

從學習歷程記錄檔動態建構決策樹以支援適性化教學

陳芸霽

謝盛文

陳年興

國立中山大學資訊管理學系 國立中山大學資訊管理學系 國立中山大學資訊管理學系

fredia@elearning.nsysu.edu.tw onyxhsw@cc.nsysu.edu.tw nschen@cc.nsysu.edu.tw

摘要

網路學習的發展與成熟，透過學習者在教學網站參與各項教學活動過程中所記錄下來的學習歷程檔案，可以幫助教師有效的掌握學習者的學習狀況。為了將這些儲存每個學習者的學習動作之網頁日誌轉換成具教育意義的資訊，以幫助教師能夠即時觀察學生的學習狀況。並提供整合多個維度的觀察方式，讓教師可即時觀察學生所有的學習行為及學習狀況。本研究提供一個整合性的分析機制，可以利用現有的學習歷程檔案，整合多個觀察維度分析出學生的學習行為，並用決策樹分析預測出可能發生學習困難的學生，讓教學者可以即時的給予適當的教學輔助。

關鍵詞：適性化教學、學習歷程記錄檔、資料探勘、決策樹分析、網路教學

一、研究背景與動機

隨著網際網路的普及與資訊科技的進步，以資訊數位化的方式來進行知識的傳授與共享已經成為必然的趨勢，其中利用網路教學的方式也是主要的應用之一。網路教學打破了時空的限制，讓教師與學生可以在網路上進行與傳統教學相近的教與學活動。其最大的好處是可以在不影響學生進行學習的情況下，方便的記錄所有與學生相關的學習行為資訊。對教師而言，這些學習資訊除了可以用來檢視學生的課程表現及學習情況外，亦可做為教師在教材編排、教學策略製定及教學活動設計之參考(劉惠如，1999)。然而對於教師而言，這些網頁日誌資訊雖然完整記錄了學生所有的學習行為，也能確實的反映出學生在課程中所有的表現及學習情形，但是這些網站日誌並不是針對教育用途而設計，教師並不易從這些記錄中了解學生各種學習行為與教學策略的關係，所以教師很難從學習歷程中推導學生的學習活動效能進而制定有效的教學活動及教學策略。換而言之，教師在進行網路教學時並無法直接根據學生目前即時的學習狀況偵測出學習是否有效(劉晨鍾，2000)。這種教學上的決策資訊除了可以反映出學生的學習情形與學習成效的關係之外，也可以了解教師的教學特

色以及班級經營的方式。而若能從這些資料中找出對於教師有幫助的決策資訊，將更能協助教師掌握學生在修課過程中的學習情形，以及針對學生不同的學習狀況進行個別化的教學。因此，本論文的研究議題便是如何將這些儲存著各個學習動作的網頁日誌轉換成具教育意義的資訊，以幫助教師能夠即時觀察學生的學習狀況。並提供教師立即性與直接性的以多個維度的觀察學生所有的學習行為。針對這些問題，本研究將提供一個整合性的分析機制可以利用現有的學習歷程記錄，以多個觀察維度分析出學生的學習行為，並預測出可能發生學習困難的學生以即時的給予適當的教學輔助。研究中將分析後的學生學習行為資料作為資料探勘中決策樹分析的輸入變項，再加上以學生成績作為學習成效指標的分類方式，進而找出學習行為與學習成效間的關係，並進一步作分析及預測(林清賀，1998；呂靜芳，1999；倪家祥，2000)。

本研究將利用中山大學資管系網路碩士學分班第五期、第六期、以及第七期資料共十八門課程做為本研究的資料來源，並以學期與課程為單位做為分析對象。但是由於資料來源並不完整，因此本研究將針對其中單一課程(eLearning 理論與實務)不同期的資料(第六期及第七期)做為本研究的驗證對象；先用第六期資料做為訓練資料找出決策規則，再用第七期資料做為測試對象以驗證找到的決策規則是否有效以及有效程度為何，並用相同的決策樹軟體進行驗證。

二、文獻探討

本研究的主要目的在於提供教師輔助決策資訊，以輔助教師在教學時能夠即時知道學生的學習狀況，並針對不同學習行為的學生給予不同的教學或輔助。因此，首先探討目前對於學習歷程記錄與相關的研究，以了解如何應用學生學習歷程記錄於網路教學平台的相關研究。接著探討有關影響學習者的學習型態與學習成效之關係的相關研究與歸納，藉以了解目前影響學習者不同的學習型態與學習成效的關係；並針對學生學習活動、學習時間與學習成效之關係做說明，藉此了解學習者在網路學習環境中的個人學習狀況。最後也針對本研

究使用的資料分析方法之相關理論與應用進行說明，包括了資料探勘的相關理論以及決策樹分析的基本原理和延伸的演算法理論，做為本研究在進行資料分析時的依據。

(一) 學習歷程記錄與相關研究

過去有關網路上學習歷程記錄的研究，多是分析網站所記錄的網頁日誌資料以獲取決策性資訊的研究，例如 WebWatcher 可以記錄與分析使用者的網頁日誌的資料，藉由對過去系統使用者留下的記錄進行資料分析與運算，以決定哪些網頁是使用者最常去，或是根據使用者的使用模式，找出下一個最可能連結的網頁推薦給使用者 (Joachims, T., 1998、Freitag, D., Mitchell, T. etc., 1998)。另外 Fuller, R. (2002) 提出可以藉由統計驗證使用者花在網頁上的時間來評估使用者對網頁的興趣，來改善網站的網頁架構。此外也可以利用網路的流量分析 (例如用 MRTG, The Multi Router Traffic Grapher)，或是教學網站中如果有提供已經整理過的資訊 (例如同班同學資訊、各項學習指標的排名等方式) 呈現整體班級的學習情形。諸如此類的研究，都是藉由分析網頁日誌記錄，得到系統運作情形或使用者活動趨向等資料。但是上述研究多僅能呈現學習情形，並無法針對這些學習情形即時的給予老師對於學生有一些直接且易讀的教學資訊，因此必須要運用其他資料分析方法來針對這些資料做分析。因此，本研究利用資料探勘技術從大量網頁日誌中的學習記錄中嘗試探勘出一些決策性的規則，並依造不同時間點下進行規則分析，以期能即時的瞭解學生的學習情形並給予適時的輔助。

