

財團法人俞國華文教基金會獎助出國專題研究報告書

(出國類別：研究)

台灣金融情勢、經濟下行風險與貨幣政策

傳遞：兼論機器學習方法之應用

服務機關：中央銀行
姓名職稱：張天惠/科長
派赴國家：德國、英國
出國期間：112年6月29日至
112年9月28日
報告日期：112年12月8日

摘要

2008 年全球金融危機突顯金融市場的脆弱性對實體經濟活動之負面影響。金融脆弱性不僅無法支持實體經濟運作，甚至會因高度金融脆弱，擴大和延長負向衝擊對經濟成長的影響。然而，金融市場變化資訊龐雜且瞬息萬變，不易即時且全面掌握，金融情勢指數(financial conditions index, FCI)匯集一國整體的金融情況，以綜合之方式描繪金融變數與總體經濟活動之間的關係，據以預測未來總體經濟走勢，並可提供未來經濟下行風險之資訊。FCI 可協助央行在金融衝擊於其傳遞至實體經濟前迅速反應，因此，FCI 適宜作為央行訂定貨幣政策時之參考指標。

考量近年文獻與主要央行在 FCI 之應用不斷翻新，以及近期機器學習之發展，本專題研究除了持續精進非監督式學習方法外，另廣納監督式學習進行 FCI 之估計，主題探討 FCI 對總體經濟變數之領先性、對經濟下行風險之預測、與景氣循環轉折點之預測等。透過探討金融情勢與未來經濟下行風險間的關係，進而評估 FCI 是否可作為早期預警指標。最後，本專題研究亦以 VAR 模型，分析金融情勢衝擊對總體經濟之影響，並說明其對貨幣政策之意涵。

本專題研究採用大量金融市場變數，蒐集外匯(11 個變數)、貨幣(11 個)、股票(10 個)、房地產(7 個)與信用(8 個)等五個主要金融市場，共 47 個價與量之金融變數來估計 FCI，樣本期間自 2003 年 1 月至 2023 年 10 月，資料型態為月與季的混頻資料。本專題一共估計 6 個 FCI，分別為(1) FCI-Factor，以因子模型(factor model)估計，選取主要因子當作 FCI；(2) FCI-LDA 採用線性判別分析(linear discrimination analysis, LDA)估計，以負的工業生產指數年增率當作目標函數；(3) FCI-Fa+LDA，先於 5 個金融市場以因子模型萃取主要因子，再以 LDA 方法(以負的工業生產指數年增率當作目標函數)估計權重；(4) FCI-

LassoLogit, 以正規化 Logit 模型估計; (5) FCI-RF, 以隨機森林(random forests, RF) 法估計; (6) FCI-SVM, 以支持向量機(support vector machine, SVM)方法估計。本專題建構之 FCI 數值為正, 表示金融情勢較為寬鬆, 對於未來經濟成長有正向拉力; FCI 若為負, 表示金融情勢較為緊縮, 將抑制未來經濟成長動能。本專題實證結果如下:

1. 以國發會的領先、同時與落後指標之構成項目當作實質總體經濟變數, 在觀察的樣本期間內, 本專題所建構的 6 個 FCI 具有領先絕大多數實質面的總體經濟變數之特性, 可有效掌握實質面景氣脈動。
2. 分量迴歸結果顯示, 大多數監督式學習之 FCI 皆能監測未來經濟成長的下行風險, 尤其是在短期較為明顯, 其中以 FCI-LDA 與 FCI-SVM 表現較佳; 而非監督式學習之 FCI, 則是在較長期表現較好。整體而言, FCI 可提供有關未來經濟成長、尤其是經濟成長面臨下行風險之資訊。
3. 當 FCI 下降, 未來景氣衰退之機率將上升, 顯示 FCI 可反映未來景氣衰退, 且隨預測期間的增加, FCI 對較長期之景氣衰退表現顯著較佳, 顯著優於其對短期景氣衰退的表現, 可作為對未來景氣衰退之良好的預警指標。
4. 當面臨 FCI 正向衝擊, 產出會立即上升且顯著持續增加大約 1 年; 物價則一開始下降, 而後因持續寬鬆狀態而於第 10 期後顯著微上升, 利率上升惟不顯著, 失業率則下降, 結果符合理論預期與文獻。

本次到德國與英國進行專題研究, 了解小型開放經濟體面對除了美國貨幣政策帶來的外溢效果外, 高度金融整合(financial integration) 可能對其為風險分擔(risk sharing)亦或是傳遞更為快速且巨大的衝擊。再者, 如何評估與量化經濟下行風險與其傳遞管道, 更有利於提升專

題研究深度。整體而言，以上經驗分享均獲益良多，茲提出心得與建議事項如下：

1. FCI 提供潛在風險對未來經濟成長影響之有用訊息，可作為未來景氣衰退之良好預警指標，央行亦可利用 FCI 協助貨幣政策對外溝通，以資料說明(data-dependent)的方式，引導市場預期；FCI 勾勒總體經濟模型未能捕捉到的重要金融面向，且為較高頻指標，可作為總體經濟評估的穩健性檢測。
2. 機器學習雖可處理大量且複雜的資料，降低人為錯誤，提高工作效率與預測的準確度，惟相當依賴大量且高品質之資料，計算耗時且應用上仍有一些侷限，例如容易出現過度配適(overfitting)、尚須人為介入，方能達到最佳效果，或是其結果難以解釋，無因果關係等。英格蘭銀行(BoE)表示尚未採機器學習進行 MFCI 估計，主因為機器學習猶如黑盒子(black-box)模式，難以解釋其經濟意涵；若以機器學習進行相關政策分析時，恐無法知道衝擊的來源，更無法追蹤其效果。因此，以機器學習估計之 FCI 可能較適合當作輔助工具。
3. 在全球高度金融整合下，小型開放經濟體之金融情勢深受全球金融情勢衝擊，浮動匯率亦無法完全阻隔其影響，致吸納衝擊效果有限。因此，早期預警指標的目的便是協助政策制定者，事前採取因應措施，防止可能的金融傷害，甚至是巨幅經濟損失，而 FCI 作為早期預警指標，確實可作為政策施行之參考依據。
4. 面對可能金融危機的發生，除了依據早期預警指標外，應進一步了解金融危機的起因。因此，當 FCI 持續示警時，宜分析其衝擊之來源。此外，考量金融衝擊可能引發比景氣衰退更加嚴重的負向影響，若要獲得較佳的貨幣政策成效，須考慮總體經濟及金融體系的相互關係。

目 錄

壹、前言.....	1
貳、FCI 文獻回顧與近年主要央行之編製、應用與發展.....	5
一、FCI 文獻回顧.....	5
二、近年主要機構與央行 FCI 之編製、應用與發展.....	7
三、FCI 與經濟下行風險預測.....	19
四、台灣 FCI 文獻.....	27
參、機器學習法之發展與應用.....	29
一、機器學習之介紹.....	32
二、主要央行機器學習之應用與文獻.....	40
肆、台灣實證分析.....	44
一、資料來源與說明.....	44
二、實證分析.....	48
(一)Granger 因果關係檢定.....	50
(二)經濟下行風險.....	54
(三)FCI 與貨幣政策傳遞.....	63
伍、結論與心得.....	64
參考文獻.....	68

壹、前言

央行透過評估多樣化的總體經濟與金融訊息，制定與執行貨幣政策與總體審慎措施，以達成物價穩定、金融穩定與經濟成長等法定職責。然而，隨著各國金融市場全球化、高度複雜與交互影響，金融市場資訊龐雜且瞬息萬變，不易即時且全面掌握，因此，主要央行往往會透過金融情勢指數(financial conditions index, FCI)來瞭解整體金融情勢，FCI可提供潛在風險對未來經濟成長影響之有價值訊息，有助提高央行對金融情勢之掌握，以利適時地調整貨幣政策態勢。

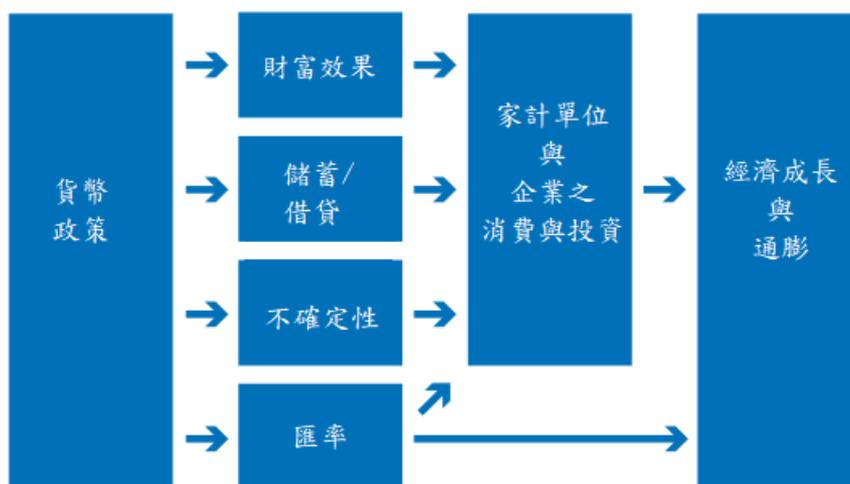
FCI為融合多樣化金融變數，以綜合之方式描繪一國整體的金融情況，捕捉金融變數與總體經濟活動之間的動態關係，並據以預測未來總體經濟走勢。而貨幣政策與金融情勢關係密切，主要係因貨幣政策影響家計單位與企業的消费與投資決策，最後傳遞至最終目標：經濟成長與物價穩定，而這中間的決策過程即是透過這些金融變數(金融情勢)傳遞。

2008 年全球金融危機對全球經濟與金融市場帶來重大衝擊，總體金融的脆弱性(macrofinancial vulnerabilities)不僅無法支持實體經濟運作，甚至會因高度脆弱性，擴大(amplify)和延長(prolong)負向衝擊對經濟活動的影響(Adrian et al., 2019)，促使全球央行重新審視總體金融部門失衡(macrofinancial imbalances)帶來的風險，因此，分析金融情勢以評估未來總體經濟發展對央行相當重要。

對政策制定者而言，金融變數具有即時預報經濟情勢與預測未來經濟成長的特徵，主要係因金融變數本質上具前瞻性，並可將市場預期內化總體資料，因此它們可以直接影響未來經濟走勢。再者，金融變數多為高頻且即時資料。因此，主要經央行多應用 FCI 協助貨幣政策決策。而 FCI 除了前述的可據以預測未來總體經濟外，央行利用

FCI 作為分析尚有一些優點(Alsterlind et al., 2020)，首先，可協助貨幣政策對外溝通，亦即透過 FCI 對外界說明整體金融情勢是否寬鬆或緊縮，以及近期發展情況，以資料說明(data-dependent)的方式，明確與透明的溝通有助強化外界對貨幣政策的信心，進而引導市場預期；再者，FCI 勾勒總體經濟模型未捕捉到的重要金融面向，可作為總體經濟評估的穩健性檢測，亦即如同 Adrian et al. (2019)、IMF(2017a, b)等研究皆發現 FCI 可預測經濟成長之下行風險。

圖 1 金融市場與實體經濟之連結



資料來源：Fransson and Tysklind (2017)

此外，近年不論學界，或是主要機構與各國央行應用機器學習方法有長足的發展，包含建模分析、總體經濟金融變數之預測，和金融監理等，以提昇政策品質(BIS, 2022)。機器學習由於能夠處理高維度資料(high-dimensional data)，進行模型篩選(model selection)，不預先假設資料間的結構關係，而是從大量資料學習，捕捉資料間的關係，其預測績效多優於傳統迴歸模型。例如 IMF 曾以機器學習法將預測經濟成長風險的變數分組後，進行降維，編製 FCI，並預測在當前金融情勢下之經濟成長風險(Prasad et al., 2019)。英格蘭銀行(Bank of

England, BoE)運用機器學習，以金融機構的資產負債表為基礎，建構預警模型，以及對英國中期(medium-term horizon of two years)通膨預測(Chakraborty and Joseph, 2017)¹。加拿大央行(Bank of Canada)則是利用機器學習法即時監測金融機構異常資料，以強化監控機制及金融預警系統。

鑑於金融情勢可提供央行貨幣政策參考之重要性，且近期機器學習法之發展，以及主要央行在 FCI 之應用不斷翻新，值得再深入剖析。本次俞國華基金會獎助出國專題研究擬在張天惠(2023)之基礎上，做進一步擴充。張天惠(2023)以工業生產指數成長衝擊作為實質景氣的代理變數，嘗試從鄰近經濟下行風險預測的角度切入，採機器學習中的線性判別分析(linear discrimination analysis, LDA)，對預測經濟成長下行風險的變數分組，進行降維後編製 FCI。實證結果發現 LDA 方法建構之 FCI 對預測未來經濟下行風險具有預警能力，FCI 提供有關未來經濟成長、尤其是經濟成長面臨下行風險之資訊，且領先絕大多數實質面總體經濟變數。

考量機器學習發展之趨勢，本專題研究除了持續精進非監督式學習(unsupervised learning)方法外，另將廣納監督式學習(supervised learning)方法之運用，嘗試包含 Logistic 迴歸模型(logistic regression, LR)、隨機森林(random forests, RF)與支持向量機(support vector machine, SVM)等²，透過將資料的特徵擷取、分層、分類，亦或是將資料以目標函數(或損失函數)進行訓練，進行降維後，編製與估計台灣之 FCI，以期其對台灣經濟成長與下行風險有良好之預測能力，提

¹ 除了文中介紹的建模與預測外，亦以機器學習找出潛在的科技創投公司籌資模式，詳見本專題研究第三章第二小節。

² 機器學習方法間因分類(層)或訓練方式具有不同之特性，其預測績效表現也會有差異。一般而言，當決策邊界(decision boundary，用以分割資料作為分類的邊線)為線性時，LDA 與 LR 表現較佳。若決策邊界為非線性時，二次判別分析(QDA)可能表現較好。若決策邊界更為複雜時，無母數(nonparametric)的階層式分群等方法可能會有較佳的表現。

供政策參考。

再者，考量近年文獻與主要央行 FCI 之應用，FCI 對經濟成長與經濟下行風險的預測，以及與金融穩定關連至為重要，本專題研究將以不同計量方法探討有關：(1)FCI 對總體經濟變數之領先性；(2)FCI 對經濟下行風險之預測；(3)FCI 與景氣循環之關係及其轉折點之預測等議題。此外，由前述可知，全球金融危機突顯高度金融脆弱性對經濟成長的衝擊，過去許多文獻(如 De Santis and Van der Veken, 2020；Krygier and Vasi, 2021 等)發現，金融情勢緊縮與脆弱程度上升時，會大幅增加未來經濟衰退的機率。基於央行需維護金融穩定與協助經濟成長的法定職責，央行亦重視極端事件對經濟成長的影響。透過探討金融情勢與未來經濟下行風險間的關係，進而評估 FCI 是否可作為早期預警指標。

最後，本專題研究將進一步支持分析金融情勢以評估未來總體經濟發展對央行相當重要，主要係因金融情勢會透過影響家庭與企業的儲蓄及投資，影響實際的經濟活動；貨幣政策從決策傳遞到最終目標：物價穩定、經濟成長等，多會經由這些金融變數傳遞(Hatzius et al., 2010；Fransson and Tysklind, 2017)，而總體金融之脆弱性(macro-financial vulnerabilities)會擴大與延長負向衝擊對經濟活動的影響。因此，本專題研究將以向量自我迴歸(vector autoregression, VAR)方法，分析金融情勢衝擊對總體經濟之影響，探討其在貨幣政策傳遞之角色。

本專題研究之架構如下，除第一章前言外，第二章為 FCI 文獻回顧與近年主要央行之編製、應用與發展，尤其在經濟下行風險之運用，以及台灣 FCI 文獻之回顧，作為本專題研究建構 FCI 之根據。第三章為機器學習法之發展與應用。第四章為台灣之實證結果與分析，包含 Granger 因果檢定、FCI 對經濟下行風險預測、景氣轉折與 FCI 衝擊之影響。第五章為結論與心得。

貳、FCI 文獻回顧與近年主要央行之編製、應用與發展

一、FCI 文獻回顧

FCI 起源於貨幣情勢指數(monetary conditions index, MCI)，加拿大銀行於 1980 年代末期將利率與匯率變數融合為單一指標，即 MCI，以提供央行作為貨幣決策之考量。然而，貨幣政策傳遞除了利率與匯率傳遞管道外，尚包含資產價格管道等，因此，加拿大央行與學界嘗試將更多不同金融變數融入指標，因而產生 FCI。1990 年代中期，加拿大銀行開始編製與公佈 FCI，為最早發展 FCI 的濫觴。早期 FCI 文獻著重於將 MCI 納入少量金融變數，以進一步擴充，方法多以從 IS 曲線推演而來的縮減式(reduced form)或 VAR 等模型為主，受限於模型自由度，僅能選取利率、匯率、房價與股價等少量具有代表性且統計顯著之金融變數，如 Goodhart and Hofmann (2001)、Mayes and Viren (2001)、Gauthier et al. (2004)、Swiston (2008)與 Guichard and Turner (2008)等，這些文獻並進一步檢視 FCI 對未來產出與通膨的預測能力，估計結果多顯示 FCI 具有對 GDP 成長率與未來通膨之預測能力(詳見張天惠(2012)與 Wacker et al. (2014)整理)。

此外，在 2008 年全球金融危機前，早期有關預警金融危機的文獻，多從總體變數示警的角色來看，例如 Demirgüç-Kunt and Detragiache (1998)發現銀行危機的發生多與經濟衰退、過高的實質利率與高通膨有關。Glick and Hutchison (2001)則發現經濟成長減緩與高度金融自由化易導致銀行危機。而 Borio and Lowe (2002)研究發現，信用快速擴張和資產價格大幅上升預測 1970 年至 1999 年間 34 國的銀行危機，從而激發建立「早期預警指標(early-warning indicator)」的廣泛研究。

此外，全球金融危機突顯金融情勢與總體經濟連結的重要性，尤其是過度的信用擴張與資產價格泡沫破滅是觸發金融危機的重要因素(Schularick and Taylor, 2012; Jordà et al., 2016; Greenwood et al., 2022)。而 Greenwood et al. (2022)實證發現，過去三年信用和資產價格的快速成長，無論是在企業或家庭部門，在未來三年內陷入金融危機的機率約為 40%，是承平時期的(normal time)的 6 倍。考量大量的金融變數編製的 FCI 更易捕捉金融市場與景氣循環間的關係，尤其是納入信用與資產價格變數，因而 FCI 日益受到各界重視，不論是在計量方法或是其應用上皆快速的發展。

金融危機之後的文獻除了多採用大量金融變數，並將信用或資產價格，甚至利差、風險溢酬、金融調查資料等相關變數考量其中，而為廣泛地納入更多金融變數，與過去僅可納入少量變數的縮減式模型不同，多應用主成分分析法(principal component analysis, PCA)或因子模型，從大量金融變數萃取資訊，捕捉眾多變數之間共同變動。如美國芝加哥聯邦準備銀行(Chicago Fed)的 NFCI (National Financial Conditions Index) (Brave and Butters, 2011)、Claessens et al. (2012)、Hatzius et al. (2010)、Osoris et al. (2011)、Vonen (2011)、ECB (2012)、Erdem and Tsaronis (2013)、Angelopoulou et al. (2013)、Wacker et al. (2014)、Levanon et al. (2015)、Kapetanios et al. (2018)等文獻。

Claessens et al. (2011, 2012)之研究發現，金融脆弱性會增加經濟成長的風險，亦即一旦高度金融脆弱，將會擴大和延長不同衝擊對經濟成長的影響。因此，在金融危機期間，當巨大的損失或違約威脅到銀行業時，金融體系不僅無法支持實體經濟運作，且會進一步傳播衝擊，而非吸收衝擊(Borio, 2014; Brunnermeier and Sannikov, 2014; Krishnamurthy and Muir, 2017)。全球金融危機突顯高度金融脆弱性對經濟成長的衝擊，過去許多文獻(如 De Santis and Van der Veken, 2020;

Krygier and Vasi, 2021 等)發現，金融情勢緊縮與脆弱程度上升時，會大幅增加未來經濟衰退的機率。

Kapetanios et al. (2018)納入 28 個英國金融變數(如安全性資產之利差、私部門利差、資產價格、信用、貨幣與信用限制調查資料等)，樣本期間自 2004 年 1 月至 2014 年 6 月的月頻資料，方法採用偏最小平方法(Partial Least Squares, PLS)，萃取大量金融變數資訊，降維後編製英國的 FCI。該方法相較於最小平方法(Least Square, LS)或縮減式模型(reduced-form model)，PLS 可解決高度線性重合與高維度變數下的變數選擇問題，同時可減少模型參數的數量，保留原始資料的訊息。PLS 將大量變數降維為新的低維特徵，稱為潛在變量(Latent Variables)，用來捕捉大量變數中的變異性。而這潛在變量是原始變數的線性組合，透過組合建模與分析，有助更好地解釋變數的變異性且提高預測能力。Kapetanios et al. (2018)研究發現，採 PLS 編製之 FCI 對月頻 GDP 具有良好的預測能力，且優於 Goldman Sachs 編製的 FCI。FCI 有助認定信用供給衝擊，納入 FCI 的衝擊反應函數裡，信用供給衝擊對總體經濟之影響較大且較長。

二、近年主要機構與央行 FCI 之編製、應用與發展

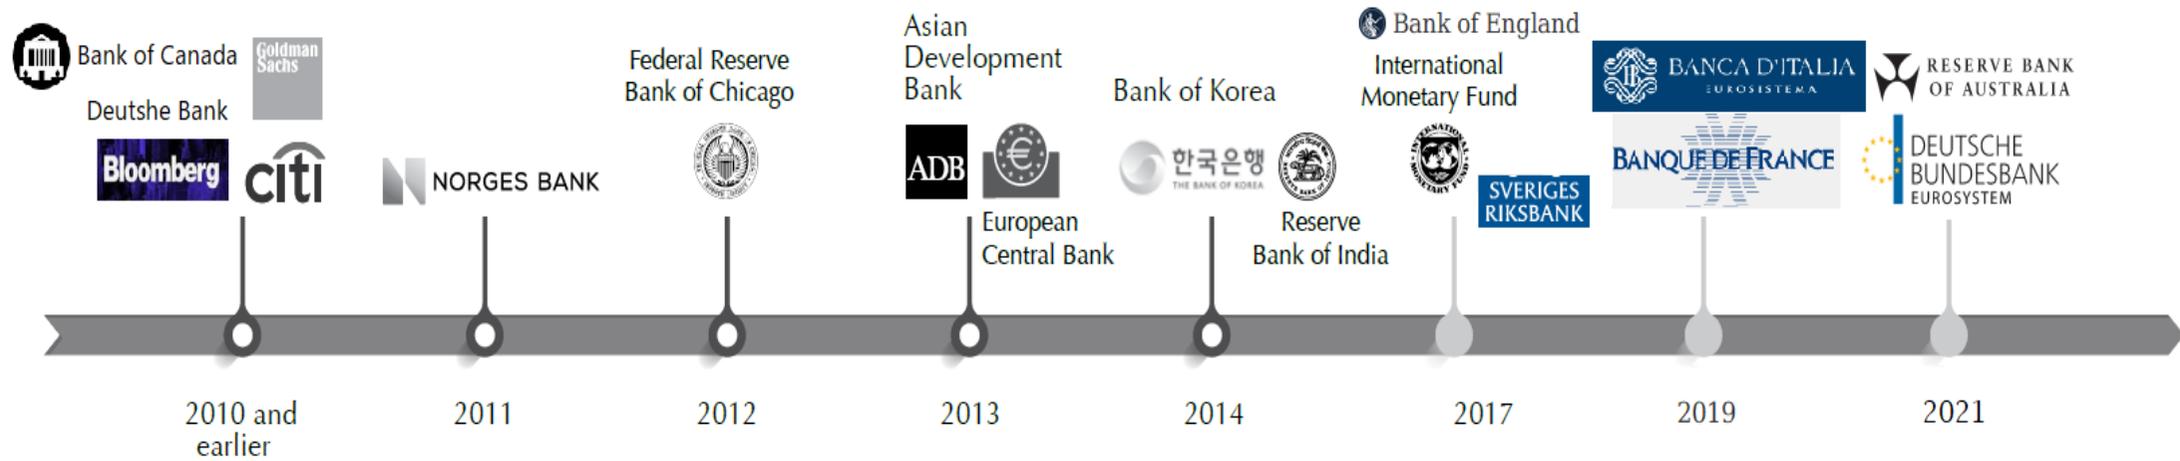
如前所述，全球金融危機之前，FCI 之建構多採用可直接刻劃變數與總體經濟間關係的縮減式模型、VAR 等，因此，選取較少但具代表性且統計顯著之金融變數當作解釋變數，此段時間發展的 FCI 如最早的加拿大央行(Gauthier et al., 2004)、Bloomberg (Rosenberg, 2009)、Citi Group (D'Antonio, 2008)等。圖 2 為主要央行、國際組織與私人機構編製 FCI 之發展。2010 年以後多強調總體金融連結，因此多以納入眾多金融變數，採用 PCA 或因子模型，由大量金融變數中萃取出主要因子當作 FCI，如挪威央行(Vonen, 2011)、美國 Chicago Fed (Brave and Butters, 2011; Brave and Kelley, 2017)、ADB (Debuque-Gonzales and

