

112cbc-經 1(委託研究報告)

台灣通膨率預測： 運用大數據資料分析

受委託單位：國立政治大學

研究主持人：林馨怡 (國立政治大學經濟學系)

兼任研究員：顏佑銘 (國立政治大學國際經營與
貿易學系)

葉錦徽 (國立中央大學財務金融學
系)

中央銀行 委託研究

中華民國 113 年 5 月

(本報告內容純係作者個人之觀點，不應引申為本機關之意見)

| |
|--------------|
| 中央銀行委託研究計畫編號 |
|--------------|

| |
|------------|
| 112cbc-經 1 |
|------------|

台灣通膨率預測： 運用大數據資料分析

受委託單位：國立政治大學

研究主持人：林馨怡 (國立政治大學經濟學系)

兼任研究員：顏佑銘 (國立政治大學國際經營與
貿易學系)

葉錦徽 (國立中央大學財務金融學
系)

研究期程：中華民國 112 年 5 月至 113 年 5 月

研究經費：新臺幣 700,000 元

中央銀行 委託研究

中華民國 113 年 5 月

(本報告內容純係作者個人之觀點，不應引申為本機關之意見)

摘要

本計畫選擇 93 個與台灣通貨膨脹相關的總體經濟及貨幣金融變數，構建 2000 年 1 月至 2023 年 12 月的大數據資料庫，並應用時間序列模型、LASSO 家族模型、因子模型，非線性機器學習方法，以及組合模型預測台灣通膨率。實證結果發現，在向前一期通膨預測方面，無論是線性、非線性機器學習模型或是組合模型的預測表現相近，均優於時間序列模型。在短期或中長期通膨率預測方面，非線性機器學習模型具有較小的預測誤差，其中，隨機森林方法的預測表現最佳，此結果與重要總體經濟變數與通膨之間潛在的非線性關係有關。再者，藉由觀察預測模型選擇對通膨預測的重要變數，我們發現台灣通膨深受國際因素及進出口貿易影響，主要貿易對手國相關變數經常被選為重要變數。國內因素中，貨幣總計數、市場利率、批發與零售業營業額、以及供給面相關變數對通膨預測較有貢獻。此外，房市及股市相關變數也有一定的解釋能力。最後，包含領先、同時、落後指標的綜合指數、企業脆弱指數、痛苦指數及非流動性指標等指數類型變數涵蓋市場重要訊息，亦富含通膨預測資訊。

目錄

| | |
|--------------------------|-----------|
| 1 前言 | 1 |
| 2 文獻回顧 | 6 |
| 2.1 通膨預測文獻 | 6 |
| 2.2 台灣通膨率預測文獻 | 13 |
| 3 研究方法 | 16 |
| 3.1 時間序列模型 | 16 |
| 3.2 LASSO 模型家族 | 17 |
| 3.3 因子模型 | 20 |
| 3.4 非線性機器學習方法 | 23 |
| 3.5 組合式預測方法 | 26 |
| 4 資料 | 29 |
| 4.1 台灣通貨膨脹率 | 29 |
| 4.2 大數據資料 | 30 |
| 4.3 資料處理說明 | 35 |
| 4.4 模型比較 | 37 |
| 5 實證結果與討論 | 40 |
| 5.1 向前一期通膨預測 | 40 |
| 5.2 短期通膨預測 | 44 |
| 5.3 中長期通膨預測 | 50 |
| 6 結論與討論 | 63 |

| | |
|-----------------------|------------|
| 參考文獻 | 65 |
| A 附錄：變數處理及資料來源 | 70 |
| B 附錄：ADF 檢定值 | 74 |
| C 附錄：樣本外預測走勢圖 | 76 |
| D 附錄：穩健性測試 | 84 |
| D.1 不同被預測變數 | 84 |
| D.2 不同樣本期間 | 84 |
| D.3 不同視窗長度 | 85 |
| E 附錄：期中報告意見回覆 | 91 |
| F 附錄：期末報告意見回覆 | 111 |

圖目錄

| | | |
|-----|-----------------------------------|----|
| 圖 1 | CPI 年增率 (%) | 31 |
| 圖 2 | 核心 CPI 年增率 (%) | 31 |
| 圖 3 | 向前期樣本外預測走勢圖 ($h = 1$) | 43 |

表目錄

| | | |
|------|---|----|
| 表 1 | 預測模型 | 39 |
| 表 2 | 預測模型之向前期預測表現 ($h=1$) | 42 |
| 表 3 | 各模型重要變數 ($h=1$) | 45 |
| 表 4 | 未來一年內通膨率預測結果 ($h=3、6$) | 46 |
| 表 5 | 未來一年內通膨率預測結果 ($h=9、12$) | 47 |
| 表 6 | 各模型重要變數 ($h=3$) | 51 |
| 表 7 | 各模型重要變數 ($h=6$) | 52 |
| 表 8 | 各模型重要變數 ($h=9$) | 53 |
| 表 9 | 各模型重要變數 ($h=12$) | 54 |
| 表 10 | 未來二年內通膨率預測結果 ($h=18、24$) | 55 |
| 表 11 | 未來三年內通膨率預測結果 ($h=30、36$) | 56 |
| 表 12 | 各模型重要變數 ($h=18$) | 59 |
| 表 13 | 各模型重要變數 ($h=24$) | 60 |
| 表 14 | 各模型重要變數 ($h=30$) | 61 |
| 表 15 | 各模型重要變數 ($h=36$) | 62 |
| 表 18 | 以不同 CPI 通膨率作為被解釋變數 ($h=1$) | 86 |
| 表 19 | 以不同 CPI 通膨率作為被解釋變數 ($h=12$) | 87 |
| 表 20 | 不同樣本區間 ($h=1$) | 88 |

| | |
|----------------------------------|----|
| 表 21 不同樣本區間 ($h=12$) | 89 |
| 表 22 不同視窗長度 | 90 |

1 前言

通貨膨脹是總體經濟中重要指標之一，若能了解通貨膨脹走勢，將有助於判斷當前經濟環境及預測未來經濟狀況。獲得值得信賴和準確的通貨膨脹率資料是相當重要的；例如：政策執行者在執行貨幣和財政等相關政策時，投資者對名目資產進行避險時，廠商做投資決策和商品定價時，以及勞工和管理者間的薪資契約協商等情況，皆需仰賴準確的通貨膨脹率資料或是正確的通貨膨脹率預測。

目前關於通膨預測的文獻，除了以傳統時間序列模型為基礎的計量模型外，主要可以分為四大類。第一大類為以總體理論模型為預測模型的文章，第二大類則是嘗試將意見調查結果納入通膨預測研究，第三大類則係以多個總體變數建構新指標，包括擴散指標 (diffusion index)、因子模型 (factor model)，以及動態因子模型 (dynamic factor model) 等方式進行通膨預測。近年來，有許多大型總體金融數據資料庫建構，但鑑於過去傳統計量方法不再適用，且隨著機器學習方法蓬勃發展，經濟學者將機器學習方法運用於通膨預測，此為第四大類文獻。相關文獻可進一步細分為線性機器學習方法，如：Medeiros and Mendes (2016)，與非線性機器學習方法，如：Inoue and Kilian (2008)、Choudhary and Haider (2012)、Kohlscheen (2021)、Medeiros et al. (2021)、Barkan et al. (2023) 以及 Almosova and Andersen (2023) 等。

前述文獻大都以美國為實證範例，近年來則陸續有學

者使用各式機器學習方法對其他國家進行通膨預測，舉例而言，Baybuza (2018) 關注俄羅斯之通膨預測，Esquivel Monge (2007) 和 Rodriguez-Vargas (2020) 預測哥斯大黎加通膨，以及 Medeiros et al. (2016) 和 Araujo and Gaglianone (2023) 進行巴西的通膨預測。此外，有多篇研究關注台灣通膨率預測，包括：陳佩玗 (2013)、朱浩榜 (2019)、蕭宇翔與繆維正 (2021)、林依伶與陳佩玗 (2021) 與朱浩榜 (2023)。然而，目前預測台灣通膨率的文獻，較少納入大量總體金融變數建構大數據資料，進行預測。此外，一旦建立大數據資料後，傳統計量模型不再適用，需應用機器學習方法才能進行預測及分析。故本計畫加入機器學習方法於台灣通膨率預測，期待能提高台灣通膨率預測之準確度，俾有助於央行擬訂適合的貨幣政策。

本計畫應用總體經濟及金融市場大數據資料，提出多種計量與機器學習方法預測台灣通膨率，並比較預測模型之預測表現。首先，本計畫選擇 93 個與台灣通貨膨脹息息相關的總體經濟及貨幣金融變數，建構 2000 年 1 月至 2023 年 12 月間的大數據資料庫，其中變數可以分成 11 個類別，包括：景氣指標、就業、民生消費、貨幣金融、股票市場、債券市場、房地產市場、大宗物資、國際收支與進出口、海外因素及情緒指標。接著，我們以時間序列模型為基準模型，並考慮多種機器學習模型進行通膨預測，包括：LASSO (least absolute shrinkage and selection operator) 家族模型 (脊迴歸 (ridge regression)、LASSO、EN、Adaptive LASSO、

Adaptive EN)，因子模型 (主成分分析法、目標因子方法 (target factors))，非線性機器學習方法 (套袋樹法 (bagging tree)、隨機森林 (random forest))，以及組合預測等模型 (LASSO-LS、EN-LS、LASSO-套袋樹、隨機森林-LS)。而後以均方根誤差 (root mean squared error, RMSE)、平均絕對誤差 (mean absolute error, MAE)，以及中位絕對偏差 (median absolute deviation from the median, MAD) 等評估指標，評估模型的樣本外預測表現。預測期間涵蓋向前一期、短期 (一年以內)，以及中長期 (二至三年)，以檢視在不同預測期間下，各預測模型的表現差異。此外，本計畫利用部分預測模型進行變數挑選，識別隱含重要通膨預測資訊的預測變數，使得通膨預測不僅及於不同預測模型間演算方法的比較，更藉由檢視對預測台灣通膨有重要影響的關鍵變數，進一步瞭解對通膨走勢有相當影響力的傳遞管道，期望藉此提升通膨預測準確性。

由向前一期通膨預測之實證結果可得知，LASSO 模型家族的預測表現普遍較基準模型佳，而因子模型的預測表現較基準模型差。就機器學習模型及組合模型而言，實證結果顯示，這些模型的預測表現亦較基準模型佳，與 LASSO 模型家族的預測表現差異不大，機器學習模型中，以套袋樹法表現較佳，組合模型中則以 LASSO-套袋樹法表現較佳。此外，LASSO 模型家族、非線性機器學習模型，以及組合模型的向前一期通膨預測的樣本外預測走勢與真實通膨率亦步亦趨，能夠精確地預測台灣通膨率。

再者，相較於向前一期之預測表現，一年內之短期通膨率預測之預測誤差皆有上升趨勢。實證結果顯示，無論何種評估標準，非線性機器學習模型皆有最小的預測誤差，此結果與向前一期之結果類似。在預測未來 3 個月通膨時，以 RMSE、MAE 及 MAD 衡量表現最佳的模型分別為套袋樹法、隨機森林及 AR 模型；在預測未來 6 個月、9 個月及 12 個月通膨時，不論是以何種評估標準衡量，均以隨機森林的預測表現最佳，已明顯改善基準模型預測表現。

最後，關於二至三年的中長期通膨預測方面，在預測未來 18 個月及 24 個月通膨時，不論是以何種評估標準衡量，以隨機森林的預測表現最佳，而套袋樹法的預測表現亦相當優異，在預測未來 24 個月通膨時，若在 MAD 為評估標準下，該模型表現較隨機森林更佳。在預測未來 30 個月及 36 個月通膨表現仍以非線性機器學習模型最為突出，LASSO 模型家族與組合模型之間差異不大。

整體而言，在不同通膨預測期間下，大致以隨機森林穩定維持最佳的預測表現，套袋樹法則居次。綜觀不同未來預測區間的樣本外多期預測走勢可以看出，LASSO 模型家族、因子模型、非線性機器學習模型及組合模型均在多期預測表現較佳，其中以非線性機器學習模型的隨機森林方法，在所有多期預測的預測期間下，維持穩定且良好的預測表現。

為了進一步瞭解關於大數據資料庫眾多變數預測通膨的能力，本計畫觀察不同預測模型在不同預測期間下所選擇對通膨預測有解釋能力的變數，我們發現，台灣通膨深受國際因

素及進出口貿易影響，以至於主要貿易對手國相關變數大多經選為重要變數，惟就機器學習模型及組合模型而言，此一影響隨預測期間拉長而有所下降。其次，國內因素對通膨預測較有貢獻者，除前一年經季節調整(季調)的CPI年增率外，尚有貨幣總計數、市場利率、批發業與零售業營業額，以及供給面相關變數等。再者，其他偶經選擇為重要變數的國內因素，如房市及股市相關變數，對通膨預測亦有一定解釋能力。最後，指數類型變數富含通膨預測資訊內涵，如領先、同時、落後指標綜合指數等景氣指標、企業脆弱指數、痛苦指數，以及非流動性指標等亦經常位列於重要變數，顯示不同面向的指標涵蓋所屬市場的重要訊息。

綜上所述，本計畫使用近期較為主流的各式機器學習模型進行通膨預測，比較不同模型間的預測表現，實證結果可以發現，應用大數據資料預測台灣通膨率時，無論是短、中、長期預測區間，機器學習方法模型之預測表現皆優於傳統時間序列計量方法。本計畫更藉由檢視對預測台灣通膨有重要影響的關鍵變數，進一步瞭解對通膨走勢存在相當影響力的傳遞管道，期望藉此提升通膨預測準確性，並期望能有政策意涵。近期許多研究指出，重要總體經濟與金融變數之間存在非線性關係，由於非線性機器學習方法較為擅長捕捉經濟體系中潛藏的非線性特徵，從而廣泛應用於通膨預測，與本計畫的實證結果一致，因此，此一研究方法可供央行未來通膨預測參考，以利後續政策執行，並達到央行經營目標。

2 文獻回顧

通貨膨脹為總體經濟中的重要指標，準確的通膨預測因有助於判斷當前經濟環境及預測未來經濟狀況，在許多經濟決策中均扮演舉足輕重的角色。對家戶與企業而言，涉及買賣、租賃、借貸、僱傭及投資等性質的契約類型，皆係以名目價格為基礎進行議定；對一國的貨幣當局而言，準確的通膨預測除可作為制定貨幣政策的參考依據，進而達成物價穩定的核心經營目標，亦可提升通膨預期的定錨程度，從而增強實施貨幣政策的效果。鑑於通膨預測影響層面廣泛，經濟學者致力於通膨預測相關研究，持續尋找通膨預測表現良好且穩定的模型與方法。

2.1 通膨預測文獻

目前關於通膨預測的文獻，除了以傳統時間序列模型為基礎的計量模型外，主要可以分為四大類。第一大類為以總體理論模型為預測模型的文章。Stockton and Glassman (1987) 以美國 1977–1984 年通貨膨脹為例，比較不同理論模型在不同經濟狀況下的預測表現。他們發現理性預期模型通常低估真正的通貨膨脹率水準。其次，在尚未發生急遽貨幣成長的觀察期間，貨幣模型具有不錯的預測表現，惟美國政府於 1982 年改變貨幣政策後，貨幣模型的預測表現惡化。相較於以上兩種理論模型，加入預期概念的菲利普曲線具有較佳的預測結果，另外，計量模型表現優於經濟理論模型。Stock and Watson (1999b) 比較傳統和新建構的菲利普曲線模型以及多

種通膨預測模型，實證結果顯示，就預測美國 1959–1997 年通貨膨脹的能力而言，傳統菲利浦曲線模型預測表現不佳，而改用 168 個總體經濟變數組合而成的指標所建構的菲利浦曲線模型，其預測表現較佳。Cecchetti, Chu and Steindel (2000) 也探討由多個總體變數建構的指標對通貨膨脹率預測能力。他們以美國 1975–1996 年的實證研究結果顯示，加入指標變數無法改善通貨膨脹預測能力。

Atkeson and Ohanian (2001) 利用當期的通貨膨脹率作為未來一年通貨膨脹預測的單純 (naive) 方法，以美國 1985–2000 年的資料進行實證，發現傳統菲利浦曲線的預測表現比單純方法的表現差，意即在通貨膨脹情況趨於穩定的經濟環境下，菲利浦曲線對於通膨預測而言不再是一項好的工具。Fisher, Liu and Zhou (2002) 為驗證 Atkeson and Ohanian (2001) 的結果僅是否僅存在於通貨膨脹波動性較低以及貨幣政策發生改變之際，因此他們將總觀察期間擴大為 1977–2000 年。他們發現，觀察期間為 1985–2000 年時，單純方法確實擁有較佳的預測表現，但在通貨膨脹波動性較高的 1977–1984 年間，單純方法的預測表現並未較佳。由上述文獻可知，菲利浦曲線模型的通膨預測表現並不穩定，需視觀察期間而定。

第二大類則是部分經濟學者嘗試將意見調查結果納入通膨預測研究。舉例而言，Ang, Bekaert, and Wei (2007) 比較數種時間序列、菲利浦曲線及利率期限結構預測模型，以及不同意見調查結果對美國 1980 年代及 1990 年代的通膨預測

表現。實證結果發現，在所有模型中，以利率期限結構模型的預測表現最差，意見調查結果的預測表現最佳。Faust and Wright (2013) 比較計量與菲利浦曲線預測模型，以及意見調查方法預測美國 1985-2011 年的通貨膨脹率。他們發現以意見調查為基礎的主觀預測通常較以模型為基礎的預測更為準確。另外，當模型將通貨膨脹率的平均趨勢納入考量時，這些模型預測表現通常較佳。他們建議，結合當季通貨膨脹率調查預測值與長期調查預測值的方法，可獲得與實際調查預測相當的表現。

第三大類則係以多個總體變數建構新指標進行通膨預測。Stock and Watson (2002) 利用主成分分析法 (principal component analysis) 估計 215 個總體變數的因子變數，並稱之為擴散指標 (diffusion index)，再利用這些擴散指標建構預測模型。他們分析 1970-1998 年美國 8 個總體變數的結果指出，僅使用少量擴散指標建構的預測模型表現最好，且預測表現隨著預測期間加長而增進。Camba-Mendez and Kapetanios (2005) 以 5 個歐元區國家為例，他們發現以動態因子方法建立的核心通膨對整體通膨的預測能力較傳統方法所建立者為佳。Bai and Ng (2008) 進一步提出擴散指數預測的改良方法，除了允許預測變數與因子之間為非線性函數外，亦透過硬門檻標準與軟門檻標準選擇目標預測變數。研究結果發現，使用數量較少但資訊豐富的目標預測變數來估計因子，相較於傳統的擴散指數預測，在所有預測期間下，預測能力均有所提升，且使用軟門檻標準的模型預測能

力較使用硬門檻標準的模型預測能力佳。而後 Bai and Ng (2009) 提出利用 boosting 方法選擇所需預測變數預測美國 1960–2003 年的通膨率、聯邦資金利率、工業生產成長率、就業成長率及失業成長率等經濟變數，其研究結果顯示，在考慮 132 個預測變數下，boosting 方法預測表現優於一般因子增強自我迴歸預測模型，並顯著優於傳統自我迴歸預測模型。

近年來，隨著機器學習方法蓬勃發展，學者逐漸將機器學習方法運用於通膨預測，此為第四大類文獻。機器學習方法可進一步細分為線性和非線性。線性方法主要是面對高維度時變數時的變數選擇相關方法，主要為 LASSO 模型家族。例如：Medeiros and Mendes (2016) 發現，當樣本數增加，模型候選解釋變數也增加時，Adaptive LASSO 在選擇相關預測變數時具一致性，且 Adaptive LASSO 方法的預測表現較其他基準模型佳。

近期許多研究指出，重要總體經濟變數之間存在非線性關係，由於非線性機器學習方法較為擅長捕捉經濟體系中潛藏的非線性特徵，從而廣泛應用於通膨預測。

以人工神經網路 (artificial neural network) 為例，Moshiri and Cameron (2000) 使用倒傳遞神經網路模型與傳統時間序列方法預測 1970–1994 年的美國通膨率。他們的研究結果顯示，在某些預測期間，倒傳遞模型的預測表現較傳統計量方法佳。Chen et al. (2001) 使多種人工神經網路方法建構半參數非線性自迴歸模型，並比較線性模型與半參數非線性自

迴歸模型預測美國通膨的能力。研究結果發現，不論是以何種指標進行衡量，半參數非線性自迴歸模型的表現均優於基準線性模型。Nakamura (2005) 考慮僅使用 2 個落後期的簡單設定之神經網路方法，預測美國 1978–2003 的 GDP 平減指數資料。她的研究結果顯示，在短期預測區間下，神經網路的表現平均而言較單變量自我迴歸模型佳。McAdam and McNelis (2005) 則比較線性模型與以神經網路為基礎的複雜模型，對美國、日本及歐元區的通膨預測表現。研究結果發現，在歐元區的服務類價格指數上，複雜模型的預測表現優於線性模型，而在這些國家的消費者及生產者物價指數方面，複雜模型的預測表現也相當良好。

Choudhary and Haider (2012) 以人工神經網路模型預測 28 個 OECD 國家的月通膨率，研究結果發現，在較短的樣本外預測期間下，人工神經網路模型對於 45% 的國家而言為較佳的預測模型，而自我迴歸模型對於 21% 的國家而言為較佳的預測模型；在長期的樣本外預測期間下，則無特定模型的預測表現較佳。此外，將多個人工神經網路模型以進行混合，亦可作為可靠的通膨預測工具。Almosova and Andersen (2023) 使用長短期記憶循環神經網路方法預測美國每月 CPI 通膨率，研究結果顯示，此方法之預測表現優於自我迴歸模型、神經網路及馬可夫轉換模型，與季節性自迴歸移動平均模型相當。

除前述神經網路方法外，另有經濟學者使用其他機器學習法預測通膨。例如，Inoue and Kilian (2008) 提出套袋法，並

將實質經濟活動指標納入美國 CPI 預測模型，他們的研究結果顯示，套袋法預測較相同權重預測、中位數預測、指數加權整合預測等方法更為準確。惟套袋法與貝氏收縮、脊迴歸、Adaptive LASSO 以及貝氏模型平均等方法的表現差異不大。Kohlscheen (2021) 以 6 個總體經濟變數建構多個迴歸樹，對 20 個先進國家於 2000–2021 年間的通膨進行預測，此方法有相對良好的預測能力。另外，他們也發現通膨預期是預測 CPI 最重要的變數。

最近關於使用大數據預測通膨的研究朝向同時比較多種機器學習方法及應用至大數據資料。Medeiros et al. (2021) 以 McCracken and Ng (2016) 建置之美國 FRED-MD 資料庫，同時比較多種時間序列計量方法、因子方法，以及機器學習方法對美國通膨預測之表現。他們的實證結果顯示，隨機森林方法優於其他預測方法，他們指出，隨機森林的良好表現除可歸因於該模型特別的變數選擇方法，亦與重要總體經濟變數與通膨之間潛在的非線性關係有關。

前述文獻大都以美國為實證範例，近年來則陸續有經濟學者使用各式機器學習方法對其他國家進行通膨預測，期待透過不同經濟結構與型態的應用，檢視機器學習方法是否維持良好的通膨預測表現。舉例而言，Baybuza (2018) 使用數種機器學習方法對俄羅斯進行通膨預測。實證結果顯示，隨機森林及採用 boosting 方法模型的預測表現至少與傳統預測模型相同，證實了使用機器學習方法將有助於更準確地預測俄羅斯通膨情形。Esquivel Monge (2007) 及 Rodriguez-Vargas

(2020) 先後以機器學習方法預測哥斯大黎加通膨。Esquivel Monge (2007) 利用預期增強的菲利浦曲線模型等 3 種通膨的線性模型，搭配人工神經網路的系統方法，其研究結果發現，在大多數的情況下，人工神經網路的系統方法較傳統方法的預測結果佳。Rodriguez-Vargas (2020) 使用多種機器學習方法進行預測，其研究結果發現，預測表現最好的方法為長短期記憶循環神經網路、KNN (K-nearest neighbors) 以及隨機森林方法。此外，多種模型的組合預測優於個別預測，亦提升了通膨水準及變化方向等層面的預測準確性。

Medeiros et al. (2016) 及 Araujo and Gaglianone (2023) 亦先後試圖以機器學習方法來改善巴西的通膨預測。Medeiros et al. (2016) 使用 LASSO 方法預測巴西通膨率指標，研究結果顯示，短期預測方面以 LASSO 模型表現較佳，長期預測方面則以時間序列模型或是因子模型表現較佳。他們也觀察到，使用 LASSO 方法選擇變數時，通常會選到政府債務以及貨幣變數，失業及生產等變數則很少被選擇，他們根據此結果認為，菲利浦曲線無法解釋巴西通膨機制。Araujo and Gaglianone (2023) 以富含 501 個變數的大型資料庫為基礎，使用新興機器學習方法、傳統計量模型及組合預測方法等 50 種方法，其研究結果顯示，雖不存在單一最佳模型，但在許多情況下，機器學習方法預測表現優於傳統計量模型。

除了上述研究之外，關於通膨率預測的文獻眾多，包括預測模型中的參數可隨時間而改變的模型、當下通貨膨脹率之即時預報 (nowcasting)，以及先對通膨指標中部分價格劇烈

變化且與潛在通膨變化無關的成分進行識別與排除後，再進行未來整體通膨的預測等。這些方法非屬本研究範疇，爰僅簡要說明於此。

2.2 台灣通膨率預測文獻

早期台灣通膨率預測的文獻多以經濟理論模型選擇變數，建構預測模型，進行台灣通膨預測研究，例如：侯德潛與徐千婷 (2002) 建構以貨幣學派為基礎的通膨預測模型，並納入通膨預期、勞動成本以及輸入性通膨等作為解釋變數，實證結果顯示，他們所建構的通膨預測模型之預測表現優於一般時間序列模型以及主計總處的預測。葉盛與田慧琦 (2004) 綜合貨幣模型、成本加成模型及菲利浦曲線模型之重要解釋變數，再加上資產價格與銀行信用等變數，建構向量自我迴歸模型，對台灣通膨率進行預測，其實證結果顯示成本加成模型與菲利浦曲線模型的預測能力較基準模型佳，亦較貨幣模型為佳。劉淑敏 (2003) 分析躉售物價指數對 CPI 增長率之影響，並發現躉售物價指數走勢確有助於預測台灣通膨率。此外，產出缺口、服務類價格、及季節因素等變數亦對通膨有重要影響。黃朝熙 (2007) 建立向量自我迴歸模型預測台灣通貨膨脹率，他發現利用貝氏向量自我迴歸估計方法的預測表現優於其他模型。透過衝擊反應函數分析，他發現除了核心 CPI 本身的衝擊外，進口物價衝擊亦為影響核心通膨的重要因素。

近期台灣通膨預測研究在選用的研究方法及解釋變數的項

目與頻率方面更加多元。陳佩玗 (2013) 分解 CPI 組成項目，以 2000–2012 年為樣本期間，進行短期通膨率之預測。她發現，研究模型中以自我迴歸模型表現較佳。在大部分模型下，利用 CPI 子項目預測後加權所得預測值的準確性較高，顯示短期預測下，採用分解 CPI 子項目之預測方式較佳。朱浩榜 (2019) 進一步探討食物類價格變動的因素，以及食物類價格年增率與整體通膨情勢的關係。他以 1999–2016 年第二季為樣本期間，其實證結果顯示，食物類的價格較易受產量、降雨災害，甚至進口成本等供給面因素影響；此外，整體的 CPI 年增率可能影響通膨預期。蕭宇翔與繆維正 (2021) 討論食物與能源的每日價格等高頻資料是否有助預測當月通膨率，其實證結果顯示，使用即時高頻資料建構之即時預報模型，大幅提升對當月通膨率的預測準確性。再者，分別預測 CPI 子項目年增率再加總的分解預測方法，其預測表現較直接預測整體通膨率為佳，此一結果與陳佩玗 (2013) 相符。

因應主計總處將經濟成長率的衡量方式改為連鎖法，林依伶與陳佩玗 (2021) 嘗試建構適合連鎖法衡量下之台灣總體計量模型，進行短、中期之經濟與物價預測。在短期部分，她們納入季及月指標的混頻預測模型，中期預測則採用年預測模型分析。實證結果顯示運用月指標確有助提升短期預測準確性，而年預測模型結果指出，2019 年的經濟成長率及通膨率為 2019 年至 2021 年的低點。近期，朱浩榜 (2023) 利用菲利浦曲線模型探討台灣的失業率與未來通膨之間的關係是否穩定，並檢視該模型的通膨預測能力。實證結果顯示，在

2000 年以前，失業率與未來通膨之間呈顯著負向關係，含有通膨的預測資訊，約至 2001 年以後，兩者關係減弱且轉呈不顯著，通膨預測能力漸失。不過，研究結果也發現，特定情境下，菲利浦曲線模型對未來一年通膨率仍具有預測資訊。

3 研究方法

本研究使用的通膨率預測模型如下：

$$\pi_{t+h} = T_h(x_t) + u_{t+h}, \quad t = 1, \dots, T, \quad h = 1, \dots, H,$$

其中 π_{t+h} 是未來的通貨膨脹率， t 為時間點， h 為預測期間； $x_t = (x_{1,t}, \dots, x_{k,t})'$ 為預測變數，共有 k 個變數，包含當期通貨膨脹率，以及各種可能影響通膨率的總體金融變數； u_{t+h} 是模型誤差項。本計畫的預測模型中， $T_h(\cdot)$ 可為線性或是非線性函數，也可以是單個模型或不同模型組合。給定 t 期（含）以前的資訊，藉由上述通膨率預測模型，我們可以得到 $t+h$ 期的通膨率直接預測 (direct forecast) 方程式：

$$\hat{\pi}_{t+h|t} = \hat{T}_{h,t-R_h+1:t}(x_t),$$

其中 $\hat{T}_{h,t-R_h+1:t}(\cdot)$ 是利用 $t-R_h+1$ 到 t 期的數據估計的目標函數， R_h 是預測區間窗口。本研究參考過去文獻，考慮多種大數據預測模型，包含 LASSO 模型家族、因子模型、機器學習方法模型，以及組合式預測模型，並以傳統時間序列模型為基準模型。各種模型簡要介紹如下。

3.1 時間序列模型

由前面文獻回顧可知，在預測通膨時，傳統時間序列模型的預測表現經常優於其他模型。為了提供模型比較的基礎，我們將時間序列模型作為基準模型。本計畫考慮 3 個時間序列模型，第一個時間序列模型為隨機漫步模型，其設定如下：

$$\pi_t = \pi_{t-1} + e_t.$$

第二個時間序列模型為自我迴歸 (AR(p)) 模型，模型設定如下：

$$\pi_t = \alpha_0 + \sum_{i=1}^p \alpha_i \pi_{t-i} + e_t.$$

第三個時間序列模型模型是自我迴歸與移動平均 (ARMA(p, q)) 模型，其設定如下：

$$\pi_t = \alpha_0 + \sum_{i=1}^p \alpha_i \pi_{t-i} + \sum_{j=1}^q \gamma_j e_{t-j} + e_t.$$

