

應用資料探勘技術於顧客行為評分模式之建構

謝弘一¹ 李天行^{2*} 邱志洲³ 邱筱筠²

¹ 輔仁大學商學研究所

² 輔仁大學管理學研究所

* 036665@mail.fju.edu.tw

³ 國立台北科技大學商業自動化與管理研究所

摘要

自從雙卡問題及次級房貸風暴浮現，銀行業普遍體認信用風險控管的重要性。對銀行而言，現行核卡制度漸趨嚴格，新顧客開發不若以往容易，既有顧客之管理與維持亦愈顯重要，能否建構一套穩健的信用風險管理系統，將直接影響銀行資產品質與獲利能力，並決定其在此一競爭激烈的金融市場中之成敗關係。然而銀行內部之龐大顧客資料，無法單採人工方式分析，資料探勘可協助萃取出隱藏於資料中的重要資訊，並可進一步用於企業經營或行銷策略的擬定。

本研究利用資料探勘工具，建構信用卡顧客行為評分模式，並針對傳統信用風險研究多將信用評分處理成信用好與不好之二元分類問題，其可能產生重要訊息遺失之缺失，將顧客類型區分為4類，以保留較多重要資訊。實證結果顯示，分類迴歸樹之整體鑑別率為94.78%，明顯高於其他模式，可作為建模工具之優先考量，而各工具篩選出重要變數與若干規則，可為銀行經營管理及策略制定之參考。

關鍵詞：資料探勘，行為評分，類神經網路，分類迴歸樹，多元適應性雲形迴歸。

Abstract

Credit scoring and behavior scoring have become very important credit risk management tasks during the past few years due to the impact of credit and cash card crises in Taiwan and the subprime mortgage crisis throughout the world. The objective of the proposed study is to explore the performance of behavior scoring using four commonly discussed data mining techniques-linear discriminant analysis (LDA), backpropagation neural networks (BPN), classification and regression tree (CART) and multivariate adaptive regression splines (MARS).

To demonstrate the effectiveness of behavior scoring using the above-mentioned techniques, behavior scoring tasks are performed on one bank credit card dataset in Taiwan. As the results reveal, CART not only outperforms LDA, BPN, and MARS in terms of scoring accuracy but also provides managerial implications with the obtained rules, and hence is an efficient alternative in implementing behavior scoring tasks.

Keywords: data mining, behavior scoring, artificial neural networks, classification and regression tree, multivariate adaptive regression splines

1. 緒論

自民國 80 年我國開放新銀行設立，為金融業之戰國時代揭開序幕後，即長期處於家數過多情形。由於競爭激烈，各家銀行莫不積極拓展新業務以增加營收，其中又以信用卡業務為最主要的重點之一。相較於授信金額龐大、放款利率低但風險較高的企業金融業務而言，信用卡業務因有年費、交易手續費和高額循環利息等豐碩收入，並可累積廣大顧客群，有助於拓展其他業務，旋即成為兵家必爭之地。各銀行莫不積極發展信用卡業務，同時在全球各大發卡機構信用卡行銷策略的推波助瀾下，信用卡發卡量逐年暴增。

由於銀行商品的同質性較高，加上模仿成本較低，因此銀行為追求經濟規模發卡量與擴大市場佔有率，競相採取價格競爭並放寬核卡標準(曾淑峰、江俊豪，2006)。如何縮短信用審查的工作並快速核准貸款或發放信用卡，為銀行提升服務品質及競爭力的重要任務。過去銀行大多使用人工方式，以直覺或是根據過去經驗，對申請人之信用狀況進行審核，判斷是

否應該核准其信用申請(Noh *et al.*, 2005)。但面對日漸增多的案件，若要維持人工審理，銀行勢必花費可觀之人力成本。同時，利用經驗累積以及主觀判斷的信用審核方式，會因為授信人員經驗差異、主觀認定，而缺乏客觀且一致之審核標準；更容易因為資深授信審核人員離職而影響授信品質，並增加核准信用不佳客戶申請案的可能性；當面對業績壓力與大量申請案件時，更可能為了衝高業績或消化大量申請案件，而產生授信浮濫的情形。上述現象不僅不符效益考量，更增加銀行呆帳發生機會，銀行須研發正確、有效且快速的信用審核制度。

近來國內外陸續爆發信用違約之金融風暴。國內發生的雙卡風暴，卡債及卡奴問題儼然演變為社會亂象，核卡不實、發卡浮濫之銀行成為眾矢之的；而美國次級房貸風暴所引發的連鎖反應，更對世界金融市場造成重大衝擊。探究兩者形成原因，皆起於將信用授予還款能力較差之客戶，因而使銀行暴露於較大的倒帳風險。銀行業者逐漸體認過去為追求市場佔有率，卻漠視還款資金來源或過度放寬持卡人發卡標準的作法，必須加以更正。提高信用額度或降低最低應繳金額，雖可刺激信用消費，然還款行為「有借有還，再借不難」之授信標準，卻可能將銀行置於極高倒帳風險的危機之中(曾淑峰、江俊豪，2006)。個人信用破產事件不斷發生，導致銀行與信用卡公司產生大量呆帳，已成為國際間共同關心的問題，然而時至今日為止，人們對於此一現象的知識卻相當有限(Donato *et al.*, 1999)。對銀行而言，現行核卡制度漸趨嚴格，新顧客開發不若以往容易，既有顧客之維持與保留亦愈顯重要，能否建構一套穩健的信用風險管理系統，將直接影響銀行的資產品質與獲利能力，並決定其在此一競爭激烈的金融市場中之成敗關係。

銀行的信用部門累積了大量顧客資料，以信用卡部門為例，其中包含顧客的人口統計變數(demographic variables)，例如性別、年齡、職業別、工作年資等連續或是類別資料，以及顧客的交易記錄、繳款記錄、信用額度與可用餘額等與顧客相關之日常資料。若將資料善加分析與處理，從資料中萃取出有用的資訊，除了能夠提供管理者對消費者更進一步瞭解的機會，更可輔助管理者制定申請案件的審件標準。一般而言，評分制度為最具實用性的信用風險評估方法，其係將眾多信用卡申請人的信用資料與持卡人的消費記錄，透過嚴謹之分析方法量化為分數，持續評估其信用風險，並據

以制定核駁申請、信用額度管理與催收帳款之決策。依照顧客生命週期可將評分制度分為：申請評分(application scoring)、行為評分(behavior scoring)和催收評分(collection scoring)等三類，並分別作為信用卡業務之事前、事中和事後信用風險控管機制(Connors and Bona, 2003；張振志，2007)。此三大系統為銀行控管信用風險之重要支柱，三者必須平衡發展，不可偏廢，然目前大部分之信用風險評估模式均著重於探討事前的申請評分系統，對於其餘評分系統則鮮有著墨。此外，由於銀行內部所累積的龐大顧客資料，不易單採人工方式進行分析，而資料探勘(data mining, DM)可協助人們萃取出這些隱藏於資料中的重要資訊，以進一步用於企業經營或行銷策略之擬定。準此，本研究擬針對信用卡既有之客戶歷史行為資料，運用鑑別分析(discriminal analysis, DA)、類神經網路(artificial neural networks, ANNs)、分類迴歸樹(classification and regression tree, CART)、多元適應性雲形迴歸(multiple adaptive regression splines, MARS)等數種資料探勘技術，建立信用卡行為評分模式，提供銀行或授信業者執行既有客戶之信用風險動態管理，偵測用戶違約危機以達改善授信決策、監控客戶信用品質、管理信用額度等目標，進而提昇企業獲利能力。

本論文共分為五部分：第一部份為緒論，說明本文之研究動機、目的及論文的整體架構；第二部分則回顧資料探勘、信用評分與行為評分相關文獻；第三部分則針對類神經網路、分類迴歸樹及多元適應性雲形迴歸做一簡單介紹；第四部分為實證研究，分別比較四種行為評分模式之整體鑑別能力，並進行綜合比較；第五部分則為本研究的結論與建議。

2. 文獻探討

2.1 資料探勘

隨著傳統資料處理逐漸轉成電子型式，資料探勘的發展就已經悄悄地在進行。拜科技進步所賜，電腦及儲存媒體等硬體與軟體價格不斷下降，電腦運算速度也不斷地提昇，再加上交易資料不斷累積，龐大資料量已難單純運用人腦了解與想像。資料之成長，除資料欄位數目(the number of fields)的增加，也包含資料筆數(the number of cases)的增加(Fayyad and

Stolorz, 1997)。人類分析及想像較高維度資料之能力有限，大量資料更難以傳統的人工方式加以整理；而藉由電腦強大運算能力與資料探勘工具，能夠以有效率的方式從現存高維度資料中，萃取出內隱難見，且深具價值的資訊。

