


東 海 大 學

工業工程與經營資訊研究所

碩士論文

澎湖國家風景區遊客量預測模式之研究



研 究 生：蔡卓翰
指 導 教 授：洪堯勳 副教授
 王文清 副教授

中 華 民 國 九 十 九 年 六 月

The Study on Visitor's Forecasting Model of Penghu National Scenic Area

By
Jwo-Han Tsai

Advisor: Prof. Jau-Shin Hon
Prof. Wen-Ching Wang

A Thesis
Submitted to the Institute of Industrial Engineering and
Enterprise Information at Tunghai University
in Partial Fulfillment of the Requirements
for the Degree of Master of Science
in
Industrial Engineering and Enterprise Information

July 2010
Taichung, Taiwan, Republic of China

澎湖國家風景區遊客量預測模式之研究

學生：蔡卓翰

指導教授：洪堯勳教授

王文清教授

東海大學工業工程與經營資訊研究所

摘要

國家風景區設置目的為提供遊客自然觀光資源，達到休閒遊憩的功能。澎湖國家風景區近幾年來由於大量遊客的湧入，導致澎湖的觀光遊憩資源逐漸消失，加上澎湖遊客量呈強烈的季節性變化，使得周邊相關產業規劃不及應付。因此建立一遊客量預測模式，以因應外在環境之變化及本身遊憩資源的供給與分配，對於國家風景區的經營管理，有其絕對的重要性。

過去學者研究顯示以量化研究來進行需求預測會有較佳的結果，且在預測的領域之中，部份研究採取方法之間的比較，如此有可能遺漏重要之訊息。因此本研究擬採用一結合時間序列與倒傳遞類神經網路(ARIMA-BPN)之預測模式，期望將資料線性與非線性之關係同時納入考慮，對遊客量進行量化預測之研究。

本研究先以時間序列 ARIMA 建立預測模型，再將其預測值之誤差投入倒傳遞類神經網路(BPN)之中。另外加入大陸來台觀光人數、景氣領先指標、消費者物價指數、失業率、美元兌台幣匯率及澎湖地區之氣溫、雨量、相對溼度、降水日數和日照時數等十項投入變數當作參考指標，並利用迴歸分析(最佳子集合迴歸)進行變數的篩選，於類神經網路中進行學習預測，來對時間序列模型所產生的預測值進行修正。

實證分析結果顯示，篩選變數後之 ARIMA-BPN 模型的預測績效最佳，單一 ARIMA 模型次之，而使用未篩選變數之 ARIMA-BPN 模型預測績效最差。因此，本研究所提出之 ARIMA-BPN 結合模式證實若將資料線性與非線性關係同時納入考慮，並利用迴歸分析篩選影響變數，確實能達到預測績效提昇的結果；但若未進行變數篩選的動作，則可能造成預測準確度較為不佳。本研究之結果期能提供澎湖及其他國家風景區於未來的管理與規劃方面作為參考指標。

關鍵字詞：國家風景區、時間序列、迴歸分析、倒傳遞類神經網路

The Study on Visitor's Forecasting Model of Penghu National Scenic Area

Student: Jwo-Han Tsai

Advisor: Prof. Jau-Shin Hon
Prof. Wen-Ching Wang

Department of Industrial Engineering and Enterprise Information
Tunghai University

Abstract

The purpose of setting up National Scenic Area is to provide visitors with natural tourism resources in order to enhance recreational functions. In recent years the influx of large number of tourists has caused Penghu's tourism resources to disappear gradually. Moreover, Penghu tourists showed a strong seasonal variation so that it is hard to coordinate the peripheral industries to support the needs. Therefore, to establish a predictive model of tourists in response to the external environment variation and the recreational resources supply and distribution is absolutely important for the sound management of National Scenic Area.

the scholars' study showed that if using the quantitative method to predict it will draw better result. In Addition, some studies make comparison between multiple measures while lack of thoroughness in the realm of prediction, therefore there may be missing of important information. To cope with the above deficiency, this study uses a combination of Time Series and Back- Propagation Neural Network (ARIMA-BPN) prediction model; expect to bring both linear and nonlinear relationship of data into account to do the quantitative prediction of the tourists study.

First, use Time Series ARIMA to establishment the prediction model, then input the error of predicted value to Back-Propagation Neural Network (BPN). Besides, we input ten factors as the reference indexes. Then use Regression Analysis (Best Subset Regression) for variable screening and initiate prediction learning in neural network. This process can revise the predicted value generated by Time Series model to get better result.

Empirical results show that, the prediction performance of ARIMA-BPN after variable screening is the best, simple ARIMA model is the second, and the prediction performance of ARIMA-BPN without variable screening is the worst. Therefore, The ARIMA-BPN combination model which proposed by this study confirms that if bringing the linear and nonlinear relationships of data into account simultaneously, then using Regression Analysis to screen variables, can indeed enhance the forecast performance ; but if we don't proceed with the variable screening, it may result in relatively poor prediction accuracy. We expect the study findings will provide information for the Penghu and the other National Scenic Areas as a reference of management and planning in the future.

**Keywords: National Scenic Area · Time Series · Regression Analysis ·
Back-Propagation Neural Network**

致謝

一轉眼，兩年的時光就這樣匆匆流逝。兩年前，為了自己的夢想，亦然決定跨系轉來工工就讀，如今終於拿到了”夢寐以求”的碩士學位，證明兩年來努力沒有白費，也總算是達成了人生一個重要的里程碑。

研究所兩年期間，由衷感謝指導教授洪堯勳博士及王文清教授的悉心指導，並在研究領域上給予發揮自由與支持，使得學生論文得以順利完成。並感謝蕭子誼教授、陳建良教授與蕭志同教授，百忙之中協助學生完成論文口試，並給予建議與指正，使論文得以趨於完備。另外，亦感謝工工系老師們的認真教學，讓我在研究所兩年期間，於工工領域專業知識技術的學習及思考邏輯能力方面，有極大的收穫。

研究所兩年的時光，除了研究及修課外，最難得的是能認識一群共同奮鬥的好朋友。穎志、明修是我的好麻吉，這兩年來能跟你們一起”努力打拼”是我的榮幸，也謝謝同研究室的宛蓉。秉欣、宣傑總是和我們無話不談；宏鈞親和力十足，讓人沒有距離感；還有神經跟水管一樣大條的彥彰哥，天天都讓大家哭笑不得。另外，也要感謝學弟妹怡嬪、靖儀、柏祥和秉群，因為你們的加入，為研究室增添了無數的歡笑。雖然跟你們相處時間只有短短一年，但我一定會再回來看你們的！

還要感謝統計系的俞一唐老師，謝謝你兩年來對我的照顧及幫助，你永遠是我心目中的好老師及好朋友。另外，也要感謝一群”不正經”的大學同學，雖然大家都愛互相調侃，但我相信這才是我們關心彼此的方式。未來大家不管走甚麼樣的路，都要互相扶持，互相加油！

最後要感謝我的父母和哥哥，辛辛苦苦將我撫養長大，在我求學這條路上，花費了無數的時間與金錢，只為了讓我達成人生的目標。沒有你們的用心栽培，就沒有今天的我。你們永遠是我一生的驕傲！

卓翰 謹誌於

東海大學工業工程與經營資訊研究所

經濟性決策分析研究室

民國九十九年七月

目錄

摘要.....	I
致謝.....	III
目錄.....	IV
圖目錄.....	VI
表目錄.....	VII
第一章 緒論.....	1
1.1 研究背景與動機.....	1
1.2 研究目的.....	3
1.3 研究架構與流程.....	3
1.4 研究限制.....	5
第二章 文獻探討.....	6
2.1 國家風景區.....	6
2.1.1 澎湖國家風景區概況.....	6
2.2 影響遊客量之因素探討.....	7
2.3 遊客量預測.....	9
2.3.1 時間序列預測相關文獻探討.....	12
2.3.2 修正性預測方法.....	13
2.3.3 小結.....	15
第三章 研究方法.....	17
3.1 研究操作概念.....	17
3.2 研究樣本期間與資料蒐集.....	17
3.2.1 資料蒐集.....	17
3.3 離群值的偵測與處理.....	18
3.3.1 離群值的影響.....	18
3.3.2 離群值的偵測.....	18
3.4 時間序列分析.....	19
3.4.1 定態序列.....	19
3.4.2 單根檢定.....	19
3.4.3 自我迴歸整合移動平均(ARIMA)模型.....	20
3.5 迴歸分析.....	26
3.5.1 迴歸分析概念.....	26
3.5.2 最佳子集合迴歸.....	26
3.6 類神經網路.....	28
3.6.1 類神經網路簡介.....	28
3.6.2 類神經網路原理及架構.....	28
3.6.3 類神經網路之運作.....	31
3.6.4 倒傳遞類神經網路.....	32
3.7 預測績效之評估指標.....	38

第四章 實證分析.....	40
4.1 資料分析與處理.....	40
4.1.1 原始資料分析.....	40
4.1.2 離群值的偵測與處理.....	41
4.2 時間序列模型建構與分析.....	42
4.3 迴歸分析.....	46
4.4 倒傳遞類神經模型建構與分析.....	47
4.5 模型之驗證與比較.....	51
4.6 預測模型於遊憩區域之應用.....	52
第五章 結論與建議.....	54
5.1 研究結論.....	54
5.2 未來研究建議.....	55
參考文獻.....	56

圖目錄

圖 1.1 澎湖國家風景區 2001~2009 年之月平均遊客人數	2
圖 1.2 研究流程圖	4
圖 2.1 澎湖國家風景區遊憩區域圖	7
圖 2.2 2001~2009 大陸來台觀光人數序列圖	9
圖 3.1 本研究操作概念圖	17
圖 3.2 ARIMA 模型操作流程圖	25
圖 3.3 人工神經元模型	29
圖 3.4 倒傳遞類神經網路架構	32
圖 4.1 澎湖國家風景區遊客量序列圖	41
圖 4.2 澎湖國家風景區遊客量盒形圖	41
圖 4.3 取自然對數及一階季節差分後之序列圖	43
圖 4.4 殘差自我相關圖	45
圖 4.5 殘差常態性檢驗圖	45
圖 4.6 最佳子集合迴歸變數組合結果	46
圖 4.7 倒傳遞類神經網路運作流程圖	47
圖 4.8 倒傳遞類神經網路架構圖	49
圖 4.9 倒傳遞類神經網路訓練結果圖	50
圖 4.10 不同模型之預測值序列比較圖	52
圖 4.11 馬公本島遊憩系統最佳子集合迴歸變數組合結果	53
圖 4.12 馬公本島遊憩系統之不同模型預測值序列比較圖	53

表目錄

表 2.1 時間序列和類神經網路預測模型的比較.....	15
表 3.1 類神經網路模式分類表.....	31
表 3.2 MAPE 預測能力等級表.....	39
表 4.1 原始時間序列單根檢定表.....	42
表 4.2 經資料轉換後之時間序列單根檢定表.....	43
表 4.3 季節性 ARIMA 模式之參數估計試誤結果.....	44
表 4.4 殘差自我相關性及常態分配檢定結果.....	44
表 4.5 候選模型及評估指標.....	45
表 4.6 類神經網路訓練參數設定表.....	49
表 4.7 不同預測方法之績效比較表.....	51
表 4.8 馬公本島遊憩系統候選模型及評估指標.....	52
表 4.9 馬公本島遊憩系統之不同預測方法之績效比較表.....	53

第一章 緒論

1.1 研究背景與動機

世界各國已普遍將無煙囪的「觀光產業」與科技產業，共同視為二十一世紀的明星產業。台灣地區近年來隨著經濟與科技的快速發展，國民生活水準提高，國人對戶外休閒活動的需求與消費能力快速成長，加上政府不斷推行觀光及休閒政策，鼓勵民眾走出戶外，故利用週休二日及國定假日從事國內外旅遊活動，早已成為國人日常生活中的常態行為。

台灣的地理環境特殊，擁有豐富的自然資源及多樣化的人文景觀，加上人民熱情友善，社會治安良好等條件，造就了我國發展觀光事業的雄厚潛力。政府於1984年起，陸續成立東北角暨宜蘭海岸、東部海岸、澎湖、花東縱谷、大鵬灣、馬祖、日月潭、參山、阿里山、茂林、北海岸及觀音山、雲嘉南濱海、西拉雅等13座國家風景區。「國家風景區」為「國家級風景特定區」的簡稱，有別於國家公園設立之主要目的為保護世界級或國家級之珍貴自然資源或文化資產，國家風景區設置目的是為了提供遊客自然觀光資源，達到休閒遊憩的功能【17】。在提供休閒遊憩功能上，如何保存相關的生態觀光資源，維持自然資源的永續發展，將是國家風景區管理的首要目標。

澎湖群島星羅棋布於台灣海峽中，地勢平坦，為台灣地區極具特色之島嶼景觀，無論在歷史景觀或人文歷史資源上皆蘊藏無窮之寶藏，故政府於民國79年將澎湖地區劃設為澎湖國家風景特定區，於民國84年成立澎湖國家風景區管理處。澎湖素以乾淨不受汙染之海洋環境為主要遊憩活動訴求，但近幾年來大量遊客的湧入，破壞了原始的生態，且影響當地居民的生活，若不再重視此問題，將導致澎湖的觀光遊憩資源將逐漸消失，更可能造成業者及遊客的離開；另外，由於澎湖觀光深受氣候影響，故遊客量呈現強烈的季節性變化，如圖(1.1)所示，顯示旅遊旺季主要分佈於4月至9月間，此時澎湖觀光業者呈現來者不拒的狀態，為了搶生意紛紛進行削價競爭，旅遊品質粗糙，亦破壞整個觀光市場機制【2】。

陳淑女【18】提到當旺季遊客量的成長超過了周邊相關產業規劃的規模時，若無未來遊客數量作為基礎進行規劃考量，勢必會使周邊產業不及應付，造成服務品質下降。鑑於遊客量之掌握有助於觀光目的地整體經營管

理計畫，提高遊憩體驗品質【12】，因此，建立一遊客預測模式，以因應外在環境之變化及本身遊憩資源的供給與分配，對於國家風景區的經營管理，有其絕對的重要性。




圖 1.1 澎湖國家風景區 2001~2009 年之月平均遊客人數

(資料來源:本研究整理)

一般遊客量預測方法，通常可分為定性方法與定量方法兩種。定性預測方法主要是用於沒有過去歷史資料，必須根據主觀判定或預測者的經驗來決定，如德爾菲法(專家意見法);定量預測方法則是藉由使用歷史數據或因果變數來建立預測模式的數學模型，其又可分為線性模型與非線性模型。在線性模型中，以迴歸分析與時間序列模型最具代表性，且頗具預測成效。其中時間序列模型採用過去資料來構建預測模式，可描述歷史數據的線性關係，對中長期的預測有很大的效果，且其對於週期性、季節性及循環性之趨勢易於掌握【7】。然而線性模型對資料特性仍有許多限制，且面對許多複雜問題時，預測能力有所不足。最主要的問題是，線性模型對具有「非線性」關係及變數之間有交互作用關係的情況時較難適用【24】。因此，許多研究改用非線性模型來進行研究，期能改善預測績效。而 White【50】指出，類神經網路在解決非線性關係問題的能力，通常較傳統統計模型為佳。

由於定性預測方法易受主觀因素的影響，且並非由過去歷史資料分析而得，故難以反應實際遊客人數的變動趨勢。又以往對於國家風景區遊客人數的預測研究較少，部份研究以定性之專家意見法或單純以過去歷史資料進行遊客人數的推估，鮮少將影響遊客人數之變數納入考量。另外，Bates

& Granger【32】認為，傳統之預測方式多採用方法之間的比較，如此有可能會遺漏某些重要的訊息。綜合以上問題，本研究擬使用過去的歷史資料，並蒐尋影響遊客量之變數，建構一結合時間序列與倒傳遞類神經網路之量化預測模型，期望能提供給相關單位做為經營管理的參考基礎。

1.2 研究目的

具體而言，由於量化預測方法可藉由歷史數據，並使用數學方式進行預測。張盛鴻等【20】亦指出，數學性的技術通常能比專家意見的預測有較好結果。故本研究擬採用量化預測模式，結合一時間序列與倒傳遞類神經網路的預測方法，以澎湖國家風景區為例，針對遊客量預測進行研究。

本研究之研究目的如下：

1. 蒐集澎湖國家風景區之遊客量資料及影響遊客量的變數，初步判斷遊客人數變化的趨勢，嘗試以時間序列(ARIMA)的量化方法建立線性預測模型，進行遊客量的預測。
2. 進一步針對預測值與實際值之差異，利用迴歸分析篩選出影響遊客量之顯著變數的最佳組合，以建立倒傳遞類神經網路(BPN)的非線性模型，進行誤差的修正。
3. 針對本研究所建構之預測模型(篩選變數後之 ARIMA-BPN 模型)，與單一時間序列 ARIMA 模型及未篩選變數之 ARIMA-BPN 模型進行預測準確度之績效比較，嘗試找出最適的預測模型。
4. 由本研究之實證結果，可提供澎湖及其他國家風景區管理單位作為經營決策與管理之參考依據。