Maria, 2013)、歐洲央行(ECB) (Pariès et al., 2014)、印度央行(Shankar, 2014)等。

若是以較高頻且常見的 Chicago Fed 的 FCI 說明，Chicago Fed 每週編製，用以反映美國當前整體(貨幣、債券、股市及傳統與影子銀行)的金融情勢，起始年為 1973 年，組成項目包含 9 個市場(包含商業信用、影子銀行、債券市場、商業票據與附買回交易市場、衍生性金融商品市場等)，共 105 個大量金融變數，採動態因子模型(dynamic factor model)，編製 NCFI。另為排除經濟活動對 FCI 的影響，進一步編製 ANFCI (Adjusted NCFI)，先將前述 105 個金融變數分別對 3 個月移動平均的 Chicago Fed 全國經濟活動指數(Chicago Fed National Activity Index, CFNAI)和通膨率做簡單迴歸，得到殘差項後，再以動態因子模型編製成 ANFCI。當 ANFCI 數值大於 0，表示相對於 CFNAI 與通膨率所反映的經濟活動情況，金融情勢較為緊縮。

後續有編製 FCI 的機構與央行則如 IMF (IMF, 2017a ; 2017b)、瑞典央行(Fransson and Tysklind, 2017 ; Alsterlind et al., 2020)、英格蘭銀行(Kapetanios et al., 2018)、法國央行(Banque de France)(Petronovich and Sahuc, 2019)、義大利央行(Bank of Italy) (Miglietta and Venditti, 2019)、澳洲央行(Reserve Bank of Australia) (Hartigan and Wright, 2021) 與德國央行(Deutsche Bundesbank) (Metiu, 2022)等等。以下選擇幾個主要機構與央行進行詳細介紹。

圖 2 主要央行、國際組織與私人機構編製 FCI



註：以官網資料為主，或是該機構或央行成員在其機構或央行之著作。

資料來源：作者自行整理

(一) IMF

IMF 主要有二篇報告在說明 FCI 之建構與其應用，如 IMF (2017a) 與 IMF (2017b)。IMF (2017a) 蒐集自 1996 年起，43 個先進與新興市場經濟體相似的 10 組月頻率金融變數³，方法採用 Doz et al. (2011) 的動態因子模型與 Koop and Korobilis (2014) 的參數可隨時間改變的向量自我迴歸(time-varying parameter VAR)模型，建構這 43 個先進與新興市場經濟體之 FCI，在相同的基礎上，有利於進行跨國比較；另一方面，IMF 再進一步萃取這 43 個經濟體 FCI 的共同因子，以代表全球金融情勢指數(global FCI, GFCI)，FCI 上升表示金融情勢趨緊縮，下降表示趨於寬鬆狀態。

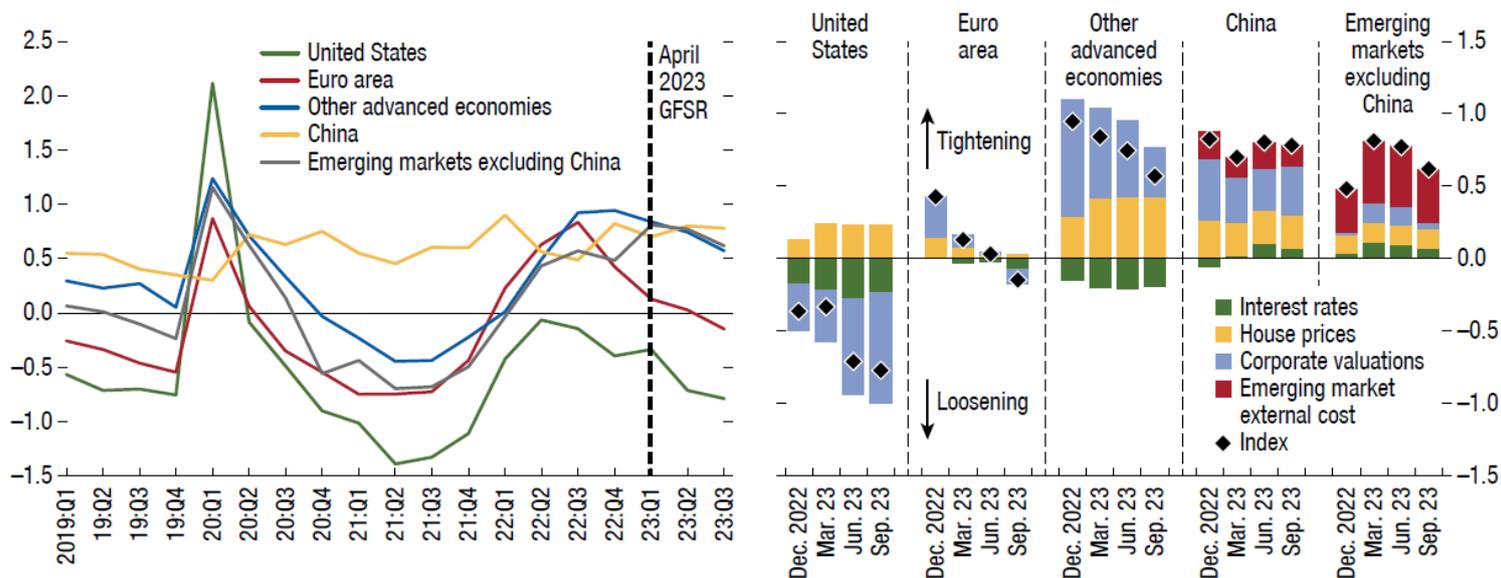
IMF (2017a) 以此 GFCI 對經濟成長率進行分量迴歸(Quantile regression, QR)，發現 FCI 對未來 1 年經濟成長率預測值之 10 分位數的係數，約為其中位數的係數之 3 倍，FCI 與未來經濟衰退的關係較強，顯示當預測未來經濟成長較差(低分量)，則 FCI 之係數較大。此外，GFCI 可解釋樣本內各經濟體 FCI 約 30~40% 的變動，且 GFCI 與美國 FCI 同步性強，因此，若該經濟體與美國金融連結(以 FDI 衡量)越強的國家，則國內金融情勢越容易受全球金融情勢影響。然而，該報告也發現，跨國金融情勢雖具有同向變動的性質，但在過去 20 年間，各國國內金融情勢變動歸因於全球金融情勢變動的比率似乎並未大幅增加。儘管各國與美國金融整合(financial integration)會增加全球金融衝擊對國內金融情勢的影響程度，但若該國金融發展程度愈高，則愈可削弱此國外衝擊。

IMF (2017b) 則延續 IMF (2017a) 與 Adrian et al. (2016) 經濟成長尾

³ 金融變數包含期限利差(10 年期公債與 3 個月期國庫券的殖利率差距)、長期實質利率的變動、銀行間利差(銀行間利率與 3 個月期國庫券殖利率之差距)、主權利差(該國與基準國 10 年期公債殖利率差距)、公司債利差、股價報酬與房價報酬、股價波動度、金融部門的總市值占比與信用成長等。

端風險之架構，並以 2008 年全球金融危機為例，分析 FCI 對未來經濟成長的尾端風險之預測。該報告發現在金融危機期間，納入 FCI 之模型對於預測未來 1 季經濟衰退之機率遠高於未納入 FCI 之模型，且採用即時(real-time)資料的 FCI 預測表現更佳，證實納入 FCI 之預測模型確實可預警未來經濟大幅衰退之風險。爾後 IMF 在每年 2 次的全球金融穩定報告(Global Financial Stability Report)中，定期說明主要經濟體與全球 FCI 狀況，並將 FCI 納入 GaR 架構當作經濟成長風險的衡量。圖 3 為 2023 年 10 月 IMF 全球金融穩定報告中近期主要經濟體之 FCI 走勢，圖中顯示美國金融情勢寬鬆，歐元區本季則轉呈寬鬆，其餘先進經濟體、中國與新興市場經濟體金融情勢仍處於緊縮狀態。

圖 3 近期主要經濟體之 FCI 走勢(IMF 編製)與其組成貢獻



資料來源：IMF Global Financial Stability Report, 2023 Oct.

(二) 英格蘭銀行

BoE 認為描繪整體金融情勢不僅僅是透過金融變數，亦包含許多貨幣變數，因此，BoE 將評估金融情勢和實體經濟間關係之指標，稱為貨幣與金融情勢指數(Monetary and Financial Conditions Index, MFCI)。

MFCI 納入影響英國未來 GDP 的關鍵變數(或其替代變數)，參考 OECD 的作法，從 IS 曲線推導而來，以各變數與經濟成長間的動態關係來估計，因此，BoE 將每個變數對英國 GDP 的邊際影響進行加權來編製 MFCI。目前 MFCI 之內涵主要包含 8 個成分，分別為英鎊匯率指數(Sterling exchange rate index)、10 年期政府公債殖利率(10-year nominal government bond yield)、3 年期遠期隔夜指數交換利率(3-year instantaneous forward Overnight Index Swap)、英國股價加權指數(FTSE All-Share equity price index)、加權平均資本成本(Weighted average cost of capital, WACC)、投資等級公司債利差(Investment grade corporate bond spreads)、房貸利率相對隔夜指數交換利率之差距(Mortgage spreads to OIS)與無擔保貸款利率相對隔夜指數交換利率之差距(Unsecured spreads to OIS) (BoE, 2021)。圖 4 為 BoE MFCI 與其子項目之走勢，MFCI 大於 0 表示金融情勢較為緊縮；MFCI 小於 0 表示金融情勢較寬鬆。

BoE 認為 MFCI 可及時提供整體金融情勢，且建構簡單，可分解其主要影響的組成變數。因此，MFCI 提供 BoE 貨幣政策委員會(Monetary Policy Committee, MPC)作為貨幣政策決策之參考，例如在 2020 年 6 月、11 月；2021 年 2 月、5 月之貨幣政策報告(Monetary Policy Report)中皆有引用 MFCI 進行分析。

圖 4 英格蘭銀行 MFCI 與其子項目



資料來源：BoE (2021)

(三)德國央行

德國央行參考 Metiu (2022)，利用 70 個金融變數，先以 PCA 萃取出 6 個子項目，分別為信用風險(credit risk)、流動性風險(liquidity risk)、市場風險(market risk)、債券殖利率曲線、貨幣與信用(money and credit volumes)、銀行放款行為(bank lending behavior)等，其中信用風險子項目包含 5 個金融市場中有/無擔保的信用差距變數；流動性風險子項目則是包含外匯市場與政府公債等 3 個變數；市場風險子項目包含 14 個股票市場波動度之變數。此 3 子項目主要衡量金融市場壓力。而貨幣與信用子項目包含信用、流動性、金融中介槓桿程度等 9 個變數；銀行放款行為子項目則是以銀行放款調查(BLS)資料為主，納入 32 個衡量銀行放款狀況之變數。爾後，再透過隨時變(time-varying) 權重⁴組成金融情勢指數(composite indicator of financial conditions, CIFIC)，分析金融情勢與總體經濟衰退風險之關係。

⁴ 採用與時變權重可捕捉子項目間的變動關係，亦即當子項目同方向變動時，會給予較大權重；子項目若朝不同方向變動時，則給予較小權重。

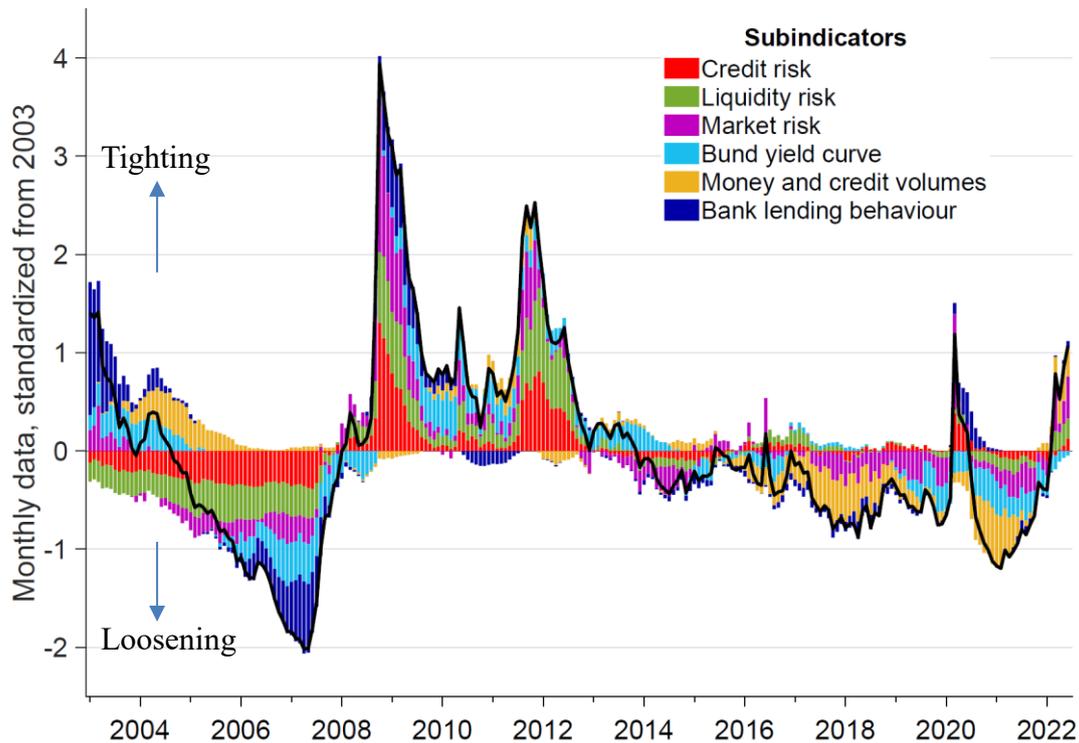
樣本期間自 2003 年 1 月起，CIFC 大於 0 表示金融情勢較平均更為緊縮；CIFC 小於 0 表示金融情勢較平均寬鬆。圖 5 為德國央行 CIFC 與其子項目之走勢，德國金融情勢歷經 4 次較嚴重的緊縮狀態，分別為 2000 年初德國金融危機、2008 年全球金融危機、2010 年起之歐債危機，與 2020 年 COVID-19 衰退。

Metiu (2022) 研究發現德國金融情勢與美國及歐元區的金融情勢有強烈的同步現象，CIFC 與美國 Chicago Fed NFCI 之相關係數為 0.66，CIFC 與歐元區可反映金融市場系統脆弱性的系統壓力綜合指數(composite indicator of systemic stress, CISS)⁵之相關係數為 0.78。此三指數在全球金融危機、歐債危機與 2020 年 COVID-19 衰退時期，皆同步為較為緊縮狀態，顯示全球資本移動、金融槓桿、信用和資產價格的連動，易導致國內金融情勢會受全球影響大，呼應 Miranda-Agrippino and Rey (2020, 2022) 等文獻；僅 CIFC 在 2000 年初德國金融危機時呈現較為趨緊，此為德國國內特有的狀況。此外，若從該研究預測誤差變異數分解結果來看，金融衝擊(financial shock)可解釋 CIFC 約 30% 的變動，為最大影響；其次則為與景氣循環有關的投資衝擊與需求面衝擊，各約可解釋 CIFC 20% 的變動。而供給面衝擊與貨幣衝擊則影響較小。

2022 年起德國央行之金融穩定報告(Financial Stability Reviews) 納入 CIFC，用以捕捉德國整體金融情勢的變化。

⁵ 詳 Holló, et al. (2012)。該文編製歐元區日頻與週頻 CISS，採用 5 個金融系統部門(包含金融中介部門、貨幣市場、股票市場、債券市場與外匯市場)共 15 個變數，以 PCA 萃取 5 主組成分，再以其對產出衝擊的反應函數當作權重，編製歐元區 CISS。

圖 5 德國央行 CIFC 與其子項目



資料來源：Metiu (2022)

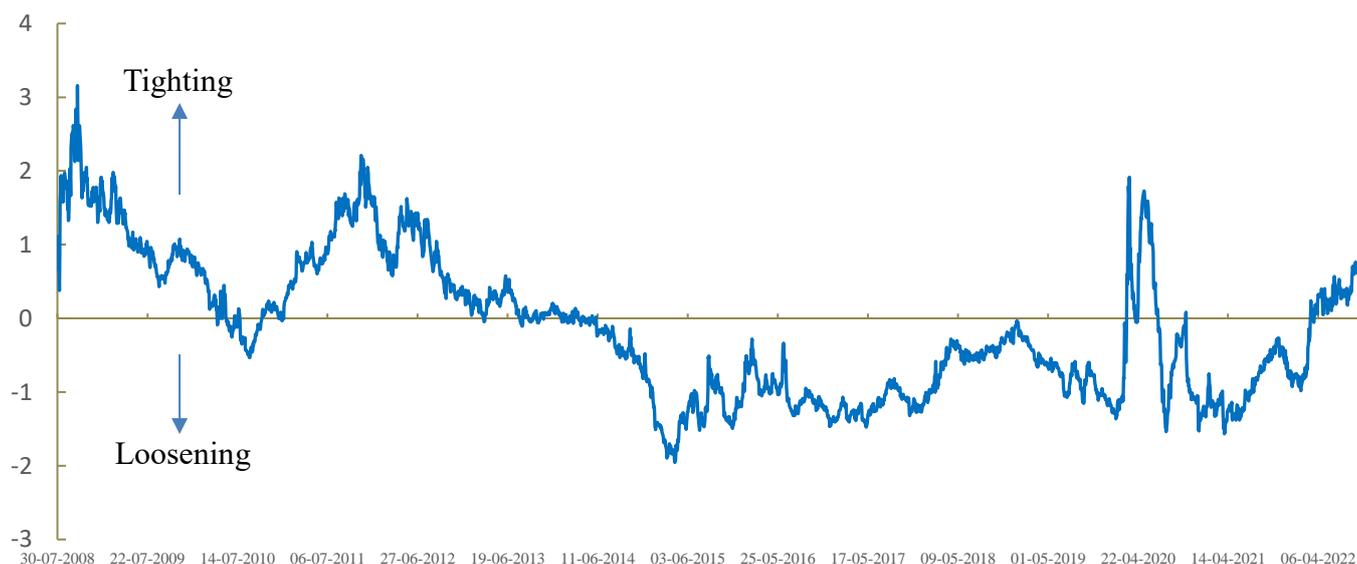
(四)法國央行

法國央行參考 Petronevich and Sahuc (2019)，編製歐元區日頻率之 FCI，納入利率(6 個)、信用(4 個)、股價指數(2 個)、不確定性(2 個)、通膨指標(2 個)與匯率(2 個)等共 18 個變數，Petronevich and Sahuc (2019)認為 FCI 應具備能及時捕捉潛在風險的成分，反映快速變化的金融體系，因此，法國央行之歐元區 FCI 以條件波動度(conditional volatility)為依據，將愈不穩定的成分給予愈高的權重。實際估算時，首先將這 18 個變數以 PCA 萃取出 6 個主成分，再以 GARCH(1,1)估計每個主成分的波動度，並依其波動度占全體波動度的比率當作權重，將 6 個主成分加權後建構歐元區 FCI。

圖 6 為法國央行之日頻率歐元區 FCI，當 FCI 大於 0，表示金融情勢較平均緊縮；當 FCI 小於 0 則表示金融情勢較平均寬鬆。歐元區

FCI 明顯於 2008 年全球金融危機、2010 年起之歐債危機較為緊縮，2014 年起受到 ECB 採行多項非傳統貨幣政策，如定向長期再融通操作(target long-term refinancing operations, TLTROs)、擴大資產購買計畫(asset purchase programmes, APP)等影響，FCI 轉呈寬鬆狀態且維持一段較長的寬鬆時間，直至 2020 年 COVID-19 與近期金融情勢才再轉為較緊縮狀態。

圖 6 法國央行 FCI



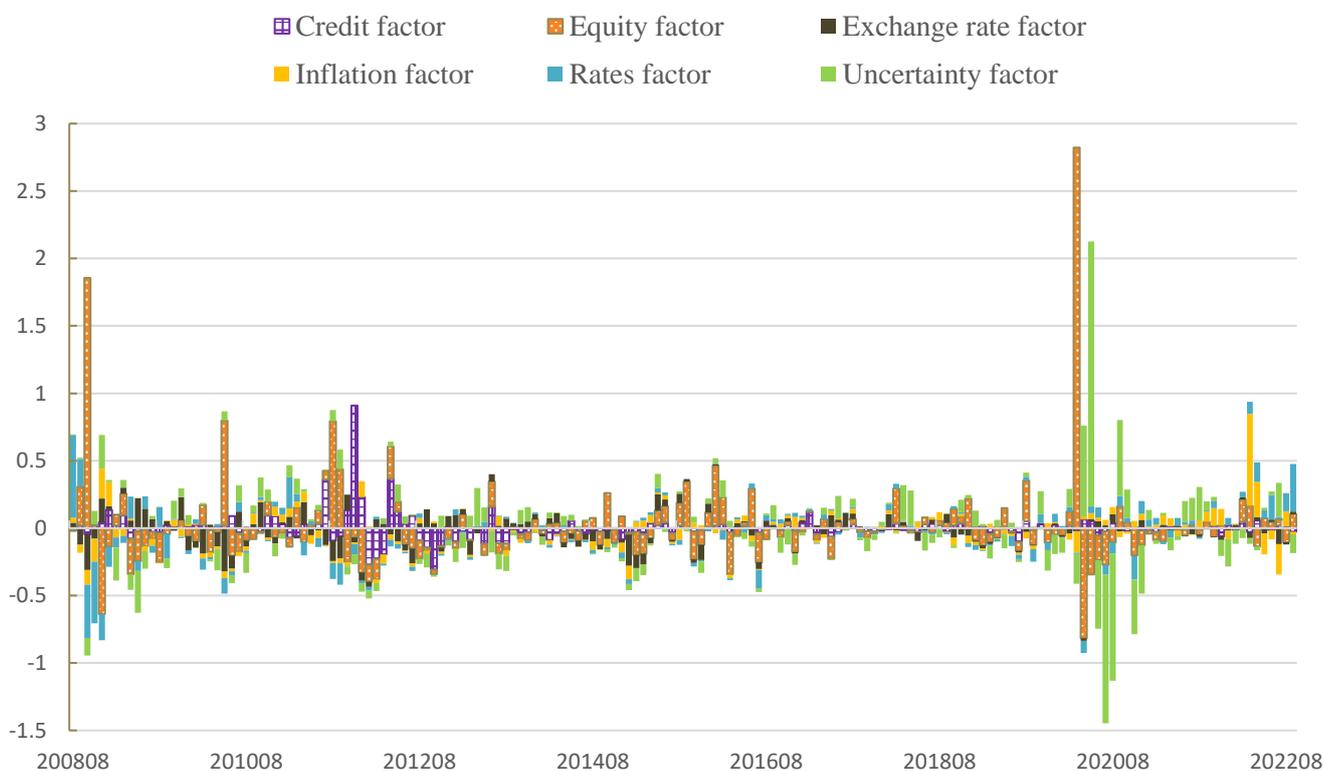
資料來源：法國央行

法國央行認為，法國央行之歐元區 FCI 與 Goldman Sachs 歐元區 FCI 相較，兩者相關係數雖為 0.93，但差異較大在 2010 年股市驟跌、2012 年歐債危機與 2015 年歐元區擴大實施 APP 時，Goldman Sachs 歐元區 FCI 較無法像該央行編製的 FCI 容易捕捉波動的轉折點。

法國央行歐元區整體 FCI 資料為日頻率，惟日頻資料可能因市場反應過大而夾雜非資訊的雜訊，因此，在 FCI 中 6 個主成分貢獻資料僅為月頻資料。圖 7 為月資料之法國央行歐元區 FCI 與其主成分，2020 年 COVID-19 時 FCI 緊縮效果主要來自不確定性，其次為股價因子。整體而言，以股票市場對 FCI 變動之影響最大，約 28%，其次