以上模型的 π_t 是為 t 期的通膨率， α_i, γ_j 為模型參數， e_t 為誤差項。 p, q 為用來預測通膨的前期通膨率及誤差項的期數，本計畫使用貝氏資訊準則 (Bayesian information criterion; BIC) 選取最適的期數。

3.2 LASSO 模型家族

估計迴歸模型，要避免因大數據帶來的高維度所造成的過度配飾 (overfitting) 的問題時，常使用收縮法 (shrinkage)，本研究考慮五種利用收縮法估計迴歸模型的方法，是為 LASSO 模型家族。在實證應用上，使用 LASSO 模型家族預測時，可以直接使用 LASSO 家族的參數估計值進行預測，或是利用 LASSO 模型家族選出變數後，再利用所選變數做為模型預測變數。本計畫將同時考慮上述兩種方式，預測模型設定為線性迴歸模型，令 $y_t = \pi_{t+h}$ 代表迴歸模型的被解釋變數， $T_h(x_t) = \beta_0 + \sum_{i=1}^k \beta_i x_{it}$ ， β_i 為參數， x_{it} 為第 i 個解釋變數。

3.2.1 脊迴規 (Ridge Regression)

Hoerl (1962) 和 Hoerl and Kennard (1970) 提出脊迴歸，透過特定的懲罰項限制迴歸參數值，進而獲得適當的變數。脊迴歸方法的極小化問題如下：

$$\min \sum_{t=1}^T (y_t - \beta_0 - \sum_{i=1}^k \beta_i x_{it})^2 + \lambda \sum_{i=1}^k \beta_i^2,$$

其中的其中 T 為樣本數， λ 為調整係數，且 $\lambda \geq 0$ 。由上述極小化問題可以看出，脊迴歸具有壓縮估計係數的效果。脊迴歸透過將估計式向零壓縮，如此估計式的偏誤增加，同時變異數減少。

3.2.2 LASSO

Tibshirani (1996) 提出的 LASSO 方法與脊迴歸方法的概念相似，其極小化的問題如下：

$$\min \sum_{t=1}^T (y_t - \beta_0 - \sum_{i=1}^k \beta_i x_{it})^2 + \lambda \sum_{i=1}^k |\beta_i|,$$

其中 λ 為調整係數，本計畫透過交叉驗證方式選取最適 λ 。¹ LASSO 方法會使部分變數向零壓縮，因此 LASSO 方法同時具有壓縮係數值和挑選變數的效果，可達到降低解釋變數維度，解決高維度變數問題。

¹此處交叉驗證是指藉由分割訓練樣本進行交叉驗證，在本計畫中，我們將訓練集分割為十份，逐一將這十份當作樣本外測試集，並以其餘的九份當作樣本內訓練集，最後選擇 RMSE 最小的測試集之 λ 。

3.2.3 Elastic Net (EN)

由 Zou and Hastie (2005) 所提出的 EN 方法目標式如下：

$$\min \sum_{t=1}^T (y_t - \beta_0 - \sum_{i=1}^k \beta_i x_{it})^2 + \lambda_1 \sum_{i=1}^k |\beta_i| + \lambda_2 \sum_{i=1}^k \beta_i^2$$

其中 $\lambda_2/(\lambda_1 + \lambda_2) \geq 0$ ， λ_1 及 λ_2 均透過交叉驗證方式選取最適值。由上式可知，當 $\lambda_2 = 0$ 時，EN 方法可簡化為 LASSO 方法；當 $\lambda_1 = 0$ 時，EN 方法可簡化為脊迴歸。就估計係數而言，EN 方法下的參數估計係數壓縮程度會介於 LASSO 方法和脊迴歸方法之間。

3.2.4 Adaptive LASSO

由於 LASSO 方法在某些狀況下，所挑選的變數可能有不一致的問題，因此 Zou (2006) 提出 Adaptive LASSO，用以改進 LASSO 方法。Adaptive LASSO 方法在限制迴歸參數時，給予每個參數不同權重，其目標式如下：

$$\min \sum_{t=1}^T (y_t - \beta_0 - \sum_{i=1}^k \beta_i x_{it})^2 + \lambda \sum_{i=1}^k w_i |\beta_i|,$$

其中 w_i 是參數 β_i 的權重。Adaptive LASSO 方法之執行分為兩階段：第一階段時，考慮具有一致性 (\sqrt{n} -consistency) 的估計式 $\tilde{\beta}_j$ ；在第二階段使用 $\hat{w}_i = 1/|\tilde{\beta}_i|^\gamma$ 為權重，其中 $\gamma > 0$ ，並求解下列極小化問題：

$$\min \sum_{t=1}^T (y_t - \beta_0 - \sum_{i=1}^k \beta_i x_{it})^2 + \lambda \sum_{i=1}^k \frac{1}{|\tilde{\beta}_i|^\gamma} |\beta_i|.$$

Zou (2006) 證明，當 $\gamma = 1$ 時，若以最小平方法估計的 $\hat{\beta}_i^{OLS}$ 作為第一階段的一致性估計式，且限制式 $\beta_i \hat{\beta}_i^{OLS} \geq 0$ 成立之

下，Adaptive LASSO 方法所選之變數將具一致性。Medeiros and Mendes (2016) 的研究顯示 Adaptive LASSO 方法能運用在模型誤差項是非常態分佈及異質變異的情況下，亦即此方法適用大部分的時間序列資料。

3.2.5 Adaptive Elastic Net (Adaptive EN)

Zou and Zhang (2009) 將 EN 跟 Adaptive LASSO 方法結合，提出 Adaptive EN 方法，其目標式如下，

$$\min \sum_{t=1}^T (y_t - \beta_0 - \sum_{i=1}^k \beta_i x_{it})^2 + \lambda_1 \sum_{i=1}^k w_i |\beta_i| + \lambda_2 \sum_{i=1}^k \beta_i^2,$$

其中 w_i 是參數 β_j 在 L_1 範數懲罰項中的權重，可使用與 Adaptive LASSO 法中同樣的方法決定， λ_1 及 λ_2 均透過交叉驗證方式選取最適值。Adaptive EN 法同時考慮 Adaptive LASSO 方法加權 L_1 範數懲罰項以及一般的 L_2 範數懲罰項，其中，加權 L_1 範數懲罰項主要作為變數選擇之用， L_2 範數懲罰項則是穩定變數選擇，因此可以增加預測表現。當調整參數 λ_2 為零時，Adaptive EN 即為 Adaptive LASSO 方法；而當 $w_i = 1$ 時，Adaptive EN 為一般的 EN 方法。

3.3 因子模型

與前述 LASSO 模型家族方法不同，因子模型法是從大量且高維度的變數中，萃取出新的因子變數，再利用因子變數進行預測。考慮 k 個預測變數 $x_{1,t}, \dots, x_{k,t}$ ，我們可以設定以下

因子模型：

$$x_{it} = \lambda_i' f_t + e_{it}, \quad i = 1, \dots, k, \quad t = 1, \dots, T, \quad (1)$$

其中 $f_t = (f_t^1, \dots, f_t^r)'$ 是代表這些變數的共同因子向量，維度為 $(r \times 1)$ ，且通常 $r \ll k$ ； λ_i 表示第 i 個變數的因子負擔 (factor loading)，維度為 $(r \times 1)$ ，可視為因子向量 f_t 的權重， e_{it} 為代表這些變數個別特徵的誤差項。定義 $x_t = (x_{1t}, x_{2t}, \dots, x_{kt})'$ ， $e_t = (e_{1t}, e_{2t}, \dots, e_{kt})'$ 以及 $\Lambda = (\lambda_1, \lambda_2, \dots, \lambda_k)'$ ，我們可以將因子模型 (1) 寫成矩陣形式：

$$x_t = \Lambda f_t + e_t.$$

再將 x_t 堆疊起來，令 $X = (x_1, x_2, \dots, x_T)'$ ， $F = (f_1, f_2, \dots, f_T)'$ ，可得到以矩陣表示的因子模型如下：

$$X = F\Lambda' + e.$$

實證上，通常是先利用因子模型方法估計及選出適當的因子變數 $\hat{f}_t = (\hat{f}_t^1, \dots, \hat{f}_t^r)'$ ，再將這些因子變數加入自我迴歸模型，建構預測模型，此作法為 Stock and Watson (2002) 的擴散指標預測方程式：

$$\pi_{t+h} = \alpha_0 + \sum_{i=1}^p \alpha_i \pi_{t+h-i} + \sum_{j=0}^q \gamma_j \hat{f}_{t-j} + e_{t+h},$$

並以 BIC 選擇最適落後期數 p, q 。本計畫考慮兩種因子模型方法，分別是靜態因子模型與目標因子模型。為簡化起見，我們考慮不含落後項的預測模型，故在估計出因子 \hat{f}_t 後，將 \hat{f}_t 視為可觀察變數，因此向前 h 期預測為

$$\hat{\pi}_{t+h} = \hat{\alpha}_0 + \hat{\gamma}_0 \hat{f}_t.$$

3.3.1 靜態因子模型

令 Σ_t 為 x_t 的共變異數矩陣， Ω_t 為 f_t 的共變異數矩陣， Ψ_t 為模型誤差項 e_t 的共變異數矩陣。若假設不同變數間的誤差項不相關，即 $E(e_{it}e_{jt}) = 0, \forall i \neq j$ ，則 $\Psi_t = \text{diag}(\text{var}(e_{1t}), \dots, \text{var}(e_{kt}))$ ，此時因子模型為靜態模型。又若假設誤差項和因子不相關， $E(f_t e_t') = 0$ ，則可以推導出：

$$\Sigma_t = E[(\Lambda f_t + e_t)(\Lambda f_t + e_t)'] = \Lambda \Omega_t \Lambda' + \Psi_t.$$

由於因子模型中，可以有無窮多組 Λ 以及 F 的組合，故需要額外假設以確保唯一性：(1) 所有因子彼此間為互相正交且標準化 (mutually orthogonally normalized)，即 $\Omega_t = E(f_t f_t') = I_r$ ；(2) 由因子負擔所構成的矩陣之內積為對角矩陣，即 $\Lambda' \Lambda = I_k$ 。根據這兩個假設，可得到 $\Sigma_t = \Lambda \Lambda' + \Psi_t$ ，此種靜態因子模型又稱為常態因子模型 (normal factor model)。我們可以利用主成分分析方法估計因子模型，作法為找出矩陣 $X'X$ 的特徵向量，這些特徵向量就構成因子負擔矩陣 $\hat{\Lambda} = [\hat{\lambda}_1, \hat{\lambda}_2, \dots, \hat{\lambda}_k]$ ，然後代入 $f_t = \Lambda' x_t$ 可得因子估計式： $\hat{f}_t = \hat{\Lambda}' x_t$ 。

3.3.2 目標因子方法

Bai and Ng (2008) 認為，若直接由所有蒐集到的預測變數矩陣 X 萃取因子，其中包含的無資訊變數會添加許多雜訊到因子的估計中，使得因子的預測能力下降。他們因此提出排除無資訊變數，選擇有預測能力的目標預測變數 (targeted

predictors)，然後再估計因子，此即為目標因子方法。

Bai and Ng (2008) 建議硬門檻或軟門檻標準選擇變數，有預測能力的變數組合會隨被解釋變數 y 不同而不同。硬門檻標準是利用統計檢定判斷變數是否顯著，排除統計上不具顯著性的變數；軟門檻標準則是以收縮法選擇變數，例如 LASSO 或 EN 方法。本研究使用硬門檻標準選擇目標預測變數，作法如下：

1. 以當期通膨率 π_t 對常數項、落後 1 至 4 期通膨率 $\pi_{t-h-1}, \dots, \pi_{t-h-4}$ ，和個別預測變數 x_{it-h} 進行一般迴歸估計，共有 k 條迴歸式。令 t_i 是預測變數 x_{it-h} 的 t 統計量，並將 $|t_1|, |t_2|, \dots, |t_k|$ 由大至小排序。
2. 給定顯著水準 α ，選擇 $|t_i|$ 超過 α 的變數，將這些變數依其 $|t_i|$ 大小排序，構成目標預測變數組合 $x_t(\alpha) = (x_{[1t]}, \dots, x_{[k_\alpha^*t]})$ ，其中 k_α^* 為 $|t_i|$ 超過顯著水準的個數。
3. 對目標預測變數 $x_t(\alpha)$ 依主成分分析法估計因子 \hat{f}_t ，將 \hat{f}_t 視為可觀察變數，代入預測模型進行預測。

3.4 非線性機器學習方法

晚近幾種常用的以決策樹 (decision tree) 為基礎之機器學習法常被用來預測通膨；這些方法最大的特點在於，透過決策樹，它們可以很有效地捕捉被解釋變數與解釋變數間的非線性關係。在建構決策樹模型時，由 Breiman (1984) 所提出的 CART (classification and regression tree) 是常用的建構決策

樹方法，此方法依被解釋變數是類別變數或是連續變數可將決策樹分為分類樹以及迴歸樹。

決策樹的預測方式是先將資料分成訓練資料和測試資料，先以訓練資料建構決策樹。決策樹的建構方式是將訓練資料按特徵不斷遞迴分類，每分類一次就會產生兩種以上的分枝，每次分類後的訓練資料的類別亂度會下降，最後訓練資料將會被切割成許多子集合。當決策樹建構完後，會把測試資料按訓練資料的分類方式分成許多子集合，而測試資料的類別預測即為該子集合的預測類別。決策樹如果訓練得當，它將會有非常不錯的表現，但是決策樹的訓練，常伴隨著巨大的變異數，以至於表現非常的不穩定。決策樹的表現，很大一部分是取決於解釋變數之區域劃分是否精確，例如：先前的區域劃分會影響後續的區域劃分，而不同樣本也會造成劃分區域不同。故若先前的劃分不精確，其產生的錯誤會延續下去，導致之後的劃分也會不精確，並造成決策樹表現不穩定。

3.4.1 套袋樹法

常用的穩定決策樹表現的方法是由 Breiman (1996) 所提出的套袋法，其英文 Bagging 是 bootstrap aggregation 簡寫。套袋法的原理為使用拔靴法生成樣本並估計模型參數，之後再將這些估計值加總平均以降低參數估計值變異數。本研究計畫考慮非線性的套袋樹方法 (bagging trees)，使用區塊拔靴抽樣法 (block bootstrap) 生成多組樣本，並訓練決策樹，再

將這些決策樹之預測結果平均，以降低決策樹訓練時的變異。

在本研究中，我們以全部解釋變數為預測變數，故每組新樣本集合有 k 個預測變數，通膨率為被預測變數，接著建構 B 棵決策樹，每一棵決策樹會有一個對應的預測值，簡單平均這 B 個預測值即可得到套袋樹方法的預測值。使用套袋樹方法預測通膨率之實際作法如下：

1. 將原樣本以區塊拔靴抽樣法重抽樣，重抽樣生成 B 個拔靴樣本集合。
2. 對第 b 個新樣本集合使用 CART 方法資料建構迴歸樹，當切割至每個區域樣本數少於 5 個時停止，每一棵迴歸樹最終被切成 K_b 個區域。在第 i 個最終分割區域之下，以對應的被解釋變數訊息組合的常數 \hat{c}_i^b 為預測值，其中 $i = 1, \dots, K_b$ 。
3. 對每一個拔靴樣本集合重覆第二步驟，總共有 B 個預測值，將這些預測值的簡單平均即為套袋樹方法的預測值：

$$\hat{\pi}_{t+h} = \frac{1}{B} \sum_{b=1}^B \left[\sum_{i=1}^{K_b} \hat{c}_i^b \mathbf{1}_k(X_t^b, \hat{\Theta}^b) \right],$$

其中 \hat{c}_k^b 為最終切割域的被解釋變數之預測值。

3.4.2 隨機森林方法

隨機森林為 Breiman(2001) 所提出，與套袋樹方法類似，隨機森林建構每一決策樹的資料都由原訓練資料以拔靴法抽

出，之後再將這些決策樹之預測值平均。但和套袋樹法不同的是，在訓練時，每個決策樹之節點在分岔時會隨機從 k 個變數當中選 p 個計算類別極端化程度，再用其中表現最好的變數建構分岔。選取之變數數目可依預測模型而有所不同，如迴歸模型常用 $\lfloor k/3 \rfloor$ 個變數，分類模型常用 $\lfloor \sqrt{k} \rfloor$ 個變數，其中 k 為全部變數個數， $\lfloor \cdot \rfloor$ 為高斯符號。

由於在建構決策樹的過程加入了隨機性，因此可以解決過度配適的問題。又隨機選取變數的方式可以降低拔靴法訓練的決策樹之間的相關性，進而降低決策樹訓練的變異數。使用隨機森林方法預測通膨率之實際作法與上述之套袋樹作法類似，唯一不同之處為，每一個拔靴樣本建構決策樹時，在決策樹每一個節點，隨機挑選 $\lfloor k/3 \rfloor$ 個解釋變數建構分岔。

3.5 組合式預測方法

眾多預測方法中，組合式預測方法也常被使用。組合式預測方法的概念為組合不同預測，以求取預測表現最佳之方法。本計畫考慮四種組合式預測方法，前兩種組合式預測方法為利用 LASSO 模型家族選出變數後，再利用所選變數做為模型預測變數，也就是分別以 LASSO 或是 EN 方法挑選變數，再依挑選之變數設定線性迴歸模型，並以此預測通膨率。另外兩種組合式預測方法分述如下：

3.5.1 LASSO-套袋樹方法

LASSO-套袋樹方法使用 LASSO 進行變數挑選，然後使用 LASSO 所挑選的變數建構新資料，並以套袋樹法建構決策樹並進行預測。若此混合方法與單純使用套袋樹法的結果相近的話，表示是否挑選變數並不重要。具體作法如下：

1. 將原樣本以區塊拔靴法重抽樣，得到 B 個拔靴樣本集合。對每一個拔靴樣本集合，以全部 k 個預測變數為候選解釋變數，利用 LASSO 方法挑選變數。
2. 將第一步驟選取之變數作為新的解釋變數，使用套袋樹方法建構決策樹並預測，並以新模型的預測值作為該樣本集合的預測值。
3. B 個拔靴樣本集合總共有 B 個預測值，其簡單平均即為 LASSO-套袋樹方法的預測值。

3.5.2 隨機森林-LS 方法

混合線性隨機森林 (hybrid linear-random forest models) 為 Medeiros et al. (2021) 所提出的方法，此種混合方法是結合非線性的套袋樹與線性迴歸方法。這種混合方法利用建構決策樹時選取變數，並以所選變數建構線性迴歸模型，具體作法如下：

1. 將原樣本以區塊拔靴法重抽樣，得到 B 個拔靴樣本集合，並對每一個新樣本集合建構一棵決策樹，節點數設定為 20。

2. 對第 b 個新樣本集合，以上一步驟切割節點時有使用到的解釋變數建構新的線性迴歸模型，計算預測值 $\hat{\pi}_{t+h}^b$ 。
3. 對每一個拔靴樣本集合重覆第二步驟，總共有 B 個預測值，將這些預測值的簡單平均即為模型預測值：

$$\hat{\pi}_{t+h} = \frac{1}{B} \sum_{b=1}^B \hat{\pi}_{t+h}^b.$$

4 資料

4.1 台灣通貨膨脹率

本計畫提出多種計量與機器學習方法預測台灣通膨率，其中通膨率定義如下：

$$\pi_t = \frac{CPI_t - CPI_{t-12}}{CPI_{t-12}} \times 100$$

其中， CPI_t 為 t 時點 (月) 季調後的 CPI，因此通貨膨脹率 π_t 即為季調 CPI 的年增率。圖 1 為 2000 年 1 月至 2023 年 12 月間，季調前後的 CPI 年增率走勢。

我們可將 CPI 年增率走勢大致分為三個階段，第一階段為 2000 年至 2007 年，此一階段 CPI 年增率走勢相對穩定，在 2003 年以前，在零軸上下 2 個百分點之間波動，自 2004 年起逐漸走升，至 2006 年緩步回降。第二階段為 2008 年至 2020 年，自 2007 年下半年起，由於國際原物料及原油價格持續大幅上揚，致使 CPI 年增率明顯上漲，此一漲勢至 2009 年回跌，而後至 2020 年，受限於國內投資不足，抑制經濟與薪資成長，CPI 年增率維持較低且穩定水準。第三階段為 2021 年迄今，受到 COVID-19 疫情導致全球供應鏈瓶頸及俄烏戰爭影響，國際原物料及原油價格再度攀升，推升食物類、油料費及耐久性消費品價格，CPI 年增率再度走升，約維持 3% 左右水準。圖 2 為相同期間下，排除蔬果類與能源類之核心 CPI 年增率走勢。一般而言，核心 CPI 已排除波動較大的干擾因素，因此核心 CPI 年增率的漲跌變化與 CPI

年增率大致相同，惟核心 CPI 年增率的變動幅度較 CPI 年增率小。

4.2 大數據資料

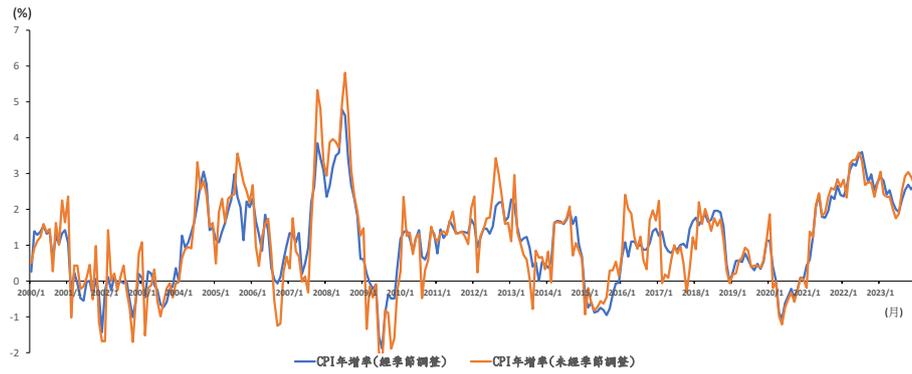
本計畫選擇 93 個與台灣通貨膨脹息息相關的總體經濟及貨幣金融變數，並將這些變數分成 11 個類別，包括：景氣指標、就業、民生消費、貨幣金融、股票市場、債券市場、房地產市場、大宗物資、國際收支與進出口、海外因素及情緒指標。以下就各個類別所含變數進行說明。

景氣指標方面，本計畫收錄台灣實質 GDP 年增率、景氣對策信號綜合分數、領先指標綜合指數、同時指標綜合指數、落後指標綜合指數、落後指標/領先指標、痛苦指數、工業生產指數年增率，以及工業生產指數-製造業年增率等實質面與名目面的景氣相關指標。資料來源為台灣經濟新報 (Taiwan Economic Journal, TEJ) 與經濟部統計處。

就業方面，根據 Stock and Watson (1999b) 研究，失業率有助於預測通貨膨脹率，因此本計畫將失業率納入預測變數。除此之外，本計畫嘗試納入勞動參與率、非農業就業人口、經常性薪資、基本工資-月、各行業平均工時-月，以及工業及服務業受僱員工淨進入率等就業相關變數，觀察這些變數是否對提升通膨預測準確性有所助益。資料來源為 TEJ 與中華民國統計資訊網。

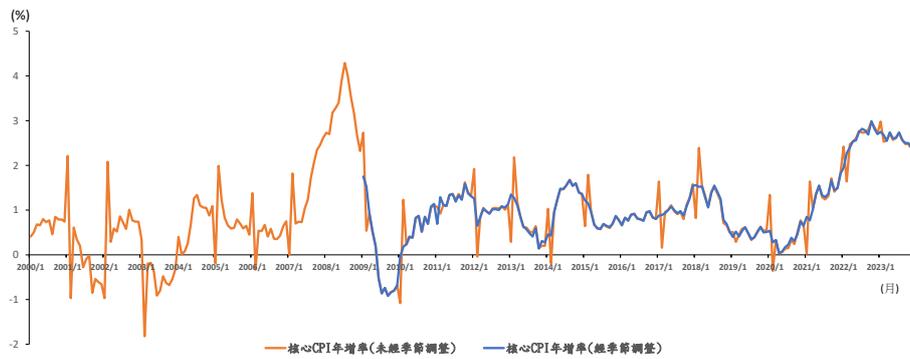
民生消費方面，本計畫將季調 CPI 年增率及未季調 CPI 年增率均納入預測變數，並納入未季調核心 CPI 年增率、未

圖 1: CPI 年增率 (%)



資料來源：中華民國統計資訊網

圖 2: 核心 CPI 年增率 (%)



資料來源：中華民國統計資訊網

註：經季調之核心 CPI 通膨率最早的資料期間為 2009 年。

季調躉售物價總指數年增率、進口物價總指數、出口物價總指數、批發業營業額年增率，以及零售業營業額年增率等。值得注意的是，行政院主計總處自 2023 年 1 月起停編躉售物價指數，故後續資料使用「國產與進口品物價總指數」所計算之年增率進行替代。資料來源為中華民國統計資訊網與經濟部統計處。

貨幣金融方面，考量貨幣總計數對通膨有直接影響，本計畫將 M1B 年增率與 M2 年增率均納入預測變數。此外，本計畫亦將金融機構存放款情形相關變數納入預測變數，如信用對產出佔比、本國銀行逾放比率、台灣全體貨幣機構放款、台灣全體貨幣機構存款、台灣全體貨幣機構存放比，以及台灣全體金融機構資產淨額等，檢視這些變數中是否存在預測未來通膨的資訊。資料來源為 TEJ 與中央銀行，信用產出比與台灣全體貨幣機構存放比則係自行計算而得。

除上述常見的總體經濟指標外，本計畫同時考慮股票市場、債券市場，以及房地產市場等金融市場重要變數可能蘊含的通膨預測資訊。本計畫選擇的股票市場變數包含台股加權指數、金融類股票指數、機電類股票指數、大盤週轉率、大盤股價淨值比、大盤本益比、大盤股價營收比、大盤現金殖利率、恐慌指數，以及 Ami 非流動性指數。資料來源皆為 TEJ，而 Ami 非流動性指數為參考 Amihud (2002) 與 Barardehi et al. (2021) 將 Amihud (2002) 之計算結果進行處理而得，計算方式請參見附錄 A。

許多重要的債券市場變數與通膨密切相關。根據預期

理論，長天期公債利率隱含一國未來景氣與通膨狀況。Sims (1980) 研究發現，商業本票利率有助於預測通膨；而 Mishkin (1989)、Jorion and Mishkin (1991) 等研究則發現，長短天期利差對預測通膨亦有所助益。是以本計畫納入重貼現率、金融業拆款利率、五年期公司債、台灣十年公債利率、商業本票 31-90 天期次級市場利率、美國長 (十年) 短 (五年) 天期利差，以及美國長 (十年) 短 (一年) 天期利差等變數作為預測變數，期望借助這些變數與通膨有關的資訊內涵，改善通膨預測表現。資料來源為 TEJ 與中央銀行，利差相關變數係由自行計算而得。

鑑於 CPI 分類項目中，居住類價格的權重僅次於食物類價格，對通膨具一定程度影響，加以 Stock and Watson (1999b) 發現消費者購屋貸款以及生產者建屋貸款等變數對於通膨有良好的預測能力，因此本計畫亦納入台北市房租指數、五大銀行新承做放款金額-購屋貸款、五大銀行新承做放款利率-購屋貸款、消費者購屋貸款 (購置住宅貸款與房屋修繕貸款)、生產者建屋貸款 (建築貸款)、消費者購屋貸款集中度，以及生產者建屋貸款集中度等房地產市場相關變數。資料來源為中央銀行、中華民國統計資訊網，以及台北市房租指數銜接表，其中購屋貸款與建屋貸款集中度係自行計算而得，計算方式參考附錄 A。

由於台灣為一小型開放經濟體，國內經濟狀況深受國際經濟情勢影響，故本計畫亦納入國際收支與進出口相關變數，包含金融帳-資產-其他投資、金融帳-負債-其他投資、經常帳

淨額、外匯存底、外銷訂單、出(入)超、價值指數-出口，以及價值指數-進口等。資料來源為 TEJ 與財政部。另外，台灣具出口導向經濟體的特性，國際原物料及原油價格等供給面因素對通膨影響甚鉅，因此本計畫納入銅現貨、黃金現貨、鋁現貨、鋼板、布蘭特原油現貨，以及 CRB 期貨商品指數等變數。其中，考量食品類價格為 CPI 中權數最大的項目，而 CRB 商品指數所包含的商品以農產品為最大占比，因此本計畫使用 CRB 期貨商品指數衡量食物類價格。資料來源皆為 TEJ。

除國際原物料及原油價格外，本計畫針對中國大陸、美國、日本及南韓這 4 個主要貿易往來國家，收錄其 GDP 成長率、物價指數年增率、公債利率、匯率等變數，期望完整納入可能影響通膨的海外因素。這些變數包含中國實質 GDP 成長率、中國 CPI 年增率、日本實質 GDP 成長率、日本十年公債殖利率、日本 CPI 年增率、日本隔夜無擔保拆借利率、美國實質 GDP 成長率、美國十年公債殖利率、美國二年公債殖利率、美國三個月國庫券利率、美國 CPI 年增率、美國聯邦資金市場利率、南韓實質 GDP 成長率、南韓公債殖利率、南韓 CPI 年增率、南韓貨幣市場利率、美日匯率、美中匯率、美韓匯率、美台匯率。除了美國實質 GDP 成長率資料取自聖路易聯邦準備銀行資料庫 (Federal Reserve Economic Data, FRED) 外，其餘資料來源皆為 TEJ。

最後，本計畫考量經濟個體(廠商或家戶)根據其對於未來通膨或景氣的態度，調整經濟決策，進而對整體經濟情況有

重大影響。鑑此，本計畫收錄情緒指標，探討這些指標對於通膨而言是否具備預測能力。情緒指標可進一步區分為景氣面、企業面及股市面。我們使用國立新加坡大學信用風險評等系統所計算的市值平均企業脆弱指數，² 作為企業面之情緒衡量標準；並使用中央大學台灣經濟發展研究中心所編製的消費者信心指數作為景氣面之情緒衡量標準。至於股市面之情緒衡量標準，我們參考 Tobias and Brunnermeier (2016) 計算 Delta CoVaR，該變數用於衡量在金融機構不同風險事件的條件下，大盤月報酬率的風險價值。

本研究所採用之許多變數，其歷史資料可能面臨持續更新或調整，本計畫以 2023 年 12 月 31 日之最新資料為基準，意即使用資料期間 2000 年 1 月至 2023 年 12 月之月頻率資料進行後續實證研究。爾後若變數之歷史資料有更新或調整情況，原則上不再進行修正。

4.3 資料處理說明

資料的處理主要依照以下三個步驟進行：(1) 調整所有變數的資料頻率一致；(2) 處理資料遺漏值；(3) 進行單根檢定及定態調整。各步驟詳細說明如下：

首先，本計畫使用月頻率資料進行實證研究，惟不同變數之原始資料可能為日頻率、月頻率或季頻率資料，因此需將原始資料均調整為月頻率資料。若原始資料為日頻率資料，則將該月之日資料取平均值，舉例而言，2020 年 6 月的月資