1.3 研究架構與流程

本研究共分為五個章節，各章節內容如下：

第一章 緒論

說明研究背景及動機、研究目的、研究限制、研究架構與流程。

第二章 理論基礎與文獻探討

針對影響台灣國家風景區遊客量之因素的相關文獻進行整理與研究，並蒐集遊客量預測之相關文獻，進行本研究預測模式的探討與決定。

第三章 研究方法

定義本研究之研究範圍及資料來源，並針對本研究所建立之預測模型進行理論基礎的說明，並提出所建構之預測模型的績效評估準則。

第四章 實證結果與分析

針對本研究所建立之預測模型進行樣本內建模與樣本外驗證的步驟，並對不同預測模型進行預測績效的比較。

第五章 結論與建議

根據本研究的實證結果，提出本論文的研究發現，並對後續研究提出建議及方向。

本研究之流程如圖 1.2 所示：

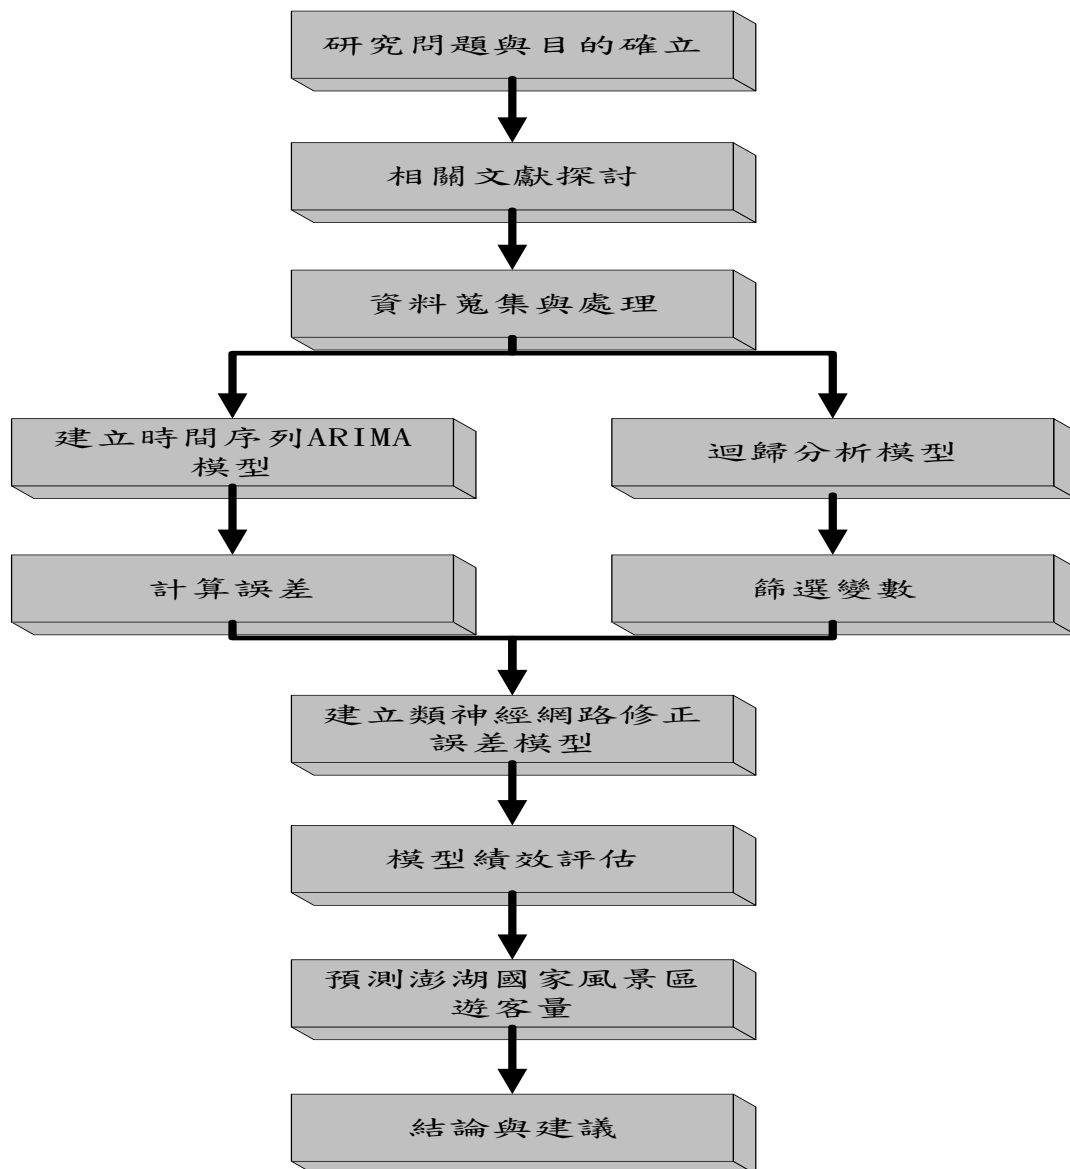


圖 1.2 研究流程圖(資料來源:本研究整理)

1.4 研究限制

1. 由於澎湖占地廣大並包含許多景點，無法精確地統計各景點的遊客人數並進行加總。故本研究所選取的資料來源，是由澎湖國家風景區管理處針對全風景區遊客人數進行概估而得。
2. 本研究於影響遊客量因素中，投入大陸來台觀光人數資料。由於此資料於政府全面開放大陸來台(2008年7月)前，遊客人數較少，無實際資料。故本研究於2008年7月前之大陸來台觀光人數資料，採交通部觀光局所提供之亞洲其他地區(不包含港澳、日本、韓國、印度、中東及東南亞地區)來台觀光人數代替。
3. 影響遊憩區遊客人數的因素很多，要完全掌握並加以探討十分困難。因此，本研究僅針對大環境之氣候、經濟及外在遊客因素，對澎湖風景區之遊客量進行修正，並無考慮其餘較細部的影響變數。

第二章 文獻探討

利用週休二日及國定假日從事國內外旅遊活動，早已成為國人日常生活中的常態行為。不同於國家公園設立的主要目的，是為了保護世界級或國家級之珍貴自然資源或文化資產，國家風景區設置的目的是為了提供民眾休閒遊憩的功能。澎湖國家風景區，無論在歷史景觀或人文歷史資源上，皆蘊藏無窮的寶藏。但近幾年來因大量遊客湧入，加上遊客量深受季節變化的影響，如未能確實預測前來觀光之遊客數量，將會對澎湖國家風景區相關管理單位，甚至當地居民及業者，造成某種程度的影響。

本章首先針對澎湖國家風景區進行概況了解，接著蒐集相關文獻，整合各學者對於影響遊客量之變數進行探討，提出本研究影響遊客量變數的選擇。再進一步利用相關文獻，探討不同預測方法於遊客量預測的應用，並探究本研究擬採用之預測模型的適用性，提出本研究預測模式之合理依據，以利進行後續實證分析。

2.1 國家風景區

「國家風景區」為「國家級風景特定區」的簡稱。目前已規劃完成的共有 13 座，隸屬交通部觀光局管轄，底下各設有風景區管理處經營管理之。國家風景區根據《發展觀光條例》第 11 條所劃設，其中第 18、19 條也指出具有大自然之優美景觀、生態、文化與人文觀光價值之地區，應規劃建設為觀光地區，禁止破壞相關的生態觀光資源，維持自然資源永續發展。台灣地區於 1984 年起，相繼成立東北角暨宜蘭海岸、東部海岸、澎湖、花東縱谷、大鵬灣、馬祖、日月潭、參山、阿里山、茂林、北海岸及觀音山、雲嘉南濱海、西拉雅等 13 座國家風景區。

2.1.1 澎湖國家風景區概況

澎湖群島散布於台灣海峽東南方，大約在台灣嘉義縣與金門縣之間，東對台灣、西面福建，北上可連絡馬祖列島、大陳島、舟山群島，南下則可以連接東沙群島、南沙群島而通達南洋各國，為台灣海峽之咽喉，據大陸與台灣之中站，自古即為東亞沿海及太平洋遠洋航線的要衝，地理位置十分重要。澎湖群島東西寬約 40 公里，南北長約 60 公里，係由近百個大小不等的島嶼組成，總面積約 127 平方公里，其中以澎湖本島最大(含馬公市及湖西鄉)，其次依序為西嶼、白沙、望安及七美。澎湖國家風景區依遊

憩區域之不同，由北至南依序可將其分為北海遊憩系統、馬公本島遊憩系統及南海遊憩系統等三大部份，如圖 2.1 所示。

民國七十九年元月，交通部觀光局訂定澎湖地區為國家級風景特定區。並於八十四年，正式成立「交通部觀光局澎湖國家風景區管理處」；另外設有貓嶼海鳥保護區及望安綠蠵龜產卵棲地保護區等野生動物保護區，與玄武岩自然保留區，目的是希望能有效利用資源，促使澎湖經濟的發展。澎湖國家風景區，具有特殊豐富的地質地形及海洋景觀，加上開發悠久的人文古蹟，使澎湖兼具自然和人文的觀光資源。近年來，澎湖縣政府積極發展觀光，於每年四月至九月舉辦海上花火節、菊島海鮮節、澎湖國際藝術沙灘節、綠蠵龜生態研習、萬龜祈福等活動，更讓澎湖的觀光價值提升不少。

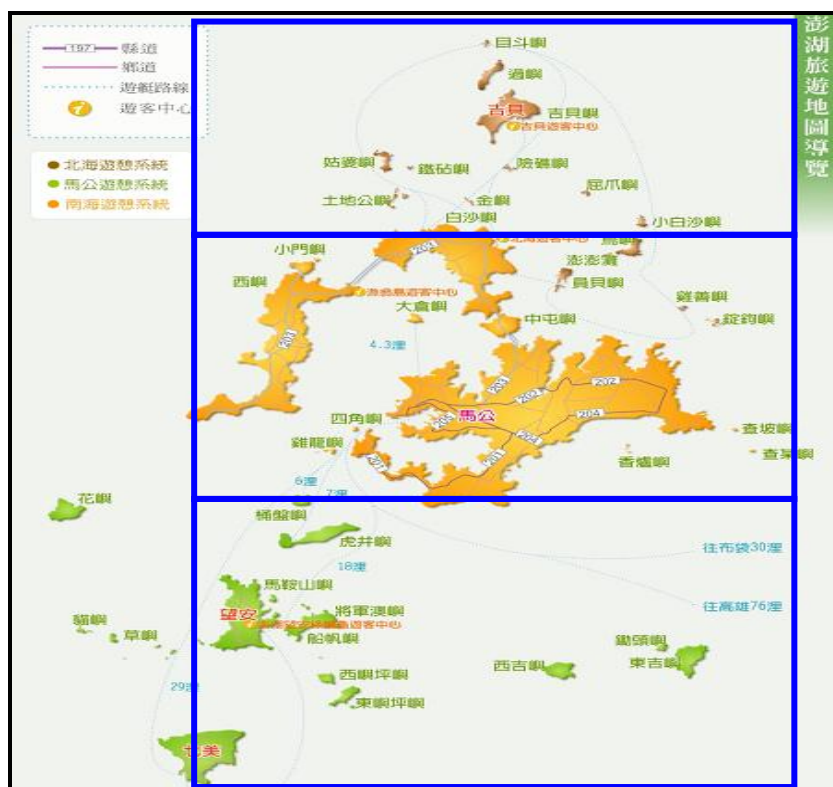


圖 2.1 澎湖國家風景區遊憩區域圖

(資料來源:【51】)

2.2 影響遊客量之因素探討

Blackwell, Miniard & Engel【33】指出，影響消費者決策之因素約略分為個人差異、環境影響因素和心理程序三大類。這三大類的因素對於消費行為的需求確認、搜尋、購前方案評估、購買和消費等階段，都會造成影

響。旅遊選擇行為之思考決策模式與消費行為相似，亦可被視為是消費行為的一種。惟其異於一般商品消費行為者，是除了前述三大類決策因素外，尚必需考量旅遊目的地環境屬性的影響【3】。旅遊目的地的環境屬性為遊客進行旅遊決策時所會考慮的因子之一。對於旅遊目的地環境屬性的分類，有許多學者提出其研究結果。Hu and Ritchie【39】認為，旅遊環境包含一般屬性(天氣與自然景觀)與體驗屬性(社會與文化特質)；高珮詩【15】將環境心理學及壓力調適理論結合，以瞭解天氣對森林遊憩活動之影響。他將天氣視為壓力來源，指出天氣可作為遊樂區的特色，亦是影響遊客量及管理單位休園與否的考量因素。

除此之外，影響遊客進行旅遊選擇之重要屬性尚有很多。林晏州【11】藉由遊客抽樣調查結果，分析並整理影響遊客選擇遊憩區之重要因素，可分為旅遊費用、遊憩服務設施、遊憩活動機會與自然及人文景觀資源；林倉龍【10】利用迴歸分析方法，提出國內生產毛額(GDP)及消費者物價指數(CPI)對遊客參訪國家風景區有顯著的影響力；聶建中、周明智【29】亦指出總體環境中，經濟因素以代表景氣成長的國內生產毛額、物價指數及匯率三項總體因素影響來台旅客最為顯著。

綜合上述的眾多研究可知，影響遊客量之因素很多，要完全掌握並加以探討十分困難。遊客會在外部及內部因素影響下，進行旅遊活動之評估、考量與選擇【6】。將其歸納整合的結果，基於經濟因素及氣候因素，對遊客人數多寡有一定的影響力。故本研究擬選擇國內生產毛額(GDP)、消費者物價指數(CPI)、失業率及美元兌台幣匯率等，作為經濟因素；澎湖地區之氣溫、雨量、相對濕度、降水日數及日照時數等，作為氣候因素，將其納入投入變數之中。另外，根據第一銀行的解釋，國內生產毛額 GDP 可以反映一國經濟總產出規模的變化，是各國經濟景氣的具體象徵。而利秀蘭、陳惠薇【1】利用 Granger 因果關係檢定發現，景氣領先指標與國內生產毛額 GDP 呈現高度線性相關。因此，基於資料齊一性之考量，本研究將採用代表景氣象徵之景氣領先指標，來代替國內生產毛額 GDP，作為影響遊客量之投入變數。

另外，政府於民國 96 年 4 月 1 日，開放福建地區大陸人士可經由金馬小三通至澎湖進行觀光旅遊活動；民國 97 年 7 月 4 日，更實施兩岸直航包機政策，全面開放大陸旅客來台，導致大陸來台觀光旅客飆升(圖 2.2)。故

上述兩項政策對於澎湖觀光旅遊模式及當地澎湖觀光產業的影響，將是一項需要探討的指標【2】。因此，本研究除前述選擇之經濟因素及氣候因素作為投入變數外，亦加上大陸來台觀光人數，作為影響遊客量之因素，並利用迴歸分析具有解釋自變數及應變數線性相關程度之能力，對本研究所選擇之投入變數進行篩選，期能找出影響澎湖國家風景區遊客量之最佳變數組合，提升預測模式的績效。




圖 2.2 2001~2009 大陸來台觀光人數序列圖
(資料來源:本研究整理)

2.3 遊客量預測

遊客量預測相關文獻中，一般分為定性(Qualitative)預測方法和定量(Quantitative)預測方法，張盛鴻等【20】認為，定性預測方法主要用於沒有過去歷史資料，使用非數學的方式，依賴判斷、直覺及主觀性的評價，如德爾菲法(專家意見法)。定量預測方法則偏重於數學模式的應用，依據過去的歷史資料或因果變數來建立預測模式，以所得之客觀數字作為預測資訊的來源依據【9】。

風景區遊客量之預測是其規劃開發的重要依據。因此，遊客量的預測是整個觀光區各類需求預測中最重要的一環。張盛鴻等【20】指出，數學性的技術通常能較專家修正的預測有比較好的結果。而 James and Jens【40】也指出需求預測的目標通常是較無結構性、以及需求不確定性高，屬於高度複雜性的市場，定性的預測通常較缺乏數字化的依據，容易導致預測不準確。故本研究針對量化預測進行文獻探討。一般來說，遊客量的推估可分為以下幾種【5】：

1. 時間序列模型

時間序列分析模型是藉由過去數年遊客量之變動趨勢，並假設此變動趨勢於未來數年之內不致改變，而應用過去之變動趨勢延伸至預測未來的方法，亦即未來遊客量 Y 是時間 t 的函數：

$$Y=f(t) \quad (2.3.1)$$

此模式適合預測年度不長及環境條件無變化者。改進的方法為差分(difference)、移動平均法(Moving Average Method)及落後(lag)等等。這些方法可以消除數列的長期趨勢、循環變動、季節變動及不規則變動。由於數列處理的結果，可使數列中過大及過小的數字相互補償，因而得到較和緩而平滑的曲線。此模式利用遊憩區歷年來的遊客量資料，就其時間數列的趨勢，分別選定最佳的迴歸模式，繼而估算出各觀光區常態成長下之年遊客人數，其數學公式如下：

$$Y= T * C * S * I \quad (2.3.2)$$

其中 Y 指遊客量估計值；T 代表長期趨勢(Long-Run Trend)，由於數列往往會隨時間呈現有規律的遞增或遞減的長期動向。這種動向即所謂的長期趨勢；C 代表循環變動(Cyclical Variation)，指數列在趨勢線附近的週期性變動；S 指季節變動(Seasonal Variation)，指的是數列每隔特定時間會定期循環；I 指不規則變動(Irregular Variation)，指的是數列隨機或偶發性的變動，也稱為白色干擾(White noise)。

2. 重力模型(Gravity Model)

本模式是利用交通運輸預測模式的觀念之重力模式運用，主要是針對目的地與出發地之距離，以求其關係或頻度。

$$V_{ij} = \alpha * D_{ij}^{\beta} * P_i \quad (2.3.3)$$

或

$$V_{ij} = \alpha * D_{ij}^{\beta} * V_i \quad (2.3.4)$$

其中， V_{ij} 指出發地 i 目的地 j 之遊客量； D_{ij} 指出發地 i 至目的地 j 之距離； P_i 指出發地 i 的人口數； V_i 指出發地 i 的總發生量； α 及 β 為常數。由於此模式的資料取得不易且係數求得過程複雜，又未考慮設施容量的限制，故一般應用時，常加以簡化或另以其它方式輔助之。

