

臺灣進出口值之預測-傳統方法與深度學習法之比較

Forecasting Import and Export of Taiwan - Comparison of Traditional Methods and Deep Learning Methods

連春紅¹

崑山科技大學 房地產開發與管理系 副教授

chlien@mail.ksu.edu.tw

李政峯²

國立高雄科技大學 企業管理系 教授

jflee@nkust.edu.tw

彭品蓉³

國立高雄科技大學 企業管理系碩士班 研究生

F110157113@nkust.edu.tw

摘要

本研究旨在評估經濟結構模型、時間序列模型、長短期記憶神經網絡(LSTM)模型和卷積神經網絡(CNN)+LSTM模型在預測臺灣進出口值方面的能力。實證結果顯示,在傳統預測方法中,時間序列模型的表現優於經濟結構模型。對於深度學習方法,將80個景氣循環變數同時輸入LSTM模型的預測效果可能優於或劣於將變數分類別輸入的效果。然而,由於變數數量眾多,若未進行降維處理,目前無法超越傳統時間序列模型的預測能力。在所有模型中,CNN+LSTM模型表現最佳,這證實了在處理大量變數時,將CNN的圖像辨識能力應用於經濟解釋的可行性。透過CNN進行降維處理並將結果輸入LSTM模型,可以獲得最佳的預測結果。

關鍵詞：深度學習、進出口值、預測、景氣循環。

Keyword：Deep Learning、Forecast、LSTM、CNN。

第一章 緒論

第一節 研究背景

臺灣為一海島型國家,內需市場狹小且資源有限,經濟發展需要仰賴貿易的支持。歷史上,臺灣便因位處東亞重要貿易航道上,成為殖民國家開展貿易活動的戰略據點。自17世紀起,臺灣便與歐洲、東南亞國家以及中國等地保持緊密的貿易關係。

近代臺灣各時期之經濟發展政策與貿易高度相關,主要包括進口替代政策(1953年-1959年)、出口導向政策(1959年-1972年)以及貿易自由化政策(1980年代至今)。自1984年起,前行政院院長俞國華強調經濟發展的三大原則,即自由化、國際化和制度化。臺灣以此三大原則作為貿易發展政策的基礎,並透過建立多項措施促進對外貿易發展、降低貿易障礙,加強與其他國家的經濟合作,進一步推動國內經濟的成長。

國際貿易的蓬勃發展使各國市場趨於一體化且相互依存,各國關係因貿易日益緊密。當國際貿易受到重大事件趨於疲弱時,其影響層面更加廣泛。自2020年開始,全球受到Covid-19疫情影響,供應鏈中斷導致商品供應短缺並出現價格波動。此外,2022年烏俄戰爭爆發,國際能源價格上漲,國際貿易運輸成本增加,進一步加劇通貨膨脹。美國為抑制通膨選擇升息,然而此政策將減緩全球經濟活動,對臺灣的進出口貿易產生衝擊。

基於以上背景,研究臺灣進出口值的預測至關重要。然而預測的準確性和可靠性一直是個挑戰,因此本研究比較不同預測方法,以找尋最佳預測模型。

第二節 研究動機

根據圖 1.1 和圖 1.2 的觀察，臺灣進出口貿易值呈現動態成長的趨勢，唯有 2008-2009 年金融風暴、2015-2016 年全球景氣低迷以及 2020-2021 年 Covid-19 影響下，對外貿易總額有較明顯的下降。臺灣對外貿易依存度高，近年來多次出現進出口總額佔 GDP 比重超越 100% 的情形。因此，若能夠準確預測進出口貿易值，就能夠更準確的預測臺灣的經濟表現。




圖 1.1 臺灣出口值




圖 1.2 臺灣進口值

2020 年以來全球受到 COVID-19 疫情的影響，經過兩年時間，全球迎來後疫情時代，各地景氣逐漸復甦，但仍未完全穩定。疫情期間所發生的供應鏈斷鏈、塞港塞櫃等問題目前尚未完全解決。人力及貨櫃短缺、運費浮動等運輸問題使海運成本增加，對大量依賴海運的國際貿易造成干擾。在此情況下，若能預測臺灣的國際貿易趨勢，將有助於我們了解後疫情時代經濟的復甦速度。

臺灣經濟發展受到進出口值的影響，而進出口值又會受到國內外經濟情勢的影響。根據國家發展委員會的研究，自 2000 年以來，對於景氣循環完成時點和實際結束時點之認定存在 1.5 年至 4 年的落差(蕭宇翔、林依伶，2020)。國發會除了內部人員於《經濟研究》年刊中多次發表關於景氣循環的相關議題外，還長期委託學術單位對景氣循環之預測進行研究(e.g. 周大森，2019；黃裕烈等，2019；何宗武等，2020)。然而，儘管經過各方面的研究和預測方式的調整，每月仍須不斷針對預測結果進行修正。

由於進出口值是景氣循環指標的構成項目之一，同時進出口值亦會受景氣循環指標影響，兩者間存在複雜且非線性的關係，增加了兩者在預測上的難度。若能夠提高進出口值的預測準確度，將有機會提升景氣循環指標的預測準確度，可以幫助政府制定更適宜的經濟發展政策。同樣地，若企業決策有更準確的進出口值的預測值可作為發展時的參考依據，也能制定更符合未來趨勢的策略。基於上述原因，我們希望可以建立一個能夠更準確預測進出口值的模型，以滿足實務上的各種需求。

為了預測進出口值，本研究將使用四種模型，包含時間序列模型、經濟結構模型以及深度學習的兩種模型，並比較四種預測方法的結果，找出最佳的預測模型。過去的文獻已有利用時間序列和結構模型預測進出口值(e.g. Awe et al., 2018；Keck et al., 2010；Sun et al., 2020)，而本篇研究中將加入深度學習方法來進行進出口值的預測。

具體而言，我們將每一期的景氣循環視為一張圖片，其中圖片上的每個像素都各自代表一個總體經濟變數。我們將利用卷積神經網路(Convolutional neural network, CNN)在影像辨識領域的優勢，把景氣循環圖片作為輸入來訓練 CNN 神經網路，提取出圖片的特徵並建構出代表景氣循環的指標(李政峯，2022)。這個基於 CNN 神經網路建構出的景氣循環指標將作為數入變數，傳入長短期記憶模型(Long Short-Term Memory, LSTM)進行深度學習，以預測進出口值。

此種結合卷積神經網路和長短期記憶模型的深度學習方法在影像辨識和語音辨識等領域有顯著成果，我們希望能將這種方法應用於經濟預測領域，提供更具準確性和可靠性的預測方法。

第三節 研究目的

由於臺灣對於進出口貿易的高度依賴，貿易表現對臺灣經濟發展有重大影響，若能更加準確預測進出口值對於政策面會有重要幫助。同時，由於進出口貿易值和景氣循環指數間的非線性複雜關係，若能夠更加準確預測進出口值，對於預測景氣循環也有助益。因此本研究欲達成以下目標：

1. 深度學習法的跨領域應用。將景氣循環的構成視為圖片，並利用 CNN 做特徵提取，從而建構出景氣循環指標，再利用建構出的指標做為深度學習模型的輸入變數，用於預測臺灣進出口值。
2. 尋找最佳預測模型。針對進出口值的預測，將使用時間序列模型、經濟結構模型、深度學習模型進行，我們將評估這三種預測方式的預測績效，並尋找最佳的預測模型。
3. 提供實務參考。透過找出最適合的模型來更準確地預測進出口貿易值，能夠為臺灣的政府政策制定和企業決策提供參考，將有助於做出更適宜的規劃。
4. 豐富過去文獻不足之處。本研究結合景氣循環指標與 CNN 的影像辨識技術並賦予經濟上的意義，這種應用方法於文獻中相對少見，本研究可填補這方面文獻的不足，協助了解深度學習在經濟領域的應用。

