

傳統統計模型與機器學習模型之區隔力比較與應用

張雅媚 李佳壘 張恆維 / 金融聯合徵信中心 研究部

前言

近年來，人工智慧（Artificial Intelligence，以下簡稱AI）蔚為風潮，從日常生活中的智慧助理、汽車自動駕駛，至總體經濟市場之情勢預測、醫療診斷的輔助工具等，AI的應用範疇日益趨廣。在金融領域，已有不少業者以機器學習（Machine Learning，ML）作為AI的核心驅動力，其相關演算法、生成式人工智慧（Generative AI，以下簡稱GAI），以及可解釋性人工智慧（Explainable AI，以下簡稱XAI）等概念與技術，正逐漸在學術界及產業實務界普及。

分辨式人工智慧（Discriminative AI）與生成式人工智慧（GAI）是在現今AI領域中兩個重要的範疇。分辨式AI的應用在於根據輸入數據將其正確地分類或預測其所屬的類別，如聯徵中心使用銀行報送過來個人戶及企業戶之授信資料，以該些資料有效預測該些授信戶未來是否會違約；抑或在醫療領域中，根據病患的影像判斷其是否罹患特定疾病，皆屬於分辨式AI之應用範疇；常見的分辨式AI模型包括羅吉斯

迴歸、決策樹、類神經網路、隨機森林及支援向量機等。相較之下，GAI的功用則是生成與訓練數據相似之新數據，近年來備受矚目的GAI如GPT系列之大型語言模型（Large Language Models，以下簡稱LLMs），以及DALL-E等圖像生成模型，便是GAI的典型代表，這些模型能夠生成相當逼真的文本、圖像、音訊及影片等，其應用範圍涵蓋內容創作、虛擬助理、以及新藥開發等領域；GAI的快速發展，展現AI在創造力方面之潛力，卻也引發關於內容真實性、智慧財產權等一系列重要的倫理與社會議題，目前較不適合運用於聯徵中心之評分相關業務上。

故本研究主要聚焦於分辨式AI的範疇，將不同種類之消金及企金資料，採用各種統計與機器學習模型，對特定研究標的進行分析與預測。後續研究主要分為二個目的，一是針對聯徵中心個人戶及企業戶評分範圍之樣本，利用不同研究方法預測客戶未來違約機率，比較各方法與聯徵中心信用評分產品（個人為J10，企業為J21）之區隔效果與模型適用性，瞭解若以

其他研究方法在處理個人戶與企業戶授信等大量金融數據時，是否預測更精準、區隔能力更佳，或是在計算與應用上更有效率，並兼顧變數可解釋性與合理性，同時可達成模型維護之方便性以及法規與倫理考量；綜合衡量這些研究方法在聯徵中心應用之適切性。

另一個研究目的則為嘗試將既有信用評分模型的預測目標，從個人戶及企業戶未來「違約與否」置換成未來「資金需求程度」，藉由聯徵中心特有的新業務查詢次數進行觀察，並著重於評估不同研究方法在資金需求預測上的區隔力。此外，亦嘗試加入除聯徵中心評分變數外之其他變數，如特約商店（以下簡稱特店）及電子支付機構特約機構（以下簡稱電支特約機構）等相關非傳統評分變數，進入模型中綜合探討，因現今金融市場消費型態之改變，愈來愈多消費者透過信用卡及電子支付消費，將藉此進一步分析是特店或電支特約機構之賣家，在未來對資金需求之程度。

本研究後續將研究結果以消金與企金分別清楚整理。由於個人戶和企業戶的屬性、行為模式以及金融需求存在顯著差異，因此針對兩者開發之預測模型和所考量的關鍵變數也會有所不同。在消金方面，模型可能會更側重於個人的信用卡行為、授信行為等；而在企金方面，除了企業之授信行為，財務報表、產業特性以及與銀行往來之歷史記錄等，亦是相當重要的一環。期望藉由本次研究，透過各種研究方法分別建立模型和評估分析結果，能更清晰地瞭解與比較分辨式AI在不同客戶群體中之應用效果。

AI在金融市場應用情形

數位轉型浪潮下，AI正快速改變各行各業的運作模式，特別是在金融產業中，AI的導入已成為轉型升級的關鍵驅動力。隨著大數據與演算法技術的成熟，金融機構積極導入AI應用強化各項業務流程，從前台的客戶服務、中台的風險管理、詐欺偵測，到後台的行政管理與流程優化，涵蓋面向十分多元，以協助金融機構提升營運效率、降低成本，並創造前所未有的競爭優勢。

舉例而言，在內部訓練方面，金融機構運用GAI技術模擬多種客戶互動情境，使業務人員可透過對話練習提升應對與溝通能力，相較傳統大量人工訓練資源，不僅可有效降低教育訓練成本，也加快人員熟悉業務的速度；此外，亦透過自然語言處理（Natural Language Processing，以下簡稱NLP）技術，分析內部文件與作業流程，逐步建立內部專屬的資料庫，使員工透過提問即可快速獲得精準回覆，顯著提升作業效率與準確性。

在智能客服應用，金融機構逐步導入LLMs，結合內部資料，打造專屬AI客服系統，可快速回應客戶多樣化、個人化的需求，提供24小時的即時服務，以有效提升服務品質與滿意度；此外，在客戶行銷方面，透過GAI技術分析客戶偏好，根據客戶過去的交易與瀏覽行為，精準推薦適合的理財商品或優惠活動，以提升行銷成效並增強客戶的黏著度。

最後，在詐欺偵測領域，金融機構則運用機器學習模型開發系統，藉由即時分析大量交易資料，快速識別異常行為模式與可疑交易，

以提前發出風險警訊，大幅提高防詐效率。整體而言，AI技術在金融領域扮演愈來愈關鍵的角色，隨著技術日趨成熟，未來應用將更加深入與普及。

AI在信用風險領域應用概況

瞭解金融業大致AI應用範疇後，本節將進一步說明AI於信用風險領域的應用概況。在信用風險領域中，信用風險評分模型是授信決策的重要工具，早期主要以傳統統計模型（如羅吉斯迴歸模型）作為主要核心基礎，藉由客戶的信用資料（如負債狀況、還款紀錄等），預測其未來的違約風險；然而，針對缺乏信用歷史資料的信用小白或信用資料相對不足的客群（如中小企業、自由工作者）而言，往往難以進行準確的授信決策。

隨著處理大數據處理與AI技術的快速發展，金融機構開始嘗試運用多元的資料來源及非結構化資料，使用機器學習模型方法進行信用風險分析，透過NLP、網路爬蟲等技術，從替代性資料中擷取重要資訊，包含電信資料、網路評論、電商消費紀錄等，並結合傳統信用資料，建構信用評分模型，為缺乏信用資料族群建立更完整的信用輪廓，擴大金融服務的可及性，以更全面地評估申貸者的信用風險。

另一方面，除拓展資料面的使用，金融機構亦嘗試運用機器學習模型進行模型建置，除直接用於訓練完整模型外，亦可運用該方法從原始資料中捕捉細微的行為變化，找出特徵間的非線性關係，再將其整合至傳統統計模型中，在保有可解釋性的同時提升模型準確性，以優化整體模型。

綜上所述，AI在信用風險領域上的發展充滿潛力，但仍面臨許多挑戰與限制，如機器學習模型的可解釋性（Explainability）問題，對於過於複雜的演算法及不透明的產出結果，將不利於監管與客戶溝通；此外，替代性資料的使用亦可能涉及個人隱私，若缺乏明確授權或使用不當，恐觸犯個資保護法規，如歐盟所訂定的《一般資料保護規則》（General Data Protection Regulation, GDPR）對資料取得提出嚴格規範，強調「目的限制」、「合法性」、「資料最小化」等原則，要求在蒐集與處理個資時，目的須特定、合法，且取得用戶同意，並確保資料在適當且最小限度範圍內蒐集，有鑑於此，金融機構必須建立完善的監管機制，審視資料蒐集的正当性與合規性，如何保障使用者的隱私與資訊安全，成為目前金融科技發展中不可忽視的重要課題。