Fayyad and Stolorz (1997)認為，知識探索(knowledge discovery in database, KDD)係從資料庫中探索有用知識之全部過程，資料探勘僅為知識探索程序之其中一個步驟。知識探索係辨別出資料中有效、新奇、具潛在效益及可被理解的特徵(patterns)；資料探勘則運用計算(computational)技術，在可接受計算效率限制下，萃取出隱藏於資料中之特徵或模式(models)。Fayyad and Stolorz (1997)將資料探勘技術分為五種基本方法，如預測模式(predictive modeling)、群集(clustering)、統計摘要模式(data summarization)、相依模式(dependency modeling)及變化與誤差偵測(change and deviation detection)等。由於資料探勘技術備受重視，其應用領域也因此日益廣泛，目前已包含金融、保險、商業、行銷、法律、科學等；申言之，只要該產業擁有具分析價值與分析需求的資料倉儲或資料庫，即可利用資料探勘之方法與技術進行有目的之探掘分析。

2.2 信用評分與行為評分

信用評分系統的設計，係用以回答「信用申請者於給定的未來某時間點，其發生違約之可能性」，而該違約風險原本係經由人工方式，以過去經驗為基礎所進行的判斷(Noh *et al.*, 2005)。信用評分問題可視為「判斷信用好或不好」的問題，以提供是否授予信用之決策協助，因此信用評分問題可被處理成資料探勘中的分類(classification)問題。Durand 於 1940 年代初期，首先指出鑑別分析等分類技術可用於貸款風險之信用評分，然而並未真正用於預測之用途(Thomas, 2000)。而最早的信用評分模式，係由 Bill Fair 與 Earl Isaac 兩人於 1950 年代提出，使用鑑別分析建構信用評分模式，用於信託公司(finance houses)與郵購等產業，當時此兩產業中某些公司，正遭逢信用管理問題——信用分析師被徵召入伍，因此有經驗的人員嚴重短缺，而信用評分模式的出現，可協助非專業人士制定信用決策(Lucas, 2001; Thomas, 2000)。

行為評分出現時間較信用評分更晚，其發展的原理與信用評分類似，而其模式建構方式

係以原信用評分模式所使用變數為基礎，並增加其他可描述行為之變數。信用評分之目的係評估新的信用申請者是否存在違約可能性，以輔助授信決策之制定；行為評分則用於衡量既存客戶的信用狀況，以決定後續之信用管理決策(Lucas, 2001; Thomas, 2000)。行為評分之應用範圍較信用評分更廣，其主要目的為預測現存客戶之未來績效，因此可用於決定既有客戶新信用之授予、信用額度之決定、新產品於特定客戶之行銷、信用不良客戶之管理與早期催收決策之制定等(Banasiak and O' Hare, 2001; Thomas, 2000)。

企業若欲於競爭激烈、瞬息萬變的當今環境中維持競爭優勢，必須建立並妥善運用以知識為基礎(knowledge-based)之決策系統，然而多數企業僅專注於前端決策自動化系統(front-end decision automation)，卻忽略了後端決策自動化系統(back-end decision automation)方為企業成功之基礎。大部分的企業收益，最多可高達 90%，來自於既有顧客之重複購買行為；然而，既存顧客同時卻也可能是造成逾期帳款或呆帳損失的高風險族群，故企業必須透過對既有顧客之行為評分機制，徹底了解並執行風險管理方為上策。企業透過行為評分系統可將風險較低之授信決策予以自動化處理，鎖定問題帳戶並立即進行深入調查，而不需將資源耗費於非問題帳戶上，如此有助於提升授信決策之效率、有效分配企業資源，並降低信用交易及帳款催收之處理成本(Banasiak and O' Hare, 2001)。

2.3 行為評分之相關研究

綜觀國內外有關風險管理評估研究，較少針對行為評分進行探討。本研究將部分重要研究整理如下：

馬芳資(1994)利用範例學習法(learning from examples)建構信用卡之信用風險預警系統，藉由分析信用卡客戶的信用資料與繳款情形，預測其發生違約呆帳之機率，研究發現於顧客首度延遲繳款時產生信用風險預警，將可減少信用管理人員約 30%的工作量。

陳敬聰(1997)依持卡人近 6 個月之繳款評等記錄、年齡、學歷、職業、年收入、公司等級、行業別、有無不動產、持卡種類及張數等變數，利用類神經網路建構 6 個單一預警模式，再透過交叉驗證法(cross validation approach)調整模式參數，使準確度皆可達 95%

以上。其多重模式比較結果亦指出，類神經網路預警系統優於鑑別分析法與範例學習法，結合基因演算法與類神經網路混合學習法更可提高準確度至 98% 以上，可作為預警決策之參考。

Fritz and Hosemann (2000) 以年營業額介於 500 至 5,000 萬之德國企業作為研究對象，利用企業過去之 98 項時間序列資料變數，分別使用鑑別分析、圖形辨識 (pattern recognition)、基因演算法 (genetic algorithm, GA)、類神經網路，及決策樹等多項分析方法建立自動化評分系統，除檢視各模式之分類準確度，亦綜合考慮模式之透明度 (transparency)、IT 建置成本及查核功能 (verification)。研究結果指出，最適化鑑別分析模式為德國企業最佳之行為評分模式。

Lin (2002) 整合羅吉斯迴歸及前向式類神經網路 (feed-forward neural network) 建構複合式評分模式，先透過貝氏定理 (Bayesian rules) 將分類方程式簡化，再以羅吉斯迴歸中之最大似估計法，及前向式類神經網路中之兩階段學習演算法估計貝氏後驗機率 (Bayesian posterior probability)，其實證結果顯示該複合式評分模式優於單一迴歸模式。

Hsieh (2004) 提出一資料探勘及行為評分的整合模式，以針對某銀行信用卡既有顧客進行風險管理。該研究首先利用付款行為、最近購買日、購買頻率、購買金額等行為評分預測因子，以自組織映射圖 (self-organizing map, SOM) 類神經網路模式將顧客予以分類，再以 Apriori 關聯法則描繪顧客屬性特徵，以協助發展行銷策略。

詹育晟 (2005) 以國內某金融機構的現金卡用戶為研究對象，採用進件系統中之客戶基本資料，以及聯合徵信中心的信用資料，利用羅吉斯迴歸針對核卡後用戶行為建立評分模式，以作為金融業者採取降低損失措施的參考依據。研究結果提出性別、教育程度、最近 3 個月內照會次數、行外金融機構總借款餘額／行外金融機構總借款訂約金額、信用卡有效家數、現金卡張數、現金卡總訂約金額、現金卡總借款餘額／現金卡總訂約金額、本行目前額度／本行訂約額度等 9 項重要變數，其中多項來自於聯合徵信中心或其衍生變數，故聯合徵信中心所提供之外部資料極具參考價值。

盧俊傑 (2006) 提出一種偵測信用卡不良客戶智慧型推論系統，利用國內某金融機構信用

卡持卡人的人口統計變數與帳款及信用餘額等財務資料，以結合模糊邏輯 (fuzzy logic) 與特徵分析 (feature analysis) 的倒傳遞類神經網路模式進行不良信用卡客戶之偵測分析，研究結果顯示其準確度可達 90% 以上。

張振志 (2007) 利用人口統計、客戶消費、繳款行為及存款記錄等 46 個變數作為自變數，採用鑑別分析、羅吉斯迴歸、倒傳遞類神經網路及兩階段整合模式建構信用卡行為評分模式。研究發現近 3 個月平均額度使用率、近 6 個月逾期 30 天以上次數、信用卡貸款產品註記、信用卡貸款產品持有數、最長持卡月數、年齡、預借現金額度使用率、代償卡註記、距上次繳款日的天數、教育程度、近 6 個月平均額度使用率等 11 項為影響行為評分結果之重要變數，此外，前述 4 種分類模式中，以倒傳遞類神經網路兩階段整合模式之整體鑑別率最高。

陳怡妃 (2008) 利用 1,220 筆國內某發卡銀行提供之顧客資料建構顧客行為評分模式。為彌補單一分類工具不足之處，將高維度資料藉由無母數多元適應性雲形迴歸 (MARS)、無母數加權特徵萃取 (nonparametric weighted feature extraction, NWFE) 及支援向量機 (support vector machines, SVM) 等工具串結，先進行特徵篩選及萃取，以縮減維度與運算複雜度。研究結果發現，相較於使用單一工具之分類模式，該整合模式之整體鑑別率最高，個別誤置成本最低，並能有效縮短模式運算時間，而為最佳之鑑別模式。