3. 阻礙機會模型(Intervening Opportunity Model)

此模式利用統計學上機率的觀念以預測遊客量。其公式如下：

$$\Pr(S_j) = e^{-LD} - e^{-L(D+D_j)}$$

$$T_{ij} = A_i \Pr(S_j) \quad (2.3.5)$$

其中， T_{ij} 指*i*與*j*區間的旅遊次數； A_i 為至*i*區的總旅遊次數； $\Pr(S_j)$ 指由地點*i*至*j*之旅遊機率； L 為常數； D 指到達*j*區以外地區之遊客量； D_j 指到達*j*區之旅次。式 2.3.5 說明了，當旅遊機會增加時，由地點*i*至*j*的旅遊次數亦將隨之改變。

4. 多元迴歸分析模式(Multiple Regression Analysis Model)

本模式是將遊客量(Y)之影響因素(X_i)列入考慮。其模式為：

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (2.3.6)$$

其中 β_i 為常數， $i=1,2,\dots,n$ 。本法利用迴歸找出自變數與應變數的關係。主要是建立在統計性的分析，故每種關係都應加以合理的檢定。此模式由於考慮因素可配合資料取得而做調整，較符合預測所需。

5. 總量比例分配法

總量比例分配法的概念，是依據全國遊客量之預測值，按一定比例分配至各縣市或遊憩區，亦或依據全國性各種遊憩活動參與量之預測值，按比例分配至各種遊憩活動，再分配至各遊憩區。應用總量分配法時，假設遊憩活動或遊憩區之分配比例不變，其隱含假設即在未來預測期間，國民對於各種遊憩活動之相對偏好程度不變，或某縣市對遊憩區開發與品質改善程度與其他縣市相當，故其應用上限制極大，對各影響因子應力求客觀性。

6. 飽和承載量法

此模式適用評定旅遊區內之各項遊憩活動，在其資料特性下之最適遊憩承載量(Optimal-Recreational Carrying Capacity)為預測之最大遊憩量。其方法為假設某一種活動其全年遊憩承載量為瞬間承載量(Maximum Instant Carrying Capacity)(最適承載量與旅遊區各種活動的面積長度的相乘積)與每日週轉率(Turnover Rate)及全年適合該項活動的旅遊日數的相乘積。其運算過程如下：

$$\text{MIC} = \text{ORCC} * A \text{ (or L)} \quad (2.3.7)$$

$$\text{MDC} = \text{MIC} * \text{TR} \quad (2.3.8)$$

$$\text{MYC} = \text{MDC} * N \quad (2.3.9)$$

$$Y = \sum MYC \quad (2.3.10)$$

其中，MIC 指瞬間承載量；MDC 指最大日承載量；MYC 指最大年承載量；ORCC 指最適承載量；A or L 指面積或長度；TR 指每日週轉率；N 指全年適合該遊憩活動日數；Y 指旅遊區全年各項遊憩活動之總承載量。此模式為確保遊憩經驗品質與環境品質的規劃方法，而其最大任務則為決定最適承載量。

由上可知，時間序列不但能經由過去時間的數值來預測未來數值可能的變化，且對於週期性、季節性及循環性之趨勢易於掌握。因此本研究將以時間序列模式作為澎湖國家風景區遊客量的預測模式。

2.3.1 時間序列預測相關文獻探討

應用時間序列於遊客量預測方面，已有多位學者驗證其預測之有效性，且較其它預測模式優良。以下將針對時間序列於遊客量預測之相關文獻進行探討。

Sheldon and Var【48】曾針對過去有關觀光預測的研究作回顧，文中將過去 20 年間有關觀光預測的實證方法，分成時間數列模型、計量經濟模型和專家意見法等三大類。每種類型在實證上所花費的成本、資料蒐集與方法難易度各有不同。比較後發現，時間數列法的成本較低；重力模型較適合國際觀光客流向分析；專家意見法則適用於資料較難取得的情況。

張翊峰等【19】利用時間序列 ARIMA 模式，推估寶來、不老溫泉區未來遊客的成長量，再配合此區的生態承載量(Ecological Capacity)，推估未來之最適遊客人數。研究結果顯示，寶來、不老溫泉的遊客量呈現正向成長的趨勢。

施瑞賢【13】針對來華觀光旅客人數進行需求預測。他利用 Box-Jenkins 提出的四個步驟建立來華觀光旅客人數之 ARIMA 模式，並以香港、日本、亞洲、美國及歐洲等地區為對象進行實證研究，以 MAPE 及 RMSPE 評估模型的預測能力。研究結果發現其績效指標值均良好，顯示 ARIMA 模式是適合預測來華觀光旅客人數之需求預測模型。

塗三賢、吳萬益、林俊成、任憶安【14】以 ARIMA 模式建立森林遊樂區遊客人數與營收之預測模型。並針對林務局所屬的十六處森林遊樂區以自 1990 年至 1998 年間的資料，經由 ARIMA 模型之實證結果顯示，

有十一處森林遊樂區其 ARIMA 模型具有季節性的因素，只有東眼山、雙流與大雪山等三處森林遊樂區，未出現季節性型態。

Chu【34】探討如何建立季節性及非季節性的模式。並以新加坡在 1990 年至 1997 年之遊客量為實驗資料，檢測所設定的模式。Chu 比較不同模式之預測準確性，並以 MAPE 為衡量準則；說明在(p,d,q)參數選擇正確的前提下，結論為 ARIMA 有相對顯著較小的 MAPE。

鄭天澤和李旭煌【28】的研究，利用 1980 至 1992 年台灣地區出國人數資料做分析。研究結果顯示，台灣地區出國總體市場方面，單變量時間數列模式、轉移函數模式之準確性較高。兩種的模式中，又以單變量時間序列模式的預測能力較佳。個別市場包括日本、美國、香港、韓國及泰國方面，則有不同的較佳預測模式。

吳佳穎【7】以民國 89 年 1 月至民國 94 年 12 月之台灣各國家公園遊客人數資料，進行遊客量預測模式之研究。實證結果顯示，在墾丁、陽明山、玉山、雪霸等四座國家公園，以 ARIMA 預測準確度較高，而太魯閣國家公園與金門國家公園則以迴歸方式決定權重的組合預測模式較為優良；太魯閣國家公園為 ARIMA 與 Winters 指數平滑法組合，而金門國家公園則是 ARIMA 與 Holt 指數平滑法的組合。

由於時間序列模式所需的成本較低，且具有預測趨勢性，並可掌握季節性的影響。許多學者亦指出，時間序列為預測遊客量之合適模型，並於多數情況下較其他預測模式優良。因此，本研究擬採時間序列模型進行澎湖國家風景區遊客量的預測。

2.3.2 修正性預測方法

類神經網路是指模仿生物神經網路的資訊處理系統。它使用大量人工神經元，以仿效生物神經網路的運作方式，透過不斷學習與修正進行預測，並以不同之演算法來進行數據的推演。其特性為非線性的學習能力，能以簡單的鏈結值及轉換函數，描述複雜與非線性的資料集合。應用其功能，已有多位學者驗證類神經網路在遊客量的預測上的適合性及有效性。以下針對類神經網路應用於遊客量預測之相關文獻進行探討。

Cho【49】之研究利用指數平滑法、ARIMA 及類神經網路，預測外國旅客至香港觀光的成長趨勢。本研究預測國家觀光客來自美國、英國、新加坡、台灣、韓國及日本等六國。結果顯示，此六國家預測除了英國外，

都以類神經網路模式的預測最佳，英國則以指數平滑預測較佳。

李飛、白豔萍【4】採用倒傳遞類神經模型，對山東省國內遊客量進行預測。文中利用實際數據進行模擬，並將模擬結果與採用相同數據的灰色系統模型、多元迴歸模型及指數平滑法的模擬結果進行比較。實證結果發現，以倒傳遞類神經網路的模擬結果與實際情況最為逼近。

Jiang and Lee【41】針對來台的美國觀光客人數，使用以倒傳遞學習演算法為基礎的類神經網路建構預測模式。研究發現，其預測結果可以達到要求的準確度。因此可証實倒傳遞類神經網路具有良好的預測能力。

類神經網路的最大特性是其具有適應性學習能力。多位學者亦驗證出類神經網路的學習能力之有效性。統合羅華強【30】及張斐章、張麗秋【21】的觀點，認為類神經網路具有以下優於統計經驗模式的特性及能力，概述如下：

1.適應性學習：

每種類型的類神經網路都有特定的學習演算法。經由演算法可以調整節點與節點之間的連接權重值；透過不斷地調整權重值，直到得到正確的輸入-輸出模式。

2.回想過程：

當類神經網路接受到一個輸入刺激，進而依據網路架構產生一個輸出值時，我們稱這一過程為回想過程。在前饋式網路中，回想過程為一對一映射方式，得到一個輸入刺激則對應到一個輸出。而在回饋式網路中，前期輸入刺激會反覆的回饋，因此輸入和輸出的關係不斷被修正與調整，故為一動態系統，常用於描述非線性動態系統的行為。

3.過濾能力：

在類神經網路中，某個輸入與某個輸出之關係，並非直接由網路中某個節點所單獨負責。每一個節點只會映射出輸入-輸出模式的一個微特徵(Micro Feature)，意指每一個節點只會對模型造成輕微地影響。當網路中所有的微特徵組合在一起時，才能夠映射出完整的輸入-輸出模式。因此，當某一節點所輸入要處理的訊號，具有雜訊或處理的數據不完整時，此一輸入對網路所造成的影響，將不會有想像的那麼嚴重。

本研究擬將影響澎湖國家風景區遊客量之因素，作為類神經網路之投

入變數，期藉由類神經網路具有適應性學習及解釋變數間非線性關係之優越能力，對時間序列模型的預測誤差進行預測，以達到修正誤差的功能。

以下本研究針對時間序列模型及類神經網路模型兩種方法之內涵、優缺點及限制，整理如下表 2.1 所示：

表 2.1 時間序列和類神經網路預測模型的比較

預測方法	內涵	優點	缺點與限制	相關文獻
時間序列	採用過去的資料來構建預測模式，時間數列分析對中長期預測仍有很大的效果。	1.對於週期性、季節性及循環性之趨勢易於掌握。 2.純粹以變數歷史數據做為預測基礎，資料收集容易，成本花費低。	1.模式選擇需高度技巧與經驗。 2.缺乏經濟理論基礎，造成模式解釋不易。 3.解釋模型常假設為線性關係，對於非線性關係不易掌握。	【14】【16】 【18】【28】 【48】
類神經網路	使用大量人工神經元來仿效生物神經網路運作方式，透過不斷學習與修正而進行預測。	1.輸入與輸出變數之間的關係，事前無需任何假設。 2.以簡單的網路權數描述複雜的數據集合。 3.可適用於任意型態的輸出輸入對應關係。	1.無法保證可找到全面誤差的最小點。 2.最佳隱藏層數目與神經元數目無規則可循。 3.網路結構大時學習速率緩慢。 4.模型本身不具有因果的解釋能力。	【24】【31】 【49】

(資料來源:本研究整理)

2.3.3 小結

傳統的預測通常將不同預測方法對相同的預測目標進行預測，並做方法間的比較，再取預測績效較佳者作為研究的預測模型，績效不佳者則捨

棄，然而 J. M. Bates 及 Granger C.W.J. 【32】認為，直接捨棄績效不好的模型，可能會造成將某些重要的影響變數排除的後果。因為預測績效不佳即有可能因為此模型包含顯著影響的變數，而造成預測績效不良。另外，雷可為、方田紅【25】亦說明旅遊市場往往受到多種因素的制約，因素之間呈現錯綜複雜的關係，其中包含線性及非線性的規律。如單純採用一種模型進行預測很難同時考慮線性與非線性的變化。因此，本研究擬根據所探討的預測模型，對於遊客量預測的適用性及預測績效的優良性，結合時間序列及類神經網路模型，將遊客量資料的線性和非線性之關係同時納入考慮，並利用迴歸分析具有解釋自變數及應變數線性相關程度的能力，進行影響遊客量變數的篩選，期望能將顯著的變數選入模型，達到預測績效的提升。

第三章 研究方法

本章針對本研究之研究設計與操作加以闡述。首先說明論文整體的研究流程及樣本資料蒐集，接著再針對本研究所使用的預測方法進一步解說，最後說明不同模型的預測績效衡量標準。

3.1 研究操作概念

本研究嘗試先以時間序列 ARIMA 模型，對澎湖國家風景區之遊客量進行預測，並擬進一步採用迴歸分析(最佳子集合(Best Subset)迴歸)篩選變數，將其投入倒傳遞類神經網路進行誤差的修正。本研究操作概念如圖 3.1 所示：

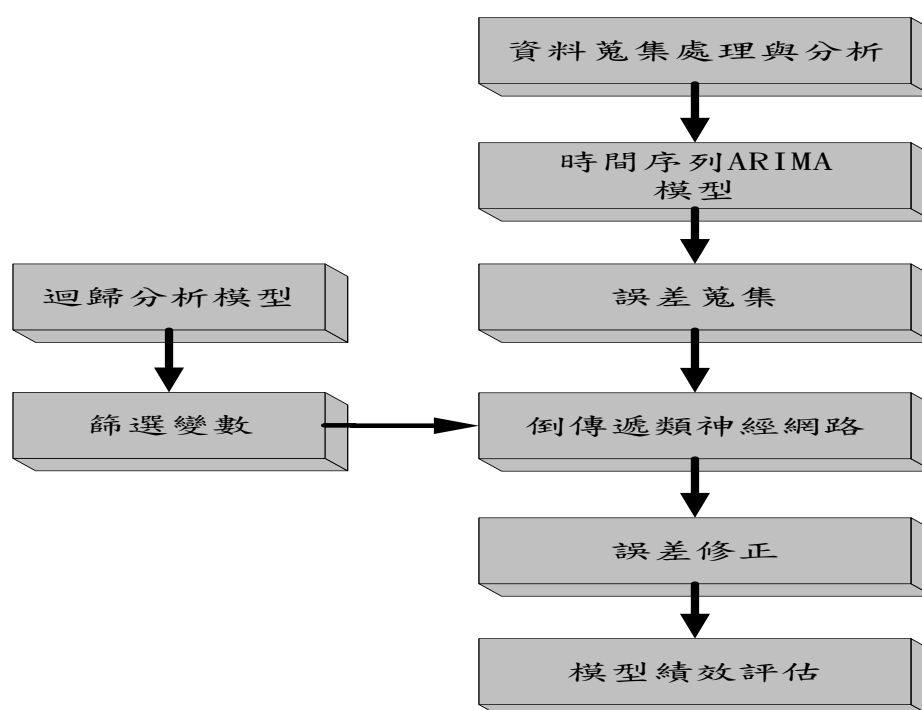


圖 3.1 本研究操作概念圖(資料來源:本研究整理)

3.2 研究樣本期間與資料蒐集

3.2.1 資料蒐集

本研究的樣本採用澎湖國家風景區 2001 年 1 月至 2009 年 12 月期間之月遊客量資料，並蒐集同一時段之影響遊客量因素，如經濟因素包含景氣領先指標、消費者物價指數、失業率、美元兌台幣匯率；氣候因素包含澎湖地區之氣溫、雨量、相對溼度、降水日數、日照時數，並加入大陸來台觀光人數作為影響遊客量的因素。

3.3 離群值的偵測與處理

3.3.1 離群值的影響

在時間序列的觀測值，有時會受干擾事件的影響，而呈現序列中與其他觀測值不具有一致性的現象【8】，例如禽流感、SARS、道路坍塌、封山、異常氣候現象，甚至記錄或輸入資料錯誤等干擾。這些異常的觀測值統稱為離群值(Outliers)。離群值會影響對於預測模式殘差的估計，所以離群值的偵測(Outlier Analysis)，在模式建構的過程中相當重要。

3.3.2 離群值的偵測

統計檢定的判斷，可以用來偵測離群值。離群值的統計檢定(statistical tests for outliers)的方式之一，乃利用與平均值之標準差的差異，來衡量每一個觀測值。本研究利用盒形圖(Box Plot)和 IQR(Inter Quartile Range)之倍數決定數列中是否含有離群值存在。

當離群值對時間序列模式的預測效率有顯著不利影響時，應該被修正。因此，在前述偵測過程後，下一個步驟便是以較佳的值替換離群值。一般而言，可以考慮下列的方式：

1. 若時間序列存在可信賴的預測模式，則可以利用預測值來取代離群值。
2. 若時間序列具有完全隨機特性，則可以利用序列的平均值取代離群值。
3. 若時間序列為正自我相關，不論是隨機漫步或趨勢，則可以利用相鄰兩個觀測值的平均值來取代。
4. 若時間序列為季節性的變化，當兩個季節性相鄰觀測值具有極佳的代表性時，則可以利用其平均值來取代。

3.4 時間序列分析

依時間過程所得到變數的觀察值，稱為時間序列(time series)。而對時間序列的研究，稱為時間序列分析(time series analysis)。時間序列模型(time series model)便是以分析序列變數過去資料與現在的關係，來預測變數未來的變動趨勢。時間序列的資料往往不能以迴歸分析的方法來建立模型而加以分析。因為迴歸分析欲建立的是因果模型，而時間序列中之各觀測值間通常都存在相關性，時間相隔越短的兩個觀測值，其相關性越大。時間序列並不滿足所謂“各觀測值為獨立”的必要假設。因此，時間序列分析和其他傳統分析不同的是，它不需藉助預測變數，僅依照變數本身過去的資料所存在的變異型態來建立模型。因此，本節介紹在建立實證模型前，處理時間序列資料所需要的相關檢定，來配適一良好的 ARIMA (Autoregressive Integrated Moving Average Models) 模式。