第二章 文獻探討

第一節 國際貿易

國際貿易和經濟成長間的因果關係，大致可分為四種假說：出口帶動經濟成長(ELG)、經濟成長帶動出口(GLE)、進口帶動經濟成長(ILG)、經濟成長帶動進口(GLI)。過去文獻表明一個國家可能同時滿足超過一個假說，國際貿易和經濟成長的關係可能為單向因果關係或雙向因果關係。

壹、出口

在世界各地推動貿易自由化的時期，許多實證研究發現開放對於經濟成長具有積極影響，但如何將貿易政策與更快的經濟均衡成長相連結的理論模型仍難以建立，再加上數據的取得困難，限制了此類實證研究的深入。然而，透過研究 93 個國家的新數據集，發現開放程度越高的國家具有更高的總要素生產率(TFP)成長率，證實了開放對於經濟成長具有正面影響。(其中 TFP 常代表經濟體的技術進步率，可用以說明經濟增長) (Edwards,1998)。

研究也指出出口促進政策對於促進經濟成長有極大幫助。Bhagwati(1988)研究指出出口對於經濟成長有助益，但要共同合作與努力以確保此助益不會受到保護主義干預。此外，出口產品的多樣化和構成亦具有重要性，國家專業出口的商品之經濟影響與其專業程度、生產效率、人力資本等多項因素有關，出口「品質」排名高產品的國家會有更好的經濟表現，而高科技產品的出口對於經濟產出增長的效果更為顯著(Hausmann, Hwang&Rodrik,2007; Aditya & Acharyya,2013)。

A. Giles & Williams (2000) 發現出口帶動經濟成長(ELG)假說在亞洲國家的表現較拉丁美洲和非洲國家好，許多新興工業國家(如:新加坡、台灣)之生活水準每 10 年就成長一倍。亞洲國家價格彈性高於非洲國家，出口貿易對於亞洲區域成長有幫助(Senhadji & Montenegro,1999)。因此，若一個國家希望提高經濟成長率，應該採取出口促進與經濟成長導向的政策 (Emery,1967; Bahmani-Oskooee & Economidou,2009)。

以上研究提供了不同國家關於出口與經濟成長關係的證據，顯示出口帶動經濟成長(ELG)假說和經濟成長帶動出口(GLE)假說在不同國家間的應驗情況各異，表明出口貿易與經濟成長之間的關係並非單向的。

貳、進口

出口和進口對於經濟成長同樣具有重要性，然而經濟策略常偏重於出口對於經濟成長的影響，這種觀點通常效果有限(Awokuse,2008)。根據基於經濟成長理論提出的模型，商業導向的創新被視為技術進步的主要動力，國家的總要素生產率不僅取決於國內的研發資本，也依賴國外的研發資本(Coe & Helpman,1995)。進口在提供出口部門所需的中間生產投入方面有重要作用，同時能協助解決技術和知識有限的問題，因此進口開放對經濟成長至關重要。

有關進口對經濟成長的影響會受到進口項目和國家情況有所不同。例如，Mujahid et al.(2019)發現，巴基斯坦的進口項目中原物料占最大比重，因此進口對 GDP 的影響比出口來得更加明顯。建議巴基斯坦應以進口中間產品和資本為目標，減少進口消費品。Maitra(2020)則研究印度改革後時期，發現短期和長期下進口帶動經濟成長(ILG)假說均獲得證明。而 Raghutla & Chittedi(2020)的研究指出，巴西、印度、中國和南非滿足經濟成長帶動進口(GLI)假說，俄羅斯滿足進口帶動經濟成長(ILG)假說。此外，隨著全球貿易發展，勞動力充足的國家能創造就業機會，並促進經濟成長。

貿易對經濟成長具有重要影響，特別是進口與經濟成長之間存在著雙向關係。我們應該同等重視出口和進口政策，並鼓勵更加外向開放的經濟體制，進口自由化的政策對經濟成長是有益的。

第二節 傳統貿易預測

參、經濟結構模式—出口需求函數

Kabir(1988)研究認為孟加拉國出口需求會受到國外所得與進口財相對價格的影響，將匯率影響列入考量。孟加拉國的出口受到貿易國家價格水準的影響較高，受自身價格水準的影響較低，而匯率變化對孟加拉國的出口並無影響，推測是因為孟加拉國在國際市場上是價格接受者(price-taker)的地位。

Hossain(2009)發現印尼的出口與印尼於全球收入、出口相對價格有長期關係。1990 年代後，印尼的出口需求函數改變，收入的彈性下降，且出口相對價格的彈性增加。此結果為印尼 2000 年開始出口成長減緩，也影響其於金融危機後的經濟復甦。Chou(2000)研究得出匯率波動對中國總出口、製成品出口及礦物燃料出口均有負面影響，支持匯率不確定性會阻礙貿易之假設。

新加坡出口函數的變數有實質國外所得、出口價格、競爭者出口價格，外部需求是新加坡出口成長的關鍵因素(Arize, 2001)。沙烏地阿拉伯的出口需求與國外所得和有效匯率有長期均衡關係(Sultan, 2014)。印度的實質出口與國外所得、匯率和相對價格有長期均衡關係。實證分析中發現不論是長期或短期，出口受到外國所得最多影響、其次是相對價格，而匯率在未對出口量有明顯刺激(Dash, Dutta & Paital, 2018)。

估計亞洲開發中國家的出口需求函數，包含印度、中國、菲律賓、印尼、新加坡、馬來西亞。出口與貿易國家所得和相對價格存在長期共整合關係，相對價格對於些國家的出口量有明顯的影響。出口應被亞洲開發中國家視為經濟發展一大動力，國家可以嘗試貶值貨幣以增加國際市場上的競爭力，同時增加其出口收入，因此鼓勵推動出口相關政策(Kumar, 2011)。

統整以上對於不同國家的出口需求函數研究，我們認為出口需求與出口財相對價格和外國所得有關聯性，因此本研究中將使用這兩個變數來建構進口需求函數。

肆、經濟結構模式—進口需求函數

Narayan & Narayan (2005)應用進口財相對價格、投資支出、消費支出、出口支出等變數，對斐濟的進口需求模型進行估計。研究結果得出以下結論：(1)價格為重要變數；(2)投資支出、消費支出和出口支出的增加將導致進口需求增加；(3)該模型由不同支出類別構成，具有良好的預測能力，可為決策者提供有價值的預測參考。

中國的傳統進口需求函數與國內活動和相對價格有關。國內活動使用國內生產毛額(GDP)、國內生產毛額減掉出口、國家現金流、最終支出四種指標組成。實證結果發現以上四種指標與中國進口需求存在長期均衡關係，國內活動和相對價格長期來說缺乏彈性(Tang, 2003)。

印度進口需求以 GDP 為主要解釋變數，對相對價格敏感性較低，且進口自由化對進口需求的影響小(Dutta & Ahmed, 2004)。孟加拉國的進口需求函數包含實質進口價格、實質 GDP、實質外匯存底以及一個虛擬變數，該虛擬變數用來反映進口自由化政策的影響(Dutta & Ahmed, 1999)。馬來西亞的進口需求與收入和進口財相對價格存在長期關係，這表明貨幣、財務及匯率政策對於維持馬來西亞的貿易平衡有幫助(Tang & Nair, 2002)。

日本的進口需求與實質收入和進口財相對價格有長期關係。實質收入的長期彈性為 0.99，相對價格的長期彈性為 0.82。進口需求量對收入具有彈性，意味著經濟成長對貿易平衡有負面影響，為減少進口需求壓力，政策可以透過減少國內需求的某些部分(如：終端消費品、投資等)(Tang, 2003)。臺灣進口需求同樣與實質收入和進口財相

對價格存在長期關係。實質國內收入在短期和長期均具有彈性，這表明國內經濟成長對貿易平衡有負面影響(Chen,2008)。

統整以上對於不同國家的進口需求函數研究，同時模型設定上認為出口和進口是對稱關係，因此本研究以進口財相對價格和國內所得作為變數，建構進口需求函數。

參、時間數列方法

為了促進國家的經濟良好成長，預測和建模是當今很重要的工具，其中時間數列方法即為一重要技術。過去文獻有許多以單變量時間序列模型對進口值和出口值進行預測，在此部分進行整理。