3. 研究方法

3.1 類神經網路

近年來有關類神經網路的研究都顯示類神經網路具有強大的樣式分類 (pattern classification) 與樣式辨認 (pattern recognition) 的能力 (Wong *et al.*, 1997; Vellido *et al.*, 1999; Zhang *et al.*, 1998)，並且可以廣泛的應用於監督式 (supervised) 與非監督式 (unsupervised) 的學習問題當中。由於類神經網路具有嚴謹的數學基礎、大量平行的處理能力、容錯能力、高聯想力以及雜訊過濾等特性，且對於傳統統計方法建構模式時所要求的許多假設條件亦可予

以彌補(Rumelhart *et al.*, 1986)，因此在相關領域的應用中，已有許多文獻被發表，例如市場區隔、股價指數預測、匯率/利率預測、破產預測、企業危機預警、信用預測、信用評等及保險問題中的道德危機等(李天行等人, 2001; 李天行、唐筱菁, 2004; Berry and Linoff, 1997; Fish *et al.*, 1995; Hann and Steurer, 1996; Hsieh, 2005; Huang *et al.*, 2004; Lee *et al.*, 1997; Lee and Chen, 2005; Lee and Chiu, 2002; Lee *et al.*, 2002; Vellido *et al.*, 1999; Wong *et al.*, 1997; Zhang *et al.*, 1998)。

類神經網路發展至今已有多成熟的模式被提出，可依學習策略分為監督式學習、非監督式學習與聯想式學習(associate learning)等 3 種類別的網路架構。在眾多網路模式中，以屬於監督式學習的倒傳遞類神經網路最具代表性、應用也最為廣泛。根據 Vellido *et al.*(1999)的研究指出，於 1992 到 1998 年間，在商業領域中使用類神經網路作為研究方法者，約有 78% 的比例使用倒傳遞類神經網路(Back-propagation Network, BPN)，且由於倒傳遞類神經網路具有學習準確度高，回想速度快、高容錯能力等優點(Anderson and Rosenfeld, 1988; Rumelhart *et al.*, 1986; Lippmann, 1987; Nelson and Illingworth, 1990; Stern, 1996)，故本研究中以倒傳遞類神經網路作為分析工具。

3.2 分類迴歸樹

早在 1960 年代開始便有許多文獻以樹狀結構方式進行資料分析，不過早期的分析工具僅能處理連續型的變數，對於間斷型變數的分析，因為無法同步處理，故而難達到理想的成效。爾後，分類迴歸樹的發展解決了前述問題，成為可以同步處理連續型及間斷型資料的分析工具。分類迴歸樹為一新型的分類技術，由 Breiman *et al.* (1984)提出，其基本原理是針對每個分割點使用二元分割(binary splitting)過程分析龐大的資料集，透過不斷遞迴的過程，

將預測變數依照與其相對應的各項指標，把既有的訓練樣本劃分成數個已知的類別，再將劃分分割點的每個程序彙整成一連串的分類規則，利用這些規則對測試樣本進行劃分類別的動作。使用上的優點乃是透過樹狀圖的表現方式，將資料的分析結果清楚且完整的呈現出來，因此在資料分析的過程中具有視覺化與容易解釋的特色。

基本上，CART 的主要進行步驟可分為三部分：先將樣本資料劃分為訓練與測試樣本，並根據劃分條件使用訓練樣本作為學習樣本，依據劃分規則建構最大數目的決策樹；其次是依照所挑選的準則，從樹的底部向上進行修剪，並產生許多子樹群(subtrees)，直到修剪準則被滿足為止；最後使用測試樣本進行交叉驗證，並在子樹群中挑選一最佳樹狀結構。待樹狀結構建置完成後，CART 將產生一連串的分類規則，而該規則可輔助決策者瞭解，在輸入新的樣本資料後，如何將新樣本劃分到適當的分類群組中。有關 CART 的詳細進行步驟描述整理如下：

首先是建構最大樹狀結構，CART 使用遞迴二元劃分規則進行資料切割的動作，CART 在每個結點中將資料分割為兩個子資料集，而在進行切割的決策時，並不考慮該切割點對整體表現的影響，因此可以更快速的方式建構最大樹狀結構。此外 CART 考慮了所有可能的切割組合，並依照事先所選定的指標篩選最佳切割點。挑選結點異質性的指標有 Gini、Toving、Entropy 等，其中最常用的指標為 Gini 值(Gini index) ($Gini(t) = 1 - \sum_i P_i^2$, t 表已知結點 t 、 P_i 則表第 t 個結點中第 i 個類別的機率)。當 Gini 值愈小則代表在該切割點所產生的子結點中，其內的組成份子愈單純；換言之，該切割點愈能代表不同類別之間的差異，因此所造成分類錯誤的機率也愈低。而這樣的流程會一直

由上往下(top-down)進行，直到所有的資料皆被劃分到同一類別，或是已經細分到某一類別內僅存單一類別樣本時，或是滿足了某些條件(決策樹層數、細分的程度等)的情況下才停止。

當 CART 找出某一末端結點時，便需決定該結點歸屬於哪一類別，通常皆以個數最多的類別當作該末端結點的類別。CART 會以計算誤判成本考慮是否繼續產生子結點，當所有末端終點都完成後，此時的樹狀結構稱之為最大樹(maximal tree)。傳統的決策樹建構過程如 CHAID 等均停止於第一步驟，因此往往無法降低誤判率，而 CART 則進一步進行樹狀結構的修剪步驟，以提高分類的準確度。

第二個步驟為修剪樹狀結構，當最大樹狀結構建構完成後，CART 會開始修剪樹狀結構以降低誤判率。決策樹修剪以誤判率(error rate)或誤判成本(error cost)最小為原則。通常使用者可將資料分為訓練和測試樣本兩部分，以訓練樣本建構樹狀結構，而測試樣本則用來計算誤判率。將測試樣本代入計算最大樹與所有子樹的誤判率，並挑選出最低誤判成本或最低誤判率的樹狀結構。但當樣本數不足時(一般建議樣本數需大於 150)，使用者則可使用交叉驗證法進行樹狀結構修剪。

而第三個步驟為選擇最佳樹狀結構，為了避免經過修剪後的樹狀結構太小，使用者可以放寬最小誤判率以獲得較大或較複雜的樹狀結構。而在選擇最佳樹狀結構的同時，也可以觀察變數的重要程度，例如當某變數被移除時，誤判率明顯增加，或者變數在被挑選的樹狀結構出現的機率愈高，就表示該變數為重要的鑑別因素，其他有關 CART 的詳細運算請參考 Breiman *et al.* (1984)。

3.3 多元適應性雲形迴歸

MARS 是一個新興的多變量無母數迴歸程序技術，是藉由採用數個基本方程式(basis

function, BF)的累加模式以解釋非線性狀態的工具(Friedman, 1991)。

$$\hat{f}(x) = a_0 + \sum_{m=1}^M a_m \prod_{k=1}^{K_m} [s_{km} \cdot (x_{v(k,m)} - t_{km})]_+ \quad (1)$$

上面的方程式(1)為通用的 MARS 模式，其中 BF 則是後段累乘的部分(如下所示)，主要是根據需求而變化。

$$B_m(x) = \prod_{k=1}^{K_m} H[s_{km} \cdot (x_{v(k,m)} - t_{km})]_+ \quad (2)$$

其中 a_0 與 a_m 皆為參數值，其功能類似線性迴歸模式的迴歸係數；M 為 BF 的個數，經由評估準則決定； K_m 為切割之折點個數； s_{km} 之值為 +1 or -1，其作用為顯示方向； $v(k,m)$ 是對變數的標示；最後 t_{km} 則是各結點的分界點(數值)。

而在給定目標變數和一個可選擇預測變數的集合下，MARS 令所有模式建立及調度自動化，其中包括將有意義的變數與較不恰當的變數分開、決定預測變數間的交互作用、採用新的變數群聚技術處理遺失值問題及採用大量的自我測試避免過度配適(Steinberg *et al.*, 1999)。

吾人可將 BF 視為每一段規則中所屬的解釋方程式，而每個 BF 則是經由評估其損適性(loss of fit, LOF)之判斷標準決定所包含之影響變數的個數，並同時經由前推式及後推式演算法尋找較適當的折點數以及交互作用，解決高維度資料的各種問題，是相當具有彈性的迴歸處理程序，可以快速地自動建立準確的模式推測其連續或二元的反應變數(Friedman, 1991)。而根據 LOF 決定 BF 個數時，主要是參酌各個 BF 在加入後，是否在主要模式中具有貢獻性，評估其表現是否在可接受的範圍內，以降低模式的複雜度，加速其對資料的處理及判斷。而其權衡的概念如上述，是以 LOF 的觀念加以判斷，而所採用的方法為 GCV (generalized cross validation)，是由 Spline 的研

