

東海大學
應用數學系
碩士學位論文

藉由機器學習探究失智症分群的非平衡數據問題

**Classification of Imbalanced Dementia
Historical Data via Machine Learning
Technique**

指導教授：黃皇男 教授
研究生：杜歆楷

中華民國 108 年 7 月

東海大學

應用數學系

碩士學位口試委員審定書

本系碩士班 杜歆楷 君

所提論文 Classification of Imbalanced Dementia Historical Data
via Machine Learning Technique
(藉由機器學習探究失智症分群的非平衡數據問題)

合於碩士班資格水準，業經本委員會評審通過，特此證明。

口試委員：

邱子龍

陳淑芬

魏誠佑

陳宏銘

指導教授：

黃呈男

系主任：

胡馨云

中華民國 一〇八 年 七 月 二 日

誌謝

在研究所三年的時間，雖然經歷許多挫折和困境，曾經對自己所選擇的道路有所迷惑，感謝黃皇男老師這幾年的教誨和引導，在大學和碩士時期的裝備，讓我的知識和經驗都有很大的成長，即使研究過程中有許多失誤，但老師耐心的聆聽和協助，讓我感受到認真、嚴謹的研究態度，對我的學習之路來說影響深刻。謝謝邱百誼醫師的提醒和照顧，讓我在碩士的學業道路上有更廣闊的視野和見地，也感謝其他口試委員們的用心，魏誠佑醫師、陳淑珍老師和陳宏銘老師在論文口試上給予的寶貴建議，使論文得以順利完成。

謝謝東海大學應用數學系的所有老師，加上大學時期共七年的時間，每一位老師細心的指導和建議，再多的話也說不盡我內心的感謝。也要感謝在研究所的同學和住宿村的學弟，無論是在論文上的建議或是在生活當中的精神激勵，都是我撰寫論文很重要的動力，也祝福你們未來課業順利、平安喜樂。

最後，謝謝一直支持著我的每一位家人，和我摯愛的女友廖晶悅忻，謝謝你們無時無刻的照顧和經濟上的支持，讓我能專心且順利完成研究，也謝謝上帝讓我經歷了一場非凡的碩士之旅，願將此與家人共享成果的喜悅！

東海大學應用數學所 杜歆楷

摘要

以現在台灣的高年齡層比例逐年增加的現象來說，面臨著失智症族群人數不斷提升的環境，失智症的提早診斷和保健治療成了重要議題；嚴重失智症尚須要昂貴醫療儀器的輔助才能精確診斷，為了兼顧提早診斷與節省醫療資源，臨床失智症量表(CDR)的運用則是最佳的選擇。在探討臨床失智症量表與醫師診斷失智症嚴重程度的相關性時，不同程度之間的類別數量應影響整體準確率的呈現，以致少數量類別會影響到問卷本身的準確度。

本論文的目的是透過不同機器學習的方式，包含單純貝氏分類法、多層感知器、以決策樹為分類器的引導聚集算法、支持向量機等演算法，來建立臨床失智症量表數據和醫師診斷的篩選模型。臨床量表數據依據失智症的嚴重程度分成六類、五類和三類等三種，研究結果顯示以決策樹為分類器的引導聚集算法為最佳。由於三類數據分布明顯為非平衡，因此透過 SMOTE 方法對少量數據進行調整，分析結果顯示對準確度與靈敏度的提升相當有限。最後利用主成分分析的技術，進行臨床量表題目的幾種化簡，並經由信度分析，選擇臨床量表的重要題目，研究結果顯示語言有關題目扮演重要角色。

關鍵詞：臨床失智症量表、機器學習、非平衡數據

Abstract

With the high accelerated rate of aging in Taiwan, the amount of people with dementia is rapidly increasing. Early diagnosis and health care of dementia have become an important issue. Severe dementia still requires expensive medical apparatus to assist the accurate diagnosis. In order to balance early diagnosis and expanded medical resources, the Clinical Dementia Rating (CDR) scale may be a good choice. When study the correlation between the CDR score and the physician's diagnosis of the stages (severity) of dementia, the population sizes between different stages should play an important role, especially the population size of minority stages will affect the accuracy of the study.

The purpose of this thesis is to establish CDR score data and screening models for physician diagnosis through different machine learning methods, including classifiers such as Naïve Bayes, Multilayer perceptron, Bootstrap aggregating with decision tree, and support vector machine. The CDR score data are divided into six, five and three stages according to the severity of dementia. Bootstrap aggregating with decision tree classifier is the best among the others. Also, the population sizes for three stages case are obviously imbalanced, SMOTE method is used to adjust a small amount for the normal stage and the study result shows the improvement is rather limited. Finally, principal component analysis (PCA) is carried out to simplify CDR questionnaires, and certain questions are selected and verified through the reliability analysis. Our study shows that newly added language-assessment questionnaire plays an important role in our analysis.

Keywords: CDR, machine learning, imbalanced data, PCA

目 錄

誌謝.....	i
摘要.....	ii
Abstract.....	iii
目錄.....	iv
表目錄.....	vi
圖目錄.....	vii
第一章 緒論.....	1
1.1 研究背景與動機.....	1
1.2 文獻回顧.....	2
1.3 論文架構.....	3
第二章名詞解釋與知識.....	4
2.1 失智症.....	4
2.2 輕度認知障礙.....	5
2.3 臨床失智症量表.....	6
2.4 機器學習.....	6
2.4.1 監督式學習.....	7
2.4.2 決策樹.....	7
2.4.3 引導聚集算法.....	9
2.4.4 單純貝氏演算法.....	10
2.4.5 多層感知器.....	11
2.4.6 支持向量機.....	11
2.5 混淆矩陣.....	14
2.6 非平衡數據.....	14
2.7 主成分分析法.....	15
2.8 信度分析.....	17
2.9 實驗環境.....	18
第三章 分析過程.....	19

3.1 資料處理流程	19
3.2 Data A 屬性	21
3.3 Data B 屬性	23
3.4 決定訓練資料的比例大小	25
3.5 不同演算法法的學習比較	26
3.5.1 資料第一次調整	29
3.5.2 資料第二次調整	31
3.6 總比較結果	33
第四章 數據平衡化與主成分分析	36
4.1 六類之分析	38
4.1.1 五類之分析	39
4.1.2 三類之分析	40
4.2 主成分分析	41
4.3 挑選題目比較	49
4.4 信度分析	52
第五章 結論	55
5.1 討論與結論	55
5.2 未來展望	57
參考文獻	59
附 錄	61
1. 此論文研究的臨床失智症量表 (CDR)	61

表目錄

表 2-1	混淆矩陣.....	14
表 3-1	Data A 資料屬性	21
表 3-2	NMD6 對應人數表	22
表 3-3	NMD5 對應人數表	22
表 3-4	NMD3 演算法比較	22
表 3-5	Data B 資料屬性	23
表 3-6	NMD6 對應人數表	24
表 3-7	NMD5 對應人數表	24
表 3-8	NMD3 對應人數表	24
表 4-1	Data B 六類平衡前後人數比較表.....	38
表 4-2	六類 ACC、TPR 前後比較表	38
表 4-3	Data B 五類平衡前後人數比較表.....	39
表 4-4	五類 ACC、TPR 前後比較表	39
表 4-5	Data B 三類平衡前後人數比較表.....	40
表 4-6	三類 ACC、TPR 前後比較表	40
表 4-7	六類特徵值之累積比例表.....	45
表 4-8	六類特徵向量各問題之對應最大絕對值題目表.....	47
表 4-9	六類篩選問題個數結果.....	48
表 4-10	六類比較結果.....	49
表 4-11	五類比較結果.....	50
表 4-12	三類比較結果.....	50
表 4-13	篩選題目順序結果表.....	51
表 4-14	22 題目信度分析表.....	52
表 4-15	17 題目信度分析表.....	53
表 4-16	10 題目信度分析表.....	54

圖目錄

圖 2-1	決策樹流程圖	8
圖 2-2	Bagging 流程圖	10
圖 2-3	MLP 流程圖	201
圖 2-4	SVM 說明圖	202
圖 2-5	Weka 軟體首頁	18
圖 3-1	資料處理流程圖	20
圖 3-2	Data A 不同比例學習之圖表	25
圖 3-3	六類 NB 分析之結果	27
圖 3-4	六類 MLP 分析之結果	27
圖 3-5	六類 C4.5(Bagging)分析之結果	28
圖 3-6	六類 SVM 分析之結果	28
圖 3-7	五類 NB 分析之結果	29
圖 3-8	五類 MLP 分析之結果	30
圖 3-9	五類 C4.5(Bagging)分析之結果	30
圖 3-10	五類 SVM 分析之結果	30
圖 3-11	三類 NB 分析之結果	31
圖 3-12	三類 MLP 分析之結果	32
圖 3-13	三類 C4.5(Bagging)分析之結果	32
圖 3-14	三類 SVM 分析之結果	32
圖 3-15	Data A 之 ACC 結果	33
圖 3-16	Data A 之 TPR 結果	33
圖 3-17	Data B 之 ACC 結果	34
圖 3-18	Data B 之 TPR 結果	34
圖 4-1	資料平衡化流程圖	37
圖 4-2	相關係數矩陣	42
圖 4-3	特徵向量列表果	43
圖 4-4	特徵向量 V1,V2 對應數據圖	44
圖 4-5	各題目所占比例和累積比例圖	46

第一章 緒論

1.1 研究背景與動機

近年來台灣人口年齡老化快速，導致相關失智症人口也隨之增加，經衛生福利部的調查結果統計[1]，和內政部 107 年 12 月底的總人口統計資料[2]合併估算之後，65 歲以上老人共 343 萬多人(占全部的 14.56%)，其中輕微認知障礙(mild cognitive impairment, 簡稱 MCI)有 62 萬多人(占 18.23%)；失智症總共快 27 萬人(占 7.86%，其中極輕度失智症逾 11 萬人)。也就是 65 歲以上的老人大約每 12 人即有 1 位失智者，而 80 歲以上的族群每 5 人就有 1 個確認為失智者。從台灣失智症協會於 107 年 8 月 30 日公告的「中華民國人口推計」(2018 年到 2065 年)，再加上不同年齡層失智症盛行率的評估，從民國 120 年失智人口的逾 46 萬人到民國 154 年的逾 89 萬人，將來會是以不到 1 小時的速率增加 1 名確定為失智症的速度成長，此推估數據對於高齡化社會的台灣來說，是急迫需要重視且關心的議題，失智症相關的保健治療和準確評估也成了醫療專業中不可忽視的一環。

從短時間軸來看，盡早發現並治療失智症確實有一定的改善和幫助，以現在台灣評估失智症的方法使用問卷的形式為大宗，但不同題目問卷對於族群的準確度結果是否值得信賴也成了必要面對的問題，特別是人們填問卷評估後不同嚴重程度的族群數量。對問卷本身來說，正常族群(無病)和失

智症族群(有病)填寫的比例非常懸殊，此情形會產生少數影響準確度，導致問卷判定類別時無法最優化來呈現結果。

本論文特別針對非平衡數據的問題來分析不同病症程度的族群和狀態，並使用不同方法的機器學習來了解問卷對各類族群的適用性，不只是為了減少時間成本，更是希望問卷透過機器學習的機制之後能更有效率的準確篩檢病患之目的。

1.2 文獻回顧

利用機器學習來做不同領域的研究很多種類，應用在失智症和醫療相關的部分國內的文獻研究有雲林科技大學的李孟昭 [3] 利用磁共振造影和擴散張量影像中萃取出腦部的特徵指標，運用 CART 決策樹分析、逢甲大學的廖育民[4]利用貝式分類分析失智症不同類別的初期診斷、國立臺北科技大學的 Ningthoujam Avichandra Singh[5]使用模糊神經網絡和變異數分析(ANOVA)將失智症的醫療數據進行評估並清楚分成不同的類別，東海大學的張盛彥[6]，利用決策量表來進行分類學習並從主成分分析中簡化量化問卷的研究。

1.3 論文架構

此論文的架構分成五個章節如下：

第一章 緒論

說明以不同機器學習方法來分析失智症族群的研究環境、研究目的和研究方法。

第二章 名詞解釋與知識

介紹會使用到的相關理論方法和名詞，包含失智症相關專有名詞解釋、機器學習的介紹和運用在此論文的方法。

第三章 分析過程

利用兩個資料集 Data A 與 Data B 來進行預處理和分析，並使用不同的機器學習方法，最後以混亂矩陣分析結果，除此之外透過處理不平衡數據的資料方法，來前後比較整理前後準確差異性。

第四章 平衡化後數據結果

找出最好的機器學習方法後，平衡數據調整內容後分析結果，了解實際運作。

第五章 結論

說明此研究的結論，以及未來展望。

第二章名詞解釋與知識

此章節介紹在此篇論文會使用到的理論方法和名詞，包含專有名詞解釋、機器學習的介紹和運用此論文的方法。從第一小節到第三小節為失智症相關名詞，第四小節到六小節為不同機器學習的演算法相關名詞解釋，第七小節到第九小節為確認問卷可信度相關方法和程式介紹。

2.1 失智症

從美國精神醫學協會 (American Psychiatric Association) 制定精神疾病診斷與統計手冊第五版[7]的定義，失智症是結合多群症狀的多認知功能障礙，主要症狀在複雜注意力、執行功能、學習和記憶、語言能力、知覺動作或社會認知的認知力有明顯降低的影響等等，病症判斷的憑據由資訊提供者、臨床專業人員的了解或經過臨床評估測驗之後顯示認知功能顯著減損，而且在複雜工具性日常生活能力需要協助，認知缺損非只譫妄之情形，無法以另一精神疾病做更好的解釋(例如重鬱症、思覺失調症)。

路易氏體失智症本身符合失智症的準則，此具有兩個核心症狀或一個次要症狀和一個以上的核心特徵，此案例就有可能有路易氏體失智症，以下分別為核心症狀和次要症狀為說明。

核心診斷症狀：

1. 認知波動，注意力和警覺力有明顯的改變。
2. 清楚且具體的視幻覺反覆發生。

3. 認知退化進展後，隨即有帕金森症自發性症狀發生。

次要診斷症狀：

1. 符合快速眼動睡眠障礙標準症狀

2. 嚴重的抗精神藥物敏感性

路易氏體無法以腦血管疾病、另一種神經退化、物質效應、或另一神經、精神或系統性疾病作出更好的解釋。

血管性認知障礙症符合認知障礙症診斷的準則，若發病的時間點跟上次腦血管事件有關係或複雜注意力及前額葉執行功能退化的明顯證據，若出現下列三者之一項，診斷極可能由血管疾病所引起的認知障礙症

1. 診斷時藉由神經影像證實腦血管疾病的神經組織受傷。

2. 認知障礙症候群在時序性確定與至少一次腦血管事件有關。

3. 臨床和基因(腦動脈血管病變合併皮質下梗塞和腦白質病變，兩者的證據顯示腦血管疾病存在)

由診斷準則可知大部分的失智症病患診斷可由詳盡並使即可獲得；剩下的由神經學檢查、基因、影像或是其他檢查來完成。

2.2 輕度認知障礙

在 1999 年 Ronald C. Petersen[8]論文中所提出的輕度認知障礙(Mild cognitive impairment, MCI)定義是由個體、群體或是診斷醫師確認或判定記憶力退化的情形，但一般知能功能和日常生活功能仍然正常。Petersen 將此分為兩種型態：(1)失憶型態(Amnestic MCI, a-MCI)和(2)非失憶型態(non-Amnestic MCI, na-MCI)。失憶型態(aMCI)本身有明顯的記憶障礙但不符合判定

失智症的標準，在一些認知能力例如執行能力、判斷力上相對地完整。

2.3 臨床失智症量表

臨床失智症量表 (Clinical Dementia Rating, CDR) 是一種利用量化的分數表來表示病症程度的量表方法，能透過主觀的訪談數據和臨床判斷來描述並評估病患的整體狀況。此量表包含 7 大項目：記憶力 (memory, M)、定向感 (orientation, O)、判斷與問題解決 (judgment-problem solving, J)、社區事務 (community affairs, C)、家居生活與嗜好 (home hobbies, H)、個人自理能力 (personal care, P) 和語言能力 (language, L)。分數由 0 到 3 分來區別六種不同的程度：0 代表正常 (Normal)，0.5 代表疑似障礙 (Uncertain dementia)，0.7 代表初期障礙 (incipient dementia)，1 代表輕度障礙 (mild dementia)，2 代表中度障礙 (moderate dementia)，3 代表重度障礙 (severe dementia)。此論文的 CDR 版本並非原始版本，由秀傳紀念醫院的邱百誼醫師所提供，此表經過醫師多次改良之後與原本稍微不同，若，改良後的臨床失智症量表 CDR 每項問題詳細如附錄 1 所示。

2.4 機器學習

機器學習 (Machine Learning) 是一門人工智慧的科學，從過往給定的資料和經驗中找出一定的運作原則來建立一

種模型，並拿來做資料的預測分析，此運作可透過輸入資料量的增加而有更準確、精準的預測。此篇論文使用機器學習的過程中將資料集的 60% 作為訓練資料(train set)和資料集的 40% 作為測試資料(test set)。

2.4.1 監督式學習

監督式學習(Supervised Learning) 是機器學習裡的其中一種方法，它從訓練資料中建立函數，函數由輸入資料和輸出為主要組成，在分析完一些標記過的訓練範例後，去預測此函數對可能出現的輸入的輸出。輸出本身可以是一個連續值(迴歸分析)，或是一個預測類別。

2.4.2 決策樹

決策樹(Decision Tree)最早從 1966 年 Hunt 等人提出，由決策和結果組成的樹狀圖，本身包含節點和分支，節點有三種：決策節點、機會節點和終結點。決策節點是指所有決策的開頭起點，機會節點是指決策時所遇到所有可能機會的類別，終結點是最後分類的結果。分支有不同決策後的分類屬性，經過不同的節點分類到不同的分支，可以觀察到每一層的不同分類的細節，其方法在視覺簡化分類上有很大的突破，圖 2-1 為說明圖：

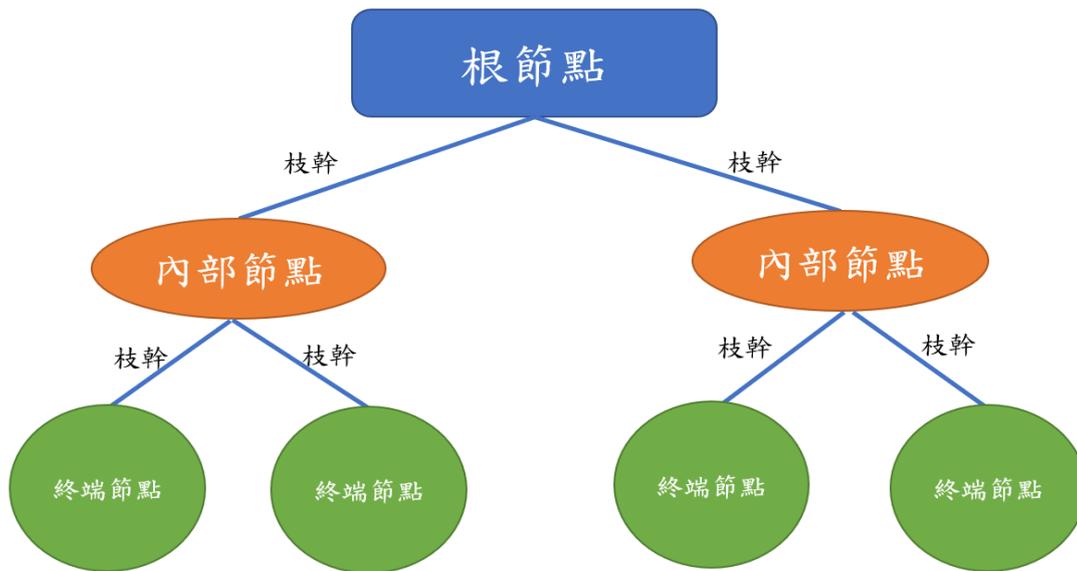


圖 2-1 決策樹說明圖

C4.5 由 J. Ross Quinlan 在 1992 提出[9]的算法，是從決策樹算法中改良後的學習法，此演算法起源來自於 ID3(Iterative Dichotomiser 3)決策樹演算法，以下為會用到的公式。