建立 ARIMA 模型來對巴基斯坦的進口總額和出口總額做預測，最終使用 ARIMA(2,2,2)模型預測進口和 ARIMA(1,2,2)模型預測出口，同時本研究發現巴基斯坦的進出口總額有成長趨勢(Farooqi,2014)。比較季節性 ARIMA、Holt-Winters' 方法、向量自我迴歸(VAR)模型三種方法，以出口總額和外國淨資產作為其他內生變量的 VAR 模型用於預測孟加拉國的進口總額較為準確(Khan,2011)。

Wang(2011)利用時間數列模型預測臺灣出口總額，得出當樣本週期較短時，模糊時間數列模型預測準確度更高，而當樣本週期延長時，ARIMA 模型的預測誤差較小。Arumugam & Anithakumari(2013) 比較模糊時間數列法和 ARIMA 方法的預測績效，ARIMA 模型有較小的預測誤差及較接近實際趨勢的預測路徑，對臺灣出口值的預測效果較佳。

Kumar & Gupta(2010)用單變量時間數列模型預測未來十年旁遮普邦的工業品出口值。根據預測結果作為政策制訂方向的參考，建議旁遮普邦致力於提升研發和品質，以確保出口值的增長。Kongcharoen & Kruangpradit(2013) 使用單變量時間數列模型預測泰國對主要貿易夥伴的出口值，ARIMAX 模型在日本、美國、歐盟、澳洲優於 ARIMA 模型，因此最終推薦以 ARIMAX 模型直接預測泰國出口值。

時間序列模型在國家整體進出口值常被應用，在服務和商品的預測上也有良好的表現。根據時間序列預測的結果，可以對國家的經濟政策提供建議。

第三節 景氣循環

壹、景氣循環與貿易

國際貿易佔全球產的比重增加，貿易對景氣循環波動的潛在影響力增加，因此了解哪些因素會影響貿易從各種面向都是重要的。Prasad(1999)的研究為了分析貿易對於不同種類的經濟衝擊會如何應對發展新的實證架構，給予景氣循環和貿易間條件相關性的綜合觀點。

景氣循環包含擴張期與收縮期，在擴張期時可以觀察到許多經濟活動同時擴張，而在收縮期時可以觀察到許多經濟活動萎縮，此現象不具有固定週期性且時間持續長度可能不同。景氣循環的概念可以統整眾多總體變數，藉由景氣循環變數來協助貿易預測(Stock & Watson,2002)。

貿易理論本身對於經濟結構變數有完整描述，但根據實證結果發現，貿易變數是構成景氣循環的一部分，而其本身也會受到景氣循環影響，景氣循環和貿易的關係複雜且為非線性(Iyidoğan & Akbulut, 2017; Mosikari & Eita, 2020)。

貳、景氣循環同步現象

實證研究發現貿易關係越緊密的國家，其景氣循環相關性會更高(Kose & Yi,2006)。大量貿易使工業國家間的景氣循環同步程度增加，根據 1960-1999 年間共 147 個國家的數據，此現象在開發中國家也是可見的，但相關性較已開發工業國家小非常多。研究表明在已開發國家和開發中國家同步反應有差異，景氣循環同步性的差異主要源於專業化程度和雙邊貿易模式的差異(Calderon, Chong & Stein,2007)。

東亞地區景氣循環的性質與同步程度，由於東亞地區國家間貿易頻繁，經濟同步程度有逐年上升趨勢。大多數東亞國家有經濟成長的共同動力，也就是出口聯動的結果(Moneta & Rüffer,2009)。理論上貿易的增加會造成貿易夥伴間的景氣循環往任意方向轉變，一般來說產業間(inter-industry)的貿易會導致專業化程度提高，使同步性降低，而產業內(intra-industry)的貿易則會扭轉這類現象。根據 Shin & Wang(2003)研究中 12 個亞洲經濟體的數據，發

現產業內的貿易是導致亞洲經濟體之間景氣循環同步性增加的主要原因，且這個結果對於區域內貨幣同盟(currency union)有重要意義。

根據景氣循環同步現象，本研究在景氣循環變數中增加了與臺灣有密切貿易的國家的相關變數，以確保考量到貿易密切國家的經濟表現對臺灣進出口值的影響。

第四節 人工智慧(Artificial Intelligence, AI)

壹、卷積神經網路(Convolutional Neural Network, CNN)

CNN (卷積神經網路) 與傳統人工神經網路 (ANN) 類似，都會透過學習優化神經元組成。然而，CNN 和傳統 ANN 最顯著差異為 CNN 主要用於圖像辨識。此圖像辨識特點受到放射學界關注。CNN 在放射學診斷的應用具有重要意義，能夠協助放射科醫生的表現並提升對病患的照護。具體來說，CNN 在圖像辨識方面擁有一些獨特的優勢(O'Shea & Nash, 2015; Yamashita, 2018)。

Simard, Steinkraus & Platt(2003)分享具體的做法協助文件分析人員應用神經網路，主要提出重點如下：(1)通過添加數據來擁有盡可能大的訓練集；(2)了解卷積神經網路比全連接網路更適合識別文件的任務，且這個神經網路不需要複雜的方法。

CNN 同樣被應用於語音辨識，實證結果表明與用於電話辨識和語音搜索的深度神經網路(DNN)相比，CNN 具有更低的辨識錯誤率(Abdel-Hamid et al., 2014)。

貳、長短期記憶神經網路(Long Short-Term Memory, LSTM)

長短期記憶神經網路(LSTM)可以解決過去循環神經網路(RNN)方法無法處理的議題。LSTM 網路在處理連續的輸入流有優勢。如果沒有重置功能可能導致網路無限延長而崩潰。在研究中引入「遺忘門」的概念，讓 LSTM 能夠在適當的時間學會自我重置，釋放內部資源(Gers, Schmidhuber & Cummins, 2000; Staudemeyer & Morris, 2019)。

近年來，大量交通數據的可用性和計算能力的提升，促使我們應用 LSTM 網路對交通進行預測。短期交通預測是實現智能交通系統的核心關鍵，若能準確預測交通，通勤者就可以選擇適當出遊方式、路線和時間，對交通管理有重要意涵 (Zhao et al., 2017)。此外，我們還可以採用 LSTM 網路模型，利用高速公路的旅行時間數據，建構旅行時間預測模型(Duan, Yisheng & Wang, 2016)。

參、應用—財務金融領域

深度學習模型在財務金融領域的應用越來越普及。從最初研究人員創建的各種機器學習模型，到後來此領域出現的深度學習模型，深度學習模型預測結果優於傳統機器學習模型。對於通常涉及大量且複雜的數據集的問題，現有的金融理論和模型難以完整考量，而深度學習法的應用可產生較標準財務方法有用的結果(Heaton, Polson & Witte, 2017; Sezer, Gudelek & Ozbayoglu, 2020)。

由於深度學習模型在工程領域的普及，引起經濟和財務領域的研究興趣。Chen, He & Tso(2017)使用深度學習捕捉原油價格變動的複雜且非線性特徵，提出模型對原油價格的未來走勢做預測，結果顯示深度學習模型提高預測準確度。

根據以上文獻中關於深度學習在財務金融領域的應用成果，可以推斷在預測進出口值時，使用深度學習模型的準確度可能會高於傳統經濟模型。

肆、應用—貿易領域

Liu(2021)在分析國內外出口預測的研究後，結合神經網路和模糊理論建立了出口預測模型，並預測出口的變化區間。Zhang (2019)則提出深度學習模型在處理大量歷史資料方面具有優勢，可以縮短建模時間並獲得良好預測效果，為水產品的出口預測提供了一種新的方法。

