

飯店住宿率之預測績效-以 A 飯店為例

Predictive Performance Evaluation of Hotel Accommodation Rate: A Case Study of Hotel A

連春紅¹

崑山科技大學 全球商務與行銷系 副教授

jflee@nkust.edu.tw

李政峯²

國立高雄科技大學 企業管理系 教授

chlien@mail.ksu.edu.tw

鄞湘育³

國立高雄科技大學 企業管理系碩士在職專班 研究生

J107257126@nkust.edu.tw

摘要

觀光業是經濟成長的重要驅動力，可創造許多就業機會。旅館住宿是構成觀光業的重要成分之一，然因住宿需求易受國家政策和經濟景氣的影響，產生較大的波動，使得需求預測不是一件容易的工作。若能準確預測住宿需求，將可降低飯店經營的風險，創造較大的利潤。

本文企圖尋找最準確的預測模型，以供A飯店住宿需求的預測。我們應用時間數列模型(ARIMA與ETS)，與AI人工智慧模型(ANN與SVR)，分析A飯店每日的住宿人數，期間由2015年1月1日至2019年12月31日止，共1826個觀察值；再以RMSE和SMAPE兩種指標來評估模型的預測準確度。預測結果顯示，整體而言，AI模型的預測能力普遍優於時間數列模型；以RMSE來說，ANN與SVR的值相當接近，優於ARIMA模型，但略高於ETS；若從SMAPE來看，AI模型的預測表現仍優於傳統模型，且SVR的準確度高於ANN，而在傳統模型中，ETS依舊表現得比ARIMA來得好。最後，根據預測準確度最佳的模型，對2020年的住宿人數進行事前預測，據以得到可行的建議，提供實務上管理飯店之用。

關鍵詞：ARIMA、ETS、人工智慧、預測績效評估。

Keywords：ARIMA, ETS, artificial intelligence, forecast evaluation.

1.緒論

1.1 研究背景

「觀光產業」是目前各國最具社會經濟指標的產業之一。根據「世界觀光旅遊委員會」(WTTC)的研究，2017年觀光產業佔全球GDP的10.4%，並預估全球旅遊支出以每年3.8%的成長率且在未來10年穩定增加至12.45兆美元(交通政策白皮書第六章觀光政策，2019)。隨著各國陸續推出有利的入境政策、網路發展推動資訊的普及與全球經濟成長等因素，旅遊業的成長動能不容小覷。

台灣是一個海島型氣候的島嶼，天然資源相對有限，如需發展需要由許多資源支持的產業，相對並非容易，而台灣獨特景色及民俗文化是發展觀光產業的特色之一。觀光發展需要長期規劃投入許多的相關建設，並保持政策的延續方可完成。為增加台灣旅遊市場熱度，觀光局也結合兩地旅遊業者，並整合觀光資源推出相關旅遊促銷商品，以深度旅遊及樂活台灣為主軸，開發更多來台新旅遊路線，並不斷以廣告方式增加旅遊台灣曝光度。

依據觀光局(2019)發布的最新來台旅客消費及動向調查，就台灣市場而言，在2011年造訪台灣的觀光客約550萬人次，其中以中國大陸旅客為最多，其次為日本旅客，第三大旅客來源則為近三年受益於航線增加的東南亞區域，排名第四的則是港澳的旅客，第五則是來自美洲的觀光客。以各國來台旅客的購物消費力來看，中國客平均每人每日消費96.30美元，較排名第二的港澳遊客多出九成六，與排名第三的新加坡相比，更足足多出一倍，日本則位居第四(TTR台灣趨勢研究：產業分析：旅行業發展趨勢，2019)。

- 一、近年來受兩岸政策影響來台人數降低導致南部經濟受重創。為舒緩陸客減少的壓力，政府鼓勵東南亞人民來台灣旅遊，以及後來的暖冬補助，對觀光產業有不小的助益。
- 二、面對未來，隨著全球創新科技及共享經濟的發展趨勢，台灣在各項觀光政策規畫及執行均須因應旅遊趨勢轉變與時俱進，才能掌握商機與世界接軌，並且需要政府持續與觀光產業密切妥善溝通，聆聽各界的聲音，尋求最適方案，以開創新興商機。
- 三、在受到兩岸政策影響來台人數降低導致南部經濟受重創。交通部觀光局數據(2019)顯示，高雄的飯店2015-2018年來減少銷售約10萬間客房，甚至新開的高檔飯店，房價打對折還是門可羅雀。
- 四、就A飯店而言，自從民國86年營業自今，雖為老牌飯店，但在陳設上並不簡陋，也有在做不定期修繕、維護，可面對環境上影響，新飯店不斷增加，導致在經營上的困難點。
- 五、許多老舊旅社在本身特色不足、傳統家庭式管理、經營不善的情況下，面對住房率下滑、景氣波動等壓力下，加上近年來新型設計旅店快速崛起，許多由企業集團投資的文創產業、特色旅館，也面臨來自國外的旅館經營業者進入競爭範圍，擠壓到現有市場，且面臨市場變化大，入不敷出的業者不在少數，許多老舊旅社進行拋售，結束營運以將房地產改做其他用途。如何在經營上決策出適切的營運需求規劃，影響著飯店的存亡(楊衍邦，2018)。

1.2 研究動機

- 一、觀光產業易受政治、經濟、疾病、季節等等眾多因素影響，使得價格隨著季節及供需不停變動。這些眾多不可知的因素，往往影響到國家經濟發展、觀光業者的生存以及員工的就業權利。
- 二、住宿是觀光產業的最基本需求，住宿的演化從早期的民宿至現在的星級飯店，都是為了滿足消費市場需求。此外，資訊科技的進步，更加速了飯店的市場需求，間接促使飯店產業在項目開發上持續升級與推陳出新。從旅遊消費行為得知，飯店住宿是觀光休閒旅遊中最基本的一項消費活動，也是跨區旅遊中的剛性需求。
- 三、由於飯店業是屬於服務性的事業，其產業具備一些特殊的經濟特性。飯店經營管理需考量的除了旅館軟、硬體，外在周遭環境及整體經濟景氣，皆需要專業團隊審慎評估各項條件，方能有效引領經營者做最高效益的決策。
- 四、從觀光產業鏈中的供需比重來看，最直接連動，受惠及受傷的為飯店業、航空業、汽車出租、及旅行服務。其中飯店是受到最直接衝擊，餐飲業則受到選擇性多樣化影響，受到衝擊程度較小。
- 五、就A飯店而言，是屬於老字號的知名飯店座落於高雄商業區，在地經營已約25年，喜新厭舊是人之常情，時常反射於生活上，對飯店業者來說，不是每幾年重新大整修，或者大幅升級硬體設備即能改變，也要考量環境因素，在面對市場的趨勢也使飯店需有經營上的考量。
- 六、以A飯店來說精準住宿需求預測，對於飯店經營風險的管控，有莫大的助益。尤其是，空房管控、人員配置、飯店硬體品質維護、以及客源開發等等問題，都需要靠足夠的住宿需求數據來解決所有經營的相關問題，並面對同業的競爭。

1.3 研究目的

若能正確預測出住宿需求，即能評估出所需旅館房間數、餐飲供需求、觀光人才需求量、資金調配計畫、以及建築維修工程排程計畫。瞭解上述各項需求後，即能做好規畫。

本研究之研究目的如下：

- 一、建立適合A飯店住宿需求預測模型，以過去的A飯店住宿需求變化趨勢預測模型來建立住宿需求預測模式。
- 二、使用時間數列預測方法與AI人工智慧的預測方法來預測飯店的住宿需求，並比較各模型的預測準確度，本研究所用之預測工具有：指數平滑法(Error Trend Season, ETS)、差分自我迴歸移動平均模型(Autoregressive Integrated Moving Average Model, ARIMA)、類神經網路(Artificial Neural Network, ANN)、及支持向量迴歸(Support Vector Regression, SVR)。
- 三、藉由住宿需求預測成果參考數據，作為飯店經營管理之依據決策，以提供A飯店所面臨的困境之參考。