為匯率成分影響 16%，不確定性成分影響 15%，其餘主成分之影響為 13~14%。法國央行之歐元區 FCI 資料可至其官網取得。

圖 7 法國央行 FCI 主成分



資料來源：法國央行

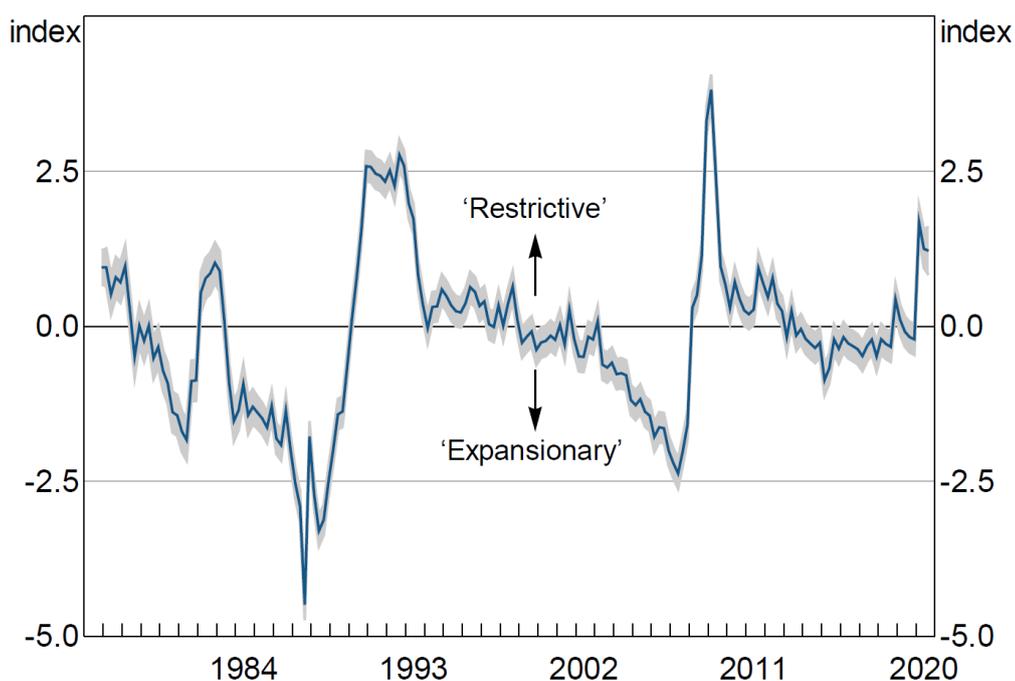
(五)澳洲央行

澳洲央行參考 Hartigan and Wright (2021)，認為金融情勢為整體情勢的概括，不僅需納入從歷史資料上發現對總體經濟有影響的金融變數，還須包含潛在風險來源的變數，因此，澳洲央行納入包含資產價格(18 個)、利率與利差(17 個)、信用與貨幣(14 個)、債券(11 個)、金融槓桿(5 個)、銀行部門風險(4 個)、金融系統複雜度(2 個)、金融市場風險(2 個)、企業與消費者對金融情勢展望之調查(2 個)等共 75 個變數，採用 Doz et al. (2011, 2012)兩階段動態因子模型(two-step dynamic factor model)，以準最大概似法(quasi-maximum likelihood)估

計澳洲 FCI。樣本期間自 1976 年第 3 季起，為季頻率資料，但由於資料取得的問題，為非平衡資料(unbalanced)，一開始僅有 37 個變數，至 1987 年增加 54 個，自 1994 年中起才有完整的 75 個變數資料。

圖 8 為澳洲央行 FCI 走勢圖，FCI 大於 0 表示金融情勢較平均緊縮；FCI 小於 0 表示金融情勢較平均寬鬆。1980 年代後期澳洲 FCI 為寬鬆狀態，主要係因信用與資產價格(特別是住宅與商用房地產價格)快速成長；至 1990 年代經濟衰退時，信用供給萎縮，資產價格暴跌，致 FCI 轉為緊縮狀態。1990 年代中期到 2000 年中期，FCI 維持在 0 附近，呼應全球大溫和時期(Great Moderation)。FCI 在全球金融危機大幅緊縮，而近年則是因 COVID-19 疫情爆發，FCI 急遽惡化，特別是由於資產價格下跌，信用疲弱與金融市場風險上升，惟此段金融情勢並不如全球金融危機期間的緊縮，除了歸因於央行與政府財政的重大政策因應措施外，亦反映自全球金融危機以來金融體系韌性的提高(Kearns 2020)。

圖 8 澳洲央行 FCI



資料來源：Hartigan and Wright (2021)

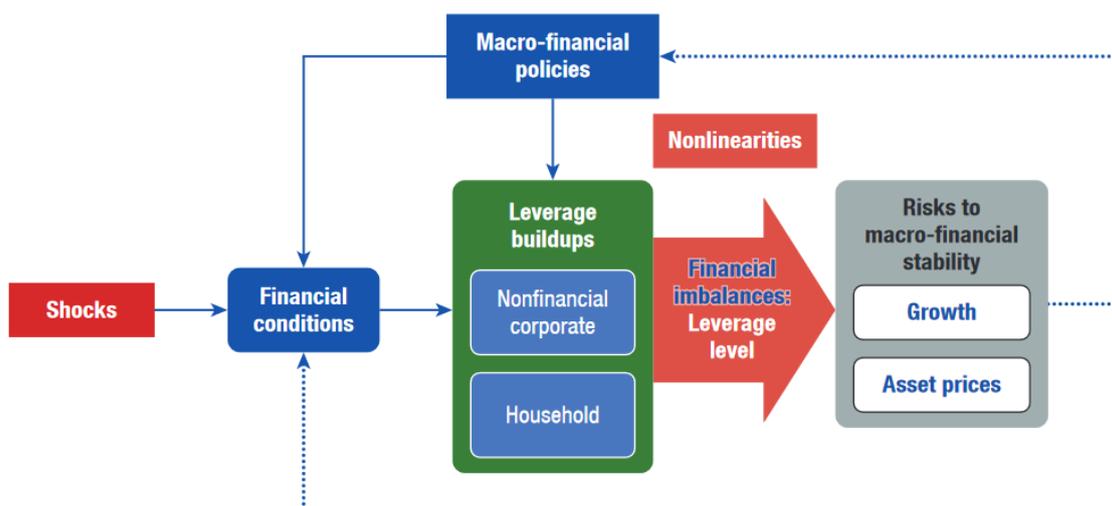
說明：灰色區域為 95%信賴區間。

三、FCI 與經濟下行風險預測

金融脆弱性會增加經濟成長的風險，亦即一旦高度金融脆弱，將會擴大和延長不同衝擊對經濟成長的影響。因此，在金融危機期間，當巨大的損失或違約威脅到銀行業時，金融體系不僅無法支持實體經濟運作，反而會進一步傳播衝擊，而非吸收衝擊(Claessens et al., 2011, 2012；Borio, 2014；Brunnermeier and Sannikov, 2014；Krishnamurthy and Muir, 2017)。許多文獻亦表明全球金融危機突顯高度金融脆弱性對經濟成長的衝擊，例如 López-Salido et al. (2017)證實過熱的信用市場預示未來兩年內實際 GDP 的衰退；Mian et al. (2019)發現信用快速增加，尤其是家庭借款增加，將預期未來中期 GDP 成長低緩。Baron and Xiong (2017)則發現信用擴張伴隨股價泡沫破滅將導致更深的經濟衰退。Krygier and Vasi (2021)發現金融情勢緊縮與脆弱程度上升時，會大幅增加未來經濟衰退的機率。

圖 9 為金融情勢與經濟下行風險之關係。金融情勢、總體金融穩定政策與槓桿堆砌(leverage buildups)彼此相互影響，其中槓桿衡量金融脆弱性。金融情勢寬鬆，金融中介與市場傾向承擔更多風險與更願意將錢貸放出去；而廠商與家計單位則亦傾向借更多的錢，致使整體槓桿上升；而總體金融穩定政策(包含貨幣、總體審慎與財政政策)或透過金融情勢，亦或直接影響槓桿效果，進而影響總體經濟。因此，當面對金融衝擊時，金融情勢轉為緊縮狀態，金融風險會因為資產價格急速修正與去槓桿化(deleverage)而急速上升，導致未來經濟成長下行風險上升。且在衝擊前的債務水準愈高，破壞性的去槓桿化愈強，經濟下行風險程度愈高(IMF, 2021)。

圖 9 金融情勢與經濟下行風險之關係



資料來源：IMF (2021)

有鑑於此，Adrian et al. (2016, 2019)提出經濟成長風險值(Growth-at-Risk, GaR)架構，該文認為政策制定者不僅關心經濟成長上行風險的預測，亦關注其下行風險，以及預測對意外衝擊的敏感程度，從而擬定妥適之貨幣政策。然而，一般的總體經濟預測通常僅提供條件平均值(conditional mean)的點估計(point estimate)結果，若僅觀察點預測值，可能會忽略不確定性因素的影響，而這些風險最終會隨著時間的推移影響點預測值。

再者，全球金融危機突顯金融體系高度脆弱性對經濟成長的衝擊，鑑於央行需維護金融穩定的法定職責，須在經濟成長與其下行風險間進行權衡，央行亦重視極端事件對經濟成長的影響。GaR 概念即是將財務理論中的風險值(Value-at-Risk, VaR)模型擴充為 GaR 方法，而 VaR 係指給定一既定的信賴區間，在一定期間內面臨最大的預期損失。GaR 架構將其模型擴充，考量目前的總體金融情勢，在未來 h 期，一定信賴區間下(通常為 95%或 90%)可能的經濟成長率預測值，亦即 GaR 值為在極端狀況下的經濟成長率預測值。方程式如下：

$$\Pr(y_{t+h} \leq GaR_{\alpha} | \Omega_t) = 1 - \alpha$$

其中 y_{t+h} 為未來 $t+h$ 期的經濟成長率； Ω_t 為目前擁有的訊息集，亦即目前的總體金融情勢； $1-\alpha$ 為信賴區間。舉例說明此方程式，在 $h=1$ 下， $GaR_{95\%} = -10\%$ 表示未來1期有5%之機率會使GDP成長率下降超過10%。

該文再進一步依據QR方法在不同風險下的配適結果，估算skewed- t 分配，用以建構金融情勢(以Chicago Fed的NFCI衡量)或總體變數(如實質GDP成長率)對未來GDP成長的機率分配預測。Adrian et al. (2016, 2019)發現GDP成長率具高度尾端風險(tail risks)，尤其呈現偏向左尾的不對稱性。而不斷惡化的金融情勢會使GDP成長的條件波動度增加與條件均值下降，導致GDP成長的低分量會隨金融情勢惡化而變化，但較高分量隨時間卻保持穩定的狀態。此外，GDP成長的上行風險在大多數時期較低，然而，隨著金融情勢愈緊縮，下行風險將逐漸增加。該文認為金融部門的擴大機制(amplification mechanisms)⁶是造成經濟成長脆弱性的主因。

GaR架構有助政策制定者在不同條件下對GDP成長預期分配結果進行建模。因此，Prasad et al. (2019)將IMF (2017b)應用於跨國分析所採行的GaR架構作一有系統的介紹，並提供實際運作的指引，強化總體金融分析與政策討論。該文以Python為計算基礎，說明IMF開發建構於Excel表的GaR模型。

首先，Prasad et al. (2019)透過PCA或LDA將預測經濟成長風險的變數分組(partition)後，進行降維，這些變數分類別屬於：(1)與金融情勢相關之變數，旨在捕捉嵌入資產價格的風險、獲得融資的難易程度、融資成本和財務壓力程度，變數包含股價報酬、房價成長率、利

⁶ 金融部門的擴大機制係指負向衝擊透過金融部門傳遞(如資產價格、資產負債表等機制)會對實體經濟活動造成更大、更持續之影響。

差、期限貼水、債券波動度、股價波動度與根據調查資料之銀行借貸標準(lending standards)、長期實質利率、外匯市場變數等，如同文獻中常用於衡量 FCI 之變數；(2)總體金融脆弱變數，強調槓桿指標，刻劃總體金融不平衡(如信用缺口、逾放比、房價所得比、外部融資缺口等)、借款人跨部門與金融部門資產負債表的脆弱性(如企業與家計單位之資產負債比、銀行資本適足率等)；與(3)其他因素，包含全球 VIX、全球、美國、中國大陸等經濟成長率，以及原物料價格等，此因素對小型開放經濟體相對重要。

其次，將前述重要變數萃取出來的因子進行 QR。最後，依據 QR 結果估算 *skewed-t* 分配，配適未來經濟成長率，計算 10% 的 GaR 值。採用 GaR 分析，可提供政策制定者量化風險情境的參考，作為經濟衰退早期預警系統。GaR 模型最重要的優勢係能量化總體金融對經濟成長的風險，評估總體金融因素影響未來 GDP 成長整體分配的相對重要性，並監測經濟活動風險如何隨時間演變。值得注意的是，Prasad et al. (2019)認為 GaR 並非結構模型，不可用來進行因果推論(causal inferences)。

而 Adrian et al. (2022)進一步將 Adrian et al. (2019)方法擴充，以 11 個先進經濟體資料，探討金融情勢與未來 GDP 成長分配之間的關係。該文證實金融情勢對 GDP 成長率分配具有良好的預測能力，FCI 對低分量(第 5 分量)比對中分量 GDP 成長之影響大；且金融情勢在短、中、長期有不同的影響，短期而言，寬鬆的金融情勢預示高經濟成長和低度波動性，而在中長期，經濟成長將放緩，且波動度增加。此發現亦與波動動態和金融危機的文獻(Brunnermeier and Sannikov, 2014)一致，亦即「波動度的矛盾(volatility paradox)」，低波動期後往往會在未來帶來更大規模總體經濟的收縮。

除了 IMF 外，一些主要經濟體央行目前皆有以 GaR 架構，追蹤

在當前金融情勢下預期經濟成長的風險，如 BoE (Aikman et al., 2019)、新加坡貨幣管理局 (Monetary Authority of Singapore, MAS) (MAS, 2019)、捷克國家銀行 (Czech National Bank) (Szabo, 2020)、加拿大央行 (Duprey and Ueberfeldt, 2020)、ECB (Figueres and Jarocinski, 2020)、愛爾蘭央行 (Bank of Ireland) (O' Brien and Wossner, 2021)、澳洲央行 (Hartigan and Wright, 2021)、義大利央行 (Alessandri and Di Cesare, 2021) 與法國央行 (Ferrara et al., 2022)。

以法國央行為例，Ferrara et al. (2022) 考量金融變數多屬於高頻資料，因此擴充 Adrian et al. (2019) 方法為日頻 GaR。該文採用衡量總體金融連結的 FCI (已於前文介紹) 與可反映金融市場系統脆弱性的 CISS，應用貝氏混合頻率資料抽樣分量迴歸 (Bayesian mixed-data sampling MIDAS quantile regression) 模型估算 10% 的 GaR 值，進行即時下行風險預測。該文實證結果發現，日頻 GaR 指標具有良好的 GDP 即時預報 (nowcasting) 功能；可提供 GDP 衰退的早期預警訊息，且可用以評估每日貨幣政策的效果。在 COVID-19 疫情大流行爆發的初期六個月內，日頻 GaR 指標已提供即時的歐元區 GDP 尾端風險。該指標目前為法國央行用來評估金融情勢與金融脆弱性對 GDP 衰退風險的基礎。

澳洲央行則是依循 Hartigan and Wright (2021) 乙文，再進一步以 FCI 建構 GaR 模型，預測澳洲未來經濟成長的下行風險。由於金融情勢對未來總體經濟的影響是不對稱的，採用 GaR 模型主要希冀能量化危機的損失，亦即當經濟體面臨金融危機時，經濟損失會有多大。該文以 FCI 評估 5 個重要總體經濟變數，包含實質 GDP 成長率、家庭消費成長率、投資成長率、就業成長率與失業率之風險。實證結果發現，FCI 對未來經濟活動確實具不對稱影響，對下行風險比上行風險影響更大。FCI 對澳洲 GDP 成長率、就業成長率的下行風險，以

及失業率的上行風險具有良好的預測能力；惟對家庭消費與投資之下行風險解釋力較少。

2020 年爆發全球 COVID-19 大流行，GaR 架構的研究更為廣泛。例如，Barro et al. (2020) 應用 GaR 架構量化 1918-1920 年西班牙流感導致的預期產出損失，並以前述量化結果進一步分析 COVID-19 對預期總體經濟風險之影響。De Santis and Van der Veken (2020) 亦以 1918-1920 年西班牙流感帶來的經濟衰退為例，證實金融變數確實可提高對 GDP 成長率的預測能力，且經濟活動減弱不一定是因為實際 GDP 成長的條件均值產生變化，而相反地，卻可能是因為分配的更高階動差變動。

Alessandri and Di Cesare (2021) 則使用 GaR 作為 COVID-19 於義大利案例之研究。該文實證結果發現金融市場反應太慢，即使是在相對較短的時間範圍內，也很難證實因疫情大流行導致後來的經濟成長下行風險之增加。

而愛爾蘭央行以 O'Brien and Wossner (2021) 研究，發現愛爾蘭未來產出成長受當前金融情勢(以 FCI 衡量)和金融脆弱性(以信用缺口衡量)很大的影響。金融情勢變化顯著影響經濟成長的鄰近風險(near-term risks)，而中期風險則更依賴金融脆弱程度，尤其是長期信用的過度成長。

Krygier and Vasi (2021) 以 GaR 架構，分析總體經濟情勢對瑞典未來經濟成長的尾端風險之預測。該文從金融穩定的角度，以系統風險指標(systemic risk indicator, FSI)追蹤不同市場的風險與脆弱性；以 FCI 反映金融市場的動態，實證結果發現，金融情勢緊縮與金融脆弱程度上升時，會大幅增加瑞典未來經濟衰退的機率。該文續將模型延伸，以全球金融危機與 COVID-19 為例，發現 FSI 與 FCI 對全球金融危機

導致的經濟衰退具有良好的預測能力，惟 COVID-19 並非起因金融不平衡，因此，金融變數對 COVID-19 的預測能力仍有侷限。

日本銀行(Bank of Japan, BoJ)亦有相似的研究，在其 2018 年 10 月金融系統報告(Financial System Report)首度引入 GaR 架構視覺化分析金融脆弱性對經濟的下行風險(BoJ, 2018)。BoJ 以金融缺口(financial gap)刻劃金融脆弱程度，金融缺口以 14 個金融活動指標，包含股價、房地產價格、企業與家計單位信用、民間投資、M2 等去除趨勢值後依據變數彼此相關性給予權重後建構。BoJ 之 GaR 架構與其他主要央行略不同，其以產出缺口變動當作衡量經濟活動指標，採 QR 估計，結果發現金融缺口愈大對經濟下行風險之影響高於上行風險；且短期，金融缺口擴張會抑制經濟下行風險，但長期金融缺口的擴大卻會快速增加經濟下行風險。值得注意的是，BoJ 認為 GaR 方法利用過去歷史經驗提供未來經濟下行風險之機率概況，並無傳遞機制之意涵；再者日本資料起自 1983 年起，GaR 方法恐無法捕捉非因金融脆弱性(如 COVID-19)引發之經濟衰退。

BoJ 進一步於 2022 年 10 月金融系統報告中(BoJ, 2022)再度說明 GaR 結果，短期日本國內金融缺口增加可支持經濟成長，而國外金融情勢緊縮將帶來下行壓力，進而使中長期之經濟下行風險轉而大幅增加，因此，日本經濟成長之機率分配偏向左尾。

然而，有些文獻認為金融指標恐無法提供足夠預測尾端風險之訊息，如 Loria et al. (2019)、Plagborg-Møller et al. (2020)等。Plagborg-Møller et al. (2020)衡量金融指標與美國未來 GDP 成長分配間的非線性關係。該研究發現，金融指標並無提供準確的尾端風險預警能力，對經濟成長分配的更高階動差預測能力不佳。該文亦發現，即使金融訊息可能有助於即時(real time)預測 GDP 成長分配，但金融市場似乎沒有包含大量關於 1 季後 GDP 成長的前瞻性訊息。

Loria et al. (2019)以混頻動態因子模型(mixed-frequency dynamic factor model)，從美國的金融與總體變數中(包含波動率指數 VXO、3 個月 Libor 利率與 3 個月國庫券之利差、債券超額溢價、工業生產、零售銷售額、PMI 組成指標中的新增訂單、初次申請失業救濟金人數等)分別萃取出金融與總體因子，探討衝擊在經濟成長之不對稱風險中的角色。該文將萃取出的金融與總體因子以 QR 捕捉低(第 10 分量)、中(第 50 分量)與高(第 90 分量)分量下之經濟成長率，實證結果發現，除了持續惡化的金融情勢外，總體經濟活動減緩亦會使經濟前景尾端風險之機率上升，顯示金融情勢可能並非唯一影響經濟成長下行風險之因素，此結果呼應 Caldara et al. (2020)及 Plagborg-Møller et al. (2020)等文獻研究成果。

惟前述文獻並沒有探討造成經濟成長風險具不對稱性的原因，或是說明衝擊之傳遞機制，有鑑於此，Loria et al. (2019)進一步在 QR 基礎下以 local projection 方法，探討面對負向的供給面衝擊與需求面衝擊(如貨幣政策衝擊與信用利差衝擊)時，不同分量下經濟成長率之反應。實證結果發現，負向的供給面與需求面衝擊不僅會使中分量之經濟成長下降，更會讓經濟成長的尾端風險機率大幅上升；而較高分量下的經濟成長則較為穩定。因此，對低分量下的經濟成長而言，負向衝擊會使其大幅下降。此外，該文模擬經濟體面臨嚴重金融危機的情形，探討負向衝擊對經濟成長風險的傳遞機制。結果發現，當金融恐慌(financial panic)發生時，資訊不對稱使逆選擇與道德風險問題惡化，金融市場無法有效率運作，致資金多流往較無效率的企業或家計單位，阻斷正常企業借貸，因而使投資與經濟成長急遽下降。此結果顯示，金融情勢惡化對低分量下經濟成長之影響遠大於中分量或高分量，因此，金融危機與經濟衰退具高度相關。

四、台灣 FCI 文獻

與國際文獻相較，目前研究台灣 FCI 文獻亦不少，惟組成變數、方法略有所差異。早期的研究包括徐千婷(2008)；全球金融危機後發展的台大-國泰產學合作計畫(2011)、張天惠(2012)、管中閔等(2014)。近年則有黃裕烈等(2019)與張天惠與朱浩榜(2020)。徐千婷(2008)將原先 MCI 納入房屋單價、信義房價指數、股價與股票總市值占名目 GDP 比率等變數，採用單一方程式、VAR 模型與 ARDL 估算 FCI 權數，以編製 FCI。該文實證結果認為以縮減式模型估計之 FCI 預測能力較 MCI 佳。台大-國泰產學合作計畫(2011)則考慮股票、利率與匯率 3 個市場，共 18 個金融變數，採用 PCA 編製 FCI；該機構定期公布 FCI，衡量整體金融情勢，並預測未來走向。

張天惠(2012)則採用 Forni et al. (2005)的一般化動態因子模型 (generalized dynamic factor model, GDFM)，考慮匯率、利率與股票市場共 12 個金融變數，並根據變數特性區分不同市場群組，分別對各市場變數估計後編製 FCI。區分市場之 FCI 不僅可顯現變數之市場結構，還可描繪貨幣傳遞機制、金融情勢與總體經濟活動間的關係，較傳統未區分市場之 FCI 具有較佳的樣本外預測能力。管中閔等(2014)採兩步驟建構台灣 FCI，首先以 Bai and Ng (2004)提出之 PANIC (Panel Analysis of Nonstationarity in Idiosyncratic and Common components)模型，估計股票、貨幣與外匯市場中代表價與量的 6 個主要變數，再透過景氣波動與各變數的迴歸分析，估計 6 個變數對 FCI 的組合權數。該文實證結果發現 FCI 具有領先大多數實質面總體變數的特性。

近年如黃裕烈等(2019)參考 Chicago Fed 編製 NFCI 的概念，將 273 個變數分別區分為信用(包含貨幣、匯率、信用等變數)、金融槓桿(leverage) (包含資本市場相關的財經變數)與風險(市場與風險相關變數)等三面向，採用管中閔等(2014)方法，建構台灣 FCI。爾後，利

用 probVAR (VAR-augmented probit model)模型，預測未來經濟衰退的可能性；另以 IMF 開發 Excel-GaR 模組，配適未來 GDP 成長的機率分配，以及估算 10%的 GaR 值。實證結果發現，FCI 為一領先指標，可提供極短期經濟衰退機率的預測。該文並以 2018 年資料為基礎，預測 2019 年年底 GDP 成長率有 10%機率为-1.43%。