研究設定

本節將說明本次模型建置之整體設計，包含模型方法、建模、驗證時點、模型建置流程，以作為後續模型應用依據，相關設定與說明如下：

一、建模時點：

以2022 / 12為建模時點，2023 / 01~2023 / 12為績效期間。

二、驗證時點：

以2023 / 12為驗證時點，2024 / 01~2024 / 12為績效期間。

三、建模方法：

5種，其中包含2種傳統統計模型（羅吉斯迴歸、決策樹）、3種機器學習模型（類神經網路、隨機森林、支援向量機），將分別依序說明：

(一) 羅吉斯迴歸（Logistic Regression）：

羅吉斯迴歸是一種廣泛應用於二元分類問題的統計模型，透過函數轉換，將預測某事件發生的可能性，輸出至介於0到1之間的機率值，模型結構相對較簡單，且具可解釋性高之特點，其結構如圖1所示。

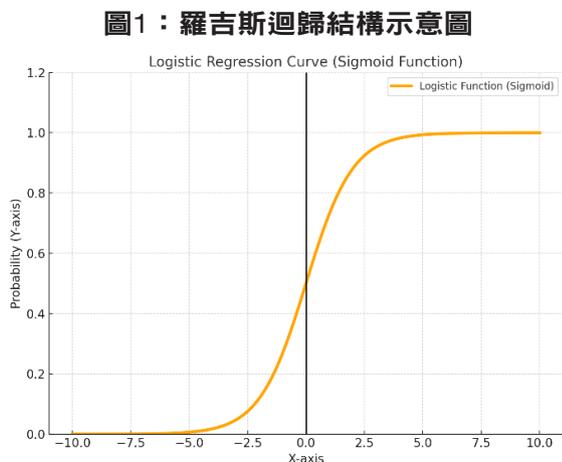
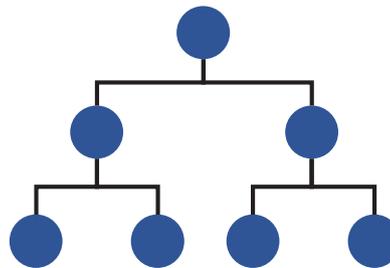


圖1：羅吉斯迴歸結構示意圖

(二) 決策樹（Decision Tree）：

決策樹是一種常見的分類與迴歸模型，透過類似流程圖的結構進行資料分類或預測。模型以節點為單位，將每個節點根據最佳的變數與分割點做出判斷，並依此將資料切分成不同子集，形成一棵分支結構的決策模型。本研究為避免決策樹結果過於複雜，將每個節點分支數限制為2、最大深度設置為4層，其結構如圖2所示。

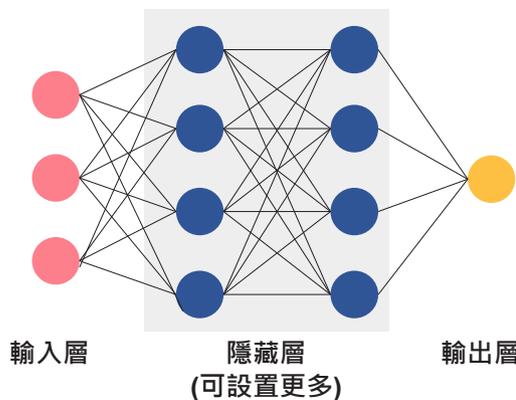
圖2：決策樹模型結構示意圖



(三) 類神經網路（Neural Network）：

類神經網路為模擬人腦神經元結構的機器學習模型，由多項神經元的節點構成，並包含輸入層、隱藏層與輸出層，其透過多層非線性運算，學習資料中的複雜關係與模式，具備強大預測力，並能處理複雜、非線性的數據關係。本研究為探討不同隱藏層數結果之差異，將其分別設定為1-3層進行觀察，其結構如圖3所示。

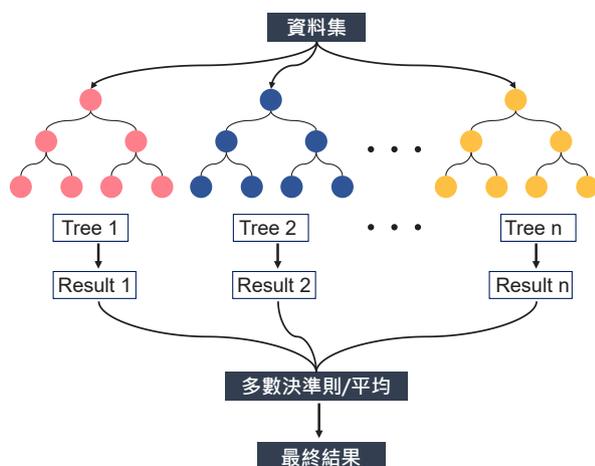
圖3：類神經模型結構示意圖



(四) 隨機森林（Random Forest）：

由多棵隨機生成的決策樹組成，每棵樹使用不同的樣本與特徵進行訓練，並以多數決準則或平均方式決定模型最後預測結果，其可輸出變量的重要性程度，且具備良好的預測準確性。本研究將根據不同樣本，設置不同決策樹數量，其結構如圖4所示。

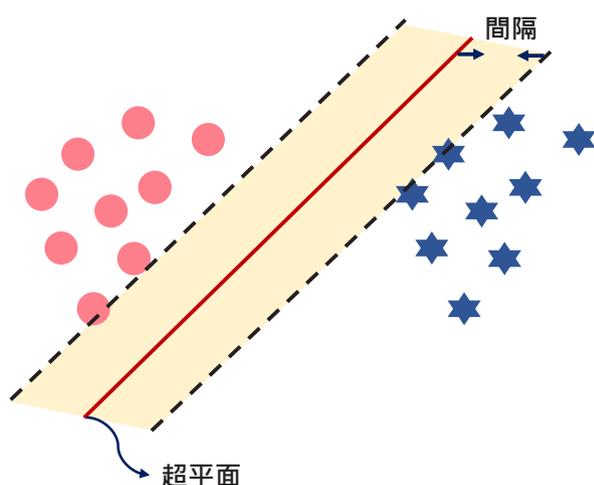
圖4：隨機森林模型結構示意圖



(五)支援向量機 (Support Vector Machine, SVM)：

主要應用於分類問題的機器學習方法，透過尋找最佳化的超平面 (hyperplane)，區分不同類別的資料，使不同類別間の間隔最大化，並可藉由核函數 (kernel function) 處理非線性資料，以達線性可分的效果。其結構如圖5所示。

圖5：支援向量機模型結構示意圖



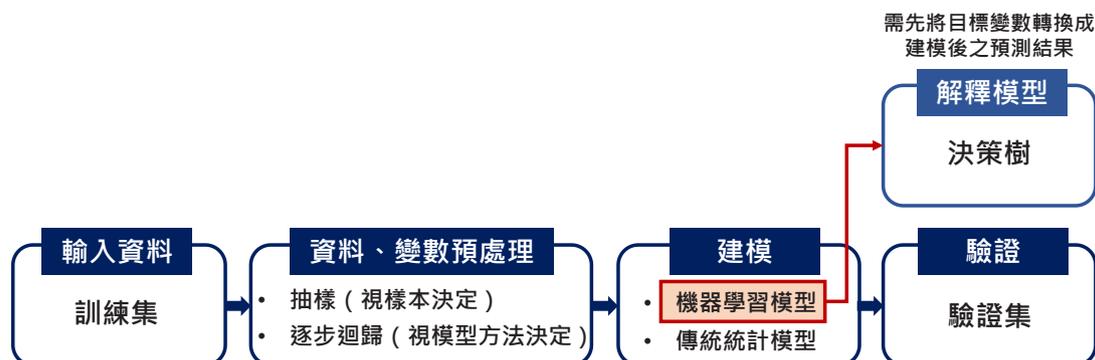
四、建置流程：

本研究係以統計軟體內建之羅吉斯迴歸、決策樹、類神經網路模組、隨機森林與支援向量機方法為基礎進行模型建置，其中，羅吉斯迴歸與決策樹方法由軟體自動化篩選變數後，直接建立模型結果；其餘機器學習模型則為避免模型過度配適 (overfitting) 與提高模型運算效率，將透過逐步迴歸 (Stepwise regression) 方式，事先進行變數篩選，再由模型產生運算結果。