測試前的數據量計算：

$$\text{info}(T) = - \sum_{i=1}^m \frac{\text{freq}(C_i, T)}{|T|} \log_2 \left(\frac{\text{freq}(C_i, T)}{|T|} \right)$$

其中 T 為一個集合， $|T|$ 為集合的數據數量， i 為類別的數量， C_i 為 T 集合的類別， $\text{freq}(C_i, T)$ 為在 T 集合內類別的數據量。

測試後的數據量計算：

$$\text{info}_x(T) = \sum_{i=1}^p \frac{|T_i|}{|T|} \text{info}(T_i)$$

其中 T_i 為 T 集合從 X 變數測試後的子集合， i 為 1 到 p 的變數， X 屬於 X_1 到 X_p 的集合。

資料獲利 (information gain) 的公式為測試前的資料量減掉測試後的資料量：

$$\text{Gain}(X) = \text{info}(T) - \text{info}_X(T)$$

將資訊獲利除以資訊分裂值 (splitinfo) 得出資訊獲利比 (gain ratio)。

$$\text{gain ratio}(X) = \frac{\text{Gain}(X)}{\text{Splitinfo}(X)}$$

其中

$$\text{Splitinfo}(X) = \sum_{i=1}^m \frac{|T_i|}{|T|} \log\left(\frac{|T_i|}{|T|}\right)$$

在 Weka 內的工具中 C4.5 又稱為 J48，是 Weka 3.9.3 版本目前最新的演算工具其中之一，其中的函數和運算都可以透過人工來調整不同的參數。

2.4.3 引導聚集算法

引導聚集算法 (Bootstrap Aggregating，簡稱 Bagging)，由 Leo Breiman 在 1996 年提出 [10]，此方法是從訓練資料中隨機抽取多個樣本並訓練多個分類模型，將測試資料帶入模型中可得到所有分類模型的權重答案，最後用投票來得到結果，此方法優點在於可以從資料中剔除有瑕疵、不好的資料，降低訓練模型的非穩定性。此篇論文在實驗引導聚集算法的時候利用 Weka 中的 J48 分類器以 60% 的訓練資料中隨機並重複挑出 60% 的比例建立 T

組分類模型，將 40% 的測試資料代入分類模型得到 P 組答案並投票來得到學習的結果，流程圖 2-1 如下：

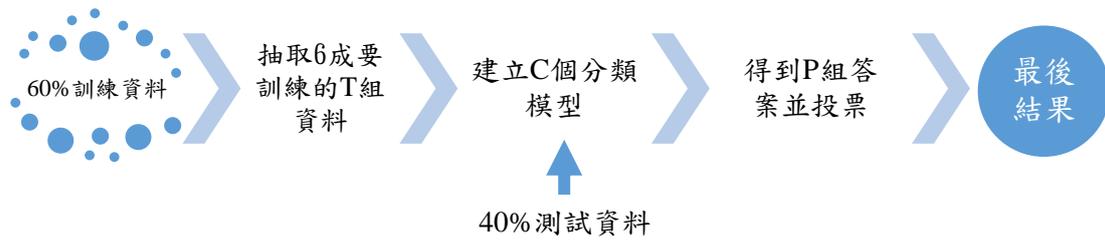


圖 2-2 Bagging 流程圖

2.4.4 單純貝氏演算法

單純貝氏演算法 (naïve Bayes classifier, 簡稱 NB)[11] 以貝氏定理為主要基礎，根據屬性向量將數據歸於最有可能的分類項，令 C 屬於 1 到 k 的一個集合表示資料類別， $X = (X_1, X_2, \dots, X_p)$ 表示屬性向量，原本的貝氏原理公式為：

$$P(C = i | X = x) = \frac{P(X|C) \cdot P(C)}{P(X)}$$

其中 i 為各類別， x 為個別特徵向量。

在訓練樣本時，假設每一分類中的每一個屬性為相互獨立

$$P(X|C) = \prod_{j=1}^p P(X_j = x_j | C = i)$$

其中 p 為屬性向量的數量， j 屬於 1 到 p 的集合。

雖然很難接近現實的情況，但以分類結果來看對準確性的影響不大，可以預測數據類別的最大可能的結果為下列公式：

$$C = \arg \max_c P(C) \prod_i^p P(X_j = x_j | C = i)$$

2.4.5 多層感知器

多層感知器 (Multilayer Perceptron, 簡稱 MLP) 由 1966 年 Rosenblatt Frank 提出 [12], 此法屬於前向傳遞類神經網絡的一種, 其中包括三層結構, 分別為輸入層、隱藏層 (可以多層存在) 和輸出層。此算法可以進行迴歸運算, 在輸入層與輸出層中間可以插入多個非線性層 (隱藏層), 此演算法有加入隨機森林以強化分類器的效果, 圖 2-1 為說明圖:

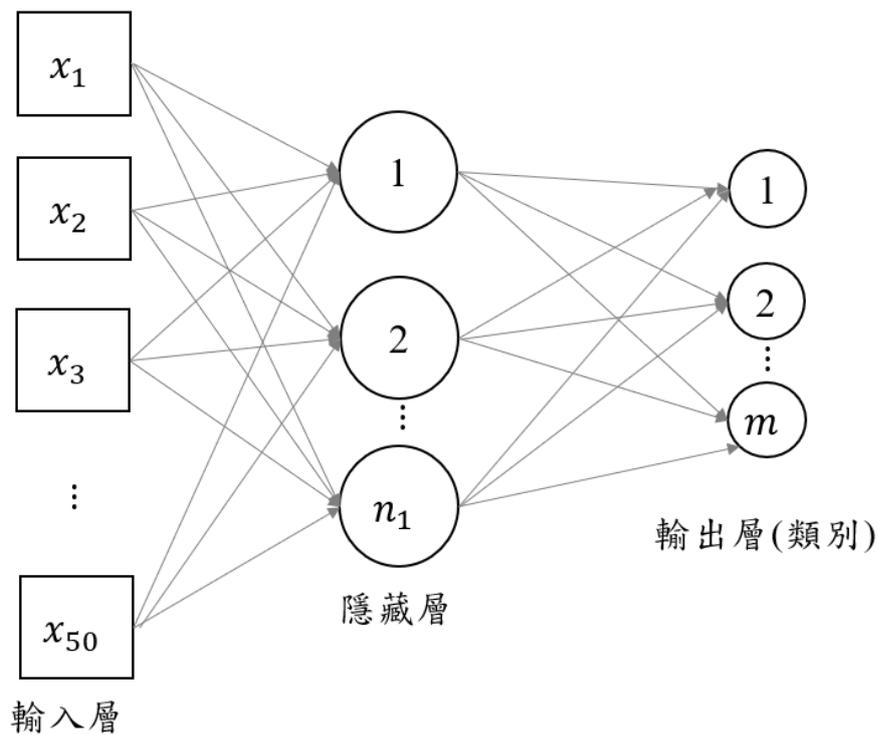


圖 2-3 MLP 流程圖

2.4.6 支持向量機

支持向量機(Support Vector Machine 又稱為 SVM)，1963年由 Vladimir N. Vapnik 和 Alexey Ya. Chervonenkis 發明[13]是監督式學習的一種，此篇論文討論線性(linear)支持向量機的說明和實驗應用。此方法的目的是希望找到一個分類超平面(classification hyperplane)可以把兩個不同類別的數據完美區分出來(兩類之間邊界最大化)，圖 2-4 為 SVM 說明圖：

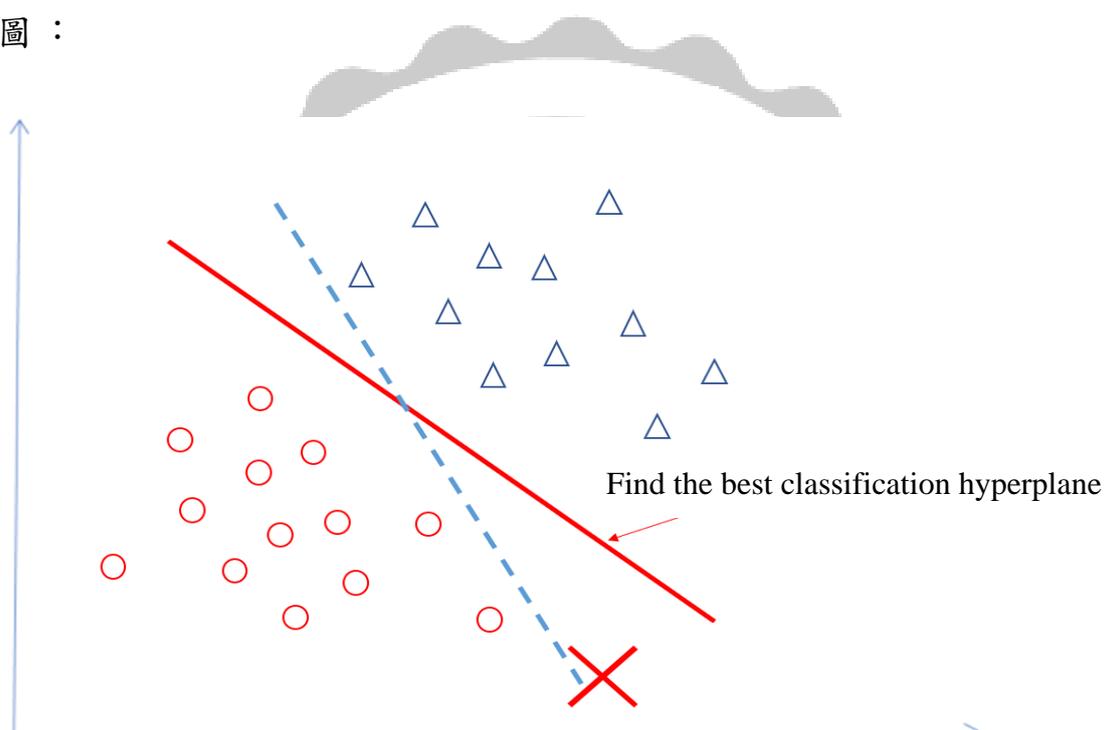


圖 2-4 SVM 說明圖

假設在一個特徵空間上的訓練資料為 $T = \{(x_1, y_1), \dots, (x_n, y_n)\}$ ，分類超平面以虛線表示，此公式定義為

$$w^T x + b = y$$

其中 w 為權重向量， b 為截距常數。

假設將兩個支持超平面(support hyperplane)以虛線表示的公式寫成

$$w^T x + b = 1, \quad w^T x + b = -1$$

若分類超平面與這兩個支持超平面的距離 D 都是 $\frac{1}{\|w\|}$ ，則定義可以寫成

$$y_m \cdot (w^T x_m + b) \geq 1, \quad m = 1, 2, \dots, n$$

因此我們得到一個函數

$$\begin{cases} \max 2D = \max \frac{2}{\|w\|} \\ \text{s.t. } y_m \cdot (w^T x_m + b) \geq 1, m = 1, 2, \dots, n \end{cases}$$

利用拉格朗日乘數法(Lagrange multiplier method)將之變成二次方程式

$$L(w, b, a) = \frac{1}{2} |w|^2 - \sum_{m=1}^n \alpha_m [y_m \cdot (w^T x_m + b) - 1]$$

其中 $\alpha_m, m = 1, 2, \dots, n$ 為 Lagrange 乘數，求此式的最小值，經過代入運算之後可化成下列的最優化解

$$\begin{cases} \min_{\alpha_m \geq 0} \sum_{m=1}^n \alpha_m - \frac{1}{2} \sum_{m=1}^n \sum_{k=1}^n \alpha_m \alpha_k y_m y_k x_m^T x_k \\ \text{subject to } \sum_{m=1}^n \alpha_m y_m = 0 \end{cases}$$

若 support hyperplane 的最佳解不存在，則將定義寫成

$$y_m \cdot (w^T x_m + b) \geq 1 - \xi_m, \quad m = 1, 2, \dots, n$$

2.5 混淆矩陣

混淆矩陣(confusion matrix)常用來評估算法之準確性或分類結果的分析表，可以判斷預測分類是否符合實際分類，其每一行代表預測分類，每一列代表實際分類，請看表 2-1。

表 2-1 混淆矩陣

		預測分類(Predicted)	
		1	0
實際分類 (Actual)	1	True-Positive (TP)	False-Negative (FN)
	0	False-Positive (FP)	True-Negative (TN)

表中各意義，解釋如下：

True-Positive (TP):真陽性，預測值是正例，同時實際值也被判為正例。

False-Negative (FN):假陰性，預測值是負例，但實際值卻被判為正例，可視為漏報情形。

False-Positive (FP):假陽性，預測值是正例，但實際值卻被判為負例，可視為誤報情形。

True-Negative (TN):真陰性，預測值是負例，同時實際值也被判為負例。

透過表 2-1，我們希望能得到最高準確率(Accuracy,ACC)和靈敏度(Sensitivity,TPR)來檢驗其有效性，公式如下：

$$ACC = \frac{TP + TN}{TP + TN + FN + FP}, \quad TPR = \frac{TP}{TP + FN}$$

2.6 非平衡數據

非平衡數據(imbalanced data)在正負樣本數量比例相差很大的時候，導致混亂樣本差距影響準確度的問題，在許多演算法中本身假設內部的類別分布是均衡的，會有機率性地假定不同類別的誤差，以至於發生準確率相對地低，少數類會被忽略的情形。

因此本篇論文想要利用合成少數過取樣法 (Synthetic Minority Over-Sampling Technique, 簡稱 SMOTE)來調整內容數據的數量比例，此法[14]在 2002 年時提出，它是一種對過取樣 (Oversampling)的改良方法，不直接對少數進行取樣，而是設計算法從少數類的樣本中增加一些人工合成的虛擬數據，讓整體的準確率更客觀，步驟如下：

1. 首先選定一個確定的樣本S
2. 找出離樣本S最近的K個樣本，K可以是來自不同類別的樣本資料，此論文設定 5 個樣本
3. 從這 5 個樣本隨機挑出一個樣本設定為R
4. 合成一個新的樣本S'，公式如下

$$S' = \lambda S + (1 - \lambda)R$$

其中 λ 為(0,1)之間的隨機亂數。

2.7 主成分分析法

主成份分析法 (principal components analysis, 簡稱 PCA)[15]是一種利用原始變量之間的相關性來簡化數據類別

的降維方式，主要是從共變異數矩陣的特徵分解，為求出此資料集的主成分和加權，可觀察出各種分類佔據不同的比重呈現的重要性，並以少數的類別來代表整體資料集。

假設數據具有 m 個病例數和 n 個題目，可假設矩陣 X 為：

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix}_{m \times n}$$

其中 $X_n = \begin{bmatrix} x_{1n} \\ x_{2n} \\ \vdots \\ x_{mn} \end{bmatrix}$ 為變數；主成分分析法流程，分為下列步驟：

(1) 數據標準化

$$X_i^* = \frac{(X_i - \bar{X}_i)}{\sigma_{X_i}}, \quad i = 1, 2, \dots, p-1, p$$

其中 X_i^* 為標準化後的數據， $\bar{X}_i = \frac{1}{n} \sum_{j=1}^n x_{ij}$ 為 X_i 的平均數，

$\sigma_{X_i} = \sqrt{\frac{1}{n} \sum_{j=1}^n (x_{ij} - \bar{X}_i)^2}$ 為 X_i 的標準差。

(2) 找出兩變數之間的相關係數矩陣

$$R = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ r_{21} & r_{22} & \cdots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{n1} & r_{n2} & \cdots & r_{nn} \end{bmatrix}$$

$$r_{ij} = \frac{(X_i^*)^T X_j^*}{(n-1)}, \quad i, j = 1, 2, \dots, n$$

其中 r_{ij} 為相關係數。

(3) 計算特徵值(eigenvalue)與特徵向量(eigenvector)

將 R 代入特徵方程，解出 n 個非負特徵值 $\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_n$ ，且 $\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_n \geq 0$ ，並利用每個特徵值算出對應的特徵向量。

$$\det(R - \lambda I) = 0$$

其中 I 為單位矩陣。

(4) 選擇主成分變數個數

分析累積比例得到的結果，如果累積比例在 0.7 以上，代表此整體資料集的效果是良好的。

2.8 信度分析

信度分析(reliability and validity analysis)是許多問卷測量問卷中很重要的探討議題，[16]主要目的是探討問卷的具體目的和這些類別預測的構念之間的關係，信度(reliability)是檢驗測量工具本身的辨識能力如何？信度高時在相似的條件下重複測定會得到一致的結果，此論文以內在一致信度為主要分析法，並以信度係數法為分析點，公式如下：

$$\alpha = \left(\frac{k}{k-1}\right)\left(1 - \frac{\sum_{i=1}^k \sigma_i^2}{\sigma_t^2}\right)$$

其中 k 為量表題目數， σ_i^2 為全體樣本第 i 個題目的變異數， σ_t^2 為全體樣本的總變異數。從以上定義公式之最右項可知，即為「相關係數」之變異數分析定義，以「1」減去變異值，即「內在一致」的信度。

2.9 實驗環境

此論文研究所使用的分析軟體為 Weka，版本是 3.9.3，全名為懷卡托智慧分析環境 (Waikato Environment for Knowledge Analysis)，此系統匯集許多機器學習演算法和數據預處理工具，而且使用上快速操作，可應用不同的資料處理並分析結果。



圖 2-3 Weka 軟體首頁

第三章 分析過程

3.1 資料處理流程

此章節說明所有資料集的屬性，以失智症登陸資料庫為資料來源，資料集分別為 Data A(有重複病例之數據)與 Data B(無重複病例且最新診斷數據)，首先需要對資料集做預處理，把非必要的欄位和資料刪除之後，決定訓練資料和測試資料的比例，並將不同的機器學習演算方法代入數據資料，分析準確度和靈敏度的差異性；目的是在簡化分類的過程當中用不同的機器學習法來做實驗，從得出的準確率和靈敏度進而找出準確率最高的方法，數據分析處理流程如下 3-1 所示。