許多文獻證實，過度且持續的信用創造及資產價格泡沫為觸發金融危機的重要因素，因此，張天惠與朱浩榜(2020)乙文與過去台灣文獻不同，除了採用常見的金融變數外，並納入房地產市場與銀行信用等，共 46 個金融變數，以 Doz et al. (2011)兩階段動態因子模型，建構我國 FCI。該文以 QR 檢驗 FCI 與未來經濟成長的關係，以及利用接收者操作特徵(receiver operating characteristic, ROC)曲線測試 FCI 預測經濟下行風險的準確性。最後再以 2008 年全球金融危機與 2015 年年底之第 14 次景氣衰退為例，說明 FCI 的確可提供未來經濟成長面臨下行風險的資訊。該文實證結果顯示，FCI 顯著領先實質面的總體經濟變數，且可提供經濟預測的額外資訊。當未來經濟成長的下行風險愈高，FCI 的領先性質將愈形明顯；FCI 對於經濟活動陷入衰退之預測能力佳，且納入房地產與信用變數之 FCI 表現更勝一籌。

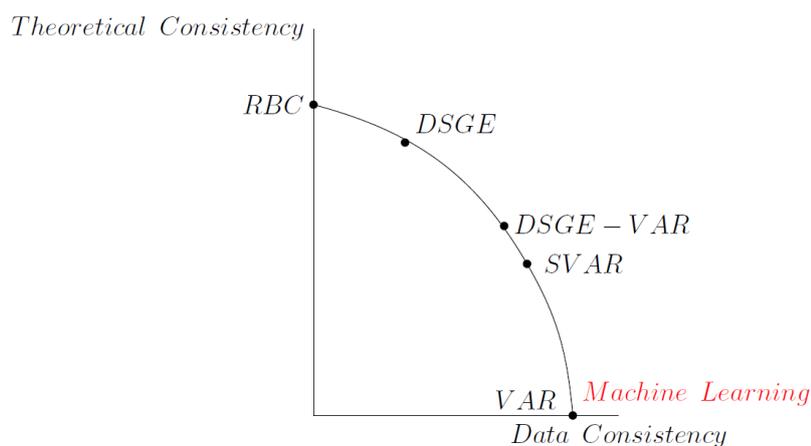
參、機器學習法之發展與應用

機器學習是一門涵蓋電腦科學、機率論、統計學等多項領域的技術，概念最早源自於 McCulloch and Pitts (1943)與 Rosenblatt (1958)，McCulloch and Pitts (1943)嘗試透過大腦神經元運作原理，建立數學模型；而 Rosenblatt (1958)則是依據此模型，調整神經元間連結強度的學習規則，而成為感知器(perceptron)，為開啟機器學習研究的先河。1980 年代後期始，受電腦硬體儲存成本下降、運算能力增強，與能處理大量的數據，機器學習再次興起。

機器學習為人工智慧(AI)的一個分支，旨在使用統計、演算法等從數據中學習，發現隱藏關係，從而做出更加準確的預測和決策，而非以傳統方式進程式編碼。與傳統模型的主要差異在於，傳統模型是將規則與資料放入模型以得到結果(答案)；機器學習則是將資料與結果(答案)放入機器學習以獲得規則。與傳統迴歸模型須具經濟理論基礎之設定相較，機器學習不預先假設資料間的結構關係，而是從大量資料中學習，捕捉資料間的關係，且能處理高維度資料(high-dimensional data)，進行模型篩選(model selection)，其預測績效多優於傳統迴歸模型。

若是與央行執行貨幣政策與評估政策效果時，常使用的總體經濟模型相較，央行面臨著選擇模型是理論一致性(theoretical consistency)或資料一致性(data consistency)間的權衡(trade-off)，如圖 10，實質景氣循環(real business cycle, RBC)模型與動態隨機一般均衡模型(DSGE)具有強而有力的理論基礎，而未限制 VAR 模型與機器學習則是依賴資料(data-driven)(Genberg and Karagedikli, 2021)。

圖 10 央行常見的模型



資料來源：Genberg and Karagedikli (2021)

機器學習因界定問題的方式而分為三種，分別為監督式學習、非監督式學習與增強式學習(reinforcement learning)。其中，非監督式學習指的是只有觀測值(x)，沒有決策(y)可供參考，亦即從歷史觀測值中找出潛在規則，而非從歷史資料學習怎麼做決策，如因子模型(factor model)、PCA 與階層式分群(hierarchical clustering)等。而監督式學習著重於尋找觀察值(x)與決策(y)之間的關聯性，若是以數學式表示，監督式學習就是在尋找函數 $y=F(x)$ 中的 F ，例如正規化迴歸(regularized regression，如 OLS、LASSO、脊(ridge)迴歸)、支持向量機(support vector machine, SVM)、決策樹(decision tree)、隨機森林(random forest, RF)等。兩者差異主要在於提供的資料是否有標註(target)。而增強式學習如同非監督式學習，不標註資料，而是透過每次反饋的好壞，機器自行逐步修正學習，以取得最大化的預期利益，得到正確的結果。

機器學習雖可處理大量且複雜的資料，降低人為錯誤，提高工作效率與預測的準確度，惟相當依賴大量且高品質之資料，計算耗時且應用上仍有一些侷限與挑戰，例如：(1)容易出現過度配適(overfitting)，即演算法過度依賴訓練集合而產生偏誤(bias)；(2)維度的詛咒(Curse of

Dimensionality)，參數數量隨著輸入特徵的數量呈指數增長；(3)尚須人為介入，方能達到最佳效果；(4)其結果難以解釋，無法了解因果關係，無經濟意涵；(5)尚無一種機器學習可在所有方面都是最好的，須不停嘗試；(6)較缺乏標注的數據，使機器學習訓練更為困難。

考量機器學習快速發展與應用廣泛，表 1 為常見的機器學習方法比較，本專題研究依據其類別為(非)監督式、適合用於迴歸預測或是特徵分類、模型為有/無母數法、可處理資料量大小，以及資料是否須標準化(normalization)等說明，本章第 1 小節將先介紹這些常見的機器學習方法，第 2 小節再進一步說明文獻發展與主要央行在機器學習的應用，尤其有關模型建構、經濟預測、指標編製與協助貨幣政策等方面。

表 1 常見的機器學習方法比較

	類別	適用範圍	有/無母數	可處理之資料量	是否須標準化	說明
正規化迴歸	監督式	迴歸	有	小至大	否	可解釋、易計算但較無彈性
Logit	監督式	分類	有	小至大	否	可解釋、易計算但較無彈性
隨機森林	監督式	迴歸/ 分類	無	小至中	否	可解釋、易計算但易過度配適
支持向量機	監督式	迴歸/ 分類	無	小至中	是	易計算但易過度配適與不易解釋
人工神經網絡	監督式	迴歸/ 分類	半	中至大	是	須大量計算、易過度配適、不易解釋且須大量資料(data hungry)
k-means	非監督式	-	無	小至大	是	維度的詛咒
階層式分群	非監督式	-	無	小至大	是	維度的詛咒

資料來源：Chakraborty and Joseph (2017)，作者整理

一、機器學習之介紹

(一)監督式學習

1.正規化迴歸

線性迴歸係監督式學習的一種，依照訓練資料找出一個最接近各點的線性方程式，並藉由此趨勢線預測出新的資料(測試資料)應該在的位置。

假設線性迴歸模型如下：

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}, \quad \boldsymbol{\epsilon} \sim \mathcal{N}(0, \sigma^2).$$

其中， \mathbf{y} 為 $n \times 1$ 的被解釋變數向量； \mathbf{X} 為 $n \times k$ 的解釋變數矩陣， $\boldsymbol{\epsilon}$ 為常態分配之殘差項； $\boldsymbol{\beta}$ 為待估參數。常用的 OLS 係極小化損失函數(loss function)，

$$\mathcal{L}_{\text{ols}} = \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2, \quad (3.1)$$

若在上式(3.1)中的 OLS 損失函數加上懲罰項 $\lambda\|\boldsymbol{\beta}\|$ ，則可得到 LASSO 的損失函數(Tibshirani, 1996)：

$$\mathcal{L}_{\text{lasso}} = \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2 + \lambda\|\boldsymbol{\beta}\|, \quad (3.2)$$

其中， $\lambda\|\boldsymbol{\beta}\|$ 亦稱為 L1 規範懲罰項(L1 norm penalty term)， λ 為調控參數(tuning parameter)，用於控制係數。

而若在(3.1)式之 OLS 損失函數加上懲罰項 $\lambda\|\boldsymbol{\beta}\|^2$ 以控制係數(Hoerl and Kennard, 1970)，則為脊迴歸之損失函數：

$$\mathcal{L}_{\text{ridge}} = \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2 + \lambda\|\boldsymbol{\beta}\|^2. \quad (3.3)$$

其中， $\lambda\|\boldsymbol{\beta}\|^2$ 亦稱為 L2 規範懲罰項(L2 norm penalty term)， λ 為調控

參數。

LASSO 與脊迴歸調控參數 λ 的概念相同，同樣使各特徵資料的權重受到限制，避免預測結果大量依賴某幾項特徵資料，減少不合理權重出現的機會。而兩者最大的不同在於，LASSO 可使不重要的解釋變數的係數確實為 0；脊迴歸僅能使不重要的解釋變數的係數接近於 0。其原因在於，LASSO 的懲罰項為絕對值總和，但脊迴歸的懲罰項為平方和，因此，脊迴歸的限制條件會形成圓形的可解區域，而 LASSO 的限制條件則會形成菱形的可解區域，進而得到不同的估計結果。

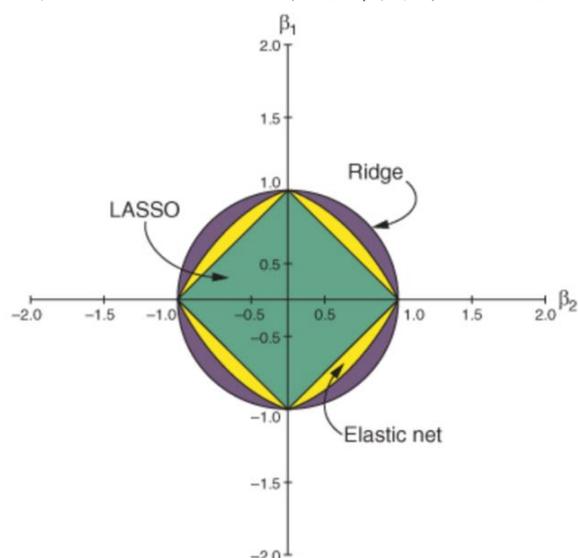
此外，由於 LASSO 與脊迴歸各有優缺，彈性網路(elastic net, EN)綜合 LASSO 與脊迴歸兩者的懲罰項(Friedman et al., 2010)，彈性網路的損失函數為：

$$\mathcal{L}_{\text{ENet}} = \frac{\|y - X\hat{\beta}\|^2}{2n} + \lambda \frac{1-\alpha}{2} \|\hat{\beta}\|^2 + \lambda\alpha \|\hat{\beta}\|, \quad (3.4)$$

其中， λ 、 α 均為調控參數。 λ 的概念與 LASSO 及脊迴歸相同，當 $\alpha = 0$ 時，EN 將回到脊迴歸的損失函數；當 $\alpha = 1$ 時，EN 則回到 LASSO 的損失函數。同樣地， λ 、 α 可透過 AIC、BIC 或均方誤(mean squared error, MSE)等方式挑選。圖 11 為 LASSO、脊迴歸與彈性網路之差異。

EN 綜合脊迴歸懲罰項達到有效正規化優勢以及 Lasso 懲罰項能夠進行變數挑選優勢，可控制多重共線性(multicollinearity)問題，使迴歸模型在解釋變數過多時仍得以執行，同時亦可降低資料的干擾雜訊，得以在尋找較具影響力的變數時，兼顧預測的準確性。

圖 11 LASSO、脊迴歸與彈性網路



資料來源：Rhys (2020)

2. Logit 迴歸

Logit 迴歸(LR)主要在探討被解釋變數(y)與解釋變數(x)之間的關係，但與線性迴歸不同的是，線性迴歸用來預測一連續值，而 Logit 迴歸亦可用來分類。因此，線性迴歸中的 y 通常為連續型變數；Logit 迴歸所探討的 y 則為二元變數(binary variable)，且 x 可以是二元或連續變數。

3. 線性判別分析

LDA 源自 Fisher (1936)⁷，其核心概念為透過投影(projection)的方式降維，依據組內變異最小與組間距離最大為目標，找到一適當的投影軸，將資料點從高維度空間投影至低維度空間，藉以獲得較佳的判定效果。

給定一組自 K 個類別的訓練集 x_1, x_2, \dots, x_n 。定義 μ 為平均值向量； B 為類別間散佈矩陣(between-class scatter matrix)，代表若將每個類別的資料視為一個單獨的資料點(由此類別的平均向量代表)所得到的

⁷ LDA 推導詳見 Bishop (2006)。

散佈矩陣。W為類別內散佈矩陣(within-class scatter matrix)，代表若將每個類別的資料視為一個獨立資料集所得到的散佈矩陣。T為全部資料點的散佈矩陣(total scatter matrix)。以矩陣表示如下：

$$\begin{aligned}\mu &= \sum_{i=1}^n x_i/n , \\ B &= \sum_{i=1}^n n_i(\mu_i - \mu)(\mu_i - \mu)^t , \\ W &= \sum_{i=1}^K \sum_{x \in \omega_i} (x - \mu_i)(x - \mu_i)^t , \\ T &= \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^t \text{ 且 } B + W = T\end{aligned}$$

LDA 之目的希望找到投影向量 v ，亦叫做判定向量(discriminant vector)，希望資料在投影後，隸屬在同一類別的資料點能盡量集中，而類別與類別之間能盡量散開。因此，LDA 定義一個目標函數 $J(v)$ ，經由對此目標函數的最佳化，求取最佳的投影向量 v ，目標函數如下：

$$J(v) = v^t B v / v^t W v \quad (3.4)$$

將式(3.4)以 v 微分，可得當 $(v^t B v) W v = (v^t W v) B v$ 時， $J(v)$ 為極大。在標準化限制式下， $v^t B v$ 與 $v^t W v$ 為純量矩陣，且 $v \propto W^{-1} \mu$ ，極大化問題可由廣義特徵值問題來表示，如下式：

$$B \mu = \lambda W \mu$$

其中 λ 為廣義特徵值(generalized eigenvalue)，將計算出的廣義特徵值由大到小排序，擷取前 r 個廣義特徵值所對應的廣義特徵向量(generalized eigenvector)即為其解。

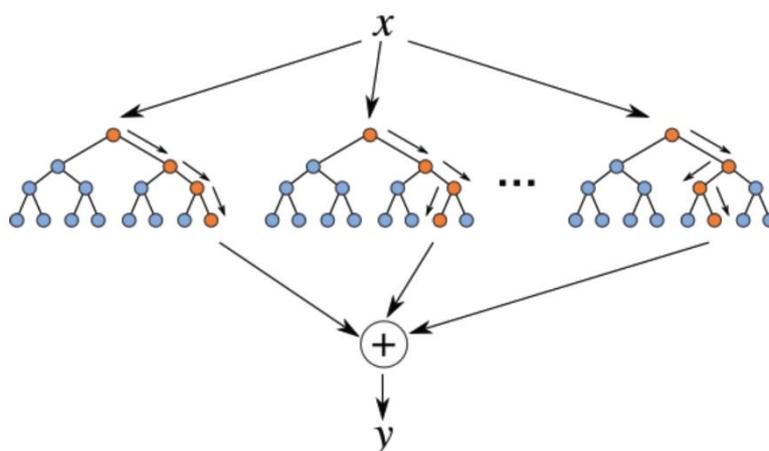
LDA 與因子模型或 PCA 非常相像，都是透過投影將特徵由高維度轉換到低維度。不同的是，LDA 同時考量了被標注的變數，屬於監督式學習。因子模型的目的在保留特徵最大的變異性，LDA 目的則是為了使降維後的資料點更容易被區分。

4. 決策樹

決策樹為常見的機器學習演算法之一，適用於資料的分類、迴歸與預測。決策樹特色為每個分類階段清楚明確，由根節點(root node)開始生成樹狀結構，每個子節點(decision node)代表分類依據，當資料通過節點後會依其屬性被分到不同的分枝上，樹會持續的生成樹枝，直到資料無法再被分類為止，即長出最末端葉子(leaf node)，得到該資料所屬分類。決策樹分類過程透明、結果容易解釋且能實際描繪出整棵樹枝決策過程，因此被廣泛應用。

而隨機森林則由 Breiman (2001)提出，是一個包含多棵決策樹的模型，透過統整所有決策結果，其概念如圖 12。隨機森林透過 Bagging 或 bootstrap aggregating 分別對樣本與特徵進行抽取後放回的隨機抽樣，建立資料子集，並運用這些不同的資料子集隨機建立森林裡一棵棵的決策樹。原始隨機森林之最終結果採用每棵樹結果的平均，因此，後續延伸發展的方法如將表現較好的決策樹給予較高權重之權重森林(weighted forests)、提高運算效能的線上森林(online forests)、排序森林(ranking forests)、集群森林(clustering forests)等(Biau and Scornet, 2016)。

圖 12 決策樹與隨機森林



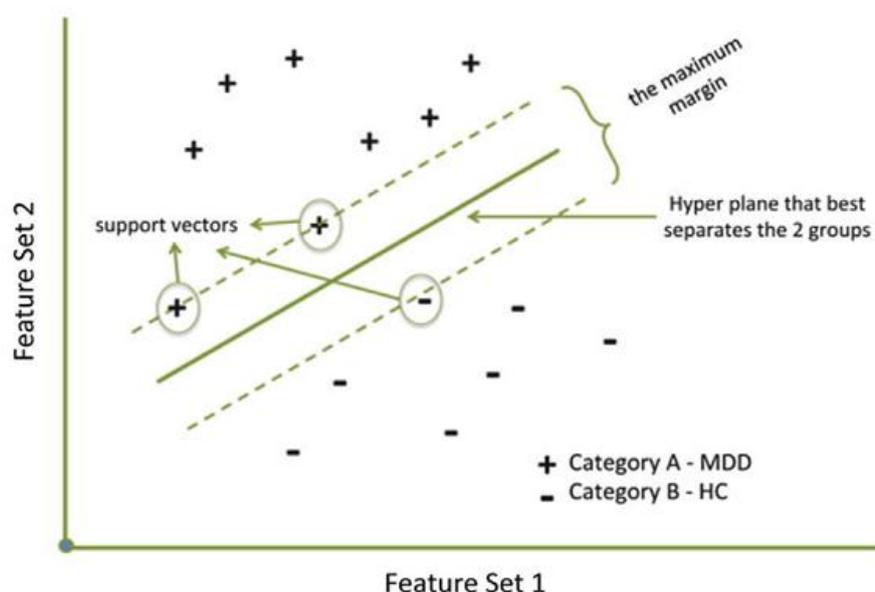
資料來源：Shibitov and Mamedli (2021)

5. 支持向量機

支持向量機主要概念是將資料分類，在資料空間中建構一個最佳的超平面(hyperplane)，能夠讓邊界(margin)最大化，以利區隔兩類資料，又被稱為二元分類器(binary classifier)。「超平面」在二維空間裡係指一條線；在三維空間裡則為一個平面；但在更高維空間中，由於無法觀測到，因此，以超平面一詞概稱。

圖 13 為支持向量機分類之說明，支持向量機主要目的是找到最佳的超平面(中間綠色實線)，並希望區隔兩類資料的邊界距離能愈大愈好，以縮小分類誤差，而落在邊界上的樣本(在容忍邊界內的樣本)即為支持向量(support vector)。由於多數資料分類無法以簡單的線性函數將之區隔，因此，支持向量機利用核函數(kernel function)⁸之特性，將特徵空間映射(mapping)高維度空間，以利找尋最佳超平面。與線性迴歸模型不同的是，支持向量機為盡量極大化邊界，因而不易受到極端值影響，且不會有高度線型重合之問題，有助提高模型分類與預測之準確度。

圖 13 支持向量機



資料來源：Pisner and Schnyer (2020)

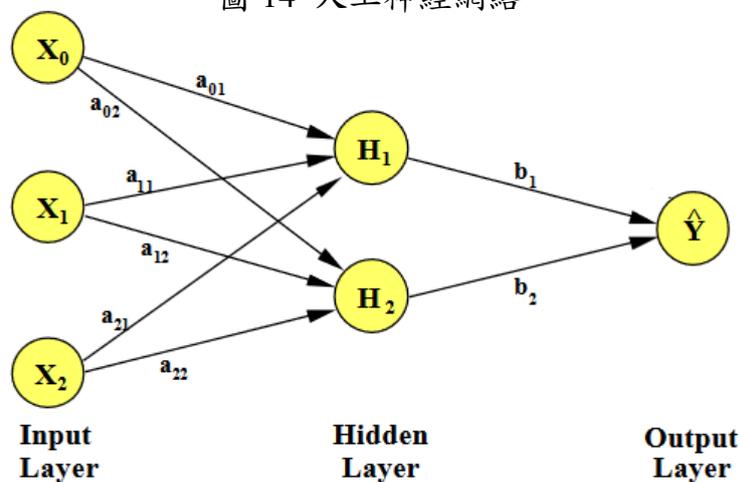
⁸ 核函數包含多項式(polynomial)高斯(radial basis, RBF)等。

7. 人工神經網絡

人工神經網絡(artificial neural networks, ANN)概念源自於人類中樞神經系統，神經網絡由多個神經元組成，相互連接形成網絡，訊息通過神經元間各個節點進行傳遞和處理。ANN 主要目的是模擬人腦的神經元間的互動關係，進而對大數據進行有效的學習和預測，應用於分類與迴歸等領域。

ANN 基本結構包括輸入層(input layer)、隱藏層(hidden layer)和輸出層(output layer)如圖 14。輸入層接收大量資訊，並將其傳遞給隱藏層，隱藏層進一步處理數據並將其傳遞給輸出層，較多隱藏層層數雖能處理複雜問題，但過多的層數易有過度學習之狀況，難以收斂。輸出層產生最終的預測結果或分類。每個神經元可對應多個輸入與輸入資料，但屬同一層的神經元間不互相連接。ANN 依網路架構可區分為前饋式(feedforward)和回饋式(recurrent)，前者為參數從輸入層向輸出層單向傳播，神經元無反向或側向傳遞；後者則允許訊息在不同層間(內)各神經元間來回傳遞。常見的 ANN 類別包含多層感知機(Multi-Layer Perception)、倒傳遞神經網路(back propagation neural networks, BPNN)皆屬於前饋式。

圖 14 人工神經網絡



資料來源：Gonzalez (2000)

(二)非監督式學習

非監督式學習如因子模型、PCA 與階層式分群等，本小節介紹常見的因子模型。因子模型(或 PCA)為機器學習中用來進行降維、特徵選擇(feature selection)或分類的統計方法(Bishop, 2006)。因子模型利用正交轉換(orthogonal transformation)對一系列可能相關變數的觀測值進行線性轉換，從而投影成一組線性不相關變數的值，這些不相關變數稱為主成分(principal components)。以下將簡單說明。

動態因子模型為令 x_{it} 為在第 t 期的第 i 個變數，其中 $i = 1, \dots, N$ 與 $t = 1, \dots, T$ ，動態因子模型方程式為：

$$x_{it} = \chi_{it} + e_{it} = \sum_{j=1}^k b_{ij}(L)f_{jt} + e_{it} , \quad (3.5)$$

變數 x_{it} 由兩個獨立且不可觀察到的成分所組成，其中一個成分 χ_{it} 為共同成分(common component)，而 e_{it} 則為特徵成分(idiosyncratic component)。 f_{jt} 為 q 個無法觀測之共同因子(common factor)， $q \leq N$ ； $b_{ij}(L) = b_{i1}L + b_{i2}L^2 + \dots + b_{is}L^s$ 為 s 期動態因子負荷(dynamic factor loading)，代表 x_{it} 與 f_{jt} 之間聯繫關係。將式(1)以靜態因子模型表達，也就是將 N 個金融變數與 q 個因子之關係綜合起來，即可得到：

$$x_t = \Lambda f_t + e_t , \quad (3.6)$$

其中將 s 個落後期與 q 個因子結合為 r 個因子負荷矩陣， $r = q(s + 1)$ ，表示最多估計 r 個因子負荷(詳見 Bai and Ng, 2007)。等式左邊為實際資料，等式右邊的因子負荷 Λ 與共同因子 f_t 皆為待估計變數。

