

應用類神經網路及非傳統信用資料於信用評分模型之探討

李彥錚 鄭聖儒 / 金融聯合徵信中心 研究部

一、前言

在評分模型方法論的研究領域，類神經網路早在90年代即已開始被討論，是否得以作為建構評分模型的一種方法論。在早期的文獻中，類神經網路相較其餘各種方法論（包括羅吉斯迴歸、選擇權評價模型、區別分析模型、Cox比例危機模型），並不容易得出一個備受大眾支持的結論，原因並不在於其模型的預測效力不佳（事實上有部分研究顯示此類方法的預測效力還不錯），而是其容易產生過度配適（套到模型以外的樣本，預測效力就會大幅降低）的後果，也難以就模型結果解釋。白話來說，就是當一個前台業務辛苦找來了一個客戶，卻被後台的評分擋下來時，後台無法提供易於解釋及接受的說法。因為無法建立一致性的管理原則，所以此種方式就比較難被實務界認定為最佳化的管理模式，而在線性處理較佳的羅吉斯迴歸則成為方法論的主流。

然而在近年步入數位金融的時代後，隨著各種新名詞的出現一包括替代性資料、非

結構化資料、機器學習、深度學習、人工智慧（AI）…等，搭配演算工具的一再進化，原先看似已經定論的模型方法應用，也開始出現了波瀾，「將你的數位軌跡用AI來計算評分」業已成為廣泛的討論話題，那麼在這樣的風潮下，也應再行檢視現行所採用的方法論是否仍是實務採用的最佳選擇。

AI的內涵包含了許多複雜的理論，而其中核心的概念、用以作為運算基礎的方法論，其實就是類神經網路。雖然這個概念早已在聯徵中心推出第一版信用評分模型之前即已被深入研究，且最後並未實際應用於信用評分產品，然而本中心以羅吉斯迴歸為核心基礎的信用評分產品已有留存多年的大量資料，且搭配越來越強大的運算軟體，也降低了以類神經網路運算資料的門檻，對兩者重新進行比較並不構成太大的阻礙，本文將藉此進一步分析現行個人信用評分產品（J10）與套用類神經網路模組產生之評分模型結果，探究傳統理論與新興研究方法在現今時空背景下的優缺點。

此外，類神經最受注目的另一項特色，即是它能廣納多元型態的資料，再以自動化方式，將各類原始數據相互組建合成，產出額外提升預測效力的資訊，而這個特性剛好可結合現今企業授信的趨勢。自2005年起，普惠金融的概念已逐漸在全球興為浪潮，我國主管機關為與國際接軌，也於同年推動「本國銀行加強辦理中小企業放款方案」，並訂定2項指標每年追蹤，顯示中小企業或新創企業已逐漸成為資金需求者中相當重要的客群，然此類企業以往較不易直接向金融機構取得資金，授信行為無從考證，難以衡量信用風險；另一方面，隨著金融市場的蓬勃發展，僅就傳統的授信產品評估客戶風險屬性面相稍過單一，可能會忽略了其他非授信行為對風險的影響。因此聯徵中心配合主管機關政策指示，已開發數種非傳統授信資料產品一併供會員查詢參考。本文嘗試以傳統方法及類神經模型各別分析這類資訊的風險樣態，期不論是補足缺乏授信資料企業的審核依據、落實普惠金融政策，或是作為已有授信資料企業的額外參考，皆能以更多元的角度評估企業風險屬性，增進金融市場效益。

總結來說，本文的研究主軸有兩項，分述如下：

(一) 研究目的(A) -個人信用評分模型應用類神經之探討：

係欲以相同的樣本群出發，將現行J10（個人信用評分）的評分結果與統計軟體內以類神經網路模組所計算出的結果加以比較，從預測效力及消費者（客戶）溝通的角度切入，分析兩種方法論的差別。

(二) 研究目的(B) -無授信資料企業之信用風險評估：

旨在分析將授信類變數排除後，以非傳統授信類變數評估風險的可能性，然聯徵中心目前蒐集之非傳統授信資料¹多以企業為主，故本文在分析無授信資料的主體也以企業為研究標的。將選取至少已上線兩年，且包含一般企業非屬傳統授信借貸行為之產品，分別為「衍生性金融商品交易額度、動支金額及保證資訊（C05）」、「融資租賃交易資訊（R04）」、「勞工退休準備金相關資訊（R08）」、「企業重大污染裁罰處分資訊（R09）」共四類²，初步分析產品內容後，再假設評分範圍企業若完全無授信資料，改以非傳統授信借貸行為變數替代，嘗試以羅吉斯迴歸建置模型與現有評分產品一同比較。但單一非傳統變數或許不具顯著的解釋能力，故也將利用統計軟體中類神經網路節點功能建置模型，將非授信類資訊納為建模因子，觀察可否進一步提升模型預測力。

1 本中心可供查詢之非授信類資料有部分為介接取得(獲當事人同意由本中心向資料所屬機構查詢資料，並未儲存在本中心資料庫)，如中小企業融資平台、證券信用交易資訊等，該類資料不在本文研究範圍內。

2 此四類產品僅作為本文分析使用，並未實際納入現行企業信用評分產品(J20、J21)中。

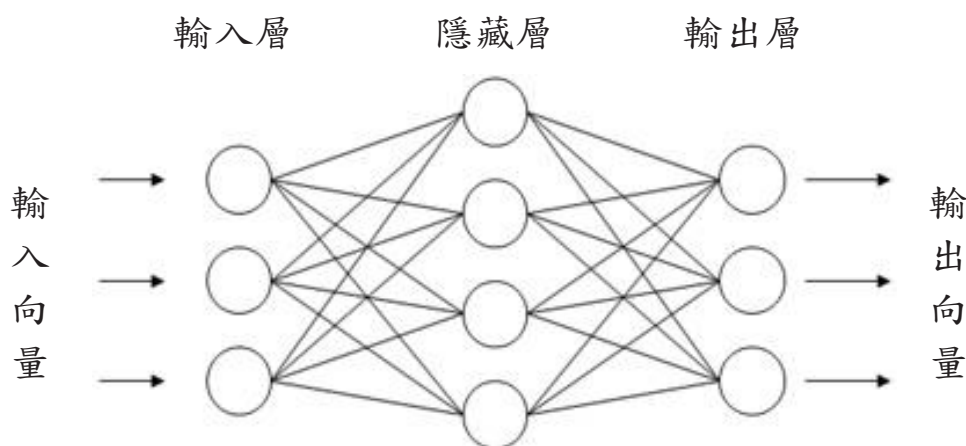
二、研究說明

(一) 研究目的(A) -個人信用評分模型應用類神經之探討

節錄維基百科的說明，類神經網路的定義為：「是一種模仿生物神經網路的結構和功能的數學模型或計算模型，用於對函式進行估計或近似。神經網路由大量的人工神經元聯結進行計算。大多數情況下人工神經網路能在外界資訊的基礎上改變內部結構，是一種自適應

系統，通俗的講就是具備學習功能。現代神經網路是一種非線性統計性資料建模工具，神經網路通常是通過一個基於數學統計學類型的學習方法（Learning Method）得以最佳化。」一般來說，類神經網路的結構示意如圖1，但若另從網路上搜尋，卻很難找出一個簡明的函數式可解釋類神經網路內各項元素的關係。換言之，類神經網路的概念相當抽象，但若我們要以一個最簡單的說法，來說明它所發揮的功能，應為「其處理非線性關係的能力」。

圖1、類神經網路的示意圖



在傳統迴歸模型的世界，線性關係是解釋各種現象的說明方式，在這個基礎下去解釋量化風險管理，只要找到某個因子，然後定義這個因子的數值越高，風險就越大；數值越低，風險就越小，接著就建立了一個模型的架構。然而，真實世界往往有其複雜之處，並非任何因果關係都是線性關係，或許某項風險因子是數值大到某個程度之後，風險反而開始降低，而這樣的情形就是傳統迴歸模型所無法解釋的，所造成的直接影響就是模型的預測效力會降低。而類神經網路的特色，就在於它不是以線性關係來解釋輸入與輸出的關聯，因此在理

論上而言，它對於模型的預測力應該是有所助益的。

另外一個類神經網路的特色，在於它可以在模型內套用盡可能多量的變數進行分析。若以人類世界的角度來解釋，我們會採用很多明確清晰的邏輯解釋或預測事物，但同時也會採用各種蛛絲馬跡來作各種推斷，而在某些情境下，甚至這些蛛絲馬跡的預測效果比明確的邏輯還要更佳。若將這個道理套入到模型內，可以想像某些風險因子如果拿來單獨觀察，或許並不具有甚麼解釋力，然而組合在一起時，可能會產生一些意想不到的效果。這種情形在傳

