

# 全球主要央行運用人工智慧(AI)監測 總體經濟金融情勢之作法

中央銀行金融業務檢查處

曾筱婷、李佳芸\*

中華民國 114 年 12 月

\* 本文所有論點皆屬作者意見，不代表中央銀行及作者服務單位之立場。



## 摘要

近年來，全球經濟及金融環境變化快速，如何在既有的申報資料基礎下，進一步使用新聞報導、政策文件、市場調查等非結構化新興資料，提升總體經濟與金融指標分析及預測之精準度，或強化風險預警機制效能，係各國監理機關關注的議題。鑑此，具備資料處理與運算優勢的人工智慧(artificial intelligence, AI)技術，已成為可行的因應方案之一。

AI 技術屬新興技術，在導入時應留意其對央行可能帶來之風險，例如可解釋性不足、個資保護及營運風險等，因此，瞭解各國央行導入 AI 之治理架構與實務流程，對本行在規劃 AI 應用策略時具有高度參考價值。在監理運用方面，本報告將近年全球主要央行 AI 相關研究報告，依其使用目的區分為「改善資料品質及資訊蒐集」、「總體經濟及金融分析」、「支援貨幣政策與政策傳遞研究」、「個體審慎監理」及「總體審慎監理」等 5 大類，並聚焦於前揭研究報告中，與本行權責範圍較相關之代表性應用案例，作進一步探討。在 AI 技術方面，目前主要央行對於 AI 之應用仍以模型結構相對單純的機器學習技術為主，僅少數嘗試使用深度學習及生成式 AI，主要係因模型複雜度越高，越可能面臨可解釋性不足的問題，且若資料量體不夠大，使用高複雜度的模型反而容易出現過度學習(overfitting)之情況。

AI 技術能夠輔助央行處理龐大、高顆粒度及多型態資料，並可捕捉資料的非線性關係與異質性，為央行帶來快速處理資料、辨識新興風險與資料異常，以及即時預測經濟走勢等效益。然而，該技術應用亦衍生新的挑戰，例如資料雜訊、模型偏誤與過度學習風險、可解釋性與因果推論能力不足、技術人才缺乏、成本高昂與外部供應商依賴等。因此，本報告建議本行應建立以人為本的 AI 協作模式，採務實漸進方式導入 AI 技術，並強化 AI 相關風險之控管，以確保在風險可控下運用 AI。此外，加強跨央行合作及分享導入案例，亦有助於汲取國際實務經驗，作為本行規劃 AI 應用之參考基礎。



## 目 次

摘 要.....	i
壹、前言.....	1
貳、人工智慧(AI)於央行業務之應用與技術發展 .....	2
一、AI 於央行業務之應用 .....	2
二、全球主要央行 AI 技術應用概覽 .....	3
參、全球主要央行運用 AI 之研究案例 .....	8
一、改善資料品質及資訊蒐集 .....	8
二、總體經濟與金融分析 .....	11
三、支援貨幣政策與政策傳遞研究 .....	16
四、風險評估及預警系統 .....	20
肆、央行業務應用 AI 之效益與挑戰 .....	32
一、AI 對央行之效益 .....	32
二、AI 對央行之挑戰 .....	34
伍、結論與建議.....	37
一、結論 .....	37
二、建議 .....	39
附錄、全球主要央行運用 AI 之研究案例 .....	41
參考資料.....	52

## 圖目錄

圖 1：ECB 處理 MMSR 資料流程.....	10
圖 2：GDP 成長率走勢 .....	12
圖 3：供應鏈瓶頸衝擊下的通膨反應函數 .....	14
圖 4：2003 年至 2012 年間 FOMC 會議紀錄關注主題占比.....	17
圖 5：FOMC 會議對「通膨」議題之關注程度變化.....	18
圖 6：FOMC 會議對「金融發展」及「金融穩定」議題之關注程度變化....	18
圖 7：各模型相較基準模型之風險性資產密度變化 .....	23
圖 8：ECB 之 LSIs 決策樹監理模型 .....	24
圖 9：非金融企業部門財務狀況惡化指數衝擊對各項總體經濟變數影響.....	27
圖 10：不同 AI 模型中各經濟變數之危機預測貢獻程度 .....	29
圖 11：Fed 處理 OECD 報告等文字資料程序.....	30

## 表目錄

表 1：各項演算法之異常值定義及特點 .....	10
表 2：Fed 報告使用之文字資料 .....	31
表 3：AI 對央行之效益與挑戰 .....	35

## 壹、前言

近年來，全球經濟及金融環境變化快速，各國央行亟須即時監測總體經濟變化，且迅速因應情勢採取措施，以維護金融穩定。另一方面，隨網路時代推動資料量與資料型態呈爆炸式成長，資訊傳遞速度亦大幅提升，使金融市場波動更為頻繁且迅速，影響各項金融指標走勢的因素亦日益多元與複雜。如何在既有的申報資料基礎下，進一步使用新聞報導、政策文件、市場調查等非結構化新興資料，提升總體經濟與金融指標分析及預測之精準度，或強化風險預警機制效能，係各國監理機關關注的議題。鑑此，具備資料處理與運算優勢的人工智慧(artificial intelligence, AI)技術，已成為可行的因應方案之一。

一般而言，AI 泛指由電腦或機器執行擬人智慧的科技，近年來國際金融組織或各國監理機關陸續發布 AI 相關報告，並闡釋 AI 之意涵，例如金融穩定委員會(Financial Stability Board, FSB)將 AI 定義為「運用電腦系統來執行傳統上需要人類智慧完成之任務」，IOSCO 定義 AI 為「讓電腦模仿人類決策以解決問題之技術，其任務包括學習、推理、計劃、感知、語言理解等」，我國金管會則將 AI 系統定義為「透過大量資料學習，利用機器學習或相關建立模型之演算法，進行感知、預測、決策、規劃、推理、溝通等模仿人類學習、思考及反應模式之系統」<sup>1</sup>。AI 具備快速處理巨量資訊、解析非結構化資料，並擷取隱含重要訊息及提供新的分析觀點等能力，為央行帶來創新契機。然而，AI 應用同時伴隨資料隱私保護、模型透明度不足與演算法偏誤等風險，亦涉及模型穩健性與可解釋性等挑戰，亟待央行在推動數位轉型過程中審慎規劃並妥適因應。

本報告首先簡介 AI 於央行業務之應用與技術發展，其次說明全球主要央行運用 AI 監測總體經濟金融情勢之研究案例，並分析央行業務應用 AI 之效益與挑戰，最後為結論與建議。

---

<sup>1</sup> 有關對 AI 定義內容請參見 FSB (2017)、IOSCO (2021)及金管會(2024)。

## 貳、人工智慧(AI)於央行業務之應用與技術發展

### 一、AI 於央行業務之應用

因 AI 技術具有提升央行資料處理能力及強化政策制定基礎等效益，各國央行逐漸將 AI 技術應用於自身業務中，本報告參考國際清算銀行(BIS) 2022 年報告<sup>2</sup>，將 AI 於央行業務之應用分為 5 大類別：

- (一)改善資料品質及資訊蒐集：AI 技術可協助央行**建立一套確保資料品質之架構**，並針對龐大資料進行**異常值偵測**、**缺漏值填補**及透過整合其他資料來源以**擴充現有資料**，在執行異常值偵測時，AI 技術不僅使央行更快找到異常資料，亦有助於**偵測新型資料異常模式**，可用於**確保支付系統正常運作**及**防制洗錢**。
- (二)總體經濟及金融分析：由於 AI 技術能同時處理大量變數及高顆粒度資料，並能捕捉及描述複雜的非線性關係，越來越多央行開始將其導入**輔助預測總體經濟及金融變數之流程**，包括理解與整理現有資料、進行經濟建模及預測分析等，並分為「**總體經濟指標**」及「**景氣循環**」分析及預測等兩大面向。
- (三)支援貨幣政策與政策傳遞研究：AI 技術可處理非結構化資料(例如文字或圖像資料)之特性，有助各國央行用於**瞭解其他主要央行關注議題**及**分析自身政策溝通效果**，進而達到適時調整政策及傳遞有效訊息予社會大眾之目的。
- (四)個體審慎監理：AI 技術可用於**加強監理機關與受監管機構間資訊交流與溝通**，例如協助撰寫監理信函及檢測申報資料異常值。此外，AI 技術亦可用於**評估單一金融機構面臨風險**及**辨識潛在的應監管機構**(例如涉足金融服務之金融科技公司)。
- (五)總體審慎監理：2008 年全球金融危機後，各國央行逐漸重視總體審慎監理，其中**壓力測試**已成為評估金融機構風險之重要工具。

---

<sup>2</sup> Araujo et al. (2022).

近年來隨 AI 技術快速發展，其可更細緻區分不同部位風險來源，使監理機關及金融機構更有誘因將 **AI 技術應用於風險評估**。此外，因多數危機屬發生機率低但衝擊巨大之極端事件，**AI 技術**可整合多維度資料、辨識非線性關係及模擬市場參與者行為等特性，**特別適用於建構危機預警系統**。

考量本行權責範圍主要為**總體審慎監理**(如外匯政策、信用政策、支付清算系統、金融穩定評估等)，與金管會主責之**個體審慎監理**(如個別金融機構的核准設立、日常監理及違規裁罰等)不同，本報告爰從以下 4 個面向探討各國應用 **AI 技術情形**：(1)**改善資料品質及資訊蒐集**、(2)**總體經濟及金融分析**、(3)**支援貨幣政策與政策傳遞研究**及(4)**總體審慎監理**，特別是**風險評估及預警系統之建構**。此外，因各國央行技術之實際運用多屬未公開資訊，本報告主要蒐集近年全球主要央行<sup>3</sup>所發布之研究報告，並輔以國際貨幣基金組織(IMF)及國際清算銀行(BIS)之相關研究案例，以供本行未來推動 AI 應用研究之參考及借鑑。

## 二、全球主要央行 AI 技術應用概覽

AI 技術依其模型複雜度大致可分為**機器學習 (machine learning)**<sup>4</sup>、**深度學習 (deep learning)**<sup>5</sup>及**生成式 AI (generative AI, GenAI)**<sup>6</sup>三個發展階段。模型複雜度越高，其處理大量且多元資料型態的能力也越強，惟亦面臨可解釋性不足的問題，且若資料量體不夠大，使用高複雜度的模型反而容易出現過度學習(overfitting)<sup>7</sup>之情況，

<sup>3</sup> 包括美國 Fed、歐洲央行、英格蘭銀行、法國央行及德國央行，亦包含葡萄牙央行及俄羅斯央行等。

<sup>4</sup> 機器學習是 AI 模型的基礎，透過分析大量資料，模型得以自動找出規律或建立預測規則，進而對新資料進行判斷或預測。

<sup>5</sup> 深度學習是機器學習的子領域，其使用神經網路(neural network)進行學習，能夠處理複雜且非線性的資料關係，進而用於分類、語音辨識、圖像辨識、自然語言處理等多種任務。

<sup>6</sup> 生成式 AI 為模擬人類智慧，以創造使用者所需內容之 AI 系統，其形式可包括文章、圖像及音訊等。

<sup>7</sup> 過度學習係指模型過度學習訓練資料，導致在資料樣本內預測表現良好，卻無法有效預測新資料之情況。

影響模型表現。因此，目前主要央行對於 AI 之應用仍以模型結構相對單純的機器學習技術為主，僅少數嘗試使用深度學習及生成式 AI。

以下簡要說明全球主要央行常使用之 AI 模型：

## (一) 機器學習模型

### 1. 線性迴歸模型

以傳統的線性迴歸統計模型為基礎，結合機器學習演算法，使電腦能自動化調整模型參數，進而發掘資料中的規律並進行預測。常見模型包括普通最小平方法(ordinary least squares, OLS)、加權最小平方法(weighted least squares, WLS)等基本模型，以及因應高維度資料及多重共線性<sup>8</sup>可能產生之過度學習問題，加入正則化(regularization)機制<sup>9</sup>的最小絕對值收斂與選擇算法迴歸模型(least absolute shrinkage and selection operator regression, LASSO regression)、嶺迴歸模型(ridge regression)及彈性網路迴歸模型(elastic net regression)等，或加入降維技術之偏最小平方法(partial least squares, PLS)<sup>10</sup>。上述模型被廣泛應用於總體經濟指標與景氣循環預測之相關研究。部分央行亦使用自迴歸整合移動平均模型 (autoregressive integrated moving average, ARIMA)對時間序列資料進行分析與預測。

### 2. 分類與異常偵測模型

針對探討資料間的非線性關係對指標預測之影響，以及金融數據異常偵測等研究，主要央行使用之機器學習模型包括基本的邏輯迴歸模型(logistic regression)，以及各種資料分群與切割方法，如支援向量

<sup>8</sup> 多重共線性係指自變數之間存在高度相關的情況。

<sup>9</sup> 正則化係透過在函數中加入懲罰項，以防止模型過度學習的技術。LASSO 模型以「參數的絕對值總和」為懲罰項；嶺迴歸模型以「參數平方和」為懲罰項；彈性網路迴歸模型則於函數中同時加入 LASSO 及嶺迴歸模型的懲罰項。

<sup>10</sup> 偏最小平方法先將自變數轉化為一組新的線性組合，藉此降低資料維度，提取最有解釋力的特徵後，再進行迴歸分析。

機(support vector machine, **SVM**)<sup>11</sup>、基於密度之含離群值空間分群法(density-based spatial clustering of applications with noise, **DBSCAN**)<sup>12</sup>、**k** 近鄰演算法(k-nearest neighbors)<sup>13</sup>、局部離群因子(local outlier factor, **LOF**)<sup>14</sup>及第一整數近鄰分群階層法(first integer neighbor clustering hierarchy, **FINCH**)<sup>15</sup>、基於直方圖之離群分數(histogram-based outlier score, **HIBOS**)<sup>16</sup>及孤立森林(isolation forest, **IF**)<sup>17</sup>等。此外，亦有採用機率分配方法之分類模型，如簡易貝氏分類(**Naive Bayes**)<sup>18</sup>及隱含狄利克雷分布法(Latent Dirichlet Allocation, **LDA**)<sup>19</sup>等。

### 3. 樹狀模型

樹狀模型透過一連串條件判斷，將資料依特徵分割成不同區域，進而進行預測、分類或異常值偵測。基礎模型稱為決策樹(decision tree)，多棵決策樹組成隨機森林(random forest, **RF**)<sup>20</sup>。隨機森林透過