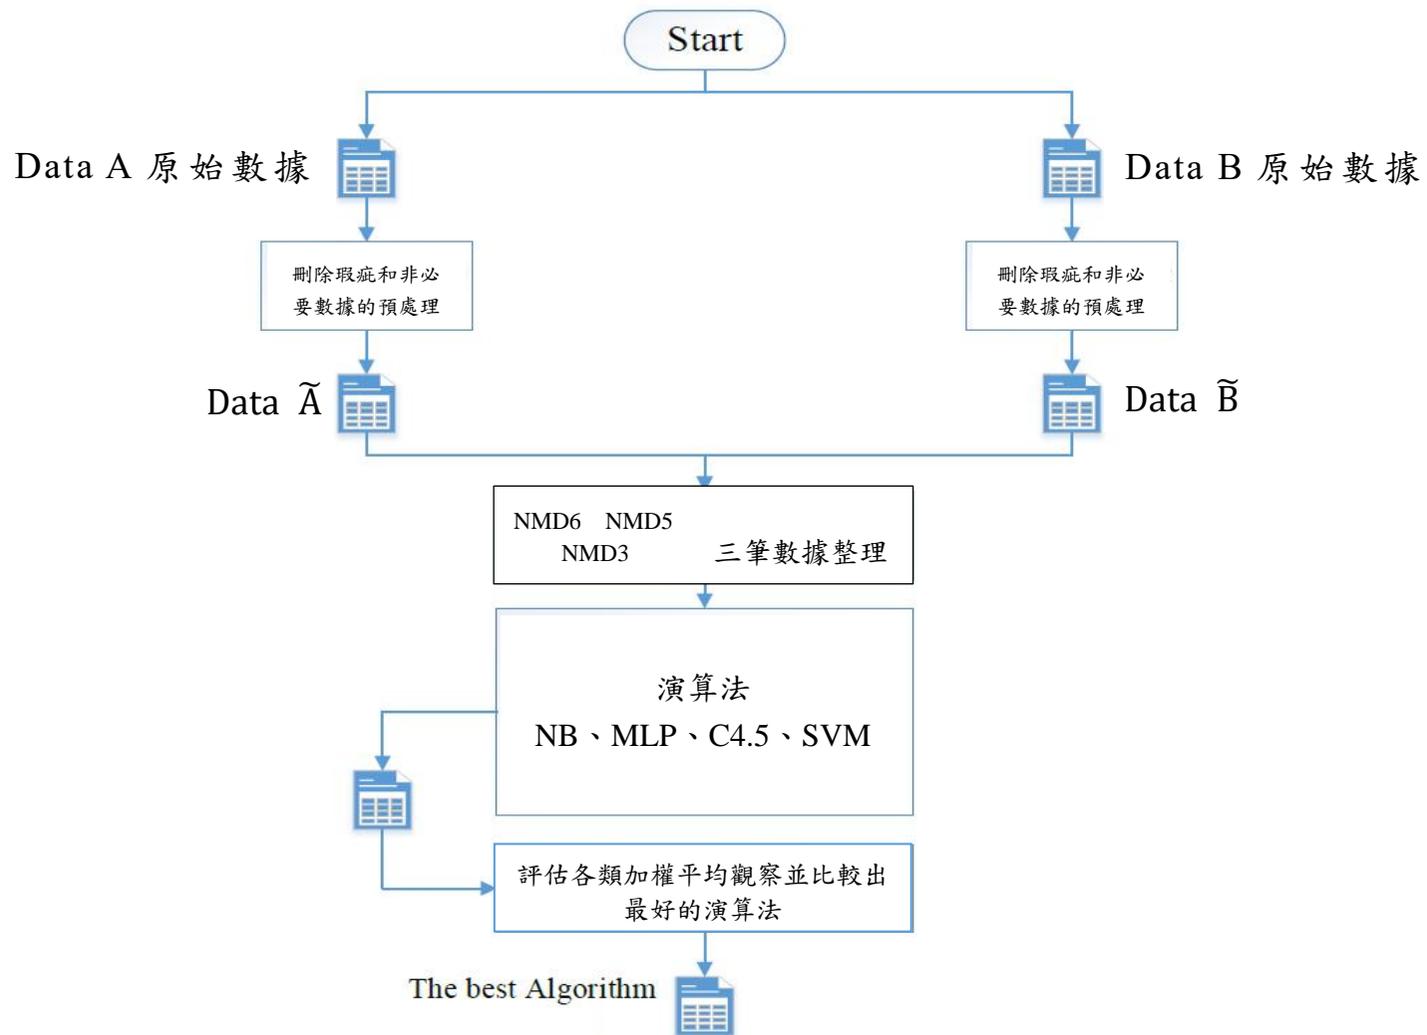


圖 3-1 資料處理流程圖

3.2 Data A 屬性

此資料的時間範圍為 2015/10/1-2018/11/02，人數有 6701 人，有包含重複病例的資料(回診好幾次)，其中有 50 個問題和 4 種算法所算出的結果，結果分別是 NMD6、NMD5 和 NMD3，此處的 NMD 表示 Normal，MCI 與 Dementia 的簡寫；NMD6、NMD5 和 NMD3 的類別分別有六、五和三種，表 3-1 為資料屬性，表 3-2 說明 6 類分類的結果，表 3-4 說明 5 類分類的結果。50 個問題當中，36 個問題的答案為 0、11 個問題的答案為 0、1、2，2 個問題的答案為 0、1、2、3，1 個問題的答案為 0、1、2、3、5，結果如下：

表 3-1 Data A 資料屬性

日期	2015/10/1-2018/11/02	
總人數		6701 人
性別		
	男	2842 人
	女	3859 人
年齡	15 歲-102 歲	
	人 \leq 65 歲	1028 人
	65 歲 < 人 \leq 75 歲	1665 人
	人 \geq 76 歲	3998 人
教育程度	0--19 年	
	小學程度(1-6 年)	3160 人
	中學程度(7-12 年)	2559 人
	高等程度(12-25 年)	961 人

表 3-2 NMD6 對應人數表

狀態	人數
Normal	535
Uncertain dementia	1687
Incipient dementia	678
Mild dementia	1812
Moderate dementia	1309
Severe dementia	680

表 3-3 NMD5 對應人數表

狀態	人數
Normal	535
MCI	1687
Mild dementia	2490
Moderate dementia	1309
Severe dementia	680

表 3-4 NMD5to3 對應人數表

狀態	人數
Normal	535
MCI	1687
Dementia	4479

3.3 Data B 屬性

此資料的時間範圍為 2015/10/1-2018/11/02，跟 Data A 的屬性類似，將重複病例的數據刪除之後尚有 4248 個最後一次看診或最新的病例數據資料，表 3-5 為資料屬性、表 3-6、表 3-7、表 3-8 分別表示 NMD6、NMD5、NMD3 之對應人數。

表 3-5 Data B 資料屬性

日期	2015/10/1-2018/11/02	
總人數		4248 人
性別		
	男	1844 人
	女	2404 人
年齡	15 歲-102 歲	
	人 \leq 65 歲	735 人
	65 歲 < 人 \leq 75 歲	1028 人
	人 \geq 76 歲	2485 人
教育程度	0--19 年	
	小學程度(1-6 年)	1909 人
	中學程度(7-12 年)	1640 人
	高等程度(12-20 年)	699 人

表 3-6 NMD6 對應人數表

狀態	人數
Normal	459
Uncertain dementia	1084
Incipient dementia	409
Mild dementia	982
Moderate dementia	792
Severe dementia	522

表 3-7 NMD5 對應人數表

狀態	人數
Normal	459
MCI	1084
Mild dementia	1391
Moderate dementia	792
Severe dementia	522

表 3-8 NMD3 對應人數表

狀態	人數
Normal	459
MCI	1084
Dementia	2705

3.4 決定訓練資料的比例大小

為了達到簡化資料但不失準確率的目的，在演算法實驗之前首先需要確定訓練和測試資料的比例才能確保至少要取多少資料可以最貼近整體資料集，因此我們先取 Data A 的 NMD6 為舉例，並做出不同比例的比較圖，方法使用引導聚集算法並使用 J48 分類器，橫軸為訓練資料的比例，縱軸為 ACC 和 TPR 對應的機率，列表如下：

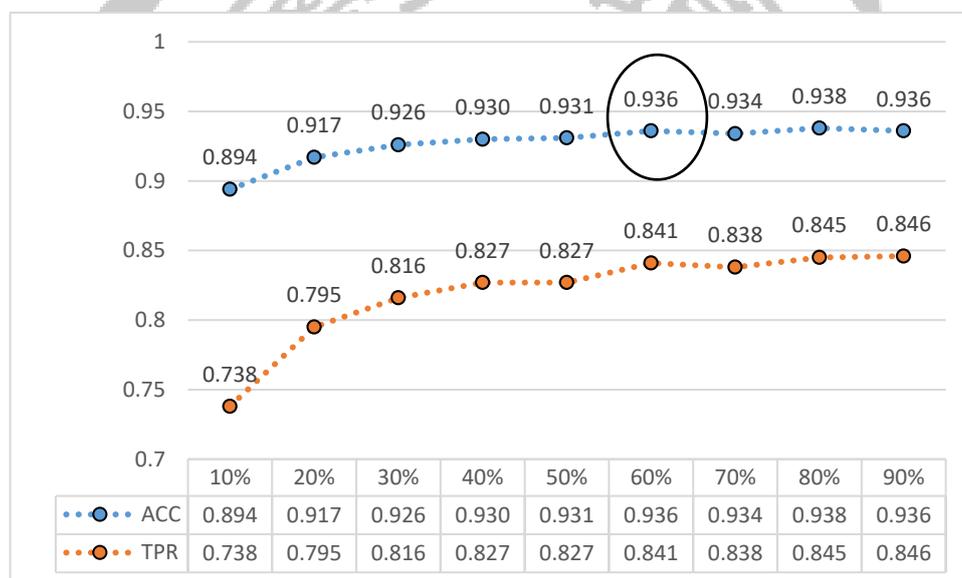


圖 3-2 Data A 不同比例學習之圖表

從上圖可見，ACC 在訓練資料的 60% 比例時和 90% 比例一致，在 70% 比例以後趨近水平，故此我們以取 60% 為訓練資料，40% 為測試資料為主要實驗比例。

3.5 不同演算法法的學習比較

資料集為 Data A(有重複的數據)和 Data B(無重複且病例最新數據)，並在 NMD6、NMD5、NMD3 中使用不同的演算法，以方便觀察不同類別的 ACC、TPR 在不同訓練資料比例中的情形，並挑選出最高的方法，此步驟的目的在觀察分類簡化過程當中的準確率和靈敏度(TPR)是否有明顯的差異性，加權平均(weighted average)為不同類別比重數量的數據，公式如下：

$$\text{weighted average} = \frac{1}{N} \sum_{i=1}^n A_i * P_i$$

其中 N 為全部數據量， n 為資料集的類別總數， A_i 為第 i 個類別的比重， P_i 為第 i 個類別對應的數量。

圖 3-3、圖 3-4、圖 3-5 和圖 3-6 分別為六類的 NB、MLP、C4.5(Bagging)和 SVM 等不同方法的比較圖，此篇論文使用的方法在 C4.5(Bagging)演算法反覆訓練 20 次為標準，並且每個方法以 60% 訓練資料和 40% 測試資料為比例來運作演算法。

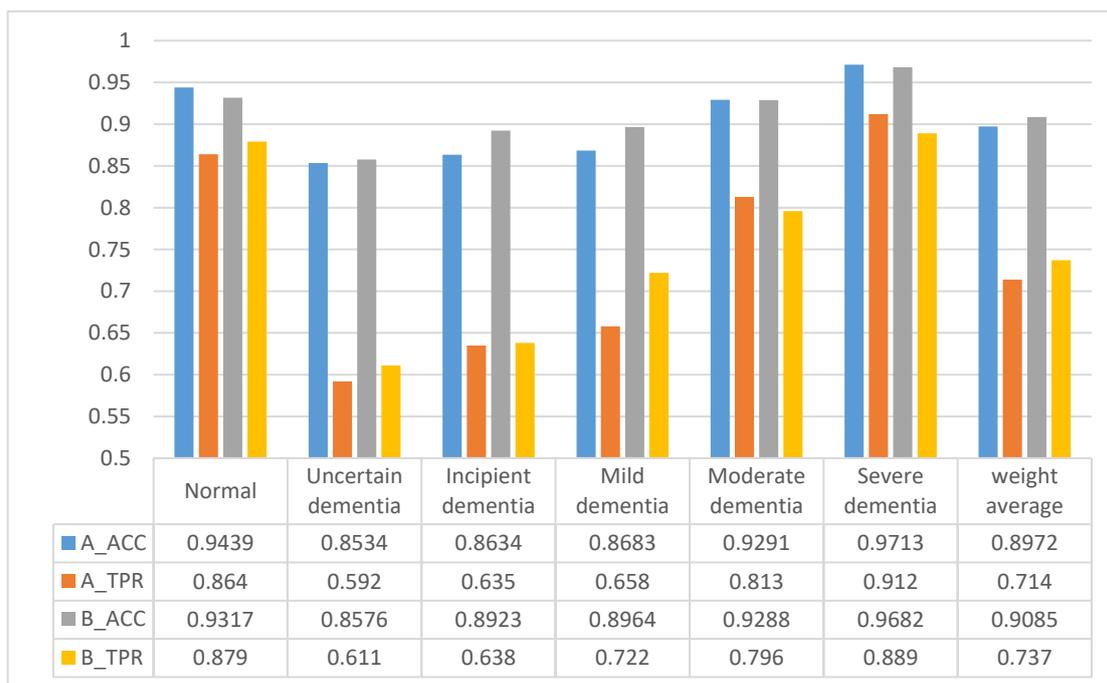


圖 3-3 六類 NB 分析之結果

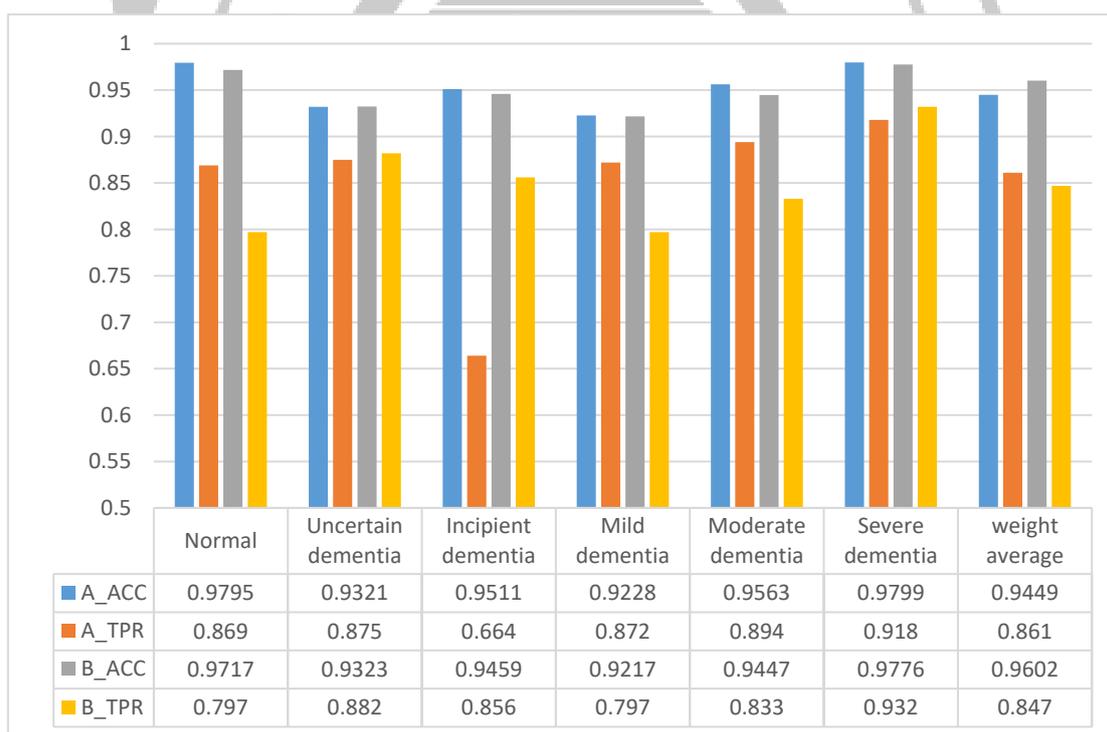


圖 3-4 六類 MLP 分析之結果

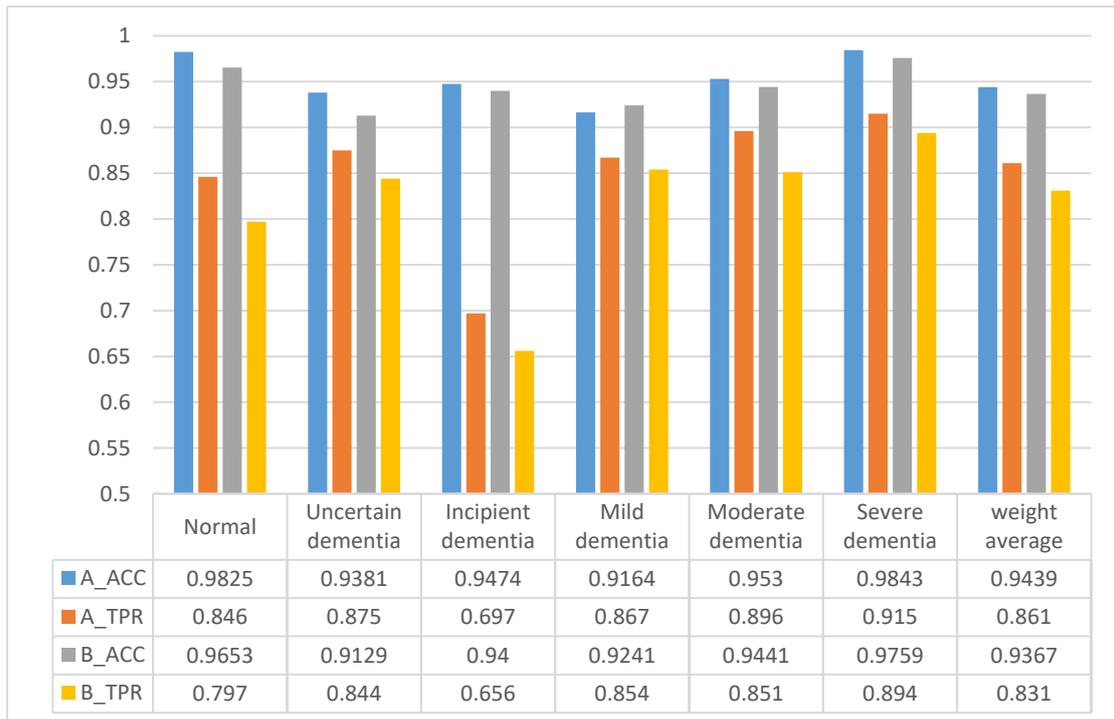


圖 3-5 六類 C4.5(Bagging)分析之結果

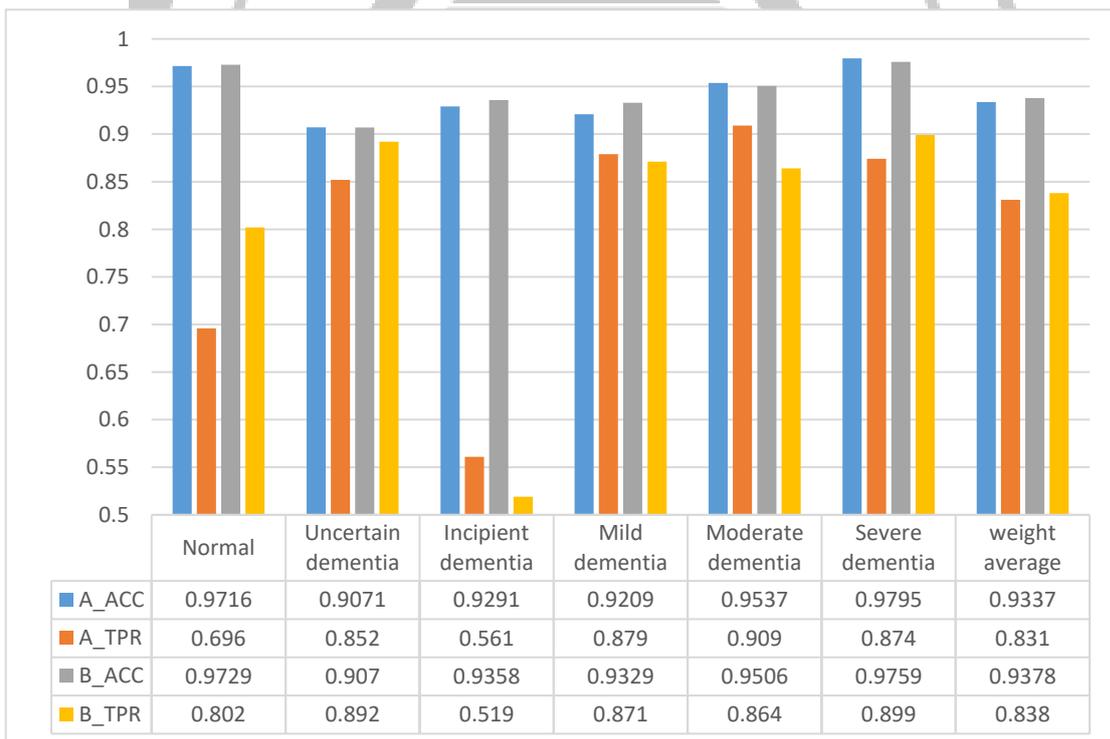


圖 3-6 六類 SVM 分析之結果

可從上面這些圖表觀察到，NB 演算法的加權平均明顯比其他三個方法還要低，可優先刪除，再來觀察其他三個

演算法的圖表，在判定 Normal、Mild dementia、Moderate dementia 和 Severe dementia 的診斷錯誤率非常的低(加權平均在 80%~90%左右)，若從加權平均來看，雖然目前六類以 MLP 演算法為最有效，但仍然要繼續觀察簡化的過程。