實際求解時，可採幾種方式進行估計，一種為利用頻域(frequency domain)的概念，透過使用離散傅立葉轉換(discrete Fourier transform)，捕捉時間序列資料中隱含之共同結構。另一種方式則採用狀態空間(state space)模型形式，利用最大概似法與 Kalman filter 估計。

二、主要央行機器學習之應用與文獻發展

隨著電腦科技的突飛猛進，高效能運算與演算法不斷地進步，近年不論學界，或是主要機構與各國央行在應用機器學習方法皆有長足的發展。大數據與機器學習應用於央行之業務範疇相當廣泛，包含金融即時監控與異常交易偵測、統計資料的校正與精進、總體經濟預測、模型建構、政策決策之輔助、金融監理及總體金融穩定政策、經濟指標編製等。透過大數據資料與機器學習應用有助評估政策效果，以提昇政策品質(BIS, 2022)。

在模型建構方面，以法國央行為例，法國央行應用大數據資料與機器學習建構 BIZMAP 模型，從出口與對外直接投資(FDI)的角度，提供法國中小企業(SMEs)最具經濟吸引力的歐盟國家或地區排名，透過對新市場的分析，協助其業務國際化。首先，BIZMAP 模型利用機器學習，即以隨機森林法(missForest)與 Kalman Filter 插補缺漏值；再以出口與對外直接投資為目標，將 7 個大型資料庫中的 80 多個變量納入貿易引力模型(gravity trade model)，透過 LASSO 迴歸選擇更確切的變數；最後，再以 OLS 對重要變數與經濟變數進行迴歸分析後，於 BIZMAP 應用程序中開發出一個交互式數據的視覺化工具。根據行業別和所在國，BIZMAP 為法國 SMEs 提供該行業最有發展潛力的歐洲國家排名。透過減少國外資訊不確定性，BIZMAP 不僅使法國 SMEs 能夠了解主要驅動因素，而且還提供對 281 個歐洲地區進行相互比較(Kien et al., 2022)。

在總體經濟預測方面，紐西蘭央行(Reserve Bank of New Zealand, RBNZ)運用 550 個紐西蘭與國外總體經濟變數進行即時預報(nowcast)，實證結果發現機器學習之預測績效皆優於傳統 AR 方法，尤其是預測表現最佳的 SVM、梯度提升(gradient boosting)決策樹與神經網絡提高即時預報 20-30%的準確性(Richardson et al., 2021)。

歐洲中央銀行體系(European System of Central Banks, ESCB)於2018 年建立定價個體資料分析網絡(Price-setting Microdata Analysis Network, PRISMA)大數據資料庫，蒐集自2013 年以來歐元區國家零售業商品之條碼掃描資料(scanner data)與線上價格，涵蓋37,000 多家商店超過180 萬種商品的每週價格，其中條碼掃描資料包含商品端(store scanner, IRi)-每週零售業銷售商品的價格與數量與家庭端(GfK)-每週家庭購買商品之價格與數量。ECB 運用 PRISMA 資料庫中德國、荷蘭、法國、義大利等4 個歐元區國家的商品銷售掃碼資料(IRi)進行食物類通膨變動之分析，結果發現4 國超市商品調價頻率較低，1 個月中僅9.5%商品調價，表示平均而言，商品10.5 個月才會調價一次；相較之下，美國價格變動的頻率(每7 個月會調價一次)和幅度都要高得多。且美國區域依賴性(state dependent)遠高於歐元區4 國，商品價格較大的波動既迫使零售商更頻繁地調整價格，增加價格錯置問題(price misalignment)，進而推升物價大幅走升(Karadi et al, 2023)。

而德國央行則是運用前述 PRISMA 資料庫中德國3 萬多個家庭週頻率購買零售商品之條碼掃描資料(GfK)，量化和即時檢測食物類價格和數量之變化，並對通膨進行即時預報。採用此高頻且大量資料的好處在於，在每月第1 週結束後兩天，亦即官方HICP 發佈前近6 週，已可獲得當月HICP 通膨率變動的詳細資訊(Menz et al., 2022)。

英格蘭銀行(Bank of England)對央行常用的機器學習進行一系列的介紹，並運用機器學習進行3 項案例研究，分別是(1)金融監理：以金融機構的資產負債表為基礎，建構預警模型；(2)經濟預測：對英國未來2 年的中期(medium-term horizon of two years)通膨預測，其結論指出，遞迴神經網路(recurrent neural networks)與SVM 之預測績效皆超越時間序列模型；(3)金融市場結構：找出潛在的科技創投公司之籌資模式。這些案例皆顯示機器學習不論在建模、CPI 預測或是政策應

用上都優於傳統方法(Chakraborty and Joseph, 2017)。

再者，機器學習在編製經濟指標亦有長足的發展，且以其編製之指標有助總體經濟預測。若以情緒指數(sentiment index)為例，央行關心民眾與企業的預期，因為他們對經濟狀況的情緒會影響消費、投資與儲蓄等決策。衡量情緒有兩種方式，一種透過調查民眾或企業對當前與未來經濟狀況的看法，如消費者信心指數(consumer sentiment index, CSI)與商業情勢指標(business conditions index, BCI)等。另一種方式則是近年學界與央行皆有發展的，以媒體新聞資料為依據，採文字探勘(text mining)方法萃取關鍵字，編製情緒指數。

馬來西亞央行(Central Bank of Malaysia)從自 2001 年起共 72 萬篇經濟與金融新聞的文字中萃取關鍵字，編製情緒指數，並分析情緒指數與總體經濟間的關聯。該國研究發現，以線性模型(如 OLS、Ridge 等)、非線性機器學習模型(如 Boosting、RF 等)和長短期記憶神經網絡(LSTM)可提高以新聞文字為基礎之情緒指數對 GDP 與其組成的預測績效，尤其情緒指數領先民間投資 2-3 季(Chong et al., 2022)。此外，以新聞文字為基礎的情緒指數可預測以調查資料為基礎的 CSI 與 BCI。其他文獻如 Aguilar et al. (2021)、Kalamara et al. (2020)、Larsen and Thorsrud (2019)、Nguyen and Cava (2020)、Rambaccussing and Kwiatkowski (2020)等亦證實以新聞文字隱含的情緒有助預測總體經濟變數。印尼央行(Bank Indonesia, BI)亦利用過去歷史新聞資料進行文字探勘，找出景氣擴張與收縮之關鍵字，透過文字探勘結果，評估新聞媒體及市場對央行政策之預期。

2019 年愛爾蘭經濟強勁成長，就業人數升至 257 萬人的新高，造成薪資上漲壓力。愛爾蘭央行採用 Indeed 線上徵才 7000 萬份資料，以徵才職缺(job posting)之點擊率建構薪資成長的領先指標，即時追蹤當前勞動市場緊俏程度(Adrjan and Lydon, 2019)。

機器學習亦可協助央行即時監控金融系統與異常交易的偵測。如加拿大央行利用機器學習法即時監測金融機構異常資料，以強化監控機制及金融預警系統。德國央行則與德國聯邦金融監管局(BaFin)合作，擬定銀行業和保險業利用機器學習應用於風險模型的規範，以強化監控機制及金融預警系統。

此外，與本專題主題相關的，全球金融危機後的文獻多採用 PCA 或因子模型等建構 FCI，如前章節之說明，這類文獻不勝枚舉，若排除這些採用非監督式學習的文獻，則如前所述之 IMF 曾利用機器學習中之 LDA 將預測經濟成長風險的變數分組後，進行降維，編製 FCI，並在當前金融情勢變化下進行未來經濟成長風險之預測(Prasad et al., 2019)。而 Fed Board (Kiley, 2020)亦考量 LASSO、EN 與 RF 等機器學習建構 FCI，並利用 FCI 預測美國失業率。該文實證發現以機器學習建構之 FCI 描繪 1990 年初和 2000 年初經濟衰退之前其金融情勢已緊縮，此與 Chicago Fed 之 NFCI 略不同，主要係因機器學習建構之 FCI 給予股票價格較大的權重。此外，該文實證結果發現以 RF 方法建構之 FCI 較能刻劃與經濟活動間的非線性關係，亦即緊縮的金融情勢將導致經濟活動的急劇惡化，而寬鬆的金融情勢則與經濟小幅成長有關。

Pietrzak (2022)認為合適的早期預警指標應具準確、即時且結果易被解釋，因此，應廣納不同面向的金融脆弱程度之變數。該文以 Chicago Fed 之 NFCI 衡量金融危機，亦即將 NFCI 之第 90 分量設定為 1，顯示為有金融危機；其餘為 0，沒有金融危機。採用信號法(signal extraction)、機器學習(包含 KNN、LDA、QDA、SVM、RF、LR、NB 等)等 8 種方法來預測金融危機，實證結果發現金融情勢緊縮可預先偵測 4~12 季的金融危機，其中以 KNN 與 RF 之預測績效較佳，LR 預測績效則較差。

肆、台灣實證分析

一、資料來源與說明

文獻上對於 FCI 應該納入哪些變數無一致的準繩，並未能為選擇納入指標提供任何理論或實證理由。首先，FCI 是由 MCI 擴充而來，本專題考慮納入兩個原始 MCI 中的利率與匯率相關變數；且幾乎所有現有的 FCI 都考慮資產價格效應之衡量(如 Brave and Butters, 2011; Koop and Korobilis, 2014 等)。再者，Hatzius et al. (2010)與 Wacker et al. (2014)等文獻認為 FCI 應適當反映金融部門的風險，而 Wacker et al. (2014)認為信用利差反映不同市場參與者可接受資金的相對價格。Castro (2010)認為信用利差是景氣循環的領先指標。因此，本專題將從利率、匯率、資產價格與信用等變數著手。

參考前述文獻 FCI 之變數，考量不同方法的特性，如因子模型特色在於從大量變數中萃取出相關性或共同性，不受變數間的線性關係影響，而機器學習中，資料質量常是影響最後結果準確度的關鍵。因此，本專題研究延續台灣相關文獻，並選用資料取得較容易之變數，採用大量金融市場變數，蒐集外匯(11 個變數)、貨幣(11 個)、股票(10 個)、房地產(7 個)與信用(8 個)等五個主要金融市場，共 47 個金融市場中價與量之金融變數來估計 FCI。外匯市場除了一籃子匯率外，另包含主要貿易對手國之雙邊匯率與外幣拆放市場交易。貨幣市場則除了市場利率外，再納入貨幣數量變數，如通貨淨額、準備貨幣、M1B 與 M2，以及納入國內外短期利率與國內外長期利率，主要用以衡量小型開放經濟體(如台灣)之資金流出入狀況。再者，考量股票市場多樣化金融商品之特性，納入摩台指期貨、台灣 50 指數與店頭市場股價指數；而近年外資持股比重約四成，且外資或機構交易對股價報酬具顯著的同期正相關，因此，納入 3 大法人累計買賣超金額、外資及陸資所持有股票占總市值比。

在房地產市場變數方面，考量變數代表性與容易取得，交易面選取信義房價指數(衡量中古屋市場價格)、國泰房價指數(衡量預售屋與新成屋之價格)與建物所有權移轉登記棟數；生產面則採用核發建築物建造執照總樓地板面積代表房地產景氣，以核發建築物使用執照總樓地板面積代表房地產實際生產狀況；並以購置住宅貸款衡量房地產景氣與交易狀況。信用變數方面則選用全體銀行放款餘額與消費者貸款，其中全體銀行放款係用於衡量整體金融機構之授信規模；而景氣不佳時，銀行會以縮減消費者貸款為優先業務考量，故亦納入消費者貸款變數，此外，並另納入放款與投資等資料。其中，信義房價指數、國泰房價指數(又稱可能成交價指數(全國))與台北市可能成交價指數為季資料，以 Chow-lin 依時拆分法轉換為月資料。

樣本期間為 2003 年 1 月到 2023 年 10 月，資料型態為月與季的混頻資料，共 263 個資料點。此外，2023 年 10 月如外匯交易量、信義房價指數、國泰房價指數、核發建築物建造執照總樓地板面積等，因統計公布時間落後(ragged-edge data)而為缺漏值。資料來源為中央銀行金融統計月報、證交所、內政部營建署、信義房屋、國泰房屋、國際清算銀行(BIS)、聖路易 Fed (St. Louis Fed)的美國聯邦準備經濟資料庫(Federal Reserve Economic Data, FRED)等。

資料多為月頻率資料；若為日頻資料則以簡單平均轉換為月頻資料；若資料為季資料(如房價指數等)，則以 Chow-lin 依時拆分法轉換為月資料。為確保所有變數為定態(stationary)，當變數為水準值，先對該變數取對數，依單根檢定結果決定是否對去年同期取差分轉換為定態數列；當變數為比率或利率時，則直接對該變數進行單根檢定後再決定是否需取差分⁹。所有變數經轉換為定態數列後，再將定態變數標準化(normalized)，以避免因變數單位不一致而造成估計上的偏差。

⁹ 單根檢定以 Augmented Dickey-Fuller(ADF)檢定為主，限於篇幅，結果不擬列出。

變數與資料處理如表 2。

本專題一共編製 6 種 FCI，其處理方式說明如下：(1) FCI-Factor：以因子模型估計，選取主要因子當作 FCI；(2) FCI-LDA 採用 LDA 方法估計，以負的工業生產指數年增率當作目標函數；(3) FCI-Fa+LDA：先於五個金融市場中以因子模型萃取主要因子，再以 LDA 方法(以負的工業生產指數年增率當作目標函數)估計權重；(4) FCI-LassoLogit：以正規化 Logit 模型估計；(5) FCI-RF：以 RF 法估計；(6) FCI-SVM：以 SVM 方法估計，其中(4)(5)(6)為監督式學習，亦以負的工業生產指數年增率當作目標函數。

表 2 FCI 採用的大量變數名稱

編號	變數	變數來源	資料頻率	變數處理	資料公布 落後(月)
1	NEER_broad	BIS	月	2	1
2	NEER_narrow	BIS	月	2	1
3	REER_broad	BIS	月	2	1
4	REER_narrow	BIS	月	2	1
5	新台幣對美元匯率	中央銀行金融統計月報	月	2	0
6	日圓對美元匯率 JPY/USD	中央銀行金融統計月報	月	2	0
7	韓元對美元匯率 KRW/USD	中央銀行金融統計月報	月	2	0
8	人民幣對美元匯率 CNY/USD	中央銀行金融統計月報	月	2	0
9	歐元對美元匯率 USD/EUR	中央銀行金融統計月報	月	2	0
10	外匯交易量	中央銀行金融統計月報	月	2	2
11	台北外幣拆放市場交易(美元)	中央銀行金融統計月報	月	2	2
12	金融業隔夜拆款利率	中央銀行金融統計月報	月	1	1
13	1~30 天期商業本票利率(次級市場)	中央銀行金融統計月報	月	1	1
14	31~90 天期商業本票利率(次級市場)	中央銀行金融統計月報	月	1	1
15	10 年期公債利率(次級市場)	中央銀行金融統計月報	月	1	1
16	通貨淨額(日平均數)	中央銀行金融統計月報	月	2	1
17	準備貨幣(日平均數)	中央銀行金融統計月報	月	2	1
18	貨幣總計數-M1B(日平均數)	中央銀行金融統計月報	月	2	1
19	貨幣總計數-M2(日平均數)	中央銀行金融統計月報	月	2	1

20	國內外短期利差 ^a	中央銀行金融統計月報、FRED	月	1	1
21	國內外長期利差 ^b	中央銀行金融統計月報、FRED	月	1	1
22	國內長短期利差 ^c	中央銀行金融統計月報	月	1	1
23	台灣加權股價指數	中央銀行金融統計月報	月	2	0
24	股票市場總市值	中央銀行金融統計月報	月	2	0
25	股市日平均成交值	中央銀行金融統計月報	月	2	0
26	融資餘額(前期餘額+新增-償還)	中央銀行金融統計月報	月	2	0
27	融券餘額(前期餘額+新增-償還)	中央銀行金融統計月報	月	2	0
28	TAMSCI 摩根台股指數期貨	證交所	月	2	0
29	臺灣 50 指數	證交所	月	2	0
30	店頭市場股價指數	證交所	月	2	0
31	3 大法人累計買賣超金額	證交所	月	2	0
32	全體外資及陸資所持有股票占總市值比	金管會證期局	月	1	0
33	信義房價指數	信義房屋	季	2	2
34	國泰房價指數	國泰房屋	季	2	2
35	可能成交價指數(台北市)	國泰房屋	季	2	2
36	建物所有權移轉登記棟數	內政部營建署	月	2	2
37	核發建築物建造執照總樓地板面積	內政部營建署	月	2	1
38	核發建築物使用執照總樓地板面積	內政部營建署	月	2	1
39	消費者貸款-購置住宅貸款	中央銀行金融統計月報	月	2	1
40	消費者貸款	中央銀行金融統計月報	月	2	1
41	全體銀行放款餘額	中央銀行金融統計月報	月	2	1
42	全體銀行放款餘額(對公營事業)	中央銀行金融統計月報	月	2	1
43	全體銀行放款餘額(對民營企業)	中央銀行金融統計月報	月	2	1
44	貨幣機構放款與投資	中央銀行金融統計月報	月	2	1
45	貨幣機構放款	中央銀行金融統計月報	月	2	1
46	貨幣機構對非金融機構證券投資	中央銀行金融統計月報	月	2	1
47	債券市場(政府、公司、金融債券)餘額	中央銀行金融統計月報	月	2	1

註：1.變數處理說明：1 為原始值，無轉換；2 為取對數後，對去年同期取差分。

a.國內外短期利差為台灣 31-90 天期商業本票利率(次級市場)-美國 3 個月國庫券利率；

b.國內外長期利差為台灣 10 年期公債利率(次級市場)-美國 10 年期公債殖利率；

c.國內長短期利差為台灣 10 年期公債利率(次級市場)-台灣隔夜拆款利率；

2.資料公布落後情形，以月衡量，並以 2023 年 11 月 1 日之資料為準。

二、實證分析

本專題研究編製之 FCI 大於零，表示金融情勢寬鬆；FCI 若小於零，則表示金融情勢較為緊縮。圖 15 為 6 種採用不同變數或估計方式之 FCI 與工業生產指年增率走勢。其中，6 種 FCI 與工業生產指數年增率走勢大致一致，亦即當金融情勢處於寬鬆狀態時，工業生產多為正成長；而金融情勢緊縮時，通常伴隨著經濟衰退，如同文獻(如 Gertler and Gilchrist, 2018)結果一致，經濟衰退與金融情勢的反轉同時發生。Gertler and Gilchrist (2018)證實金融危機影響實體經濟體的傳遞過程，亦即家計單位和銀行首先面臨財務困境，而隨著危機的延續，非金融企業亦面臨財務困境，致經濟衰退更深更長。該文認為家計單位資產負債表管道(household balance sheet channel)和銀行在金融危機與經濟衰退扮演重要的角色。從圖 15 觀察，若 FCI 非為緊縮狀態，則經濟通常不會出現衰退的情況。

此外，FCI 對 2008 年全球金融危機、2011~2012 年歐債危機期間、2014~2015 年的「新平庸經濟」(New Mediocre)期間與 COVID-19 疫情期間皆具領先性。

除了因子模型為非監督式學習，其餘採監督式學習皆以負的工業生產指數年增率當作目標函數，故其 FCI 較利於捕捉工業生產下行風險之走勢，例如在全球金融危機、歐債危機、2015 年新平庸之全球經濟停滯期間與 COVID-19 疫情等。

圖 15 FCI 與工業生產指數年增率走勢圖



(一)Granger 因果關係檢定

為了更全面性的檢視總體經濟變數與 FCI 的相互關係，本節考慮以國家發展委員會的領先、同時與落後指標之構成項目當作實質總體經濟變數(x_t)，一共 18 個總體變數¹⁰，採用 Granger 因果關係檢定檢視 6 種 FCI 與這 18 個 x_t 之間是否具有領先、落後或反饋關係。其中為使比較模型具一致性，以 1 年(12 期)當作 Granger 因果關係檢定之落後項選擇，不再分別找尋各模型最適落後項。

Granger 因果關係檢定結果如表 3~5，表內數值為 Wald 統計量與 p 值，其中若 x_t 對 FCI 皆無法拒絕虛無假設，即 x_t 不會「Granger 影響」FCI；但若 FCI 對 x_t 皆拒絕虛無假設，即 FCI 會「Granger 影響」 x_t ，顯示 FCI 具有預測未來實質總體變數之能力，為總體經濟變數之領先指標。若以表 3 的 FCI-Factor 結果為例，領先指標構成項目中的「建築物開工樓地板面積」與 FCI-Factor 具有雙向 Granger 因果關係，FCI-Factor 對其餘變數多具領先關係。若再以表 5 的 FCI-RF 結果為例，除了領先指標構成項目中的「外銷訂單動向指數」、「貨幣總計數」、「股價指數」與 FCI-RF 具有雙向的 Granger 因果關係外，其餘總體經濟變數對 FCI-RF 都無法拒絕虛無假設，但卻拒絕 FCI-RF 不會「Granger 影響」 x_t 的虛無假設，因此，FCI-RF 具有領先絕大多數實質面總體變數的特性。其餘 FCI-LDA、FCI-Fa+LDA、FCI-LassoLogit、FCI-SVM 亦大多拒絕不會「Granger 影響」 x_t 的虛無假設，總體經濟變數對 FCI 多無法拒絕虛無假設。

在觀察的樣本期間內，本專題研究所建構的 FCI 具有領先絕大多數實質面的總體經濟變數之特性。

¹⁰ 領先、同時與落後指標之構成項目，共 18 個變數，以 ADF 單根檢定結果決定是否對去年同月取差分轉換為定態數列；當變數為比率或利率時，則直接對該變數進行單根檢定後再決定是否需取差分。

表 3 FCI-Factor、FCI-LDA 與總體變數的 Granger 因果關係檢定

	$H_0: X_t$ 不 Granger Cause FCI-Factor		$H_0: \text{FCI-Factor}$ 不 Granger Cause X_t		$H_0: X_t$ 不 Granger Cause FCI-LDA		$H_0: \text{FCI-LDA}$ 不 Granger Cause X_t	
	檢定統計量	p 值	檢定統計量	p 值	檢定統計量	p 值	檢定統計量	p 值
領先指標構成項目								
外銷訂單動向指數	1.500	0.126	1.269	0.239	7.428	0.000	2.865	0.001
貨幣總計數	0.714	0.737	2.973	0.001	1.938	0.032	2.300	0.009
股價指數	0.973	0.475	1.888	0.037	3.661	0.000	1.919	0.017
工業及服務業受僱員工淨進入率	1.415	0.161	2.073	0.020	1.109	0.354	3.223	0.014
建築物開工樓地板面積	2.032	0.026	1.716	0.070	1.363	0.192	5.673	0.019
半導體設備進口值	1.278	0.234	1.552	0.095	0.712	0.739	1.949	0.030
同時指標構成項目								
工業生產指數	1.337	0.199	1.731	0.062	1.970	0.028	2.657	0.000
電力(企業)總用電量	1.332	0.182	3.679	0.000	1.466	0.107	2.671	0.002
製造業銷售量指數	1.377	0.179	2.365	0.000	1.394	0.097	1.994	0.026
批發、零售及餐飲業營業額	1.483	0.110	1.672	0.075	2.436	0.006	1.820	0.016
非農業部門就業人數	1.352	0.150	1.970	0.028	0.708	0.587	8.193	0.000
海關出口值	1.315	0.212	2.062	0.021	1.059	0.396	1.732	0.062
機械及電機設備進口值	0.914	0.534	1.661	0.077	0.840	0.609	2.761	0.000
落後指標構成項目								
失業率	0.711	0.740	6.350	0.000	0.936	0.511	7.130	0.000
製造業單位產出勞動成本指數	0.919	0.529	1.598	0.094	1.338	0.199	2.237	0.011
金融業隔夜拆款利率	1.348	0.193	2.342	0.056	1.110	0.353	2.374	0.095
全體金融機構放款與投資	1.257	0.215	1.822	0.022	0.758	0.385	2.443	0.005
製造業存貨價值	0.469	0.931	1.596	0.095	1.351	0.192	2.236	0.011