2.文獻探討

2.1 觀光產業與旅館業概況

2.1.1 旅館

是一種非常古老的行業，據資料可查約2千年前就有客棧的存在，而成為20世紀現代的一種「旅館工業（hotel and travel industry）」。（潘朝達1980）。依學者見解，旅館一詞含有提供旅客住宿的設施、餐飲、及其他相關服務、且是以營利為目的之一定設施等要素（陳宗玄、張瑞琇, 2008）。發展迄今旅館事業更有「旅遊工業」的代稱（hotel and travel industry、或稱hospitality industry），今日旅館業所提供產品、服務的內涵，已可結合日常生活所需的住宿、餐飲、乃至特殊休閒設備例如健身、養生或其他遊憩設備及服務。

台灣旅館業之發展，應可分為：發軔時期（民國45-52年）、奠基時期（民國53-65年）、大型化國際觀光旅館時期（民國66-78年）、連鎖時期（民國79-88年）與特色品牌經營時期（民國89年至今）五個階段（陳宗玄、張瑞琇, 2008）。

2.1.2 旅行社

依觀光發展狀態，也漸漸地發展出旅行業，在我國旅行業的分類，係以其經營能力、資本額及經營的業務範圍作為分類的依據。根據我國「旅行業管理規則」第二條規定：旅行業區分為綜合旅行業、甲種旅行業及乙種旅行業三種。旅行活動之各單項業務，都是商業上的行為，例如：交通工具的安排或是票務，旅館的住宿與每日三餐的安排，觀光景點的參觀介紹等都是，但是透過旅行業的穿針引線，所有事務都組成了活動體。

2.1.3 觀光旅遊的發展

由於網路時代的來臨，應用網際網路的操作，顧客即可輕易地獲得旅遊產品的資訊，旅客選擇決定前往某一地區旅遊除了考慮預算、可用的時間、同行的夥伴等因素外，景點的名氣往往是關鍵的因素。台灣地區休閒發展的趨勢研究中發現，許多類型的天然資源都可作為吸引力的景點，如海岸、海洋、自然景觀、山地、森林等，當旅客被吸引前往時，可以對其主要的特色做介紹，讓旅客更能體會在地生活的型態和風俗民情。

另以全球訂房網中Booking.com是目前世界最大的旅遊電子商務公司之一，主要提供全球住宿預訂的服務，是美國上市公司Booking Holdings（NASDAQ：BKNG）的旗下品牌之一，延續科技旅遊熱，利用AI、VR等技術，來探討未來趨勢的發展改進。

旅遊新創發展迅速，年輕的一代不想被傳統既有的產業思維模式所框架住，紛紛打造了許多創新的旅遊模式，飯店部份也會依市場趨勢作出行銷策略，在藉由科技的發展，平常生活中有許多相關旅遊的媒體報導、廣告投放或事物氛圍等會引發出想出遊的想法。

2.2 飯店經營管理相關文獻

2.2.1 飯店經營

經營策略是指企業經營最高層次的決策（司徒達賢，1994）。經營一個飯店，跟經營一家管理公司，其實是不一樣的。就像是管理顧問公司，總部的專業人才必須懂得怎樣去經營飯店、服務客人。而且，同時需建立很多跨國營運制度，並且善於溝通。

2.2.2 經營趨勢

隨著台灣社會漸發展為M型社會，台灣旅館發展定位也分為高檔與低價路線，而旅館的經營模式也漸漸往兩端發展。高檔旅館提供高級客製化服務為導向，強調極盡奢華享受及氛圍，旅客在接受服務的同時也區別出社會地位，除了實質的住房需求外也提供無形的服務價值；低價路線的旅館則是因應經濟需求及基本住宿需求而生，以標準化流程及減少服務流程來降低成本，簡易化、自助式的服務降低了房價（林幸君等人，2015）。

2.2.3 飯店消費

是一般大眾生活的部分，然飯店功能提供了人們繁忙社會中，追求快樂享受假期的旅行、或平日犒賞自己、或與人分享、或社交需求，旅館消費已然是生活的一部分。旅館消費是一種高貴、也絕對奢侈的行為，但享受昂貴的特權已是平民化了。然從整個旅館發展過程來看，顯示其往高消費的方向進化，這種面向意味著旅館空間已由「日常性」往「非日常性」的娛樂休閒方向發展，且日趨休閒性、普及性（郭純純，2004）。

2.2.4 新經濟模式所產生的旅館

台灣面臨的成本上漲、客群結構改變、品牌區隔模糊得情況，旅館供應量愈來愈大，而需求的漲幅卻不如預期，市場的競爭將更加劇烈，面對外在環境下，除了來自原有的競爭者的競爭壓力之外，有新型旅館的經營模式影響競爭的可能，還有來自其他產業，所謂的潛在競爭者進入市場的可能，面對未來越來越多的經營模式及多樣化的新型產業與職業別，對於競爭者動態觀察及關注是不可缺少的(沈方正，2018)。

張皓為(2018)也表示透過新經濟模式所產生的旅館，Airbnb、訂房網站等等，正快速影響產業。趙正義(2007)表示，旅館業的拋售跟不動產景氣有關連，由於近些年景氣不佳，來台旅客的供需不平衡，又面臨多方競爭壓力，而導致許多旅館業者倒閉。經濟日報報導中楊衍邦(2018)則表示，許多老舊旅社在本身特色不足、傳統家庭式管理、經營不善的情況下，面對住房率下滑、景氣波動等壓力下，加上近年來新型設計旅店快速崛起，許多由企業集團投資的文創產業、特色旅館，也面臨來自國外的旅館經營業者進入競爭範圍，擠壓到現有市場，且面臨市場變化大，入不敷出的業者不在少數，許多老舊旅社進行拋售，結束營運以將房地產改做其他用途。由此來看，台灣旅館產業似乎正陷入激烈的交替潮。新經濟模式的旅館成為旅館產業未來新世代。

2.3 觀光需求預測相關文獻

2.3.1 時間序列分析預測法

時間序列分析預測法以連續性預測原理作指導，利用歷史觀察值形成的時間數列，對預測目標未來狀態和發展趨勢作出定量判斷的預測方法。主要有移動平均法、指數平滑法、趨勢外推法、季節指數預測法、ARMA模型預測法、馬爾可夫預測法等等。

施瑞峰(2000)利用時間數列方法，以台北、高雄、台中、花蓮、風景與其他等六個地區國際觀光旅館國人住宿率為研究對象，其中高雄、台中、花蓮與其他地區等四個地區國人住宿率均超過50%，以Box-Jenkins之四個步驟建立ARIMA模型。鄭天澤與時巧煒(1995)應用簡算法，時間趨勢模式，指數傾斜法，時間序列模式，計量經濟模式等預測方法，建立來台觀光旅客需求預測模式，並針對總體或各主要市場的需求，利用各種模式評估標準，提出最佳預測模式。

林景琪(2017)使用移動平均法在年資料房間數有更好的預測能力、指數平滑法在月資料房間數能力最佳及線性迴歸在季房間數預測最佳。房間數需求預測既有助於飯店針對不同客源製定銷售策略，也提供飯店內部軟體的教育訓練及硬體的規劃調整作參考，以有效利用淡旺季，達到最高營業效益。