²見網站：<https://nuscri.org/zh-cn/cvi/>

料即以該年 6 月份的每日數據計算簡單平均值而得。若原始資料為季頻率資料，依據該變數為存量變數或流量變數而有不同的調整方法。針對流量變數，我們將該季數據直接除以 3 平分至每個月，以金融帳資產之其他投資為例，2018 年 1 月至 3 月資料之計算方式，係將該年第一季的資料直接除以 3，也就是 $-1453/3=-484.33$ 。針對存量變數，先計算本季與前一季之變動量，再將此變動量除以 3，並以前一季之數據為基底逐月累加。本計畫所使用之變數無存量變數。此外，有些變數存在數據遺漏問題，本計畫統一使用前一筆資料作為替代值。舉例而言，3 月有資料缺漏情形，則以 2 月的資料補齊。

再者，本計畫將所有變數進行單根檢定，如變數之序列存在單根，表示該序列可能為非定態序列，此現象將嚴重影響模型的分析，因此需對序列進行調整。本計畫採用 Augmented Dickey-Fuller Test(ADF 檢定)，若檢定結果拒絕虛無假設，則不對變數另外處理；若無法拒絕虛無假設，代表該變數之序列可能是非定態，需要對變數進行調整。經第一次 ADF 檢定後，序列為非定態之變數共有 45 個：進口物價總指數、出口物價總指數、非農業就業人口、經常性薪資、基本工資-月、本國銀行逾放比率、台灣全體貨幣機構放款、台灣全體貨幣機構存款、台灣全體金融機構資產淨額、台股加權指數、機電類股票指數、金融類股票指數、恐慌指數、大盤週轉率、美國長短天期利差、台北市房租指數、五大銀行新承做放款金額-購屋貸款、消費者購屋貸款(購置住

宅貸款 + 房屋修繕貸款)、生產者建屋貸款 (建築貸款)、消費者購屋貸款集中度、生產者建屋貸款集中度、銅現貨、黃金現貨、鋁現貨、鋼板、布蘭特原油現貨、CRB 期貨商品指數、外匯存底、價值指數-出口、價值指數-進口、經常帳淨額、日本十年公債殖利率、日本隔夜無擔保拆借利率、美國十年公債殖利率、美國兩年公債殖利率、美國三個月國庫券利率、美國聯邦資金市場利率、南韓公債殖利率、南韓 CPI 年增率、南韓貨幣市場利率、美日匯率、美中匯率、美韓匯率，以及消費者信心指數。

對於這些序列為非定態的變數，我們先對變數取一階差分，接著將差分後的變數再進行一次 ADF 檢定。第二次檢定結果仍為非定態之變數共有 2 個：消費者購屋貸款和生產者建屋貸款，我們再次對這些變數取一階差分並進行檢定，第三次檢定所有變數均為定態。ADF 檢定值參考附錄 B，表格第一行代表以原資料進行檢定之檢定值，第二行代表將這 45 個變數取一階差分後進行檢定之檢定值，第三行則代表將第二次檢定仍為非定態的 2 個變數再取一次差分進行檢定的檢定值。

4.4 模型比較

本計畫使用滾動視窗法 (rolling window) 評估模型的樣本外預測能力。假設模型估計所使用之樣本數，即視窗長度 (window length) 為 W 。以在第 t 期預測第 $t+h$ 期之通膨率 π_{t+h} 來說，我們使用第 $t-W+1$ 至第 t 期的樣

本估計並產生預測值 $\hat{\pi}_{t+h}$ 。本計畫設定之 $W = 120$ ， $h = (1, 3, 6, 9, 12, 18, 24, 30, 36)$ 。之後在第 $t + 1, t + 2, \dots$ 期預測第 $t + 1 + h, t + 2 + h, \dots$ 期通膨率 $\pi_{t+1+h}, \pi_{t+2+h}, \dots$ ，皆使用過去 W 期的樣本估計模型，產生預測值 $\hat{\pi}_{t+h+1}, \hat{\pi}_{t+h+2}, \dots$ ，共產生 $T - (t + h) + 1$ 個樣本外預測及預測誤差。就本計畫而言，起始訓練樣本期間為 2000 年 3 月至 2010 年 2 月，樣本外期間為 2010 年 3 月至 2023 年 12 月，以向前一期預測 ($h = 1$) 為例，共產生 166 個預測點，依此類推。

本計畫以上述預測方式為基礎，以 3 個時間序列模型、5 個 LASSO 模型家族、2 個因子模型、2 個機器學習模型及 4 個組合模型，進行未來通膨率 π_{t+h} 之預測，並計算 RMSE、MAE 及 MAD 等 3 種評估指標，比較模型的通膨預測表現，模型設定如表 1 所示。以下就各項評估指標進行介紹。

首先，RMSE 為衡量預測值與實際觀測值之間差異的平均幅度的指標，計算方式為誤差平方的平均之平方根：

$$RMSE = \sqrt{\frac{1}{T - (t + h) + 1} \sum_{i=t+h}^T \hat{e}_i^2},$$

其中 $e_i = \pi_i - \hat{\pi}_i$ 為預測誤差， π_i 是實際觀測值， $\hat{\pi}_i$ 是樣本外預測值。預測值由第 $t + h$ 期開始至第 T 期，總共有 $T - (t + h) + 1$ 個樣本外預測。再者，由於 RMSE 易受極端值影響，許多研究也考慮使用 MAE 為評估預測表現的指標，計算方式為誤差絕對值的平均：

$$MAE = \frac{1}{T - (t + h) + 1} \sum_{i=t+h}^T |\hat{e}_i|.$$

表 1: 預測模型

| 預測模型 | 模型設定 |
|-------------------|---|
| 時間序列模型 | |
| 隨機漫步 | $\pi_t = \alpha_0 + \pi_{t-1} + e_t$ |
| AR(p) | $\pi_t = \alpha_0 + \sum_{i=1}^p \phi_i \pi_{t-i} + e_t$ |
| ARMA(p, q) | $\pi_t = \alpha_0 + \sum_{i=1}^p \phi_i \pi_{t-i} + \sum_{i=1}^q \psi_i e_{t-i} + e_t$ |
| LASSO 模型家族 | |
| 脊迴歸 | $\pi_{t+h} = \beta_0 + \sum_{i=1}^k \beta_i^{\text{Ridge}} x_{t,i} + e_{t+h}$ |
| LASSO | $\pi_{t+h} = \alpha_0 + \sum_{i=1}^k \beta_i^{\text{LASSO}} x_{t,i} + e_{t+h}$ |
| EN | $\pi_{t+h} = \alpha_0 + \sum_{i=1}^k \beta_i^{\text{EN}} x_{t,i} + e_{t+h}$ |
| Adaptive LASSO | $\pi_{t+h} = \alpha_0 + \sum_{i=1}^k \beta_i^{\text{adaLASSO}} x_{t,i} + e_{t+h}$ |
| Adaptive EN | $\pi_{t+h} = \alpha_0 + \sum_{i=1}^k \beta_i^{\text{adaEN}} x_{t,i} + e_{t+h}$ |
| 因子模型 | |
| 主成分分析法 | $\pi_{t+h} = \alpha_0 + \sum_{i=1}^{k_f} \gamma_i f_{t,i} + e_{t+h}$ |
| 目標因子 | $\pi_{t+h} = \alpha_0 + \sum_{i=1}^{k_w} \alpha_i w_{t,i} + \sum_{i=1}^{k_f} \gamma_i f_{t,i} + e_{t+h}$ |
| 非線性機器學習模型 | |
| 套袋樹法 | $\hat{\pi}_{t+h} = \alpha_0 + \frac{1}{B} \sum_{b=1}^B \left[\sum_{i=1}^{K_b} \hat{c}_i^b \mathbf{1}_k(X_t^b, \hat{\Theta}^b) \right]$ |
| 隨機森林 | $\hat{\pi}_{t+h} = \alpha_0 + \frac{1}{B} \sum_{rf=1}^B \left[\sum_{i=1}^{K_{rf}} \hat{c}_i^{rf} \mathbf{1}_k(X_t^{rf}, \hat{\Theta}^{rf}) \right]$ |
| 組合模型 | |
| LASSO-LS | $\pi_{t+h} = \alpha_0 + \sum_{i=1}^{k_{lu}} \beta_i x_{t,i}^{\text{LASSO}} + e_{t+h}$ |
| EN-LS | $\pi_{t+h} = \alpha_0 + \sum_{i=1}^{k_{el}} \beta_i x_{t,i}^{\text{EN}} + e_{t+h}$ |
| LASSO-套袋樹 | $\hat{\pi}_{t+h} = \alpha_0 + \frac{1}{B} \sum_{b=1}^B \left[\sum_{i=1}^{K_b} \hat{c}_i^b \mathbf{1}_k(X_t^b, \text{LASSO}, \hat{\Theta}^b) \right]$ |
| 隨機森林-LS | $\pi_{t+h} = \alpha_0 + \sum_{i=1}^{k^*} \beta_i x_{t,i}^{\text{RF}} + e_{t+h}$ |

最後，MAD 藉由計算所有誤差與誤差之中位數之差異的絕對值後，對這些絕對值取中位數：

$$MAD = \text{median} (|\hat{e}_i - \text{median}(\{\hat{e}_{t+h}, \dots, \hat{e}_T\})|), i = t+h, \dots, T.$$

由上所述，以單一指標來看，由模型預測誤差所計算之指標數值越低，表示模型預測能力較佳，預測表現越好，但由於計算標準不同，故不同指標之間無法相互比較。

5 實證結果與討論

本計畫主要目的為應用總體經濟及金融市場大數據資料，以 3 個時間序列模型，和 13 個機器學習模型預測台灣通膨率(即季調後 CPI 年增率)，並討論預測模型表現。此外，本計畫透過其中部分預測模型挑選變數，進而識別隱含重要通膨預測資訊的預測變數。為了驗證預測模型之優劣，我們分別以向前一期通膨預測、一年以內的短期通膨預測，以及二至三年的中長期通膨預測評估模型。

5.1 向前一期通膨預測

本計畫首先進行 16 個預測模型的樣本外預測結果評估，向前一期的預測表現列於表 2，不同模型下預測誤差最小值以粗體呈現。由表 2 可知，以 RMSE 為模型表現評估標準時，ARMA 模型表現最佳，其 RMSE 為 0.509；LASSO 模型家族以 Adaptive LASSO 模型表現最佳，RMSE 為 0.372，預測誤差最小，明顯優於時間序列模型的預測表現；因子模型之 RMSE 為所有預測模型中最大，表示模型的預測表現不佳。而不論是機器學習模型或是組合模型，其向前一期之預測表現差異不大，RMSE 介於 0.381 與 0.474 之間。

以 MAE 評估模型表現來看，以 LASSO 模型家族的 Adaptive LASSO 模型預測表現最佳，MAE 為 0.290，其次為 LASSO 及 Adaptive EN 模型。結合 LASSO 模型的 LASSO-套袋樹模型或是 LASSO-LS 模型的預測亦表現良好。而若以 MAD 評估模型表現，則是以組合模型表現最佳，LASSO-LS

模型及 LASSO-套袋樹模型的 MAD 為 0.237，LASSO 相關模型及非線性機器學習模型預測表現居中，接著是時間序列模型，最後是因子模型。

綜上所述，觀察實證結果可以發現，LASSO 模型家族的預測表現普遍較基準模型佳，以 RMSE 及 MAE 作為評估指標時，使用 Adaptive LASSO 模型的表現最佳；而以 MAD 作為評估指標時，使用 LASSO-LS 及 LASSO-套袋樹模型的預測表現最佳。就因子模型而言，此類模型的預測表現較基準模型差，若以目標因子模型進行預測，雖可改善一般因子模型（主成分分析法）的預測表現，惟改善幅度有限，其表現仍較基準之時間序列模型差。就機器學習模型及組合模型而言，實證結果顯示，這些模型的預測表現亦較基準模型佳，與 LASSO 模型家族的預測表現差異不大，機器學習模型中，以套袋樹法表現較佳，組合模型中則以 LASSO-LS 及 LASSO-套袋樹法表現較佳。

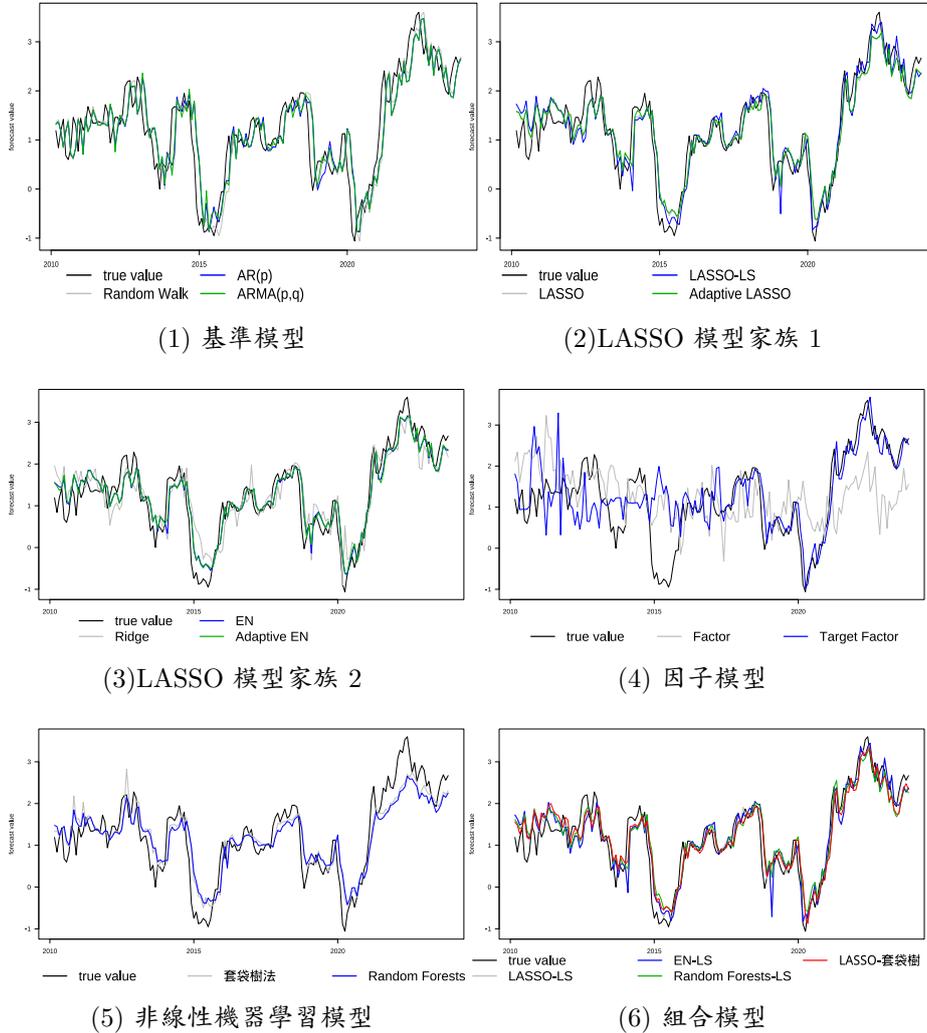
圖3為向前一期通膨預測的樣本外預測走勢圖，其中黑色實線為樣本外真實值。由此圖可以看到，組合模型樣本外預測走勢與真實值亦步亦趨，能夠精確地預測台灣通膨率。LASSO 模型家族與非線性機器學習模型之預測走勢也相當接近真實值，除當通膨率落於谷底或高峰等較不易被捕捉外，其樣本外預測能力也相當不錯。以模型預測走勢與真實值之相近程度而言，上述三類模型之樣本外預測值優於基準時間序列模型之表現。而因子模型明顯表現較差，其預測走勢與真實值有一段落差。

表 2: 預測模型之向前一期預測表現 (h=1)

| 模型 | 預測誤差計算方式 | | |
|----------------|--------------|--------------|--------------|
| | RMSE | MAE | MAD |
| 時間序列模型 | | | |
| 隨機漫步 | 0.525 | 0.393 | 0.290 |
| AR(p) | 0.511 | 0.392 | 0.301 |
| ARMA(p,q) | 0.509 | 0.387 | 0.305 |
| LASSO 模型家族 | | | |
| LASSO | 0.381 | 0.296 | 0.259 |
| 脊迴歸 | 0.525 | 0.403 | 0.322 |
| EN | 0.381 | 0.298 | 0.263 |
| Adaptive LASSO | 0.372 | 0.290 | 0.246 |
| Adaptive EN | 0.378 | 0.295 | 0.254 |
| 因子模型 | | | |
| 主成分分析法 | 1.010 | 0.837 | 0.741 |
| 目標因子 | 0.761 | 0.523 | 0.321 |
| 非線性機器學習模型 | | | |
| 套袋樹法 | 0.450 | 0.345 | 0.261 |
| 隨機森林 | 0.468 | 0.366 | 0.283 |
| 組合模型 | | | |
| LASSO-LS | 0.396 | 0.303 | 0.237 |
| EN-LS | 0.399 | 0.305 | 0.262 |
| LASSO-套袋樹 | 0.381 | 0.294 | 0.237 |
| 隨機森林-LS | 0.414 | 0.318 | 0.268 |

最後，本計畫列示 LASSO 模型家族、因子模型、機器學習模型及組合模型經變數選擇的過程，當係數超過給定值，即認定為模型所選重要變數，而重要程度係依變數被模型所選的次數進行排序。表 3 列出不同通膨預測模型所選擇的前 8 個重要變數。就 LASSO 模型家族而言，我們以 LASSO、EN、Adaptive LASSO 及 Adaptive EN 等模型選取重要變數，其中我國前一年經季調的 CPI 年增率、中國 CPI 年增率、中國實質 GDP 成長率、美國 CPI 年增率、布蘭特原油現貨、出口物價總指數、M2 年增率、批發業營業額年增率，以及零售業營業額年增率等變數為全部模型皆有選擇的變數。

圖 3: 向前一期樣本外預測走勢圖 ($h = 1$)



此結果與台灣屬小型開放經濟體，深受國際經濟情勢與進出口貿易影響的直覺相符，而批發業與零售業營業額等重要內需市場指標，以及貨幣總計數等項目，確實均對通膨有重要影響。

就因子模型而言，我們以目標因子模型進行變數挑選，該模型選擇 CPI 年增率、批發業營業額年增率、零售業營業額年

增率，以及出口物價總指數與 LASSO 模型家族相同外，另選取金融類股票指數、台灣全體金融機構資產淨額，以及消費者購屋貸款集中度等變數。就機器學習模型及組合模型而言，這些模型均選擇前一年經季調的 CPI 年增率、中國 CPI 年增率、美國 CPI 年增率、躉售物價總指數年增率、痛苦指數，以及非流動性指標。由此可以發現，除部分與 LASSO 模型家族重複選取的重要變數外，此類模型特別篩選躉售物價總指數年增率為預測通膨重要變數，推測係因躉售物價指數主要衡量原物料與零件等中間財價格，其變動反映採購成本的變化，因此富含通膨預測資訊。

5.2 短期通膨預測

本計畫期亦利用各種預測模型進行一年內之短期通膨率預測，本小節討論這些模型對未來 3、6、9、12 個月的通膨率預測表現。首先，表 4 列示向前 3 個月及 6 個月通膨預測表現，不同模型下預測誤差最小值以粗體呈現。相較於向前一期之預測表現，向前 3 或 6 期之整體預測誤差皆有上升趨勢。實證結果顯示，無論使用何種評估標準，非線性機器學習模型皆有最小的預測誤差。LASSO 模型家族或是時間序列模型在向前 3 期之預測表現接近，但向前 6 期之預測表現以 LASSO 模型家族較佳。整體而言，在預測未來 3 個月通膨時，以 RMSE、MAE 及 MAD 衡量表現最佳的模型分別為套袋樹法、隨機森林及 AR 模型，其預測誤差值分別為 0.631、0.509 及 0.411；在預測未來 6 個月通膨時，不論

表 3: 各模型重要變數 (h=1)

| 模型 排序 | LASSO | EN | Adaptive LASSO | Adaptive EN | 目標因子 |
|----------|----------------------|----------------------|----------------------|----------------------|------------------|
| 1 | CPI 年增率 (經季調) | CPI 年增率 (經季調) | CPI 年增率 (經季調) | CPI 年增率 (經季調) | CPI 年增率 (經季調) |
| 2 | 中國 CPI 年增率 | 中國 CPI 年增率 | 批發業營業額年增率 | 中國 CPI 年增率 | 金融類股票指數 |
| 3 | 批發業營業額年增率 | 批發業營業額年增率 | 中國 CPI 年增率 | 批發業營業額年增率 | 消費者購屋貸款集中度 |
| 4 | 零售業營業額年增率 | 零售業營業額年增率 | 零售業營業額年增率 | 痛苦指數 | 出 (入) 超 |
| 5 | 中國實質 GDP 成長率 | 痛苦指數 | 中國實質 GDP 成長率 | 零售業營業額年增率 | 台灣全體金融機構資產淨額 |
| 6 | 出口物價總指數 | 美國 CPI 年增率 | 出口物價總指數 | 美國 CPI 年增率 | 零售業營業額年增率 |
| 7 | 布蘭特原油現貨 | M2 年增率 | M2 年增率 | 中國實質 GDP 成長率 | 批發業營業額年增率 |
| 8 | 美國 CPI 年增率 | 中國實質 GDP 成長率 | 布蘭特原油現貨 | M2 年增率 | 出口物價總指數 |
| 模型 排序 | 套袋樹 | 隨機森林 | LASSO-套袋樹 | 隨機森林-LS | |
| 1 | CPI 年增率 (經季調) | CPI 年增率 (經季調) | CPI 年增率 (經季調) | CPI 年增率 (經季調) | |
| 2 | 美國 CPI 年增率 | 美國 CPI 年增率 | 中國 CPI 年增率 | 痛苦指數 | |
| 3 | 中國 CPI 年增率 | 躉售物價總指數年增率 (未經季調) | 躉售物價總指數年增率 (未經季調) | 躉售物價總指數年增率 (未經季調) | |
| 4 | 躉售物價總指數年增率 (未經季調) | 中國 CPI 年增率 | 美國 CPI 年增率 | 美國 CPI 年增率 | |
| 5 | 非流動性指標 | 痛苦指數 | M2 年增率 | 非流動性指標 | |
| 6 | M2 年增率 | 非流動性指標 | 痛苦指數 | 中國 CPI 年增率 | |
| 7 | 進口物價總指數 | M2 年增率 | 大盤股價營收比 | 進口物價總指數 | |
| 8 | 台灣十年公債利率 | 重貼現率 | 非流動性指標 | 台灣十年公債利率 | |

表 4: 未來一年內通膨率預測結果 (h=3、6)

| 模型 | RMSE | | MAE | | MAD | |
|----------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | h=3 | h=6 | h=3 | h=6 | h=3 | h=6 |
| 時間序列模型 | | | | | | |
| 隨機漫步 | 0.745 | 1.006 | 0.551 | 0.789 | 0.420 | 0.680 |
| AR(p) | 0.712 | 0.960 | 0.527 | 0.755 | 0.411 | 0.660 |
| ARMA(p,q) | 0.715 | 0.906 | 0.539 | 0.713 | 0.439 | 0.534 |
| LASSO 模型家族 | | | | | | |
| LASSO | 0.730 | 0.756 | 0.579 | 0.640 | 0.471 | 0.572 |
| 脊迴歸 | 0.709 | 0.834 | 0.568 | 0.689 | 0.483 | 0.627 |
| EN | 0.713 | 0.776 | 0.566 | 0.637 | 0.466 | 0.594 |
| Adaptive LASSO | 0.720 | 0.769 | 0.574 | 0.649 | 0.481 | 0.597 |
| Adaptive EN | 0.691 | 0.786 | 0.554 | 0.651 | 0.449 | 0.585 |
| 因子模型 | | | | | | |
| 主成分分析法 | 1.019 | 1.077 | 0.850 | 0.888 | 0.854 | 0.832 |
| 目標因子 | 0.985 | 0.980 | 0.796 | 0.797 | 0.714 | 0.676 |
| 非線性機器學習模型 | | | | | | |
| 套袋樹法 | 0.631 | 0.674 | 0.513 | 0.563 | 0.428 | 0.491 |
| 隨機森林 | 0.633 | 0.659 | 0.509 | 0.546 | 0.423 | 0.472 |
| 組合模型 | | | | | | |
| LASSO-LS | 0.811 | 0.740 | 0.630 | 0.610 | 0.510 | 0.563 |
| EN-LS | 0.792 | 0.749 | 0.608 | 0.610 | 0.504 | 0.545 |
| LASSO-套袋樹 | 0.686 | 0.808 | 0.555 | 0.679 | 0.440 | 0.611 |
| 隨機森林-LS | 0.710 | 0.794 | 0.577 | 0.665 | 0.490 | 0.583 |

是以何種誤差指標衡量，均為隨機森林的預測表現最佳，其 RMSE、MAE 及 MAD 值分別為 0.659、0.546 及 0.472。

表 5 列出向前 9 個月及 12 個月通膨預測表現，相較於基準模型，其他模型均有助於提升預測準確性，其中以非線性機器學習模型表現最佳，LASSO 模型家族次之，並略優於組合模型，而因子模型表現最差。整體而言，在預測未來 9 個月及 12 個月通膨時，不論是以何種誤差指標衡量，均為隨機森林方法的預測表現最佳，以 RMSE 為例，ARMA 模型及隨機森林在預測未來 9 個月通膨時分別為 1.072 及 0.631，在預測未來 12 個月通膨時則分別為 1.165 及 0.677。

表 5: 未來一年內通膨率預測結果 (h=9、12)

| 模型 | RMSE | | MAE | | MAD | |
|----------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | h=9 | h=12 | h=9 | h=12 | h=9 | h=12 |
| 時間序列模型 | | | | | | |
| 隨機漫步 | 1.196 | 1.287 | 0.954 | 1.029 | 0.770 | 0.855 |
| AR(p) | 1.150 | 1.245 | 0.917 | 1.003 | 0.717 | 0.807 |
| ARMA(p,q) | 1.072 | 1.165 | 0.855 | 0.943 | 0.672 | 0.711 |
| LASSO 模型家族 | | | | | | |
| LASSO | 0.791 | 0.821 | 0.607 | 0.643 | 0.486 | 0.516 |
| 脊迴歸 | 0.837 | 0.815 | 0.631 | 0.632 | 0.524 | 0.524 |
| EN | 0.811 | 0.857 | 0.620 | 0.628 | 0.483 | 0.460 |
| Adaptive LASSO | 0.795 | 0.810 | 0.617 | 0.615 | 0.496 | 0.470 |
| Adaptive EN | 0.814 | 0.816 | 0.629 | 0.612 | 0.482 | 0.473 |
| 因子模型 | | | | | | |
| 主成分分析法 | 0.993 | 0.966 | 0.813 | 0.745 | 0.689 | 0.519 |
| 目標因子 | 1.016 | 0.899 | 0.810 | 0.666 | 0.681 | 0.491 |
| 非線性機器學習模型 | | | | | | |
| 套袋樹法 | 0.647 | 0.712 | 0.506 | 0.544 | 0.383 | 0.425 |
| 隨機森林 | 0.631 | 0.677 | 0.497 | 0.527 | 0.359 | 0.384 |
| 組合模型 | | | | | | |
| LASSO-LS | 0.821 | 0.855 | 0.621 | 0.645 | 0.501 | 0.477 |
| EN-LS | 0.813 | 0.941 | 0.623 | 0.691 | 0.468 | 0.502 |
| LASSO-套袋樹 | 0.853 | 0.897 | 0.684 | 0.711 | 0.561 | 0.601 |
| 隨機森林-LS | 0.795 | 0.887 | 0.650 | 0.706 | 0.577 | 0.551 |

在不同預測期間，各預測模型所選擇的重要變數各有不同。以表 6 為例，在向前 3 個月通膨預測時，LASSO 模型家族的變數選擇大致相同，除以前一年經季調的 CPI 年增率及 M2 年增率等與預測目標直接相關的變數外，大多選擇中國 CPI 年增率、中國實質 GDP 成長率、美國長短天期利差、美國 CPI 年增率、美台匯率、南韓 CPI 年增率、日本 CPI 年增率，以及進口物價總指數等，顯示台灣通膨變動容易受到貿易對手國經濟因素影響。因子模型、機器學習模型及組合模型除亦選擇許多國際因素相關變數外，均選擇躉售物價總指數年增率，強調供給面因素對通膨預測的重要性。

在向前 6 個月通膨預測方面 (見表 7)，重要預測變數有相當程度的改變。LASSO 模型家族除選擇一定比例的國際因素相關變數，如中國 CPI 年增率、美國三個月國庫券利率、南韓貨幣市場或公債利率等，亦選擇零售業營業額年增率及本國銀行逾放比率等國內市場變數。而因子模型、機器學習模型及組合模型方面，選擇一定比例的國際因素相關變數，如中國與日本的實質 GDP 成長率與 CPI 年增率；此外，這些模型大多選擇領先、同時、落後指標綜合指數等景氣相關變數。值得注意的是，在預測未來 6 個月通膨時，許多預測模型選擇之重要變數出現股票市場大盤之相關指標，以及台北市房租指數與五大銀行新承做放款利率-購屋貸款等變數，顯示金融市場及不動產市場中亦隱含預測短期通膨重要資訊。

向前 9 個月通膨預測方面 (見表 8)，LASSO 模型家族選擇的國際因素變數主要與日本有關，如日本實質 GDP 成長率及日本 CPI 年增率，另亦均選擇南韓貨幣市場利率；此外，各項匯率亦為預測通膨的重要資訊來源，如美中、美日及美台匯率。就國內市場變數而言，此類模型均選取本國銀行逾放比率及台北市房租指數作為重要變數。因子模型、機器學習模型及組合模型選擇的國際因素變數主要與中、日兩國有關，如中、日實質 GDP 成長率及 CPI 年增率。

在 12 個月通膨預測方面 (表 9)，LASSO 模型家族選擇除前一年經季調的 CPI 年增率外，仍以國際因素相關變數為主，包含美國聯邦資金市場利率、美國、中國及日本 CPI 年增率、日本十年期公債殖利率，其他另選擇 CRB 期貨商品

指數，因食物類價格為 CPI 權數中占比最大者，因此與通膨變化有高度相關性。因子模型、機器學習模型及組合模型方面，日本 CPI 年增率的重要性有所增加，除與先前相同的領先、落後指標綜合指數等景氣指標外，額外增加如商業本票 31-90 天期次級市場利率、金融業拆款利率等貨幣市場重要指標。此外，由實證結果可以發現，大部分模型均選擇五大銀行新承做放款利率-購屋貸款為預測未來 12 個月通膨時重要變數，且重要程度與極短期預測相比有上升趨勢。

由上述結果可知，在預測未來一年內通膨時，就 LASSO 模型家族而言，此類模型均篩選相當數量的國際因素或進出口貿易相關變數，如美國、中國及日本 CPI 年增率，以及美台、美中、美日匯率等。在極短期預測時 ($h = 1, 3$)，此類模型除選擇前一年經季調的 CPI 年增率為相當重要的變數外，亦選擇進、出口物價總指數、零售業與批發業營業額年增率為重要變數；在短期預測時 ($h = 6, 9, 12$)，出現更多樣的國際及國內指標，國際如美國三個月國庫券利率、日本實質 GDP 成長率及美國聯邦資金市場利率等，國內如台北市房租指數、五大銀行新承做放款利率-購屋貸款，以及本國銀行逾放比率等。