進出口數據通常有巨量、非線性、難配適的特性，導致預測進出口具挑戰性。Qu et al.(2019)為解決進出口數據難以預測的問題，利用 LSTM 的循環神經網路進行預測中國山東省的數據，並證明神經網路的預測有效性高於傳統時間數列模型。Dave et al.(2021)基於 ARIMA 和 LSTM 模型的特點建立混合的機器學習模型，其中 LSTM 應用於數據的非線性部分，而 ARIMA 應用於數據的線性部分，此混合模型最終用於預測印尼的未來出口值。Chen et

al.(2021)建立長短期記憶網路模型(LSTM)預測石油進口風險。通過與 BP、SVM、CNN 模型的比較，針對石油進口風險的預測，LSTM 模型有更好的效果和預測績效。

考量到進出口數據的複雜性，深度學習模型很適合用於預測，因此本研究中選擇深度學習模型，並預期有良好的預測績效。

第三章 研究方法

本章節介紹本研究使用之研究方法，第一部份介紹研究變數，第二部分介紹傳統預測方法中的經濟結構模型和時間序列方法，第三部分介紹深度學習的 CNN 和 LSTM，第四節介紹模型預測績效評估之方式。

第一節 研究變數

本研究中使用的變數分為傳統預測方法和深度學習法兩塊。傳統預測方法所使用的變數為經濟結構模型中所提及的變數以及時間序列法所需的進出口值。深度學習法所使用的變數參考了蕭宇翔與林依伶(2020)的研究，納入該研究中使用的總體經濟變數，以及 2021 年與臺灣貿易總額前十名國家(中國、美國、日本、香港、韓國、新加坡、馬來西亞、德國、越南、澳大利亞)的加權 GDP 和 CPI，大致可以分為工業、貿易、勞動力、服務業、股價、物價指數、貨幣、金融(存放款)、金融(利率匯率)、經濟心理、經濟指標及國外這十二大類的經濟變數。

資料期間為 1980 年 1 月至 2022 年 11 月，採用月資料。每個變數共有 515 筆資料，劃分 80%的資料為訓練集和 20%的資料為測試集。訓練集包含了 1980 年 1 月至 2014 年 4 月的 412 筆資料，測試集包含了 2014 年 5 月至 2022 年 11 月，共 103 筆資料。

第二節 傳統預測方法

壹、經濟結構模型

根據經濟學理論的說法，影響國家進口需求的兩大經濟變量為國內實質所得和進口財相對價格。而出口和進口的模型是對稱關係，影響國家出口需求的兩大經濟變量為國外經濟活動及出口財相對價格 (Kabir,1988)。

參考過去文獻(eg. Kabir,1988 ; Tang,2003 ; Narayan&Narayan,2005 ; Narayan & Narayan,2010)，我們採用之進口需求函數模型為，

$$IM_t = \alpha + \beta_1 MRP_t + \beta_2 Y_t + \varepsilon_t \quad (1)$$

IM_t 為實質進口值(取自然對數); MRP_t 為進口財相對價格(取自然對數); Y_t 為實質國內生產毛額(取自然對數); ε_t 為迴歸誤差項。

出口需求函數模型部分，參考文獻 (Kabir,1988 ; Arize et al.,2000 ; Baak,2008 ; Narayan & Narayan,2010)後採用之模型設定為，

$$EX_t = \alpha + \beta_1 XRP_t + \beta_2 WY_t + \varepsilon_t \quad (2)$$

EX_t 為實質出口值(取自然對數); XRP_t 為出口財相對價格(取自然對數); WY_t 為國外經濟活動，以實質國外所得(取自然對數)衡量; ε_t 為迴歸誤差項。

貳、時間數列模型

時間序列預測利用欲求變數自身歷史資料對其進行預測，常使用之預測模型有：自我迴歸模型(Autoregressive Model,AR)，移動平均模型(Moving Average Model,MA)，以及結合 AR 模型與 MA 模型之自我迴歸移動平均模型(Autoregressive Moving Average Model,ARMA)。本篇研究利用 ARMA 模型對進出口值進行預測，模型設定如下：

AR(p)模型：

$$y_t = \alpha + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \cdots + \beta_p y_{t-p} + \varepsilon_t \quad (3)$$

$$y^*_t = \alpha^* + \beta_1 y^*_{t-1} + \beta_2 y^*_{t-2} + \cdots + \beta_p y^*_{t-p} + \varepsilon^*_t \quad (4)$$

y_t 為進口值預測值，假設預測值與自身過去落後 p 期之資料有關，寫成公式(3)之 AR 模型。其中 α 為常數項， ε_t 為干擾項。 y^*_t 為出口值預測值，假設預測值與自身過去落後 p 期之資料有關，寫成公式(4)之 AR 模型，其中 α^* 為常數項， ε^*_t 為干擾項。

MA(q)模型：

$$y_t = \mu + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (5)$$

$$y^*_t = \mu^* + \theta_1 \varepsilon^*_{t-1} + \theta_2 \varepsilon^*_{t-2} + \cdots + \theta_q \varepsilon^*_{t-q} + \varepsilon^*_t \quad (6)$$

y_t 為進口值預測值，假設預測值與過去 q 期之殘差值有關，寫成公式(5)之 MA 模型。其中 μ 為數列平均值， ε_t 為干擾項。 y^*_t 為出口值預測值，假設預測值與過去 q 期之殘差值有關，寫成公式(6)之 MA 模型，其中 μ^* 為數列平均值， ε^*_t 為干擾項。

ARMA(p,q)模型：

$$y_t = c + \beta_1 y_{t-1} + \cdots + \beta_p y_{t-p} + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (7)$$

$$y^*_t = c^* + \beta_1 y^*_{t-1} + \cdots + \beta_p y^*_{t-p} + \theta_1 \varepsilon^*_{t-1} + \cdots + \theta_q \varepsilon^*_{t-q} + \varepsilon^*_t \quad (8)$$

y_t 為進口值預測值，假設預測值與過去落後 p 期之資料和過去 q 期之殘差值相關，因此公式(7)結合部分 AR 模型(公式(3))及部分 MA 模型(公式(5))，模型中包含 p 個自我迴歸項及 q 個移動平均項。其中 c 為常數項， ε_t 為干擾項。 y^*_t 為出口值預測值，假設預測值與過去落後 p 期之資料和過去 q 期之殘差值相關，因此公式(8)結合部分 AR 模型(公式(4))及部分 MA 模型(公式(6))，模型中包含 p 個自我迴歸項及 q 個移動平均項。其中 c^* 為常數項， ε^*_t 為干擾項。

參數估計：

ARMA(p,q)模型的階次選擇，我們利用訊息量準則作為選擇標準，實務上常用赤池訊息量準則(Akaike Information Criterion, AIC)和貝氏訊息量準則(Bayesian Information Criterion, BIC)。操作方式為設定最大階次，並根據 AIC 及 BIC 進行選擇，以訊息量準則最小值對應之階次(p,q)為最適階次。

第三節 深度學習法

壹、卷積神經網路(Convolutional Neural Network, CNN)

卷積神經網路由 Fukushima(1980)提出，主要應用於圖像處理、影像辨識領域。我們所熟知的圖片是由多個像素組成，而我們可以將每個像素都視為一個輸入變數。當圖片解析度高且像素數量多時，為了能夠順利且有效地辨識圖片，我們需要對圖片進行特徵提取(即降維處理)，這個處理概念類似於主成分分析或因素分析方法。本研究將景氣循環視為一張圖片，每個景氣循環由 M 個總體變數組成，因此每張景氣循環圖片就有 M 個像素，整個研究共有 T 期景氣循環(T 張圖片)。透過 CNN 進行特徵提取(降維)，我們可以建構景氣循環指標，並用以預測進出口值。

CNN 之原理是將圖片經過過濾器(filter)來強化圖片的特徵，並在此基礎上進行深度學習。當圖片之解析度和像素較高時，若將像素直接輸入至神經層(layer)的神經元中，神經網路之模型參數數量將會過多，進而增加過度配適(overfitting)的風險。因此，如何減少模型參數數量以避免過度配適是圖片辨識中的重要問題。

CNN 通常由卷積層(Convolution Layer)、池化層(Pooling Layer)、全連接層(Fully Connected Layer)組成。卷積層的主要功能為減少每個神經元處理的輸入變數數量，讓每個神經元負責處理一個大小為 $N \times N$ 的輸入像素區域，這個區域被稱為感受野(Received Field)。感受野可以重疊，同一個感受野可以由多個神經元負責，並且不同神經元可以共用參數，這樣可以減少神經元處理的輸入變數個數。