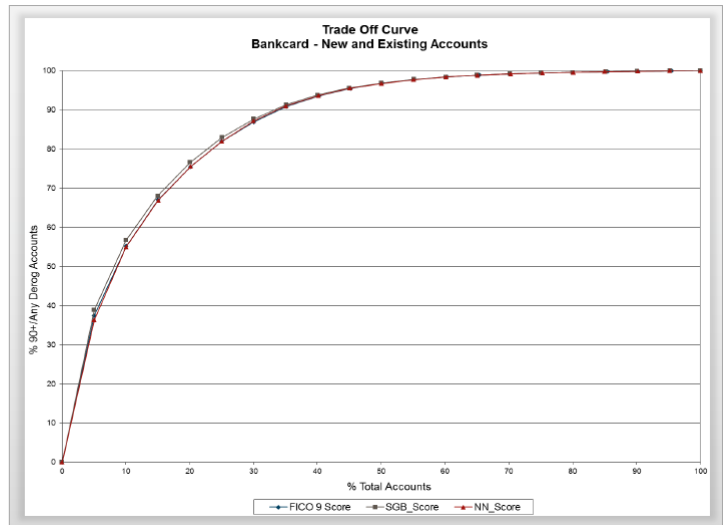
統迴歸模型裡，可能會因單變數的解釋力不足而被剔除，而且傳統模型所能收納之變數數量有其上限，太多變數會導致模型無法產出；但在類神經網路時，不但不受變數數量的限制，還可能將這些組合加乘的效果顯現出來，進而提升模型預測力。

以美國信用評分界的標竿企業FICO公司

而言，確實也曾針對傳統的方法論（即其FICO Score所採用的方法）、SGB（一種類似決策樹的分析方法）與類神經網路（Neural Net-Based）的模型績效，進行一番比較（如圖2）。而結果顯示，三種統計方法下的模型預測力幾無差異，意味著非傳統方法論下的預測效力，似乎未如預期般的高。

圖2、各類方法論下預測效力比較圖(資料來源：FICO)

Score	Metric	Value
FICO® Score 9	ROC	.901
	KS	63.2
SGB-Based	ROC	.905
	KS	64.3
Neural Net-Based	ROC	.901
	KS	63.5



FICO尚針對其非評分樣本作了一個實驗，將其內部研究用的評分模型（非實際產品）與SGB模型的違約預測力相較，結論也是

差異不大（如圖3），以此結果來看，無論是在評分樣本或非評分樣本，方法論的選擇對於模型預測效力，似乎並不產生攸關的影響。

圖3、各類方法論下針對非評分樣本的預測效力比較圖(資料來源：FICO)

Performance of "Research Score" On Unscorable Credit Files with Derogatory Info			
	ROC	KS	Gini
Scorecard-based	0.639	19.7	.278
SGB-based	0.647	20.8	.294

這樣的結果相當有趣，儘管這些非傳統應用的方法論在理論上有其優點、在產業內也有不小的討論度，但以美國的資料實證卻並未有特別優異的表現。本文則嘗試以我國的資料為分析標的，觀察是否會有相似或完全相反的表現。有關本研究目的之研究設定與結果，將在第三節及第四節詳細說明。

(二) 研究目的(B) -無授信資料企業之信用風險評估

本文在應用類神經方法研究的另一項目的，係利用它廣納各種形態資料的特性，藉此瞭解本中心蒐集之非傳統授信資料評估無信用資料企業的信用風險的效果，並與傳統建模方法一同比較。初步選取衍生性商品類、融資租賃類、勞退準備金類及重大污染裁罰類資訊作為風險因子，以下將簡略說明前述非傳統授信資料的產品內容與預期風險樣態。

1. 衍生性金融商品交易額度、動支金額及保證資訊

衍生性金融商品資訊包含衍生性商品避險與非避險交易之核給額度、動支金額、揭露期限內的違約註記等。直覺上來說，衍生性商品非避險動用金額比率（動支金額/核給額度）愈高、或揭露期限內已有違約紀錄的企業，信用風險連

帶也會較高。此外，衍生性商品屬風險較高之交易種類，因此能承作此類交易的企業，本身應有一定的風險承擔能力，故可預期有衍生性商品交易的企業，信用風險應該較低。

2. 融資租賃交易資訊

融資租賃交易資訊包含契約總價金、應收租金餘額、繳款紀錄、債權狀態（催收或呆帳）等。一般來說，融資租賃動用金額比率（應收租金餘額/契約總價金）較高、或有融資租賃延遲繳款、催收、呆帳紀錄的企業，信用風險也會較高。

3. 勞工退休準備金相關資訊

勞工退休準備金資訊涵蓋範圍較廣，包含勞工投保人數、預估6個月工資、新、舊制勞工人數、適用新制且保留（或不保留）舊制年資勞工人數、工資墊償基金³提撥紀錄等。因本產品內容較為繁雜，較難統一預期風險屬性，初步預期勞工投保人數愈多之企業，隱含其規模愈大，信用風險較低；而保留舊制年資勞工人數愈多之企業，隱含其成立年數愈長、經營已趨穩定，信用風險同樣也較低；若工資墊償基金提撥有延誤或欠繳紀錄的企業，隱含其已有一定水準的資金壓力，信用風險相對較高。

3 依勞動基準法第28條訂定，凡適用勞基法的事業單位，由雇主每月按僱用勞工投保薪資總額萬分之2.5提繳積欠工資墊償基金，當雇主發生歇業、清算或宣告破產時，勞工因此而被積欠之工資、勞基法之退休金、資遣費或勞工退休金條例之資遣費，可以由該基金先行墊付，而雇主應於規定期限內，將墊償款償還給積欠工資墊償基金。

4. 企業重大污染裁罰處分資訊

企業重大污染裁罰處分資訊包含列管編號、處分機關、處分日期、違反法條、違反事實、處分方式等。本產品涵蓋範圍皆屬質化類資訊，初步預期曾有裁罰處分紀錄之企業，會發生授信違約的機會應該也會隨之升高。

本小節已初步窺探非傳統授信資料產品之內涵，為了應證類神經方法能包容各種形態資料的特性，將上述所提及之欄位稍作處理後，全數納為風險因子進行建模，將在第三節說明基本分析與建模之相關設定，並在第四節呈現相關數據分析結果。

三、研究設定

(一) 研究目的(A) -個人信用評分模型應用類神經之探討

- **樣本範圍：**觀察時點下聯徵中心個人信用評分範圍內的樣本，且業務類別限定在房貸、信貸、信用卡，若所報送之資料非為此3類業務者，則不予納入分析範圍。所選用的樣本係採取部分抽樣，保留所有違約樣本，再從全部正常樣本中隨機抽出相對3倍違約樣本數量之正常樣本數，兩者合計作為分析之樣本。
建模係以抽樣後的樣本投入建模，惟執行樣本外測試時，係以全部樣本進行測試。
- **觀察期與績效期設定：**以2018/06為基準，觀察未來一年有無違約。
- **樣本外測試：**前述之2018/06係模型建立之時點，然而為了檢視模型是否會產生過度配適，另選取建模以外的時點，將不同的樣本套入模型係數產生違約率，觀察其違約預測

力是否與建模時點的結果有明顯差異。樣本外測試的資料時點設定為2018/09。

- **分析變數：**用以建模分析之變數，係J10建模過程中所用以參考的所有重要變數，主要為金融機構所報送之資料及查詢狀況。
- **房貸戶之定義為：**授信科目別為中長期擔保放款且放款用途別為購置不動產，授信擔保品類別為住宅用之土地與建物或不含土地之建物；
- **信貸戶之定義為：**授信科目別註記非屬於十足擔保者且授信擔保品類別為純信用，（但不含現金卡放款）；
- **信用卡戶之定義為：**持有信用卡超過三個月以上者。
- 分別以前述之3種業務別，以下述5種方式進行模型預測力比較：
 - A. J10：係直接採用J10信用評分的驗證結果（此法係以羅吉斯為基礎，兼具人為判斷及機械化篩選變數的方式而產生），不再另建模型。
 - B. 羅吉斯：係以統計軟體內建之模組以迴歸模型為基礎，進行自動化變數篩選，並自動化建立羅吉斯迴歸模型的評分結果（此法係以羅吉斯為建模基礎，但以全機械化的方式篩選變數）。
 - C. 半類神經：係以統計軟體內建之模組以迴歸模型為基礎，先進行自動化變數篩選，再自動化建立類神經網路的評分結果（此法係以類神經為建模基礎，但以全機械化的方式篩選變數）。