機器學習模型及組合模型亦篩選某些國際因素相關變數，如美國及中國 CPI 年增率。在極短期預測時 ($h = 1, 3$)，此類模型重要變數包括前一年經季調的 CPI 年增率、躉售物價總指數年增率及 M2 年增率；在短期預測時 ($h = 6, 9, 12$)，重要變數包括國際指標，如中國及日本實質 GDP 成長率，國內

指標則如領先、同時、落後指標綜合指數等景氣指標及五大銀行新承做放款利率-購屋貸款、商業本票 31-90 天期次級市場利率、金融業拆款利率等重要市場利率。

5.3 中長期通膨預測

除短期通膨率外，本計畫亦嘗試運用大數據資料於中長期台灣通膨率預測，我們以未來二至三年之向前 18、24、30、36 個月的通膨預測表現探討預測模型之優劣。表 10、11 分別列出向前 18、24 個月以及向前 30、36 個月之通膨預測表現。由表 10 可知，在預測未來 18 個月及 24 個月通膨時，仍以非線性機器學習模型表現最佳，LASSO 模型家族次之，並略優於組合模型，而因子模型表現最差，此一結果與短期通膨預測中，預測未來 9 個月及 12 個月通膨表現的結果相似。整體而言，在預測未來 18 個月及 24 個月通膨時，不論是以何種誤差標準衡量，隨機森林的預測表現最佳，以 RMSE 衡量，預測誤差值分別為 0.661 及 0.667；而套袋樹法的預測表現亦相當良好，在預測未來 24 個月通膨時，其 MAD 值為 0.380，表現較隨機森林的 0.405 更佳。

表 11 之結果顯示，預測未來 30 個月及 36 個月通膨表現以非線性機器學習模型最為突出，以 RMSE 及 MAE 為評估標準下，在預測未來 30 個月通膨時，隨機森林優於套袋樹法，而在預測未來 36 個月通膨時，套袋樹法優於隨機森林；以 MAD 為評估標準下則相反。LASSO 模型家族與組合模型之間差異不大，LASSO 模型家族以 Adaptive LASSO 及

表 6: 各模型重要變數 (h=3)

| 模型 排序 | LASSO | EN | Adaptive LASSO | Adaptive EN | 目標因子 |
|----------|----------------------|----------------------|----------------------|----------------------|---------------------|
| 1 | CPI 年增率 | CPI 年增率 (經季調) | CPI 年增率 (經季調) | CPI 年增率 (經季調) | 中國 CPI 年增率 (經季調) |
| 2 | 中國 CPI 年增率 | 中國 CPI 年增率 | 中國 CPI 年增率 | 中國 CPI 年增率 | 台灣十年公債利率 |
| 3 | 美國長(十年)短(五年) 天期利差 | 美國長(十年)短(五年) 天期利差 | 美國長(十年)短(五年) 天期利差 | 美國長(十年)短(五年) 天期利差 | 同時指標綜合指數 |
| 4 | 批發業營業額年增率 | 批發業營業額年增率 | 批發業營業額年增率 | 批發業營業額年增率 | 南韓實質 GDP 成長率 |
| 5 | 進口物價總指數 | 進口物價總指數 | 進口物價總指數 | 進口物價總指數 | 躉售物價總指數年增率 |
| 6 | 美國 CPI 年增率 | 美國 CPI 年增率 | 美國 CPI 年增率 | 美國 CPI 年增率 | 台灣全體貨幣機構放款 |
| 7 | 南韓 CPI 年增率 | 美台匯率 | 南韓 CPI 年增率 | 美台匯率 | 銅現貨 |
| 8 | 美台匯率 | 南韓 CPI 年增率 | 美台匯率 | M2 年增率 | 中國實質 GDP 成長率 |
| 模型 排序 | 套袋樹 | 隨機森林 | LASSO-套袋樹 | 隨機森林-LS | |
| 1 | 中國 CPI 年增率 | 中國 CPI 年增率 | CPI 年增率 (經季調) | 躉售物價總指數年增率 (未經季調) | |
| 2 | 躉售物價總指數年增率 (未經季調) | 躉售物價總指數年增率 (未經季調) | 中國 CPI 年增率 | 非流動性指標 | |
| 3 | 台灣十年公債利率 | 台灣十年公債利率 | 美國 CPI 年增率 | 台灣十年公債利率 | |
| 4 | 非流動性指標 | 非流動性指標 | 痛苦指數 | 中國 CPI 年增率 | |
| 5 | 落後指標綜合指數 | 美國 CPI 年增率 | M2 年增率 | 同時指標綜合指數 | |
| 6 | 同時指標綜合指數 | 同時指標綜合指數 | 躉售物價總指數年增率 (未經季調) | 痛苦指數 | |
| 7 | 美國 CPI 年增率 | CPI 年增率 (經季調) | 批發業營業額年增率 | 美國 CPI 年增率 | |
| 8 | 五大銀行新承做放款利率 -購屋貸款 | 金融業拆款利率 | 大盤股價營收比 | 落後指標綜合指數 | |

表 7: 各模型重要變數 (h=6)

| 模型 排序 | LASSO | EN | Adaptive LASSO | Adaptive EN | 目標因子 |
|----------|----------------------|----------------------|----------------|----------------------|----------------------|
| 1 | 中國 CPI 年增率 | 零售業營業額年增率 | 中國 CPI 年增率 | 中國 CPI 年增率 | 日本實質 GDP 成長率 |
| 2 | 台北市房租指數 | 中國 CPI 年增率 | 零售業營業額年增率 | 零售業營業額年增率 | 同時指標綜合指數 |
| 3 | 零售業營業額年增率 | 台北市房租指數 | 台北市房租指數 | 台北市房租指數 | 本國銀行逾放比率 |
| 4 | 美日匯率 | 美日匯率 | 美日匯率 | 美日匯率 | 消費者購屋貸款集中度 |
| 5 | 本國銀行逾放比率 | 本國銀行逾放比率 | 本國銀行逾放比率 | 本國銀行逾放比率 | 五大銀行新承做放款利率 -購屋貸款 |
| 6 | CRB 期貨商品指數 | CRB 期貨商品指數 | CRB 期貨商品指數 | 美國三個月國庫券利率 | 美國實質 GDP 成長率 |
| 7 | 痛苦指數 | 美國三個月國庫券利率 | 美國三個月國庫券利率 | CRB 期貨商品指數 | MIB 年增率 |
| 8 | 美國三個月國庫券利率 | 痛苦指數 | 痛苦指數 | 痛苦指數 | M2 年增率 |
| 模型 排序 | 套袋樹 | 隨機森林 | LASSO-套袋樹 | 隨機森林-LS | |
| 1 | 中國實質 GDP 成長率 | 同時指標綜合指數 | 中國 CPI 年增率 | 領先指標綜合指數 | |
| 2 | 領先指標綜合指數 | 領先指標綜合指數 | 大盤股價淨值比 | 五大銀行新承做放款利率 -購屋貸款 | |
| 3 | 同時指標綜合指數 | 中國實質 GDP 成長率 | 日本實質 GDP 成長率 | 同時指標綜合指數 | |
| 4 | 大盤股價淨值比 | 大盤股價淨值比 | 中國實質 GDP 成長率 | 非流動性指標 | |
| 5 | 五大銀行新承做放款利率 -購屋貸款 | 五大銀行新承做放款利率 -購屋貸款 | 日本 CPI 年增率 | 落後指標/領先指標 | |
| 6 | 金融業拆款利率 | 落後指標綜合指數 | 進口物價總指數 | 落後指標綜合指數 | |
| 7 | 大盤股價營收比 | 大盤股價營收比 | 南韓貨幣市場利率 | 躉售物價總指數年增率 (未經季調) | |
| 8 | 日本實質 GDP 成長率 | 非流動性指標 | 台北市房租指數 | 大盤股價淨值比 | |

表 8: 各模型重要變數 (h=9)

| 模型 排序 | LASSO | EN | Adaptive LASSO | Adaptive EN | 目標因子 |
|----------|----------------------|----------------------|----------------------|----------------------|--------------|
| 1 | 日本實質 GDP 成長率 | 日本實質 GDP 成長率 | 日本 CPI 年增率 | 核心 CPI 年增率 (未經季調) | 同時指標綜合指數 |
| 2 | 日本 CPI 年增率 | 日本 CPI 年增率 | 日本實質 GDP 成長率 | 日本實質 GDP 成長率 | 日本實質 GDP 成長率 |
| 3 | 核心 CPI 年增率 (未經季調) | 核心 CPI 年增率 (未經季調) | 南韓貨幣市場利率 | 南韓貨幣市場利率 | 台灣十年公債利率 |
| 4 | 南韓貨幣市場利率 | 南韓貨幣市場利率 | 核心 CPI 年增率 (未經季調) | 工業生產指數年增率 | 日本 CPI 年增率 |
| 5 | 美中匯率 | 工業生產指數年增率 | 美日匯率 | 日本 CPI 年增率 | M2 年增率 |
| 6 | 本國銀行逾放比率 | 本國銀行逾放比率 | 本國銀行逾放比率 | 美日匯率 | 大盤現金殖利率 |
| 7 | 美日匯率 | 美台匯率 | 美中匯率 | 台北市房租指數 | 領先指標綜合指數 |
| 8 | 台北市房租指數 | 台北市房租指數 | 台北市房租指數 | 本國銀行逾放比率 | 出 (入) 起 |
| 模型 排序 | 套袋樹 | 隨機森林 | LASSO-套袋樹 | 隨機森林-LS | |
| 1 | 中國實質 GDP 成長率 | 中國實質 GDP 成長率 | 日本 CPI 年增率 | 五大銀行新承做放款利率 -購屋貸款 | |
| 2 | 日本 CPI 年增率 | 日本 CPI 年增率 | 日本實質 GDP 成長率 | 日本 CPI 年增率 | |
| 3 | 落後指標/領先指標 | 日本實質 GDP 成長率 | 進口物價總指數 | 落後指標/領先指標 | |
| 4 | 日本實質 GDP 成長率 | 五大銀行新承做放款利率 -購屋貸款 | 大盤股價淨值比 | 領先指標綜合指數 | |
| 5 | 五大銀行新承做放款利率 -購屋貸款 | 大盤股價營收比 | 中國實質 GDP 成長率 | 中國 CPI 年增率 | |
| 6 | 非流動性指標 | 領先指標綜合指數 | 企業脆弱指數 | M1B 年增率 | |
| 7 | 領先指標綜合指數 | 落後指標/領先指標 | 中國 CPI 年增率 | 日本實質 GDP 成長率 | |
| 8 | 中國 CPI 年增率 | 同時指標綜合指數 | 南韓貨幣市場利率 | 大盤現金殖利率 | |

表 9: 各模型重要變數 (h=12)

| 模型 排序 | LASSO | EN | Adaptive LASSO | Adaptive EN | 目標因子 |
|----------|-------------------------|-------------------------|----------------------|----------------------|----------------------|
| 1 | 美國聯邦資金市場利率 | 美國聯邦資金市場利率 | 美國聯邦資金市場利率 | 美國聯邦資金市場利率 | 台灣實質 GDP 年增率 |
| 2 | CPI 年增率 (經季調) | CPI 年增率 (經季調) | 日本 CPI 年增率 | CPI 年增率 (經季調) | 中國 CPI 年增率 |
| 3 | 日本 CPI 年增率 | 日本 CPI 年增率 | CPI 年增率 (未經季調) | 美中匯率 | MIB 年增率 (經季調) |
| 4 | 美國 CPI 年增率 | 美中匯率 | 中國 CPI 年增率 | 日本 CPI 年增率 | CRB 期貨商品指數 |
| 5 | 中國 CPI 年增率 | 中國 CPI 年增率 | 美國 CPI 年增率 | 美國 CPI 年增率 | 美國實質 GDP 成長率 |
| 6 | 美中匯率 | 美國 CPI 年增率 | 美中匯率 | 中國 CPI 年增率 | 台灣十年公債利率 |
| 7 | CRB 期貨商品指數 | 五大銀行新承做放款利率 -購屋貸款 | CRB 期貨商品指數 | 五大銀行新承做放款利率 -購屋貸款 | 美國長 (十年) 短 (五年) 天期利差 |
| 8 | 五大銀行新承做放款利率 -購屋貸款 | CRB 期貨商品指數 | 五大銀行新承做放款利率 -購屋貸款 | 痛苦指數 | M2 年增率 |
| 模型 排序 | 套袋樹 | 隨機森林 | LASSO-套袋樹 | 隨機森林-LS | |
| 1 | 日本 CPI 年增率 | 日本 CPI 年增率 | 日本 CPI 年增率 | CPI 年增率 (經季調) | |
| 2 | 中國實質 GDP 成長率 | 五大銀行新承做放款利率 -購屋貸款 | 痛苦指數 | 日本 CPI 年增率 | |
| 3 | 五大銀行新承做放款利率 -購屋貸款 | 中國實質 GDP 成長率 | 中國實質 GDP 成長率 | 五大銀行新承做放款利率 -購屋貸款 | |
| 4 | 金融業拆款利率 | 金融業拆款利率 | 五大銀行新承做放款利率 -購屋貸款 | 美國 CPI 年增率 | |
| 5 | MIB 年增率 | 商業本票 31-90 天期 次級市場利率 | M2 年增率 | 躉售物價總指數年增率 (未經季調) | |
| 6 | 商業本票 31-90 天期 次級市場利率 | MIB 年增率 | delta_covar | MIB 年增率 | |
| 7 | CPI 年增率 (經季調) | 落後指標綜合指數 | 中國 CPI 年增率 | 領先指標綜合指數 | |
| 8 | 落後指標綜合指數 | CPI 年增率 (經季調) | CPI 年增率 (經季調) | 落後指標綜合指數 | |

表 10: 未來二年內通膨率預測結果 (h=18、24)

| 模型 | RMSE | | MAE | | MAD | |
|----------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | h=18 | h=24 | h=18 | h=24 | h=18 | h=24 |
| 時間序列模型 | | | | | | |
| 隨機漫步 | 1.341 | 1.551 | 1.025 | 1.224 | 0.785 | 1.025 |
| AR(p) | 1.291 | 1.491 | 0.985 | 1.182 | 0.765 | 1.012 |
| ARMA(p,q) | 1.195 | 1.362 | 0.915 | 1.094 | 0.701 | 0.901 |
| LASSO 模型家族 | | | | | | |
| LASSO | 0.856 | 0.779 | 0.682 | 0.637 | 0.564 | 0.536 |
| 脊迴歸 | 0.874 | 0.860 | 0.698 | 0.710 | 0.555 | 0.622 |
| EN | 0.864 | 0.816 | 0.692 | 0.667 | 0.522 | 0.570 |
| Adaptive LASSO | 0.861 | 0.789 | 0.698 | 0.640 | 0.607 | 0.564 |
| Adaptive EN | 0.846 | 0.841 | 0.683 | 0.698 | 0.563 | 0.625 |
| 因子模型 | | | | | | |
| 主成分分析法 | 0.991 | 1.072 | 0.799 | 0.850 | 0.694 | 0.657 |
| 目標因子 | 0.966 | 1.013 | 0.730 | 0.805 | 0.593 | 0.642 |
| 非線性機器學習模型 | | | | | | |
| 套袋樹法 | 0.685 | 0.677 | 0.547 | 0.530 | 0.455 | 0.380 |
| 隨機森林 | 0.661 | 0.667 | 0.521 | 0.526 | 0.446 | 0.405 |
| 組合模型 | | | | | | |
| LASSO-LS | 0.944 | 0.893 | 0.753 | 0.721 | 0.611 | 0.613 |
| EN-LS | 0.929 | 0.983 | 0.741 | 0.775 | 0.605 | 0.687 |
| LASSO-套袋樹 | 0.874 | 0.849 | 0.725 | 0.729 | 0.575 | 0.552 |
| 隨機森林-LS | 0.814 | 0.817 | 0.668 | 0.695 | 0.540 | 0.519 |

Adaptive EN 表現較佳，組合模型則以隨機森林-LS 表現最佳；因子模型在預測未來 30 個月通膨時，以一般因子模型表現較佳，在預測未來 36 個月通膨時，則為目標因子模型表現較佳。整體而言，在不同通膨預測期間下，大致以隨機森林穩定維持最佳的預測表現，套袋樹法則居次。

我們也將各預測模型在不同預測期間通膨預測所選擇的重要變數分別列在表 12 至表 15。結果顯示，在預測未來二至三年通膨時，LASSO 模型家族所選擇的重要變數主要由國際因素相關變數構成。在中期預測時 ($h = 18, 24$)，此類模型選擇的國際因素包含美國聯邦資金市場利率、中國及日本

表 11: 未來三年內通膨率預測結果 (h=30、36)

| 模型 | RMSE | | MAE | | MAD | |
|----------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | h=30 | h=36 | h=30 | h=36 | h=30 | h=36 |
| 時間序列模型 | | | | | | |
| 隨機漫步 | 1.656 | 1.598 | 1.361 | 1.274 | 1.250 | 0.975 |
| AR(p) | 1.595 | 1.551 | 1.314 | 1.245 | 1.258 | 0.932 |
| ARMA(p,q) | 1.460 | 1.436 | 1.208 | 1.175 | 1.074 | 0.847 |
| LASSO 模型家族 | | | | | | |
| LASSO | 0.947 | 0.987 | 0.767 | 0.797 | 0.608 | 0.741 |
| 脊迴歸 | 0.989 | 0.999 | 0.781 | 0.826 | 0.561 | 0.734 |
| EN | 0.946 | 0.955 | 0.763 | 0.775 | 0.616 | 0.711 |
| Adaptive LASSO | 0.937 | 0.971 | 0.760 | 0.773 | 0.605 | 0.657 |
| Adaptive EN | 0.936 | 0.977 | 0.749 | 0.786 | 0.605 | 0.691 |
| 因子模型 | | | | | | |
| 主成分分析法 | 1.096 | 1.166 | 0.898 | 0.962 | 0.692 | 0.848 |
| 目標因子 | 1.231 | 1.075 | 1.028 | 0.855 | 0.914 | 0.713 |
| 非線性機器學習模型 | | | | | | |
| 套袋樹法 | 0.709 | 0.593 | 0.563 | 0.475 | 0.408 | 0.381 |
| 隨機森林 | 0.695 | 0.625 | 0.553 | 0.499 | 0.414 | 0.370 |
| 組合模型 | | | | | | |
| LASSO-LS | 0.926 | 1.061 | 0.749 | 0.848 | 0.570 | 0.716 |
| EN-LS | 0.956 | 1.077 | 0.759 | 0.846 | 0.575 | 0.728 |
| LASSO-套袋樹 | 0.961 | 1.034 | 0.804 | 0.864 | 0.642 | 0.691 |
| 隨機森林-LS | 0.901 | 0.840 | 0.742 | 0.714 | 0.560 | 0.627 |

CPI 年增率、日本實質 GDP 成長率及美日匯率等，顯示日本經濟對我國通膨預測有相當程度的解釋能力；國內因素則有 M2 年增率、台灣十年期公債利率、零售業營業額年增率及進、出口物價總指數等。在長期預測時 ($h = 30, 36$)，國際因素差異不大，惟國內因素除 M1B、M2 年增率等貨幣總計數變數外，另篩選出生產者建屋貸款集中度及消費者購屋貸款集中度，且重要性不低，顯示房市相關變數亦對通膨預測資訊有重要影響。

相較於 LASSO 模型家族，機器學習模型及組合模型選擇的國際因素相關變數較少，主要為日本 CPI 年增率，以及中

國、日本實質 GDP 成長率為主。在中期預測時 ($h = 18, 24$)，此類模型大多選擇領先、同時、落後指標綜合指數等景氣指標、金融業拆款利率、台灣十年期公債利率及商業本票 31-90 天期次級市場利率等市場利率，以及非流動性指標。在長期預測時 ($h = 30, 36$)，國內因素比例更高，除景氣相關指標外，亦選擇 M1B、M2 年增率等貨幣總計數變數，以及台灣十年期公債利率、非流動性指標，以及部分勞動市場變數等。

本計畫觀察不同預測模型在不同預測期間下所選擇對通膨預測有解釋能力的變數，並可歸納出 4 個重點：(1) 整體而言，台灣通膨深受國際因素及進出口貿易影響，主要貿易對手國之 CPI 年增率、實質 GDP 成長率、匯率及其政策利率等變數，以及進出口物價總指數大多為重要變數，惟就機器學習模型及組合模型而言，此一影響隨預測期間增加而有所下降。(2) 國內因素對通膨預測較有貢獻者，除前一年經季調的 CPI 年增率外，尚有貨幣總計數相關變數如 M1B、M2 年增率，市場利率如金融業拆款利率、台灣十年期公債利率及商業本票 31-90 天期次級市場利率，產業相關如批發業、零售業營業額年增率，供給面變數如躉售物價總指數年增率等。(3) 其他偶經選擇為重要變數之國內因素，如台北市房租指數、五大銀行新承做放款利率-購屋貸款、建屋或購屋貸款集中度等房市變數，以及股市大盤相關指標等變數，對通膨預測亦有一定解釋能力。(4) 指數類型變數富含通膨預測資訊內涵，如機器學習模型及組合模型在中長期通膨預測時經

常選擇領先、同時、落後指標綜合指數等景氣指標，而企業脆弱指數、痛苦指數、非流動性指標等亦經常位列於重要變數，顯示不同面向的指標涵蓋所屬市場的重要訊息。

除上述數值列表外，本研究亦將樣本外多期預測走勢圖列於附錄 C，各種不同穩健性設定列於附錄 D。綜觀所有實證結果，時間序列模型僅在向前一期預測表現較佳，LASSO 模型家族、因子模型、非線性機器學習模型及組合模型均在多期預測表現較佳，其中在所有多期預測的預測期間下，非線性機器學習模型之隨機森林模型維持穩定且良好的預測表現。

表 12: 各模型重要變數 (h=18)

| 模型 排序 | LASSO | EN | Adaptive LASSO | Adaptive EN | 目標因子 |
|----------|-------------------------|-------------------------|----------------|----------------------|----------------|
| 1 | 美國聯邦資金市場利率 | 美國聯邦資金市場利率 | 中國 CPI 年增率 | 美國聯邦資金市場利率 | 台灣全體貨幣機構存放比 |
| 2 | 中國 CPI 年增率 | 中國 CPI 年增率 | 美國聯邦資金市場利率 | 中國 CPI 年增率 | 中國 CPI 年增率 |
| 3 | 日本 CPI 年增率 | 日本 CPI 年增率 | 日本 CPI 年增率 | 日本 CPI 年增率 | 金融帳-資產-其他投資 |
| 4 | M2 年增率 | 日本實質 GDP 成長率 | M2 年增率 | M2 年增率 | 生產者建屋貸款 (建築貸款) |
| 5 | 零售業營業額年增率 | 痛苦指數 | 零售業營業額年增率 | 零售業營業額年增率 | 台灣十年公債利率 |
| 6 | 生產者建屋貸款集中度 | M2 年增率 | 日本實質 GDP 成長率 | 日本實質 GDP 成長率 | 企業脆弱指數 |
| 7 | 日本實質 GDP 成長率 | 躉售物價總指數年增率 (未經季調) | 生產者建屋貸款集中度 | 痛苦指數 | 日本 CPI 年增率 |
| 8 | 痛苦指數 | 生產者建屋貸款集中度 | 痛苦指數 | 躉售物價總指數年增率 (未經季調) | 落後指標/領先指標 |
| 模型 排序 | 套袋樹 | 隨機森林 | LASSO-套袋樹 | 隨機森林-LS | |
| 1 | 金融帳-資產-其他投資 | 金融帳-資產-其他投資 | 日本 CPI 年增率 | M2 年增率 | |
| 2 | 商業本票 31-90 天期 次級市場利率 | 金融業拆款利率 | 美國聯邦資金市場利率 | 躉售物價總指數年增率 (未經季調) | |
| 3 | 落後指標綜合指數 | 商業本票 31-90 天期 次級市場利率 | 台灣十年公債利率 | 非流動性指標 | |
| 4 | 日本 CPI 年增率 | 落後指標綜合指數 | M2 年增率 | 同時指標綜合指數 | |
| 5 | 金融業拆款利率 | 同時指標綜合指數 | 生產者建屋貸款集中度 | 台灣十年公債利率 | |
| 6 | 非流動性指標 | 日本 CPI 年增率 | 痛苦指數 | 日本 CPI 年增率 | |
| 7 | 失業率 | 台灣十年公債利率 | 中國實質 GDP 成長率 | 美台匯率 | |
| 8 | 台灣十年公債利率 | 非流動性指標 | 日本實質 GDP 成長率 | 落後指標綜合指數 | |

表 13: 各模型重要變數 (h=24)

| 模型 排序 | LASSO | EN | Adaptive LASSO | Adaptive EN | 目標因子 |
|----------|----------------------|-------------------------|----------------|----------------------|----------------------|
| 1 | 台灣十年公債利率 | 台灣十年公債利率 | 台灣十年公債利率 | 台灣十年公債利率 | M1B 年增率 |
| 2 | 美日匯率 | 台灣實質 GDP 年增率 | M2 年增率 | 非流動性指標 | M2 年增率 |
| 3 | 非流動性指標 | 非流動性指標 | 美日匯率 | 日本 CPI 年增率 | 台灣實質 GDP 年增率 |
| 4 | 日本 CPI 年增率 | 日本 CPI 年增率 | 出口物價總指數 | 出口物價總指數 | 美國長 (十年) 短 (五年) 天期利差 |
| 5 | M2 年增率 | 出口物價總指數 | 非流動性指標 | 台灣實質 GDP 年增率 | 美國 CPI 年增率 |
| 6 | 出口物價總指數 | 南韓貨幣市場利率 | 日本 CPI 年增率 | M2 年增率 | 勞動參與率 |
| 7 | 台灣實質 GDP 年增率 | 進口物價總指數 | 台灣實質 GDP 年增率 | 美日匯率 | 美國二年公債殖利率 |
| 8 | 大盤股價淨值比 | M2 年增率 | 大盤股價淨值比 | 進口物價總指數 | 中國 CPI 年增率 |
| 模型 排序 | 套袋樹 | 隨機森林 | LASSO-套袋樹 | 隨機森林-LS | |
| 1 | 中國實質 GDP 成長率 | 中國實質 GDP 成長率 | 中國 CPI 年增率 | 落後指標綜合指數 | |
| 2 | 中國 CPI 年增率 | 落後指標綜合指數 | 勞動參與率 | 躉售物價總指數年增率 (未經季調) | |
| 3 | 台灣十年公債利率 | 領先指標綜合指數 | 台灣十年公債利率 | 非流動性指標 | |
| 4 | 金融帳-資產-其他投資 | 同時指標綜合指數 | 信用對產出佔比 | 五大銀行新承做放款利率 -購屋貸款 | |
| 5 | 台灣全體貨幣機構存放比 | 中國 CPI 年增率 | 美國聯邦資金市場利率 | 落後指標/領先指標 | |
| 6 | 落後指標綜合指數 | 商業本票 31-90 天期 次級市場利率 | 非流動性指標 | 領先指標綜合指數 | |
| 7 | 非流動性指標 | 台灣全體貨幣機構存放比 | 中國實質 GDP 成長率 | 同時指標綜合指數 | |
| 8 | 五大銀行新承做放款利率 -購屋貸款 | 金融帳-資產-其他投資 | 美國 CPI 年增率 | 金融帳-資產-其他投資 | |

表 14: 各模型重要變數 (h=30)

| 模型 排序 | LASSO | EN | Adaptive LASSO | Adaptive EN | 目標因子 |
|----------|----------------------|----------------------|----------------------|-------------|--------------|
| 1 | 日本 CPI 年增率 | 日本 CPI 年增率 | 日本 CPI 年增率 | 日本 CPI 年增率 | 企業脆弱指數 |
| 2 | 生產者建屋貸款集中度 | 生產者建屋貸款集中度 | 生產者建屋貸款集中度 | 生產者建屋貸款集中度 | 落後指標/領先指標 |
| 3 | M2 年增率 | 中國 CPI 年增率 | M2 年增率 | 中國 CPI 年增率 | 落後指標綜合指數 |
| 4 | 中國 CPI 年增率 | M2 年增率 | 中國 CPI 年增率 | M2 年增率 | 日本 CPI 年增率 |
| 5 | 躉售物價總指數年增率 (未經季調) | 大盤現金殖利率 | 躉售物價總指數年增率 (未經季調) | 恐慌指數 | 台灣全體貨幣機構存放比 |
| 6 | 企業脆弱指數 | 美中匯率 | 企業脆弱指數 | 五年期公司債 | 日本實質 GDP 成長率 |
| 7 | 日本實質 GDP 成長率 | 躉售物價總指數年增率 (未經季調) | 日本實質 GDP 成長率 | 企業脆弱指數 | 台灣全體貨幣機構存放比 |
| 8 | 恐慌指數 | 五年期公司債 | 美中匯率 | 美中匯率 | 失業率 |

| 模型 排序 | 套袋樹 | 隨機森林 | LASSO-套袋樹 | 隨機森林-LS |
|----------|-------------|-------------|----------------------|-------------|
| 1 | 台灣全體貨幣機構存放比 | 台灣全體貨幣機構存放比 | 美台匯率 | M2 年增率 |
| 2 | 落後指標綜合指數 | 落後指標綜合指數 | 勞動參與率 | 台灣全體貨幣機構存放比 |
| 3 | 大盤本益比 | 領先指標綜合指數 | M2 年增率 | 美台匯率 |
| 4 | M2 年增率 | 大盤本益比 | 生產者建屋貸款集中度 | 同時指標綜合指數 |
| 5 | 失業率 | 同時指標綜合指數 | 痛苦指數 | 失業率 |
| 6 | 美台匯率 | M2 年增率 | 企業脆弱指數 | 落後指標綜合指數 |
| 7 | 同時指標綜合指數 | 台灣十年公債利率 | 躉售物價總指數年增率 (未經季調) | 台灣十年公債利率 |
| 8 | 重貼現率 | 失業率 | 日本實質 GDP 成長率 | 大盤本益比 |