陳月津(2014)應用ARIMA之時間數列法來做預測推估，探討台南市文化古蹟觀光未來遊客量。利用Box-Jenkins步驟建立ARIMA預測模型分析台南市延平郡王祠、赤崁樓、孔子廟、祀典武廟、五妃廟、大天后宮、安平小鎮、整體區域八處古蹟觀光的遊客人數進行推估與預測。

2.3.2 非線性方法應用在需求預測

越來越多的研究人員提出了多種方法來預測旅遊業的需求。最常見的時間序列方法包括ARIMA模型和ETS。這些方法通常使用歷史數據集通過高度依賴於線性假設的單變量或多元數學函數來預測未來的遊客流量。儘管已被廣泛認可，但此類方法因其較差的非線性擬合能力而受到限制。這證明非線性方法在需求預測的有用性，即使用ANN和SVR。

3. 研究方法

本論文擬使用時間數列法與AI人工智慧法，用來預測A飯店未來的住宿需求，包含住宿人數與住宿率，時間序列分析模型是藉由過去數年欲觀測之議題之變動趨勢，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。因此本論文擬使用多種時間序列分析模型預測A飯店的住宿需求，資料集使用A飯店2015-2018年住宿人數，其中擬採用7天住宿人數($St-7$, $St-6$, ..., $St-1$)作為輸入資料， St 作為預測值訓練時間序列分析模型，擬使用方法有ETS、ARIMA、ANN與SVR，並以2019年作為測試資料集，以期望能預測2020年A飯店的住宿人數。本研究擬根據所探討的預測模型，對於預測的適用性及預測績效的優良性。介紹如下：

3.1 指數平滑法

ETS是在1959年所提出的(Brown, 1959)。其數學公式為:

$$S_t = ay_t + (1-a)S_{t-1} \quad (1)$$

此處, S_t :時間t的平滑值; y_t :時間t的實際值;

S_{t-1} :時間t-1的平滑值; a 平滑常數, 其取值範圍為[0,1];

時間序列的態勢具有穩定性或規則性, 所以時間序列可被合理地順勢推延, 過去的時態在某種程度上會持續到最近的未來, 所以將較大的權數放在最近的資料。ETS演算法特別適用於具備季節性和其他先前假設資料的資料集。ETS預測是使用過去觀測值的加權平均值, 隨著觀測值的增長, 權重呈指數衰減, 換句話說, 觀測值的時間越近, 相關的權重就越高。ETS可在廣泛的時間範圍內快速生成可靠的預測, 對工業應用至關重要。ETS的點預測等於預測分佈的中位數。對於僅具有加性成分的模型, 預測分佈為正態, 因此中位數和均值相等, 對於具有乘法誤差或季節性乘積的ETS模型, 點預測將不等於預測分佈的均值, 因此ETS適用於沒有明確趨勢或季節性模式的預測數據。ETS訓練將使用A飯店2015-2018年住宿人數, 其中擬採用7天住宿人數($St-7, St-6, \dots, St-1$)作為輸入資料, St 作為預測值。

3.2 差分自我迴歸移動平均模型

1970年代Box-Jenkins提出ARIMA模式時間數列模式修正與伴合應用的文獻相繼而出, 其應層面廣至經濟、商業、工程首農業等學科的資料分析上, 並成為近年來觀光需求從事短期預測所常用的工具。ARIMA是時間數列分析法的一個基礎工具, 其適用的範圍較為有限。其後陸續發展出來的轉換函數(transfer function model)、介入分析(intervention analysis)(Box and Taio, 1975)與多變數時間數列模型(multipletime series models)等, 更加增進了時間數列法的完備性與適用性。

ARIMA(p,d,q)模型, 是將自迴歸(AR)過程和移動平均(MA)過程作結合的廣義自迴歸移動平均(ARMA)模型, 以此模型延伸了時間序列的複合模型。其數學公式為:

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) (1-L)^d X_t = \left(1 - \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t \quad (2)$$

此處, L 是滯後數(Lag operator), $d \in \mathbf{Z}d > 0$ 。

p --代表預測模型中採用的時序數據本身的滯後數(lags), 也叫做AR(Auto-Regressive)項, 是使用一個觀察值和多個滯後觀測間依存關係的迴歸模型。

d --代表時序數據需要進行幾階差分, 才是穩定的, 也叫Integrated項, 是通過計算不同時間觀測值的值差, 使時間序列平穩化。

q --代表預測模型中採用的預測誤差的滯後數(lags), 也叫做MA(Moving Average)項, 是當對滯後觀測(q)使用移動平均模型時, 計算觀察值與殘差值間的依賴性的方法。

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A飯店住宿資料, 資料集使用A飯店2015-2018年住宿人數, 擬採用7天住宿人數($St-7, St-6, \dots, St-1$)作為輸入資料, St 作為預測值, 根據時間數列的趨勢, 分別選定最佳的迴歸模式, 繼而估算出A飯店常態成長下之年住宿人數。

3.3 類神經網路

人工神經網路(Artificial Neural Network, ANN)是一種模仿生物神經網路(動物的中樞神經系統, 特別是大腦)的結構和功能的數學模型或計算模型, 用於對函數進行估計或近似, 神經網路是通過一種數學統計學類型的學習方法, 得以最佳化參考值。也是數學統計方法中的一種應用, 透過統計學的數學方法, 能找到多數可用函數, 加以分析局部觀測值部份; 此外在人工智慧中的感知領域, 可通過數學統計方法的應用, 做感知領域的解釋。(也就是說通過統計學的方法, 人工神經網路能夠類像人類大腦一樣具有簡單的決定能力和簡單的判斷能力), 這種方法比起傳統的邏輯學推理演算更具有優勢。其數學公式為:

$$t = f(\overline{W}'\overline{A} + b) \quad (3)$$

此處， \overline{W}' 為權重向量， \overline{W} 為 \overline{W}' 的轉置； \overline{A} 為輸入向量； b 為偏置； f 為傳遞函數。

所謂神經元的功能即是先找出輸入向量與權重向量的乘積，再經一個非線性傳遞函數所求出的結果。而在單一神經元，是使用單一n維向量環境，輸入一個輸入向量值，神經元即可判斷此輸入向量值位於邊界的哪一方。其數學公式為：

$$\overline{W}'\overline{p} + b = 0 \quad (4)$$

此處， \overline{W}' 為權重向量； b 為偏置； \overline{p} 為輸入向量。

ANN是基於簡單大腦數學模型的預測方法。ANN允許響應變量與其預測變量之間存在複雜的非線性關係。ANN架構中，可以將神經網絡視為分層組織的神經元網絡。預測變量（或輸入）構成底層，而預測變量（或輸出）構成頂層。ANN也可能有包含隱藏神經元的中間層。最簡單的網絡不包含隱藏層，並且等效於線性迴歸，如圖1所示，這些預測變量附帶的係數稱為權重。ANN預測是通過輸入的線性組合獲得的。在神經網絡框架中使用學習算法選擇權重，該學習算法使成本函數（例如Root Mean Square Error, RMSE）最小化。具有隱藏神經元的中間層，神經網絡就會變成非線性，稱為多層網路，其中節點的每一層都從先前的層接收輸入，一層中節點的輸出是下一層的輸入，使用加權線性組合對每個節點的輸入進行組合，在輸出之前，通過非線性函數修改結果。權重從隨機值開始，然後使用觀察到的數據進行更新，由神經網絡產生的預測中存在隨機性的元素，因此，通常使用不同的隨機起點對網絡進行幾次訓練，並對結果取平均值。

在預測方面，網絡採用迭代方式進行訓練模型。為預測時間序列下一步，使用可用的歷史輸入，為預測未來兩步，將一步預測與歷史數據一起用作輸入，過程一直進行到計算出所有需要的預測為止(Kohzadi, Boyd, Kermanshahi, and Kaastra, 1996)。ANN模型中，資料集將使用A飯店2015-2018年住宿人數，採用7天住宿人數(St-7, St-6, ..., St-1)作為輸入資料，St作為預測值，並藉由ANN模型訓練並動態調整模型參數，期望找到最佳的ANN模型，幫助預測2020年的A飯店住宿人數