D.類神經：以統計軟體內建之類神經網路模組所產生的評分結果（此法係以類神經網路為建模基礎，且未事先篩選變數，以樣本內的所有資料投入模型而產生）。

E.深度學習：基本上與D法相似，皆係套用統計軟體的預設，同樣採用類神經網路為建模基礎，且同以多層感知器為架構，所差別者僅在於隱藏層數，層數越多代表可以建構出更複雜的非線性函數，通常大於3層以上的類神經網路，一般即稱為深度學習。D法的隱藏層僅有1層，而E法下則設定為3層。而D法及E法下的隱藏層內單元數皆為3個。

A、B的差異，在於比較專家判斷所帶來的影響；另C法之目的是為了試圖降低過度配適，故採用了迴歸模型先行選擇變數，因此C、D法的差異，則是為了觀察採取降低過度配適的方法，是否對模型的效力產生影響；E法則是觀察隱藏層數的多寡是否影響模型效力。

(二) 研究目的(B) -無授信資料企業之信用風險評估

1.非授信類產品之樣本範圍及風險屬性：

- 資料家數：係指各非授信類產品資料所蒐集並歸戶後的企業家數。
- 評分範圍：資料家數中，屬聯徵中心企業信用評分產品（J20）範圍之企業家數。
- 規模別：按資本額大小，超過8000萬者定義為大型企業，3000萬~8000萬者定義為中型企業，小於3000萬者定義為小型企業。

2.以非授信類產品資訊作為風險因子進行兩階段建模：

- 樣本範圍：觀察時點下聯徵中心J20企業信用評分範圍內的樣本，總計131,832家，不另外進行區隔，以全數樣本進行建模。
- 觀察期與績效期設定：考量違約需績效期（未來1年）資訊，以2018/12為資料分析時點，2019/01~2019/12為績效期間。
- 驗證時點：前述之2018/12是選取資料分析及建立模型之時點，另選取前一年度2017/12設定為樣本外驗證之資料時點，並將驗證時點的企業樣本套入模型產生評分，比較兩時點的違約預測力是否存有明顯差異，主要係檢視單以資料分析時點建置之模型是否會產生過度配適的問題。
- 變數觀察時間：考量非授信類資料來源之產品揭露期限及可查詢期間皆不相同，為方便併同比較分析，本研究選取之非授信類變數觀察期間，最長設定為自資料分析時點過去一年，即2018/01~2018/12。
- 分析變數：本研究將進行兩階段之建模。第一階段建模係只針對樣本範圍的非授信類變數（即前述的衍生性商品、融資租賃及勞退準備金相關資訊）進行建模，目的在觀察此三類非授信變數的風險排序及違約預測力。第二階段則以樣本範圍的基本資料類變數、財務變數、負責人變數，不納入傳統授信類變數，改加上原有之非授信類變數一併建模，目的是模擬金融機構評估無信用資料的企業申請貸款之情境，假定樣本範圍無授信資料，以非授信類變數加上其他可由聯徵中心產品蒐集的資訊建置模型，並觀察其是否存有違約預測力，再與聯徵中心現有之評分產品比較。

- 建模方法：為找出最能發揮非授信類資訊價值的預測模型，本研究以下列三種方式建模：

A. 羅吉斯迴歸（自動）-Logistic Regression（Default）：以統計軟體內建之羅吉斯迴歸模型為基礎，由軟體自動化篩選變數，並建立模型的評分結果。此方式是目前建置風險預測模型的主流方法，但全由軟體依自動運算之統計數據挑選變數，目標是提升模型效力，並不涉及人為判斷。

B. 羅吉斯迴歸（人工）-Logistic Regression（Manual）：同樣以統計軟體內建之羅吉斯迴歸模型為基礎，但以人工判斷方式，挑選出具預測力且較容易解釋因果關係之變數，再建立模型的評分結果，類似本中心現有評分產品的建置方式，目的係與自動化篩選變數的A法比較，以人為考量變數多樣性、可解釋性所挑選出的變數，其建置的模型效力是否會存有明顯差異。

C. 類神經方法-Neural Network：以統計軟體內建之類神經網路模組，自動化產生之評分結果，本法並未事先篩選變數，而是將樣本範圍內的所有資料投入模型產生，目的係與A、B法比較，在不考慮單一變數解釋力的設定之下，可否建置預測效力更佳之模型。

四、研究結果

（一）研究目的(A) -個人信用評分模型應用類神經之探討

以2018/06時點之統計結果，房貸戶共約200萬戶、未來一年違約者約7千戶；信貸戶共約113萬戶、未來一年違約者約2.7萬戶；信用卡戶共約955萬戶、未來一年違約者約4.8萬戶。除A法係直接採用本中心評分監控報告的驗證數字以外，其餘4種方法皆採取前述之抽樣方式進行建模，以下分別列示各業務別下，採取不同模型方法論下所得出之模型效力數據。

● 房貸戶的結果

表 1、房貸戶下各模型方法的預測效力

方法	預測效力	AUC (建模時點 201806)	AUC (驗證時點 201809)
A-J10 (採歷次監控結果)		0.928	0.928
B-羅吉斯		0.929	0.925
C-半類神經		0.922	0.918
D-類神經		0.924	0.920
E-深度學習		0.910	0.905

從表1的結果來看，以純用羅吉斯方法的建模結果（B法），所建構出的房貸模型效力最高，相較之下，在理論上標榜能以更多維度進行分析的類神經網路法（D法），並未帶來更多的區別力，而以更多層次運算的深度學習法（E法），預測效力反較單一層次的D法為低。

而在樣本外的驗證時點，BCDE等4法的預測力皆有略微下降，然而下降幅度極為微小，尚難稱其有過度配適的情況。而以降低過度配適為目的之C法，在D法及E法的降幅盡皆微小的情況下，亦無法呈現出明顯之區別。

綜合來看，儘管5個方法之間的預測力各有差異，但其實結果都十分相近，並未有壓倒性的差異出現。

- 信貸戶的結果

表 2、信貸戶下各模型方法的預測效力

方法 \ 預測效力	AUC (建模時點 201806)	AUC (驗證時點 201809)
A-J10 (採歷次監控結果)	0.868	0.870
B-羅吉斯	0.850	0.851
C-半類神經	0.864	0.866
D-類神經	0.868	0.869
E-深度學習	0.859	0.862

從表2的結果來看，以J10（A法）及類神經網路法（D法）的結果，對於信貸戶的違約預測效力最高。在本業務別下，類神經網路法（D法）及深度學習法（E法），雖有不錯的預測力，但並未展現更優質的效果。

而在樣本外的驗證時點，BCDE等4法的預測力皆有略微上升，但幅度亦極為微小，無法得出有特別意義之推論。

綜合來看，儘管5個方法之間的預測力各有差異，但與房貸的情形相似，結果都十分相近，並未有壓倒性的差異出現。

- 信用卡戶的結果

表 3、信用卡戶下各模型方法的預測效力

方法 \ 預測效力	AUC (建模時點 201806)	AUC (驗證時點 201809)
A-J10 (採歷次監控結果)	0.946	0.947
B-羅吉斯	0.901	0.878
C-半類神經	0.946	0.921
D-類神經	0.947	0.922
E-深度學習	0.947	0.922

從表3的結果來看，以類神經網路法（D法）及深度學習法（E法）的結果，對於信用卡戶的違約預測效力最高。在本業務別下，類神經的分析模式或可展現出其多維度的分析優勢，但與其他方法相較，除B法的效力明顯較低外，並未有太大的差異。

而在樣本外的驗證時點，BCDE等4法的預測力皆有下降，顯示在信用卡戶下，純以自動化方式選用變數的運算結果，預測力可能較不穩定，而相較之下，J10的預測力並未出現變動。