具體建置流程如圖6所示，首先，準備訓練資料集，並進行資料與變數預處理，資料部分將根據樣本數的大小，視情況決定是否進行「抽樣」步驟；變數部分則依據模型方法，再選擇是否透過「逐步迴歸 (Stepwise regression)」方式預先篩選變數，完成上述前置處理後，再接續進行模型建置，分別產出各模型之相應結果；最後，為驗證各模型之預測表現與穩定性，將使用驗證資料集進行測試，以檢驗模型是否具過度配適 (overfitting) 的問題，並評估模型泛化能力。

其中，針對機器學習模型，由於其「黑箱性質」較高，無法直接由模型建置結果中瞭解各變數對目標變數間之影響程度與關聯，故後續將會再透過決策樹方法，進行後續變數解釋性分析；此外，建置決策樹前，須先進行目標變數轉換，意即將原始目標變數 (如是否違約之二元變數) 轉換為機器學習模型所產生之預測機率值，並以此建構後續決策樹。

圖6：模型建置流程



違約模型

聯徵中心現有之信用評分產品（個人為J10，企業為J20、J21）自推出至今，皆已使用十餘年的時間，不論個人或企業之信用評分產品，皆維持穩定且良好之風險區隔效果；期間經歷幾次改版，目前個人部分為第六版，企業則是第三版。本次研究重要目的之一為探討在相同樣本下，比較聯徵中心現有之信用評分產品，與前節介紹之傳統統計模型及機器學習模型之區隔效果與模型適用性，後續將分別呈現個人與企業之分析結果，並以AUC、KS兩項指標進行區隔力之觀察。

一、個人金融

(一) 樣本範圍：

考量個人部位之樣本數過多，若全數投入建模將導致資料處理效率不佳，故本次研究將以聯徵中心J10個人信用評分範圍內之信貸戶

為例，並採取部分抽樣方式建模，將保留所有違約樣本，再以隨機抽樣方式抽出3倍的正常樣本，使最終樣本結構具備足夠的正常樣本，同時保有違約樣本的代表性，如表1所示。

表1：信貸戶樣本說明

	樣本數	違約率
抽樣前樣本	約149.5萬筆	2.7%
抽樣後樣本	約16.2萬筆	25.0%

(二) 輸入變數：

聯徵中心所有評分變數及基本屬性變數¹，涵蓋面向包含信用卡類、授信類、查詢類等，將各面向之資料彙整並量化成相關資訊（變數），作為瞭解個人戶之基礎。

(三) 目標變數：

利用績效期間違約與否，探討研究範圍樣本未來一年是否違約。

1 基本屬性變數包含：性別、年齡、學歷、收入，然該些個人屬性資料，為避免引起爭議，並未實際運用於聯徵中心評分產品中。

(四) 模型區隔力：

比較前節所述之各項模型方法與聯徵中心現行信用評分產品—J10之區隔力，結果如圖7所示。整體而言，在建模時點下，無論觀察哪一指標，區隔效果皆以隨機森林模型最佳，其AUC與KS值分別為 94.4、73.9；反之，以決策樹模型區隔效果最差，其AUC與KS值分別為 67.7、34.9；其餘模型方法之AUC、KS值則分別皆高於89、62，對應至解釋能力指標說明²，顯示其皆具有良好的違約區隔力。

若以J10評分產品角度觀察，其AUC、KS值分別為89.6、62.6，略低於羅吉斯迴歸結果，雖J10評分產品亦為使用羅吉斯迴歸所建構，但因此處羅吉斯迴歸為針對本次樣本重新建模後的結果，故模型可能更貼合現有資料特性，使其區隔效果較高；另一方面，比較傳統統計模型與機器學習模型區隔效果，雖後者預測力較高，惟其提升幅度有限，原因可能與聯徵中心資料多為結構化之負債資料特性有關，其相對完整且邏輯規則一致，導致機器學習方法無法展現其處理大量資料及多樣特徵的優

勢，使兩類模型方法之區隔效果並未有太大差異。

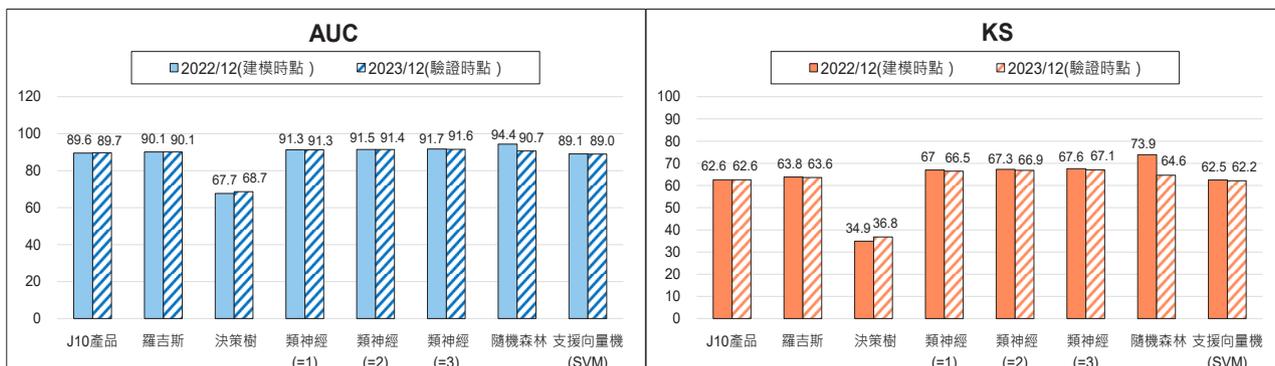
另觀察驗證時點之AUC、KS值，除隨機森林之KS值相較建模時點出現較明顯下滑，可能較不穩定外，其餘各模型區隔表現大致與建模時點相近，顯示模型具良好之泛化能力。

綜上所述，除決策樹外，各建模方法皆有一定區隔水準，且結果並無顯著差異，此外，除隨機森林預測結果可能較不穩定，其餘模型方法應無過度配適（overfitting）的問題，可作為後續分析與實務應用之參考依據。

(五) 模型解釋：

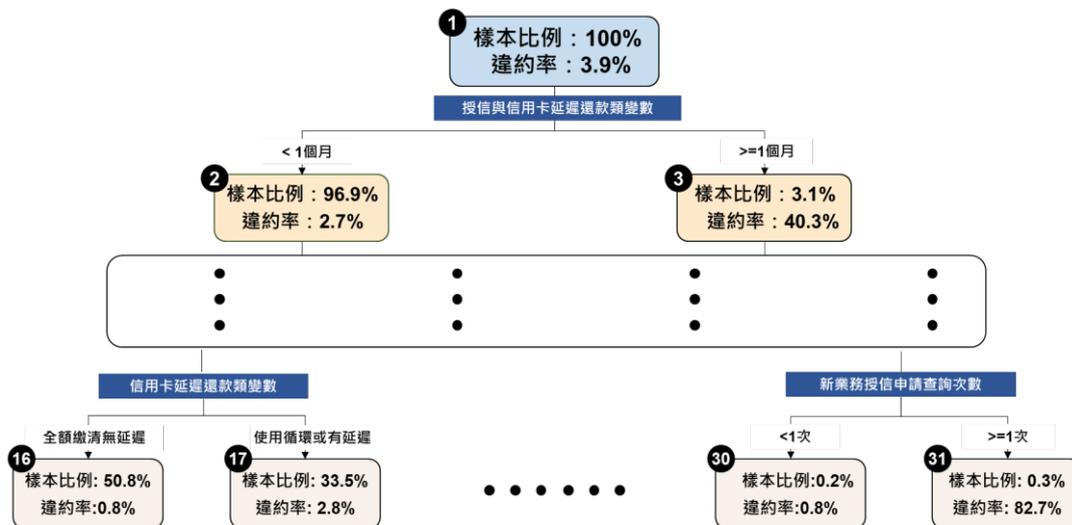
初步瞭解各模型方法區隔力後，針對機器學習模型，本研究進一步運用統計軟體，使其自動化挑選變數及切點，產生最適決策樹結果，以進行後續變數解釋性分析，並以區隔效果最佳方法—隨機森林為例進行說明，此外，因本階段分析重點並非探討各變數對對目標變數之影響程度，故此處僅列示部份決策樹結果，如圖8所示。