圖 3-1 神經元示意圖

3.4 支持向量迴歸

SVR是SVM的延伸型態，能夠處理連續的預測問題，SVM是一種知名的二元分類器，由俄羅斯的統計學家Vapnik 等人所提出，一種基於統計學習理論的演算法。其概念是透過最佳化工具找尋到邊界，讓資料在空間中能夠被區分成兩類，所以又被稱為二元分類器。當資料是線性可分的狀況下，先假設觀察集 $\{x_k, y_k\}_{k=1}^N$ ，給予觀察

值 $x_k \in R^n$ ，輸出值 $y_k \in R$ ，其中 $y_k \in \{-1, 1\}$ ，則分類的決策函數，其數學公式為：

$$y(x) = \text{sign}[w^T x - b] \quad (5)$$

假定觀察集合向量值滿足下列數學不等式：

$$\begin{cases} w^T x_k - b > 0, \text{if } y_k = +1 \\ w^T x_k - b < 0, \text{if } y_k = -1 \end{cases} \quad (6)$$

此處，當找到最大的分類間隔值， w 值：為垂直邊界的向量值； b 為起始點至邊界的距離值，即可找到最佳邊界。

資料點 x 至邊界 $f(x)$ 的距離，其數學公式為：

$$d(w, b, x) = \frac{w^T x + b}{\|w\|} \quad (7)$$

最大的分類間隔值，其數學公式為：

$$M(w, b) = \min_{y=1} d(w, b, x) + \min_{y=-1} d(w, b, x) = \frac{2}{\|w\|} \quad (8)$$

此時，可以重新定義數學不等式：

$$\begin{cases} w^T x_k - b \geq 1, \text{if } y_k = +1 \\ w^T x_k - b \leq -1, \text{if } y_k = -1 \end{cases} \quad (9)$$

要尋找最佳 w 值與 b 值，需找到最小的 $\|w\|$ ，其此二次規劃的數學公式為：

$$\min \frac{1}{2} w^T w, \text{subject to } y_i (w^T x + b) \geq 1, i = 1, \dots, n \quad (10)$$

當目標函數為二次型式時，即存在最佳解，其 w 值與 b 值位於 $|wx + b| = 1$ 上之樣本資料，稱為支撐向量。但有許多現實中的資料存在非線性可分的問題，為了解決線性不可分之情況，需使在觀察模式中容許誤差之存在，其產生數學公式的修改為：

$$\min \frac{1}{2} w^T w + C \left(\sum_{i=1}^n \xi_i \right) \text{s.t. } \begin{cases} y_i (w^T x + b) \geq 1 - \xi_i \\ \xi_i \geq 0, i = 1 \dots n \end{cases} \quad (11)$$

此處， ξ 為鬆弛變量值，當樣本被分類到不正確的邊界時 $\xi > 1$ ，反之為0； C 為成本參數，表示對支持向量機之重視程度，當 C 越大則發生誤差時，目標函數受到影響越大。如果希望訓練值誤差最小化，則將 C 增大；但為避免過度的凝合產生，則選擇縮小 C 使邊界增大。

此外若資料是線性不可分割時，必須將觀察值由原始點之低維度空間映射至另一邊的高維度空間，使其成為線性可分割的資料，再求得其解，因此需要定義核心函數，用來對資料群作映射，其定義函數數學公式為：

$$K(x, x_i) = \varphi(x) \cdot \varphi(x_i) \quad (12)$$

此處， φ 為資料映射到比原先更高為度特色空間的函數。

支持向量迴歸算法主要是通過升維後，在高維空間中構造線性決策函數來實現線性迴歸，在線性迴歸問題中，需找尋迴歸函數，其數學公式為：

$$f(x) = (w \cdot x) + b, w \in R^n, b \in R \quad (13)$$

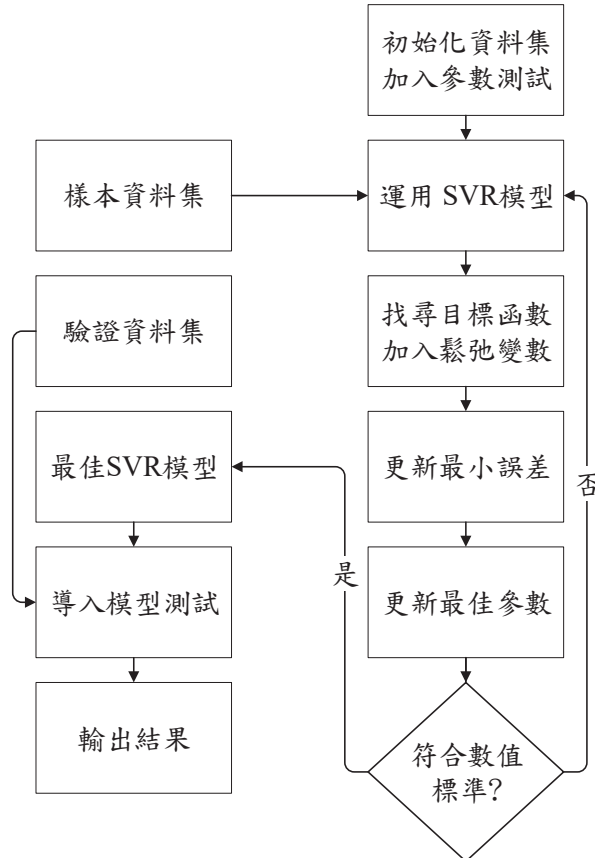
依據結構誤差最小化規則，其數學公式為：

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \text{s.t. } \begin{cases} y_i - (w \cdot x_i + b) \leq \varepsilon + \xi_i \\ (w \cdot x_i + b) - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i = 1 \dots l \end{cases} \quad (14)$$

此處，前項是用來處理資料的複雜度，後項則用來處理控制經驗資料風險， ξ_i 為鬆弛變數，使用鬆弛變數之和與C成本參數相乘，定義為損失函數，使用此損失函數來檢測迴歸式與觀察樣本之間的距離。

SVR使用損失函數克服了分類問題，非線性函數問題和預測問題。由於旅遊數據通常表現出非線性特徵，因此SVR也被廣泛應用於旅遊需求預測研究中。住宿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。SVR模型中，資料集使用A飯店2015-2018年住宿人數，其中擬採用7天住宿人數($St-7, St-6, \dots, St-1$)作為輸入資料， St 作為預測值，利用訓練好的SVR模型進行A飯店2020年住宿人數預測，如表3-1所示。

表 3-1 SVR模型建立表



資料來源：本研究整理

最後本研究使用均方根誤差(RMSE)與對稱平均絕對百分比誤差(SMAPE)做預測績效評估。均方根誤差(RMSE)是均方誤差的算術平方根，均方根誤差的平方項能剔除偏差間的正負態，此平方根能使實際值和預測值的偏差完整的保留在這個指標中，方均根偏移主要用來聚集預測中誤差的大小，通常是在不同的時間下，以一個量值來表現其預測的能力。均方根偏移是一個好的準度的量度衡量指標，是由均方誤差開根號而來，其數學公式為：

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (15)$$

此處，假設預測值： $\hat{y} = \{y_1, y_2, \dots, y_n\}$ ；真實值： $y = \{y_1, y_2, \dots, y_n\}$ ，當預測值與真實值接近0，模型越為準確；誤差越大，此數值即為越大。均方根誤差，需在均方誤差算式中加入根號，求出的數值較容易直接觀察，如RMSE=10，可解釋為迴歸效果，預測值與真實值平均相差為10。其代表的數學公式為：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (16)$$