3.5.1 資料第一次調整

以 Data A(有重複的數據)和 Data B(無重複且最新數據)為資料集，將六分類其中一個類別 Uncertain dementia 成為新的類別 MCI，再將 Incipient dementia 的人數加進 Mild dementia 的類別，從此步驟得到五類的數據。以下列圖 3-7、圖 3-8、圖 3-9 與圖 3-10 分別為五類使用 NB、MLP、C4.5(Bagging)和 SVM 等演算法後的比較圖，列表如下：

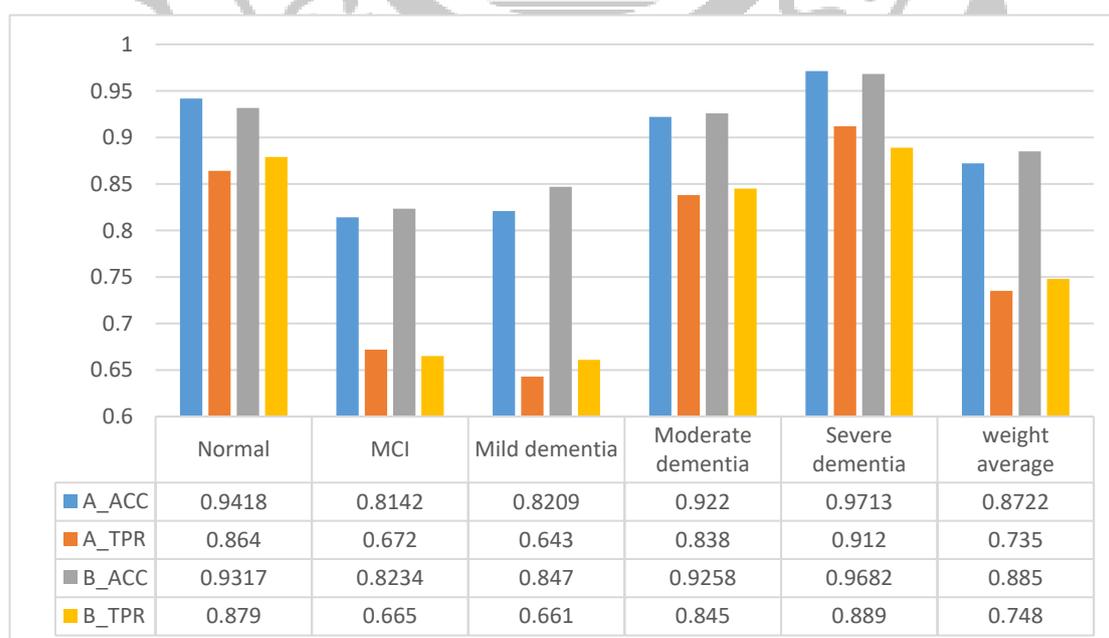


圖 3-7 五類 NB 分析之結果

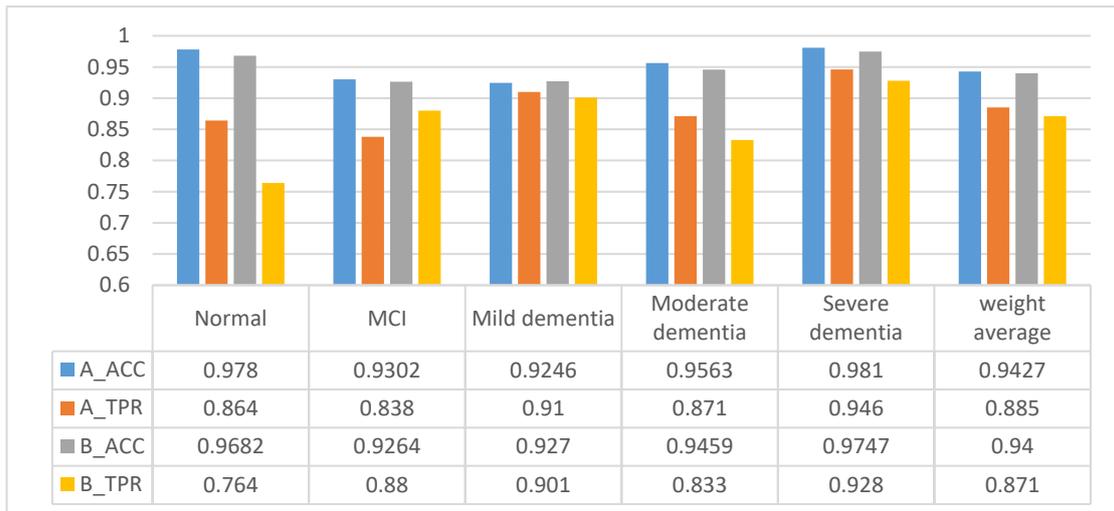


圖 3-8 五類 MLP 分析之結果

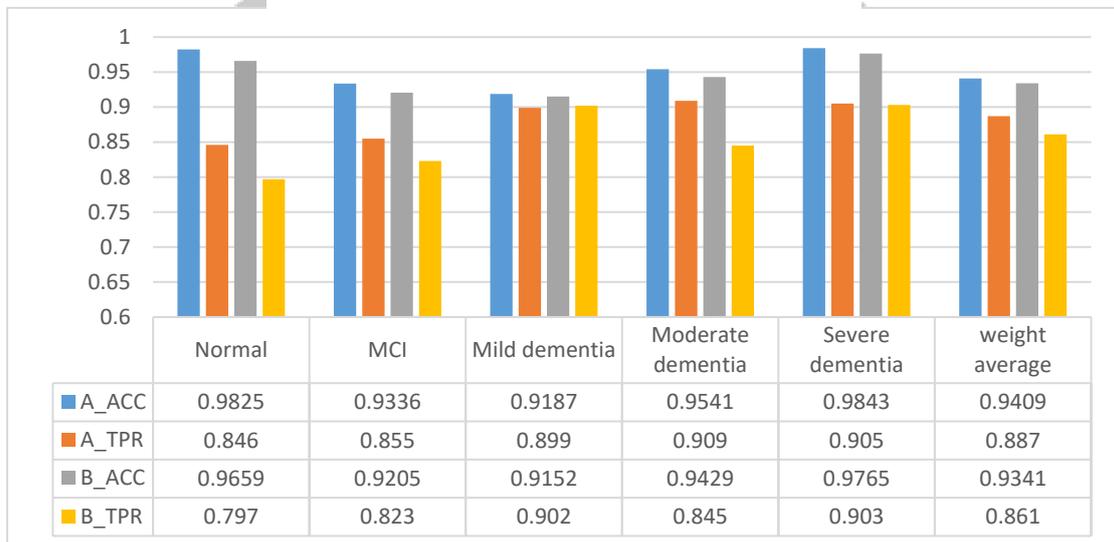


圖 3-9 五類 C4.5(Bagging)分析之結果

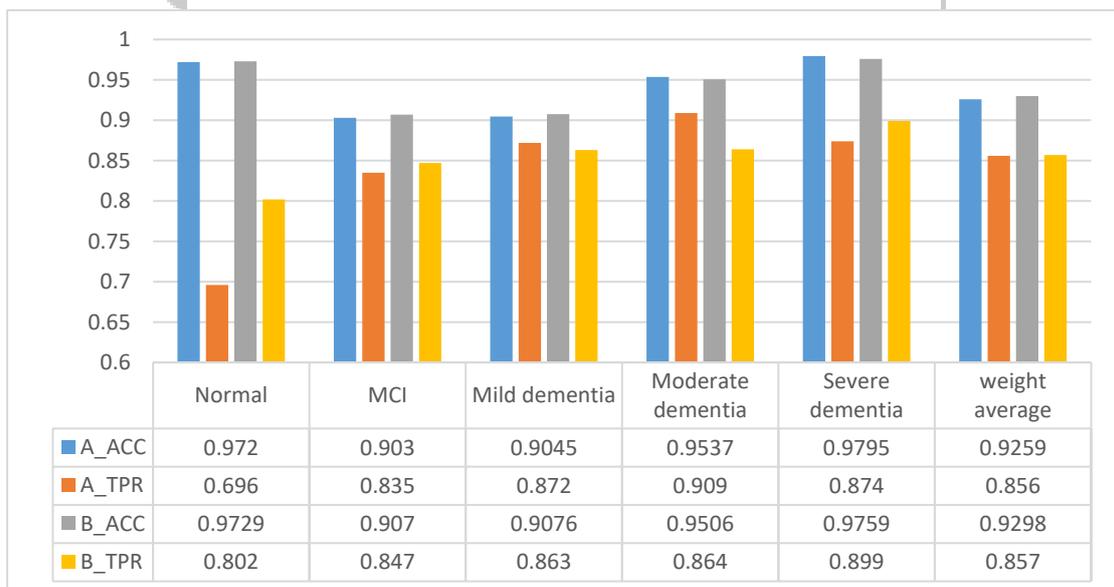


圖 3-10 五類 SVM 分析之結果

第一次調整類別之後一樣可以將加權平均不理想的 NB 演算法優先刪除，可以觀察到在五類的分類上以決策樹為分類器的引導聚集算法為最大改善的方式，接下來要持續觀察簡化成三類的過程。

3.5.2 資料第二次調整

將屬性資料類別融合，並觀察準確率的前後變化，利用五類的數據，將 Mild Dementia、Moderate Dementia 和 Severe Dementia 合併成新的類別(Dementia)，調整後得到 NMD3 的數據，之後代入不同的學習法，並分析其結果，以下圖 3-11、圖 3-12、圖 3-13、圖 3-14 為 NMD3 不同演算法的比較表：