表 4 FCI-Fa+LDA、FCI-LassoLogit 與總體變數的 Granger 因果關係檢定

	$H_0: X_t$ 不 Granger		$H_0: \text{FCI-Fa+LDA}$ 不 Granger		$H_0: X_t$ 不 Granger		$H_0: \text{FCI-LassoLogit}$ 不 Granger		
	Cause FCI-Fa+LDA		Cause X_t		Cause FCI-LassoLogit		Cause X_t		
	檢定統計量	p 值	檢定統計量	p 值	檢定統計量	p 值	檢定統計量	p 值	
領先指標構成項目									
外銷訂單動向指數	4.823	0.000	3.298	0.000	3.886	0.000	1.680	0.073	
貨幣總計數	1.326	0.197	9.500	0.000	2.049	0.022	4.781	0.000	
股價指數	1.498	0.129	2.119	0.017	1.461	0.141	2.052	0.021	
工業及服務業受僱員工淨進入率	1.304	0.211	2.864	0.001	1.219	0.343	2.531	0.004	
建築物開工樓地板面積	0.999	0.454	2.277	0.012	1.036	0.420	1.957	0.033	
半導體設備進口值	0.874	0.574	2.788	0.002	1.108	0.355	3.379	0.000	
同時指標構成項目									
工業生產指數	2.273	0.010	3.677	0.000	1.361	0.187	4.313	0.000	
電力(企業)總用電量	2.200	0.013	5.411	0.000	1.474	0.105	5.063	0.000	
製造業銷售量指數	1.385	0.174	4.311	0.000	1.344	0.102	4.900	0.000	
批發、零售及餐飲業營業額	1.494	0.107	3.971	0.000	1.156	0.121	3.966	0.000	
非農業部門就業人數	0.921	0.527	2.455	0.005	1.035	0.418	2.425	0.006	
海關出口值	1.436	0.151	3.890	0.000	1.382	0.176	3.263	0.000	
機械及電機設備進口值	0.899	0.549	3.146	0.000	1.514	0.100	3.609	0.000	
落後指標構成項目									
失業率	0.928	0.520	1.870	0.074	0.962	0.486	1.074	0.384	
製造業單位產出勞動成本指數	1.110	0.353	1.590	0.096	1.185	0.295	1.866	0.040	
金融業隔夜拆款利率	1.078	0.380	2.686	0.002	1.073	0.384	1.660	0.078	
全體金融機構放款與投資	1.263	0.213	3.113	0.000	1.558	0.103	1.826	0.046	
製造業存貨價值	0.487	0.921	3.448	0.000	0.906	0.542	3.227	0.000	

表 5 FCI-RF、FCI-SVM 與總體變數的 Granger 因果關係檢定

	$H_0: X_t$ 不 Granger Cause FCI-RF		$H_0: \text{FCI-RF 不 Granger Cause } X_t$		$H_0: X_t$ 不 Granger Cause FCI-SVM		$H_0: \text{FCI-SVM 不 Granger Cause } X_t$	
	檢定統計量	p 值	檢定統計量	p 值	檢定統計量	p 值	檢定統計量	p 值
領先指標構成項目								
外銷訂單動向指數	9.271	0.000	1.622	0.087	4.934	0.000	2.235	0.011
貨幣總計數	4.006	0.000	4.238	0.000	1.473	0.136	2.278	0.010
股價指數	4.723	0.000	1.750	0.058	1.378	0.178	4.955	0.000
工業及服務業受僱員工淨進入率	0.931	0.517	2.564	0.004	1.550	0.109	2.283	0.053
建築物開工樓地板面積	0.955	0.495	1.712	0.070	0.959	0.491	3.673	0.039
半導體設備進口值	0.702	0.748	4.794	0.000	1.576	0.100	3.121	0.000
同時指標構成項目								
工業生產指數	1.507	0.123	4.363	0.000	1.800	0.050	2.668	0.002
電力(企業)總用電量	1.153	0.319	4.805	0.000	1.039	0.414	2.419	0.006
製造業銷售量指數	1.687	0.113	3.435	0.000	1.344	0.101	2.480	0.005
批發、零售及餐飲業營業額	1.193	0.290	2.800	0.001	1.163	0.311	1.589	0.097
非農業部門就業人數	0.688	0.762	2.224	0.012	1.124	0.342	1.948	0.031
海關出口值	0.835	0.615	3.244	0.000	2.029	0.023	3.437	0.000
機械及電機設備進口值	0.376	0.971	3.380	0.000	1.591	0.096	3.325	0.000
落後指標構成項目								
失業率	0.886	0.562	2.015	0.024	0.318	0.986	2.003	0.025
製造業單位產出勞動成本指數	0.945	0.503	1.753	0.058	0.835	0.615	3.107	0.000
金融業隔夜拆款利率	0.627	0.818	3.895	0.000	0.895	0.553	1.874	0.085
全體金融機構放款與投資	0.941	0.507	1.792	0.051	0.974	0.475	2.901	0.001
製造業存貨價值	1.472	0.137	2.734	0.002	1.022	0.430	3.047	0.001

(二)經濟下行風險

前小節 Granger 因果關係檢定證實，FCI 具有預測未來實質總體變數之能力，為多數總體經濟變數之領先指標。而 Adrian et al. (2019) 基於分量迴歸方法，發現當前金融情勢與未來 GDP 成長條件分配具密切關聯，因此，本節進一步將以分量迴歸模型與 probit 模型進行台灣經濟下行風險之分析。

首先，分量迴歸的模型可表示如下：

$$Q_{y_{t+h}}(\tau|x_t) = x_t\beta(\tau) + e_{t+h,\tau}. \quad (4.1)$$

其中 $Q_{y_{t+h}}(\tau|x_t)$ 是 y_{t+h} 在給定 x_t 下的第 τ 個分量； x_t 為解釋變數； $e_{t+h,\tau}$ 為模型誤差項； h 為領先期數； $\beta(\tau)$ 則為第 τ 個分量的係數。 y_t 以月資料的工業生產指數年增率作為季資料之經濟成長的替代變數， x_t 則包括常數項、當期的 FCI 及當期與落後期的工業生產指數年增率等變數，值得注意的是，其中落後期數的選擇，採 BIC 作為評選結果，除了 FCI-RF 落後期數為 1 期外，其餘之 FCI 方程式落後項皆為 2 期；考慮的領先期數包括 1 個月 ($h = 1$)、1 季 ($h = 3$)、半年 ($h = 6$) 與 1 年 ($h = 12$)。

圖 16 為式(4.1)分量迴歸的估計結果。從圖 16(a)中可知，FCI-Factor 雖然在領先期數較短 ($h = 1$) 時估計係數並無明顯趨勢，但 $h = 6$ 、12 時，從低分量至高分量，估計係數皆呈現負斜率，且具明顯的趨勢，以 $h = 6$ (半年) 為例，在低分量 (0.1) 下的係數較大 (1.87)，而在高分量 (0.9) 時的係數降至顯著的 -6.94。

圖 16 (b) 則為 FCI-LDA 之結果，領先期數較短 ($h = 1$) 與較長 ($h = 12$) 時，在不同分量下的估計係數多呈顯著，且從低分量至高分量，估計係數呈現負斜率的趨勢。 $h = 1$ 在低分量 (0.1) 下的係數顯著較大 (2.85)，而在高分量 (0.9) 時的係數降至 -1.91，惟不顯著； $h = 12$ 在低分

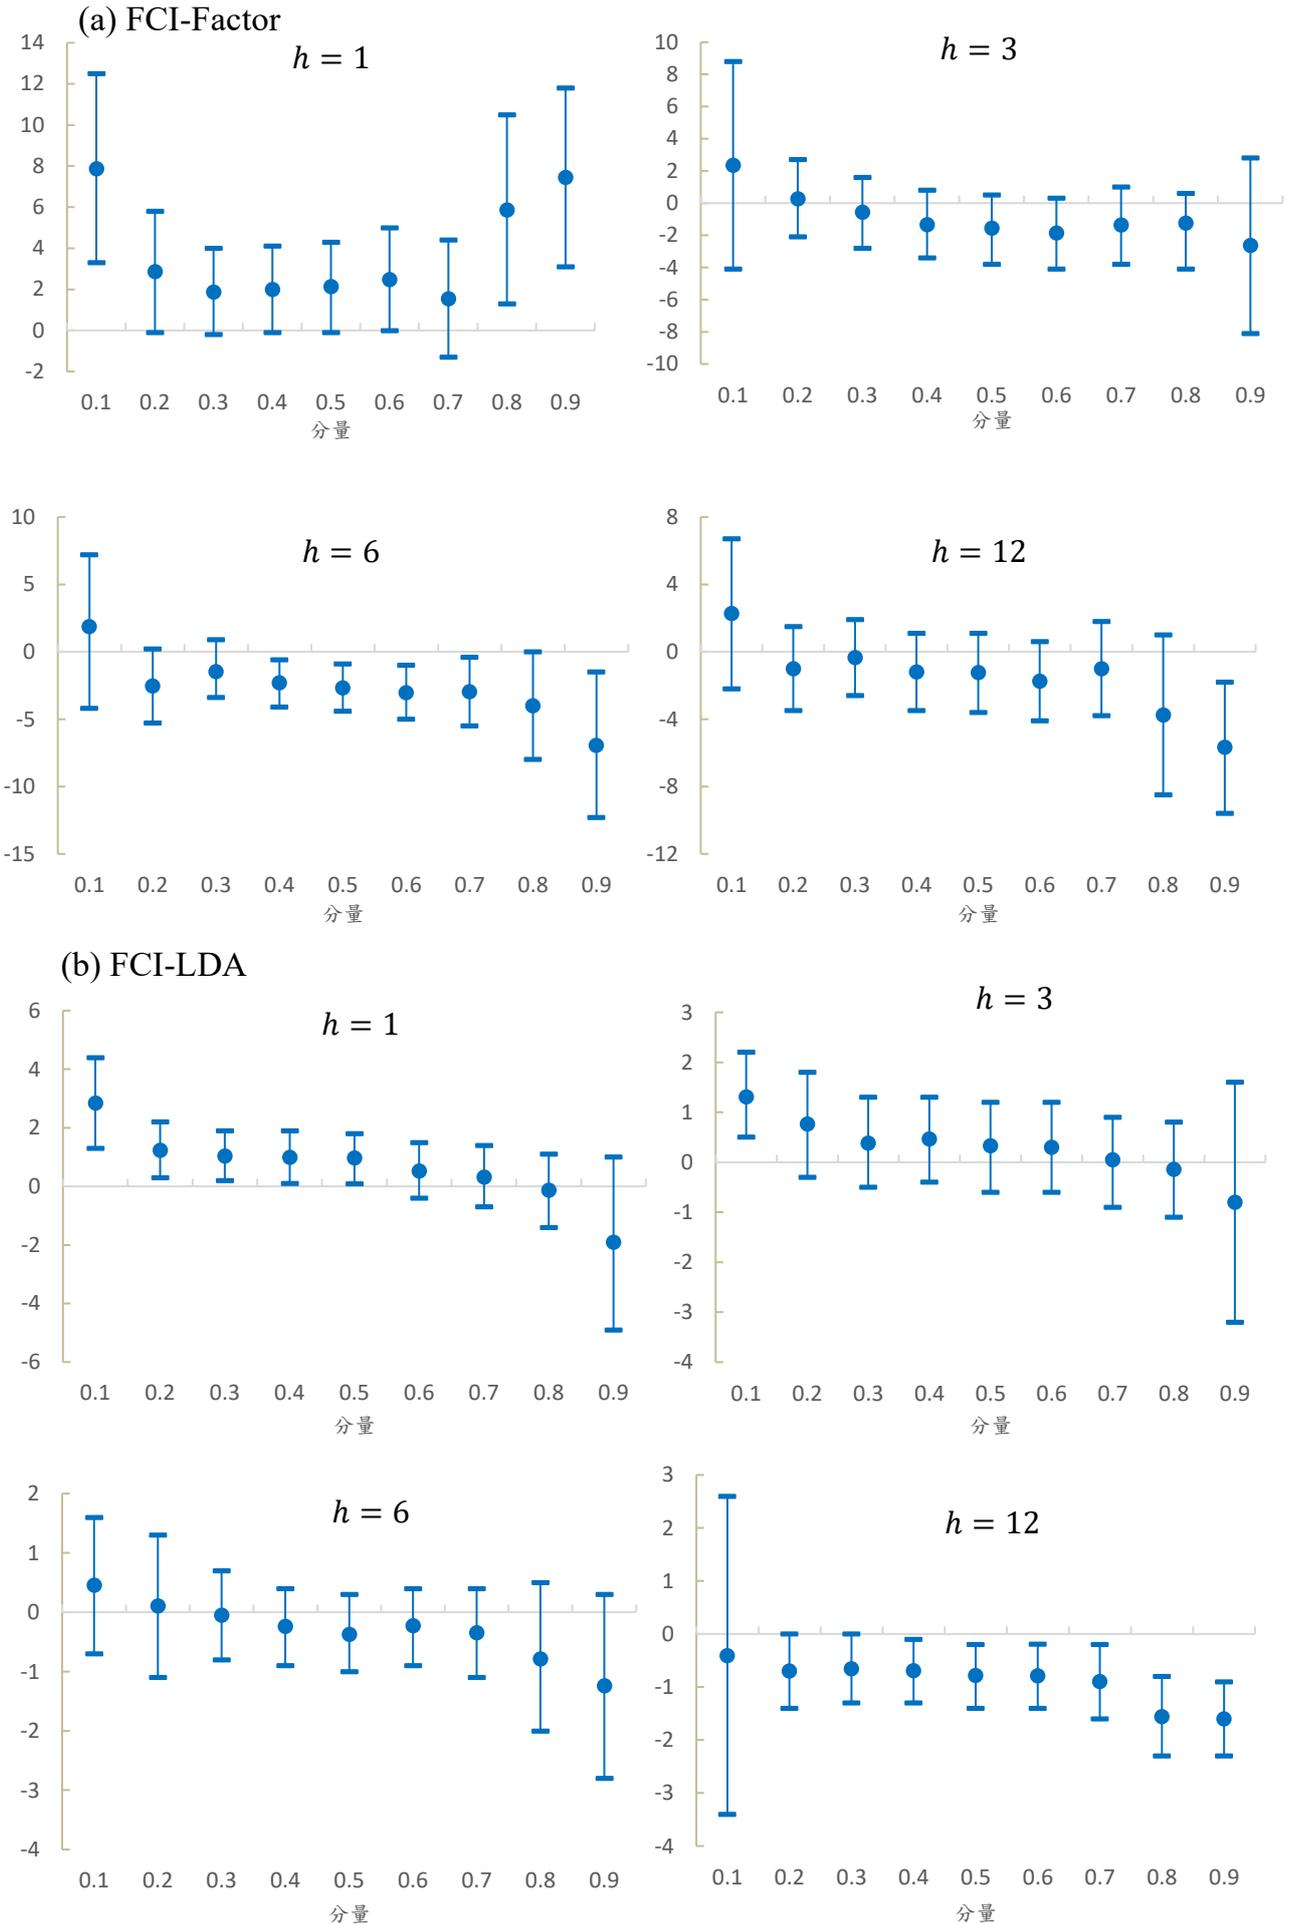
量(0.2)下的係數顯著較大(-0.70)，而在高分量(0.9)時的係數降至顯著的-1.61。這些結果皆顯示當未來經濟成長率愈低，其與 FCI 的關係顯著愈強；當未來經濟成長率愈高，其與 FCI 的關係較小。

圖 16 (c)則為 FCI-Fa+LDA 之結果，領先期數較短($h = 1$)之估計係數微幅呈負斜率，亦即在低分量(0.1)下的係數顯著較大(0.51)，而在高分量(0.8)時的係數降至顯著的 0.26。其餘 $h = 3、6、12$ 時，則是有較明顯的不同分量下估計係數呈負斜率趨勢。

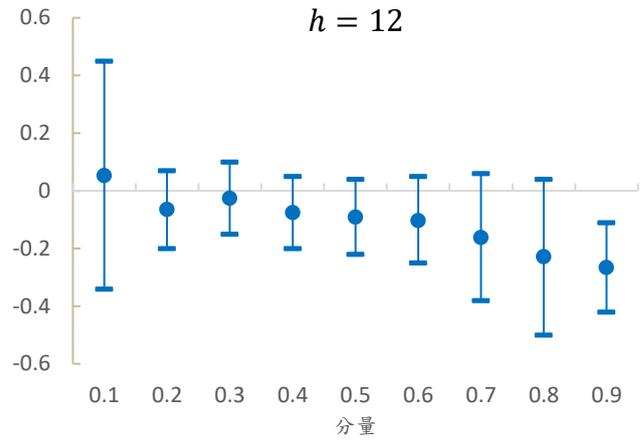
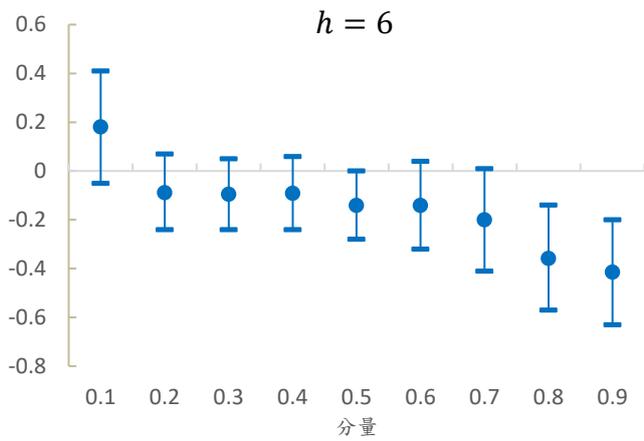
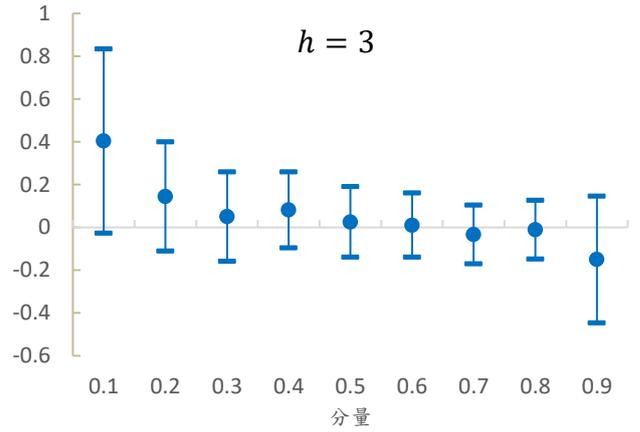
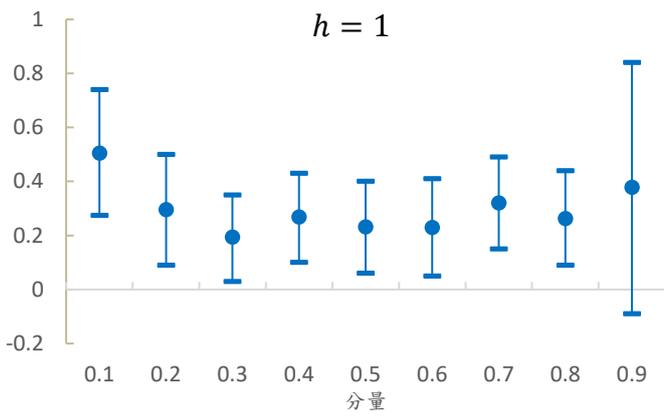
接著，圖 16 (d)與圖 16 (e)的 FCI-LassoLogit 與 FCI-RF 在領先期數 1 個月($h = 1$)時，從低分量至高分量的估計係數呈先降後升，並無明顯趨勢，惟 $h = 3、6、12$ 時，從低分量至高分量，估計係數皆呈現負斜率，且具明顯的趨勢。圖 16 (f) FCI-SVM 的 $h = 1$ 時，在低分量(0.1)的係數較大(0.76)且顯著，在較高分量(0.6)的係數顯著降至 0.53，隨後再降至高分量(0.9)之-0.02，惟不顯著。FCI-SVM 在中長期($h = 3、6、12$)估計係數亦呈負斜率趨勢，惟多不顯著，僅 $h = 12$ 時在高分量時較為顯著。

綜上所述，FCI 與未來短期內的經濟成長有關，具有領先性質；且當未來經濟成長率越低或經濟成長的下行風險越高，FCI 的領先性質將更形明顯。雖然因不同模型估計之顯著性致估計結果略有不同，惟仍可發現 FCI 在不同分量下的意涵，大多數監督式學習之 FCI 皆能監測未來經濟成長的下行風險，尤其是在短期更為明顯，其中以 FCI-LDA 與 FCI-SVM 表現較佳；而非監督式學習之 FCI，則是在較長期表現較好，而 FCI-Fa+LDA 則因先以因子模型萃取因子再以 LDA 方法估計 FCI，受到因子模型之影響，短期表現略差，較長期則預測表現較好。整體而言，FCI 可提供有關未來經濟成長、尤其是經濟成長面臨下行風險之資訊。

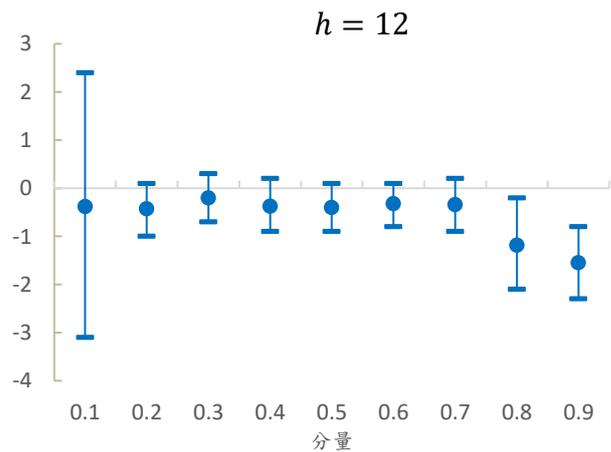
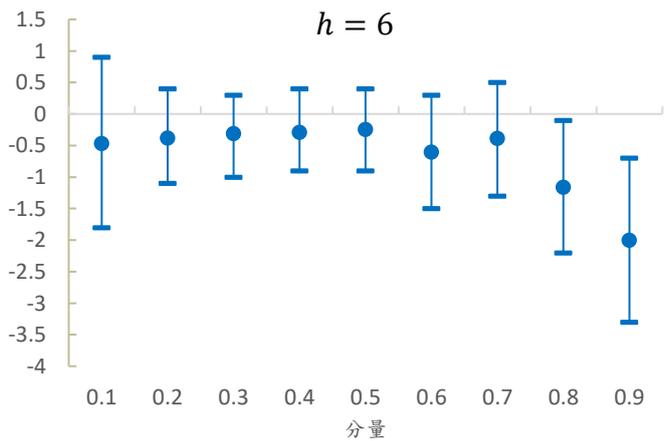
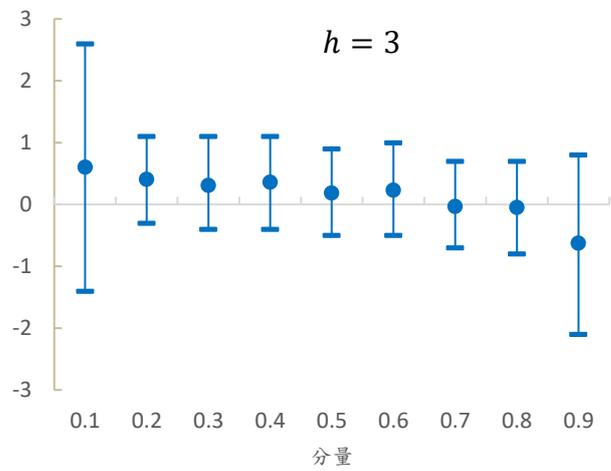
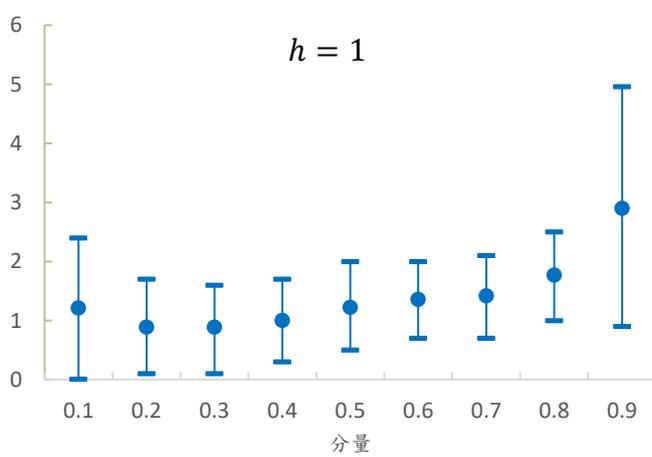
圖 16 FCI 與未來經濟成長的分量迴歸估計結果