操作時我們事先定義好的過濾器逐步掃過圖片，過濾器是一個小型的矩陣或權重集，代表某種特定的圖像特徵，掃過之圖片區域像素值會與過濾器進行兩兩乘積，如果圖片區域的特徵與過濾器特徵相似，則運算後的值會增大以強化圖片特徵，反之值則會減小。此過程使輸入變數經過卷積層後維度下降，並生成一個稱為特徵地圖(Feature Map)的降維變數。

池化層則用於壓縮圖片並保留重要資訊，幫助判斷圖片中是否包含某些特徵。池化層將特徵地圖作為輸入，計算其平均值或最大值，進而在降維同時保留了最重要的特徵。變數經過卷積層和池化層之運算後，輸入變數的維度已大幅縮小，重要特徵已被提取。最後再將這些特徵值輸入到全連接層進行運算並做預測。

貳、長短期記憶模型(Long Short-Term Memory, LSTM)

在我們將景氣循環的組成變數經過 CNN 做特徵提取後，輸入全連接神經網路處理後，即可得到進/出口之預測值。本研究中使用了一種具長短期記憶(LSTM)的神經網路架構作為最終預測模型。

神經網路架構主要包含輸入層(Input Layer)、隱藏層(Hidden Layer)、輸出層(Output Layer)。輸入層和輸出層的變數數量以及隱藏層的數目皆可以由使用者自行決定。在神經網路中，基本單位是神經元，神經元為線性函數，將前一層神經元之輸出值為輸入值，經過線性函數和激發函數的運算得到輸出值，而此輸出值會作為下一層神經元之輸入。激發函數的選擇使模型可處理資料中複雜且非線性的關係。增加神經元個數和隱藏層層數可近似非線性關係，此種增加層數的方法即為深度學習。常見的激發函數有羅吉斯函數(logistic function)與線性整流函數，函數表示如下：

$$\begin{aligned} \text{羅吉斯函數: } S(x) &= \frac{1}{1+e^{-x}} \\ \text{線性整流函數: } ReLU &= \text{Max}(0, x) \end{aligned} \quad (9)$$

相較於傳統預測方法，深度學習不需要先假設變數與預測值間的關係是線性的，而是可以透過資料本身去決定變數之間的關係是線性還是非線性。神經網路中各層神經元透過對應的參數連接，這些參數值須經過資料訓練得出。在資料通過神經網路得出預測結果後，我們計算預測值與實際值的誤差，然後使用反向演算法將誤差傳遞回去，並透過調整神經元權重找到最小的均方根誤差(RMSE)。

在選擇使用的神經網路類型時，我們允許神經元間存在內部回饋現象，這種內部回饋機制使前一層的訊息可以傳遞至下一層，然後再傳遞回前一層，此回饋機制可保留時間序列的長期記憶，非常適合用來預測非線性的時間序列。此種類型的循環神經網路有兩種常見模型，分別是RNN(Elman,1990)和LSTM(Hochreiter & Schmidhuber,1997)。LSTM 模型既可以預測非線性時間序列，又可以避免梯度消失問題，改善了 RNN 長期記憶不足的問題。

LSTM 包含輸入層、遞迴的隱藏層與輸出層。隱藏層使用記憶區塊(memory block)取代普通神經元，並導入三個控制記憶的機制，即輸入門(input gate)、輸出門(output gate)和忘記門(forget gate)。其中，忘記門之功能在於避免梯度消失的問題。這三個門的開啟與關閉也是模型中的參數之一，透過資料學習來決定哪些資訊要被忘掉或學習(Bucci, 2020)。LSTM 的記憶細胞運作方式如圖 3.1 所示。




圖 3.2 LSTM 記憶細胞

第四節 預測績效評估

本研究以均方根誤差(Root-mean-square error, RMSE)以及平均絕對百分比誤差(Mean absolute percentage error, MAPE)衡量模型的預測效果。公式如下：

$$RMSE = \sqrt{\frac{\sum (y_t - \hat{y}_t)^2}{n}} \quad (10)$$

y_t 為 t 期實際值， $\hat{y}_t$ 為 t 期預測值， n 為測試集資料個數。當 RMSE 值愈小，預測值之準確度愈高。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (11)$$

y_i 為 i 期實際值， $\hat{y}_i$ 為 i 期預測值， n 為測試集資料個數。當 MAPE 值愈小，預測值之準確度愈高。

第四章 研究結果

第一節 研究資料

壹、資料來源

傳統預測方法所使用的變數整理如表 4.1。深度學習法所使用的變數整理如表 4.2。

表 4.1 經濟結構模型變數

變數名稱	資料來源
實質進口值	AREMOS
實質出口值	AREMOS
進口財相對價格	FRED+自行設算
出口財相對價格	FRED+一自行設算
實質國內生產毛額	stock-ai (from 行政院主計總處)
實質國外所得	FRED

表 4.2 景氣循環變數

分類	變數名稱	資料來源
Group1 工業	工業生產指數	AREMOS+Stock-ai (from 行政院經建會)
	製造業生產量指數	經濟部統計處
	製造業銷售量指數	經濟部統計處
	製造業存貨量指數	經濟部統計處
	製造業生產價值	經濟部統計處
	製造業銷售價值	經濟部統計處
	製造業存貨價值	經濟部統計處
	製造業存貨率	經濟部統計處
	製造業營業氣候觀測點	Money DJ 理財網
	電力(企業)總用電量	Stock-ai (from 行政院經建會)
Group2 貿易	機械及電機設備進口值(新臺幣)	Stock-ai(from 行政院經建會)
	實質海關出口值(新臺幣)	自行計算(x10/x42)
	實質海關進口值(新臺幣)	自行計算(x11/x42)
	實質機械及電機設備進口值(新臺幣)	自行計算(x12/x42)
	出口數量指數	AREMOS
	進口數量指數	AREMOS
	純貿易條件	AREMOS
	所得貿易條件	AREMOS
	外銷訂單動向指數(以家數計)	AREMOS+Stock-ai (from 行政院經建會)
Group3 勞動力	工業勞動生產力指數	AREMOS+中華民國統計資訊網
	製造業勞動生產力指數	AREMOS+中華民國統計資訊網
	製造業單位產出勞動成本指數	AREMOS+中華民國統計資訊網
	工業及服務業經常性薪資	勞動部勞動統計查詢網
	工業及服務業實質經常性薪資	勞動部勞動統計查詢網
	非農業部門就業人數	Stock-ai(from 行政院經建會)
	工業及服務業經常性受雇員工人數	AREMOS
	工業及服務業經常性受雇員工淨進入率	AREMOS+自行計算
	每人每月平均總工時	勞動部勞動統計查詢網
	每人每月平均加班工時	勞動部勞動統計查詢網
	失業率	勞動部勞動統計查詢網
Group4 服務業	批發、零售及餐飲業營業額	經濟部統計處+自行計算
	批發業營業額	經濟部統計處
	零售業營業額	經濟部統計處
	餐飲業營業額	經濟部統計處
Group5 股價	股價指數	AREMOS
	股市日平均成交值	AREMOS
Group6 物價指數	消費者物價指數	AREMOS
	核心物價指數	Stock-ai (from 行政院主計處)
	躉售物價指數	AREMOS

表 4.3 景氣循環變數(續)