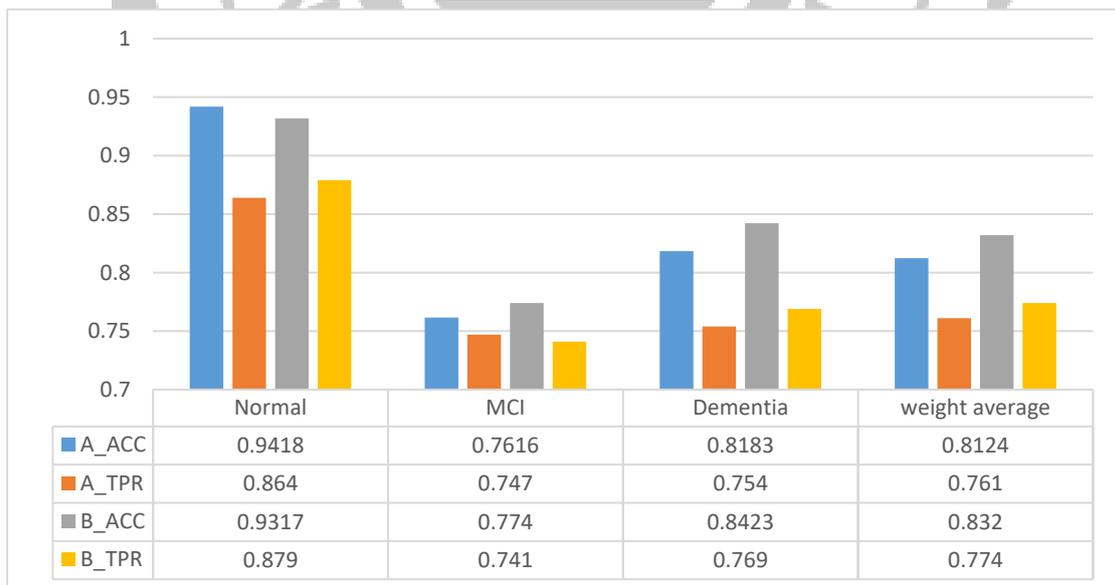


圖 3-11 三類 NB 分析之結果

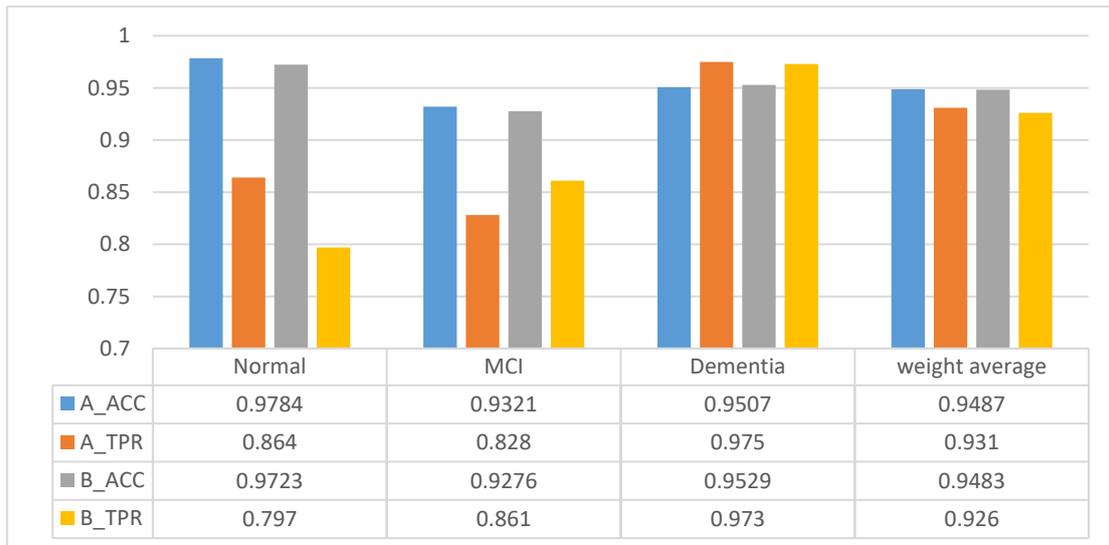


圖 3-12 三類 MLP 分析之結果

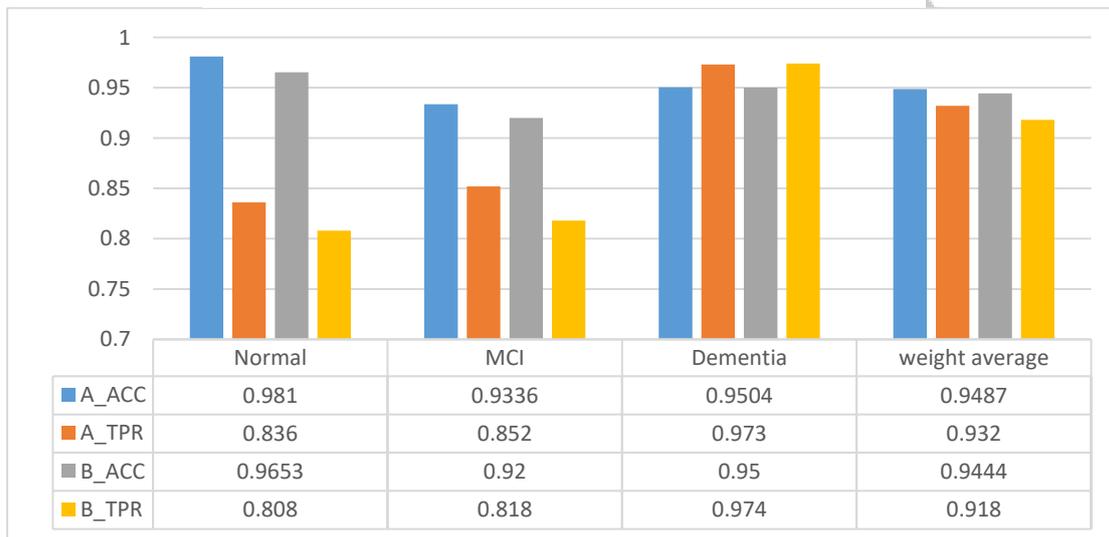


圖 3-13 三類 C4.5(Bagging)分析之結果

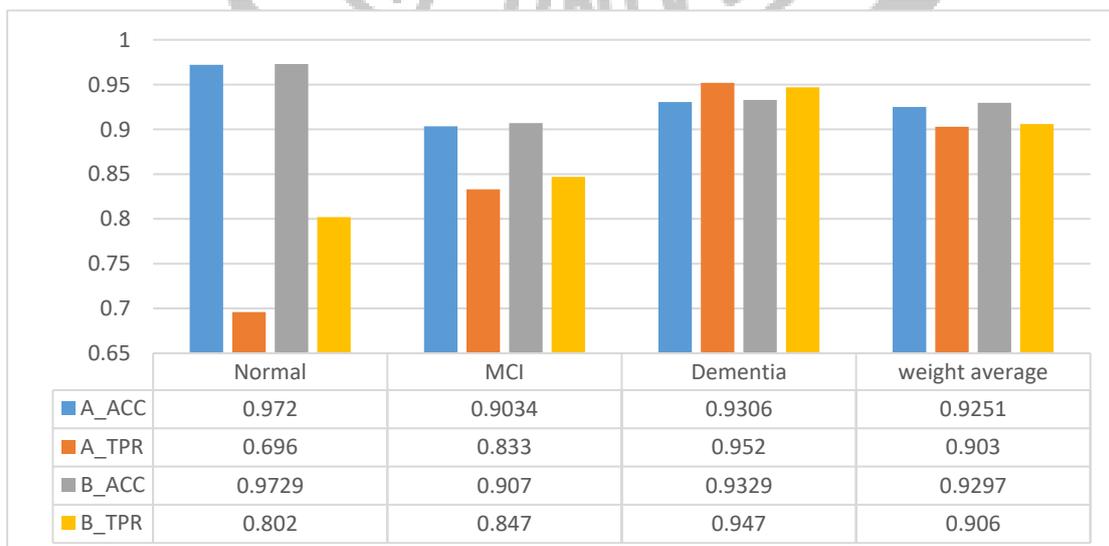


圖 3-14 三類 SVM 分析之結果

3.6 總比較結果

將每個加權平均做成以四種不同演算法為比較的直方圖表，以觀察簡化類別的變化，以下四個圖表分別為變化結果。

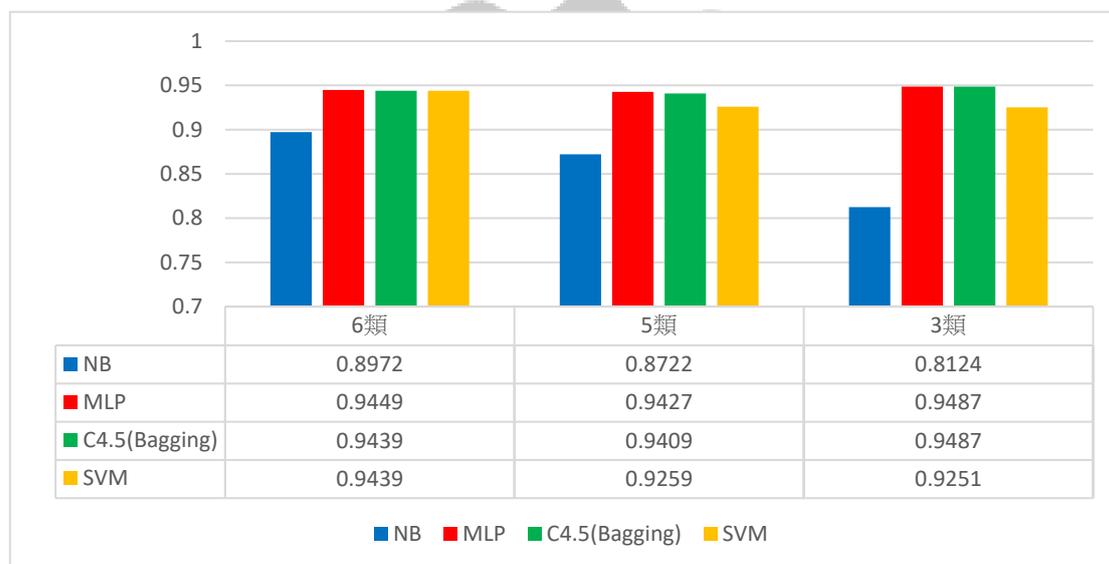


圖 3-15 Data A 之 ACC 結果

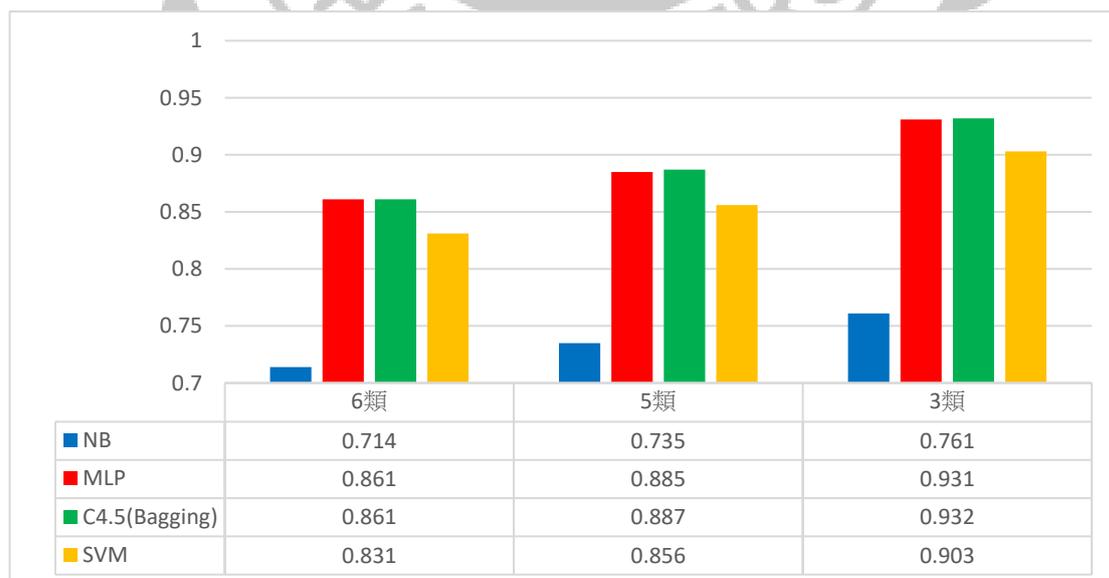


圖 3-16 Data A 之 TPR 結果

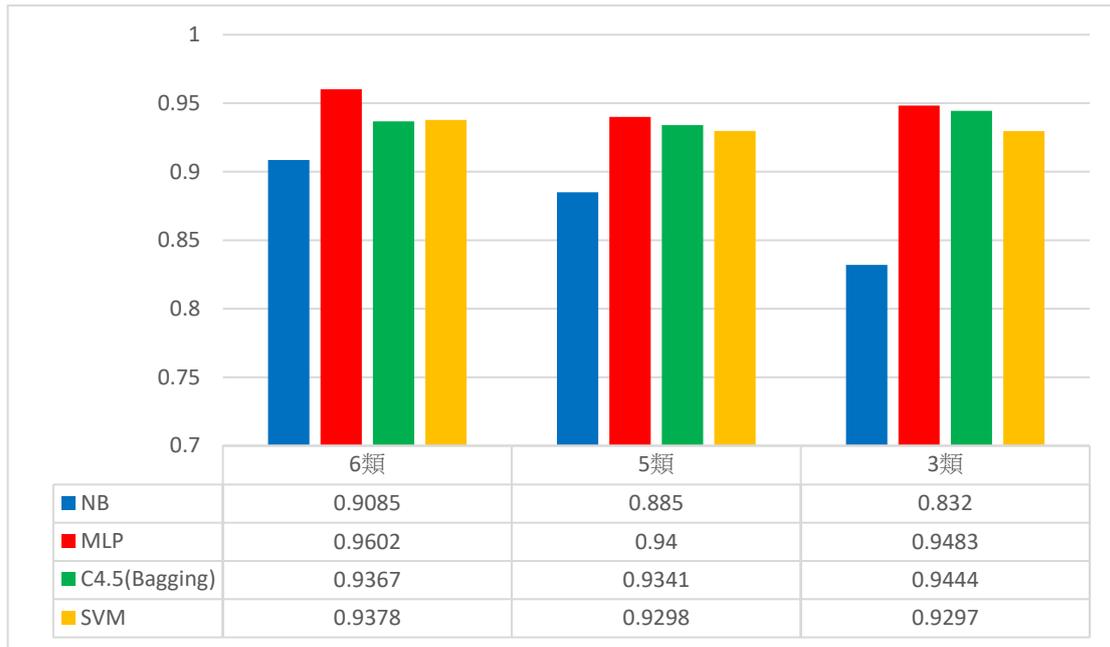


圖 3-17 Data B 之 ACC 結果



圖 3-18 Data B 之 TPR 結果

從上面總結果比較可以看到，在簡化的過程中除了 Data B 的 ACC 以外，其他都因為簡化分類少而逐漸提升整體問卷的準確度和各類的靈敏度。對 Data A 和 Data B 而言 ACC 都

超過八成以上，甚至有的方法在簡化到三類時快到九成五，代表這四個演算法非常貼近改良過後的 CDR，不過我們可以先把加權平均較低的 NB 優先刪除不考慮，Data A 和 Data B 在 ACC 的表現都是以 C4.5(Bagging)增加幅度最大且沒有弱化的現象而且 TPR 的部分也是 C4.5(Bagging)演算法勝出，雖然從 Data B 的數據來看簡化後的結果是 MLP 最高，但是我們以簡化分類的過程中哪一個改善最大為主要判定，因此從起伏來做比較的話，C4.5(Bagging)的部分的 ACC 和 TPR 是最好的，因此我們判定決策數為分類器的引導聚集方法在簡化分類後的準確度和靈敏度是最好的。

第四章 數據平衡化與主成分分析

此章節用 Data B 作為資料集，將資料集拆開成 NMD6、NMD5 和 NMD3 的分類子資料之後，各自對最少數類別做合成數據的增加，並且在確保不會超過第二少數類別的數據量之下做不同的演算法。第一小節使用 SMOTE 法針對 NMD6、NMD5 和 NMD3 中最少數類別合成一定比例的人工數據之後再使用 C4.5 with Bagging 演算法後，可以得到資料集平衡化後的 Data B，然後再將兩者的準確率和靈敏度再做一次比較和分析，第一小節查看六類、五類和三類調整前後的效果會如何，第二小節將數據做主成分分析來觀察簡化題目的過程，最後在把這三種不同的分類資料總比較這三種分類法的評估情形，此章節的流程如圖 4-1。

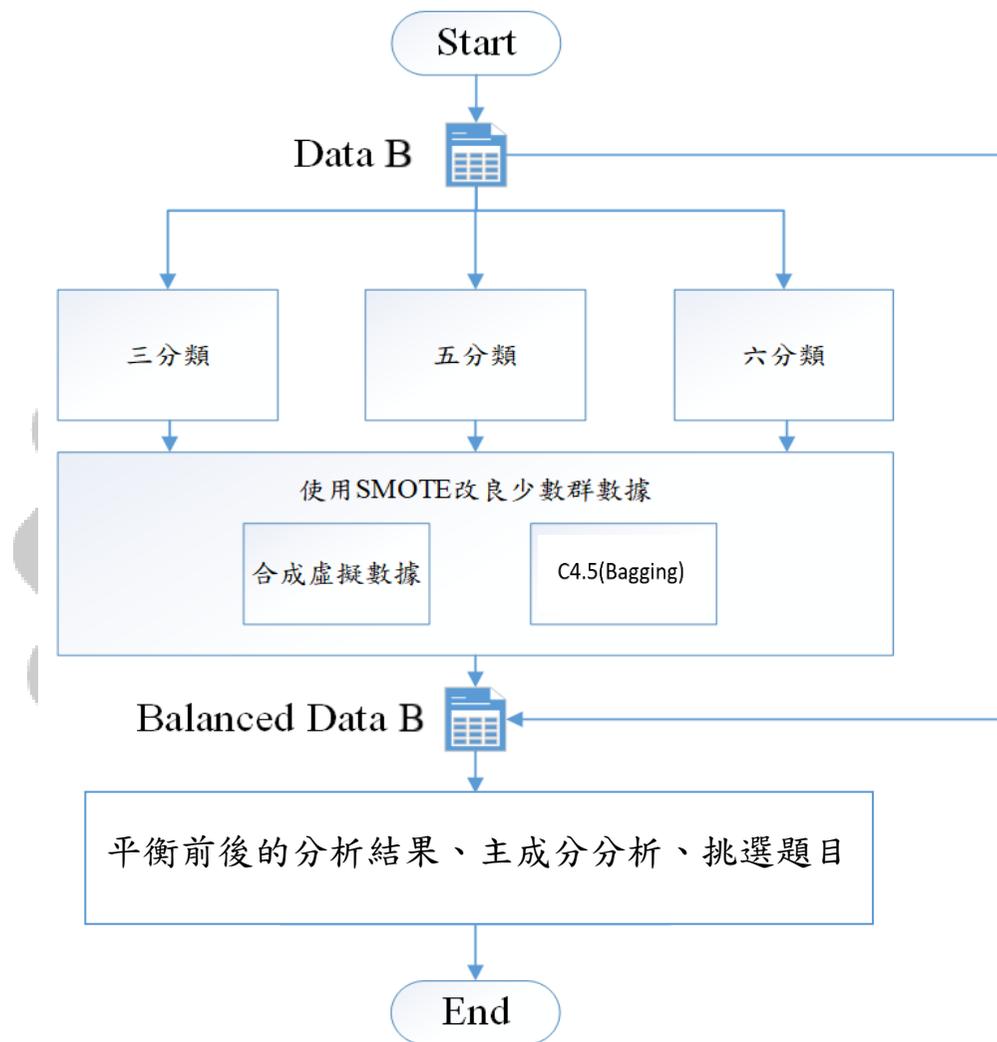


圖 4-1 資料平衡化流程

4.1 六類之分析

此節用 Data B 為資料集，首先觀察不同分類的人數差異，並將最少的數據增加本身的 10%，以確保數據不會超過第二少的數據量，之後觀察準確率和靈敏度的前後差異，如表 4-1、表 4-2。

表 4-1 Data B 六類平衡前後比較人數表

狀態	Before	After
Normal	459	459
Uncertain dementia	1084	1084
Incipient dementia	409	449
Mild dementia	982	982
Moderate dementia	792	792
Severe dementia	522	522
Total	4248	4288

表 4-2 六類 ACC、TPR 前後比較表

Group	ACC		TPR	
	Before	After	Before	After
Normal	0.9653	0.9749	0.797	0.869
Uncertain Dementia	0.9129	0.9201	0.844	0.827
Incipient Dementia	0.9400	0.9516	0.656	0.749
Mild dementia	0.9241	0.9184	0.854	0.854
Moderate dementia	0.9441	0.9452	0.851	0.850
Severe dementia	0.9759	0.9784	0.894	0.924
Weight Average	0.9367	0.9398	0.831	0.844

4.1.1 五類之分析

此節用 Data B 的 NMD6 為資料集，將 Uncertain dementia 定義為新的類別 MCI，再把 Incipient dementia 的樣本數加進 Mild dementia，從而得到五分類的數據，觀察不同分類的人數差異，將第一少的數據增加本身的 10%，為了確保數據不會超過第二少的數據量，之後再觀察準確率和靈敏度的前後差異，如表 4-3、表 4-4。

表 4-3 NMD5 平衡前後比較人數表

狀態	Before	After
Normal	459	504
MCI	1084	1084
Mild dementia	1391	1391
Moderate dementia	792	792
Severe dementia	522	522
Total	4248	4293

表 4-4 五類 ACC、TPR 前後比較表

Group	ACC		TPR	
	Before	After	Before	After
Normal	0.9659	0.9720	0.797	0.846
MCI	0.9205	0.9208	0.823	0.863
Mild dementia	0.9152	0.9237	0.902	0.871
Moderate dementia	0.9429	0.9668	0.845	0.944
Severe dementia	0.9765	0.9895	0.903	0.934
Weight Avg.	0.9341	0.9434	0.861	0.886

4.1.2 三類之分析

5. 此節用 Data B 的 NMD6 為資料集，將 Uncertain Dementia 和 Incipient Dementia 兩類合併成 MCI，再把 Mild Dementia、Moderate Dementia 和 Severe Dementia 合併成新的類別 (Dementia)，觀察不同分類的人數差異，將第一少的數據增加本身的 10%，取 10% 是為了確保不會超過第二少的數據，之後觀察準確率和靈敏度的前後差異，如表 4-5、表 4-6。

表 4-5 Data B 三類平衡前後比較人數

狀態	Before	After
Normal	459	504
MCI	1084	1084
Dementia	2705	2705
Total	4248	4293

表 4-6 三類 ACC、TPR 前後比較表

Group	ACC		TPR	
	Before	After	Before	After
Normal	0.9712	0.9720	0.857	0.856
MCI	0.9335	0.9400	0.909	0.928
Dementia	0.9612	0.9680	0.962	0.967
Weighted Avg.	0.9526	0.9580	0.933	0.940

從 4.1、4.1.1 和 4.1.2 小節的分析可以看到在平衡前後的變化，雖然在六類、五類中增加合成數量在最少數類別的 TPR 確實有增加，但從三類的數據中，但從整體的加權

平均而言並沒有太大的起伏效果，甚至降低的情形，代表此情形為犧牲整體的 TPR 但是能針對特定類別的 TPR 增加，因此主成分分析處理過程使用非平衡數據(4248 筆)來分析。

4.2 主成分分析

主成分分析的步驟如下：

1. 資料標準化

將問題裡的答案減去個問題的平均再除以標準差。

2. 計算相關係數矩陣

計算不同問題(變數)之間的相關係數，圖 4-2 為相關係數矩陣。

3. 計算特徵值與特徵向量

將第二步的相關係數矩陣代入特徵方程式，算出特徵值與對應的特徵向量 V_1, \dots, V_{50} ，其中取比重在 0.5% 之前 36 個特徵值所對應的向量， V_1, \dots, V_{36} 列表如圖 4-3 所示，圖 4-4 為 V_1, V_2 的座標圖，這些特徵向量由原始 50 個問題的線性組合而成，，例如 V_1 特徵向量的內容為

-0.187H01-0.181C05-0.178C01-0.178C03+0.177P07-0.176C07
-0.175C06+0.174P04-0.172C04-0.171C02+0.168P10+0.167P05
-0.166J05+0.166P06-0.165C08+0.165P08+0.164P09-0.162J06
+0.161P02+0.161P01-0.158O05+0.158P03-0.152J04-0.146L02
-0.145M02-0.144J03-0.144O06-0.143M12-0.141O03-0.141M03
-0.14L03-0.139M08-0.134O02-0.129L05-0.124J02-0.121L06
-0.118M06-0.112O07-0.106M05-0.105M10-0.1M07-0.092J01
-0.088M09-0.077M01-0.068L09-0.059L04-0.058M04-0.057L01
-0.015C09-0.011L08