(二) 資料分析方法之相關理論

本研究利用分類分析的方式，從學習歷程記錄中以不同的分類方式對學生的學習成效 (此即為學生的學期成績) 做分類，並針對學生過去在網站上的學習歷程與學習成績等資料進行分類分析來分析資料。教師可決定哪些決策規則可以再利用，並回饋至系統中。而本研究也將用上述的分析步驟進行資料分析，而在採用資料探勘分類分析方法前亦會對資料進行前置處理，從大量資料中取得學生學習行為相關屬性。研究中所利用的分類分析技術為決策樹分析法。以下針對決策樹相關的基本概念做一說明。決策樹是一棵語意樹 (Semantic Tree)，他與一般的資料結構中的樹一樣有節點與樹葉，每一個節點都被安排一個適當的測試，然後利用該測試結果決定資料並將再利用此一節點的哪一棵子樹作為分類的條件繼續做決策，最後透過節點中的測試達到問題分析

的目的 (邱美珍, 1996)。本研究所採用的決策樹演算法是由 Quinlan 於 1993 年所提出的 C4.5 學習法，它的基本理論是改良自他於 1986 年所提出的 ID3 學習系統。近年來新發展的歸納學習方法，大多改良自 C4.5 學習方式或與其比較學習效能，它幾乎已變成目前歸納學習法中的標準學習法。C4.5 的學習方法是利用消息理論 (Information Theory)，而以歸納學習的方法建構決策樹的一種過程。其中包括下列三種步驟：由訓練資料建構決策樹、決策樹的修剪 (Prune)、從決策樹中產生學習規則。以下將對此三種步驟作一詳細說明。

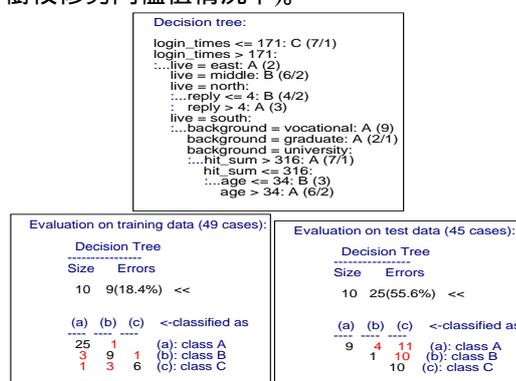
首先為建構決策樹，C4.5 學習方法的首要就是從訓練資料中建構決策樹，其基本概念可以追溯至 1950 年代末期的 Hoveland 及 Hunt 二位學者提出的理論。簡單說明如下：假設一組訓練資料所組成的集合 S 中有 K 種類別 (Class)，即 $S = \{C_1, C_2, C_3, \dots, C_k\}$ 。一般我們在給定訓練資料時，會有多種決策樹可以正確的將資料分類，因此如何找出一最小而能正確的分類的決策樹便在於分類屬性的考量。而本研究所採用的 C4.5 是由其前身 ID3 學習法改進而來。在 ID3 中分類屬性的選擇標準稱為 gain，其基本作法是根據消息理論為基礎，它是測量資訊量多寡來計算各個類別的資訊量，並進而計算出該訓練集合的平均資訊量，也就是所謂的亂度 (Entropy) 來表達該集中資料的複雜度。假設訓練資料形成得集合 S 中有 n 種類別 $C_i, i = 1, 2, 3, \dots, n$ ，每個類別的資料個數以 $freq(C_i, S)$ 表示， $|S|$ 代表 S 中所有資料的個數，因此各個類別其資料出現機率可表示為 $\frac{freq(C_i, S)}{|S|}$ ，因此根據消息理論，各個類別的資訊為 $-\log_2\left(\frac{freq(C_i, S)}{|S|}\right)$ ，訓練集中包含各個類別的訓練資料，由各類別的資訊量可以計算出訓練集合的平均資訊量 (即亂度)，為各個類別的資訊量乘上各個類別資料的出線機率總和為： $info(S) = -\sum_{i=1}^n \frac{freq(C_i, S)}{|S|} \log_2\left(\frac{freq(C_i, S)}{|S|}\right)$ 。根據 $info(S)$ 的計算方式，當集合 S 根據某個屬性 A 分割成多個子集合 $S_1, S_2, S_3, \dots, S_m$ 時，其分割後所佔的資訊量等於各個子集合的資訊量乘上各個子集合所佔的比例的總和： $info_A(S) = \sum_{i=1}^m \frac{|S_i|}{|S|} \times info(S_i)$ 。因此集合 S 經由屬性 A 分割後所獲得的資訊量則為分割前的資訊量減去分割後的資訊量，表示為： $gain(A) = info(S) - info_A(S)$ 。而 ID3 學習系統選擇分類屬性的方法即計算所有屬性的 gain 值，並選擇其中 gain 值最大的做為分類屬性。決策樹以此屬性的屬性質分割成多個訓練子集合，形成多個樹。各個子樹重複上述步驟尚未被選為分類的屬性中在找出 gain 值最大的作為分類屬性，在分割成多個子樹直到不能再

