編號:(109)025.0205

運用人工智慧掌握景氣動態

「本研究報告內容僅供本會業務參考」

國家發展委員會 編著中華民國 109 年 12 月

編號:(109)025.0205

運用人工智慧掌握景氣動態

委託單位:國家發展委員會

受託單位:國立臺灣師範大學

計畫主持人:何宗武

協同主持人: 葉國俊、張淑華、林雅淇

計畫期程:109年3月26日-109年12月25日

國家發展委員會 編著中華民國 109 年 12 月

本案主旨為大數據機器學習,也就是所謂 data-driven。基於此, 我們旨在提出一個「訓練」景氣循環「預測」的大規模資料結構。我 們採用 68 筆變數,從 1982/1 到 2019/12,與兩組機器學習模型:組 1: GLM, SVM, TREE, RF。組 2: H2O.ai 的 autoML 和 RNN-LSTM。

本案對於採納人工智慧方法對時間序列預測的建議:任何單一模型皆會面臨未來資料性質不確定帶來的預測問題,因此,人工智能或機器學習等模型也不例外。但是, data-driven 的機器學習有大量模型可以訓練出大量預測,因此,採用 Forecasting Average 整合結果可提高預測正確性。LSTM 學習過程複雜,因此演算耗時且表現也沒有比較好,人工智慧平台 H2O.ai 提供的開源程式 autoML 有深度學習的項目,而且是將五個進階模型做預測平均組合。相當符合我們做的方式,建議未來可以直接採用。

未來研究建議:採用 Rabinowicz and Rosset (2020) 的 Corrected CV 更精確掌握模型篩選,提升 forecasting average 的表現。

Abstract

The objective of this project is machine learning, the so-called data-driven analytics. Accordingly, we are to propose a training methodology to predict business cycles. We use 68 input variables, ranging from 1982/1 to 2019/12, together with two sets of machine learning methods: Set 1: GLM, SVM, TREE, RF; set 2: H2O.ai autoML and RNN-LSTM. Our conclusion for applying AI methods to predict economic time series are as follows:

Firstly, any single method will suffer from model uncertainty that is derived from stream of new data, AI machine learning has no exception. However, data-driven machine learning methods can generate a huge amount of model predictions, which enables the use of Forecasting Average to aggregate prediction results to enhance forecasting performance.

Secondly, LSTMis a branch of deep-learning, whose learning process is not only complex, but also delicate, resulting in time-consuming computation without better performance. On the other hand, the AI platform H2O.ai offers open source autoML (automatic maching learning) includes deep learning method and aggregate the predictions of five advanced methods, which match out way of study, we strongly suggest the adoption of it in the future study.

In the future, we suggest consider the Corrected CV of Rabinowicz and Rosset (2020) to account for the impact of correlated data, which is known to have better selection capability, and is expected to raise the predictive performance of forecasting average.

目錄

壹、研究目的	
貳、研究大綱	7
(一)研究流程與內容	7
(二)預期成果	7
參、相關研究介紹與探討	9
(一)國內外景氣循環認定與預測文獻概述	9
(二)總體變數預測的機器學習方法應用	14
(三)其他財經議題應用機器學習方法	20
肆、研究方法	24
(一) 景氣分類	24
(二)交叉驗證架構	25
(三)機器學習方法	27
(四)預測診斷	39
(五)模型執行	41
(六)變數說明	42
伍、第一階段實證結果	53
(一)模型:y _t =F(X _{t-p})	53
(二)模型:y _t =F(y _{t-p} , X _{t-p})	68
陸、第一階段分析之小結與預測	83
(一) 小結	83
(二)預測	93

(一) 綜合比較	95
捌、結論與建議	96
	97
附錄 A、相關研究介紹與探討之列表1	99
	05
附錄 B 多模型和設定之 Sampling variations1	12
参考文獻1	28
附件一 期初報告意見回覆1	135
附件二 期中報告意見回覆1	139
附件三 期末報告意見回覆1	43

壹、研究目的

景氣循環是經濟體系中一個十分明顯且重要的總體現象,它不僅影響個人的工作機會與所得,也牽動政府的決策行為,因此與體系中的成員息息相關。它是指國家總體經濟活動的波動,一個循環描述許多經濟活動大約同時發生擴張,隨後收縮、衰退,然後又開始復甦的情形,這一連串的波動會週而復始但不定期的發生(Burns and Mitchell, 1946)。一個景氣循環週期包含一個擴張期(expansion,即介於景氣高峰 peak 之期間)及一個收縮期(contraction,即介於景氣高峰 peak 之期間)及一個收縮期(contraction,即介於景氣高峰至景氣谷底之期間)。如同Burns and Mitchell (1946)所指出的,景氣循環會反覆發生,但並非是相同的大小和時間間隔。景氣循環的多變性,使得預測景氣循環變得非常有挑戰性。實務上,我國國發會界定台灣景氣循環週期,每個擴張期及收縮期個別應持續至少5個月,全循環至少需15個月。

景氣循環又可分為「古典循環 (classic cycle)」及「成長循環 (growth cycle)」兩種概念。前者係指經濟活動水準值的波動;後者則指不含長期趨勢後的循環波動。我國與OECD目前均採「成長循環」之概念。

所謂景氣循環的基準日期(the reference date of business cycle)是指總體經濟波動高峰及谷底的時點。目前各國認定基準日期的方式,如美國國家經濟研究局(National Bureau of Economic Research, NBER)採古典循環的概念,以就業、生產、所得及銷售四大部門代表性指標進行分析,再輔以GDP資料做綜合性研判,最後由Business Cycle Dating Committee 做最終確認。日本內閣辦公廳的經

濟與社會研究機構(The Economic and Social Research Institute of the Cabinet Office, ESRI)則是以同時指標構成項目編製歷史擴散指數(historical diffusion index)判定,最後由景氣動向指數研究會完成認定。OECD採用成長循環概念,以月GDP為基準循環數列做轉折點認定。

我國國發會對於景氣基準日期之認定,係採成長循環概念。除選取一組代表性經濟指標,綜合為一基準循環數列,並參酌個別代表性指標表現,以判斷景氣基準日期。景氣峰谷認定工作,亦由生產、消費、就業、貿易、交易等代表性數列編製擴散指數,以輔佐景氣基準日期之判斷。最後邀集各界專家學者討論,完成峰谷日期之認定。

值得注意的是,不論是美國的 NBER, 日本的 ESRI 或是我國的國發會,對於景氣循環的階段皆採「事後認定」,且宣告的時點大多在峰谷發生後近一年。然而一國政策制定需具備前瞻性,若能建立一套有效預測景氣循環變動的模式應有所助益。

為了建立一套有效預測景氣變動的模型,本文先依照國發會公布的 10 多個景氣循環日期,透過泛函時間序列 (functional time series) 的相位圖 (phase plot),以圖 1.1 工業生產指數為例,呈現 5 個最近景氣循環所隱含的經濟活動特性。

Ramsay and Silverman (2002) 利用簡諧函數 (harmonic function) $\sin(2\pi t)$ 繪製相位圖,指出經濟循環其實是被兩種能量移轉的狀態所驅動:勢能 (potential) 和動能 (kinetic)。利用下圖 1.2 說明,X 軸是此函數的一階微分,稱為速度 (velocity),也就是的函數斜率,測量了

Taiwan In(IPI) and its linear trend

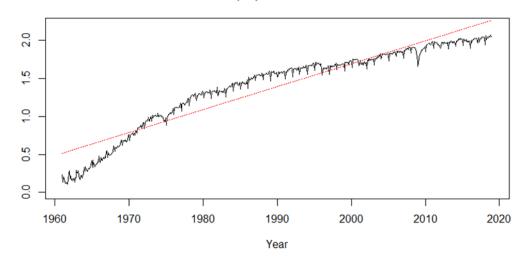


圖 1.1:臺灣工業生產指數時間序列趨勢

相對變化率 (遞增或遞減); Y 軸是二階微分稱為加速度 (acceleration), 也就是函數的凹性。因此, X=0 的垂線, 代表增減的轉換點, 捕捉了經濟指標的增減; Y=0 的水平, 代表凹性轉換點, 捕 捉了增減的速度。Y 軸上下兩端極值就是勢能極大時, X 的 左右兩端極值就是動能最大之時。物理學上勢能就是蓄勢待 發,動能就是正在移動。

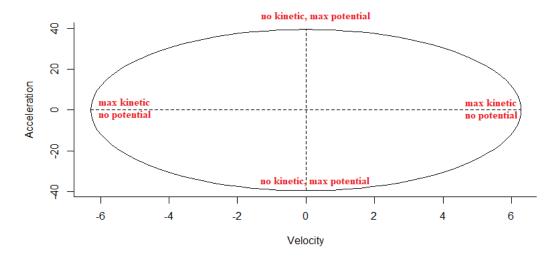


圖 1.2:基本相位圖

簡單地說,一圈就是一個經濟活動的時間週期,如一年內的每月變化。根據國發會公布的景氣循環日期,我們可以在各循環內看經濟指標的變化。以工業生產指數為例,我們把它在最近5個循環的特徵繪製相位圖,說明如下:

圖 1.3 是第 11 下凹型○循環,相位圖解讀如下:1 月開始到 4 月是一個工業生產小循環,4 月開始一個大循環,大循環走到暑假之後 8 月底進入小循環,一直到年底。在 9 月以後回到原點,勢能和動能都差不多耗盡。

圖 1.4 是包含次貸危機的第 12 個上凹型∪循環,在此,工業生產指數的型態有了轉變:1 月開始的由大轉小的收縮循環,期間多個微小的週期,到了年底大週期開始。這應該是金融海嘯帶來的工業生產衰退尾聲。

圖 1.5 是第 13 個下凹型○循環,模式同第 12 個,但是 工業生產活動不再出現圍著原點調節的 2~6 月小週期,應 該是依靠外在刺激保持工業生產活動的狀況大量出現,反應 政府多項刺激經濟衰退的措施。年底進入工業生產動能衰退, 於次年 1 月再進入多個經濟波段。

圖 1.6 是第 14 個上凹型○循環,大體和前次雷同,但是 1 月開始收縮後,做同心圓式的擴張。至年底由負增長接上 次年,再進入波段。

工業生產指數相位圖不能代表整個經濟活動,但是它指 出臺灣近年景氣循環的工業生產不確定越來越高,受全球經 濟衝擊或經濟轉型的影響十分明顯,這也說明我們所面對的 複雜景氣轉折和預測挑戰。基於上述情勢,本案採用機器學習與人工智能方法來預測景氣轉折。

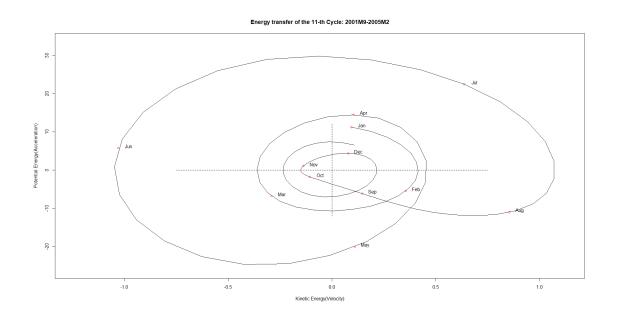


圖 1.3: 工業生產指數在第 11 次景氣循環的週期特性

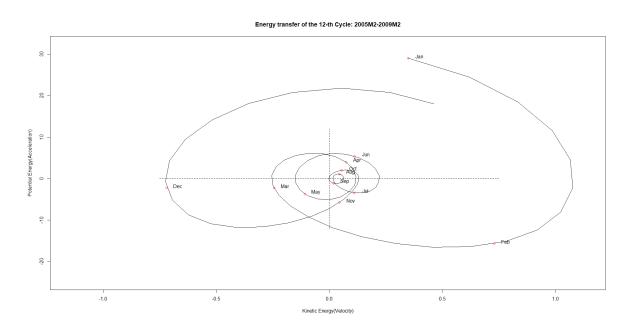
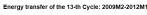


圖 1.4:工業生產指數在第 12 次景氣循環的週期特性



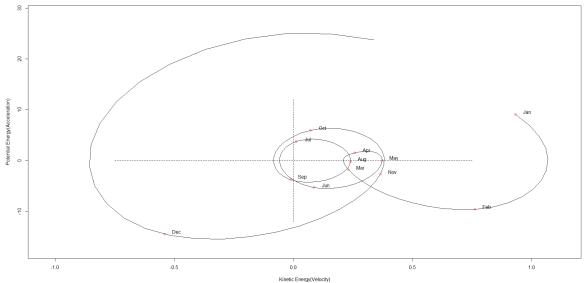


圖 1.5:工業生產指數在第 13 次景氣循環的週期特性

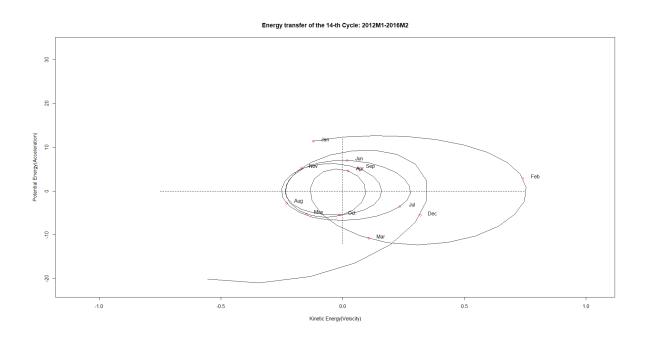


圖 1.6:工業生產指數在第 14 次景氣循環的週期特性

貳、研究大綱

(一)研究流程與內容

本計畫研究流程如圖 2.1 所示:研究初期以文獻與資料 蒐集為主,從國內外文獻探討,瞭解目前研究缺口與資料特 性。期中報告為第二階段,重點在建立廣義線性模型 (傳統 統計模式) 的二元機率模式 (Logit) 與嘗試三元或多元模 式,並以機器學習方法中的支援向量機 (Support Vector Machine, SVM) 和基因演算法 (Genetic algorithm) 改善上 述模式。第三階段則以兩個進階機器學習方法:自動化機器 學習 (autoML) 和 LSTM,訓練期中報告的資料結構。我們 先進行樣本內估計,依據此結果進行樣本外預測。最後進行 預測績效評估,研判未來景氣轉折狀況。

(二)預期成果

透過本計畫訓練國發會的歷史資料,執行特徵萃取 (features extraction),再測試預測表現,基此建立一個可預測未來景氣轉折的模型,做為政策評估之用。

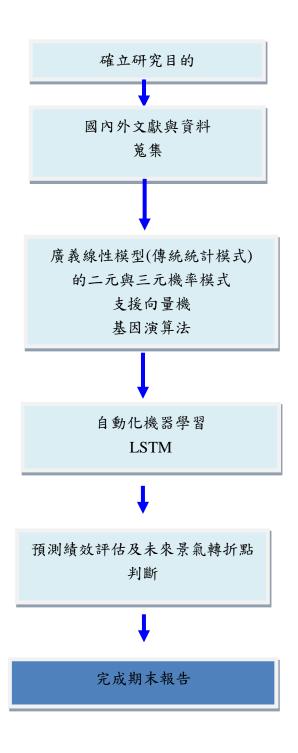


圖 2.1: 研究架構

参、相關研究介紹與探討

(一)國內外景氣循環認定與預測文獻概述

對於景氣循環認定,一般常用的方法是利用無母數演算法 (non-parametric dating algorithm),認定景氣循環的峰頂 (peak) 與谷底 (trough) 之後,定義峰頂至谷底為衰退期,谷底至峰頂為擴張期,如 Bry and Boschan (1971), Harding and Pagan (2002)。文獻上對景氣循環的預測,傳統上著重於建立模型預測景氣循環的衰退期與擴張期。一般常用的方法有二元選擇模型 (binary choice model),如 Estrella and Hardouvelis (1991), Estrella and Mishkin (1995, 1997), Estrella (2005),以及國發會使用的 Hamilton (1989) 2 狀態 Markov-Switching 模型。

近年特別是 2007-2008 金融危機造成全球經濟衰退,許多國家長期處於低經濟成長與高停滯性失業 (Adler et al., 2017)。面對這種有別於以往的總體經濟現況,傳統將景氣循環週期區分為擴張期與衰退期的二分法似乎也有些過時 (Proaño and Tarassow, 2018)。

自 Sichel (1994) 之後,已有許多研究將景氣循環週期分為三個階段,據以探討其優點。例如 Krolzig and Toro (2001) 利用 3 狀態的 Markov-Switching (MS)-VAR 模型,探討美國實質 GDP 與就業的交互關係,該文定義三種觀察不到的狀態,分別為「衰退」、「正常」與「高成長」三個時期。類似的研究還有 Ferrara (2003), Nalewaik (2011) 與 Ho and Yetman (2012),利用 3 狀態的 MS-VAR 模型估計美國經濟,

他們定義的 3 狀態則是經濟體系長期趨勢的低、中、高三種成長狀態。相較之下,Schreiber and Soldatenkova (2015) 利用 subset-VAR 模型預測美國經濟衰退、停滯與擴張的機率。 Proaño (2017) 先提出非參數化的 dating algorithm,來確認德國加速成長、正常或低度成長、以及衰退的三個期間,並利用 ordered probit model 來預測前述景氣循環的三階段。 Candelon et al. (2013) 進一步將景氣循環週期,區分為加速成長、正常成長、衰退以及嚴重衰退等四個期間,檢視 4 狀態 ordered probit model 的預測能力。Carstensen et al. (2017) 利用 3 狀態 Markov-Switching 動態因子模型來預測普通與嚴重的衰退。

Nalewaik (2011) 與 Proaño (2017) 所強調的景氣循環三階段區分方式,較傳統的兩階段區分方式,多了一個低度成長或停滯成長的階段,產生一個有趣的優勢。由於低度成長或停滯成長可能發生在經濟衰退之前或之後,因此景氣循環三階段區分方式也改善了模型預測經濟衰退的績效。

Proaño and Tarassow (2018) 以日本與德國近年所經歷長期低度成長為例,應用景氣循環三階段區分法與 Proaño (2017) 提出的方法預測景氣循環階段,發現對於提前六個月的景氣循環預測,ordered probit model 相對傳統的 binary probit model 績效更好,顯示對於經常發生低度成長的經濟體,ordered probit model 更具洞察景氣變動的附加價值。他們發現三階段的 ordered probit model 相對傳統的 binary probit model,有較準確的機率預測與較佳的分類績效,尤其是預測日本與德國的衰退期與加速成長期。

Proaño and Tarassow (2018) 的實證方法,首先是採用Proaño (2017) 提出非參數化的 dating algorithm,將景氣循環區分為加速成長 (accelerations)、衰退 (recessions) 以及正常或低度成長 (normal or low growth) 三個期間 (簡稱ARNG)。Proaño (2017) 的 dating algorithm 有以下步驟:步驟一是衰退期的認定,根據 Harding and Pagan (2002) 延伸Bry and Boschan (1971) 的方法,先認定景氣循環的峰頂 (peak) 與谷底 (trough),介於峰頂與谷底的期間即為衰退期;步驟二是認定加速成長期或繁榮期;最後是非衰退期以及非繁榮期的期間,即認定為低經濟成長期間。

Proano and Tarassow (2018) 接著利用 ordered probit model 估計景氣循環的三階段,間斷變數的定義為 C_i =0, 1, 2,其中 0 代表經濟衰退期,1 代表經濟低成長期,2 代表經濟加速成長期,並利用 automatic General-to-Specific (G2S) indicator selection procedure 決定迴歸的自變數。為了進行比較,該文也使用了傳統的 binary probit model。接著,將月資料區分為訓練樣本 (training set) 與測試樣本 (testing set) 進行模型的估計與樣本外預測 (out-of-sample forecasting)。最後並利用 ROC 曲線的兩項統計量,即 AUROC 與 Youden index 評估 ordered- probit model 與 binary-probit model 的預測能力。

現存文獻如 Bry and Boschan (1971),Harding and Pagan (2002),Proaño and Tarassow (2018) 對於景氣循環的認定,不論是兩階段或三階段,做法上都需先認定景氣的峰頂與谷底,將其視為一個「轉折點」,亦即景氣的峰谷是一個「時點」,而他們使用的非參數 dating algorithm 係屬「事後認定」。雖然實務上,美國的 NBER,日本的 ESRI 或是我國國發會

所公告的景氣循環的基準日期 (the reference date of business cycle) 也是指總體經濟波動高峰及谷底的「時點」,但實際上經濟活動處於景氣的峰谷可能長達數個月,而非只有一個月。因此有別於傳統,本計畫將峰谷設定為一個「轉折區」應是合理的假設。

再者,文獻上已顯示,景氣循環階段的區分將影響模型的預測能力。目前文獻證明三階段的區分方式,模型的預測能力優於傳統的衰退期與擴張期二分法。大部分文獻對於景氣循環三階段的區分為:衰退期、加速成長期與低成長(或正常成長)期。Proaño and Tarassow (2018) 即發現對於提前六個月的景氣循環預測,三階段的 ordered probit model 相對傳統的兩階段 binary probit model 績效更好,尤其是預測日本與德國的衰退期與加速成長期。

國內相關研究多聚焦於經濟成長率的預測。GDP及其增長率是最常用的經濟發展衡量指標,一個合適的預測模型對於相關政策制定有極大助益。林向愷等(1998)和 Huang (1999) 曾使用單變量 Markov-Switching 模型預測臺灣景氣循環動態, Chen and Lin (2000) 則以多變量 Markov-Switching 模型研究相關議題。即使這些模型在預測方面表現良好,但未將其他總體資料數據對提升預測力的可能性納入考量。徐士勛等(2005)以 Stock and Watson (1998, 2002) 為基礎,建立考量商品市場、貨幣市場及勞動市場等變數的擴散指標預測模型,顯示這些市場訊息得以掌握總體面表現,進而改善預測能力。

陳宜廷等 (2011) 在模型設置時納入了消費、貨幣和國外部門的歷史訊息,發現可以改善主計總處發布的一季前臺

灣經濟成長率預測能力,惟仍未能解決景氣循環對訊息過度 反應而產生的預測誤差。葉錦徽等 (2012) 應用 Huang et al. (1998) 的經驗解構法 (empirical mode decomposition, EMD) 預測臺灣實質經濟成長率,解構序列並將所有成分內涵置於 模型進行預測,結果呈現良好的多步預測績效。吳易樺等 (2014) 使用要素模型進行預測,並比較該模型與時間序列線 性模型的預測力,以主成分分析法 (principal component analysis, PCA) 挑選用來預測 GDP 的要素,結果顯現該模 型多步預測力優於時間序列模型。

徐婉容 (2020) 使用金融市場、總體變數、情緒指標與 技術指標等四類變數,來預測臺灣股市大盤 (加權股價指數) 未來一個月的狀態,並探討其對投資人與政策決定者的含意。 不同於傳統的分類方式,該文將股市熊市區分為兩類,分別 為 (1) 第一類熊市:熊市未伴隨股市盈餘緊縮; (2) 第二 類熊市:熊市伴隨股市盈餘緊縮,發現多數總體變數對兩類 熊市的預測能力與方向並不相同,且第二類熊市與實質經濟 面的變動有較緊密關聯。為了處理大量的預測變數,除了主 成份分析法外,該文另採用偏最小平方迴歸法 (partial least square) 來估計共同因子,並發現不同類的變數適用於不同 的估計方式,而混合主成份分析法與偏最小平方迴歸法來萃 取共同因子,可改善模型的預測能力。相較於傳統分類下的 熊市預測模型,該文發現將股市分為3狀態之多元邏輯迴歸 模型,可提高對股市狀態的命中率,對投資人來說更具經濟 價值。吳俊毅與朱浩榜 (2019)則是透過即時預報或短期預測, 提供判定臺灣經濟情勢的參考。該文應用大數據分析中的機 器學習法,較為即時地認定景氣狀態,希望能在政府正式發 布認定結果前,提前預判景氣轉折。

(二)總體變數預測的機器學習方法應用

機器學習的學習演算法和統計學有所重疊,多數機器學習方法都有一個類似統計的架構。然而兩者的區別,在於統計計量是建立在嚴格的理論假設,然後由之產生統計推論。如果這些假設不正確,結果也會有問題。機器學習的方式則在於將少量關於資料的知識轉化為大量的知識,而且當演算過程的知識開始累積,對未來的預測就會越準確。因此,機器學習演算的核心特徵就是遞迴(iteration)。

近年機器學習模型大量應用於時間序列預測。在總體變數預測方面,Ahmed et al. (2010) 提出多層感知機 (multilayer perceptron)、貝式類神經網絡、徑向基函數 (radial basis functions)、一般化迴歸類神經網絡 (generalized regression neural networks, GRNN)、 K-近鄰演算法 (K-nearest neighbor, KNN)、分類和迴歸決策樹 (CART regression trees)、使用 SVM 作迴歸模型 (support vector regression, SVR)、高斯過程 (Gaussian processes) 等八個機器學習方法,以約一千筆 M3 月資料為樣本,進行低頻的貨幣供給預測。研究結果顯示,多層感知機與高斯過程的預測力是最好的。Ülke et al. (2018) 為美國個人消費支出通貨膨脹率建立預測模型,比較機器學習方法及時間序列模型,發現前者之預測準確性較高。

在預測 GDP 及其成長率表現方面, Feng and Zhang (2014) 使用人工類神經網絡 (artificial neural network, ANN) 方法和灰預測 GM (1,1) 模型預測中國經濟成長率,顯示 ANN 之預測誤差小於 GM (1,1)。 Sokolov-Mladenović et al. (2016) 以

進出口貿易值預測歐盟 28 國經濟成長率,顯示使用 ANN 方法結合極限學習機 (extreme learning machine) 預測準確率 佳。

近兩年學者使用機器學習模型預測經濟成長率亦有突 破。Richardson et al. (2019) 使用 550 個國內外總體指標, 以 1995Q1-2008Q4 數據,為紐西蘭 2009Q1-2018Q1 實質經 濟成長率執行當下預測 (nowcasting),發現機器學習方法如 SVM和NN,較諸傳統時間序列模型的自我迴歸 (autoregressive, AR)、因子模型 (factor model) 及貝式向量 自我迴歸模型(bayesian vector autoregression, BVAR) 等, 誤差皆有明顯下降。 Diebold and Shin (2019) 提出 partially-egalitarian 最小絕對收斂和選擇算子 (least absolute shrinkage and selection operator, peLASSO) 程序, 該程序篩選出最適合的預測因子,再為之配置相同權重進行 合併,以 1999Q3-2016Q4 樣本期間,歐洲中央銀行專業預測 人員調查的數據資料,預測歐元區樣本外一年的實質經濟成 長率。作者指出 peLASSO 預測績效優於簡單因子平均合併 (simple average combination) 的方法;而從向前疊加 (rolling forward) 找出最佳績效平均方法,預測表現亦優於 simple average combination。Cepni et al. (2020) 使用傳統計量 AR 方法和多個 LASSO 方法,樣本期間自 2003 年 1 月至 2018 年 6 月,以超過 80 個國內外經濟政策不確定性和數據非預 期因子 (data surprise factors) 建立模型,為巴西、印尼、墨 西哥、南非及土耳其等國,於 2008 年 7 月至 2018 年 6 月經 濟成長率採取遞迴擬真 (pseudo) 樣本外預測,預測方法有 樣本外一期、樣本外兩期、以及 nowcasting。結果指出包含

全球因子的貝氏變異 LASSO 方法,預測績效領先傳統計量 及其他 LASSO 方法。

有鑑於土耳其經濟成長率波動幅度過大,傳統計量模型 不易預測, Bolhuis and Rayner (2020) 以機器學習的隨機森 林 (Random forest, RF)、梯度提升決策樹 (gradient boosted trees, GBT)、SVM 方法、以及傳統計量動態因子模型 DFM, 以約 200 個因子,為 2012-2019 期間土耳其經濟成長率進行 nowcasting。該文說明 RF、GBDT 與 SVM 在機器學習方法 中需要參數較少,不易有過度配適問題且計算成本較低。其 次,這三個模型具互補性,故可將其預測值做不同組合以降 低預測誤差,例如組合1以三個模型的預測值等權重平均; 組合 2 以預測誤差平方的均數根 RMSE (root mean square error) 倒數做加權平均;組合 3 以 inverse RMSE rank 作為 權重。這是因為 SVM 在訓練樣本有限時,相對其他兩個模 型容易產生過度配適問題,導致預測值對於領先指標的些微 變動相當敏感。形成組合後,SVM 就像 RF 與 GBDT 平衡的 砝碼,後兩者在成長穩定時表現較優異,而在成長波動大時, SVM 則可捕捉極端衝擊 (extreme shock) 的效果。該文以 Bai and Ng (2008) 的 hard thresholds 解決預測因子高維度 問題,即僅選入與目標變數相關係數顯著的迴歸因子,且通 常顯著水準必須高於某個門檻值。

關於預測績效評估,Bolhuis and Rayner (2020) 使用疊加式樣本外當期預測評估模型績效:將當期預測時點可得歷史資料,分成訓練集與測試集,利用交叉驗證調校模型參數。當模型完成校準,即利用即時可得所有歷史資料,以模型獲得個別 nowcasting,並以 RMSE 評估模型績效。為了進一步改善 ML 模型的透明度 (transparency) 與可解釋性

(interpretability),該文針對預測值偏離歷史平均數的程度, 利用 Shapley value 衡量每個預測因子的貢獻度,顯示相較於 計量模型,機器學習方法不僅減少許多預測誤差,亦在捕捉 經濟成長率波動性方面有所改善。RF在整體樣本期間有好的 預測績效,但無法完全捕捉經濟成長的大幅變動。GBDT的 預測值波動稍大,但能捕捉到大幅的成長變動。SVM 最能捕 捉大幅的成長變動,但預測值的波動幅度也較高。ML 組合 型的預測績效皆優於基準模型 DFM, RMSE 平均降幅 33%。 在全樣本 ML 組合型的預測績效,亦較個別 ML 模型平均改 善 15%。預測因子的重要性,除了前一季的經濟成長, nowcasting 模型主要依賴的預測因子為股市、進口、business confidence、失業率與製造業 PMI。若以 Shapely value 解釋 各預測因子,對 nowcasting 預測值偏離歷史平均數的邊際貢 獻平均數,則以三個月 nowcasting 來看,較低的生產指數與 較高的通膨,對成長率 nowcasting 預測值偏低貢獻最大。 nowcasting 預測值隨時間的偏離,源於金融條件與消費指標 惡化。

在預測景氣衰退的表現方面,近來有愈來愈多文獻,比較機器學習的分類模型與傳統計量模型,如 Probit/logit regression,對景氣衰退的預測能力。Gogas et al. (2015)以二元分類模型,利用殖利率曲線預測美國景氣衰退,並定義實質GDP低於長期趨勢的產出缺口 (output gap)為「衰退」。實證顯示相較於二元概率比迴歸 (probit)和對數機率(logit)模型,使用SVM方法預測正確性更高。

Puglia and Tucker (2020) 利用國庫券期間利差與其他九個金融市場與總體經濟特徵變數,檢視機器學習方法相對於 probit regression 預測美國景氣衰退的能力。資料期間為 1972

年 1 月至 2019 年 6 月,共 558 筆月資料。為了估計樣本外預測,該文分別採用傳統的 K-folds 交叉驗證,以及考慮資料時間序列特性的 nested time series (NTS) 交叉驗證,進行樣本外預測準度的估計。NTS 交叉驗證估計的預測績效排序為 probit、隨機森林、XGBoost、LightGBM、類神經網路、支撐向量機,但 K-folds 交叉驗證的排序則是相反,顯示兩種交叉驗證實證結果差異頗大。

Puglia and Tucker (2020) 認為主流的交叉驗證方法,如 K-folds 或是 leave-p-out,一般用來估計使用機器學習與管理 bias-variance tradeoff 的模型,適用於 i.i.d.而非序列相關的時間序列資料。雖然時間序列資料可使用疊加視窗的交叉驗證,但這個方法適用於日資料或更高頻資料,以及非常長期的資料,因此前述方法應用於有限時間序列研究議題是有困難的。在資料結構存在序列相關、分類失衡 (class imbalance) 與結構轉變的前提下,NTS 交叉驗證對於訓練/測試子集的大小 (size) 與驗證子集的大小,可以取得一個好的平衡,同時也對預測績效提供一個相對保守的估計。因此Puglia and Tucker 認為,以 NTS 交叉驗證選擇超參數與估計樣本外預測誤差,是較佳的策略。

Soybilgen (2020) 利用動態因子模型與類神經網路模型,確認美國景氣循環現在與過去的狀態。該文在實證研究上有三個步驟:步驟 1 利用移動平均減少資料中的噪音;步驟 2 從超過 100 個變數的大量資料中,萃取動態因子;步驟 3 則將前述動態因子餵進類神經網路模型。該文採用的依變數為二元分類變數,根據 NBER 的公告,「衰退期」設定依變數的值為 1,「擴張期」設定依變數的值為 0。樣本期間自 1960年 1 月至 2016年 12 月。實證結果顯示:(1) 前述方法不論

在樣本內或樣本外,皆可準確預測美國的景氣循環階段;(2) 噪音的縮減是預測景氣循環重要的步驟;(3) 利用 FRED-MD 的偽即時與復古資料 (pseudo real time and vintage data),實 證顯示類神經網路模型對於景氣轉折點的確認,即時準確又 快速。

Soybilgen (2020) 發現,若資料未經移動平均去除噪音,則將降低類神經網路模型的預測績效;而資料經5個月,尤其是3個月的移動平均後,類神經網路模型的預測績效大幅改善。再者,動態因子模型的設定,假設共同動態因子數 r,共同衝擊 (common shock) 個數 q,落後期 p,則當 p=1, r=q=2或 r=q=4,NN 的預測績效最佳。最後,類神經網路模型的設定相對簡化,一層隱藏層 (hidden layer) 與一層產出層 (output layer)。由於它對於起始值很敏感,因此每個估計視窗都跑 100 次不同的起始值,然後將 100 個類神經網路模型的結果加以平均。

Psimopoulos (2020) 以機器學習方法中的類神經網路 (ANN)、機器向量學習機 SVM 與隨機森林 RF,預測包括澳洲、德國、日本、墨西哥、英國與美國等 6 國的景氣衰退。樣本採取季資料,涵蓋期間 40 年,每個國家 dataset 都包含約 150 個變數。Psimopoulos (2020) 首先定義衰退為實質 GDP連續下降兩季,並將模型預測焦點放在景氣衰退前的條件,因此該文將景氣衰退當季與前三季設定二元選擇變數的衰退={1,1,1,1},其餘為 0。該文以隨機森林生成的決策結果篩選重要的解釋變數,為了符合模型簡約原則,篩選每個國家的解釋變數至 10 個之內。採用樣本外預測績效,以混淆矩陣 (confusion matrix) 為基礎的 6 個評估方法,比較所使用的模型。實證結果發現,SVM 預測績效最佳,整體分類精

準度達 90%左右,而 Probit 與 Logit 模型都至少比一種機器學習模型的績效差。另外,代表債務的總體變數如房貸,出現在每個國家的決策規則,是預測景氣衰退的重要變數。