究先趨(Craven and Wahba, 1979)所提出的判斷準則，下列為 GCV 的處理方法：

$$LOF(\hat{f}_M) = GCV(M) = \frac{1}{N} \sum_{i=1}^N [y_i - \hat{f}_M(x_i)]^2 / \left[1 - \frac{C(M)}{N} \right]^2 \quad (3)$$

其中 $C(M)$ 為採用 m 個 BF 所需付出的成本，而最主要的概念是來自下列方程式：

$$\Delta[\hat{f}(x), f(x)] = [\hat{f}(x) - f(x)]^2 \quad (4)$$

綜上所述，最佳化的 MARS 模式是由兩個處理程序決定。在第一個程序中，模式是由不斷增加 BF (所有的主要效果、折點或交互作用) 直到找到一個完整的模式，也就是前推式的演算法；而第二步驟則是根據其貢獻度去除貢獻較少的基本方程式，直到找到一個誤差及變數個數的最佳平準點，也就是後推式的演算法。而藉由有效給定回應方程式以及交互作用及採用兩階段程序模式選擇法，MARS 可以可靠地追蹤非常複雜且隱藏在高維度資料裡的資料結構。因此 MARS 之優點在於可以藉由較佳的演算程序，快速找出隱藏於高維度複雜資料結構中的最佳變數轉換和交互作用。而這個新的迴歸模式建立程序，可以從上述的過程中，有效地在資料中發掘出過去的處理方法中，難以發現的變數之間的重要特性及關係。

4. 研究方法

實證研究部分首先進行實證資料庫之描敘及前置處理作業，其次則依序說明各項分類工具之模式建構過程及實證結果，最後並針對各項結果進行綜合比較與分析。

4.1 資料預處理

實證資料庫為國內某大發卡銀行所提供之信用卡顧客抽樣資料，而行為評分模式之建

構，除須取得一般徵信資料外，更強調必須依據歷史消費紀錄持續地觀察用戶行為模式，故本研究係以 2005 年一月為資料時間基期，首先剔除遺漏值或明顯輸入錯誤之資料，並排除近半年內均無任何消費紀錄之呆卡，或有遺失、遭竊、偽卡、卡片毀損、自行停用、遭銀行強制停用等情形之無效卡，以及持卡未滿半年、VIP、無限卡等特殊客戶，隨後選取無任何逾期繳款或使用循環利息紀錄之客戶作為觀察對象，經過為期 12 個月的觀察期後，依據 2006 年一月之繳款評等紀錄評斷客戶行為。經上述資料前置處理後，實證資料庫共有 5,000 筆樣本資料。傳統的信用風險研究，大部分使用二元分類器(binary classifiers)，並將問題處理成信用好與不好的二元分類(binary classification)問題(Noh *et al.*, 2005)。由於各種客戶類型帶給銀行的效益不盡相同，銀行必須採用不一樣的行銷策略與信用管理政策，單純的二分法可能遺失許多重要訊息，因此本研究將顧客類型區分為正常還款、循環繳息、無消費紀錄與帳款逾期等 4 類，其分布情形如表 1 所示，其中包含正常還款者 1,770 筆、循環繳息者 1,170 筆、無帳單或消費紀錄者 1,510 筆、有帳款逾期紀錄者 550 筆等共 4 類，而自變數則包括人口統計變數及歷史消費與卡片使用狀況等描述行為特性之變數共 43 項。

表 1 樣本資料分布情形

類別 (編碼)	次數	百分比	累積百分比
正常還款者 (1)	1,770	35.4%	35.4%
循環繳息者 (2)	1,170	23.4%	58.8%
無消費紀錄者 (3)	1,510	30.2%	89.0%
帳款逾期者 (4)	550	11.0%	100.0%
總和	5,000	100.0%	

4.2 模式建構

本研究乃運用傳統統計之鑑別分析 (DA)，以及人工智慧之倒傳遞類神經網路

(BPN)，無母數之分類迴歸樹(CART)與多元適應性雲形迴歸(MARS)等工具進行信用卡行為評分分類模式之建構，其中鑑別分析使用 SPSS Inc. 出版之 SPSS for Windows 12.0 (2003) 版統計套裝軟體，倒傳遞類神經網路則使用 Vesta Services Inc. 出版之 Qnet 97 (1998) 軟體，而分類迴歸樹與多元適應性雲形迴歸則分別使用由 Salford Systems 所出版之 CART 6.0 ProEX (2008) 版軟體及 MARS 2.0 (2001) 版軟體進行分析。

為降低模式建構過程中出現樣本偏誤之現象，並確保模式之穩健性(robustness)，本研究採用 5-fold 交叉驗證(5-fold cross-validation) 方式進行模式建構，因此每種工具都將建構 5

個模式。然為避免篇幅過於繁雜，實證結果均以第一個集合為例加以說明，其他集合部分僅列出其組鑑別率及平均整體鑑別率。

4.2.1 鑑別分析實證結果

由於實證資料庫中包含類別變數，分析前須先將之轉換為虛擬變數。鑑別分析採用逐步鑑別分析法(stepwise discriminant analysis)，以各變數的 Wilks' lambda 值(又稱 U 統計量)作為逐步鑑別分析的變數選擇法，選取能將整體 Wilks' lambda 值降至最低的重要變數進入鑑別方程式中。經由模式的建構程序，由 43 個變數中共選出 23 項重要變數，鑑別方程式如表 2 所示：

表 2 DA 模式之鑑別方程式

	Y			
	正常還款	循環繳息	無消費記錄	帳款逾期
年齡	.441	.411	.465	.412
普卡持有數	2.026	2.246	1.865	2.263
距上次溢繳日之天數	.000	-4.835E-5	.002	.000
近 6 個月平均總消費餘額與繳款金額比	.032	.016	.020	.016
當月最低應繳款	7.400E-6	-4.721E-6	3.916E-6	-7.420E-5
距上次繳款日的天數	.001	3.736E-5	.002	.001
近 24 個月累積總消費金額	3.700E-6	1.025E-6	5.946E-7	1.078E-6
近 6 個月超額消費次數	-.035	-.631	.033	-1.076
近 3 個月平均帳上總金額	-3.078E-5	-5.282E-6	-2.350E-5	-6.341E-5
近 3 個月平均額度使用率	-.013	.060	-.025	.028
近 3 個月最高額度使用率	.140	.070	.097	.104
當月總消費餘額	-1.356E-5	-3.291E-5	-1.313E-5	2.422E-5
當月額度使用率	.000	.123	.027	.133
距上次最高消費月之月數	.082	.063	.067	.065
最高消費餘額	-4.133E-6	4.520E-6	-1.991E-6	1.968E-6
永久額度	2.848E-5	3.102E-5	2.398E-5	3.108E-5
當月預借現金次數	-.173	.566	-.183	.054
近 6 個月逾期 30 天以上的平均金額	.000	-6.961E-5	.000	.001
近 6 個月逾期 30 天以上之次數	-.188	-.744	-.241	8.167
距上次繳款逾期之月數	.025	.031	.020	.006
教育程度	2.958	1.979	3.566	2.088
有無信用卡貸款產品	12.224	11.141	11.944	9.783
有無自動扣款戶	9.552	10.747	10.373	10.524
(常數)	-25.949	-28.530	-25.418	-44.909

觀察表 2 之鑑別方程式係數可發現，各變數對於信用卡顧客行為模式類型判別之影響力及管理意涵。舉例而言，當顧客出現普卡持有張數偏多、年齡偏高、近 3 個月最高額度使用率高、當月預借現金次數較少、近 6 個月逾期 30 天以上次數較少等特性時，模式偏向將該客戶歸為正常繳款顧客；反之，當顧客出現近 6 個月逾期 30 天以上次數較多、有信用卡貸款產品、無辦理自動扣款、當月帳上一般消費餘額偏低、距上次繳款逾期之月數較久、距上次溢繳日之天數較長等特性時，模式則傾向將該顧客歸類為帳款逾期顧客。鑑別分析所得之集合一測試樣本之結果整理於如表 3。

表 3 DA 模式之鑑別結果

Predict \ Target	1	2	3	4	總和	鑑別率
1	329	5	20	0	354	92.94%
2	40	180	12	2	234	76.92%
3	87	0	213	2	302	70.53%
4	2	15	5	88	110	80.00%
整體鑑別率	81.00%					

表 4 DA 模式交叉驗證鑑別結果

集合別	交叉驗證鑑別結果				整體鑑別率
	{1-1}	{2-2}	{3-3}	{4-4}	
一	92.94%	76.92%	70.53%	80.00%	81.00%
二	91.81%	74.36%	73.84%	82.73%	81.30%
三	96.61%	75.64%	68.87%	80.00%	81.50%
四	96.33%	73.50%	69.54%	80.00%	81.10%
五	94.63%	73.08%	71.19%	82.73%	81.20%
平均	94.46%	74.70%	70.79%	81.09%	81.22%