- 
- <sup>11</sup> 支援向量機係透過尋找最佳分界超平面(hyperplane)，將不同類別資料點分開的機器學習模型，可用於分類、預測(迴歸分析)或異常值偵測。單類支援向量機(one-class SVM)即為一種用於異常值偵測的方法，該模型利用正常資料訓練，透過判斷新資料是否屬於此正常類別來找出異常值。
  - <sup>12</sup> 基於密度之含離群值空間分群法透過檢查資料點周圍的密度找出資料群集，並能夠自動辨識離群值。該方法能進一步擴展為階層式密度分群(hierarchical DBSCAN, HDBSCAN)，透過層級架構處理密度分布較為不均的資料集。
  - <sup>13</sup> **k** 近鄰演算法係指以距離為基礎的非參數(non-parametric)機器學習方法，常用於分類(classification)與迴歸(regression)。其核心概念為將新的觀測值分類或預測為與其「距離最近」的 **k** 個已知資料點結果。
  - <sup>14</sup> 局部離群因子透過比較一個資料點與其鄰近資料點的密度差異，衡量其離群程度。若某資料點相對於鄰近資料點的密度越稀疏，則越可能是離群點。
  - <sup>15</sup> 第一整數近鄰分群階層法是一種根據每個點的「最近資料點」來分群的方法，透過逐步合併彼此接近的點，自動建立出分群層次。
  - <sup>16</sup> 基於直方圖之離群分數係將每個特徵獨立建成直方圖，找出落在低頻區域的資料點，並根據這些特徵的異常程度加總來判斷資料點的離群程度。
  - <sup>17</sup> 孤立森林係一種高效率之非監督式異常值偵測方法，適用於大規模與高維度金融資料。其透過多次隨機切分資料以衡量觀測值被「孤立」之程度，進而辨識潛在異常值。因具有運算速度快、無需標記資料、能捕捉非線性及複雜結構等優點，特別適用於 AML、交易監控、金融市場異常偵測及總體審慎監理中之早期預警系統建構。
  - <sup>18</sup> 簡易貝氏分類是一種基於貝氏定理的機器學習方法，通過計算各類別的條件機率，將資料點分類到最可能的類別中。
  - <sup>19</sup> 隱含狄利克雷分布法是一種主題模型，能夠從大量文字資料中挖掘潛藏的主題結構。該方法假設每篇文章皆由多個主題混合而成，而每個主題則由一組單詞組成，透過機率統計方法，找出每篇文章包含的潛在主題，以及各主題的比例。
  - <sup>20</sup> 隨機森林相關模型包括：(1)極端隨機樹(extremely randomized trees, ERTs)：與隨機森林概念相似，皆使用多棵決策樹產出結果，差異在於隨機森林會尋找最佳的分割節點，ERTs 則隨機選擇分割節點，故決策樹的多樣性更高，但可能犧牲精準度；(2)分位數迴歸森林(quantile regression forests)：隨機森林的拓展，除提供所有決策樹的預測平均值外，更進一步計算預測結果的信賴區間或其他分位數。

對資料與特徵的隨機抽樣，建造多棵決策樹，並將所有樹的預測數值平均後作為最終預測結果。若為分類問題，則由各棵樹選出其認為的類別，並以獲得最多數支持之類別為最終結果。**提升法(boosting)**<sup>21</sup>串聯多個結構較簡單、表現能力較弱的決策樹，並在每次訓練著重修正前一個模型錯誤的部分，持續提升模型效能。

#### 4. 淺層神經網路模型

**神經網路(neural network, NN)**是一種**模仿人腦神經系統結構與運作的機器學習模型**，資料經由輸入層進入神經網路，透過每層神經元(稱為隱藏層)的加權運算及非線性函數轉換，逐層傳遞至下一層，最終在輸出層產出預測結果，藉此**處理複雜的資料分析與預測問題**。基礎的神經網路層數較淺(約 1-2 層隱藏層)，適合處理較簡單的任務；隨著資料量增加與資料型態越趨複雜，神經網路的層數也逐漸增加，形成所謂的「深度學習」模型。神經網路模型依據應用場景可分為多種，如負責處理圖像資料的**圖像神經網路(graph neural network, GNN)**、用於轉換多維資料的**自編碼器(autoencoder)**<sup>22</sup>等。

#### (二) 深度學習模型

多層結構的神經網路模型能夠更精準而全面地分析資料，進而完成影像、語音、自然語言處理等複雜性任務。其中，**Transformer 架構**係用於**處理序列資料(如語言、文字、音訊等)的複雜神經網路架構**，**賦予模型能夠判斷詞語上下文或音訊變化的能力**。**BERT 模型**(bidirectional encoder representations from transformer)為基於Transformer 架構建立的一種**預訓練語言模型**，**能夠同時考慮上下文，提升模型的語義理解能力**。美國 Fed、國際清算銀行(BIS)及歐洲央行

<sup>21</sup> 提升法之具體應用如梯度提升法(gradient boosting)，其核心係透過梯度下降方式逐步最小化損失函數，並以多棵弱學習器累積改善模型預測誤差。在此基礎上，發展出更進階之演算法，如極限梯度提升(extreme gradient boost, XGBoost)及 LightGBM (light gradient boosting machine)等，以提升運算效率、記憶體使用與模型表現。

<sup>22</sup> 自編碼器由編碼器與解碼器組成，編碼器將高維度的原始資料壓縮成低維表示，解碼器再以該等低維資料重建原始資料，藉此擷取關鍵的資料特徵。

(ECB)<sup>23</sup>等組織的研究中即有以 **BERT 模型分析官方文件或民間調查報告**，進而**預測總體經濟指標**之案例。另一種基於 Transformer 架構的模型為 **UniTTab**，用於**處理結構化表格資料**。

### (三) 生成式 AI 模型

隨著模型優化、巨量資料及運算能力的顯著提升，基於 Transformer 架構的**大語言模型**(large language model, **LLM**)興起，並進一步發展出 **GPT、Gemini、Claude** 等超大型預訓練語言模型。考量模型可解釋性及回覆穩定性等因素，目前**主要央行對生成式 AI 的應用仍以內部文件摘要、會議紀錄生成等輔助型工作為主，尚未用於決策層面**，但相關技術突破已為資料分析與應用帶來新的思維。Fed、BIS 及 ECB 近期均發表相關研究<sup>24</sup>，探討生成式 AI 模型於**總體經濟指標預測**或**貨幣政策效果分析**等領域的應用。

此外，無論採用前揭機器學習、深度學習或生成式 AI 模型，在處理文字資料時，皆需將**文字轉為**電腦能理解的**向量數值**，常見作法如 **Word2Vec**<sup>25</sup>等。

---

<sup>23</sup> 參見 Soto (2023)、Cajner et al. (2024) 及 Araujo et al. (2025)。

<sup>24</sup> 參見 Dunn et al. (2024) 及 Araujo et al. (2025)。

<sup>25</sup> Word2Vec 係將每個單詞映射到一個高維向量空間中，而語義相近的詞彙會被映射到向量空間的相近位置，藉此在保留單詞間語義關係的前提下，將單詞轉換為向量數值。Word2Vec 有兩種訓練方式，連續詞袋模型(continuous bag of words, CBOW)根據上下文單詞預測中心單詞；跳字模型(skip-gram)則根據中心單詞預測其上下文單詞。

## 參、全球主要央行運用 AI 之研究案例

本節進一步說明全球主要央行、IMF 及 BIS 運用 AI 於「改善資料品質及資訊蒐集」、「總體經濟與金融分析」、「支援貨幣政策與政策傳遞研究」及「風險評估及預警系統」等業務之實務作法，鑑於相關案例眾多，僅就若干具代表性者予以詳述；其餘案例之摘要內容，請參見附表。

### 一、改善資料品質及資訊蒐集

各國央行在處理受監管機構申報之細部資料時，容易面臨**資料不足、申報異常**及資料運用成效有限等問題，需投入大量人力成本進行資料品質監測及後續分析。當 AI 技術逐漸成熟，各國央行開始將機器學習模型融入工作流程，以提升作業效率並改善資料品質管理。此外，AI 模型可從大規模細部資料中辨識異常模式，有助於偵測新型資料異常與潛在不法行為，強化犯罪防制成效。

在**處理申報資料異常**方面，全球主要央行**普遍採用機器學習模型**，常見演算法包括**迴歸分析、孤立森林、階層式分群法(包括 DBSCAN 及 HDBSCAN)<sup>26</sup>及極限梯度提升<sup>27</sup>**等。異常值通常定義為分類中與模型預測值偏差顯著、容易被區分或過去曾被標註為異常值之數值。此外，**德國央行及 ECB 已建立一套將 AI 模型納入工作流程之有效作法**，包括**資料預處理、異常值標記及整合多種演算法結果**等三大步驟。

在**分析細部資料**方面，BIS 之 Aurora 計畫及 Hertha 計畫皆顯示運用 AI 技術**進行細部資料分析有助於提升可疑交易偵測率、降低誤報率**，並**協助辨識以往不易辨識之新型金融犯罪模式**。雖然其使用資

---

<sup>26</sup> 見註 12。

<sup>27</sup> 見註 21。

料多屬合成資料(synthetic data)<sup>28</sup>，但結果仍證明跨國及跨機構合作在**提升監理科技(SupTech)效能**方面具高度價值。

以下詳細說明 ECB 應用案例，以瞭解其如何將 AI 模型有效納入工作流程：

ECB 使用 AI 技術運用於處理其貨幣市場統計申報資料(money market statistical reporting, MMSR)，該資料集為**逐筆交易資料**，由 10 個歐洲國家共 47 家銀行**每日提報**約 5 萬筆交易(包括 3 萬筆擔保交易、1.5 萬筆無擔保交易及 5 千筆換匯交易及隔夜指數交換交易)，規模龐大。由於 MMSR **具大量類別變數<sup>29</sup>及分布高度不對稱之特性**，ECB 須建構一套高效且可擴充之資料處理流程，以及時處理資料並確保資料品質。

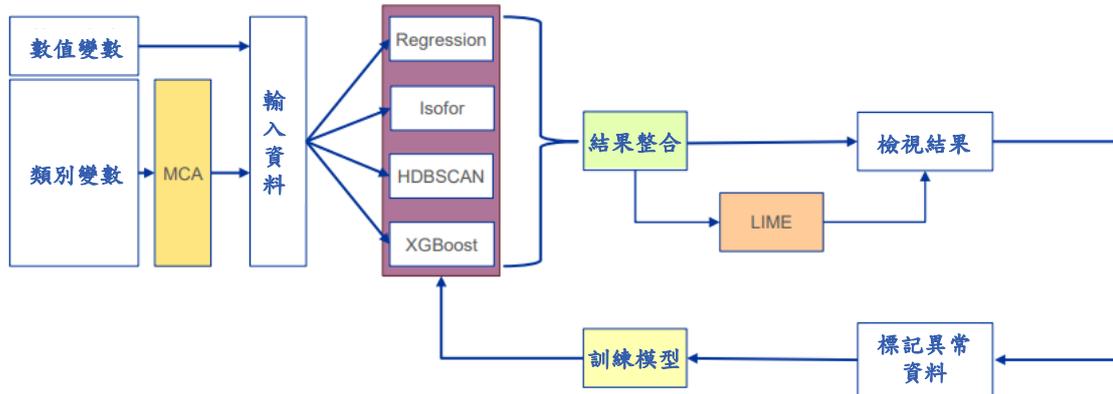
ECB 透過 3 步驟將 AI 模型有效整合至 MMSR 處理流程(圖 1)。首先進行**多重變數對應分析(multiple correspondence analysis, MCA)**，藉以不同類別變數間特徵的關聯性，**將類別變數轉換為可用於模型之數值化特徵(亦即數值變數)**，並將關聯性較高之變數群組化處理。其次，ECB 透過**多種演算法標記異常值**，其使用之演算法異常值定義及特點如表 1，再使用 LIME 演算法<sup>30</sup>評估個別模型標記之解釋度與合理性，以協助分析人員理解不同演算法之標記原因。最後，因過程中使用多種演算法，ECB 先對**各種演算法結果重要性或可靠性設定權重後進行加權平均**，再將多元演算法結果整合為單一輸出後，納入一致之資料品質管理流程。此外，ECB 亦利用 AI 模型產出之結果進行異常資料標記，並作為後續模型訓練之額外樣本。

<sup>28</sup> 合成資料係因原始資料具隱私性無法直接使用，而透過統計方法或 AI 模型等方式，讓電腦「模擬」原始資料方式生成新資料。

<sup>29</sup> 類別變數係指變數數值僅代表該類別不同種類之名稱，而沒有程度差異，例如性別、血型等。

<sup>30</sup> LIME (Local Interpretable Model-Agnostic Explanations)演算法透過在某個資料值附近建立簡單、可解釋模型以說明原始模型的局部行為。

圖 1：ECB 處理 MMSR 資料流程



資料來源：Accornero and Boscaroli (2021)。

表 1：各項演算法之異常值定義及特點

演算法	異常值定義	特點
迴歸分析	與模型預測值偏差最多的資料值	傳統方法
孤立森林	較容易被劃分的資料值	1. 有近似線性的時間複雜度，且因採用資料抽樣方式，記憶體需求量低 2. 能夠辨識分散及群聚行異常值 3. 可處理「淹沒效應」及「遮蔽效應」 <sup>1</sup>
階層式分群法 (使用 HDBSCAN 演算法 <sup>2</sup> )	與其他資料值關聯性較弱的資料值	1. 效能良好 2. 參數簡潔 3. 可處理「連鎖現象」 <sup>3</sup> 4. 可結合 GLOSH 演算法
XGBoost <sup>4</sup>	以歷史資料中先前已被標記或辨識為異常者作為判斷基準	1. 效率及準確性皆高 2. 高度依賴歷史資料進行訓練

註：1. 淹沒效應及遮蔽效應皆為異常偵測時常見的錯誤，因多數情境中異常值較稀少，導致模型辨識時難以正確標記錯誤。淹沒效應係將正常事件標記為異常，遮蔽效應則無法正確辨識異常值。

2. HDBSCAN 演算法說明請參考本文註 12。

3. 連鎖現象係指資料值透過各點連接成一個「長型鏈狀群體」，而非正常緊密群體，導致無法偵測出異常值。

4. XGBoost 技術請參考本文註 21。

資料來源：Accornero and Boscaroli (2021)。

## 二、總體經濟與金融分析

央行在總體經濟與金融分析領域之 AI 應用，主要聚焦於「**總體經濟指標**」及「**景氣循環**」兩類之**分析及預測**。在技術方面，多採**機器學習模型**，常用模型包括 **LASSO**、**嶺迴歸**、**彈性網路迴歸**、**支援向量機**、**隨機森林**及**神經網路**。在資料型態方面，除傳統的總體經濟統計資料外，亦涵蓋高顆粒度資料(如商品細項價格、每日股票報酬等)，以及政府官方聲明、政策會議紀錄、民間機構問卷調查結果及新聞文本等非結構化資訊。透過多元且具異質性的資料型態，央行期望進一步強化預測模型之準確性，並自龐雜資料中進一步發掘潛在的經濟結構特徵或洞察決策行為，以強化前瞻性分析與研判能力。

### (一) 總體經濟指標之分析及預測

全球主要央行在運用 AI 技術提升總體經濟指標之預測表現方面，已進行大量研究，除使用各類**機器學習**模型外，近年來亦逐步嘗試導入**深度學習**及**生成式 AI**技術，以下分別列舉三種技術應用案例：

#### 1. 機器學習案例

英格蘭銀行(BoE)於 2020 年發表研究論文<sup>31</sup>，探討新聞報導中所蘊含的經濟訊號，是否能顯著提升對總體經濟指標的預測準確性，並比較自迴歸(auto-regression, AR)模型與機器學習模型的預測表現差異。

該研究蒐集英國三大主流媒體 1990 年至 2019 年間有關金融市場、產業及經濟之每日新聞資料，並分別使用「演算法式文字指標加上 AR 模型」及「機器學習模型」進行總體經濟指標預測。預測指標包括 GDP、失業率、企業投資、家庭消費、消費者物價指數(CPI)、生產指數(IOP)、服務業指數(IOS)、金融壓力指數<sup>32</sup>及 IMF 英國金融情勢指數。「演算法式文字指標加上 AR 模型」係先依預設規則將新聞

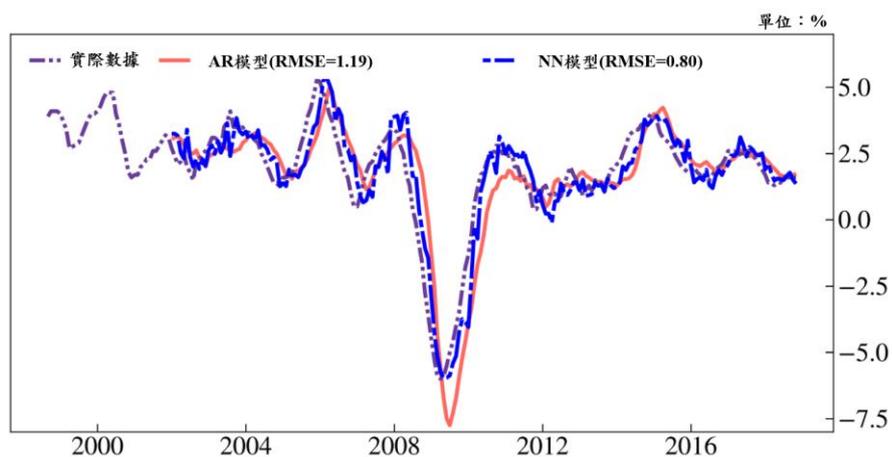
<sup>31</sup> Kalamara et al. (2020).

