

行政院所屬各機關因公出國人員出國報告書
(出國類別：實習)

參加東南亞國家中央銀行研訓中心
舉辦之「總體經濟監測之數據分析」
(Data Analytics for Macroeconomic
Surveillance) 研訓課程出國報告書

服務機關：中央銀行

姓名職稱：鄭育傑/辦事員

派赴國家：印尼

出國期間：114年6月15日至6月21日

報告日期：114年8月

摘 要

隨資訊科技快速進步與數位化浪潮持續推進，愈來愈多數據被廣泛蒐集、處理與應用，大數據及新興研究分析工具的發展，加上生成式 AI 出現，正大幅重塑央行在經濟監管、風險評估以及對外溝通上的運作模式。

作為貨幣政策的最高決策機構，央行一向仰賴數據作為政策設計與執行的基礎。在資料型態日益多樣且數量急遽攀升的背景下，雖有助於強化決策依據，然而如何從中擷取關鍵訊息，並轉化為具政策價值的資訊（Information），成為當代央行研究人員面臨的重要挑戰。

事實上，當前傳統研究方法已難以即時、有效且準確地滿足大數據時代下的分析需求，為因應此挑戰，多數先進經濟體央行積極導入新興研究分析工具，包含機器學習、自然語言處理與生成式 AI 等，以提升資料處理與分析效率，簡化內部作業流程，並增強整體工作效能。惟應用這些新技術的過程中，央行亦須理解並審慎評估潛藏在背後的風險與限制。現階段，一般認為新興研究分析工具仍屬輔助性質，多被視為對傳統研究方法的補充，尚難完全取代既有的理論架構與分析模式。

最後，央行應持續關注 AI 治理的國際發展趨勢，積極參與各國國際組織所發起的合作倡議計畫與政策討論活動，並隨技術與制度的演進適時更新內部因應機制。如此不僅有助於強化社會大眾對政策的理解與信任，也能進一步維護央行的公信力與政策效能。

目 錄

壹、 前言	1
貳、 大數據資料	2
一、大數據之內涵	2
二、大數據帶給央行的影響	5
三、小結	7
參、 新興研究分析工具	7
一、機器學習	7
二、自然語言處理	13
三、生成式AI	17
肆、 心得與建議	26
一、心得	26
二、建議	27
參考文獻	29

圖目次

圖 1：各國央行應用大數據之目的調查.....	4
圖 2：央行貨幣政策決策流程.....	5
圖 3：AI、機器學習與大數據分析關係示意圖	8
圖 4：FOMC 聲明情緒分數趨勢	16
圖 5：AI 領域技術演進關係.....	18
圖 6：最佳化 AI 實務.....	24

表目次

表 1：機器學習演算法統計分析模型彙整表.....	11
表 2：文件特徵矩陣形式概念.....	14

壹、前言

隨資訊科技不斷革新與數位化浪潮持續推進，大數據興起雖強化各國央行貨幣政策決策基礎，但面對資料型態日益多元與規模龐大，如何從中萃取具決策價值的資訊，已成為央行研究人員必須克服的重要挑戰。

傳統研究方法往往難以即時、有效且準確地因應大數據環境下的分析需求，因此，多數先進經濟體央行積極導入各式新興研究分析工具，以提升資料處理與分析效率，簡化內部作業流程，並強化整體工作效能。此類應用正大幅重塑央行在日常貨幣政策與金融監理業務中的運作模式，應密切關注相關技術發展趨勢。

職奉准於民國 114 年 6 月 15 日至 6 月 21 日參加東南亞國家中央銀行聯合會（South East Asian Central Banks, SEACEN）研訓中心於印尼峇里島舉辦之「總體經濟監測之數據分析（Data Analytics for Macroeconomic Surveillance）」研訓課程，為期 5 日，共計 33 位學員參加，分別來自 11 個不同國家（台灣、尼泊爾、印尼、汶萊、印度、柬埔寨、馬來西亞、泰國、斯里蘭卡、菲律賓、寮國）之央行與貨幣金融監理單位。

本次講者除 SEACEN 研訓中心之講師外，另邀請澳洲蒙納許大學（Monash University）、澳洲央行（Reserve Bank of Australia, RBA）、紐西蘭央行（Reserve Bank of New Zealand, RBNZ）等學者專家授課。課程內容豐富多元，涵蓋大數據簡介、資料視覺化、新興研究分析工具之概述與應用、以及生成式人工智慧（Generative Artificial Intelligence，以下簡稱生成式 AI）運用、監管及全球治理等議題。

課程期間，除由講師帶領學員就相關議題進行講解及討論外，亦透過國際金融組織與各國金融監理機關之公開資料，運用統計軟體建構簡易分析模型並進行演示，期望學員未來能依自身需求進一步深入

探索與應用。由於課程涵蓋面向廣泛，本報告僅就部分重要議題進行說明。

本報告分為肆章，第壹章為前言；第貳章介紹大數據的內涵與應用挑戰；第參章概述新興研究分析工具的發展與應用，包含機器學習、自然語言處理與生成式 AI；第肆章為心得與建議。

貳、大數據資料

本次研訓課程以「數據」為核心，展開一系列應用議題之探討。隨資訊科技持續進步與數位化浪潮襲來，可取得資料量呈現幾何式增長，促使新興「大數據」概念應運而生。

一、大數據之內涵

所謂「大數據」(Big Data)，泛指伴隨數位工具與資訊系統普及所產生之龐大資料集，惟目前尚未有單一且一致性的定義 (FSB, 2017)。為更容易地理解其意涵，實務上以「5V 結構¹」進行描述與定義，分別為數量 (Volume)、速度 (Velocity)、多樣性 (Variety)、真實性 (Veracity) 與價值 (Value)。具體而言，大數據不僅資料量龐大，涵蓋層面廣泛且細緻，並具備即時生成與高頻率更新的特徵；其多元化的資料型態，經適當處理後，得以轉化為真實可信且具決策意義的資訊價值。

若以央行進行總體經濟研究分析與預測為目的，採用時間序列架構說明將更為切合。假設在一個時間長度為 T 、單位時間內觀測次數為 m 、變數數量為 N 所構成的資料矩陣 ($mT \times N$) 中，只要一或多個維度 (Dimensionality) 呈現極大規模，便可歸類為大數據。此一視角有助央行辨識資料特徵與分析需求，據此採取適切的數據

¹ 最早由 Laney, D. (2001) 提出「3V」結構，後續由 IBM 等企業將其進一步擴充為 5V，新增 Veracity (真實性) 與 Value (價值) 兩個面向。近年來，學界與業界實務亦逐步引入 Variability (變異性) 與 Visualization (視覺化)，將架構延伸至 6V、7V 的多元結構。

處理與分析策略。

相較傳統總體經濟與金融統計資料，新興大數據在資料來源與品質上，存在顯著差異與挑戰。首先，大數據多非基於學術研究或統計建模目的所設計與蒐集，而是社會經濟活動的「副產品 (By-Product)」²，此類資料集通常涵蓋整體母體，因此不涉及傳統的抽樣誤差；惟其資料來源往往缺乏透明度，且具有代表性不足的問題，主因為觀測資料本身已受到設限 (Censored)。

以社群媒體資料 (如 FB、IG 等) 為例，網路資源分布不均及進入門檻，可能導致樣本過度反映已開發國家或特定年齡層 (如年輕族群) 的行為特徵。此外，社群媒體平台的內容審查政策、推播演算法及內部管理機制等結構性因素，會進一步扭曲原始資料樣貌，使觀察到的資料與整體社會現實存在顯著差異。結果可能導致後續經濟分析產生錯誤推論，甚至強化既有偏見，對政策制定產生不利影響。

再者，由於大數據並非基於特定研究或統計目的所設計與取得，其資料通常保有高維度且結構不明確的特徵，因而在資料清理、運算處理及儲存管理等方面面臨相當挑戰。例如，網頁瀏覽紀錄蘊含大量使用者行為資訊，並隨時間動態反映其變化模式。此類資料以一連串事件呈現，事件之間可能高度相關，也可能完全無關，且可依無數方式進行組織與詮釋，從而衍生出無限組潛在變數集合。