表 15: 各模型重要變數 (h=36)

| 模型 排序 | LASSO | EN | Adaptive LASSO | Adaptive EN | 目標因子 |
|----------|------------------|------------------|------------------|------------------|----------------------|
| 1 | CPI 年增率 (經季調) | CPI 年增率 (經季調) | 美中匯率 | CPI 年增率 (經季調) | MIB 年增率 |
| 2 | MIB 年增率 | MIB 年增率 | MIB 年增率 | MIB 年增率 | 非流動性指標 |
| 3 | 美中匯率 | 美中匯率 | CPI 年增率 (經季調) | 美中匯率 | M2 年增率 |
| 4 | 中國 CPI 年增率 | 消費者購屋貸款集中度 | 消費者購屋貸款集中度 | 消費者購屋貸款集中度 | 核心 CPI 年增率 (未經季調) |
| 5 | 消費者購屋貸款集中度 | 中國 CPI 年增率 | 中國 CPI 年增率 | 南韓 CPI 年增率 | 同時指標綜合指數 |
| 6 | 南韓 CPI 年增率 | 南韓 CPI 年增率 | 南韓 CPI 年增率 | 中國 CPI 年增率 | 美國長 (十年) 短 (五年) 天期利差 |
| 7 | 非流動性指標 | 非流動性指標 | 非流動性指標 | 日本十年公債殖利率 | 金融業拆款利率 |
| 8 | 出口物價總指數 | 日本十年公債殖利率 | 出口物價總指數 | 非流動性指標 | 中國實質 GDP 成長率 |
| 模型 排序 | 套袋樹 | 隨機森林 | LASSO-套袋樹 | 隨機森林-LS | |
| 1 | 美國實質 GDP 成長率 | 美國實質 GDP 成長率 | MIB 年增率 | MIB 年增率 | |
| 2 | MIB 年增率 | 落後指標綜合指數 | 痛苦指數 | 美國實質 GDP 成長率 | |
| 3 | 落後指標綜合指數 | MIB 年增率 | M2 年增率 | 台灣十年公債利率 | |
| 4 | 大盤本益比 | 領先指標綜合指數 | 台灣十年公債利率 | 落後指標/領先指標 | |
| 5 | 台灣十年公債利率 | 大盤本益比 | 消費者購屋貸款集中度 | 落後指標綜合指數 | |
| 6 | 非流動性指標 | 台灣十年公債利率 | 落後指標綜合指數 | 非流動性指標 | |
| 7 | 領先指標綜合指數 | 同時指標綜合指數 | 非流動性指標 | 領先指標綜合指數 | |
| 8 | 落後指標/領先指標 | 非流動性指標 | 美國實質 GDP 成長率 | 大盤本益比 | |

6 結論與討論

近年來機器學習方法蓬勃發展，越來越多經濟學者將其運用於通膨預測，利用機器學習方法結合電腦自動演算技術與統計方法的優勢，發現大規模數據中蘊含與通膨預測有關的重要意義。本計畫應用總體經濟及金融市場大數據資料，提出 13 個機器學習方法預測台灣通膨率，實證結果發現，由向上一期通膨預測方面，LASSO 模型家族、非線性機器學習模型及組合模型的預測表現差不多，均較基準時間序列模型佳。在短期或是中長期通膨率預測方面，非線性機器學習模型有最小的預測誤差，其中以隨機森林的預測表現最佳，明顯改善基準模型預測表現，與 Medeiros et al. (2021) 的實證結果一致，而其他模型如 LASSO 模型家族、非線性機器學習模型及組合模型亦有良好的預測表現。整體而言，較無特定一個機器學習方法在所有預測期間及穩健性測試項目中表現最佳，因此仍須持續嘗試借助不同機器學習方法進行預測，藉此獲得理想的預測績效。

本計畫所使用的在各種機器學習方法中，以非線性機器學習方法的預測表現最佳，主因為該方法有效捕捉經濟體系中潛在的非線性特徵，有助於提升通膨預測準確性。非線性機器學習方法包含隨機森林及套袋樹法，實證結果顯示，整體而言前者為表現最佳的模型，且在短、中、長預測期間的表現相當穩定，而後者表現亦較其他預測模型突出，此結果與重要總體經濟變數與通膨之間潛在的非線性關係有關。綜觀

國內通膨預測相關研究，類似的研究方法似較為少見，因此本計畫建議，央行宜妥善運用前述方法作為通膨預測工具，除可改善通膨預測表現外，亦可借助其變數選擇機制，篩選出對通膨預測有重要影響性的關鍵變數，進而加深對通膨傳遞管道的瞭解，據以採取妥適的貨幣政策，最終達到央行穩定物價的核心目標。

本計畫雖嘗試以機器學習方法進行台灣通膨預測，並找出就通膨預測而言相對重要的關鍵變數，惟仍有許多延伸議題值得進一步討論。首先，本計畫以大規模數據為基礎進行分析，惟變數眾多，可能不利於未來實際預測的應用，且隨預測期間拉長，可能會提高預測困難度。因此未來或可參考本計畫中預測模型所選取的重要變數，使用對通膨預測較有貢獻的變數進行預測，在預測的效率性與準確性之間取得良好平衡。此外，利用機器學習方法選擇之重要變數，有時並未有明確直接之經濟意涵，這也是使用機器學習方法的限制之一。再者，本計畫考慮眾多機器學習模型，受限於研究期程，僅考慮 3 種指標評估模型表現，未來或可進一步考慮不同預測準確性檢定，以評估不同模型樣本外預測能力是否相等。最後，本計畫僅將機器學習方法作為預測模型使用，實際上，該方法應用層面相當廣泛。舉例而言，未來可將該方法進一步運用於文字探勘 (text mining)，結合資料檢索技術與自然語言處理，建立通膨預測指標，並檢視此一指標是否有助提升通膨預測準確性，亦為相當值得探討的延伸議題。

參考文獻

中文：

- 朱浩榜 2019,「探討台灣食物類價格及其與通膨情勢之關係」,中央銀行季刊,第四十一卷第二期,頁 5-32。
- 朱浩榜 2023,「探討臺灣的菲利普曲線及其通膨預測能力」,臺灣經濟預測與政策,第五十三卷第二期,頁 51-103。
- 侯德潛、徐千婷 2002,「我國通貨膨脹預測模型之建立」,中央銀行季刊,第二十四卷第三期,頁 9-40。
- 林依伶、陳佩玗 2021,「連鎖法衡量下之台灣短中期通膨與經濟成長預測」,中央銀行季刊,第四十三卷第一期,頁 7-48。
- 陳佩玗 2013,「台灣地區短期通貨膨脹率之預測」,中央銀行季刊,第三十五卷第一期,頁 63-90。
- 黃朝熙 2007,「台灣通貨膨脹預測」,中央銀行季刊,第二十九卷第一期,頁 5-29。
- 葉盛、田慧琦 2004,「台灣的物價情勢：影響因素探析與計量實證模型應用」,中央銀行季刊,第二十六卷第四期,頁 69-115。
- 劉淑敏 2003,「我國躉售物價指數對消費者物價之影響效果分析」,中央銀行季刊,第二十五卷第二期,頁 37-48。
- 蕭宇翔、繆維正 2021,「以高頻物價數據進行通膨預測」,經濟論文叢刊,第四十九卷第三期,頁 371-414。

英文：

- Almosova, A., Andresen, N. 2023. Nonlinear inflation forecasting with recurrent neural networks. *Journal of Forecasting*, 42(2), 240-259.
- Amihud, Y. 2002. Illiquidity and stock returns: cross-section and time-series effects. *Journal of Financial Markets*, 5(1), 31-56.
- Ang, A., Bekaert, G., Wei, M. 2007. Do macro variables, asset markets, or surveys forecast inflation better? *Journal of Monetary Economics*, 54(4), 1163-1212.
- Araujo, G.S., Gaglianone, W.P. 2023. Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models. *Latin American Journal of Central Banking*, 4, 100087.
- Atkeson, A., Ohanian, L.E. 2001. Are Phillips curves useful for forecasting inflation? *Federal Reserve Bank of Minneapolis Quarterly Review*, 25, 2-11.
- Bai, J. 2003. Inferential theory for factor models of large dimensions. *Econometrica*, 71, 135-171.
- Bai J, Ng S. 2002. Determining the number of factors in approximate factor models. *Econometrica*, 70:191-221.
- Bai, J, Ng, S. 2008. Forecasting economic time series using targeted predictors. *Journal of Econometrics*, 146, 304-317.

- Bai, J, Ng, S. 2009. Boosting diffusion indexes. *Journal of Applied Econometrics*, 24, 607-629.
- Barardehi, Y. H., Bernhardt, D., Ruchti, T. G., Weidenmier, M. 2021. The night and day of Amihud's (2002) liquidity measure. *The Review of Asset Pricing Studies*, 11(2), 269-308.
- Barkan, O., Benchimol, J., Caspi, I., Cohen, E., Hammer, A., Koenigstein, N. 2023. Forecasting CPI inflation components with hierarchical recurrent neural networks. *International Journal of Forecasting*, 39(3), 1145-1162.
- Baybuza, I. 2018. Inflation forecasting using machine learning methods. *Russian Journal of Money and Finance*, 77(4), 42-59.
- Bermingham, C. 2007. How useful is core inflation for forecasting headline inflation? *The Economic and Social Review*, 38(3), 355-377.
- Breiman, L. 1996. Bagging predictors. *Mach. Learn.*, 24, 123-140.
- Breiman, L. 2001. Random forests. *Mach. Learn.*, 45, 5-32.
- Breiman, L., Friedman, J. H., Olshen, R. A., Stone, C. J. 1984. Classification and regression trees. Belmont, CA: Wadsworth. *International Group*, 432, 151-166.
- Breitung, J., Roling, C. 2015. Forecasting inflation rates using daily data: A nonparametric MIDAS approach. *Journal of Forecasting*, 34, 588-603.
- Camba-Méndez, G., Kapetanios, G. 2005. Forecasting euro area inflation using dynamic factor measures of underlying inflation. *Journal of Forecasting*, 25, 491-503.
- Cecchetti, S., Chu, R., Steindel, C. 2000. The unreliability of inflation indicators. *Federal Reserve Bank of New York Current Issues in Economics and Finance*, 6, 1-6.
- Chamberlain, G., Rothschild, M. 1983. Arbitrage, factor structure, and mean-variance analysis on large asset markets. *Econometrica*, 51, 1281-1304.
- Chen, X., Racine, J., Swanson, N.R. 2001. Semiparametric ARX neural-network models with an application to forecasting inflation. *IEEE Transactions on neural networks*, 12(4), 674-683.
- Choudhary, M. A., Haider, A. 2012. Neural network models for inflation forecasting: An appraisal. *Applied Economics*, 44(20), 2631-2635.
- Coulombe, P., Leroux, M., Stevanovic, D., Surprenant, S. 2022. How is machine learning useful for macroeconomic forecasting? *Journal of Applied Econometrics*, 37, 920-964.
- Crone, T., Khettry, N., Mester, L., Novak, J. 2013. Core measures of inflation as predictors of total inflation. *Journal of Money, Credit and Banking*, 45(2-3), 505-519.
- Duan, J.-C., Zhu, Y. 2020. Economic growths of ASEAN-5 countries impacted by global and domestic credit risks. *Asian Journal of Economics and Banking*, 4(2), 1-20.

- Elliott, G., Gargano, A., Timmermann, A. 2013. Complete subset regressions. *Journal of Econometrics*, 177(2), 357–373.
- Elliott, G., Gargano, A., Timmermann, A. 2015. Complete subset regressions with large-dimensional sets of predictors. *Journal of Economic Dynamics and Control*, 54, 86–110.
- Esquivel Monge, M., 2007. Performance of artificial neural networks in forecasting Costa Rican inflation. Department of Economic Research, Central Bank of Costa Rica DEC-DIE-029-2009-DI..
- Faust, J., Wright, J.H., 2013. Forecasting inflation. *Handbook of economic forecasting*. Elsevier B.V.. Vol. 2A, Chapter 1, 3-56. Ed.
- Filippo, G.D. 2015. Dynamic model averaging and CPI inflation forecasts: A comparison between the Euro area and the United States. *Journal of Forecasting*, 34, 619-648.
- Fisher, J.D.M., Liu, C.T., Zhou, R. 2002. When can we forecast inflation? *Federal Reserve Bank of Chicago Economic Perspectives*, 1, 30-42.
- Freeman, D. 1998. Do core inflation measures help forecast inflation? *Economics Letters*, 58, 143-147.
- Funke, M., Mehrotra A., Yu H. 2015. Tracking Chinese CPI inflation in real time. *Empirical Economics*, 48(4), 1619-1641.
- Ghosh, S. 2007. Adaptive elastic net: A doubly regularized method for variable selection to achieve oracle properties. *Tech. Rep. pr07-01, available at <http://www.math.iupui.edu/research/preprints.php>, IUPUI.*
- Ghosh, S. 2011. On the grouped selection and model complexity of the adaptive elastic net. *Statist. Comput.*, 21, 3, 451-462.
- Hansen, B., Racine, J. 2012. Jackknife model averaging. *Journal of Econometrics*, 167, 38-46.
- Hastie, T., Tibshirami, R., Friedman, J. 2001. *The elements of statistical learning: Data mining, inference and prediction*, New York: Springer.
- Hastie, T., Tibshirani, R., Friedman, J. 2009. *The Elements of Statistical Learning*, 2nd, Spring Series in Statistics, New York, NY, USA: Spring New York Inc.
- Hoerl, A.E. 1962. Application of ridge analysis to regression problems. *Chemical Engineering Progress*, 58, 54-59.
- Hoerl, A.E., Kennard, R.W. 1970. Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, 12(1), 55-67.
- Inoue, A., Kilian, L. 2008. How useful is bagging in forecasting economic time series? a case study of U.S. CPI inflation. *Journal of the American Statistical Association*, 103, 511-522.
- Jorion, P., Mishkin, F. 1991. A multicountry comparison of term-structure forecasts at long horizons. *Journal of Financial Economics*, 29(1), 59-80.

- Kohlscheen, E., 2021. What does machine learning say about the drivers of inflation? BIS Working Papers n. 980.
- Koop, G., Korobilis, D. 2012. Forecasting inflation using dynamic model averaging. *International Economic Review*, 53(3), 867–886.
- Lenza, M., Warmedinger, T. 2011. A factor model for Euro-area short-term inflation analysis. *Jahrbücher für Nationalökonomie und Statistik*, 231(1), 50-62.
- McCracken, M., Ng, S. 2016. FRED-MD: A monthly database for macroeconomic research. *Journal of Business and Economic Statistics*, 34, 574–589.
- McAdam, P., McNelis, P. 2005. Forecasting inflation with thick models and neural networks. *Economic Modelling*, 22(5), 848–867.
- Medeiros, M., Mendes, E. 2016. ℓ_1 -Regularization of high-dimensional time-series models with non-Gaussian and heteroskedastic errors. *Journal of Econometrics*, 191, 255–271.
- Medeiros, M., Vasconcelos, G. 2016. Forecasting macroeconomic variables in data-rich environments. *Economics Letters*, 138, 50–52.
- Medeiros, M., Vasconcelos, G., de Freitas, E.H., 2016. Forecasting brazilian inflation with high dimensional models. *Brazilian Review of Econometrics*, 36 (2), 223–254.
- Medeiros, M. C., Vasconcelos, G., Veiga, Á, Zilberman, E. 2021. Forecasting inflation in a data-rich environment: The benefits of machine learning methods. *Journal of Business & Economic Statistics*, 39, 98–119.
- Meyer, B., Pasaogullari, M. 2010. Economic commentary: Vol. 17, Simple ways to forecast inflation: What works best? Federal Reserve Bank of Cleveland.
- Mishkin, F. S. 1989. The information in the longer maturity term structure about future inflation. *National Bureau of Economic Research Cambridge, Mass., USA*.
- Modugno, M. 2013. Now-casting inflation using high frequency data. *International Journal of Forecasting*, 29, 664–675.
- Monteforte, L., Moretti, G. 2010. Real-time forecasts of inflation: the role of financial variables. IDEAS Working Paper Series from RePEc.
- Moshiri, S., Cameron, N. 2000. Neural network versus econometric models in forecasting inflation. *Journal of Forecasting*, 19(3), 201–217.
- Nakamura, E. 2005. Inflation forecasting using a neural network. *Economics Letters*, 86(3), 373–378.
- Pincheira, P., Selaive, J., Nolazco, J. 2019. Forecasting inflation in Latin America with core measures. *International Journal of Forecasting*, 35(3), 1060-1071.

- Rodríguez-Vargas, A. 2020. Forecasting Costa Rican inflation with machine learning methods. *Latin American Journal of Central Banking*, 1, 100012.
- Sims, C. A. 1980. Comparison of interwar and postwar business cycles: Monetarism reconsidered. *National Bureau of Economic Research Cambridge, Mass., USA*.
- Steindel, C., Cecchetti, S. G., Chu, R. 2000. The unreliability of inflation indicators. *Current Issues in Economics and Finance, Federal Reserve Bank of New York*, 6(4).
- Stock, J., Watson, M. 1998. Diffusion indexes. NBER Working Paper, No. 6702.
- Stock, J., Watson, M. 1999a. *Business cycle fluctuations in US macroeconomic time series. Handbook of Macroeconomics*, 1, 3-64.
- Stock, J., Watson, M. 1999b. Forecasting inflation. *Journal of Monetary Economics*, 44, 293–335.
- Stock, J., Watson, M. 2002. Macroeconomic forecasting with diffusion indexes. *Journal of Business and Economic Statistics*, 20, 147–162.
- Stockton, D., Glassman, J. 1987. An evaluation of the forecast performance of alternative models of inflation. *Review of Economics and Statistics*, 69, 108–117.
- Tibshirani, R. 1996. Regression shrinkage and selection via the Lasso. *Royal Statistical Society*, 58(1), 267–288.
- Tobias, A., Brunnermeier, M. K. 2016. CoVaR. *The American Economic Review*, 106(7), 1705.
- Zhang, X., Wan, A. T., Zou, G. 2013. Model averaging by jackknife criterion in models with dependent data. *Journal of Econometrics*, 174, 82–94.
- Zou, H., 2006. The adaptive lasso and its oracle properties. *J. Am. Stat. Assoc.*, 101, 1418–1429.
- Zou, H., Hastie, T. 2005. Regularization and variable selection via the elastic net. *Royal Statistical Society*, 67(2), 301–320.
- Zou, H., Zhang, H. H. (2009). On the adaptive elastic-net with a diverging number of parameters, *Annals of Statistics*, 37(4), 1733–1751.

A 附錄：變數處理及資料來源

| 變數及代號名稱 | 計算及處理方法 | 資料來源 |
|----------------------------------|--|---|
| 台灣實質 GDP 年增率 gdp_tw | 季頻率換月(流量) | TEJ-總體經濟-NE0812 台灣-實質 GDP 年增率 (2016=100)-季 (百分比) |
| 景氣對策信號綜合分數 econ_lead1 | | TEJ-總體經濟-EA1101 台灣-景氣對策信號綜合分數-月 (分數) |
| 領先指標綜合指數 econ_lead2 | | TEJ-總體經濟-EB0101 台灣-領先指標綜合指數-月 (指數) |
| 同時指標綜合指數 econ_sim | | TEJ-總體經濟-EC0101 台灣-同時指標綜合指數-月 (指數) |
| 落後指標綜合指數 econ_lag | | TEJ-總體經濟-EB0103 台灣-落後指標綜合指數-月 (指數) |
| 落後指標/領先指標 econ_lag_lead | econ_lag /econ_lead2 | 自行計算 |
| 痛苦指數 pain_index | | TEJ-總體經濟-EB15 台灣-痛苦指數-月 (指數) |
| 工業生產指數年增率 ipi | | 中華民國統計資訊網經濟部統計處 |
| 工業生產指數-製造業年增率 mpi | | 中華民國統計資訊網經濟部統計處 |
| 信用對產出佔比 cgr | loan/名目月 GDP | 自行計算 |
| 本國銀行逾放比率 npl | 以前一筆資料替代遺漏值 | 中央銀行重要金融指標 |
| 台灣全體貨幣機構放款 loan | | 中央銀行重要金融指標 |
| 台灣全體貨幣機構存款 de- posit | | 中央銀行重要金融指標 |
| 台灣全體貨幣機構存放比 dtl | loan/deposit | 自行計算 |
| 台灣全體金融機構資產淨額 nafi | | TEJ-總體經濟-MU40 台灣-全體金融機構-資產-資產淨額 = 負債權益淨額-月-台幣 (百萬)(TWD) |
| M1B 年增率 m1b | | TEJ-總體經濟-MA1702 台灣 M1B 日平均年增率 (百分比) |
| M2 年增率 m2 | | TEJ-總體經濟-MA1501 台灣-M2 年增率-日平均值 (百分比) |
| 核心 cpi 年增率 (未經季 調)cpi_core_tw | | 中華民國統計資訊網 |
| 消費者物價總指數年增率 (經 季調)cpi_tw_sa | | 中華民國統計資訊網 |
| 消費者物價總指數年增率 (未 經季調)cpi_tw_nsa | | 中華民國統計資訊網 |
| 躉售物價總指數年增率 (未經 季調)wpi_tw | 躉售物價指數自 112 年 1 月起停編，故後 續資料依主計處新編 列之「國產與進口品 物價總指數」年增率 補齊。 | 中華民國統計資訊網 |
| 進口物價總指數 imp_price | | 中華民國統計資訊網-物價統計資料庫-各種物價總指數-進口物價總指數-美元計價-經季調 |

| 變數及代號名稱 | 計算及處理方法 | 資料來源 |
|--------------------------------|--|--|
| 出口物價總指數 exp_price | | 中華民國統計資訊網-物價統計資料庫-各種物價總指數-出口物價總指數-美元計價-經季調 |
| 批發業營業額年增率 whole_sales | | 經濟部統計處-批發、零售及餐飲業營業額統計 |
| 零售業營業額年增率 retail_sales | | 經濟部統計處-批發、零售及餐飲業營業額統計 |
| 台股加權指數 index_vw | | TEJ-調整股價(月)-Y9999(特殊轉檔) |
| 金融類 index_fin | | TEJ-調整股價(月)-Y2800(特殊轉檔) |
| 機電類 index_ele | | TEJ-調整股價(月)-Y1600(特殊轉檔) |
| 大盤週轉率 tr | 日頻率換月 | TEJ-調整股價(日)-Y9998 |
| 大盤股價淨值比 pbr | 日頻率換月 | TEJ-調整股價(日)-Y9998 |
| 大盤本益比 per | 日頻率換月 | TEJ-調整股價(日)-Y9998 |
| 大盤股價營收比 psr | 日頻率換月 | TEJ-調整股價(日)-Y9998 |
| 大盤現金殖利率 dy | 日頻率換月 | TEJ-調整股價(日)-Y9998 |
| 恐慌指數 vix_us | | TEJ-總體經濟-SB82 芝加哥擇權交易所波動率指數(恐慌指標)(指數)(USD) |
| ami_illiq 非流動性指標 | $\ln \left(\frac{\sum_{k=1}^{12} \frac{ ret_{t-k} }{dolv_{t-k}}}{12} \right)$ <p>其中"ret"為大盤月報酬率，"dolv"為大盤的月成交值。</p> | 自行計算 |
| 重貼現率 dr | | TEJ-總體經濟-MB0101 台灣-中央銀行-重貼現率-月(百分比) |
| 金融業拆款利率 ior | | TEJ-總體經濟-MB30 台灣-金融業拆款利率-隔夜-加權平均-月(百分比) |
| 五年期公司債 cb5 | 以前一筆資料替代遺漏值 | TEJ-總體經濟-MB4908 台灣-資本市場利率-公司債-5年期-月(百分比) |
| 台灣十年公債利率 gb10_tw | | 中央銀行重要金融指標 |
| 商業本票 31-90 天期次級市場利率 cp | | 中央銀行重要金融指標 |
| 美國長(十年)短(五年)天期利差 gb_spread_us1 | gb10_us-gb5_us | 自行計算。gb5_us: 美國五年期公債殖利率，來源為 TEJ-總體經濟-CA1502-美國五年期公債殖利率(百分比)。此變數僅用來計算利差，不會單獨進模型 |
| 美國長(十年)短(一年)天期利差 gb_spread_us2 | gb10_us-gb1_us | 自行計算。gb1_us: 美國一年期公債殖利率，來源為 TEJ-總體經濟-CA2602-美國一年期公債殖利率(百分比)，遺漏值以前一筆資料替代。此變數僅用來計算利差，不會單獨進模型 |
| 台北市房租指數 rent_tpe | | 台北市房租指數銜接表 |
| 五大銀行新承做放款金額-購屋貸款 nla_h | | 五大銀行(台銀、合庫銀、土銀、華銀及一銀)新承做放款金額與利率 |
| 五大銀行新承做放款利率-購屋貸款 nlr_h | | 五大銀行(台銀、合庫銀、土銀、華銀及一銀)新承做放款金額與利率 |
| 消費者購屋貸款(購置住宅貸款+房屋修繕貸款)la_d | | 中華民國統計資訊網 |
| 生產者建屋貸款(建築貸款)la_s | | 中華民國統計資訊網 |

| 變數及代號名稱 | 計算及處理方法 | 資料來源 |
|------------------------------|----------------------------|--|
| 消費者購屋貸款集中度 lagr_d | la_d/過去 12 期名目 月 GDP 總和 | 自行計算 |
| 生產者建屋貸款集中度 lagr_s | la_s/過去 12 期名目 月 GDP 總和 | 自行計算 |
| 失業率 unem_rate | | 中華民國統計資訊網 |
| 勞動參與率 labor | | TEJ-總體經濟-人口就業薪資統計- LA06 台灣-勞動參與率-月 (百分比) |
| 非農業就業人口 nonfarm | | TEJ-總體經濟-人口就業薪資統計- LA14 台灣-就業人數-非農業部門-月 (千人) |
| 經常性薪資 wage_reg | | TEJ-總體經濟-人口就業薪資統計- LB23 台灣-經常性薪資-各行業-月 (元)(TWD) |
| 基本工資-月 wage_base | | TEJ-總體經濟-人口就業薪資統計- WI01 台灣基本工資-月薪 |
| 各行業平均工時-月 wage_avg | | TEJ-總體經濟-人口就業薪資統計- LB4303 台灣-平均工時-各行業-月 (小 時) |
| 工業及服務業受僱員工淨進 入率 net_enter | LC01-LC0102 | 1.TEJ-總體經濟-人口就業薪資統計- LC01 台灣-進入率-工業及服務業-月 (百分比) 2.TEJ-總體經濟-人口就業薪 資統計-LC0102 台灣-退出率-工業及服 務業-月 (百分比) |
| 銅現貨 copper | | TEJ-總體經濟-重要原物料指標- PA0802 銅價-倫敦高級銅極現貨價 (噸)(USD) |
| 黃金現貨 gold | | TEJ-總體經濟-重要原物料指標-PA10 倫敦黃金現貨 (盎司)(USD) |
| 鋁現貨 alumi | | TEJ-總體經濟-重要原物料指標- PA1201 倫敦鋁現貨價 (噸)(USD)) |
| 鋼板 steel | | TEJ-總體經濟-重要原物料指標- PA1205 鋼板-中鋼基價 (噸)(TWD) |
| 布蘭特原油現貨 brent | | TEJ-總體經濟-重要原物料指標-PA15 北海布蘭特原油現貨 (平均)(桶)(USD) |
| CRB 期貨商品指數 crb | | TEJ-總體經濟-重要原物料指標-PA31 路透/Jefferies-CRB 期 |
| 金融帳-資產-其他投資 bop_fa_oia | 季頻率換月 (流量) | TEJ-台灣-BOP-FA-其他投資-資產-美 元-BPM6-季-季-美元 (百萬元)(USD) |
| 金融帳-負債-其他投資 bop_fa_oil | 季頻率換月 (流量) | TEJ-台灣-BOP-FA-其他投資-負債-美 元-BPM6-季-季-美元 (百萬元)(USD) |
| 經常帳淨額 bop_ca | 季頻率換月 (流量) | TEJ-總體經濟-國際收支平衡表-MD61 台灣-國際收支-經常帳-淨額-BPM6-季- 美元 (百萬元)(USD) |
| 外匯存底 fr | | TEJ-總體經濟-國際收支平衡表-MC13 台灣-外匯存底-美元-月 (億元)(USD) |
| 外銷訂單 sales | | TEJ-總體經濟-進出口統計-TA01 台 灣-外銷訂單金額總計-美元-月 (百萬 元)(USD) |
| 出(入)超 net_exp | | 財政部-一般貿易制度-進出口貿易值-貿 易總值 |
| 價值指數-出口 exp | | 財政部-一般貿易制度-貿易指數-總指數 |
| 價值指數-進口 imp | | 財政部-一般貿易制度-貿易指數-總指數 |

| 變數及代號名稱 | 計算及處理方法 | 資料來源 |
|------------------------|-------------|---|
| 中國實質 GDP 成長率 gdp_ch | 季頻率換月 (流量) | TEJ-總體經濟-CK19 中國實質 GDP 成長率-季 (百分比) |
| 中國 CPI 年增率 cpi_ch | | TEJ-總體經濟-CK18 中國 CPI 年增率 (百分比) |
| 日本實質 GDP 成長率 gdp_jp | 季頻率換月 (流量) | TEJ-總體經濟-CB2796 日本實質 GDP 年增率-2015=100(百分比) |
| 日本十年公債殖利率 gb10_jp | | TEJ-總體經濟-CB1502 日本十年公債殖利率-月均值 (百分比) |
| 日本 CPI 年增率 cpi_jp | | TEJ-總體經濟-CB2412 日本 CPI 年增率-2020=100(百分比) |
| 日本隔夜無擔保拆借利率 rate_jp | | TEJ-總體經濟-CB1603 日本隔夜無擔保拆借利率-月底值 (百分比) |
| 美國實質 GDP 成長率 gdp_us | 季頻率換月 (流量) | FRED |
| 美國十年公債殖利率 gb10_us | | TEJ-總體經濟-CA15 美國十年期公債殖利率 (百分比) |
| 美國二年公債殖利率 gb2_us | | TEJ-總體經濟-CA26 美國二年期公債殖利率 (百分比) |
| 美國三個月國庫券利率 gb3m_us | | TEJ-總體經濟-CA14 美國國庫券利率-三個月期 (百分比) |
| 美國 CPI 年增率 cpi_us | | TEJ-總體經濟-CA2402 美國 CPI 年增率-1982-84=100(百分比) |
| 美國聯邦資金市場利率 rate_us | | TEJ-總體經濟-CA13 美國聯邦資金市場利率-市場實際拆款利率 (百分比) |
| 南韓實質 GDP 成長率 gdp_sk | 季頻率換月 (流量) | TEJ-總體經濟-CH0308 南韓實質 GDP 季成長率-2010=100-季調 (百分比) |
| 南韓公債殖利率 gb10_sk | | TEJ-總體經濟-CH15 南韓公債利率 (百分比) |
| 南韓 CPI 年增率 cpi_sk | | TEJ-總體經濟-CH2306 南韓 CPI 消費者物價指數年增率-2020=100(百分比) |
| 南韓貨幣市場利率 rate_sk | | TEJ-總體經濟-CH13 南韓貨幣市場利率 (百分比) |
| 美日匯率 usd_jpy | | TEJ-總體經濟-CB19 美元兌日圓匯率-月底值 (元)(USD) |
| 美中匯率 usd_cny | | TEJ-總體經濟-CK13 美元兌人民幣匯率-月底值 (元)(USD) |
| 美韓匯率 usd_krw | | TEJ-總體經濟-CH19 美元兌韓元匯率-月底值 (元)(USD) |
| 美台匯率 usd_twd | | TEJ-總體經濟-MC02 台灣美元兌新台幣-月底值 (元)(USD) |
| 企業脆弱指數 cvi | 日頻率換月 | 新加坡大學 |
| 消費者信心指數 ccl | 以前一筆資料替代遺漏值 | TEJ-總體經濟-EB18 台灣-消費者信心指數-月 (指數) |
| delta_covar | | 自行計算 |