<sup>32</sup> 該指數源自 Chatterjee et al. (2017)。

文本轉換為量化分數<sup>33</sup>，再將該分數計算結果作為自變數輸入 AR 模型進行預測。「機器學習模型」則依據詞彙列表進行**特徵工程(feature engineering)**，將**每篇新聞轉換為詞頻向量(term frequency vector)**<sup>34</sup>，再輸入多種機器學習模型(LASSO、嶺迴歸、彈性網路迴歸、支援向量機、隨機森林及神經網路)進行預測。兩種作法之主要差異在於，前者基於既定規則預先定義各詞彙之權重，後者則**保留文章中所有相關詞彙之特徵**，由機器學習模型自行學習最佳權重配置，因而能更靈活捕捉新聞文本中所蘊含的經濟訊號。

研究發現，新聞文本確實具有前瞻性資訊，能有效**預測未來 3 至 9 個月之總體經濟指標**，而**機器學習模型**在各項總體經濟指標之**預測表現皆優於 AR 模型**，且在辨識經濟轉折點時反應更為**迅速、準確**(圖 2)。機器學習模型中以**嶺迴歸及神經網路模型之預測表現最佳**；相較之下，LASSO 及彈性網路迴歸模型表現則較為遜色，主要係因嶺迴歸及神經網路模型**對所有特徵值皆賦予一定權重**，能保留並**運用更廣泛資訊進行預測所致**。

圖 2：GDP 成長率走勢



資料來源：Kalamara et al. (2020)。

<sup>33</sup> 如「詞典法」預先定義特定詞彙之正負面情緒分數，再依此計算各篇文章所含詞彙及對應之分數加總；「布林法」計算滿足特定邏輯條件(例如某篇文章同時包含三個預定義詞彙)的文章數量。

<sup>34</sup> 詞頻向量係文字向量化方法之一，計算各詞彙在文章中出現的次數或比例，並依照預先建立的詞彙列表順序，將其表示為一組向量。

除預測總體經濟指標的未來走勢外，ECB 也積極嘗試運用機器學習技術進行**即時預測(nowcasting)**<sup>35</sup>。該機構蒐集 1998 年至 2021 年間，法國、德國、義大利及西班牙的**每日新聞資料**，並將新聞文本轉化為**情緒指標**<sup>36</sup>後，作為機器學習模型(包括嶺迴歸、隨機森林、提升法及神經網路模型)之輸入變數，用以**即時預測前揭四國的實質 GDP 季增率**。

研究結果顯示，**在季度初期，各項總體經濟指標尚未公布前，每日新聞資訊可顯著提升對該季度 GDP 成長率的預測準確性**，凸顯高頻新聞資料在即時預測之價值。此外，四種模型中，能夠**捕捉資料間非線性結構的隨機森林、提升法與神經網路模型**，在面對如 2008 年全球金融危機及 2020 年新冠疫情等**經濟劇烈波動期間**，皆展現出**較佳的預測表現**。

## 2. 深度學習案例

鑑於供應鏈瓶頸對實體經濟具有重大影響，並可能透過供給面衝擊物價穩定，Fed 於 2023 年發表研究報告<sup>37</sup>，利用**褐皮書(Beige Book)**之文本**建構美國「供應鏈瓶頸情緒指數(Supply Chain Bottleneck Sentiment Index, 以下簡稱 SCB 情緒指數)」**，並**探討該指數與未來通膨走勢之關聯性**。

此研究使用 1991 年至 2022 年間所有褐皮書文本，首先透過**Word2Vec 估計各篇文章詞彙的向量數值**，以捕捉語意間之相似性。其次，使用**深度學習模型 FinBERT** 分析包含供應鏈瓶頸相關詞彙的語句，據以建構 SCB 情緒指數<sup>38</sup>。**FinBERT 係專為金融文字資料訓練的情感分析模型，能透過上下文語境捕捉語意**，彌補傳統詞彙列表

<sup>35</sup> Ashwin et al. (2021).

<sup>36</sup> ECB 係使用「詞典法」將文字轉化為情緒分數，「詞典法」相關說明請見註 33。

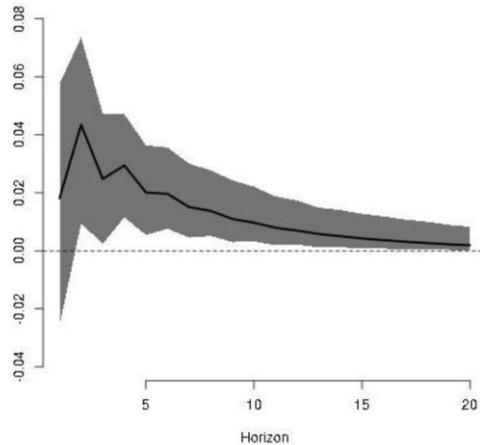
<sup>37</sup> Soto (2023).

<sup>38</sup> SCB 指數之計算公式為： $(\text{負面語句總數} - \text{正面語句總數}) / \text{總語句數量}$ ，指數值越高表示對供應鏈瓶頸的負面情緒越強。

僅憑單一詞彙判斷情緒所產生之限制。

研究結果顯示，在控制過去的通膨、油價及工業生產數值等變數後，**SCB 情緒指數與 CPI 月增率呈顯著正相關**。圖 3 說明 SCB 情緒指數對通膨的影響路徑。當供應鏈瓶頸衝擊發生時，通膨率會迅速上升，且需一段時間才會回落，顯示**供應鏈對物價具有持續性的影響**。

圖 3：供應鏈瓶頸衝擊下的通膨反應函數



註：該反應函數係採用貝氏向量自迴歸模型(Bayesian VAR)，納入 SCB 情緒指數、工業生產成長率、油價成長率及 CPI 成長率等 4 個變數的前兩期數值計算而得。灰色區域表示 10%至 90%的信賴區間。

資料來源：Soto (2023)。

### 3. 生成式 AI 案例

BIS 與 ECB 經濟學家合作，於 2025 年發表研究論文<sup>39</sup>，探討如何運用 **ECB 貨幣政策記者會新聞稿**(下稱 ECB 新聞稿)之文本資訊，提升對**歐元區核心通膨之預測**能力。

該研究蒐集 2002 年至 2023 年間所有 ECB 新聞稿資料，並分別採用 **Word2Vec** 及**大語言模型(BERT 及 GPT)**進行語意分析。透過上述模型將新聞稿內容轉換為文字向量後輸入向量自迴歸模型(VAR)，以預測未來一至四個季度歐元區不含能源與食品的調和消費者物價指數(HICPex)。

<sup>39</sup> Araujo et al. (2025).

研究發現，將 ECB 新聞稿之文字資訊納入模型後，較僅使用歷史通膨資料之基準模型具更高之預測準確度，顯示央行溝通內容確實包含反映政策評估與經濟前景的前瞻性訊息。另在不同語意模型比較上，**Word2Vec 與大語言模型在預測表現上並無明顯差異**，研究者推測，針對如央行新聞稿這類**主題明確且內容相對聚焦的專業文章**，**大語言模型**於跨領域、多語境捕捉語意關係的**優勢**，可能因而**未能充分展現**。

## (二) 景氣循環之分析及預測

Fed 及 ECB 皆嘗試運用機器學習模型分析經濟及金融市場數據之變化，並探討其與景氣循環的關聯。以下舉 ECB 之研究<sup>40</sup>為例：

ECB 分析 1980 年至 2019 年第一季期間，S&P500 指數成分股中所有上市公司的**每日股票報酬**資料，並運用 Granger 因果檢定<sup>41</sup>建立動態股票報酬關聯網絡；隨後採用**遞迴特徵消除法(recursive feature elimination, RFE)**<sup>42</sup>自高度複雜的關聯網絡結構中**篩選出最具預測性之特徵**，並將其分別輸入**邏輯迴歸、簡易貝氏分類器及支援向量機等模型**，進行**景氣循環即時預測**。

研究發現，**機器學習模型能有效預測「景氣衰退期間」及「景氣循環週期之轉折點」**，其中**支援向量機**模型在樣本內預測時表現最佳，惟樣本外之預測表現則不如其他兩個模型，顯示該模型可能存在**過度學習**問題。此外，該研究透過**特徵值篩選**，**辨識出對景氣循環變化較敏感之產業**，包含金融業(特別是保險業)、製造業、運輸業及零售業。

<sup>40</sup> Azqueta-Gavaldón et al. (2020b).

<sup>41</sup> Granger 因果檢定是一種分析時間序列間因果關係的統計方法，即**判斷一個時間序列的過去值是否能預測另一個時間序列的未來值**。ECB 即以此方法分析各家公司股票報酬之因果關係，進而建立股票報酬關聯網絡。

<sup>42</sup> **遞迴特徵消除法**係**機器學習領域中的一種特徵選擇技術**，透過反覆移除對模型貢獻最小的特徵，找出最具預測力的變數組合。

### 三、支援貨幣政策與政策傳遞研究

此類別主要係運用 AI 技術分析央行發布資訊，以瞭解央行在不同期間的關注議題及立場變化，或探討央行政策溝通之傳遞效果，協助決策者掌握市場反應，並適時調整溝通方式，以提升政策傳遞成效。

#### (一) 央行關注議題分析

IMF<sup>43</sup>及 Fed<sup>44</sup>先後於 2021 年及 2024 年發表研究論文，分別運用機器學習及生成式 AI 模型，分析美國聯邦公開市場委員會(FOMC)會議紀錄中，各種主題之討論比重，探討 Fed 對各類總體經濟議題之關注程度及其演變。

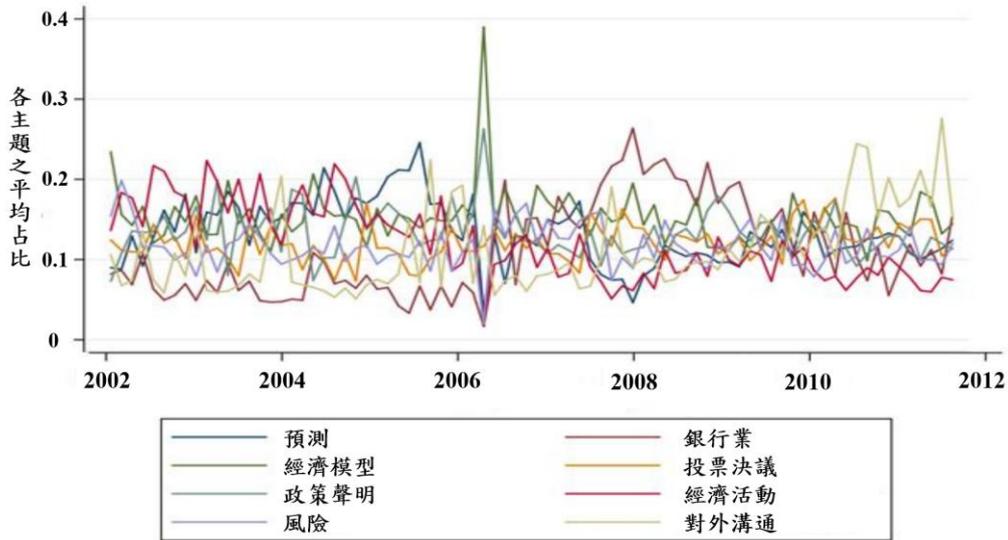
IMF 採用隱含狄利克雷分配(LDA)法分析 2003 年至 2012 年間，個別 FOMC 會議紀錄之詞彙機率分布及主題分群。研究團隊透過專家判讀各主題群之經濟意涵，將其歸納為八大主題：預測、經濟模型、政策聲明、風險、銀行業、投票決議、經濟活動及對外溝通。研究發現，2007 年至 2008 年全球金融危機期間，以「經濟模型」相關議題討論度最高。其後，隨金融體系脆弱性趨增，FOMC 的討論焦點逐漸轉向「銀行業」相關議題。此外，央行「對外溝通」議題在樣本後期(2011 年至 2012 年)之討論比重亦明顯提高，顯示危機後 Fed 對透明度、前瞻指引與政策溝通之重視程度不斷提升(圖 4)。

---

<sup>43</sup> Carcel-Villanova and Edison (2021).

<sup>44</sup> Dunn et al. (2024).

圖 4：2003 年至 2012 年間 FOMC 會議紀錄關注主題占比



資料來源： Carcel-Villanova and Edison (2021)。

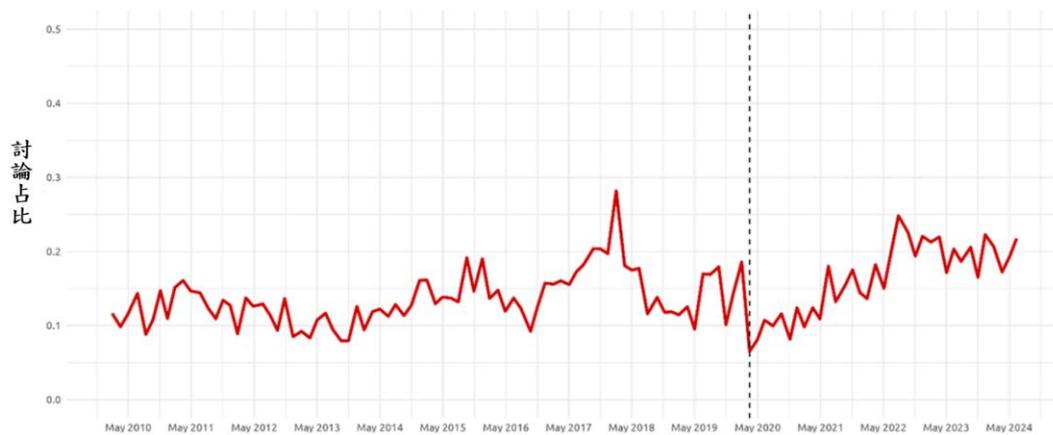
Fed 採用 **生成式 AI 模型**，分析 2010 年至 2024 年間的 FOMC 會議紀錄。研究團隊首先隨機**抽取 20% 的樣本進行人工分類**，並據此訂定七大主題類別：實體經濟活動、勞動市場、通膨、金融穩定、聯邦基金利率、資產負債表及金融發展。再**依據該分類準則**，由**生成式 AI 模型分析每篇會議紀錄中，各主題的討論比重**，並比較 11 種生成式 AI 模型(包括多個版本的 GPT、Gemini、Claude 等)在主題分類上之準確性。

此研究使用 F1-score 為衡量指標，該指標值介於 0 到 1，並同時反映模型之精確度(precision)及召回率(recall)<sup>45</sup>，越接近 1 表示越準確。研究結果顯示，所有**生成式 AI 模型**在 7 個主題類別之**平均 F1-score 介於 0.8 至 0.93**，**準確性高**，其中又以當時最新的 **GPT-4o 表現最佳**。觀察 FOMC 會議討論主題之演變，2010 年代後期，**由於通膨持續低迷且勞動市場強勁，FOMC 會議對「通膨」議題之討論比重明顯增加**，雖於疫情初期短暫回落，但自 2021 年起再度攀升，至 2024 年仍為該會議討論之核心議題之一(圖 5)；此外，在樣本期間內，關於「**金**

<sup>45</sup> F1-score 是一種評估模型效能的指標，綜合考量模型的精確度與召回率。其中，精確度係指模型判定為正樣本中，實際為正樣本的比例；召回率則指所有實際為正樣本中，被模型正確辨識的比例。