分為止。ID3 選擇分類屬性的方法對於一般學習問題已經有不錯的結果，但是當分類條件較偏向分出的子集合較多的屬性，其中最特殊的便是當集合 S 分割後的子集合都只有一個資料時，其分割後的資訊量為零，因此所或的的資訊量最大。然而此種分割並沒有太大的意義。為了彌補這種缺點，Quinlan 在 C4.5 中提出將 gain 正規化的方法以緩和分成過多子集合的效應。正規化的方法是利用將原有的 gain 值除以 split info(A) 的值，即 $gainratio(A) = gain(A) / split\ info(A)$ ，其中 $split\ info(A) = -\sum_{i=1}^{|S_i|} \frac{|S_i|}{|S|} \times \log_2 \frac{|S_i|}{|S|}$ 可代表集合透過屬性 A 分割的子集合個數指標，分割後的子集合個數越多 split info 的值就會越大，相對的 gain ratio 的值就偏小。因此利用 split info 使得 C4.5 學習系統改善了 ID 分類偏向多子集合的缺點。

第二步為修剪決策樹，在建構決策樹的程序中，有二個停止的條件：一個是分割後的每個子集合中的資料都屬於同一種類別。第二個則是子集合中已經沒有任何資料可以改進。因此當資料不完整、過於稀疏或是含有雜訊時，利用此種方式所建構的決策樹通常過於配合資料(Over-fits the Data)，以致於所產生的決策樹太過於複雜，因此在利用 C4.5 建構決策樹後還需要做適當的修剪。C4.5 修剪過程的標準是根據預估錯誤率的值作為判斷條件。它的方法是從樹的底部(樹葉)往上測試每一個節點所形成的子樹，若是將子樹以一個樹葉代替後所得到的錯誤預估率較低，則將子樹修剪成為樹葉，否則將保留原來的子數。所謂錯誤預估率是指由現有訓練資料的錯誤比率來評估其他非訓練資料的錯誤比率。更明確的說，假設被分類於某一子樹的所有訓練資料個數為 N ，其中有 E 個訓練資料分類錯誤，而錯誤預估率就是由 E/N 來評估當有新的資料被測試時利用此一條件判斷結果為不正確的機率值。計算錯誤預估率的方法有數種，C4.5 學習系統的預估錯誤率是採用 (N, E) 二項式分配的機率值，其作法是給定一個可信度(Confidence Level, CF)，簡單的以其二項式分配機率的上限值來作為預估錯誤率的值，寫為 $U_{CF}(E, N)$ 。其中 N 是所有訓練資料中屬於此子樹的個數，而 E 則是 N 中分配錯誤的資料個數。因此預測錯誤的資料個數則為 $N \times U_{CF}(E, N)$ 。

最後是由決策樹中產生規則，在建立決策樹的分類模型後，我們的直覺是要達到正確的預測，但是除此之外我們還會希望進一步建立類似人類智慧的分類模型。換句話說，分類模型除了要具有高正確率之外最好也能夠擁有簡單易懂的規則。C4.5 學習方法在建立了決策樹之後又將決策樹轉換成更簡單的規則以降低判斷資料類別的複雜度。由決策樹產生規

則最簡單的方式便是將決策樹中的每一個樹葉根據其路徑建立一條規則，然而此種方法所產生規則的複雜程度與原來的決策樹一樣，並沒有做任何的改進。而 C4.5 利用產生規則的過程中做了一次簡化的步驟，以仔細評估每一個條件在規則中的必要性，讓建立規則所使用的條件最精簡，但又不造成錯誤率過高。本研究所要分析變項中有關學習行為的所有屬性值為連續型的資料屬性，而有關學習行為的屬性個數非常多，因此本研究即是以決策樹演算法以用來找尋影響學生在進行網路學習時影響學習成效的變項有哪些，圖一即為以課程『elearning 理論與實務』第六期、第七期為訓練資料與測試資料，並利用 C4.5 所得到的決策規則(以均值+0.5 標準差的分類方式，35% 樹枝修剪門檻值情況下)。



圖一、elearning 理論與實務的決策規則

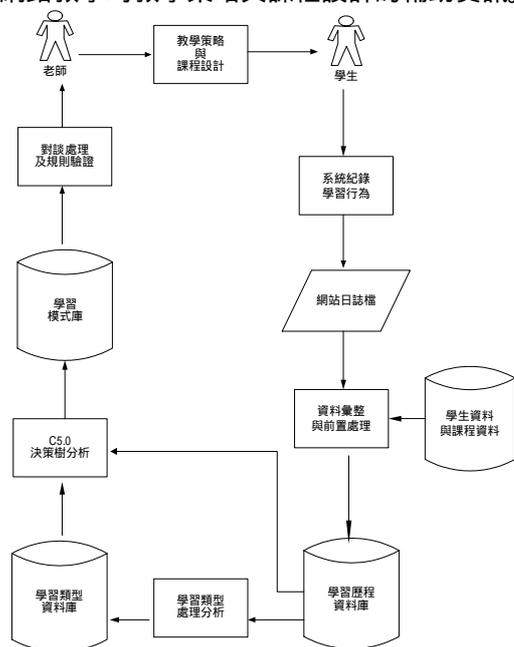
三、研究架構

藉由文獻探討，了解在網路上進行教學，不但學生的上課方式比傳統教學較具彈性，更可以利用網站主機自動且完整的記錄學生在網站上的學習活動。當學生在網站上進行學習活動時，所有的學習動作都會被完整的記錄在網路教學平台的網頁日誌裡。雖然網頁日誌已將使用者的學習動作依照時間先後順序一筆一筆完整記錄，然而，網頁日誌裡的學習記錄若未經分析及整理，仍然只是一些大量而且沒有意義的資料，無法轉為有用的資訊，因此本研究將從網頁日誌裡萃取出與學習記錄有關的部份資料，再利用資料探勘技術對這些資料進行分類與分析，以提供教師關於學生學習行為與學習成效間的關係與相關程度，並讓教師能從學生過去的學習行為中，進一步即時的預測目前及未來學生可能的各種學習情形，並適時的給予學習輔助或調整教學策略。