(三) 其他財經議題應用機器學習方法

除了總體變數,學者亦使用機器學習模型預測金融變數。 由於股價高頻資料數據本身具有跳躍式或噪音等問題,導致 時間序列模型預測力惡化,序列出現轉折點時亦然。Patel et al. (2015) 以印度 S&P CNX Nifty 指數和孟買敏感指數 (S&P Bombay Stock Exchange Sensitive Index) 十年數據做 為樣本,將第一階段的 SVR 模型結果,分別帶入第二階段的 類神經網路模型、隨機森林 (random forest, RF)、SVR 等模 型, 結果 SVR 與 ANN 預測力最佳。Wei (2016) 提出混合時 間序列的適應性類神經模糊推論系統 (adaptive network-based fuzzy inference system, ANFIS), 用來預測臺灣 加權股價指數與香港恆生股價指數,以均方根誤差 (root mean squared error, RMSE) 衡量績效,顯示該模型預測力優 於自我迴歸 (autoregressive, AR) 模型和 SVR 模型。至於在 低頻的股價預測方面, Hafezi et al. (2015) 提出以 bat-neural network multi-agent system (BNNMAS)、遺傳演算法類神經 網絡 (genetic algorithm neural network, GANN)、GRNN 等方 法,使用德國股價指數 DAX 季資料預測未來八年走勢,比 較上述方法在預測 2007-08 年全球金融危機下 DAX 的績效後, 認為 BNNMAS 是正確性最高最可靠的模型。由於曾有文獻 使用非線性 AR (nonlinear AR, NAR) 模型預測單一指數,故 de Stefani et al. (2017) 採用機器學習模型預測恐慌指數時,

另提出外部輸入非線性自動 (nonlinear AR with exogenous input, NARX) 迴歸方法,亦即結合兩個指數的訊息後預測其中一個指數,同時兼採類神經網路模型, KNN 和 SVR 等方法,結果顯示在 NARX 架構下,另一個指數的補充訊息有助於降低 NAR 架構下的預測誤差,進而提升指數的預測力。

機器學習方法已經零星出現在資產定價的文獻。Rapach et al. (2013)應用 LASSO 並以所有國家落後期報酬,預測全球股市的報酬。有數篇研究利用神經網絡預測衍生性金融商品的定價,如 Hutchinson et al. (1994)與 Yao et al. (2000)。 Khandani et al. (2010)與 Butaru et al. (2016)利用迴歸樹預測信用卡拖欠與違約。Sirignano et al. (2016)估計一個深度類神經網絡模型,分析抵押品提前償還、拖欠與取消贖回。Heaton et al. (2016)則發展類神經網絡模型,進行投資組合選擇。

近來機器學習亦已被用來分析橫斷面股票報酬。Harvey et al. (2016) 利用 bootstrap 過程探討多層面比較。Giglio and Xiu (2016) 與 Kelly et al. (2019),利用降維的方法估計並檢定因子定價模型。Moritz and Zimmermann (2016) 應用決策樹為基礎,設計模型進行 portfolio sorting。Kozak et al. (2020) 與 Freyberger et al. (2020) 利用收縮與選擇 (shrinkage and selection) 方法,分別漸進求得隨機折現因子與預期報酬率的非線性函數。

Gu et al. (2020) 對股票報酬率預測的兩種實證文獻進行延伸:其一是 Fama and French (1993) 與 Lewellen (2015),以股票特性探討預期報酬率的差異。這一派文獻典型的分析方法為橫斷面迴歸,將未來股票報酬,對一些落後期的股票

特性作迴歸估計;其二是 Welch and Goyal (2008),Koijen and Nieuwerburgh (2011),Rapach and Zhou (2013) 的報酬率時間序列預測。典型作法是將總和型的投資組合報酬率,對少數總體預測因子作時間數列迴歸。採用的模型有以 OLS 為基礎的三種迴歸模型,包括 Boosted 迴歸樹、隨機森林、類神經網路等。Gu et al. (2020) 採用大量資料進行實證分析,實證期間 1975-2016 涵蓋約 30000 支股票,每支股票有 94 個特性變數,74 個產業部門的虛擬變數等,共 900 個 baseline signals。實證結果顯示:(1) 個股月報酬率的預測,以迴歸樹與神經網絡可大幅改善迴歸模型的預測績效,且淺層學習優於深度學習;(2) 投資組合報酬率的預測,則以非線性方法的機器學習預測績效改善幅度最為明顯,最成功的預測因子類型為價格趨勢、流動性與波動性;(3) 根據機器學習的估計結果做 portfolio selection,可大幅提高 Sharpe ratio,顯示投資績效的顯著進步。

近年更有一支新發展的文獻,即結合機器學習與均衡資產定價,利用機器學習方法確認資產價格與條件變數之間的基本與深層關聯性,了解資產定價的經濟機制。相關研究包括 Kelly et al. (2019), Gu et al. (2020), Feng et al. (2020)。

近期學者開始將機器學習方法應用於金融危機預測。如Suss and Treitel (2019) 利用隨機森林預測英國的銀行壓力 (bank stress); Nik et al. (2016) 利用神經網絡預測新興經濟體的金融危機。前述文獻雖然是以 panel data 為研究樣本,但預測多以橫斷面變數為基礎,甚少考慮時間序列的落後期結構 (lag structure)。

為了充分利用 panel data 的時間序列資訊,Tolo (2020)利用循環類神經網絡 (Recurrent Neural Networks, RNN),進行提前 1-5 年的系統性金融危機預測。該文使用Jorda-Schularick-Taylor data sets,樣本期間 1870-2016,包含17個國家危機發生的日期,以及總體經濟變數年資料。該文依變數為二元分類變數,設定危機發生當年與前 1 年 (或前1-5年) 為 1,其餘為 0。使用的模型有 Logit模型、MLP、長短期記憶遞歸神經網絡 (long-short term memory, LSTM) 與RNN-GRU (the gated recurrent unit RNN),並以 AUC 做為比較模型績效的指標。實證發現 RNN-LSTM 與 RNN-GRU 對於時間序列具有穩健的預測能力,故可顯著改善預測績效。

為清楚呈現比較文獻差異,上述文獻之綜合列表於附錄 A。

肆、研究方法

(一)景氣分類

本研究依照國發會實際數據,即由專家判斷的景氣循環 為觀察值(Y),然後透過多個產經時間序列資料,對此循環狀 態進行預測,以掌握未來的景氣動態。換言之,本計畫並不 是景氣循環的計量認定,而是依照「已經認定的循環」為觀 察值,然後建立預測模型。和一般方法略有不同,我們用類 別編碼,預測分類區間,也就是轉折。

二元分類型 (轉折點): 我們把國發會公布的景氣循環日期資料編碼,針對二元分類 Y: {0=衰退,1=擴張},並應用機器學習演算法訓練對 {0=衰退,1=擴張}的預測表現,如果 {0,1}的預測精確度夠高,則兩者交換處就是轉折點。

資料編碼如下圖 4.1:

4	A	В	С	G	н	1	J	K	L	M	N	0	P	Q	R	S	T	U	V	W	×	Y
1	Date	國發會	transition0 IP	_TWN	LD_OECD	LD_G7	LD_NAFT/	LD_US	COIND_US	LAGD_US	NTDUSD	TWN_Uner T	WN_labo Cl	PI	Export_NT I	Export_US	Import_NT	Import_US[1	LD_TWN	LD_TWN_	LAGD_TW	MS_TWN
51	1981/10/1	收縮	0	21.09	99.2477	98.8902	98.4	57.2	60.7	58.7	37.865	1.73	0.16	58.12	73776	1952.3	62685	1654.4				
52	1981/11/1	收缩	0	20.28	99.1124	98.7437	98.1	57.1	60.5	58.6	37.78	1.55	-0.5	57.73	69407	1836.2	63421	1673.4				
53	1981/12/1	收縮	0	24.14	98.9731	98.6034	97.8	56.9	60.2	58.4	37.84	1.32	0.85	57.65	72199	1913.1	60800	1606.8				
54	1982/1/1	收缩	0	18.62	98.8189	98.4615	97.4	56.3	59.9	58.5	37.712	1.36	-0.56	58.02	65561	1734.9	55785	1472.3	17.27	100	18.03	46624
55	1982/2/1	收縮	0	19.77	98.6322	98.308	97.1	56.6	60.2	58.2	37.912	1.62	-0.56	57.84	57990	1538.2	58836	1556.5	17.35	99.58	18.44	45106
56	1982/3/1	收縮	0	21.97	98,4313	98.15	96.7	56.3	60.1	57.9	38.097	1.32	0.73	57.99	70614	1863.7	61808	1627	17.41	99.08	18.79	43740
57	1982/4/1	收缩	0	21.13	98.2381	98.0072	96.4	56.3	60	58.1	38.337	1.49	0.01	58.14	71813	1890.8	69314	1820.2	17.42	98.3	19.04	43169
58	1982/5/1	收縮	0	21.55	98.0717	97.8961	96.2	56.1	60	58	38.756	1.98	-0.87	58.49	76035	1986.8	68585	1787.5	17.39	97.33	19.17	43576
59	1982/6/1	收缩	0	21.09	97.943	97.8284	96.1	55.6	59.8	58.1	39.092	1.95	0.02	58.61	72635	1880.3	56784	1466.1	17.35	96.28	19.18	44514
60	1982/7/1	收縮	0	21.55	97.87	97.8116	96.1	55.7	59.5	58	39,429	2.21	0.67	58.58	78692	2012.6	63966	1631.8	17.31	95.21	19.05	46184
61	1982/8/1	收缩	0	20.77	97.8722	97.8531	96.2	55.4	59.4	57.8	39,799	2.65	-0.14	60.35	78724	1997.6	66667	1687.3	17.29	94.32	18.84	46636
62	1982/9/1	收縮	0	21.22	97.959	97.9625	96.5	55.8	59.3	57.7	39.85	2.68	-0.43	59.79	72260	1819.7	54195	1361.3	17.33	93.73	18.57	4682
63	1982/10/1	收縮	0	20.86	98.1243	98.1364	96.8	56.1	59	57.4	39,963	2.77	-0.7	59.31	69283	1742.5	59286	1487.4	17.46	93.59	18.32	4752
64	1982/11/1	收缩	0	20.56	98.3517	98.3713	97.2	56.2	59	56.9	40,479	2.71	-0.02	58.83	71172	1784.2	53871	1347.1	17.71	94.1	18.11	4772
55	1982/12/1	收縮	0	23,33	98.6287	98.6602	97.7	56.6	59	56.4	40.062	2.79	0.28	59.05	83070	2045.6	68313	1678	18.09	95.29	17.96	4828
56	1983/1/1	收缩	0	22.45	98.9357	98.9854	98.3	57.7	59.3	56.1	39.88	2.73	1.12	59.07	66634	1670.9	58884	1472.8	18.58	97.06	17.84	5017
67	1983/2/1	收縮	0	17.99	99.2431	99.3182	98.8	58.3	59.1	56.1	39.877	3.45	-0.45	59.66	62684	1574.2	48050	1203.7	19.13	99.04	17.78	5447
68	1983/3/1	擴張	1	22.99	99,5504	99.6571	99,4	59.1	59.4	56	39,955	2.91	-0.11	59.91	71376	1791.1	74211	1857.6	19.68	101	17.79	5194
69	1983/4/1	擴張	1	22.83	99.8436	99,989	99.9	59.6	59.6	56	39.992	2.61	0.08	60.17	83607	2091.7	57781	1442	20.23	102.91	17.9	5185
70	1983/5/1	擴張	1	23.87	100.115	100.301	100.3	60.4	59.9	55.8	39,975	2.42	0.99	59.76	85963	2152.8	70614	1764	20.68	104.33	18.12	5284
71	1983/6/1	擴張	1	24.38	100.359	100.579	100.7	61.2	60.3	56	40.131	2.51	1.1	60.2	88820	2222.2	56321	1405.6	20.98	104.92	18.43	5384
72	1983/7/1	擴張	1	25	100.568	100.813	101.1	61.8	60.8	56.1	40.04	2.88	6.81	59.53	93151	2323	72449	1802.2	21.11	104.66	18.78	5580
73	1983/8/1	擴張	1	25.07	100.746	101.005	101.4	62.1	60.6	56.5	40.186	2.91	-3.17	59.5	96422	2406.9	76339	1900.9	21.08	103.63	19.11	5531
74	1983/9/1	擴張	1	24.48	100.898	101.156	101.6	62.9	61.4	56.5	40.167	2.7	-0.88	59.68	86841	2164.5	60126	1494.9	21.14	103.03	19.44	5614
75	1983/10/1	擴張	1	24.46	101.027	101.268	101.8	63.7	61.9	56.5	40.147	2.79	0.65	59.66	85896	2141	76503	1902.1	21.3	102.96	19.79	5623
76	1983/11/1	擴張	1	24.68	101.128	101.341	101.9	64	62.2	56.8	40.208	2.34	1.05	59.16	94734	2361.3	80317	1996.9	21.51	103.13	20.18	5633
77	1983/12/1	擴張	1	26.19	101.195	101.366	102	64.7	62.5	57.1	40.224	2.27	1.33	58.35	92662	2307.3	83455	2072.9	21.75	103.45	20.61	5750
78	1984/1/1	擴張	1	27.24	101.217	101.337	102	65.6	63	57.2	40.203	2.34	0.25	58.39	94912	2361.6	64863	1609.9	22.03	103.97	21.06	6145
79	1984/2/1	擴張	1	21.51	101.186	101.258	102	66.2	63.4	57.8	40.184	2.75	-0.43	58.98	76518	1906.7	67406	1675.5	22.35	104.66	21.51	6276
30	1984/3/1	擴張	1	26.84	101.107	101.136	101.8	66.3	63.5	58.1	40.024	2.09	0.54	59.14	99197	2475.6	71338	1775.9	22.63	105.18	21.9	6014
31	1984/4/1	擴張	1	26.12	101	100.98	101.6	66.6	63.9	58.6	39.735	2.01	0.83	59.25	103590	2603.4	72571	1819.3	22.81	105.24	22.21	5969
32	1984/5/1	擴張	1	27.95	100.877	100.809	101.4	67.1	64.1	59.1	39,669	2.11	1.13	59.97	114161	2885.8	80329	2025.5	22.85	104.66	22.47	6033
33	1984/6/1	收缩	0	27.11	100.74	100.63	101.2	67.3	64.5	59.4	39.784	2.23	0.7	59.92	107750	2710.7	71184	1786.3	22.76	103.5	22.75	6165
84	1984/7/1	收縮	0	28.21	100.612	100.47	101	67.5	64.6	59.9	39,424	2.52	2.45	59.76	115712	2926.5	81595	2058.4	22.6	102.04	23.05	6250
85	1984/8/1	收缩	0	27.94	100.497	100.329	100.7	67.5	65	60.3	39.043	3.02	0.06	59.98	108612	2778.5	80274	2048.3	22.42	100.53	23.37	6255
86	1984/9/1	收縮	0	25.53	100.392	100.208	100.6	67.5	65.2	60.6	39.1	3.03	-0.78	60.18	94584	2425.2	62340	1594.4	22.28	99.2	23.72	6321
87	1984/10/1	收縮	0	25,87	100,302	100.111	100,4	67.7	65.2	60,9	39,173	2,77	-0.04	59.94	103966	2659.7	74304	1896	22.21	98,23	24.07	62761

圖 4.1: 資料編碼方式

(二)交叉驗證架構

我們應用演算法訓練國發會事後認定的歷史資料,執行 特徵萃取 (features extraction),再測試預測表現。預期建立 一個可預測未來景氣轉折的模型,做為政策評估之用。

第一、交叉驗證的作法如下圖 4.2。基本時間序列架構 是兩段:藍色的訓練資料集 (training data) 和紅色的測試資 料集 (test data):



圖 4.2:交叉驗證作法

實際演算時,會在訓練資料集中,分出驗證區段 (validation),也就是所謂的 K-fold 交叉驗證 (K-fold cross-validation),如下圖 4.3:

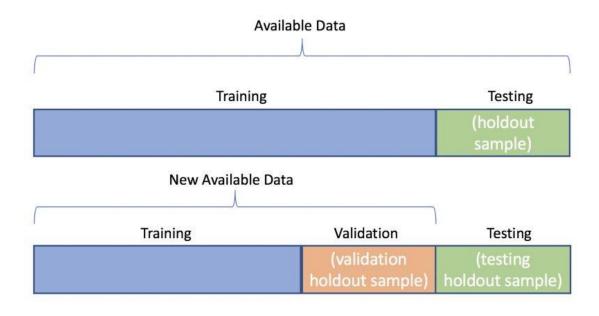


圖 4.3: K-fold 交叉驗證

第二、時序疊加 (Rolling) 設計。時間序列常常會採用疊加法,也就是如下圖 4.4 單步遞迴或直接預測:

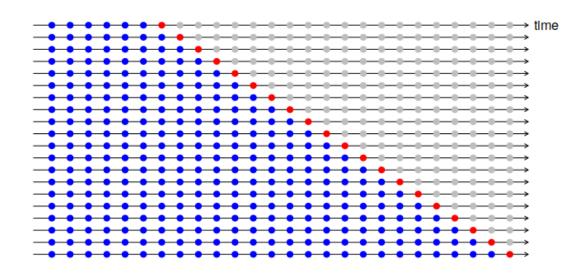


圖 4.4: 單步遞迴

但是在機器學習中,訓練本就是從一筆資料中訓練出最好的模式,然後預測未來。我們的作法依照測試期疊加移動,如下圖 4.5:



圖 4.5: 依照測試期移動作法

為遷就共同數據,我們的資料自 1982 年 1 月到 2016 年 2 月,共 398 個月,解釋變數落後期取 1-6 個月,函數如下

$$Y_t = f(X_{t-1,...}X_{t-6})$$

每一段訓練期時間為 299 個月,測試期是 25 個月。訓練期採用 10-Fold 交叉驗證,因此移動一次疊加增加 25 個月,一共移動 4 次,可以據此檢視預測績效變化 (sampling variation)。

例外的是 LSTM,深度學習 LSTM 因為要求訓練期的樣本和測試期樣本皆能整除 Cache size,因此樣本數略小於前述模式。採用估計 230 個月,測試 23 個月。其餘皆採用估計 299 個月,測試 25 個月。

(三)機器學習方法

機器學習方法有很多,因此我們不能預設固定要用什麼方法。基本上我們嘗試以下四種方法,兩階段資料結構的設計:

方法1.支援向量機 (Support Vector Machine, SVM)

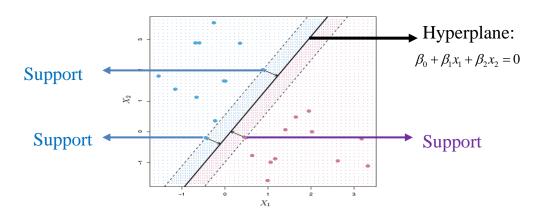
近年機器學習方法蓬勃發展,SVM已經被認為是淺層機器學習方法,其角色類似統計方法的線性迴歸,但重要性卻不容忽視。SVM的概念由 Vapnik (2013)¹ 建立,不同於統計學習方法所使用的實證風險最小化原則 (empirical risk minimization, ERM),將訓練資料數據最小化,SVM體現將結構風險最小化 (structural risk minimization, SRM) 的原理,將一般化誤差的上限最小化,此一差異使得 SVM 方法具備較高的潛力進行一般化。

SVM 是一組將序列模型化,具有強大與充分彈性的研究方法,可以應用在分類、迴歸、預測時間序列等課題。SVM隱含的理論最早建立在分類模型概念上:最小平方法 (least square) 將平方誤差總和 (sum of squared errors, SSE) 最小化以尋找參數估計值,但將 SSE 最小化的缺點之一,是參數估計值容易受到某一偏離整體數據資料趨勢的觀察值影響。此時最小化度量 (minimization metric) 可為另一個替代方案,如 Huber 函數對觀察值較不敏感,可用來求解最佳參數估計值。當殘差值的平方較小時,此函數使用平方殘差值,而當殘差值較大時,此函數使用取絕對值後的殘差值。

解釋 SVM 可從如下圖 4.6, support vector classifier (SVC) n 個觀察值的範例開始。SVC 就是找出一個很小的子集合 (subset), 做為支撐線性超平面 (hyperplane) 的向量。

٠

¹ 原書首版於 1995。



資料來源: James et al. (2013, 第9章)

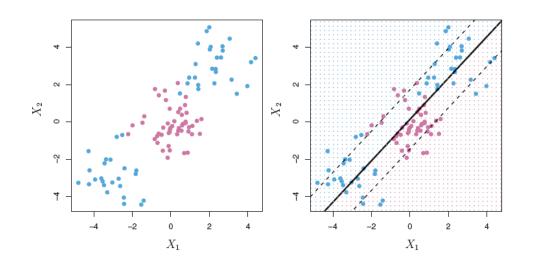
圖 4.6: SVC 分類示意圖

SVC子集合為下述最佳化函數的解得出

$$\begin{aligned} & \underset{\beta_0,\beta_1,\mathsf{K}}{Max}. \ M \\ & s.t. \sum_{j=1}^p \beta_j^2 = 1 \\ & y_i(\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \mathsf{L} + \beta_p x_{ip}) \ge M(1 - \varepsilon_i), \forall i = 1, \mathsf{L} \ n, \\ & \varepsilon_i \ge 0, \sum_{i=1}^n \varepsilon_i \le C \\ & \forall y_i \in \{-1,1\} \text{: associated class labels} \end{aligned}$$

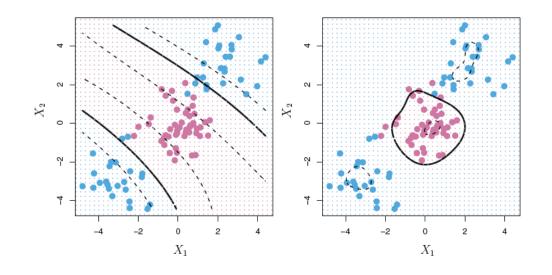
 y_i 是分類標籤:當 $y_i=1$,觀察值為藍色; $y_i=-1$,觀察值為紅色。此例為雙變數,因超平面的線性組合為 0,若觀察值在此超平面上方 (藍色), $\beta_0+\beta_1x_1+\beta_2x_2$ 即為正數,且所有觀察值 $y_i=1$ 相乘為正,滿足 M>0 的條件;反之,若觀察值在此超平面下方 (紅色), $\beta_0+\beta_1x_1+\beta_2x_2$ 為負數,和 $y_i=-1$ 相乘為正,亦滿足 M>0 的條件。 SVC 演算法即在解出讓 M 值極大的參數 β_s ,這個線性分類演算法遇到觀察值不再是線性可分或是非線性時,就出現線性超平面無法將

觀察值完全分類的問題,如下圖4.7(A):



(A) SVM 無法將觀察值分類之示意圖

SVM 就是利用 kernel 函數,從 SVC 發展出來的,如圖 4.7 (B):



(B) SVM 用 kernel 的分類效果

資料來源: James et al. (2013,第9章)

圖 4.7: SVM 的分類原理

kernel 函數簡單地說就是一個投影,把資料從低維度投影到高維度 (超平面),然後就可以將二維無法分類的資料加以歸類,如下圖 4.8:

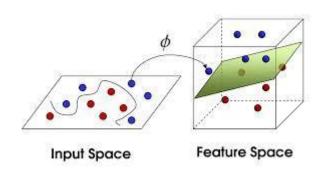


圖 4.8: kernel 投影函數示意圖

就數學規劃, SVM 就是解一個最佳化函數如下:

$$\begin{aligned} & \underset{\beta_0,\beta_1,\mathbf{K}}{\textit{Max.}} & M \\ & s.t. \sum_{j=1}^{p} \beta_j \\ & y_i(\beta_0 + \sum_{j=1}^{p} \beta_{j1} x_{ij} + \sum_{j=1}^{p} \beta_{j2} x_{ij}^2) \ge M(1 - \varepsilon_i), \forall i = 1, L \ n \\ & \varepsilon_i \ge 0, \sum_{i=1}^{n} \varepsilon_i \le C, \sum_{j=1}^{p} \sum_{k=1}^{2} \beta_{jk}^2 = 1 \end{aligned}$$

其中 C 是成本函數 (cost function)。

SVM 的差異在於分類器:
$$f(x) = \beta_0 + \sum_{i \in S} \alpha_i \langle x, x_i \rangle = \beta_0 + \sum_{i \in S} K \langle x, x_i \rangle$$

線性 kernel : $K\langle x_i, x_j \rangle = x_i' x_j$

非線性 kernel 有兩種:

- 1.K 階多項式 $K(x_i, x_i) = (r + \gamma \cdot x_i' x_i)^d \cdot d > 0$, 一般 r = 0, γ 為定值(1/n)。
- 2. Radial kernel: $K(x_i, x_j) = e^{r \cdot x_i x_j}$ 。此為最廣泛使用,也是實務上較成

功的函數。

由以上方程式,SVM不僅使用 ε 損失函數也考量懲罰項。一個簡易表示法,為SVM迴歸係數將以下式「成本及懲罰項」方程式最小化

$$Cost \cdot \sum_{i=1}^{n} L_{\varepsilon}(y_i - \hat{y}_i) + \sum_{j=1}^{P} \beta_j^2$$
,

其中 $L_{\varepsilon}(\cdot)$ 是 ε 的不敏感方程式,Cost 參數是成本懲罰,是用來懲罰大的殘差值。上式的懲罰以脊迴歸 (ridge regression) 的倒數或類神經網絡 (neural networks) 的權值衰減 (weight decay) 表示,因為懲罰附屬於殘差而不是參數。為簡化考量,我們使用 SVM 的穩健性技術支持統計迴歸。²

雖然 SVM 和多數機器學習,看似是對類別變數作分類的計算。但是,類似 lm 到 glm,迴歸樹到決策樹,SVM 的分類概念皆可直接用於連續資料,其概念類似統計的連續資料所產生的信賴區間,統計依照條件期望值和標準差建構信賴區間,然後取一個 size (0.05) 把被解釋變數歸成兩類。

方法2. 基因演算法 (Genetic Algorithms, GA)

基因演算法不是我們預定的內容,惟視情況加入評估。 GA 是由演化生物學的演化理論而來,如下圖 4.9 取自 Kuhn and Johnson (2013, p.497):

² 對變數型態是 numeric 時,SVM 延伸為 Support Vector Regression (SVR),即可處理連續的預測問題。應用在經濟成長率預測時,通過經濟成長率或其他變數等特徵值,訓練出這些特徵值和經濟成長率"增加"和"減少"的關係,即通過特徵值劃分指定經濟成長率"增加"和"減少"的邊界,繼之進行預測。

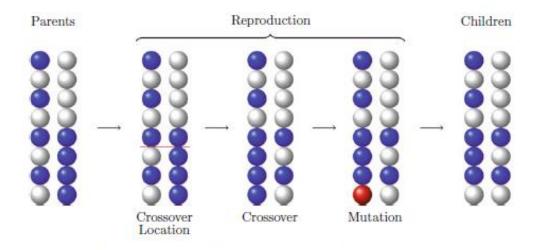


圖 4.9: 基因演算法圖示

基因演算法的特徵萃取比較複雜,演算流程可以參考 Kuhn and Johnson (2013, p.498) 所述如下:

- 1 Define the stopping criteria, number of children for each generation (GenSize), and probability of mutation (pm, 突變機率)
- 2 Generate an initial random set of m binary chromosomes, each of length p
- 3 repeat
- 4 for each chromosome (景氣轉換區) do
- 5 Tune and train a model and compute each chromosome's fitness

6 end

- 7 **for** reproduction k = 1. . . GenSize/2 **do**
- 8 Select two chromosomes based on the fitness criterion
- 9 Crossover: Randomly select a loci and exchange each chromosome's genes beyond the loci
- 10 Mutation: Randomly change binary values of each gene in each new child chromosome with probability, pm

11 **end**

12 **until** stopping criteria is met

如上述,基因演算法會點對點去配置最佳的演化系統,然後產生一個區塊 loci 處理突變 (mutation) 的異常資料。從時間序列的角度,就是結構發生非線性變化。基因演算法的計算,是由一組人口樣本 (GenSize),隨機抽樣資料 p 筆配對估計遺傳架構,然後繁衍另一半 (GenSize/2) 資料 (reproduction),也就是做預測配適。一直重複修正錯誤,直到突變機率 pm 小於 5%。整個演算流程繁瑣複雜,且比 KNN或隨機森林法要耗時。

方法 3.自動化機器學習 (Automatic Machine Learning, autoML)

我們採用 H₂O.ai 平臺提供的自動化機器學習演算法,它 是自動機器學習和大數據的開源解決方案,例如 H₂O.glm 是 在 HoO 環境建立一個一般化線性模型。H2O.ai 是著名的深度 學習人工智慧組件,包括尖端機器學習演算法、績效矩陣與 附屬函數等,使得機器學習方法強大而不失簡潔。我們採用 的自動化演算法,計算多個機器學習模式,包括:監督深度 學習 (類神經網絡)、隨機森林 (random forest)、一般化線性 模型、梯度提高機器 (gradient boosting machine)、素樸貝式 (naïve Bayes)、疊積集成 (stacked ensembles) 等等。以上模 式在訓練和驗證兩個子樣本之間,經大規模演算後取出各模 型的最佳結果,最後以疊積強化 (stacked ensembles) 合併出 最適的預測。在機器學習,此方式也稱為委員會方法 (committee approach),類似統計的預測平均法 (forecasting average)。也就是說,以下代表符號為 H2O.autoML 所求得的 預測數列,並非基於單一種機器學習模型,而是多模型組合 模式下的綜合結果。

H₂O 是典型的機器學習架構,它會依照資料的時間序列 結構,產生大量的時間特徵 (features) 作為解釋變數,然後 根據這些特徵資料進行分類演算。如下圖 4.10:

```
> train_tbl
# A tibble: 250 x 84
                                                                                         diff year year.iso half quarter month month.xts month.lbl
                                                                                                                                                                                                                                                                                                                                                                             day hour minute
            value index.num
                                                                                                                                                            <int> <int>
                                                                                                                                                                                                                        <int> <int>
                                                                                                                                                               1983
                                        431136000 2.68e6
                                                                                                                       <u>1</u>983
                                                                                                                                                                                                                                          2
                                                                                                                                                                                                                                                                                                                         August
                                                                                                                                                                                                                                                                                                                 8 September
                                        433728000 2.59e6
                                                                                                                       1983
                                                                                                                                                               1983
                                                                                                                                                                                                                                                                                                                                                                                    30
                                        436<u>406</u>400 2.68e6
                                                                                                                                                               1983
                                                                                                                                                                                                                                                                                                                        October
                                                                                                                                                                                                                                                                                                            10 November
                                        438998400 2
                                                                                           .59e6
                                                                                                                       <u>1</u>983
                                                                                                                                                               1983
                                                                                                                                                                                                                                                                11
                                                                                                                                                                                                                                                                                                                                                                                    30
                                                                                                                                                                                                                                                                                                                                                                                                                                                 ŏ
                                                                                                                       1983
                                                                                                                                                                                                                                                                12
                                                                                                                                                                                                                                                                                                                                                                                    31
            0
                                        441676800 2.68e6
                                                                                                                                                               1983
                                                                                                                                                                                                                                                                                                            11 December
                                        444<u>355</u>200
                                                                                           .68e6
                                                                                                                       1984
                                                                                                                                                               <u>1</u>984
                                                                                                                                                                                                                                                                                                                         January
                                                                                                                                                                                                                                                                                                                1 Februa
2 March
                                        446<u>860</u>800 2
                                                                                           .51e6
                                                                                                                       <u>1</u>984
                                                                                                                                                               1984
                                                                                                                                                                                                                                                                                                                         February
     8 0
                                        449539200 2.68e6
                                                                                                                       1984
                                                                                                                                                               1984
                                                                                                                                                                                                                                                                                                                                                                                    31
                                        452<u>131</u>200
                                                                                           .59e6
                                                                                                                                                               <u>1</u>984
                                                                                                                                                                                                                                                                                                                         April
          1 454809600 2.68e6 1984 1984 1 2 5 4 May 31 0 ... with 240 more rows, and 71 more variables: second <int>, hour12 <int>, am.pm <int>, wday < wday.xts <int>, wday.lb1 <fct>, mday <int>, qday <int>, nday <int>, am.pm <int>, wday < wday.xts <int>, wday.lb1 <fct>, mday <int>, qday <int>, mday? <int>, mday? <int>, meek <int>, week <int>, y_L6 <db1>, LD_IT_ITWN_L4 <db1>, LD_OECD_L4 <db1>, LD_GT_L4 <db1>, LD_NAFTA_L4 <db1>, LD_NAFTA_L4 <db1>, CPI_L4 <db1>, Export_USD_million_L4 <db1>, Import_USD_million_L4 <db1>, LD_TWN_L4 <db1>, LD_TWN_L4 <db1>, LD_GT_L5 <db1>, ID_GT_L5 <db1>, ID_NAFTA_L5 <db1>, LD_US_L5 <db1>, LD_GT_L5 <db1>, LD_DAFTA_L5 <db1>, LD_US_L5 <db1>, LD_GT_L5 <db1>, LD_DAFTA_L5 <db1>, CPI_L5 <db1>, LD_US_L5 <db1>, LD_DAFTA_L5 <db1>, CPI_L5 <db1>, LD_TWN_L6 <db1>, LD_DAFTA_L5 <db1>, LD_US_L5 <db1>, LD_DAFTA_L5 <db1>, LD_DAFTA_L5 <db1>, LD_DAFTA_L5 <db1>, LD_DAFTA_L5 <db1>, LD_DAFTA_L5 <db1>, LD_DAFTA_L6 <db1>, LD_US_L6 <
 10 1
                                        454<u>809</u>600 2.68e6
                                                                                                                      <u>1</u>984
                                                                                                                                                               <u>1</u>984
                                                                                                                                                                                                      1
                                                                                                                                                                                                                                                                                                                                                                                    31
                                                                                                                                                                                                                                                                                                                                                  am.pm <int>, wday <int>.
```

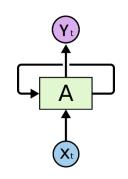
圖 4.10: H₂O 產生大量時間特徵並進行分類演算

方法 4. LSTM

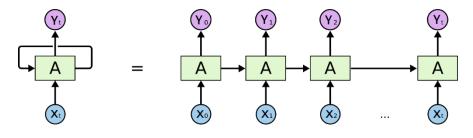
深度學習方法的應用場域是型態辨識 (pattern recognition),不是為了時間序列預測所開發。不過辨識只是從所掃描的圖形萃取特徵,再和資料庫特徵比對,然後做預測,它其實就是資料驅動的預測。因此若應用在時間序列預測,就需要透過歷史資料訓練,建立一個型態資料庫,然後比對產生預測。

深度學習的類神經模式,對於層級和節點的函數,並非事先假設,而是由演算法根據資料的複雜關聯生成,類似統計上的無母數方法。LSTM模型需要先理解遞迴類神經網路(RNN)的概念:人類並非從閱讀一篇文章時才開始思考,而

是在閱讀一篇文章時,從之前已認識的文字來理解其意涵。 換言之,「想法是持久的」,我們並非將之前每件事物丟棄後 重新思考,但傳統的類神經網絡卻無法做到持久性想法。例 如在一場電影裡,若想將每個時點發生的每件事做分類,很 難得知如何使用電影先前事件的推理告知下個事件。以下圖 4.11 為例,RNN 對此議題主張「有著迴圈的網絡使訊息得 以持久」。



(A) RNN 有迴圈



(B) Unrolled RNN

資料來源: Olah, C. (2015), "Understanding LSTM Networks," https://colah.github.io/posts/2015-08-Understanding-LSTMs/.