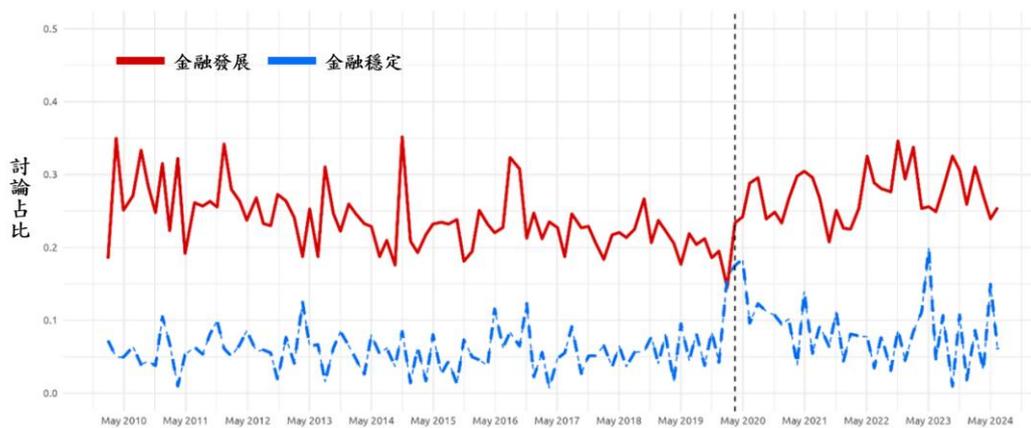
融發展」與「金融穩定」的討論比重亦走升，且在特定時期出現高峰，如 2020 年 3 月疫情初期的緊急 FOMC 會議，以及 2023 年矽谷銀行與 Signature 銀行倒閉事件期間(圖 6)。

圖 5：FOMC 會議對「通膨」議題之關注程度變化



資料來源：Dunn et al. (2024)。

圖 6：FOMC 會議對「金融發展」及「金融穩定」議題之關注程度變化



資料來源：Dunn et al. (2024)。

## (二) 央行溝通效果分析

BoE 於 2021 年發表研究論文<sup>46</sup>，旨在探討**央行如何透過調整其溝通方式，獲得更多新聞報導**，進而更有效地將訊息傳遞予社會大眾。

研究團隊以 1998 年至 2019 年間 BoE 發布之溝通文件<sup>47</sup>，以及同期間的新聞報導為資料基礎，並設計一套經濟模型，以**衡量「央行資訊被新聞報導採用程度」與「央行溝通文件之特徵」及「總體經濟變數」的關係**：

$$\frac{1 - k_t}{k_t} = \beta_0 + \beta_1^T (\theta_{B,t}^T \theta_{B,t}) + \beta_2^T \theta_{B,t} + \beta_3^T (z_t \otimes \theta_{B,t}) + \beta_4^T z_t + \beta_5^T (z_t \otimes z_t)$$

其中，k 係指新聞報導中直接轉述央行溝通內容的比例，其衡量方法為比較央行溝通文件發布前一天及後一天，新聞報導內容與該溝通文件之文本相似度變化； $\theta$  表示**央行溝通文件的特徵向量**，透過 Word2Vec、軟餘弦相似度<sup>48</sup>、詞性標注、句法分析等語言處理技術，產製出包含主題、語言處理特徵及新聞價值特徵三大面向之文件特徵資料集；z 則表示總體經濟變數向量(如 GDP 成長率、失業率、通膨率等)。**為避免模型過度學習**，該研究亦使用 **LASSO 技術** 進行降維處理。

研究發現，**經濟波動性或不確定性程度**係影響央行溝通文件能否**獲得媒體報導之重要因素之一**，例如在通膨率波動性較高時，央行的問答環節更容易成為媒體關注重點。此外，此研究亦歸納出幾項能**有效提高央行溝通文件取得媒體報導機會之方法**，包括：(1)採用較為簡潔的語句結構；(2)多使用第一、二人稱(「我們」、「我」、「你」)與讀者互動；(3)在文章首句總結重點；及(4)**搭配具體數據**或提及關鍵決策人物(如央行總裁)。

<sup>46</sup> Munday and Brookes (2021).

<sup>47</sup> 包括貨幣政策記者會新聞稿、通膨報告、問答環節、演講及會議紀錄等。

<sup>48</sup> 軟餘弦相似度(soft cosine)係透過計算兩個字詞向量之間夾角的餘弦值，衡量兩字詞的相似性。

#### 四、風險評估及預警系統

在風險評估方面，AI 模型可輔助金融機構建構內部壓力測試模型，並有效減少資本計提需求，例如法國央行(BdF)曾以 AI 模型模擬銀行內部評等法之計算流程，結果顯示，神經網路模型可大幅減少風險性資產之提列，進而提升銀行在資本適足性管理上採用 AI 技術之誘因。

在預警系統方面，各國央行針對金融機構個別危機、企業個別危機及金融體系總體危機均已利用 AI 模型作為輔助預測工具，其使用資料包括銀行及企業財務資料、總體經濟資料、市場面資料等量化資料，部分研究亦納入國際組織報告、新聞摘要及監理機制蒐集之質化資料，透過結合多元資料來源及 AI 模型輔助，可更全面掌握各類危機之可能誘因與傳染途徑。

在技術應用方面，各國央行多以機器學習模型為主，常見的演算法包括隨機森林、梯度提升<sup>49</sup>、支援向量機及神經網路，部分央行亦採用決策樹演算法，但因其容易產生過度學習問題，在多數情境下預測能力不如其他模型。此外，若使用邏輯迴歸模型處理高維度之大型資料集時，各國央行則通常搭配嶺迴歸或 LASSO 等正則化技術<sup>50</sup>，以避免模型過度學習問題，並提升預測穩健性。

以下將就各類應用，說明部分央行之具體案例，以瞭解 AI 技術如何協助辦理金融機構壓力測試及建構有效預警系統。

##### (一) 金融機構壓力測試

BdF 於 2021 年發布報告<sup>51</sup>，探討銀行在使用內部評等(Internal

---

<sup>49</sup> 見註 21。

<sup>50</sup> 見註 9。

<sup>51</sup> Fraisse and Laporte (2021).

Ratings-Based, IRB)法<sup>52</sup>計算資本要求時，**是否有採用 AI 模型取代現行邏輯迴歸模型之誘因(例如減少風險性資產之計算結果等)**。研究資料主要來自 BdF 全國貸款登錄系統資料庫，擷取前 6 大放款銀行之企業貸款餘額，並搭配 BdF 企業財務資料庫(FIBEN)之財務資料，以預測企業違約機率。貸款資料排除非獨立企業、金融、不動產、公共和非營利部門企業，且**前 6 大放款銀行總額占全體銀行之 80%以上**，具一定代表性。

研究假設 6 家銀行在計算資本要求時皆使用 IRB 法，且未採標準法(standard approach)<sup>53</sup>，並模擬一套銀行內部評等模型之實際運作流程，其建模分為 3 大步驟：**(1)估計企業連續風險分數**：將企業財務資料與違約率進行分析，並計算連續風險分數、**(2)轉換為離散風險等級**：將連續風險分數轉換為離散風險等級，使同級內風險特徵具同質性，不同級間則具異質性、**(3)對應違約機率(PD)**：將每一風險等級對應一個違約機率，通常為該等級歷史違約率之長期平均值。

在上述流程中，**BdF 僅在第一步驟—估計企業風險分數時，分別採取現行邏輯迴歸模型(基準模型)與多種 AI 模型方法，並進行比較**。所使用之 AI 演算法包括**單層、雙層及三層神經網路、隨機森林、梯度提升、嶺迴歸**等 6 種方法，訓練資料期間為 2009 年至 2014 年資料，測試樣本為 2015 年資料，用以評估 AI 模型與傳統模型的預測差異。

BdF 評估 AI 模型有效性時，區分為 3 大面向：**(1)AI 模型是否能建立穩健評等系統**：不同風險等級須具備遞增的違約機率，且不得出現高風險等級反而具有較低違約率之錯置情形、**(2)AI 模型是否能準**

---

<sup>52</sup> 內部評等法係指銀行依自身建立的模型來評估借款人違約機率等風險變數，並用來計算資本要求之方式，現行銀行使用 IRB 法需經監理機關核准，且其內部模型多使用邏輯迴歸及專家判斷建構而成。

<sup>53</sup> 標準法係指銀行依監理機關設定風險權數計算資本要求之方式，通常監理機關係依外部信用評等來設定風險權數。

確預測違約機率、(3)銀行是否有採取 AI 模型之誘因：使用 AI 模型可大幅減少風險性資產之計算結果。

在建立穩健評等系統方面，BdF 使用錯置率(Inversion Rate)及風險區分程度(Risk Differentiation)2 項指標<sup>54</sup>衡量，其中錯置率最低的是嶺迴歸及三層神經網路模型，風險區分程度最高的是三層神經網路及基準模型。然而，不同銀行之結果仍呈現差異：部分銀行神經網路模型表現最好，部分則仍為基準模型。

在預測違約機率方面，BdF 使用 ROC 曲線下面積(area under the ROC curve, AUC)<sup>55</sup>及 F1-score<sup>56</sup>2 項指標衡量，隨機森林模型在 AUC 及 F1-score 表現最佳，然而其測試樣本效能明顯下降，顯示存在過度學習問題，其餘 AI 模型在預測效能上大致與基準模型(邏輯迴歸)相近，未呈現大幅優勢。在分析銀行是否有採取 AI 模型之誘因，BdF 使用風險性資產(Risk-weighted asset, RWA)密度<sup>57</sup>衡量(圖 7)，其中梯度提升模型反而使多數銀行須提列更多風險性資產，隨機森林模型則可使部分銀行大幅降低風險性資產提列，然而其無法通過評等穩健性及預測評估，故不具可行性；單層、雙層及三層神經網路模型至少有一種使個別銀行在同樣暴險下，降低風險性資產提列幅度達 2%至 27%，顯示其具備提高銀行採用 AI 模型之誘因。

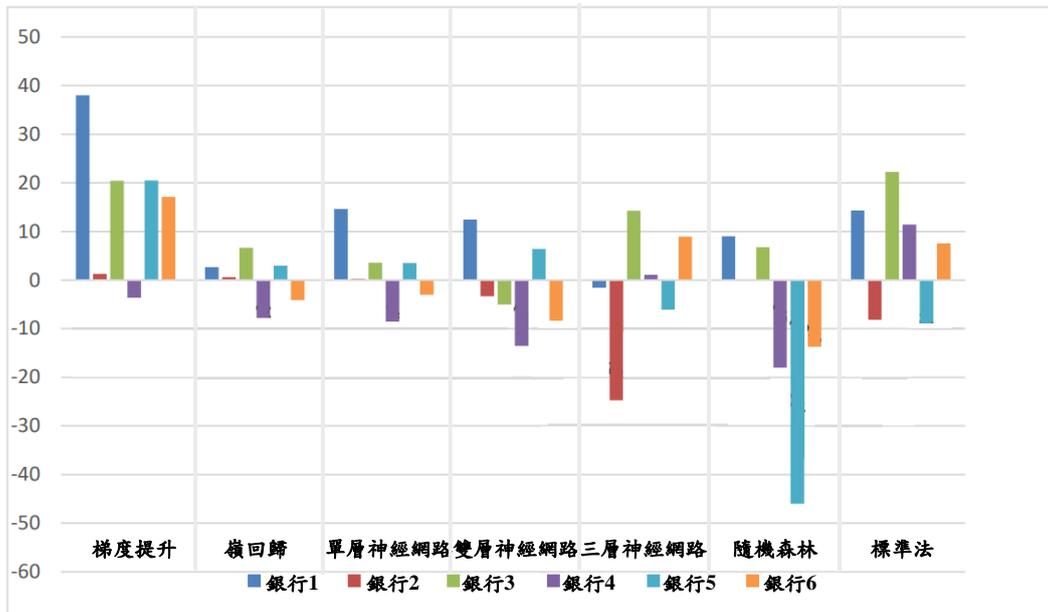
<sup>54</sup> 錯置率係指模型實際風險等級錯置次數除以預期錯置次數，其數值越小越好；風險區分程度係指 Z 檢定拒絕違約機率相等假設次數除以總檢定次數，其數值越高越好。

<sup>55</sup> ROC 曲線由真陽性率(分類之效益)與偽陽性率(分類之成本)所構成，AUC 即為 ROC 曲線下面積並介於 0 至 1 之間，當 AUC 越接近 1，則表示模型完美分類所有樣本。

<sup>56</sup> 見註 45。

<sup>57</sup> 風險性資產(RWA)密度係指風險性資產除以暴險值，當暴險值不變，若提列之風險性資產顯著下降，則銀行更有誘因使用 AI 模型。

圖 7：各模型相較基準模型之風險性資產密度變化



註：風險性資產密度=風險性資產/暴險值；採 2009 年至 2014 年資料計算平均值。  
資料來源：Fraisie and Laporte (2021)。

## (二) 金融機構經營危機預警系統

金融機構經營危機預警系統旨在提前辨識個別金融機構是否出現經營惡化或潛在危機跡象，以便監理機關能及早採取必要之干預或導正措施。ECB 於 2019 年發布報告<sup>58</sup>，闡述一套專為其**定義下之重要性較低銀行**(Less-significant institutions, **LSIs**)所設計之**創新預警系統**。

在 ECB 單一監理機制(Single Supervisory Mechanism, SSM)架構下，部分銀行因其規模小、經濟重要性有限或跨境活動程度較低而被分類為 LSIs，其監理權責主要由各國主管機關負責，ECB 採與各國主管機關合作，以間接監理模式進行監管。

為瞭解各 LSIs 是否有出現經營惡化或潛在危機跡象，ECB 結合**銀行申報之監理報表**、監理機制蒐集之**質化資料**及**各國總體經濟指標**，用以預測依歐盟「銀行復原及處置指令」規定及 Betz et al. (2014)<sup>59</sup>定義之經營危機樣態。首先在資料處理方面，ECB 刪除缺漏值過多變

<sup>58</sup> Bräuning et al. (2019).

<sup>59</sup> Betz et al. (2014).



在模型預測能力方面，**決策樹模型與基準模型在 AUC 表現大致相當**，但前者之「未預測到經營危機比率」較低，顯示**決策樹模型更能捕捉實際危機事件**。此外，決策樹模型可有效預測非訓練樣本年份(2017年)約 79%的銀行經營危機事件。該研究亦發現**對獲利能力較低之 LSIs**，其經營危機之發生與所屬國家之整體經濟情勢高度相關，顯示**總體環境對其營運表現影響顯著**，而**對獲利能力較高之 LSIs**，則應**關注其信用風險程度**。本項模型已作為**ECB 監管 LSIs 之日常監理工具之一**。

### (三) 企業違約預警系統

**企業部門生產活動為總體經濟變數(例如 GDP、就業等)之重要組成部分**。因此，分析企業部門財務健全程度及建構違約預警系統，將有助監理機關預測未來總體經濟變化情形。**Fed**於 2019 年發表報告<sup>61</sup>，探討如何**利用 AI 模型輔助預測美國各上市企業違約機率**。報告中使用資料包括：**美國上市企業財務報表資料、股市資料及總體經濟資料**。違約定義為各上市企業進入破產程序之申請日期。

該研究選擇**25 項已於相關文獻中證實可有效預測違約之企業層級變數**，包括 Tobin's Q、Kaplan-Zingales 指數等重要財務比率。**使用之 AI 演算法包括單層神經網路、支援向量機、隨機森林、梯度提升等 4 種方法**，模型訓練方法分為：(1)**樣本內預測**：將 1985 年第 1 季資料至 2018 年第 3 季資料，採違約樣本 10%與非違約樣本 90%之抽樣方式進行訓練及測試，訓練樣本及測試樣本相同，用以評估模型擬合能力；(2)**遞迴預測法**：將 1985 年第 1 季至 1988 年第 4 季資料作為訓練樣本，並用以預測後續數季之違約機率(測試樣本)。

在模型預測能力方面，**隨機森林模型無論在樣本內預測或遞迴預測 AUC 表現皆優於其他模型**。該研究爰以**隨機森林模型所估計之個**

---

<sup>61</sup> Pike et al. (2019).