(一)研究架構與變數

本研究分析資料的方式，是從已經前置處理過的學習歷程檔案資料庫中，以學生的基本

資料，以及學生在網站上的學習記錄之各個屬性做為本研究的分析變項，這些屬性值包括名目尺度(性別、學歷等等)與等距尺度(上課次數、線上討論次數等等)。首先，透過資料探勘中分類分析的方式找出這些分析變項對於不同的課程、不同學習成效的學生所產生的各種意義，以及各個分析變項之間可能的關係。接著，利用決策樹軟體進一步從學習歷程記錄中找出學生的各種學習行為屬性與學習成效之間的決策規則，並透過與過去歷史資料及現有資料來驗證這些決策規則是否可適用不同的學期。最後，由教師驗證這些決策規則是否的確能反應教師對於該門課的授課方式，以評估這些決策規則是否有效，以做為教師在進行網路教學時教學策略與課程設計的輔助資訊。



圖二、研究架構圖

圖二說明了教師如何在網路教學系統上利用學習歷程檔案來分析與觀察學習行為。學生在教學網站上進行學習的動作，包括登入網站、瀏覽教材、參與線上討論、點選並閱讀文章、張貼及回覆文章等等，均被系統記錄於網站的日誌檔。由於日誌檔的記錄過於零散，因此，對於教師或是學生來說不具備實質的意義與幫助，必須再結合學生的基本資料檔及課程資訊與學生關係的課程資料庫的資料，經過前置的處理以及資料彙整處理後，才能進一步建立描述每門課程中每個學生學習行為的學習歷程資料庫，以做為往後快速查詢各門課程中學生即時學習情形的參考依據。因此，研究中利用所分析的變數共分有十二個屬性，可分為兩個部份，一個是學生的社會人口變項，另一個是學生在網站上的學習行為變項。其中社會人口變項包括了學生的性別、年齡、學歷以及

居住地區等，茲分述如下：1.性別：分為男、女兩種屬性值。2.年齡：此一屬性值為連續型資料。3.學歷：分為專科技術學院、大學、研究所三種屬性值。4.居住地區：分為北部、中部、南部、東部以及外島地區五種屬性值。此外，學習行為主要分為三個部分，分述如下：1.課程學習行為：學生在課程中的學習行為，包括了『上課次數』、『參與線上討論次數』及『未繳作業次數』三個屬性。此為數值型資料。2.學生發表文章的篇數：學生如果在進行網路上課時，如果對於上課教材內容有疑惑的地方，或是在課程的討論區中(課程內容的討論、課程議題的討論)張貼文章與教師、其他同學的互動，都可以藉由網站中學生發表文章的學習行為觀察得知，在本研究中是以文章發表篇數做為衡量此一學習行為的變項。可分為兩個屬性，分別是『提問文章的篇數』以及『回覆別人文章的篇數』。屬性值皆為數值型資料。3.學生發表文章後被點選的頻率：被點選次數越高的文章對於課程內容或是該討論主題應具有較高的參考價值，為了衡量此一學習行為變項，本研究將發表文章被點選頻率分為兩個部份：提問文章被點選次數以及回覆文章被點選次數，而本研究為了提升分析此部份變項的嚴謹性，除了以該生所有張貼過文章被點選的總次數為分析的屬性外，同時，也將單一學生張貼文章的類型分為提問文章或是回覆文章兩個屬性。因此該部份可分為三個屬性，分別是『發表文章被點選總次數』、『提問文章被點選次數』，以及『回覆文章被點選次數』。屬性值皆為數值型資料。

(二)資料處理

為了找出這些不同學習類型的學生與其學習成效之間的關係，本研究利用資料探勘中的分類分析法，以及決策樹與決策規則的方式來呈現上述的關係，以求分析的結果能夠具有系統性與易讀性。同時，這些決策規則亦會存入學習模式庫。讓教師可以從學習模式庫中得知過去相同課程的學生學習行為與學習成效之間的關聯為何？哪些學習行為會影響學習成效？甚至是哪些學習行為會直接影響到學生最終的學習成效不佳？教師以這些決策資訊來評估過去的教學活動，並且評估這些決策資訊的正確性，而這些決策規則經過驗證之後直接內建至教學系統，系統除了即時的觀察目前修習該門課程的學生的學習情形，也可以依據這些決策規則系統偵測並適時的提供訊息給教師及學生。然而由於本研究的分析變項中大部份的屬性值都是數值性資料(例如：上課次數、線上討論次數等等)，尚未進行分類，若採用原始分類分析方法進行分析並無法直接處理這些連續型屬性的變項。此外，相同學

生的學習成績也並未分類，由於上述有關屬性值的限制，在進行分類分析時會有如何決定分類類別的困難，而藉由文獻探討中可以得知在處理有關連續型屬性的資料的方法，已經可以用 CART 演算法直接解決這類問題。然而學生的學習成績等級分類並沒有相關的研究或是演算法來改善這個問題，因此本研究擬採用不同的成績分類方式，以找出最適合的等級分類方式。本研究主要將成績的分類方式分成兩種方式：(1)固定區間：本研究採用 10 分、20 分、25 分、33 分做為成績類別切割點。(2)標準差，亦即用均值 \pm 固定的標準差做為成績類別切割點：本研究採用 0.5 個標準差、1 個標準差、0.5 與 1.5 個標準差三種方式。此外，本研究根據過去多數研究採用的時間變項來做為學習類型分析的觀察維度。主要是以不同時間點下各個學習行為屬性值的累積量，亦即從開學日起至該各個時間點計算各項頻率的累計值，並藉由觀察不同時間點學習行為變項之累計量的變化與學習成效的關係，以提供未來進行決策樹分析時，藉著觀察各屬性與決策規則的關係，是否也會隨著不同的時間點而有不同的屬性影響，換言之，各個時間點下決策規則中的屬性是否皆相同；以及，是否能在學期結束前就提早預測出哪些學生可能落入低分群，發生學習成效不佳的問題，並給予補救教學或相關的教學策略。學習成效是以學生最終該門課的學期成績做為衡量的標準。基於上述目的，本研究對時間維度的資料所進行的處理方式是將時間單位以不同的方式進行切割處理，從開學日為時間起點，分別以七天為一個單位(單週)、十四天為一個單位(雙週)、二十八天為一個單位(單月)等方式，將這些學習行為變項(上課次數、線上討論次數、提問文章篇數、回覆文章篇數、發表文章被點選總次數、提問文章被點選次數、回覆文章被點選次數)的屬性值，用累計的方式來計算這些屬性值，藉由觀察這些屬性在時間累積下的變化量與決策規則之間的關係，以盡可能以較早的時間點就能描述該門課學生的學習行為，並針對當時學生的學習行為做出可能學習成效的預測。