綜合來看，信用卡戶下各方法（B法除外）的預測力仍極為相近，但以J10的穩定性最高。

若將前述3種業務（房貸、信貸、信用卡）的模型結果綜合比較，可看出各法的預測力在不同業務別下各有優劣，但與J10的差異皆不大。考量J10的評分效力已達相當高的水準，在這個基礎下，評估何種方法較適合於實務應用，尚要就其他面向綜合考量。而最主要的考量面向，就在於它的模型結果是否易於解釋，是否可以做為與大眾溝通的工具，然而以類神經網路的複雜邏輯，若要進一步地就個案深入觀察（例如：為何A個案的分數較高、B個案的分數較低），恐將面臨難處。國內針對類神經網路於信用風險的研究雖已長達10餘年，然而即使是現在的時新統計軟體，也無法解釋所投入的上百個變數，到底是哪一個變數影響較大；雖然統計軟體尚可另以決策樹模型的工具，協助使用者找出相對重要的幾個變數，但也僅是模擬出來的結果，並非類神經網路模型的真實面貌，且若面臨資料當事人詢問「為什

麼我較上期降低了30分」時，也無法給予其明確的答案。所以，此類模型因無法提供教育消費者改善自身信用狀況的功能，對於信用報告機構而言，目前仍非最佳之選擇。

(二) 研究目的(B) -無授信資料企業之信用風險評估

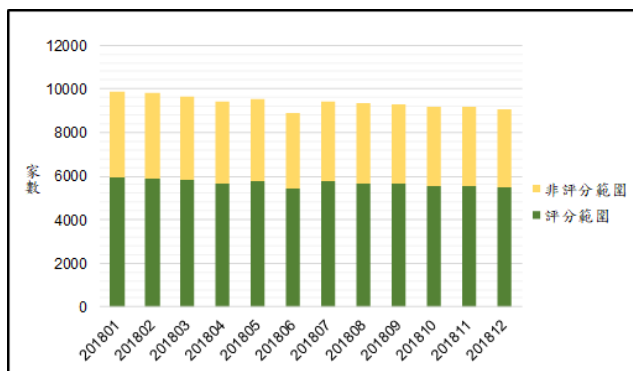
本小節首先觀察各類非傳統授信資訊的樣本範圍，並與企業規模（或加上成立年數）一同交叉分析、依實際數據統整風險屬性。再將非傳統授信資訊一同納為風險因子，進行兩階段建模，比較不同建置方法在建模時點與驗證時點之預測效力。

1. 非授信類產品資訊樣本範圍及風險屬性分析

(1) 衍生性金融商品交易額度、動支金額及保證資訊

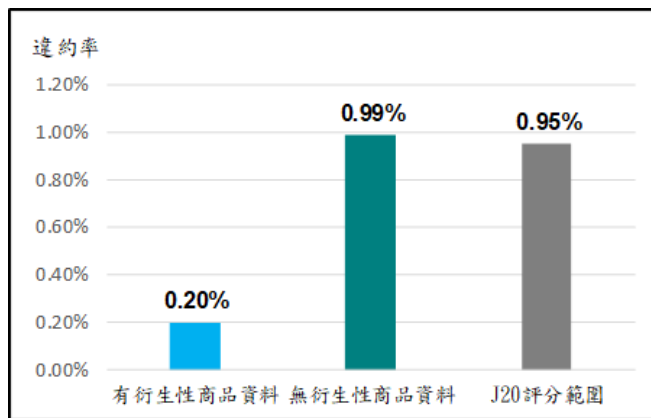
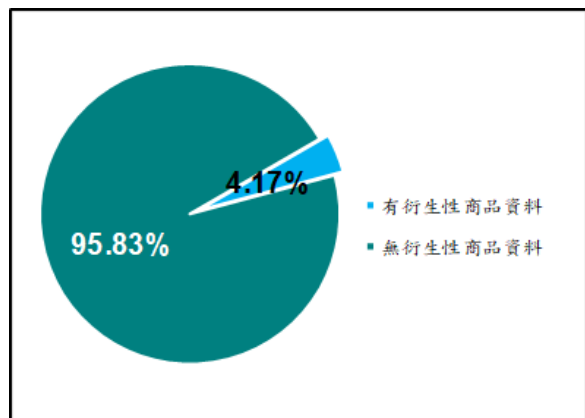
本產品資訊來源係聯徵中心訂定衍生性金融商品月報作業要點，再由會員機構報送相關交易資料取得。每月報送的企業家數約9,000~10,000家，其中約5,500~6,000家為聯徵中心企業評分產品（J20）之評分範圍，如圖4所示。

圖4、2018年度衍生性資料家數分佈與評分範圍占比



接續觀察圖5，單就資料分析時點2018/12來看，J20評分範圍總計131,832家中，僅有5,495家有衍生性商品資料，占比約4.17%。若將評分範圍區分成有無衍生性商品報送資料兩群觀察違約率，可知有衍生性商品報送資料的企業違約率較低，僅約0.2%，而無衍生性商品報送資料的企業違約率較高，約0.99%，整體評分範圍違約率為0.95%。另有關衍生性商品的動用金額比例、有無違約紀錄等觀察指標，將一同列為風險因子建置模型，相關圖表與數據詳見表4及圖17。

圖5、2018/12有無衍生性商品佔J20評分範圍比例及違約率比較



進一步觀察有衍生性商品資料的企業為何違約率會低於無衍生性商品資料的企業，將評分範圍按資本額大小區分為小型企業、中型企業、大型企業，再觀察有衍生性商品資料企業中各規模別之佔比，如圖6所示，有衍生性商品資料的企業中，有超過7成的企業皆屬中大型企業，而小型企業僅約27.1%，另由圖7觀察各規模別企業下有衍生性商品資料的家數及佔比，可知有衍生性商品資料的家數其實都不多，小型企業約1,500家，中型及大型企業都約在2,000家左右，若以比例來看，小型企業只有約1.53%的樣本有衍生性商品資料，中型企業約8.59%，而大型企業則有將近20%的樣本有衍生性商品資料。由此可以推估，衍生性商品除了避險需求外，多半是以投資交易獲利為目的，但其風險較高，金融機構傾向對大規模之企業核給衍生性商品交易額度，足見中大

圖6、J20評分範圍-有衍生性商品資料企業之規模別佔比

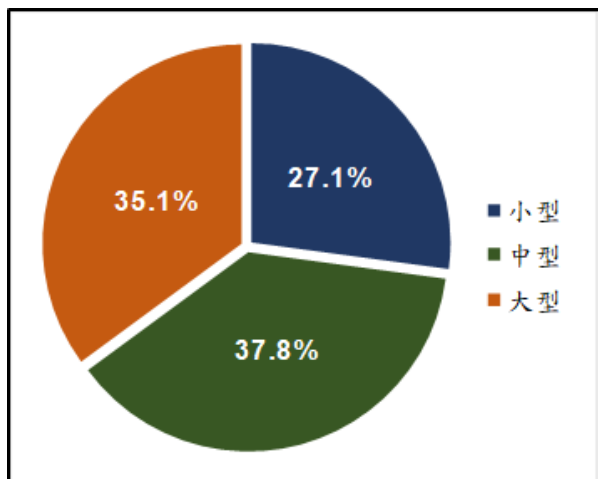
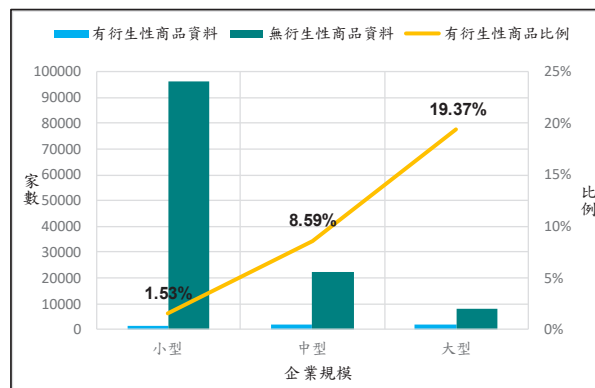