圖7：違約模型區隔力結果一個人金融



2 K-S值大於61、AUC值介於80-90間，表示其區隔能力很強。

圖8：違約模型事後解釋之決策樹一個人金融（隨機森林）



在分析決策樹結果前，首先觀察決策樹變數挑選結果，如表2所示，不重複計算下，共有7項變數進入模型，其中有6項與延遲行為相關，另1項則為查詢類變數，整體而言，所有變數皆具合理性，意即延遲行為愈嚴重、查詢次數愈頻繁，其違約風險亦隨之提高。

表2：違約模型變數說明一個人金融(隨機森林)

變數類型	標籤	影響
授信	授信延遲還款類變數	+
	授信延遲類型	+
信用卡	各期間信用卡延遲還款類變數 (此處不一一列示)	+
組合	授信與信用卡延遲還款類變數	+
查詢	新業務授信申請查詢次數	+

接續觀察事後解釋之決策樹結果，首層分類節點為「授信與信用卡延遲還款類變數」，其中，多數樣本於授信及信用卡延遲天數皆小於一個月，約占96.9%，其違約率約2.7%；相對地，僅3.1%樣本延遲天數超過一個月，但其

違約率則高達40.3%，顯示該變數可有效將樣本區分為高、低違約風險兩大群體，最後，觀察最後一層分類，約近5成的樣本會被分類至節點16，且違約率僅0.8%，顯示多數樣本皆屬無或輕微延遲族群。整體而言，透過決策樹的視覺化結構，可瞭解各變數對違約風險的差異，並藉由觀察分類門檻值，作為使用者風險評估之參考。

除列示隨機森林後續建構之決策樹所挑選之變數外，此處亦呈現使用羅吉斯迴歸，自動化選用變數的運算結果。如表3所示，相較隨機森林之事後解釋之決策樹結果，羅吉斯迴歸所納入的變數更為廣泛，惟此差異並非代表兩者結果有優劣之分，因透過決策樹雖然可以輔理解機器學習模型中變數對目標變數的影響方向與程度，但該方法僅為模擬的結果，並無法完整揭示機器學習模型內部複雜的運算邏輯，變數與目標變數間的真实關係與影響仍難以清楚解釋。

表3：違約模型變數說明—個人金融(羅吉斯迴歸)

變數類型	標籤	影響
基本屬性	教育程度	-
授信	授信延遲還款類變數	+
	擔保授信比率	-
	授信餘額減少時間	-
信用卡	信用卡額度使用率	+
	信用卡預借現金額度	-
	有效信用卡持卡時間	-
	信用卡延遲還款類變數	+
組合	授信與信用卡延遲還款類變數	+
查詢	新業務授信申請查詢次數	+

機器學習模型區隔力確實略高於傳統統計模型結果，但考量模型之可解釋性（Explainability）與可溝通性（Communicability），因機器學習模型相對複雜，其運作仍存在一定程度的黑箱特性，導致難以清楚理解，進而對其結果產生疑慮或信任落差；反之，傳統統計模型（如羅吉斯迴歸）在預測力上雖略遜一籌，但其具備明確的參數意義與推論邏輯，能清楚說明各變數對目標變數的影響方向與程度，對於模型建立者與使用者而言，可提供更高的透明度與實用價值。

綜上所述，對於現階段信用報告機構而言，作為對外說明（如對消費者、監理機關）為主要考量，仍以傳統統計模型作為建構信用風險模型之主要方法為宜，不僅能維持模型的穩定性與解釋性，也較易符合合規性、透明性與資訊揭露的需求。

二、企業金融

(一) 樣本範圍：

聯徵中心J21企業信用評分範圍內之樣本，總計約21.2萬家，不另外再以產業別建置評分卡，將全部樣本投入建模。

(二) 輸入變數：

聯徵中心所有評分變數，涵蓋面向包含企業基本資料、授信類、查詢類、財務報表變數及負責人變數等，將各面向之資料彙整並量化成相關資訊（變數），作為瞭解企業授信戶之基礎。

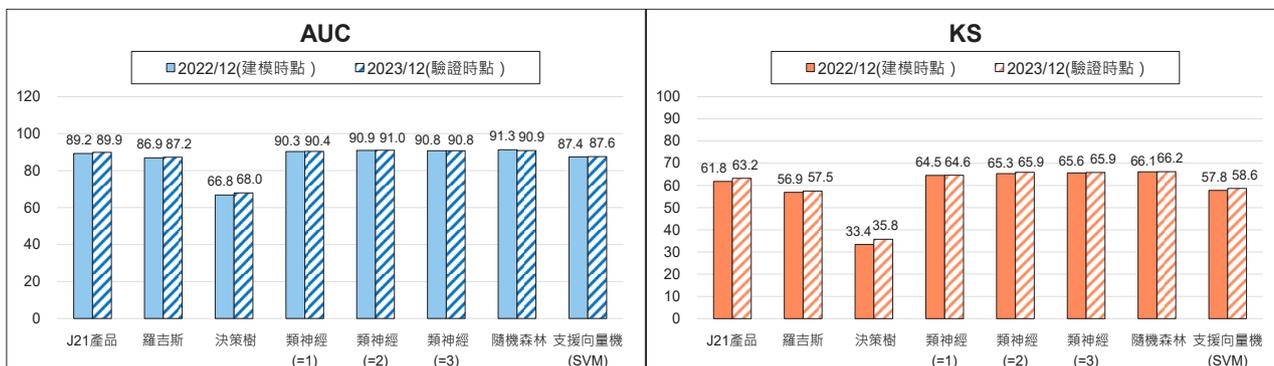
(三) 目標變數：

利用績效期間違約與否，探討研究範圍樣本未來一年是否違約。

(四) 模型區隔力：

首先，從違約模型之區隔能力開始，剖析以各種統計方法建模之結果。在建模時點2022年12月下，如圖9所示，聯徵中心J21產品之KS值為61.8，AUC值為89.2，顯示相當不錯之區隔能力；另外綜合觀察其他傳統統計模型及機器學習模型之結果，可以發現不論是KS值還是AUC值，最高者皆為隨機森林方法，其值分別為66.1及91.3，最低者皆為決策樹方法，其值分別為33.4及66.8；而與聯徵中心建模方法最相近之羅吉斯迴歸，其KS值是56.9，AUC值則是86.9。綜上所述，是以隨機森林方法之區隔能力最佳，但相較於聯徵中心J21產品及羅吉斯迴歸方法，並沒有太顯著之差異；而觀察驗證時點2023年12月下，各統計方法之KS值及AUC值，相較於建模時點，彼此間亦差異不大，顯示皆無過度配適（overfitting）之問題。

圖9：違約模型區隔力結果—企業金融



(五) 模型解釋：

違約模型之樣本範圍為聯徵中心J21企業信用評分範圍，總計約21.2萬家企業，績效期間之違約率為1.1%。針對這些企業樣本，本研究使用許多研究方法，觀察投入變數與目標變數之間的關係；以下將探討傳統統計模型之羅吉斯迴歸與機器學習模型之隨機森林方法，兩者所使用變數面向之異同，以及變數可解釋性之比較，分析採用傳統統計模型與機器學習模型之優劣。