由表 3 可知，測試樣本於鑑別分析模式所得之整體鑑別率為 81.00%，其中以 {1-1}¹ (註 1) 的個別鑑別率 92.94% 最高，而 {3-3} 的個別鑑

¹其中以數字 1、2、3、4 分別表示正常還款者、循環繳息者、無消費紀錄者及帳款逾期者，在 {x-y} 中，以 x 表示實際類別，而以 y 表示模式所得之預測類別。

別率僅 70.79% 為最低。茲將 5 個集合之測試資料交叉驗證結果列示於表 4，各集合之整體鑑別率分別為 81.00%、81.30%、81.50%、81.10% 及 81.20%，其平均整體鑑別率則為 81.22%。

4.2.2 倒傳遞類神經網路模式實證結果

在類神經網路模式的網路結構中，由於 Zhang *et al.* (1998) 認為單一隱藏層已能分析大部分之分類問題，為避免網路結構過於龐大，因此將隱藏層數目設為一層；輸入層神經元則包含 43 個神經元；而隱藏層神經元個數部分，根據文獻中指出一般採用 2n (Wong, 1991)、2n+1 (Lippmann, 1987; Hecht-Nielsen, 1990) 等個數組合做為試誤法的起始點，其中 n 為神經元之個數，因此本研究分別採用以 84、85、86、87、88 等 5 種組合進行測試；為提升模式鑑別率，本研究將原單一神經元 4 項類別之依變數轉換為以 2 個神經元表示 4 項類別，轉換前後對照請參見表 5；在網路參數的相關設定中，訓練圈數經試誤後定為 7000 圈；而試誤過程中發現當學習率大於 0.0006 時，網路皆無法收斂，故將測試 0.0006、0.0005、0.0004、0.0003、0.0002 等 5 種學習率。

表 5 BPN 模式依變數轉換對照表

應變數	類別	轉換前		轉換後	
		應變數	類別	應變數	類別
Y	1	(Y1, Y2)	(0, 0)		
Y	2	(Y1, Y2)	(0, 1)		
Y	3	(Y1, Y2)	(1, 0)		
Y	4	(Y1, Y2)	(1, 1)		

由於本研究性質屬資料探勘中之分類問題，而均方根誤差 (root mean square error, RMSE) 僅為演算法所得結果，其值愈低並非代表模式鑑別率愈高，故本研究以鑑別率最高之網路結構作為最佳網路模式。表 6 為不同參數組合設定下所得之訓練樣本 RMSE、測試樣本 RMSE 及測試樣本之整體鑑別率，結果顯示當網路結構為 {43-88-2-0.0006}，亦即輸入層神經

表 6 BPN 模式於各項參數組合之實證結果

隱藏層 神經元數	學習率	訓練 RMSE	測試 RMSE	測試樣本之 整體鑑別率	訓練 時間
84	0.0002	0.191423	0.193616	82.20%	32:32
	0.0003	0.179508	0.181876	84.50%	32:32
	0.0004	0.173660	0.177806	85.10%	32:31
	0.0005	0.173410	0.178722	85.30%	32:35
	0.0006	0.170374	0.173064	86.60%	32:31
85	0.0002	0.185610	0.186987	83.00%	34:33
	0.0003	0.178144	0.179835	85.10%	33:11
	0.0004	0.177177	0.178002	86.20%	33:08
	0.0005	0.173235	0.175144	86.40%	33:06
	0.0006	0.171142	0.173691	85.70%	33:02
86	0.0002	0.191511	0.192631	82.40%	34:11
	0.0003	0.179724	0.181088	85.10%	33:44
	0.0004	0.175591	0.179696	84.50%	33:24
	0.0005	0.172898	0.174977	85.80%	33:48
	0.0006	0.171720	0.174154	86.20%	33:10
87	0.0002	0.188467	0.190257	82.80%	33:32
	0.0003	0.177942	0.179417	85.20%	33:35
	0.0004	0.178445	0.179413	86.00%	33:47
	0.0005	0.172815	0.175010	85.70%	33:47
	0.0006	0.169457	0.172918	86.70%	34:36
88	0.0002	0.186869	0.188219	83.40%	33:58
	0.0003	0.177179	0.178450	85.40%	33:58
	0.0004	0.173605	0.174706	86.60%	33:56
	0.0005	0.173645	0.176029	86.00%	33:59
	0.0006	0.169776	0.172069	86.90%	33:56




圖 1 {43-88-2-0.0006} 訓練樣本 RMSE 趨勢圖

元數目為 43，隱藏層神經元數目為 88，輸出層神經元數目為 2，且學習率為 0.0006 時，將獲致最佳鑑別結果(86.90%)。此外，由圖 1 可看出在 {43-88-2-0.0006} 參數設計中，訓練樣本 RMSE 已趨收斂，可知此模式收斂情形良好。

表 7 為測試樣本於此最佳模式之鑑別結果，其整體鑑別率為 86.90%，其中又以 {4-4} 之鑑別率達 91.82% 為最高。此外，由於類神經網路訓練過程較為耗時，此模式訓練過程共費時 33 分 56 秒，且集合一資料中 25 種參數組合模式平均費時 33 分 28 秒。

表 7 BPN 模式之鑑別結果

Predict Target	Predict				總和	鑑別率
	1	2	3	4		
1	321	8	24	1	354	90.68%
2	27	193	5	9	234	82.48%
3	45	0	254	3	302	84.11%
4	1	3	5	101	110	91.82%
整體鑑別率	86.90%					

表 8 則整理 5-fold 交叉驗證中各集合之整體鑑別率，其結果分別為 86.90%、89.70%、87.70%、87.50%、87.40%。整體而言，類神經網路模式所得之鑑別結果介於 86.90% 至 89.70% 之間，而其平均整體鑑別率則為 87.84%

表 8 BPN 模式交叉驗證鑑別結果

集合別	交叉驗證鑑別結果				整體 鑑別率
	{1-1}	{2-2}	{3-3}	{4-4}	
一	90.68%	82.48%	84.11%	91.82%	86.90%
二	98.02%	88.03%	79.47%	94.55%	89.70%
三	89.83%	83.76%	86.09%	93.64%	87.70%
四	98.59%	88.89%	74.17%	85.45%	87.50%
五	91.53%	79.49%	86.09%	94.55%	87.40%
平均	93.73%	84.53%	81.99%	92.00%	87.84%

4.2.3 分類迴歸樹模式實證結果

在分類迴歸樹模式建構過程中，採用 Gini 值作為結點之異質性評估指標，並依分類迴歸

樹列出各變數之重要性，進行重要預測變數之篩選。分類迴歸樹模式於集合一之最適樹狀結構如圖 2 所示²，而表 9 則彙總分類迴歸樹模式篩選出之重要變數及其相對重要性，其共篩選出「近 6 個月逾期 30 天以上之次數」、「近 6 個月平均總消費餘額與繳款金額比」、「近 3 個月平均帳上總金額」、「距上次繳款日的天數」、「當月總消費餘額」、「當月最低應繳款」、「距上次繳款逾期之月數與距上次溢繳日之天數」等 8 項重要變數，其中又以「近 6 個月逾期 30 天以上之次數」之相對重要性達 100% 為最高。

表 9 CART 最適結構之重要變數相對重要性

變數代碼	變數名稱	重要性 (%)
X41	近 6 個月逾期 30 天以上次數	100.00
X20	近 6 個月平均總消費餘額與繳款金額比	78.32
X28	近 3 個月平均帳上總金額	75.29
X23	距上次繳款日的天數	30.19
X31	當月總消費餘額	8.49
X22	當月最低應繳款	6.15
X42	距上次繳款逾期之月數	2.36
X18	距上次溢繳日之天數	1.86

表 10 列出分類迴歸樹歸納出各葉結點之分類規則，由其中可得若干管理意涵。以葉結點 1 為例，若顧客具有「近 6 個月逾期 30 天以上之次數」不超過 0.5 次、「近 3 個月平均帳上總金額」在 52 元以下等特性時，模式便將其歸為無消費記錄顧客，發卡機構因此可考慮減少或避免於此類顧客之投資，以提升經營績效。分類迴歸樹模式於測試集合一之鑑別結果列於表 11，而 5-fold 交叉驗證之實證結果則彙總於表 12，結果顯示其整體鑑別率介於 93.60%