圖7、各規模別有衍生性商品資料家數、比例分布

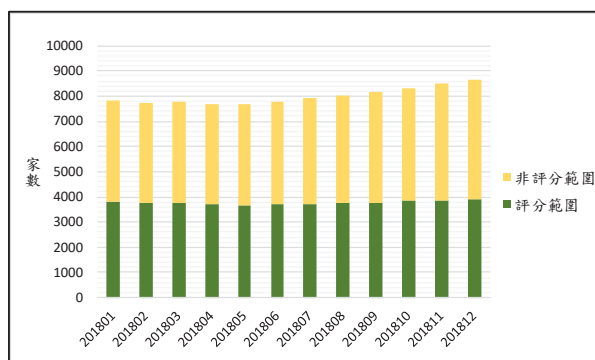


型企業經營較穩定，承擔風險能力較高，故有衍生性商品資料的企業違約率會低於無衍生性商品資料的企業。

(2) 融資租賃交易資訊

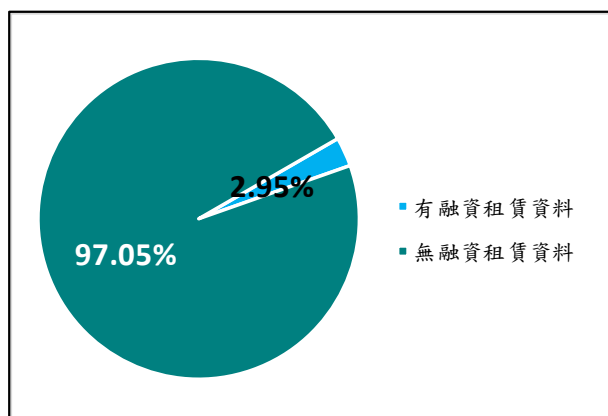
本產品資訊來源係聯徵中心訂定作業要點，再由加入作業要點之融資租賃公司報送交易相關資料取得。每月報送的企業家數約8,000~9,000家，其中約4000家為聯徵中心企業評分產品（J20）之評分範圍，如圖8所示。

圖8、每月融資租賃資料家數分布與評分範圍占比



接續觀察圖9，單就資料分析時點2018/12來看，J20評分範圍總計131,832家中，僅有3,884家有融資租賃交易資料，占比僅約2.95%。有關融資租賃交易動用金額比例、有無延遲繳款、催收或呆帳紀錄等觀察指標，將一同列為風險因子建置模型，相關圖表與數據詳見表4及圖17。

圖9、2018/12有無融資租賃佔J20評分範圍比例



另將評分範圍按資本額大小區分為小型企業、中型企業與大型企業，觀察有融資租賃資料企業中各規模別之佔比，如圖10所示，有融資租賃資料的企業中，有超過8成的企業皆屬小型企業，而中大型企業合計不到2成，另由圖11觀察各規模別企業下有融資租賃資料的家數及佔比，可知所有規模別的家數或佔比都不高，小型企業約3,000家，中型及大型企業都約在1,000家以下，若以比例來看，三規模有融資租賃資料的比例都在5%以內。

圖10、J20評分範圍-有融資租賃資料企業之規模別佔比

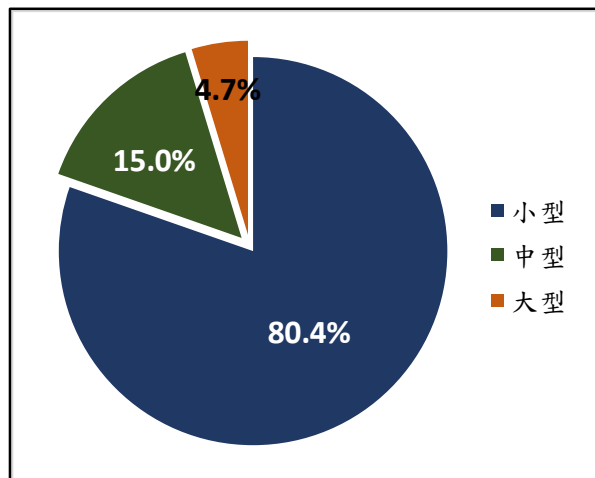
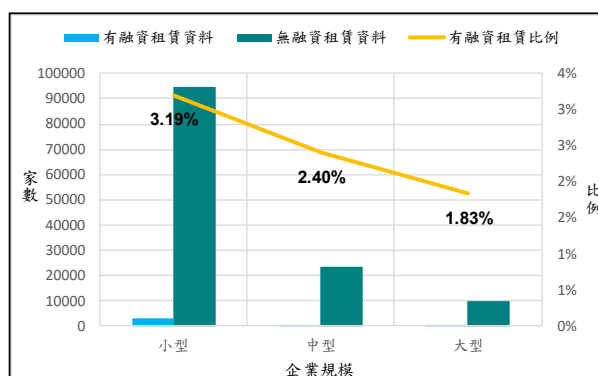


圖11、各規模別有融資租賃資料家數、比例分布

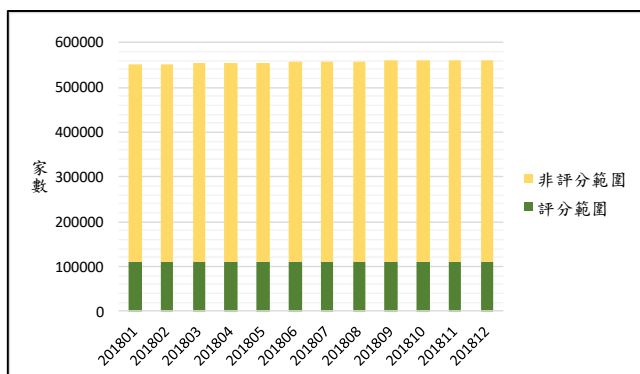


(3) 勞工退休準備金相關資訊

本產品資訊係由勞動部彙整勞工保險局之事業單位投保資料及臺灣銀行之勞工退休準備金專戶資料，再提供予聯徵中心，資訊涵蓋範圍以該企業是否有參加「勞保」為要件，若某企業並不屬於勞工保險條例第六條⁴規定強制投保之事業單位，也非依勞工保險條例第八條

自願加保，則該企業不屬於資訊涵蓋範圍（此類企業以下簡稱為無勞退準備金資料企業）。以資料分析時點2018/12過去一年來觀察，每月取得資料的企業家數約55萬左右，其中約11萬家為本中心企業評分產品（J20）之評分範圍，如圖12所示。

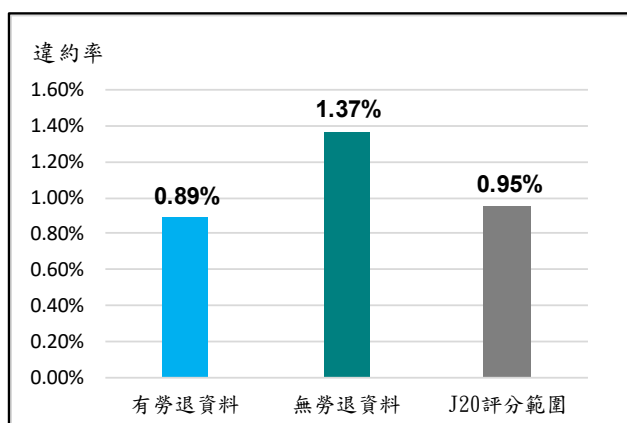
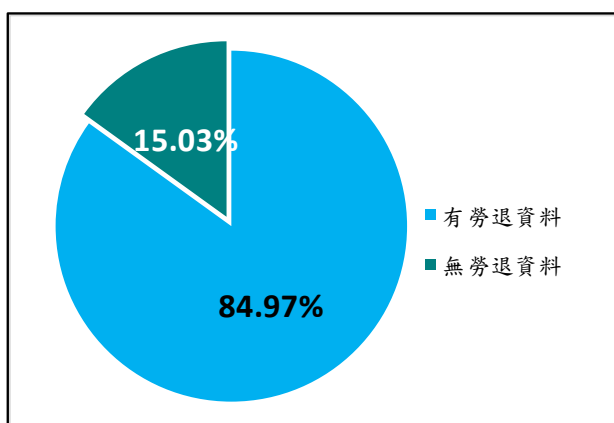
圖12、每月勞退相關資料家數分佈與評分範圍占比



依勞動部網站之統計資訊，資料分析時點2018/12之勞保投保單位數約為56萬家，而觀察圖13，單就資料分析時點2018/12來看，J20評分範圍總計131,832家中，有112,012家企業有勞退準備金資料，占比約85%。若將評分範圍區分成有無勞退準備金資料兩群觀察違約率，可知有勞退準備金資料的企業違約率較低，約0.89%，而無勞退準備金資料的企業違約率較高，約1.37%，整體評分範圍違約率為0.95%。

直覺上來說，無勞退準備金資料企業可能因規模不大或成立時間不長，所以非屬強制投保單位也未自行加保，為進一步分析，同樣將評分範圍按資本額區分為小型企業（資本額小於3,000萬）、中型企業（資本額3,000