Correlation matrix

1	0.17	0.41	0.13	0.37	0.4	0.41	0.32	0.35	0.29	0.17	0.42	0.41	0.22	0.16	0.11	0.09	0.25	0.39	0.35	0.27	0.24	0.29	0.35	0.26	0.31	0.31	0.35	0.03	0.29	-0.18	-0.19	-0.18	-0.21	-0.24	-0.23	-0.22	-0.19	-0.19	-0.21	0.08	0.21	0.18	0.07	0.22	0.19	0	0.09		
0.17	1	0.38	0.18	0.33	0.34	0.26	0.44	0.23	0.29	0.61	0.36	0.4	0.61	0.6	0.57	0.4	0.44	0.39	0.44	0.53	0.58	0.56	0.51	0.62	0.52	0.56	0.53	0.53	0.49	-0.06	0.64	-0.58	-0.52	-0.56	-0.58	-0.52	-0.5	-0.59	-0.54	-0.57	-0.57	0.19	0.56	0.54	0.23	0.42	0.47	0.05	0.21
0.41	0.38	1	0.21	0.45	0.51	0.45	0.55	0.38	0.41	0.37	0.61	0.64	0.49	0.36	0.25	0.2	0.4	0.65	0.65	0.58	0.5	0.62	0.64	0.55	0.6	0.58	0.62	0.61	0.6	0.05	0.58	-0.39	-0.4	-0.39	-0.46	-0.53	-0.48	-0.48	-0.42	-0.41	-0.45	0.15	0.43	0.37	0.15	0.41	0.35	0.03	0.19
0.13	0.18	0.21	1	0.16	0.14	0.13	0.21	0.14	0.13	0.12	0.15	0.19	0.21	0.21	0.08	0.09	0.17	0.2	0.19	0.24	0.22	0.2	0.2	0.19	0.18	0.21	0.19	0.25	0.18	0.08	0.28	-0.22	-0.24	-0.19	-0.24	-0.22	-0.26	-0.24	-0.25	-0.21	-0.23	0.11	0.18	0.18	0.08	0.18	0.15	-0.02	0.2
0.37	0.33	0.45	0.16	1	0.52	0.35	0.52	0.4	0.34	0.31	0.41	0.49	0.41	0.32	0.22	0.18	0.37	0.42	0.45	0.4	0.4	0.4	0.43	0.39	0.4	0.39	0.41	0.39	0.41	-0.07	0.43	-0.29	-0.29	-0.28	-0.32	-0.32	-0.32	-0.35	-0.3	-0.33	-0.34	0.09	0.33	0.29	0.12	0.28	0.29	-0.02	0.15
0.4	0.34	0.51	0.14	0.52	1	0.41	0.55	0.44	0.39	0.32	0.53	0.59	0.41	0.33	0.25	0.2	0.41	0.54	0.54	0.45	0.4	0.47	0.51	0.43	0.48	0.45	0.48	0.47	0.5	-0.03	0.47	-0.31	-0.31	-0.3	-0.36	-0.39	-0.36	-0.37	-0.32	-0.34	-0.37	0.09	0.36	0.3	0.13	0.31	0.27	-0.02	0.14
0.41	0.26	0.45	0.13	0.35	0.41	1	0.41	0.33	0.33	0.24	0.45	0.46	0.33	0.23	0.17	0.13	0.32	0.46	0.46	0.39	0.36	0.41	0.46	0.37	0.41	0.38	0.42	0.41	0.43	0.05	0.4	-0.25	-0.26	-0.25	-0.3	-0.33	-0.31	-0.32	-0.28	-0.28	-0.3	0.11	0.29	0.26	0.08	0.3	0.26	0.01	0.15
0.32	0.44	0.55	0.21	0.52	0.55	0.41	1	0.42	0.39	0.43	0.51	0.59	0.54	0.44	0.31	0.24	0.52	0.51	0.56	0.55	0.54	0.53	0.53	0.53	0.54	0.54	0.55	0.5	0.01	0.59	-0.42	-0.43	-0.42	-0.48	-0.48	-0.47	-0.49	-0.44	-0.46	-0.49	0.14	0.43	0.37	0.15	0.4	0.36	0.01	0.2	
0.35	0.23	0.38	0.14	0.4	0.44	0.33	0.42	1	0.48	0.23	0.41	0.44	0.31	0.26	0.19	0.14	0.31	0.42	0.38	0.32	0.3	0.34	0.37	0.3	0.34	0.32	0.35	0.34	0.38	-0.03	0.33	-0.22	-0.21	-0.19	-0.24	-0.26	-0.25	-0.26	-0.23	-0.23	-0.24	0.06	0.28	0.21	0.11	0.18	0.21	-0.03	0.1
0.29	0.29	0.41	0.13	0.34	0.39	0.33	0.39	0.48	1	0.29	0.44	0.45	0.38	0.32	0.26	0.18	0.32	0.47	0.41	0.39	0.37	0.44	0.46	0.41	0.44	0.41	0.45	0.42	0.45	-0.02	0.41	-0.3	-0.3	-0.28	-0.34	-0.37	-0.34	-0.36	-0.32	-0.32	-0.33	0.06	0.34	0.26	0.11	0.21	0.22	-0.05	0.11
0.17	0.61	0.37	0.12	0.31	0.32	0.24	0.43	0.23	0.29	1	0.35	0.38	0.6	0.64	0.54	0.42	0.46	0.37	0.42	0.52	0.56	0.56	0.5	0.61	0.52	0.56	0.53	0.53	0.49	-0.06	0.64	-0.57	-0.53	-0.55	-0.58	-0.5	-0.5	-0.58	-0.54	-0.57	-0.57	0.19	0.52	0.52	0.24	0.42	0.47	0.03	0.2
0.42	0.36	0.61	0.15	0.41	0.53	0.45	0.51	0.41	0.44	0.35	1	0.64	0.43	0.33	0.23	0.19	0.4	0.67	0.59	0.52	0.49	0.58	0.62	0.52	0.6	0.54	0.6	0.58	0.63	0.05	0.54	-0.36	-0.38	-0.36	-0.42	-0.49	-0.44	-0.44	-0.39	-0.38	-0.41	0.11	0.39	0.33	0.13	0.37	0.3	0.01	0.15
0.41	0.4	0.64	0.19	0.49	0.59	0.46	0.59	0.44	0.45	0.38	0.64	1	0.47	0.35	0.26	0.21	0.44	0.65	0.64	0.55	0.5	0.6	0.62	0.55	0.63	0.57	0.62	0.59	0.63	0.01	0.57	-0.38	-0.39	-0.37	-0.44	-0.5	-0.45	-0.46	-0.4	-0.41	-0.44	0.13	0.44	0.37	0.14	0.39	0.34	0	0.17
0.22	0.61	0.49	0.21	0.41	0.41	0.33	0.54	0.31	0.38	0.6	0.43	0.47	1	0.61	0.43	0.34	0.46	0.48	0.54	0.65	0.65	0.64	0.59	0.67	0.59	0.65	0.62	0.61	0.56	-0.03	0.69	-0.58	-0.55	-0.56	-0.63	-0.58	-0.57	-0.62	-0.56	-0.6	-0.6	0.18	0.55	0.51	0.21	0.45	0.46	0.02	0.2
0.16	0.6	0.36	0.21	0.32	0.33	0.23	0.44	0.26	0.32	0.64	0.33	0.35	0.61	1	0.51	0.44	0.47	0.36	0.4	0.52	0.56	0.53	0.47	0.57	0.48	0.54	0.49	0.54	0.46	-0.03	0.66	-0.6	-0.57	-0.58	-0.62	-0.5	-0.53	-0.61	-0.6	-0.62	-0.6	0.19	0.51	0.49	0.24	0.4	0.45	0.03	0.25
0.11	0.57	0.25	0.08	0.22	0.25	0.17	0.31	0.19	0.26	0.54	0.23	0.26	0.43	0.51	1	0.47	0.41	0.25	0.28	0.37	0.41	0.42	0.38	0.48	0.39	0.44	0.39	0.4	0.38	-0.04	0.49	-0.47	-0.41	-0.44	-0.46	-0.37	-0.37	-0.46	-0.44	-0.47	-0.45	0.15	0.45	0.43	0.24	0.27	0.36	0.01	0.16
0.09	0.4	0.2	0.09	0.18	0.2	0.13	0.24	0.14	0.18	0.42	0.19	0.21	0.34	0.44	0.47	1	0.37	0.2	0.22	0.3	0.33	0.32	0.29	0.37	0.3	0.34	0.3	0.34	0.29	0	0.44	-0.4	-0.35	-0.39	-0.39	-0.3	-0.31	-0.39	-0.37	-0.42	-0.4	0.12	0.31	0.31	0.24	0.22	0.27	0.03	0.19
0.25	0.44	0.4	0.17	0.37	0.41	0.32	0.52	0.31	0.32	0.46	0.4	0.44	0.46	0.47	0.41	0.37	1	0.4	0.42	0.43	0.42	0.41	0.41	0.42	0.42	0.45	0.44	0.49	0.41	-0.02	0.55	-0.42	-0.43	-0.4	-0.46	-0.41	-0.43	-0.47	-0.44	-0.46	-0.47	0.16	0.42	0.41	0.21	0.35	0.37	0.02	0.24
0.39	0.39	0.65	0.2	0.42	0.54	0.46	0.51	0.42	0.47	0.37	0.67	0.65	0.48	0.36	0.25	0.2	0.4	1	0.65	0.57	0.51	0.65	0.59	0.66	0.63	0.66	0.04	0.6	-0.39	-0.4	-0.39	-0.46	-0.54	-0.49	-0.48	-0.42	-0.42	-0.44	0.14	0.43	0.37	0.14	0.42	0.33	0.03	0.18			
0.35	0.44	0.65	0.19	0.45	0.54	0.46	0.56	0.38	0.41	0.42	0.59	0.64	0.54	0.4	0.28	0.22	0.42	0.65	1	0.65	0.54	0.66	0.66	0.67	0.64	0.66	0.64	0.63	0.03	0.64	-0.44	-0.45	-0.43	-0.5	-0.57	-0.53	-0.53	-0.46	-0.47	-0.49	0.17	0.47	0.42	0.16	0.46	0.39	0.03	0.22	
0.27	0.53	0.58	0.24	0.4	0.45	0.39	0.55	0.32	0.39	0.52	0.52	0.55	0.65	0.52	0.37	0.3	0.43	0.57	0.65	1	0.65	0.7	0.66	0.71	0.68	0.74	0.7	0.67	0.64	0.05	0.72	-0.56	-0.56	-0.56	-0.64	-0.66	-0.63	-0.65	-0.58	-0.59	-0.62	0.21	0.55	0.52	0.22	0.5	0.45	0.05	0.23
0.24	0.58	0.5	0.22	0.4	0.4	0.36	0.54	0.3	0.37	0.56	0.49	0.5	0.65	0.56	0.41	0.33	0.42	0.51	0.54	0.65	1	0.67	0.63	0.73	0.63	0.67	0.65	0.64	0.59	-0	0.72	-0.59	-0.56	-0.57	-0.63	-0.61	-0.59	-0.65	-0.58	-0.59	-0.61	0.2	0.55	0.52	0.22	0.48	0.46	0.06	0.25
0.29	0.56	0.62	0.2	0.4	0.4	0.41	0.53	0.34	0.44	0.56	0.58	0.6	0.64	0.53	0.42	0.32	0.41	0.55	0.66	0.7	0.67	1	0.87	0.82	0.82	0.83	0.83	0.79	0.76	0.08	0.75	-0.6	-0.6	-0.6	-0.67	-0.71	-0.66	-0.7	-0.61	-0.6	-0.63	0.2	0.6	0.54	0.21	0.51	0.45	0.04	0.2
0.35	0.51	0.64	0.2	0.43	0.51	0.46	0.53	0.37	0.46	0.5	0.62	0.62	0.59	0.47	0.38	0.29	0.41	0.74	0.66	0.66	0.63	0.87	1	0.76	0.79	0.77	0.8	0.76	0.77	0.06	0.71	-0.53	-0.53	-0.54	-0.6	-0.65	-0.59	-0.64	-0.55	-0.54	-0.57	0.18	0.57	0.51	0.2	0.48	0.42	0.04	0.2
0.26	0.62	0.55	0.19	0.39	0.43	0.37	0.53	0.3	0.41	0.61	0.52	0.55	0.67	0.57	0.48	0.37	0.42	0.56	0.6	0.71	0.73	0.82	0.76	1	0.76	0.81	0.78	0.72	0.02	0.75	-0.65	-0.62	-0.65	-0.7	-0.7	-0.64	-0.72	-0.63	-0.65	-0.66	0.21	0.63	0.58	0.23	0.51	0.48	0.06	0.2	
0.31	0.52	0.6	0.18	0.4	0.48	0.41	0.53	0.34	0.44	0.52	0.6	0.63	0.59	0.48	0.39	0.3	0.42	0.65	0.67	0.68	0.63	0.82	0.79	0.76	1	0.83	0.82	0.75	0.76	0.07	0.71	-0.56	-0.56	-0.56	-0.63	-0.68	-0.62	-0.66	-0.57	-0.57	-0.59	0.19	0.56	0.51	0.19	0.5	0.45	0.04	0.19
0.27	0.56	0.58	0.21	0.39	0.45	0.38	0.54	0.32	0.41	0.56	0.54	0.57	0.65	0.54	0.44	0.34	0.45	0.59	0.64	0.74	0.67	0.83	0.77	0.81	0.83	1	0.85	0.76	0.74	0.12	0.77	-0.65	-0.65	-0.64	-0.72	-0.75	-0.71	-0.75	-0.67	-0.65	-0.67	0.22	0.59	0.56	0.21	0.53	0.46	0.05	0.22
0.31	0.53	0.62	0.19	0.41	0.48	0.42	0.54	0.35	0.45	0.53	0.6	0.62	0.62	0.49	0.39	0.3	0.44	0.66	0.66	0.7	0.65	0.83	0.8	0.78	0.82	0.85	1	0.76	0.77	0.07	0.73	-0.57	-0.57	-0.57	-0.														

	Y1	Y2	Y3	Y4	Y5	Y6	Y7	Y8	Y9	Y10	Y11	Y12	Y13	Y14	Y15	Y16	Y17	Y18	Y19	Y20	Y21	Y22	Y23	Y24	Y25	Y26	Y27	Y28	Y29	Y30	Y31	Y32	Y33	Y34	Y35	Y36
M01	-0.0766	-0.237	-0.0243	0.0754	-0.2432	0.1252	0.1544	-0.2035	-0.0783	0.097	-0.2197	-0.0972	-0.537	-0.319	0.1266	-0.3743	-0.1112	-0.284	0.0087	0.0159	0.1685	-0.1541	0.029	-0.0307	-0.033	0.0627	-0.0161	0.0671	0.0643	-0.0613	0.0717	0.0176	-0.0296	0.0004	-0.0084	0.0097
M02	-0.1448	0.1017	-0.2183	0.0444	0.1183	-0.0555	-0.005	0.0641	0.0487	-0.1423	-0.0517	-0.0944	-0.0153	-0.0529	-0.0618	-0.152	0.2845	0.2269	0.0289	-0.0167	0.0813	-0.0072	0.1212	0.1172	0.3558	0.0749	0.271	0.5339	0.0647	-0.0268	0.0334	-0.2093	-0.0427	-0.3095	0.103	-0.0384
M03	-0.1412	-0.2139	0.0458	-0.0445	-0.0489	-0.0143	0.0185	0.0627	0.0629	-0.0093	-0.071	0.0946	-0.028	0.1109	0.0226	-0.0667	-0.0947	0.1524	0.2898	0.0531	0.356	0.17	-0.0868	-0.1261	-0.1642	-0.1772	0.0724	-0.2996	0.1265	-0.3617	-0.1584	0.0128	-0.2764	0.0804	-0.0238	
M04	-0.0584	0.0067	0.0507	0.0154	-0.334	-0.1785	-0.5149	0.5406	-0.2498	0.309	-0.0077	0.0866	-0.2669	0.0689	0.0861	0.0406	0.0532	0.02	-0.0718	-0.0907	-0.0724	0.0065	-0.0226	0.0144	-0.0508	0.0476	0.0474	-0.035	-0.0461	0.0327	0.0021	0.025	0.0552	-0.0158	-0.0511	-0.0087
M05	-0.1061	-0.1877	-0.1516	0.171	-0.1548	-0.0745	0.1406	0.0626	-0.0972	-0.0096	-0.2142	0.07	0.2548	-0.4563	0.2135	0.2436	0.1472	-0.1617	0.1479	-0.1023	-0.1917	0.4744	-0.0625	-0.0473	0.1722	-0.072	0.0858	-0.1002	0.0228	0.0497	-0.0005	-0.0434	0.0274	0.0303	0.0174	-0.015
M06	-0.1182	-0.2368	-0.094	0.1462	-0.1114	0.0298	0.1065	-0.0055	0.0206	-0.0301	-0.1115	0.1099	0.166	-0.039	0.1924	0.0853	0.2206	0.2003	-0.0477	-0.0481	-0.2195	-0.6419	-0.2622	0.1861	-0.004	0.1092	-0.1719	-0.0768	-0.1783	0.0322	-0.1195	0.0208	-0.0047	-0.1331	0.0312	-0.0625
M07	-0.0998	-0.2118	-0.0014	0.0059	-0.1625	0.0445	0.1206	-0.101	0.0971	0.0551	-0.1521	-0.1983	-0.3331	0.1415	-0.6152	0.4874	0.1586	0.0191	-0.0712	0.0283	-0.1325	0.0442	-0.0274	0.0405	-0.0037	-0.0556	0.0582	-0.0255	-0.0016	0.0594	-0.034	-0.0353	-0.0168	0.016	0.0062	0.0164
M08	-0.1391	-0.1431	-0.0895	0.1341	-0.1297	-0.0556	0.0769	0.1366	0.0596	0.0506	-0.1544	0.0554	0.3403	0.0647	-0.119	-0.0122	-0.0369	-0.0537	-0.085	-0.0915	0.142	-0.0855	0.3243	0.0486	-0.4544	-0.095	-0.1276	0.1786	0.1883	0.1665	0.4543	-0.0522	-0.0078	-0.0289	-0.0238	0.0947
M09	-0.0875	-0.2274	-0.1196	0.2107	-0.135	0.1232	-0.048	-0.1115	-0.3194	0.0019	0.356	-0.1667	0.1542	-0.116	-0.0249	0.0114	-0.1625	0.2573	-0.556	0.2673	0.1714	0.1053	-0.0039	-0.0919	0.0677	-0.0385	0.0215	-0.0134	-0.0623	-0.016	-0.0357	-0.0217	0.0302	-0.0271	-0.0214	0.0042
M10	-0.105	-0.1734	-0.0405	0.1854	0.0242	0.1218	-0.1364	-0.152	-0.253	-0.0143	0.5152	-0.1812	0.0596	0.0629	-0.1441	-0.0289	-0.0484	-0.1997	0.4123	-0.4646	-0.0962	-0.0406	-0.0318	0.079	-0.0739	0.0547	0.037	-0.059	-0.0106	-0.0095	0.0054	-0.0046	0.0287	-0.1052	0.0212	-0.0134
M12	-0.143	0.109	-0.2181	0.0572	0.139	-0.0235	-0.0035	-0.0069	0.1026	0.089	-0.0461	-0.0571	-0.0114	-0.0511	-0.1468	-0.2946	-0.0432	0.0688	0.0306	0.1424	-0.2168	0.0679	-0.2258	-0.0435	-0.3023	-0.0669	0.4354	-0.3128	-0.3422	-0.0027	0.2758	0.0686	0.0507	-0.16	-0.0107	-0.109
O02	-0.1343	-0.2403	0.0551	-0.0017	-0.0081	0.0794	0.0244	-0.0294	0.0727	-0.0354	0.0279	0.0646	-0.047	0.1975	0.0864	-0.2243	-0.0033	0.2294	0.1205	0.0877	-0.1438	0.132	0.3862	0.1765	0.1991	0.1567	0.0635	-0.3299	0.1453	0.4539	-0.0294	0.1107	-0.0152	-0.0974	-0.1165	0.0928
O03	-0.1412	-0.2431	-0.0029	0.0316	-0.0373	0.0045	0.0369	0.015	0.0487	-0.0222	-0.0379	0.0917	0.047	0.1552	0.1228	-0.0222	0.0378	0.1655	0.0771	-0.0139	0.0058	-0.0194	0.169	-0.0033	-0.2653	0.02	0.4581	0.1056	0.0327	-0.3639	-0.2961	-0.0147	-0.0796	0.4793	0.0762	0.0195
O05	-0.1579	0.0224	-0.1088	0.0565	0.0905	-0.1303	-0.0066	0.1268	-0.0383	0.0713	-0.0583	-0.0416	0.1399	-0.1323	-0.261	-0.1046	-0.1753	-0.0625	0.1144	0.0611	0.0314	-0.111	-0.0489	-0.0581	0.1998	0.0183	-0.0693	0.2517	-0.273	0.2585	-0.098	0.3989	-0.2555	0.3908	-0.2305	0.1
O06	-0.1436	0.1383	-0.1928	0.1368	0.0151	-0.0081	-0.0404	0.0756	0.0195	0.1039	0.0375	-0.0507	0.0163	-0.0555	-0.1576	-0.2164	-0.1131	0.06	0.1404	0.236	-0.296	-0.076	-0.2077	-0.0969	-0.0356	-0.1399	-0.2059	-0.0562	0.4878	0.0088	-0.2152	-0.3565	0.1027	0.1691	0.0176	0.1756
O07	-0.1122	0.1326	-0.2824	0.1188	0.1562	0.1928	-0.1151	-0.0821	0.1678	0.1897	0.0445	-0.0671	-0.0881	0.003	0.0588	-0.0599	0.5416	0.0692	-0.0954	-0.2138	0.321	0.1592	-0.0372	-0.0931	-0.1411	0.0891	-0.2727	-0.2134	-0.0049	0.0443	-0.0609	0.9099	-0.0246	0.0123	-0.0548	0.0414
O01	-0.092	0.1359	-0.2303	0.1496	0.0406	0.3394	-0.1203	0.0046	0.3727	-0.1443	0.101	0.2085	-0.1819	-0.1359	0.1874	0.3845	-0.4808	0.1207	0.0438	0.0461	-0.0299	0.0284	0.1748	0.0421	-0.0449	0.0494	0.0324	-0.0093	0.0039	0.084	-0.0101	-0.0921	-0.0146	-0.0007	0.0419	
O02	-0.1236	-0.0191	-0.2162	0.1552	-0.159	0.1052	0.0194	0.0247	0.2096	0.0495	-0.0561	0.0764	0.1546	0.5119	0.0354	-0.1258	-0.059	-0.5505	-0.2191	0.051	-0.036	0.0873	-0.0498	0.0187	0.243	0.037	0.0076	0.0258	-0.0939	-0.0943	-0.139	0.0346	0.1308	-0.0588	0.061	-0.0811
O03	-0.1445	-0.2319	0.0688	-0.0519	0.019	0.0197	-0.0265	0.0086	0.0527	-0.0451	0.1024	0.0756	-0.0997	0.1598	0.0667	-0.0911	0.0364	0.1816	0.1212	0.0645	-0.1075	0.0955	-0.0626	-0.0685	0.2633	-0.0479	-0.2437	0.0583	-0.1592	-0.1791	0.4931	-0.0828	0.0883	0.34	0.2252	-0.0353
O04	-0.1516	-0.1797	0.0368	-0.064	-0.0047	-0.0674	0.0299	0.0553	0.0857	-0.0512	-0.0343	0.0695	0.0576	0.0773	-0.0455	0.0504	-0.0479	0.1408	0.1238	-0.0327	0.2811	0.0165	-0.3639	-0.1315	0.1241	0.1225	0.0866	-0.042	0.3192	-0.2897	0.1338	0.278	0.1968	-0.1921	-0.4404	0.1455
O05	-0.1662	-0.0384	0.0336	-0.069	0.053	-0.091	-0.0161	0.1215	-0.0051	0.0027	-0.0477	0.027	0.077	-0.0774	-0.1702	0.0167	-0.1528	-0.0013	0.0295	-0.0591	0.3152	-0.1052	-0.1121	-0.0683	0.1389	0.1901	0.0802	-0.2543	0.195	0.1589	-0.0088	0.1058	0.0251	0.0473	0.6337	-0.1883
O06	-0.1616	0.0111	-0.0458	-0.0276	0.0718	-0.1087	0.0136	0.1348	-0.0038	0.0207	-0.0115	-0.0176	0.0599	-0.1863	-0.2164	-0.0445	-0.0783	-0.0119	0.0514	0.0523	0.0133	0.0047	0.4241	0.2481	0.069	0.0968	-0.2751	-0.2827	-0.1413	-0.5202	-0.1383	-0.007	0.026	-0.109	-0.0686	-0.0187
O01	-0.1784	-0.0637	0.0878	-0.1181	0.1987	-0.0084	-0.0799	0.0057	0.0212	0.0123	0.0328	0.0086	-0.0216	-0.0921	0.0261	0.0346	0.0413	-0.0888	-0.0676	0.0683	-0.0562	-0.0092	-0.026	-0.0403	-0.0613	-0.0709	-0.0577	0.0813	-0.049	0.0076	0.0334	-0.0366	-0.0219	-0.0697	-0.02	-0.0052
O02	-0.1711	-0.1334	0.0776	-0.1184	0.1636	0.0082	-0.0754	-0.0019	0.0308	-0.0083	0.0645	0.0269	-0.0853	-0.0499	0.0534	0.0552	0.0829	-0.0623	-0.0361	0.0877	-0.1495	0.0199	-0.0068	-0.088	0.027	-0.0914	-0.1622	0.1044	-0.1186	-0.0452	0.1689	-0.0232	0.0407	0.011	0.0445	-0.0242
O03	-0.1778	0.0076	0.0136	-0.0777	0.2029	-0.044	-0.0164	0.0243	-0.0115	0.0309	0.005	-0.0097	-0.0253	-0.1517	-0.0436	0.0474	0.0104	-0.0873	-0.0603	-0.013	-0.0249	-0.0597	0.1544	0.0186	-0.0354	0.0214	-0.0064	-0.0409	-0.0477	-0.0678	-0.0819	0.0392	0.1039	-0.0745	-0.0106	-0.0464
O04	-0.1719	-0.0943	0.0913	-0.1178	0.1756	-0.002	-0.0477	-0.1143	0.0434	-0.0078	0.0182	-0.0112	-0.037	0.0975	0.057	0.0222	-0.1143	-0.1224	0.0086	-0.0576	0.0169	-0.0274	-0.0178	-0.126	0.1373	0.0831	0.0715	0.1007	-0.0003	-0.0105	-0.0408	0.0487	-0.0318	-0.0278	0.0887	
O05	-0.181	-0.0095	0.1123	-0.0918	0.1504	-0.0057	-0.0446	0.0168	0.0163	0.0325	0.0102	0.004	0.0503	-0.0948	0.0192	0.0693	-0.0143	-0.1577	-0.1343	-0.0149	0.0515	-0.0368	-0.051	-0.007	-0.084	0.1132	0.0531	0.0051	0.0503	0.0913	-0.0637	-0.031	0.0327	-0.0121	0.1105	0.0855
O06	-0.175	-0.091	0.0908	-0.1113	0.1813	-0.0033	-0.0657	0.0036	0.0265	0.0029	0.0511	0.0197	0.0135	-0.0451	0.04	0.0627	0.0071	-0.1609	-0.0889	0.0448	-0.0026	-0.0347	-0.007	-0.0448	-0.0881	0.0567	0.0473	0.0417	0.0189	0.0641	-0.052	-0.0425	0.0602	-0.0123	0.0602	0.0394
O07	-0.1758	-0.0403	0.0905	-0.0947	0.0221	0.0748	-0.1096	-0.002	0.0618	0.0244	0.0122	0.0243	0.0312	0.0417	0.0285	-0.0085	0.0005	-0.1111	-0.0226	0.1167	-0.1205	0.0436	-0.0298	-0.0321	-0.0258	-0.0857	-0.1202	0.0644	0.0718	-0.0151	-0.0113	0.0589	-0.2378	-0.1477	-0.1191	-0.0466
O08	-0.1651	-0.1265	0.0716	-0.072	0.1518	0.0341	-0.0721	-0.0677	0.0266	-0.0172	0.0561	0.0653	-0.0888	-0.0063	0.0963	-0.0065	0.0505	-0.0018	-0.094	0.037	-0.1891	0.0777	0.0219	-0.0564	-0.0468	0.034	0.0278	0.0878	0.1198	0.1274	-0.1681</					

