

# 以色塊屬性關聯規則建立影像分類決策

陳建宏 柯佳伶

台灣師範大學資訊教育系

jlkoh@ice.ntnu.edu.tw

## 摘要

本論文提出以色塊屬性關聯規則作為影像特徵，並用以建立影像分類規則。首先將影像轉至 HSV 色空間且量化，並取出色塊物件及色塊屬性值。接著再建構二元關聯次數累計表，以快速計算出一張影像中所有的色塊屬性值二元關聯規則之支持度及確信度。我們提出動態多決策樹演算法，挑選出對區分影像類別句重要性的色塊屬性值關聯規則，進而建立影像分類決策規則；亦提出分類決策規則的精簡方法，可有效降低分類規則的數量且不明顯影響分類正確率。此外，本方法亦擴增為模糊型式，可接受具模糊類別的訓練影像並產生模糊分類結果。在我們的實驗中顯示，本論文所提出的影像分類方法明顯優於 C4.5 與模糊決策樹，並對各種不同種類的影像領域皆達到一定程度的分類正確率。

**關鍵詞：**影像分類，色塊屬性關聯規則，動態多決策樹

## 一、緒論

影像資料是多媒體資料中最常見的一種類型，其包含了比一般文數字資料更為豐富的資訊。因此，針對影像資料的資料探勘技術也成為近來重要的研究方向。將影像資料以內容語意分類，較為符合使用者對於影像的概念。因此，於同一語意類別中的影像所探勘到的共同特徵或規則可作為語意概念的代表或用以搜尋同類別影像時的比較範本。利用分類方法建立影像低階特徵與高階語意的關聯性後，便可以由影像低階特徵推導出高階語意，將制定影像內容語意之過程自動化。

一個影像物件的資料量比一般的文數字資料龐大，因此要在影像資料上進行資料探勘，必須先將影像物件資料簡化，轉換為足以代表影像的特徵來表示。常用到的特徵有顏色、形狀、紋理材質等[3][5][6][11][13]。論文[14]以小波理論影像轉換後取得特徵值，用於紋理材質影像的搜尋上，其查詢效率較一般能量函數方法高 6%至 8%。論文[4]提出針對醫療用影像的分類方法，先計算影像中像素灰階值的亂度值、對比值、不連續度、同質度、相似度等作為分類用的特徵，再以類神經網路對這些特徵進行分類。

以上所提到的論文所使用的影像特徵皆屬於全域式，其描述範圍為整張影像。通常在影像中含有多個物件而非僅有一個，此時全域式的影像特徵便無法描述出各個物件特徵，因此較適用於特別的影像應用領域，例如醫療影像或紋理材質影像。區域式或物件式的影像特徵則對於含物件的影像有較佳的描述能力，故常應用於影像內容式查詢[11]或影像分類上。

QBIC[6]是一個提供影像內容查詢的影像資料庫系統，它提供使用者分別以顏色、材質紋理、形狀、物件位置等特徵查詢相似影像。QBIC 考慮了影像局部區域的特徵，因此使用者可針對特定位置的顏色或材質紋理查詢影像。Blobworld 系統[3][5][13]使用最大期望值演算法將影像依照顏色與材質紋理特徵分割為多個區域，使用者可以選定影像中必須滿足查詢條件的區域，並指定顏色、材質紋理、位置或形狀等在查詢條件及其重要加權。以上研究顯示了區域式影像特徵或物件式影像特徵於影像查詢時的優點：此類特徵可反應影像中不同位置特徵的變化，因此與人類認知概念較為接近。例如一張影像中，若偏上方有一大塊區域為藍色，人類會認為此塊區域是『藍天』；若此區域之顏色特徵不變，但位置處於影像的下方，則人類會認為此塊區域為『大海』。人類判斷影像物件並非僅針對一個或兩個特徵，有些物件主要是以其位置與顏色（例如藍天、大海）判斷，有些物件則是以其形狀判斷（例如馬、驢），或是以其材質紋理判斷（例如斑馬、老虎）。

WebSeer 系統[2]提供對於 WWW 環境中影像資料的搜尋引擎，其將影像分類為照片與圖形。WebSeer 利用訓練樣本資料中的顏色數量、常用色彩矩陣、最遠鄰居矩陣、色彩長條圖矩陣等特徵產生決策樹，用以將影像分類為照片或圖案。[8]亦提出一個應用於 WWW 環境，以顏色、形狀與物件組成為特徵的影像分類與搜尋系統，但僅針對運動類照片作分類。

前面提及的影像分類或查詢系統有的針對其應用領域特別設計特徵取出方法，有的讓使用者決定查詢時所重視的特徵，在『決定哪些特徵為重要特徵』的部份未達到自動化，皆由人為決定。[12]則提出利用自我組織圖來產生最佳識別特徵集合的方法，將決