別企業違約機率作為起點，採「由下而上」之角度建構全新的非金融企業部門財務狀況惡化(Non-Financial Corporate Health, **NFCH**)指數。

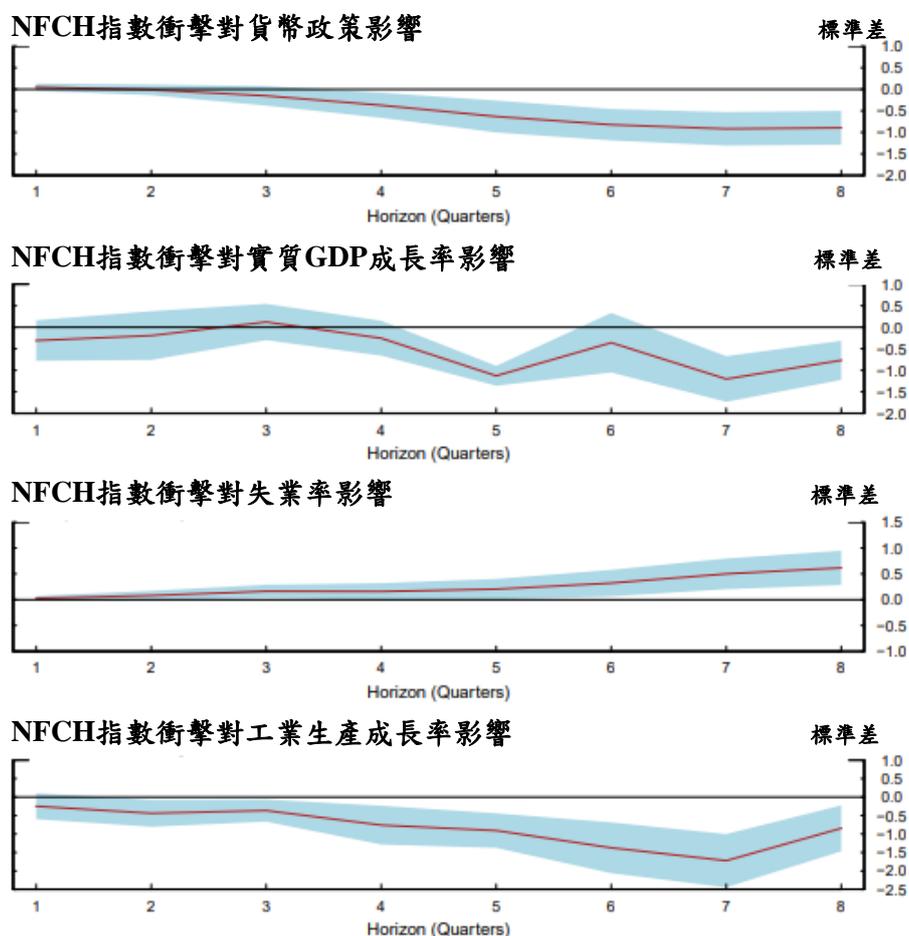
NFCH 指數由「資產規模加權之個別企業違約機率」、「違約機率偏度(skew)之季變動」及「違約機率標準差之季變動」等三項變數組成。該研究發現，當 **NFCH 指數上升超過歷史平均 2 個標準差時，總體經濟通常於 2 季內進入衰退**。若進一步將 NFCH 指數納入預測未來經濟表現之模型，預測殘差將明顯下降，顯示該指標**具備顯著的前瞻性資訊**，可有效提升對未來工業生產、就業人口、實質 GDP 及失業率等變數之預測準確度情形。

此外，該研究運用 Jordà (2005)<sup>62</sup>所提出之局部映射法(local projection method)，分析 NFCH 指數與各項總體經濟變數之關聯性，結果指出，當 **NFCH 指數上升時，將帶動實質 GDP 下降、失業率上升、工業生產下降**，並促使央行傾向採取寬鬆貨幣政策，導致**實質聯邦資金利率下降**(圖 9)，反之，實質 GDP、失業率或工業生產成長率等單一變數變化對 NFCH 指數影響較不顯著，顯示單一因素衝擊尚不足以改變企業整體財務健全程度。

---

<sup>62</sup> Jordà (2005).

圖 9：非金融企業部門財務狀況惡化指數衝擊  
對各項總體經濟變數影響



註：Jordà (2005) 衝擊反應函數 (Impulse Response Functions, IRFs) 係衡量實體經濟活動對 NFCH 指數出現一個標準差衝擊時的反應，每個模型皆包含 4 項反應變數，並分析其後 8 季變化情形。實質 GDP 成長率及工業生產成長率係採季變動資料，貨幣政策則指實質聯邦資金利率。

資料來源：Pike et al. (2019)。

#### (四) 金融危機預警系統

金融危機通常會帶來龐大的經濟與社會成本，例如 2008 年全球金融危機、2020 年新冠疫情引發之金融市場動盪等。然而，因金融危機發生頻率極低，其特性難以透過一般統計方法捕捉，且往往高度依賴專家在事後對危機之判定。因此，監理機關雖無法完全避免金融危機發生，但若能及早辨識風險累積跡象，便可及早採取措施(例如啟動逆循環資本緩衝等總體審慎政策)，以降低金融危機發生的可能性與嚴重程度。緣此，部分央行嘗試透過 AI 模型建置金融危機預警系統，

其使用的資料可分為**總體經濟資料**及**文字資料**兩大方面。

## 1. 總體經濟資料

ECB 於 2021 年發布報告<sup>63</sup>，使用 Jordà-Schularick-Taylor 總體長期資料庫，涵蓋 1870 年至 2016 年 17 個已開發經濟體之**總體經濟資料**、**金融市場數據**及**金融危機標註**，用以探討哪些經濟變數具有預測各國金融危機之能力，並評估國內及跨國變數間交互影響作用。

為及早辨識金融危機，該研究將**危機發生前 2 年標註為危機樣本**，並排除危機發生當年及其後 4 年，以避免危機後資料偏誤影響模型。此外，ECB 亦排除 1933 年至 1939 年經濟大蕭條期間數值，並採「國家及年份」配對為觀測值，用以預測**10 項國內變數**(殖利率曲線斜率、股價、消費、CPI、信用成長比率、債務負擔比率、投資、經常帳、公債及 M2)及**2 項自行定義之跨國變數**<sup>64</sup>(跨國殖利率曲線斜率及信用成長比率)**與個別國家發生金融危機之關聯性**。

使用之**AI 演算法**包括**決策樹**、**隨機森林**、**極限隨機樹(ERTs)**<sup>65</sup>、**支援向量機**、**神經網路**等 5 種方法，模型訓練方法分為：(1)**5 等分交叉驗證法**：將資料分成 5 個子集，反覆進行訓練及測試，特點為**以未來資料訓練模型**，可解決**危機稀缺性問題**，但較偏向探索性分析；(2)**遞迴預測法**：若要預測 T 年資料，則模型僅使用截至 T-2 年資料訓練，特點為**以歷史資料預測未來**，較符合**監理機關實務需求**。

在模型預測能力方面，不論是交叉驗證法或遞迴預測法，各類**AI 模型(除決策樹模型外)**之**AUC**皆高於**傳統邏輯迴歸模型**，僅**決策樹模型**有過度學習現象。ECB 亦採用 Shapley 值<sup>66</sup>分析各項經濟變數對

<sup>63</sup> Bluwstein et al. (2021).

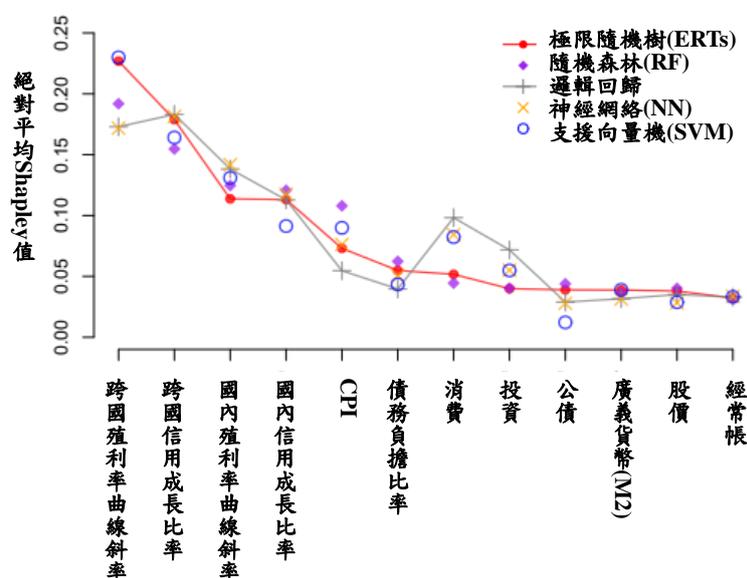
<sup>64</sup> 跨國變數定義為**預測國家以外之其他經濟體數值平均**。

<sup>65</sup> 見註 20。

<sup>66</sup> Shapley 值係由合作賽局理論大師 Lloyd Stowell Shapley 提出，用於評估參與合作賽局的每個玩家對於勝利的貢獻價值。在 AI 模型中則指**當某項變數被加入模型後，會為模型帶來多少額外預測能力**。

危機預測貢獻之相對程度(圖 10)，其中**跨國殖利率曲線斜率**、**跨國信用成長比率**、**國內殖利率曲線斜率**及**國內信用成長比率**等 4 項變數在 5 種 AI 模型皆為影響危機發生之重要因素，且當殖利率曲線趨於平坦甚至倒掛，以及信用成長比率快速攀升時，**危機發生機率將大幅上升**。此外，ECB 以 Shapley 迴歸探討國內及跨國變數間交互影響作用，研究發現**國內信用成長比率與跨國殖利率曲線斜率呈正相關**，即跨國殖利率曲線趨向平坦時，可能進一步擴大國內金融市場過熱情形，因而顯著提高危機發生機率。

圖 10：不同 AI 模型中各經濟變數之危機預測貢獻程度



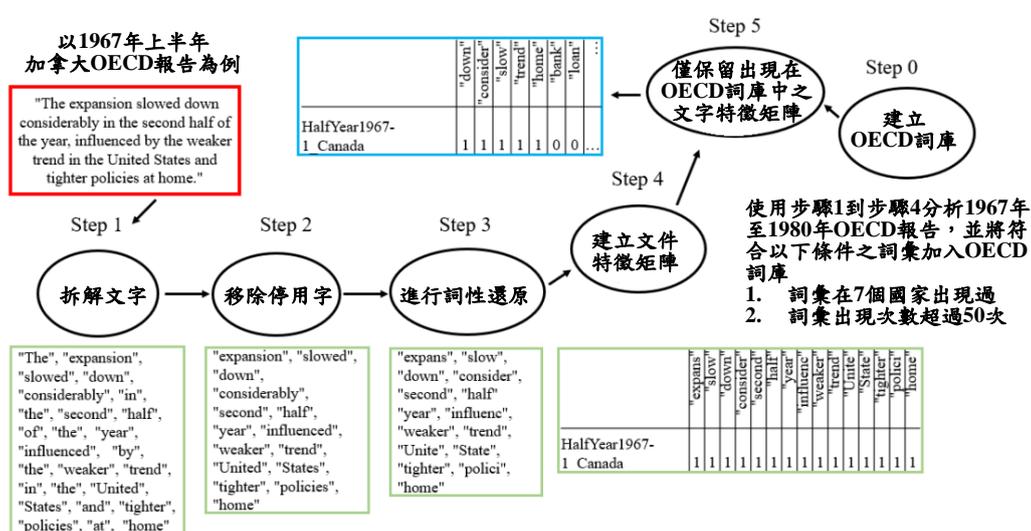
資料來源：Bluwstein et al. (2021)。

## 2. 文字資料

**文字資料在偵測金融危機上具有重要價值**。由於**官方經濟統計資料**通常具滯後性，**難以即時反映金融體系壓力**，文字資料可作為傳統量化資料之補充，並有效掌握市場情緒與潛在風險累積情形。透過自然語言處理(Natural Language Processing, NLP)技術，文字資料可轉化為結構化資料，並納入傳統邏輯迴歸或各類 AI 模型中，以提升危機預測準確度。

Fed 於 2023 年發布報告<sup>67</sup>，將 **OECD 各國經濟展望報告**、**路透每日新聞摘要**(Reuters Daily News Feed, RDNF)及 **IMF 第四條協議報告**等文字資料納入危機預測模型，並與**傳統股價波動率模型**、**情緒指標模型**進行**預測能力比較**。在將文字資料轉換為結構化資料時，須先進行多項資料前置處理作業，包括先移除出現頻率最高及最低的詞彙以建立核心詞庫，再移除停用字(stop word)<sup>68</sup>及進行詞性還原(lemmatization)，最後建立文件特徵矩陣，且僅保留詞庫出現文字(圖 11)。

圖 11：Fed 處理 OECD 報告等文字資料程序



資料來源：Chen et al. (2023)。

該研究主要採用 **3 份文字資料(表 2)**分別辨識不同文獻定義之**金融危機**：(1)利用 OECD 各國經濟展望報告辨識 24 個已開發經濟體是否會發生 Romer and Romer (2017)<sup>69</sup>定義之輕微危機以上事件；(2)利用路透每日新聞摘要辨識 62 個經濟體是否將發生 Laeven and Valencia (2013)<sup>70</sup>定義之銀行危機；以及(3)利用 IMF 報告辨識 39 個經濟體是否會發生 Laeven and Valencia (2013)定義之銀行危機。此外，Fed 採用兩種 NLP 驅動之 AI 演算法(**支援向量機及隨機森林**)，並將其**演算法**

<sup>67</sup> Chen et al. (2023).

<sup>68</sup> 停用字(stop word)係指在 NLP 技術中對語意貢獻較小而常被過濾掉的常見詞彙，例如「的」、「是」、「在」等。

<sup>69</sup> Romer and Romer (2017).

<sup>70</sup> Laeven and Valencia (2013).