圖13、2018/12有無勞退相關資料佔J20評分範圍比例及違約率比較



4 有關勞工保險詳細法規條件之說明請參閱勞動部網站：<https://www.bli.gov.tw/0007758.html>。

萬~8,000萬）、大型企業（資本額大於8,000萬），另外按成立年數區分為成立小於10年，成立10~20年及成立超過20年之企業，再分別觀察有勞退準備金資料企業中各規模別及成立年數之佔比，如圖14所示，有勞退準備金資料的企業中，若以規模別來看，有超過7成的企業皆屬小型企業，而中大型企業合計將近3成；若以成立年數來看，成立超過10年的企業佔比約68.7%，成立不到10年的企業約31.4%。另由圖15觀察各規模別及成立年數之企業有勞退準備金資料的家數及佔比，先以規模別觀察，雖然小型企業有勞退準備金資料的家數最多（約8.1萬家），大型企業家數最少（約9,300家），但若以比例來看，大型企業

有約93.4%的企業有勞退準備金資料，小型企業則約83.28%。再以成立年數觀察，有勞退準備金資料的企業不論從家數或比例來看，都是以成立超過20年最高，家數約4.3萬家，佔比約92.12%。由此可以推估，成立時間較久的企業，多屬強制投保單位或自行加保單位，而這類企業在信用風險上也普遍較成立時間短的企業低，故有勞退準備金資料的企業違約率會低於無勞退準備金資料的企業。另有關於勞工投保人數、保留舊制員工數、工資墊償基金提撥情形等觀察指標，將一同列為風險因子建置模型，相關圖表與數據詳見表4及圖17。

圖14、有勞退相關資料企業之規模別及成立年數佔比

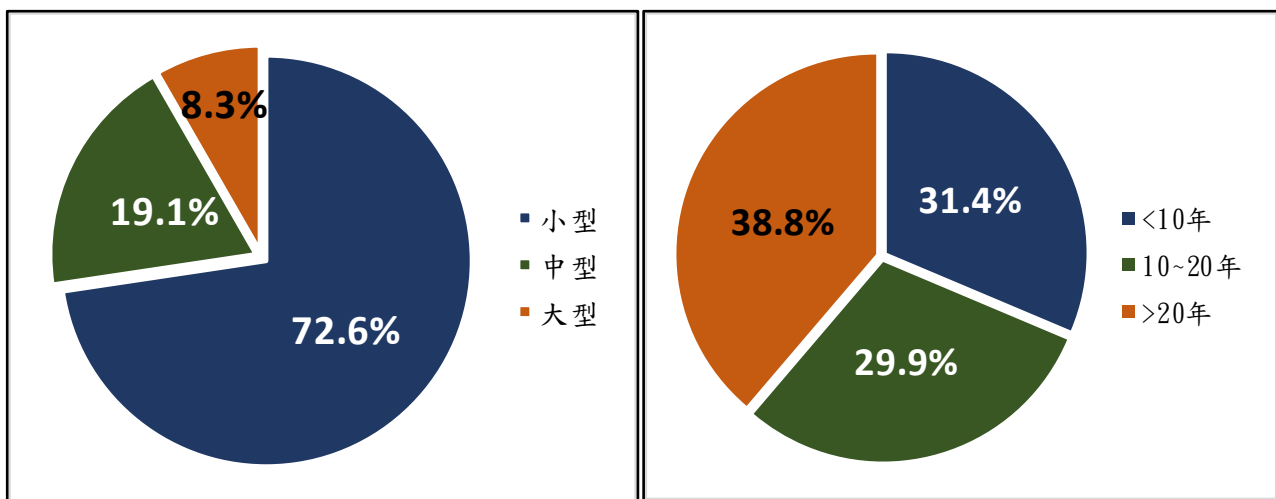
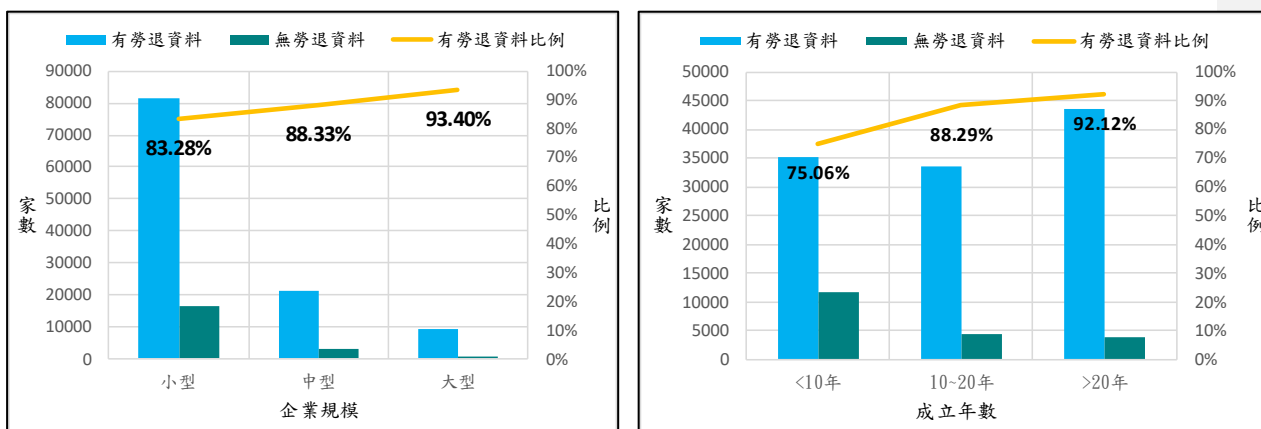


圖15、各規模別、成立年數有勞退準備金資料家數、比例分布



(4) 企業重大污染裁罰處分資訊

本產品資訊來源係由行政院環保署提供「企業重大污染裁罰資料(含統編)」，再由本中心建置企業授信戶業經行政院環保署或各地方政府環保機關裁定違反環保法令且情節重大之裁罰資料。經檢視產品內容，至今所涵蓋的資料量仍偏少，單一年度的資料都小於100筆，若以該產品的揭露期限(5年)來觀察，在資料時點2018/12評分範圍企業中，僅有95家企業在揭露期限內曾有重大污染裁罰紀錄，佔比約0.07%，且一般直覺上有重大裁罰紀錄的企業，違約率應也會較高，但這95家企業於授信揭露期限內都無違約紀錄，考量有裁罰紀錄的企業在評分範圍中比例極低且缺乏違約樣本的情況下，目前要以本產品的資料評估企業風險可行性不高，須待資料累積一定數量後再行分析，但會員機構除評估信用風險外仍可查

詢，針對借款戶是否符合綠色金融政策標準審核放貸。

(5) 非傳統授信資訊風險屬性統整

上述已分別介紹四類非傳統授信類產品資料的樣本概況及違約率分布，並就資料的有無分析企業的風險屬性，大致可歸納重點如下：

- 在資料分析時點2018/12，J20評分範圍中僅勞退準備金資料的涵蓋比例較高，其餘三類產品有資料之企業佔比都在5%以內，其中重大污染裁罰紀錄資料的企業甚至完全沒有違約樣本。
- 較易獲得銀行核給衍生性商品額度，或屬勞保強制投保單位的多為信用風險較低的中大型企業，而使用融資租賃則以小型企業占比最高。

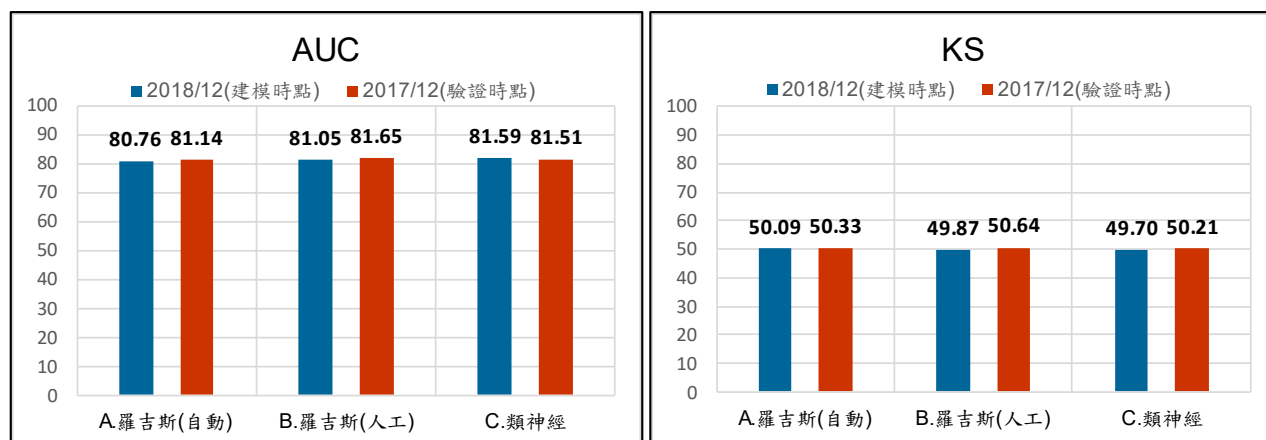
2. 羅吉斯迴歸與類神經方法建模結果分析

(1) 第一階段建模結果分析

首先觀察第一階段建模（僅採用樣本範圍之衍生性商品、融資租賃及勞退準備金相關資訊）-各以A.羅吉斯（自動）、B.羅吉斯（人工）及C.類神經方法建置之效力，本研究以AUC及KS之數值進行比較，如圖16所示。藍色長條圖為建模時點2018/12之效力數據，從AUC來看，以C.類神經方法的數值81.59最高，但與A.羅吉斯（自動）、B.羅吉斯（人