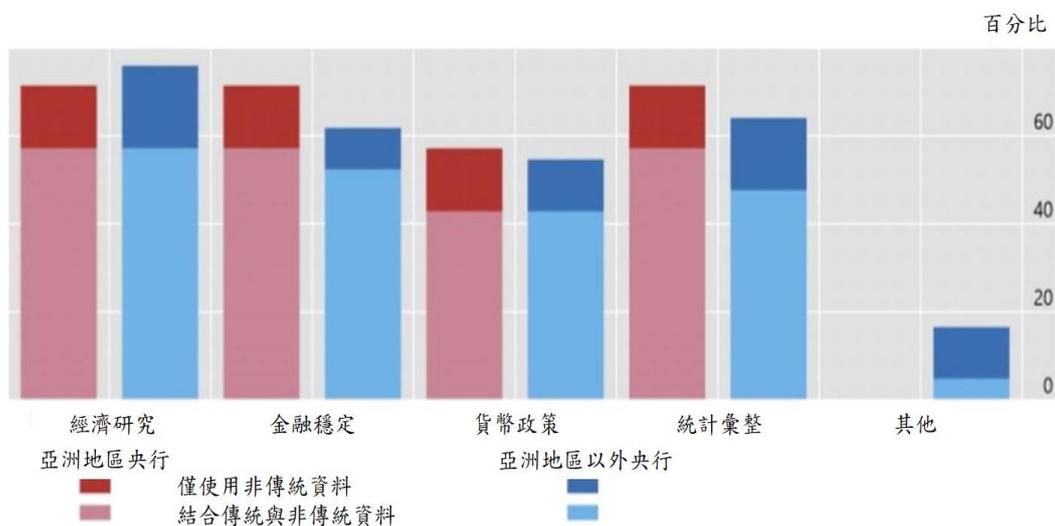
因此，進行統計分析前，需先對資料經過特別處理，包括資料重組與降低維度，以確保資料品質。此過程耗費大量人力與時間，

² SEACEN 研訓課程講義列舉大數據範例包含：電子商務與信用卡消費紀錄、行動裝置通聯資訊、交通與移動軌跡、網路搜尋引擎資料、網路社群媒體互動紀錄、非結構化文本資料、感測器與物聯網 (IoT) 資料，以及政府部門行政資料等。

並高度依賴高效能運算設備、新興資料處理工具及專業資料分析人員的支援。儘管如此，大數據在資料細緻度、使用彈性與即時性方面展現出的高度價值，仍吸引各國央行研究人員持續投入資源，積極深化其研究與應用，尤以亞洲地區央行³最為明顯（Cornelli et al., 2022）。

圖 1 為各國央行應用大數據之目的調查。在主要四個領域中，亞洲地區央行除應用於經濟研究領域外，在其他領域對大數據的運用程度均高於其他地區，且更廣泛地使用非傳統數據（深色比例），以支持金融穩定與貨幣政策。至於其他類別，亞洲地區目前尚無央行利用大數據資料投入「虛擬資產監控」、「網路安全」與「網路分析」領域。

圖 1：各國央行應用大數據之目的調查



資料來源：Cornelli et al.(2022)

註 1：受訪者可同時複選多個項目。

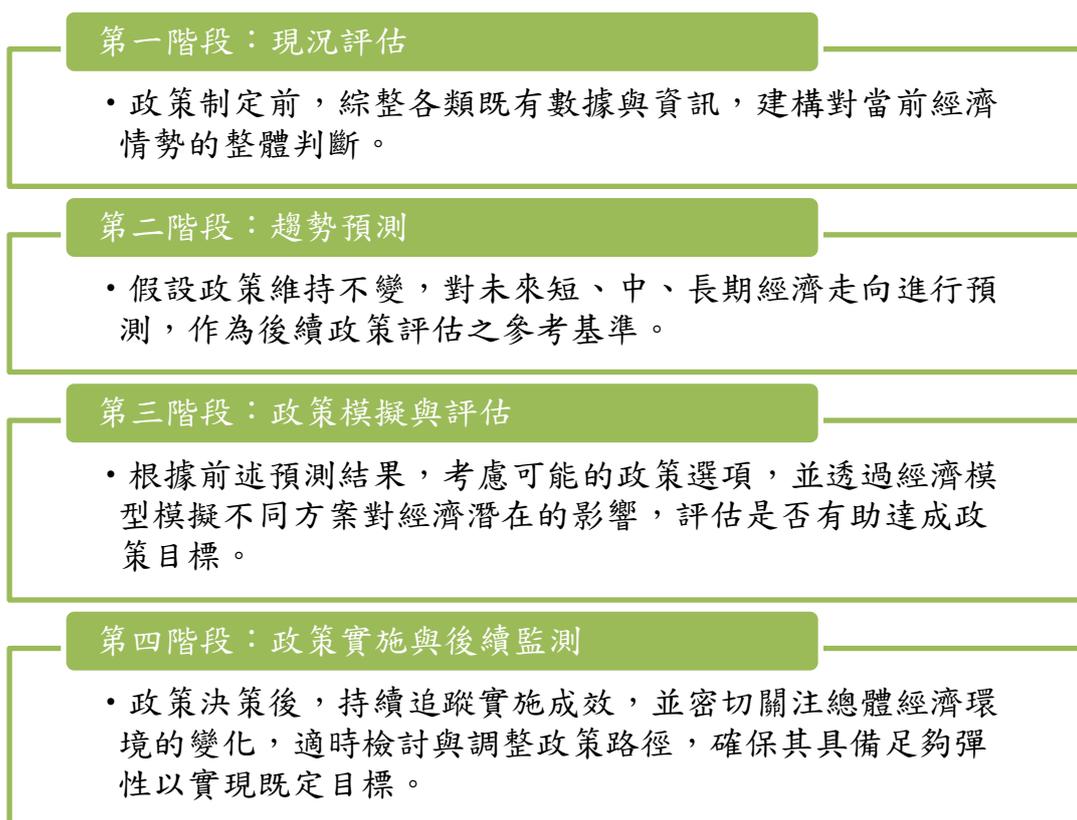
註 2：其他類別包括「虛擬資產監控」、「網路安全」與「網路分析」三個領域。

³ 根據 IFC (Irving Fisher Committee, IFC) 2020 年調查報告指出，2020 年亞洲地區央行應用大數據的比例較 2015 年上升 53% 至 86%。另外，約 60% 的央行廣泛討論大數據相關議題（其他地區約 42%），且所有受訪央行在高階政策應用層面，均對其抱有高度至極高的興趣（其他地區僅 58%）。

二、大數據帶給央行的影響

央行基於業務職能，長期以數據作為貨幣與金融決策之依據，政策制定流程大致可分為以下四個階段（參圖 2）：

圖 2：央行貨幣政策決策流程



資料來源：整理自 SEACEN 講義

為建構貼近現實且具高度準確的經濟模型，央行研究人員致力於捕捉並納入更多變數間的互動關係、效果傳導機制與外部衝擊因素。大數據規模龐大且高度細緻的特徵，能有效補足傳統經濟數據的不足。雖然大數據多為個體層級資料，惟 Indonesia Bank (2023) 指出，廣泛應用個體資料有助於發現總體經濟變化的潛在模式，進而提升經濟預測準確度。因此，央行在模型建構與分析過程中，應進一步思考如何捕捉並評估基於個別消費、投資或借貸決策等個體

行為所產生之總體經濟效果。

此外，傳統上央行相較金融市場其他參與者，被認為擁有資訊優勢，能更全面且精確地掌握總體經濟情勢。然而，隨資訊科技快速發展，市場資訊環境已發生結構性轉變，央行體系以外的部分私人機構與科技平台，可能掌握更廣泛、細緻且即時的資訊。在此背景下，如何有效取得這些機構視為核心資產的大數據資料，並建立制度化且互信的合作機制，以強化貨幣政策分析與決策依據，成為央行未來須面對的重要課題。

同時，應用大數據的關鍵挑戰之一，涉及個人資料使用的法律依據，以及相關的安全性、倫理與隱私問題（Jones and Tonetti, 2020；Boissay et al.,2021；Cornelli et al.,2022）。在當代社會，保護個人隱私免於商業機構或政府不當侵害，已普遍被視為一項基本人權。倘若央行於研究與政策制定過程中，直接分析民眾的搜尋紀錄、社群媒體貼文或線上平台活動等資料，恐引發社會大眾對個資濫用之疑慮與不信任感。

此外，來源透明度不足且品質難以驗證的網路資料，未必符合官方統計機構應遵循的準則與方法論。若央行過度依賴此類資料，可能對其聲譽造成風險，進而影響研究結果的可靠性，並削弱公眾對貨幣政策決策的可信度。

在大數據的蒐集、應用與管理等方面，許多央行內部尚未建立正式且完整的資料治理（Data Governance）架構，造成內部摩擦（Internal Friction）問題顯著。此問題主要源自組織內部並無有效的溝通協作機制，各部門多半依照自身需求，採用最經濟與便捷的方案進行資料應用。