結果平均後作為平均文字模型，據以衡量傳統股價波動率模型、情緒指標模型、平均文字模型及平均模型<sup>71</sup>等 4 種模型之危機預測能力。

表 2：Fed 報告使用之文字資料

文字資料	包含國家	資料頻率	訓練樣本	測試樣本
OECD 經濟展望報告	1981 年以前加入 OECD 之 24 個已開發經濟體	半年資料	1981-2004 年資料	2005-2012 年資料
路透每日新聞摘要 (RDNF)	62 個經濟體	由毫秒資料整理為月資料	1996-2004 年資料	2005-2017 年資料
IMF 第四條協議報告	39 個經濟體	年資料	1983-2004 年資料	2005-2017 年資料

資料來源：Chen et al. (2023)。

在模型預測能力方面，**OECD 經濟展望報告**因主要用於辨識已開發經濟體危機，故**平均模型之 AUC 表現最佳**；平均文字模型則次之；當危機嚴重程度提升時，**平均文字模型之 AUC 將超越平均模型**。研究結果顯示，平均模型因波動率模型本身可能受市場雜訊干擾而使預測能力下降。而在**包含較多新興經濟體之 RDNF 資料及 IMF 報告**，**傳統股價波動率模型 AUC 表現最佳**，其次為平均模型，反映新興經濟體文字資料可用性與完整度較低，使得**NLP 模型難以充分提取有效訊號**。此外，該研究透過 LIME 演算法<sup>72</sup>觀察個別詞組對模型預測之貢獻程度，常見**金融危機詞組**包括銀行(Bank)、貸款(Loan)、金融(Financial)及信用(Credit)，反映傳統金融危機常見之信用緊縮與銀行體系風險訊號。另非傳統金融危機(例如新冠疫情引發之金融危機)則由政府(Government)、金融困境(Financial difficulties)、財務支持(Financial support)與失業(unemployment)等詞組驅動。結果顯示，**文字資料可捕捉「危機類型」差異，並提供傳統量化資料無法呈現之細緻風險訊息**。

<sup>71</sup> 平均模型係股價波動率模型、情緒指標模型及平均文字模型等 3 種模型結果平均而得。

<sup>72</sup> 見註 30。

## 肆、央行業務應用 AI 之效益與挑戰

在全球金融環境快速數位化的背景下，央行面臨的資訊型態正變得更加龐大且複雜，包括高頻市場交易資料、逐筆申報資料、大量企業財務資訊，以及新聞、政策文件等非結構化文字內容。**傳統分析工具逐漸面臨限制**，而 AI 技術因具備非線性擬合能力、強大資料處理性能與情境分析能力，正成為央行提升研究分析與強化政策工具的重要利器。然而，**導入 AI 的同時也伴隨資料品質、模型可解釋性、人才需求與外部依賴等多重挑戰**，若未妥善因應，可能反而削弱政策執行效能。以下分別從 AI 帶來的效益與挑戰兩個面向(表 3)進行說明。

### 一、AI 對央行之效益

#### (一)強化資料處理能力與提升資訊品質

AI 能同時處理龐大、高顆粒度與多型態資料，使央行在資料管理方面大幅提升效率。AI 模型可自動掃描申報資料、監理資料及市場交易資料中的錯誤模式，辨識缺漏值、格式異常或不合邏輯的資料點，**減輕人工檢查負擔**。透過 AI 輔助建立一致且可追溯的資料處理流程，有助**提升央行資料治理架構之完整性，使後續研究與監理分析有更健全的資料基礎**。

#### (二)提供前瞻性風險偵測能力

AI 在辨識金融脆弱性方面展現高度價值，能捕捉傳統統計難以偵測的非線性風險累積過程。透過整合銀行財務資料、企業財報、市場波動資訊及外部新聞，AI 可提前呈現金融機構、企業部門或金融市場之風險上升訊息。多國央行研究顯示，**AI 建構之預警系統通常可在危機爆發前提出警訊，使監理機關能更早啟動逆循環資本緩衝或進行針對性監理**，降低系統性風險擴散之可能性。

### (三)提升總體經濟預測準確性與穩健度

AI 能分析新聞資訊、股票收益率、商品價格細項及各類總體指標等多元資料型態，以強化 GDP、通膨率、失業率與景氣循環轉折點之預測能力。相較於傳統線性模型，**AI 特別擅長處理經濟環境急遽反轉情境**，例如金融危機或疫情期間，能更精準捕捉快速變動的經濟結構，**使決策者能及時調整貨幣政策方向，提升政策反應速度。**

### (四)強化文字資料分析能力並提升前瞻性資訊價值

NLP、BERT 與生成式 AI 之興起，使央行能更快分析大量非結構化文字，包括新聞報導、央行聲明、會議紀錄、監理文件與市場調查報告等。多國央行研究皆顯示，文字資料因其兼具描述性作用及影響性作用<sup>73</sup>，比傳統官方統計資料更具前瞻性，且**文字資訊中隱含的語氣、主題變化與語意內涵，可在經濟或金融危機尚未反映於數據前即呈現警訊**。例如新聞中新增的負面詞彙、央行聲明篇幅增加或語氣轉趨審慎，均可能顯示市場情緒惡化或政策方向調整的訊號。NLP、BERT 與生成式 AI 技術讓央行能更快速掌握該等文字線索，作為**研判風險與政策評估之重要補充**。

### (五)增進政策研究深度並改善決策流程

AI 技術可支援情境分析、壓力測試與政策影響評估，協助央行更完整建構政策效果之推估架構。例如 AI 可輔助探索貨幣政策傳遞過程之非線性路徑或發掘金融市場行為中可能存在的結構變化。AI 亦有助**改善監理科技之效率**，使央行能更快速偵測系統性風險與提升監理實務之即時性。整體而言，AI 能讓政策分析更加精準，並使**決策過程更具數據基礎**。

<sup>73</sup> 描述性作用係指文字資料作為描寫和反應事件現狀之價值，不因受眾多寡而有所影響，影響性作用則指文字資料本身可能激發或促使金融事件發生，例如報導個別銀行財務狀況不佳導致擠兌，此影響力會受受眾多寡影響。

## 二、AI 對央行之挑戰

### (一) 資料雜訊、模型偏誤與過度學習風險

AI 模型對資料品質高度敏感，若訓練資料來源不一致、資料未經充分清理或存在偏誤，其輸出結果即可能失真。此外，為追求較高的預測準確度，**部分模型可能出現過度學習，導致在訓練樣本上表現優異，但在新資料或新經濟情境下預測能力下降**。AI 模型的預測表現也可能因資料特性不同而有差異，以 BdF 案例為例，不同 AI 模型在 6 家銀行的產出表現迥異，顯示 **AI 模型的穩健性與普適性仍具限制，使央行在模型選擇上必須格外謹慎**。

### (二) 模型可解釋性與因果推論能力不足

AI 模型常存在「黑盒子」問題，無法清晰說明模型推論背後的邏輯，這對強調公開透明與政策正當性的央行而言是一大挑戰。央行貨幣政策與監理政策均需基於可解釋且可驗證的依據，若模型無法清楚呈現因果關係，將不利於政策溝通。此外，**AI 擅長辨識相關性，但不具備完整因果推論能力**(Buckmann et al (2021))，**與央行在政策評估中所需之因果邏輯有所差距**。因此，央行在使用 **AI 時必須保留最終決策權**，並結合 LIME、Shapley 值等解釋工具，以確保模型輸出結果可被理解與利用。

### (三) 技術人才缺乏、成本高昂與外部供應商依賴

央行在 AI 相關技術上仍普遍面臨內部能力不足的問題。資料工程、模型訓練、系統部署與模型監理皆需大量專業人才，而**央行在人事制度與薪資結構上難以與大型科技公司競爭**，導致不易留住高階資料科學人才。此外，建立 AI 所需之資料伺服器、運算資源與軟體工具成本高昂，使央行不得不依賴外部供應商。然而，AI 技術高度集中於少數科技巨頭，**若外部供應商系統故障或遭受攻擊，可能造成央行**

營運中斷，甚至引發金融穩定與聲譽風險。

#### (四)資料治理<sup>74</sup>、資安風險與模型治理<sup>75</sup>要求提高

AI 技術使用大量敏感性資料，因此央行需強化資料治理、加密機制、資安防護與模型監理流程。AI 模型部署後仍需定期監測其效能、偏誤與穩健性，並確保隨著金融環境變化持續調整模型。同時，資料跨機關共享與跨境資料流動亦可能引發法令遵循與隱私權問題，央行需建立一套完善的內控與風險管理架構，以確保 AI 技術能在可控風險內運作。

表 3：AI 對央行之效益與挑戰

面向	效益	挑戰
資料處理與品質管理	<ul style="list-style-type: none"> <li>• AI 能快速處理大量、高顆粒度與多型態資料</li> <li>• 協助偵測異常值、缺漏值與申報錯誤，提升資料治理效率與即時性</li> </ul>	<ul style="list-style-type: none"> <li>• AI 對資料品質高度敏感，若資料雜亂、偏誤或未充分清理，模型輸出將受影響</li> <li>• 難以取得標準化、高品質長期資料</li> </ul>
風險偵測與預警能力	<ul style="list-style-type: none"> <li>• 可捕捉非線性關係，提前辨識金融機構、企業部門與金融市場脆弱性</li> <li>• 有助強化總體審慎監理前瞻性</li> </ul>	<ul style="list-style-type: none"> <li>• 可能存在過度學習問題</li> <li>• 模型在不同經濟情境、不同金融機構間表現不一致，無單一模型能於所有情境皆具優勢</li> </ul>
總體經濟預測能力	<ul style="list-style-type: none"> <li>• 利用新聞資訊、股票收益率、商品價格細項等多元資料源，強化預測能力</li> <li>• 提升 GDP、通膨、失業率及景氣循環預測之準確性與穩健度</li> </ul>	<ul style="list-style-type: none"> <li>• 高度依賴資料量、資料品質與可得性，模型在極端情境下仍可能失真</li> <li>• 難以解釋變數間之因果關係</li> </ul>
文字資料分析能力	<ul style="list-style-type: none"> <li>• NLP、BERT 與生成式 AI 能快速提取新聞、報告與央行聲明中隱含之語意與情緒變化</li> <li>• 有助提前掌握市場情緒與危機訊號</li> </ul>	<ul style="list-style-type: none"> <li>• 新興市場或非英語資料可得性較低，資料品質參差不齊</li> <li>• 生成式 AI 容易產生幻覺</li> </ul>

<sup>74</sup> 資料治理包括資料品質管理、標準化與結構化、資料權限與存取管理、資料安全與資安風險管理等，其核心目的在於確保資料品質與資料流程透明化，使資料能作為決策與模型分析之可靠基礎。

<sup>75</sup> 模型治理係指使用者對模型之設計、開發、使用、持續監控與驗證所建立的管理制度與流程，旨在確保模型之穩健性、可解釋性、透明度與合規性，避免模型錯誤影響政策判斷。

面向	效益	挑戰
政策研究與決策流程	<ul style="list-style-type: none"> <li>• AI 可支援情境分析、壓力測試、政策影響評估</li> <li>• 有助提升政策工具的精準度與即時性</li> </ul>	<ul style="list-style-type: none"> <li>• 模型可解釋性不足，不利政策溝通</li> <li>• 部分模型屬「黑盒子」，難成為貨幣政策與監理政策之唯一參考依據</li> </ul>
技術能力與作業風險	<ul style="list-style-type: none"> <li>• 可利用 AI 強化監理科技(Suptech)與法遵科技(Regtech)功能，強化技術分析能力</li> <li>• 提高監理效率、作業自動化與偵測異常能力</li> </ul>	<ul style="list-style-type: none"> <li>• 中央銀行技術人才不足、基礎建設成本高</li> <li>• 對外部供應商依賴程度增加，IT 故障或資安事件風險升高</li> </ul>
資料治理與法令遵循	<ul style="list-style-type: none"> <li>• AI 提升政策分析之資料基礎，促進科學化決策</li> </ul>	<ul style="list-style-type: none"> <li>• 需建立健全資料治理、模型監控、資安管理與法遵架構</li> <li>• 跨國資料合作涉及法令遵循與隱私權議題</li> </ul>

資料來源：作者整理。

## 伍、結論與建議

### 一、結論

#### (一)AI 技術具有處理非結構化資料、即時預測及強化風險辨識等應用效益

AI 能夠整合並分析龐雜且非結構化的資訊來源，如新聞文字、社群輿情或企業財報，協助央行得以更全面掌握潛在的經濟與金融風險。國際研究顯示，新聞資訊具有前瞻性，可在官方總體經濟指標尚未公布前，作為即時預測的資料基礎。若再結合 AI 模型的高速運算與特徵擷取能力，能協助決策者及早掌握市場動態，並即時採取因應措施，降低外部衝擊的影響。

此外，AI 技術在異常偵測與風險評估方面亦展現重要功能。透過 AI 模型自動辨識高維度資料中的不尋常模式與異常變化，可及早辨識潛在風險來源；而 AI 模型對多種量化與質化資訊的動態分析，亦有助於提升預警系統的準確性。整體而言，AI 技術具有補強現行央行監測市場與控管風險工具之潛力，將有助提升其監測金融情勢與維持金融穩定之能力。

#### (二)各類模型特性與適用情境不同，無單一模型能在所有情境下皆保持最佳表現

不同 AI 模型在運算架構、訓練資料需求及可處理問題形態方面各具特長，故其表現往往受資料結構與應用目的影響而呈現差異。傳統統計方法或機器學習模型在樣本較少、資料結構相對單純時，通常具有較佳的穩定性與可解釋性，能提供較為一致的分析與預測結果；深度學習模型則擅長處理較複雜的非線性關係與高維度資料，能捕捉更多潛在特徵，但對資料品質與資料量高度敏感，若資料量不足、雜訊比例偏高或前置處理不完善，則模型易出現過度學習或預測偏誤等

問題。

近年興起的**生成式 AI 模型**在理解語意、彙整跨資料來源訊息及生成內容方面較具優勢，**特別適用於處理政策文本、新聞語料或其他非結構化資料**。然而，若應用場域中資料結構單純，或分析目的不涉及複雜語意分析或內容生成，其所能帶來的附加價值便相對有限。整體而言，從目前主要央行對 AI 相關應用之研究可看出，**無單一模型能在所有情境下皆保持最佳表現**。模型的表現往往取決於資料型態、分析與預測目標，以及可解釋性要求等多項因素，**如何整合不同模型的優勢，採取混合式架構與多模型協作的策略，以發揮互補效果，提升分析的準確性與穩健性**，將是發展 AI 應用的重要方向。

### (三) 央行應用 AI 仍面臨模型可解釋性、資料品質敏感性與內部能力不足等挑戰

儘管 AI 能提升市場監測效率與分析深度，但其**模型運作邏輯**仍存在**透明度不足**的問題，決策過程透明度有限，**使預測結果難以解釋並轉化為具體的政策依據**。目前主要央行的 AI 應用仍以**機器學習模型為主**，雖有部分央行嘗試進行深度學習與生成式 AI 模型的相關應用研究，但多僅用於文件語意與情緒分析、主題分類等輔助決策層面，尚未廣泛運用於核心預測或政策評估模型。

此外，**資料來源的完整性與一致性將直接影響模型表現**，且**模型越複雜，對資料品質的敏感性越高**，稍有雜訊即可能導致預測偏誤、過度學習或穩健性不足。因此，央行推動 AI 應用，需仰賴**具備專業資料處理能力的人才**，透過資料清理、缺漏值填補與變數轉換等方式，以確保模型輸入的資料品質，且**強化內部資料治理架構及發展 AI 專業人才培育**。另考量央行內部人力配置在短期內難以涵蓋所有領域，建立**外部廠商協作與風險控管機制**，以降低技術依賴與外部營運風險，亦為央行未來發展 AI 應用的重要課題。

## 二、建議

### (一) 央行應建立以人為本的 AI 協作模式

AI 技術擅長從大量資料中萃取相關性，但缺乏真正的因果推論，且 AI 技術亦不具備央行員工對經濟理論、金融監理與法規、金融市場運作等專業知識，因此央行在導入 AI 技術時，**應建立以人為本的 AI 協作模式，使 AI 成為輔助分析的工具，而非取代人類專業判斷的決策者**。例如由 AI 技術輔助資料處理，並由央行員工在**應用 AI 技術的各個環節**(理解現有資料、進行經濟建模及預測分析等)**進行結果檢視**。再者，央行員工之專業知識除有助提升模型效能及適用性外，亦能降低 AI 在資訊不足時可能產生的錯誤推論、偏誤判斷或幻覺問題，俾將模型應用於央行特定任務。

此外，大語言模型興起雖可協助央行提升文件撰寫效率，如生成新聞稿，進行語句潤飾、多語翻譯及語氣一致化，以提升對外溝通效率，然而，此類模型可能受訓練資料偏誤影響，**缺乏普世價值觀及可能隱含歧視等因素**，亦可能**生成不精確或具誤導性的內容**，故仍須透過人為專業判斷進行檢視與修訂，以確保資訊之正確性與政策一致性。綜言之，**AI 的價值在於輔助而非取代人類智慧**，央行之 AI 應用應以「專業」為核心，「可解釋性」為原則，建立人機協作架構，讓 AI 成為強化金融穩定和政策判斷的助力。