工）的差異很微小，顯然C.類神經方法藉由特徵工程確實能萃取出提升預測力的組合變數資訊，但並未壓倒性的勝過A.羅吉斯（自動）、B.羅吉斯（人工）；而就KS來看，則以A.羅吉斯（自動）的數值50.09最高，但同樣地，彼此間的差異很微小。紅色長條圖為驗證時點2017/12之效力數據，不論是AUC或KS之數值，套用驗證時點的效力並未下降，反而都些微上升。綜合來說，三種建模方法對應的區隔能力皆有不錯的水準，彼此間並沒有明顯差

圖16、第一階段建模之AUC與KS比較圖



異，也皆無過度配適的問題。

接著分析由B.羅吉斯（人工）所篩選出，非授信類資料中預測力較高、且較容易解釋的風險因子⁵，並觀察其風險排序，如表4、圖17所示。先由表4觀察非授信類風險因子的預測力，以 $IV > 0.1$ 、 $KS > 10$ 作為基本門檻來看，「過去12月衍生性商品曾有違約註記」的效力稍低， IV 僅0.035、 KS 僅3.24，主因係有衍生

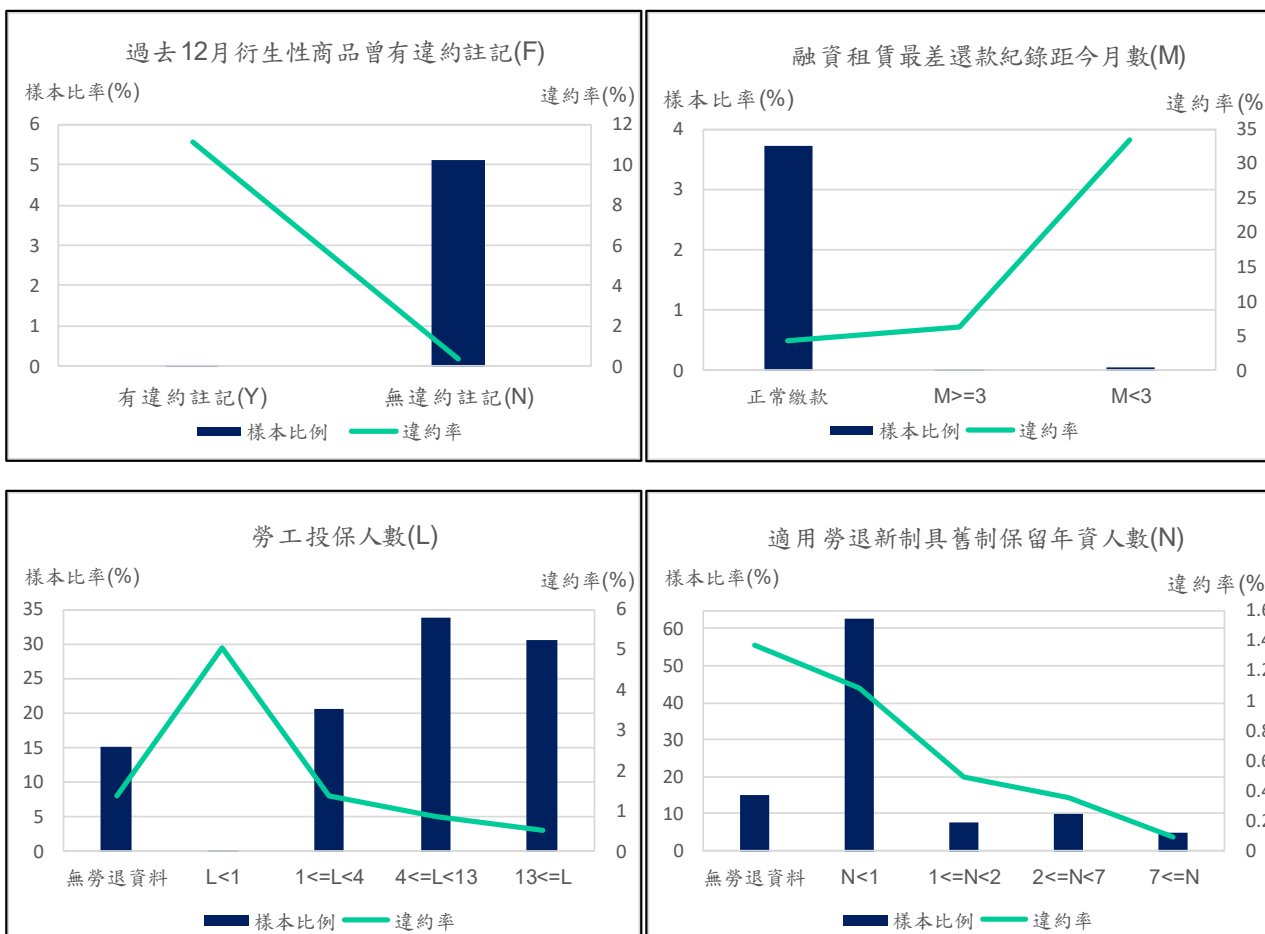
性商品資料的企業違約樣本數非常少，但衍生性商品有違約註記在評估信用風險上較容易解釋且有明顯的風險排序，故仍納為建模風險因子之一。而效力最高的變數為「過去12月工資墊償基金最高欠繳月數」， IV 為1.3， KS 為45.69。其餘變數的 IV 值約在0.15~0.3區間， KS 值約在14~17區間，效力中等。各變數樣本分配、違約率如圖17所示。

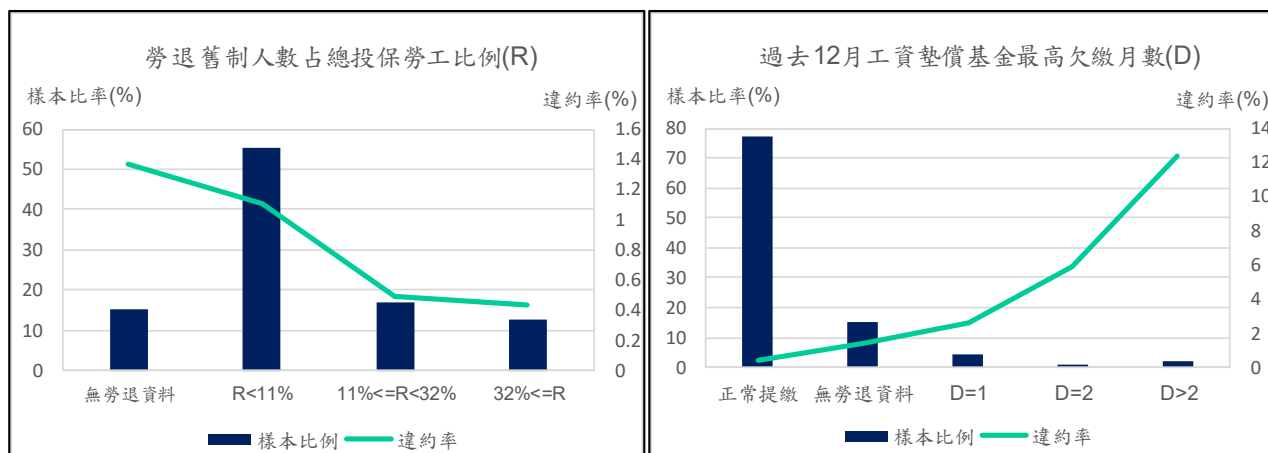
5 因篇幅有限，僅呈現預測力較高(有明顯風險排序效果)變數之相關數據與圖表。

表 4、非授信類變數風險因子違約預測效力

序號	變數名稱	IV	KS
1	過去12月衍生性商品曾有違約註記(F)	0.035	3.24
2	融資租賃最差還款紀錄距今月數(M)	0.282	14.65
3	勞工投保人數(L)	0.164	16.93
4	適用勞退新制具舊制保留年資人數(N)	0.226	14.57
5	勞退舊制人數占總投保勞工比例(R)	0.151	15.44
6	過去12月工資墊償基金最高欠繳月數(D)	1.3	45.69