在對稱平均絕對百分比誤差(SMAPE)是基於百分比或相對誤差的準確性度量。最早引用類似公式的是

Armstrong (1985)，其中將其稱為調整後的MAPE，並且在分母中沒有絕對值的情況下進行定義，後來，Flores (1986)對它進行了討論，修改和重新提出，而MAPE是由平均絕對誤差MAE的百分比延伸而來，其數學公式為：

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (17)$$

此處，當預測值與真實值接近0，模型越為準確。MAPE為0的百分比為較佳模型，MAPE大於100的百分比為較不佳模型，其數學公式為：

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (18)$$

此處，MAPE與MAE的差別為分母，此公式如在真實數值出現0值時，不適用。故選擇SMAPE作為誤差評估指標，其數學公式為：

$$SMAPE = \frac{100}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|) / 2} \quad (19)$$

此處， y_i 為實際值， \hat{y}_i 為預測值。SMAPE優點在於數值出現0值時可以使用的評估方式，在此本研究選用百分比誤差方式，容易解釋。

4.實證分析

本研究使用A飯店入住人數的日資料，入住人數資料從2015年至2019年進行分析處理，其中日資料從2015年至2018年作為入住人數樣本的訓練期，再進行2019年每日入住人數作績效評估。

4.1 資料來源與處理

樣本資料來源為A飯店住宿人數日資料，樣本在各年度上顯示不同的差異性，樣本為自2015年1月1日至2019年12月31日止，共1826日為估計期，其中為資料自2019年1月1日至2019年12月31日止，共365日的實際住宿人數整理來作為驗證期與誤差比對，並以7日為一單位來進行自迴歸，以樣本資料進行指數平滑法、差分自我迴歸移動平均模型、類神經網路、支持向量迴歸等模式，進行誤差值績效比較，於各預測方法中獲取結果，再以RMSE和SMAPE做績效比較，RMSE和SMAPE值越小，績效度越高，最後以最佳預測模型作參數推估，最後用較佳預測模型對2020年入住人數資料進行事前預測，進而得到建議飯店實務之應用。

4.2 敘述統計分析

模型設定後，先透過敘述統計來分析此研究數據資料，運用集中量數的部分了解各變量內的觀察值集中與分散的情況。以平均數、標準差、最小值、最大值等來作推論，另外使用偏態係數、峰態係數這兩種統計數據，表示測量數據與正態分布偏離的情況。再以Jarque - Bera檢驗此研究樣本的偏態係數、峰態係數，數據是否具有符合常態分布。最後依 P 值(P-value)檢驗此研究統計量算出來的概率值數據，評估檢驗假設中虛無假設成立或表現更嚴重的可能性、 P 值是否與選定顯著性水平相比更小，則虛無假設是否會被否定而不可接受。

如表4-6所示，在表中為A飯店各項區域變數之敘述統計結果。從表4-6各項變數之統計結果可知，以平均值而言，最大值發生在2015年的212位，最小值為2019年101位，兩者相差了111位，由此可看出旅客人數大幅減少。就標準差而言，最大值發生在2016年的86位，最小值為2015年的68位，兩者相差18位，2016年剛好是前任總統就任與執政黨換黨派時期。再由偏態係數可看出，2017年至2019年之偏態係數分別為0.330、0.433、0.479，三者均為正數(>0)，其資料分佈型態屬於右偏型態分配，2015年為-0.869、2016年為-0.709及2015年至2019年入為-0.029，變數均為負數(<0)，呈左偏型態分配。另由峰態係數可看出，2015年至2019年，5年分別為2.860、2.037、1.888、2.044與2.332，最後5年總合為1.660，變數皆< 3，則呈低闊峰的型態。可看出入住人數表現逐年下滑的趨勢。在2015年-2019年期間，經歷2次總統大選集一次的執政黨改變，香港反送中政策，也面臨中國客開始減縮來台，開放南向政策。每年南部5月-9月間氣候炎熱等問題。另外，就Jarque-Bera常態檢定在1%顯著水準下，各變數皆為拒絕標準常態分配(N(0,1))之虛無假設，故為非標準常態分配。

表 4-6 A 飯店 2015 年-2019 年各人數敘述統計表

	2015 年	2016 年	2017 年	2018 年	2019 年	2015 年- 2019 年
	(日/人)	(日/人)	(日/人)	(日/人)	(日/人)	(日/人)
平均值	212	191	130	118	101	158
中位數	236	226	119	99	89	148
最大值	371	319	288	300	287	371
最小值	0	0	0	0	0	0
標準差	68	86	84	83	74	90
偏態 係數	-0.869	-0.709	0.330	0.433	0.479	-0.029
峰態 係數	2.860	2.037	1.888	2.044	2.332	1.660
Jarque- Bera	46.283***	43.758***	25.440***	25.283***	20.760***	136.837***
ρ -值	<0.000	<0.000	<0.000	<0.000	<0.000	<0.000
觀察值	365	366	365	365	365	1826

註 1: *、**和***分別代表在 10%、5%與 1%顯著水準下。

註 2: Jarque-Bera 統計量之虛無假設為常態分配。

由於大多時間序列資料為具有單根特性，因此本研究採用 Augmented Dickey-Fuller 檢定，ADF 檢定法是 DF 檢定法的擴展。Dickey-Fuller test (DF 檢定) 為單根檢定之始祖，重要的假設是誤差項必須符合白噪聲 (white noise)，如果數列中包含自我迴歸和移動平均值，則模型的誤差項將具有序列自我相關現象(李鈺瑩, 2014)。Said and Dickey (1984) 提出 Augmented Dickey-Fuller 檢定，誤差項是一個恆定的，可逆 (invertible) 的 ARMA(p, q) 過程，該過程允許 DF 單根檢驗的迴歸式中包括應變數的後向差異，從而使誤差項符合白噪聲並消除了序列相關性錯誤項。ADF 單根檢定加入了 Δy_t 的落後項來消除 數列相關，其使用估計的模型為含截距項、不含時間趨勢項類型，其公式為：

$$\Delta y_t = a + \rho y_{t-1} + \sum_{i=1}^p r_i \Delta y_{t-i} + \varepsilon_t \quad (20)$$

此處， Δ 為一階差分， a 為截距項， t 為時間趨勢項， p 為最適落後期數， $\sum_{i=1}^p r_i \Delta y_{t-i}$ 為最適落後項， ε 為誤差項。欲檢定的假設如下：

$$H_0: \rho = 0 \quad (\text{yt 具有單根，為非恆定的時間數列})$$

$$H_1: \rho < 0 \quad (\text{yt 不具有單根，為恆定的時間數列})$$

在執行單根檢定之前，必需為模型設置最佳的落後期數，以使殘差項通過白噪音檢查，然後再對其 ρ 值進行檢定。如果 ρ 顯著不同於零，則它是拒絕單根的虛無假設，即變數是一個非恆定的序列；否則，無效假設是單根不能被拒絕，即變數是一個非恆定序列。如果變數的水準值是一個非恆定序列，我們將對變數進行一階差分處理，然後再進行檢查。使用 ADF 檢定此樣本資料恆定性與否，辨識變數的樣本資料 是否存在單根之檢定，以判斷 2015 年-2019 年住宿人數之變數是否具為單根。單根檢定的虛無假設為具有單根，若檢定結果無法拒絕虛無假設，則代

表具有單根的特性；反之，若結果為拒絕虛無假設，則代表數列具有恆定的性質。

如表4-7所示，表中為A飯店的ADF檢定量表，2015年至2019年的單日住宿人數資料上ADF統計值 $>1\%$ ，但 $<5\%$ 的臨界值Critical Value，ADF檢驗的原假設是存在單位根，2015年至2019年統計值是小於 5% 水準下的數字就可以極顯著的拒絕原假設，其p值小於 5% 的顯著水準，所以2015年至2019年資料中單根不存在，具有恆定的性質。