1. 羅吉斯迴歸：

從傳統統計模型方法選取探討羅吉斯迴歸之分析結果，如表4所示，模型使用相當廣泛面向之變數，以下細部觀察所使用變數與企業未來一年違約與否之相關性。首先，企業基本資料有選取成立時間，成立時間愈短，未來違約的機率愈高；授信類變數則呈現額度使用率愈高或十足擔保之授信餘額愈少，以及信保占授信餘額比例愈多，未來違約機率愈高之趨勢；查詢變數與往來銀行家數，則顯示新業務查詢次數愈多或授信往來銀行家數愈多，未來之信用風險愈高；負責人變數則是該企業負責人之授信行為愈差，該企業之違約風險愈高。

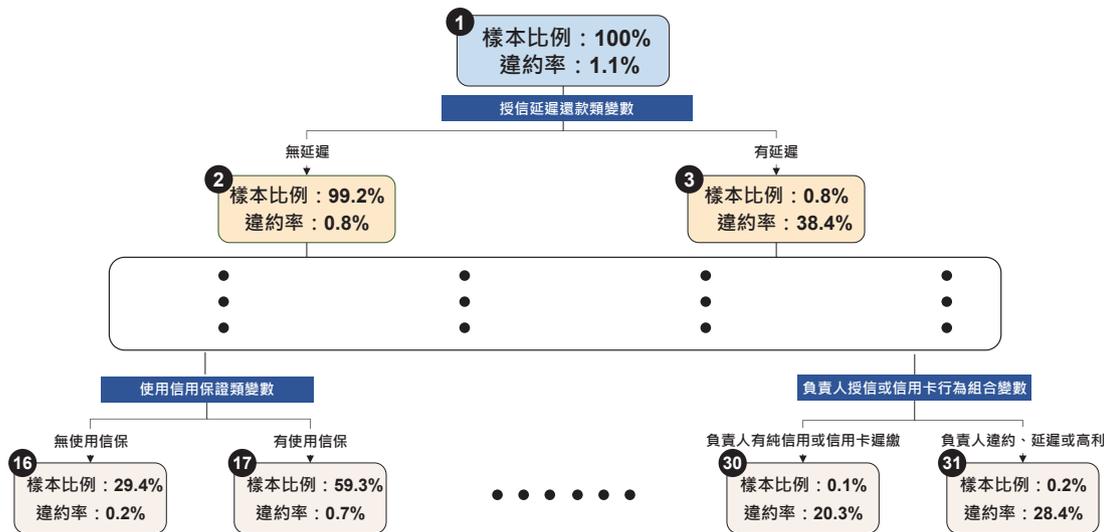
表4：違約模型變數說明—企業金融(羅吉斯迴歸)

變數類型	名稱	影響
基本資料	成立時間	-
	授信	
授信	授信額度使用率	+
	十足擔保授信餘額比例	-
	信保之授信餘額比例	+
查詢	新業務查詢總家數	+
往來家數	授信往來銀行家數	+
負責人	負責人組合變數	+

2. 隨機森林：

機器學習模型方法則選取探討區隔能力最佳之隨機森林分析結果，前面有提到若採用機器學習模型方法，由於其計算過程相當複雜，不容易直接觀察投入變數與目標變數之間的關係，故只能採用事後解釋之方式，針對計算完成之模型，嘗試用決策樹去理解哪些變數會影響企業違約與否。本研究用決策樹之事後解釋方式，是將所有的樣本以不同變數做層層分類，如圖10，嘗試就決策樹之分析結果，解釋投入變數對企業未來違約與否之關係；決策樹有使用之變數則羅列在表5，可以看到與前述羅吉斯迴歸所使用之變數類型不盡相同，雖能就決策樹所呈現之變數對企業違約與否之影響

圖10：違約模型事後解釋之決策樹—企業金融（隨機森林）



看出一些端倪，如授信行為表現較差或查詢次數較多則未來違約機率較高，但無法評估實際影響之多寡。隨機森林的優勢在於模型區隔能力較佳，能更有效預測企業未來是否違約，劣勢是無法很直觀地解釋其計算過程，且採用事後解釋之決策樹呈現之變數往往無法與模型所使用變數完全契合。

表5：違約模型變數說明—企業金融(隨機森林)

變數類型	名稱	影響
授信	十足擔保扣除信保之授信餘額比例	-
	非十足擔保之授信餘額	+
	信保之授信餘額比例	+
往來家數	授信往來銀行家數	+
延遲	有授信延遲紀錄距今月數	-
	有大額退票紀錄	+
	有授信或融資租賃延遲還款類變數	+
負責人	負責人組合變數	+

借款需求預測模型

前一節為觀察樣本在未來一年之違約狀況，本節則是嘗試將目標變數置換，以觀察樣本在未來一年有無新業務查詢來取代，因本研究認為除了違約與否，客戶的借款需求亦是相當重要之研究標的。同前一節，亦會分別呈現個人與企業之分析結果，然而，與前一節不同的是，分析的樣本非皆為聯徵中心評分範圍，個人與企業皆會將樣本範圍依照不同屬性再分成二組，以下皆會詳細說明。

一、個人金融—信用卡樣本

(一) 樣本範圍：

建模時點下持有有效信用卡，且近一年內有交易紀錄之卡戶，並排除近一年曾有授信行為者與資料揭露期限內之違約樣本，與前節相同，考量資料處理效率，將採取部分抽樣方式建模，將保留所有查詢樣本，再以隨機抽樣方式抽出3倍的正常樣本，兩者合計作為分析之樣本，如表6所示。

表6：信用卡樣本說明

	樣本數	查詢率
抽樣前樣本	約631萬筆	8.5%
抽樣後樣本	約215萬筆	25.0%

(二) 輸入變數：

與前一節不同，因本節研究目標為觀察樣本在未來一年有無新業務查詢，若使用過去已有查詢紀錄之變數進入模型，將有可能造成模型預測結果受到目標變數自身特徵的影響，進而產生不合理的結果，故此處將排除查詢類變數，此外，由於已將近一年有授信行為之樣本刪除，故亦將授信類相關變數一併剔除，最後，嘗試再加入特店以及電支特約機構³之資料及J10信用評分進入模型分析，以捕捉潛在之風險特徵。綜上所述，本次模型涵蓋之變數面向包含信用卡類、基本屬性類、評分變數（J10）及特店與電支特約機構等變數。

(三) 目標變數：

利用績效期間有新業務查詢與否，探討研究範圍樣本未來一年是否有新業務查詢。

(四) 模型區隔力：

結果如圖 11 所示，在建模時點下，無論觀察哪一指標，皆以隨機森林區隔效果最佳，其AUC與KS值分別為 72.9、33.5；反之，以決策樹區隔效果最差，其AUC與KS值分別為

66.4、25.4；其餘模型方法之AUC、KS值則分別皆高於69、28，整體而言，雖區隔效果不及前述預測違約之模型結果，但對應至解釋能力指標說明⁴，多數模型方法仍具一定區隔力。

另進一步比較傳統統計模型與機器學習模型區隔力，由圖中所示，雖後者表現略勝一籌，但差異幅度不大，此外，同時觀察類神經網路於不同層數設定下結果，區隔力亦無明顯差異，與前述預測違約模型相同，此結果可能與聯徵中心資料多為結構化之負債資料特性有關，此處不再重複闡述⁵。

最後，觀察驗證時點之AUC、KS值，多數模型方法於驗證時點皆略低於建模時點結果，惟整體差異甚小，顯示模型具良好之泛化能力，並未出現過度配適（overfitting）現象。