圖 4.11: RNN 迴圈

其中矩形面積 A 為一個類神經網絡連接著投入 X_t 和產出值 Y_t, 迴圈使訊息從網絡的某一步驟傳輸至下一步驟。

進一步探究便可發現,上圖 4.11 (A) 相較於一般類神經網絡並非如此不同。RNN 可視為相同網絡的複本 (RNNs),每個步驟將訊息傳遞至後續者。考量展開迴圈如上圖 4.11 (B)

近似通路的本質,顯示 RNN 各環節密切地序列相關。

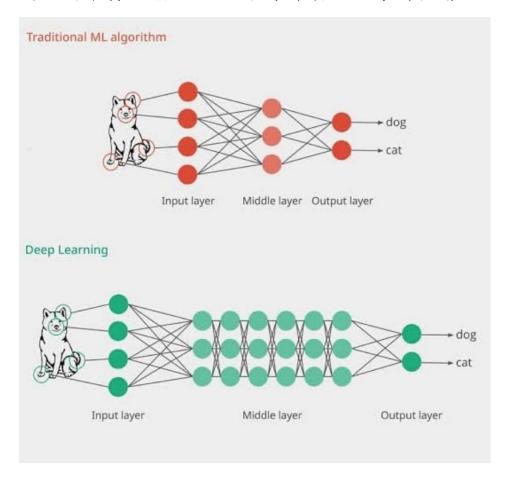


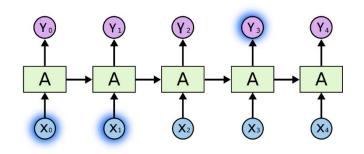
圖 4.12: 傳統機器學習和深度學習的比較

上圖 4.12 比較傳統機器學習和深度學習,後者其實是一種更複雜的神經網路。RNNs 近年在文獻中被大量使用,並應用於如語音辨識 (speech recognition)、語言模型 (language modeling)、翻譯、圖像描述 (image captioning) 等等,且各種應用仍持續有所進展,可參閱 Karpathy (2015) 的詳盡說明。 RNNs 的網路架構特性使其本身具有記憶性,故已成功應用在時序數據的處理上。應用在預測經濟成長率時,投入 X_t (向前一期經濟成長率及其他變數) 並透過類神經網絡,可預測出 Y_t (經濟成長率預測)。

-

³ http://karpathy.github.io/2015/05/21/rnn-effectiveness/

RNNs 其中一個特性,在於能夠將前期與當前的訊息連接,但這視情況而定,因為有時我們只需注視最近訊息執行當前任務。舉例來說,考量一個嘗試以之前文字預測下個文字的語言模型,如果我們試著從以下這句話 "There are many birds flying in the ____",預測最後一個文字,其實我們不需要更多上下文,很明顯地那個字會是 "sky"。在此情況下,相關訊息和需要位置之間的差異很小,RNNs 可使用過去訊息學習,如下圖 4.13×100 和 100 可得 100 不 100 可得 100 可得 100 可以 100



資料來源: Olah, C. (2015), "Understanding LSTM Networks," https://colah.github.io/posts/2015-08-Understanding-LSTMs/.。

圖 4.13: 在 RNN 迴圈使用過去訊息學習

然而大多數情況下我們需要更多前後文。例如我們試著從以下這句話"I was born in China... I speak fluent _____"來預測最後一個文字,當前訊息建議下個文字可能是一個語言的名字。但如果我們欲縮小語言範圍,我們就需要更多前後文。有時相關訊息和需要位置之間的差異很大,而 RNNs 無法學習將訊息結合,此稱之為依賴長期記憶問題。

理論來說 RNNs 可以處理長期記憶依賴,人們謹慎選取參數,進而以這種形式解係數估計值。不過 RNNs 實際上似乎無法學習這個部分,稱之為梯度消失問題 (vanishing gradient problem),這在梯度變得相當大或相當小時出現,因而造成輸入資料庫結構長期全距依賴性 (long-range

dependencies) 模型化的困難。此時最具效率性的方法,是使用 DL4J 支持下 RNN 的 LSTM 變異,也被稱為 LSTM 網絡。

如同 SVM, LSTM 也添加 AR(P) 以及趨勢和季節等額外虛擬變數。另外,本研究係在模型的合理值範圍內做 grid search。

(四)預測診斷

混淆矩陣產出多個預測表現指標,以下進行實證時將以四個指標為主:正確性 (accuracy)、精確性 (precision)、F1和 Kappa。正確性和精確性衡量了預測為「真」程度,數值介於 0和 1,越大越好。F1和 Kappa 則考量預測為「偽」整體評估模型狀況,F1數值介於 0和 1,越大越好;Kappa 數值介於-1和 1,大於 0.4 較可靠。技術說明如下:

	Actual		
混淆矩陣		0	1
Predicted	0	C=312	B=40
	1	A=1	D=4

由混淆矩陣顯示出的可預測性指標如下所示:

正確率 (Accuracy):總樣本中主對角線預測正確率 (預測 Yes/No 的正確率),即 (C+D)/(A+B+C+D)。 312+4/357 =88.52%

2. 精確率 (Precision): Positive=0 的預測值 (C+B) 與真實值 (C) 相符的比重。

3. Kappa(
$$\kappa$$
) = $\frac{觀察符合率 - 機率符合率}{1-機率符合率}$,

即透過機率符合率和觀察符合率,綜合評估模型對資料的可預測 性。⁴

以上述矩陣,計算如下:

觀察符合率=0.874+0.0112=0.8852(若只計算主對角線,就是accuracy)

機率符合率=
$$\frac{\frac{312+40}{357}\cdot(312+1)+(\frac{1+4}{357})\cdot(4+40)}{357} = \frac{308.616+0.652}{357} = 0.866$$

$$Kappa = \frac{0.8852 - 0.866}{1 - 0.866} = 0.1417$$

Kappa 係作為預測修正的權重,因為它具備了如下性質: $-1 \le Kappa \le 1$,若 Kappa < 0,說明機率符合率大於觀察符合率;Kappa=0,說明診斷試驗的結果完全由機率因素導致;Kappa > 0 說明觀察符合率大於因為機率符合的程度。既有研究總結得出,如果 $0 < Kappa \le 0.40$,則說明診斷試驗的可重複性差;如果 0.40 < Kappa < 0.75,則說明具有中、高度可重複性;如果 Kappa ≥ 0.75 ,那麼該診斷試驗就具有極好的可重複性。臨床醫生和研究者們根據這一指標綜合評估診斷試驗的可

 $\frac{(A+C)}{(A+B+C+D)} \times \frac{(B+C)}{(A+B+C+D)} + \frac{(B+D)}{(A+B+C+D)} \times \frac{(A+D)}{(A+B+C+D)}$

⁴ Kappa coefficient 是一種統計量化指標,平衡類別之間正確性的一種指標,簡單說就是要把大者恆大的影響消除掉的指標。假設 "高估"的樣本數遠大於低估時,只需把資料都判給 "高估" 一類,整體的正確率都很高/錯誤率很低。計算中的觀察符合率係指預測正確的機率,為總樣本中主對角線預測正確率,即百分比混淆矩陣的對角線元素相加;機率符合率則是把每個類別 (實際第i類別的總和乘上預測第i類別的總和) 做加總,即

重複性,排除機率因素干擾。5

4. F1 Score=
$$\frac{2}{\frac{1}{Precision} + \frac{1}{Recall}}$$
, Recall=C/(C+A), F1 介於 0和 1之間,

越大越好。

(五)模型執行

上述模型在本研究案中的作法,分雨次完成。

- 1. 第一階段 (期中報告)
 - (1) 廣義線性模型 (傳統統計模式) 的二元機率模式 (Logit),預測{0,1}的目標變數。
 - (2) 以決策樹預測{0,1}的目標變數。
 - (3) 以機器學習方法改善上述模式的預測:支援向量機 和隨機森林。
 - (4) 添加基因演算法。
- 2. 第二階段 (期末報告)

兩個進階機器學習方法,即以自動化機器學習 (autoML)和 LSTM,訓練期中報告的資料結構。

-

⁵ 混淆矩陣中若有類別間樣本不平均,使得預測時發生大者恆大,也就是只要把資料都判給數量最多的一類,整體的正確率都很高的情況,而 Kappa 指標就是在判別是否有此情況。臨床應用上,如 Landis and Koch (1977) 以混淆矩陣應用在神經學的試驗上,來分析不同地區病患的病徵差異,同樣使用 Kappa 指標判斷不同地區間不平均的情況。近年研究機器學習模型廣泛應用在睡眠階段的診斷,也有運用 Kappa 指標 (Peker, 2016; Kuo and Chen, 2020)。

(六)變數說明

所有數據皆是月頻率,資料來源方面,臺灣數據來自主計總處和國發會網站,國外景氣指標資料則由開放數據網站(www.stock-ai.com)取得,細節整理如下。

被解釋變數

依照國發會公布的擴張與收縮狀態期間,編製的二元變數。重疊月份歸類為前一狀態,資料期間為 1961/1~2016/2 (第 14 次循環)。

解釋變數

- 1. IPI_TWN:臺灣工業生產指數。1961/1~2019/12
- 2. LD_OECD: OECD 領先指數。1961/1~2019/12
- 3. LD G7:G7 領先指數。1961/1~2019/12
- 4. LD_NAFTA: NAFTA 領先指數。1961/1~2019/12
- 5. LD_US: 美國領先指數。1961/1~2019/12
- 6. COIND US: 美國同時指數。1961/1~2019/12
- 7. LAGD_US: 美國落後指數。1961/1~2019/12
- 8. NTDUSD: 台幣兌美元匯率。1961/1~2019/12
- 9. M1A:臺灣貨幣供給額 (百萬新臺幣)。1961/7~2019/12
- 10. M1B:臺灣貨幣供給額 (百萬新臺幣)。1961/7~2019/12
- 11. M2:臺灣貨幣供給額 (百萬新臺幣)。1961/7~2019/12
- 12. quasiM_NTD: 準貨幣 (百萬新臺幣)。1961/7~2019/12
- 13. quasiM_USD: 準貨幣,外幣 (百萬新臺幣)。1961/7~2019/12
- 14. quasiM_postal:準貨幣,郵政儲蓄系統 (百萬新臺幣)。1961/7~

2019/12

- 15. Deposit_money: 存款貨幣 (百萬新臺幣)。1961/7~2019/12
- 16. reserve_money:儲備貨幣 (百萬新臺幣)。1961/7~2019/12
- 17. deposit_FI:存款 (貨幣金融機構)(百萬新臺幣)。1961/7~2019/12
- 18. deposit_demand_MF1:存款(貨幣金融機構),企業和個人:活期存款(百萬新臺幣)。1961/7~2019/12
- 19. deposit_time_MF1:存款(貨幣金融機構),企業和個人:定期儲蓄存款(百萬新臺幣)。1961/7~2019/12
- 20. deposit_FX_MF1: 存款 (貨幣金融機構),企業和個人:外幣存款 (百萬新臺幣)。1961/7~2019/12
- 21. deposit_postal_MF: 存款 (貨幣金融機構),郵政儲蓄存款 (百萬新臺幣)。1961/7~2019/12
- 22. deposit_government_MF: 存款, 政府存款 (百萬新臺幣)。1961/7 ~2019/12
- 23. ACRS:有擔保的融通利率%。1961/7~2019/12
- 24. Loan_INV_1:貸款和投資,貨幣金融機構 (百萬新臺幣)。1961/7 ~2019/12
- 25. Loan_INV_2:貸款和投資,貸款 (百萬新臺幣)。1961/7~2019/12
- 26. Loan_INV_3:貸款和投資,組合投資(百萬新臺幣)。1961/7~2019/12
- 27. Loan_INV_4:貸款和投資,政府 (百萬新臺幣)。1961/7~2019/12
- 28. Loan_INV_5:貸款和投資,國有企業 (百萬新臺幣)。1961/7~2019/12
- 29. Loan_INV_6:貸款和投資,私營領域 (百萬新臺幣)。1961/7~2019/12
- 30. TWII:臺灣加權股價指數。1968/1~2019/12
- 31. TWII trans:股票成交金額(上市,百萬)。1968/1~2019/12

- 32. ForeignReserves:外匯準備 (百萬美元)。1969/3~2019/12
- 33. credit1:借項總金額:支票帳戶。1972/1~2019/12
- 34. credit2:借項總金額:活期存款。1972/1~2019/12
- 35. credit3:年周轉率:支票帳戶。1972/1~2019/12
- 36. credit4:年周轉率:活期存款。1972/1~2019/12
- 37. credit5:金融機構:貸款及貼現。1972/1~2019/12
- 38. credit6:金融機構:貸款及貼現:政府機關。1972/1~2019/12
- 39. credit7:金融機構:貸款及貼現:政府企業。1972/1~2019/12
- 40. credit8:金融機構:貸款及貼現:私營領域。1972/1~2019/12
- 41. credit9: 貨幣金融機構:貸款與貼現 (LD)。1972/1~2019/12
- 42. credit10:貨幣金融機構:企業與個人存款 (EI)。1972/1~2019/12
- 43. credit11:信用合作社:貸款及貼現。1972/1~2019/12
- 44. credit12:中華郵政股份有限公司:貸款。1972/1~2019/12
- 45. credit13:人壽保險公司:貸款。1972/1~2019/12
- 46. credit14:同業銀行短期貸款業務。1973/10~2019/12
- 47. credit15:銀行承兌:發行量。1975/3~2019/12
- 48. credit16:銀行承兌:未償。1975/3~2019/12
- 49. credit17:銀行承兌:贖回物。1975/7~2019/12
- 50. credit18:商業票據:發行量。1976/5~2019/12
- 51. credit19:商業票據:未償。1976/5~2019/12
- 52. credit20:商業票據:贖回物。1977/3~2019/12
- 53. TWN_Unemp:臺灣失業率。1978/1~2019/12
- 54. credit21:借項總金額:活期儲蓄存款。1980/1~2019/12
- 55. credit22:年周轉率 (次),活期儲蓄存款。1980/1~2019/12
- 56. TWN_labourNetTurnover:臺灣淨勞動周轉率。1980/1~2019/12
- 57. CPI:臺灣消費者物價指數。1981/1~2019/12
- 58. Export_NTD_million:臺灣出口 (以台幣計價)。1981/1~2019/12

- 59. Export_USD_million:臺灣出口 (以美元計價)。1981/1~2019/12
- 60. Import_NTD_million:臺灣進口 (以台幣計價)。1981/1~2019/12
- 61. Import_USD_million:臺灣進口 (以美元計價)。1981/1~2019/12
- 62. LD_TWN:臺灣領先指數。1982/1~2019/12
- 63. LD_TWN_detrend:臺灣領先指數 (去除趨勢)。1982/1~2019/12
- 64. LAGD_TWN:臺灣落後指數。1982/1~2019/12
- 65. Tax98: 營業稅,12個月移動平均 (NDC_data_SW.xlsx, tax), 1982/1~2019/12
- 66. Tax98: 娛樂稅稅收 (NDC_data_SW.xlsx, tax), 1982/1~2019/12
- 67. Tax98: 貨物稅 (NDC_data_SW.xlsx, tax), 1982/1~2019/12
- 68. C112: 製造業營業氣候測驗點 (NDC_data_SW.xlsx, confidence), 1982/1~2019/12
- 69. EM14: 非農業部門就業人數-公共行政及國防強制性社會安全。 (NDC data SW.xlsx, labor) 1988/1~2019/12
- 70. T94: 鐵路貨運量 (噸公里) (NDC_data_SW.xlsx, traffic), 1985/1 ~2019/12
- 71. T95: 台鐵貨運收入 (NDC_data_SW.xlsx, traffic), 1985/1~2019/12
- 72. credit23:可轉讓定期存單:發行量。1985/10~2019/12
- 73. credit24: 可轉讓定期存單: 贖回物。1985/10~2019/12
- 74. credit25:可轉讓定期存單:未償。1985/10~2019/12
- 75. credit26:存款:所有銀行:共計。1987/5~2019/12
- 76. credit27:存款:所有銀行:企業和個人 (EI)。1987/5~2019/12
- 77. credit28:存款:所有銀行:政府。1987/5~2019/12
- 78. credit29:國內銀行:已發行的銀行債券。1987/5~2019/12
- 79. credit30:外幣貸款:國內銀行 (包括中間業務銀行)。1987/5~2019/12

- 80. credit31:外幣貸款:共計。1987/5~2019/12
- 81. credit32:OBU:發放給非金融機構的貸款:居民。1987/5~2019/12
- 82. credit33: OBU: 發放給非金融機構的貸款: 非居民。1987/5~2019/12
- 83. credit34:外幣貸款:外資銀行本地分行 (LBFB)。1987/12~2019/12
- 84. credit35:空頭支票比:包括已取消的:值。1987/12~2019/12
- 85. credit36:空頭支票:包括已取消的:值。1988/7~2019/12
- 86. credit37: 消費者貸款:未償:國內銀行、外資銀行、中型商業銀行 (DB)。1988/7~2019/12
- 87. credit38:消費者貸款:未償:DB:房屋購買。1988/7~2019/12
- 88. credit39:消費者貸款:未償:DB:房屋修理。1988/7~2019/12
- 89. credit40:消費者貸款:未償:DB:汽車貸款。1988/7~2019/12
- 90. credit41:消費者貸款:未償:DB:員工福利貸款。1988/7~2019/12
- 91. credit42: 消費者貸款: 未償: DB: 其他消費貸款。1988/7~2019/12
- 92. credit43:建築貸款:未償:國內銀行、外資銀行、中型商業銀行。1988/7~2019/12
- 93. IP22: 工業生產指數-飲料製造業 (NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 94. IP23: 工業生產指數-菸草製造業 (NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 95. IP24:工業生產指數-紡織業 (NDC_data_SW.xlsx, prod), 1988/1 ~2019/12
- 96. IP25:工業生產指數-成衣及服飾品製造業 (NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 97. IP26:工業生產指數-木竹製品製造業 (NDC_data_SW.xlsx, prod), 1988/1~2019/12

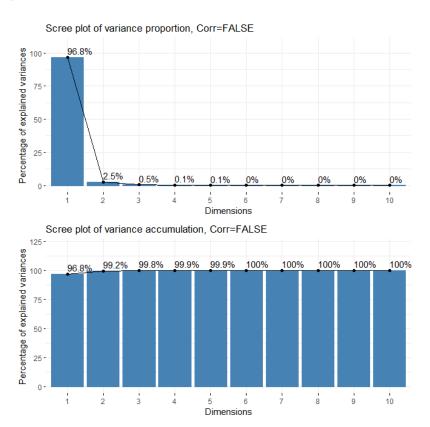
- 98. IP27: 工業生產指數-非金屬礦物製品製造業 (NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 99. IP28:工業生產指數-家具製造業 (NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 100. IP29: 工業生產指數-其他製造業 (NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 101. IP30: 工業生產指數-電力及燃氣供應業 (NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 102. IP31: 工業生產指數-用水供應業 (NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 103. Price23: 不含新鮮蔬果及能源 (核心物價) (NDC_data_SW.xlsx, price), 1982/1~2019/12
- 104. Price24: 躉售物價指數 (NDC_data_SW.xlsx, price) , 1982/1~ 2019/12
- 105. Price25: 進口物價指數 (用台幣計價) (NDC_data_SW.xlsx, price), 1982/1~2019/12
- 106. Price26: 出口物價指數 (用台幣計價) (NDC_data_SW.xlsx, price), 1982/1~2019/12
- 107. risk1: 政策利率: 月結: 貼現率。1961/7~2019/12
- 108. risk2: 基準貸款利率: 國內五大銀行: 平均。1961/7~2019/12
- 109. risk3: 定期存款利率: 國內五大銀行: 平均: 一個月。1961/7~ 2019/12
- 110. risk4:實際有效匯率指數:BIS:2010 年=100:狹窄的。1963/10~2019/12
- 111. risk5: 定期存款利率: 國內五大銀行: 平均: 一年。1975/7~2019/12
- 112. risk6:外匯:新臺幣兌美元:銀行同業:平均。1979/1~2019/12
- 113. risk7:商業票據利率:二級市場:1至30天。1980/11~2019/12

- 114. risk8: 商業票據利率: 二級市場: 31 至 90 天。1980/11~2019/12
- 115. risk9: 商業票據利率: 二級市場: 91 至 180 天。1980/11~2019/12
- 116. risk10:商業票據利率:初級市場:1至30天。1980/11~2019/12
- 117. risk11: 商業票據利率: 初級市場: 31 至 90 天。1980/11~2019/12
- 118. risk12: 商業票據利率: 初級市場: 91 至 180 天。1980/11~2019/12
- 119. risk13: 可轉讓定期存款利率:1天至90天。1980/11~2019/12
- 120. risk14: 可轉讓定期存款利率:91至180天。1980/11~2019/12
- 121. risk15:同業拆借利率:隔夜:加權平均。1981/1~2019/12
- 122. risk16: 兌美元匯率: 月平均。1983/10~2019/12
- 123. risk17:存款準備金率:支票帳戶。1988/12~2019/12
- 124. risk18:存款準備金率:活期存款。1988/12~2019/12
- 125. risk19: 存款準備金率:儲蓄存款:活期。1988/12~2019/12
- 126. risk20: 存款準備金率: 儲蓄存款: 定期。1988/12~2019/12
- 127. risk21: 存款準備金率: 定期存款。1988/12~2019/12
- 128. risk22:存款準備金率:其他債務:外幣存款。1988/12~2019/12
- 129. risk23:存款準備金率:信託基金。1988/12~2019/12

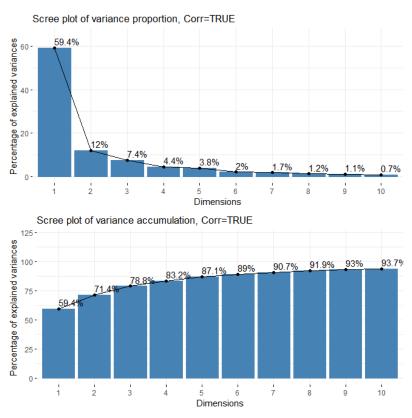
以上資料最長始自 1961 年 1 月,有 662 個月;最短則自 1988 年 12 月起。除了淨勞動周轉率和失業率,其餘變數皆以 12 個月計算變動率。進出口採美元計價。除了編碼為二元景氣的被解釋變數,投入訓練的解釋變數有原始數據和降維因子兩類。因為資料長度不一,我們最後選擇始 1982/1 的數據,共 68 筆。以上資料排序和檔案 mainData.RData 一致,若需要增加變數,可以自行調整。

除了基本的確定趨勢和季節虛擬變數,投入變數 (input variables) X有兩種:第一種是 68 筆原始數據。第二種是用因子分析法萃取的少量因子。我們採用三個方法,將 129 個解釋 變數 降維成 10 個以內:獨立因子法 (independent

component analysis, ICA)、以相關係數矩陣計算的主成分方法(principal component analysis, PCA)、和以共變異數矩陣計算的主成分方法。採用相關係數矩陣的主成分,資料必須沒有常數或接近常數的變數。因子萃取的陡坡圖如圖 4.1 (A)與 (B),依照對整體變異大於 93.7%的解釋程度,採用相關係數矩陣計算的主成份取 10 個因子;至於採用共變異數矩陣計算的主成份取 4 個因子,ICA 則以二元相關係數檢定的p-value 小於 0.02 為準,取 20 個獨立因子,圖 4.1 (C) 繪出 6 個範例。

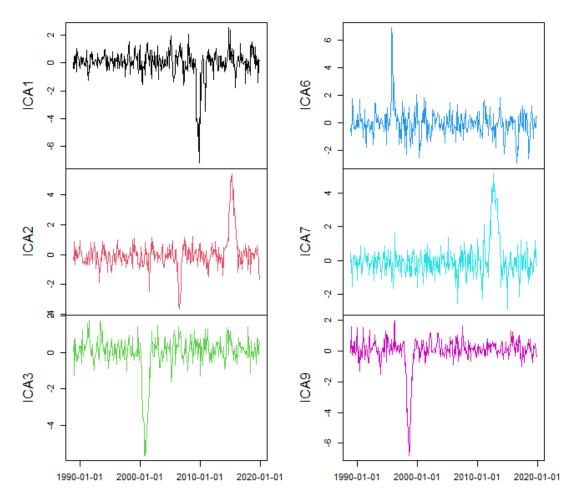


(A) 以共變異數矩陣計算的主成份



(B) 以相關矩陣計算的主成份

ICA for P-value < 0.05



(C) ICA 因子

圖 4.1: 因子數量

以下實證,依照演算時間分成兩階段:

第一階段的四個基本的方法: glm (generalized linear model, 廣義線性模型), RF (random forest, 隨機森林), SVM (support vector machine, 支援向量機)和 rpart (分類決策樹, decision tree)。

第二階段兩個方法:H2O.ai 的自動化機器學習 autoML

和具長短時間記憶的循環類神經網路 RNN-LSTM。

原始數據從 $1982/1\sim2019/12$ 的無缺值,共有 68 筆變數。我們訓練的模式如 $y_t=F(X_{t-p}), p=1,2...6$,訓練資料 $1982/1\sim2016/2$ 共 398 個月,訓練資料用 299 個月估計,估計期內含 10-fold 的交叉驗證。滾動預測 25 個月,然後向前疊加滾動 4 期,也就是說一個模型有 3 類資料,4 個滾動時段,6 個落後期,總模型有 288 個。最後用這 288 個模型選出 50 個,預測未公布的景氣階段 2016/3-2019/12,如本文第陸章內容所示。

伍、第一階段實證結果

第一階段的預測表現診斷有四部份,以兩類 input variables 為基礎

$$y_t = F(\mathbf{X}_{t-p})$$

 $y_t = F(y_{t-p}, \mathbf{X}_{t-p}),$

每一個模型依照 X 的資料性質再區分為兩類:原始資料和因子資料。因為模型和設定很多,以下我們以熱力圖的階層式 集群法呈現預測結果的模型關聯。

(-)模型: $y_t=F(X_{t-p})$

第一、X是原始數據

圖 5.2 列出 4 個指標,每個熱力圖皆處理 24 個設定和 4 個模型的交叉結果,4 個模型代號說明分別如下:

glm: generalized linear model,廣義線性模型。

RF: random forest, 隨機森林。

SVM: support vector machine, 支援向量機。

rpart: decision tree, 決策樹。

設定表示方式,以 Lag2_t3 為例,代表落後期 p=2,資料疊加至第 3 次。從 t1 到 t4,資料是疊加的,據此可以看看資料多少的預測績效變化。

圖 5.2 (A) 為正確性,以此圖為例說明如何解讀。圖左 上角的 Color Key 為正確性指標數值區間的色彩:越淺越大。 右邊白色接近1,左端紅色接近0。

主圖四軸皆有資訊:右邊為 input variables 的設定,X 軸為所採用的4個模式;上方和Y軸皆顯示階層式集群分類, 上方集群將4個模式歸類,Y軸集群將設定歸類。

以圖 5.2 (A) 的正確性而言,我們發現:

- 1. SVM和glm為一組、rpart和RF為一組;
- 2. 紅色是預測不好的設定,各模型在不同預測區間內的預測表現差異大。對 SVM 及 glm 而言,疊加一次 (t1) 的表現最好,疊加四次 (t4) 的表現最差;但對 rpart 而言,反而疊加一次 (t1) 的表現最差,疊加四次 (t4) 的表現最好; RF在 t1 及 t4 時,有機會出現良好的預測表現。
- 3. X 軸排靠右邊的模型,是 24 個設定中表現最好的。依此例,是隨機森林 (或和決策樹共同)的正確性最好。
- 4. 24 個設定歸類過於繁瑣,我們不細說,應該把重點放在合理的預測設定。例如,Lag1或Lag2在實務上不太可行,因為除了日資料,大多數的月資料都會落後當月 1~2 個月。因此,以一季 Lag3 為預測點是比較合理的。大致上,Lag3~Lag6 的預測績效都還不錯。

整體而言,四個模型表現出的正確性類似。接下來我們看圖 5.2 (B) 的精確性,精確性是設定 Positive= 0,也就是擴張期的計算。我們發現:

- 1. rpart 的預測精確性最好,glm 其次,RF 第三,SVM 居末;
- 2. 與正確性的結果相似,當疊加至 1 次時,預測精確性最佳, RF、SVM 及 glm 的預測表現可至 80%,僅 rpart 表現稍

差。

- 3. rpart 是在疊加至 4 次的表現最好,可達到 100%。
- 4. 除了疊加一次時以 Lag 1 期表現最好外,在疊加次數 2~4 下,表現最好的 Lag 期數為 3~4 個月。

接下來我們看圖 5.2 (C) 的 F1 指標,此為召回率 (recall) 和精確性 (precision) 的加權調和平均數。我們發現:

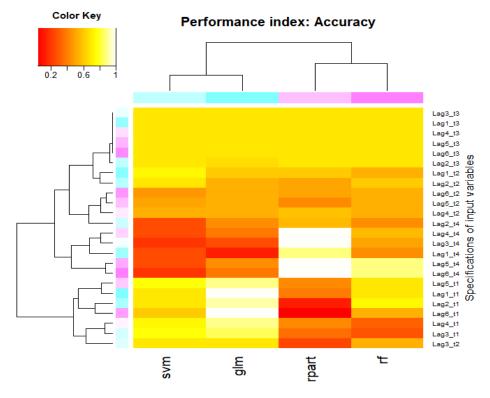
- 1. rpart 和 RF 為一組,表現最佳;glm 和 SVM 為一組,表現次之。
- rpart 在疊加至 4 次時 F1 指標達 80%; glm 在疊加 1 次時的 F1 指標達 80%, 均相當理想。
- 3. 紅色是預測不好的設定,在集中疊加至 2、3 次的情況下, F1 均表現不佳;同前,資料越多,預測不一定越好。
- 4. 除在疊加一次時以 Lag 1 期表現最好外,在疊加次數 2~4 時,表現最好的 Lag 期數為 3 及 5 個月。

接下來我們看圖 5.2 (D) 的 Kappa 指標,此一平衡類別之間正確性的指標,簡單說就是要把大者恆大的影響消除掉。 Kappa 值介於-1~1 之間,正值越大,代表模型越好。圖左上角的 Color Key 為 Kappa 數值區間的色彩,越淺正值越大。 右邊白色接近 1,左端紅色接近-1。我們發現:

- 1. RF和 SVM 為一組、此二模型與 glm 又可為一組。 glm 和 SVM 的 Kappa 指標表現普遍而言最好;
- 2. rpart 在疊加至 4 次時,以及 glm 在疊加至 1 次時,Kappa 指標表現最佳,可達到 1;

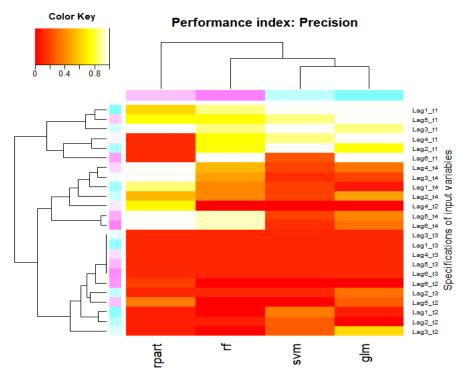
3. rpart 的 Kappa 表現不穩定,雖在疊加至 4 次時 Kappa 值可達到 1,但在疊加 1 次時的預測表現反而最差。

綜上所述, rpart 及 glm 的正確性最好, RF僅些微落後。 但在精確性、F1 及 Kappa 上, glm 和 rpart 最佳, 不相上下。



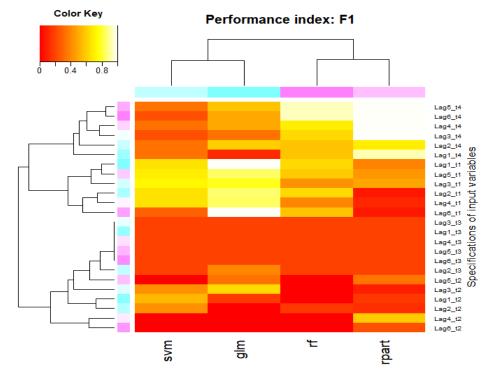
Models used to train raw data

(A) 正確性指標 (Accuracy)



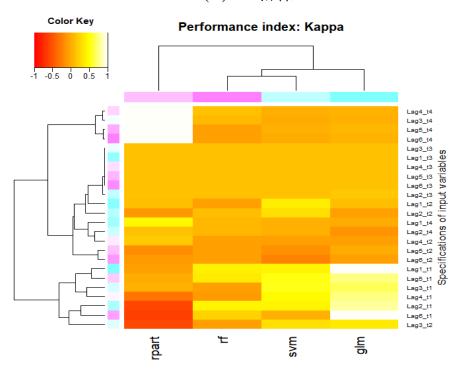
Models used to train raw data

(B) 精確性指標 (Precision)



Models used to train raw data

(C) F1 指標



Models used to train raw data

(D) Kappa 指標

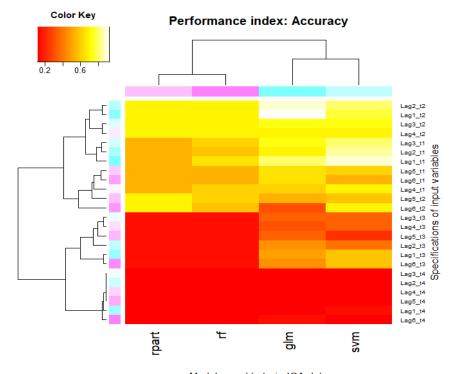
圖 $5.2: y_t=F(X_{t-p})$ 且 X=原始資料的預測表現

第二、X是降維因子

因原始數據多導致計算上較無效率,故以下嘗試降維。 先由 ICA 開始,圖 5.3 列出四個指標,以下說明發現結果:

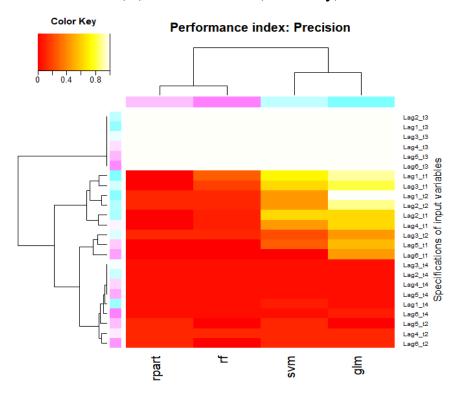
- 1. 在正確性方面, glm 及 SVM 指標表現最佳,除了在疊加預測至 4 次時 (t4) 正確性較差外,其餘情況正確性至少在 60%以上,表現第三佳為 RF。疊加次數仍是影響預測表現的主要因素;在不同疊加次數下,Lag 2 或 3 的表現最佳。
- 2. 在精確性方面,glm 預測表現極好,半數以上情況精確性達 80%,僅在疊加預測至 2、4次時精確性下降至 20%以下。其餘模型(SVM, RF, rpart)則除在疊加預測至 3次時精確性極佳,可達 100%;但半數的情況精確性在 40%以下,多發生在疊加預測至 1、2、4次時 (t1, t2, t4)。
- 3. 在 F1 指標方面, glm 和 SVM 預測表現相近, 以 glm 最佳, 在疊加預測至 1、2 次時 F1 指標至少大於 0.6, 甚至可達 0.8; 其中以 Lag 3 或 4 較好。其次為 RF 及 rpart, 在所有情況下 F1 指標均小於 0.4。在疊加預測至 4 次時 (t4), 各模型的 F1 指標到最差的程度。
- 4. 在 Kappa 指標方面,SVM 及 glm 為最好,在疊加預測 1 次時,Kappa 指標在 0.5 以上。