B 附錄：ADF 檢定值

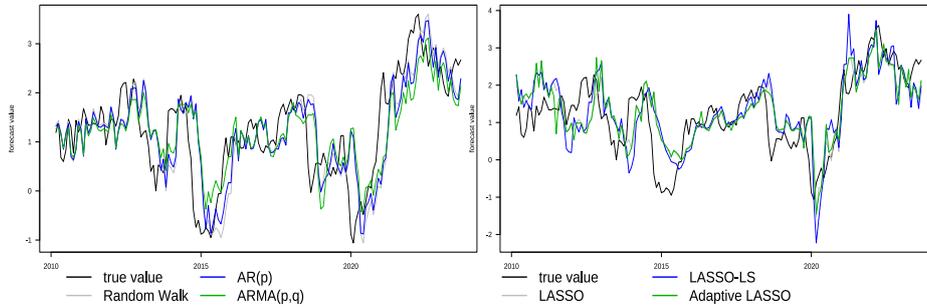
| 變數 | 第一次檢定 | 第二次檢定 | 第三次檢定 |
|--------------------------------------|-------|----------|----------|
| 進口物價總指數 (imp_price) | -2.08 | -5.55*** | |
| 出口物價總指數 (exp_price) | -3.08 | -4.94*** | |
| 非農業就業人口 (nonfarm) | -0.84 | -5.02*** | |
| 經常性薪資 (wage_reg) | 0.08 | -7.51*** | |
| 基本工資-月 (wage_base) | -1.27 | -8.23*** | |
| 本國銀行逾放比率 (npl) | -2.32 | -4.59*** | |
| 台灣全體貨幣機構放款 (loan) | 0.57 | -4.46*** | |
| 台灣全體貨幣機構存款 (deposit) | 1.14 | -4.79*** | |
| 台灣全體金融機構資產淨額 (nafi) | 0.28 | -7.27*** | |
| 加權指數 (index_vw) | -2.96 | -6.21*** | |
| 機電類 (index_ele) | -2.26 | -6.25*** | |
| 金融類 (index_fin) | -3.14 | -6.71*** | |
| 恐慌指數 (vix_us) | -2.54 | -5.80*** | |
| 大盤週轉率 (tr) | -3.38 | -9.32*** | |
| 美國長 (十年) 短 (五年) 天期利差 (gb_spread_us1) | -2.76 | -5.52*** | |
| 美國長 (十年) 短 (一年) 天期利差 (gb_spread_us2) | -2.87 | -5.02*** | |
| 台北市房租指數 (rent_tpe) | -2.57 | -5.31*** | |
| 五大銀行新承做放款金額-購屋貸款 (nla_h) | -2.01 | -7.51*** | |
| 消費者購屋貸款 (la_d) | 0.09 | -2.18 | -7.42*** |
| 生產者建屋貸款 (la_s) | -2.81 | -2.71 | -8.09*** |
| 消費者購屋貸款集中度 (lagr_d) | -2.18 | -3.64** | |
| 生產者建屋貸款集中度 (lagr_s) | -3.16 | -3.44** | |
| 銅現貨 (copper) | -2.51 | -7.25*** | |
| 黃金現貨 (gold) | -2.00 | -6.00*** | |
| 鋁現貨 (alumi) | -3.07 | -7.10*** | |
| 鋼板 (steel) | -2.15 | -6.30*** | |
| 布蘭特原油現貨 (brent) | -2.35 | -7.00*** | |
| CRB 期貨商品指數 (crb) | -2.56 | -6.33*** | |
| 外匯存底 (fr) | -2.29 | -5.59*** | |
| 價值指數-出口 (exp) | -3.05 | -7.68*** | |
| 價值指數-進口 (imp) | -3.38 | -7.06*** | |
| 經常帳淨額 (bop_ca) | -3.41 | -8.31*** | |
| 日本十年公債殖利率 (gb10_jp) | -1.37 | -7.24*** | |
| 日本隔夜無擔保拆借利率 (rate_jp) | -2.56 | -6.56*** | |
| 美國十年公債殖利率 (gb10_us) | -1.60 | -7.48*** | |
| 美國二年公債殖利率 (gb2_us) | -2.11 | -5.09*** | |
| 美國三個月國庫券利率 (gb3m_us) | -3.05 | -4.01** | |
| 美國聯邦資金市場利率 (rate_us) | -3.36 | -3.78 | |
| 南韓公債殖利率 (gb10_sk) | -1.88 | -6.35*** | |
| 南韓 CPI 年增率 (cpi_sk) | -2.89 | -5.92*** | |
| 南韓貨幣市場利率 (rate_sk) | -2.29 | -4.83*** | |

| | | | |
|----------------|-------|----------|--|
| 美日匯率 (usd_jpy) | -1.10 | -6.94*** | |
| 美中匯率 (usd_cny) | -0.73 | -6.98*** | |
| 美韓匯率 (usd_krw) | -3.00 | -6.58*** | |
| 消費者信心指數 (cci) | -3.01 | -6.12*** | |

註：ADF 檢定之臨界值，參考 Cook(2001)，10% 顯著水準的臨界值為-3.11，5% 為-3.398，1% 為-3.961。

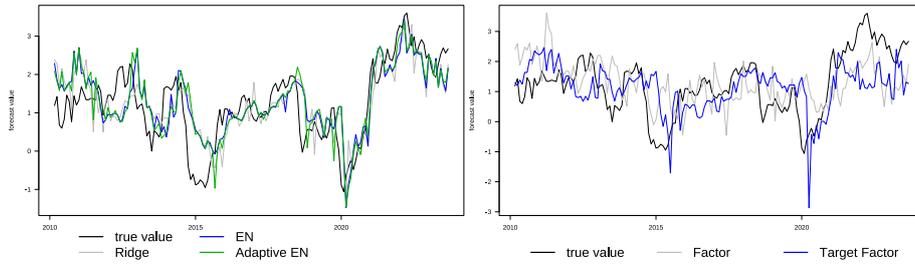
C 附錄：樣本外預測走勢圖

樣本外預測走勢圖 ($h = 3$)



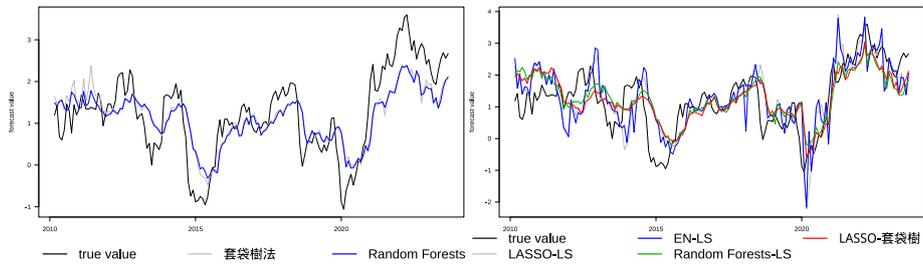
(1) 基準模型

(2) LASSO 模型家族 1



(3) LASSO 模型家族 2

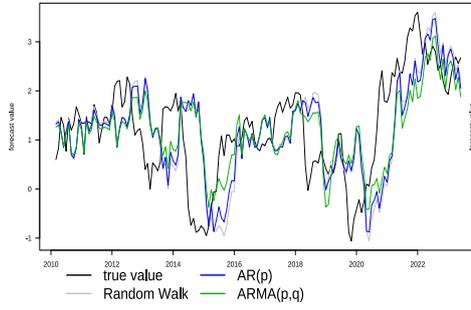
(4) 因子模型



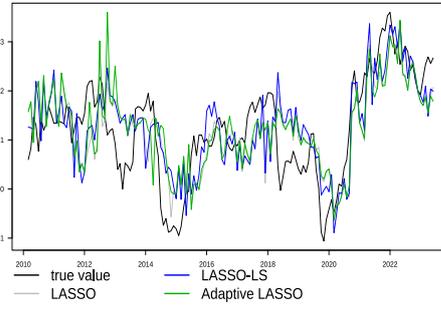
(5) 非線性機器學習模型

(6) 組合模型

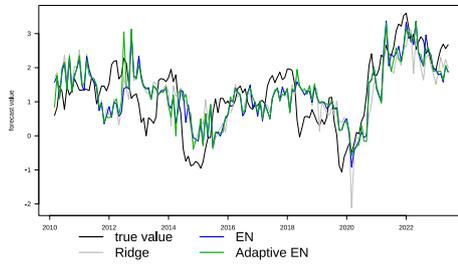
樣本外預測走勢圖 ($h = 6$)



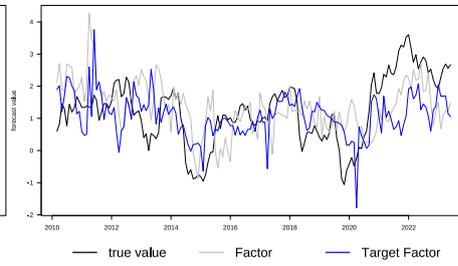
(1) 基準模型



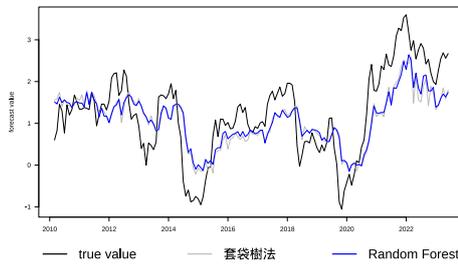
(2) LASSO 模型家族 1



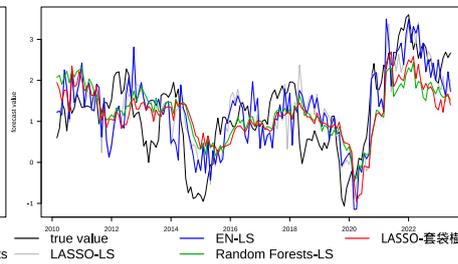
(3) LASSO 模型家族 2



(4) 因子模型

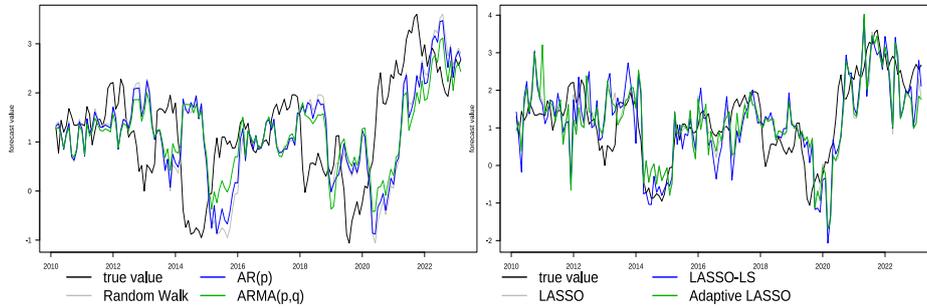


(5) 非線性機器學習模型



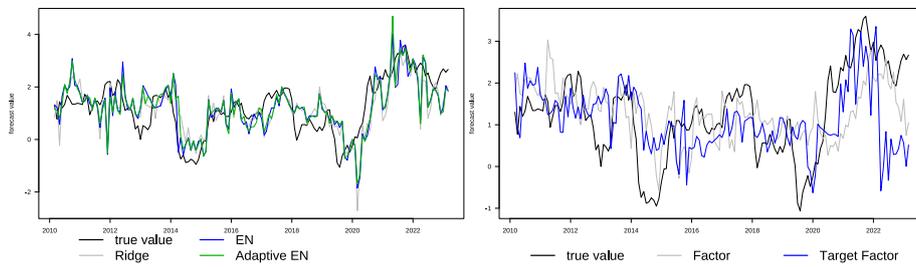
(6) 組合模型

樣本外預測走勢圖 ($h = 9$)



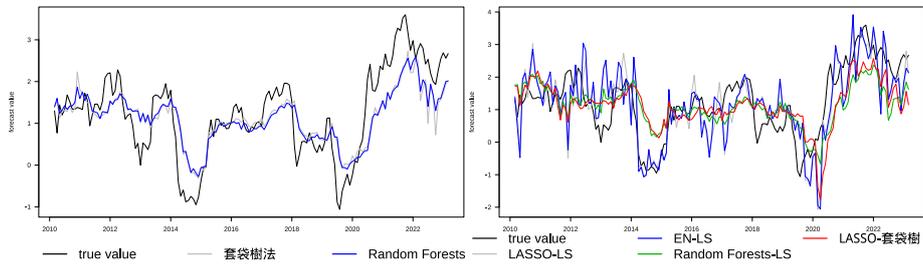
(1) 基準模型

(2) LASSO 模型家族 1



(3) LASSO 模型家族 2

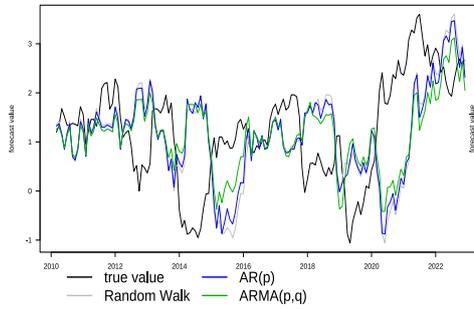
(4) 因子模型



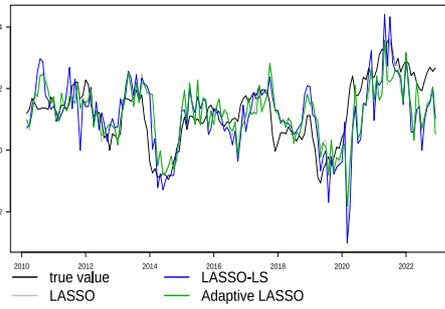
(5) 非線性機器學習模型

(6) 組合模型

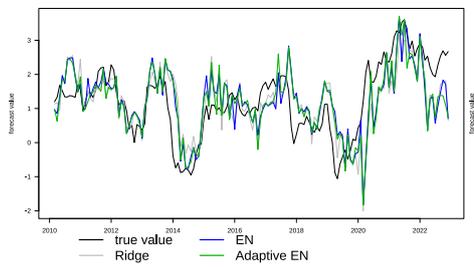
樣本外預測走勢圖 ($h = 12$)



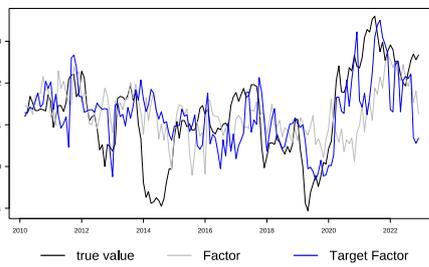
(1) 基準模型



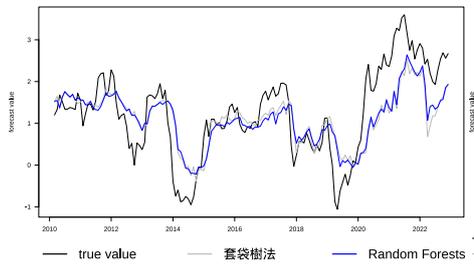
(2) LASSO 模型家族 1



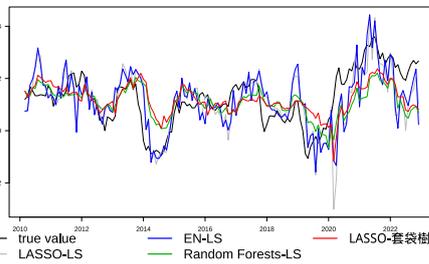
(3) LASSO 模型家族 2



(4) 因子模型

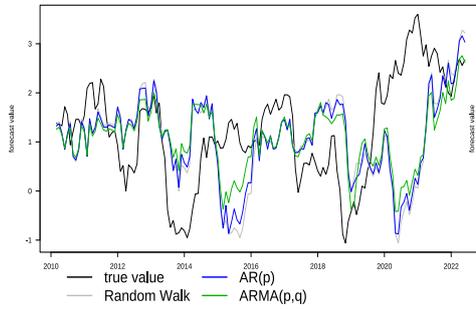


(5) 非線性機器學習模型

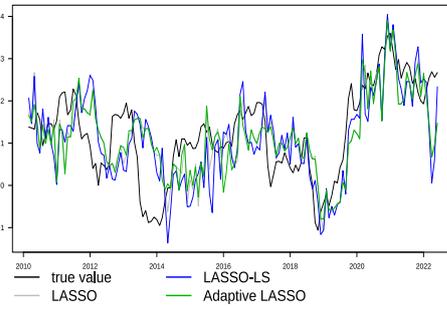


(6) 組合模型

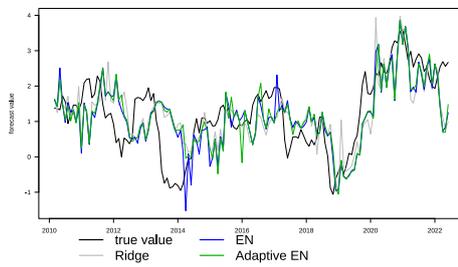
樣本外預測走勢圖 ($h = 18$)



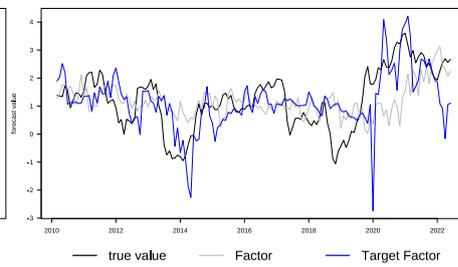
(1) 基準模型



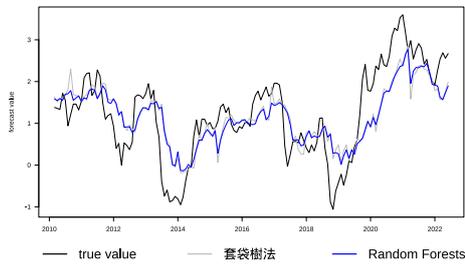
(2) LASSO 模型家族 1



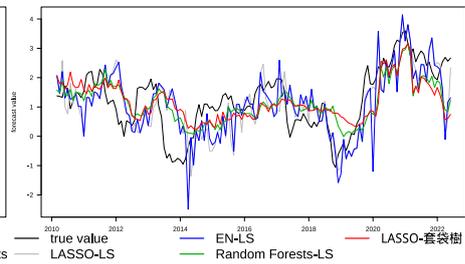
(3) LASSO 模型家族 2



(4) 因子模型

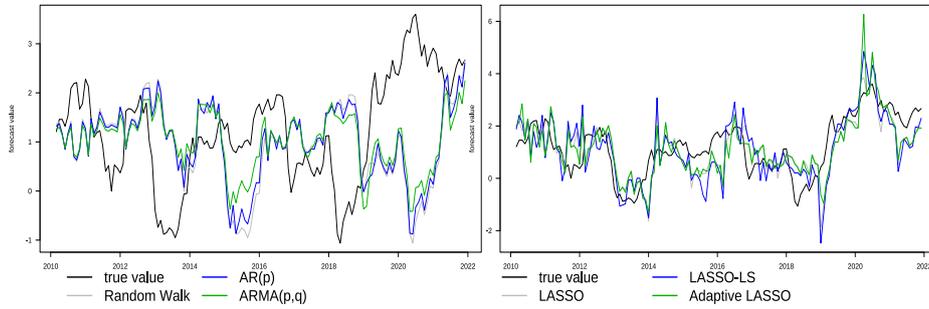


(5) 非線性機器學習模型



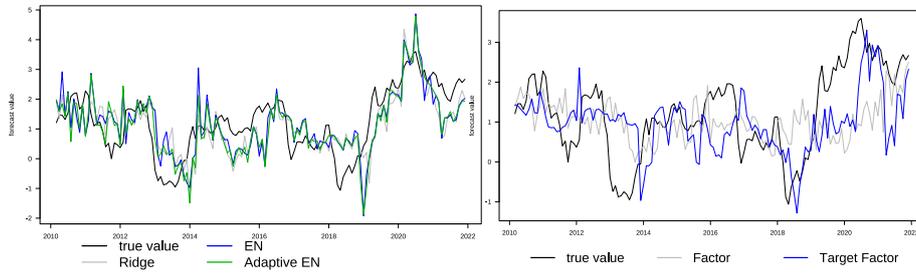
(6) 組合模型

樣本外預測走勢圖 ($h = 24$)



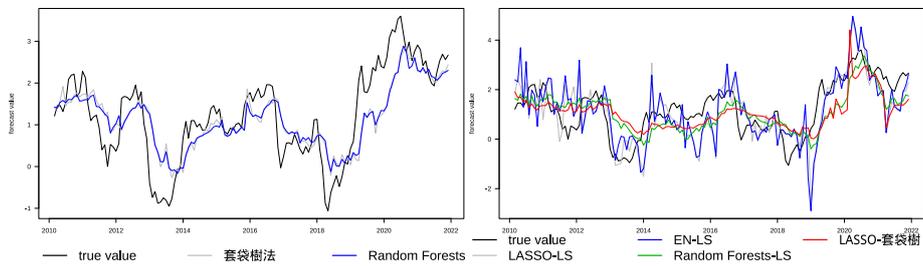
(1) 基準模型

(2) LASSO 模型家族 1



(3) LASSO 模型家族 2

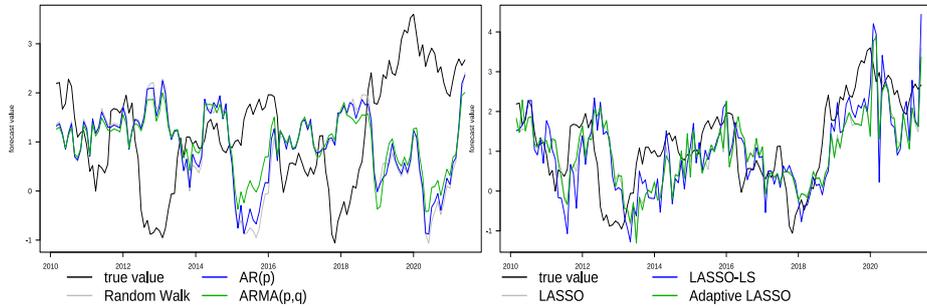
(4) 因子模型



(5) 非線性機器學習模型

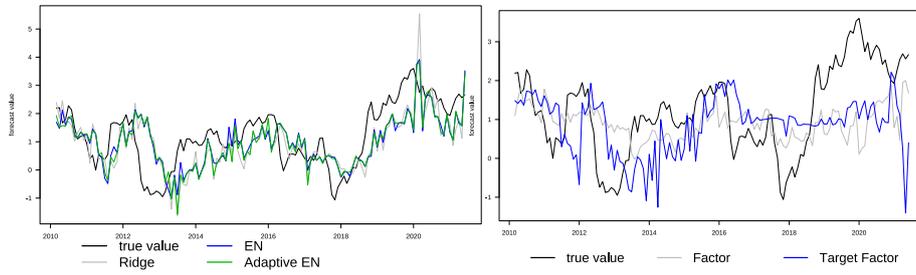
(6) 組合模型

樣本外預測走勢圖 ($h = 30$)



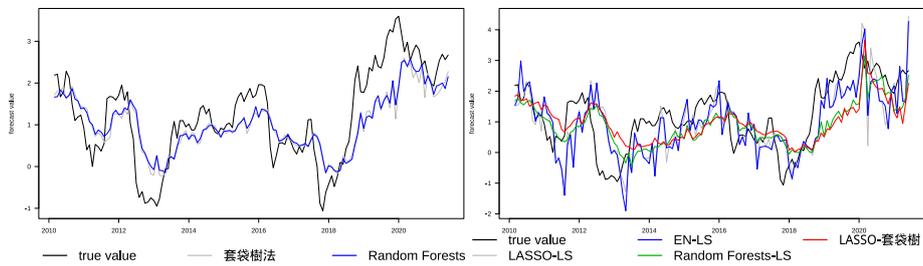
(1) 基準模型

(2) LASSO 模型家族 1



(3) LASSO 模型家族 2

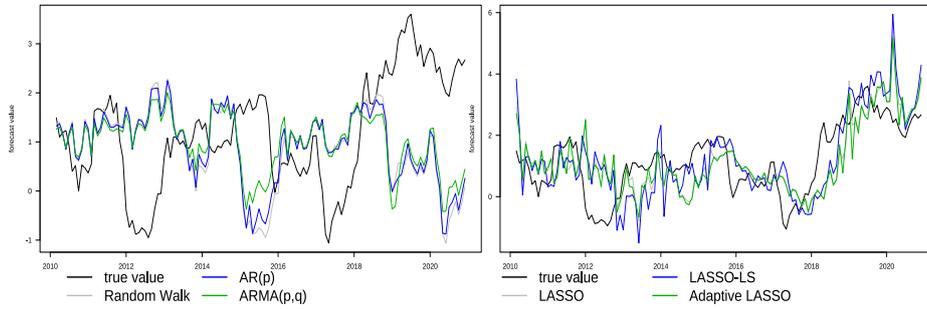
(4) 因子模型



(5) 非線性機器學習模型

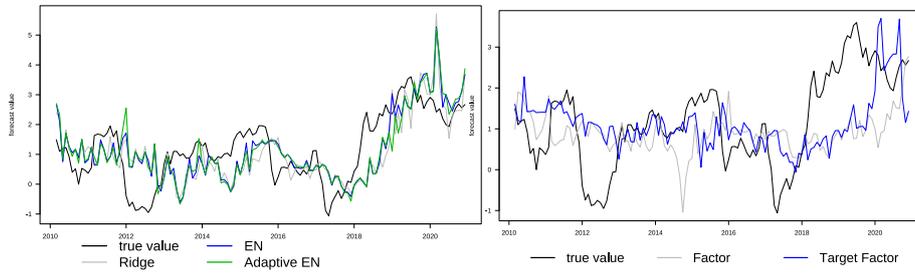
(6) 組合模型

樣本外預測走勢圖 ($h = 36$)



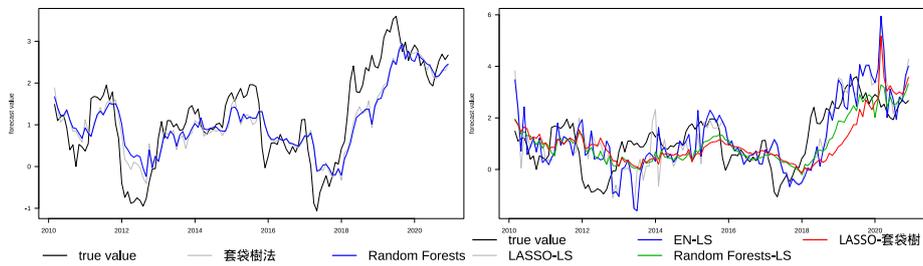
(1) 基準模型

(2) LASSO 模型家族 1



(3) LASSO 模型家族 2

(4) 因子模型



(5) 非線性機器學習模型

(6) 組合模型

D 附錄：穩健性測試

D.1 不同被預測變數

本研究使用不同被預測變數 (季調 CPI 年增率、未季調 CPI 年增率及未季調核心 CPI 年增率) 進行穩健性分析，結果如下：

- 以 RMSE 為預測表現的評估標準：
 1. 向前 1 期預測：以季調 CPI 年增率、未季調 CPI 年增率及未季調核心 CPI 年增率作為被預測變數時，前兩者表現最佳的模型皆為 LASSO 模型，第三者為隨機森林-LS 模型。
 2. 向前 12 期預測：以季調 CPI 年增率、未季調 CPI 年增率及未季調核心 CPI 年增率作為被預測變數，皆為隨機森林模型表現最好。
- 以 MAE 為預測表現的評估標準：
 1. 向前 1 期預測：以季調 CPI 年增率、未季調 CPI 年增率及未季調核心 CPI 年增率作為被預測變數時，前兩者表現最佳的模型皆為 Adaptive-LASSO 模型，第三者為隨機森林-LS 模型表現最好。
 2. 向前 12 期預測：以季調 CPI 年增率、未季調 CPI 年增率及未季調核心 CPI 年增率作為被預測變數時，表現最佳的模型皆為隨機森林模型。
- 以 MAD 為預測表現的評估標準：
 1. 向前 1 期預測：以季調 CPI 年增率、未季調 CPI 年增率及未季調核心 CPI 年增率作為被預測變數時，表現最佳的模型分別為 LASSO-套袋樹模型、EN-LS 模型及隨機漫步模型。
 2. 向前 12 期預測：以季調 CPI 年增率、未季調 CPI 年增率及未季調核心 CPI 年增率作為被預測變數時，第一個表現最佳的模型為套袋樹法模型，後兩者皆為隨機森林模型。

D.2 不同樣本期間

其次，我們使用不同樣本期間 (2000 年至 2023 年、2000 年至 2019 年及 2020 年至 2023 年) 進行穩健性分析，結果如下：

- 以 RMSE 為預測表現的評估標準：
 1. 向前 1 期預測：在 2000 年至 2023 年及 2000 年至 2019 年期間，皆為 LASSO-套袋樹模型表現最好，而 2020 年至 2023 年則為 LASSO-LS 模型表現最好。
 2. 向前 12 期預測：2000 年至 2023 年隨機森林模型表現最好，2000 年至 2019 年套袋樹法模型表現最好，2020 年至 2023 年目標因子模型表現最好。
- 以 MAE 為預測表現的評估標準：

1. 向前 1 期預測：2000 年至 2023 年、2000 年至 2019 年皆為 Adaptive-LASSO 模型表現最好，2020 年至 2023 年 LASSO-LS 模型表現最好。
 2. 向前 12 期預測：與 RMSE 結論相同。
- 以 MAD 為預測表現的評估標準：
 1. 向前 1 期預測：2000 年至 2023 年 LASSO-套袋樹模型表現最好，2000 年至 2019 年 LASSO-LS 模型表現最好，而 2020 年至 2023 年期間 Adaptive-EN 模型表現最好。
 2. 向前 12 期預測：三個樣本區間皆為套袋樹法模型表現最好。

D.3 不同視窗長度

最後，我們使用不同視窗長度 (120 期、60 期) 進行穩健性分析，結果如下：

- 以 RMSE 為預測表現的評估標準：
 1. 向前 1 期預測：在視窗長度 120 期及 60 期下，預測表現最好的模型皆為 LASSO 模型。
 2. 向前 12 期預測：在視窗長度 120 期及 60 期下，預測表現最好的模型皆為隨機森林模型。
- 以 MAE 為預測表現的評估標準：
 1. 向前 1 期預測：在視窗長度 120 期及 60 期下，預測表現最好的模型分別為 Adaptive-LASSO 模型及 LASSO-套袋樹模型。
 2. 向前 12 期預測：在視窗長度 120 期及 60 期下，預測表現最好的模型分別為隨機森林模型及套袋樹法模型。
- 以 MAD 為預測表現的評估標準：
 1. 向前 1 期預測：在視窗長度 120 期及 60 期下，皆為 LASSO-套袋樹模型表現最好。
 2. 向前 12 期預測：視窗長度 120 期及 60 期下，皆為套袋樹法模型表現最好。