分類	變數名稱	資料來源
Group7 貨幣	通貨淨額	AREMOS
	準備貨幣	AREMOS
	貨幣總計數—M1A	AREMOS
	貨幣總計數—M1B	AREMOS
	貨幣總計數—M2	AREMOS
	貨幣總計數—實質 M1B	自行計算(x48/x42)
	貨幣總計數—實質 M2	自行計算(x49/x42)
Group8 金融 (存放款)	主要金融機構存款	Stock-ai (from 中央銀行)
	貨幣機構放款與投資	Stock-ai (from 中央銀行)
	貨幣機構放款	Stock-ai (from 中央銀行)
	貨幣機構對非金融機構證券投資	政府資料開放平台
	五大銀行新承做放款金額	AREMOS+政府資料開放平台
Group9 金融 (利率匯率)	五大銀行新承做放款利率	AREMOS+政府資料開放平台
	金融業隔夜拆款利率	AREMOS
	商業本票利率—次級市場—1-30 天期	AREMOS
	商業本票利率—次級市場—31-90 天期	AREMOS
	10 年期政府公債次級市場利率	AREMOS
	10 年期公債減隔拆利率	自行計算(x61-x58)
	10 年期公債減商業本票 1-30 天期	自行計算(x61-x59)
	10 年期公債減商業本票 31-90 天期	自行計算(x61-x60)
	名目有效匯率	Stock-ai (from 國際清算銀行)
	實質有效匯率	Stock-ai (from 國際清算銀行)
Group10 經濟心理	消費者信心指數	AREMOS+Stock-ai (from 中央大學台灣經濟發展研究中心)
	消費者信心指數—未來半年國內經濟景氣	AREMOS+Stock-ai (from 中央大學台灣經濟發展研究中心)
Group11 經濟指標	國發會領先指標綜合指數(不含趨勢)	統計資訊網
	國發會同時指標綜合指數(不含趨勢)	統計資訊網
	國發會落後指標綜合指數(不含趨勢)	Stock-ai (from 國家發展委員會)
	建築物開工樓地板面積	Stock-ai (from 行政院經建會)
Group12 國外	OECD 領先指標—Total	Stock-ai (from 經濟合作暨發展組織)
	OECD 領先指標 +6 個非會員國	Stock-ai (from 經濟合作暨發展組織)
	亞洲主要 5 國領先指標	Stock-ai (from 經濟合作暨發展組織)
	世界工業生產指數	Stock-ai (from 經濟合作暨發展組織)
	G7 會員國工業生產指數	Stock-ai (from 經濟合作暨發展組織)
	美國工業生產指數	OECD data
	美國 PMI	Stock-ai (from 美國供應管理協會)
	美國長短期利差	Stock-ai (from 經濟合作暨發展組織)
	與台灣貿易前十大國家 GDP 加權和	FRED(資料)+EViews 處理
	與台灣貿易前十大國家 CPI 加權和	FRED(資料)+EViews 處理
輸出	海關出口值(新臺幣)	AREMOS
	海關進口值(新臺幣)	AREMOS

貳、資料預處理

本研究，對於變數的預處理進行了以下幾點：

1.加權 GDP 和加權 CPI：根據 2021 年與臺灣貿易總額前十名國家，計算各國家佔貿易總額的比例，作為權重，對 GDP 和 CPI 進行運算。

2.進/出口財相對價格：由於國內外進出口財價格不易取得完整資料，本研究此變數使用公式(12)自行設算，其中 CPI*代表與「台灣貿易前十大國家加權 CPI」， e 表示匯率。

$$\text{相對價格} = \frac{\text{CPI}^* \times e}{\text{CPI}} \quad (12)$$

3.缺失資料：若資料缺失為未來值，則使用時間序列估算方法填補缺失值；若資料缺失為過去值，則暫時以 0.0001 代替。另外，GDP 的年資料和季資料被 Eviews 轉換為月資料使用。

4. 取自然對數處理：所有放入模型中的變數都經過取自然對數的處理，以使數據符合模型的要求。

第二節 傳統預測方法

壹、經濟結構模型

出口需求函數與進口需求函數的迴歸分析結果如表 4.3 所示。出口需求函數的 RMSE 為 0.3625、MAPE 為 0.0256，而進口需求函數的 RMSE 為 0.1966、MAPE 為 0.0127。圖 4.1 呈現了預測出口值與實際出口值的時間序列圖，雖然預測值較實際值高估，但整體趨勢皆呈上升趨勢。圖 4.2 呈現了預測進口值與實際進口值的时间序列圖，預測值有起伏但最終呈現上升的趨勢，整體而言預測值較實際值有高估情形。

表 4.4 經濟結構模型結果

	RMSE	MAPE
出口	0.3625	0.0256
進口	0.1966	0.0127




圖 4.4 出口需求函數預測



圖 4.3 進口需求函數預測

貳、時間序列模型

本研究選擇參數之標準為赤池訊息量準則(Akaike Information Criterion, AIC)的最小值組合。得到出口值的时间序列模型為 ARMA(5,9)，進口值的时间序列模型為 ARMA(7,7)，預測結果如表所示。出口值 ARMA(5,9)的 RMSE 為 0.1908、MAPE 為 0.0100，而進口值 ARMA(7,7)的 RMSE 為 0.1937、MAPE 為 0.0108。預測出口值與實際出口值的时间序列圖呈現如圖 4.3，預測進口值與實際進口值的时间序列圖呈現如 4.4。進出口的預測值皆呈現波浪起伏，呈現週期性的變動。

表 4.5 時間序列模型結果

		RMSE	MAPE
出口	ARMA(5,9)	0.1908	0.0100
進口	ARMA(7,7)	0.1937	0.0108



圖 4.3 出口值時間序列預測




圖 4.4 進口值時間序列預測

第三節 深度學習法

壹、長短期記憶模型(LSTM)

本研究不僅將所有變數一起作為輸入，還將十二大類的變數分組，將每組分別作為單獨的輸入，並使用進/出口值作為對應的輸出，以訓練和測試模型的預測能力。各組別對應的變數類別如表 4.5。礙於研討會篇幅問題，實證結果僅呈現所有景氣循環變數作為輸入之結果以及根據 MAPE 預測效果較佳之前三組別。

表 4.6 景氣循環變數分組對照表

組別	group1	group2	group3	group4	group5	group6
變數類別	工業	貿易	勞動力	服務業	股價	物價指數
組別	group7	group8	group9	group10	group11	group12
變數類別	貨幣	金融(存放款)	金融(利率匯率)	經濟心理	經濟指標	國外

以出口值作為輸出的 LSTM 模型，實證結果如表 4.6。當將所有景氣循環變數作為輸入，訓練集的 RMSE 為 0.1101、MAPE 為 0.0071，測試集的 RMSE 為 0.2666、MAPE 為 0.0153。當以不同類別變數分別作為輸入，金融(存放款)、經濟心理、經濟指標對於出口值的預測準確度較高。

表 4.6 出口值 LSTM 模型結果

	訓練集		測試集	
	RMSE	MAPE	RMSE	MAPE
全部變數	0.1101	0.0071	0.2666	0.0153
金融(存放款)	0.1088	0.0069	0.2423	0.0123
經濟心理	0.1254	0.0079	0.2115	0.0118
經濟指標	0.1208	0.0075	0.2273	0.0121




圖 4.6 出口值 LSTM 預測-全部變數




圖 4.5 出口值 LSTM 預測-金融(存放款)



圖 4.7 出口值 LSTM 預測-經濟心理



圖 4.8 出口值 LSTM 預測-經濟指標

以進口值作為輸出的 LSTM 模型，實證結果如表 4.7。當將所有景氣循環變數作為輸入，訓練集的 RMSE 為 0.1032、MAPE 為 0.0065，測試集的 RMSE 為 0.2668、MAPE 為 0.0121。當以不同類別變數分別作為輸入，貿易、金融(存放款)、國外對於進口值的預測準確度較高。

表 4.7 進口值 LSTM 模型結果

	訓練集		測試集	
	RMSE	MAPE	RMSE	MAPE
全部變數	0.1032	0.0065	0.2268	0.0121
貿易	0.1226	0.0077	0.1942	0.0111
金融(存放款)	0.1189	0.0073	0.2438	0.0121
國外	0.1098	0.0070	0.2353	0.0120




圖 4.9 進口值 LSTM 預測-全部變數



圖 4.10 進口值 LSTM 預測-貿易




圖 4.11 進口值 LSTM 預測-金融(存放款)



圖 4.12 進口值 LSTM 預測-國外

貳、卷積神經網路(CNN)+長短期記憶模型(LSTM)