綜上所述,以ICA降維後 glm 及 SVM 的表現為最好, 其次為 RF。與降維前相比,精確性略為提升,然而正確性、 F1 及 Kappa 指標表現,仍然較原始數據稍差。值得一提的是, 疊加預測次數對各模型及各指標的影響,並無一致性;但在 不同疊加次數下,以 Lag 3 或 4 的表現較好。



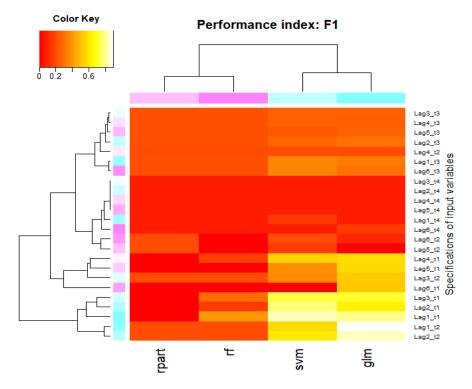
Models used to train ICA data

(A) 正確性指標 (Accuracy)



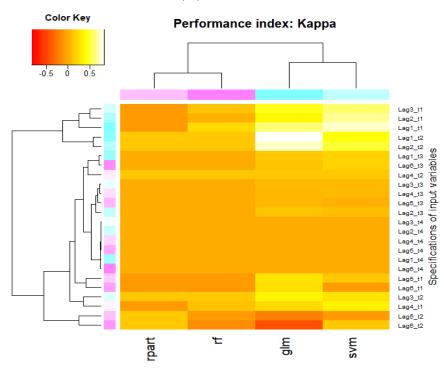
Models used to train ICA data

(B) 精確性指標 (Precision)



Models used to train ICA data

(C) F1 指標



Models used to train ICA data

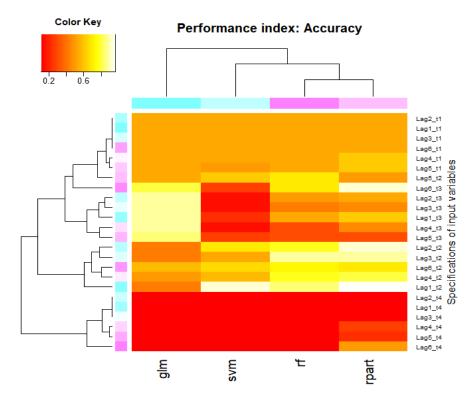
(D) Kappa 指標

圖 $5.3: y_t=F(X_{t-p})$ 且 X=ICA 的預測表現

再看以相關係數矩陣計算的 PCA 方法,降維後的結果如圖 5.4 所示,說明如下:

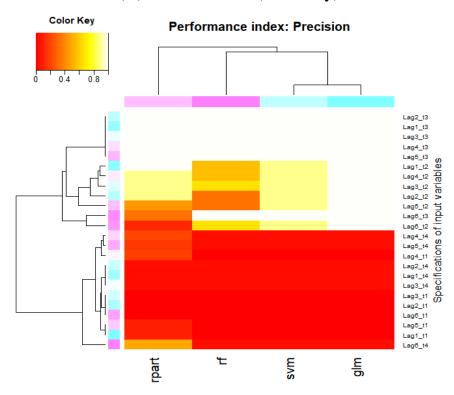
- 1. 在正確性方面, rpart 及 RF的預測表現最好,除在疊加預測至 2 次時正確性達到 80% 之外,在疊加預測至 3 次也可出現正確性改善的情況。glm 及 SVM 的正確性居後,但 glm 在疊加預測至 3 次表現較好 (高於 80%),而 SVM 在此時則表現差 (低於 30%);
- 2. 在精確性方面, glm 表現最佳, 半數以上情況精確性達 90%以上, 其次為 SVM, rpart 及 RF 居後。在疊加預測至 3次時 (t3), 各模型均出現精確性 100%的表現;
- 3. 由於各模型在正確性及精確性的表現優劣較無明顯一致性,因此 F1 指標亦無明顯的優劣分別。在疊加預測至 2 次時 (t2),各模型普遍有較好的表現,尤其以 rpart 較佳;另外,在疊加預測至 1、4 次時 (t1, t4), rpart 的預測表現稍佳。
- 4. 在 Kappa 指標方面,rpart 表現最佳,其次 RF、glm。

綜上所述,以相關係數矩陣計算的 PCA 方法降維後,精確性明顯提升 (精確性達 80%的情況,由 1/4 提升至近 1/2),但正確性則下降 (正確性低於 20%的情況增加至將近 1/4),因此與原始數據之結果相比,F1 指標及 Kappa 表現並無明顯不同。此外,在降維後,原本預測表現較差的 rpart,反而大幅改善,但整體而言,各模型的預測表現無明顯的優劣分別。



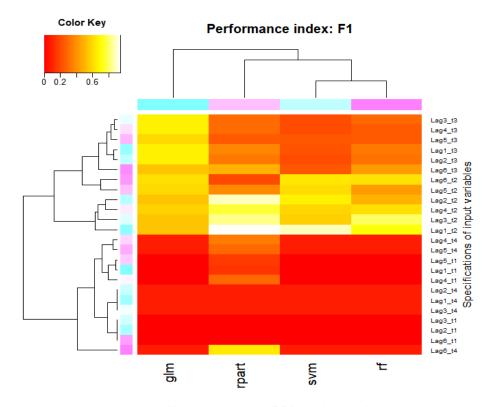
Models used to train PCA data by correlation

(A) 正確性指標 (Accuracy)



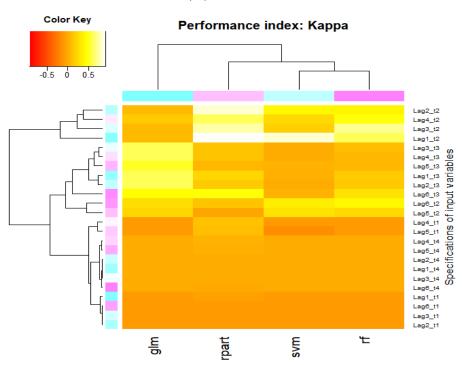
Models used to train PCA data by correlation

(B) 精確性指標 (Precision)



Models used to train PCA data by correlation

(C) F1 指標



Models used to train PCA data by correlation

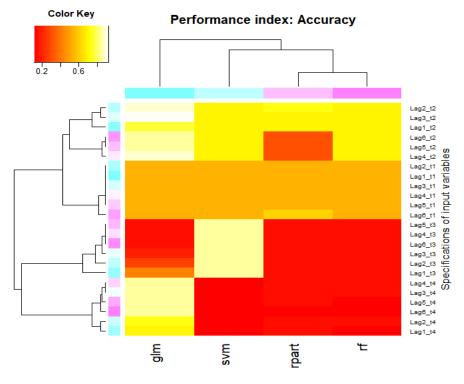
(D) Kappa 指標

圖 $5.4: y_t=F(X_{t-p})$ 且 $X=PCA_{corr}$ 的預測表現

以共變異數矩陣計算 PCA 方法降維後,如圖 5.5 所示, 結果如下:

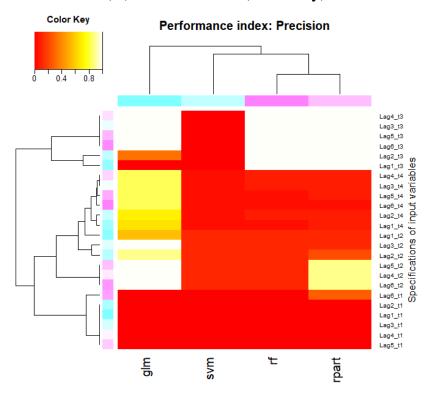
- 1. 在正確性方面, glm 及 SVM 最佳, 雨者在四分之三以上的情況下,正確性大於 60%, 半數也達到正確性 70%。其次是 RF,但半數以上情況仍達到正確性 60%。整體而言,以疊加至 2 次時,預測表現最好,其次是疊加預測 1 次。
- 2. 在精確性方面, glm 及 rpart 最佳, 在疊加至 3 次時, 精確性均可達 100%; 但在疊加預測 1 次時 (t1), 無論何種模型下精確性均僅有 20%;
- 3. 由於正確性和精確性,在不同疊加次數下的表現截然不同, 因此在 F1 指標整體而言並不理想,僅有 glm 佳,近半數 情況以上 F1 指標可達 0.7,其次是 RF 及 rpart,但與 glm 的預測績效表現相比差距仍大;
- 4. 在 Kappa 指標方面,glm 表現顯著優於其他模型,半數以上情況 Kappa 指標可達到 0.5。

綜上所述,以共變異數矩陣計算的 PCA 方法降維後,預測表現未有明顯提升,與降維前同樣是 glm 模型表現最好。當萃取少量因子後,因未增加其他解釋變數,因此預測表現與原始數據之間,沒有明顯差距。



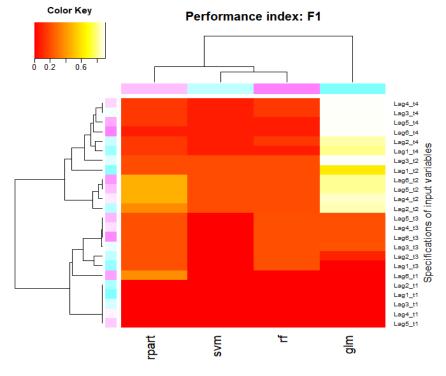
Models used to train PCA data by covariance

(A) 正確性指標 (Accuracy)



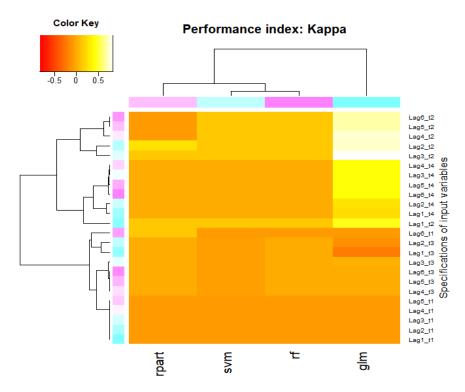
Models used to train PCA data by covariance

(B) 精確性指標 (Precision)



Models used to train PCA data by covariance

(C) F1 指標



Models used to train PCA data by covariance

(D) Kappa 指標

圖 $5.5: y_t=F(X_{t-p})$ 且 $X=PCA_cov$ 的預測表現

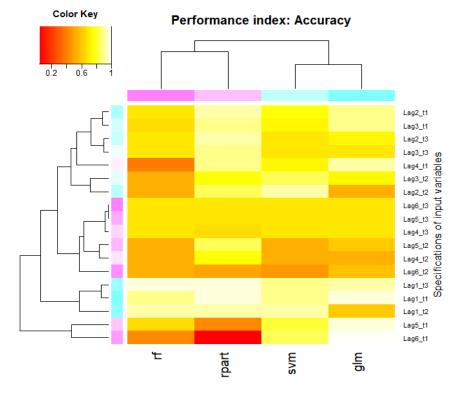
(二)模型: $y_t=F(y_{t-p}, X_{t-p})$

第一、X是原始數據

以原始數據,並加入 y_t 的落後期變數,即為ARX模型, 結果如下:

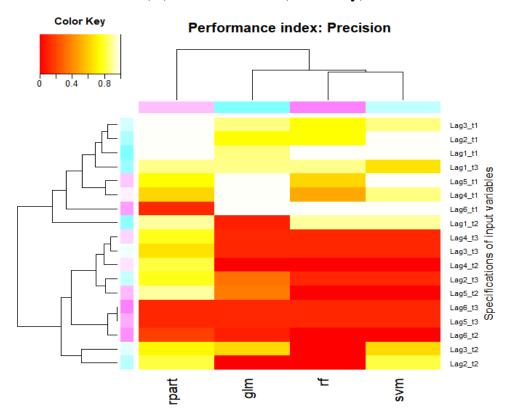
- 1. 在正確性方面,當增加解釋變數後,glm 及 SVM 表現最穩定,正確性在 70%以上。rpart 雖然 80%以上的情況下,正確性大於 80%,僅有少數情況正確性低於 20%(在疊加 1次,且落後期為 Lag 5 與 6 時較不穩定;
- 2. 在精確性方面, rpart 表現最佳, 精確性多在 80%以上。 其餘模型如 SVM, RF或 glm, 但有半數以上的情況, 精確 性為 80%;
- 3. 在 F1 指標方面,以 rpart 表現最佳,70%以上情況 F1 指標在 0.8 以上。其次為 SVM 及 glm,有半數以上情況,F1 指標都有 0.8 以上;
- 4. 在 Kappa 指標方面, rpart 表現最佳, 其次為 glm 及 SVM。

加入 y_t 的落後期變數後,各模型的預測績效指標都有提升。rpart 的表現最佳,正確性及精確性都在 80%以上,相當優秀。



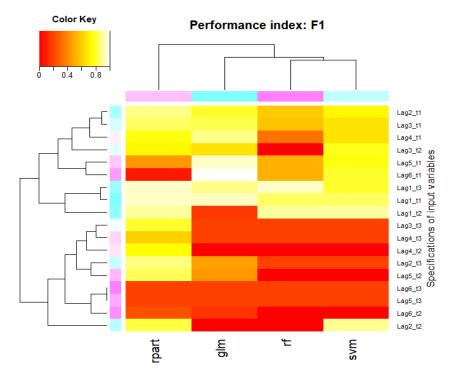
Models used to train raw data

(A) 正確性指標 (Accuracy)



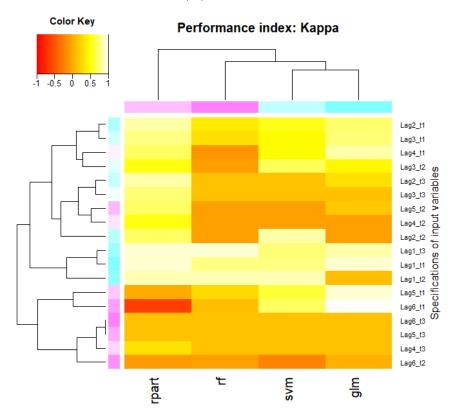
Models used to train raw data

(B) 精確性指標 (Precision)



Models used to train raw data

(C) F1 指標



Models used to train raw data

(D) Kappa 指標

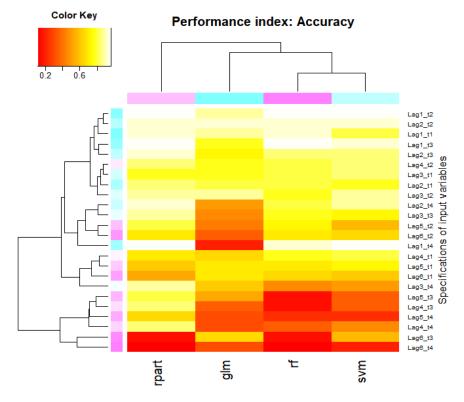
圖 $5.6: y_t = F(y_{t-p}, X_{t-p})$ 且 X = 原始資料的預測表現

第二、X是降維因子

因原始數據多,預測成效雖好但計算上較無效率,故以下嘗試降維。首先來看 ICA 降維後的結果:

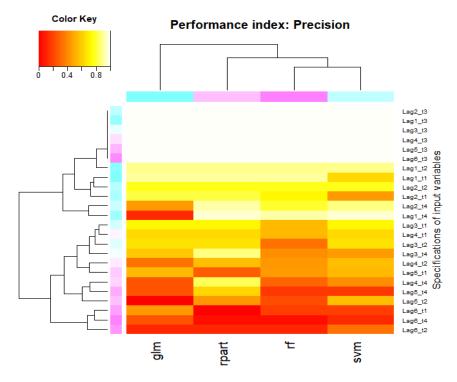
- 1. 在正確性方面,以 ICA 降維後,當 Lag=1,2 時,所有模型的正確性可到 90-100%之間。然而原本 rpart, SVM, RF在未降維前,正確性未有低於 40%的情況,在 ICA 降維後,正確性略為下降至 80%~90%。而原本表現次好的 glm,在降維後的正確性下降;
- 2. 在精確性方面,在 ICA 降維後,多數模型的精確性提高, 半數情況精確性可達 80%以上。但原本最差的 glm,在 ICA 降維後,也可改善精確性;
- 3. 在 F1 指標方面, ICA 降維後, rpart 表現仍最優, 三分之二的情況其 F1 指標在 0.8 以上, 以落後期為 Lag 1, 2 的預測表現最好。
- 4. 在 Kappa 指標方面,表現前三的模型依序為 rpart, SVM, RF, 最後為 glm。相較於降維前,此三模型在降維後, Kappa 指標都有提高。

綜上所述,在 ICA 降維後,rpart 的表現仍是最佳。而glm 因 ICA 降維而明顯改善預測表現,以落後期為 Lag 1,2 的預測表現最好。



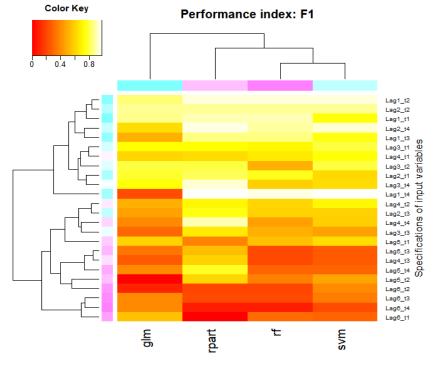
Models used to train ICA data

(A) 正確性指標 (Accuracy)



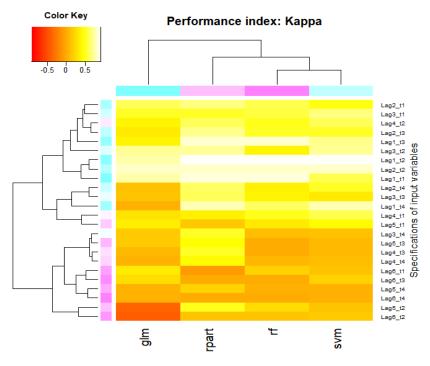
Models used to train ICA data

(B) 精確性指標 (Precision)



Models used to train ICA data

(C) F1 指標



Models used to train ICA data

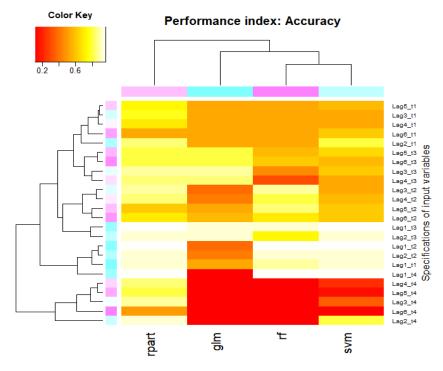
(D) Kappa 指標

圖 $5.7: y_t = F(y_{t-p}, X_{t-p})$ 且 X = ICA 的預測表現

再看以相關係數矩陣計算 PCA 方法降維後的結果,如圖 5.8 所示:

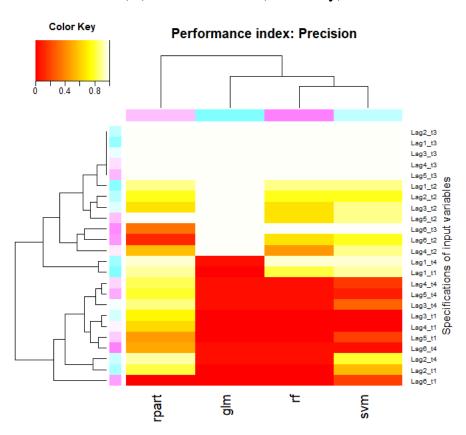
- 1. 在正確性方面,以相關係數矩陣計算的 PCA 方法降維後, rpart 的正確性提高,大部分情況的正確性可到 80%以上 (多為落後期 Lag 1 及 2 時)。而其他模型 SVM, RF 及 glm, 在以相關係數矩陣計算的 PCA 方法降維後,正確性不增 反減,尤其在疊加至 4 次時,正確性降至 0.2。
- 2. 在精確性方面,以相關係數矩陣計算的 PCA 方法降維後預測表現改善。rpart 精確性最佳,除少數情況外均可在60%以上,SVM、RF 的精確性在半數以上情況達 80%。疊加至3次時,所有模型的精確性均可達 100%。glm 的表現兩極,疊加至2及3次時精確性可達 100%,但疊加至1及4次時精確性低於 20%;
- 3. 在 F1 指標方面,按表現排序為 rpart, SVM, RF 及 glm; rpart 在絕大多數情況的 F1 均可達 0.8,僅在 Lag 6 時小於 0.4;
- 4. 在 Kappa 指標方面, rpart 最佳, Kappa 指標在 0.5 以上, 其後為 SVM、RF, 但大多數情況仍在 0.2 以上, glm 最差。

綜上所述,以相關係數矩陣計算的 PCA 方法降維後,表現最佳為 rpart,正確性或精確性在 80%以上,相當優良;其次為 SVM 與 RF。此結果與以原始數據的 X 差距不大,但略遜於 ICA 方法降維後的結果。



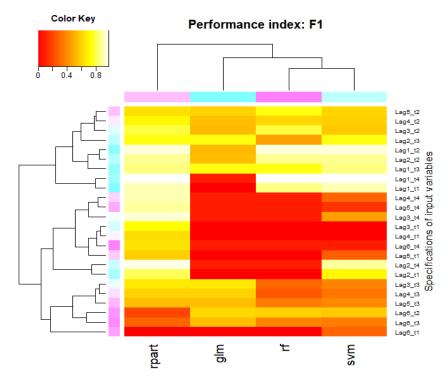
Models used to train PCA data by correlation

(A) 正確性指標 (Accuracy)



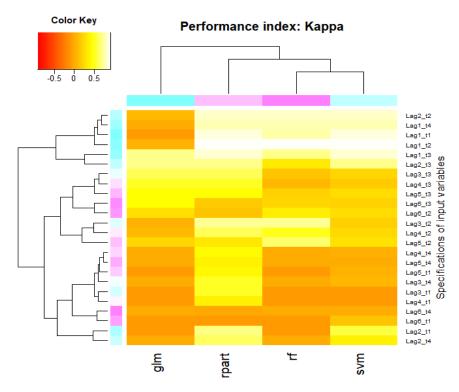
Models used to train PCA data by correlation

(B) 精確性指標 (Precision)



Models used to train PCA data by correlation

(C) F1 指標



Models used to train PCA data by correlation

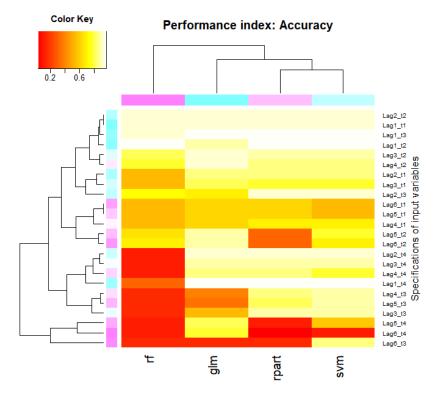
(D) Kappa 指標

圖 $5.8: y_t = F(y_{t-p}, X_{t-p})$ 且 $X = PCA_{corr}$ 的預測表現

再看以共變異數矩陣計算 PCA 方法降維後的結果,如圖 5.9 所示:

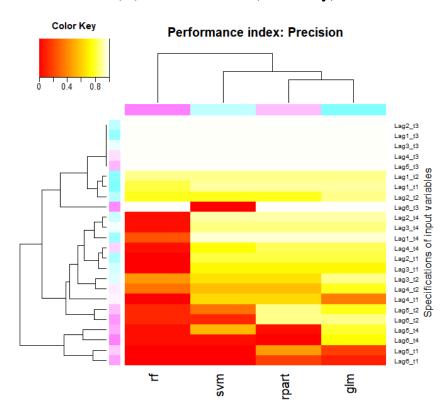
- 1. 在正確性方面,以共變異數矩陣計算的 PCA 方法降維後, rpart 正確性仍高; SVM 與 glm 的正確性在降維後明顯提高,大部分情況可到 80%以上,與 rpart 相當。但 RF 降 維後,正確性表現反而降低,約 30%的情況降至 20%;
- 2. 在精確性方面,以共變異數矩陣計算的 PCA 方法降維後, 各模型的精確性均有改善, SVM, glm, rpart 半數以上情況 可達 80%。表現最差者為 RF, 半數情況精確性在 20%;
- 3. 在F1指標方面,按表現排序為glm, rpart, SVM,以共變 異數矩陣計算的PCA方法降維後,F1指標均有改善,但 RF的F1指標仍差;
- 4. 在 Kappa 指標方面,glm 最佳,Kappa 指標接近 1,其後為 SVM 與 rpart,但半數以上情況在 0.4 以上。

綜上所述,以共變異數矩陣計算的 PCA 方法降維後,表現最佳為 glm,正確性多數在 90%以上,相當優良;其次為 SVM 與 rpart; RF 的表現最差。



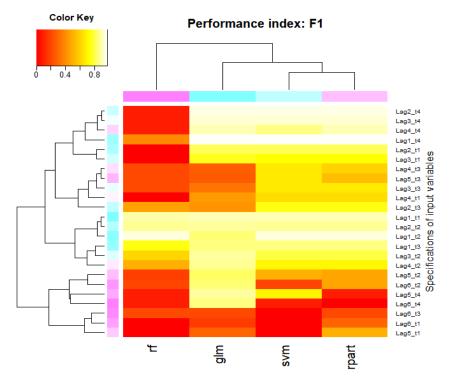
Models used to train PCA data by covariance

(A) 正確性指標 (Accuracy)



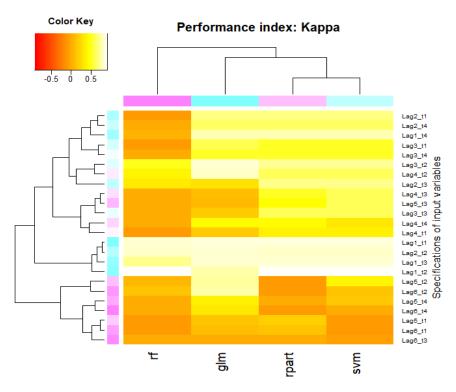
Models used to train PCA data by covariance

(B) 精確性指標 (Precision)



Models used to train PCA data by covariance

(C) F1 指標



Models used to train PCA data by covariance

(D) Kappa 指標

圖 $5.9: y_t=F(y_{t-p}, X_{t-p})$ 且 $X=PCA_cov$ 的預測表現

最後我們檢視 sampling variation。因各模型預測表現與 樣本疊加次數的關係,多數圖形皆列於附錄 B。在無自我相 關變數時結果如下:

- 1. 首先看原始資料的結果,大致而言各模型表現與疊加次數無明顯一致性。glm 及 rpart 表現較相近,在疊加至 1、3次(t1,t3)時正確性、精確性或 F1 均在 0.5以上;在疊加至 2、4次(t2,t4)時的預測表現較差,降至 0.5以下,尤其在 t4 最差。而 RF或 SVM 則是在疊加至 3次(t3)時預測表現較好,正確性、精確性或 F1 在 0.5以上,疊加至 2次(t2)以內均表現不佳。疊加至 4次(t4)時,僅有 RF的預測表現好,正確性、精確性或 F1 可達到 1。
- 2. 當以 ICA 降維時,各模型表現與疊加次數具有一致性。除了在落後期為 Lag 6 時,各模型均是在疊加至 1、2 次 (t1,t2) 模型的正確性、精確性及 F1 較佳,在 0.5 以上;但在疊加至 3、4 次 (t3,t4) 時,正確性及精確性及 F1 降低至 0.5 以下。
- 3. 以相關係數矩陣計算的 PCA 方法降維,各模型在疊加至 1次 (t1) 時的預測表現差異不大,正確性及精確性及 F1 約為 0.5,在疊加至 4次 (t4) 時最差,正確性及精確性及 F1 接近於 0。而 SVM 及 RF 在疊加至 2次 (t2) 時最好,正確性及精確性及 F1 在 0.5以上,並接近於 1。rpart 在疊加 1 至 4次 (t1~t4) 時表現均不理想,正確性及精確性及 F1 均小於 0.5。
- 4. 以共變異數矩陣計算的 PCA 方法降維,各模型在疊加至 1、2 次 (t1,t2) 時的預測表現差異不大; t1 時正確性及精確性及 F1 約為 0.5,在 t2 時大於 0.5。但在疊加至 4 次 (t4)

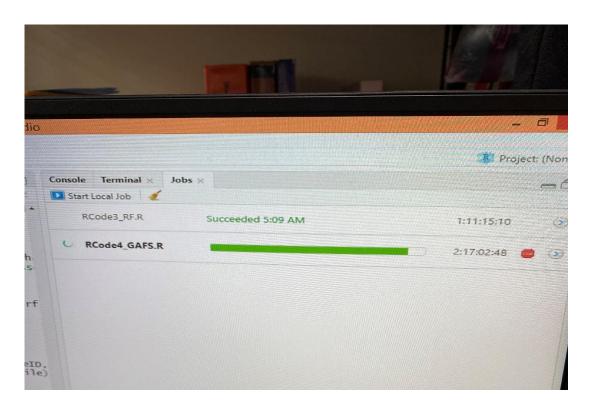
時最差,正確性及精確性及F1接近於0,僅有glm表現好,可接近1。而在疊加至3次(t3)時,僅rpart 的正確性及精確性及F1可大於0.5,其餘均較差。

在無 AR 項時,降維對模型預測表現的改善效果有限。 因此以下再進行加入 AR 項,結果如下:

- 1. 原始資料加入 AR 項後,在疊加至 2、3 次 (t2, t3) 時,所有模型的正確性均在 0.5 以上,同時其精確性亦均達 0.5;另 glm、RF 在疊加 1 次 (t1) 時精確性提高至接近 1,預測表現極佳。換言之,加入 AR 項後明顯增強預測表現。
- 2. 以 ICA 降維後,各模型正確性與精確性變差。多數模型均在疊加至 1、2次(t1, t2)時的正確性及精確性較佳,達0.5以上;疊加至 3、4次(t3, t4)時則降至 0.5以下,僅RF在 t3, t4 時仍保持接近 1。唯一例外是 glm 在落後期數Lag 5,6 時,疊加至 3次(t3)時預測表現較佳,正確性及精確性可達 0.5以上,疊加至 4次(t4)時降至 0.5以下。
- 3. 以相關係數矩陣的 PCA 降維後,疊加至 1~3 次 (t1~t3) 之間時,除了 glm 在 t2、SVM 在 t3 時,所有模型正確性及精確性均大於 0.5;疊加至 4 次 (t4) 時,除了 RF 正確性與精確性仍大於 0.5,其餘均小於 0.5。因此 RF 是最穩定,不論疊加次數為何,F1 及 Kappa 均介於 0.5 與 1 之間;另除 glm 之外,各模型在疊加至 1~3 次 (t1~t3) 的 F1 大於 0.5,t4 的 F1 小於 0.5。
- 4. 以共變異數的 PCA 降維後,除 SVM 在疊加至 3~4 次 (t3~t4),以及 glm 在疊加至 3 次 (t3) 時,正確性及精確性均小於 0.5 之外,各模型正確性及精確性均大於 0.5。

綜合前述,加入AR項後,RF的預測正確性與精確性接近1,並且在改變疊加次數或PCA降維後,都有一致的結果。

前文提及本計畫將嘗試進行基因演算法 (GAFS),其結果整體而言,耗時久且其預測表現沒有特別好。如以下附圖所示,平行運算耗時二天又 17 小時以上,因此以下第二階段的實做就不考慮 GAFS。



陸、第一階段分析之小結與預測

(一) 小結

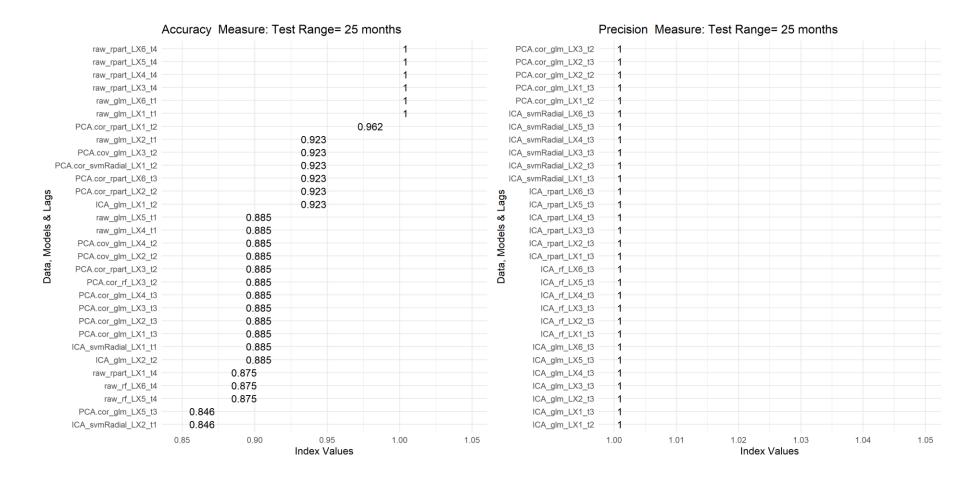
前述熱力圖協助我們檢視模型之間的關聯,因為 input variables 的設定,加上四類資料和四個模型的組合甚多,所以我們將之依指標,排序為最好與最差的 30 個,結果摘要如下:

1.模型僅包含 X 時:

- (1)預測績效最好的 30 個模型組合,如圖 6.1 所示:①在正確性方面,X 為原始數據的 rpart 及 PCA 方法 (共變異數或相關係數矩陣) 降維的 glm,正確性均達 85%以上;②在精確性方面,前 30 個模型組合的精確性均達到 1,包含以相關係數矩陣計算的 PCA 方法降維之 glm,以 ICA方法降維之 SVM, rpart, RF 及 glm;③在 F1 方面,X 為原始數據的 rpart 及 PCA 方法 (共變異數或相關係數矩陣) 降維的 glm,F1 均達 80%以上;④各模型 Kappa 的表現與 F1 相似。
- (2)預測績效最差的 30 個模型組合,如圖 6.2 所示:①在正確性方面,當 X 為以相關係數矩陣的 PCA 方法降維之 glm,或以 ICA 方法降維的 SVM, rpart, RF 及 glm,正確性僅 11.5%;②在精確性方面,最差的 30 個模型組合精確性均為 0,包含以相關係數矩陣計算的 PCA 方法降維之本研究使用模型,以 ICA 方法降維之 rpart 及 RF;③最差的 30 個模型組合,其正確性及精確性相似,而 F1 均為 0。

2.模型包含 AR 及 X 時:

- (1)預測績效最好的 30 個模型組合,如圖 6.3 所示:①在正確性方面,X 為原始數據以 PCA 方法 (共變異數或相關係數矩陣) 降維的 rpart, SVM 及 glm,及以 ICA 降維的 SVM, rpart, RF,正確性均達 96%以上;②在精確性方面,前 30 個模型組合的精確性均達到 1,包含以相關係數矩陣計算的 PCA 方法降維之 glm,以 ICA 方法降維之 SVM, rpart, RF 及 glm;③在 F1 方面,X 為原始數據的 rpart 及 PCA 方法 (共變異數或相關係數矩陣) 降維的各模型組合,F1 均達 94%以上;④各模型 Kappa 的表現與 F1 相似。
- (2)預測績效最差的 30 個模型組合,如圖 6.4 所示:①在正確性方面,當 X 為以相關係數矩陣的 PCA 方法降維之 RF 及 glm,或以 ICA 方法降維的 RF,正確性僅 11.5%;②在精確性方面,最差的 30 個模型組合精確性均為 0,包含以 PCA 方法降維(含相關係數及共變異數矩陣計算)之 RF 及 glm;③在 F1 及 Kappa 方面,最差 30 個模型組合的正確性及精確性相似,其中 RF 及 glm,F1 及 Kappa 均為 0。