綜上所述，除決策樹模型區隔力略低外，各建模方法皆有一定區隔水準且結果並無顯著差異，可作為後續分析與實務應用之參考依據。

(五) 模型解釋：

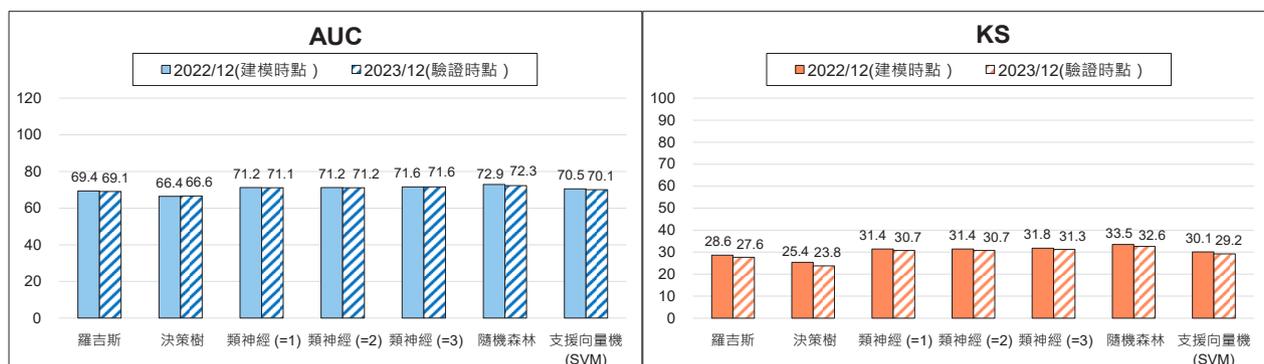
初步瞭解各模型方法區隔力後，針對機器學習模型方法，本研究進一步運用統計軟體，使其自動化挑選變數及切點，產生最適決策樹結果，以進行後續變數解釋性分析，並以區隔效果最佳方法—隨機森林為例進行說明。

3 特店為商店與收單機構簽約，並依該契約接受信用卡交易之商店；電支特約機構則為與電支機構簽約，約定使用者得以電子支付帳戶或儲值卡支付實質交易款項者，前述兩者樣本全體信用卡建模樣本比例，分別約0.04%、1.80%，其占比相對偏低。

4 K-S值介於20-40、AUC值介於70-80間，表示其區隔能力為佳。

5 相關說明詳見前一節中個人金融之區隔力結果。

圖11：借款需求預測模型區隔力結果一個人信用卡樣本



觀察決策樹結果，可發現多數分類變數皆與信用卡使用情形相關，如信用卡負債金額、額度使用率、預借現金額度等，並從上述特徵中可觀察出若信用卡負債金額較高、額度使用率較高或預借現金額度較低者，其查詢率亦會呈現較高的現象。該些變數皆符合實務直覺，舉例而言，信用卡負債金額較高者，顯示其可能存在一定的現金流壓力，若再面臨臨時資金需求，則更有可能產生新的借貸行為；此外，信用卡額度使用率較高的客群亦說明持卡人財務彈性不足，可能頻繁動用信用額度來維持支出，導致未來產生借款需求的比例愈高；相同地，預借現金額度較低者，若出現短期資金吃緊的狀況，亦可能會提高借款意願。

整體而言，針對原先近一年無貸款之潛在借款客群，可藉由觀察信用卡負債狀況、額度使用率及預借現金額度等變數觀察其未來是否借錢的可能性，然如同於前述預測違約模型提及，該決策樹僅為針對機器學習模型所構建之輔助解釋模型，變數皆為模擬出的結果，非代表真實機器學習模型所考量之變數，僅能作為輔助參考，無法提供充分支持依據。

二、個人金融—授信樣本

(一) 樣本範圍：

建模時點下近一年內有授信行為，並排除資料揭露期限內之違約樣本，另抽樣方式與前節個人金融樣本不同，因原始查詢樣本過多，約近145萬筆，若與前節相同保留所有查詢樣本再進行抽樣，將影響資料處理效率，故此處將改採以隨機抽樣方式，自原始樣本中抽取10%作為分析樣本，樣本數則如表7所示。

表7：授信樣本說明

	樣本數	查詢率
抽樣前樣本	約574萬筆	25.0%
抽樣後樣本	約57.4萬筆	25.1%

(二) 輸入變數：

與信用卡樣本相同，本次模型涵蓋之變數面向包含信用卡類、基本屬性類、評分變數（J10）及特店與電支特約機構⁶等變數。

(三) 目標變數：

利用績效期間有新業務查詢與否，探討研究範圍樣本未來一年是否有新業務查詢。

6 特店與電支特約機構樣本占全體授信建模樣本比例，分別約0.09%、2.80%，其占比相對偏低。

(四) 模型區隔力：

結果如圖12所示，在建模時點下，無論觀察哪一指標，區隔效果皆以隨機森林最佳，其AUC與KS值分別為 76.3、39.3；反之，以決策樹區隔效果最差，其AUC與KS值分別為 68.8、29.9；其餘模型方法之AUC、KS值則分別皆高於73、35，整體而言，雖區隔效果不及前述預測違約模型結果，但對應至解釋能力指標說明⁷，多數模型方法仍具一定區隔力。

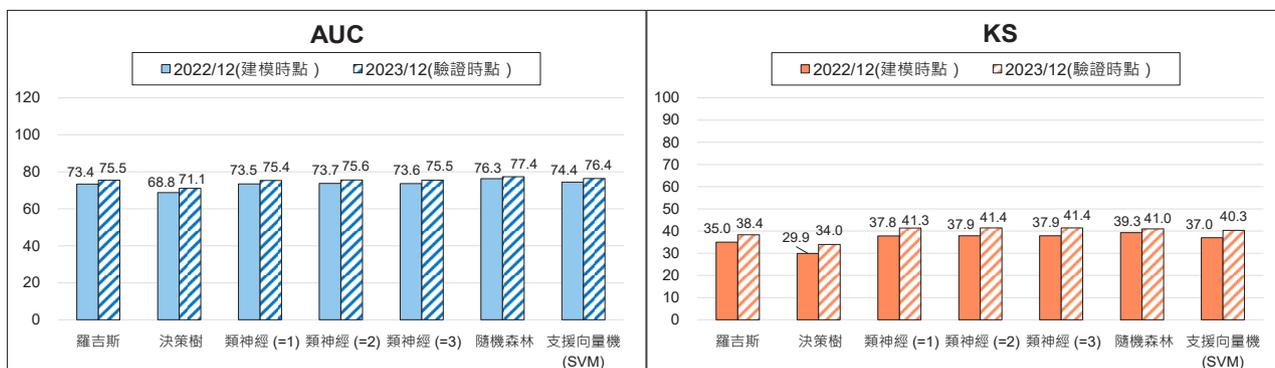
另進一步比較傳統統計模型與機器學習模型區隔力，與信用卡樣本結果一致，雖後者表現略勝一籌，但差異幅度不大，此外，同時觀

察類神經網路於不同層數設定下結果，區隔力亦無明顯差異，可能原因前述分析已進行相關說明⁸，此處不再贅述。

此外，觀察驗證時點之AUC、KS值，多數模型方法於驗證時點皆略高於建模時點結果，但整體差異甚小，顯示模型具良好之泛化能力，並未出現過度配適（overfitting）現象。

綜上所述，除決策樹模型區隔力略低外，各建模方法皆有一定區隔水準，且結果並無顯著差異，可作為後續分析與實務應用之參考依據。

圖12：借款需求預測模型區隔力結果一個人授信樣本



(五) 模型解釋：

初步瞭解各模型方法區隔力後，針對機器學習模型方法，本研究進一步運用統計軟體，使其自動化挑選變數及切點，產生最適決策樹結果，以進行後續變數解釋性分析，並以區隔效果最佳方法—隨機森林為例進行說明。

觀察決策樹結果，多數分類變數皆與授信特徵相關，如授信負債金額、授信往來家數、授信額度使用率等變數，並從上述特徵中可觀

察出若授信負債金額較高、往來家數愈多或授信額度使用率愈高者，其查詢率亦會呈現較高的現象。從實務面角度思考，其亦具合理性，舉例而言，若客戶之授信負債金額較高時，可能意味其資金運作規模較大，若出現資金缺口，未來再次借貸的機率即更高；此外，授信往來家數愈多則反映該客群資金運用頻繁，說明可能其資金需求愈大，潛在借錢的機率愈

7 K-S值介於20-40、AUC值介於70-80間，表示其區隔能力為佳。

8 相關說明詳見前一節中個人金融之區隔力結果。

高，而授信額度使用率亦是如此，當使用率偏高時，顯示其資金壓力較大，可動用餘額有限，自然存在較高潛在借款需求。

整體而言，針對近一年有貸款之客群，可藉由觀察授信往來家數、授信負債金額及授信額度使用率等變數觀察其未來是否借錢的可能性，惟如同於前述預測違約模型已提及，該決策樹僅為模擬的結果，非代表真實機器學習模型所考量之變數，故此結果可能無法提供充分支持，僅能作為輔助參考。