定重要特徵的步驟自動化。在該論文的實驗中顯示該方法於人類臉部影像及自然風景影像之分類查詢皆有良好效果，並能適應物件位置與大小的變動。

由以上文獻的探討，我們針對影像分類搜尋問題定出以下幾項研究目標：一、制定出合適的影像特徵，使其能表現出區域式特徵，且能反應一張影像的整體內容分佈關聯；二、自動判斷哪些特徵為重要分類特徵；三、探勘出影像低階特徵與高階語意概念的關聯性，以達成影像自動分類的目的。為了達到這些目標，本論文以色塊物件為描述基本影像屬性之單位，以物件屬性值間存在之關聯規則作為影像特徵。接著，以決策樹演算法選出重要特徵並產生分類決策，自動建立影像低階特徵與高階語意概念的關聯。在擷取物件式影像特徵的過程，我們將影像轉至 HSV(Hue、Saturation、Value)色空間，並取出色塊物件及色塊屬性值。我們設計了二元關聯次數計表，僅需色塊數量的線性時間複雜度便可計算出所有色塊屬性值間之二元關聯規則的支持度與確信度。在決策樹演算法的部份，我們分別採用 C4.5 演算法與模糊決策樹方法實作，並將演算法擴增為產生動態多決策樹。我們以自然風景影像、動物影像、材質影像及交通工具影像等不同類型影像進行實作正確率評估，證實了本論文所提出之分類方法於不同類型之影像分類皆達到一定程度的正確率，其中自然風景影像的分類正確率可達到 91.92%；而所找出之分類決策規則，在經過我們所提出的分類規則精簡方法摘要後仍然具有相近的正確判斷率。

本論文以下內容組織說明如下：第二節先簡述影像自動分類與決策樹演算法，並說明本論文方法之相關定義與概念。在第三節中對本論文提出的色塊屬性關聯規則特徵的抽取方法作詳盡的介紹。第四節將介紹本論文的動態多決策樹分類決策規則建立方法。第五節中以各種不同類型影像應用的分類實驗來探討色塊屬性關聯規則分類方法的分類效果，並與其它方法比較。第六節總結本論文，並提出未來的研究方向。

## 二、基本概念

在本章中，我們將簡述影像自動分類問題與決策樹演算法，並說明本論文提出之色塊屬性關聯規則分類方法的基本概念與相關定義。

### (一) 影像分類規則

分類問題的研究目的是要利用已知分類

的物件之屬性找出分類決策規則，用以判斷未知類別物件之分分類結果。

決策樹演算法的目的是由已知類別的物件集合之屬性值建立決策樹，是產生分類決策規則的常見方法。決策樹演算法之主要概念為不斷選取最適於分類的屬性，每次選取的分類判斷條件將集合分為幾個子集後再遞迴挑選，直至子集中的物件皆屬同一分類為止。

ID3 演算法[17]為決策樹演算法中的一種。依照資訊理論中所提出的觀念：資訊量越高則亂度越高，亦代表物件的分類情形越混亂。因此，ID3 演算法在選取最適分類的屬性時，挑選能將資訊量降低最多的屬性，以期建立出較小的決策樹，而其所表示出的分類決策規則也較精簡。ID3 對連續數值屬性值資料建立決策樹的效果較差，因此 C4.5[11]將 ID3 擴增為先將連續數值屬性值依最佳分割屬性值分為兩群後再建立決策樹。

利用各種影像處理方法可以取得影像的低階特徵，但是卻無法取得語意概念的高階特徵。影像數量較少時，可由專家人為標出影像的語意概念；當影像數量很大時，此方法便極不可行。將高階特徵視為影像的類別，低階特徵視為影像的屬性時，此一問題便轉為影像資料的分類問題。以決策樹演算法產生影像的分類決策規則後，電腦便可由影像低階特徵自動推導出高階語意。

### (二) 色塊屬性關聯規則

在本論文中對色塊的定義如下：在影像中，若兩像點為彼此的四連通[19]，則這兩個像點屬於同一個色塊。如圖一，I 為一  $10 \times 5$  之影像，其中有 A、B、C、D、E、F、G 共 7 個色塊。


圖一

在本論文中，我們以色塊為物件單位，由各個色塊計算出顏色、位置、大小等低階影像屬性，將這些色塊的各個影像屬性以矩陣形式表列出來，即為色塊屬性矩陣。

關聯規則[20][21]為描述資料庫中資料物件屬性值關聯性的一種方法。在此論文中，

我們稱只考慮兩兩屬性值間的關聯規則為二元關聯規則。我們將影像中之色塊視為資料物件單位，並取出同一影像中所有色塊其屬性的二元關聯規則，以及其支持度及確信度，稱為色塊屬性關聯規則。下列關聯規則為圖三影像之色塊屬性關聯規則當中的幾個：

顏色=3→大小=3, support=0.57,  
confidence=0.75

大小=3→顏色=3, support=0.57,  
confidence=1

顏色=3→限制矩形寬=2, support=0.57,  
confidence=0.75

顏色=3→大小=4, support=0.43,  
confidence=0.67.