### (二) 央行應以務實漸進方式導入 AI 技術，並強化 AI 相關風險之控管

為確保 AI 應用之穩健性，央行在導入 AI 技術時，應採務實漸進的導入策略，**先聚焦低風險領域**(例如協助提高員工生產力、內部流程自動化等)，**再拓展至支援申報資料處理及經濟分析等**，**並應持續發展可解釋性工具**，以維持政策評估過程之透明度及社會信任程度。

此外，為強化本行對 AI 相關風險之控管，宜參酌國際組織所提

建議，從風險辨識、評估流程建置、既有治理架構調整，以及資通安全與隱私權保護等四大面向著手<sup>76</sup>。其主要重點包括：(1)明確界定 AI 風險概況：央行應依據其策略目標，制定對 AI 技術的風險承受能力、(2)建立 AI 專案評估流程：成立跨部門團隊以評估 AI 專案的可行性，確保其符合策略目標及風險偏好、(3)使用並調整現有治理架構：將 AI 風險管理整合至現有流程，以釐清各部門角色及責任，以及(4)著重資訊安全管理及隱私權保護：由於 AI 模型需存取大量內部資料且透明度有限，資訊之機密性、完整性、可用性及隱私保護等將益形重要。

### (三)加強跨央行合作及分享導入案例，發揮加乘效果

AI 技術屬新興技術，在導入時應留意其對央行可能帶來之風險，例如可解釋性不足、個資保護及營運風險等，因此**瞭解各國央行導入 AI 之治理架構與實務流程，對本行在規劃 AI 應用策略時具有高度參考價值**。近年來，BIS 及 IMF 等國際組織持續透過舉辦研討會或論壇，以及其附屬創新中心(Innovation Hub)執行案例研究與技術實驗等方式，促進各國央行分享 AI 導入經驗。相關主題包括資料治理、模型治理、可解釋性工具發展、文字分析技術應用、監理科技(Suptech)方案及風險評估方法等，以期國際間逐步形成以 AI 技術應用為核心之合作網絡。

為充分發揮央行合作之加乘效果，**本行**應積極參與各項國際組織與央行之跨國會議，汲取**主要央行導入 AI 技術之實務經驗**，並定期蒐集、整理國際案例與研究成果，作為本行規劃 AI 應用之參考基礎，從而制定更能符合我國金融體系特性之 AI 發展策略。

---

<sup>76</sup> 參見 BIS (2025a)。

## 附錄、全球主要央行運用AI之研究案例

### 申報資料及金融市場異常偵測

應用類別	機構名稱	研究主題及成果	應用 AI 技術
申報資料及金融市場異常偵測	ECB	ECB 之貨幣市場統計資料因具有眾多類別變數且分布不對稱之特性，爰較難進行資料品質監測。ECB 透過 <b>多重對應分析</b> 將類別變數轉換為數值變數， <b>再利用 ML 模型找出異常值</b> ，並將 <b>多種演算法結果整合至工作流程</b> ，藉以改善現行流程效率(Accornero and Boscaroli (2021))。	ML : WLS Regression、IF、 HDBSCAN、 XGBoost
	BIS	<p>1. Aurora 計畫係透過<b>分析跨國匯款資料合成交易資料集</b>，探討 ML 模型對洗錢防制偵測之有效性，並於 2023 年完成初步研究。研究結果顯示，<b>ML 模型相較傳統規則導向型監控可偵測更多可疑交易並減少誤報機率</b>，納入跨國資料時，ML 模型效率將進一步提升(BIS (2023))。</p> <p>2. Hertha 計畫旨在<b>使用交易系統之合成資料集及 AI 模型</b>，瞭解進行交易系統分析是否有助銀行或支付服務提供商(payment service providers, PSPs)偵測更多可疑交易。研究結果顯示，<b>PSPs 使用支付系統分析結果可發現更多可疑帳戶，並有助其偵測新型金融犯罪模式</b>(BIS (2025b))。</p>	ML : Logistic Regression、ANN、 GNN、IF  ML : XGBoost、IF DL : UniTTab

應用類別	機構名稱	研究主題及成果	應用 AI 技術
	德國央行	德國央行建構一套ML工作流程以處理其蒐集之高顆粒度統計資料，例如 MFI 利率統計及貨幣市場統計(MMSR)等，工作流程包括資料預處理、利用 ML 模型標記異常值、進行模型可解釋性探討及整合多項演算法結果。研究認為 ML 模型有助於偵測錯誤並提高資料品質，透過主動學習及可解釋性整合專家意見，將進一步提高工作流程效率 (Cagala et al. (2021))。	ML : IF 、 kNN 、 DBSCAN 、 LOF 、 FINCH 、 One Class SVM 、 Autoencoder 、 PCA & rPCA <sup>77</sup> 、 HBOS 、 ARIMA
	俄羅斯央行	使用 ML 模型進行申報資料之自動化驗證及異常監控，例如驗證借款人申報資料代碼是否有誤、檢測借款利率資料異常值及分析借款人是否屬於中小企業等，並指出在處理大型、複雜資料集時，需要仔細選擇模型、評估指標，並在必要時進行樣本平衡處理 (Diachkov (2021))。	ML : DT 、 XGBoost 、 Logistic Regression 、 NN 、 RF
	葡萄牙央行	針對大量且逐筆之中央信用貸款登錄系統資料，檢視其是否有異常登錄(已還清但仍有餘額、無連續登錄等)、分析類別變數資料品質，並利用孤立森林(IF)演算法找出貸款金額異常值 (Faria da Costa et al. (2021))。	ML : IF

<sup>77</sup> 主成分分析(Principal Component Analysis, PCA)係指將多維資料轉換成少數幾個能代表大部分變異型態的新變數方法，而 rPCA 為改良版 PCA，可同時轉換資料主要結構，並分離異常值。

## 總體經濟與金融分析

應用類別	機構名稱	研究主題及成果	應用 AI 技術
總體經濟指標之分析及預測	Fed	<ol style="list-style-type: none"> <li>1. 運用 <b>ML 模型</b>找出影響「消費者通膨預期」與「專業機構通膨預期」的關鍵經濟指標變數。結果顯示，兩種通膨預期分別受到不同的經濟指標影響。若驗證兩種通膨預期係因資訊效率不足而產生偏離理性之預期結果，即使藉由改善資訊偏誤來提升通膨預測表現，其效果亦不顯著(Berge (2017))。</li> <li>2. 運用 <b>ML 模型</b>辨識美國聯準會《褐皮書》中與供應鏈瓶頸相關的詞彙，再透過<b>深度學習(DL)</b>模型進行情緒分析，進而建構「<b>供應鏈瓶頸情緒指數 (Supply Chain Bottleneck Sentiment, SCB Sentiment)</b>」。研究結果顯示，<b>SCB 情緒指數與 CPI 月增率呈顯著正相關</b>(Soto (2023))。</li> <li>3. 蒐集美國供應管理協會(ISM)每月發布之「<b>製造業商業報告</b>」中，有關<b>製造業採購經理人的開放式問卷調查資料</b>，運用詞典分析法與 <b>DL 模型</b>分別進行情緒分析，進而建構<b>情緒指標以預測製造業產出</b>。研究結果顯示，金融穩定詞典與 <b>DL 模型</b>判斷文字情緒之表現最佳，而基於<b>開放式問卷文字</b>所建構之<b>情緒指標</b>，也與 <b>ISM 擴散指數(diffusion index)</b>及<b>製造業生產指數</b>的變化相當一致(Cajner et al. (2024))。</li> </ol>	<p>ML : Boosting</p> <p>ML : Word2Vec DL : BERT</p> <p>DL : BERT</p>

應用類別	機構名稱	研究主題及成果	應用 AI 技術
		<p>4. 選定<b>失業率</b>為經濟活動衡量指標，透過 <b>ML 演算法</b>選擇出最能預測失業率之金融變數，<b>建構金融狀況指數(Machine Learning-Financial Conditions Index, ML-FCI)</b>。研究發現，<b>ML-FCI 能夠有系統地選擇金融變數資料定態性<sup>78</sup>轉換方法</b>(如使用月變動百分比或年變動百分比)，提高其對失業率的預測能力，而採用<b>隨機森林(RF)技術亦能夠捕捉非線性特徵</b>(如金融狀況緊縮時，失業率通常大幅上升；寬鬆時，失業率下降幅度則較溫和)(Kiley (2020))。</p>	<p>ML：LASSO、Elastic Net、RF</p>
	ECB	<p>1. 蒐集法國、德國、義大利及西班牙之<b>每日新聞</b>，<b>建立情緒指標</b>，再透過 <b>ML 模型即時預測</b>前揭四國之<b>實質 GDP 季增率</b>。研究顯示，使用每日新聞資訊能顯著提升危機時期及每季初期總體經濟指標尚未公布前之 GDP 預測準確性；<b>RF、Boosting 及 NN 等非線性 ML 模型在 2008 年全球金融危機及 2020 年疫情期間之預測表現較佳</b>，較能有效捕捉 GDP 的急遽變動(Ashwin et al. (2021))。</p> <p>2. 運用 <b>ML 模型預測歐元區通膨</b>，輸入變數包含通膨預期、成本壓力、實體經濟活動及金融變數等範疇。研究結果顯示，ML 模型之預測結果與目前 ECB 使用之「輔以專家判斷之線性預測模型」大致相同(Lenza et al. (2023))。</p>	<p>ML：Ridge、RF、Boosting、NN</p> <p>ML：Quantile Regression Forests</p>

<sup>78</sup> 定態性(stationarity)係指資料具有穩定的統計特性，以利進行統計分析或預測。為使資料達到定態性，通常會採差分、轉換為變動百分比或成長率等方式進行資料轉換，而轉換後的資料頻率(如月度、季度或年度變動比)將直接影響資料的預測能力，ML-FCI 相較於傳統模型，較能夠有效選擇適合的資料頻率，提升預測表現。

應用類別	機構名稱	研究主題及成果	應用 AI 技術
		<p>3. 運用<b>每週快速消費品細項價格資料</b>，即時預測當月各商品細項、主要商品群組及整體物價的通膨率。研究發現，<b>ML 模型的即時預測表現優於傳統 AR 模型及 Bloomberg 預測</b>(Beck et al. (2024))。</p> <p>4. 採用 <b>ML 模型</b> 篩選德國、法國、西班牙及義大利的新聞文章中有關經濟不確定性之詞彙，再將文章依據各政策不確定性因素進行分類(如財政、貨幣、政治、地緣政治、歐盟規範等，類別名稱由專家定義)，藉此<b>分析經濟不確定性指標(EPU)的組成因素，以及各因素對企業投資之影響</b>。研究發現，各類不確定性因素對總體經濟的影響方式及對各國的影響程度皆有不同(Azqueta-Gavaldón et al. (2020a))。</p> <p>5. 以 <b>ML 模型</b> 篩選中國相關新聞報導中有關金融風險之詞彙，分析各金融風險來源，並找出關鍵風險來源<b>建構中國金融風險指標</b>。研究顯示，該指標能<b>即時捕捉中國的金融風險事件</b>，而<b>中國金融風險衝擊具有全球擴散效應</b>(Al-Haschimi et al. (2023))。</p>	<p>ML : OLS、Ridge、LASSO、Elastic Net</p> <p>ML : Word2Vec、LDA</p> <p>ML : Word2Vec、LDA</p>
	BoE	<p>1. 蒐集英國<b>每日新聞</b>，計算每月有關<b>市場情緒及不確定性之詞彙累計數</b>，再透過 <b>ML 模型</b> 預測如 GDP、消費者物價指數(CPI)、失業率、企業投資、家庭消費、生產指數(IOP)、服務業指數(IOS)、金融壓力指數及英國金融情勢指數等<b>總體經濟指標</b>。研究顯示，<b>新聞</b></p>	<p>ML : Ridge、LASSO、Elastic Net、SVM、RF、NN</p>

應用類別	機構名稱	研究主題及成果	應用 AI 技術
		<p>報導文字具有前瞻性，能有效預測未來 3 至 9 個月之總體經濟指標；而 Ridge 及 NN 模型對所有特徵值皆賦予一定權重，預測表現較佳 (Kalamara et al. (2020))。</p> <p>2. 利用英國國家統計局(ONS)公布之 CPI 商品細項價格指數，預測英國的總體 CPI、核心 CPI 及服務業通膨。研究結果顯示，Ridge、LASSO、Elastic Net 在通膨上升或下降趨勢時，預測未來 6 至 12 個月 CPI 之效果較佳；若納入總體經濟指標進行預測，則以 SVM、RF 及 NN 等非線性 ML 模型在通膨上升期且預測期為 1 至 3 個月時表現較佳。非線性 ML 模型在經濟循環轉折或極端事件期間亦有較佳的預測能力 (Joseph et al. (2022))。</p> <p>3. 運用神經網路菲利普曲線模型(Neural Network Phillips Curve)，解析推動英國服務類通膨的主要因素。研究者將輸入變數分為名目慣性、通膨預期、輸入成本與產出缺口等四類，並分別建構對應的子網絡以進行模型訓練，再整合各子模組之輸出值，形成預測結果 (Buckmann et al. (2023))。</p>	<p>ML：PCA、PLS、Ridge、LASSO、Elastic Net、SVM、RF、NN</p> <p>ML：NN</p>
	BIS、ECB	<p>以 ML 及大型語言模型(BERT 及 GPT)進行 ECB 貨幣政策記者會新聞稿之語意分析，以預測歐元區不含能源與食品的調和消費者物價指數(HICPex)。研究結果顯示，納入新聞稿資訊能有效提升預測準確</p>	<p>ML：Word2Vec</p> <p>DL：BERT</p> <p>GenAI：GPT</p>

應用類別	機構名稱	研究主題及成果	應用 AI 技術
		度，而 <b>Word2Vec</b> 與大型語言模型之預測表現並無顯著差異(Araujo et al. (2025))。	
	IMF	蒐集多項 <b>總體經濟相關指標</b> ， <b>即時預測</b> 奧地利、匈牙利、愛爾蘭、馬爾他、波蘭及葡萄牙等 6 國之 <b>實質 GDP 季增率</b> 。研究結果顯示， <b>ML 模型在市場高度波動時(如疫情期間)預測表現較佳，較能捕捉經濟活動轉折點</b> (Dauphin et al. (2022))。	ML：Ridge、LASSO、Elastic Net、SVM、RF、NN
景氣循環之分析及預測	Fed	運用 <b>ML 模型</b> 檢視各項 <b>金融市場與總體經濟變數對美國經濟衰退的預測能力</b> ，並與傳統的 Probit 邏輯迴歸模型進行比較。在較嚴謹的巢狀時間序列(Nested Time-Series, NTS)交叉驗證 <sup>79</sup> 結果中，ML 模型表現普遍不如 Probit 模型，推測可能與資料量不足及資料具高度時間相關性等因素有關。惟 <b>ML 模型</b> 的價值在於其能夠 <b>捕捉多項經濟變數間複雜的交互關係與經濟衰退訊號之關聯性</b> (Puglia and Tucker (2020))。	ML：NN、SVM、RF、Boosting (XGBoost、LightGBM)
	ECB	藉由統計方法判別 <b>S&amp;P500 各成分股間每日報酬率的關聯性</b> ，建構 <b>動態的股票報酬關聯網絡</b> ，再透過 <b>ML 方法</b> 即時預測景氣循環階段。研究發現，ML 模型能有效預測 <b>景氣衰退期間及景氣循環週期之轉折點</b> ，並能夠辨識對景氣循環變化較敏感之產業(Azqueta-Gavaldón et al.	ML：SVM、Naive Bayes、Logistic Regression

<sup>79</sup> 巢狀時間序列(Nested Time-Series, NTS)交叉驗證是一種針對時間序列資料設計的驗證方法，旨在確保模型僅使用過去資料進行預測，避免因資料洩漏(data leakage, 即模型提前看到未來的資料)而高估實際預測表現。詳細說明請參見：Puglia and Tucker (2020)。