舉例而言，各部門為管理資料建立多個造價不菲且規格各異的

系統，這些系統往往相互獨立且缺乏共通性。再者，資料儲存與使用流程缺乏標準化，導致後續資料整理效率低下，且重複性工作頻繁發生；隨著作業流程複雜度增加，整體研究分析品質也難以達到最佳水準。上述因素均不利於資料的可近用性（Accessibility），限制了大數據在應用層面的效益。

因此，建立完善且統一的資料治理架構，不僅能減少內部摩擦（Internal Friction）、提升資料使用效率，還可降低資源浪費，進而發揮大數據於貨幣金融政策制定中的實質效益。

三、小結

大數據的應用固然為央行的研究與決策帶來嶄新的契機，然而這並不代表可以忽視傳統統計的基本衡量原理與推論假設，也不代表可以直接建構有效且可靠的資料關係結構，並作為可信賴的公眾溝通基礎。新興大數據資料仍然是對傳統資料來源與方法的補充而非替代，無法取代常識、經濟理論、或對嚴謹研究設計的需求（Einav and Levin, 2014）。

參、新興研究分析工具

實務上，可用於分析大數據資料的工具種類繁多，研究人員應依資料型態與分析需求，選擇最適工具。本章以經濟領域中常見的三種研究分析工具：機器學習（Machine Learning, ML）、自然語言處理（Natural Language Processing, NLP）與生成式 AI 進行簡要概述。

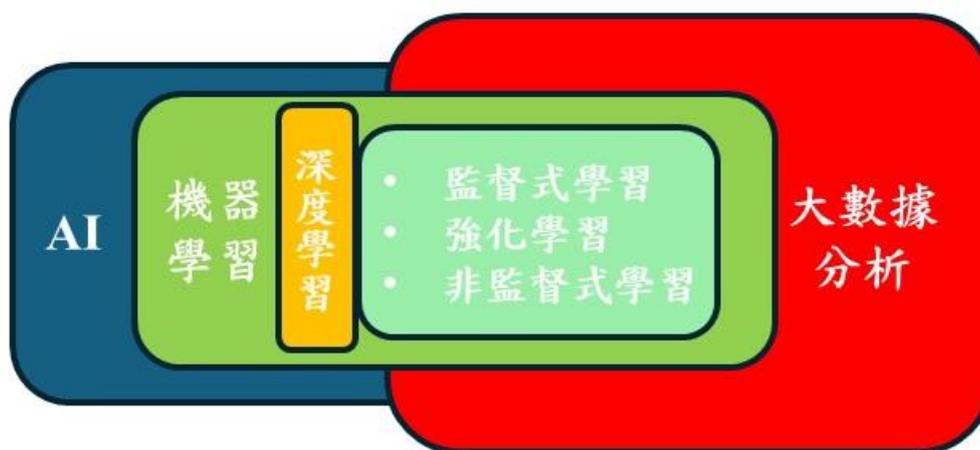
一、機器學習

（一）機器學習簡介

機器學習源自計算機科學，是 AI 領域下的一個重要分支。其核心在於透過演算法設計，使電腦在缺乏或有限的人為干預下，能

自動辨識並學習資料中的關聯與模式，進而應用於預測、分類或視覺化等問題。圖 3 概略呈現本節說明之結構。

圖 3：AI、機器學習與大數據分析關係示意圖



資料來源：整理自 FSB (2017)

依據訓練資料特性、分析方式與產出結果的差異，機器學習的演算法學習方式可區分為以下四種類型：

1. 監督式學習 (Supervised Learning)：

透過人為定義與標記 (Label)，建立供演算法訓練的資料集，電腦由此學習輸入與輸出之間的對應規則與關係，並進一步應用於預測或分類 (Classification) 尚未標記的新資料。

2. 非監督式學習 (Unsupervised Learning)：

與監督式學習不同，此類方法所使用的資料不含標記。演算法需依據資料間的相似特徵偵測潛在模式，並常透過分群 (Clustering)、降維 (Dimensionality Reduction) 等技術，進行分群、歸類、結構探索或資料簡化。

3. 強化學習 (Reinforcement Learning, RL)：

不同於監督式與非監督式學習，強化學習不依賴標記資料，而是透過與環境的反覆互動進行學習。演算法在未知環境中採取行動後，會根據外部回饋（如獎勵或懲罰訊號）調整策略，逐步形成最適行動方案，最終目標為最大化累積報酬 (Maximize Cumulative Reward)。

4. 深度學習 (Deep Learning, DL)：

深度學習是一類基於人工神經網路 (Artificial Neural Networks, ANN) 的演算法，設計理念受人類大腦結構與功能的啟發。神經網路由多層神經元 (Neurons) 組成，透過逐層連結進行資訊傳遞與特徵提取。當網路層數加深，模型能學習到更複雜的模式與高階抽象特徵，並具備自動化特徵擷取與學習的能力。

深度學習可應用於監督式、非監督式與強化學習等不同框架，目前已廣泛運用於語音與影像識別、自然語言處理以及醫療診斷等領域，是近年發展最快速、應用最廣泛的機器學習方法之一。

有關上述學習模式，在金融監理領域的應用⁴可簡述如下：由於銀行等金融機構每日產製數以百萬計的交易紀錄，若依靠人工逐筆審查，顯然不切實際。因此，根據資料類型與監控目的不同，藉由選用不同的機器學習模式與統計模型，以有效降低監管與遵循成本。

在缺乏歷史標記資料且尚無具體已知任務的情況下，非監督式

⁴ SEACEN 研訓課程第十講「SupTech and RegTech: AI for Financial Supervision」課程演練範例。

學習可用於偵測異常交易⁵ (Anomaly Detection)，協助辨識未知或新興風險；惟異常不表示該交易屬於犯罪行為，其僅提供預警訊號，後續仍須依個案具體情況進行審查與確認。

相對地，若擁有已標記的歷史資料，且監控目的明確而具體，例如檢測交易是否涉及金融犯罪，則適合採用監督式學習。透過既有案例訓練模型，可用於預測新交易是否具有不法風險，進而提升審查效率與準確性。

事實上，如果資料品質足夠，不同學習模式得相互結合應用，已達成互補效果並提高工作效能。以防制洗錢與打擊資恐為例，可先利用非監督式學習初步篩選異常交易，縮小樣本審查範圍；隨後再運用監督式學習，對篩選出的異常交易加以研判。

許多機器學習演算法建立於一般研究人員熟悉的統計方法之上，而相比傳統統計模型，機器學習架構具更高的彈性，能在不同情境下擴展線性回歸模型，進一步捕捉非線性關係，處理更複雜的大數據問題。

機器學習所使用演算法除基本的線性回歸模型 (Linear Regression Model) 與邏輯回歸模型(Logistic Regression)外，還包括非線性模型，如決策樹(Decision Tree)、隨機森林(Random Forest)、極限梯度提升樹 (XGBoost)，以及近年應用於生成式 AI 的人工神經網路模型方法。表 1 簡要彙整一般機器學習常用演算法的分析方式。

⁵ SEACEN 研訓課程講義列舉出實務常見異常態樣，包含：非常態大額交易、幣別錯配交易、化整為零的分散交易、以及其他非常規交易方法等。

表 1：機器學習演算法統計分析模型彙整表

演算方法	決策原理	學習模式	常用情境	主要優點	主要缺點
線性回歸	最小平方法 (Ordinary Least Squares, OLS)。	監督	·預測連續數值，如房價、國民所得與通膨等指標	·模型簡潔透明 ·解釋性佳	·僅適用線性關係 ·對離群值敏感
邏輯回歸	$P(y=1) = 1 / (1 + e^{-(\beta x)})$ 。	監督	·二元分類	·可輸出機率值 ·解釋性佳	·易遺漏複雜模式 ·可能欠擬合
正則化回歸 (Regularized Regression)	模型納入懲罰項調校 (L1/L2)。	監督	·發生多重共線性 ·發生過擬合	·減少過擬合 ·避免共線性	·解釋性下降 ·需調校參數
決策樹 (Decision Tree)	If-Then-Else 規則的樹狀結構。	監督	·回歸與分類 (CART Model)	·解釋性佳 ·訓練速度快	·易過擬合 ·對數據微小變化敏感
隨機森林	多棵獨立 CART 樹組合平均。	監督	·非線性分析	·表現穩健 ·處理遺失值佳 ·非線性關係處理能力佳	·解釋性不佳 ·決策時間慢
極限梯度提升樹	多棵 CART 樹串接，自錯誤中逐步學習優化。	監督	·非線性分析 ·預警系統 ·評分機制	·高準確性 ·處理遺失值佳 ·具正則化機制	·解釋性不佳 ·參數調校複雜
K-鄰近演算法 (K-Nearest Neighbor)	依最近 K 個鄰點進行多數決或加權平均。	監督	·回歸與分類	·簡單直觀 ·可處理多種類型資料	·K 值需事先決定 ·維度限制 ·計算量大且速度較慢
K-平均演算法 (K-Means)	最小化樣本到分群中心 (Centroid) 的距離。	非監督	·分群任務	·簡單直觀 ·計算容易	·K 值需事先決定 ·對初始值設定、離群值及資料規模敏感 ·僅適用數值資料
階層式分群 (Hierarchical Clustering)	透過階層架構，將資料層層反覆分裂或聚合分類。	非監督	·分群任務	·無須事先指定群組數 ·樹狀結構易理解	·計算量大 ·適用小樣本 ·對離群值敏感
主成分分析 (Principal Component Analysis, PCA)	利用線性轉換，降低原始數據維度，並保留其主要代表特性。	非監督	·數據降維 ·特徵提取	·使數據便於分析 ·去除雜訊(Noise) ·避免共線性	·解釋性不佳 ·可能損失部分重要訊息
強化學習	最大化累積報酬。	強化	·遊戲 (如 AlphaGo) ·自駕車駕駛 ·機器人控制	·學習最佳策略 ·無需標記資料 ·應用彈性高	·策略不穩定 ·收斂速度慢 ·獎勵機制設計不容易

