變化這種非線性的預測存在著先天性不足的缺陷，且僅以時間為解釋變數過於簡化，可能為單變量 ARIMA 整體預測能力較差的主要原因。而類神經網路則具有很強的非線性映射能力，且能通過學習把樣本所隱含的內在規律分布在網路之中，唯需要長期的訓練樣本，但以本研究之數據而言可能是因為吞吐量數據的產生具隨機性，而其強項在於因果關係預測及突發性預測方面，加上資料的筆數太少導致訓練不足且選取的變數也不多，致使整體結果較差。

在 Makridakis 與 Hibon (2000) 研究中發現—「沒有一種方法對所有的時間序列或預測時間範圍擁有絕對的優勢，且複雜的方法並不會顯著地比簡單的方法精確。也就是在沒有顯著的差異下，越簡單的越好」，由於時間序列與類神經網路在建立其預測模式時，需要多筆的過去資料，而灰色 GM (1,1) 模型的特性為預測所需數據少、計算方式簡單、不需要太關聯的因素便可用於短期或中長期預測且精準度高，因此在實際預測時建議可採用計算上較為簡單的灰色 GM (1,1) 模型加以預測，以提高效率。由於本研究僅使用單變量 ARIMA、類神經網路及灰色 GM (1,1) 模型三種預測方法做初步之預測，另外礙於類神經網路較擅於處理穩態之時間序列，因此對於後續研究建議方面，可在前置作業時將數據穩態後再使用類神經網路預測以改善其預測效能。除此之外，本研究建議可另外再使用其他的預測方法，或以改良式的方法加以預測，以尋求出最準確的預測方法。

臺灣大學學術期刊資料庫

參考文獻

周文賢、張隆憲、古金英，1999，「台灣貨櫃運量決定因素及預測之研究」，海運學報，7 期：頁 83-110。

周明道、林光、李選士，2003，「基隆港出口營運預測與營運發展研究」，航運季刊，12 卷 3 期：頁 23-43。

周建張，2003，「台灣地區海運貨櫃運量迴歸預測模式之改善研究」，航運季刊，12 卷 1 期：頁 27-42。

周惠，2004，「青島港貨運吞吐量的時間序列模型」，數理統計與管理，23 卷 4 期：頁 28-32。

邱振崑，1996，「港埠營運量時間數列之預測」，海運研究學刊，1 期：頁 121-134。

梁金樹、周聰佑，2003，「臺灣地區海運進出口貨物運量預測」，海運學報，12 期：頁 203-218。

彭文怡、朱經武，2006，「季節性預測模式比較-以台灣地區國際港埠進口貨櫃預測為例」，航運季刊，15 卷 2 期：頁 21-36。

黃文吉、吳勝傑、程培倫、尤仁弘，2003，「由生命週期觀點談灰色理論於運輸需求預測之應用-以臺灣地區港埠貨櫃運輸需求預測為例」，海運學報，12 期：頁 171-185。

葉怡成，1997，初版，應用類神經網路，台北，儒林圖書公司。

楊神化、關克平，2005，「Spreadsheet 方法在港口吞吐量預測中的運用」，武漢理工大學學報 (交通科學與工程版)，29 卷 5 期：頁 801-804。

鄧聚龍，1986，初版，灰色預測與決策，武昌，華中理工大學出版社。

鄧聚龍、郭洪，1996，灰預測原理與應用，台北，全華科技圖書。

劉燕、陳一梅，2006，「灰色系統模型在內河港口吞吐量預測中的應用」，水運工程，4 期：頁 31-34。

劉勇南，2006，「對東莞市港口吞吐量預測方法的思考」，水運工程，7 期：頁 1-3。

顏進儒、林永山，1997，「我國主要定期航線貨物運量分析」，運輸學刊，10 卷 4 期：頁 97-112。

魏健宏、楊雨青，1999，「高雄港轉口貨櫃運量預測之研究—以類神經網路評選輸入變數」，運輸學刊，11 卷 3 期：頁 1-20。

Babcock, M. W., & Lu, X. 2002. Forecasting Inland waterway grain traffic. ***Transportation Research Part E***, 38 (1): 65-74.

Box, G. E. P., & Jenkins, G. M. 1970. Time series analysis forecasting and control. ***Management Science***, 17 (4): 141-164.

Box, G. E. P., & Pierce, D. A. 1970. Distribution of residual autocorrelations in

臺灣大學學術期刊資料庫

autoregressive-integrated moving average time series models. ***Journal of the American Statistical Association***, 65 (332): 1509-1526.

Deng, J. L. 1982. Control problem of grey system. ***Systems and Control Letters***, 1 (4): 288-294.

Fung, K. F. 2001. Competition between the ports of Hong Kong and Singapore: A structural vector error correction model to forecast the demand for container handling services. ***Maritime Policy and Management***, 28 (1): 3-22.

Fung, M. K. 2002. Forecasting Hong Kong's container throughput: An error-correction model. ***Journal of Forecasting***, 21 (1): 69-80.

Herbig, P., Milewicz, J., & Golden, J. E. 1993. Forecasting: Who, what, when, and how. ***Journal of Business Forecasting***, 12 (2): 16-21.

Klein, A. 1996. Forecasting the Antwerp maritime traffic flows using transformation and intervention model. ***Journal of Forecasting***, 15 (5): 395-412.

Lam, W. H. K., Ng, P. L. P., Seabrooke, W., & Hui, E. C. M. 2004. Forecasts and reliability analysis of port cargo throughput in Hong Kong. ***Journal of Urban Planning and Development***, 130 (3): 133-144.

Lebell, D., & Krasner, O. J. 1977. Selecting environmental forecasting techniques from business planning requirements. ***Academy of Management Review***, 2 (3): 373-383.

Lewis, C. D. 1982. ***Industrial and business forecasting methods*** (2nd ed.). London: Butterworths.

Ljung, G. M., & Box, G. E. P. 1978. On a measure of lack of fit in time series models. ***Journal of Biometrika***, 65 (2): 67-72.

Mackinnon, J. 1996. Numerical distribution functions for unit root and cointegration tests. ***Journal of Applied Econometrics***, 11 (6): 601-618.

Makridakis, S., & Hibon, M. 2000. The M3 competition: Results, conclusions and implications. ***International Journal of Forecasting***, 16 (4): 451-476.

McNees, S. S. 1979. The forecasting record for the 1970's. ***New England Economic Review***, Sep/Oct: 33-53.

Seabrooke, W., Hui, E. C. M., Lam, W. H. K., & Wong, G. K. C. 2003. Forecasting cargo growth and regional role of the port of Hong Kong. ***Cities***, 20 (1): 51-64.

臺灣大學學術期刊資料庫

附錄

類神經網路訓練參數設定

epochs 訓練最大循環次數：500

goal 性能目標：0

max_fail 最大驗證數據失敗次數：5

mem_reduc 降低記憶體需求量之係數：1

min_grad 最小性能梯度：1e-010

mu 動量初始值：0.001

mu_dec 動量減少係數：0.1

mu_inc 動量增加係數：10

mu_max 動量最大值：10000000000

show 每隔多少訓練循環數目就顯示：25

time 最大的訓練所需時間：Inf

臺灣大學學術期刊資料庫