應用類別	機構名稱	研究主題及成果	應用 AI 技術
		(2020b))。	

### 支援貨幣政策與政策傳遞研究

應用類別	機構名稱	研究主題及成果	應用 AI 技術
央行關注議題分析	Fed	分析 2010 年 1 月至 2024 年 6 月間之 <b>FOMC 會議紀錄</b> ，由 <b>專家訂定主題</b> (實體經濟活動、勞動市場、通膨、金融穩定、金融發展、聯邦資金利率、資產負債表及金融發展)，再透過 <b>生成式 AI 分類</b> ，以 <b>探討 FOMC 會議討論內容之演變</b> (Dunn et al. (2024))。	GenAI：GPT、Claude、Gemini、
	IMF	以 <b>ML 模型</b> 計算 2003 年至 2012 年間所有 <b>FOMC 會議紀錄的詞彙機率分布及主題分群</b> ，再透過 <b>專家判讀各主題群之經濟意涵</b> (包含預測、經濟模型、政策聲明、風險、銀行業、投票決議、經濟活動及對外溝通等八類)，以 <b>分析 Fed 此期間對各項主題的關注程度及演變</b> (Carcel-Villanova and Edison (2021))。	ML：LDA
央行溝通效果分析	BoE	運用 <b>ML 技術分析 BoE 發布資訊前後</b> ， <b>新聞報導內容之變化</b> ，探討 BoE 如何 <b>調整溝通方式</b> ，以有效 <b>提升其內容在新聞媒體的報導程度</b> ，進而 <b>改善對公眾的溝通效果</b> (Munday and Brookes (2021))。	ML：Word2Vec、LASSO

## 風險評估及預警系統

應用類別	機構名稱	研究主題及成果	應用 AI 技術
金融機構壓力測試	BdF	模擬銀行在使用內部評等法計算資本要求時，是否有採用 ML 模型取代現行邏輯迴歸模型之誘因(例如減少風險性資產提列)。研究結果顯示，在辨識企業評等等級方面，神經網路(NN)及邏輯迴歸模型表現最佳，各模型在預測企業違約機率差異不大，然而 <b>NN 模型可大幅減少風險性資產提列，使銀行更有誘因採用 ML 模型</b> (Fraisie and Laporte (2021))。	ML：NN、RF、GB、Ridge
金融機構經營危機 預警系統	ECB	使用銀行申報之監理報表、監理機制蒐集之質化資料及總體經濟指標， <b>預測 ECB 定義中重要性較低銀行(例如儲蓄銀行、合作銀行)是否會產生經營危機</b> ，經過多次試驗後產生一個包括 12 項變數及 19 個節點的創新決策樹(DT)模型。研究結果顯示， <b>DT 模型雖與 LASSO 邏輯迴歸模型(基準模型)預測能力相當，但 DT 模型未預測到經營危機比率低於基準模型</b> (Bräuning et al. (2019))。	ML：DT、LASSO
	BoE	使用 BoE 歷史銀行監理資料庫之銀行財務資料及英國總體經濟資料，進行 2 種線性模型及 4 種 ML 模型分析，以預測英國各家銀行是否會產生經營危機(遭評分 8 分以上之高風險銀行)。研究結果顯示， <b>RF 模型預測能力遠高於其他演算法，且預測結果最貼近實際情形</b> ，此外， <b>透過整合多種演算法結果可進一步提高預測能力</b> (Suss and	ML：kNN、RF、GB、SVM

應用類別	機構名稱	研究主題及成果	應用 AI 技術
		Treitel (2019))。	
企業違約預警系統	Fed	使用美國多家資料庫之上市企業財務報表及股市資料、美國總體經濟資料，以預測美國各上市企業違約機率，並將個別企業違約機率進行加權處理， <b>建構一項全新的非金融企業部門財務狀況惡化(NFCH)指數</b> 。研究結果顯示， <b>RF 模型預測個別企業違約機率能力高於其他演算法</b> ，而以 RF 模型結果建構之 <b>NFCH 指數亦有助預測未來工業生產、就業人口、實質 GDP 及失業率情形</b> (Pike et al. (2019))。	ML：NN、SVM、RF、GB
	俄羅斯央行	使用 <b>俄羅斯央行支付系統資料改善俄羅斯央行現行預測企業違約機率模型之準確度</b> ，例如以所得稅資料彌補企業營收資料缺口等。研究結果顯示，不論是 <b>邏輯迴歸模型或 RF 模型</b> 在使用支付系統資料後，均可 <b>有效改善</b> 原始模型準確度(Buzanov and Shevelev (2021))。	ML：Logistic Regression、RF
金融危機預警系統	ECB、IMF	1. ECB 與 IMF 合作建構一份 1990 年以來跨國逾放比率(NPL)及銀行危機資料集，該資料集蒐集 78 個國家共 88 次銀行危機前 3 年及後 7 年之銀行整體 NPL 資料，並分析危機發生前後 NPL 變化、NPL 與危機後經濟成長之關聯性，此外， <b>研究使用 ML 模型以辨識 NPL 上升之關鍵風險因素</b> 。研究結果顯示 <b>高信用成長、高政府債務、固定匯率制度及企業多使用短期債務皆屬 NPL 上升之關鍵因素</b> (Ari et al. (2020))。	ML：Post-R-Lasso

應用類別	機構名稱	研究主題及成果	應用 AI 技術
	ECB、 BoE	2. 使用一個涵蓋 1870 年至 2016 年 17 個已開發經濟體之總體經濟資料、市場面資料及金融危機標示之長期資料庫，以 <b>瞭解國內及跨國變數是否可有效預測個別國家金融危機</b> ，並探討國內及跨國變數間交互影響作用。研究結果顯示， <b>ML 模型除決策樹(DT)模型外預測能力皆高於傳統邏輯迴歸模型</b> ，此外， <b>信用成長比率及殖利率曲線斜率皆為提前預測金融危機之關鍵變數</b> (Bluwstein et al. (2021))。	ML：DT、RF、 ERTs、SVM、NN
	Fed	使用 OECD 經濟展望、路透社每日新聞摘要及 IMF 第四條協議報告等 <b>文字資料</b> ，透過 ML 模型分別 <b>預測個別國家是否會產生金融危機</b> ，並與股價波動率模型(基準模型)比較其預測能力。研究結果顯示，在 <b>已開發經濟體危機預測上，文字模型預測能力優於基準模型</b> ，然而若預測對象包含較多新興經濟體，則基準模型表現較佳，反映新興經濟體文字資料可用性與完整度較低，使得文字模型難以充分提取有效訊號。此外， <b>文字模型亦有助於辨識非傳統金融危機</b> (如新冠疫情引發之金融危機)(Chen et al. (2023))。	ML：SVM、RF

資料來源：作者整理。

## 參考資料

金管會 (2024), 「金融業運用人工智慧(AI)指引」, 6月。

Accornero, Matteo and Gianluca Boscariol (2021), “Machine Learning for Anomaly Detection in Datasets with Categorical Variables and Skewed Distributions,” October.

Al-Haschimi, Alexander, Apostolos Apostolou, Andrés Azqueta-Gavaldón, and Martino Ricci (2023), “Using Machine Learning to Measure Financial Risk in China,” *ECB Working Paper Series No. 2767*, January.

Araujo, Douglas, Giuseppe Bruno, Juri Marcucci, Rafael Schmidt, and Bruno Tissot (2022), “Machine Learning Applications in Central Banking,” *IFC Bulletin*, BIS, November.

Araujo, Douglas, Nikola Bokan, Fabio Alberto Comazzi, and Michele Lenza (2025), “Word2Prices: Embedding Central Bank Communications for Inflation Prediction,” *BIS Working Papers No. 1253*, March.

Ari, Anil, Sophia Chen, and Lev Ratnovski (2020), “The Dynamics of Non-performing Loans During Banking Crises: A New Database” *ECB Working Paper Series No. 2395*, April.

Ashwin, Julian, Eleni Kalamara, and Lorena Saiz (2021), “Nowcasting Euro Area GDP with News Sentiment: A Tale of Two Crises,” *ECB Working Paper Series No. 2616*, November.

Azqueta-Gavaldón, Andrés, Dominik Hirschbühl, Luca Onorante, and Lorena Saiz (2020a), “Economic Policy Uncertainty in the Euro Area: An Unsupervised Machine Learning Approach,” *ECB Working Paper Series No. 2359*, January.

Azqueta-Gavaldón, Andrés, Dominik Hirschbühl, Luca Onorante, and Lorena Saiz (2020b), “Nowcasting Business Cycle Turning Points with Stock Networks and Machine Learning,” *ECB Working Paper Series No. 2494*, November.

Beck, Günter W., Kai Carstensen, Jan-Oliver Menz, Richard Schnorrenberger, and

- Elisabeth Wieland (2024), “Nowcasting Consumer Price Inflation Using High-Frequency Scanner Data: Evidence from Germany,” *ECB Working Paper Series No. 2930*, April.
- Berge, Travis J. (2017), “Understanding Survey Based Inflation Expectations,” *Finance and Economics Discussion Series*, Divisions of Research & Statistics and Monetary Affairs, Federal Reserve Board, Washington, D.C., April.
- Betz, Frank, Silviu Oprică, Tuomas A. Peltonen, and Peter Sarlin (2014), “Predicting Distress in European Banks,” *Journal of Banking and Finance*, volume 45, 225-241, August.
- BIS (2023), “Project Aurora: The Power of Data, Technology and Collaboration to Combat Money Laundering across Institutions and Borders,” May.
- BIS (2025a), “Governance of AI Adoption in Central Banks,” January.
- BIS (2025b), “Project Hertha: Identifying Financial Crime Patterns in Real-time Retail Payment Systems,” June.
- Bluwstein, Kristina, Marcus Buckmann, Andreas Joseph, Sujit Kapadia, and Özgür Şimşek (2021), “Credit Growth, the Yield Curve and Financial Crisis Prediction: Evidence from A Machine Learning Approach,” *ECB Working Paper Series No. 2614*, November.
- Bräuning, Michael, Despo Malikkidou, Stefano Scalone, and Giorgio Scricco (2019), “A New Approach to Early Warning Systems for Small European Banks,” *ECB Working Paper Series No. 2348*, December.
- Buckmann, Marcus, Andy Haldane, and Anne-Caroline Hüser (2021), “Comparing Minds and Machines: Implications for Financial Stability,” *BoE Staff Working Paper No. 937*, August.
- Buckmann, Marcus, Galina Potjagailo, and Philip Schnattinger (2023), “Dissecting UK Service Inflation via a Neutral Network Phillips Curve,” *Bank Underground*, BoE, October.

- Buzanov, Gleb and Andrey Shevelev (2021), “Probability of Default Model with Transactional Data of Russian Companies,” September.
- Cagala, Tobias, Jörn Hees, Dayananda Herurkar, Mario Meier, Nhan-Tam Nguyen, Timur Sattarov, Kent Troutman, and Patrick Weber (2021), “Unsupervised Outlier Detection in Official Statistics,” November.
- Cajner, Tomaz, Leland D. Crane, Christopher Kurz, Norman Morin, Paul E. Soto, and Betsy Vrankovich (2024), “Manufacturing Sentiment: Forecasting Industrial Production with Text Analysis,” *Finance and Economics Discussion Series*, Federal Reserve Board, Washington, D.C., April.
- Carcel-Villanova, Hector and Hali Edison (2021), “Text Data Analysis Using Latent Dirichlet Allocation: An Application to FOMC Transcripts,” IMF, October.
- Chatterjee, Somnath, Ching-Wai (Jeremy) Chiu, Sinem Hacioglu-Hoke, and Thibaut Duprey (2017), “A Financial Stress Index for the United Kingdom,” *BoE Staff Working Paper No. 697*.
- Chen, Mary, Matthew DeHaven, Isabel Kitschelt, Seung Jung Lee, and Martin J. Sicilian (2023), “Identifying Financial Crises Using Machine Learning on Textual Data,” *Fed International Finance Discussion Papers No. 1374*, March.
- Dauphin, Jean-François, Kamil Dybczak, Morgan Maneely, Marzie Taheri Sanjani, Nujin Suphaphiphat, Yifei Wang, and Hanqi Zhang (2022), “Nowcasting GDP - A Scalable Approach Using DFM, Machine Learning and Novel Data, Applied to European Economies,” *IMF Working Paper 22/52*, March.
- Diachkov, Dmitrii (2021), “Machine Learning-based Approaches for Automatic Data Validation and Outlier Control of Loan Microdata in the Bank of Russia,” October.
- Dunn, Wendy, Ellen E. Meade, Nitish Ranjan Sinha, and Raakin Kabir (2024), “Using Generative AI Models to Understand FOMC Monetary Policy Discussions,” *FEDS Notes*, December.

- Faria da Costa, André, Francisco Fonseca, and Susana Maurício (2021), “Novel Methodologies for Data Quality Management Anomaly Detection in the Portuguese Central Credit Register,” October.
- Fraisse, Henri and Matthias Laporte (2021), “Return on Investment on AI: The Case of Capital Requirement,” *BdF Working Paper Series No. 809*, March.
- FSB (2017), “Artificial Intelligence and Machine Learning in Financial Services,” November.
- IOSCO (2021), “The Use of Artificial Intelligence and Machine Learning by Market Intermediaries and Asset Managers,” September.
- Jordà, Òscar (2005), “Estimation and Inference of Impulse Responses by Local Projections” *American Economic Review*, 95(1), 161–182, March.
- Joseph, Andreas, Galina Potjagailo, Eleni Kalamara, Chiranjit Chakraborty, and George Kapetanios (2022), “Forecasting UK Inflation Bottom Up,” *BoE Staff Working Paper No. 915*, September.
- Kalamara, Eleni, Arthur Turrell, Chris Redl, George Kapetanios, and Sujit Kapadia (2020), “Making Text Count: Economic Forecasting Using Newspaper Text,” *BoE Staff Working Paper No. 865*, August.
- Kiley, Michael T. (2020), “Financial Conditions and Economic Activity: Insights from Machine Learning,” *Finance and Economics Discussion Series*, Divisions of Research & Statistics and Monetary Affairs, Federal Reserve Board, Washington, D.C., November.
- Laeven, Luc and Fabian Valencia (2013), “Systemic Banking Crises Database,” *IMF Economic Review*, 61(2), 225–270, June.
- Lenza, Michele, Inés Moutachaker, and Joan Paredes (2023), “Forecasting Euro Area Inflation with Machine Learning Models,” *Research Bulletin No. 112*, ECB, October.
- Munday, Tim and James Brookes (2021), “Mark My Words: The Transmission of

Central Bank Communication to the General Public via the Print Media,” *BoE Staff Working Paper No. 944*, October.

Pike, Tyler, Horacio Sapriza, and Tom Zimmermann (2019), “Bottom-up Leading Macroeconomic Indicators: An Application to Non-financial Corporate Defaults Using Machine Learning,” *Fed Finance and Economics Discussion Series No. 70*, August.

Puglia, Michael and Adam Tucker (2020), “Machine Learning, the Treasury Yield Curve and Recession Forecasting,” *Finance and Economics Discussion Series*, Divisions of Research & Statistics and Monetary Affairs, Federal Reserve Board, Washington, D.C., May.

Romer, Christina D. and David H. Romer (2017), “New Evidence on the Aftermath of Financial Crises in Advanced Countries,” *American Economic Review*, *107(10)*, 3072–3118, October.

Soto, Paul E. (2023), “Measurement and Effects of Supply Chain Bottlenecks Using Natural Language Processing,” *FEDS Notes*, February.

Suss, Joel and Henry Treitel (2019), “Predicting Bank Distress in the UK with Machine Learning,” *BoE Staff Working Paper No. 831*, October.