本方法利用 CNN 做特徵提取後放入 LSTM 中，輸入為 80 個經濟相關變數，輸出為出口值或進口值。CNN+LSTM 的實證結果如表 4.8，預測出口值的模型訓練集 RMSE 為 0.0470、MAPE 為 0.0028，測試集為 RMSE 為 0.1471、MAPE 為 0.0078，預測進口值的模型訓練集 RMSE 為 0.0512、MAPE 為 0.0028，測試集 RMSE 為 0.1409、MAPE 為 0.0079。

表 4.7 CNN+LSTM 模型結果

	訓練集		測試集	
	RMSE	MAPE	RMSE	MAPE
出口	0.0470	0.0028	0.1471	0.0078
進口	0.0512	0.0028	0.1409	0.0079

圖 4.13 和圖 4.14 分別為出口值和進口值的訓練集預測值和實際值的时间序列圖，圖形與 LSTM 相比較相符，顯示出 CNN+LSTM 模型在訓練集上有較好的配適度。而圖和圖分別為出口值和進口值的測試集預測值和實際值的时间序列圖，可以觀察到 CNN+LSTM 預測值的趨勢與 LSTM 預測值相似，但在 2021 年後，CNN+LSTM 的預測值更加貼近實際值。



圖 4.13 出口值 CNN+LSTM 預測



圖 4.14 進口值 CNN+LSTM 預測

第四節 統預測方法與深度學習法之比較

本節將統整不同方法出口值的預測績效與進口值的預測績效，並根據統整結果找出較佳的預測模型。根據統整的結果，考量到 MAPE 是以百分比方式呈現預測的誤差，比起 RMSE 更適合作為不同模型間比較的選擇標準。因此，本研究認為對於進出口值的預測，CNN+LSTM 表現最佳，其次是時間序列模型，然後是 LSTM 模型，而經濟結構模型最差。

在深度學習法中，LSTM 模型的測試集上的 MAPE 較傳統時間序列模型(ARMA)高，原因是因為輸入中有大量變數的具有相似性，導致模型出現過度配適(overfitting)情形。在此情況相對簡單地利用自身歷史資料的時間序列模型反而表現較好。當深度學習模型中輸入包含大量高相關性的變數時，有經過 CNN 進行特徵提取再輸入 LSTM 可以使深度學習的預測有更良好的績效表現。傳統經濟結構模型的預測績效表現已經非常良好，但想更進一步選擇更優的模型，深度學習方法是較佳選擇。

表 4.8 出口值各預測模型結果比較

	經濟結構模型	時間序列模型	LSTM	CNN+LSTM
RMSE	0.3625	0.1908	0.2666	0.1471
MAPE	0.0256	0.0100	0.0153	0.0078

表 4.10 進口值各預測模型結果比較

	經濟結構模型	時間序列模型	LSTM	CNN+LSTM
RMSE	0.1966	0.1937	0.2268	0.1409
MAPE	0.0127	0.0108	0.0121	0.0079

第五章 結論與建議

第一節 研究結論

根據實證結果，在預測進出口值方面 CNN+LSTM 的深度模型表現最佳，成為最適合的模型選擇。透過 CNN 進行特徵提取，再將特徵輸入 LSTM 進行序列建模，能夠更好地捕捉時間序列資料的關聯性。此模型在測試集上顯示出較低的 MAPE，證實其優於傳統時間序列模型及經濟結構模型。

第二節 研究貢獻

本研究將深度學習法應用到跨領域的研究中，並探討其在經濟預測領域的應用，這一應用突破了傳統經濟預測方法的限制。深度學習能夠從大規模和複雜的數據中提取有價值的資訊，在經濟預測中展現出了良好的績效。

此外，本研究結合景氣循環指標與 CNN 的影像辨識技術，並成功將圖像資料轉化為具有經濟意義的變數。此方法亦可以應用於其他經濟相關的預測中，對深度學習的應用和經濟預測的方法做出了創新貢獻。

經濟預測對於政府機構和企業等實務界相當重要，準確的預測模型可以幫助決策者做出更明智的決策、制定有效的和策略，進而提高經濟效益和降低風險。

第三節 研究限制及未來建議

1. 更加多元的變數: 本研究僅採用 12 大類的總體經濟相關變數作為輸入，未來的研究可以考慮引入更加多元的變數，包括但不限於社會和環境等領域的指標。這樣可以更全面地考慮各種影響經濟預測的因素。
2. 降低過度配適的情形: 本篇研究中可見測試集與訓練集的預測績效有落差，此現象即代表有出現過度配適。未來的研究可以探索各種方法來降低過度配適的情形以提高模型一般化的能力。
3. 參數調整: 深度學習模型中存在許多參數需要調整，包括隱藏層數量、神經元數目、激活函數和訓練集大小等。未來的研究可以進一步使用自動調整參數的方法，優化模型的性能，找到最佳的參數組合。

參考文獻

中文參考文獻

- 李政峯(2021)。後疫情時代全球貿易趨勢之預測：深度學習之應用。科技部 110 年度專題研究計畫。
- 蕭宇翔、林依伶(2020)。臺灣景氣狀態之預測。臺灣經濟預測與政策，51:1，1-56。

黃裕烈、徐之強、張瑞雲(2019)。**景氣監測預警系統之研究**。國家發展委員會研究報告(報告編號：(108)015.0205)，未出版。

周大森(2019)。**運用大量數據認定景氣轉折點**。國家發展委員會研究報告(報告編號：(108)020.0209)，未出版。

何宗武、葉國俊、張淑華、林雅淇(2020)。**運用人工智慧掌握景氣動態**。國家發展委員會研究報告(報告編號：(109)025.0205)，未出版。

英文參考文獻

- A. Giles, J., & Williams, C. L. (2000). Export-led growth: a survey of the empirical literature and some non-causality results. Part 1. *The Journal of International Trade & Economic Development*, 9(3), 261-337.
- Abdel-Hamid, O., Mohamed, A.-r., Jiang, H., Deng, L., Penn, G., & Yu, D. (2014). Convolutional neural networks for speech recognition. *IEEE/ACM Transactions on audio, speech, and language processing*, 22(10), 1533-1545.
- Aditya, A., & Acharyya, R. (2013). Export diversification, composition, and economic growth: Evidence from cross-country analysis. *The Journal of International Trade & Economic Development*, 22(7), 959-992.
- Amat, C., Michalski, T., & Stoltz, G. (2018). Fundamentals and exchange rate forecastability with simple machine learning methods. *Journal of International Money and Finance*, 88, 1-24.
- Arize, A. C. (2001). Traditional export demand relation and parameter instability: An empirical investigation. *Journal of Economic Studies*.
- Arize, A. C., Osang, T., & Slottje, D. J. (2000). Exchange-rate volatility and foreign trade: evidence from thirteen LDC's. *Journal of Business & Economic Statistics*, 18(1), 10-17.
- Arumugam, P., & Anithakumari, V. (2013). Fuzzy time series method for forecasting Taiwan export data. *International Journal of Engineering Trends and Technology (IJETT)-Volume4 Issue8-August*.
- Awokuse, T. O. (2008). Trade openness and economic growth: is growth export-led or import-led? *Applied Economics*, 40(2), 161-173.
- Bahmani-Oskooee, M., & Economidou, C. (2009). Export led growth vs. growth led exports: LDCs experience. *The Journal of Developing Areas*, 42(2), 179-209.
- Bhagwati, J. N. (1988). Export-promoting trade strategy: issues and evidence. *The World Bank Research Observer*, 27-57.
- Bucci, A. (2020). Cholesky-ANN models for predicting multivariate realized volatility. *Journal of Forecasting*, 39(6), 865-876.
- Calderon, C., Chong, A., & Stein, E. (2007). Trade intensity and business cycle synchronization: Are developing countries any different? *Journal of international Economics*, 71(1), 2-21.
- Chen, S., Song, Y., Ding, Y., Zhang, M., & Nie, R. (2021). Using long short-term memory model to study risk assessment and prediction of China's oil import from the perspective of resilience theory. *Energy*, 215, 119152.
- Chen, S.-W. (2008). Long-run aggregate import demand function in Taiwan: an ARDL bounds testing approach. *Applied Economics Letters*, 15(9), 731-735.
- Chen, Y., He, K., & Tso, G. K. (2017). Forecasting crude oil prices: a deep learning based model. *Procedia Computer Science*, 122, 300-307.
- Chou, W. L. (2000). Exchange rate variability and China's exports. *Journal of Comparative Economics*, 28(1), 61-79.
- Coe, D. T., & Helpman, E. (1995). International r&d spillovers. *European economic review*, 39(5), 859-887.
- Dash, A. K., Dutta, S., & Paital, R. R. (2018). Bilateral export demand function of India: An empirical analysis. *Theoretical Economics Letters*, 8(11), 2330-2344.
- Dave, E., Leonardo, A., Jeanice, M., & Hanafiah, N. (2021). Forecasting Indonesia exports using a hybrid model ARIMA-LSTM. *Procedia Computer Science*, 179, 480-487.
- Duan, Y., Yisheng, L., & Wang, F.-Y. (2016). Travel time prediction with LSTM neural network. 2016 IEEE 19th international conference on intelligent transportation systems (ITSC),
- Dutta, D., & Ahmed, N. (1999). An aggregate import demand function for Bangladesh: a cointegration approach. *Applied Economics*, 31(4), 465-472.