三、企業金融—企業有授信行為

(一) 樣本範圍：

聯徵中心資料庫企業主檔有統編，設立登記正常，資料揭露期限內無違約，且過去一年有授信行為之樣本，總計約22.3萬家。

(二) 輸入變數：

與前一節不同的是，為避免出現以過去有新業務查詢紀錄去預測未來有無新業務查詢，此處將查詢變數剔除，再加入特店以及電支特約機構⁹之資料進入模型分析，故涵蓋面向包含

企業基本資料、授信類、財務報表變數及負責人變數及特店與電支特約機構等，將各面向之資料彙整並量化成相關資訊（變數），作為瞭解企業授信戶之基礎。

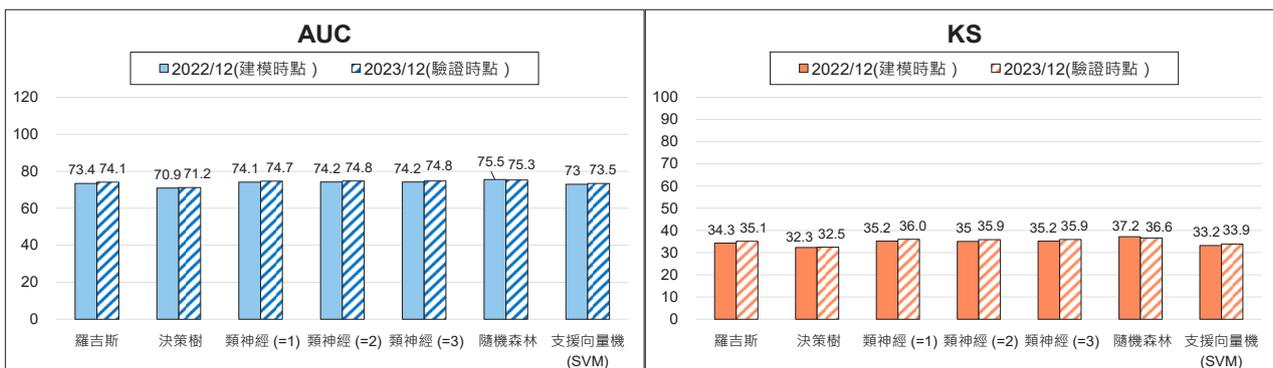
(三) 目標變數：

利用績效期間有新業務查詢與否，探討研究範圍樣本未來一年是否有新業務查詢。

(四) 模型區隔力：

在建模時點2022年12月下，觀察傳統統計模型及機器學習模型之結果，如圖13所示，可以發現不論是KS值還是AUC值，最高者皆為隨機森林方法，其值分別為37.2及75.5，最低者皆為決策樹方法，其值分別為32.3及70.9；而與聯徵中心建模方法最相近之羅吉斯迴歸，其KS值是34.3，AUC值則是73.4。綜上所述，是以隨機森林方法之區隔能力最佳，但相較於羅吉斯迴歸方法，甚至表現較差之決策樹方法，並沒有太顯著之差異；而觀察驗證時點2023年12月下，各統計方法之KS值及AUC值，相較於建模時點，彼此間亦差異不大，顯示皆無過度配適（overfitting）之問題。

圖13：借款需求預測模型區隔力結果—企業有授信樣本



9 特店與電支特約機構樣本占全體有授信行為之企業建模樣本比例，分別約18.75%、9.25%，其占比雖較個人金融高，但比例亦相對偏低。

(五) 模型解釋：

在借款需求預測模型-企業有授信行為之樣本範圍內，總計約有22.3萬家企業，績效期間之查詢率為36.6%。針對這些企業樣本，本研究亦使用前述之研究方法，觀察投入變數與目標變數之間的關係；以下分析重點在於在目標變數置換成未來一年是否有新業務查詢下，以區隔能力最佳之隨機森林方法為代表，觀察哪些投入模型之變數，影響企業在未來一年之查詢率。

觀察決策樹結果，針對影響企業在未來一年查詢率之因素，可從分類變數看出一些端倪，如企業頻繁地與銀行往來，往來銀行家數愈多，則愈多被查詢的可能；此外，若企業之資本額愈高或是該企業有財報，可以理解成規模愈大之企業，其業務擴張將更頻繁，資金需求也將提高，故有較高之查詢率。

整體而言，針對近一年有授信行為之企業戶，根據上述決策樹結果，可藉由往來銀行家數、不同擔保類別之授信餘額、資本額大小、是否有財報等變數觀察其未來是否再貸款之可能性，呈現往來銀行家數多、資本額較大或有財報之企業，其新業務查詢率較高；然誠如先前違約預測模型所述，該決策樹僅為模擬性質，並未完整納入真實機器學習模型所評估之變數，故其結果可能無法提供強力的佐證，僅能作為輔助資訊。

四、企業金融—企業無授信行為

(一) 樣本範圍：

聯徵中心資料庫企業主檔有統編，設立登記正常，資料揭露期限內無違約，且過去一年無授信行為之樣本，總計約156.6萬家。

(二) 輸入變數：

與前一節不同的是，為避免出現以過去有新業務查詢紀錄去預測未來有無新業務查詢，此處將查詢變數剔除，又由於過去無授信行為，故再刪除授信類相關變數，再加入特店以及電支特約機構¹⁰之資料進入模型分析，故涵蓋面向僅包含企業基本資料、財務報表變數、負責人變數及特店與電支特約機構等，將各面向之資料彙整並量化成相關資訊（變數），作為瞭解企業無授信戶之基礎。

(三) 目標變數：

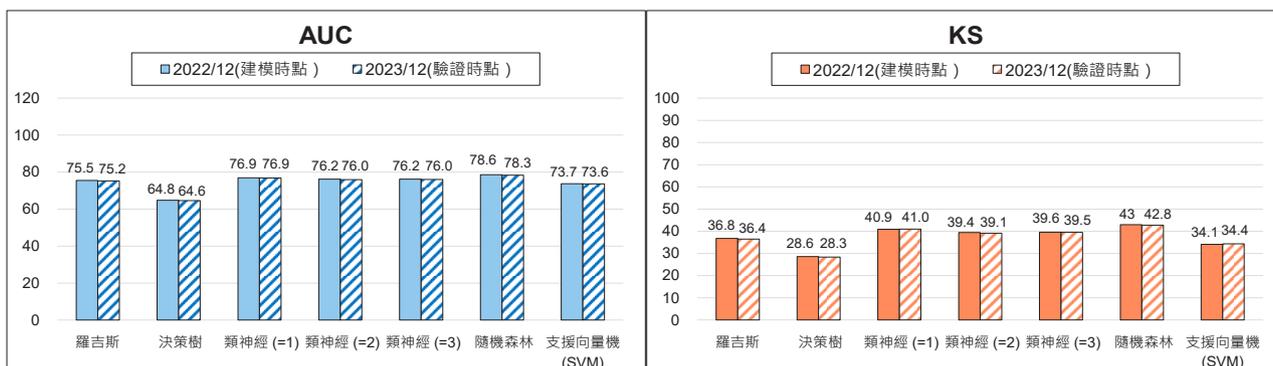
利用績效期間有新業務查詢與否，探討研究範圍樣本未來一年是否有新業務查詢。

(四) 模型區隔力：

在建模時點2022年12月下，觀察傳統統計模型及機器學習模型之結果，如圖14所示，可以發現不論是KS值還是AUC值，最高者皆為隨機森林方法，其值分別為43.0及78.6，最低者皆為決策樹方法，其值分別為28.6及64.8；而與聯徵中心建模方法最相近之羅吉斯迴歸，其KS值是36.8，AUC值則是75.5。綜上所述，是以隨機森林方法之區隔能力最佳，但相較於羅吉斯迴歸方法，並沒有太顯著之差異，僅表現較差之決策樹方法區隔能力明顯較低；而觀察驗證時點2023年12月下，各統計方法之KS值及AUC值，相較於建模時點，彼此間亦差異不大，顯示皆無過度配適（overfitting）之問題。