演算方法	決策原理	學習模式	常用情境	主要優點	主要缺點
人工神經網路	多層感知器 (Multilayer Perceptron, MLP)。	監督/ 非監督/ 強化	<ul style="list-style-type: none"> ·語音及影像識別 ·自然語言處理 ·醫療診斷 	<ul style="list-style-type: none"> ·學習能力佳 ·準確度高 	<ul style="list-style-type: none"> ·解釋性不佳 ·需大量數據 ·高算力成本

資料來源：整理自 Seacen 講義與自行補充

(二) 機器學習之優勢與挑戰

機器學習近年愈來愈受關注，主因在於其具備強大的運算與學習能力，能即時發掘資料中過往未被偵測複雜模式，因此在大數據分析領域尤為熱門。

以通膨預測為例，傳統經濟學者通常依據既有理論假設變數間呈線性關係，然而若以提升預測準確性為主要目標，反而可能限制預測表現。相比之下，機器學習不必對估計模型施加此類假設，例如採用神經網路模型演算法時，不會對解釋變數與預測目標之間的關係設定特定的函數結構限制，從而更靈活地捕捉資料中的非線性模式。

此外，在氣候變遷相關的金融風險評估中，機器學習也能進行較細緻的敏感度分析，或生成替代的氣候模擬情境，以檢驗模型參數設定與假設的健全性。當模型訓練完成後，可快速揭示潛在風險因子、情境影響差異並洞察長期經濟情勢變化路徑，有助監理機關提前規劃最佳因應策略，提升決策效率。

儘管機器學習展現強大能力，應用上仍面臨若干限制：

首先，演算法主要依賴歷史資料進行學習，若總體經濟出現結構性變化時，例如 2008 年金融海嘯或 2020 年 Covid-19 疫情期間，整體消費、投資、支出與進出口貿易發生劇烈變動，導致資料出現未知的模式時，機器學習表現可能產生偏誤。其次，機器學習演算

法常被視為「黑盒子」(Black-Box)，其複雜且不透明的的運算過程，使因果關係難以界定，不利邏輯解釋。此外，背後缺乏完整的經濟理論基礎支持，對於政策施行需有一套明確「敘事說帖」的央行而言，不利溝通之達成。

綜上所述，機器學習分析結果仍需透過經濟理論檢驗，並符合傳統經濟邏輯脈絡。短期內，機器學習僅能作為傳統模型(如 RBC、DSGE 或 VAR)的補充，難以完全取代傳統分析方法。專家與學者的經驗判斷在最終決策中仍舉足輕重，尤其是在總體經濟遭受結構性衝擊時期。

二、自然語言處理

(一) 自然語言處理簡介

自然語言處理，可通俗稱為「文本分析」(Text Analysis)，係透過一系列運算工具與統計技術，將非結構化文字資料轉換為可量化或數值化的格式，使這類無法以傳統方法研究的資料⁶，能夠用於量化分析與評估。

實務上，研究人員通常會稱文字資料中的單一觀測值稱為文件(Document)，而由多個文件所組成的整資料集則稱為「語料庫」(Corpus)。以英文文本資料為例，執行自然語言處理分析的流程一般可分為以下三個主要步驟：

1. 對原始文本進行初步整理，盡可能保留具意義的詞彙，並排除不必要的雜訊。常見作法包括將字母統一大小寫、移除非字母字元⁷，以及刪除常見的停用詞⁸ (Stopwords)。

⁶ 常見的資料來源包含：新聞媒體報導、監理報告、內部備忘錄、演講稿，以及社群媒體貼文等。

⁷ 例如標點符號、數字等文本中對語意無實質影響的元素。

⁸ 指文本中出現頻率高但對語意貢獻有限的常用詞彙。英文中常見的範例包括冠詞："A"、"An"、"The"；連接詞："And"、"Or"、"But"；以及代名詞："He"、"She"、"It"。

2. 將文本斷詞化⁹ (Tokenisation)，並轉換為文件特徵矩陣 (Document Feature Matrix, DFM)，以達成文字資料的數值化表示。例如，假設有一語料庫包含三份文件，分別為「The economy is struggling.」、「Deflation is happening.」、「The central bank reacts.」，經過整理與數值化後，文件特徵矩陣的概念如表 2 所示。

表 2：文件特徵矩陣形式概念

Document	economy	struggling	deflation	happening	central	bank	reacts
Doc. 1	1	1	0	0	0	0	0
Doc. 2	0	0	1	1	0	0	0
Doc. 3	0	0	0	0	1	1	1

註 1：每一列代表單一個別文件。

註 2：每一欄代表文本斷詞後的基本詞語單位，又可稱為「特徵」。

註 3：表格中之數值則表示各個詞元在每份文件中出現的次數。

3. 根據研究目的採用不同方法進行分析，常見技術包括資料視覺化¹⁰、TF-IDF (Term Frequency - Inverted Document Frequency) 衡量指標¹¹、情感分析¹² (Sentiment Analysis) 以及主題建模¹³ (Topic Modelling) 等，用以擷取文本中的潛在的資訊與模式。

⁹ 指將文本資料依語言規則拆解成詞元 (Token) 的過程，詞元通常被視為模型處理文字的最小語義片段。例如句子 "I Love You." 經斷詞化後可拆解為 "I"、"love"、"you" 三個詞元。

¹⁰ 文字雲 (Word Cloud) 分析是常見的文字視覺化方法，用以呈現不同詞彙在文本中的相對重要性，並透過字體大小、顏色、粗細及雲體形狀等特徵，使重要性較高的詞彙以較顯眼的方式表現，有助讀者快速掌握文本的核心要點。

¹¹ Gerard S. et al. (1983) 提出了一種用於文字探勘與資訊檢索的統計加權方法，旨在衡量詞彙在特定文本中的相對重要性。其核心原理在於賦予那些在單一文本中頻繁出現，但在整體語料庫中不常見的詞彙較高權重。此機制能有效地排除高頻但資訊價值低的泛用詞，進而凸顯具主題代表性的關鍵詞。

¹² 藉由量化文字中的情緒或語氣 (例如：正面、負面或中性)，可辨識文本的情緒傾向，進而掌握語者或撰文者的情緒立場。衡量方式多以辭典法 (Dictionary-Based Approach) 為基礎，透過事先定義正面與負面詞彙清單，並確保該清單與分析文本領域相關聯，以有效反映文本情緒。Loughran and McDonald (2011) 及 Correa et al. (2021) 辭典為經濟金融領域常用的參考文獻。

¹³ 主題建模是一種非監督式機器學習方法，無須事先標註資料，即可自動識別與發掘語料庫中潛在「主題 (Topics)」的分佈，從而輔理解文本的結構與內容特性。

(二) 自然語言處理之於央行

當代央行的貨幣政策實施已不限於傳統政策行動，文字作為溝通媒介，本身即為一種政策工具，其重要性不亞於利率調整。央行透過對未來政策的表態，例如前瞻性指引（Forward Guidance），向大眾傳達立場，進而影響市場資金成本、債券殖利率以及大眾對未來經濟情勢的預期。