表 18: 以不同 CPI 通膨率作為被解釋變數 (h=1)

| 模型 | RMSE | | | | MAE | | | | MAD | | | |
|----------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|-----------|--------------|
| | CPI (季調) | CPI (未季調) | 核心 CPI (未季調) | CPI (季調) | CPI (未季調) | 核心 CPI (未季調) | CPI (季調) | CPI (未季調) | 核心 CPI (未季調) | CPI (季調) | CPI (未季調) | 核心 CPI (未季調) |
| | 時間序列模型 | 0.525 | 0.804 | 0.448 | 0.393 | 0.617 | 0.314 | 0.290 | 0.480 | 0.180 | 0.211 | 0.223 |
| 隨機漫步 | 0.511 | 0.766 | 0.405 | 0.392 | 0.594 | 0.303 | 0.301 | 0.467 | | | | |
| AR(p) | 0.509 | 0.766 | 0.406 | 0.387 | 0.593 | 0.307 | 0.305 | 0.467 | | | | |
| ARMA(p,q) | | | | | | | | | | | | |
| LASSO 模型家族 | | | | | | | | | | | | |
| LASSO | 0.374 | 0.650 | 0.443 | 0.293 | 0.505 | 0.330 | 0.251 | 0.414 | 0.254 | | | |
| 脊迴歸 | 0.524 | 0.772 | 0.431 | 0.402 | 0.598 | 0.326 | 0.320 | 0.517 | 0.238 | | | |
| EN | 0.382 | 0.671 | 0.438 | 0.298 | 0.520 | 0.325 | 0.263 | 0.420 | 0.243 | | | |
| Adaptive LASSO | 0.374 | 0.659 | 0.445 | 0.292 | 0.504 | 0.334 | 0.245 | 0.394 | 0.266 | | | |
| Adaptive EN | 0.380 | 0.669 | 0.440 | 0.294 | 0.520 | 0.328 | 0.258 | 0.420 | 0.251 | | | |
| 因子模型 | | | | | | | | | | | | |
| 主成分分析法 | 1.010 | 1.166 | 0.755 | 0.837 | 0.971 | 0.627 | 0.741 | 0.884 | 0.517 | | | |
| 目標因子 | 0.761 | 1.099 | 0.644 | 0.523 | 0.886 | 0.520 | 0.321 | 0.766 | 0.413 | | | |
| 非線性機器學習模型 | | | | | | | | | | | | |
| 套袋樹法 | 0.445 | 0.709 | 0.454 | 0.342 | 0.555 | 0.334 | 0.259 | 0.435 | 0.229 | | | |
| 隨機森林 | 0.472 | 0.712 | 0.470 | 0.370 | 0.569 | 0.343 | 0.280 | 0.462 | 0.240 | | | |
| 組合模型 | | | | | | | | | | | | |
| LASSO-LS | 0.383 | 0.676 | 0.461 | 0.300 | 0.518 | 0.348 | 0.242 | 0.412 | 0.272 | | | |
| EN-LS | 0.390 | 0.678 | 0.447 | 0.303 | 0.517 | 0.340 | 0.265 | 0.391 | 0.293 | | | |
| LASSO-套袋樹 | 0.381 | 0.666 | 0.446 | 0.294 | 0.514 | 0.339 | 0.239 | 0.420 | 0.262 | | | |
| 隨機森林-LS | 0.413 | 0.685 | 0.400 | 0.318 | 0.533 | 0.298 | 0.260 | 0.435 | 0.226 | | | |

表 19: 以不同 CPI 通膨率作為被解釋變數 (h=12)

| 模型 | RMSE | | | | MAE | | | | MAD | | | |
|----------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | CPI (季調) | CPI (未季調) | 核心 CPI (未季調) | CPI (季調) | CPI (未季調) | 核心 CPI (未季調) | CPI (季調) | CPI (未季調) | 核心 CPI (未季調) | CPI (季調) | CPI (未季調) | 核心 CPI (未季調) |
| | 時間序列模型 | 1.287 | 1.437 | 0.778 | 1.029 | 1.170 | 0.629 | 0.855 | 1.035 | 0.610 | 0.855 | 1.035 |
| 隨機漫步 | 1.245 | 1.320 | 0.761 | 1.003 | 1.100 | 0.611 | 0.807 | 0.945 | 0.493 | 0.807 | 0.945 | 0.493 |
| AR(p) | 1.165 | 1.206 | 0.752 | 0.943 | 1.024 | 0.603 | 0.711 | 0.939 | 0.531 | 0.711 | 0.939 | 0.531 |
| ARMA(p,q) | | | | | | | | | | | | |
| LASSO 模型家族 | | | | | | | | | | | | |
| LASSO | 0.837 | 0.948 | 0.564 | 0.623 | 0.749 | 0.449 | 0.444 | 0.635 | 0.352 | 0.444 | 0.635 | 0.352 |
| 脊迴歸 | 0.848 | 0.997 | 0.581 | 0.649 | 0.774 | 0.464 | 0.511 | 0.627 | 0.390 | 0.511 | 0.627 | 0.390 |
| EN | 0.818 | 0.951 | 0.553 | 0.610 | 0.758 | 0.451 | 0.452 | 0.673 | 0.377 | 0.451 | 0.673 | 0.377 |
| Adaptive LASSO | 0.846 | 1.004 | 0.563 | 0.627 | 0.781 | 0.444 | 0.464 | 0.638 | 0.347 | 0.464 | 0.638 | 0.347 |
| Adaptive EN | 0.829 | 0.961 | 0.567 | 0.621 | 0.753 | 0.452 | 0.476 | 0.617 | 0.377 | 0.476 | 0.617 | 0.377 |
| 因子模型 | | | | | | | | | | | | |
| 主成分分析法 | 0.966 | 1.063 | 0.746 | 0.745 | 0.845 | 0.625 | 0.519 | 0.694 | 0.536 | 0.519 | 0.694 | 0.536 |
| 目標因子 | 0.899 | 1.159 | 0.656 | 0.666 | 0.896 | 0.522 | 0.491 | 0.696 | 0.461 | 0.491 | 0.696 | 0.461 |
| 非線性機器學習模型 | | | | | | | | | | | | |
| 套袋樹法 | 0.712 | 0.868 | 0.508 | 0.546 | 0.708 | 0.389 | 0.414 | 0.586 | 0.290 | 0.414 | 0.586 | 0.290 |
| 隨機森林 | 0.674 | 0.828 | 0.484 | 0.527 | 0.677 | 0.371 | 0.415 | 0.562 | 0.282 | 0.415 | 0.562 | 0.282 |
| 組合模型 | | | | | | | | | | | | |
| LASSO-LS | 0.920 | 0.907 | 0.598 | 0.685 | 0.732 | 0.475 | 0.519 | 0.679 | 0.400 | 0.519 | 0.679 | 0.400 |
| EN-LS | 0.865 | 0.979 | 0.565 | 0.650 | 0.767 | 0.455 | 0.485 | 0.657 | 0.378 | 0.485 | 0.657 | 0.378 |
| LASSO-套袋樹 | 0.898 | 0.968 | 0.556 | 0.710 | 0.786 | 0.459 | 0.577 | 0.629 | 0.459 | 0.577 | 0.629 | 0.459 |
| 隨機森林-LS | 0.891 | 0.999 | 0.569 | 0.710 | 0.816 | 0.462 | 0.536 | 0.720 | 0.384 | 0.536 | 0.720 | 0.384 |

表 20: 不同樣本區間 ($h=1$)

| 模型 | RMSE | | | | MAE | | | | MAD | | | |
|----------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|
| | 2000.03 -2023.12 | 2000.03 -2019.12 | 2020.01 -2023.12 | 2000.03 -2023.12 | 2000.03 -2019.12 | 2000.03 -2019.12 | 2020.01 -2023.12 | 2000.03 -2023.12 | 2000.03 -2019.12 | 2000.03 -2019.12 | 2020.01 -2023.12 | 2020.01 -2023.12 |
| 時間序列模型 | | | | | | | | | | | | |
| 隨機漫步 | 0.525 | 0.507 | 0.566 | 0.393 | 0.368 | 0.368 | 0.451 | 0.290 | 0.270 | 0.290 | 0.350 | 0.350 |
| AR(p) | 0.511 | 0.487 | 0.566 | 0.392 | 0.367 | 0.367 | 0.450 | 0.301 | 0.264 | 0.301 | 0.329 | 0.329 |
| ARMA(p,q) | 0.509 | 0.486 | 0.561 | 0.387 | 0.362 | 0.362 | 0.447 | 0.305 | 0.261 | 0.305 | 0.326 | 0.326 |
| LASSO 模型家族 | | | | | | | | | | | | |
| LASSO | 0.374 | 0.384 | 0.354 | 0.293 | 0.291 | 0.291 | 0.293 | 0.251 | 0.234 | 0.251 | 0.216 | 0.216 |
| 脊迴歸 | 0.524 | 0.540 | 0.485 | 0.402 | 0.415 | 0.415 | 0.372 | 0.320 | 0.331 | 0.320 | 0.287 | 0.287 |
| EN | 0.382 | 0.387 | 0.363 | 0.298 | 0.299 | 0.299 | 0.296 | 0.263 | 0.233 | 0.263 | 0.231 | 0.231 |
| Adaptive LASSO | 0.374 | 0.379 | 0.361 | 0.292 | 0.291 | 0.291 | 0.298 | 0.245 | 0.236 | 0.245 | 0.214 | 0.214 |
| Adaptive EN | 0.380 | 0.385 | 0.357 | 0.294 | 0.294 | 0.294 | 0.296 | 0.258 | 0.242 | 0.258 | 0.200 | 0.200 |
| 因子模型 | | | | | | | | | | | | |
| 主成分分析法 | 1.010 | 0.883 | 1.281 | 0.837 | 0.706 | 0.706 | 1.177 | 0.741 | 0.596 | 0.741 | 0.479 | 0.479 |
| 目標因子 | 0.761 | 0.875 | 0.362 | 0.523 | 0.622 | 0.622 | 0.290 | 0.321 | 0.441 | 0.321 | 0.194 | 0.194 |
| 非線性機器學習模型 | | | | | | | | | | | | |
| 套袋樹法 | 0.445 | 0.424 | 0.506 | 0.342 | 0.323 | 0.323 | 0.407 | 0.259 | 0.246 | 0.259 | 0.317 | 0.317 |
| 隨機森林 | 0.472 | 0.419 | 0.594 | 0.370 | 0.322 | 0.322 | 0.499 | 0.280 | 0.242 | 0.280 | 0.280 | 0.280 |
| 組合模型 | | | | | | | | | | | | |
| LASSO-LS | 0.383 | 0.425 | 0.316 | 0.300 | 0.316 | 0.316 | 0.265 | 0.242 | 0.231 | 0.242 | 0.280 | 0.280 |
| EN-LS | 0.390 | 0.411 | 0.336 | 0.303 | 0.311 | 0.311 | 0.281 | 0.265 | 0.235 | 0.265 | 0.282 | 0.282 |
| LASSO-套袋樹 | 0.381 | 0.389 | 0.365 | 0.294 | 0.298 | 0.298 | 0.292 | 0.239 | 0.238 | 0.239 | 0.202 | 0.202 |
| 隨機森林-LS | 0.413 | 0.423 | 0.375 | 0.318 | 0.322 | 0.322 | 0.302 | 0.260 | 0.272 | 0.260 | 0.233 | 0.233 |

表 21: 不同樣本區間 ($h=12$)

| 模型 | RMSE | | | | MAE | | | | MAD | | | | |
|----------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|
| | 2000.03 -2023.12 | 2000.03 -2019.12 | 2020.01 -2023.12 | 2000.03 -2023.12 | 2000.03 -2019.12 | 2000.03 -2023.12 | 2020.01 -2023.12 | 2000.03 -2023.12 | 2000.03 -2019.12 | 2000.03 -2023.12 | 2020.01 -2023.12 | 2000.03 -2019.12 | 2020.01 -2023.12 |
| 時間序列模型 | | | | | | | | | | | | | |
| 隨機漫步 | 1.287 | 1.159 | 1.681 | 1.029 | 0.927 | 1.389 | 0.855 | 0.690 | 1.350 | | | | |
| AR(p) | 1.245 | 1.121 | 1.615 | 1.003 | 0.900 | 1.352 | 0.807 | 0.689 | 1.258 | | | | |
| ARMA(p,q) | 1.165 | 1.020 | 1.511 | 0.943 | 0.811 | 1.294 | 0.711 | 0.668 | 0.895 | | | | |
| LASSO 模型家族 | | | | | | | | | | | | | |
| LASSO | 0.837 | 0.659 | 1.279 | 0.623 | 0.504 | 0.984 | 0.444 | 0.380 | 0.521 | | | | |
| 脊迴歸 | 0.848 | 0.708 | 1.169 | 0.649 | 0.538 | 0.941 | 0.511 | 0.460 | 0.402 | | | | |
| EN | 0.818 | 0.672 | 1.231 | 0.610 | 0.506 | 0.950 | 0.452 | 0.378 | 0.535 | | | | |
| Adaptive LASSO | 0.846 | 0.685 | 1.197 | 0.627 | 0.525 | 0.961 | 0.464 | 0.432 | 0.470 | | | | |
| Adaptive EN | 0.829 | 0.647 | 1.182 | 0.621 | 0.508 | 0.958 | 0.476 | 0.403 | 0.401 | | | | |
| 因子模型 | | | | | | | | | | | | | |
| 主成分分析法 | 0.966 | 0.811 | 1.266 | 0.745 | 0.608 | 1.051 | 0.519 | 0.437 | 0.714 | | | | |
| 目標因子 | 0.899 | 0.892 | 0.984 | 0.666 | 0.651 | 0.756 | 0.491 | 0.467 | 0.565 | | | | |
| 非線性機器學習模型 | | | | | | | | | | | | | |
| 套袋樹法 | 0.712 | 0.510 | 1.090 | 0.546 | 0.384 | 0.999 | 0.414 | 0.282 | 0.288 | | | | |
| 隨機森林 | 0.674 | 0.514 | 1.002 | 0.527 | 0.394 | 0.917 | 0.415 | 0.308 | 0.291 | | | | |
| 組合模型 | | | | | | | | | | | | | |
| LASSO-LS | 0.920 | 0.702 | 1.444 | 0.685 | 0.546 | 1.125 | 0.519 | 0.444 | 0.607 | | | | |
| EN-LS | 0.865 | 0.690 | 1.392 | 0.650 | 0.527 | 1.044 | 0.485 | 0.391 | 0.573 | | | | |
| LASSO-套袋樹 | 0.898 | 0.715 | 1.246 | 0.710 | 0.540 | 1.143 | 0.577 | 0.353 | 0.382 | | | | |
| 隨機森林-LS | 0.891 | 0.646 | 1.373 | 0.710 | 0.498 | 1.313 | 0.536 | 0.342 | 0.351 | | | | |

表 22: 不同視窗長度

| 模型 | RMSE | | | | | | MAE | | | | | | MAD | | | | | | | | | | | |
|----------------|--------------|-------|--------------|-------|-------|-------|--------------|--------------|--------------|--------------|--------------|--------------|-------|--------------|-------|--------------|--------------|--------------|-------|-------|-------|-------|-------|-------|
| | W=120 | | W=60 | | W=120 | | W=60 | | W=120 | | W=60 | | W=120 | | W=60 | | | | | | | | | |
| | h=1 | h=12 | h=1 | h=12 | h=1 | h=12 | h=1 | h=12 | h=1 | h=12 | h=1 | h=12 | h=1 | h=12 | h=1 | h=12 | | | | | | | | |
| 時間序列模型 | | | | | | | | | | | | | | | | | | | | | | | | |
| 隨機漫步 | 0.525 | 1.287 | 0.673 | 1.692 | 0.393 | 1.029 | 0.510 | 1.297 | 0.290 | 0.855 | 0.380 | 1.070 | 0.511 | 1.245 | 0.679 | 1.651 | 0.392 | 1.003 | 0.522 | 1.265 | 0.301 | 0.807 | 0.413 | 1.002 |
| AR(p) | 0.509 | 1.165 | 0.682 | 1.562 | 0.387 | 0.943 | 0.525 | 1.185 | 0.305 | 0.711 | 0.420 | 0.921 | 0.509 | 1.165 | 0.682 | 1.562 | 0.387 | 0.943 | 0.525 | 1.185 | 0.305 | 0.711 | 0.420 | 0.921 |
| ARMA(p,q) | | | | | | | | | | | | | | | | | | | | | | | | |
| LASSO 模型家族 | | | | | | | | | | | | | | | | | | | | | | | | |
| LASSO | 0.374 | 0.837 | 0.483 | 1.199 | 0.293 | 0.623 | 0.363 | 0.752 | 0.251 | 0.444 | 0.277 | 0.553 | 0.524 | 0.848 | 0.755 | 0.949 | 0.402 | 0.649 | 0.586 | 0.752 | 0.320 | 0.511 | 0.487 | 0.596 |
| 脊迴歸 | 0.382 | 0.818 | 0.494 | 1.018 | 0.298 | 0.610 | 0.360 | 0.738 | 0.263 | 0.452 | 0.266 | 0.592 | 0.374 | 0.846 | 0.489 | 1.210 | 0.292 | 0.627 | 0.367 | 0.749 | 0.245 | 0.464 | 0.285 | 0.537 |
| Adaptive LASSO | 0.380 | 0.829 | 0.505 | 1.172 | 0.294 | 0.621 | 0.367 | 0.753 | 0.258 | 0.476 | 0.267 | 0.566 | 0.380 | 0.829 | 0.505 | 1.172 | 0.294 | 0.621 | 0.367 | 0.753 | 0.258 | 0.476 | 0.267 | 0.566 |
| Adaptive EN | | | | | | | | | | | | | | | | | | | | | | | | |
| 因子模型 | | | | | | | | | | | | | | | | | | | | | | | | |
| 主成分分析法 | 1.010 | 0.966 | 1.142 | 1.143 | 0.837 | 0.745 | 0.922 | 0.897 | 0.741 | 0.519 | 0.814 | 0.716 | 0.761 | 0.899 | 0.625 | 1.044 | 0.523 | 0.666 | 0.478 | 0.832 | 0.321 | 0.491 | 0.360 | 0.713 |
| 目標因子 | | | | | | | | | | | | | | | | | | | | | | | | |
| 非線性機器學習模型 | | | | | | | | | | | | | | | | | | | | | | | | |
| 套袋樹法 | 0.445 | 0.712 | 0.597 | 0.761 | 0.342 | 0.546 | 0.450 | 0.581 | 0.259 | 0.414 | 0.348 | 0.442 | 0.472 | 0.674 | 0.620 | 0.757 | 0.370 | 0.527 | 0.465 | 0.588 | 0.280 | 0.415 | 0.354 | 0.446 |
| 隨機森林 | | | | | | | | | | | | | | | | | | | | | | | | |
| 組合模型 | | | | | | | | | | | | | | | | | | | | | | | | |
| LASSO-LS | 0.383 | 0.920 | 0.543 | 1.833 | 0.300 | 0.685 | 0.394 | 0.802 | 0.242 | 0.519 | 0.294 | 0.559 | 0.390 | 0.865 | 0.535 | 1.126 | 0.303 | 0.650 | 0.393 | 0.756 | 0.265 | 0.485 | 0.300 | 0.592 |
| EN-LS | 0.381 | 0.898 | 0.473 | 1.231 | 0.294 | 0.710 | 0.350 | 0.853 | 0.239 | 0.577 | 0.254 | 0.692 | 0.413 | 0.891 | 0.547 | 0.978 | 0.318 | 0.710 | 0.401 | 0.777 | 0.260 | 0.536 | 0.310 | 0.629 |
| LASSO-套袋樹 | | | | | | | | | | | | | | | | | | | | | | | | |
| 隨機森林-LS | | | | | | | | | | | | | | | | | | | | | | | | |

E 附錄：期中報告意見回覆

壹、評論人意見與報告人答覆

徐之強教授評論意見：

- 一、就目前計畫進度而言，此計畫應已達成委託單位之要求。惟期中報告中有部分論述不夠清晰，希望可以在期末報告進一步釐清。例如，計畫利用滾動式窗法 (rolling window) 進行樣本內估計與樣本外預測，但並未說明起始訓練樣本期間、視窗長度與樣本外預測期間 (雖然可從圖 4-9 大致推出)。此外，收縮法 λ, γ 的決定，拔靴法或交叉驗證的抽樣方式 (block bootstrap?) 等，宜再加以詳細說明。
- 二、模型估計與預測宜注意 publication bias。例如，若要預測 2024 年 1 月的通貨膨脹率 (主計總處 2 月初公布)，股價指數、匯率、利率、消費者信心指數等已有 1 月的資訊，領先、同時、工業生產指數等為 2023 年 12 月底資料，而台、美、中、日經濟成長率與國際收支帳等資料 (季頻轉月頻是否存在測度誤差?) 卻只到 2023 年 9 月。釐清本計畫訊息集合與模型估計、h-step ahead 預測之時間軸關係具有實務應用價值。
- 三、由於台灣通貨膨脹率資料具有很強的持續性 (persistence)，但表 1 的預測模型設定顯示：除了時間數列模型外，其他預測模型似乎均未考慮 π_t 的落後項。建議計

畫團隊考慮將 π_t 落後項視為必要的預測變數 (如 Stock and Watson, 2002), 用以捕捉台灣通貨膨脹率資料的特徵, 並可探討其他預測變數 (因子) 比 π_t 自己的落後項是否能進一步提升額外的預測能力。

- 四、就預測績效評估方面, 除了比較 RMSE, MAE 等不同衡量預測表現的指標外 (建議將表 2 – 6 中預測誤差最小的數字以粗體表示), 若在時間允許下, 是否可利用一些文獻常用的預測準確性檢定 (如 Diebold and Mariano, 2002; Giacomini and White, 2006 等), 以評估不同模型樣本外預測能力是否相等。
- 五、此計畫利用不同機器學習方法選擇不同的預測變數 (模型)。然而, 計畫團隊若能補充那些預測變數最常被選出, 或影響樣本外預測績效最主要的總體與金融變數是那些 (opening the black box), 應可大幅提升此計畫的學術與實用價值。
- 六、從初步實證結果可知: 相較於時間數列模型, 機器學習方法在預測未來 12 個月以上的通貨膨脹率表現有相對優勢。然而, 此結論是否具穩健性 (robustness)? 建議計畫團隊可以嘗試不同的資料期間 (例如, 有無包含 COVID 疫情期間), 不同的視窗長度, 不同的樣本外預測期間等。
- 七、請補充台灣通膨預測的參考文獻。
- 八、表 2 與表 3 可以合併。

九、 P.31，leave-one-out cross-validation 解釋有待釐清。

答覆意見：

一、 感謝評論人意見，我們已在期末報告詳述起始訓練樣本期間、視窗長度與樣本外預測區間等，詳見期末報告第 4.1 節。此外，收縮法法 λ ， γ 的決定，拔靴法或交叉驗證的抽樣方式等設定及討論也補充於相關章節，其中 LASSO 模型家族 λ 、 γ 的決定及交叉驗證說明見第 3.2.2 節 (P.18) 至第 3.2.4 節 (P.19)。

另外，由於目前文獻中討論機器學習方法時，大都使用一般拔靴抽樣法的隨機森林模型，如 Medeiros et al. (2021)，本研究計畫因此先執行一般區塊拔靴抽樣法，生成樣本後，再以該樣本建構迴歸樹模型，如此可以得到多個樣本生成的迴歸樹模型。將所有訓練後的迴歸樹模型集合起來，便得到使用區塊拔靴抽樣法的隨機森林模型。詳見計畫之參考程式檔。

二、 我們同意大數據資料庫中的 publication bias 可能造成變數收集的時間落差，為統一起見，本計畫期末報告的樣本區間為 2000 年 1 月至 2023 年 12 月，目前研究計畫的大數據資料庫包含全部 93 個變數在全部樣本區間的資料，因此在進行向期一期與短中長期預測等 2024 年 1 月以後的通膨率應無問題。惟實際運用時，可能必需以最慢獲得的變數期間為樣本內時間斷點。

三、 本研究的大數據資料庫中包括當期通膨率，故在進行未

來之短中長期預測時皆已考慮此效果。我們在期末報告第 4.2 節第四段補充說明。見期末報告 P.30。

- 四、 期末報告已依您建議，將預測誤差最小的數字以粗體表示。惟因目前考慮眾多機器學習模型，受限於研究期程，期末報告並未進一步考慮如 Diebold and Mariano (2002) 或是 Giacomini and White (2006) 檢定，我們將相關的研究限制說明於第六章結論與討論，未來建議委託單位可以進一步考慮此延伸。
- 五、 感謝評論人建議，期末報告已補充將不同機器學習方法選擇的不同的預測變數列出。我們在報告中也討論在短中長期預測之下，最常被選出的總體與金融變數之實證意涵，詳見期末報告第 5.1 至 5.3 節與表 3，表 6-9 與表 12-15，冀望能大幅提升此計畫的學術與實用價值。
- 六、 我們依您建議考慮穩健性測試，包括不同的資料期間 (有無包含 COVID 疫情期間)，不同的視窗長度 (視窗長度 120 和 60 期)，不同的樣本外預測期間 (向前 1 至 36 期) 等。實證結果顯示本研究結果具穩健性，由於篇幅關係，我們將之列在期末報告附錄 D。
- 七、 感謝建議，期末報告已補充台灣通膨預測的參考文獻，詳見期末報告第 2.2 節。
- 八、 期末報告已依您建議合併表格，將向前一期之所有模型比較列在同一張表。

九、由於期中報告時，其他評論意見建議刪去其他非屬機器學習模型，故期末報告已將相關章節刪去。

劉祝安研究員評論意見：

一、研究方法的建議

- (一) 當 $h > 1$ 時，採用直接預測 (direct forecast) 或疊代預測 (iterated forecast)？
- (二) 預測方法在向前多期預測的調整：
 - 例如，Jackknife 模型平均法在 $h = 1$ 時採用 leave-one-out 方法，在 $h > 1$ 時採用 leave-h-out 方法。
- (三) 預測模型的參數設定：因子模型的因子個數如何選擇？機器學習方法的 nuisance parameter 如何設定？
- (四) 嚴格來說，完全子集合迴歸和 Jackknife 模型平均法不是機器學習的方法。此外，這兩個方法是否考慮到所有 92 個變數的模型組合？
- (五) 第 3 章的研究方法有介紹因子提升方法、動態因子模型、梯度提升法，以及一些其他的機器學習方法，但是目前在實證分析裡尚未運用。

二、資料處理的建議

- (一) 資料使用的範圍：附錄的表 7 顯示資料的起始日差異很大 (最早為 1980-01，最晚為 2000-01)。是否去除 Covid 期間資料？

(二) 報告中提到遺漏值使用前一筆資料代替。是否改用平均值插補、迴歸插補或內插法？

三、模型比較的建議

(一) 評估指標：the out-of-sample R² statistics。

(二) 假設檢定各個預測模型的差異：

– Apply the Diebold-Mariano test or the multivariate comparison based on the Model Confidence Set proposed by Hansen et al. (2011).