圖17、非授信類風險因子之樣本分配與違約率





(2) 第二階段建模結果分析

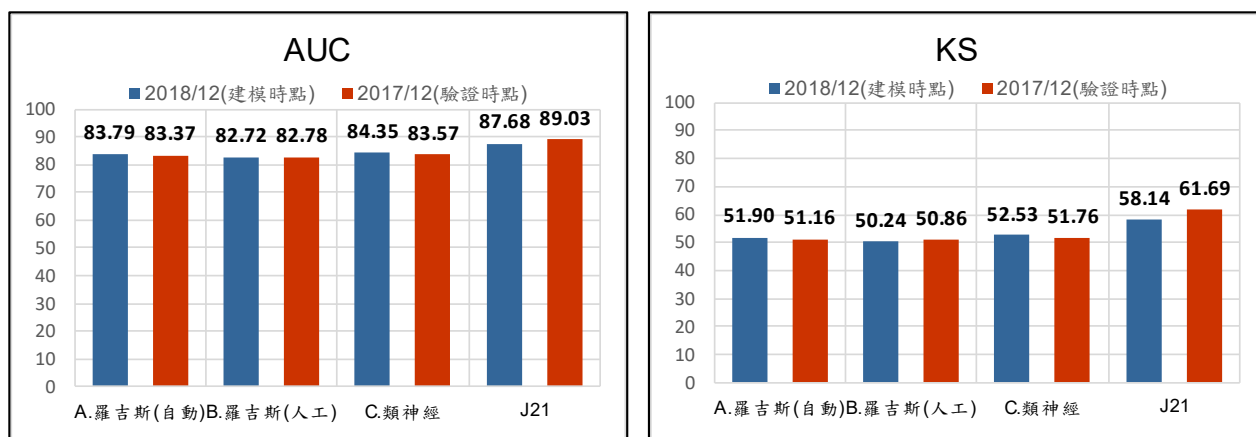
接續觀察第二階段建模之結果，本階段係假定樣本範圍企業皆無授信資料的情境，單以基本資料類、財報類、負責人類⁶資訊，加上非授信類資料進行建模，其中B.羅吉斯（人工）所挑選之非授信類風險因子和級距皆與第一階段建模相同，再與本中心現行評分產品J21⁷（含負責人資訊）一比較模型效力。結果如圖18所示，在2018/12時點，A、B、C三種建模方法之AUC、KS數值皆較第一階段建模結果高，表示納入企業基本資料、財報資料及負責人資訊後，模型的效力的確更好。而A、B、C三種建模方法互相比較下，類神經方法

的AUC為84.35，KS為52.53，稍高於羅吉斯（自動）、羅吉斯（人工），但彼此間的差異不大，與第一階段建模結果相似，說明類神經方法確實能萃取出提升效力之組合變數資訊，只是並未壓倒性勝過羅吉斯方法。另加入J21模型一比較，A、B、C三種方法的模型效力都較低，表示若以非授信類變數替代授信類變數建置模型，雖有不錯的預測力，但傳統以授信類資料為主所建置之J21模型效力仍舊較高。另外以驗證時點觀察，三種方法中僅B.羅吉斯（人工）的AUC、KS數值微幅上升，其餘兩種方法則微幅下降，差異都非常微小，表示三種建模方法皆無過度配適的問題。

6 此處的負責人資訊組合較為單純，僅區分為負責人有違約及負責人無違約。

7 因第二階段建模中加入負責人資訊建模，在比較上選擇同樣含負責人資訊的企業評分產品J21較為合理。

圖18、第二階段建模及J21之AUC與KS比較圖



五、結論

由個人信用評分模型應用類神經的研究結果顯示，在「分析樣本為與銀行已有往來之正常客戶」、且「主要分析用之資料為銀行報送資料及查詢狀況」之前提下，不同的演算方法對於模型的預測力，其實並不會造成很大的差異，各種方法的預測效果都在伯仲之間，與前述所引用的FICO研究結果相似。

上述研究仍有一些限制，例如僅採用聯徵中心既已蒐集之資料，未含其餘多元的替代性資料、且在計算上的設定係套用統計軟體的預設，並未做額外的人為調整等，這些限制對於個人信用評分模型應用類神經的研究結果可能會造成部分影響。

在這個議題上，聯徵中心平衡考量「模型的預測力高低」及「模型結果的可解釋性」兩個面向，身為台灣唯一的信用報告機構，除了提升會員服務品質外，也應顧及當事人權益，以目前類神經網路尚無法就其預測效力達到明

顯的提升、且對於演算結果無法提供易於解釋的說明、以及聯徵中心目前的信用評分預測力仍有相當水平（整體的AUC達90）的前提下，維持現行方法仍為相對較佳的選擇。

而由非傳統授信資料評估無信用資料企業風險之研究結果，可歸納結論如下：

(一) 本文所分析之非授信類資料，佔J20評分範圍企業的比例普遍不高：

樣本範圍中有衍生性商品、融資租賃或重大污染裁罰紀錄資料的企業家數占比都在5%以內，其中有衍生性商品資料的多為中大型企業，主要係衍生性商品風險較高，營運較穩定的中大型企業更容易獲得銀行核給衍生性商品額度；而有融資租賃資料的多為小型企業，主要係小型企業較不易從金融機構取得授信，須透過融資租賃補足資金缺口。而有重大汙染裁罰紀錄的企業家數更為稀少，低於100家。僅有勞退準備金資料的企業佔比較高，約85%。

(二) 非授信類資料中以勞退準備金相關資料的預測表現最佳，較有可能替代傳統授信資料：

因有衍生性商品及融資租賃資訊的企業比例較低，僅是否有違約註記、最差繳款紀錄類型的資訊有較明顯的風險排序和預測力；而勞退準備金資料涵蓋率較高，投（勞）保員工數、舊制員工數比例等變數皆有不錯的預測力，以積欠工資墊償基金欠繳月數的預測力最為突出。

(三) 以非授信類資料建置模型雖有不錯的預測效力，但仍不及以傳統授信資料為核心所建置之J21評分模型：

第一階段分析結果顯示三種模型預測效力並無明顯差異也無過度配適問題。而第二階段建模再加入企業基本資料、財務資料及負責人資訊一同建模，並與J21評分模型比較，結果顯示三種模型預測效力皆較第一階段建模上升，但都不及J21模型之效力，顯示非授信類資料雖能捕捉企業風險屬性，但無法完全取代傳統授信類資料。

(四) 以羅吉斯迴歸、類神經方法各別建置的模型，效力並無明顯差異：

類神經方法模型的AUC、KS數值雖然稍高，但整體來說與羅吉斯迴歸模型無明顯差異，說明類神經方法並沒有壓倒性的預測效力，且不若羅吉斯迴歸模型能清楚解釋變數與違約率之間的關係。

聯徵中心針對企業評分的原則係「行為評分」，所以上述無授信類資料不能完全取代授信類資料的結果並不意外，但有部分非授信風險因子仍具參考價值，譬如若企業已有衍生性商品違約註記、近3個月融資租賃有延遲繳款或積欠工資墊償基金有欠繳等情形，授信會隨之發生違約的機會也更高，應謹慎評估。期會員機構除查詢授信類產品外，也可多加善用聯徵中心蒐集之非授信類產品，不論無授信資料企業或已有授信往來企業皆能融合多方面資訊加以評估控管風險，滿足企業取得合理的資金來源，促進金融市場發展。

另外在個資及隱私保護的浪潮下，GDPR（歐盟一般資料保護規範）也沒有忽略這波機器學習的趨勢，特為其訂立了相關之規範，在第22條規定「自動化個人決策和分析指引」（Guidelines on Automated individual decision-making and Profiling for the purposes of Regulation）的內容中，為了避免演算法歧視，禁止對個人資料採取完全自動化的決策。亦即人為的參與及判斷仍然是重要的，且必須要能解釋其演算結果，才能符合GDPR保護個人隱私之規定。因此，機器學習固然有其創新性的應用，回歸到實務面仍有其他觀點需加以平衡，而非一味地全盤採用，但聯徵中心仍將持續關注此類議題的發展，並與會員分享相關之研究成果。