10 企業為特店或電支特約機構之樣本占全體無授信行為之企業建模樣本比例，分別約11.25%、5.78%，其占比雖較個人金融高，但比例亦相對偏低。

圖14：借款需求預測模型區隔力結果—企業無授信樣本



(五) 模型解釋：

在借款需求預測模型-企業無授信行為之樣本範圍內，總計約有156.6萬家企業，績效期間之查詢率為5.2%，明顯低於企業有授信行為者。針對這些企業樣本，本研究亦使用前述之研究方法，觀察投入變數與目標變數之間的關係；以下分析重點亦是在目標變數置換成未來一年是否有新業務查詢下，以區隔能力最佳之隨機森林方法為代表，觀察哪些投入模型之變數，影響企業在未來一年之查詢率。

此處亦以決策樹之事後解釋方式，探討哪些變數類型將影響企業未來之查詢率，較重大的不同為無授信類相關變數置入到模型當中，故分析之變數與前面差異甚大。綜合決策樹之結果，針對原先近一年尚無授信行為之企業戶，呈現企業負責人有純信用、企業為特店或電支特約機構、資本額較大或有財報者，有較多之潛在資金需求，代表企業之營運規模較大，需要以較多資金實現業務擴張之目的（如特店或電支特約機構有許多分店，或是正在展店等），故其查詢率愈高；然而如前面所述，該決策樹僅為模擬性質，與真實機器學習模型所評估之變數存在落差，故其分析結果僅具輔助參考價值。

機器學習模型的可解釋性

在許多AI系統中，特別是機器學習模型，往往像是一個“黑箱（black box）”模型，使用者輸入大量資料，模型經由一連串複雜的運算訓練後，再產出結果，而其中使用者並無法輕易理解其內部運作方式。然如要將AI系統於生活中運用，尤其是金融領域，則決策過程應更加透明，使得使用者能夠理解其為什麼做出某個特定的預測或決策，進而增強AI系統的可信度和可操作性，而在聯徵中心信用評分產品之運用更是如此。

XAI（Explainable AI）指的是“可解釋的人工智慧”，是AI領域中的一個重要概念，旨在讓AI的決策過程變得透明、可理解，並且能夠向使用者或開發者解釋AI系統是如何得出其結論或做出預測的，運用在信用評分上，則可以幫助解釋消費者評分較高或較低之原因，這樣的解釋不僅可以增加使用者對評分的信任，也可讓消費者透過低分理由進行借貸行為之改善調整，還有助於評分模型開發者確保合規性，特別是在涉及反歧視偏見和公平貸款的情況下，這也是為何前文嘗試透過決策樹來解釋機器學習模型之原因。

而現階段XAI技術可以幫助將這些複雜的決策過程透明化，例如：LIME（局部可解釋模型）或SHAP（Shapley值）等方法可以對AI模型的輸出結果進行解釋，告訴消費者或金融機構哪些因素對最終決策影響最大，然XAI技術也尚有一些挑戰，例如：許多解釋技術尚在發展還未成熟、解釋性與模型效能間的取舍、開發成本與技術門檻高、解釋方式可能過於簡化等。因此如要達到普遍性使用該項技術，仍有一定發展空間。

綜合上述，考量聯徵中心信用評分產品係提供通用型評分供金融機構與社會大眾使用，往往需明確清楚了解影響評分的變數與影響幅度，且針對使用變數之合理性，更是要面對消費者的巨大挑戰，在過去幾次改版經驗中，甚至為了變數合理性，需犧牲變數解釋力，且藉由前文分析亦可知，聯徵中心信用評分採迴歸模型與機器學習模型之區隔力並無太大差距，因此，目前並無採用機器學習模型，未來如欲使用AI學習模型來建置信用評分，除了資訊技術面、資料面之問題，XAI技術的發展會是聯徵中心未來所關注的重點。

結語

本研究經由上述各節，嘗試在分辨式AI之範疇下，應用各種研究方法針對消金與企金之資料建模，分別探討個人戶與企業戶在未來違約與否，或是有無新業務查詢。針對研究結果，除比較傳統統計模型（羅吉斯迴歸、決策樹）與機器學習模型（類神經網路、隨機森林、支援向量機）各種方法之區隔能力，也深

入探討各個模型的可解釋性以及實際應用考量，並進一步對於不同預測目標及將新變數投入模型當中分析，做一個新的嘗試。

不論消金還是企金，在違約模型的部分，透過AUC及KS值之比較，皆證實機器學習模型方法在區隔能力上的優勢，尤其以隨機森林方法為最佳；然而，隨機森林等機器學習模型方法，是透過高度複雜之運算過程所得出的結果，其決策過程難以追溯和理解，本研究僅能利用事後解釋之決策樹，嘗試對機器學習模型去作輔助說明，無法完整剖析變數之間的真實關係。相較之下，如傳統統計模型下之羅吉斯迴歸，雖然在區隔能力略遜一籌，但其AUC及KS值之表現已有一定的水準；羅吉斯迴歸方法之優點在於針對分析結果之可解釋性與合理性，能清楚地瞭解各個變數對違約風險之影響方向和程度，也更方便建模者在日後進行模型監控、驗證和調整。

除了違約模型，既然本文是探討創新技術AI的運用，聯徵中心亦希望藉由轉換不同目標變數來進行新嘗試，而查詢次數係聯徵中心特有資訊，亦可間接來觀察金融市場之潛在資金需求，所以本研究嘗試將傳統以預測「是否違約」為目標的信用評分模型，重新轉換為預測「是否有資金需求」的模型架構；運用新業務查詢資料，並利用現有的評分變數，再創新性地加入了特店與電支特約機構等變數，探討個人戶和企業戶未來是否有新業務查詢，研究的核心仍在於比較不同建模方法的區隔力表現；研究結果與違約模型相同，不論消金還是企金，皆以隨機森林方法之區隔力為最佳。另

一方面，進一步觀察模型中之變數，在個人金融部分，對於過去一年已有貸款的客群，其未來的借款意願可以從其現有的授信往來家數、授信負債金額及授信額度使用率等變數中看出一些端倪；而針對過去一年沒有貸款的潛在客群，則可從其信用卡負債狀況、額度使用率及預借現金額度等變數，觀察未來借款的可能性。在企業金融部分，針對過去一年已有授信行為的企業戶，可透過觀察其往來銀行家數、各種擔保類別的授信餘額、資本額以及是否有財報等資訊來評估其未來資金需求的迫切性；而對於過去一年尚無授信行為之企業戶，則可關注其負責人變數、企業是否為特店或電支特約機構、資本額大小以及是否有財報等變數，去分析是否存在潛在資金需求。

聯徵中心資料庫包含豐富的信用相關資訊，在現有評分產品的考量上，涵蓋面向已相當廣泛且完整，然而由於聯徵中心部分資料之特殊性，在運用隨機森林等機器學習模型方法處理這些資料時，除了面臨變數解釋性難題外，還可能涉及法規與倫理上的問題，某些高維度或衍生變數的應用可能難以清晰地追溯其與信用風險的直接關聯，進而引發關於模型公平性和歧視性的擔憂。因此，聯徵中心會謹慎選擇模型方法和變數應用，以確保其合法性、合規性和合理性。因此，現階段聯徵中心評分產品之模型仍以羅吉斯迴歸方法為主，且於前文之研究過程中，雖有嘗試納入既有評分變數外的其他資料，例如：性別、年齡等個人屬性變數，但此僅作為研究分析使用，並未有實際應用於評分。

雖目前聯徵中心仍以羅吉斯迴歸方法應用在評分產品上，然展望未來，若XAI的技術日益成熟，未來的金融預測模型將能夠在維持高區隔能力的同時，提供更清晰、更透明的變數解釋性，屆時，更複雜的機器學習模型將有望在金融領域得到更廣泛和更深入的應用。