3.4.1 定態序列

採時間序列進行計量分析前，應先檢定變數是否呈現定態(stationary)。所謂定態，係指一時間序列資料產生的過程為一隨機過程(stochastic process)。但此一隨機過程之機率分配，不隨時間而改變。若一時間序列為定態，則其變數具有相同的期望值及變異數，亦即該序列存在一均值，受到衝擊事件影響僅是短暫，隨時間便會逐漸消逝，整個序列再度回到長期的均衡。

根據Granger and Newbold【37】的研究發現，若對非定態變數序列進行傳統的迴歸分析，則可能產生判定係數很高，且變數之t統計量非常顯著，但Durbin-Watson檢定值卻很低的假性迴歸(spurious regression)現象，導致估計結果產生偏差。由於許多研究發現，大多經濟或財務的時間序列資料變數，都具有非定態性質。因此，採用時間序列變數進行研究時，檢定變數是否為定態，成為必備的先驗步驟。

3.4.2 單根檢定

單根檢定(Unit Root Test)主要是用來檢定序列是否為定態，即檢測樣本是否存在單根。若一序列經過d次差分始達定態，則稱此序列為一整合級次為d的序列，表示為I(d)(integrated of order d)。一般而言，單根檢定方法中，以Dickey-Fulle檢定法與Augmented Dickey-Fuller檢定法最廣為使用。但由

於DF檢定法，係假設殘差符合白噪音¹性質，而迴歸殘差項卻可能存在序列相關的現象，造成DF值不正確，檢定範圍受到限制，使得DF檢定的檢定力不足【26】。為解決此問題，Said and Dickey【47】提出當殘差項非白噪音時，將誤差項序列相關的可能性考慮進來之修正模型，即將解釋變數加入被解釋變數的落後項，視其為額外的解釋變數後再進行檢定，即為ADF單根檢定。Engle and Granger【46】亦建議使用ADF檢定法來檢測單根問題。故本研究採用ADF檢定法來進行單根檢定。

一般而言，ADF 檢定法有以下三種模型：

1. 無截距項與時間趨勢項

$$\Delta Y_t = \gamma Y_{t-1} + \sum_{i=2}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (3.4.1)$$

2. 有截距項與無時間趨勢項

$$\Delta Y_t = \alpha_0 + \gamma Y_{t-1} + \sum_{i=2}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (3.4.2)$$

3. 有截距項與時間趨勢項

$$\Delta Y_t = \alpha_0 + \alpha_1 T + \gamma Y_{t-1} + \sum_{i=2}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (3.4.3)$$

式中 Δ 表示差分， $\Delta Y_t = Y_t - Y_{t-1}$ 服從白噪音， $\varepsilon_t \sim N(0, \sigma^2)$ ， α_0 為截距項， T 為時間趨勢(trend)， P 為使殘差項 ε_t 符合白噪音的最適落後期數。此三種模型之虛無假設為 $H_0: \gamma = 0$ (即 Y_t 序列存在單根)，若檢定結果 γ 顯著異於0，即拒絕單根存在，表示該序列為定態；若所得結果為非定態序列，則須經由資料處理並進行反覆檢定，直到 γ 顯著異於0，成為定態序列結果。

3.4.3 自我迴歸整合移動平均(ARIMA)模型

自我迴歸移動平均(Autoregressive Integrated Moving Average, ARIMA)係由Box and Jenkins(1970)提出，主要由兩部分所組成，分別為自我迴歸(AutoRegressive, AR)模型與移動平均(Moving Average, MA)模型。

1. 自我迴歸(AR)模型

¹白噪音(white noise)之定義如下：

(1)誤差項之期望值為零，即 $E(\varepsilon_t) = 0$, for all t

(2)誤差項之變異數為一固定常數，即 $\text{var}(\varepsilon_t) = \sigma^2$, for all t

(3)誤差項之自我共變數為零，即 $\text{cov}(y_t, y_{t-k}) = \text{cov}(y_{t-j}, y_{t-k-j}) = 0$, for all $j, k, j \neq k$

AR模型指應變數(y_t)除了受誤差項(ε_t)影響外，亦受該變數前 p 期值 (y_{t-1}, y_{t-2}, \dots)所影響，以AR(p)表示，模型如下：

$$y_t = a_0 + \sum_{i=1}^p a_i y_{t-i} + \varepsilon_t \quad (3.4.4)$$

其中 a_0 表示截距項， y_t 為第 t 期實際值， a_i 代表 y_{t-i} 估計參數， ε_t 為白噪音。又定義落後運算因子(Backward Shift Operator) B 為

$$B^1 y_t = y_{t-1}, B^2 y_t = y_{t-2}, B^p y_t = y_{t-p} \quad (3.4.5)$$

則(3.4.4)可寫為

$$y_t = a_0 + (a_1 B^1 + a_2 B^2 + \dots + a_p B^p) y_t + \varepsilon_t \quad (3.4.6)$$

將當期 y_t 視為應變數，而過去 p 期之數個觀測值 $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ 當作自變數做一個複迴歸。然而自變數及應變數皆來自於同一個隨機過程，即未來的觀測值深受過去之觀測值所影響，故成為自我迴歸模式。

2. 移動平均(MA)模型

MA模型指應變數(y_t)與過去 q 期隨機干擾項($\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$)有關係，以MA(q)表示，模型如下：

$$y_t = a_0 + \sum_{i=1}^q b_i \varepsilon_{t-i} + \varepsilon_t \quad (3.4.7)$$

其中 a_0 表示截距項， b_i 代表 ε_{t-i} 估計參數， ε_t 為白噪音。若以落後運算因子 B 代替則可將(3.4.7)寫為

$$y_t = a_0 + (1 + b_1 B^1 + b_2 B^2 + \dots + b_q B^q) \varepsilon_t \quad (3.4.8)$$

此模式表示當期觀測值 y_t 會受到當期及過去干擾項($\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$)的影響，此影響會持續到 $t, t+1, \dots, t+q$ 等期後自動消失。

3. 自我迴歸移動平均(ARMA)模型

若一應變數(y_t)同時與變數之前期($y_{t-1}, y_{t-2}, \dots, y_{t-p}$)及誤差項之前期($\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$)相關，則稱此模型為ARMA(p,q)模型。

$$y_t = a_0 + \sum_{i=1}^p a_i y_{t-i} + \varepsilon_t + \sum_{i=1}^q b_i \varepsilon_{t-i} \quad (3.4.9)$$

其中 a_0 表示截距項， a_i 與 b_i 代表估計參數， ε_t 為白噪音。以落後運算因子 B 代替則可將(3.4.7)寫為

$$(1 - a_1 B^1 - a_2 B^2 - \dots - a_p B^p) y_t = a_0 + (1 + b_1 B^1 + b_2 B^2 + \dots + b_q B^q) \varepsilon_t \quad (3.4.10)$$

4. 自我迴歸整合移動平均(ARIMA)模型

若一變數(y_t)同時與變數之前期(y_{t-1} 、 y_{t-2} 、 y_{t-3} 、 \dots 、 y_{t-p})及誤差項之前期(ε_{t-1} 、 ε_{t-2} 、 ε_{t-3} 、 \dots 、 ε_{t-q})相關，則稱此模型為ARMA(p,q)模型。若有一資料為非定性資料，ARMA模型無法配適時，可利用取差分方式進行配適。定義差分運算因子(Difference Operator) ∇ 為

$$\text{一階差分：} \nabla y_t = y_t - y_{t-1} = (1 - B) y_t \quad (3.4.11)$$

$$\text{二階差分：} \nabla^2 y_t = \nabla y_t - \nabla y_{t-1} = (1 - B)^2 y_t \quad (3.4.12)$$

$$\text{d階差分：} \nabla^d y_t = (1 - B)^d y_t \quad (3.4.13)$$

若取d次差分後可用ARMA(p,q)配適，則稱此模型為ARIMA(p,d,q)。其模型如下：

$$\Delta^d y_t = a_0 + \sum_{i=1}^p a_i \Delta^d y_{t-i} + \varepsilon_t + \sum_{i=1}^q b_i \varepsilon_{t-i} \quad (3.4.14)$$

其中d表示差分次數， a_0 表示截距項， a_i 與 b_i 代表估計參數， ε_t 為白噪音。若以落後運算因子B代替則可將(3.4.14)寫成

$$(1 - a_1 B^1 - a_2 B^2 - \dots - a_p B^p)(1 - B)^d y_t = a_0 + (1 + b_1 B^1 + b_2 B^2 + \dots + b_q B^q) \varepsilon_t \quad (3.4.15)$$

令 $a_p(B) = 1 - a_1 B^1 - a_2 B^2 - \dots - a_p B^p$ 且 $b_q(B) = 1 + b_1 B^1 + b_2 B^2 + \dots + b_q B^q$ ，則(3.4.15)可化簡為

$$a_p(B) \nabla^d y_t = a_0 + b_q(B) \varepsilon_t \quad (3.4.16)$$

5. 季節性ARIMA(SARIMA)模型

在預測上許多資料會受規則性週期的影響，如冷氣、冰品之銷售在夏季時皆特別明顯。這些資料皆有其共同之特徵，亦即相隔固定期間之觀測值，彼此間具有高度相關性【8】。假設時間序列除了趨勢性之外，尚存在有週期性，且每s期循環一次，則此ARIMA(p,d,q)模型尚需考慮季節性因素，對此模型再做季節性差分。若 $\{y_t\}$ 為季節性時間序列，s代表週期，如月資料s=12，季資料s=4。對於一個每隔s期之時間數列，其AR(P)_s季節性自我迴歸模式定義為

$$y_t = a_0 + a_s y_{t-s} + a_{2s} y_{t-2s} + \cdots + a_{P_s} y_{t-P_s} + \varepsilon_t \quad (3.4.17)$$

式中 a_{i_s} , $i=1,2,\dots$, 稱為季節性自我迴歸參數。

MA(Q)_s 季節性移動平均定義為

$$y_t = a_0 + b_s \varepsilon_{t-s} + b_{2s} \varepsilon_{t-2s} + \cdots + b_{Q_s} \varepsilon_{t-Q_s} + \varepsilon_t \quad (3.4.18)$$

式中 b_{j_s} , $j=1,2,\dots$, 稱為季節性移動平均參數。

ARMA(P,Q) 為

$$y_t = a_0 + a_s y_{t-s} + a_{2s} y_{t-2s} + \cdots + a_{P_s} y_{t-P_s} + \varepsilon_t + b_s \varepsilon_{t-s} + \cdots + b_{Q_s} \varepsilon_{t-Q_s} \quad (3.4.19)$$

以落後運算因子 B 代替則可將(3.33)寫為

$$(1 - a_s B^s - a_{2s} B^{2s} - \cdots - a_{P_s} B^{P_s}) y_t = a_0 + (1 + b_s B^s + b_{2s} B^{2s} + \cdots + b_{Q_s} B^{Q_s}) \varepsilon_t \quad (3.4.20)$$

令 $\alpha_p(B^s) = 1 - a_s B^s - a_{2s} B^{2s} - \cdots - a_{P_s} B^{P_s}$ 且 $\beta_Q(B^s) = 1 + b_s B^s + b_{2s} B^{2s} + \cdots + b_{Q_s} B^{Q_s}$ 則(3.4.20)可簡化為

$$\alpha_p(B^s) y_t = a_0 + \beta_Q(B^s) \varepsilon_t \quad (3.4.21)$$

則 ARIMA(P,D,Q) 為

$$\alpha_p(B^s) \nabla_s^D y_t = a_0 + \beta_Q(B^s) \varepsilon_t \quad (3.4.22)$$

時間序列在連續數年中，每隔 s 期的數個觀測值存在高度相關的特性。但許多時間序列亦常在連續時期的數個觀測值彼此間具有相依性，所以必須同時考慮一般連續性及季節性模型。一般時間序列 ARIMA(p,d,q) 和季節性時間序列 ARIMA(P,D,Q) 相乘模式如下：

$$\alpha_p(B^s) a_p(B) \nabla_s^D \nabla^d y_t = a_0 + \beta_Q(B^s) b_q(B) \varepsilon_t, \text{ 其中 } a_0 \text{ 為常數項。} \quad (3.4.23)$$

任一時間序列可以不同型態出現。一般可根據 Box and Jenkins (1976) 提出的時間序列分析步驟進行實證分析。其操作流程如圖 3.2 所示：

1、資料蒐集及整理 (Data collection)

時間序列模式的條件須在資料為定態下進行。由於許多時間序列並非定態【46】，故需將非定態資料轉換為定態資料後，才可進行後續分析的使用。單根檢定為檢定時間序列使用的資料，在長期下是否為定態的一種方法。若原始資料並非定態，則此一步驟常藉由將資料取自然對數、差分或季節差分，將非定態資料轉換成定態資料，以進行後續的分析。通常資料

變異較大時，可取自然對數進行轉換；資料呈現趨勢性時，則做差分處理；而若資料呈現季節性之循環，則可使用季節差分，以消除季節趨勢【22】，使之達到基本時間序列條件的假設。

2、模型判定 (Identification)

模型判定部分，主要是利用樣本估計的自我相關 (ACF) 和偏自我相關 (PACF)，作為判斷依據 p 、 d 、 q 實得參考依據。為了避免人為判斷所產生的誤差，在實務上常用試誤 (Trial and Error) 的方法，藉由選取最小之 AIC 或 SBC 值，來求得最佳的模型。在試誤法的過程中，將 p 與 q 值階次皆限制在 3 以下。

3、參數估計 (Estimation)

參數估計階段，主要針對候選模型進行參數估計並檢定是否顯著，以避免模型有太多不必要的參數。一般而言，常使用統計及圖形判斷方式進行參數估計。因此必須檢定參數是否顯著，直到找到參數都顯著的模型。

4、模式判斷與檢驗 (Diagnostic checking)

模型配適後，為了解估計模型是否合適，必須檢定模型之殘差項是否存在序列相關，以及檢定模型之殘差是否符合「常態分配」。一般評估殘差項是否存在序列相關之標準，以 Ljung and Box【43】提出的 Ljung-Box Q 統計量，檢定殘差項是否存在 m 階序列相關。其虛無假設為 H_0 ：無 m 階序列相關。Ljung-Box Q 統計量為：

$$Q = T(T+2) \sum_{i=1}^m \frac{\rho(i)^2}{(T-i)} \sim \chi^2(m) \quad (3.4.24)$$

其中 T 為樣本數， $\rho(i)$ 為殘差第 i 階自我相關係數， m 為落後期數。若 $Q > \chi^2(m)$ ，則拒絕無 m 階序列相關之虛無假設，表示模型配適不適當，必須重新認定及估計；若 $Q < \chi^2(m)$ ，則表示模型配適適當。評估殘差項是否符合「常態分配」之標準為 Jarque-Bera 統計量。其虛無假設 H_0 ：被檢定之變數為常態分配。Jarque-Bera 統計量為：

$$JB = \frac{T-n}{6} \left(S^2 + \frac{1}{4}(K-3)^2 \right) \quad (3.4.25)$$

其中 S 為偏態系數(skewness)， K 為峰態系數(kurtosis)， n 為待估參數， T 為樣本數。若無法拒絕虛無假設，則我們可設定此模型之殘差項符合常態分配。

5、模式選取 (Model selection)

在時間序列的研究中，最佳模式之選取，一般以 Akaike (1974)提出的 AIC (An Information Criterion) 或Schwartz(1978)提出的SBC (Schwartz Bayesian information Criterion) 準則來決定最適模型。若AIC和SBC值愈小，則代表模型的配適度越佳。計算方式分別如下所示。

$$AIC = T \ln(SSE) + 2k \quad (3.4.26)$$

$$SBC = T \ln(SSE) + k \ln(T) \quad (3.4.27)$$

其中 T 是樣本總數， $\ln(SSE)$ 是SSE(殘差平方和)取自然對數， $\ln(T)$ 是樣本總數取自然對數， k 是待估參數總數。

此兩種模型選擇準則何者較佳，並沒有一致的定論。一般而言，根據模型的簡約性(parsimony)原則，參數較少的模型就是較好的模型【26】。而 SBC 準則較 AIC 準則嚴格。當樣本資料愈大時，SBC 愈能選擇出正確的模型；在同情況下 AIC 傾向選出落後期較長的模型【35】。因此當 AIC 準則與 SBC 準則相抵觸時，則以 SBC 準則為優先考量。