四、研究結果

本研究採用 C5.0 的演算法來直接處理連續型資料，來解決本研究大部份屬性值未分類的問題，其中參數設定方面是採用 35% 的樹支修剪門檻值，以及測試時需最少符合 3 筆資料做為條件。而另一方面，由於避免只採用決策樹分析法則進行分析時過於主觀，本研究亦採用統計分析方式作為對照，並比較兩者間錯誤率的差別進而選擇有效的預測方式。

(一) 決策樹法則分析結果

本研究採用的樣本為中山大學網路碩士學分班『elearning 理論與實務』不同期的資料(第六期及第七期)做為本研究的驗證對象；先用第六期資料做為訓練資料找出決策規則(共 49 筆資料)，再用第七期資料(共 45 筆資料)做為測試對象以驗證找到的決策規則是否有效以及有效程度為何。其中分析屬性，包括了性別、年齡、居住地區、學歷、上課次數、參與線上討論的次數、未繳作業次數、提問文章篇數、回覆文章篇數、發表文章被點選總次數、提問文章被點選次數、回覆文章被點選次數。針對上述十二個屬性以及相對應的成績等級做為決策樹分析軟體的輸入，利用決策樹軟體找出學生的各種學習行為屬性與學習成效之間的決策規則，再透過與同一課程不同學期的資料做驗證之後，即可做為教師在進行網路教學時教學策略與課程設計的輔助資訊。表三為不同時間單位下的訓練錯誤率與預測錯誤率，以七天為時間單位來看，各種成績的分類方式的訓練錯誤率皆能在 30% 以下，其中以均值 \pm 1 個標準差的錯誤率的平均表現較低(平均錯誤率為 8.06%)；而且每一個分類方式都能隨著時間的累積而慢慢的降低錯誤率，其中均值 \pm 固定標準差(0.5、0.5 與 1.5)這兩種成績分類方式都能在第八週至第九週及第九週至第十週的時候訓練錯誤率降至 15% 以下，表示在此時間點的學習歷程已經能完整的描繪出學生學習行為與學習成效的決策規則。不同時間單位下的預測錯誤率，其中以均值 \pm 1 個標準差的錯誤率的平均表現較低(平均錯誤率為 27.45%)，然而其餘成績分類方式所呈現的錯誤率確有偏高的趨勢(圖三、圖四即以圖形化的方式表現，分別為以七天的時間單位下各個時間點之訓練錯誤率與預測錯誤率)，也因此本研究更進一步的分析錯誤率的分布狀況。

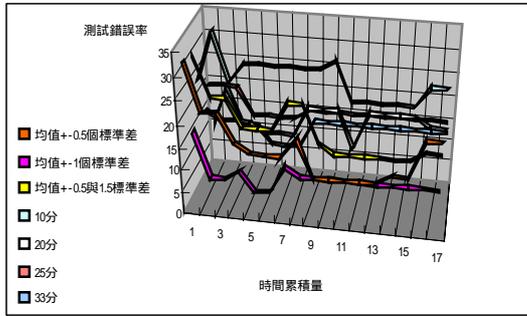
表四為以不同時間單位下各個時間點的高估及低估錯誤樣本的分佈狀況及各時間點所產生的決策法則(為求簡化以英文字母分別代表各屬性)，其中高估所表示的意涵為實際所得到的成績較預測成績結果低，低估表示實際所得到的成績較預測結果高；而本研究的研究目的在於幫助教師能夠即時瞭解學生的學習狀況並給予輔助，為避免教師疏於輔導高估學生而導致最後終落入低分群，因此本研究將針對高估錯誤率進行探討，藉以降低高估錯誤率。由表三得知成績分類為 0.5 標準差、0.5 與 1.5 標準差、20 分、25 分以及 33 分的分類方式在第七週及第八週高估錯誤率皆有明顯的下降且 1.0 標準差及以 10 分為分類方式在第六週及第七週亦皆有明顯的下降，因此雖然

在整體預測錯誤率方面偏高，但在以不同成績分類方式下第七週、第八週之後的高估錯誤率已下降許多，甚至在以 1.0 標準差的分類方式

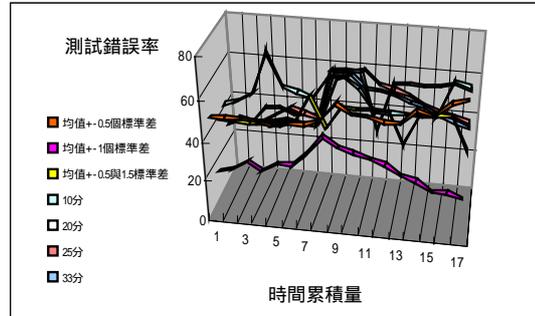
第八週以後錯誤率皆達到 0(圖五即以圖形化的方式表現)，顯示了以此決策方式是可以幫助教師輔導未來可能落入低分群的學生。