表 4-7 A 飯店 2015 年-2019 年住宿 ADF 檢定量表

時間	變數	階次	t-值	p-value	1% 臨界值	5% 臨界值	10% 臨界值
2015年-2019年	住宿 人數(日)	20	-3.146	0.023***	-3.434	-2.863	-2.568

註 1: *、**和***分別代表在 10%、5%與 1%顯著水準下。

註 2: ADF 統計量之虛無假設為單根的特性。

此研究樣本作擬採用上述ADF單根檢定來檢定變數之單根情形。若接受變數具有單根的虛無假設，則可於下一小節的做預測模型推估與預測模型績效比較。

4.3 預測模型推估與績效比較

本研究使用Python作資料分析驗證的特性，進行實證分析，藉以檢視變數間是否存在長期均衡關係。本研究擬先進行敘述統計，然後再進行單根檢定，並做時間序列分析，加以處理缺失資料，將歷史資料作分類建立模型以檢視近來觀察值的資料、進行推估一些未知的連續性變數，與未來的數值以及趨勢，並利用最新資料作為輸入值，最後透過平均絕對百分比誤差值，可以獲得適合的驗證模型對2020年的入住人數作預測，獲得較佳的實證結果，預測A飯店的住宿人數，以製定切實可行的運營計劃或進行旅游資源管理。

首先ETS模型建立，利用平滑推算方式，使用A飯店2015年01月01日至2018年12月31日，以分別7日的住宿人數為一單位，然時間序列合理地順勢推延至2019年01月01日至2019年12月31日住宿人數作為驗證期，如圖4-6所示在預測參考值來看，在圖當中9月份曲線較低，3月份曲線較高，1月份至6月份預測參考值與實際值相較之下趨勢與人數差異較大，7月份至12月份預測參考值與實際值趨勢與人數差異較小。




圖 4-6 2019年ETS實際值與預測值曲線圖

於ETS預測模型推估後所獲取結果，再以RMSE和MAPE做績效比較與衡量實際值與預測參考值之間的偏差，數值越小，表示績效度越高，此回歸模型在預測參考值的表現上如表4-8所示，RMSE值為(58.408)、SMAPE值為(0.835)。

其是ARIMA模型建立，根據時間序列的自相關函數和偏自相關函數圖判斷平穩性，使用P為自迴歸項數，Q為滑動平均項數，D為平穩序列所做的差分階，選擇適當P.D.Q也是關鍵步驟。首先利用AUTOARIMA找到最佳的

P.D.Q(2.1.1)值作參考，依照最佳參考值作評估參考值，原P.D.Q為(2.1.1)，最後調整為P.D.Q為(2.1.0)作參考值。如圖4-7所示在預測參考值來看，在圖當中9月份與11月份曲線較低，2月份曲線較高，整年度預測參考值與實際值相較之下趨勢與人數差異較大。




圖 4-7 2019年ARIMA實際值與預測值曲線圖

於ARIMA預測模型推估後所獲取結果，再以RMSE和MAPE做績效比較與衡量實際值與預測參考值之間的偏差，數值越小，表示績效度越高，此回歸模型在預測參考值的表現上如表4-8所示，RMSE值為(75.415)、SMAPE值為(0.999)。

再者為ANN模型建立，應用類神經網路系統，利用人類神經思考過程的原理，首先將A飯店2015-2018年住宿人數，採用7天住宿人數(St-7, St-6, ..., St-1)作為輸入資料，St作為預測值，並藉由ANN模型訓練並動態調整模型參數，在程式裡加入隱藏層，並產生最佳的ANN模型。如圖4-8所示在預測參考值來看，在圖當中從1月份與12月份曲線皆出現人數50位左右的趨勢。




圖 4-8 2019年ANN實際值與預測值曲線圖

於ANN預測模型推估後所獲取結果，再以RMSE和MAPE做績效比較與衡量實際值與預測參考值之間的偏差，數值越小，表示績效度越高，此回歸模型在預測參考值的表現上如表4-8所示，RMSE值為(59.499)、SMAPE值為(0.855)。

最後SVR模型建立，導入微粒群演算法，應用於人工智慧，加入權重值來取得與找尋較佳值作預測的模型，誤差值愈小代表其實際數值與假設存在的數值的相似程度愈高，結果如圖9所示在預測參考值來看，在圖當中從

1月份與12月份曲線預測參考值與實際值趨勢與人數差異較小，預測值更接近於實際數據。

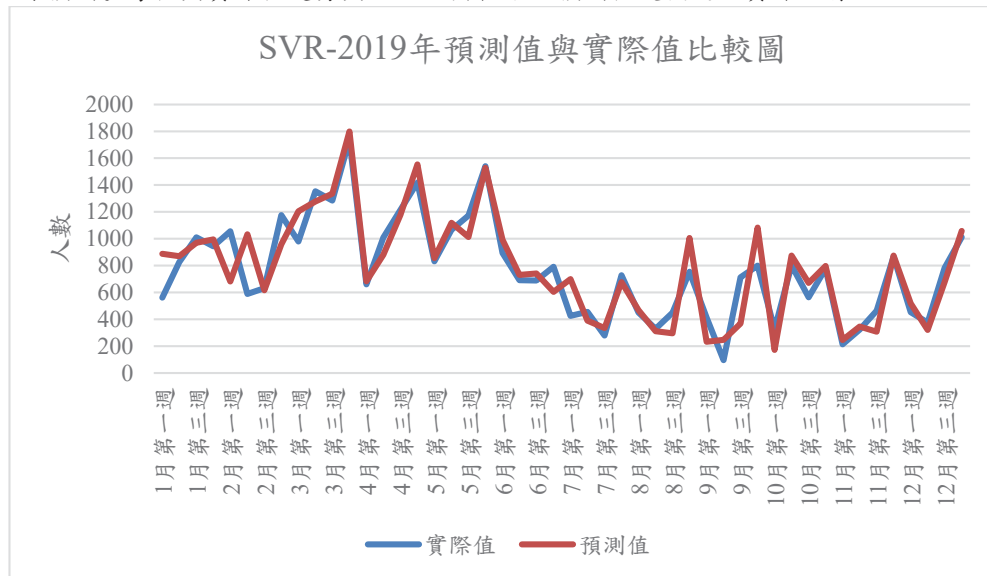


圖 4-9 2019年SVR實際值與預測值曲線圖

於SVR預測模型推估後所獲取結果，再以RMSE和MAPE做績效比較與衡量實際值與預測參考值之間的偏差，數值越小，表示績效度越高，此迴歸方式在預測參考值的表現上如表4-8所示，RMSE值為(58.996)、SMAPE值為(0.599)。

表 4-8 RMSE與SMAPE績效比較表

	ETS	ARIMA	ANN	SVR
RMSE	58.408	75.415	59.499	58.995
SMAPE	0.835	0.999	0.855	0.599

註:數值越小，表示績效度越高。

資料來源：本研究整理

此外，如表4-8所示，所有住宿人數預測方法中，表當中SVR模型進行RMSE和SMAPE做衡量實際值與預測參考值之間的偏差績效比較，SVR的預測績效仍比ETS，ARIMA和ANN模型優異，其中SMAPE的值最低，就RMSE值也是較好的。就平均精度而言，其SMAPE (RMSE) 與ETS之相比差數為0.236 (0.587)；其SMAPE (RMSE) 與ARIMA之相比差數為0.4 (16.42)；其SMAPE (RMSE) 與ANN之相比差數為0.256 (0.504)，與其他方式相較之下，績效較佳。