²各變數代碼所代表之變數名稱，請參見表 9。

表 10 CART 模式最適結構之分類規則

葉結點	分類規則	類別
1	$X_{41} \leq 0.5 \ \& \ X_{28} \leq 52$	3
2	$X_{41} \leq 0.5 \ \& \ X_{28} > 52 \ \& \ X_{20} \leq 98.5 \ \& \ X_{31} \leq 2570 \ \& \ X_{23} \leq 46$	1
3	$X_{41} \leq 0.5 \ \& \ X_{28} > 52 \ \& \ X_{20} \leq 98.5 \ \& \ X_{31} \leq 2570 \ \& \ X_{23} > 46$	3
4	$X_{41} \leq 0.5 \ \& \ X_{28} > 52 \ \& \ X_{20} \leq 98.5 \ \& \ X_{31} > 2570 \ \& \ X_{23} \leq 56$	2
5	$X_{41} \leq 0.5 \ \& \ X_{28} > 52 \ \& \ X_{20} \leq 98.5 \ \& \ X_{31} > 2570 \ \& \ X_{23} > 56$	3
6	$X_{41} \leq 0.5 \ \& \ X_{28} > 52 \ \& \ X_{20} > 98.5 \ \& \ X_{23} \leq 52.5$	1
7	$X_{41} \leq 0.5 \ \& \ X_{28} > 52 \ \& \ X_{20} > 98.5 \ \& \ X_{23} > 52.5$	3
8	$X_{41} > 0.5 \ \& \ X_{22} \leq 1172.5 \ \& \ X_{42} \leq 1.5$	4
9	$X_{41} > 0.5 \ \& \ X_{22} \leq 1172.5 \ \& \ X_{42} > 1.5 \ \& \ X_{18} \leq 84$	1
10	$X_{41} > 0.5 \ \& \ X_{22} \leq 1172.5 \ \& \ X_{42} > 1.5 \ \& \ X_{18} > 84$	3
11	$X_{41} > 0.5 \ \& \ X_{22} > 1172.5$	4

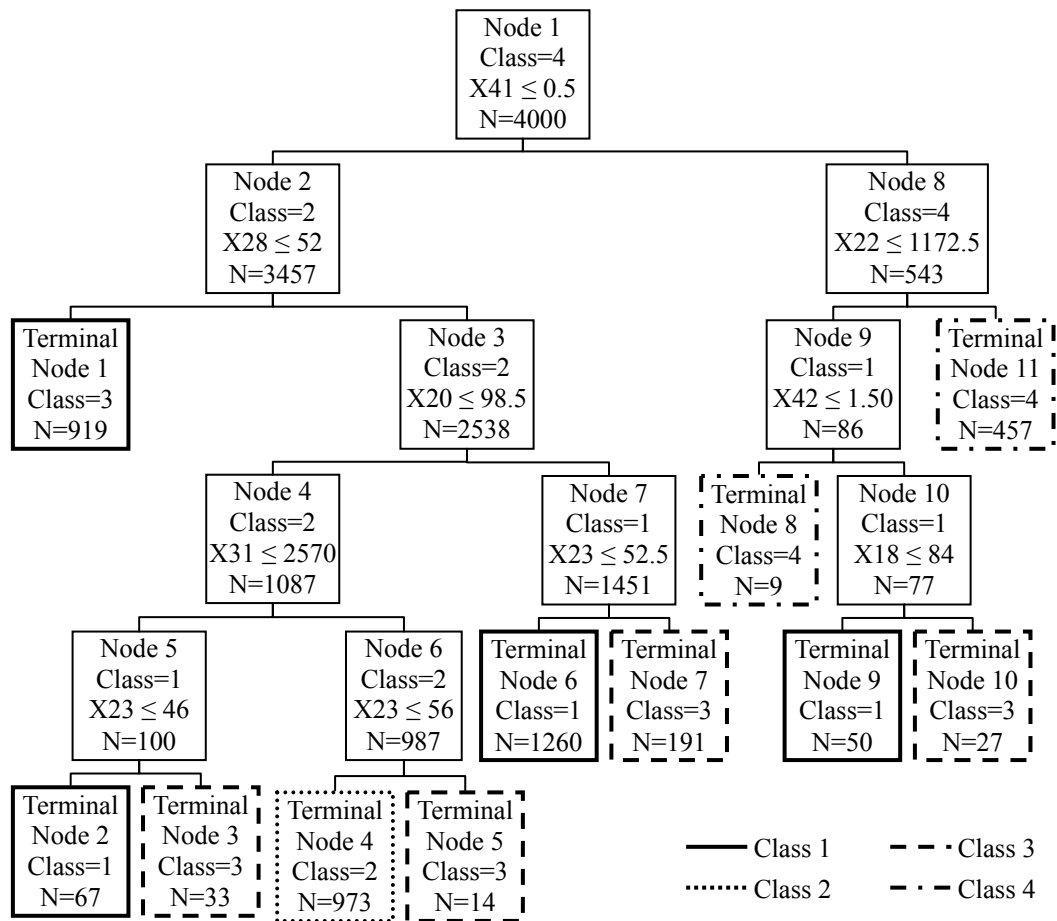


圖 2 CART 模式之最適樹狀結構圖

至 96.30%之間，分別為 94.80%、94.70%、94.50%、96.30%、93.60%，而其平均整體鑑別率則為 94.78%。

表 11 CART 模式之鑑別結果

Predict Target	Predict				總和	鑑別率
	1	2	3	4		
1	330	21	3	0	354	93.22%
2	4	222	2	6	234	94.87%
3	14	0	287	1	302	95.03%
4	0	0	1	109	110	99.09%
整體鑑別率	94.80%					

表 12 CART 模式交叉驗證鑑別結果

集合別	交叉驗證鑑別結果				整體鑑別率
	{1-1}	{2-2}	{3-3}	{4-4}	
一	93.22%	94.87%	95.03%	99.09%	94.80%
二	94.35%	92.74%	94.70%	100.00%	94.70%
三	90.11%	95.30%	97.02%	100.00%	94.50%
四	94.63%	93.59%	99.01%	100.00%	96.30%
五	94.35%	88.89%	94.04%	100.00%	93.60%
平均	93.33%	93.08%	95.96%	99.82%	94.78%

2.4 多元適應性雲形迴歸模式實證結果

多元適應性雲形迴歸模式建構係依據變異數分析(ANOVA)及 LOF-GCV 值之評估準則搜尋重要且有效的變數，以篩選出顯著的基本方程式。並且根據包含在其中的變數重要性，以決定較具貢獻的輸入變數。在集合一的資料中，共篩選出「近 6 個月平均總消費餘額與繳款金額比」、「距上次繳款日的天數」、「近 6 個月平均額度使用率」、「當月額度使用率」、「近 6 個月逾期 30 天以上之次數」等 5 項重要變數，其相對重要性詳列於表 13，其中又以「距上次繳款日的天數」之相對重要性達 100%為最高。

MARS 模式除可篩選重要變數外，若將模式中數段基本方程式累加運算後，更有助於捕

捉變數資料特性，並從中瞭解實務上之管理意涵。以集合一為例，MARS 共建構出 15 條基本方程式，以向後逐步消去法(backward stepwise elimination)篩選出 11 條具顯著性之基本方程式，並據以發展出 MARS 最適模式方程式(請參見表 14)，其可作為信用卡客戶行為評分之評估依據。舉例而言，當顧客出現「近 6 個月平均總消費餘額與繳款金額比」超過 8%、「距上次繳款日的天數超過 80 天」、「當月額度使用率」低於 29%、「近 6 個月逾期 30 天以上之次數」低於 1 次、「近 6 個月平均額度使用率」低於 6%等特性時，MARS 最適模式方程式運算後之 Y 預測值較小，即表示該顧客較偏向正常繳款顧客；反之，當顧客出現「距上次繳款日的天數」介於 27 至 80 天、「當月額度使用率」超過 29%、「近 6 個月逾期 30 天以上之次數」超過 1 次、「近 6 個月平均總消費餘額與繳款金額比」超過 101%等特性時，運算所得之 Y 預測值較大，即表示該顧客較偏向帳款逾期顧客。

表 13 MARS 模式之重要變數及相對重要性

變數代碼	變數名稱	重要性 (%)	-GCV 值
X23	距上次繳款日的天數	100.000	0.428
X20	近 6 個月平均總消費餘額與繳款金額比	43.550	0.214
X41	近 6 個月逾期 30 天以上之次數	35.189	0.197
X26	近 6 個月平均額度使用率	11.410	0.168
X32	當月額度使用率	10.395	0.167

MARS 模式於集合一之鑑別結果列於表 15，而 5-fold 交叉驗證結果則彙總於表 16，其整體鑑別率介於 84.80%至 89.80%之間，分別為 86.10%、89.80%、84.80%、88.00%、85.10%，而平均整體鑑別率則為 86.76%。