表三、不同時間單位下各個時間點之訓練錯誤率與預測錯誤率

成績分類	訓練錯誤率							預測錯誤率						
	均值+0.5個標準差	均值+1個標準差	均值+0.5與1.5個標準差	10分	20分	25分	33分	均值+0.5個標準差	均值+1個標準差	均值+0.5與1.5個標準差	10分	20分	25分	33分
1	32.7	16.3	30.6	24.5	16.3	20.4	10.2	51.1	20	42.2	46.7	33.3	31.1	28.9
2	22.4	6.1	22.4	34.7	14.3	20.4	18.4	51.1	22.2	42.2	48.9	35.6	31.1	26.7
3	22.4	6.1	22.4	24.5	14.3	20.4	10.2	51.1	26.7	42.2	53.3	35.6	31.1	35.6
4	16.3	8.2	16.3	28.6	14.3	14.3	10.2	51.1	22.2	42.2	73.7	35.6	35.6	35.6
5	14.3	4.1	16.3	28.6	12.2	14.3	6.1	48.9	26.7	42.2	57.8	37.8	40	33.3
6	14.3	4.1	16.3	28.6	12.2	14.3	6.1	51.1	26.7	44.4	55.6	35.6	37.8	33.3
7	14.3	10.2	22.4	28.6	12.2	14.3	6.1	51.1	33.3	57.8	53.3	35.6	35.6	33.3
8	18.4	8.2	22.4	28.6	18.4	16.3	12.2	53.3	42.2	42.2	64.4	64.4	60	53.3
9	10.2	8.2	14.3	28.6	18.4	16.3	12.2	62.2	37.8	53.3	64.4	64.4	60	55.6
10	10.2	8.2	12.2	30.6	18.4	16.3	12.2	57.8	35.6	53.3	60	64.4	62.2	48.9
11	10.2	8.2	12.2	22.4	10.2	16.3	12.2	57.8	33.3	53.3	48.9	35.6	55.6	48.9
12	10.2	8.2	12.2	22.4	18.4	16.3	12.2	55.6	31.1	53.3	48.9	60	53.3	46.7
13	10.2	8.2	12.2	22.4	18.4	16.3	12.2	55.6	26.7	37.8	48.9	60	51.1	44.4
14	12.2	8.2	12.2	22.4	18.4	16.3	12.2	62.2	24.4	53.3	48.9	60	46.7	42.2
15	12.2	8.2	12.2	22.4	18.4	16.3	12.2	60	20	53.3	48.9	60	44.4	37.8
16	20.4	8.2	14.3	26.5	16.3	16.3	12.2	66.7	20	53.3	66.7	62.2	42.2	35.6
17	20.4	8.2	14.3	26.5	16.3	16.3	12.2	68.9	17.8	37.8	64.4	60	40	33.3
7天平均錯誤率	15.9	8.06	16.7	26.5	15.7	16.5	11.1	56.2	27.4	47.3	56.0	49.4	44.5	39.6
14天平均錯誤率	16.7	7.28	16.2	28.1	16.3	16.9	11.9	57.2	27.4	46.8	56.5	53.3	44.4	39.5
28天平均錯誤率	16.3	8.2	16.3	26.5	16.3	15.8	11.7	56.6	28.3	43.8	62.7	55	47.2	42.2



圖三、以七天為單位之訓練錯誤率

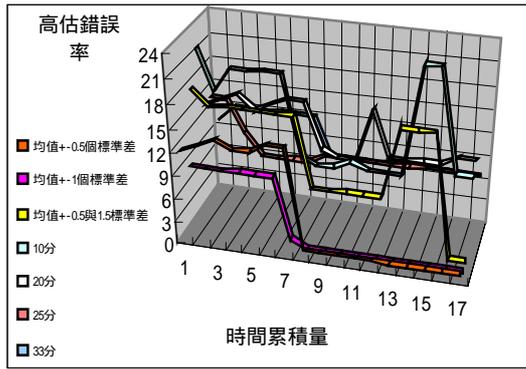


圖四、以七天為單之預測錯誤率

表四、不同時間單位下各個時間點的高估及低估錯誤樣本的分佈狀況

成績分類	均值0.5標準差		均值1標準差		均值0.5與1.5標準差		10分		20分		25分		33分	
	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估
1	12	11	9	0	18	1	22	1	14	1	14	0	10	5
2	13	10	9	1	16	4	17	10	15	1	14	0	12	0
3	14	8	9	3	16	4	20	7	16	0	10	0	12	3
4	13	9	9	1	16	4	20	7	14	2	7	1	12	3
5	13	9	9	3	16	4	20	7	16	2	7	0	12	3
6	14	9	9	3	16	4	20	7	16	0	7	0	12	3
7	14	9	1	14	16	4	10	20	16	0	7	0	12	3
8	1	23	0	19	7	21	9	22	10	19	8	19	7	17
9	1	27	0	17	7	19	9	22	9	20	8	20	7	16
10	1	25	0	16	7	17	10	18	9	20	8	17	7	16
11	1	25	0	15	7	17	9	20	16	0	8	17	7	14
12	1	24	0	14	7	15	9	20	10	17	8	16	7	14
13	1	24	0	12	16	4	9	21	10	17	8	15	7	12
14	1	26	0	11	16	4	23	1	10	17	8	13	7	10
15	1	25	0	9	16	4	23	1	10	17	8	12	7	9
16	1	29	0	9	0	4	10	22	11	17	8	11	7	9
17	1	25	0	8	0	7	10	21	11	16	8	10	7	8