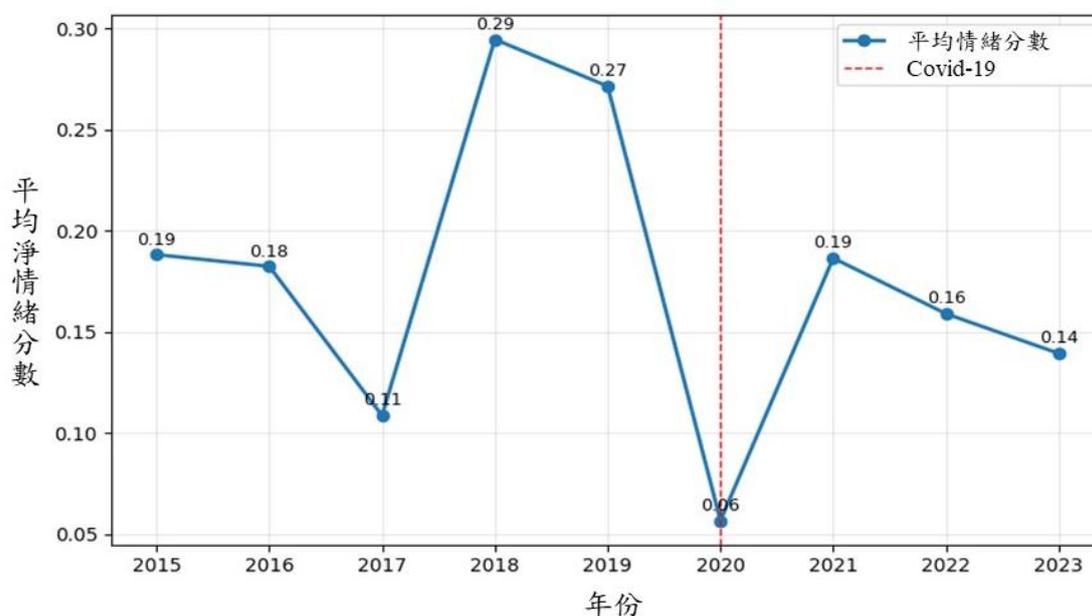
詳讀央行之官方聲明資料有助於了解其釋放的訊號，並研判未來貨幣政策走向。因此，金融市場參與者往往高度關注其中的措辭差異及語氣變化，以避免遺漏可能預示政策轉向的蛛絲馬跡。例如，相較於「通膨溫和」，「通膨壓力正在增強」一句表達央行對通膨失控的擔憂，釋放政策可能轉向鷹派（升息）的訊號；反之，相較於「經濟活動穩健」，「經濟動能趨緩」一句則顯示央行更關注經濟成長放緩，釋放政策可能轉向鴿派（降息）的訊號。

以美國聯邦公開市場委員會（FOMC）於 2015 年至 2023 年公開聲明資料所進行之情緒趨勢分析¹⁴為例。如圖 4 所示，整體平均情緒分數偏向正面，惟 2020 年因 Covid-19 疫情引發的經濟衰退恐慌，使鴿派立場抬頭，導致指標大幅下滑。彼時利率數度調降的政策走向，符合該時期央行聲明所釋放的潛在政策訊號¹⁵。

¹⁴ SEACEN 研訓課程第八講「NLP for Central Bank Communication and Market Signals」課程演練範例。此處情緒指標採粗估方式，每個正面詞彙數與負面辭彙數權重皆為 1，分數計算為正向詞彙出現次數減去負向詞彙出現次數。正面詞彙有「Growth」、「Strong」、「Recovery」以及「Improvement」；負向詞彙則有「Recession」、「Decline」、「Weak」以及「Uncertainty」。

¹⁵ Chong and Ho (2023) 以馬來西亞央行聲明為資料進行情緒分析，研究結果顯示情緒分數與政策利率呈同步變動的趨勢，並發現情緒分析在預測利率變動時存在不對稱效果：負面情緒（鴿派）對長期公債殖利率下降的預測力強，有額外的推動效果，而正面情緒（鷹派）語言對提高殖利率的影響則較弱。

圖 4：FOMC 聲明情緒分數趨勢



資料來源：整理自 SEACEN 講義

然而，央行的官方聲明與新聞稿通常具有高度專業性，由許多經濟學理論及專業術語構成，需仰賴新聞媒體將其內容重新編寫，轉化為易於理解且涵蓋核心重點的報導，使更廣泛的受眾理解，以利對外政策溝通的順暢。惟此一傳遞過程中，受媒體放大效應¹⁶（Media Amplification Effect）影響，有時訊息未必能精確傳達央行立場，甚至可能被扭曲。

因此，除了金融市場參與者對央行官方聲明的理解之外，央行及其他金融監理機關人員也應運用自然語言處理技術，分析新聞媒體報導與評論，以追蹤政策訊息的接收狀況及市場回饋的主導敘事。這有助於審慎評估官方訊息是否遭受曲解而削弱政策效果，並研判市場是否正確回應政策訊號，或受到疫情、地緣政治等其他外部因素干擾。在彙總市場各式訊號後，可進一步提升對未來總體金

¹⁶ 源自 Kaspersen et al. (1988) 提出之「社會風險放大模型」(Social Amplification of Risk Framework, SARF)，說明媒體如何通過資訊傳遞和社會反應機制，放大社會風險感知程度與事件影響力。媒體放大效果的來源包括報導頻率、語氣、以及呈現手法等因素。

融情勢的判斷與評估能力。

在當前資訊爆炸的時代，自然語言技術能將大量非結構化文本資料轉化為多樣且豐富的訊號，為央行在市場監控、貨幣決策與政策響力評估等方面提供有力支持。惟仍須特別留意，非結構化文本資料母體本身可能存在偏誤而影響分析結果，故仍有必要結合傳統分析方法進行交叉驗證與補充。

三、生成式 AI

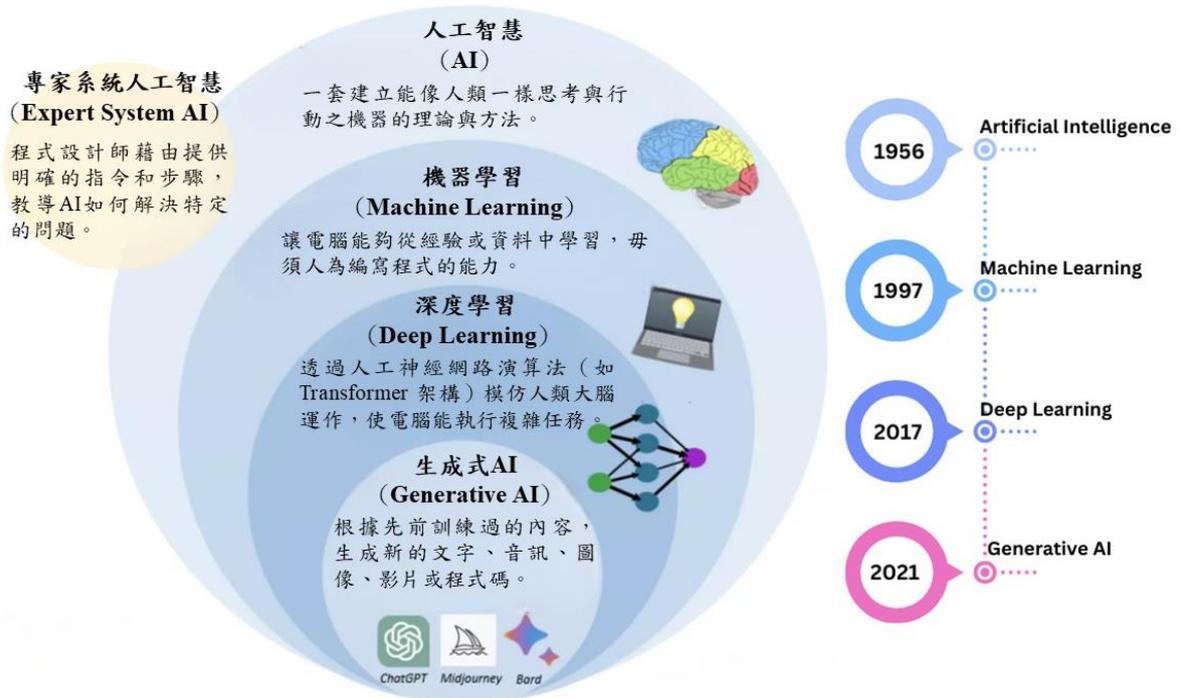
(一) 生成式 AI 發展與應用

生成式 AI 是一種能根據所學資料，自動生成各類內容的演算法技術，可產出文字、圖像、音樂、影片、程式碼等多種資料形式。自 2022 年末 ChatGPT 問世以來，引發的熱潮使生成式 AI 成為近年備受關注的 AI 科技應用之一。其發展脈絡建立於大數據興起，以及深度學習與大語言模型¹⁷（Large Language Model，以下簡稱 LLM）技術突破所推動。