因此，本研究擬採用時間序列分析法，建構澎湖國家風景區遊客量之 ARIMA 模型，以進行本研究預測架構之初步預測。

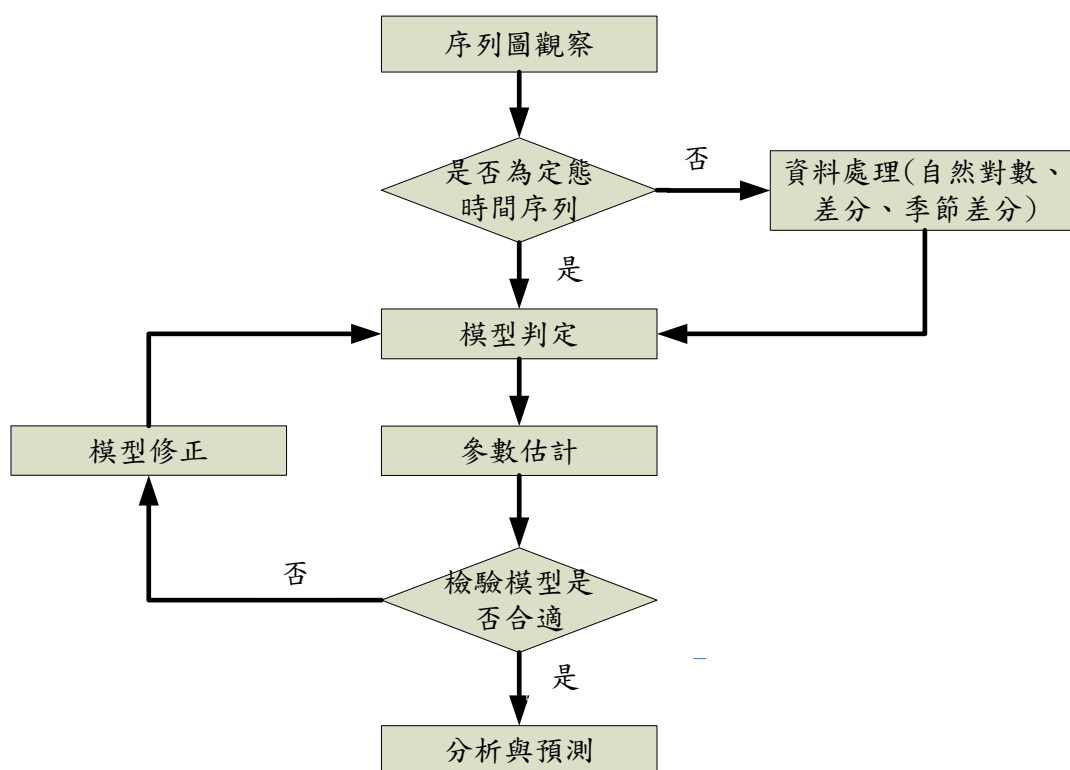


圖 3.2 ARIMA 模型操作流程圖

資料來源：【9】、本研究整理

3.5 迴歸分析

3.5.1 迴歸分析概念

迴歸分析(regression analysis)是用來研究兩個或兩個以上變數間的關係。此法的主要目的是建立一個迴歸模式，然後根據一個或多個自變數(independent variable)之值，來預測相依變數(dependent variable)或稱反應變數(response variable)之值。透過迴歸方程式，得到各自變數對應變數的影響力。若一迴歸模型之判定係數 R-Square 的值越高，則代表自變數對應變數的解釋能力越強。

一般迴歸分析可分為簡單迴歸(simple regression)和多元迴歸(multiple regression)兩種。簡單迴歸為探討單一自變數 x_i 對應變數 y_i 的預測過程。其迴歸方程式如下：

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (3.5.1)$$

$$\text{且 } \varepsilon_i \sim N(0, \sigma^2), i = 1, 2, \dots, n$$

其中 β_0 為常數項， β_1 為迴歸係數， ε_i 為殘差項。

多元迴歸是利用多個自變數 $x_{1i}, x_{2i}, \dots, x_{ki}$ 預測一個依變數 y_i 的過程，其迴歸方程式如下：

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i \quad (3.5.2)$$

$$\text{且 } \varepsilon_i \sim N(0, \sigma^2), i = 1, 2, \dots, n$$

其中 $x_{1i}, x_{2i}, \dots, x_{ki}$ 為自變數， y_i 為依變數， β_0 為常數項， $\beta_1, \beta_2, \dots, \beta_k$ 為迴歸係數， ε_i 為殘差項。

3.5.2 最佳子集合迴歸

最佳子集合迴歸(best-subset regression)是迴歸分析中篩選變數的方法之一。藉由對迴歸式中所有自變數對依變數之關係進行模式組合，估算所有可能之迴歸模式的績效值，相互比較後，選取績效最佳之迴歸變數組合，達到篩選變數的效果。因此，本研究即利用最佳子集合迴歸具有篩選變數之功能，對影響澎湖國家風景區遊客量之變數進行篩選，期能挑選出最佳的變數組合，提升預測績效。

於迴歸模式之績效指標選擇方面，R-Square 可代表依變數 y 於總變異中被自變數 x_1, x_2, \dots, x_k 解釋之百分比例，為模式配適度(Goodness of Fit) 之

重要指標，其公式如下：

$$R^2 = \frac{SSR}{SSTO} = 1 - \frac{SSE}{SSTO}, 0 \leq R^2 \leq 1 \quad (3.5.3)$$

其中 $SSTO$ 為總差異平方和， SSR 為組間平方和。

在多元迴歸模式中，一般皆認為 R-Square 越大則模式越好。事實上，判定係數 R-Square 越大，並不一定表示該模式越好，因為在式(3.5.3)中，自變數每多放一個，則其誤差平方和必定會降低，而造成 R-Square 增加的結果。因此，若研究者放入一些毫無意義的自變數時，必定可使 R-Square 增加，而誤認該變數或該模式是有意義的。因此要修正上述缺失，就必須考慮以修正後判定係數(adjusted R-Square)，來檢驗該模式是否良好。其公式定義為：

$$R_a^2 = 1 - \frac{SSE(n-1)}{SSTO(n-k-1)} = 1 - (1 - R^2) \left(\frac{n-1}{n-k-1} \right) \quad (3.5.4)$$

因此，本研究選擇修正判定係數(Adjusted R-Square)為迴歸模型之績效指標。

3.6 類神經網路

3.6.1 類神經網路簡介

「類神經」一詞，最早起源於1943年，由McCulloch and Pitts於「A Logical Calculus of Ideas Imminentin Nervous Activity」中，提出神經元數學模型(MP model)。但此模型採用固定的鍵結值(synaptic weights)與閾值(threshold)，故不具有學習能力。之後，1949年Hebb提出神經元間的鍵結值發生改變，將導致學習效果的產生。使得MP模型與Hebb學習法則對後來的類神經網路發展建立了基礎。到了1957年，Frank Rosenblatt提出感知機(Perceptron)，為第一種類神經網路模型。它由具有可調整鍵結值及閾值的單一類神經元所組成，主要用於理論研究與樣本識別。但1969年Minsky and Papert於「Perceptron」書中，以數學證明當時類神經網路模型的學習能力極受限制，甚至連最簡單的「互斥或」(exclusive or, XOR)問題都無法解決，而使類神經網路的發展陷入低潮。直到1980年代中期後，隨著霍普菲爾網路(Hopfield neural network)的提出，類神經網路的研究才再次熱門起來。1986年Rumelhart and McClelland等人，提出倒傳遞類神經網路(BPN)與通用差距法則(generalized delta rule)。此種類神經網路克服了XOR的問題。並且以理論證明此種演算法的收斂性。此種模型已成為目前應用最廣的網路。至今為止，類神經網路仍然有新的架構與理論不斷被提出，配合電腦運算速度的增加，使得類神經網路的功能更為強大，運用層面更為廣泛。

3.6.2 類神經網路原理及架構

類神經網路(Artificial Neural Network, ANN)，又稱人工神經網路，是指模仿生物神經網路的資訊處理系統。根據DARPA Neural Network Study (1988)定義，類神經網路為「一種由許多簡單的處理單元以平行方式運作所構成的神經網路」。葉怡成(2009)較精確定義為「類神經網路是一種計算系統，包括軟體與硬體，它使用大量簡單的人工神經元來模仿生物神經網路的能力。人工神經元是生物神經元的簡單模擬，它從外界環境或者其他人工神經元取得資訊，並加以非常簡單的運算，並輸出其結果到外界環境或者其他人工神經元」。

類神經網路與傳統統計方法或專家系統不同之處，在於其不需事先設定出特定的函數形式，資料也不需限定在某種特定的統計分配假設，是一種能透過學習，來處理多變數時間非線性關係的工具。類神經網路便是藉由

模擬人類大腦神經的運作方式，透過不斷學習及錯誤修正，創建與訓練出符合實際問題的類神經網路架構，以映射出輸入與輸出間關係的數學式，以達到正確預測的目的。

類神經網路的基本架構可分三個層次：處理單元(processing element, PE)、層(layer)、網路(network)所構成。一個類神經網路是由許多人工神經元，又稱處理單元所組成。介於處理單元間的訊號傳遞路徑稱為連結(connection)。每一個連結都有對應的權重值 W_{ij} (weight)，用以代表處理單元 i 對處理單元 j 的影響強度，其運作方式如圖3.3所示。每一個處理單元接受輸入訊號後，以扇狀方式送出訊號，成為下一層處理單元的輸入訊號。處理單元的輸出值與輸入值的關係式，一般可用下列函數表示：

$$Y_j = f\left(\sum W_{ij}X_i - \theta_j\right) \quad (3.6.1)$$

其中， Y_j ：輸出變數，模仿生物神經元的輸出訊號。

X_i ：輸入變數，模仿生物神經元的輸入訊號

W_{ij} ：連結權重值(weight)，模仿生物神經元的神經節強度。

θ_j ：模仿生物神經元的模型的閾值(bias)，又稱偏權值。即輸入訊號的加權乘積必須大於此門檻值，才会有訊號傳送至下個神經元。

Σ ：集成函數(summation function)，此部分是將每一個輸入(X_i)與權重值(W_{ij})相乘後做加總。

f ：模仿生物神經元處理功能的轉換函數(transfer function)，用以將從其他處理單元輸入的輸入值之加權乘積和($\sum_{i=1}^n W_{ij}X_i$)和偏權值(θ_j)的總合轉換成處理單元輸出值的數學公式。轉換函數通常被設為一個具有雙向彎曲的指數函數。




圖3.3 人工神經元模型(資料來源:【23】)

至目前為止，許多學者針對不同問題的解決，提出許多不同類神經網

路模型，每一種類神經網路的演算法並不相同。而類神經網路通常依照學習策略與網路架構二種方式進行分類，分別詳述如下【23】：

1. 依學習策略分類

- (1) **監督式學習(Supervised Learning)**：從問題領域中取得訓練範例(有輸入變數與輸出變數)，並從中學習輸入變數與輸出變數的內在對應規則，以應用於新的案例，即只有輸入變數值，而需推論輸出變數值的應用。分類應用(如疾病診斷)與預測應用(如經濟預測)屬之。
- (2) **無監督式學習(Unsupervised Learning)**：從問題中取得訓練範例(只有輸入變數值)，並從中學習範例的內在集群規則，以應用於新的案例。即只有輸入變數值，而需推論它與那些訓練範例屬同一聚類的應用。無監督式學習可作為監督式應用的前端處理。
- (3) **聯想式學習(Associate Learning)**：從問題中取得訓練範例(狀態變數值)，並從中學習範例的內在記憶規則，以應用於新的案例，即只有不完整的狀態變數值，而需推論其完整的狀態變數值的應用。資料擷取應用與雜訊過濾應用屬之。
- (4) **最適化應用(Optimization Learning)**：類神經網路除了「學習」應用外，還有一類特殊應用，即最適化應用——對一個問題決定其設計變數值，使其在能滿足設計的限制下，設計目標達到最佳狀態的應用。設計應用與排程應用屬之。此類應用的網路架構，大都與聯想式學習網路架構相似。

2. 依網路架構分類

- (1) **前向式架構(forward)**：神經元分層排列，形成輸入層、隱藏層(若干層)、輸出層。每一層只接受前一層的輸出作為輸入，稱前向式架構。
- (2) **回饋式架構(feedback)**：從輸出層回饋到輸入層，或是層內各處理單元間有連結者，或是當神經元不分層排列，只有一層，各神經元間均可以相互連結，稱回饋式架構。依據學習策略與網路架構的區分，茲將類神經網路的十四種模式分類，整理如表3.1所示。

表 3.1 類神經網路模式分類表

學習策略 \ 網路架構	前向式架構	回饋式架構
監督式學習	認知機 倒傳遞網路(BPN) 機率神經網路(PNN) 學習向量化網路(LVQ) 反傳遞網路(CPN)	波茲曼機(BM) 時空樣本識別網路(STPR) 新認知機(也可作無監督學習)
無監督式學習	自組織映射圖(SOM)	自適應共振理論(ART)
聯想式學習		霍普菲爾網路(HNN) 雙向聯想記憶網路(BAM)
最適化應用		*霍普菲爾-坦克網路(HTN) *退火神經網路(ANN)

*屬解最適化問題的網路，不屬上述任一種學習模式

(資料來源:【23】)

3.6.3 類神經網路之運作

類神經網路如何學習而具有功能，便要瞭解網路如何透過訓練，來調整並決定加權值 W_{ij} 和偏權值 θ_j 。基本上，類神經網路的運作分成兩個過程【30】：

1. 訓練過程—目的在決定網路的權重值與偏權值。
2. 模擬過程—目的在決定網路的預測輸出值或驗證網路的準確度。

在訓練過程中，網路遵循所謂的學習規則(Learning Rule)，各種類型的網路各有不同的學習規則。學習規則目的即在修正網路的權重值與偏權值。訓練過程一般採用所謂的訓練演算法(Training Algorithm)，同樣的，不同類型網路也各有其不同的訓練演算法。

類神經網路在運作時會將所需訓練的資料，或稱訓練數據集(Training Data Set)分成兩類：

1. 訓練數據集—目的在修改網路的權重值與偏權值。
2. 測試數據集—目的在驗證網路的準確度。

總而言之，類神經網路運作方式為透過訓練，不斷的調整節點之間的權重值與偏權值，使網路所計算的輸出為目標輸出，其運作目的就是要讓網路能映射出正確的輸入—輸出關係模式。

3.6.4 倒傳遞類神經網路

倒傳遞類神經網路為目前類神經網路學習模式中最具代表性，應用最普遍的模式，屬於監督式學習網路，適用於分類、診斷、預測和雜訊過濾等應用。

典型倒傳遞類神經網路的基本原理，是利用最陡坡降法(the gradient steepest descent method)的觀念，採用錯誤更正學習法則的倒傳遞演算法(back propagation algorithm)。「倒傳遞」是指非線性多層網路內計算梯度的方法，將錯誤的訊號以回饋方式修正網路的連結權重與閾值，使誤差函數最小化，而將推論的輸出值能夠最接近目標輸出值，以達到網路學習的目的。目前，倒傳遞演算法基於其他不同標準的最佳化技巧，而有了許多變化的演算法，例如共軛梯度法(Conjugate Gradient)和牛頓法等。另外，類神經網路工具箱被視為一個已知能運作良好並已建立好步驟的套裝軟體，亦已提供了大多數變化的演算法。

1. 倒傳遞網路之架構

倒傳遞類神經網路架構為多層感知機(multilayer perceptrons)，輸入信號以前饋(feedforward)方式，每一層只接受前一層的輸出作為輸入。主要由輸入層、隱藏層和輸出層所構成。其架構如圖3.4所示：

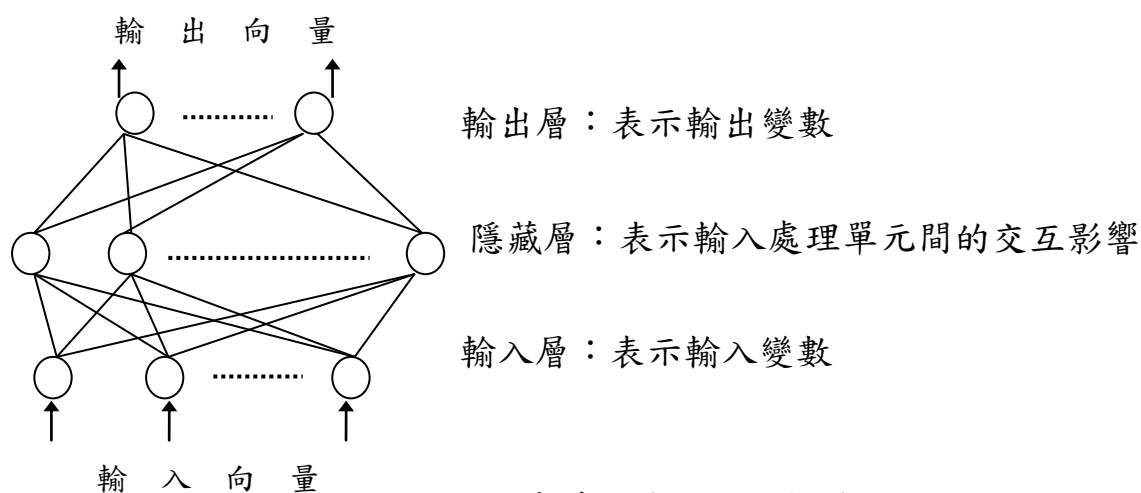


圖 3.4 倒傳遞類神經網路架構

(資料來源:【23】)

- (1) 輸入層：用以表現網路的輸入變數，其處理單元數目依問題而定。使用線性轉換函數，即 $f(x) = x$ 。
- (2) 隱藏層：用以表現網路輸入處理單元間的交互影響，其處理單元數目

並無標準方法可決定，經常需以試驗方式決定最佳的數目。使用非線性轉換函數。在網路中隱藏層的數目可以不只一層，也可以沒有隱藏層。

(3) 輸出層：用以表現網路的輸出變數，其處理單元數目依問題而定，常使用非線性轉換函數。

2. 倒傳遞網路之學習演算法

以下將簡單說明在倒傳遞網路的學習過程中，網路如何利用一輸入向量 X 與一目標輸出向量 T ，來修正網路加權值 W ，而達到學習的目的。

在倒傳遞網路中，第 n 層的第 j 個單位輸出值 (A_j^n) 為 $n-1$ 層單位輸出值計算之淨輸入值 (net_j^n) 的非線性函數：

$$A_j^n = f(net_j^n) \quad (3.6.2)$$

$$\text{其中，} net_j^n \text{ 為集成函數 } = \sum_i W_{ij} A_i^{n-1} - \theta_j \quad (3.6.3)$$