(註：A：登入次數 (login_time)、B：發表文章 (Post)、C：回復文章 (reply)、D：總閱讀 (hit_sum)、E：閱讀發表 (hit_post)、F：點閱回復 (hit_reply)、G：性別 (sex)、H：背景 (background)、I：居住 (live)、J：年齡 (age)、K：討論次數 (chat_time))

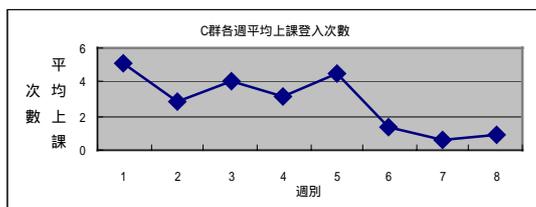
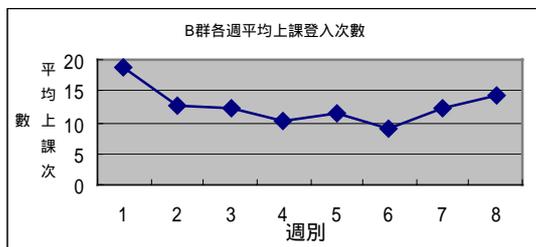


圖五、以七天為單位之高估錯誤率

在決策規則方面，由表四顯示在高估錯誤率未明顯下降時，所依據的決策法則以成績分類均值 ± 1 標準差為例，在第七週前的決策法則為居住地、回復文章數、討論次數等為主要的分類依據，而在高估錯誤率明顯下降後(發生在第七週)決策規則改以登入次數為主要的決策法則，由此顯示了在第七週後高低分學生主要差別在登入次數上已有顯著的差異，再者觀察其他成績分類方式亦可發現在第六週、第七週或第七週、第八週間的高估錯誤顯著下降的同時決策法則亦整個轉換為以上課登入次數為主要決策依據，而為探討此現象的產生，本研究深入瞭解課程資訊希望藉由課程上的相關資訊瞭解第六、七、八週之間是否有其他關鍵影響要素。研究結果顯示，中山網路大學碩士學生班第七期中考測驗於第八週週末舉行，藉由此訊息分別計算第六週至第八週高分群及低分群平均登入次數，計算結果如表五(以平均錯誤率最低均值 ± 1 標準差為例)。

表五、 期中考前兩週平均上課登入次數

	第六週	第八週平均上課登入次數
A群(0筆)		0
B群(36筆)		26.47222
C群(9筆)		1.55556



圖六、B 群與 C 群各週平均上課次數

表五顯示高分群學生(B 群)於第六週至第八週平均登入次數為 26.47222 明顯超越低分群學生(C 群) 1.55556, 而由圖六中也顯示了高分群學生平均上課登入次數各週均保持 10 次以上, 而低分群學生平均上課次數為每週 3~5 次, 甚且在第六週之後降至每週上課次數一次左右, 此結果正好與決策法則在第六週的轉變相謀和, 顯示此課程學生成績差距主要差異為期中考前兩週上課登入的次數, 也代表低分群學生於期中考前兩週上課次數明顯的下降, 此結果也說明了低分群學生可能於第六週前發生學習上的障礙或其他因素導致上課意願降低, 因此, 教師可以利用此決策法則於第六週時給予上課次數過低的學生適時的輔助及指導, 以免終至落入低分群。

(二) 統計分析結果

為避免只採用決策樹分類分析法所得到的法則及錯誤率過於主觀, 因此, 本研究亦採用了統計分析方法, 對於獨立變數包括了性別、年齡、居住地區、學歷、上課次數、參與線上討論的次數、未繳作業次數、提問文章篇數、回覆文章篇數、發表文章被點選總次數、提問文章被點選次數、回覆文章被點選次數, 與依變數成績採用逐步回歸, 分別計算出以七天、十四天、二十八天為時間區間的逐步回歸式, 並利用第六期的逐步回歸式來做為第七期的預測式, 並將預測所得成績, 亦採均值 ± 0.5 標準差、均值 ± 1 標準差、均值 ± 0.5 與 1.5 標準差、10 分、20 分、25 分、33 分等分類方式, 其預測之錯誤率結果如表六、表七、表八。由表六中得知均值 ± 1 標準差的錯誤率雖和決策樹分類分析法所得到的結果一樣, 然而其錯誤率卻集中在高估錯誤率上, 表示所得到的決策法則在做為教師指導方針時無法對低分學生給予有效的輔助; 而其餘成績分類方式不僅在錯誤率上比決策樹分類分析方式高且皆集中在高估錯誤率上, 且分析表七、表八所得到的以十四天、二十八天為單位下個成績分類錯誤率更是為高。因此, 可以證明本研究所採用的決策樹分類分析方式較傳統的統計分析方式所得到的結果較為正確, 也顯示了以決策樹分類分析方式所得到的決策法則可以提供教師教學上的輔助。

五、結論

本研究目的在提供一個整合性的分析機制, 提供給教師決策規則作為教學的輔助資訊, 以輔助教師在教學時能夠即時知道學生的學習狀況, 並針對不同學習行為的學生給予不同的教學或輔助。而由研究結果得知以決策樹

分類分析法所得到的決策法則相較於統計方式是有一定的效用，而就平均而言經由本研究分析出的決策規則的確能有效的預測出低分群的學習行為，而這對於教師來說更具有相當的意義，因為這表示經由本研究的方式，能夠在學期中藉由即時的觀察學生的學習狀況與學習行為，可以提早預測出哪些學生可能會落入低分群，藉由此方式偵測出這些可能為低學習成效的學生，教師或是助教可以即早給予教學輔助，以達到某種程式的個別化教學。如以研究中『elearning 理論與實務』課程為例，教師藉由決策法則可以得知，未來落入低分群的學生於期中考前兩週可能發生上課次數的明顯下降，因此教師便可以適時的針對未來可能落入低分群的學生給予個別化的輔助。