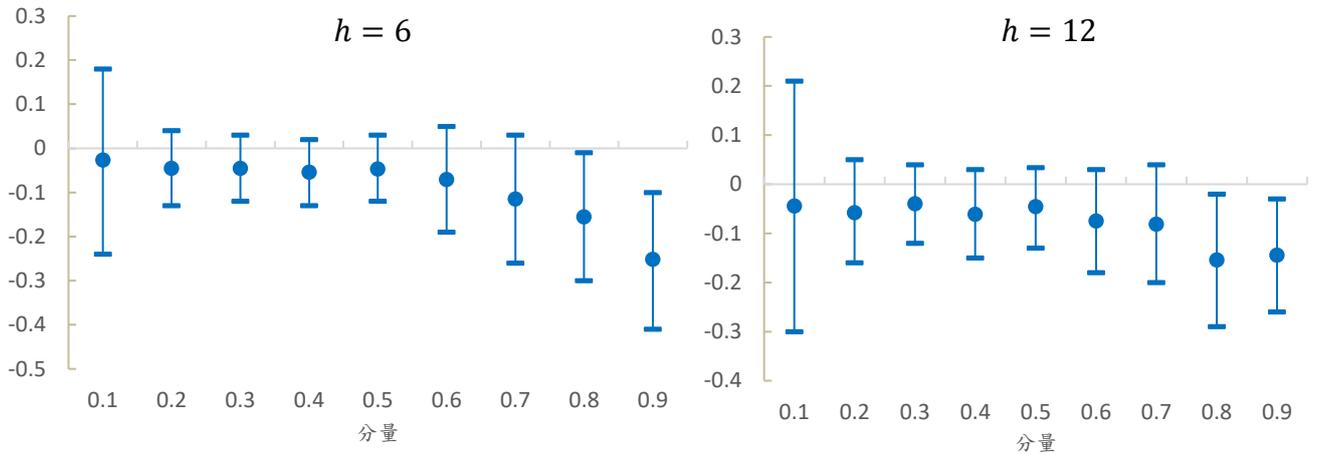
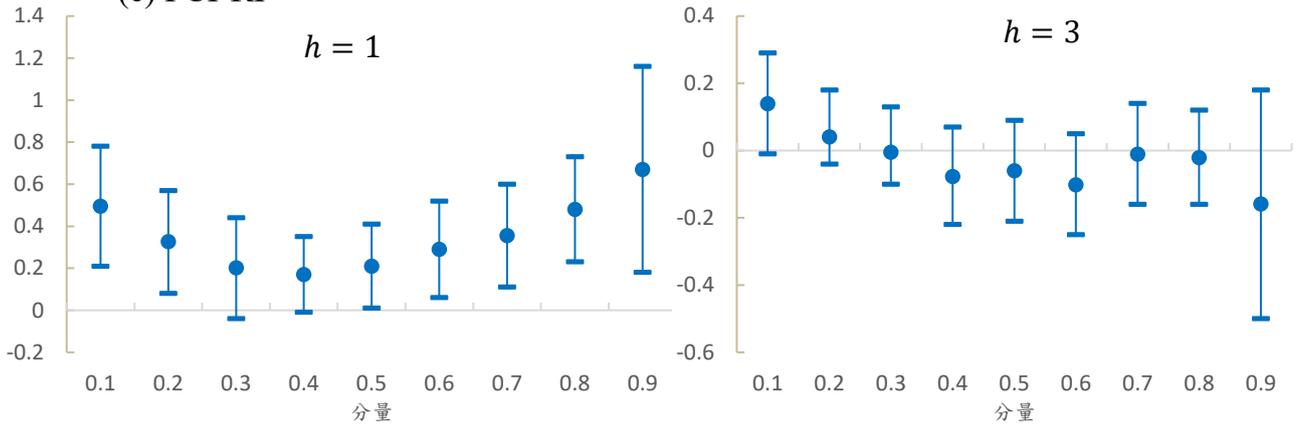
(c) FCI-Fa+LDA



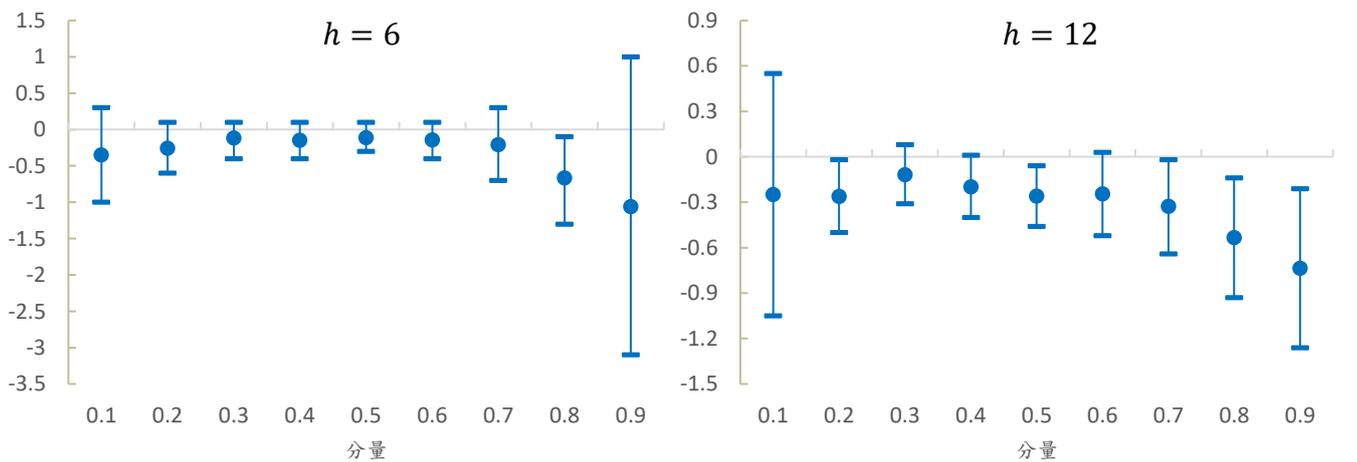
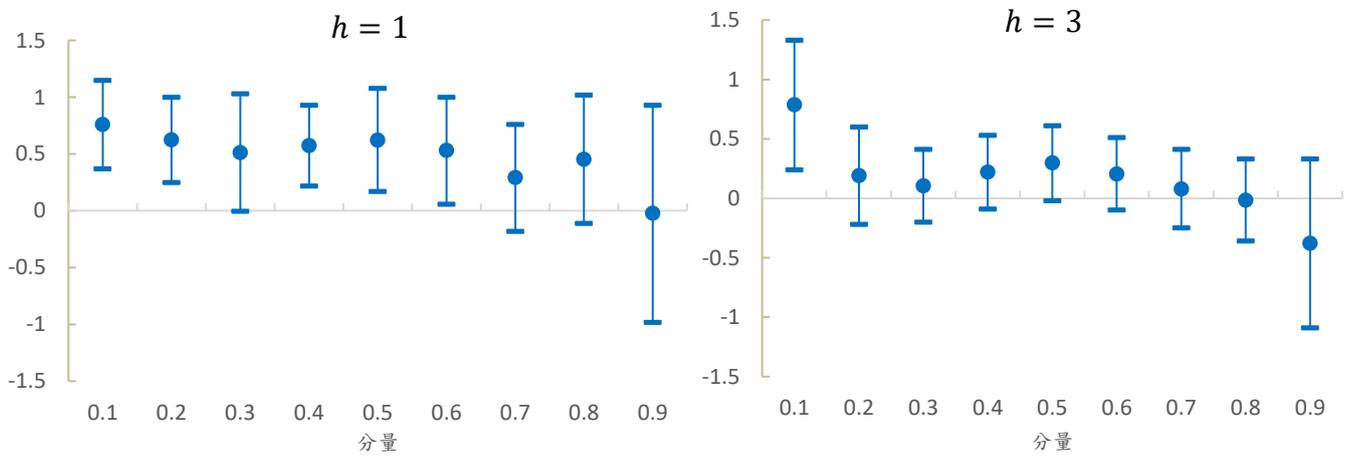
(d) FCI-LassoLogit



(e) FCI-RF



(f) FCI-SVM



從前面實證結果發現，FCI 與未來經濟衰退的關係較強。本專題研究另以 probit 迴歸模型估計 FCI 與經濟衰退的關係，並將國發會認定之景氣循環上的收縮期視為「經濟衰退」。

表 6 為歷次景氣循環的日期。台灣自 1954 年起，目前已歷經 14 次完整的景氣循環，第 15 次景氣循環之高峰為 2022 年 1 月，惟國發會尚未認定第 15 次景氣循環之谷底¹¹。若是觀察自 2003 年起的本文樣本期間內，景氣循環之全循環平均約 43 個月，持續時間已較過去短，其中擴張期長於收縮期，擴張期平均約 39 個月，收縮期平均約 12 個月。

表 6 歷次景氣循環的日期

循環次序	高峰	谷底	擴張期	收縮期	全循環
		1954.11			
第 1 循環	1955.11	1956.09	12	10	22
第 2 循環	1964.09	1966.01	96	16	112
第 3 循環	1968.08	1969.10	31	14	45
第 4 循環	1974.02	1975.02	52	12	64
第 5 循環	1980.01	1983.02	59	37	96
第 6 循環	1984.05	1985.08	15	15	30
第 7 循環	1989.05	1990.08	45	15	60
第 8 循環	1995.02	1996.03	54	13	67
第 9 循環	1997.12	1998.12	21	12	33
第 10 循環	2000.09	2001.09	21	12	33
第 11 循環	2004.03	2005.02	30	11	41
第 12 循環	2008.03	2009.02	37	11	48
第 13 循環	2011.02	2012.01	24	11	35
第 14 循環	2014.10	2016.02	33	16	49
第 15 循環	2022.01		71		
平均			40	15	53

資料來源：國發會

¹¹ 由於須足夠資料與觀察較長時間，才能確切認定景氣轉折點，故通常發布認定時間會較實際高峰或谷底時間要落後數月甚至數年之久。

由於景氣循環分為擴張期與衰退期兩種狀態，文獻常運用二元反應模型(binary response models)中的 probit(或 logistic)模型預測景氣衰退的機率，將國發會認定的景氣循環從高峰至谷底的期間(不包含高峰)定義為衰退期，由谷底至高峰的期間(不包含谷底)定義為擴張期，據以設定景氣循環的虛擬變數 y_t ：

$$y_t = \begin{cases} 1, & \text{當 } t \text{ 時點為衰退期} \\ 0, & \text{當 } t \text{ 時點為擴張期} \end{cases} .$$

以 probit 迴歸模型估計景氣落入衰退期的機率，模型設定如下：

$$\Pr(y_{t+h} = 1|x_t) = \Phi\left(\frac{-\beta x_t}{\sigma}\right), \quad (4.2)$$

其中 x_t 為前述之 6 個 FCI， h 表示對未來 h 期的預測期間。

當 $h > 0$ ，表示以當前 FCI 預測未來 h 個月景氣循環的變化，具有預測或預警的功能。如同前面實證分析之設定，預測期間 h 分別為 1、3、6、12，檢視 FCI 對預測未來 1 個月、1 季、半年與 1 年景氣循環衰退的能力。

以 probit 迴歸模型估計出衰退機率後，可進一步計算 FCI 對景氣衰退發生機率的邊際效果(marginal probability effect) $=\Phi\left(\frac{-\beta x_t}{\sigma}\right)\beta$ 。此外，亦利用式(4.2)分別檢視 6 個 FCI 在不同預測期間，對臺灣景氣衰退的配適能力。採用 Estrella (1998)提出之 pseudo- R^2 ，以衡量 FCI 對景氣衰退的配適程度(goodness of fit)。

$$R_{pseudo}^2 = 1 - \left(\frac{\log L_u}{\log L_c}\right)^{-(2/T)\log L_c},$$

其中 $\log L_u$ 為模型的最大概似函數值(log-likelihood)， $\log L_c$ 為限制模型(restricted model)中除截距項外，其餘係數值皆為零的最大概似函數數值， T 為估計樣本的長度。Pseudo- R^2 為介於 0 至 1 之間，數值越大表示模型配適度愈佳。

表 7 之 probit 模型估計結果顯示，在 $h = 1、3、6$ 時，FCI-Factor 係數估計值為負值，表示當 FCI 下降，未來 1、3、6 個月景氣衰退的機率將上升； $h=12$ 時，FCI 下降，未來 1 年景氣衰退機率上升，惟不顯著。FCI-LDA 則是 FCI 下降，未來 1、3、6 個月與 1 年景氣衰退的機率皆顯著上升。FCI-LassoLogit 與 FCI-SVM 在領先期數較短($h = 1$) 時，係數為負，惟不顯著，然而較長期($h = 3、6、12$)之 FCI 下降則顯著預測景氣衰退機率的上升。FCI-RF 在 $h=1、3$ 時之係數估計值雖皆為正值，惟不顯著。

再者，隨著對未來預測期間的增加，6 個 FCI 之配適度皆明顯增加，例如 FCI-Factor 之 pseudo- R^2 由 $h = 1$ 的 0.25，上升至 $h = 3$ 的 0.40，再上升至 $h = 6$ 的 0.54；FCI-LDA 之 pseudo- R^2 由 $h = 1$ 的 0.25，上升至 $h = 6$ 的 0.52；而 FCI-Fa+LDA 則由 $h = 1$ 的 0.24，上升至 $h = 6$ 的 0.52，其餘 3 種 FCI 皆有相同情況，惟 6 種 FCI 之 $h = 12$ 之 pseudo- R^2 皆下降。綜上所述，顯示 FCI 在反映未來較長期 (1 季、半年)之景氣狀態表現顯著優於其對短期 (1 個月)景氣情勢的表現，具有領先性質。

最後，可從表 7 景氣衰退機率之邊際效果結果來看，以 FCI-LDA 為例，在 $h = 1$ 時的 FCI 邊際效果為 -0.065，表示 FCI 每減少 1 單位會提高 6.5% 景氣衰退發生的機率； $h = 3$ 時，FCI 每下降 1 單位會提高 6.7% 景氣衰退發生的機率； $h = 6$ 時則為提高 8.1% 景氣衰退發生的機率。FCI-LassoLogit 則是在 $h = 3、6、12$ 時，FCI 每下降 1 單位分別會提高 5.3%、5.6%，以及 5.5% 景氣衰退發生的機率。

綜上所述，當 FCI 下降，未來景氣衰退之機率將上升，顯示 FCI 可反映未來景氣衰退，且隨預測期間的增加，FCI 對較長期 ($h=6$) 之景氣衰退表現顯著較佳，顯著優於其對短期景氣衰退的表現，具有領先性質，可作為對未來景氣衰退之良好的預警指標。

表 7 probit 迴歸模型估計結果

	$h = 1$	$h = 3$	$h = 6$	$h = 12$
FCI-Factor				
係數	-0.745**	-1.102***	-1.718***	-0.466
標準誤	(0.334)	(0.390)	(0.493)	(0.288)
Pseudo-R ²	0.251	0.402	0.544	0.012
衰退機率的邊際值	-0.112**	-0.157***	-0.178***	-0.104
FCI-LDA				
係數	-0.305**	-0.375***	-0.604***	-0.284**
標準誤	(0.122)	(0.134)	(0.160)	(0.112)
Pseudo-R ²	0.252	0.390	0.524	0.028
衰退機率的邊際值	-0.065**	-0.067***	-0.081***	-0.062**
FCI-Fa+LDA				
係數	-0.028	-0.088***	-0.114***	-0.036
標準誤	(0.022)	(0.025)	(0.030)	(0.023)
Pseudo-R ²	0.236	0.398	0.519	0.013
衰退機率的邊際值	-0.006	-0.014***	-0.013***	-0.008
FCI-LassoLogit				
係數	-0.150	-0.303**	-0.439***	-0.251***
標準誤	(0.113)	(0.131)	(0.129)	(0.091)
Pseudo-R ²	0.239	0.390	0.510	0.029
衰退機率的邊際值	-0.032	-0.053**	-0.056***	-0.055***
FCI-RF				
係數	0.017	0.008	-0.036	-0.023
標準誤	(0.025)	(0.029)	(0.031)	(0.024)
Pseudo-R ²	0.234	0.366	0.479	0.007
衰退機率的邊際值	0.004	0.001	-0.005	-0.005
FCI-SVM				
係數	-0.095	-0.227***	-0.399***	-0.327***
標準誤	(0.059)	(0.071)	(0.074)	(0.053)
Pseudo-R ²	0.241	0.408	0.564	0.169
衰退機率的邊際值	0.020	-0.038***	-0.042***	-0.061***

註：1. 表中係數值為負，表示該變數下降，未來 h 個月景氣衰退機率會上升；反之；景氣衰退機率下降。
 2. *為顯著水準 10%下顯著，**為顯著水準 5%下顯著，***為顯著水準 1%下顯著。
 3. Pseudo-R²數值為 Estrella (1998)之 pseudo-R²。

(三) FCI 與貨幣政策傳遞

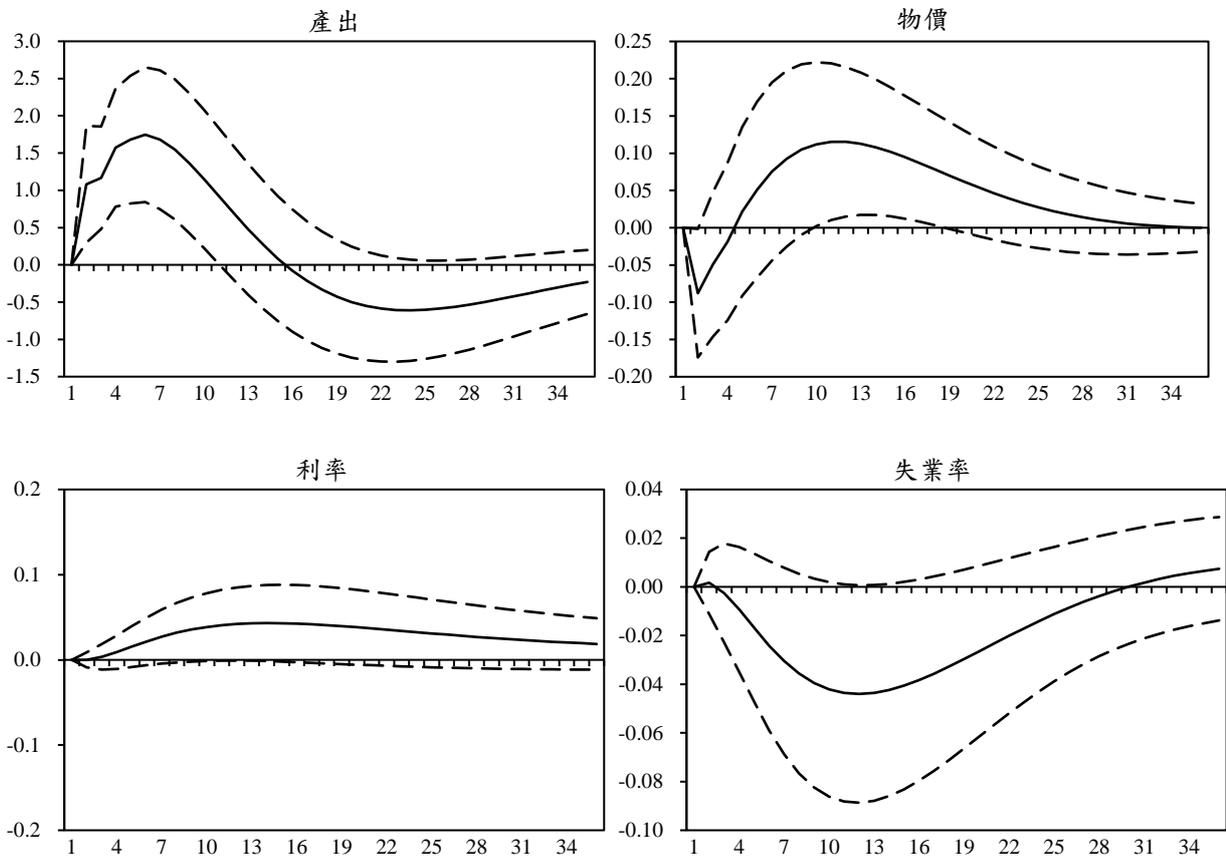
如前所述，金融情勢會透過影響家庭與企業的儲蓄及投資行為，影響實際的經濟活動；而貨幣政策從決策傳遞到最終目標多經由這些金融變數傳遞，因此，以金融情勢評估未來總體經濟走勢對央行相當重要。本小節採用 5 變數之 VAR 模型，包含產出(以工業生產指數年增率衡量)、物價(以消費者物價指數年增率衡量)、利率(以隔夜拆款利率衡量)、失業率與 FCI，分析金融情勢衝擊對總體經濟之影響。此處分析採 Koop et al. (1996)所提出的一般化衝擊反應函數(*generalized impulse response function*)估計，以避免變數間的排序對估計結果造成影響。

圖 17 為 FCI 衝擊對產出、物價、利率與失業率的反應函數，衝擊大小為 1 個標準差的正向衝擊，兩側虛線為顯著水準 95%的信賴區間，反應期間為 36 期(3 年)。圖 17 之 FCI 以 FCI-factor 當作代表。實證結果可發現，當 FCI 正向衝擊，亦即金融情勢寬鬆會使產出立即上升，產出持續顯著增加大約 1 年後轉呈不顯著；金融情勢寬鬆程度上升會先使物價下降，而後因持續寬鬆狀態而讓物價於第 10 期後顯著略微上升，利率雖上升惟不顯著，失業率則下降。其餘 5 種 FCI 亦有進行相同的 VAR 分析，結果大致相同¹²。

金融情勢衝擊對總體經濟之影響符合預期且與多數文獻一致，如 Aikman et al. (2020)亦發現 FCI 正向衝擊會使實質 GDP 上升、失業率下降與信用相對 GDP 比率上升。

¹² 囿於篇幅，不再一一列示。

圖 17 FCI 衝擊對總體變數之反應函數



註：1.衝擊大小為 1 個標準差；
2.虛線為 95%信賴區間。

伍、結論與心得

金融脆弱性不僅會增加經濟衰退的風險，甚至會因高度脆弱，擴大和延長負向衝擊對經濟成長的影響，2008 年全球金融危機深刻顯現金融市場的脆弱性對實體經濟活動之負面影響。然而，金融市場變化資訊龐雜且瞬息萬變，不易即時且全面掌握，FCI 匯集一國整體的金融情況，以綜合之方式描繪金融變數與總體經濟活動之間的關係，據以預測未來總體經濟走勢，並可提供未來經濟下行風險之資訊。因此，FCI 可作為央行訂定貨幣政策時之參考指標。

考量機器學習發展之趨勢，本專題研究另增加監督式學習方法之運用，嘗試包含 LDA、LR、RF、SVM 等，透過將資料以目標函數進行訓練，進行降維後，編製與估計台灣之 FCI，分析其對台灣經濟成長與下行風險有良好之預測能力，提供政策參考。

再者，考量近年文獻與主要央行 FCI 之應用，本專題研究探討 FCI 對總體經濟變數之領先性、對經濟下行風險之預測、與景氣循環轉折點之預測等議題。透過探討金融情勢與未來經濟下行風險間的關係，進而評估 FCI 是否可作為早期預警指標。最後，本專題研究亦以 VAR 模型，分析金融情勢衝擊對總體經濟之影響，說明其對貨幣政策之意涵。

本專題研究一共估計 6 個 FCI，分別為(1) FCI-Factor，以因子模型估計，選取主要因子當作 FCI；(2) FCI-LDA 採用 LDA 方法估計，以負的工業生產指數年增率當作目標函數；(3) FCI-Fa+LDA，先於五個金融市場中以因子模型萃取主要因子，再以 LDA 方法(以負的工業生產指數年增率當作目標函數)估計權重；(4) FCI-LassoLogit，以正規化 Logit 模型估計；(5) FCI-RF，以 RF 法估計；(6) FCI-SVM，以 SVM 方法估計。

本專題研究建構之 FCI 數值為正，表示金融情勢較為寬鬆，對於未來經濟成長有正向拉力；FCI 若為負，表示金融情勢較為緊縮，將抑制未來經濟成長動能。首先，為了較全面性的檢視總體經濟變數與 FCI 的相互關係，本專題研究以國發會的領先、同時與落後指標之構成項目當作實質總體經濟變數，在觀察的樣本期間內，本專題研究所建構的 6 個 FCI 具有領先絕大多數實質面的總體經濟變數之特性，可有效掌握實質面景氣脈動。