相比以規則為基礎的傳統 AI 系統，或以大量資料進行模式學習的進階 AI（機器學習），生成式 AI 應用面向更為廣泛。不僅能協助分析既有資料，更強調「創造」新資料的能力。應用範圍包括自動生成文章摘要、文本情緒分析，以及建構更加自然、互動性更強的聊天機器人（Chatbot）等。圖 5 簡要呈現 AI 領域技術演進的過程。

¹⁷ 相較於自然語言處理技術主要用於讓機器理解、處理與生成人類語言，LLM 則是自然語言處理與深度學習相結合的進階應用。經由大量文本資料訓練後，LLM 可自動執行文本生成、摘要、翻譯與問答等任務。此外，作為生成式 AI 的子集，LLM 主要專注於自然語言任務的處理，而圖像、音樂與影片等內容的生成仍需依賴其他深度學習技術模組。

圖 5：AI 領域技術演進關係



資料來源：整理自 SEACEN 講義

註：Transformer 是一種深度學習架構，由於具有較佳的資料處理效率與學習表現，多為現今主流 LLM 採用，代表者如 GPT (OpenAI)、Claude (Anthropic) 及 Gemini (Google) 等。

至於，為何要導入生成式 AI？生成式 AI 的優勢為何？愈來愈多實證研究顯示，在各行各業中使用生成式 AI 可帶來顯著效率提升。Brynjolfsson et al. (2023) 研究發現，將生成式 AI 對話輔助工具導入客服人員的作業流程後，整體平均人員產出提升約 14%，其中對新手與低技能勞工的生產力提升高達 34%，而對有經驗或高技能勞工的影響則較小。Noy and Zhang (2023) 研究也得出相似結果：生成式 AI 對低能力者的幫助更大，使員工間產出的時間與品質標準差縮小；此外，接觸生成式 AI 的團隊，普遍對工作滿意度

與自我效能感¹⁸ (Self-Efficacy) 有所提升，並在工作發想上更具創造力，也能進行較全面的思考。

有關央行導入生成式 AI 的應用實例，課程特別邀請澳洲 (Reserve Bank of Australia, RBA) 與紐西蘭 (Reserve Bank of New Zealand, RBNZ) 央行的研究人員進行經驗分享。

澳洲央行經濟研究部門成立了一支五人專案小組，透過跨部門合作，專注於提供資料科學相關議題的解決方案。小組的五大核心任務包括：文本資料分析與生成強化、資訊檢索精進、新興大數據應用、機器學習建模與訓練，以及內部作業流程自動化。

近期最顯著的成果，是將實施長達 25 年的商業聯絡計畫 (Business Liaison Programs) 資料整合至一套利用 LLM 開發的文本分析與檢索工具資訊系統，並已開始用於支援經濟分析。其中一項研究發現，與澳洲央行現行工資預測基準模型相比，若將基於商業聯絡計畫文本生成的工資成長指標納入模型，工資成長的即時預測表現將顯著提升，整體樣本準確度提高約 20% (Gray et al., 2025)。

該團隊尚開發了一套專屬用於內部查詢較為機敏資料的「檢索增強生成 (Retrieval-Augmented Generation, RAG)」資訊系統，旨在提升作業檢索效率，並嘗試在工作效能提升與資訊安全管理間取得平衡。透過定期的內部問卷調查顯示，該工具整體獲得不錯的回饋與使用率，不過使用回饋呈現兩極化，仍有進一步改善的空間。

紐西蘭央行則於 2023 年生成式 AI 蓬勃發展以來，積極推動組織內部的 AI 轉型。該行將傳統以預測為核心的機器學習作業，逐步轉向以流程強化 (Process-Augment) 為導向的營運型 AI

¹⁸ 心理學家 Bandura (1977) 提出，自我效能感指個人對自身能否達成特定目標的認知期待與信心程度。自我效能感的高低會影響個人的決策與行為，而良好的自我效能感則有助於人們在逆境中完成預期任務目標。

(Operational AI) 應用，目前主要實踐於會議流程智慧化以及文獻綜整與管理兩大場域。

有關會議流程智慧化，在隱私優先的前提下，整合既有的會議工作流程，包括：提升語音轉錄準確性、智慧摘要會議重點與決策事項、AI 識別待辦業務並追蹤後續成效，以及建立支援跨歷史會議紀錄全文檢索功能的檔案庫。使用者可控制哪些內容會被利用與儲存，並為所有 AI 生成的內容建立明確且可回溯的數據軌跡。

另外，運用最新 LLM 進行全面性的文獻綜整與管理，透過相關技術能迅速掌握全球央行經濟研究的新興議題與發展趨勢，並清楚呈現核心研究與延伸研究之間的關聯性，同時保留各文獻的原始資料連結，供以便後續延伸閱讀與驗證。自動化的 AI 編審程序有助於強化引文與參考文獻的正確性、確保寫作風格與文法的一致性，並大幅降低人力成本，增加研究量能。

(二) 生成式 AI 潛在風險

生成式 AI 的快速發展已對各行各業帶來深遠影響，也為央行研究人員在提升作業效率、強化決策能力及改善服務品質方面帶來顯著進步。然而，其應用過程中引發的倫理、法律與社會挑戰不容忽視。舉例而言，生成錯誤資訊的風險、隱私侵害、偏見與歧視，以及缺乏完善的問責機制等問題，均引起廣泛關注與擔憂。

生成式 AI 所產生的偏誤¹⁹，往往源自於訓練資料與演算法本身的限制。其根本原因在於演算法反映了開發者在日常生活中既存的偏見，而這些偏見又受限於訓練資料集的定義與範圍。

¹⁹ 本節關於偏誤的說明與案例，並非僅限於生成式 AI 才會發生。由於其理論基礎涉及演算法與大數據資料集的訓練，較為基礎的傳統 AI 方法同樣難以避免類似問題，可作為前述各章節的延伸與補充。

例如，一套用於招聘的 AI 系統，若以公司過去的錄用資料作為訓練依據，必然會反映該公司既有的招聘偏見與歧視。據路透社報導²⁰，美國亞馬遜公司（Amazon）曾開發一款自動審核應徵者履歷的系統，結果卻被發現偏向排除女性申請者，原因在於其訓練資料反映了科技產業長期以來男性員工佔多數的現實。其它導致偏見與歧視的類似案例還包括：犯罪風險評估系統在刑事訴訟中對有色人種的不利影響²¹，以及線上自動信用評分對女性或少數族裔等弱勢族群貸款政策的歧視²²。

此外，演算法在識別資料中尚未出現的模式時極具困難，且演算法普遍存在所謂「穩定性偏誤」（Stability Bias），意即在不確定環境下傾向維持現狀的運算模式。例如，若僅以 2008 年金融危機前的美國房貸資料進行訓練，模型便難以接受全美房價可能出現負成長的情況；又如，在現實中出現負利率之前，全球也沒有任何模型能成功預測此一現象。

儘管近年有研究者提出利用深度學習演算法，以真實資料作為訓練樣本，生成「合成資料（Synthetic Data）」以解決資料稀缺與模式缺失的問題，然而，演算法會在極為細緻的層次捕捉潛在模式，因此每一個合成資料的屬性皆須謹慎設計，否則仍可能導致演算結果不準確。

另一項重要挑戰是演算法的公平性（Fairness）。在某些情境下，如純粹用於預測，公平性可能不是首要考量；惟在科技監理、保險核保，以及前述信用評分、刑事訴訟與就業徵選等應用領域

²⁰ Dastin, J. (2018, Oct. 10). "Insight - Amazon scraps secret AI recruiting tool that showed bias against women." *Reuters*. <https://www.reuters.com/article/world/insight-amazon-scraps-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK0AG/>

²¹ Angwin et al. (2016, May. 23). "Machine Bias." *ProPublica*. <https://www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing>

²² Ward-Foxton (2019, Apr. 30). "Reducing Bias in AI Models for Credit and Loan Decisions." *EE Times*. <https://www.eetimes.com/reducing-bias-in-ai-models-for-credit-and-loan-decisions/>

中，公平性則極為關鍵。為回應此挑戰，演算法問責性（Algorithmic Accountability）的概念逐漸成形，即要求設計、部署或使用演算法的人，應確保系統決策之透明、可解釋且公平，並且能對其行為可能造成的負面影響負責。

其他 AI 應用尚面臨若干挑戰，以下挑選較為重要的項目，簡要說明如下：

1. 黑盒解釋（Black-Box Explanation）

指內部運作無法直接被觀察、理解或解釋的系統或模型。使用者只能觀察其輸入與輸出，卻無從得知其中的決策邏輯或運算過程。這類模型通常具有高度複雜性，同時也擁有良好的預測能力。然而，在需要解釋性（Explainability）與透明度（Transparency）的應用場域中²³，過度依賴黑盒模型可能引發信任、責任與倫理等問題。