表六、七天為的高低估錯誤數與平均錯誤率

成績分類 時間累積 (週)	均值加減 0.5標準差		均值加減 1標準差		均值加減 0.5與1.5標準 差		10分		20分		25分		33分	
	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估
	1	9	20	9	0	9	19	12	21	12	15	12	8	11
2	10	18	9	0	10	18	12	21	12	13	12	8	11	6
3	9	19	9	0	10	17	12	22	12	12	12	8	11	6
4	9	19	10	0	9	19	12	23	12	11	12	10	10	6
5	9	16	10	0	9	16	12	24	12	12	12	9	10	5
6	10	14	10	0	9	14	12	21	12	12	12	9	10	4
7	9	14	10	0	10	14	12	19	12	12	12	9	10	3
8	9	13	10	0	10	13	12	19	12	12	12	10	10	3
9	9	14	11	0	10	14	12	19	12	12	12	11	10	3
10	9	14	11	0	10	14	12	19	12	12	12	11	10	3
11	9	12	13	0	10	12	12	19	12	12	12	10	10	3
12	9	14	14	1	10	13	12	19	12	13	12	10	10	3
13	9	12	16	1	10	12	12	19	12	13	12	10	10	3
14	9	13	16	1	10	13	12	20	12	14	12	10	10	3
15	8	13	16	1	9	12	12	18	12	11	11	9	10	3
16	8	13	16	1	9	13	12	18	12	12	11	9	10	3
17	8	13	16	1	9	13	12	20	11	13	11	9	10	3
平均錯誤率	52.549		27.712		53.333		71.241		54.117		47.189		31.241	

表七、十四天的高低估錯誤數與平均錯誤率

成績分類 時間累積 (週)	均值加減 0.5標準差		均值加減 1標準差		均值加減 0.5與1.5標準 差		10分		20分		25分		33分	
	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估
	1	21	0	45	0	40	0	24	0	16	0	14	0	12
2	21	0	44	0	39	0	24	0	16	0	14	0	12	0
3	21	0	44	0	40	0	24	0	16	0	14	0	12	0
4	21	0	44	0	41	0	24	0	16	0	14	0	12	0
5	21	0	44	0	41	0	24	0	16	0	14	0	12	0
6	21	0	43	0	41	0	24	0	16	0	14	0	12	0
7	21	0	42	0	41	0	24	0	16	0	14	0	12	0
8	21	0	43	0	41	0	24	0	16	0	14	0	12	0
9	21	0	42	0	38	0	24	0	16	0	14	0	12	0
平均錯誤率	46.666		96.54		89.38		53.33		35.555		31.111		26.666	

表八、二十八天的高低估錯誤數與平均錯誤率

成績分類 時間累積 (週)	均值加減 0.5標準差		均值加減 1標準差		均值加減 0.5與1.5標準 差		10分		20分		25分		33分	
	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估	高估	低估
	1	21	0	45	0	45	0	22	0	16	0	14	0	12
2	21	0	45	0	45	0	22	0	16	0	14	0	12	0
3	21	0	45	0	45	0	22	0	16	0	14	0	12	0
4	21	0	45	0	45	0	22	0	16	0	14	0	12	0
平均錯誤率	46.66		100		100		48.88		35.55		31.11		26.66	

致謝

本研究由國科會計畫獎助。名稱為知識分享：顯性知識採用知識關聯圖及隱性知識採用知識地圖。計畫編號：92-2213-E-110-041。

六、參考文獻

[1] 王錦裕(2001)，線上閱讀的學習時間型態與學習互動及學習成就相關性之研究，國立高雄師範大學資訊教育研究所碩士論文。

[2] 呂靜芳(1999)，由網站行為歷程以貝式學

習建立學習者模式之引導系統，國立中央大學資訊工程研究所碩士論文。

[3] 邱美珍(1996)，決策樹學習法中連續屬性之分類研究，中原大學資訊工程研究所碩士論文。

[4] 林清賀(1998)，網路學習系統上之學習歷程評量輔助系統，國立中央大學資訊工程研究所碩士論文。

[5] 倪家祥(2000)，以網站行為的歷程建立具時間性學習者模式，國立中央大學資訊工程研究所碩士論文。

[6] 陳年興、林甘敏(2001)，"網路學習之學習行為與學習成效分析"，第十二屆國際資訊管理學術研討會，中壢，國立中央大學。

[7] 許榮隆(2000)，遠距教學的學習歷程與時間之研究，國立高雄師範大學資訊教育研究所碩士論文。

[8] 童宜慧、張基成(1996)，"網路化學習歷程檔案系統"，第八屆 ICCAI 國際電腦輔助教學研討會，台中，逢甲大學。

[9] 劉惠如(1999)，整合式網路教學之教學設計與評量，國立中山大學資訊管理研究所碩士論文。

[10] 劉晨鍾(2000)，網路學習歷程之知識探索：學習效能評鑑之工具，國立中央大學資訊工程研究所博士論文。

[11] 楊岱霖(2000)，動態適性化學習系統之研究，高雄師範大學資訊教育所碩士論文。

[12] Bloom, B.S., (1976), Human characteristics and school learning, McGrawHill.

[13] Freitag, D., McCallum, A., Mitchell, T., Nigam, K. and Slattery, S. (1998), "Learning to extract symbolic knowledge from the world wide web", *Proceedings of American Association for Artificial Intelligence (AAAI)*

[14] Fuller, R. (2002), Data Mining Overview, <http://www.datawarehouse.com/>.

[15] Joachims, T. (1998), "Text Categorization with Support Vector Machines: Learning with Many Relevant Feature", 10th European Conference on Machine Learning.

[16] Quinlan, J.R. (1993), C4.5 Programs for machine learning, Morgan Kaufmann Publishers, San Mateo, California.