W_{ij} 為第 $n-1$ 層第 i 個處理單元與第 n 層第 j 個處理單元間之連結加權值， θ_j 為偏權值(即閾值)。

因為倒傳遞網路目的在降低目標輸出值與推論輸出值之差距，一般以下列誤差函數來表示學習的品質：

$$E = \frac{1}{2} \sum_j (T_j - A_j)^2 \quad (3.6.4)$$

其中， T_j 為訓練範例之輸出層第 j 個輸出單元的目標輸出值；

A_j 為訓練範例之輸出層第 j 個輸出單元的推論輸出值。

因為誤差函數是推論輸出值的函數，而推論輸出值是網路連結權重值的函數，故誤差函數是網路連結權重值的函數。因此，調整網路連結權重值可以改變誤差函數的大小，故訓練神經網路的過程即修正連結權重值使誤差函數達到最小值的過程。為了使誤差函數達到最小值，通常使用「最陡坡降法」來調整網路連結權重值，調整的幅度和誤差函數對該權重值的敏感程度成正比，即與誤差函數對權重值的偏微分值大小成正比。每當輸入一個訓練範例，網路即小幅調整權重值大小：

$$\Delta W_{ij} = -\eta \cdot \frac{\partial E(n)}{\partial W_{ij}(n)} \quad (3.6.5)$$

其中， η 為學習速率，控制每次權重值修改的步幅。

而 $\frac{\partial E}{\partial W_{ij}}$ 可用微積分的連鎖律(chain rule)表示為：

$$\frac{\partial E}{\partial W_{ij}} = \left(\frac{\partial E}{\partial net_j^n} \right) \left(\frac{\partial net_j^n}{\partial W_{ij}} \right) \quad (3.6.6)$$

第①項第②項

將(3.6.3)代入(3.6.6)第②項得

$$\frac{\partial net_j^n}{\partial W_{ij}} = \frac{\partial}{\partial W_{ij}} \left(\sum_i W_{ij} A_i^{n-1} - \theta_j \right) = A_i^{n-1} \quad (3.6.7)$$

為簡明定義

$$\text{令 } \frac{\partial E}{\partial net_j^n} = -\delta_j^n \quad (3.6.8)$$

將(3.6.7)(3.6.8)代入(3.6.6)，則

$$\frac{\partial E}{\partial W_{ij}} = -\delta_j^n \cdot A_i^{n-1} \quad (3.6.9)$$

其中， A_i^{n-1} 為 W_{ij} 所連結之較低層處理單元之輸出值

δ_j^n 為 W_{ij} 所連結較上層處理單元之差距量

再將(3.6.9)代入(3.6.5)，可得

$$\Delta W_{ij} = \eta \cdot \delta_j^n \cdot A_i^{n-1} \quad (3.6.10)$$

此式即為倒傳遞演算法之關鍵公式。

根據上式來調整新的連結加權值 $W_{ij}(n+1)$ 為：

$$W_{ij}(n+1) = W_{ij}(n) + \Delta W_{ij}(n) = W_{ij}(n) + \eta \cdot \delta_j^n \cdot A_i^{n-1} \quad (3.6.11)$$

若 W_{ij} 連接的為輸出層，則

$$\begin{aligned} \delta_j^n &= -\frac{\partial E}{\partial net_j^n} = -\frac{\partial E}{\partial A_j^n} \cdot \frac{\partial A_j^n}{\partial net_j^n} \\ &= -\frac{\partial}{\partial A_j^n} \left[(1/2) \sum_j (T_j - A_j)^2 \right] \cdot \frac{\partial f(net_j^n)}{\partial net_j^n} \\ &= (T_j - A_j)^2 \cdot f'(net_j^n) \end{aligned} \quad (3.6.12)$$

若 W_{ij} 連接的為隱藏層，則

$$\begin{aligned} \delta_j^n &= -\frac{\partial E}{\partial net_j^n} = -\frac{\partial E}{\partial A_j^n} \cdot \frac{\partial A_j^n}{\partial net_j^n} = -\frac{\partial E}{\partial A_j^n} \cdot f'(net_j^n) \\ \frac{\partial E}{\partial A_j^n} &= \sum_k \frac{\partial E}{\partial net_k^n} \cdot \frac{\partial net_k^n}{\partial A_j^n} = \sum_k \frac{\partial E}{\partial net_k^n} \cdot W_{kj} = -\sum_k \delta_k^{n+1} \cdot W_{kj} \end{aligned}$$

$$\delta_j^n = \left[\sum_k \delta_k^{n+1} \cdot W_{kj}^n \right] \cdot f'(net_j^n) \quad (3.6.13)$$

如果轉換函數使用雙彎曲函數(sigmoid function)，則

$$f(net_j) = \frac{1}{1 + e^{-net_j}} \quad (3.6.14)$$

$$\text{則 } f'(net_j) = f(net_j) \cdot [1 - f(net_j)] \quad (3.6.15)$$

若 W_{ij} 連接的為輸出層，則

$$\delta_j^n = (T_j - A_j^n) \cdot A_j(1 - A_j) \quad (3.6.16)$$

若 W_{ij} 連接的為隱藏層，則

$$\delta_j^n = \left[\sum_k \delta_k^{n+1} \cdot W_{jk} \right] \cdot H_j \cdot (1 - H_j) \quad (3.6.17)$$

其中， A =輸出層處理單元輸出值

H =隱藏層處理單元輸出值

同理可證，

$$\Delta\theta_j = -\eta \cdot \delta_j^n \quad (3.6.18)$$

此學習過程通常以一次一個訓練範例進行，直到所有訓練範例皆輸入學習完畢，稱為一個學習循環(learning cycle)。一個網路可以將訓練範例反覆學習數個學習循環，直到網路收斂為止。當網路收斂後將結果輸出，則完成訓練過程，便可利用此一模型進行驗證、測試之過程，最後用來進行預測。

3. 倒傳遞網路常見重要參數設定

(1) 隱藏層層數

通常隱藏層之數目為一到二層時，有最好的收斂性質，太多或太少層其收斂結果則較差。若沒有隱藏層則不能反應此問題輸入變數間的交互作用，因而有較大的誤差；而更多的隱藏層，反而使網路過度複雜，使得修正網路加權值時更易掉入一誤差函數的局部最小值，而無法收斂。Funahashi【36】和Hornik【38】則指出對於大部分實際的問題來說，使用一層的隱藏層就已足夠。

(2) 隱藏層處理單元數目

通常隱藏層處理單元之數目越多收斂越慢，但可達到更小的誤差值。如果數目太少，不足以反映輸入變數間的交互作用，因而有

較大的誤差。但超過一定數目後，對降低「訓練範例」誤差幾乎沒有幫助，徒增執行時間。一般而言，隱藏層處理單元數目的選取原則如下：

$$\text{公式一: (輸入層單元數+輸出層單元數) / 2} \quad (3.6.19)$$

$$\text{公式二: (輸入層單元數} \times \text{輸出層單元數)}^{1/2} \quad (3.6.20)$$

(3) 學習速率

學習速率太大或太小對網路的收斂性質均不利。較大的學習速率雖然可較快逼近函數最小值，但過大的學習速率將導致網路加權值修正過量，造成數值振盪而難以達到收斂。依據經驗取學習速率的值取在0.5或0.1到1.0間，大都可以得到良好的收斂性。

(4) 慣性項

通常可在學習公式加上一個慣性項，即加上某比例的上次加權值改變量，以改善收斂過程中振盪的現象及加速收斂。因此(3.6.10)(3.6.18)可改寫成

$$\Delta W_{ij}^m = \eta \cdot \delta_j^n \cdot A_i^{n-1} + \alpha \cdot \Delta W_{ij}^{m-1} \quad (3.6.21)$$

$$\Delta \theta_j^m = -\eta \cdot \delta_j^n + \alpha \cdot \Delta \theta_j^{m-1} \quad (3.6.22)$$

其中， ΔW_{ij}^m = 加權值 ΔW_{ij} 第 m 次改變量，其餘類推。 α = 慣性因子，控制慣性項之比例， $0 \leq \alpha \leq 1$ ，建議值0.5。

(5) 轉換函數

轉換函數的主要目的是將作用函數輸出值，轉換成處理單元的輸出，倒傳遞網路常用的非線性轉換函數有二：

a. 雙彎曲函數(sigmoid function)

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.6.23)$$

當自變數趨於正負無限大時，其函數值趨於常數，值域在[0,1]之間。

b. 正切雙彎曲函數(Hyperbolic tangent function)

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.6.24)$$

當自變數趨於正負無限大時，其函數值趨於常數，值域在[-1,1]之間。

綜觀上述探討，發現類神經網路不須事先建立模型，可直接藉由訓練

的過程來找出輸入變數與輸出變數之間的關係，並且能夠處理變數間非線性複雜問題。因此本研究即採用類神經網路進行誤差的修正。

3.7 預測績效之評估指標

預測準確性係指衡量模型所得預測值與實際值間之誤差大小，藉以評估模型配適的好壞。本研究採用均方誤差(Mean Square Error, MSE)、均方根誤差(Root Mean Square Error, RMSE)、Theil's U(又稱Theil's Inequality Coefficient)及絕對平均誤差百分比例(Mean Absolute Percent Error, MAPE)等，來檢測模型預測值的準確性。各評估指標計算公式，茲說明如下：

1. 均方誤差(Mean Square Error, MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n (F_t - A_t)^2 \quad (3.7.1)$$

其中， A_t 代表實際值， F_t 代表預測值， n 為期數。

MSE為預測誤差值平方和之平均，其特色為大的預測誤差會比較小的預測誤差，以不成比例的方式顯現。MSE值愈小表示愈接近實際。

2. 均方根誤差(Root Mean Square Error, RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (F_t - A_t)^2} \quad (3.7.2)$$

RMSE為MSE之平方根，可將均方誤差放大之誤差經由平方根後，回歸至正常的誤差，如此可得到較為精確的比較基礎。

3. Theil's U(Theil's Inequality Coefficient)

$$U = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (F_t - A_t)^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n (F_t)^2 + \frac{1}{n} \sum_{t=1}^n (A_t)^2}} \quad (3.7.3)$$

其中 F_t 為第 t 期之預測值； A_t 為第 t 期之實際值； n 為期數。

Theil's U的分子稱為根均方誤差(RMSE)，係衡量模擬變數與它的時間路徑之偏離。Theil's U除上分母係為了使Theil's U值總是介於0與1之間。如果 $U=0$ ，則對所有的 t ， $F_t=A_t$ ，即有一個完美的配適模型；如果 $U=1$ ，則模型的預測績效相當不佳。Theil's U 衡量相對之誤差，其目的為求算每個預測誤差值達到最小，而非以預測差平均概念來衡量。因此，當Theil's U值越小，表示其預測誤差和越小，預測能力越佳。

4. 絕對平均誤差百分比例(Mean Absolute Percent Error, MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{F_t - A_t}{A_t} \right| \quad (3.7.4)$$

其中， A_t 代表實際值， F_t 代表預測值， n 為期數。

MAPE 是以實際值為分母之相對數值，所代表為百分比，不受實際值與預測值的單位或大小之影響，而產生比較基礎不穩固的問題，能夠客觀的獲得估計值與評估值間之差異程度。若 MAPE 值越小，表示預測誤差越小，模型預測能力越佳。學者 Makridakis 【44】指出，平均絕對誤差百分比，具有整合不同衡量指標的最佳特質。建議評估不同模型預測能力應以 MAPE 為準則，能提供決策者作為判斷依據。Lewis 【42】根據 MAPE 大小將預測能力分為四個等級，如表 3.2 所示。

表 3.2 MAPE 預測能力等級表

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

(資料來源:本研究整理)

第四章 實證分析

本研究以澎湖國家風景區遊客量為實證樣本，先對原始資料進行分析並做離群值處理，再將蒐集之資料分為樣本內(訓練期)以及樣本外(測試期)兩組，以樣本內資料進行時間序列 ARIMA 模式建模，並對樣本外資料進行預測，再將此模型之誤差值作為類神經網路的依變數(輸出項)進行倒傳遞類神經網路之預測，並利用迴歸分析(最佳子集合迴歸)篩選影響遊客量之因素，將其導入作為類神經網路的自變數(輸入項)，對樣本外資料進行誤差項之學習預測。最後，整合時間序列模型之樣本外預測值及倒傳遞類神經網路之樣本外誤差預測值，進行誤差修正，進而得到最終之遊客量預測值，並將此模型與單一 ARIMA 方法及未篩選變數之 ARIMA-BPN 結合模式進行預測績效之比較。

4.1 資料分析與處理

本研究分析之遊客量資料主要來源，乃蒐集交通部觀光局澎湖國家風景區管理處的月統計資料。資料蒐集範圍自 2001 年 1 月至 2009 年 12 月止。為了解資料是否可能呈現季節、趨勢、資料變異情況、離群值的出現或數列是否平穩，必須先根據資料繪製序列圖作初步的判斷，以進行後續預測模型的資料修正與參數推估。

4.1.1 原始資料分析

澎湖國家風景區之遊客量原始資料之序列圖如圖 4.1 所示。由圖 4.1 可看出，澎湖國家風景區遊客量之淡旺季的分布情形非常明顯。每年旅遊之旺季為四月至九月間，其原因為澎湖地區每年於此期間皆陸續舉辦海上花火節、菊島海鮮節、澎湖國際藝術沙灘節、綠蠵龜生態研習及萬龜祈福等活動，故吸引大批遊客前來；而淡季則大多分布於冬季月份，以年為單位的季節性因子十分明顯。

經由序列圖除可看出澎湖國家風景區遊客量的趨勢和季節性外，亦可看出 2002 年和 2003 年遊客量明顯較少，其原因為 2002 年五月的華航客機墜海意外及 2003 年三月發生 SARS 疫情。此兩年之遊客量變動情形恐成為序列之離群值而影響預測模式之準確性。因此，本研究將透過盒形圖來偵測離群值，並以適當的處理方式來修正離群值。




圖 4.1 澎湖國家風景區遊客量序列圖(資料來源:本研究整理)

4.1.2 離群值的偵測與處理

本研究以 SPSS17.0 套裝軟體中的盒形圖，判斷序列中是否出現離群值，其離群值偵測結果如圖 4.2 所示。由於澎湖國家風景區遊客量存在強烈的季節性變動，因此本研究以兩個季節性相鄰觀測值取其平均值來取代離群值。如圖 4.2 所示，以 2002 年 3 月出現離群值為例(離群值編號 15 號)，本研究將以 2000 年 3 月與 2001 年 3 月之遊客量平均值來取代離群值，以利後續預測模型的建立。

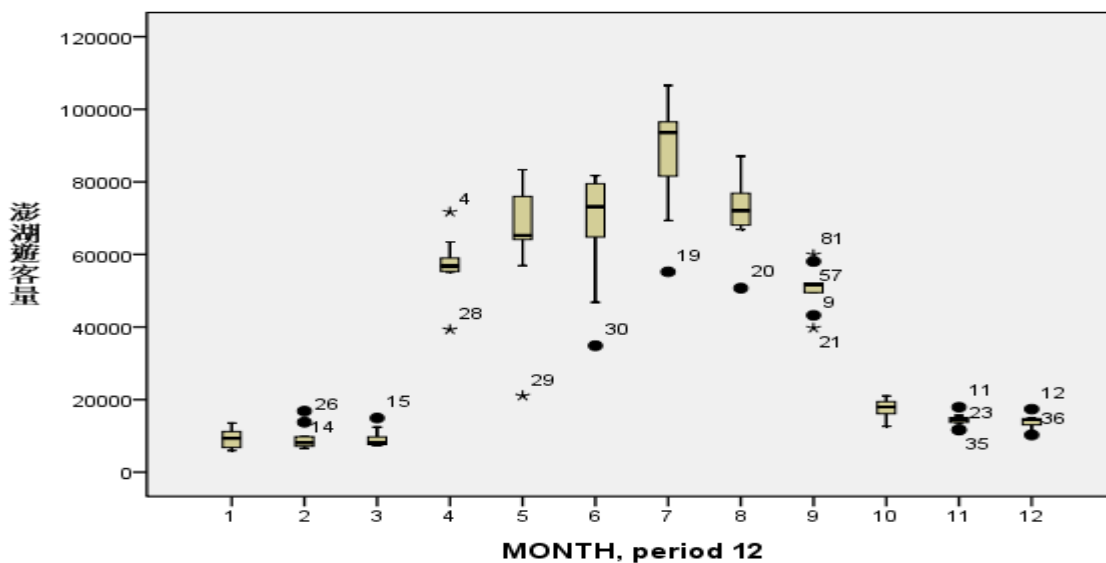


圖 4.2 澎湖國家風景區遊客量盒形圖(資料來源:本研究整理)

4.2 時間序列模型建構與分析

本研究根據 Box and Jenkins (1976)提出的時間序列分析步驟進行實證分析，分析步驟如下。

1、資料蒐集及整理

近年來有很多研究發現，許多遊客量資料具有非定態的性質。當迴歸式的解釋變數為時間序列資料且為非定態，若直接進行傳統迴歸分析很容易造成解釋變數與被解釋變數間有顯著相關之假性迴歸結果(Granger and Newbold, 1974)。但實際上並非如此，因而產生錯誤研判。因此，在進行實證研究前，必須先作單根檢定，以確認變數資料是否為定態序列，據此再以時間序列模型進行分析與預測，其結果才有意義。

本研究利用統計軟體 Eviews 5 進行 ADF 單根檢定法，檢定本研究之樣本內資料是否存在單根，即為非定態數列。檢定結果如下表 4.1，顯示不同類型的 ADF 單根檢定，皆無法拒絕存在單根的虛無假設。因此資料為非定態數列。而由圖 4.1 可看出序列呈現資料變異大且存在季節性的影響，故本研究採取對數列進行自然對數轉換並進行一階季節差分處理。其資料轉換結果如圖 4.3，顯示資料變異和季節性的影響情形已獲得改善。另進行單根檢定的結果，亦顯示經過資料轉換後之數列，皆拒絕存在單根的假設(表 4.2)，代表序列已由非定態序列轉變成定態序列，可進行後續模型建置的程序。