(A) 正確性 (Accuracy)

(B) 精確性 (Precision)

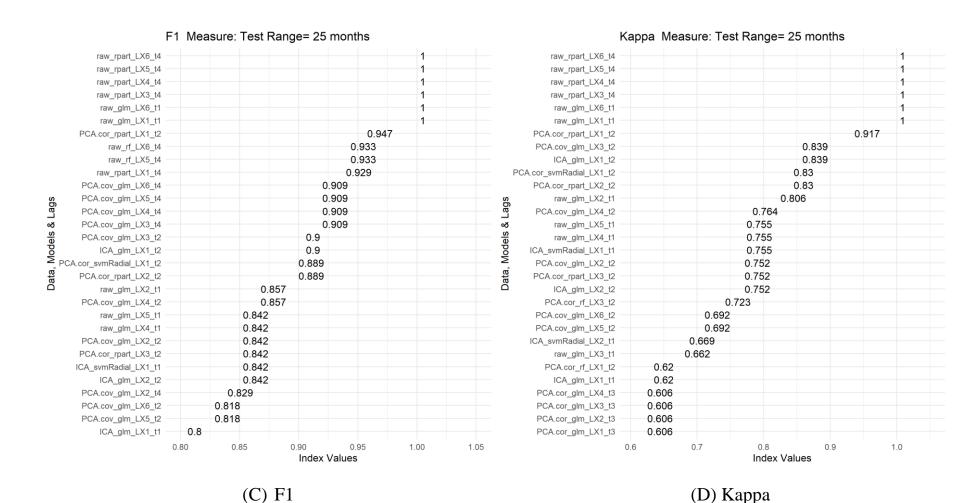
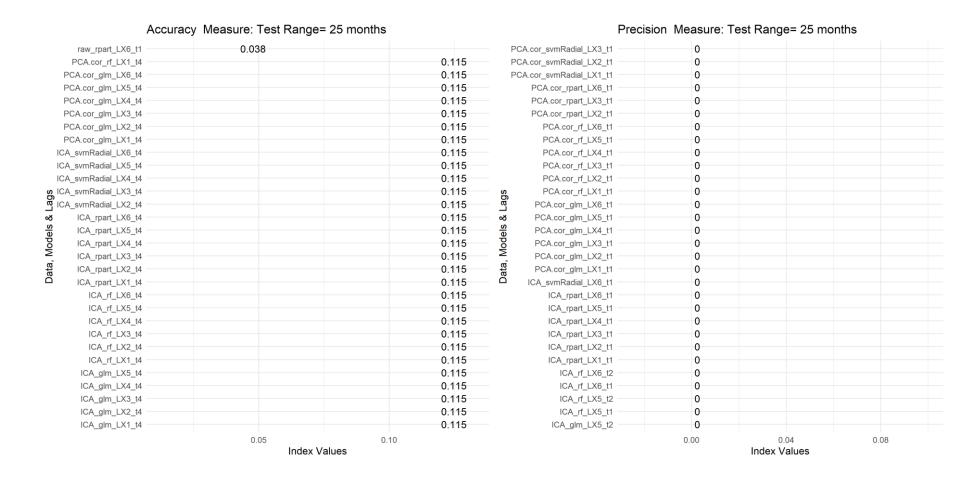


圖 6.1: 無 AR 項下預測表現最優 30 名的模型組合績效



(A) 正確性 (Accuracy)

(B) 精確性 (Precision)

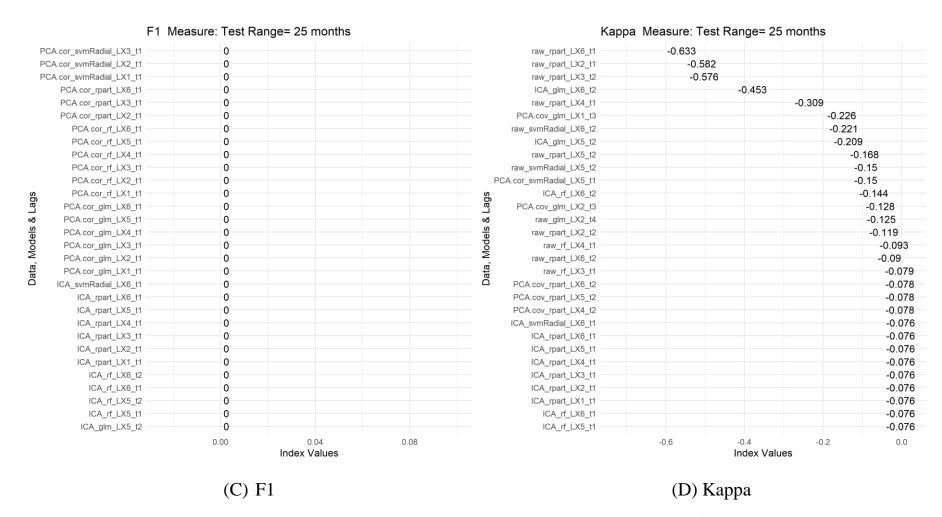
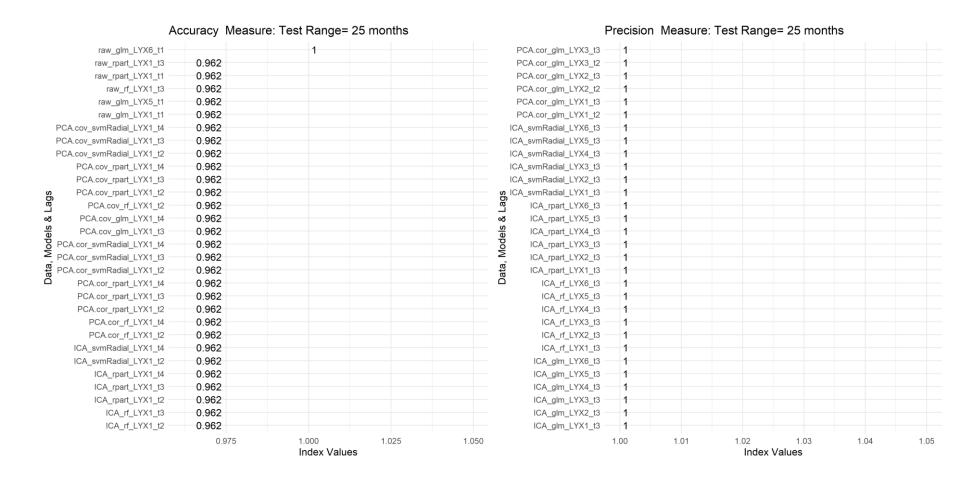


圖 6.2: 無 AR 項下預測表現最末 30 名的模型組合預測績效



(A) 正確性 (Accuracy)

(B) 精確性 (Precision)

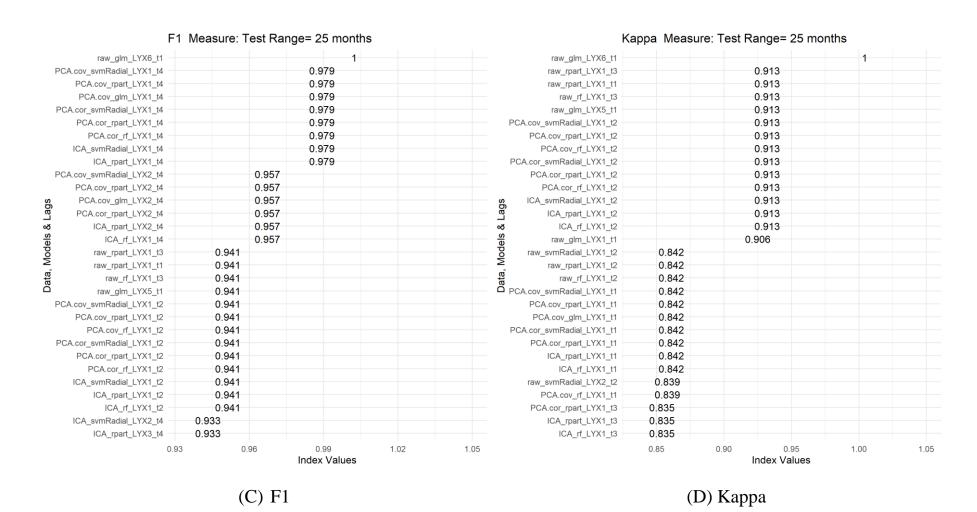
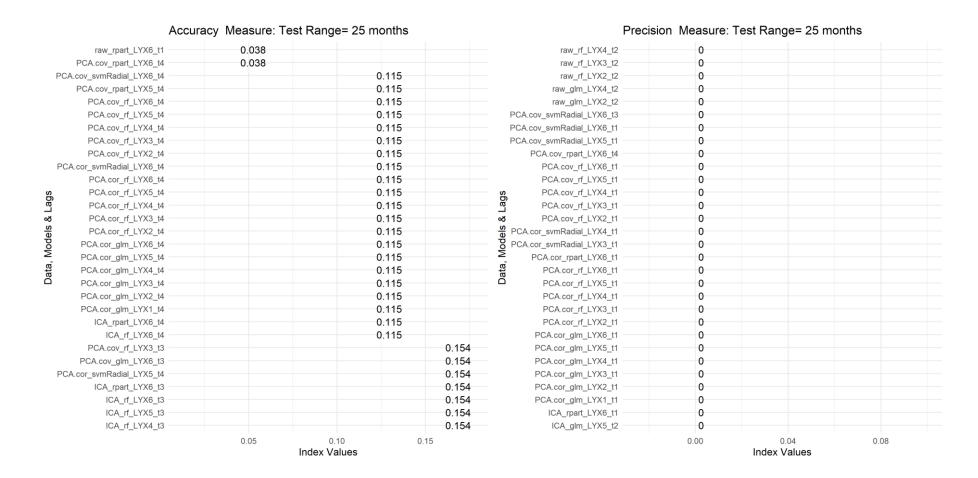


圖 6.3: 具 AR 項下預測表現最優 30 名的模型組合預測績效



(A) 正確性 (Accuracy)

(B) 精確性 (Precision)

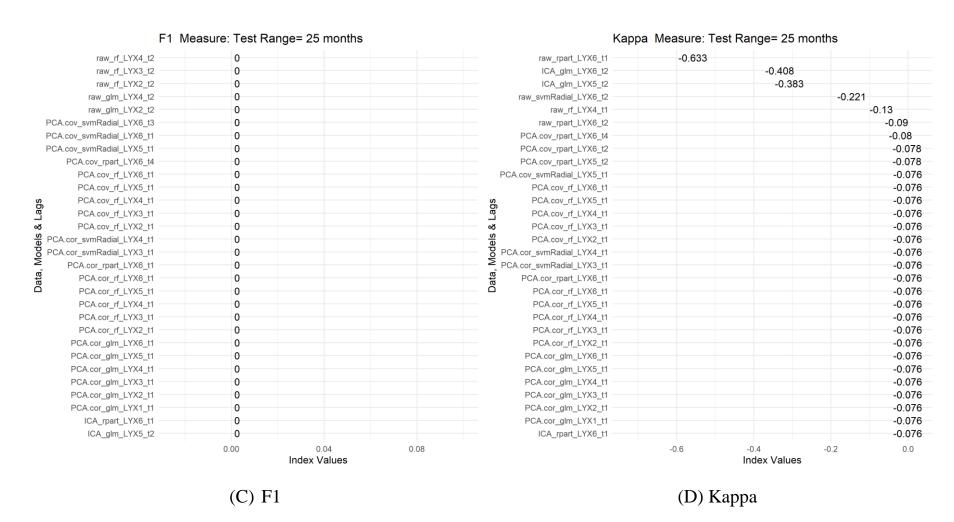


圖 6.4: 具 AR 項下預測表現最末 30 名的模型組合預測績效

(二)預測

根據上述熱力圖,模型不確定(Model Uncertianty)是很普遍現象,且根據 Rabinowicz and Rosset (2020),時間序列模式訓練資料集和測試資料集的資料相依(correlated data)問題,使傳統 K-Fold CV 會導致嚴重的預測偏誤。本文用預測平均法(forecasting average)解決:我們依照四個指標,各取出在 1982/1-2016/2 訓練期預測表現最好的前 50個模式,也就是說每個指標有 50 個最好的模型。然後根據四指標個別 50 個的簡單平均,再將四個指標的四個簡單平均再簡單平均一次產生 2016/3-2019/12 樣本外預測,結果如表 6.1A 與 6.2:

1.沒有 AR項:依國發會現已公布景氣循環峰谷認定,第 14 循環谷底為 2016 年 2 月,此為完整 1 個循環。其後開始第 15 循環的擴張期,按本研究最好的 50 個模式,以簡單平均法產生樣本外預測結果,從 2016 年 3 月經歷 23 個月的擴張期,至 2018 年 1 月為高峰,再經歷 13 個月的收縮期,至 2019 年 2 月為谷底。其後開始第 16 循環的擴張期。

表 6.1A:臺灣景氣循環峰谷認定第 15、16 循環預測 (無 AR 項)

谷底	高峰	谷底	擴張期	收縮期	全循環
2012.01	2014.10	2016.02	33	16	49
2016.02	2018.01	2019.02	23	13	36
2019.02					

綜合預測結果如下表表 6.1B

表 6.1B 臺灣景氣第 15 循環預測

	PredAveOnlyX
2016/3/1	1
2016/4/1	1
2016/5/1	1
2016/6/1	1
2016/7/1	1
2016/8/1	1
2016/9/1	1
2016/10/1	1
2016/11/1	1
2016/12/1	1
2017/1/1	1
2017/2/1	1
2017/3/1	1
2017/4/1	1
2017/5/1	1
2017/6/1	1
2017/7/1	1
2017/8/1	1
2017/9/1	1
2017/10/1	1
2017/11/1	1
2017/12/1	1
2018/1/1	1
2018/2/1	0
2018/3/1	0
2018/4/1	0
2018/5/1	0
2018/6/1	0
2018/7/1	0
2018/8/1	0
2018/9/1	0
2018/10/1	0
2018/11/1	0

2018/12/1	0
2019/1/1	0
2019/2/1	0
2019/3/1	1
2019/4/1	1
2019/5/1	1
2019/6/1	1
2019/7/1	1
2019/8/1	1
2019/9/1	1
2019/10/1	1
2019/11/1	1
2019/12/1	1

2.有 AR項:相較於無 AR項結果,第15循環的擴張期多2個月,高峰發生於2018年3月,谷底較無 AR項延後2個月,為2019年4月,相去不遠。因為2019/12以後依然是進行式,故限於資料,不做高峰認定,與無 AR項的預測結果相同。

表 6.2:臺灣景氣循環峰谷認定第 15、16 循環預測 (有 AR 項)

谷底	高峰	谷底	擴張期	收縮期	全循環
2012.01	2014.01	2016.02	33	16	49
2016.02	2018.03	2019.04	25	13	38
2019.04					

柒、第二階段-- 進一步方法

本節以LSTM及H₂O兩種深度學習方法進行預測。LSTM的 raw data 訓練計算用了 24 天又 18 小時,耗時程度超過想像,如下圖,應該是 raw data 變數太多導致。深度學習在大

規模資料的時間序列預測除了耗時,表現卻沒有比較好。財經時間序列預測,應該採用自動化機器學習模式就可以。

H₂O 的訓練之前一樣,深度學習 LSTM 因為要求訓練期的樣本和測試期樣本皆能整除 Cache size,因此樣本數略小於前述模式。採用估計 230 個月,測試 23 個月。其餘皆採用估計 299 個月,測試 25 個月。

Console Terminal x Jobs x ☐ Start Local Job ✓		-0
RCode_LSTM_raw.R Succeeded 3:35 AM	24:17:56:51	>
RCode_LSTM_Comp.R Succeeded 1:33 PM	1:04:11:26	>
RCode_LSTM_Comp.R Succeeded 1:15 PM	2:03:52:49	>
RCode_LSTM_Comp.R Succeeded 3:38 PM	2:06:16:03	>

(一) 綜合比較

深度學習方法預測結果,分別依預測指標排序最好與最 差的30個,摘要如下:

1. 預測績效最好的 30 個模型組合,如圖 6.5 所示:①在正確性方面,X為原始數據、PCA方法(共變異數或相關係數矩陣)降維的 LSTM,正確性均達 90%以上;②在精確性方面,前 30 個模型組合的精確性均達到 1,包含以原始數據、PCA方法(共變異數或相關係數矩陣)降維,以ICA方法降維之 LSTM、及 X 為原始數據之 H₂O;③在 F1 方面,X為原始數據及 PCA方法(共變異數或相關係數矩陣)降維的 LSTM,F1 均達 70%以上;④各模型 Kappa 的表現

與 F1 相似。

2. 預測績效最差的 30 個模型組合,如圖 6.6 所示:①在正確性方面,X 為原始數據的 LSTM、ICA 方法降維的 H₂O,正確性均不到 35%;②在精確性方面,前 30 個模型組合的精確性均為 0,包含以 PCA 方法(共變異數或相關係數矩陣)降維、以 ICA 方法降維之 LSTM 及 H₂O;③在 F1方面,X 為以 PCA 方法(共變異數或相關係數矩陣)或 ICA 方法降維的 LSTM 及 H₂O,F1 均為 0;④各模型 Kappa的表現與 F1 相似。

(二)預測

我們取出半數表現最好的預測模型,用之對 2016-2019 產生預測,並用簡單平均法進行樣本外預測。結果如表 6.3 與 6.4:

1. H₂O.autoML:依 H₂O.autoML 預測表現最優的前 27 個模型組合,取其預測平均,第 15 次循環的高峰發生於 2017年 12 月,經 18 個月收縮期,於 2019年 6 月到達谷底。並開始第 16 次循環。同前,因為 2019/12 以後依然是進行式,故限於資料,不做高峰認定。

表 6.3:臺灣景氣循環峰谷認定第 15、16 循環預測 (H₂O.autoML)

谷底	高峰	谷底	擴張期	收縮期	全循環
2012.01	2014.01	2016.02	33	16	49
2016.02	2017.12	2019.06	22	18	40
2019.06					

2. RNN-LSTM: 依 RNN-LSTM 預測表現最優的前 57 個模型 組合,取其預測平均,結果並未捕捉到轉折,演算耗時卻 表現奇差。

表 6.4:臺灣景氣循環峰谷認定第 15、16 循環預測 (RNN-LSTM)

谷底	高峰	谷底	擴張期	收縮期	全循環
2012.01	2014.01	2016.02	33	16	49

捌、結論與建議

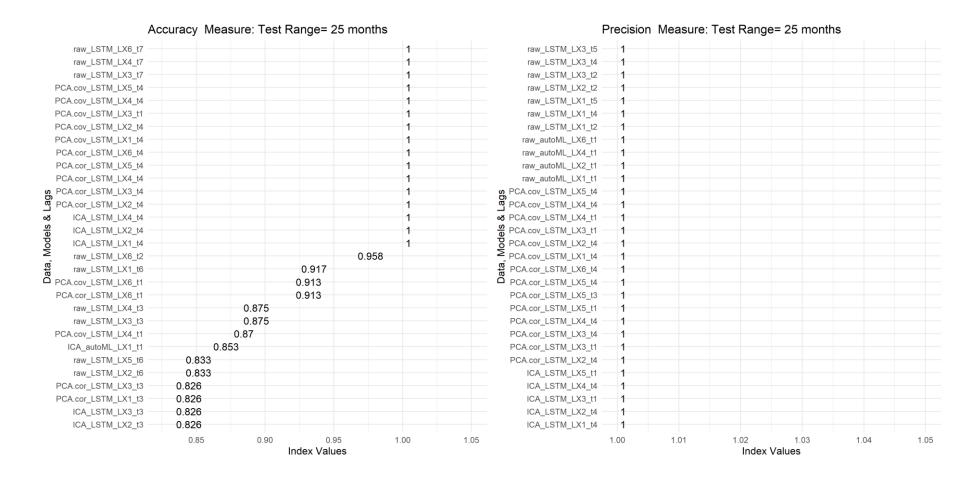
本案就景氣循環認定的歷史資料,建立多種機器學習預測模型,將國發會所編製的景氣認定,編碼為{收縮期=0,擴張期=1},因此{0,1}的切換就是轉折。如果預測準確度高,對於未來就較能掌握。依照資料長短,本案採用 68 個解釋變數,落後期從1至6。依照方法歸類,實證作法分為兩階段。就訓練而言,很多資料的表現都很好,因此在預測2016/3-2019/12 時,我們採用預測平均法 (forecasting average)。預測平均法的加權問題在文獻上有很多不同看法,因為不是本案重點,我們採用簡單平均。

人工智慧或任何的機器學習模式,都無法憑藉單一模型取得完勝,如 RNN-LSTM 的失靈: RNN-LSTM 在深度學習法訓練時表現很好,但是最後在 2016-2019 就產生不合理預測,這是典型過度配置 (over-fitting) 問題,係因學習記憶 迴圈太多或太少所導致。

據此對於人工智慧深度學習的時間序列預測,建議作法是如本文所完成的:不依賴單一模型,而是採用多個模型的預測平均 (forecasting average)。本案 H_2O .ai 所提供的自動化機器學習 (autoML) 源碼,就具有此類特性,本案的預測也是依此原則執行。

最後,未來可以考慮的進階研究,是時間序列模式中的資料相依 (correlated data) 問題導致的預測偏誤,這在Rabinowicz and Rosset (2020) 一文中有詳細討論。根據他們的模擬證據,K-Fold CV在資料集間有相依關係時,容易低估預測誤差。若考慮此問題以改善模型選擇,或將對時間序

列預測大有助益,謹供未來研究者參考。



(A) 正確性 (Accuracy)

(B) 精確性 (Precision)

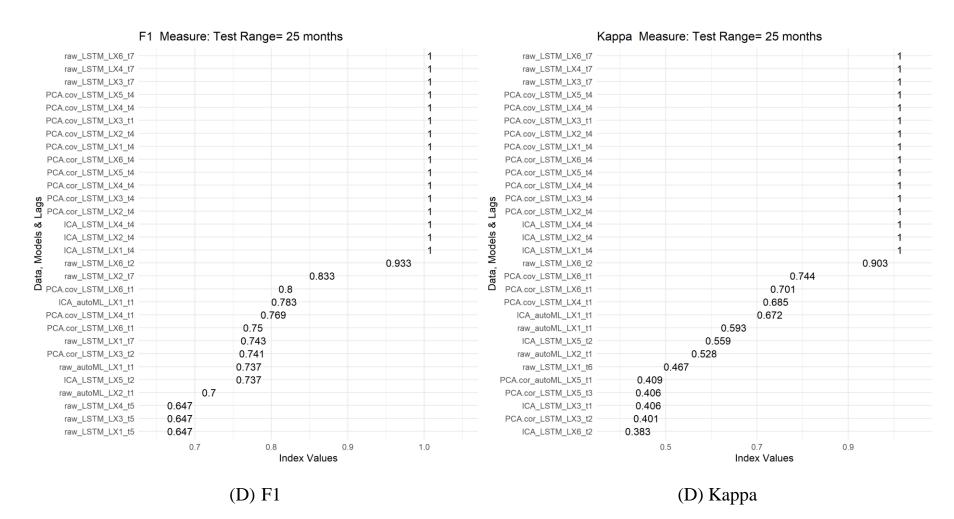
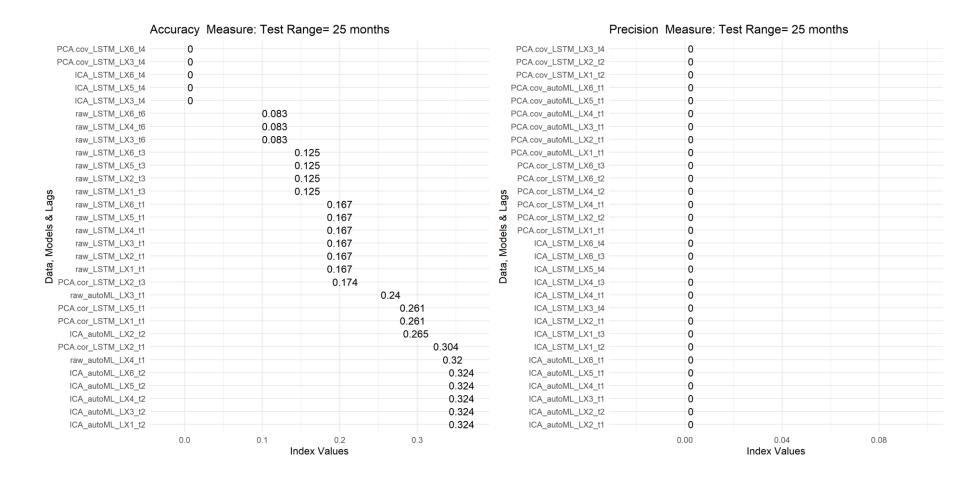


圖 6.5: 深度學習預測表現最優 30 名的模型組合預測績效



(A) 正確性 (Accuracy)

(B) 精確性 (Precision)

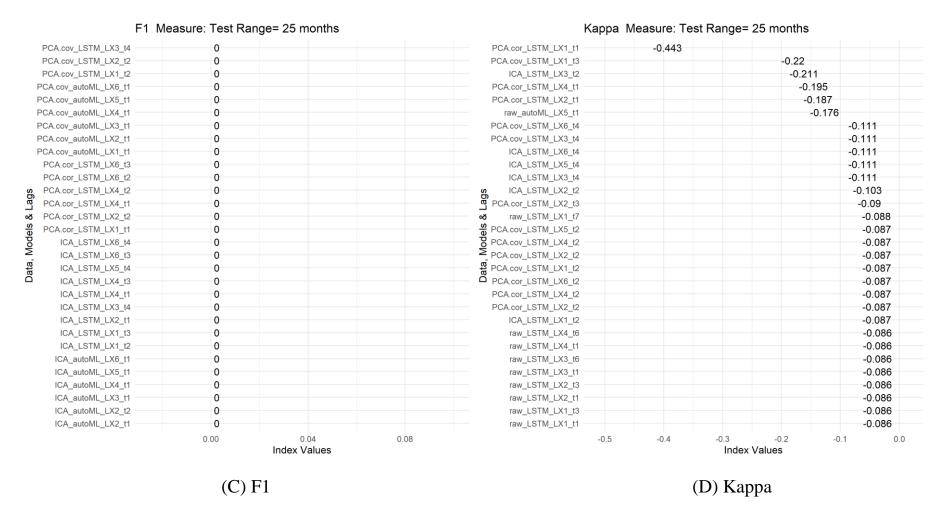


圖 6.6:深度學習預測表現最末 30 名的模型組合預測績效

附錄 A、相關研究介紹與探討之列表

作者 (年)	實證方法	研究發現
Proaño and Tarassow (2018)	景氣循環三階段區分法	三階段的 ordered probit model 相對傳統的 binary probit model
	非參數化的 dating algorithm	有較準確的機率預測與較佳的分類績效,
	ordered probit model	尤其是預測日本與德國的衰退期與加速成長期。
葉錦徽等 (2012)	Huang et al. (1998) 的經 驗	預測臺灣實質經濟成長率,解構序列並將所有成分內涵
	解構法 (empirical mode	置於模型進行預測,結果呈現良好的多步預測績效。
	decomposition, EMD)	
吳易樺等 (2014)	要素模型	以主成分分析法 (principal component analysis) 挑選用來預測
	時間序列線性模型	GDP 的要素,結果顯現要素模型多步預測力優於時間序列
	主成分分析法	模型。
徐婉容 (2020)	主成份分析法	將股市分為3狀態之多元邏輯迴歸模型,
	偏最小平方迴歸法	可提高對股市狀態的命中率,
		進而預期經濟實質面的變動。
(二)總體變數預測的機器	學習方法應用	
作者 (年)	實證方法	研究發現

Ahmed et al. (2010)

多層感知機

(multilayer perceptron)

貝式類神經網絡、

徑向基函數

(radial basis functions) >

一般化迴歸類神經網絡

(generalized regression

neural

networks, GRNN) \

K-近鄰演算法

(K-nearest neighbor, KNN) \

分類和迴歸決策樹

(CART regression trees) >

SVM 作迴歸模型

(support vector regression,

SVR) \

高斯過程 (Gaussian processes)

Richardson et al. (2019)

SVM

為紐西蘭 2009Q1-2018Q1 實質經濟成長率執行當下預測

NN

(nowcasting),發現機器學習方法如 SVM 和 NN,

AR

較諸傳統時間序列模型的誤差皆有明顯下降。

factor model

BVAR

106

Diebold and Shin (2019) peLASSO 以 1999Q3-2016Q4 樣本期間,根據歐洲中央銀行專業預測 簡單因子 人員調查的數據資料,預測歐元區樣本外一年的 實質經濟成長率。作者指出 peLASSO 預測績效優於 簡單因子平均合併(simple average combination)的方法; 而從向前疊加 (rolling forward) 找出最佳績效平均 (best average) 方法,預測表現亦優於 simple average combination • 為巴西、印尼、墨西哥、南非及土耳其等國, Cepni et al. (2020) AR 於2008年7月至2018年6月經濟成長率採取遞迴擬真 (pseudo) LASSO 樣本外預測, 預測方法有樣本外一期、樣本外兩期、 以及 nowcasting。結果指出包含全球因子的 貝氏變異 LASSO 方法,預測績效領先傳統計量 及其他 LASSO 方法。 隨機森林 (Random forest, RF在整體樣本期間有好的預測績效, Bolhuis and Rayner (2020) RF) \ 但無法完全捕捉經濟成長的大幅變動。 梯度提升決策樹 GBDT 的預測值波動稍大,但能捕捉到大幅的成長變動。 (Gradient boosted trees, GBT)、SVM 最能捕捉大幅的成長變動, 但預測值的波動幅度也較高。

SVM 方法、

動態因子模型 DFM

ML 組合型的預測績效皆優於基準模型 DFM,

RMSE 平均降幅 33%。

Gogas et al. (2015) probit

logit

SVM

以二元分類模型,利用殖利率曲線預測美國景氣衰退

實證顯示使用 SVM 方法預測正確性最高。

Puglia and Tucker (2020) probit \

隨機森林、

XGBoost \

LightGBM \

類神經網路、

支撐向量機

利用國庫券期間利差與其他九個金融市場

與總體經濟特徵變數,預測美國景氣衰退。

NTS 交叉驗證估計的預測績效排序為 probit、隨機森林

、XGBoost、LightGBM、類神經網路、支撐向量機,

但 K-folds 交叉驗證的排序則是相反,

顯示兩種交叉驗證實證結果差異頗大。

Soybilgen (2020) 動態因子模型

類神經網路模型

Soybilgen (2020) 發現,若資料未經移動平均去除噪音,

則將降低類神經網路模型 (NN) 的預測績效;

而資料經5個月,尤其是3個月的移動平均後,NN模型的預測績效大幅改善。再者,動態因子模型的設定,假設共同動態因子數 r ,共同衝擊 (common shock) 個數 q ,落後期 p ,

則當 p=1, r=q=2 或 r=q=4, NN 的預測績效最佳。

最後,類神經網路模型的設定相對簡化,一層隱藏層 (hidden layer) 與一層產出層 (output layer)。由於它對於起始值 很敏感,因此每個估計視窗都跑 100 次不同的起始值, 然後將 100 個 NN 模型的結果加以平均。

Psimopoulos (2020) 類神經網路 (ANN)、

機器向量學習機 SVM

與隨機森林 RF Probit 與 Logit SVM 預測績效最佳,代表債務的總體變數如房貸, 是預測景氣衰退的重要變數。

(三) 其他財經議題應用機器學習方法

作者(年)	實證方法	研究發現	
Patel et al. (2015)	將第一階段的 SVR 模型	以印度 S&P CNX Nifty 指數和孟買敏感指數	
	結果,分別帶入第二階段	(CODDl C4 - l - E l C '-' I l) l ケ 刺 トe	
	的 ANN、隨機森林	(S&P Bombay Stock Exchange Sensitive Index) 十年數據	
	(random forest, RF) •	做為樣本,SVR 與 ANN 預測力最佳。	
	SVR 等模型		
Wei (2016)	ANFIS	預測臺灣加權股價指數與香港恆生股價指數,	
	AR	ANFIS 的 RMSE 最小。	

SVR

Hafezi et al. (2015) BNNMAS

GANN

GRNN

預測 2007-08 年全球金融危機下 DAX 的績效後, 認為 BNNMAS 是正確性最高最可靠的模型。

de Stefani et al. (2017) NARX

ANN

KNN

SVR

採用機器學習模型預測恐慌指數時,結果顯示在 NARX

架構下,另一個指數的補充訊息有助於降低 NARX 架構下

的預測誤差,進而提升指數的預測力。

Gu et al. (2020) Boosted 迴歸樹

隨機森林

類神經網路

其一是根據 Fama and French (1993) 與 Lewellen (2015), 以橫斷面股票特性探討預期報酬率的差異。其二根據 Welch and Goyal (2008), Koijen and Nieuwerburgh (2011),

Rapach and Zhou (2013) 的報酬率時間序列預測,將總和型

的投資組合報酬率,對少數總體預測因子作時間數列

迴歸。實證發現 (1) 個股月報酬率的預測,以迴歸樹

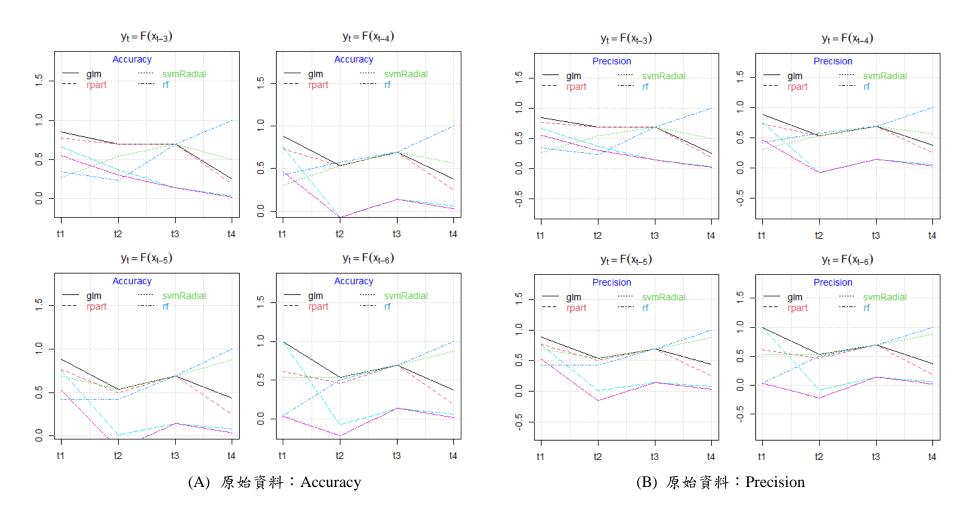
與神經網絡可大幅改善迴歸模型的預測績效,

且淺層學習優於深度學習;(2)投資組合報酬率的預測,則以非線性方法的機器學習預測績效改善幅度最為明顯,

最成功的預測因子類型為價格趨勢、流動性與波動性;