表 14 MARS 模式基本方程式及最適模式方程式

基本方程式：

$$\begin{aligned}
 BF1 &= \max (0, \text{近 6 個月平均總消費餘額與繳款金額比} - 8.000) \\
 BF3 &= \max (0, \text{距上次繳款日的天數} - 80.000) \\
 BF4 &= \max (0, 80.000 - \text{距上次繳款日的天數}) \\
 BF5 &= \max (0, \text{距上次繳款日的天數} - 27.000) \\
 BF7 &= \max (0, \text{當月額度使用率} - 29.000) \\
 BF8 &= \max (0, 29.000 - \text{當月額度使用率}) \\
 BF9 &= \max (0, \text{近 6 個月逾期 30 天以上之次數} - 1.000) \\
 BF10 &= \max (0, 1.000 - \text{近 6 個月逾期 30 天以上之次數}) \\
 BF11 &= \max (0, \text{近 6 個月平均總消費餘額與繳款金額比} - 101.000) \\
 BF13 &= \max (0, \text{距上次繳款日的天數} - 251.000) \\
 BF15 &= \max (0, \text{近 6 個月平均額度使用率} + 6.000)
 \end{aligned}$$

MARS 最適模式方程式：

$$\begin{aligned}
 Y &= 0.156 - 0.010 \times BF1 - 0.089 \times BF3 + 0.044 \times BF4 + 0.084 \times BF5 \\
 &+ 0.006 \times BF7 - 0.007 \times BF8 + 0.087 \times BF9 - 0.522 \times BF10 \\
 &+ 0.010 \times BF11 + 0.005 \times BF13 - 0.007 \times BF15
 \end{aligned}$$

表 15 MARS 模式之鑑別結果

Predict Target	Predict					總和	鑑別率
	1	2	3	4			
1	325	29	0	0	354	91.81%	
2	24	193	17	0	234	80.34%	
3	0	51	249	2	302	84.11%	
4	0	4	12	94	110	85.45%	
整體鑑別率	86.10%						

表 16 MARS 模式交叉驗證鑑別結果

集 合 別	交叉驗證鑑別結果				
	{1-1}	{2-2}	{3-3}	{4-4}	整體 鑑別率
一	91.81%	80.34%	84.11%	85.45%	86.10%
二	93.22%	85.04%	89.74%	89.09%	89.80%
三	90.11%	76.50%	86.75%	80.00%	84.80%
四	93.22%	82.05%	89.40%	80.00%	88.00%
五	95.20%	72.22%	85.43%	79.09%	85.10%
平均	92.71%	79.23%	87.09%	82.73%	86.76%

4.3 綜合比較

4.3.1 平均整體鑑別率

為比較模式之分類績效差異，將 4 個模式 5-fold 交叉驗證之鑑別結果整理於表 17。由表 17 可知，分類迴歸樹模式之平均整體鑑別率達 94.78% 為最高，顯示分類迴歸樹模式之鑑別能

力明顯優於其他 3 項分類工具。此外，鑑別分析模式之鑑別率則明顯偏低，因此推論本實證資料庫可能較不適用傳統之統計分析工具。

4.3.2 重要變數篩選能力

本研究所使用的 4 項分類工具中，除了 BPN 較不易確認輸入變數之相對重要性外，其

餘 3 項工具皆具有重要變數之篩選能力。由於本研究採用 5-fold 交叉驗證方式，故在相同分類工具下，各子集合篩選結果會因建構模式資料不同而有些許差異，為節省論文篇幅，以下僅以集合一之篩選結果進行比較。

由實證結果可看出，DA 模式篩選出的 23 項重要變數最多，CART 模式為 8 項為次之，而 MARS 模式則僅有 5 項。其中「近 6 個月平均總消費餘額與繳款金額比」、「距上次繳款日的天數」與「近 6 個月逾期 30 天以上之次數」為 3 種模式所共同篩選出之重要變數，故此推論此 3 項變數對於信用卡行為評分模式之重要程度較高；而「距上次溢繳日之天數」、「當月最低應繳款」、「近 3 個月平均帳上總金額」、「當月總消費餘額」、「當月額度使用率」與「距上次繳款逾期之月數」等 6 項變數則同時有 2 種模式認其為重要變數，重要性亦不可小覷。

此外，本研究亦發現 DA 模式雖篩選出較多重要變數，然其模式鑑別能力仍遠低於 CART 模式及 MARS 模式，因此推論其挑出某些重要變數之代表性較為不足；反之，CART 模式及 MARS 模式雖分別篩選出 8 項及 5 項重要變數，然而其於集合一之整體鑑別率均超過 85%，CART 模式甚至高達 94.6%，顯示出 CART 模式之變數篩選能力較佳，而其鑑別效率亦較高。

4.3.3 時間成本

本研究採用之實證資料僅 5,000 筆，相較於邇來發卡業務量及資料處理量同時暴增的金融機構而言，僅為九牛之一毛，而對於營運步調相當快速的金融機構而言，分秒必爭為其競爭激烈之最佳寫照，故模式建構所耗費之時間成本亦為選擇最適模式之重要考量。由表 17 彙整之模式建構時間可看出，DA、CART 與 MARS 模式所需之模式建構時間較短，而 BPN 單一參數組合所需之平均模式訓練時間明顯

較長，因此在考量時間成本的情形下，BPN 模式之適用性較低。

表 17 模式平均整體鑑別率及平均建構時間

	DA	BPN	CART	MARS
平均建構時間	4 秒	33 分 28 秒	16 秒	5 秒
平均整體鑑別率	81.22%	87.84%	94.78%	86.76%

綜上所述，本研究所建構之 CART 模式，除建構時間較 DA 與 MARS 模式稍長之外，在平均整體鑑別率及模式篩選能力等重要衡量構面之表現皆為最佳，其平均整體鑑別率更遠遠高過其他模式。

5. 結論與建議

邇來國內外陸續爆發雙卡及次級房貸風暴，嚴重衝擊民生經濟及金融表現，歸咎其因，多為金融機構發卡浮濫或貸放條件過寬，且未能善盡後續監督之責。目前信用風險評分機制多半僅止於事前防範功能的申請評分制度，對於顧客在核卡或貸放後之行為評分則較為缺乏。若金融機構能於顧客行為出現異常之際，及時做出預應性防範措施，必能強化信用風險控管能力，並大幅降低呆帳損失風險，故建構行為評分制度之重要性與急迫性不言可喻。此外，過去多數研究僅將分類結果簡化為好壞顧客兩類，與實務上需確切掌握顧客多元類型之實際需求並不相符。準此，本研究分別採用 DA、BPN、CART 及 MARS 等資料探勘技術，將顧客區隔為正常還款、循環繳息、無消費紀錄與帳款逾期等 4 類，並採取 5-fold 交叉驗證方式建構模式，希冀獲得最佳之行為評分模式。

實證結果發現，CART 之平均整體鑑別率達 94.78%，遠高於其他工具所得之鑑別率；在

時間成本部分，以 BPN 所需之模式建構時間最長，其餘工具則介於 4~16 秒之間；在重要變數篩選能力方面，CART 共篩選出 8 項重要變數，雖略多於挑出 5 項變數之 MARS，但因 CART 之鑑別率遠高於 MARS，故而推論 CART 之重要變數篩選能力較佳。整體而言，CART 除模式建構時間略長外，其餘表現皆優於其他工具，因此可列為挑選行為評分模式建構工具時之優先考量。此外，「近 6 個月平均總消費餘額與繳款金額比」、「距上次繳款日的天數」與「近 6 個月逾期 30 天以上之次數」為 3 種模式所共同篩選的重要變數，足見此三項變數對於建構信用卡行為評分模式影響之鉅，應當列為信用管理實務上優先觀察之重點。

本研究屬實證研究性質，僅以國內某金融機構之信用卡用戶為研究對象，從母體資料中進行隨機抽樣，所得之結論不一定能直接套用於其他金融機構或產業。此外，受限於個案銀行原始用戶資料庫之欄位建置，未能取得其他細部資料，例如：消費地點、單筆消費金額、消費明細……。未來研究可嘗試收集其他重要變數，或是延長樣本之觀察期間，或可改善鑑別績效。此外，任何工具皆有其優缺點，未來研究者可採用如支援向量機(support vector machine, SVM)等其他分類工具，而工具間之整合，亦可於未來研究之中進行探討。