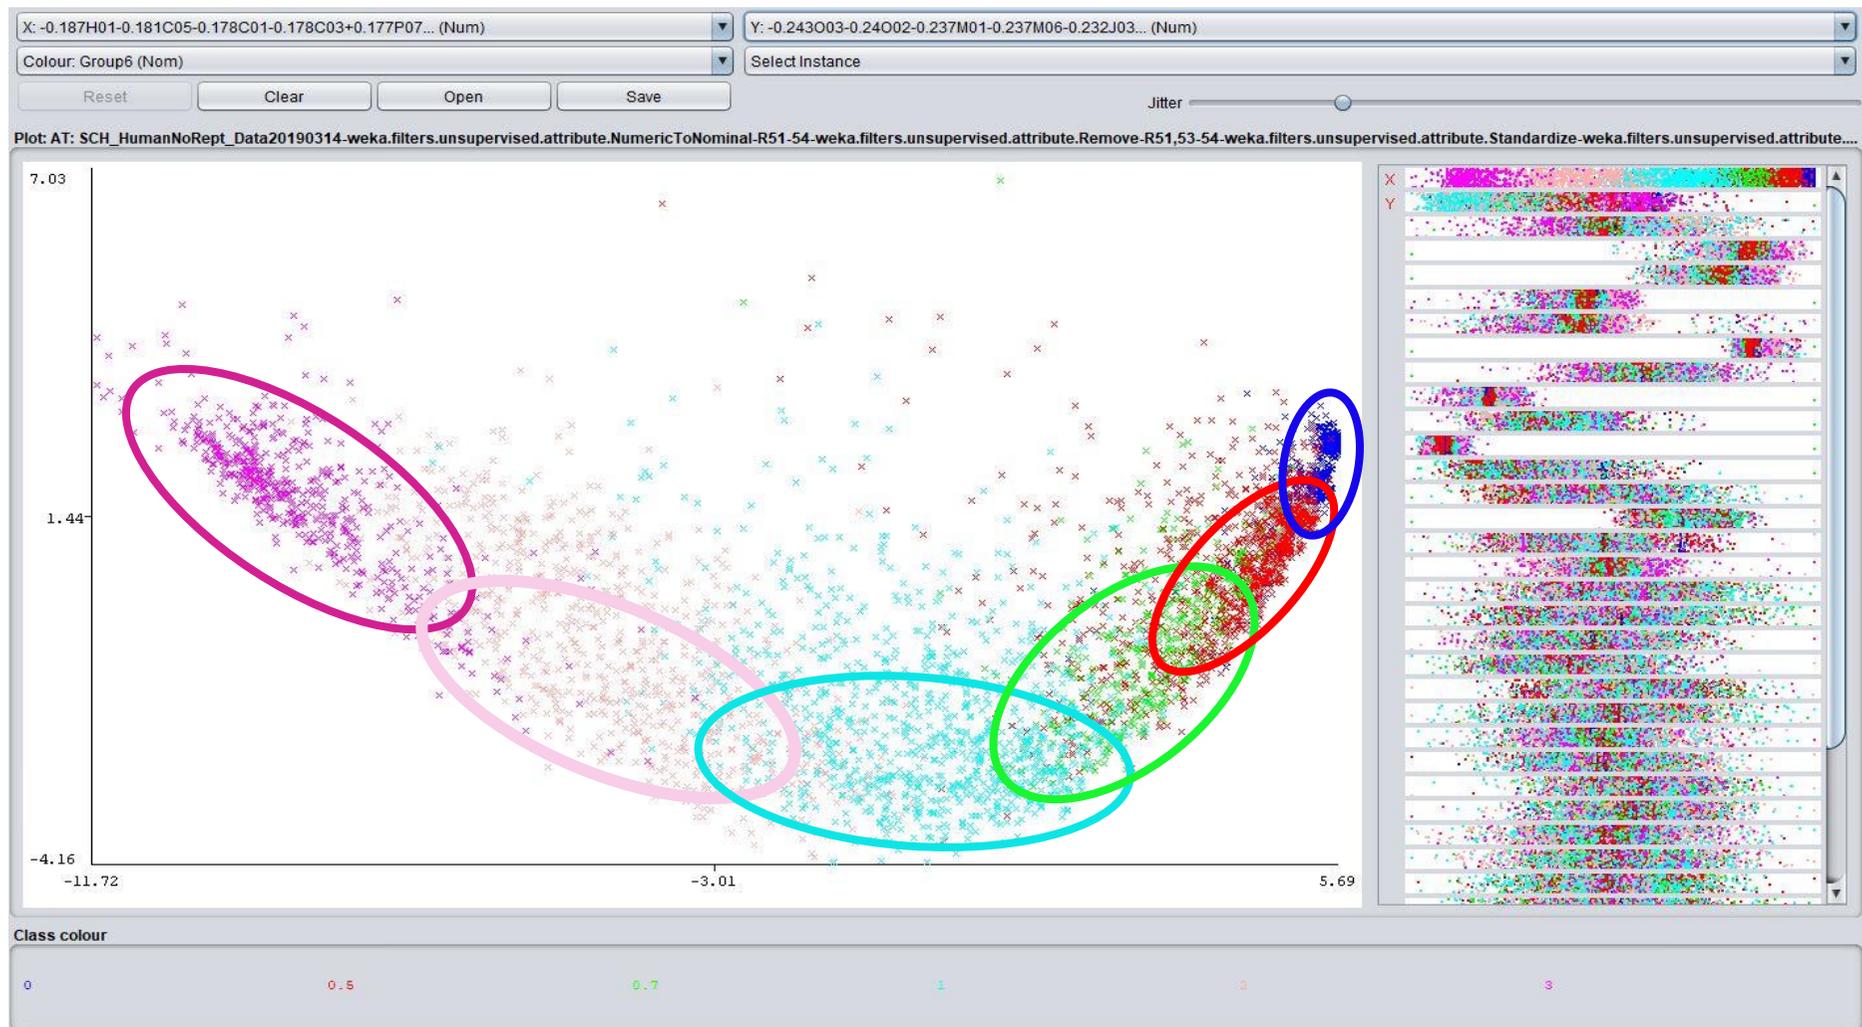


圖 4-4 特徵向量 V1,V2 對應數據圖

(4) 挑選特徵向量個數

從表 4-7 中可以觀察到特徵向量 (V1, ..., V36) 與每項特徵值、所占比例和累積比例的程度如何，圖 4-5 為累積比例示意圖。

表 4-7 六類特徵值之累積比例表

向量	Eigenvalue	Proportion	Cumulative	向量	Eigenvalue	Proportion	Cumulative
V1	23.26417	0.46528	0.46528	V19	0.50099	0.01002	0.83037
V2	3.40634	0.06813	0.53341	V20	0.47449	0.00949	0.83986
V3	1.8135	0.03627	0.56968	V21	0.46672	0.00933	0.8492
V4	1.48198	0.02964	0.59932	V22	0.44639	0.00893	0.85813
V5	1.40132	0.02803	0.62735	V23	0.43042	0.00861	0.86673
V6	1.02575	0.02052	0.64786	V24	0.41292	0.00826	0.87499
V7	0.94526	0.01891	0.66677	V25	0.39078	0.00782	0.88281
V8	0.89762	0.01795	0.68472	V26	0.37584	0.00752	0.89033
V9	0.86865	0.01737	0.70209	V27	0.36454	0.00729	0.89762
V10	0.78772	0.01575	0.71785	V28	0.35815	0.00716	0.90478
V11	0.78192	0.01564	0.73348	V29	0.34161	0.00683	0.91161
V12	0.75318	0.01506	0.74855	V30	0.32899	0.00658	0.91819
V13	0.73643	0.01473	0.76328	V31	0.32564	0.00651	0.9247
V14	0.62795	0.01256	0.77584	V32	0.32314	0.00646	0.93117
V15	0.61932	0.01239	0.78822	V33	0.31256	0.00625	0.93742
V16	0.56608	0.01132	0.79954	V34	0.30096	0.00602	0.94344
V17	0.53148	0.01063	0.81017	V35	0.28175	0.00563	0.94907
V18	0.50902	0.01018	0.82035	V36	0.27159	0.00543	0.9545

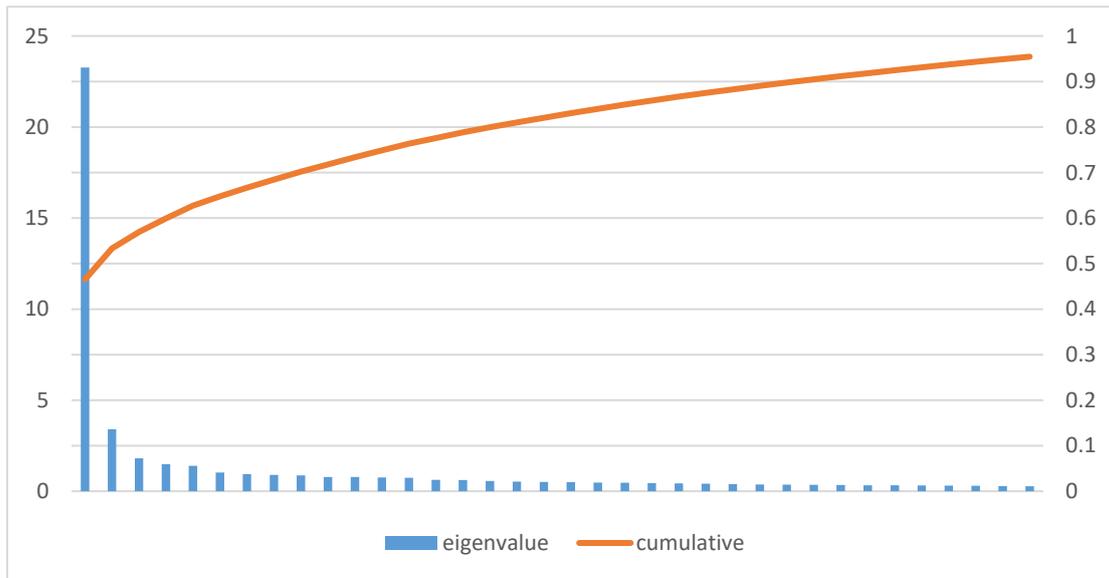


圖 4-5 各題目所占比例和累積比例圖

(5) 利用特徵向量分析問題的累積比例程度

在累積比例 95% 以內的特徵向量總共有 36 個，在(4)可以看到累積比例跟題目的對應，表 4-8 為每項特徵向量對應的絕對值的不同題目，並將有重複出現的題目刪去(以粗體刪除線表示)，篩選出 26 個題目，現實實驗裡累積比例達到 0.7 以上可說明是良好的，除了 0.7 之外，同時也實驗累積比例達到 0.75、0.8、0.85、和 0.9 的狀況，此 5 個區間是為了觀察簡化題目的過程而定，表 4-9 為挑選的分析結果。

表 4-8 六類特徵向量各問題之對應最大絕對值題目表

向量	最大絕對值	題目	向量	最大絕對值	題目
V1	0.187	H01	V19	0.556	M09
V2	0.243	O03	V20	0.595	L05
V3	0.339	C09	V21	0.356	M03
V4	0.378	L07	V22	0.642	M06
V5	0.453	L08	V23	0.424	J06
V6	0.501	C09	V24	0.497	P10
V7	0.605	L07	V25	0.454	M08
V8	0.541	M04	V26	0.502	L06
V9	0.423	L08	V27	0.458	O03
V10	0.587	L04	V28	0.534	M02
V11	0.515	M10	V29	0.488	O06
V12	0.563	L01	V30	0.520	J06
V13	0.537	M01	V31	0.493	J03
V14	0.512	J02	V32	0.455	P05
V15	0.615	M07	V33	0.647	P03
V16	0.487	M07	V34	0.479	O03
V17	0.542	O07	V35	0.634	J05
V18	0.551	J02	V36	0.731	L03

表 4-9 六類篩選問題個數結果

特徵累積	0.95	0.9	0.85	0.75
個數	28	22	17	10
問題	H01	H01	H01	H01
	O03	O03	O03	O03
	C09	C09	C09	C09
	L07	L07	L07	L07
	L08	L08	L08	L08
	M04	M04	M04	M04
	L04	L04	L04	L04
	M10	M10	M10	M10
	L01	L01	L01	L01
	M01	M01	M01	M01
	J02	J02	J02	
	M07	M07	M07	
	O07	O07	O07	
	M09	M09	M09	
	L05	L05	L05	
	M03	M03	M03	
	M06	M06	M06	
	J06	J06		
	P10	P10		
	M08	M08		
	L06	L06		
	M02	M02		
	O06			
	J03			
P05				
P03				
J05				
L03				

4.3 挑選題目比較

以 Balanced Data B 為資料集，將六類、五類、三類都做成主成分分析之後，把這些問題帶入 C4.5 with Bagging 演算法，從主成分分析法的個數挑題目來區分，為了讓準確度區分更明顯，以下取累積比例 0.95、0.9、0.85、0.75 時不同題目數量來分析 ACC、TPR 的變化過程。

(1) 6 類內部 ACC、TPR 的比較

從不同的題目數量來分別觀察 ACC 和 TPR 的變化，挑選出的問題請看表 4-6，比較結果請看表 4-10。

表 4-10 六類比較結果

類別 \ 問題	28		22		17		10	
	ACC	TPR	ACC	TPR	ACC	TPR	ACC	TPR
Normal	0.9653	0.797	0.96	0.857	0.9576	0.857	0.9447	0.692
Uncertain	0.9129	0.844	0.8546	0.731	0.844	0.736	0.8387	0.759
Incipient	0.94	0.656	0.8882	0.188	0.8864	0.088	0.9046	0.019
Mild	0.9241	0.854	0.8617	0.794	0.8399	0.784	0.8187	0.831
Moderate	0.9441	0.851	0.9023	0.666	0.8911	0.601	0.8805	0.604
Severe	0.9759	0.894	0.9682	0.908	0.9641	0.884	0.9594	0.787
Weighted Avg.	0.9373	0.831	0.8937	0.717	0.8828	0.692	0.8742	0.673

(2) 5 類內部 ACC、TPR 的比較

從不同的題目數量來分別觀察 ACC 和 TPR 的變化，挑選出的問題請看表 4-4，比較結果請看表 4-11。

表 4-11 五類比較結果

類別 \ 問題	28		22		17		10	
	ACC	TPR	ACC	TPR	ACC	TPR	ACC	TPR
Normal	0.9629	0.868	0.96	0.857	0.9564	0.852	0.9441	0.692
MCI	0.8788	0.743	0.8671	0.703	0.8593	0.7	0.8393	0.748
Mild	0.8564	0.799	0.8348	0.790	0.8181	0.771	0.8081	0.737
Moderate	0.9117	0.724	0.9036	0.666	0.8929	0.613	0.8805	0.604
Severe	0.9641	0.87	0.9688	0.913	0.9635	0.879	0.9594	0.787
Weighted Avg.	0.897	0.787	0.8857	0.767	0.8751	0.745	0.8627	0.716