		(3) 根據機器學習的估計結果做 portfolio selection,可大幅 提高 Sharpe ratio,顯示投資績效的顯著進步。
Tolo (2020)	Logit 模型、MLP、 RNN-LSTM RNN-GRU	進行提前 1-5 年的系統性金融危機預測, 使用 Jorda-Schularick-Taylor data sets 的 panel data, 樣本期間 1870-2016,包含 17 個國家危機發生的日期, 以及總體經濟變數年資料。實證發現 RNN-LSTM 與 RNN-GRU 對於時間序列具有穩健的預測能力, 故可顯著改善預測績效。

附錄 B 多模型和設定之 Sampling variations



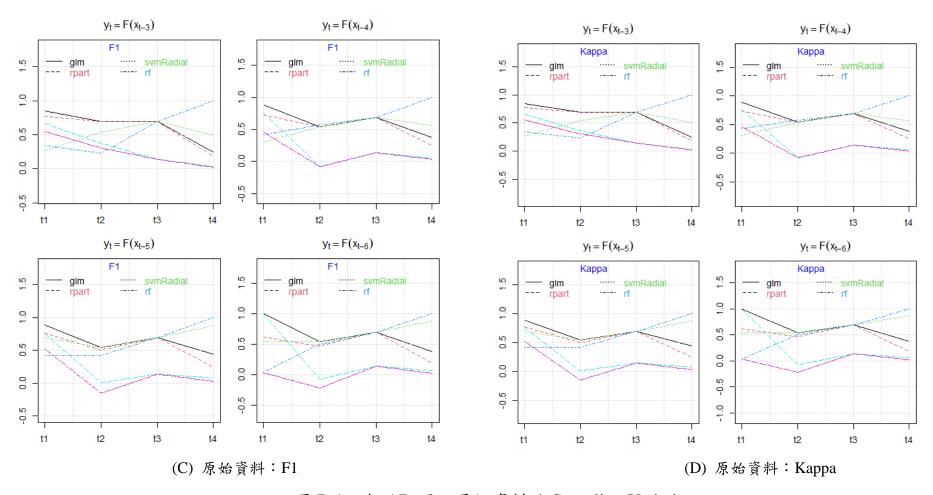
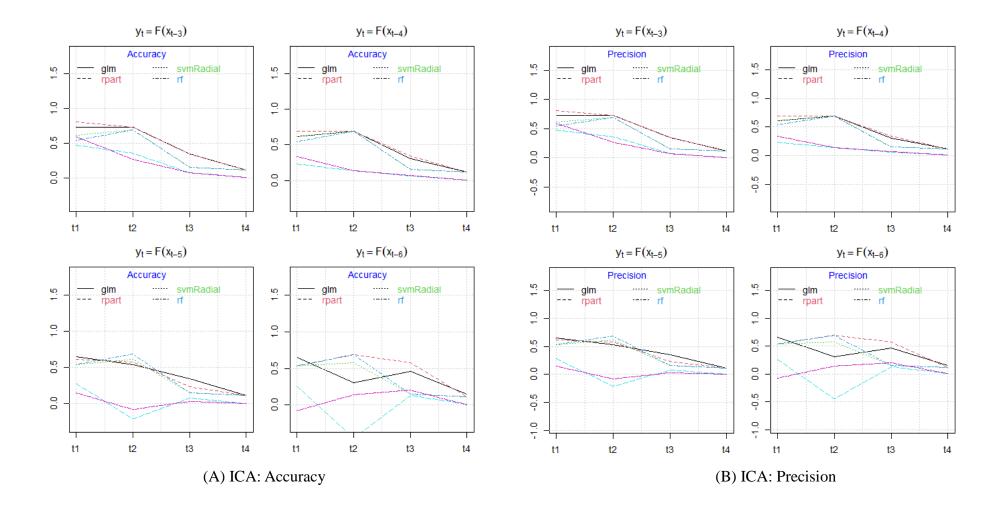


圖 B.1: 無 AR 項下原始資料的 Sampling Variation



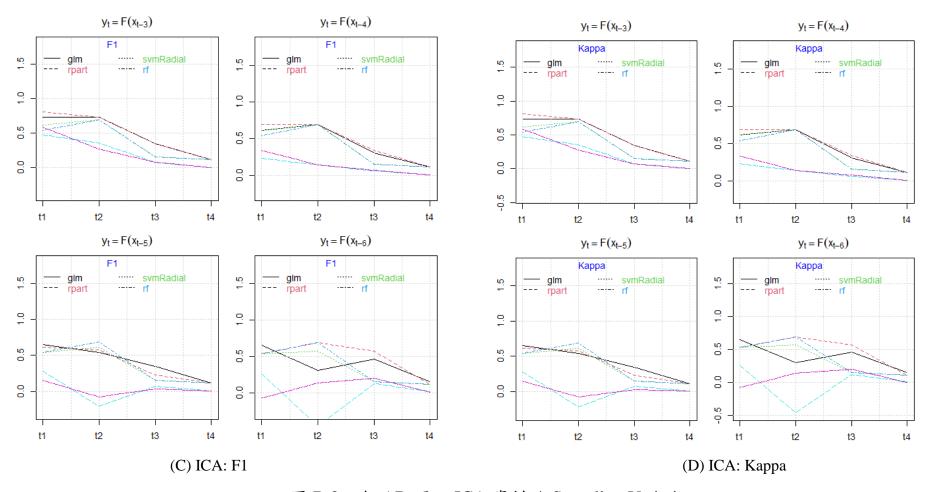
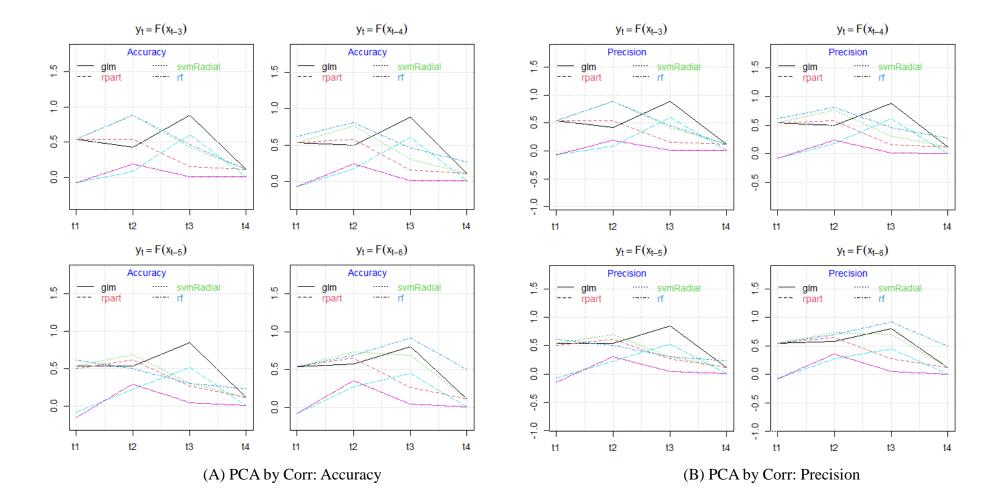


圖 B.2: 無 AR 項下 ICA 資料的 Sampling Variation



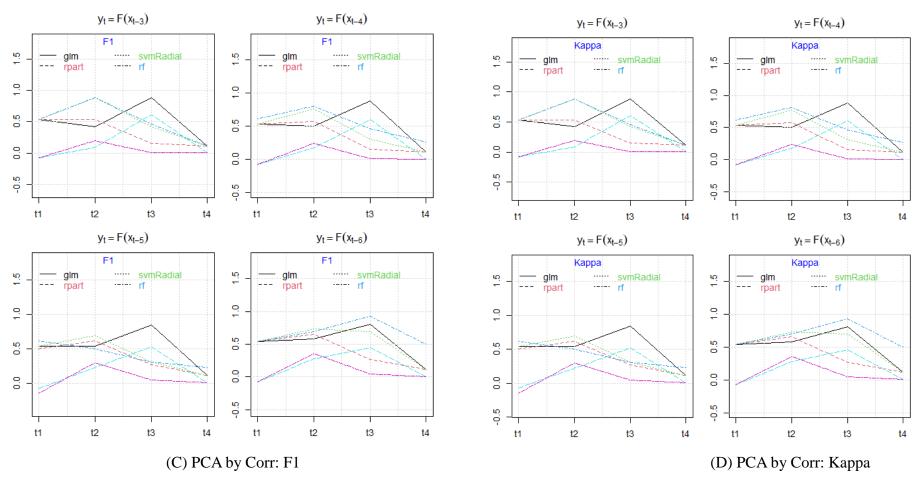
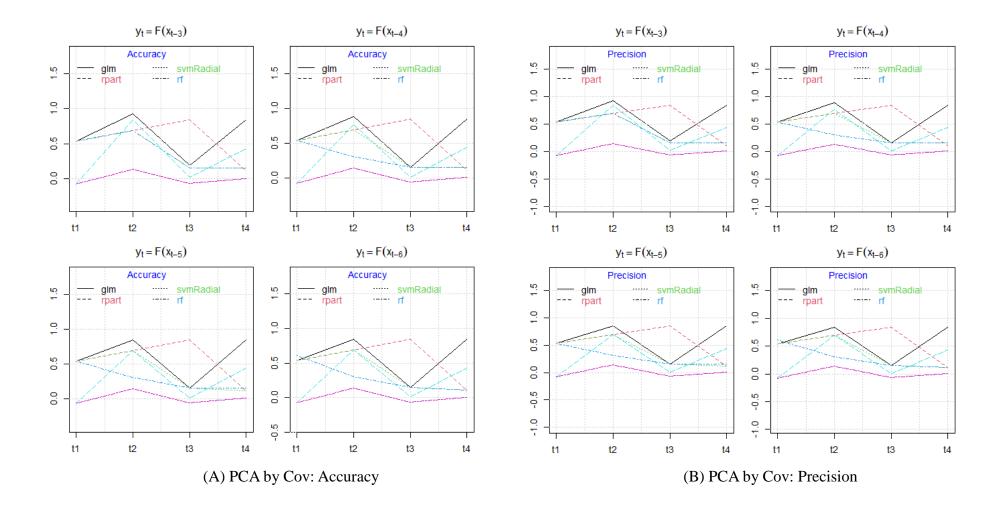


圖 B.3:無 AR 項下用相關係數計算的 PCA 之 Sampling Variation



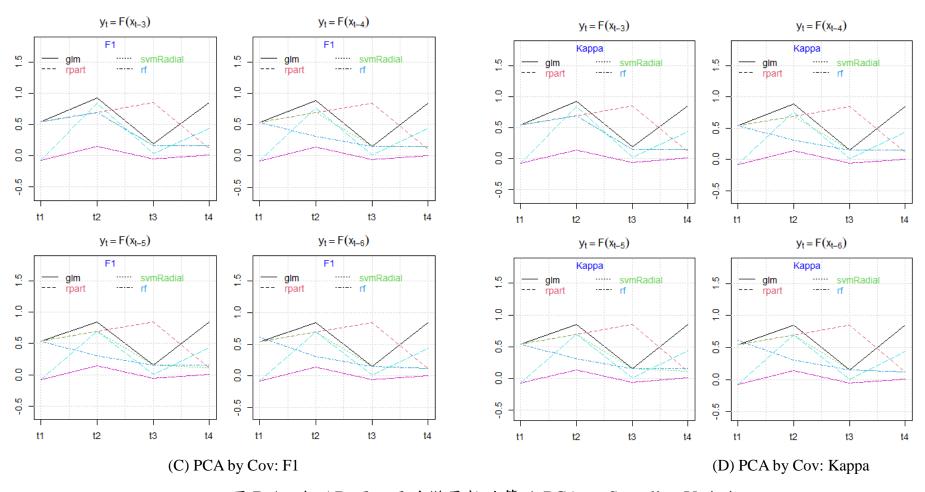
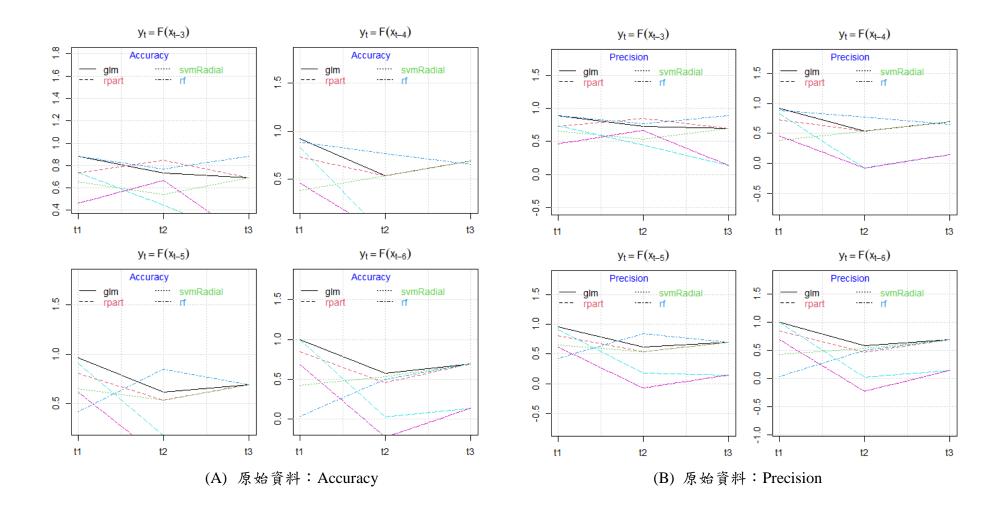


圖 B.4: 無 AR 項下用共變異數計算的 PCA 之 Sampling Variation



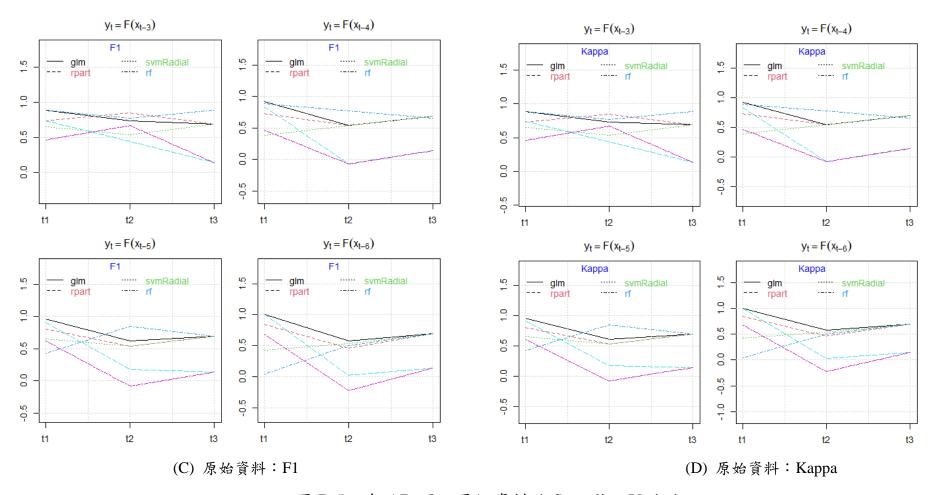
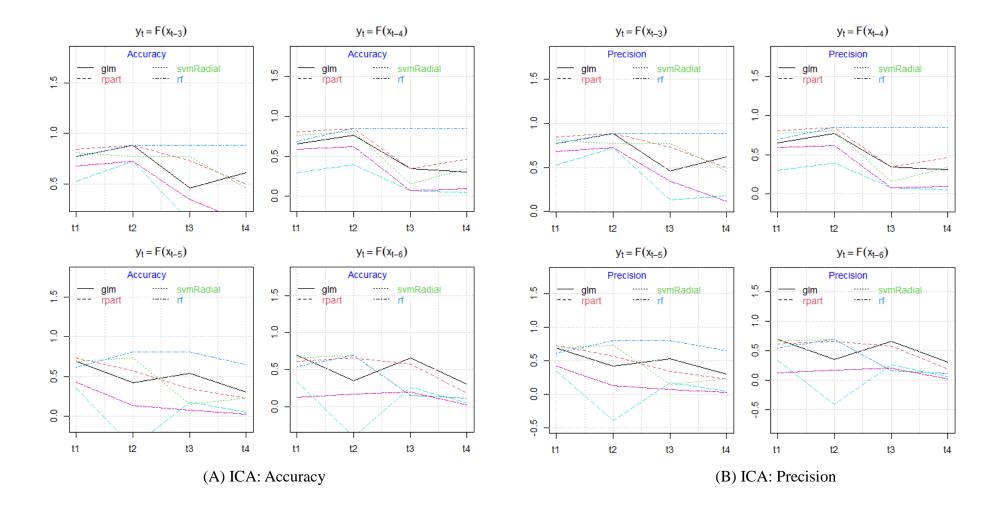


圖 B.5:有 AR 項下原始資料的 Sampling Variation



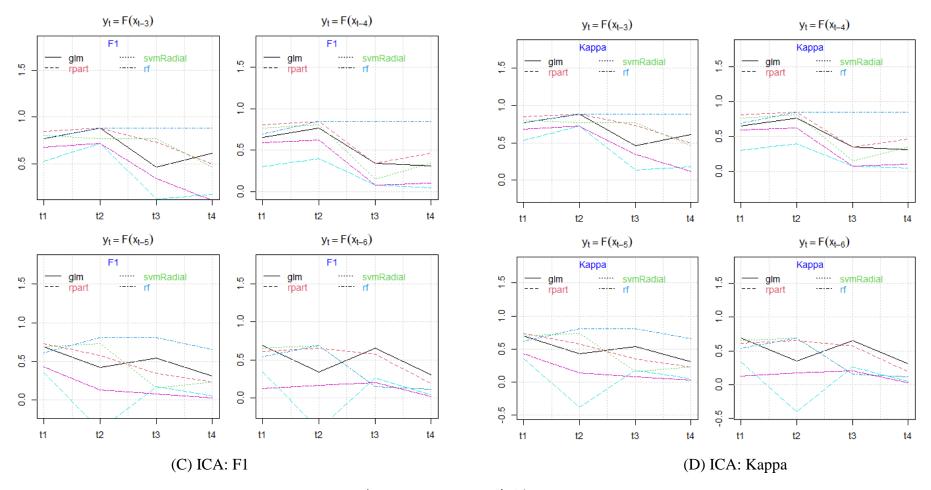
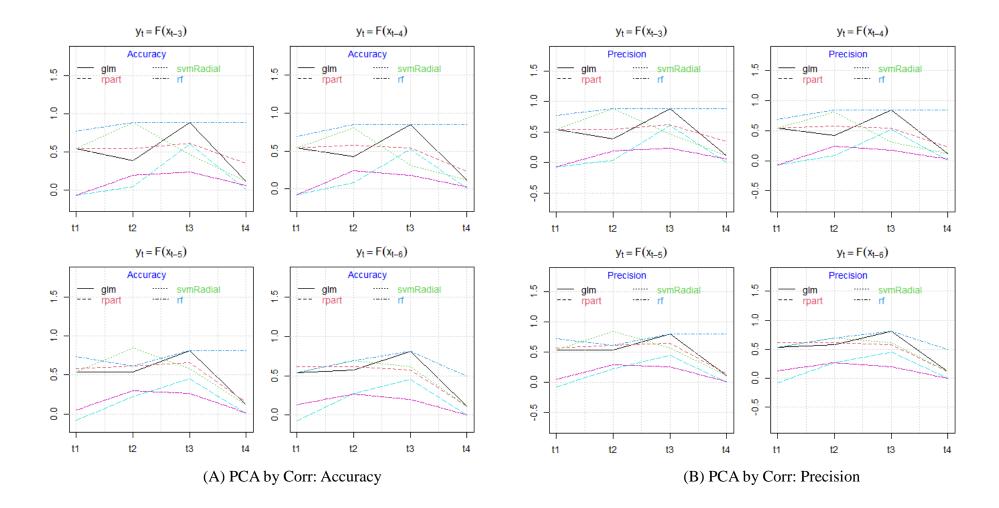


圖 B.6:有 AR 項下 ICA 資料的 Sampling Variation



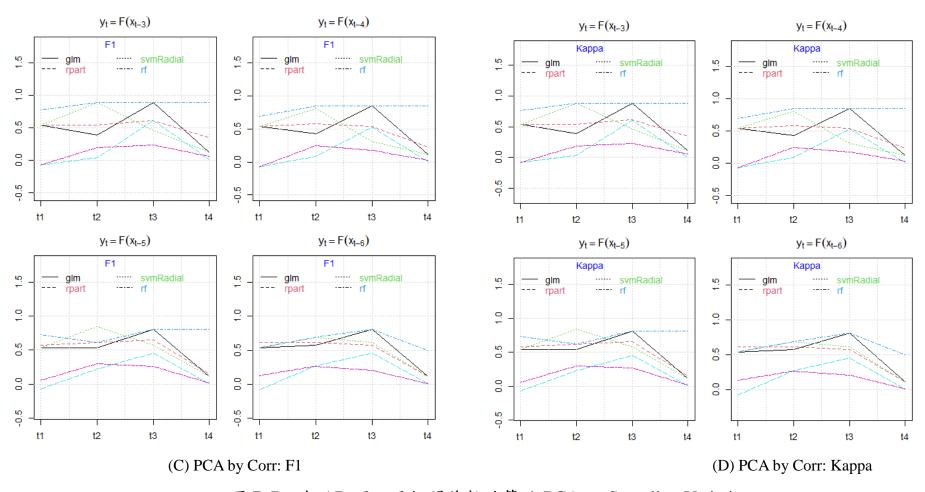
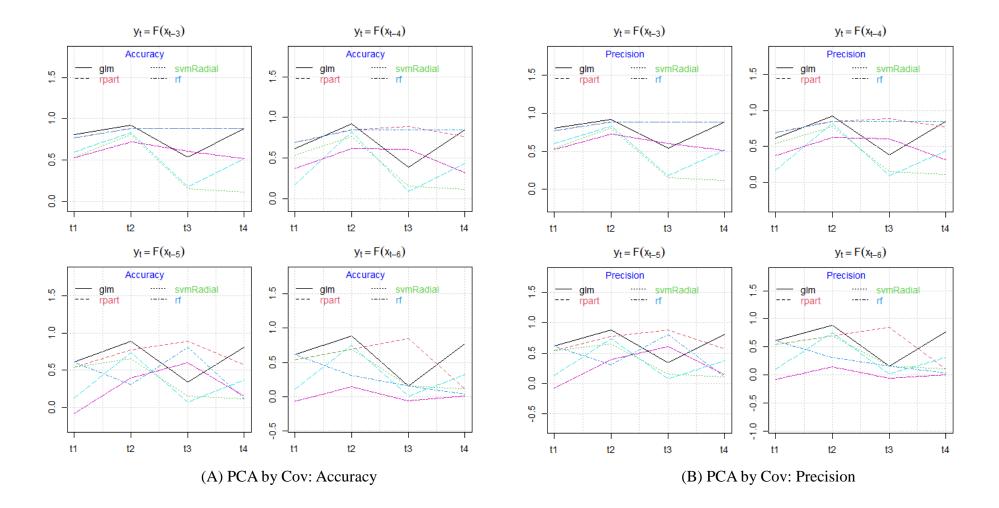


圖 B.7:有 AR 項下用相關係數計算的 PCA 之 Sampling Variation



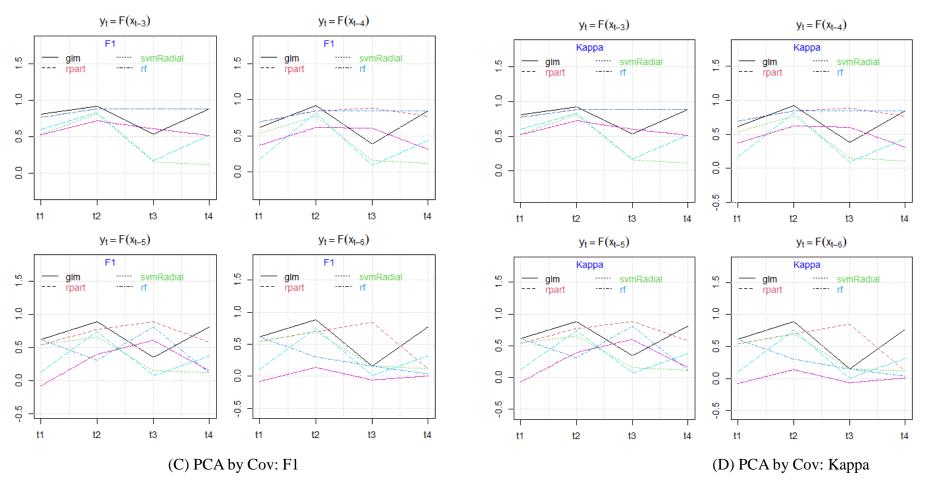


圖 B.8:有 AR 項下用共變異數計算的 PCA 之 Sampling Variation

參考文獻

- 吳易樺,黃朝熙,劉子衙 (2014)。時間序列模型對我國產業成長預 測之優劣比較,應用經濟論叢 96,35-68。
- 吳俊毅,朱浩榜 (2019)。即時預報臺灣的經濟成長率—MIDAS 模型之應用,臺灣總體金融與經濟情勢預測研討會,台北:臺灣經濟學會、中央銀行、臺灣大學經濟學系。
- 林向愷,黃裕烈,管中閔 (1998)。景氣循環轉折點認定與經濟成長 率預測,經濟論文叢刊 26(4),431-457。
- 徐士勛,管中閔,羅雅惠 (2005)。以擴散指標為基礎之總體經濟預測,臺灣經濟預測與政策 36(1),1-28。
- 徐婉容 (2020)。認定與預測台灣股市熊市, <u>中央銀行季刊</u> 42(2), 37-72。
- 陳宜廷,徐士勛,劉瑞文,莊額嘉 (2011)。經濟成長率預測之評估與 更新,經濟論文叢刊 39(1),1-44。
- 葉錦徽,程英賓,王景南 (2012)。經驗解構法與台灣經濟成長之預測,經濟論文 40(4),559-598。
- Ahmed, N. K., Atiya, A. F., Gayar, N. E., & El-Shishiny, H. 2010. An

- empirical comparison of machine learning models for time series forecasting. *Econometric Reviews* 29(5-6), 594-621.
- Adler, G., Duval, R.A., Furceri, D., Celik, S.K., Koloskova, K., & Poplawski-Ribeiro, M. 2017. Gone with the Headwinds; Global Productivity. IMF Staff Discussion Notes. International Monetary Fund.
- Bai, J., & Ng, S. (2008). Forecasting economic time series using targeted predictors. *Journal of Econometrics* 146(2), 304-317.
- Bolhuis, M. A. & Rayner, B. 2020. Deus ex machina? A framework for macro forecasting with machine learning. IMF Working Paper, WP/20/45.
- Bry, G. & Boschan, C. 1971. Cyclical Analysis of Time Series: Selected procedures and Computer Programs. NBER, Cambridge, MA.
- Burns, A. F. & Mitchell, W. C. 1946. *Measuring Business Cycles*. NBER, Cambridge, MA.
- Butaru, F., Chen, Q., Clark, B., Das, S., Lo, A. W., & Siddique, A. 2016. Risk and risk management in the credit card industry. *Journal of Banking & Finance* 72(2), 18–39.
- Candelon, A. F. & Mitchell, W. C. 2013. Disentangling economic recessions and depressions. Bundesbank Discussion Paper.
- Carstensen, K., Heinrich, M., Reif, M., & Wolters, M.H. 2017. Predicting ordinary and severe recessions with a three-state Markov-switching dynamic factor model. An application to the German business cycle. CESifo Working Paper.
- Cepni, O., Guney, I. E., & Swanson, N. R. 2020. Forecasting and nowcasting emerging market GDP growth rates: The role of latent global economic policy uncertainty and macroeconomic data surprise factors. *Journal of Forecasting* 39(1), 18-36.
- Chen, S. W. & Lin, J. L. 2000. Modelling business cycles in Taiwan with time varying Markov switching models. *Academia Economic Papers* 28(1), 17-42.
- Diebold, F. X., & Shin, M. 2019. Machine learning for regularized survey forecast combination: Partially-egalitarian LASSO and its

- derivatives. *International Journal of Forecasting* 35(4), 1679-1691.
- Estrella, A. & Hardouvelis, G. A. 1991. The term structure as a predictor of real economic activity. *Journal of Finance* 46, 555–576.
- Estrella, A. & Mishkin, F. S. 1995. The term structure of interest rates and its role in monetary policy for the European Central Bank. NBER Working Paper 5279.
- Estrella, A. and & Mishkin, F. S. 1997. The predictive power of the term structure of interest rates in Europe and the United States: Implications for the European Central Bank. *European Economic Review* 41, 1375–1401.
- Estrella, A. 2005. Why does the yield curve predict output and inflation? *Economic Journal* 115, 722–744.
- Fama, E. F. & French, K. R. 1993. Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics* 33, 3–56.
- Feng, G., Giglio, S., & Xiu, D. 2020. Taming the factor zoo: A test of new factors. *Journal of Finance*, forthcoming.
- Feng, L. & Zhang, J. 2014. Application of artificial neural networks in tendency forecasting of economic growth. *Economic Modelling* 40, 76-80.
- Ferrara, L. 2003. A three-regime real-time indicator for the US economy. *Economics Letters* 81, 373–378.
- Freyberger, J., Neuhierl, A., & Weber, M. 2020. Dissecting characteristics nonparametrically. *The Review of Financial Studies* 33(5), 2326-2377.
- Giglio, S. W. & Xiu, D. 2016. Asset Pricing with Omitted Factors. Tech. Report, University of Chicago.
- Gogas, P., Papadimitriou, T., Matthaiou, M., & Chrysanthidou, E. 2015. Yield curve and recession forecasting in a machine learning framework. *Computational Economics* 45(4), 635-645.
- Gu, S., Kelly, B. T., & Xiu, D. 2019. Autoencoder asset pricing models. Working Paper, Yale University.
- Hafezi, R., Shahrabi, J., & Hadavandi, E. 2015. A bat-neural network

- multi-agent system (BNNMAS) for stock price prediction: Case study of DAX stock price. *Applied Soft Computing* 29, 196-210.
- Hamilton, J.D. 1989. A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica* 57, 357–384.
- Harding, D. & Pagan, A. 2002. Dissecting the cycle: A methodological investigation. *Journal of Monetary Economics* 49, 365–381.
- Harvey, C. R., Liu, Y., & Zhu, H. 2016. And the cross-section of expected returns. *Review of Financial Studies* 29, 5–68.
- Heaton, J. B., Polson, N. G., & Witte, J. H. 2016. Deep learning in finance. Preprint, https://arxiv.org/abs/1602.06561.
- Ho, W.-Y.A., & Yetman, J. 2012. Does US GDP stall? BIS Working Paper.
- Huang, C. H. 1999. Phases and characteristics of Taiwan's business cycles: A Markov switching analysis. *Taiwan Economic Review* 27(2), 515-540.
- Hutchinson, J. M., A. W. Lo, and T. Poggio. 1994. A nonparametric approach to pricing and hedging derivative securities via learning networks. *Journal of Finance* 49, 851–89.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. 2013. *An Introducton to Statistical Learning*. Springer Science & Business Media.
- Karpathy, A. 2015. The Unreasonable Effectiveness of Recurrent Neural Networks. Available at http://karpathy.github.io/2015/05/21/rnn-effectiveness/.
- Kelly, B., Pruitt, S., & Su, Y. 2019. Characteristics are covariances: A unified model of risk and return. *Journal of Financial Economics* 134(3), 501-24.
- Khandani, A. E., Kim, A. J., & Lo, A.W. 2010. Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance* 34, 2767–87.
- Koijen, R. & Nieuwerburgh, S. V. 2011. Predictability of Returns and Cash Flows. *Annual Review of Financial Economics* 3,467–91.

- Kozak, S., Nagel, S., & Santosh, S. 2020. Shrinking the cross section. *Journal of Financial Economics* 135, 271–92.
- Krolzig, H.-M. & Toro, J. 2001. A new approach to the analysis of business cycle transitions in a model of output and employment. Department of Economics Discussion Paper, Oxford University.
- Kuhn, M., & Johnson, K. 2013. *Applied predictive modeling (Vol. 26)*. New York: Springer.
- Kuo, C. E., & Chen, G. T. 2020. Automatic sleep staging based on a hybrid stacked LSTM neural network: Verification using large-scale dataset. *IEEE Access* 8, 111837-111849.
- Landis, J. R., & Koch, G. G. 1977. The measurement of observer agreement for categorical data. *Biometrics*, 159-174.
- Lewellen, S. 2015. Executive compensation and industry peer groups. Unpublished working paper. London Business School.
- Moritz, B., and & Zimmermann, T. 2016. Tree-based conditional portfolio sorts: The relation between past and future stock returns. Working Paper, Ludwig Maximilian University of Munich.
- Nalewaik, J. J. 2011. Forecasting recessions using stall speeds. Finance and Economics Discussion Series, Federal Reserve Board.
- Nik, P., Jusoh, M., Shaari, A. H., & Sarmdi, T., 2016. Predicting the probability of financial crisis in emerging countries using an early warning system: Artificial neural network. *Journal of Economic Cooperation and Development* 37(1), 25-40.
- Olah, C. 2015. Understanding LSTM Networks, Available at https://colah.github.io/posts/2015-08-Understanding-LSTMs/.
- Patel, J., Shah, S., Thakkar, P., & Kotecha, K. 2015. Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert systems with applications* 42(1), 259-268.
- Peker, M. 2016. An efficient sleep scoring system based on EEG signal using complex-valued machine learning algorithms. *Neurocomputing* 207, 165-177.

- Proaño, C. R. 2017. Detecting and predicting economic acceleration, recession, and normal growth periods in real-time. *Journal of Forecasting* 36(1), 26-42.
- Proaño, C.R. & Tarassow, A. 2018. Evaluating the predicting power of ordered probit models for multiple business cycle phases in the U.S. and Japan. *Journal of the Japanese and International Economies* 50, 60-71.
- Psimopoulos, A. 2020. Forecasting economic recessions using machine learning: An empirical study in six countries. *South-Eastern Europe Journal of Economics* 1, 39-99.
- Puglia, M., & Tucker, A. 2020. Machine learning, the treasury yield curve and recession forecasting. Finance and Economics Discussion Series 2020-038, Board of Governors of the Federal Reserve System (U.S.).
- Rabinowicz Assaf and Saharon Rosset (2020) Cross-Validation for Correlated Data. Forthcoming in *Journal of the American Statistical Association*, DOI: 10.1080/01621459.2020.1801451.
- Ramsay, J. O., & Silverman, B. W. 2002. *Applied Functional Data Analysis: Methods and Case Studies*. Springer.
- Rapach, D. E., Strauss, J. K., & Zhou, G. 2013. International stock return predictability: What is the role of the United States? *Journal of Finance* 68,1633–62.
- Rapach, D. & Zhou, G. 2013. Forecasting stock returns. In *Handbook of economic forecasting*, eds. G. Elliott and A. Timmermann, 328–83. Amsterdam, the Netherlands: Elsevier.
- Richardson, A., van Florenstein Mulder, T., & Vehbi, T. 2019. Nowcasting GDP using machine learning algorithms: A real-time assessment. Reserve Bank of New Zealand.
- Schreiber, S. & Soldatenkova, N. 2015. Anticipating business-cycle turning points in real time using density forecasts from a VAR. *Journal of Macroeconomics* 47, 166–187.
- Sichel, D.E. 1994. Inventories and the three phases of the business cycle. *Journal of Business and Economic Statistics* 12(3), 269–277.