表4-8中每種方法的SMAPE和RMSE還用於評估預測績效，時間序列方法和人工智能的預測績效。與時間序列方法相比，人工智能方法無需確定數據是否固定，也無需考慮是否應使用其他統計檢驗，而是可以從訓練數據的特徵中學習。

為了進一步瞭解資料變化，特以圖4-10所呈現，在圖當中ETS、ARIMA、ANN、SVR與實際值週住宿人數，SVR的曲線仍比ETS，ARIMA和ANN曲線優異，與其他曲線相較之下較為貼近實際曲線，結果較佳。

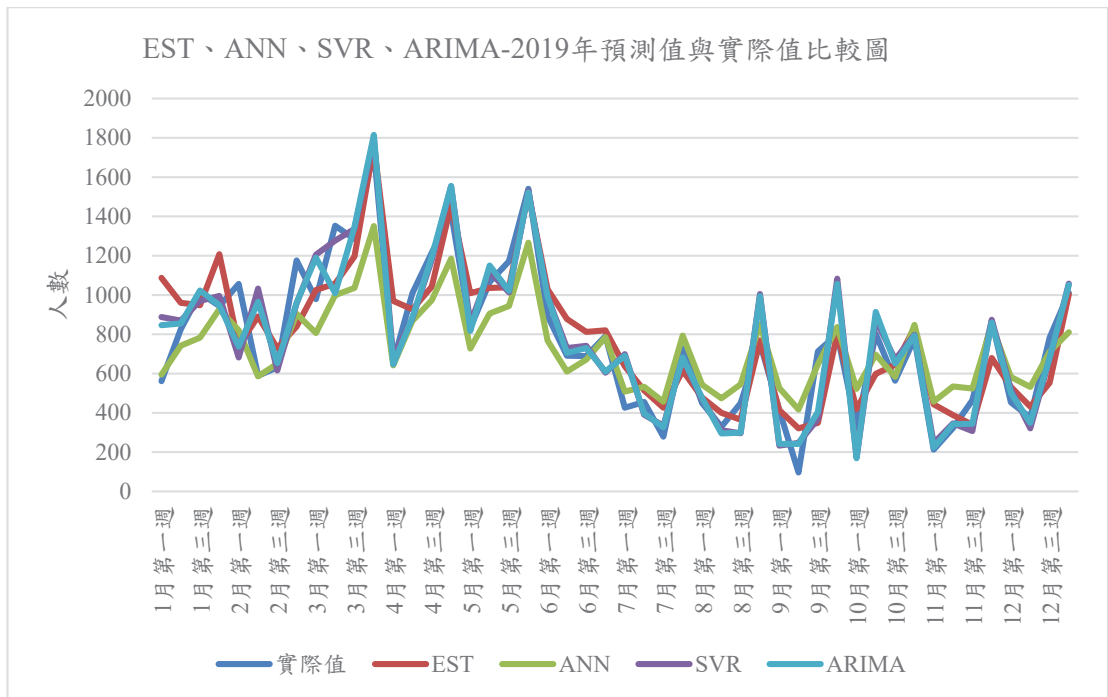


圖 4-10 2019年ETS、ARIMA、ANN、SVR實際值與預測圖

總而言之，由表4-8中及圖4-10的結果表明，就樣本外預測能力而言，本文中的人工智能SVR方法在大多數情況下均優於其他時間序列模型。此外，在解決預測問題時，SVR方法優於ANN方法，故選擇此組預測方法進行2020年的事前預測，結果如圖4-11所示，在2020年住宿人數最高點未到150，飯店在面對景氣不佳情況下，也需考量其他營運方法來作為應變。




圖 4-11 2020年SVR事前預測圖

4.4 預測模型於飯店經營之應用

本研究中，透過測試尋找出最佳參數的能力來證明SVR方法的有效性取決於所選參數，本研究使用SVR獲得的結果比使用其他方法獲得的結果更準確，觀察結果表明，SVR提供了更有利的預測結果，也進行2020年的事前預測，依事前預測出的結果，應需多考慮飯店經營上的相關問題與做事前的計畫排程。

在飯店管理上需考量多方面的問題，如表4-9所示，在飯店房間數需求量、餐飲供需量、觀光人才需求量、建築維修工程排程計畫及預算編制與調度等經營上可作適當的安排調整，經營飯店會遇到項目管理風險問題、常見人員空缺問題、跨部門人員調配、飯店硬體質量低劣耗損、客源開發以及其他與飯店相關的問題都必須進行評估，為了與競爭對手競爭，飯店也應從客戶的角度了解客房的供需關係。透過預測住宿率，可以設計出更好的對策以

降低飯店運營中的風險，並為意外的飯店運營問題做好準備，預測住宿人數之後，可以安排飯店員工並評估餐飲需求，即使在人員不足的情況下，也可以確保靈活的飯店營運。

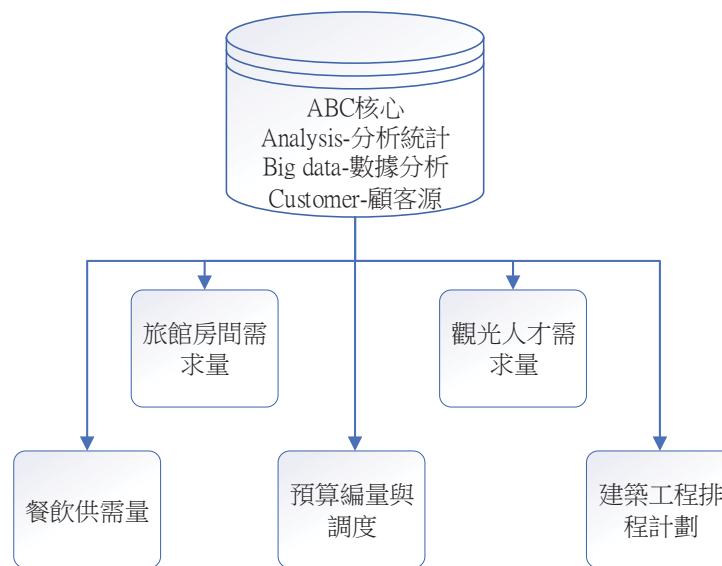


表 4-9 研究 ABC 核心表

資料來源：本研究整理

5. 結論與建議

5.1 研究結論

「觀光產業」是目前各國最具社會經濟指標的產業之一，過去幾年來的成長相當快速。台灣是一個海島型氣候的島嶼，天然資源相對有限，但因台灣有獨特景色及民俗文化，值得進一步發展成深度旅遊。

住宿是觀光產業的最基本需求，從旅遊消費行為得知，飯店住宿是觀光休閒旅遊中最基本的一項消費活動，也是跨區旅遊中的剛性需求。由於飯店業是屬於服務性的事業，其產業具備一些特殊的經濟特性。飯店經營管理需考量的除了旅館軟、硬體，外在周遭環境及整體經濟景氣，皆需要專業團隊審慎評估各項條件，方能有效引領經營者做最高效益的決策。因此，若能準確的住宿需求預測，將對飯店的經營管理有莫大協助。

A飯店是屬於老字號的知名飯店，座落於高雄商業區，交通便利，提供近百間的豪華客房，設施完善，軟硬體設備皆屬於上乘。但面對景氣的變化，以及兩岸關係的變化起伏，使得飯店的住宿人數變化相當大，增加飯店經營的風險。因此，若能藉由A飯店過去的住宿人數，找出資料的趨勢，以精準預測未來的住宿人數，便能在房間控管、人員配置與軟硬體維護上，做出較妥善的管理。