(三) 視窗長度 (W) 如何選取？不同視窗長度的結果？sub-sample 的結果？

四、其他建議

(一) 第 21 頁中 $\Phi_{t,m}$ 的定義？

(二) 第 43 頁表 2 中的 AR 和 ARMA，建議改成 AR(1) 和 ARMA(1,1)。

(三) Typo：第 31 頁的 Jacknife 應改成 Jackknife。

答覆意見：

一、研究方法的建議

(一) 本研究在 $h > 1$ 時使用直接預測。因為本研究所使用的模型大多是機器學習模型，而機器學習模型本就只是真實模型的逼近 (approximation)，因此一定存在著模型誤設。所以如 Marcellino, Stock and Watson (2006) 所言，存在模型誤設時使用直接預測會有比較穩健的結果。

- (二) 我們同意完全子集合迴歸和 Jackknife 模型平均法不是機器學習的方法，故在期末報告已將之刪去，研究計畫專注在機器學習方法相關模型。
- (三) 本計畫採用之因子模型分為主成分分析法以及目標因子方法。在主成分分析法部分，本研究考慮變數眾多，由於 8 個因子已捕捉所有變數 99% 的共同變動，因此我們選擇以 8 個因子進行後續相關分析。在目標因子方法部分，由於第一階段先以最小平方法估計並檢定顯著的變數為目標變數，故第二階段直接以全部的變數個數為因子個數。
- (四) 同第 (二) 題回覆。
- (五) 研究計畫已使用 13 個機器學習模型，且由於研究時程限制，故尚未運用之其他機器模型在期末報告一併刪除。

二、資料處理的建議

- (一) 期末報告統一資料起始日為 2000 年 1 月。另外，我們依您建議考慮有無包含 COVID 疫情期間作為穩健性測試，實證結果顯示本研究結果具穩健性，由於篇幅關係，我們將之列在期末報告附錄 D。
- (二) 針對遺漏值問題，由於期末報告統一樣本起始日為 2000 年 1 月，故僅少數變數有缺漏值狀況出現 (包括本國銀行逾放比率、五年期公司債、消費者信心指數)，而這些變數遺漏值之前一筆資料與後一筆資料數值差異不大，故僅使用前一筆資料替代遺漏值。

三、模型比較的建議

- (一) 由於 out-of-sample R2 statistics (oos-R2) 所呈現模型預測表現優劣之排序與使用 RMSE 是一樣的，而 oos-R2 也未在通膨預測中廣泛地被使用，例如: Medeiros et. al. (2021)、Stock and Watson (1999)，以及 Stock and Watson (2008) 等皆未使用 oos-R2 比較預測表現，故本研究計畫並未考慮此指標。
- (二) 我們同意以假設檢定判斷模型差異是相當好的作法，惟因目前考慮眾多機器學習模型，受限於時間關係，期末報告並未進一步考慮如 Diebold and Mariano (2002) 或是 Giacomini and White (2006) 檢定，我們將相關的研究限制說明於第六章，未來建議委託單位可以進一步考慮此延伸。
- (三) 感謝評論人意見，我們已在期末報告起始訓練樣本期間、視窗長度與樣本外預測區間等，詳見期末報告附錄 D 表 22。

四、其他建議

- (一) 尚未運用之其他機器模型在期末報告已刪除，故期末報告無 $\Phi_{t,m}$ 。
- (二) 感謝建議，由於 AR(p) 與 ARMA(p,q) 比 AR(1) 與 ARMA(1,1) 更有彈性，限於篇幅關係，故期末報告刪去 AR(1) 與 ARMA(1,1) 模型。

- (三) 期末報告已刪除完全子集合迴歸和 Jackknife 模型平均法。

貳、央行同仁發言意見與報告人答覆

金檢處同仁評論意見：

一、建議事項

- (一) P.26 3.4.2 隨機森林一節提及變數選取數目可依預測模型而有所不同，如迴歸模型常用 $\lfloor k/3 \rfloor$ ，分類模型常用 $\lfloor \sqrt{k} \rfloor$ 。請問 k 及符號 $\lfloor \cdot \rfloor$ 之意涵。
- (二) 本研究以 RMSE、MAE、MAPE 及 MAD 等 4 種評估指標，作為比較模型預測表現之衡量指標。請問不同指標數值間是否具比較性？數值越低是否表示模型越佳？似可於附表加註說明。
- (三) 本研究簡化、壓縮或提取大數據中有價值的信息，以便更有效地進行分析及建模，似可提供變數重要性排列，以利讀者瞭解各變數對預測貢獻程度。
- (四) 似可增加菲利浦曲線模型，俾進一步確認以總體理論模型為預測模型之預測能力。

二、文字建議

- (一) P.22 「…然後使用最大概似乎 估計法估計參數…」，似為「…然後使用最大概似 估計法估計參數…」。

- (二) P.30「若此混合方法與單純使用套袋法決策樹，不結合線性迴歸的結果相近的話，表示模型是否為線性並不重要」，似為「若此混合方法與單純使用套袋法決策樹 (不結合線性迴歸) 的結果相近的話，表示模型是否為線性並不重要」。
- (三) P.30「…但如何一來 在計算上將十分複雜」，應修正為「…但如何一來在計算上將十分複雜」。
- (四) P.30「…對角線在本次有被挑選到變數的位置是 1，沒有被挑選到則是 0，沒有被挑選到的變數參數是 0」，應修正為「…對角線在本次有被挑選到變數的位置是 1，沒有被挑選到則是 0，沒有被挑選到的變數參數是 θ 」。
- (五) P.31「Jackknife 模型平均法由 Hansen and Racine (2012) and Zhang, Wan, and Zou (2013)發 提出」，應修正為「Jackknife 模型平均法由 Hansen and Racine (2012) and及 Zhang, Wan, and Zou (2013) 發提出」。
- (六) P.33 及 P.34 有關研究將變數分成 11 大類，包括：景氣指標、就業、消費、貨幣金融、股票市場、債□市場、房地產市場、大宗資產、國際收支與進出口、海外因素及情緒指標。其中大宗資產似為大宗物資。

答覆意見：

一、建議事項

- (一) 本研究中 k 為解釋變數個數，而 $\lfloor \cdot \rfloor$ 則為高斯符號，表示小於等於括號內數字的最大整數。我們已將原先段落改寫，加入符號說明，見第 3.4.2 節。
- (二) 關於預測指標，以單一指標來看，由模型預測誤差所計算之指標數值越低，表示模型預測能力較佳，預測表現越好，但由於計算標準不同，故不同指標之間無法相互比較。相關說明已列於期末報告第 4.4 節，P.39。
- (三) 期末報告補充不同機器學習方法選擇的不同的預測變數。我們在報告中也討論在短中長期預測之下，最常被選出的總體與金融變數之實證意涵，詳見期末報告第 5.1 至 5.3 節與表 3，表 6-9 與表 12-15，冀望能大幅提升此計畫的學術與實用價值。
- (四) 依據本研究文獻回顧所述，許多文獻均指出基於菲利浦曲線的傳統總體經濟理論模型，其通膨預測表現易受樣本期間影響，較不穩定。本研究的總體金融大數據資料中已包含失業率等菲利浦曲線模型變數，故未特別增加菲利浦曲線模型。

二、文字建議

- (一) 感謝提供第 (一)-(五) 點文字建議，期末報告已依建議在相應章節修正。

- (二) 大宗資產 (Commodity) 係指大宗商品市場交易流通的資產，包括農產品類、原材料類、能源類及金屬類等項目，本計畫已依貴處建議，將大宗資產改為大宗物資。

經研處同仁評論意見：

一、實證研究之變數選擇與處理、實證結果

(一) 變數選擇與處理

1. 文中採用多種預測方法，建議可以對各方法超參數的設定做更清楚的說明。例如，LASSO 模型家族的 λ ；套袋法的 B (幾個拔靴法樣本)；隨機森林的 p (每個分岔選幾個變數) 與 B (幾個拔靴法樣本)；梯度提升法中的 v (模型的學習速度)；完全子集合迴歸的 k^* 與 k' ；在完全子集合迴歸中，作者如何決定那些變數為重要的解釋變數 k' ；交叉驗證 (cross-validation) 是採用哪一種方法 (如 k-fold cross-validation 的 k 數值為何)。
2. 由於本行與外界多關心原始未季調的數值，建議作者可以用未季調的 CPI 年增率作為預測目標。此外，本行亦有針對核心 CPI 年增率 (同樣是未季調數值) 進行預測，建議作者也可用相同的預測方法對核心 CPI 進行預測。
3. Medeiros et al. (2021) 所採用的變數集合中包含了不同的物價指數，如服務類消費者物價指數，以及不同的生產者物價指數，而本計畫使用的相對少，請補充說明。
4. 文章選取許多可能影響台灣通貨膨脹率之潛在變數，其

中包含與台灣貿易關係密切之美國、中國、日本及南韓。但在利率變數部分，美國除了有 5-10 年及 1-10 年之利差變數外，還有 10 年期公債殖利率、2 年期公債殖利率、3 個月 t-bill 等資料。日本及南韓則僅 10 年期公債殖利率及一個短率。中國部分則似乎未放入殖利率變數，請問考量因素為何？

5. P.34、P.57 提及躉售物價總指數年增率，惟主計總處於 2023 年 1 月起停編躉售物價指數，故資料僅至 2022 年 12 月，若後續要以本計畫的方法進行預測，是否有影響？建議可改採用生產者物價指數 PPI，其中 2021 年以前的 PPI 指數係採用國產品 WPI 指數 (其定義與 PPI 一致)，並與 2021 年後的 PPI 資料進行銜接。
6. P.35 提及選用商業本票利率此一變數，對照附錄表 7 的資料，文章應是採用商業本票 31-90 天期次級市場利率，建議寫明確。
7. P.36 引用的新加坡大學信用風險評等系統的「企業脆弱性指數」是哪一種？簡單平均？市值平均？CVI 尾部？
8. P.36 提及出口或進口「物價值指數」是否指的是「單位價值指數」？
9. P.38 非定態變數，對變數取一階差分，是否先取對數？抑或有些取對數有些則沒有？

(二) 實證結果

1. 本文的樣本期間？樣本內與樣本外期間為何？滾動視窗 W 的長度？滾動視窗的長度是否會影響實證結果？是否有做針對滾動視窗的長度進行 robustness test？此外，疫情期間如 2020 年後至 2023 年，通膨率先歷經大幅下降而接續上升的情形，14 種預測模型中，在這特殊期間內，是否有哪個模型預測表現較佳呢？
2. 時間序列模型進行預測時多採遞迴式或滾動視窗預測，因此，若做較長期預測會因缺乏新資訊而預測值趨於平坦（極端情況即為 RW 假設），本文的機器學習模型也會有類似情況嗎？對未來採用直接預測而非遞迴式預測是否為預測績效改善的原因之一？
3. 在模型預測誤差方面使用 RMSE、MAE、MAPE、MAD 等多種統計衡量預測績效，由於不同評斷標準會選擇不同的最佳模型，可否再進一步敘述 RMSE、MAE、MAPE、MAD 個別使用上的優缺點，才能更清楚知道不同模型預測績效的優劣。此外，也建議期末可進一步統計檢定不同模型的 RMSE、MAE、MAPE、MAD 差異是否顯著，以支持結論。
4. 目前的結果顯示隨機森林在中長期預測表現最佳，可否根據隨機森林的結果，補充說明哪些變數在各個預測期間下的重要性最高。
5. 文中考慮 92 個總體經濟及貨幣金融變數，若未來使用文中的方法進行預測，需要逐月更新這些變數，作者是否

可以提供下載及處理 (季調、轉換頻率) 這些變數的程式碼，以方便本行維護資料。

6. 本文機器學習模型所採的變數眾多，可能不利於未來實際預測的應用，因隨實際預測期間的拉長 (如對 2024 年 CPI 年增率的預測)，如何對模型中眾多解釋變數的設定，可能會提高執行預測困難度，文章中可否對此加以補充說明。

二、後續期末報告之建議

- (一) 期末報告可否針對預測能力較好的模型，進一步了解那些變數是相對重要的，如 Medeiros et al. (2021) 以文字雲呈現方式，以及切割樣本內的期間，進行穩健性檢定。
- (二) 近年受 COVID-19 疫情、全球供應鏈瓶頸、俄烏戰爭等非預期因素影響，台灣通膨自 2020 年的 -0.23% ，之後開始快速攀升至 2022 年的 2.95% ，提高通膨率預測的困難度。文中採用多種機器學習模型，不知研究團隊是否可以這段期間當作例子，實際採機器學習來預測自 2020 年以來之通膨預測值？並與實際值比較。
- (三) 建議期末報告能對未來技術運用方面提供最終看法，並說明政策意涵或建議。

三、文章內容文字修正或加強說明

- (一) 第二章研究方法討論多種方法，但在後續的預測上並未應用所有的方法，若有些方法在後續未使用，建議可以刪除該方法的說明 (如動態因子模型)。

- (二) 文獻回顧的部分，以國外文獻為主，不曉得是否可增加針對台灣通膨率預測的相關文獻整理，以突顯此計畫運用大數據資料分析預測台灣通膨率之貢獻。
- (三) 附錄 A 中提及工業生產指數、M1B 年增率、M2 年增率等變數應該是引自 Stock and Watson (1999b)？建議標示清楚。
- (四) 附錄圖 4 樣本外預測結果 ($h = 1$) 中，(6) 機器學習模型縱軸刻度長度明顯與其他圖形不一樣，較難比較，建議統一。附錄圖 6、圖 8 亦有相同的問題。此外，圖形縱軸與橫軸年分數值太小，建議放大。
- (五) 文字建議統一，如 P.3 與 P.4 出現菲利浦曲線與菲力浦曲線。
- (六) 建議字體可以放大一點，段落格式調整一致，以便閱讀。

答覆意見：

一、實證研究之變數選擇與處理、實證結果

(一) 變數選擇與處理

1. 感謝評論意見，我們已在期末報告詳述起始訓練樣本期間、視窗長度與樣本外預測區間等，詳見期末報告第 4.1 節。此外，收縮法 λ 、 γ 的決定，拔靴法或交叉驗證的抽樣方式等設定及討論也補充於相關章節，其中 LASSO 模型家族 λ 、 γ 的決定及交叉驗證說明見第 3.2.2 節 (P.18) 至第 3.2.4 節 (P.19)。另，非線性機器學習方

法以及組合方法等，其區塊拔靴抽樣法的抽樣樣本數為 500，區塊長度設定為 12，套袋樹和隨機森林方法皆設定最大節點數量為 20。

2. 我們依貴處建議考慮多種穩健性測試，包括以未季調之 CPI 年增率和未季調之核心 CPI 年增率作為預測目標。實證結果顯示本研究結果具穩健性，由於篇幅關係，我們將之列在期末報告附錄 D。
3. 報告內說明因研究時間有限，且不同物價指數組成細項之探討非屬此計畫研究範疇，故未考慮這些變數，未來委託單位或可進一步考慮此延伸。
4. 由台灣對國外投資金額比例來看，美國皆高於其他三者，故納入較多美國相關變數。
5. 鑑於主計總處停編 WPI 指數將造成後續資料更新困難，本計畫依建議以與 PPI 範圍相近的「國產與進口品物價總指數」與 2021 年 1 月起公布的 PPI 資料進行銜接，見期末報告 P.32。
6. 已參考貴處建議並於期末報告修正，見第 4.2 節，P.33。
7. 本研究係採市值平均之企業脆弱性指數，相關文字修正請見期末報告第 4.2 節，P.35。
8. 本研究所指為「物價值指數」，此處係承續主計總處公布時所用名稱如下：

資料來源：財政部-貿易統計資料查詢-一般貿易制度-總指數-進/出口物價值指數。

9. 本計畫皆未將變數取對數，僅以差分處理非定態變數。

(二) 實證結果

1. 期末報告已補充起始訓練樣本期間、視窗長度與樣本外預測區間等，詳見期末報告第 4.1 節。另外，我們依貴處建議，以 2020 年 1 月至 2023 年 12 月疫情期間進行穩健性測試，實證結果列於附錄 D。
2. 機器學習方法之預測模型為直接預測，故不會出現如時間序列模型之預測值趨於平坦之問題。對未來採用直接預測而非遞迴式預測的確為預測績效改善的原因之一，在期末報告中，短中長期不同預測模型之預測值圖形可以清楚佐證。
3. 我們在期末報告詳述 RMSE、MAE、MAD 之優缺點，惟因目前考慮眾多機器學習模型，受限於時間關係，期末報告並未進一步考慮如 Diebold and Mariano (2002) 或是 Giacomini and White (2006) 檢定，我們將相關的研究限制說明於第六章結論與討論，未來建議委託單位可以進一步考慮此延伸計畫。
4. 感謝評論建議，期末報告已補充將不同機器學習方法選擇的不同的預測變數列出。我們在報告中也討論在短中長期預測之下，最常被選出的總體與金融變數之實證意

涵，詳見期末報告第 5.1 至 5.3 節與表 3，表 6-9 與表 12-15，冀望能大幅提升此計畫的學術與實用價值。

5. 大數據資料總體金融變數之處理，以及期末報告所有預測模型之程式碼和相關檔案皆會依約轉交貴行進行未來分析。
6. 本計畫之目的為利用大數據資料預測通膨，因此計畫採用之變數眾多，我們同意變數眾多，可能不利於未來實際預測的應用，並可能會提高執行預測困難度，期末報告將研究限制補充於第六章。

二、後續期末報告之建議

- (一) 詳見建議 (二) 第 4 點之回應。
- (二) 詳見建議 (二) 第 1 點之回應。
- (三) 感謝建議，相關討論請見期末報告第六章之討論。

三、文章內容文字修正或加強說明

- (一) 期末報告已將未應用之研究方法相關章節刪去。
- (二) 感謝貴處意見，我們在期末報告新增一節回顧台灣通膨率相關文獻，同時也在前言說明預測台灣通膨率之文獻貢獻，希望能突顯此計畫運用大數據資料分析預測台灣通膨率之貢獻。
- (三) 感謝指正，惟考量篇幅關係，期末報告將引用之文獻一欄刪除。

(四) 感謝提供第(四)-(六)點文字建議，期末報告已依建議在相應章節修正。

F 附錄：期末報告意見回覆

壹、評論人意見與報告人答覆

徐之強教授評論意見：

- 一、本計畫所要預測的變數是否為經季節調整的 CPI 年增率？宜在 4.1 節說明清楚。
- 二、期末報告 4.1 節並未說明本研究的樣本外預測的起始點與預測期間，或對應不同的 h 下，共產生多少個點預測？
- 三、本計畫最主要貢獻是將不同預測期間的重要預測因子表列出來。研究團隊是否能將這些預測因子予以歸納整理，例如區分國際物價，景氣，國內金融，銷售，就業，...，等不同市場之影響，以提升這些重要預測變數的經濟意涵說明。
- 四、由於總體經濟變數具有很強的持續性 (persistence)，期末報告並未說明是否包含各個總體變數的落後項？落後期數為多少？以及被挑選出來的重要預測因子是落後幾期？
- 五、若要預測 2024 年 4 月的台灣通貨膨脹率，請問研究團隊如何克服季資料落後發布的問題？如美、中、台、日等 3 月的 GDP 成長率為何？
- 六、p.26，第二段文字敘述不通順。債「券」錯字。

答覆意見：

- 一、本計畫之預測變數為經季節調整的 CPI 年增率，已於期末報告修正本第 29 頁第一段補充。
- 二、本計畫採用的資料期間為 2000 年 3 月至 2023 年 12 月，所以當使用滾動視窗法並設定視窗長度為 120 時，第一個視窗使用 2000 年 3 月至 2010 年 2 月訓練模型，以 $h=1$ 為例，此時預測 2010 年 3 月的通貨膨脹率，如此滾動視窗之下，將會有 166 個預測點。補充說明請見期末報告修正本第 38 頁第一段。
- 三、關於不同市場之重要預測因子，本研究除以表格列出不同預測模型及期數之重要變數外，我們也在相關章節簡要說明重要變數之經濟意涵，詳見期末報告修正本關於表 3，表 6-9，以及表 12-15 之說明。
- 四、除 CPI 年增率外，本研究並未使用其他總體變數的落後項。
- 五、本研究並非即時預測，因此未考慮資料取得頻率問題。
- 六、感謝指正，已於期末報告修正本全文修正。

劉祝安研究員評論意見：

- 一、第 17-20 頁中有關 LASSO 模型家族的參數設定，所有的 λ 、 λ_1 、 λ_2 是否都是透過交叉驗證方式選取？
- 二、第 26 頁的組合式預測方法先採用 LASSO 或是 EN 方法

挑選變數，請說明未採用 Adaptive LASSO 或 Adaptive EN 的原因。

三、第 38 頁的表 1:

- 時間序列模型和 LASSO 模型家族的模型設定是否包含截距項？
- 關於非線性機器學習模型的兩個方法，建議模型設定採用不同的參數符號來區分。
- 請說明組合模型中的 k^* 符號。

四、第 43 頁的圖 3：建議 label 字體可以放大一點。

五、第 45 頁的表 3：請說明如何定義重要變數，以及重要變數的排序是如何決定。

六、第 58 頁提到「綜觀所有實證結果，時間序列模型僅在向前一期預測表現最佳」，建議修改成「... 表現較佳」或「... 表現尚可」。

七、第 84 頁的 D2：給定視窗長度為 $W = 120$ ，請說明如何使用 2020 年至 2023 年的樣本期間進行穩健性分析。

八、債 市場應改成債券市場。

九、第 20 頁中的 w_j 應改成 w_i

十、第 39 頁中的 e_i 應改成 \hat{e}_i 。

答覆意見：

- 一、所有的 λ 、 λ_1 、 λ_2 皆是以交叉驗證方式選取，已於期末報告修正本第 20 頁補充說明。
- 二、本研究之組合式預測模型先採用 LASSO，並未採取 Adaptive LASSO 或 Adaptive EN 方法，係因 LASSO 方法較為普及，亦可考慮以 Adaptive LASSO 方法為未來研究之參考。
- 三、本文之預測模型皆有包含截距項，已於期末報告修正本表 1 更新；另外，兩方法已採不同參數區分；組合模型之 k^* 已修改，見期末報告修正本第 39 頁表 1。
- 四、感謝建議，已於結案報告內調整，見期末報告修正本相關圖形。
- 五、本研究使用之套袋樹和隨機森林方法之重要變數定義係直接採用 R 程式語言之 random Forest 套件定義。在 LASSO 家族模型中，重要變數則是以 t 檢定判定。
- 六、感謝建議，已於期末報告修正本修正，見第 58 頁。
- 七、給定視窗長度為 $W = 120$ ，2020 年至 2023 年的樣本期間之穩健性分析是以 2010 年 1 月至 2019 年 12 月為第一個滾動視窗，訓練模型並預測 2020 年 1 月之通膨率；再以 2010 年 1 月至 2020 年 1 月為第二個滾動視窗，預測 2020 年 2 月之通膨率，依此類推，直到預測 2023 年 12 月之通膨率。
- 八、感謝提供第八至十點文字建議，已於期末報告修正本對

應處修正，見第 2、20、30、32、39 頁。

貳、央行同仁發言意見與報告人答覆

經研處同仁評論意見：

- 一、建議期末報告前面應有全文摘要。
- 二、本文主要討論的通膨率係指「季調後 CPI」，直到 P.58 才看到附錄 D 有討論不同 CPI 衡量 (如未季調 CPI 與核心 CPI) 的實證結果，建議 P.40 實證結果與討論乙節一開始即說明本文以季調後 CPI 通膨率討論為主，加深讀者印象。
- 三、P.33 第 5 行商業本票 31-90 天期次級市場利率 (經研處-變數選擇與處理-問題 6)→ 應刪除 (經研處-變數選擇與處理-問題 6)。
- 四、P.34 第 8 行 CRB 期貨商品指數衡量食物類「資產」價格 → 宜刪除「資產」。

答覆意見：

- 一、感謝建議，已於期末報告修正本補充摘要。
- 二、感謝建議，預測變數為經季節調整的 CPI 年增率，已於期末報告修正本第 29 頁第一段補充。
- 三、感謝建議，第三至四點已於期末報告修正本刪除，見第 33、34 頁。

經研處計量科同仁評論意見：

一、實證研究之變數選擇與處理、實證結果

(一) 變數選擇與處理

1. 期中報告意見回覆中提及於 4.1 節詳述起始訓練樣本期間、視窗長度與樣本外預測期間，惟內文並未提及相關內容，僅在 P.38 提及視窗 $W = 120$ 。
2. P.34 提及使用資料出口物價值指數及進口物價值指數，而綜合期中報告回覆意見內容與 P.72 資料來源敘述，應為貿易指數中的「價值指數-出口」與「價值指數-進口」，建議再確認。
3. P.36 提及資料遺漏之處理問題，原則上以前一個月資料 (t-1) 替補。若是連續 2 個月資料有遺漏，研究團隊是否以 (t-2) 之資料填補？以此類推。

(二) 實證結果

1. P.40 第二段提及「RMSE 為 0.372，明顯小於時間序列模型的預測表現」，建議文字修改為「RMSE 為 0.372，預測誤差最小，明顯優於時間序列模型的預測表現」以避免誤解。
2. 期末報告中列出不同機器學習方法選擇的不同預測變數，以及短中長期預測下，最常選出的總體與金融變數之實證意涵，未來研究團隊將會移交相關預測模型的程式碼與相關檔案給央行。想請教根據研究團隊此次的經驗，

若未來本行嘗試將相關機器學習方法加入其他總體金融變數於模型中，模型設定上是否容易處理，且使用大量總體金融變數，不曉得所運算上所花費的時間？以及為了進行運算，電腦設備的建議。

3. 由於機器學習重視統計表現績效勝於經濟理論關係，以致結果往往不易解釋。例如 $h=3$ 之下，LASSO 家族選取的重要國際變數包含美國聯邦資金利率，但其與台灣通膨之間的關係較為間接。雖然此為機器學習模型使用之限制，但如果可以，是否能多盡量闡述機器學習選取的最佳變數隱含的直接或間接經濟意涵？如果無法都有合理經濟解釋，或可列為研究限制之一。
4. 除 $h = 1$ 外， $h = 3, 6, 9, 12, 18, 24, 30, 36$ 之通膨率預測結果（表 2、4 5、10 11）幾乎皆顯示隨機森林具有較佳且穩定的預測績效。然而，附錄 D 之穩健性測試中，不同被預測變數、樣本期間與視窗長度下，雖隨機森林仍具有相當不錯的預測績效，惟 adaptive LASSO 或是某些組合模型亦有良好的預測績效。建議或可於結論加入有關「可能較無一種機器學習在所有方面都是最好的，研究者須不斷嘗試」等研究限制。
5. 請問為何期末報告增加 4 個組合模型，將期中報告的線性套袋樹法與線性隨機森林改為非線性，以及刪除 CSR 與 Jackknife 方法？
6. 附錄 D 雖有嘗試於 2020 年 1 月至 2023 年 12 月疫情期

間進行穩健性測試，惟報告列出 RMSE、MAE、MAD 之結果。而 RMSE、MAE、MAD 在評比預測誤差 (實際值與預測值之差距) 是否較小，但有可能並未捕捉到這段期間通膨前期低但後來急遽上升的動態變化，若研究團隊時間許可，建議可將這段期間機器學習預測之通膨率預測值列出以利讀者了解。

二、文章內容文字修正或加強說明

- (一) 重要變數中美國 10 年公債採阿拉伯數字「10」，但台灣十年公債採國字「十」，建議調整一致。
- (二) 文中出現「債券市場」呈現亂碼「債 市場」，建議修正，如 P.2 倒數第 5 行、P.30 第 5 行、P.32 倒數第 10 行與第 2 行。
- (三) P.6 段落開頭未縮行，其他頁數有縮行，格式建議調整一致。
- (四) P.17 第 1 段倒數第 2 行應為貝「氏」資訊準則。
- (五) P.32 第 2 段倒數第 1 行，計算方式請參見附錄 B 應為附錄 A。
- (六) P.38 第 1 行 $h = (1, 3, 6, 9, 12, 18, 24)$ ，應為 $h = (1, 3, 6, 9, 12, 18, 24, 30, 36)$ 。

答覆意見：

一、實證研究之變數選擇與處理、實證結果

(一) 變數選擇與處理

1. 已補充說明，見期末報告修正本第 38 頁第一段。
2. 期中報告之「進口物價值指數」及「出口物價值指數」，即貿易指數中的「價值指數-出口」與「價值指數-進口」，已於期末報告修正本內修正，見第 34、37、72、74 頁。
3. 若有連續遺漏值的情況，皆以 t-1 期的資料替代。

(二) 實證結果

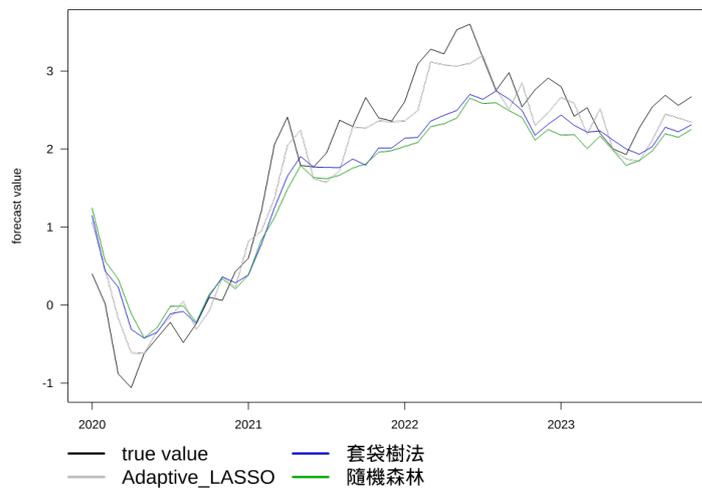
1. 感謝建議，已於期末報告修正本修正，見第 40 頁。
2. 若金融變數為月資料，可直接加入模型計算。本研究非混合頻率模型，故若變數非月頻資料，則無法簡單地融入模型中，需要另外處理成月頻資料。另外，計算時間要考慮電腦性能差異，若採用中等配置電腦 (8 核心 16 線程)，單個向前 h 期預測大約費時 20 分鐘。
3. 關於不同市場之重要預測因子，本研究除以表格列出不同預測模型及期數之重要變數外，我們也在相關章節簡要說明重要變數之經濟意涵，詳見期末報告修正本關於表 3，表 6-9，以及表 12-15 之說明。此外，我們也將此列為研究限制，見期末報告修正本修正結論，見第 64 頁。
4. 感謝建議，已於期末報告修正本補充，見第 63 頁。
5. 因期中報告時，評論人建議刪去非屬機器學習方法，故期末報告刪除 CSR 與 Jackknife 方法。

6. 2020 年 1 月至 2023 年 12 月疫情期間，使用機器學習方法預測之台灣通膨率預測值如下表：

| 時間 | 真實值 | AdaLASSO | 套袋樹法 | 隨機森林 |
|-----------|-------|----------|--------|--------|
| 2020/1/1 | 0.4 | 1.065 | 1.149 | 1.246 |
| 2020/2/1 | 0.02 | 0.46 | 0.436 | 0.564 |
| 2020/3/1 | -0.88 | -0.167 | 0.231 | 0.334 |
| 2020/4/1 | -1.06 | -0.61 | -0.31 | -0.109 |
| 2020/5/1 | -0.62 | -0.621 | -0.424 | -0.422 |
| 2020/6/1 | -0.42 | -0.331 | -0.347 | -0.286 |
| 2020/7/1 | -0.22 | -0.158 | -0.112 | -0.017 |
| 2020/8/1 | -0.48 | 0.052 | -0.082 | -0.011 |
| 2020/9/1 | -0.24 | -0.312 | -0.236 | -0.22 |
| 2020/10/1 | 0.1 | -0.073 | 0.116 | 0.141 |
| 2020/11/1 | 0.06 | 0.363 | 0.362 | 0.339 |
| 2020/12/1 | 0.43 | 0.226 | 0.285 | 0.207 |
| 2021/1/1 | 0.6 | 0.817 | 0.386 | 0.386 |
| 2021/2/1 | 1.21 | 0.95 | 0.782 | 0.838 |
| 2021/3/1 | 2.06 | 1.371 | 1.247 | 1.122 |
| 2021/4/1 | 2.41 | 2.047 | 1.654 | 1.486 |
| 2021/5/1 | 1.79 | 2.242 | 1.904 | 1.788 |
| 2021/6/1 | 1.77 | 1.618 | 1.77 | 1.634 |
| 2021/7/1 | 1.95 | 1.576 | 1.765 | 1.621 |
| 2021/8/1 | 2.37 | 1.725 | 1.762 | 1.665 |
| 2021/9/1 | 2.29 | 2.279 | 1.873 | 1.756 |
| 2021/10/1 | 2.66 | 2.267 | 1.793 | 1.81 |
| 2021/11/1 | 2.4 | 2.361 | 2.015 | 1.958 |
| 2021/12/1 | 2.36 | 2.349 | 2.014 | 1.981 |
| 2022/1/1 | 2.61 | 2.361 | 2.139 | 2.033 |
| 2022/2/1 | 3.09 | 2.494 | 2.151 | 2.085 |
| 2022/3/1 | 3.28 | 3.118 | 2.359 | 2.288 |
| 2022/4/1 | 3.22 | 3.079 | 2.431 | 2.324 |
| 2022/5/1 | 3.53 | 3.065 | 2.495 | 2.398 |
| 2022/6/1 | 3.6 | 3.097 | 2.699 | 2.653 |
| 2022/7/1 | 3.17 | 3.202 | 2.638 | 2.583 |
| 2022/8/1 | 2.75 | 2.774 | 2.745 | 2.593 |
| 2022/9/1 | 2.98 | 2.508 | 2.641 | 2.493 |
| 2022/10/1 | 2.54 | 2.848 | 2.495 | 2.405 |
| 2022/11/1 | 2.76 | 2.3 | 2.177 | 2.115 |
| 2022/12/1 | 2.91 | 2.467 | 2.318 | 2.251 |
| 2023/1/1 | 2.8 | 2.663 | 2.436 | 2.178 |
| 2023/2/1 | 2.42 | 2.588 | 2.304 | 2.187 |
| 2023/3/1 | 2.53 | 2.193 | 2.217 | 2.006 |
| 2023/4/1 | 2.2 | 2.517 | 2.233 | 2.166 |
| 2023/5/1 | 2 | 1.982 | 2.114 | 1.983 |
| 2023/6/1 | 1.93 | 1.874 | 2.001 | 1.791 |
| 2023/7/1 | 2.27 | 1.84 | 1.934 | 1.853 |
| 2023/8/1 | 2.54 | 2.117 | 2.03 | 1.976 |
| 2023/9/1 | 2.69 | 2.448 | 2.279 | 2.198 |
| 2023/10/1 | 2.56 | 2.398 | 2.221 | 2.15 |

| | | | | |
|-----------|------|-------|-------|-------|
| 2023/11/1 | 2.67 | 2.343 | 2.311 | 2.252 |
|-----------|------|-------|-------|-------|

我們將上表數值畫出走勢圖如下，可以由圖中發現 Adaptive LASSO 方法較能反映這段期間通膨前期低但後來急遽上升的動態變化。



二、文章內容文字修正或加強說明

- (一) 感謝第一、二、四、五點建議，已於期末報告修正本全文修正公債期別以國字呈現，並依建議於第 2、17、30、32、38 頁修正。
- (二) 期末報告修正本全文章節第一段皆未縮行，自第二段起則皆有縮行，全文格式已維持一致。