- Sirignano, J., Sadhwani, A., & Giesecke, K. 2016. Deep learning for mortgage risk. Working Paper, University of Illinois, Urbana-Champaign.
- Sokolov-Mladenović, S., Milovančević, M., Mladenović, I., & Alizamir, M. 2016. Economic growth forecasting by artificial neural network with extreme learning machine based on trade, import and export parameters. *Computers in Human Behavior* 65, 43-45.
- Soybilgen, B. 2020. Identifying US business cycle regimes using dynamic factors and neural network models. *Journal of Forecasting* 39(5), 827-840.
- de Stefani, J., Caelen, O., Hattab, D., & Bontempi, G. 2017. Machine learning for multi-step ahead forecasting of volatility proxies. In MIDAS@ PKDD/ECML,17-28.
- Stock, J. H. & Watson, M. W. 1998. A comparison of linear and nonlinear univariate models for forecasting macroeconomic time series. NBER Working Paper 6607.
- Stock, J. H. & Watson, M. W. 2002. Macroeconomic forecasting using diffusion indexes. *Journal of Business and Economic Statistics* 20(2), 147-162.
- Suss, J. & Treitel, H. 2019. Predicting bank distress in the UK with machine learning. Bank of England Staff Working Paper No. 831.
- Tolo, E. 2020. Predicting systemic financial crises with recurrent neutral networks. *Journal of Financial Stability* 49, 100746.
- Ülke, V., Sahin, A., & Subasi, A. 2018. A comparison of time series and machine learning models for inflation forecasting: empirical evidence from the USA. *Neural Computing and Applications* 30(5), 1519-1527.
- Vapnik, V. 2013. *The Nature of Statistical Learning Theory*. Springer Science & Business Media.
- Wei, L. Y. 2016. A hybrid ANFIS model based on empirical mode decomposition for stock time series forecasting. *Applied Soft Computing* 42, 368-376.
- Welch, I. & Goyal, A. 2008. A comprehensive look at the empirical performance of equity premium prediction. *Review of Financial*

Studies 21,1455-508.

Yao, J., Li, Y., & Tan, C.L. 2000. Option price forecasting using neural networks. *Omega* 28, 455–66.

附件一 期初報告意見回覆

期初報告意見 修改與意見回覆 架構格式:依據本案需求書,請研究團隊 調整報告格式,架構須包含研究目的、研 究規劃、文獻回顧、研究方法、目前成果 等。

文獻探討:本案重點之一在於參考國內外 文獻,研擬運用人工智慧掌握景氣動向之 方法,惟本報告文獻回顧仍偏重以傳統計 量方法認定或預測轉折點,請再補充機器 學習方法應用於景氣動向之相關文獻。 (P3)

期中報告補充了機器學習方法應用 於景氣動向之相關文獻如下: Bolhuis and Rayner (2020); Puglia and Tucker (2020);Soybilgen (2020); Psimopoulos (2020)。另外, 蒐集了其它財經議題應用機器學習 方法的文獻: Harvey et al. (2016); Giglio and Xiu (2016); Kelly, Pruitt, Su Moritz and and (2019);Zimmermann (2016); Kozak, Nagel, Santosh (2020); Freyberger, and Neuhierl, and Weber (2020); Gu, Kelly, and Xiu (2020); Kelly, Pruitt, and Su (2019); Gu, Kelly, and Xiu (2019); Feng, Giglio, and Xiu (2020);

期初報告意見	修改與意見回覆
	Suss and Treitel (2019); Nik et al.(2016); Tolo (2020) °
臺灣景氣循環特徵: (1) 建議分別以各景氣循環擴張期、收縮期之工業生產指數各月平均做相位圖,以比較不同景氣狀態之相位圖變化。 (P7) (2) 由於我國第 15 次景氣循環尚未正式認定,請刪除圖 7 及相關內文敘述。 (P8、P10)	(1) 因為景氣數據非僅工業生產指數,用工業生產指數製作景氣循環週期相位圖,目的僅於輔助說明,持續探索意義不大。相關的審查意見,後續將予以考量。 (2) 期中報告已刪除。
研究方法: (1) 本案將景氣狀態分為擴張、收縮及轉折,且定義在擴張與收縮之間取 4-6 個月為轉折區,惟本會 2000 年後定義的收	的確。本案並不限定「擴張、收縮 及轉折」,三狀態會產生稀缺值, 因此預測狀況不好。期中報告尚未 完整解釋這個狀況,期末作法還是 會以二元為主。

- 縮期為 11-16 個月, 若採取三階段定義方 法,收縮期月份將會減少為7-12個月,由 於為不平衡資料 (unbalanced data),可 能影響分類效果,請說明如何處理此問 題。(P12)
- (2) 研究方法提及將由循環類神經網路 之長短記憶模式及自動化機器學習架構 為主,輔以 SVM 架構及基因演算法產生 最佳預測模式,請詳述使用之機器學習方

期中報告已經詳細說明研究方法。

期初報告意見 修改與意見回覆 法之理論及本案使用上述方法之流程。 (P13)(3) 關於研究方法提及以隨機森林法診 斷預測誤差的類型,作為樣本外預測校正 之用,請說明本案衡量預測誤差方式,及 如何以隨機森林法診斷預測誤差類型。 (P13) (4) 由於多數機器學習方法具有初始值 及調校參數問題,請說明本案使用之機器 學習方法初始值,以及如何調校參數。 實證資料部分: 期中報告已做修改。 (1) 期初報告主要以文獻回顧為主,未 描述欲採用之總體經濟變數之內容、來 源、頻率及是否經季節調整,請於期中報 告補充採用之變數及相關內容。 (2) 由於總體經濟變數間具有共線性, 且不同變數具有相異的領先、同時、落後 特性,請說明如何進行變數篩選及處理變 數的領先、同時、落後特性。 有關文字誤植、漏字、標點符號: (1) 期中報告已增補。

- (1) 請補充第6頁 Ramsay and Silverman (2) 已於期中報告修改。 (2002) 之參考文獻。
- - (3) 期中報告已刪除。

期初報告意見	修改與意見回覆
(2) 第8頁第7行「同心圓是」,請修 改為「同心圓式」。	
(3) 請確認第11頁第7行「因為整個系統為之優化」是否正確。	

附件二 期中報告意見回覆

期中報告意見

(一)國立清華大學楊教授睿中

- 機器學習方法較難處理時間序列問題,且較無理論支持,惟目前各領域應用仍多。
- 2. 貴團隊的研究包含交叉驗證 (Cross-Validation)方法, Rabinowicz and Rosset (2020 Cross-Validation for Correlated Data. Journal of the American Statistical Association, forthcoming)指出, 若訓練集和驗證集之間有相關性,則估計 結果會有誤差,該篇論文提供一種修正方 法,建議研究團隊參考。

(二)輔仁大學廖教授仁哲

- 1. 有關景氣循環的認定或預測,提供兩篇中央銀行論文參考,分別為「即時認定台灣的景氣轉折」、「認定與預測台灣股市熊市」。前者的目標為即時預測景氣轉折,可參考其文獻及選取變數;後者使用三元羅吉斯迴歸模型,預測台灣股市牛市與熊市,與景氣循環具有關聯性。
- 目前經濟預測在學術及實務的發展趨勢為使用大量變數,建議除了現有的17

修改與意見回覆

- 1. 謝謝楊教授評論指教。
- 2. 謝謝楊教授指教推薦此文,已增加 Rabinowicz and Rosset (2020)的討論,但他們所提出的 CV 修正方法,尚需時間研究要如何做,超過本案執行能力。本案為求簡便,Rabinowicz and Rosset (2020)所指出者,算是模型不確定 (model uncertaint)之類的問題,故我們最後就 2016-2019所公布資料的預測,是採用簡單平均,計算前 50 個模型的forecasting average。
- 1. 近期我國中央銀行亦進行一些內部相關研究,並出版於中央銀行季刊(如徐婉容,2020)或是於研討會公開發表(如吳俊毅與朱浩榜,2019),亦已遵示納入。
- 2. 依照國發會提供的數據有 129 個解釋變數,本案最後依照時間長度 1981/1-2019/12 取用 68 個。

期中報告意見

個變數之外,可增加如商品、勞動、金融 等部門變數,使用維度縮減法或主成份分 析法降低維度後,進一步進行預測,可能 使機器學習方法預測效果較好。

- 3. 目前預測景氣衰退之文獻採用的變數 包含股價或股價指數、殖利率曲線、短中 長利率、利率差、家戶貸款、家戶債務、 銀行消費貸款、銀行放款等,建議可納入 變數考量。
- 4. 期中報告可考慮其他經濟預測採用之 變數轉換方法,如取log、差分、標準化等。
- 5. 請補充說明廣義線性模型使用probit 或logit 模型,文獻上預測景氣衰退多使用 probit模型,惟若擴展到多元變數預測時, logit 模型計算較為方便。
- 6. 研究方法包含利用拔靴法(bootstrap) 增強之廣義線性模型,請考量拔靴法是否 能應用在時間序列資料,並維持時間相關 性。
- 7. 目前預測績效的評估以熱力圖呈現,建 議以預測績效之量化數據呈現,並加以排 序。
- 8. 建議在訓練過程中,從30 個不同組合 選出最佳組合,並以此組合做樣本外預 測,比較不同模型之樣本外預測績效,並

修改與意見回覆

- 3. 同上。
- 4. 本案所有變數不是水準值,都是依照對數季節 (12 個月) 差分計算的變動率。
- 5.我們直接採用 R 原生函數 glm,內 建二元連結函數是 logit。
- 6. bootstrapped glm 不適合於時間序列,故依委員建議,後續用新資料重做時將之刪除。
- 7. 已將多個模型預測結果,依照優 劣排序 (pp.85-92)。
- 8. 本案已如此進行並產生預測。就 比較而言,我們直接用 Lolli plot 繪 製排序比較圖,並呈現最佳 30 和最 劣 30。
- 9.因資料稀疏,故本案不考慮三元。 二元的編碼百分之一百完全由國發 會公布的專家意見,三元則非研究 團隊的工作。因為我們發現,這需 要大量原始數據去認定,而不是依 主觀判斷插入幾個月。
- 10. 在訓練過程中,我們採用 25 個 月一期並移動 4 次,預測總共 100

期中報告意見

以一張表格呈現。實務上可採用一個模型 做為基準,將預測績效的指標如正確性、 精確性等設定為1,計算其他模型相對於 基準模型的預測績效。

- 9. 若考量三元變數,可將收縮進一步分為 「嚴重收縮」及「相對不嚴重收縮」,以 提供國發會更進一步的訊息,惟可能有資 料稀疏性問題。
- 10. 由於文獻指出不同方法在短期、中長期預測表現可能不同,建議將預測期間分為短期預測及中長期預測,比較不同方法之預測績效。
- 11. 可將門檻值做為一個調校參數,實務 上可觀察資料為收縮期或擴張期的比 例,做為門檻值調整的依據。

(三) 經濟發展處:

- 1. 建議研究團隊擴展變數種類,並考量變數轉換、時間數列資料是否適合以拔靴法處理、績效評估是否以別種方式呈現、以及不同方法在不同預測時間的表現。
- 2. 本處曾提供生產、消費、所得、就業、 貿易、交易等部門相關指標計734 項,請 說明期中報告僅使用17 項之原因,其篩 選的準則為何?
- 3. 目前期中報告的重點在於模型預測績

修改與意見回覆

個月,估計期 289 個月。如此樣本 數是根據多次計算下的折衷,因為 樣本外太短,會容易出現全 1 或全 0,導致無法計算混淆矩陣。

11. 門檻值依照標準作法,也就是以 0.5 為分界,機率≥0.5 預測為 1,其 餘為 0。我們找不到任何依據調整這 個分界,調整這一項,影響的是某 一個狀態預測增加了,另一個就減 少 了 , 會 有 over-fitting by data-mining 的問題,且在多個移動 時段,產生大量難以比較的結果。 經過數日嘗試,最後還是採用 0.5 做 為分界。

1. 如廖委員指出,拔靴法的 glm 不適合於時間序列,依委員建議,後續用新資料重做時,將採用 glm 的拔靴法估計刪除。依照國發會提供的數據,經整理有129個解釋變數,本 案 最 後 依 照 時 間 長 度1981/1-2019/12 取用 68 個。績效評估已經採用 Lolli plot 繪製排序比較圖,並呈現最佳 30 和最劣 30 個模

期中報告意見

效之比較,尚未看到實際應用之內容,請 說明本案未來如何在景氣科業務上加以 應用,如預測未來3至6個月之景氣狀 態。

4. 由於部分預測方法須設定門檻值之後,始能預測景氣狀態為擴張期或收縮期,並以混淆矩陣及相關指標表示預測表現,請補充說明門檻值決定方式。

修改與意見回覆

型在不同預測時間的表現。

- 2.依照國發會提供的數據,經整理有129個解釋變數,本案最後依照時間長度 1981/1-2019/12 取用 68 個。
- 3. 1982/1~2016/2 估計訓練,預測 國 發 會 未 公 布 的 樣 本 外 2016/3-2019/12 (pp.93-95)。
- 4. 門檻值依照標準作法,也就是以 0.5 為分界,機率≥0.5 預測為 1,其 餘為 0。我們找不到任何依據調整這個分界,因為若調整這一項,影響 的是某一個狀態預測增加了,另一個就減少了,會有 over-fitting by data-mining 的問題,且在多個移動 時段,產生大量難以比較的結果。 經過數日嘗試,最後還是採用 0.5 做為分界。

附件三 期末報告意見回覆

期末報告意見

(一)輔仁大學廖教授仁哲

- 1. 本案原始變數為 129 個,後續依時間 長度取 64 個變數進行分析,惟其他如工 業生產指數可能為重要變數,若未放入模 型,可能影響預測效果,請研究團隊多加 考量。
- 2. 關於變數選擇部分,建議可使用廣義線性模型 (Generalized Linear Model, GLM)之 logit 模型或 AIC、BIC 準則選出解釋能力較好之變數,或使用主成份分析法 (Principal Components Analysis, PCA),以降低變數維度。
- 3. 由於二元變數預測之混淆矩陣 (confusion matrix)有多個指標可供參 考,建議研究團隊與國發會討論,哪些是 國發會重視之指標,如實際衰退且正確預 測衰退,或實際擴張且正確

預測擴張之比例。若為正確預測衰退較為重要,則建議使用敏感度(Sensitivity)、精確度(Precision)、PR曲線(Precision-Recall Curve)選擇模型。

修改與意見回覆

- 1. (本文變數採用 68 個,內文誤植 64 個變數,以致委員敘述有誤,特 此致歉) 68 個變數第一個 IPI_TWN 就是臺灣工業生產指數。也是時間 最長的 (1961/1~2019/12)。我們並 未忽略工業生產指數的重要性,沒 有納入的是起自 1988/1,10 個產業 的工業生產指數,因為有一個總指數應足以代表。
- 2. AIC/BIC 等方法,是統計上的作法,而非本案以機器學習為主的作法。本案原本就是採用兩個主成分PCA和一個獨立成份ICA方法降維(見pp.49-50)。對於降維考量,我們已經相對做到完整。
- 3. 本案在執行這個預測之前,皆已 通盤考量各種狀況。廖委員建議, 原就在本案考量之內,詳細說明請 見 pp.39-41。為避免委員閱讀不清 楚,我們在 pp.39-41 指標處,增加 數值範例,以利解說指標內涵。圖 4.1 (p.24),本案定義二元如下:{0=

期末報告意見

- 4. 本研究之文獻回顧相當完整,建議進一步彙整文獻,如探討何種方法在預測經濟成長率或衰退之效果較好、使用之降維方法、重要解釋變數等。
- 5. 由於時間序列資料具有相關性,使用 K-fold Cross-Validation 較不適合,可能產 生以時間較後資料,預測較前資料之不合 理結果。建議在訓練資料階段,採用最後 一段資料進行驗證,以避免交叉驗證之不 合理情形。
- 6. 第 16 頁倒數第 3 行「交叉驗證」誤植 為「交叉驗證」,再請研究團隊修改。

修改與意見回覆

衰退,1=擴張},內建的
positive=0,也就是衰退。本案
採用的四個指標,accuracy是針
對{0,1}預測力,precision是針
對衰退精確度,kappa是考量扣
除機率符合率的觀察符合率,也
就是校正過 Sensitivity/recall 的方
法。F1 則是同時考量

Sensitivity/recall 的綜合指標。

- 4. 已經將文獻列表於附錄 A (pp.105-111)。
- 5.本文是訓練期用 K-Fold,預測 期通通都設為未來 24 個月。也 就是委員所說的最後一段。整體 訓練採用 Rolling forward,所以 預測永遠是最後一段。
- 6.全數修正,謝謝指正。

(二)國立清華大學楊教授睿中

- 1. 第 25 頁說明本研究使用 K-fold 交叉 驗證架構,惟後續呈現 NTS (Nested Time Series)交叉驗證圖形,請研究團隊確認交 叉驗證之架構。
- 2. 文獻回顧部分模型名詞不一致,請再檢
- 1. 我們的交叉驗證作法如圖 4.5: 藍色的 training 期依照 K-fold 交叉驗證,預測採向前 rolling 一段 (24個月)。這樣設計雖不 是最好,但也是為了避免前述廖 委員提出的問題。
- 2. 全數修正,謝謝指正。

期末報告意見

視並修改相關內容,以方便讀者閱讀。

3. 第 4 頁描述工業生產指數相位圖不能 代表整個經濟活動,但指出臺灣近年景氣 循環不確定越來越高,用統計術語就是型 態不確定增加,惟較無法理解相位圖與型 態不確定增加之關係,建議研究團隊補充 說明。

修改與意見回覆

(三) 經濟發展處:

- 1. 本研究使用人工智慧方法,具有資料驅動(data driven)之特色,目前研究資料至 2019年12月,惟本處會更新至最新數據進行應用,請說明模型結果或穩定性是否可能受到影響。
- 2. 本研究目標為運用人工智慧方法,即時 且準確捕捉景氣狀態,請增加結論與建 議,補充運用人工智慧方法於景氣預測的 整體成效,目前仍待需克服之困難與研究 限制,以及建議未來可能之研究方向。
- 3. 由於各模型預測擴張期、收縮期之結果 可能不為連續狀態,請補充說明如何運用

- 資料更新造成的問題,沒有模型可以保證穩定性。
- 2. 已於結論 (pp.99-100) 詳細說明。單一模型都無法完勝,未來用機器學習和人工智慧產生綜合預測平均 (forecasting average),方是一個正確的道路。本案也依此去完成。機器學習或人工智慧的模式,能夠提供遠多於計量方法的模型,也正是因為這種大家族特性,讓我們可以善用大量的模型。
- 3. 最佳作法就是以平均方式綜合 (forecasting average) 多個模型的預

期末報告意見

最佳模型組合預測轉折點。

- 4. 部分模型在不同滾動時段的預測表現兩極,如預測績效最好的模型(使用原始資料、分類決策樹、落後期為6期)在t=4的正確性為100%,但在t=1的正確性為3.8%,反而成為預測績效最差的模型。由於未來模型將在新的時段使用,請說明如何運用本研究之預測模型。
- 請補充說明如何選出預測表現最佳的
 個模型,以進行後續轉折點之預測, 另是否有固定的模型組合可供後續應用。
- 6. 研究方法說明採用 4 個滾動時段進行估計,故有 t1-t4 之模型組合,惟在深度學習預測表現最優及最差 30 個模型中,出現 t5-t7 之模型組合,請說明研究方法與預測結果之差異原因。

修改與意見回覆

測結果,已於內文 (pp.93-95) 提列 預測結果,加強說明。

- 4. 機器學習方法會因資料段屬性不同而有差異。由於不同資料段代表不同景氣,擴張期和收縮期的資料性質自然會不同。就機器學習的角度,大量模型產生的結果,自當予以綜合平均 (forecasting average)。
- 5. 已於內文 (pp.93-95) 提列預測 結果,加強說明。這 50 個最佳模型 是依據四個準則排序,例如依 accuracy 排序前 50 名。然後依據這 4 個前 50 名的平均,再平均。
- 6. 深度學習 LSTM 因為要求訓練期的樣本和測試期樣本皆能整除Cache size,因此樣本數略小於前述模式。採用估計 230個月,測試 23個月。其餘皆採用估計 299個月,測試 25個月。

運用人工智慧掌握景氣動態 結案簡報

研究團隊

主持人 何宗武 協同主持人 葉國俊 張淑華 林雅淇

一. 期末建議修改清單 1/3

(一)輔仁大學廖教授仁哲	回覆與處理
1. 本案原始變數為129個,後續依時間長度取64個變數進行分析, 惟其他如工業生產指數可能為重要變數,若未放入模型,可能影 響預測效果,請研究團隊多加考量。	1.68個變數第一個IPI_TWN就是臺灣工業生產指數。也是時間最長的 (1961/1~2019/12)。我們並未忽略工業生產指數的重要性,沒有納入的是起自 1988/1,10個產業的工業生產指數,因為有一個總指數應足以代表。
2. 關於變數選擇部分,建議可使用廣義線性模型(Generalized Linear Model, GLM)之logit 模型或AIC、BIC 準則選出解釋能力較好之變數,或使用主成份分析法(Principal Components Analysis, PCA),以降低變數維度。	2. AIC/BIC等方法,是統計上的作法,而非本案以機器學習為主的作法。本案原本就是採用兩個主成分PCA和一個獨立成份ICA方法降維 (見pp.49-50)。對於降維考量,我們已經相對做到完整。
3. 由於二元變數預測之混淆矩陣(confusion matrix)有多個指標可供參考,建議研究團隊與國發會討論,哪些是國發會重視之指標,如實際衰退且正確預測衰退,或實際擴張且正確預測擴張之比例。若為正確預測衰退較為重要,則建議使用敏感度(Sensitivity)、精確度(Precision)、PR 曲線(Precision-Recall Curve)選擇模型。	3. 本案在執行這個預測之前,皆已通盤考量各種狀況。廖委員建議,原就在本案考量之內,詳細說明請見pp.39-41。為避免委員閱讀不清楚,我們在pp.39-41指標處,增加數值範例,以利解說指標內涵。圖4.1 (p.24),本案定義二元如下:{0=衰退,1=擴張},內建的positive=0,也就是衰退。本案採用的四個指標,accuracy是針對{0,1}預測力,precision是針對衰退精確度,kappa是考量扣除機率符合率的觀察符合率,也就是校正過Sensitivity/recall的方法。F1則是同時考量Sensitivity/recall的綜合指標。
4. 本研究之文獻回顧相當完整,建議進一步彙整文獻,如探討何種方法在預測經濟成長率或衰退之效果較好、使用之降維方法、重要解釋變數等。	4. 已經將文獻列表於附錄A (pp.105-111)。
5. 由於時間序列資料具有相關性,使用K-fold Cross-Validation 較不適合,可能產生以時間較後資料,預測較前資料之不合理結果。 建議在訓練資料階段,採用最後一段資料進行驗證,以避免交叉 驗證之不合理情形。	5. 本文是訓練期用K-Fold,預測期通通都設為未來24個月。也就是委員所說的最後一段。整體訓練採用Rolling forward,所以預測永遠是最後一段。
6. 第16 頁倒數第3 行「交叉驗證」誤植為「交叉驗證」,再請研究團隊修改。	6.已全數修正,謝謝指正。

一. 期末建議修改清單 2/3

(二)清華大學楊教授睿中

- 1.第25 頁說明本研究使用K-fold 交叉驗證架構,惟後續呈現NTS(Nested Time Series)交叉驗證圖形,請研究團隊確認交叉驗證之架構。
- 文獻回顧部分模型名詞不一致,請再檢視並修改相關內容,以方便讀者閱讀。
- 3. 第4 頁描述工業生產指數相位圖不能代表整個經濟活動,但指出臺灣 近年景氣循環不確定越來越高,用統計術語就是型態不確定增加,惟較 無法理解相位圖與型態不確定增加之關係,建議研究團隊補充說明。

回覆與處理

- 1. 我們的交叉驗證作法如圖4.5:藍色的training期依照K-fold交叉驗證,預測採向前rolling一段 (24個月)。這樣設計雖不是最好,但也是為了避免前述廖委員提出的問題。
- 2. 已全數修正,謝謝指正。
- 3. 相位圖指出每一個週期的經濟週期內容,我們利用相位圖說明最近4個循環的型態變化甚大,而且一個擴張期和收縮期的月份也有所改變。例如,暑假的消費擴張效果,最近一次循環就消失。這的確不算完整證據,只是工業生產的特徵轉變,我們只是用工業生產指數加以陳述。避免誤會,已修改文字為「景氣循環的工業生產不確定」,如p.4所示。

一. 期末建議修改清單 3/3

(三)經濟發展處

- 1. 本研究使用人工智慧方法,具有資料驅動(data driven)之特色,目前研究資料至2019 年12 月,惟本處會更新至最新數據進行應用,請說明模型結果或穩定性是否可能受到影響。
- 2. 本研究目標為運用人工智慧方法,即時且準確捕捉景氣狀態,請增加 結論與建議,補充運用人工智慧方法於景氣預測的整體成效,目前仍待 需克服之困難與研究限制,以及建議未來可能之研究方向。
- 3. 由於各模型預測擴張期、收縮期之結果可能不為連續狀態,請補充說 明如何運用最佳模型組合預測轉折點。
- 4. 部分模型在不同滾動時段的預測表現兩極,如預測績效最好的模型 (使用原始資料、分類決策樹、落後期為6期)在t=4的正確性為100%, 但在t=1的正確性為3.8%,反而成為預測績效最差的模型。由於未來模 型將在新的時段使用,請說明如何運用本研究之預測模型。
- 5. 請補充說明如何選出預測表現最佳的50 個模型,以進行後續轉折點之預測,另是否有固定的模型組合可供後續應用。
- 6. 研究方法說明採用4 個滾動時段進行估計,故有t1-t4 之模型組合,惟在深度學習預測表現最優及最差30 個模型中,出現t5-t7 之模型組合,請說明研究方法與預測結果之差異原因。

回覆與處理

- 1. 資料更新造成的問題,沒有模型可以保證穩定性。因此,為了處理模型不確定性問題,最後預測採用預測平均方法forecasting average。機器學習可產生大量預測結果,預測平均相當可行。
- 2. 已於結論 (pp.99-100) 詳細說明。單一模型都無法完勝,未來用機器學習和人工智慧產生綜合預測平均 (forecasting average),是一個正確的道路。本案也依此去完成。機器學習或人工智慧的模式,能夠提供遠多於傳統方法的模型,也正是因為這種大家族特性,讓我們可以善用大量的模型於預測。
- 3. 最佳作法就是以平均方式綜合(forecasting average) 多個模型的預測結果,已於內文 (pp.93-95) 提列預測結果,加強說明。
- 4. 機器學習方法會因資料段屬性不同而有差異。由於不同資料段代表不同景氣,擴張期和收縮期的資料性質自然會不同。就機器學習的角度,大量模型產生的結果,自當予以綜合平均 (forecasting average)。
- 5. 已於內文 (pp.93-95) 提列預測結果,加強說明。這50個最佳模型是依據四個準則排序,例如依accuracy排序前50名。然後依據這4個前50名的平均,再平均。
- 6. 深度學習LSTM因為要求訓練期的樣本和測試期樣本皆能整除Cache size,因此樣本數略小於前述模式。採用估計 230個月,測試23個月。 其餘皆採用估計 299個月,測試25個月。

二. 結論摘要

- 1. 本案主旨為大數據機器學習,機器學習方法論的重點在從預測中學習(learning by doing prediction),也就是所謂 data-driven。基於此,我們旨在提出一個「訓練」景氣循環「預測」的大規模資料結構。我們採用68筆變數,從1982/1 到 2019/12,與兩組機器學習模型:
 - A. 組1: GLM, SVM, TREE, RF。
 - B. 組2: H2O.ai 的autoML和RNN-LSTM。

2. 本案對於採納人工智慧方法對時間序列預測的建議:

- A. 任何單一模型皆會面臨未來資料性質不確定帶來的預測問題,因此,人工智能或機器學習等模型也不例外。但是, data-driven 的機器學習有大量模型可以訓練出大量預測,因此,採用 Forecasting Average 整合結果可提高預測正確性。
- B. LSTM學習過程細複雜,因此演算耗時且表現也沒有比較好,人工智慧平台H2O.ai 提供的開源程式 autoM 有深度學習的項目,而且是將五個進階模型做預測平均組合。相當符合我們做的方式,建議未來可以直接採用。
- **3.** 未來研究建議:採用 Rabinowicz and Rosset(2020) 的Corrected CV 更精確掌握模型篩選,提升 forecasting average 的表現。

三. 變數說明

被解釋變數 y =依照國發會公布的擴張與收縮狀態期間,編制的二元變數。重疊月份歸為前狀態。1961/1~2016/2(第14次循環)

4	A	8	C	G	Н	- 1	J	K	L	М	N	0	P	Q	R	S	T	U	٧	W	Х	Υ
1	Date	國發會	transition01	PI_TWN	LD_OECD	LD_G7	LD_NAFT/1	D_US	COIND_US	LAGD_US I	OZUGTV	TWN_UnerT	WN_labo C	1	Export_NT E	aport_US I	mport_NT	Import_US/L	D_TWN	LD_TWN_	LAGD_TW	MS_TW
251	1981/10/1	收缩	0	21.09	99,2477	98.8902	98.4	57.2	60.7	58.7	37.865	1,73	0.16	58.12	73776	1952.3	62685	1654,4				
252	1981/11/1	收缩	0	20.28	99.1124	98,7437	98.1	57.1	60.5	58.6	37.78	1.55	-0.5	57.73	69407	1836.2	63421	1673.4				
253	1981/12/1	收缩	0	24.14	98,9731	98,6034	97.8	56.9	60.2	58.4	37.84	1,32	0.85	57,65	72199	1913.1	60800	1606.8				
254	1982/1/1	收缩	0	18.62	98.8189	98.4615	97.4	563	59.9	58.5	37.712	1.36	-0.56	58.02	65561	1734.9	55785	1472.3	17.27	100	18,03	466
255	1982/2/1	收缩	0	19,77	98.6322	98,308	97.1	56.6	60.2	58.2	37.912	1.62	-0.56	57.84	57990	1538.2	58836	1556.5	17.35	99.58	18,44	4510
56	1982/3/1	收缩	0	21.97	98,4313	98.15	96.7	56.3	60.1	57.9	38,097	1.32	0.73	57.99	70614	1863.7	61808	1627	17.41	99.08	18,79	437
57	1982/4/1	收缩	0	21.13	98.2381	98.0072	96.4	56.3	60	58.1	38.337	1,49	0.01	58.14	71813	1890.8	69314	1820.2	17.42	98.3	19.04	431
58	1982/5/1	收縮	0	21.55	98,0717	97,8961	96.2	56.1	60	58	38,756	1.98	-0.87	58,49	76035	1986.8	68585	1787.5	17,39	97,33	19,17	435
59	1982/6/1	收縮	0	21.09	97,943	97.8284	96.1	55.6	59.8	58.1	39,092	1.95	0.02	58,61	72635	1880.3	56784	1466.1	17.35	96.28	19.18	445
160	1982/7/1	收缩	0	21.55	97.87	97.8116	96.1	55.7	59.5	58	39,429	2.21	0.67	58.58	78692	2012.6	63966	1631.8	17.31	95.21	19,05	461
61	1982/8/1	收縮	0	20,77	97.8722	97.8531	96.2	55.4	59,4	57.8	39,799	2.65	-0.14	60.35	78724	1997.6	66667	1687.3	17.29	94,32	18.84	466
62	1982/9/1	收納	0	21.22	97,959	97,9625	96.5	55.8	59.3	57.7	39.85	2.68	-0.43	59,79	72260	1819.7	54195	1361.3	17.33	93,73	18.57	468
		收納	0	20.86	98,1243	98.1364	96.8	56.1	59	57.4	39,963	2,77	-0.7	59.31	69283	1742.5	59286	1487.4	17,46	93,59	18.32	475
	1982/11/1	收縮	0	20.56	98,3517	98,3713	97.2	56.2	59	56.9	40,479	2,71	-0.02	58.83	71172	1784.2	53871	1347,1	17.71	94.1	18.11	477
	1982/12/1	收納	0	23,33	98.6287	98,6602	97,7	56.6	59	56.4	40,062	2,79	0.28	59,05	83070	2045.6	68313	1678	18.09	95,29	17.96	482
166	1983/1/1	收缩	0	22,45	98,9357	98,9854	983	57.7	59,3	56.1	39,88	2,73	1,12	59,07	66634	1670.9	58884	1472.8	18.58	97,06	17.84	501
67	1983/2/1	收缩	0	17.99	99,2431	99,3182	98.8	58.3	59,1	56.1	39,877	3,45	-0.45	59,66	62684	1574.2	48050	1203.7	19.13	99,04	17,78	544
68	1983/3/1	模型	1	22.99	99,5504	99,6571	99.4	59.1	59,4	56	39,955	2.91	-0.11	59.91	71376	1791.1	74211	1857,6	19.68	101	17,79	519
269	1983/4/1	機能	-	22.83	99.8436	99,989	99.9	59.6	59.6	56	39,992	2.61	0.08	60.17	83607	2091.7	57781	1442	20.23	102.91	17.9	518
270	1983/5/1	接張	1	23.87	100.115	100,301	100.3	60.4	59.9	55.8	39,975	2.42	0.99	59.76	85963	2152.8	70614	1764	20.68	104.33	18.12	528
	1983/6/1	機製	1	24,38	100.113	100,579	100.7	61.2	60.3	56	40.131	2,51	1.1	60.2	88820	2222.2	56321	1405.6	20.98	104.92	18.43	538
271	1983/7/1	機能	1	21.20	100.568	100.813	101.1	61.8	60.8	56.1	40.04	2.88	6.81	59.53	93151	2323	72449	1802.2	21.11	104.66	18,78	558
	1983/8/1	類X 模裝	1	25,07	100,746	101,005	101.4	62.1	60.6	56.5	40,186	2.91	-3.17	59.5	96422	2406.9	76339	1900.9	21.08	103.63	19,11	553
73							101.6		61.4				-0.88	59.68				1494.9				
74	1983/9/1	描號	1	24.48	100.898	101.156		62.9		56.5	40.167	2.7			86841	2164.5	60126		21.14	103.03	19.44	561
	1983/10/1	接股	1	24.46	101.027	101.268	101.8	63.7	61.9	56.5	40.147	2.79	0.65	59.66	85896	2141	76503	1902.1	21.3	102.96	19.79	562
	1983/11/1	描版	1	24,68	101.128	101.341	101.9	64	62.2	56.8	40.208	2.34	1.05	59.16	94734	2361.3	80317	1996.9	21.51	103.13	20.18	563
	1983/12/1	機能	1	26.19	101.195	101.366	102	61.7	67.5	57.1	40.224	2.27	1.33	58.35	92662	2307.3	83455	2072.9	21.75	103.45	20.61	575
278	1984/1/1	横張	1	27.24	101.217	101.337	102	65.6	63	57.2	40.203	2.34	0.25	58.39	94912	2361.6	64863	1609.9	22.03	103.97	21.06	614
279	1984/2/1	横張	1	21.51	101.186	101.258	102	66.2	63.4	57.8	40.184	2.75	-0.43	58.98	76518	1906.7	67406	1675.5	22.35	104.66	21.51	627
180		機能	1	26.84	101.107	101.136	101.8	66.3	63.5	58.1	40,024	2.09	0.54	59.14	99197	2475.6	71338	1775.9	22.63	105.18	21.9	601
281	1984/4/1	模製	1	26.12	101	100.98	101.6	66.6	63.9	58.6	39,735	2.01	0.83	59.25	103590	2603.4	72571	1819,3	22.81	105.24	22.21	596
82	1984/5/1	横張	1	27.95	100.877	100,809	101.4	67.1	64.1	59.1	39,669	2.11	1.13	59.97	114161	2885.8	80329	2025.5	22.85	104.66	22.A7	603
88	1984/6/1	收縮	0	27.11	100.74	100,63	101.2	67.3	61.5	59.4	39.784	2.23	0.7	59,92	107750	2710.7	71184	1786.3	22.76	103.5	22.75	616
84	1984/7/1	收缩	0	28.21	100.612	100.47	101	67.5	64.6	59.9	39,424	2,52	2,45	59.76	115712	2926.5	81595	2058,4	22.6	102,04	23.05	625
85	1984/8/1	收缩	0	27.94	100.497	100,329	100.7	67.5	65	60.3	39,043	3.02	0.06	59.98	108612	2778.5	80274	2048,3	22.42	100.53	23.37	625
286	1984/9/1	收缩	0	25.53	100,392	100,208	100.6	67.5	65.2	60.6	39,1	3.03	0.78	60.18	94584	2425.2	62340	1594.4	22.28	99.2	23.72	632
287	1984/10/1	收納	0	25.87	100.302	100.111	100.4	67.7	65.2	60.9	39.173	2.77	-0.04	59.94	103966	2659.7	74304	1896	22.21	98.23	24.07	627

循環次序	谷底	高峰	谷底	擴張期	收縮期	全循環
第1循環	1954.11	1955.11	1956.09	12	10	22
第2循環	1956.09	1964.09	1966.01	96	16	112
第3循環	1966.01	1968.08	1969.1	31	14	45
第4循環	1969.1	1974.02	1975.02	52	12	64
第5循環	1975.02	1980.01	1983.02	59	37	96
第6循環	1983.02	1984.05	1985.08	15	15	30
第7循環	1985.08	1989.05	1990.08	45	15	60
第8循環	1990.08	1995.02	1996.03	54	13	67
第9循環	1996.03	1997.12	1998.12	21	12	33
第10循環	1998.12	2000.09	2001.09	21	12	33
第11循環	2001.09	2004.03	2005.02	30	11	41
第12循環	2005.02	2008.03	2009.02	37	11	48
第13循環	2009.02	2011.02	2012.01	24	11	35
第14循環	2012.01	2014.1	2016.02	33	16	49
平均				38	15	53

Tölö Eero (2020) Predicting systemic financial crises with recurrent neural networks. Journal of Financial Stability, Forthcoming.