基於以上的需求，本文企圖建立適合用來預測住宿需求的預測模型。為了達到此一目的，我們首先考慮時間數列預測模型(ARIMA與ETS)，與AI人工智慧的預測模型(ANN與SVR)，分析A飯店每日的住宿人數，期間由2015年1月1日至2019年12月31日止，共1826個觀察值。其次，以RMSE和SMAPE兩種指標來評估各模型的預測績效，當指標的數值愈小，表示模型的預測準確度愈高。最後，根據預測準確度最佳的模型，對2020年的住宿人數進行事前預測，據以得到可行的建議，提供實務上管理飯店之用。

預測結果顯示，AI預測模型的預測能力普遍優於傳統的時間數列模型；以RMSE來說，ANN與SVR的值相當接近，優於ARIMA模型，但略為高於ETS；若從SMAPE來看，AI模型的預測準確度優於傳統模型，但SVR的準確度高於ANN，而在傳統模型中，ETS依舊表現得比ARIMA來得好。

5.2 研究限制與建議

雖然本文已經使用嚴謹的統計程序，挑選出最恰當的預測模型，用來預測今年(2020)的住宿人數，發現在2020年的入住人數會銳減。但仍然無法擺脫不可抗力自然或人禍對於預測值的影響。事前預測值若要不失真，需要假設歷史資料的分配與未來的機率分配相同或類似，若未來的分配因為外部衝擊而大幅改變時，事前預測值便

會失去參考性。

本文的研究限制在於資料的期間並不長，對於需要大量資料來訓練模型的AI演算法，略顯不足。此外，AI演算法的執行需要挑選合適的參數，才能讓預測準確度提高，這部份尚有努力的空間。此外，後續研究者或許也可採用迴歸模型的設定，將住宿人數與重要變數做連結，或許能提高更精確的預測值，以供飯店經營管理之用。

參考文獻

一、 中文部份

1. 楊衍邦(2018)，臺灣旅館業在地化經營策略—文獻分析與個案訪談，高雄大學國際高階經營管理碩士在職專班碩士論文。
2. 潘朝達(1980)，旅館管理基本作業. 水牛出版社。
3. 陳宗玄、張瑞琇(2008)，休閒遊憩產業概論，揚智文化。
4. 吴观张(1994)，高层商住(写字, 旅馆)楼的设计探讨(上)，建筑学报，(8)，4-10。
5. 楊允祚(1983)，觀光詞典。
6. Garet. MS、Porter. AC、Desimone. L.、Birman. BF、Yoon. KS (2001)，是什麼使職業發展有效？全國教師樣本的結果，美國教育研究雜誌，38 (4)，915-945
7. 司徒達賢(1994)，策略矩陣分析法基礎，管理評論，13(2)，1-22。
8. 林幸君、李慧琳、許聖民、林國榮、李篤華、張靜貞、徐世勳(2015)，臺灣經濟預測與政策。
9. 石鎧禎(2018)，借鏡中國大陸經驗探討台灣電子支付的對策，淡江大學財務金融學系碩士在職專班學位論文，1-56。
10. 潘朝達(1980)，旅館管理基本作業. 水牛出版社。
11. 李宗珏、黃純德(2004)，台灣民宿業者餐旅行銷組合與關鍵成功因素之研究，銘傳大學觀光事業研究所碩士論文。
12. 林侑萱、李俊憲(2010)，中國大陸與台灣旅遊產業，市場結構差異之比較研究，大葉大學國際企業管理學系碩士論文。
13. 郭純純(2004)，觀光飯店之[款待設計](Hospitality Design) 室內空間論述，中原大學室內設計研究所學位論文，1-188。
14. 張皓為 (2018)，以文字探勘技術探討五星級飯店之品牌形象—以老爺酒店為例，真理大學觀光事業學系碩士班碩士論文。
15. 張嘉珮(2007)，觀光旅館業人力資源部門主管職能之研究，亞洲大學休閒與遊憩管理學系碩士班學位論文，1-78。
16. 潘治民、林億明、周秣宸(2009)，準固定要素與績效評估-台灣國際觀光旅館客房部之實證研究，亞太經濟管理評論，12(2)，61-80。
17. 施瑞峰(2000)，臺灣國際觀光旅館國人住宿率預測之研究，朝陽科技大學休閒事業管理系碩士論文。
18. 鄭天澤、時巧煒(1995)來華觀光旅客需求預測模式比較分析，管理評論，14(1)，77-116。
19. 黃營芳、詹雅竹(2014)應用灰色理論預測高雄地區國際觀光旅館住宿人數之研究，商業現代化學刊，7(4)，89-103。
20. 林景琪(2017)不同客源住宿高雄代表性飯店數量預測時間序列研究，國立高雄應用科技大學觀光與餐旅管理研究所。
21. 廖哲瑋、呂嘉祥、涂凱妮、林君涵、許閔傑、曾鴻儒(2010)來台觀光旅客人數預測分析。
22. 陳月津(2014)台南市古蹟觀光遊客人數預測分析，朝陽科技大學休閒生活美學產業碩士專班學位論文，1-80。

23. 徐振倫(2011)國際觀光旅館之住宿人數預測模型研究，臺灣師範大學餐旅管理與教育研究所學位論文，1-80。
24. 黃仁宗、盧炳志、穆堃豪(2013)運用類神經網路於休閒農場來客數之預測，休閒觀光與運動健康學報，4(1)，1-19。
25. 林怡秀、李宜臻、吳佳蓉、劉怡宏(2010)主要觀光遊憩區旅遊分析。
26. 交通政策白皮書第六章觀光政策 https://admin.taiwan.net.tw/upload/contentFile/auser/b/wpage/chp61/61_1.htm
27. 股感知識庫
<https://www.stockfeel.com.tw/%E6%97%85%E9%81%8A%E7%94%A2%E6%A5%AD%E6%A6%82%E8%A7%80/>
28. 中時電子報 <https://www.chinatimes.com/realtimenews/20190117003444-260410?chdtv>
29. TTR 台灣趨勢研究：產業分析：旅行業發展趨勢 https://www.twtrend.com/share_cont.php?id=37 & https://www.twtrend.com/share_cont.php?id=29
30. 欣傳媒旅遊頻道 <https://solomo.xinmedia.com/globaltourismvision/146969>
31. 天下雜誌 <https://www.cw.com.tw/article/article.action?id=5078123>
32. 台灣觀光飯店產業- 研究報告- 財經知識庫- MoneyDJ 理財網
<https://www.moneydj.com/KMDJ/Report/ReportViewer.aspx?a=7402be4a-c34f-4be6-848d-35e812ff32ed>
33. CEO 談經營哲學| 經理人 <https://www.managertoday.com.tw/articles/view/53204>
34. 飯店管理學- MBA 智库百科 <https://wiki.mbalib.com/zh-tw/%E9%A5%AD%E5%BA%97%E7%AE%A1%E7%90%86%E5%AD%A6>
35. 旅遊玩家-台灣觀光發展 <http://holidaygo.blogspot.com/2015/03/taiwan-travel-history.html>
36. 台灣觀光產業的發展歷程及趨勢 <https://www.slideshare.net/kevin0673/ss-50939472>
37. 旅@天下 Global Tourism Vision NO.79: 白色饗宴用愛繫上希望
38. 衛生福利部疾病管制署 https://www.cdc.gov.tw/Category/Fpage/vropP_BL-TpPDvG94ABqZA
39. 維基百科，自由的百科全書 <https://zh.wikipedia.org/wiki/Wikipedia:%E9%A6%96%E9%A1%B5>

二、 英文部分

1. Brown, R. G. (1959). Statistical forecasting for inventory control: McGraw/Hill.
2. Kohzadi, N., Boyd, M. S., Kermanshahi, B., & Kaastra, I. (1996). A comparison of artificial neural network and time series models for forecasting commodity prices. *Neurocomputing*, 10(2), 169-181.