- Dutta*, D., & Ahmed, N. (2004). An aggregate import demand function for India: a cointegration analysis. *Applied Economics Letters*, 11(10), 607-613.
- Edwards, S. (1998). Openness, productivity and growth: what do we really know? *The Economic Journal*, 108(447), 383-398.
- Emery, R. F. (1967). The relation of exports and economic growth. *Kyklos*, 20(4), 470-486.
- Farooqi, A. (2014). ARIMA model building and forecasting on imports and exports of Pakistan. *Pakistan Journal of Statistics and Operation Research*, 157-168.
- Fukushima, K., & Miyake, S. (1982). Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In *Competition and cooperation in neural nets* (pp. 267-285). Springer.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural computation*, 12(10), 2451-2471.
- Hausmann, R., Hwang, J., & Rodrik, D. (2007). What you export matters. *Journal of economic growth*, 12(1), 1-25.
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2017). Deep learning for finance: deep portfolios. *Applied Stochastic Models in Business and Industry*, 33(1), 3-12.
- Hopp, D. (2022). Benchmarking Econometric and Machine Learning Methodologies in Nowcasting. *arXiv preprint arXiv:2205.03318*.
- Hossain, A. A. (2009). Structural change in the export demand function for Indonesia: Estimation, analysis and policy implications. *Journal of Policy Modeling*, 31(2), 260-271.
- Iyidoğan, P. V., Dalgıç, B., & Akbulut, H. (2017). Is there a non-linear relationship between trade and growth? A panel threshold analysis for Central and Eastern European countries. *Acta Oeconomica*, 67(1), 117-136.
- Kabir, R. (1988). Estimating import and export demand function: The case of Bangladesh. *The Bangladesh Development Studies*, 16(4), 115-127.
- Khan, T. (2011). Identifying an appropriate forecasting model for forecasting total import of Bangladesh. *Statistics in Transition new series*, 12(1), 179-192.
- Kongcharoen, C., & Kruangpradit, T. (2013). Autoregressive integrated moving average with explanatory variable (ARIMAX) model for Thailand export. 33rd International Symposium on Forecasting, South Korea,
- Kose, M. A., & Yi, K.-M. (2006). Can the standard international business cycle model explain the relation between trade and comovement? *Journal of international Economics*, 68(2), 267-295.
- Kumar, G., & Gupta, S. (2010). Forecasting Exports of Industrial Goods from Punjab-An Application of Univariate ARIMA Model. *Annals of the University of Petrosani, Economics*, 10(4), 169-180.
- Kumar, S. (2011). Estimating export demand equations in selected Asian countries. *Journal of Chinese Economic and Foreign Trade Studies*.
- Liu, Y. (2021). Foreign Trade Export Forecast Based on Fuzzy Neural Network. *Complexity*, 2021.
- Maitra, B. (2020). Exploring import-led growth in India: Evidence from the post-reform period. *South Asian Journal of Macroeconomics and Public Finance*, 9(1), 87-113.
- Moneta, F., & Rüffer, R. (2009). Business cycle synchronisation in East Asia. *Journal of Asian Economics*, 20(1), 1-12.
- Mosikari, T. J., & Eita, J. H. (2020). Modelling asymmetric relationship between exports and growth in a developing economy: Evidence from Namibia. *South African Journal of Economic and Management Sciences*, 23(1), 1-10.
- Mujahid, N., Begam, A., Shamshir, M., Zeb, A., & Phil, M. (2019). Import-led growth hypothesis: A case study of Pakistan. *Journal of Economics and Sustainable Development*, 10(8), 20-28.
- Narayan, S., & Narayan, P. K. (2005). An empirical analysis of Fiji's import demand function. *Journal of Economic Studies*.
- Narayan, S., & Narayan, P. K. (2010). Estimating import and export demand elasticities for Mauritius and South Africa. *Australian economic papers*, 49(3), 241-252.
- O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.

- Park, Y.-J. (2013). Regional business cycles in East Asia: synchronization and its determinants. *Journal of East Asian Economic Integration*, 17(2), 103-128.
- Prasad, E. S. (1999). International trade and the business cycle. *The Economic Journal*, 109(458), 588-606.
- Qu, Q., Li, Z., Tang, J., Wu, S., & Wang, R. (2019). A trend forecast of import and export trade total volume based on LSTM. *IOP Conference Series: Materials Science and Engineering*,
- Ram, R. (1985). Exports and economic growth: Some additional evidence. *Economic Development and Cultural Change*, 33(2), 415-425.
- Rangasamy, L. (2009). Exports and economic growth: The case of South Africa. *Journal of International Development: The Journal of the Development Studies Association*, 21(5), 603-617.
- SaangJoon, B. (2008). The bilateral real exchange rates and trade between China and the US. *China Economic Review*, 19(2), 117-127.
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied soft computing*, 90, 106181.
- Shin, K., & Wang, Y. (2003). Trade integration and business cycle synchronization in East Asia. *Asian Economic Papers*, 2(3), 1-20.
- Simard, P. Y., Steinkraus, D., & Platt, J. C. (2003). Best practices for convolutional neural networks applied to visual document analysis. *Icdar*,
- Staudemeyer, R. C., & Morris, E. R. (2019). Understanding LSTM--a tutorial into long short-term memory recurrent neural networks. *arXiv preprint arXiv:1909.09586*.
- Stock, J. H., & Watson, M. W. (2002). Forecasting using principal components from a large number of predictors. *Journal of the American statistical association*, 97(460), 1167-1179.
- Sultan, Z. A. (2014). Saudi's export demand function: The ARDL approach. *Journal of Economics and Sustainable Development*, 5(3), 200-206.
- Tang, T. C. (2003). An empirical analysis of China's aggregate import demand function. *China Economic Review*, 14(2), 142-163.
- Tang, T. C. (2003). Japanese aggregate import demand function: reassessment from the 'bounds' testing approach. *Japan and the World Economy*, 15(4), 419-436.
- Tang, T. C., & Nair, M. (2002). A cointegration analysis of Malaysian import demand function: reassessment from the bounds test. *Applied Economics Letters*, 9(5), 293-296.
- Wang, C.-C. (2011). A comparison study between fuzzy time series model and ARIMA model for forecasting Taiwan export. *Expert Systems with Applications*, 38(8), 9296-9304.
- Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, 9(4), 611-629.
- Zhang, Y. (2019). Application of improved BP neural network based on e-commerce supply chain network data in the forecast of aquatic product export volume. *Cognitive Systems Research*, 57, 228-235.
- Zhao, Z., Chen, W., Wu, X., Chen, P. C., & Liu, J. (2017). LSTM network: a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 11(2), 68-75.