(3) 3 類內部 ACC、TPR 的比較

從不同的題目數量來分別觀察 ACC 和 TPR 的變化，挑選出的問題請看表 4-8，比較結果請看表 4-12。

表 4-12 三類比較結果

類別 \ 問題	28		22		17		10	
	ACC	TPR	ACC	TPR	ACC	TPR	ACC	TPR
Normal	0.9617	0.868	0.9606	0.874	0.957	0.868	0.94	0.692
MCI	0.8782	0.741	0.8693	0.705	0.8617	0.689	0.8434	0.719
Dementia	0.9105	0.929	0.9005	0.926	0.8976	0.922	0.8976	0.912
Weighted Avg.	0.908	0.875	0.8992	0.865	0.895	0.858	0.8886	0.84

從上面 6 類、5 類和 3 類的挑選過程中，以表 4-9 為基準將挑選出來的題目做出整理，並以累積比例 75% 篩選出來的題目結果用表 4-13 做為表示。

表 4-13 篩選題目順序結果

方法	題號	題 目	回 答 選 項				
			如常	少一點點	少很多	幾乎沒有	完全沒有，整天在自己房間
PCA	H01	現在還在從事例行的活動嗎?(例如散步、念佛、到寺廟、拜拜、禱告、上教堂等)或平常的嗜好或興趣嗎?(例如跳土風舞、打牌、麻將、卡拉 Ok、槌球、與孫子女玩等)	如常	少一點點	少很多	幾乎沒有	完全沒有，整天在自己房間
	O03	記住約會的時間會困難嗎?	會	不會			
	C09	上述活動困難，病人是因肢體或行動不便	是	不是			
	L07	語言功能異常是否最早發生，而且比其他症狀早很多?	不會	會			
	L08	說話音調變得平淡，比較沒有抑揚頓挫，會越講越小聲嗎?	不會	會			
	M04	認知功能症狀起伏很大，甚至一天之內好壞就差很多嗎?	會	不會			
	L04	一直重複說同樣的字句或重複別人的字句嗎?	不會	偶爾	常常		
	M10	會緬懷過去嗎(常提過去事)?	會	不會			
	L01	說話會明顯變得不流利嗎?	不會	稍微	明顯		
	M01	認知功能(例如記憶、思考、判斷力)明顯的比以前退化嗎?	會	不會			

4.4 信度分析

考量到這些簡化過後的題目是否有可靠性，針對不同的題目數量做不同的信度分析，確保題目的篩選有意義，下列為信度結果：

表 4-14 22 問題信度分析表

Cronbach 的 Alpha	以標準化項目為準的 Cronbach 的 Alpha	項目數
.796	.843	22

	比例平均值(如果已刪除)	比例變異(如果項目已刪除)	更正後項目總計相關性	平方複相關	Cronbach 的 Alpha (如果項目已刪
M01	9.514	29.462	.407		.788
M02	10.188	28.308	.592		.779
M03	9.811	27.459	.640		.774
M04	10.280	29.998	.264		.792
M06	9.746	27.767	.565		.777
M07	9.620	28.640	.489		.783
M08	9.906	27.353	.652		.773
M09	9.766	28.488	.443		.784
M10	9.924	28.308	.462		.782
O03	9.792	27.421	.653		.773
O07	10.263	28.941	.448		.785
J02	9.999	27.555	.574		.776
J06	10.047	27.470	.665		.773
C09	10.328	30.867	.031		.798
H01	9.453	22.886	.746		.753
P10	8.896	36.787	-.687		.854
L01	9.854	25.229	.246		.829
L04	10.317	29.927	.272		.792
L05	10.026	27.892	.567		.778
L06	9.878	26.449	.546		.774
L07	10.377	30.898	.071		.797
L08	10.254	29.600	.344		.790

表 4-15 17 問題信度分析表

Cronbach 的 Alpha	以標準化項目為準的 Cronbach 的 Alpha	項目數
.788	.823	17

	比例平均值 (如果項目已 刪除)	比例變異(如果 項目已刪除)	更正後項目總 計相關性	平方複 相關	Cronbach 的 Alpha (如果 項目已刪除)
M01	6.467	20.834	.41	.	.779
M03	6.764	19.197	.633	.	.762
M04	7.233	21.297	.267	.	.785
M06	6.699	19.459	.556	.	.767
M07	6.573	20.172	.486	.	.773
M09	6.719	20.052	.436	.	.775
M10	6.877	19.869	.463	.	.773
O03	6.745	19.174	.644	.	.762
O07	7.216	20.501	.422	.	.777
J02	6.952	19.294	.561	.	.766
C09	7.281	21.996	.052	.	.792
H01	6.406	15.438	.731	.	.740
L01	6.807	17.171	.235	.	.845
L04	7.270	21.289	.257	.	.785
L05	6.979	19.577	.555	.	.768
L07	7.329	22.093	.058	.	.791
L08	7.207	20.953	.349	.	.781

表 4-16 10 問題信度分析表

	Cronbach 的 Alpha	以標準化項目為準的 Cronbach 的 Alpha	項目數
	.562	.625	10

	比例平均值 (如果項目已刪除)	比例變異 (如果項目已刪除)	更正後項目 總計相關性	平方複相 關	Cronbach 的 Alpha (如果 項目已刪除)
M01	2.952	7.724	.311	.188	.536
M04	3.717	7.836	.260	.096	.544
M10	3.362	7.229	.342	.256	.518
O03	3.229	6.907	.485	.426	.488
C09	3.766	8.222	.081	.019	.566
H01	2.891	4.903	.564	.459	.402
L01	3.292	4.694	.244	.085	.647
L04	3.755	7.845	.240	.079	.546
L07	3.814	8.323	.079	.029	.566
L08	3.692	7.627	.340	.144	.531

由上圖所示，在 22 題目和 17 題目時，以標準化項目為準的 Cronbach Alpha 值在 0.7 以上，代表此題數問卷有中上信度，具有良好的明確目標(失智症診斷)，但在 10 題目時低於 0.7，代表此題數問卷是中下信度，題目診斷的正確率會比前兩者還要低，因此建議使用此版本的問卷時簡化到 17 個題目時仍保持一定的診斷依據。

第五章 結論

5.1 討論與結論

本論文提出以不同機器學習的演算法，針對問卷量表與醫師診斷進行分類研究，量表問題共有 50 題，除了 CDR 常見的六個領域的問題：記憶力、定向感、判斷與問題解決、社區事務、家居生活與嗜好、個人自理能力外，加入 8 題語言能力領域的問題。

所針對的數據共有 6701 筆(Data A)，若扣除第一次就診後的數據，則為 4248(Data B)，因此形成兩組數據進行研究。再依據失智症的嚴重程度，分成 6 類(NMD6)、5 類(NMD5)與 3 類(NMD3)等分群進行研究。因此實測的資料集有六種。

首先測試不同的機器學習的分類器之效果，經過測試單純貝氏分類法、多層感知器、以決策樹為分類器的引導聚集算法、支持向量機等演算法，針對問卷量表與醫師診斷進行分類研究，除了單純貝氏分類法外，其他分類器的靈敏度 (TPR) 均超過八成五以上，本論文最後選定以決策樹為分類器的引導聚集算法最後後續研究的主要方法。

從 3 類(NMD3)的數據由於正常的數據量相對少很多，為典型非平衡數據，本文利用 SMOTE 的方法，進行數量提升 10% 進行測試，

測試結果雖有改善，但對於 ACC 與 TPR 效果都小於 1%，因此後面主成分分析時，就沒有考慮進行數據調整。

本論文最後透過主成分分析，以瞭解主要特徵向量的組成，從中挑選一些主要題目，進行量表問卷的簡化，再透過信度分析，計算 Cronbach α 參數，分析簡化题目的信度。

本論文的主要結論歸納說明如下：

1. Data A 和 Data B 的 ACC 比較表時，兩者的任何演算法都接近九成甚至快到九成五，特別是 C4.5(Bagging)學習方法在簡化分類上有改善程度最高的幅度，跟其他三種學習方法比較起來更有實質意義。六分類的部分在簡化成五類和三類的時候，雖然準確度的部分五類 ACC 降低可能是受到 Uncertain Dementia 和 Incipient Dementia 的數據(不確定和初期病例不容易定義)所影響，導致雖然類別靈敏度提高但整體準確度降低的狀況，但在靈敏度的角度上有明顯增加的趨勢，這點說明以決策樹為分類器的引導聚集算法的學習效果對於邱醫師改良過的 CDR 來說，有更正確的病症程度診斷，確實達到論文所希望的目標。
2. 以判斷 ACC 和 TPR 的過程當中可以很清楚的看到演算法在分類 Uncertain dementia 和 Incipient dementia 的時候比其他類別有較低的現象，代表此量表在分析正常(Normal)和確定失智症(Dementia)

的部分確實有貼近現實的狀況高達九成，在 MCI 的部分跟其他兩類比較起來準確度較不理想，未來此量表或許有更多的改善空間。

3. 在選擇特徵向量的重要題目時，在不同分類的不同累積比例比較表中可以發現，CDR 中的語言相關性問題八題當中有四題排進挑選題目的前十名，甚至在累積比例 95%中所挑選出來的題目其中有六個題目跟語言有相關，代表語言相關性題目有相當重大的比重影響到失智症診斷分類的情形。

5.2 未來展望

在台灣失智症的醫療措施策略上，在失智症病例的數據真的需要更多延伸的研究方向，無論是在不同的細分分類上、或是在診斷時間上的考量和憑據，都希望有越來越進步成長的趨勢，讓醫療資料庫有更完善的診斷資料和就醫機制，而且如果在收集數據資料的時候如果能盡量以不侵犯病人隱私的條件之下貼近現實數據，那麼對於未來想要研究學習此方面的研究人員來說，有更多拓展不同領域的空間，具有許多發展的潛力。

在設計量表題目的部分，因為失智症有不同的症狀原因，若能在數據中知道各不同失智症的嚴重程度，問卷更能對應到不同病例的情形，並且在挑選題目的方法上有更多改良的空間。

在機器學習的方法上，在進行處理不同類別的非平衡數據來說可以有許多改良的方式，因為非平衡數據的情形實在太多。若能在確保內部訓練資料的平衡性之下設計不同失智症對應的函數模型，或是延伸失智症類別的比對和討論研究，在不同類別是否能找到更多的關係，針對不同類別的量表有不同的相對關係，都是未來可以思考的目標。



參考文獻

- [1] 內政部統計處 (2015-2018)，內政統計通報。
- [2] 台灣法人失智症協會 <http://www.tada2002.org.tw/>
- [3] 李孟昭 (2016)，結合特徵選取與資料探勘技術於阿茲海默症之辨識及決策規則，國立雲林科技大學工業工程與管理系碩士論文。
- [4] 廖育民 (2017)，應用貝氏分類於失智症臨床初期診斷，逢甲大學應用數學系碩士論文。
- [5] Ningthoujam Avichandra Singh (2018)，Medical Data Assessment and Classification Based on Fuzzy Neural Network，國立台北科技大學電資學院博士論文。
- [6] 張盛彥 (2017)，利用決策量表的機器學習進行老年失智症之分類研究，東海大學應用數學系碩士論文。
- [7] 台灣精神醫學會(譯者與審定，2014年)，DSM-5 精神疾病診斷準則手冊，台灣台北市，合計圖書出版公司。
- [8] Ronald C. Petersen, Glenn E. Smith, Stephen C. Waring, DVM, Robert J. Ivnik, Eric G. Tangalos, Emre Kokmen (1999) “*Mild Cognitive Impairment Clinical Characterization and Outcome*”, Archives of Neurology, Vol. 56, No. 3, pp. 303-308.
- [9] J. Ross Quinlan (1992) *C4.5: Programs for Machine Learning*, San Mateo, CA: Morgan Kaufmann.
- [10] Leo Breiman (1996) “Bagging predictors”, *Machine Learning*.
- [11] Harry Zhang (2004) “The Optimality of Naive Bayes”, Fredericton, New Brunswick, Canada.
- [12] Rosenblatt, Frank (1961) *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Spartan Books, Washington DC, pp. 313-315
- [13] John Platt (1998) *Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines.*, pp. 363-392
- [14] Nitesh V. Chawla, Kevin W. Bowyer, Lawrence O. Hall, W. Philip Kegelmeyer (2002) *SMOTE: Synthetic Minority Over-sampling Technique*.

- [15] 羅積玉 (1989)，多元統計分析方法與應用，科技圖書股份有限公司，台北。
- [16] 吳統雄 (2018)，態度與行為研究的信度與效度：理論、應用、反省，原刊【民意學術專刊】，1985。
- [17] 邱百誼、魏誠佑、洪光威 (2019)。人工智能臨床病史診斷失智程度與類型問卷的初步成效。秀傳醫學雜誌，18(1)，18-26。
- [18] 張乃楠 (2018) 基於混和方法探究不平衡數據分類問題，元智大學資訊工程學系碩士論文。
- [19] 徐芳玲 (2002) 以主成分分析應用在決策數名目數性質之二元分割上，國立成功大學資訊管理系碩士論文。
- [20] 凌士雄 (2004) 非對稱性分類分析解決策略之效能比較，國立中山大學資訊管理學系碩士論文。
- [21] 陳蓓韻 (2013) 驗證失智症篩檢量表第二版在台灣樣本之適用性，長庚大學職能治療學系行為科學碩士班臨床心理學組碩士論文。
- [22] 賴奕璋 (2014) 磁共振造影影像切割與擴散張量影像量化之決策樹分析-以失智症患者為例，國立雲林科技大學工業工程與管理系碩士論文。
- [23] 許意絃 (2007) 輔助冠狀動脈心臟病診斷之邏輯斯迴歸、決策樹、類神經網路及複合分析模型效能比較，國防醫學院公共衛生學研究所碩士論文。
- [24] 袁梅宇 (2014) 數據挖掘與機器學習－Weka 應用技術與實踐，清華大學出版社，北京。
- [25] Ian H. Witten, Frank Eibe, Mark A. Hall. (2011) “*Data Mining – Practical Machine Learning Tools and Technique.*”
- [26] Chi-Mo Lin, Guang-Uei Hung, Cheng-Yu Wei, Ray-Chang Tzeng, Pai-Yi Chiu. (2018) “*An Informant-Based Simple Questionnaire for Language Assessment in Neurodegenerative Disorders*”

附 錄

1. 此論文研究的臨床失智症量表 (CDR)，由邱百誼醫師提供，問題敘述如下：

題號	題 目	回 答 選 項			
		會	不會		
M01	認知功能(例如記憶、思考、判斷力)明顯的比以前退化嗎?	會	不會		
M02	會忘記配偶或子女的名字嗎?	會	不會		
M03	認知功能退化已經影響到日常生活、社交與工作嗎?	會	不會		
M04	認知功能症狀起伏很大，甚至一天之內好壞就差很多嗎?	會	不會		
M05	會常常遺失或找不到東西嗎?	常常	不會或偶爾		
M06	會常常忘記最近講過的話嗎?	常常	不會或偶爾		
M07	學習如何使用工具、設備會覺得困難嗎?(新)	會	不會		
M08	會常常忘記最近發生的事嗎?	常常	不會或偶爾		
M09	會重複問相同的問題或講同樣的事情嗎?	會	不會		
M10	會緬懷過去嗎(常提過去事)?	會	不會		
M12	會忘記很熟的事嗎(如籍貫、住址、職業)?	會	不會		
O02	會忘記正確的年份和月份嗎?	會	不會		
O03	記住約會的時間會困難嗎?	會	不會		
O05	在熟悉的環境(例如住家附近)會迷路嗎?	會	不會		

O06	會搞不清楚自己在哪裡嗎?	會	不會			
O07	會常常認錯人,如把兒子當成丈夫,把女兒當姊妹嗎?	常常	不會或偶爾			
J01	應對進退(例如參加親朋好友婚喪喜慶)常常有不適當言行舉止嗎?	會	不會			
J02	判斷力常常產生困難嗎?(例如陷入圈套、騙局、買不適當的禮物)	常常	不會或偶爾			
J03	處理複雜的財務(上銀行、繳費、開支票)會困難嗎?	會	不會			
J04	會覺得工作能力或職業技術變差了嗎?	會	不會			
J05	處理家裡內外大大小小事物會困難嗎?	會	不會			
J06	操作日常生活用品明顯比以前困難嗎?(例如使用電話、遙控器、或微波爐等)	會	不會			
C01	上街購物(外出逛街買禮物、買菜等)	獨力完成	每一次上街購物都需要有人陪或完全不會購買			
C02	金錢處理能力	正常	可以處理日常的購買,但需要別人協助與銀行往來或不能處理錢財			
C03	使用電話的能力,例如打電話或接電話	正常	只會接電話不會撥電話或完全需要協助			
C04	食物烹飪(或準備一桌菜例如做菜、點菜或外燴)	正常	需要別人把飯菜煮好、擺好或點好			

C05	家務維持(簡單家事如收拾房間、打掃)	正常	所有的家事都需要別人協助			
C06	洗衣服(或處理個人的信件如寄信收信)	正常	完全依賴他人			
C07	外出活動(搭車或騎、開車到目的地)	正常	需要協助或陪同			
C08	自行服用藥物	自行搭車或騎、開車	如果事先準備好服用的藥物份量，可自行服用或不能自己服用藥物			
C09	上述活動困難，病人是因肢體或行動不便	是	不是			
H01	現在還在從事例行的活動嗎?(例如散步、念佛、到寺廟、拜拜、禱告、上教堂等)或平常的嗜好或興趣嗎?(例如跳土風舞、打牌、麻將、卡拉 Ok、槌球、與孫子女玩等)	如常	少一點點	少很多	幾乎沒有	完全沒有，整天在自己房間
P01	進食	自己在合理時間可用筷子取食眼前食物	需別人幫忙穿脫進食輔具或只會用湯匙進食	無法自行取食或耗費時間過長		
P02	輪椅與床位間移位	可獨立完成	需要稍微協助或口頭指導	可自行從床上坐起，但移位時仍需別人幫忙	別人幫忙方可坐起來為一位(7d)	

P03	個人衛生	可獨力完成 洗臉、洗 手、刷牙及 梳頭髮	需要別人幫忙			
P04	上廁所	可自行如廁 及整裝，不 會弄髒衣物	需幫忙保持平衡，整 理衣物或使用衛生紙	需要別人 幫忙		
P05	洗澡	可獨立完成	需要別人幫忙(6b)			
P06	上下樓梯	可自行上下 樓梯	需要稍微幫忙口頭指 導	無法上下 樓梯		
P07	穿脫衣服	可自行穿脫 衣服、鞋子 及輔具	在別人幫忙下，可自 行完成一半以上的動 作	需別人幫 忙(6a)		
P08	行走於平地五十公尺以上	可獨立行走	需要稍微扶持或指導	雖無法行 走，但可 獨立操縱 輪椅	需別人幫忙 (7c)	
P09	大便控制	不會失禁， 並可自行使 用塞劑	偶爾失禁或需人幫忙 使用塞劑(6e)	需別人處 理		
P10	小便控制	日夜皆不會 尿失禁	偶而尿失禁或需人幫 忙處理(6d)	需別人處 理		

L01	說話會明顯變得不流利嗎?	不會	稍微	明顯		
L02	聽不懂別人的話，好像雞同鴨講嗎?	不會	偶爾	常常		
L03	語意表達困難，無法完整地講一個句子嗎?	不會	偶爾	常常		
L04	一直重複說同樣的字句或重複別人的字句嗎?	不會	偶爾	常常		
L05	說話變得很少嗎?	不會	會			
L06	想要講某個名詞例如人名或物名卻常常講不出來嗎?	不會	偶爾	常常		
L07	語言功能異常是否最早發生，而且比其他症狀早很多?	不會	會			
L08	說話音調變得平淡，比較沒有抑揚頓挫，會越講越小聲嗎?	不會	會			