本專題研究實證結果亦發現，雖因不同模型估計之顯著性致估計

結果略有不同，惟仍可發現 FCI 在不同分量下的意涵，大多數監督式學習之 FCI 皆能監測未來經濟成長的下行風險，尤其是在短期較為明顯，其中以 FCI-LDA 與 FCI-SVM 表現較佳；而非監督式學習之 FCI，則是在較長期表現較好。整體而言，FCI 可提供有關未來經濟成長、尤其是經濟成長面臨下行風險之資訊。此外，當 FCI 下降，未來景氣衰退之機率將上升，顯示 FCI 可反映未來景氣衰退，且隨預測期間的增加，FCI 對較長期之景氣衰退表現顯著較佳，顯著優於其對短期景氣衰退的表現，可作為對未來景氣衰退之良好的預警指標。最後，當面臨 FCI 正向衝擊，產出會立即上升且顯著持續增加大約 1 年；物價一開始下降，而後因持續寬鬆狀態而於第 10 期後顯著微上升，利率雖上升惟不顯著，失業率則下降(不顯著)。

本次到德國與英國進行專題研究，了解小型開放經濟體面對除了美國貨幣政策帶來的外溢效果外，高度金融整合(financial integration)可能對其為風險分擔(risk sharing)，亦或是傳遞更為快速且巨大的衝擊。再者，如何評估與量化經濟下行風險與其傳遞管道，更有利於提升專題研究深度。此外，英格蘭銀行課程介紹 DSGE 模型之建構，包含開放經濟體、代表性個人(RANK)與異質性個人(HANK)等模型，以及常用之預測模型(貝氏 VAR、狀態空間模型等)，對建模與預測實務之精進頗有助益。整體而言，以上經驗分享均獲益良多，茲提出心得與建議事項如下：

1. FCI 除了提供潛在風險對未來經濟成長影響之有用訊息，可作為未來景氣衰退之良好預警指標外，央行利用 FCI 進行分析尚有若干優點，例如可協助貨幣政策對外溝通，亦即透過 FCI 對外界說明整體金融情勢是否寬鬆或緊縮，以及近期發展情況，以資料說明(data-dependent)的方式，明確與透明的溝通有助強化外界對貨幣政策的公信力，進而引導市場預期；此外，FCI 勾勒總體經濟模

型未能捕捉到的重要金融面向，且為較高頻率之指標，可作為總體經濟評估的穩健性檢測。

2. 機器學習雖可處理大量且複雜的資料，降低人為錯誤，提高工作效率與預測的準確度，惟相當依賴大量且高品質之資料，計算耗時且應用上仍有一些侷限，例如容易出現過度配適(即演算法過度依賴訓練集合而產生偏誤)、尚須人為介入，方能達到最佳效果，或是其結果難以解釋，無法了解因果關係等問題。英格蘭銀行亦表示該行尚未採用機器學習進行 MFCI 估計，主要係因機器學習猶如黑盒子(black-box)模式，難以解釋其經濟意涵；且若以機器學習進行相關政策分析時，恐無法知道衝擊的來源，更無法追蹤其效果。因此，以機器學習估計之 FCI 可能較適合當作輔助工具。
3. 在全球高度金融整合下，小型開放經濟體之金融情勢深受全球金融情勢衝擊，浮動匯率亦無法完全阻隔其影響，致吸納衝擊效果有限。因此，早期預警指標的目的便是協助政策制定者，事前採取因應措施，防止可能的金融傷害，甚至是巨幅經濟損失，而 FCI 作為早期預警指標，確實可作為政策施行之參考依據。
4. 面對可能金融危機的發生，除了依據早期預警指標外，應進一步了解金融危機的起因。因此，當 FCI 持續示警時，宜分析其衝擊之來源。此外，考量金融衝擊可能引發比景氣衰退更加嚴重的負向影響，若要獲得較佳的貨幣政策成效，須考慮總體經濟及金融體系的相互關係。針對金融衝擊可能引發國內金融市場動盪，可超前部署總體審慎政策，並協調其他政策工具，以減緩衝擊。

參考文獻

- 台大-國泰產學合作計畫 (2011), 台灣經濟與金融情勢指數(FCI)編製與應用。
- 徐千婷 (2008), 「我國金融情勢指數之實證研究」, 中央銀行季刊, 第 30 卷第 3 期, 頁 5-47。
- 張天惠 (2012), 「我國金融情勢指數與總體經濟預測」, 中央銀行季刊, 第 34 卷第 2 期, 頁 11-41。
- 張天惠 (2023), 「台灣金融情勢對經濟下行風險之預測分析」, 未發表文稿, 財團法人台北外匯市場發展基金會。
- 張天惠、朱浩榜 (2020), 「台灣金融情勢與經濟預測」, 經濟論文叢刊, 第 48 卷第 1 期, 頁 77-106。
- 管中閔、徐之強、黃裕烈、徐士勛 (2014), 「臺灣金融情勢指數與總體經濟關係」, 臺灣經濟預測與政策, 第 44 卷第 2 期, 頁 103-132。
- 黃裕烈、徐之強、張瑞雲 (2019), 「景氣監測預警系統之研究」, 國家發展委員會委託計畫。
- Adrian, Tobias, N. Boyarchenko, and D. Giannone (2016), “Vulnerable Growth,” Discussion Paper DP11583, Centre for Economic Policy Research, London.
- Adrian, Tobias, N. Boyarchenko, and D. Giannone (2019), “Vulnerable Growth,” *American Economic Review*, 109(4), pp.1263-89.
- Adrian, Pawel and Reamonn Lydon (2019), “Clicks and Jobs: Measuring Labour Market Tightness Using Online Data,” Vol. 2019, No.6, Central Bank of Ireland.
- Adrian, Tobias, Federico Grinberg, Nellie Liang, Sheheryar Malik, and Jie Yu (2022), “The Term Structure of Growth-at-Risk,” *American Economic Journal: Macroeconomics*, 14 (3), pp. 283-323.
- Aguilar, Pablo, Corinna Ghirelli, Matías Pacce, and Alberto Urtasun (2021), “Can News Help Measure Economic Sentiment? An Application in COVID-19 Times,” *Economics Letters*, 199, 109730.

- Aikman, David, Andreas Lehnert, Nellie Liang, and Michele Modugno (2020), “Credit, Financial Conditions, and Monetary Policy Transmission,” *International Journal of Central Banking*, 16(3), pp. 141-179.
- Aikman, David, Jonathan Bridges, Sinem Hacioglu Hoke, Cian O’Neill and Akash Raja (2019), “Credit, Capital and Crises: a GDP-at-Risk Approach,” Staff Working Paper No. 824, Bank of England.
- Alessandri, Piergiorgio and Antonio Di Cesare (2021), “Growth-at-risk in Italy During the COVID-19 Pandemic,” Notes on Financial Stability and Supervision, Banca d’Italia.
- Alsterlind, Jan, Magnus Lindskog and Tommy von Brömsen (2020), “An Index for Financial Conditions,” Staff Memo, Sveriges Riksbank.
- Angelopoulou, E., H. Balfoussia and H. Gibson (2013), “Building a Financial Conditions Index for the Euro Area and Selected Euro Area Countries: What Does it Tell us About the Crisis?” ECB Working Paper, No. 1541.
- Bai, J. and Ng, S. (2004), “A PANIC Attack on Unit Roots and Cointegration,” *Econometrica*, 72, pp.1127-1177.
- Bank of England (2021), “How do we Monitor UK Financial Conditions,” Bank Overground.
- Bank for International Settlements (2022), “Machine Learning in Central Banking,” IFC Bulletin No 57, BIS.
- Bank of Japn (2018), Financial System Report, October, 2018.
- Bank of Japn (2022), Financial System Report, October, 2022.
- Global Financial Stability Report, April 2021: Preempting a Legacy of Vulnerabilities, IMF.
- Baron, Matthew and Wei Xiong (2017), “Credit Expansion and Neglected Crash Risk,” *The Quarterly Journal of Economics*, 132(2), pp. 713-764.
- Barro, Robert J., José F. Ursúa, and Joanna Weng (2020), “The Coronavirus

- and the Great Influenza Pandemic: Lessons from the “Spanish Flu” for the Coronavirus’s Potential Effects on Mortality and Economic Activity,” NBER Working paper, 26866.
- Biau, G. and E. Scornet (2016), “A Random Forest Guided Tour,” *TEST*, 25(2), pp.197-227.
- Bishop, C. M. (2006), *Pattern Recognition and Machine Learning*, Springer, Berlin.
- Borio, Claudio (2014), “The Financial Cycle and Macroeconomics: What Have We Learnt?” *Journal of Banking and Finance*, 45(C), pp. 182-198.
- Borio, Claudio and Philip Lowe (2002), “Asset Prices, Financial and Monetary Stability: Exploring the Nexus,” BIS Working Papers No 114.
- Brave, Scott A., and R. Andrew Butters (2010), “Gathering Insights on the Forest from the Trees: A New Metric for Financial Conditions,” Federal Reserve Bank of Chicago, Working Paper, WP 2010-07.
- Brave, Scott A., and R. Andrew Butters (2011), “Monitoring Financial Stability: A Financial Conditions Index Approach,” *Economic Perspectives IQ*, Federal Reserve Bank of Chicago, pp. 22-43.
- Brave, Scott A. and David Kelley (2017), “Introducing the Chicago Fed’s New Adjusted National Financial Conditions Index,” *Chicago Fed Letter*, No. 386.
- Breiman, Leo (2001), “Random Forests,” *Machine Learning*, 45, pp. 5–32.
- Brunnermeier, Markus K. and Yuliy Sannikov (2014), “A Macroeconomic Model with a Financial Sector,” *American Economic Review*, 104(2), pp. 379-421.
- Caldara, Dario, Matteo Iacoviello, Patrick Molligo, Andrea Prestipino, and Andrea Raffo (2020), “The Economic Effects of Trade Policy Uncertainty,” *Journal of Monetary Economics*, 109, pp, 38–59.
- Castro, Vitor (2010), “The Duration of Economic Expansions and Recessions: More Than Duration Dependence,” *Journal of Macroeconomics*, 32, pp. 347–365.

- Chakraborty, Chiranjit and Andreas Joseph (2017), “Machine Learning at Central Banks,” Bank of England Working Paper No. 674.
- Claessens, S., M. A. Kose, and M. E. Terrones (2011), “Financial Cycles: What? How? When?” IMF Working Paper No. 2011/076.
- Claessens, S., Kose M. Ayhan, and M. E. Terrones (2012), “How do Business and Financial Cycles Interact?” *Journal of International Economics*, 87(1), pp. 178-90.
- Chong, Eilyn, Chiung Ching Ho, Zhong Fei Ong, and Hong H Ong (2022), “Using Nnews Sentiment for Economic Forecasting: A Malaysian Case Study,” IFC Bulletins chapters, in: Bank for International Settlements (ed.), *Machine learning in central banking*, volume 57, Bank for International Settlements.
- D’Antonio, P. (2008), “A View of the U.S. Subprime Crisis,” in DiClemente, R. and K. Schoenholtz, EMA Special Report, September, Citigroup Global Markets Inc., pp. 26-28.
- Debuque-Gonzales, Margarita and Maria Socorro Gochoco-Bautista (2013), “Financial Conditions Indexes for Asian Economies,” ADB Economics Working Paper Series No.333, pp.1-53.
- De Santis, Roberto A. and Wouter Van der Veken (2020), “Macroeconomic Risks Across the Globe due to the Spanish Flu,” ECB Working Paper No. 2466.
- Demirgüç-Kunt, Asli and Enrica Detragiache (1998), “The Determinants of Banking Crises in Developing and Developed Countries,” IMF Staff Papers, 45(1), pp. 81-109.
- Doz, C., D. Giannone, and L. Reichlin (2011), “A Two-step Estimator for Large Approximate Dynamic Factor Models Based on Kalman Filtering,” *Journal of Econometrics*, 164(1), pp.188-205.
- Doz C., D. Giannone, and L. Reichlin (2012), “A Quasi–Maximum Likelihood Approach for Large, Approximate Dynamic Factor Models,” *The Review of Economics and Statistics*, 94(4), pp 1014-1024.

- Duprey, Thibaut and Alexander Ueberfeldt (2020), “Managing GDP Tail Risk,” Staff Working Paper 2020-3, Bank of Canada, Ottawa.
- ECB (2012), “Financing Conditions Indices for the Euro Area,” in: Monthly Bulletin, August 2012.
- Erdem, M. and K. Tsatsaronis (2013), “Financial Conditions and Economic Activity: A Statistical Approach” in: BIS Quarterly Review, March 2013, pp. 37-52.
- Estrella, A. (1998), “A New Measure of Fit for Equations with Dichotomous Dependent Variables,” *Journal of Business and Economic Statistics*, 16(2), 198–205.
- Forni, M., M. Hallin, M. Lippi, and L. Reichlin (2005), “The Generalized Dynamic Factor Model: One-Sided Estimation and Forecasting,” *Journal of the American Statistical Association*, 100(471), pp.830-840.
- Ferrara, Laurent, Matteo Mogliani, and Jean-Guillaume Sahuc (2022), “High-frequency Monitoring of Growth at Risk,” *International Journal of Forecasting*, 38(2), pp. 582-595.
- Figueres, Juan Manuel & Jarociński, Marek (2020), “Vulnerable Growth in the Euro Area: Measuring the Financial Conditions,” *Economics Letters*, 191, pp.109-126.
- Fisher, R.A. (1936), “The Use of Multiple Measurements in Taxonomic Problems,” *Annals of Eugenics*, 7, pp. 179-188.
- Fransson, Lina and Oskar Tysklind (2017), “An Index for Financial Conditions in Sweden,” *Sveriges Riksbank Economic Review*, 2017:1, pp. 6-26.
- Friedman, Jerome, Trevor Hastie, and Rob Tibshirani (2010), “Regularization Paths for Generalized Linear Models via Coordinate Descent,” *Journal of Statistical Software*, 33(1), pp. 1-22.
- Gauthier, C., C. Graham, and Y. Liu (2004), “Financial Conditions Indexes for Canada,” Bank of Canada Working Paper No. 2004-22.
- Genberg, Hans and Ozer Karagedikli (2021), “Machine Learning and

Central Banks: Ready for Prime Time?” SEACEN Working Papers.

Gertler, Mark, and Simon Gilchrist (2018), “What Happened: Financial Factors in the Great Recession,” *Journal of Economic Perspectives*, 32(3), pp. 3-30.

Glick, R. and M. Hutchison (2001), “Banking and Currency Crises: How Common Are Twins?” In R. Glick, R. Moreno, and M. Spiegel, eds. *Financial Crises in Emerging Markets*. Cambridge, UK: Cambridge University Press, Chapter 2.

Goodhart, C. and B. Hofmann (2001), “Asset Prices, Financial Conditions, and the Transmission of Monetary Policy,” Paper prepared for the conference on Asset Prices, Exchange rates, and Monetary Policy, Stanford University, March 2-3.

Gonzalez, Steven (2000), “Neural Networks for Macroeconomic Forecasting: A Complementary Approach to Linear Regression Models,” Working Papers, Department of Finance Canada.

Greenwood, Robin, Samuel G. Hanson, Andrei Shleifer, and Jakob Ahm Sørensen (2022), “Predictable Financial Crises,” *Journal of Finance*, 77(2), pp. 863-921.

Guichard, S. and D. Turner (2008), “Quantifying the Effect of Financial Conditions on US Activity,” OECD Economic Department Working paper, No. 635.

Hatzius, J., P. Hooper, F. Mishkin, K. L. Schoenholtz, and M. W. Watson (2010), “Financial Conditions Index: A Fresh Look after the Financial Crisis,” NBER Working Paper No. 16150.

Hartigan, Luke and Michelle Wright (2021), “Financial Conditions and Downside Risk to Economic Activity in Australia,” RBA Research Discussion Papers rdp2021-03, Reserve Bank of Australia.

Hoerl, Arthur E. and Rober W. Kennard (1970), “Ridge Regression: Biased Estimation for Nonorthogonal Problems,” *Technometrics*, 12, pp. 55-67.

Holló, D., M. Kremer, and M. Lo Duca (2012), “CISS - A Composite

Indicator of Systemic Stress in the Financial System,” Working paper series 1426, ECB.

IMF (2017a), “Are Countries Losing Control of Domestic Financial Conditions?” in Global Financial Stability Report, April.

IMF (2017b), “Financial Conditions and Growth at Risk,” in Global Financial Stability Report, October.

IMF (2021), Global Financial Stability Report, April 2021: Preempting a Legacy of Vulnerabilities, IMF.

Jordà, Òscar, Moritz Schularick and Alan M. Taylor (2016), “The Great Mortgaging: Housing Finance, Crises and Business Cycles,” *Economic Policy*, 31(85), pp. 107-152.

Kalamara, Eleni, Arthur Turrell, Chris Redl, George Kapetanios, and Sujit Kapadia (2022), “Making Text Count: Economic Forecasting Using Newspaper Text,” *Journal of Applied Econometrics*, 37(5), pp. 896-919.

Kapetanios, George, Simon Price and Garry Young (2018), “A UK Financial Conditions Index Using Targeted Data Reduction: Forecasting and Structural Identification,” *Econometrics and Statistics*, 7, pp. 1-17.

Karadi, P, J Amann, J S Bachiller, P Seiler and J Wursten (2023), “Price Setting on the Two Sides of the Atlantic – Evidence from Supermarket Scanner Data”, *Journal of Monetary Economics*, forthcoming.

Kearns, J. (2020), “Banking and the COVID-19 Pandemic,” Keynote address given at the 33rd Australasian Finance and Banking Conference, organised by the Institute of Global Finance and the School of Banking and Finance, UNSW Business School, Sydney, 15–17 December.

Kien, Jean-Noel, Etienne Kintzler, and Theo Nicolas (2022), “Fostering European SMEs' Internationalization Using Big Data: the BIZMAP Application,” IFC Bulletins chapters, in: Bank for International Settlements (ed.), Machine learning in central banking, volume 57, Bank for International Settlements.

Kiley, Michael T. (2020), “Financial Conditions and Economic Activity:

- Insights from Machine Learning,” Finance and Economics Discussion Series 2020-095, Washington: Board of Governors of the Federal Reserve System.
- Krishnamurthy, Arvind and Tyler Muir (2017), “How Credit Cycles across a Financial Crisis,” NBER Working Paper No. 23850.
- Koop, G. and D. Korobilis (2014), “A New Index of Financial Conditions,” *European Economic Review*, 71, pp. 101-116.
- Koop, G., M. H. Pesaran, and S. M. Potter (1996), “Impulse Response Analysis in Nonlinear Multivariate Models.” *Journal of Econometrics*, 74, pp. 119-147.
- Krygier, Dominika and Tamás Vasi (2021), “Macrofinancial Conditions, Financial Stability and Economic Growth – Evaluating the GaR Framework,” Staff Memo, Sveriges Riksbank.
- Larsen, Vegard H. and Leif A. Thorsrud (2019), “The Value of News for Economic Developments,” *Journal of Econometrics*, 210(1), pp. 203–218.
- Levanon, Gad, Jean-Claude Manini, Ataman Ozyildirim, Brian Schaitkin, and Jennelyn Tanchua (2015), “Using Financial Indicators to Predict Turning Points in the Business Cycle: The Case of the Leading Economic Index for the United States,” *International Journal of Forecasting*, 31(2), pp. 426-445.
- López-Salido, David, Jeremy C. Stein, and Egon Zakrajšek (2017), “Credit-Market Sentiment and the Business Cycle.” *The Quarterly Journal of Economics*, 132 (3), pp. 1373-1426.
- Loria, Francesca, Christian Matthes, and Donghai Zhang (2019), “Assessing Macro-Economic Tail Risk,” FRB Richmond Working Paper No. 19-10.
- Mayes, D. and M. Virén (2001), “Financial Conditions Indexes,” Bank of Finland Discussion Papers No. 2001-17.
- Miranda-Agrippino, S., and H. Rey (2020), “US Monetary Policy and the

- Global Financial Cycle,” *The Review of Economic Studies*, 87(6), pp. 2754-2776.
- Miranda-Agrippino, S., and H. Rey (2022), “The Global Financial Cycle,” *Handbook of International Economics*, 6, pp. 1-43.
- McCulloch, W.S. and W. Pitts (1943), “A Logical Calculus of the Ideas Immanent in Nervous Activity,” *Bulletin of Mathematical Biophysics*, 5, pp. 115–133.
- Menz, Jan-Oliver, Richard Schnorrenberger and Elisabeth Wieland (2022), “Using High-Frequency Scanner Data to Evaluate German Food Prices in Real Time,” *Deutsche Bundesbank Discussion Paper*, No 49/2022.
- Metiu, Norbert (2022), “A Composite Indicator of Financial Conditions for Germany,” Technical Paper 03/2022, Deutsche Bundesbank.
- Mian, Atif R., Amir Sufi, and Emil Verner (2017), “Household Debt and Business Cycles Worldwide,” *The Quarterly Journal of Economics*, 132(4), pp. 1755–1817.
- Miglietta, Arianna and Fabrizio Venditti (2019), “An Indicator of Macro-Financial Stress for Italy,” Notes on Financial Stability and Supervision, Banca d’Italia.
- Monetary Authority of Singapore (2019), Financial Stability Review, November 2019.
- Nguyen, Kim and Gianni La Cava (2020), “Start Spreading the News: News Sentiment and Economic Activity in Australia,” RBA Research Discussion Papers rdp2020-08, Reserve Bank of Australia.
- O’Brien, Martin and Michael Wosser (2021), “Growth at Risk and Financial Stability,” in Financial Stability Notes 2/FS/21, Central Bank of Ireland.
- Osorio, C., R. Pongsaparn and D. F. Unsal (2011), “A Quantitative Assessment of Financial Conditions in Asia,” IMF Working Paper, No. 11/173.
- Pariès, M. D., L. Maurin, and D. Moccero (2014), “Financial Conditions

- Index and Credit Supply Shocks for the Euro Area,” ECB Working Paper Series.
- Petronevich, A., and Sahuc, J. (2019), “A new Banque de France Financial Conditions Index for the Euro Area,” *Banque de France Bulletin*, 223.
- Pietrzak, Marcin (2022), “Can Financial Sector Distress Be Detected Early?” *Borsa Istanbul Review*, 22(6), pp. 1132-1144.
- Pisner, D. A., and D. M. Schnyer (2020), “Chapter 6 - Support Vector Machine,” in *Machine Learning: Methods and Applications to Brain Disorders*, pp. 101–121.
- Plagborg-Møller, Mikkel, Lucrezia Reichlin, Giovanni Ricco, and Thomas Hasenzagl (2020), “When is Growth at Risk?” *Brookings Papers on Economic Activity*, 2020 (Spring), pp.167-229.
- Prasad, Ananthakrishnan, Selim Elekdag, Phakawa Jeasakul, Romain Lafarguette, Adrian Alter, Alan Xiaochen Feng and Changchun Wang (2019), “Growth at Risk: Concept and Application in IMF Country Surveillance,” IMF Working Paper Series, No. 19/36.
- Rambaccussing, Dooruj and Andrzej Kwiatkowski (2020), “Forecasting with News Sentiment: Evidence with UK Newspapers,” *International Journal of Forecasting*, 36(4), pp. 1501–1516.
- Rhys, H. (2020), *Machine Learning with R*, tidyverse, and mlr, Manning Publications.
- Richardson, Adam, Thomas van Florenstein Mulder and Tuğrul Vehbi (2021), “Nowcasting GDP Using Machine-Learning Algorithms: A Real-time Assessment,” *International Journal of Forecasting*, 37(2), pp. 941-948.
- Rosenberg, M. (2009), “Financial Conditions Watch,” Bloomberg.
- Rosenblatt, F. (1958), “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain,” *Psychological Review*, 65(6), pp. 386–408.
- Schularick, Moritz and Alan M. Taylor (2012), “Credit Booms Gone Bust,”

American Economic Review, 102, pp. 1029-1061.

Shankar, Anand (2014), “A Financial Conditions Index for India,” RBI Working Paper Series No. 08.

Shibitov, Denis and Mariam Mamedli (2021), “Machine Learning Real-Time CPI Forecasting,” on IFC Workshop of “Data Science in Central Banking” Machine Learning Applications.

Swiston, A. (2008), “A U.S. Financial Conditions Index: Putting Credit Where Credit is Due,” IMF Working Paper No. 08/161.

Szabo, Milan, Zlataše Komárková, Martin Časta (2020), “Vulnerable Growth: Bayesian GDP-at-Risk,” Thematic Article on Financial Stability 2/2020, Czech National Bank.

Tibshirani, Robert (1996), “Regression Shrinkage and Selection via the Lasso,” *Journal of the Royal Statistical Society. Series B (Methodological)*, 58(1), pp. 267-288.

Vonen, N. H. (2011), “A Financial Conditions Index for Norway,” Norges Bank Staff Memo, No. 27.

Wacker, K. M, D. Lodge, and G. Nicoletti (2014), “Measuring Financial Conditions in Major Non-euro area Economies,” ECB Working Paper, No. 1743.