表 4.1 原始時間序列單根檢定表

ADF單根檢定類型	t-statistic	P-Value	臨界值(1%)
無截距項及趨勢項	-0.240466	0.5962	-2.597476
有截距項但無趨勢項	-0.875614	0.7906	-3.524233
有截距項及趨勢項	-1.536338	0.8078	-4.090602

*為10%顯著水準；**為5%顯著水準；***為1%顯著水準

(資料來源:本研究整理)




圖 4.3 取自然對數及一階季節差分後之序列圖

(資料來源:本研究整理)

表 4.2 經資料轉換後之時間序列單根檢定表

ADF單根檢定類型	t-statistic	P-Value	臨界值(1%)
無截距項及趨勢項	-6.503653	0.0000	-2.597939
有截距項但無趨勢項	-6.482606	0.0000	-3.525618
有截距項及趨勢項	-6.446552	0.0000	-4.092547

*為10%顯著水準；**為5%顯著水準；***為1%顯著水準

(資料來源:本研究整理)

2、模型判定

經過自然對數轉換及一階季節差分後，資料變異呈穩定狀態且季節性趨勢已消除，季節差分參數 $D=1$ ，故本研究所選用之時間序列模式為季節性 $ARIMA(p,d,q)(P,D,Q)_s$ 。由於本研究資料型態為以年為週期之月資料，故週期 $s=12$ 。

由於季節性 $ARIMA$ 模式須估計 p 、 q 和 P 、 Q 等參數，而為了避免人為判斷的缺失，本研究採用試誤法來求得較佳的 p 、 q 及 P 、 Q 值，其階次均估計至 3 期。

3、參數估計

本研究利用 gret 1 軟體進行參數之顯著性估計。若所估計的模式參數不顯著，則予以刪除。本研究經過初步估計的結果，共有七組候選模式符合標準，如表 4.3 所示。

表 4.3 季節性 ARIMA 模式之參數估計試誤結果

ARIMA(p,d,q)(P,D,Q) _s	AIC	SBC
(1,0,0)(0,1,1)	-15.52136	-6.414696
(2,0,0)(0,1,1)	-17.25912	-5.875786
(3,0,0)(0,1,1)	-23.49565	-9.835649
(0,0,1)(0,1,1)	-12.41054	-3.303873
(0,0,2)(0,1,1)	-25.91351	-14.53018
(2,0,1)(0,1,1)	-18.81586	-5.155860
(2,0,2)(0,1,1)	-26.97866	-11.04200

(資料來源:本研究整理)

4、模式判斷與檢驗

針對上述之七組候選模式，以 Ljung-Box Q 統計量檢定殘差項是否具有自我相關的現象，並利用 Jarque-Bera 統計量檢定殘差項是否符合常態分配。本研究利用 gret1 軟體檢定結果如表 4.4 所示，共有兩組模式符合殘差項無自我相關且呈常態分配之標準。

表 4.4 殘差自我相關性及常態分配檢定結果

ARIMA(p,d,q)(P,D,Q) _s	殘差無自我相關	殘差呈常態分配
(1,0,0)(0,1,1)	不符合	不符合
(2,0,0)(0,1,1)	不符合	不符合
(3,0,0)(0,1,1)	不符合	符合
(0,0,1)(0,1,1)	不符合	符合
(0,0,2)(0,1,1)	符合	不符合
(2,0,1)(0,1,1)	符合	符合
(2,0,2)(0,1,1)	符合	符合

(資料來源:本研究整理)

5、模式選取

經過殘差檢定後之候選模型有二個，而進一步利用 AIC 及 SBC 準則來決定最適模型，若 AIC 和 SBC 值愈小，則代表模型的配適度越佳。其結果整理如表 4.5 所示，無論在 AIC 與 SBC 準則上皆顯示 ARIMA(2,0,2)(0,1,1) 模型較佳，而由圖 4.4 及圖 4.5 亦證實此模型殘差已無自我相關及殘差符合常態分配之基本假設。故本研究即選用 ARIMA(2,0,2)(0,1,1) 模型做為最適模式，進行澎湖國家風景區樣本外遊客量之預測。

表 4.5 候選模型及評估指標

ARIMA(p,d,q)(P,D,Q) _s	AIC	SBC
(2,0,1)(0,1,1)	-18.81586	-5.15586
(2,0,2)(0,1,1)	-26.97866	-11.04200

(資料來源:本研究整理)

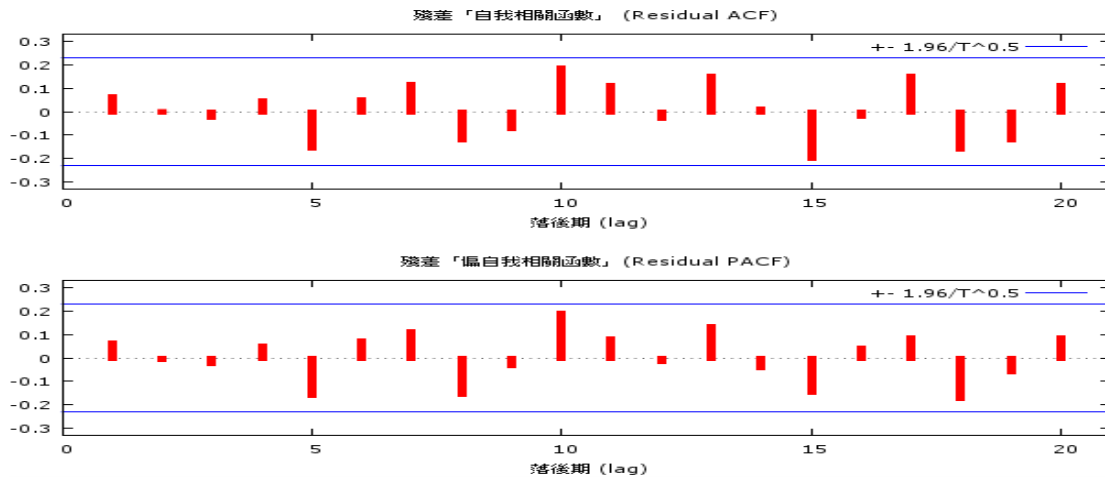


圖 4.4 殘差自我相關圖(資料來源:本研究整理)




圖 4.5 殘差常態性檢驗圖(資料來源:本研究整理)

4.3 迴歸分析

本研究採用迴歸分析之最佳子集合迴歸模式，對本研究選擇之十個影響遊客量變數(氣溫、雨量、相對濕度、降水日數、日照時數、消費者物價指數、美元兌台幣匯率、失業率、景氣領先指標及大陸來台觀光人數)進行變數篩選。本研究以樣本內十個影響遊客量之變數資料當作自變數，並以澎湖國家風景區樣本內遊客量作為依變數，期能藉由估算所有可能之迴歸模式的績效值(R-Square)，相互比較後，選取績效最佳之迴歸變數組合，達到篩選變數的效果。

本研究之最佳子集合迴歸模型包含最少 1 個最多 10 個的影響變數，並分別只展示最佳(best)的變數組合模型以進行分析。其結果如圖 4.6，可發現當變數個數為六個時，修正後之判定係數值(adjusted R-Square)最佳，高達到 84.7%，其所選取之變數組合為氣溫、相對溼度、降水日數、日照時數、失業率及景氣領先指標。因此，本研究即挑選此六個顯著影響澎湖國家風景區遊客量之變數，作為後續模型分析與預測之用。

Vars	R-Sq	R-Sq(adj)	氣溫	雨量	相對溼度	降水日數	日照時數	消費者物價指數	匯率	失業率	景氣領先指標	大陸來台觀光人數
1	66.9	66.4	X									
2	77.1	76.4	X		X							
3	80.4	79.5			X		X					X
4	84.6	83.7	X		X		X			X		
5	85.6	84.5	X		X	X	X			X		
6	86.0	84.7	X		X	X	X			X	X	
7	86.2	84.6	X		X	X	X			X	X	X
8	86.2	84.4	X		X	X	X	X		X	X	X
9	86.2	84.2	X	X	X	X	X	X		X	X	X
10	86.2	83.9	X	X	X	X	X	X	X	X	X	X

圖 4.6 最佳子集合迴歸變數組合結果(資料來源:本研究整理)

4.4 倒傳遞類神經模型建構與分析

類神經網路為擁有三項優於統計經驗模式的特性及能力，分別為適應性學習、回想過程及過濾能力，藉此三項特性來改變它的行為模式及修正輸入與輸出的關係，因此本研究採用倒傳遞類神經網路模式，以篩選後之六個顯著影響澎湖風景區遊客量之因素為自變數，而時間序列ARIMA模式之預測誤差為依變數，來預測樣本外資料可能的誤差值，以期能對本研究所建立之時間序列ARIMA模型進行誤差的修正。

倒傳遞類神經網路之運作方式如下圖4.7所示

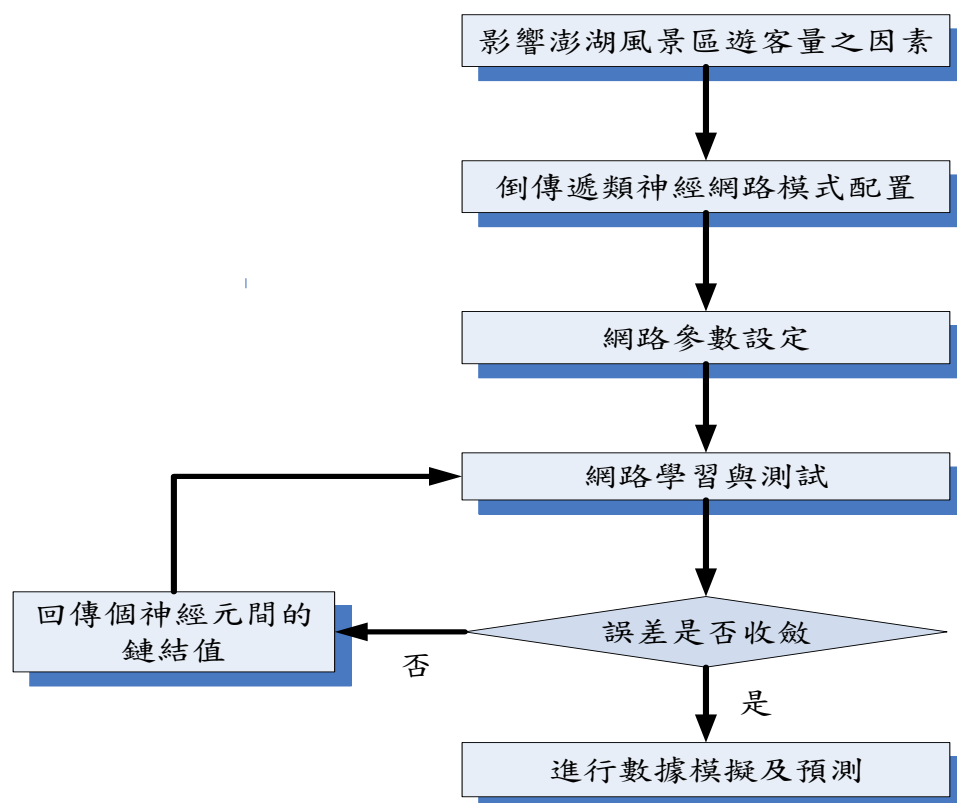


圖 4.7 倒傳遞類神經網路運作流程圖(資料來源:本研究整理)

1. 模型輸出入變數的決定

本研究所採用之輸入變數為顯著影響澎湖遊客量之因素，分別為氣溫、相對溼度、降水日數、日照時數、失業率及景氣領先指標等六項變數，而輸出變數為時間序列ARIMA模型之樣本內誤差。

2. 選取隱藏層層數與神經元數目

通常隱藏層之數目為一層到二層時有最好的收斂性質，而對於大部分實際的問題來說，使用一層的隱藏層就已足夠。故本研究採取一層隱藏層之網路架構。而在隱藏層神經元數目方面，則採用一般算數平均數

法求得，即得 $(6+1)/2=3.5$ 個，本研究乃設定為4個神經元數目。

參數設定

本研究採用MATLAB 7.0應用軟體提供之Neural Network Toolbox模組進行倒傳遞類神經網路預測模型之建構與訓練。在BPN網路模型隱藏層與輸出層內之轉換函數皆採用正切雙彎曲函數，允許輸入變數與輸出變數間的非線性關係，並使網路輸出產生範圍在-1和1之間，因此在輸出變數上本研究必須先對其進行尺度化動作，使其範圍落在-1和1之間，其尺度化公式如下。

$$x = \frac{X - \mu}{k\sigma} \quad (4.4.1)$$

其中 μ =尺度化前輸入變數的平均值; σ =尺度化前輸入變數的標準差; k =尺度化參數; X =尺度化前輸入變數的值; x =尺度化後輸入變數的值。而正切雙彎曲函數在MATLAB7.0之Neural Network Toolbox模組中所使用的指令為tansig。

而在訓練演算法方面，由於典型的倒傳遞訓練演算法容易收斂至局部最小值(Local Minima)且權值更新速率慢，學習時間長，另外，可能造成發散結果【27】。然而，目前類神經網路軟體工具箱已提供了許多高速率的演算法，因此本研究採用模組所提供快速訓練演算法Levenberg-Marquardt法，直接進行倒傳遞網路模型訓練，在Neural Network Toolbox模組中所使用的指令為trainlm，其訓練參數說明如表4.6所示。

本研究利用MATLAB7.0應用軟體之Neural Network Toolbox模組進行倒傳遞類神經網路模型建構。依上述建構流程，配置之倒傳遞類神經網路模型包括輸入層、單層隱藏層和輸出層。其中，設定輸入層共6個處理單元(即六個輸入變數)、單層隱藏層共4個處理單元，和輸出層為1個處理單元(即一個輸出變數)。而在隱藏層與輸出層部分皆設定為非線性正切雙彎曲函數(MATLAB 7.0所使用的指令為tansig)來計算該層神經元的輸出。而本研究配置之倒傳遞類神經網路架構如圖4.8所示：

表 4.6 類神經網路訓練參數設定表

訓練參數	內定值	描述
net.trainParam.epochs	1000	設定訓練的最大循環次數。
net.trainParam.goal	0	設定性能目標
net.trainParam.max_fail	5	設定最大驗證數據失敗次數
net.trainParam.mem_reduc	1	用於降低記憶體需求量的係數
net.trainParam.min_grad	1e-10	設定最小性能梯度
net.trainParam.mu	0.001	設定動量 μ 的初始值
net.trainParam.mu_dec	0.1	設定動量 μ 的減少係數
net.trainParam.mu_inc	10	設定動量 μ 的增加係數
net.trainParam.mu_max	1000000000	設定動量 μ 的最大值
net.trainParam.show	25	設定每隔多少訓練循環數目就顯示
net.trainParam.time	Inf	設定最大的訓練所需時間，單位為秒

(資料來源：本研究整理)

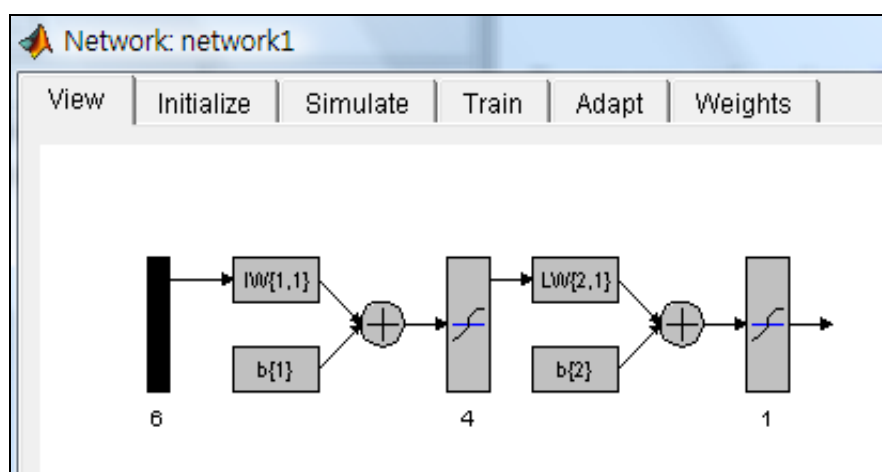


圖4.8 倒傳遞類神經網路架構圖(資料來源:本研究整理)

本研究進一步利用模組中快速訓練演算法Levenberg-Marquardt訓練法進行資料之訓練，其各網路參數設定如上述介紹，而經過1000次訓練結果可顯示訓練誤差已達收斂效果，如圖4.9所示，顯示本研究配置之倒傳遞類神經網路模型建構得宜。




圖 4.9 倒傳遞類神經網路訓練結果圖(資料來源:本研究整理)

因此本研究即採用此模型對於樣本外之資料(2008/1至2009/12共24筆)進行其誤差之預測。

4.5 模型之驗證與比較

本研究採用一結合時間序列 ARIMA 及類神經網路之預測模式，並利用迴歸分析(最佳子集合迴歸)進行變數的篩選。本研究先利用時間序列 ARIMA 模式對澎湖國家風景區遊客量進行預測，於蒐集預測誤差後，將其與篩選後之影響變數投入倒傳遞類神經網路中，進行誤差的預測，最後再將所預測之誤差值與時間序列 ARIMA 之預測值相加，藉此建立誤差修正模式。本研究所採用的樣本內資料為 2001 年 1 月至 2007 年 12 月共 84 筆資料，以此資料進行時間序列之建模以及倒傳遞類神經網路之誤差預測建模後，再對樣本外資料 2008 年 1 月至 2009 年 12 月進行驗證。驗證方式則採用 MSE 值、RMSE 值、Theil's U 值以及 MAPE 值進行比較，其結果整理如表 4.7 所示。