依時間長短,取出1982/1-2019/122 的68個 input variables(out of 129)

- 1. IPI TWN:臺灣工業生產指數。1961/1~2019/12
- 2. LD OECD: OECD領先指數。1961/1~2019/12
- 3. LD G7:G7領先指數。1961/1~2019/12
- 4. LD NAFTA: NAFTA領先指數。1961/1~2019/12
- 5. LD US: 美國領先指數。1961/1~2019/12
- 6. COIND US: 美國同時指數。1961/1~2019/12
- 7. LAGD US: 美國落後指數。1961/1~2019/12
- 8. NTDUSD:台幣兌美元匯率。1961/1~2019/12
- 9. M1A:臺灣貨幣供給額(百萬新臺幣)。1961/7~2019/12
- 10. M1B:臺灣貨幣供給額(百萬新臺幣)。1961/7~2019/12
- 11. M2:臺灣貨幣供給額(百萬新臺幣)。1961/7~2019/12
- 12. quasiM NTD: 準貨幣(百萬新臺幣)。1961/7~2019/12
- 13. quasiM USD: 準貨幣,外幣(百萬新臺幣)。1961/7~2019/12
- 14. quasiM postal: 準貨幣, 郵政儲蓄系統(百萬新臺幣)。1961/7~2019/12
- 15. Deposit money: 存款貨幣(百萬新臺幣)。1961/7~2019/12

- 16. reserve money: 儲備貨幣(百萬新臺幣)。1961/7~2019/12
- 17. deposit FI: 存款(貨幣金融機構)(百萬新臺幣)。1961/7~2019/12
- 18. deposit demand MF1: 存款(貨幣金融機構),企業和個人:活期存款(百萬新臺幣)。1961/7~2019/12
- 19. deposit time MF1: 存款(貨幣金融機構),企業和個人:定期儲蓄存款(百萬新臺幣)。1961/7~2019/12
- 20. deposit FX MF1: 存款(貨幣金融機構),企業和個人:外幣存款(百萬新臺幣)。1961/7~2019/12
- 21. deposit_postal_MF:存款(貨幣金融機構),郵政儲蓄存款(百萬新臺幣)。1961/7~2019/12
- 22. deposit government MF: 存款,政府存款(百萬新臺幣)。1961/7~2019/12
- 23. ACRS:有擔保的融通利率%。1961/7~2019/12
- 24. Loan INV 1:貸款和投資,貨幣金融機構(百萬新臺幣)。1961/7~2019/12
- 25. Loan INV 2:貸款和投資,貸款(百萬新臺幣)。1961/7~2019/12
- 26. Loan INV 3:貸款和投資,組合投資(百萬新臺幣)。1961/7~2019/12
- 27. Loan INV 4:貸款和投資,政府(百萬新臺幣)。1961/7~2019/12
- 28. Loan_INV_5:貸款和投資,國有企業(百萬新臺幣)。1961/7~2019/12
- 29. Loan INV 6:貸款和投資,私營領域(百萬新臺幣)。1961/7~2019/12
- 30. TWII:臺灣加權股價指數。1968/1~2019/12
- 31. TWII_trans:股票成交金額(上市,百萬)。1968/1~2019/12
- 32. ForeignReserves:外匯準備(百萬美元)。1969/3~2019/12
- 33. credit1:借項總金額:支票帳戶。1972/1~2019/12
- 34. credit2:借項總金額:活期存款。1972/1~2019/12
- 35. credit3: 年周轉率: 支票帳戶。1972/1~2019/12

- 36. credit4: 年周轉率:活期存款。1972/1~2019/12
- 37. credit5: 金融機構:貸款及貼現。1972/1~2019/12
- 38. credit6: 金融機構:貸款及貼現:政府機關。1972/1~2019/12
- 39. credit7: 金融機構:貸款及貼現:政府企業。1972/1~2019/12
- 40. credit8:金融機構:貸款及貼現:私營領域。1972/1~2019/12
- 41. credit9: 貨幣金融機構:貸款與貼現 (LD)。1972/1~2019/12
- 42. credit10:貨幣金融機構:企業與個人(EI)存款。1972/1~2019/12
- 43. credit11:信用合作社:貸款及貼現。1972/1~2019/12
- 44. credit12:中華郵政股份有限公司:貸款。1972/1~2019/12
- 45. credit13:人壽保險公司:貸款。1972/1~2019/12
- 46. credit14:同業銀行短期貸款業務。1973/10~2019/12
- 47. credit15:銀行承兌:發行量。1975/3~2019/12
- 48. credit16:銀行承兌:未償。1975/3~2019/12
- 49. credit17:銀行承兑:贖回物。1975/7~2019/12
- 50. credit18:商業票據:發行量。1976/5~2019/12
- 51. credit19:商業票據:未償。1976/5~2019/12
- 52. credit20:商業票據:贖回物。1977/3~2019/12
- 53. TWN Unemp:臺灣失業率。1978/1~2019/12
- 54. credit21:借項總金額:活期儲蓄存款。1980/1~2019/12
- 55. credit22: 年周轉率(次),活期儲蓄存款。1980/1~2019/12

- 56. TWN labourNetTurnover:臺灣淨勞動周轉率。1980/1~2019/12
- 57. CPI:臺灣消費者物價指數。1981/1~2019/12
- 58. Export NTD million:臺灣出口(以台幣計價)。1981/1~2019/12
- 59. Export_USD_million:臺灣出口(以美元計價)。1981/1~2019/12
- 60. Import NTD million:臺灣進口(以台幣計價)。1981/1~2019/12
- 61. Import USD million:臺灣進口(以美元計價)。1981/1~2019/12
- 62. LD TWN:臺灣領先指數。1982/1~2019/12
- 63. LD_TWN_detrend:臺灣領先指數(去除趨勢)。1982/1~2019/12
- 64. LAGD TWN:臺灣落後指數。1982/1~2019/12
- 65. Tax98: 營業稅,12個月移動平均 (NDC_data_SW.xlsx, tax),1982/1~2019/12
- 66. Tax98:娛樂稅稅收(NDC data SW.xlsx, tax) , 1982/1~2019/12
- 67. Tax98: 貨物稅(NDC data SW.xlsx, tax), 1982/1~2019/12
- 68. C112: 製造業營業氣候測驗點(NDC_data_SW.xlsx, confidence), 1982/1~2019/12
- 69. T94: 鐵路貨運量(噸公里) (NDC data SW.xlsx, traffic), 1985/1~2019/12
- 70. T95: 台鐵貨運收入(NDC data SW.xlsx, traffic), 1985/1~2019/12
- 71. credit23: 可轉讓定期存單:發行量。1985/10~2019/12
- 72. credit24: 可轉讓定期存單:贖回物。1985/10~2019/12
- 73. credit25:可轉讓定期存單:未償。1985/10~2019/12
- 74. credit26:存款:所有銀行:共計。1987/5~2019/12
- 75. credit27:存款:所有銀行:企業和個人(EI)。1987/5~2019/12

- 76. credit32:OBU:發放給非金融機構的貸款:居民。1987/5~2019/12
- 77. credit28:存款:所有銀行:政府。1987/5~2019/12
- 78. credit29: 國內銀行:已發行的銀行債券。1987/5~2019/12
- 79. credit30:外幣貸款:國內銀行(包括中間業務銀行)。1987/5~2019/12
- 80. credit31:外幣貸款:共計。1987/5~2019/12
- 81. credit33: OBU: 發放給非金融機構的貸款:非居民。1987/5~2019/12
- 82. credit34:外幣貸款:外資銀行本地分行(LBFB)。1987/12~2019/12
- 83. credit35:空頭支票比:包括已取消的:值。1987/12~2019/12
- 84. EM14: 非農業部門就業人數-公共行政及國防強制性社會安全。(NDC_data_SW.xlsx, labor) 1988/1~2019/12
- 85. credit36:空頭支票:包括已取消的:值。1988/7~2019/12
- 86. credit37: 消費者貸款:未償:國內銀行、外資銀行、中型商業銀行(DB)。1988/7~2019/12
- 87. credit38: 消費者貸款:未償:DB:房屋購買。1988/7~2019/12
- 88. credit39: 消費者貸款:未償:DB:房屋修理。1988/7~2019/12
- 89. credit40: 消費者貸款:未償:DB:汽車貸款。1988/7~2019/12
- 90. credit41:消費者貸款:未償:DB:員工福利貸款。1988/7~2019/12
- 91. credit42: 消費者貸款:未償:DB:其他消費貸款。1988/7~2019/12
- 92. credit43: 建築貸款:未償:國內銀行、外資銀行、中型商業銀行。1988/7~2019/12
- 93. IP22: 工業生產指數-飲料製造業(NDC data SW.xlsx, prod), 1988/1~2019/12
- 94. IP23: 工業生產指數-菸草製造業(NDC data SW.xlsx, prod), 1988/1~2019/12
- 95. IP24: 工業生產指數-紡織業(NDC_data_SW.xlsx, prod), 1988/1~2019/12

- 96. IP25: 工業生產指數-成衣及服飾品製造業(NDC data SW.xlsx, prod), 1988/1~2019/12
- 97. IP26: 工業生產指數-木竹製品製造業(NDC data SW.xlsx, prod), 1988/1~2019/12
- 98. IP27: 工業生產指數-非金屬礦物製品製造業(NDC data SW.xlsx, prod), 1988/1~2019/12
- 99. IP28:工業生產指數-家具製造業(NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 100.IP29: 工業生產指數-其他製造業(NDC data SW.xlsx, prod), 1988/1~2019/12
- 101.IP30:工業生產指數-電力及燃氣供應業(NDC data SW.xlsx, prod), 1988/1~2019/12
- 102.IP31:工業生產指數-用水供應業(NDC_data_SW.xlsx, prod), 1988/1~2019/12
- 103.Price23: 不含新鮮蔬果及能源(核心物價) (NDC data SW.xlsx, price), 1982/1~2019/12
- 104.Price24: 躉售物價指數(NDC data SW.xlsx, price), 1982/1~2019/12
- 105.Price25: 進口物價指數(用台幣計價) (NDC data SW.xlsx, price), 1982/1~2019/12
- 106.Price26: 出口物價指數(用台幣計價) (NDC data SW.xlsx, price), 1982/1~2019/12
- 107.risk1:政策利率:月結:貼現率。1961/7~2019/12
- 108.risk2:基準貸款利率:國內五大銀行:平均。1961/7~2019/12
- 109.risk3: 定期存款利率: 國內五大銀行: 平均: 一個月。1961/7~2019/12
- 110.risk4:實際有效匯率指數:BIS:2010年=100:狹窄的。1963/10~2019/12
- 111.risk5: 定期存款利率: 國內五大銀行: 平均: 一年。1975/7~2019/12
- 112.risk6:外匯:新臺幣兌美元:銀行同業:平均。1979/1~2019/12
- 113.risk7:商業票據利率:二級市場:1至30天。1980/11~2019/12
- 114.risk8:商業票據利率:二級市場:31至90天。1980/11~2019/12
- 115.risk9: 商業票據利率: 二級市場: 91至180天。1980/11~2019/12

116.risk10:商業票據利率:初級市場:1至30天。1980/11~2019/12 117.risk11:商業票據利率:初級市場:31至90天。1980/11~2019/12 118.risk12:商業票據利率:初級市場:91至180天。1980/11~2019/12 119.risk13:可轉讓定期存款利率:1天至90天。1980/11~2019/12 120.risk14:可轉讓定期存款利率:91至180天。1980/11~2019/12 121.risk15:同業拆借利率:隔夜:加權平均。1981/1~2019/12

122.risk16: 兌美元匯率: 月平均。1983/10~2019/12

123.risk17:存款準備金率:支票帳戶。1988/12~2019/12 124.risk18:存款準備金率:活期存款。1988/12~2019/12

125.risk19:存款準備金率:儲蓄存款:活期。1988/12~2019/12 126.risk20:存款準備金率:儲蓄存款:定期。1988/12~2019/12

127.risk21:存款準備金率:定期存款。1988/12~2019/12

128.risk22:存款準備金率:其他債務:外幣存款。1988/12~2019/12

129.risk23:存款準備金率:信託基金。1988/12~2019/12

Factors Extraction

(A) PCA by Covariance (B) PCA by Correlation (C) ICA Scree plot of variance proportion, Corr=FALSE Scree plot of variance proportion, Corr=TRUE Scree plot of variance accumulation, Corr=TRUE Scree plot of variance ac

實作架構

- 1. 資料:1982/1~2019/12 無缺值的共68筆變數。
- 2. 投入變數(input variables)X有兩種:
 - ① 第一種是原始數據68個解釋變數;
 - ② 第二種是用因子分析法萃取的少量因子。

我們採用三個方法對68個解釋變數降維成7個:獨立因子法(ICA, independent component analysis)、以相關係數矩陣計算的主成分方法(PCA, principal component analysis)、和以共變異數矩陣計算的主成分方法。採用相關係數矩陣的主成分,資料必須沒有常數或接近常數的變數。因子萃取的陡坡圖(內文圖4.1(A)(B)),依照對整體變異90%的解釋程度,採用相關係數矩陣計算的主成份,取7個因子;採用共變異數矩陣計算的主成份,取5個因子,ICA則以二元迴歸的p-value小於0.02為準,取6個獨立因子,如內文圖4.1(C)。

3. 我們訓練的模式如y_t=F(X_{t-p}), p=1,2...6。訓練資料1982/1~2016/2共398個月,訓練資料內,用299個月估計,估計期內含10-fold的交叉驗證。滾動預測25個月,然後向前疊加滾動4期,也就是說一個模型有3類資料,4個滾動時段,6個落後期,總模型有288個。最後用這288個模型選出50個預測未公布的景氣階段2016/3-2019/12(第6節)。訓練期214個月,預測期25個月,然後向前滾動;訓練期內含了交叉驗證的10-fold。

預測表現

混淆矩陣產出多個預測表現指標,第五節的實證以四個指標為主: 正確性(Accuracy)、精確性(Precision)、F1和Kappa。

- 1. positive=0(收縮期)
- 2. 正確性和精確性衡量了預測為「真」程度,數值介於0和1, 越大越好。
- 3. F1和Kappa則考量預測為「偽」整體評估模型狀況,
 - ① F1數值介於0和1,越大越好;
 - ② Kappa數值介於-1和1,大於0.4較可靠。

四. 結果報告

4個模型:glm, tree, RF, SVM

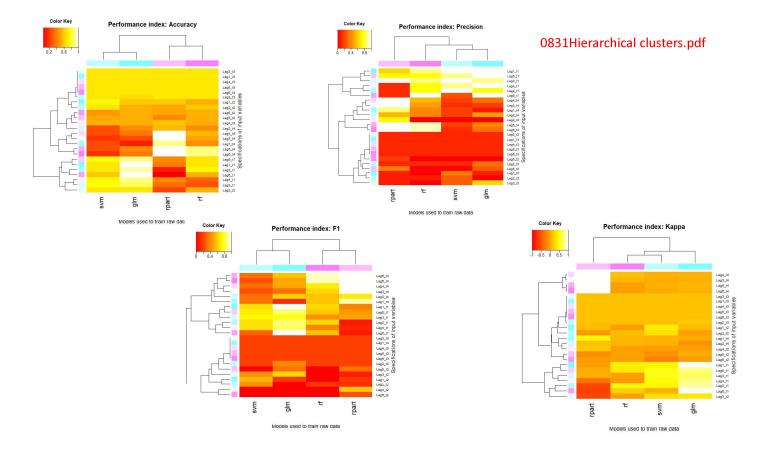
第一階段的預測表現診斷有四部份,以兩類input variables為基礎,

$$y_t = F(X_{t-p})$$
$$y_t = F(y_{t-p}, X_{t-p})$$

每一個模型依照X的資料性質再區分為兩類:原始資料和因子資料。 因為模型和設定很多,以熱力圖呈現預測結果。

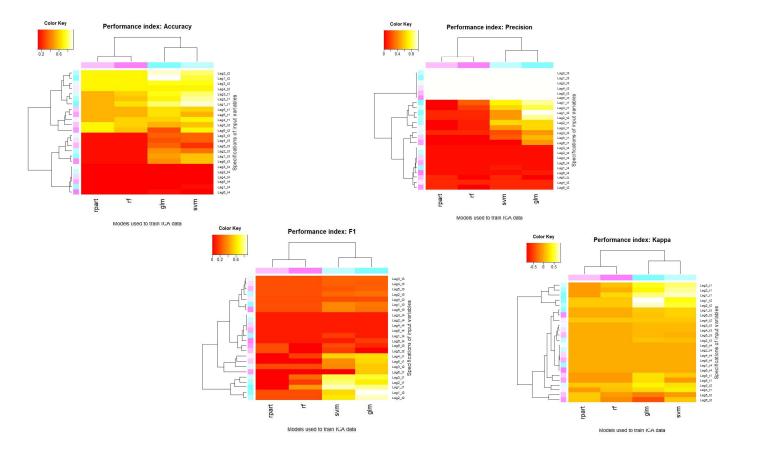
$$(-)$$
模型: $y_t=F(X_{t-p})$

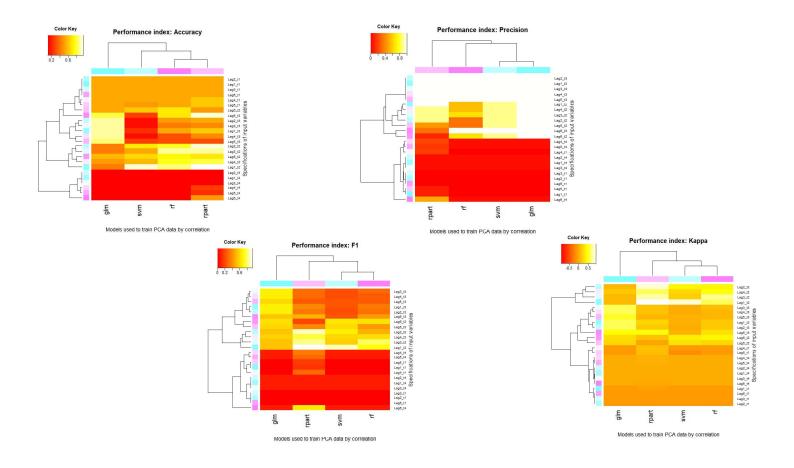
第一、X是64筆原始數據

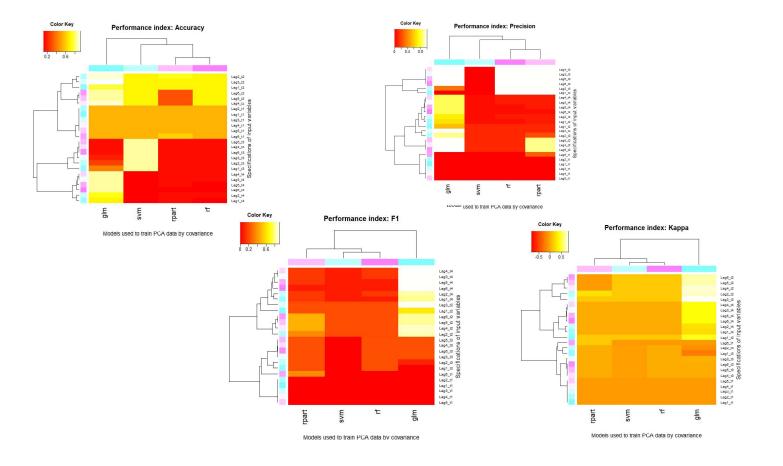


$$(-)$$
模型: $y_t = F(X_{t-p})$

第二、X是降維因子

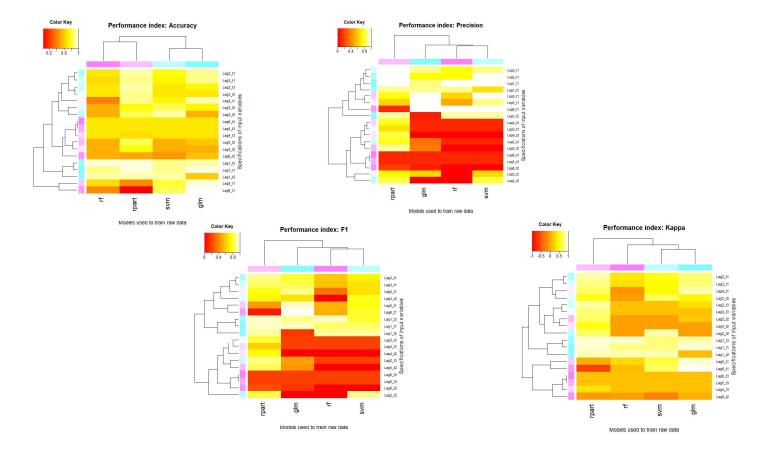






(二)模型:
$$y_t = F(y_{t-p}, X_{t-p})$$

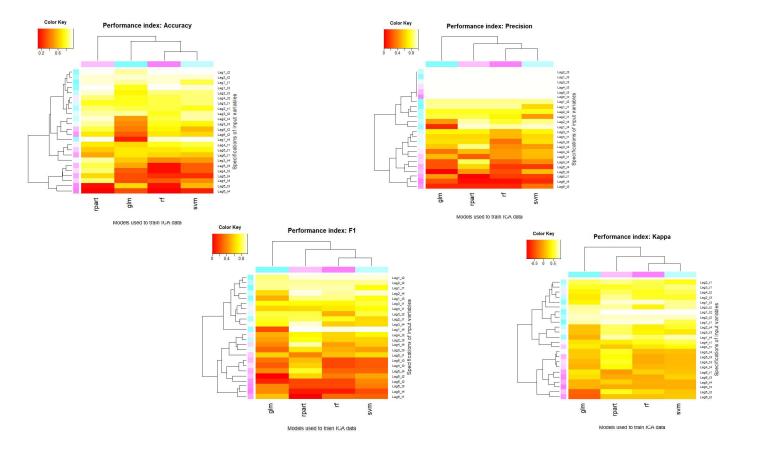
第一、X是64筆原始數據

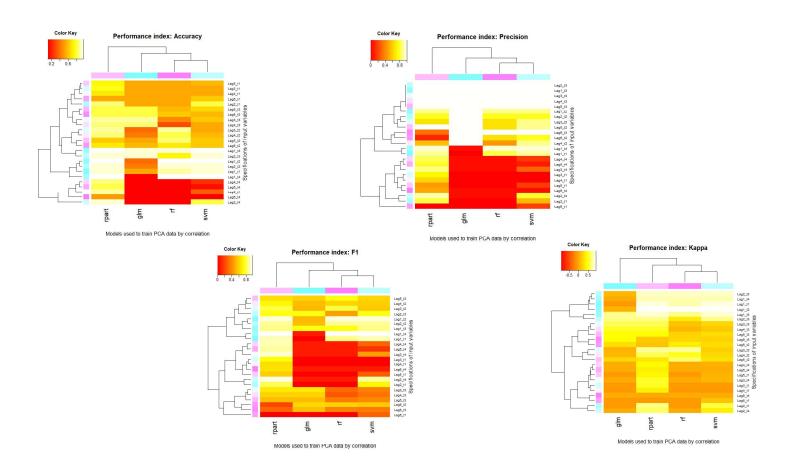


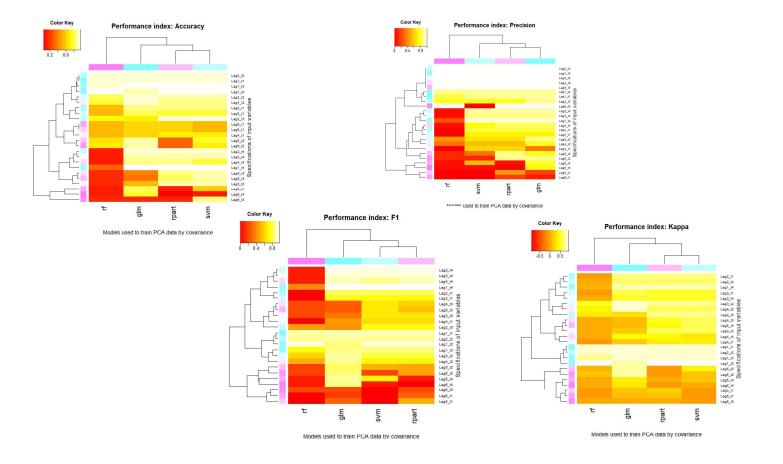
(二)模型: $y_t = F(y_{t-p}, X_{t-p})$

第二、X是降維因子

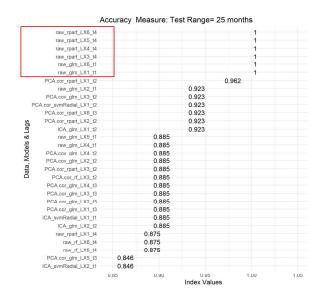
SVM, glmboost

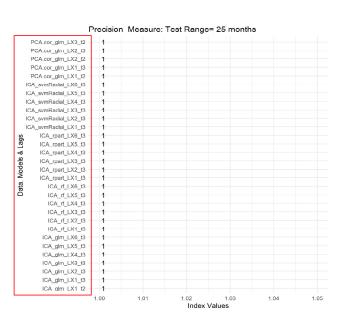


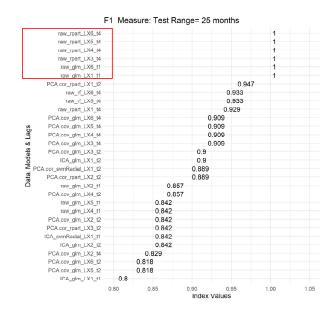


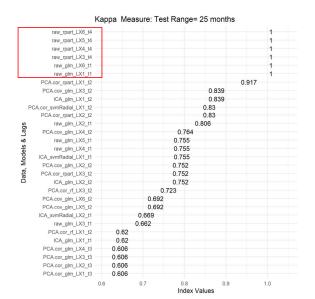


Best 30: Only X









預測 2016/3-2019/12

先將每個績效指標最好的**50**個模式,用簡單平均法計算四個績效指標的**4**個平均預測; 四個績效指標的**4**個平均預測,再平均一次。

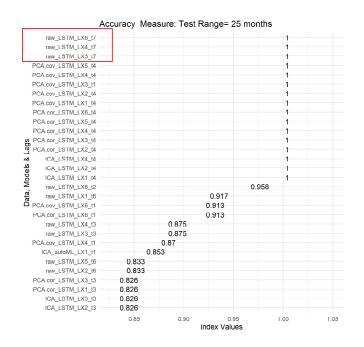
沒有AR項

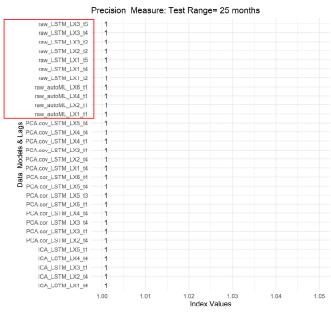
į	谷底	高峰	谷底	擴張期	收縮期	全循環
	2012.01	2014.01	2016.02	33	16	49
	2016.03	2018.01	2019.02	23	13	36
	2019.03	2019.12		10		

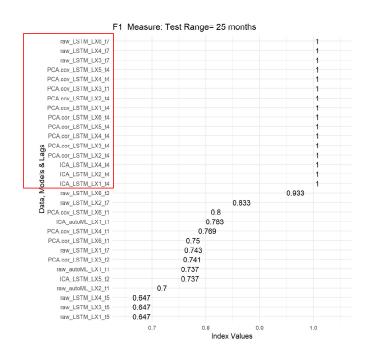
有AR項

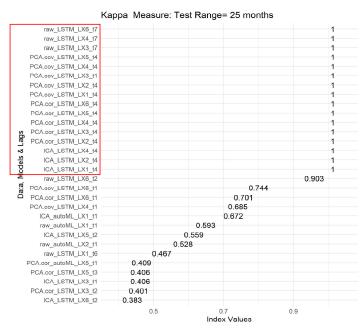
Į	谷底	高峰	谷底	擴張期	收縮期	全循環
	2012.01	2014.01	2016.02	33	16	49
	2016.03	2018.03	2019.04	25	13	
	2019.05	2019.12		8		

Best 30: LSTM & autoML









預測 2016/3-2019/12

H2O.AutoML

谷底	高峰	谷底	擴張期	收縮期	全循環
2012.01	2014.01	2016.02	33	16	49
2016.03	2017.12	2019.06	22	18	40
2019.07	2019.12		6		

RNN-LSTM-- 景氣轉折無法捕捉

谷底	高峰	谷底	擴張期	收縮期	全循環
2012.01	2014.01	2016.02	33	16	49
		2019.16		46	

iForecast: 技術移轉產生的R套件

iForecast: Machine Learning Time Series Forecasting

Compute both static and recursive time series forecasts of machine learning models.

Version: 1.0.1

Depends: $R (\ge 3.5)$, caret, zoo

Imports: magritts

Suggests: data.table, DescTools, forecast, h2o, keras, kernlab, lubridate, tensorflow, tibble, timeSeries, timeDate, timetk

Published: 2020-11-04 Author: Ho Tsung-wu

Maintainer: Ho Tsung-wu <tsungwu at ntnu.edu.tw>
License: GPL-2 | GPL-3 [expanded from: GPL (≥ 2)]

NeedsCompilation: no

CRAN checks: iForecast results

Schedule of updates

1. 2021/3: binary Y

2. 2021/6: Corrected CV

```
library(iForecast)
dep <- macrodata[,"unrate"]</pre>
ind <- macrodata[,-1]
train.end <- "2008-12-01"
test.start<- "2009-01-01"
#Case 1. Machine Learning by library(caret)
models <- c("svm","rf","rpart","gamboost","BstLm","bstSm","blackboost")[1]</pre>
type <- c("none", "trend", "season", "both") [1]</pre>
Caret <- ttsCaret(y=dep, x=ind, arOrder=c(3,5), xregOrder=c(2,4),</pre>
                                         method=models, tuneLength =10,
                                         train.end, type=type)
testData1 <- window(Caret$data, from=test.start, to=end(dep))</pre>
P1 <- iForecast (Model=Caret, newdata=testData1, type="directfit")
P2 <- iForecast (Model=Caret, newdata=testData1, type="recursive")
tail(cbind(testData1[,1],P1,P2))
                      ttsCaret(), ttsAutoML(), ttsLSTM()
> tail(results$data)
            y ar3 ar5
                        OECD L2
                                     G7_L2
                                           NAFTA_L2
                                                        OECD L4
                                                                    G7_L4
2019-07-01 3.7 3.6 3.8 -0.7054032 -0.7927722 -0.6833333 -0.8445375 -0.8891302 -0.8075641
2019-08-01 3.7 3.6 3.8 -0.6742180 -0.8242783 -0.7442388 -0.7519738 -0.7959486 -0.7036327
2019-09-01 3.5 3.7 3.6 -0.6120744 -0.8542537 -0.8072419 -0.7054032 -0.7927722 -0.6833333
2019-10-01 3.6 3.7 3.6 -0.5641829 -0.8938656 -0.8477125 -0.6742180 -0.8242783 -0.7442388
2019-11-01 3.5 3.7 3.7 -0.4422193 -0.7964165 -0.7963173 -0.6120744 -0.8542537 -0.8072419
2019-12-01 3.5 3.5 3.7 -0.2810611 -0.6360092 -0.6177776 -0.5641829 -0.8938656 -0.8477125
> results$static.Accuracy
                              RMSE
                                        MAE
                                                    MPE
                                                             MAPE
                                                                      ACF1 Theil's U
```

static forecasts -0.500012 0.8987078 0.6064988 -0.06692379 0.0886179 0.9650801 0.05521855

recursive forecasts -0.4308448 1.224351 1.012473 -0.04577748 0.1595328 0.972795 0.12958

MAE

MPF

MAPF

ACF1 Theil's U

> results recursive. Accuracy

>

MF

RMSE

運用人工智慧掌握景氣動態/何宗武計畫主持;

葉國俊、張淑華、林雅淇協同主持. -- 初版. --

臺北市: 國發會, 民109.12

面:表,公分

編號: (109)025.0205

委託單位:國家發展委員會 受託單位:國立臺灣師範大學

經濟循環 551.9

運用人工智慧掌握景氣動態 委託單位:國家發展委員會 受託單位:國立臺灣師範大學

計畫主持人:何宗武

協同主持人: 葉國俊、張淑華、林雅淇

出版機關:國家發展委員會

電話:02-23165300

地址:臺北市寶慶路3號

網址:<u>http://www.ndc.gov.tw/</u>

出版年月:中華民國 109年12月

版次:初版 刷次:第1刷

編號:(109)025.0205 (平裝)