近年來，許多新興研究嘗試利用各種數理方法，從不同角度解釋 AI 的運算與推理過程²⁴，尤其在 LLM 領域，惟龐大的參數規模與複雜的演算法架構，解釋難度前所未見。目前，此方面的研究仍處於起步的階段，應用尚未成熟、挑戰甚多。

2. 訓練資料洩漏（Training Leakage）：

在訓練 LLM 的過程中，本不應在訓練階段出現的資訊（如測試集樣本或未來資訊），意外納入模型學習，便會發生「資料洩漏」。由於模型提前接觸這些不該出現的資料，相當

²³ 例如，金融監理、醫療診斷、司法決策、風險評估等。

²⁴ SEACEN 研訓課程第十六講，舉出目前解釋 LLM 的五大面向，分別為「內生解釋（Intrinsic Explainability）」、「事後解釋（Post-Hoc Explanation）」、「機械性解釋（Mechanistic Explanation）」、「稀疏字典學習（Sparse Dictionary Learning）」以及「視覺化（Visualisation）」。

於「提前知道答案」，導致預測結果或估計參數過於樂觀，而在實際應用時往往表現不佳。

Ludwig (2025) 指出，為避免此問題，應僅使用開源²⁵ (Open-Source) LLM，且必須公開模型相關參數與完整訓練資料來源²⁶；若用於參數估計，則必須額外蒐集驗證樣本，以正確評估並校正模型自動化所產生的誤差。

3. 幻覺 (Hallucination)：

指生成式 AI 產生看似合理且具權威性，但實際上不正確或虛構的資訊，此為語言模型應用中常見的現象。Dahl et al. (2024) 發現，在法律領域中，幻覺現象發生機率高達 58%。

在缺乏外部驗證機制的情況下，幻覺往往難以察覺與評估。現階段 AI 並非真正理解自然語言，而是依據機率預測，將龐大訓練資料中觀察到的語言片段拼湊而成，因而缺乏事實判斷力。Bender et al. (2024) 將此運作模式稱為「隨機鸚鵡 (stochastic parrot)」。

近期研究指出，幻覺現象恐是語言生成技術與生俱來，難以完全避免的特性 (Kalai and Vempala, 2024; Xu et al., 2024)。因此，對於模型生成的內容應審慎檢視，並限制其在高風險領域的應用，以降低潛在損失。

4. 文檔債務 (Documentation Debt)：

泛指在模型開發、訓練、部署與維護過程中，若未能及

²⁵ 開源型 LLM 包括 Llama 與 Stories LM 系列；封閉型 LLM 則有 OpenAI 發布的 GPT 系列，以及 Anthropic 推出的 Claude 系列。

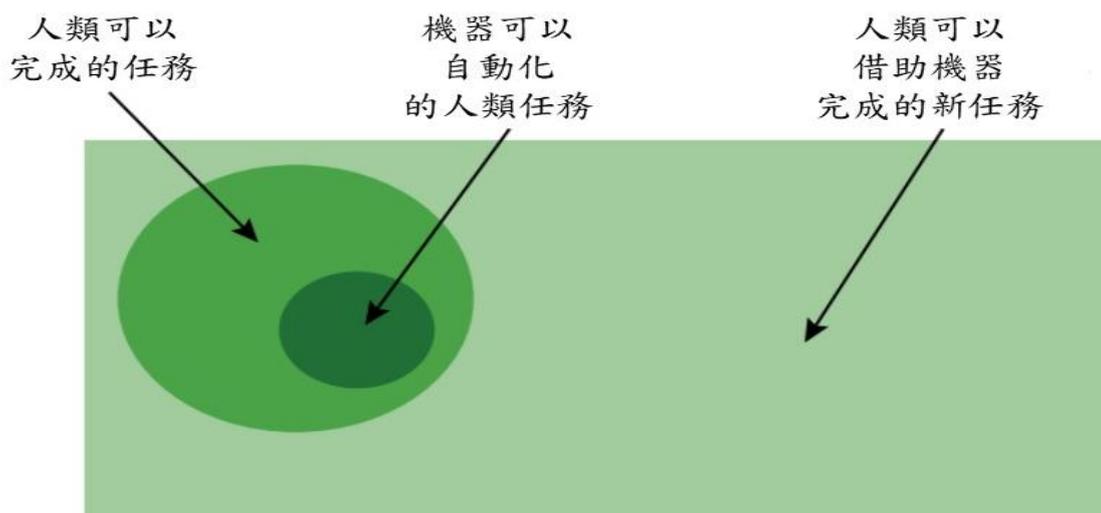
²⁶ Barrie et al. (2024) 指出即使 OpenAI 並未對外宣布有任何模型更新，如果將相同的提示詞 (Prompt) 輸入 GPT-4o 模型，不同月份仍可能產生不同結果，顯示封閉型 LLM 會在不透明的情況下持續被調整，進而影響模型輸出結果。

時或充分記錄系統架構、模型設計、資料流程與決策依據等相關文件，導致後續模型架構缺乏文檔紀錄，且複雜度過高，無法事後補充說明。這會使理解與管理成本大幅增加，同時降低了訓練資料的可追溯性與特徵透明度。

缺乏完整的文檔記錄，將無法有效掌握訓練資料特徵，也難以對模型運作中出現的問題進行修正與優化。因此，將資源投入文檔管理並妥善紀錄訓練資料集，其重要性雖不亞於模型本身，卻是常被忽視的關鍵環節之一。

綜上所述，現階段 AI 無法完全取代人類所有工作，若欠缺人為審查、驗證與價值判斷，其使用將面臨高度不確定性與潛在風險。此外，借鑑歷史經驗，Brynjolfsson (2022) 指出，借助 AI 擴展與強化人類能力，開創新任務所帶來的效益，遠大於僅自動化人類現有任務（如圖 6 所示）。這被視為人機協作的最佳實務，能有效降低落入「圖靈陷阱²⁷ (The Turing Trap)」風險。

圖 6：最佳化 AI 實務



資料來源：整理自 Brynjolfsson (2022)

²⁷ Brynjolfsson (2022) 定義為過度追求 AI 自動化，將其應用於取代人類的工作，而忽視其擴展與輔助人類提升勞動能力的技術。此種作法可能導致財富與權力集中，形成新型態的「均衡陷阱」風險，使弱勢群體難以改善自身處境。

（三）AI 治理與小結

AI 技術正以前所未有的速度發展，最先進的 AI 模型在廣度、複雜度與功能性方面均與以往技術和系統截然不同，因此 AI 治理（AI Governance）未必能跟上其實際發展的步伐。

當前 AI 治理面臨的主要挑戰包括高度的變動性與不確定性、應用的兩面性以及規範尺度的多元性²⁸。由於 AI 持續成長、發展與突破，其能力在公布時往往未知，且釋出後可能透過額外強化學習進行訓練，導致我們對 AI 運作的掌握與因應技術均極為有限，更甚者，連其風險來源與性質也知之甚少。

應用的兩面性，例如在醫學上利用 AI 預測蛋白質摺疊可能性的技術，雖能促進新藥研發，但也可能被用於開發生物武器，使我們面臨一項長期以來的問題：如何在不扼殺 AI 創新的情況下有效監管？另外，涉及國防與軍事安全的 AI 應用，若以國家角度納入治理討論，將使 AI 治理更為複雜，地緣政治角力亦成為治理格局中的重要因素。

最後，AI 規範涉及多元價值判斷，且具有高度在地化特徵，例如受語言與訓練資料影響等。以最新歐盟《人工智慧法案》²⁹（EU AI Act）為例，儘管歐盟當局期待發揮「布魯塞爾效應（Brussels Effect）」，使其成為事實上的全球標準並影響歐洲以外地區，惟其效力在 AI 領域可能有限。與《一般資料保護規則》（General Data Protection Regulation, GDPR）填補隱私規範空白不同，AI 仍存在其他競爭監管模式，例如美國偏好自願性框架而非強制規定；中國則在特定領域對 AI 嚴格管控（Chadwick et al., 2025）。

²⁸ 觀點整理自 SEACEN 研訓課程第十四講「Artificial Intelligence, Governance and Regulation」。

²⁹ 自 2025 年 8 月 2 日起，人工智慧法案項下針對「通用型人工智慧 (General-Purpose AI, GPAI) 模型」監管規定正式生效，為全球 AI 治理重要的里程碑。