表 4.7 不同預測方法之績效比較表

	MSE	RMSE	Theil's U	MAPE
時間序列 ARIMA 模型	29601673	5440.742	0.0526	0.08175
ARIMA-BPN (未篩選變數)	158400931	12585.740	0.1156	0.17907
ARIMA-BPN (篩選變數後)	30194234	5494.928	0.0533	0.07895

(資料來源:本研究整理)

由上表 4.7 可得之，篩選變數後之 ARIMA-BPN 模式之績效指標 MAPE 值最低，而時間序列模型則在績效指標 MSE、RMSE 及 Theil's U 之值最低，但由於 MAPE 具有整合不同衡量指標的最佳特質，評估不同模型預測能力應以 MAPE 為準則，因此於三者模型中，以篩選變數後之 ARIMA-BPN 模式之預測準確度最佳，單一時間序列 ARIMA 模式次之，而未篩選變數之 ARIMA-BPN 模式預測能力則有較差的表現。另外，由於時間序列 ARIMA 模型及篩選變數後之 ARIMA-BPN 模型之 MAPE 值皆小於 10%，故可得知兩者模型於遊客量的預測上，皆可達到預測精確的效果，而以下圖 4.10 亦顯示，兩者模型確實有較未篩選變數之 ARIMA-BPN 模型更貼近真實值的數列分布。




圖 4.10 不同模型之預測值序列比較圖(資料來源:本研究整理)

4.6 預測模型於遊憩區域之應用

澎湖國家風景區依遊憩區域之不同可將其分為馬公本島遊憩系統、北海遊憩系統及南海遊憩系統三大部份，其中馬公本島為遊客出入澎湖國家風景區之要塞，因此本研究進一步針對馬公本島遊憩系統之遊客量，以相同之樣本數及投入變數，對本研究所建構之預測模式之適用性進行分析與探討。

本研究針對澎湖風景區之馬公本島遊憩系統遊客量進行預測。初步利用盒形圖進行離群值偵測與處理後，將遊客量資料以時間序列 ARIMA 模式進行建構與配適。經過參數之顯著性估計、殘差自我相關檢定及殘差常態分配檢定後，其候選模型整理如下表 4.8 所示，並利用 AIC 和 SBC 最小值作為模型評估準則，結果顯示 ARIMA(3,0,3)(1,1,1)及 ARIMA(1,0,0)(1,1,1) 為較佳模型，而本研究採用 SBC 值最小作為模型選取標準，故最終選用 ARIMA(1,0,0)(1,1,1)模型做為可能最適模式，並進行預測。另外，藉由迴歸分析(最佳子集合迴歸)方法對馬公本島遊客量進行顯著影響之變數的篩選結果如下圖 4.11 所示，因此本研究即挑選修正後之判定係數(R-Square(adj)) 最高之五個變數組合，即氣溫、相對溼度、降水日數、日照時數和失業率，作為影響馬公本島遊憩系統遊客量之變數。

表 4.8 馬公本島遊憩系統候選模型及評估指標

ARIMA(p,d,q)(P,D)	AIC	SBC
(1,0,0)(1,1,1)	91.6865	104.5082
(0,0,2)(1,1,1)	94.2666	109.6527
(3,0,3)(1,1,1)	90.2170	115.8605

(資料來源:本研究整理)

Vars	R-Sq	R-Sq(adj)	氣溫	雨量	相對溼度	降水日數	日照時數	消費者物價指數	匯率	失業率	景氣領先指標	大陸來台觀光人數
1	42.99	42.1	X									
2	61.99	60.8	X							X		
3	67.5	66.0	X							X		
4	70.1	68.4	X		X					X		
5	72.2	70.1	X		X		X			X		
6	72.5	70.0	X		X	X	X			X		X
7	72.99	70.0	X	X	X	X	X			X		X
8	73.3	70.0	X	X	X	X	X	X		X		X
9	73.6	69.8	X	X	X	X	X	X	X	X		X
10	73.6	69.3	X	X	X	X	X	X	X	X	X	X

圖 4.11 馬公本島遊憩系統最佳子集合迴歸變數組合結果
(資料來源:本研究整理)

將蒐集之時間序列 ARIMA 的預測誤差值和篩選後之五個影響遊客量之變數投入類神經網路模式中進行誤差之預測，以建立誤差修正模式。其不同模型之預測績效如表 4.9 所示，其結果顯示於馬公本島遊憩系統遊客量之預測模式中，以篩選變數後之 ARIMA-BPN 模型最佳，單一時間序列 ARIMA 模式次之，而未篩選變數之 ARIMA-BPN 模式的預測績效最差。而由圖 4.11 亦顯示篩選變數後之 ARIMA-BPN 模型較其兩者模型更接近真實值。

表 4.9 馬公本島遊憩系統之不同預測方法之績效比較表

	MSE	RMSE	Theil's U	MAPE
時間序列 ARIMA 模型	13796679	3714.388	0.1218	0.3250
ARIMA-BPN (未篩選變數)	20035857	4476.143	0.1425	0.4078
ARIMA-BPN (篩選變數後)	6018710	2453.306	0.0831	0.2615

(資料來源:本研究整理)




圖 4.12 馬公本島遊憩系統之不同模型預測值序列比較圖
(資料來源:本研究整理)

第五章 結論與建議

5.1 研究結論

國家風景區設置目的為提供遊客自然觀光資源，達到休閒遊憩的功能，而澎湖國家風景區無論在海洋景觀或人文歷史資源上皆蘊藏無窮寶藏，但由於旺季大量遊客的湧入，導致周邊相關產業規劃不及應付，使得旅遊品質粗糙。因此建立一遊客預測模式，以因應外在環境之變化及本身遊憩資源的供給與分配，對於國家風景區的經營管理，有其絕對的重要性。

遊客量預測相關文獻中，主要可分為定性方法與定量方法兩種，定性預測方法主要使用非數學的方式，依賴判斷、直覺及主觀性的評價，往往缺乏數學模式之驗證，容易流於不客觀，如德爾菲法。而定量預測方法則偏重於數學模式的應用，依據過去的歷史資料或因果變數來建立預測模式，較為客觀。另外，過去部份遊客量預測較多採用單一方法之比較，如此可能會遺漏某些重要之訊息，因此本研究採取量化預測方法，提出一結合時間序列 ARIMA 與類神經網路之預測模型，期望能將遊客量資料線性與非線性之關係同時納入考慮，達到更精確的預測績效，提供澎湖國家風景區及其他國家風景區於經營管理上之參考。

本研究即採用 2001 年 1 月至 2009 年 12 月之澎湖國家風景區遊客量進行分析。本研究於進行預測模式建立前，先進行離群值的偵測與處理，並利用兩個季節性相鄰觀測值取其平均值來取代離群值。接著將離群值處理後遊客量分為樣本內資料以及樣本外資料，根據樣本內資料，以時間序列 ARIMA 模型進行預測，形成一組預測值，並與實際值比較計算誤差，將之投入類神經網路作為預測標的。另外，利用迴歸分析(最佳子集合迴歸)將影響遊客量之十個變數針對澎湖國家風景區遊客量進行變數篩選，並將篩選後之六個變數投入類神經網路中進行學習，根據建立之模型進行樣本外資料誤差之預測，最後與時間序列 ARIMA 模式之樣本外預測值進行相加達到誤差修正的效果。

本研究實證結果顯示，於澎湖國家風景區遊客量之預測模型中，以篩選變數後之 ARIMA-BPN 結合模式的預測績效最佳，單一時間序列 ARIMA 模型次之，而未篩選變數之 ARIMA-BPN 結合模式則出現較差的預測準確度。另外，由於時間序列 ARIMA 模型及篩選變數後之 ARIMA-BPN 模型

之 MAPE 值皆小於 10%，故可得知兩者模型於遊客量的預測上，皆可達到預測精確的效果。

此預測結果顯示若將處理線性關係之時間序列模式和處理非線性關係之類神經網路模式進行結合，並利用迴歸分析進行影響遊客量之變數篩選，其預測績效優於單一預測方法；但若未進行變數篩選的動作，則可能造成預測績效較單一方法為差的結果。

本研究更進一步將預測模型應用於馬公本島遊憩系統之遊客量預測，其結果亦顯示篩選變數後之 ARIMA-BPN 結合模式有最佳的預測效果，而以單一時間序列 ARIMA 模型次之，未篩選變數之 ARIMA-BPN 結合模式預測績效最差。

5.2 未來研究建議

本研究所建立之預測模式，雖於澎湖國家風景區遊客量之資料範圍內驗證得到良好的預測績效，但對於未來之研究仍有許多延伸發展及不同領域之研究方向可供研究者作為參考，本研究整理如下：

1. 本研究僅針對澎湖國家風景區遊客量進行預測，未來研究可進一步延伸至其他國家風景區或各地遊憩景點之遊客量進行預測。
2. 有鑒於政府於2008年7月全面開放大陸客來台，對台灣各地之遊憩景點遊客量勢必造成衝擊，故建議未來研究者之研究資料蒐集可以陸客來台為始，藉由預測模式的建立，以探討陸客來台後之遊客量變化。
3. 本研究僅針對大環境之氣候、經濟及外在遊客因素來對澎湖風景區之遊客量進行修正，並無考慮其餘較細部的影響變數。未來研究可試著加入其他影響變數，如船運或航空班次等。
4. 本研究針對台灣國家風景區進行一結合預測模式之適用性探討，未來研究可將其類似預測模型，針對不同性質、不同領域之產業進行驗證比較。
5. 本研究採用時間序列ARIMA和倒傳遞類神經網路之結合模式進行預測，並利用迴歸分析(最佳子集合迴歸)方法篩選影響變數，未來研究者可根據本研究之預測模式，嘗試以不同預測方法進行結合來進行預測驗證，或以不同之組合方式建立預測模型，以期獲得更佳之預測績效。

參考文獻

一、中文部份

- 【1】 利秀蘭、陳惠薇，2005。台灣景氣領先及同時指標之探討，經濟研究。
- 【2】 李英弘、林宗賢、黃智彥、李素馨，2009。澎湖國家風景區遊客調查，旅遊人次暨產值推估模式規劃，交通部觀光局澎湖國家風景區管理處。
- 【3】 李維貞，2005。生活型態、環境偏好對於遊客住宿基地選擇之影響-以廬山溫泉、清境溫泉為例。靜宜大學觀光事業學系暨研究所碩士論文，未出版，台中。
- 【4】 李飛、白豔萍，2007。BP 網絡對山東省國內旅遊市場的分析預測，中北大學學報，自然科學版，第二十八卷第五期。
- 【5】 李銘輝、郭建興，2000。觀光遊憩資源規劃，揚智文化，初版，305-325。
- 【6】 吳守從、陳建璋，2009。應用灰色理論探討墾丁國家公園遊客數量變化，人文社會科學研究，第三卷第二期，149-169。
- 【7】 吳佳穎，2007。台灣國家公園遊客人數預測模式之研究，東海大學工業工程與經營資訊研究所碩士論文。
- 【8】 林茂文，2006。時間數列分析與預測，華泰書局。
- 【9】 吳柏林，1995。時間數列分析導論，華泰書局。
- 【10】 林倉龍，2004，國家級風景特定區遊客人數預測之研究，朝陽科技大學休閒事業管理系研究所碩士論文。
- 【11】 林晏州，1998，澎湖風景特定區遊客調查暨旅遊人次推估，中華民國戶外遊憩學會，台北。
- 【12】 林晏州、林寶秀、曾柏瑋、林庭如，2007。日月潭國家風景區之遊客量推估。第四屆台灣地方鄉鎮觀光產業與前瞻學術研討會論文集。
- 【13】 施瑞賢，2002。來華觀光旅客人數需求預測之研究，朝陽科技大學休閒事業管理系研究所碩士論文。
- 【14】 涂三賢、吳萬益、林俊成、任憶安，1999，台灣地區國有森林遊樂區遊客人數與營收變動之分析，1990-1998，戶外遊憩研究，第十二期，第四卷，61-72。
- 【15】 高珮詩，2009。天氣造成遊客壓力與調適行為之研究-以阿里山國家森林遊樂區為例，中興大學森林學系研究所碩士論文。
- 【16】 陳宗玄、施瑞峰，2001。臺灣國際觀光旅館國人住宿率預測之研究，朝陽學報，6 卷，429-452。
- 【17】 陳佳聖，2007。台灣自然保護區面面觀－國家公園 VS.國家風景區，台灣國家公園專欄愛戀公園誌。
- 【18】 陳淑女，2001。陽明山國家公園遊客量之預測-以時間數列模式（ARIMA）分析法，育達研究叢刊，第二期，103-115。
- 【19】 張翊峰、張淑美、張家鳳、林建廷、余元傑，2008。台灣地區溫泉旅遊之生態承

載量分析-以高雄縣寶來、不老溫泉區為例，嘉南學報第三十四期，319-330

- 【20】張盛鴻等譯，2000。生產計畫與管理，二版二刷。，高立出版。譯自 Fogarty Blackstone Hoffmann 1991.Production & Inventory Management 2/e.
- 【21】張斐章、張麗秋，2005，類神經網路，初版，東華書局。
- 【22】陳耀茂(譯)，2009。時間序列分析的 SPSS 使用手冊，一版二刷，台北市，鼎茂圖書。原著石村貞夫。
- 【23】葉怡成，2006。類神經網路模式應用與實作，八版四刷，儒林圖書。
- 【24】葉怡成，2009。類神經網路模式應用與實作，九版一刷，儒林圖書。
- 【25】雷可為、方田紅，2009。基於組合模型的陝西省旅遊市場需求預測，西北師範大學學報，自然科學版，第四十五卷第二期。
- 【26】楊奕農，2006。時間序列分析經濟與財務上之應用，初版三刷，雙葉書廊。
- 【27】趙景明、梁淑芳，2006。導入 LM 法之平行倒傳遞演算法，資訊管理展望，第八卷第二期。
- 【28】鄭天澤、李旭煌，1995，台灣地區出國觀光旅客需求預測模式之比較分析，政治大學學報，第 71 期，179-210。
- 【29】聶建中、周明智，2002。影響來台旅遊人數及觀光外匯收入總體變數決定因素之研究，管理學報，第十九卷第三期。
- 【30】羅華強，2005。類神經網路:MATLAB 的應用，二版，高立圖書。

二、英文部份

- 【31】 Alfonso Palmer, Juan Jose Montano, and Albert Sese, 2006. Designing an artificial neural network for forecasting tourism time series, *Tourism Management*, **27**, pp.781-790.
- 【32】 Bates J. M., Granger C. W. J., 1969. The Combination of Forecasts, *Operational Research Quarterly*, **20**, pp.451-468.
- 【33】 Blackwell, R.D., Miniard, P. W., & Engel, J. F., 2001. *Consumer behavior* (9th ed.).NY: Harcourt.
- 【34】 Chu Fong-Lin, 1998. Forecasting tourism demand in asian-pacific countries, *Annals of Tourism Research*, **25**, pp.597-615.
- 【35】 Enders, W., 2004. *Applied Econometric Time Series* (2nd ed), Hoboken, NJ: Wiley.
- 【36】 Funahashi, K. (1989). On the approximate realization of continuous mappings by neural networks. *Neural Networks*, **2**, pp.183 – 192.
- 【37】 Granger, C. and Newbold, P., 1974. Spurious regression in econometrics. *Journal of Econometrics*, **2(2)**, pp.111-120.
- 【38】 Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, **2(5)**, pp.359 – 366.
- 【39】 Hu, Y., & Ritchie, J.R. B., 1993. Measuring destination attractiveness: A contextual approach. *Journal of Travel Research*, **32(2)**, pp.25-34.
- 【40】 James T. Luxhoj, Jens O. Riis, Brian Stensballe, 1995. A Hybrid Econometric-Neural Network Modeling Approach for Sales Forecasting. *Int. J. Production Economics*, **43**, pp.175-192.
- 【41】 Jiang and Lee, 2007. Tourist Arrival Forecasting Using Artificial Neural Networks, *Journal of Kaohsiung Hospitality College*, **9**, No.1.
- 【42】 Lewis, C.D., 1982. *International and Business Forecasting Methods*, London: Butterworths.
- 【43】 Ljung, G.M., and Box, G.E.P., 1978. On a measure of lack of fit in time series model. *Biometrika*, **65**, pp.297-304.
- 【44】 Makridakis, S., 1993, Accuracy measures: theoretical and practical concerns, *International Journal of Forecasting* , **9(4)**, pp.527-529.
- 【45】 Pankratz, A., 1983. *Forecasting with univariate Box-Jenkins method*. NY:Wiley.
- 【46】 Robert F. Engle and C. W. J. Granger., Co-Integration and Error Correction: Representation, Estimation, and Testing, *Econometrica*, **55**, No.2, pp.251-276.
- 【47】 Said E. Said and David A. Dicky, 1984. Testing for Unit Roots in Autoregressive -Moving Average Models of Unknown Order, *Biometrika*, **71**, No.3, pp.599-607.
- 【48】 Sheldon Pauline J. and Var Turgut, 1985. Tourism forecasting: a review of empirical research, *Journal of Forecasting*, **4**, pp.183-95.
- 【49】 Vincent Cho, 2003. A comparison of three different approaches to tourist arrival forecasting, *Tourism Management*, **24**, pp.323-330.
- 【50】 White, H., 1992. Learning and Statistics, in H. White(Ed.), *Artificial Neural Networks:*

Approximations and Learning Theory. Blackwell, Oxford, UK.

三、網站部份

【51】澎湖國家風景區網站，<http://www.penghu-nsa.gov.tw/>