誌謝

本研究部分承行政院國科會(計劃編號：NSC 97-2221-E-030-011-MY2)經費贊助，特此誌謝。

參考文獻

[1] 李天行、唐筱菁，“整合傳統財務指標與智慧資本以建構企業危機預警系統—類神經網路與 MARS 之應用”，*資訊管理學報*，

第 11 卷第 2 期，pp. 161-190，2004。

- [2] 李天行、陳能靜、蔡榮裕，“現貨盤後期貨交易資訊內涵之研究—以新加坡交易所日經 225 指數期貨為例”，*管理學報*，第 18 期，pp. 567-588，2001。
- [3] 馬芳資，“信用卡信用風險預警範例學習系統之研究”，未出版碩士論文，國立政治大學資訊管理研究所，1994。
- [4] 張振志，“資料探勘行為評分類模式之建構—以某銀行信用卡為例”，未出版碩士論文，天主教輔仁大學管理學研究所，2007。
- [5] 陳怡妃，“新興分類技術於行為評等模式之建構”，未出版博士論文，天主教輔仁大學商學研究所，2008。
- [6] 陳敬聰，“信用卡信用風險評估之研究”，未出版碩士論文，國立雲林科技大學資訊管理技術研究所，1997。
- [7] 曾淑峰、江俊豪，“銀行信用風險管理與資訊系統—以雙卡問題為例”，*台灣金融財務季刊*，第 7 輯第 4 期，pp. 1-26，2006。
- [8] 詹育晟，“個人信用行為評分模式之研究—以現金卡用戶為例”，未出版碩士論文，國立政治大學資訊管理研究所，2005。
- [9] 盧俊傑，“以倒傳遞網路偵測不良信用卡客戶之研究”，未出版碩士論文，大同大學資訊工程學系暨研究所，2006。
- [10] Anderson, J. A. and Rosenfeld, E., *Neurocomputing: Foundations of Research*, MIT Press, 1988.
- [11] Banasiak, M. and O'Hare, E., "Behavior Scoring," *Business Credit*, Vol. 103, No. 3, pp. 52-55, 2001.
- [12] Berry, M. J. A. and Linoff, G., *Data Mining Technique for Marketing, Sale, and Customer Support*, Wiley Computer, 1997.
- [13] Breiman, L., Friedman, J.H., Olshen, R.A. and Stone, C.J., *Classification and Regression Trees*, Wadsworth, 1984.
- [14] CART 6.0 ProEX— for Windows2000 /2003 /XP, *Salford Systems*, San Diego, CA, 2008.
- [15] Connors, M. and Bona, S., "Scoring the Customer Lifecycle," *Business Credit*, Vol. 105, No. 2, pp. 32-33, 2003.
- [16] Craven, P. and Wahba, G., "Smoothing Noisy Data with Spline Functions. Estimating the Correct Degree of Smoothing by the Method of Generalized Cross-Validation,"

- Numberische Mathematik*, Vol. 31, pp. 317–403, 1979.
- [17] Donato, J. M., Schryver, J. C., Hinkel, G. C., Schmoyer Jr., R. L., Grady, N. W. and Leuze, M. R., “Mining Multi-Dimensional Data for Decision Support,” *Future Generation Computer Systems*, Vol. 15, pp. 433–441, 1999.
- [18] Fayyad, U. and Stolorz, P., “Data Mining and KDD: Promise and Challenges,” *Future Generation Computer Systems*, Vol. 13, pp. 99–115, 1997.
- [19] Fish, K. E., Barnes, J. H. and Aiken, M. W., “Artificial Neural Networks: A New Methodology for Industrial Market Segmentation,” *Industrial Marketing Management*, Vol. 24, pp. 431–438, 1995.
- [20] Friedman, J. H., “Multivariate Adaptive Regression Splines (with Discussion),” *Annals of Statistics*, Vol. 19, pp. 1–141, 1991.
- [21] Fritz, S., and Hosemann, D., “Restructuring the Credit Process: Behaviour Scoring for German Corporates,” *International Journal of Intelligent Systems in Accounting, Finance and Management*, Vol. 9, pp. 9–21, 2000.
- [22] Hann, T. H. and Steurer, E., “Much Ado about Nothing? Exchange Rate Forecasting: Neural Networks vs. Linear Models Using Weekly and Monthly Data,” *Neurocomputing*, Vol. 10, pp. 323–339, 1996.
- [23] Hecht-Nielsen, R., *Neurocomputing*, Addison-Wesley, 1990.
- [24] Hsieh, N. C., “An Integrated Data Mining and Behavioral Scoring Model for Analyzing Bank Customers,” *Expert Systems with Applications*, Vol. 27, No. 4, pp. 623–633, 2004.
- [25] Hsieh, N. C., “Hybrid Mining Approach in the Design of Credit Scoring Models,” *Expert Systems with Applications*, Vol. 28, No. 4, pp. 655–665, 2005.
- [26] Huang, Z., Chen, H., Hsu, C. J., Chen, W. H. and Wu, S., “Credit Rating Analysis with Support Vector Machines and Neural Network: A Market Comparative Study,” *Decision Support Systems*, Vol. 37, pp. 543–558, 2004.
- [27] Lee, H., Jo, H. and Han, I., “Bankruptcy Prediction Using Case-Based Reasoning, Neural Networks, and Discriminant Analysis,” *Expert Systems With Applications*, Vol. 13, No. 2, pp. 97–108, 1997.
- [28] Lee, T. S. and Chiu, C. C., “Neural Network Forecasting of an Opening Cash Price Index,” *International Journal of Systems Science*, Vol. 33, pp. 229–237, 2002.
- [29] Lee, T. S. and Chen, I. F., “A Two-Stage Hybrid Credit Scoring Model using Artificial Neural networks and Multivariate Adaptive Regression Splines,” *Expert Systems with Applications*, Vol. 28, No. 4, pp. 743–752, 2005.
- [30] Lee, T. S., Chiu, C. C., Lu, C. J. and Chen, I. F., “Credit Scoring Using the Hybrid Neural Discriminant Technique,” *Expert Systems with Applications*, Vol. 23, No. 3, pp. 245–254, 2002.
- [31] Lin, Y., “Improvement on Behavior Scores by Dual-Model Scoring System,” *International Journal of Information Technology & Decision Making*, Vol. 1, pp. 153–164, 2002.
- [32] Lippmann, R. P., “A Introduction to Computing with Neural Nets”, *IEEE ASSP Magazine*, pp. 4–22, 1987.
- [33] Lucas, A., “Statistical Challenges in Credit Card Issuing,” *Applied Stochastic Models in Business and Industry*, Vol. 17, pp. 83–92, 2001.
- [34] MARS V2.0 —for Windows95/98/NT, Salford Systems, San Diego, CA, 2001.
- [35] Nelson, M. M. and Illingworth, W.T., *A Practical Guide to Neural Nets*, Addison-Wesley, 1990.
- [36] Noh, H. J., Roh, T. H. and Han, I., “Prognostic Personal Credit Risk Model Considering Censored Information”, *Expert Systems with Applications*, Vol. 28, No. 4, pp. 753–762, 2005.
- [37] Qnet 97 – Neural Network Modeling for Windows95/98/NT, *Vesta Services*, Winnetka, IL, 1998.
- [38] Rumelhart, D. E., Hinton, D. E. and Williams, R. J., *Learning Internal Representations by Error Propagation in Parallel Distributed Processing*, MIT Press, Vol. 1, Cambridge, MA, pp. 318–362, 1986.
- [39] SPSS for Windows 12.0 —Statistic Modeling for Windows 95/98/NT, *SPSS inc.*, Chicago, 2003.
- [40] Steinberg, D, Bernard, B., Phillip, C. and Kerry, M., MARS User Guide, *Salford Systems*, San Diego, CA, 1999.
- [41] Stern, H. S., “Neural Networks in Applied

- Statistics,” *Technometrics*, Vol. 38, pp. 205–216, 1996.
- [42] Thomas, L. C., “A Survey of Credit and Behavioural Scoring: Forecasting Financial Risk of Lending to Consumers,” *International Journal of Forecasting*, Vol. 16, pp. 149–172, 2000.
- [43] Vellido, A., Lisboa, P. J. G. and Vaughan, J., “Neural Networks in Business: A Survey of Applications (1992-1998),” *Expert Systems with Applications*, Vol. 17, No. 1, pp. 51–70, 1999.
- [44] Wong, B. K., Bodnovich, A. T. and Selvi, Y., “Neural Network Applications in Business: A Review and Analysis of the Literature (1988-1995),” *Decision Support Systems*, Vol. 19, No. 4, pp. 301–320, 1997.
- [45] Wong, F. S., “Time Series Forecasting Using Backpropagation Neural Networks,” *Neurocomputing*, Vol. 2, pp. 147-159, 1991.
- [46] Zhang, G., Patuwo, B.E. and Hu, M.Y., “Forecasting with Artificial Neural Networks: The State of the Art,” *International Journal of Forecasting*, Vol. 14, pp. 35–62, 1998.