綜上所述，全球對於 AI 治理現狀仍缺乏一套全面且具約束力的框架。當前由各國或國際組織提出的相關倡議路徑³⁰多屬自願性質，導致規範零散與缺乏一致性。分歧且彼此相互衝突的 AI 治理制度，恐引發監管向下競爭（Race to the Bottom），並使企業從事監管套利，進而削弱治理成效。在此背景下，單一國家或區域難以有效管控 AI 技術所帶來的風險，其治理最終仍需依靠國際社會的廣泛合作，建立多邊共識與統一標準。規範內容亦應隨 AI 技術的快速變遷及時調整，避免過度僵化或落後於技術發展，方能有效引導 AI 技術發展，落實風險控管並促進其正面價值的實現。

肆、心得與建議

一、心得

（一）傳統研究方法難以即時、有效且精確地對新興大數據進行分析，須導入新興研究分析工具與相關配套措施，以強化央行業務決策基礎

現有傳統研究方法難以即時、有效且精確地因應大數據分析需求，尤其在當前金融市場與實體經濟受到全球化、地緣政治與氣候風險等多重衝擊時，傳統模型難以快速捕捉新形態的經濟訊號與結構性變化。

導入新興研究分析工具，輔助央行進行資料處理並提升整體工作效能已勢在必行，且提供補充傳統研究方法不足的可能方向。同時，仍須搭配周全的配套措施，例如提升基礎

³⁰ 相關指引中，以 OECD（2019）「Recommendation of the Council on OECD Legal Instruments Artificial Intelligence」與 UNESCO（2022）「Recommendation on the Ethics of Artificial Intelligence」兩份文件對全球影響最為深遠，為許多國家或區域組織 AI 相關政策制定主要的參考範本。

設備算力、培訓專業人才、跨部門整合與改善組織文化等。在技術、人才與制度三方面同步配合下，方能發揮對央行決策的最佳支持效果。

(二) 理解並留意新型分析工具應用背後的限制與風險，於兼顧決策效益與風險管理前提下，找出最佳互動模式，持續深耕並推動其應用

新型研究分析工具帶來的挑戰，不僅在於「是否使用」，更在於「如何妥善運用與管控」。受限於演算法與訓練資料集可能產生的各式偏誤，以及對隱私、倫理與資安疑慮，這類工具僅能作為傳統研究方法的補充，並需透過交互驗證以確保結果可靠。

至於最佳互動模式，關鍵在於如何定義人機協作關係。正如 Brynjolfsson (2022) 指出，透過 AI 擴增人類能力，惟仍需搭配適切的治理原則，以確保該技術成為可靠的政策支援工具，帶來實質且正面的政策效益。

二、建議

(一) 應把握數位轉型契機，並參考各國央行經驗，在組織內部導入 AI 應用，簡化作業流程並提升工作效能

隨資訊科技發展日新月異，導入並強化各類資料分析工具與方法已成不可逆的趨勢。特別是生成式 AI 技術快速演進，正從根本上改變工作流程與創新模式，因此央行應於此波劇變中，把握數位轉型契機。

可借鏡澳洲與紐西蘭央行的經驗，以「人才為本、AI 輔助與可問責的治理方式」的原則，簡化作業流程並提升工

作效能。亦即，將 AI 定位為強化行政作業與輔助決策的工具，而非取代人類能力，並持續鼓勵機關內部積極嘗試、創新與學習，安排專屬時段投入 AI 技能培養與探索。同時，在所有關鍵決策中，應在人類監督前提下，保障輔助流程的透明度與可解釋性，以達成永續 AI 實踐的原則。

(二) 積極參與國際組織相關 AI 合作倡議與政策討論，持續與專家交流互動，推動業務精進，以強化政策效能與可性度

應持續關注 AI 治理議題的國際發展趨勢，積極參與國際組織的 AI 合作倡議與政策討論，以吸收最新理論與實務經驗，確保相關措施與技術導入能隨科技與政策環境變化持續優化，實現穩健且具前瞻性的 AI 應用發展。

同時，定期檢視 AI 在業務推動中的運作現況，強化風險控管與績效評估，及時發現並化解潛在風險與挑戰，適時更新內部因應機制，並透過積極溝通與透明資訊揭露，增進社會大眾對政策的理解與信任，維護央行的公信力與政策效能。

參考文獻

- Barrie, C., A. Palmer, and A. Spirling (2024), “Replication for Language Models Problems, Principles, and Best Practice for Political Science,” *Mimeo*.
- Bender, E. M., T. Gebru, A. McMillan-Major, and S. Shmitchell (2021), “On the Dangers of Stochastic Parrots: Can Language Models be Too Big ?” *In FAccT '21 Proceedings of the 2021 ACM Conference on Fairness, Accountability and Transparency*, 610-623.
- Boissay, F., T. Ehlers, L. Gambacorta, and H. S. Shin (2021), “Big Techs in Finance: on the New Nexus Between Data Privacy and Competition,” *The Palgrave Handbook of Technological Finance*, 855-875.
- Brynjolfsson, E. (2022), ”The Turing Trap: The Promise & Peril of Human-Like Artificial Intelligence,” *Daedalus*, Vol. 151, No. 2, 272-287.
- Brynjolfsson, E., Li, D., and Raymond, L. (2023), “Generative AI at Work,” *NBER Working Paper No. 31161*.
- Bandura, A. (1977), “Self-efficacy: toward a unifying theory of behavioral change,” *Psychological review*, 84(2), 191-215
- Chadwick, M., O. Rummel, and A. Sungur (2025 Apr. 9), “The European Union’s Artificial Intelligence Act: Reshaping the Future of Artificial Intelligence Regulation.” The Seacen Centre. <https://suara.seacen.org/the-european-unions-artificial-intelligence-act-reshaping-the-future-of-artificial-intelligence-regulation/>

- Chong, E. and S. J. Ho (2023), “Measuring Text-Based Sentiments from Monetary Policy Statements,” *Bank Negara Malaysia Working Papers WP5 2023*
- Cornelli, G., S. Doerr, L. Gambacorta, and B. Tissot (2022), “Big Data in Asian Central Banks,” *IFC Working Paper No. 21*.
- Correa, R., K. Garud, J. M. Londono, and N. Misleng (2021), “Sentiment in Central Banks’ Financial Stability Reports,” *Review of Finance*, Vol. 25(1), pages 85-120.
- Dahl, M., V. Magesh, M. Suzgun, and D. E. Ho (2024), “Large Legal Fictions: Profiling Legal Hallucinations in Large Language Models,” *Journal of Legal Analysis*, 16(1), 64-93.
- Einav, L. and J. Levin (2014), “Economics in the Age of Big Data,” *Science*, 346 (6210), 1243089.
- Financial Stability Board (2017), “Artificial Intelligence and Machine Learning in Financial Services,” *Market Developments and Financial Stability Implications*, 1 November.
- Indonesia Bank (2023), “Big Data Applications in Monetary Policy and Financial Stability for SEACEN Member Economies: The Case of Bank Indonesia,” *Research Studies*, July.
- Jones, C. and C. Tonetti (2020), “Nonrivalry and the Economics of Data,” *American Economic Review*, Vol. 110, No. 9, 2819-58.
- Kasperson, E. R., O. Renn, P. Slovic, H. S. Brown, J. Emel, R. Goble, J. X. Kasperson, and S. Ratick (1988), “The social amplification of risk: A conceptual framework,” *Risk analysis*, 8(2), 177-187.

- Kalai, A. T. and S. S. Vempala (2024), “Calibrated Language Models must Hallucinate,” *In Proceedings of the 56th Annual ACM Symposium on Theory of Computing*, 160-171.
- Laney, D. (2001), “3D Data Management: Controlling Data Volume, Velocity and Variety,” *META Group Research Note*, 6(70), 1.
- Loughran, T. and B. McDonald (2011), “When is a Liability not a Liability? Textual Analysis, Dictionaries, and 10-Ks,” *The Journal of finance*, 66(1), 35-65.
- Ludwig, J., S. Mullainathan, and A. Rambachan (2025), “Large Language Models: An Applied Econometric Framework (No. w33344),” *National Bureau of Economic Research*.
- Gray, N., F. Lattimore, K. McLoughlin, and C. Windsor (Forthcoming), “An AI-powered Tool for Central Bank Business Liaisons: Quantitative Indicators and On-Demand Insights from Firms,” *RBA Research Discussion Paper No 2025-xx*.
- Noy, S. and W. Zhang (2023), “Experimental Evidence on the Productivity Effects of Generative Artificial Intelligence,” *Science*, 381(6654), 1075-1081.
- SEACEN (2026, June 16-20), *Data Analytics for Macroeconomic Surveillance* [Course Sessions], SEACEN Course on Data Analytics for Macroeconomic Surveillance, Bali, Indonesia.
- Xu, Z., S. Jain, and M. Kankanhalli (2024), “Hallucination is Inevitable: An Innate Limitation of Large Language Models,” *Under review*.