### (三) 色塊屬性關聯規則分類方法

影像分類決策過程中所採用的低階影像特徵會影響分類的效果及效率，因此本論文的研究重點在於擷取影像特徵與選取分類特徵。我們提出的色塊屬性關聯規則分類方法分為以下幾個主要步驟：

(1)取得影像中的色塊並計算其屬性值，建立色塊屬性矩陣。

(2)將色塊屬性矩陣內的數值量化並轉換為交易資料表示型式，探勘出各色塊中屬性值間的二元關聯規則。

(3)以色塊屬性關聯規則及其支持度與確信度作為影像特徵，以動態多決策樹方法建立影像分類決策規則。

(4)精簡影像分類決策規則。

## 三、色塊屬性關聯規則抽取方法

### (一) 色塊屬性取出方法

我們以色塊抽取演算法取出影像中的色塊。由於一張全彩影像中所包含之色彩至多有  $256 \times 256 \times 256$  種，若直接進行色塊抽取演算法，色塊數量可能過多，且有許多色塊所佔的像點數太少。因此，在進行色塊抽取演算法前需先進行色彩量化[17]，將影像之色素值域降低至  $N$  種顏色，以使顏色相近之鄰近像點落於同一色塊中。

多數傳統影像使用 RGB 色空間描述像點顏色。量化過程時會對 R、G、B 三軸分別進行量化，因為在 R、G、B 三軸上有不同的量化誤差，量化結果會產生色偏的現象。因此本論文將影像轉至 HSV 色空間進行量化，人眼對於色調之敏感度高於亮度及飽和度，因此在 HSV 色空間上我們可以在三個座

標軸上選擇不同的量化梯度，藉此達到量化誤差小且色素值域小的目的。

本論文所使用之量化方式如下：

1. 將顏色由 RGB 空間轉至 HSV 空間。

2. 將 S 與 V 量化為四階：

$$S' = 32 + (S \text{ div } 64)$$

$$V' = 32 + (V \text{ div } 64)$$

3. 將 H 量化為 16 階：

$$H' = H \text{ div } 16$$

經以上量化過程，可將全彩影像中每個像點的色彩值域量化至 256 色。

此外，由於色彩在飽和度值低時近似於灰階，此時色調的變化對肉眼的影響極低，故可以 Hue=0 表示；而當亮度低時色彩會近於黑色，對於色調與飽和度值的變化亦難以分辨，因而可以黑色表示。考慮這兩種情形後，色彩量化過程增加以下兩個步驟：

4. 若  $S' = 32$  則  $H' = 0$

5. 若  $V' = 32$  則  $H' = 0$ ， $S' = 32$

加入這兩個步驟後，色彩值域將量化至僅需 148 種顏色即可表示。

在完成影像的色彩量化後，我們以線性掃描方式取出色塊：由左上至右下檢視每個點的顏色，若像點顏色與其左側像點之顏色相同，則將此像點併入左側像點所屬之色塊；若像點顏色與其上方像點之顏色相同，則將此像點併入上方像點所屬之色塊；若像點顏色與其上方像點及左側像點之顏色相同，則將此像點併入左方像點所屬之色塊，並將上方像點所屬之色塊及左方像點所屬之色塊合併；若像點顏色與其左側像點及上方像點顏色皆不同，則將此像點形成一新的色塊。

對每個色塊我們取出代表面積大小、顏色、位置特性的屬性，包含色調、飽和度、亮度、面積、X 座標值平均位置、Y 座標值平均位置、X 座標值標準差、Y 座標值標準差、X 座標值極大值、Y 座標值極大值、X 座標值極小值、Y 座標值極小值共十二個屬性。

考慮影像大小不一致的狀況，色塊特徵值中除了色調值、飽和度值及亮度值外，皆需以影像長寬值為標準作正規化轉換。其中 X 座標值平均位置、X 座標值標準差、X 座標值極大值、X 座標值極小值以除以影像寬度正規化；Y 座標值平均位置、Y 座標值標準差、Y 座標值極大值、Y 座標值極小值以除以影像高度正規化；色塊面積以除以影像面積正規化。

## (二) 色塊屬性資料量化與轉換

將色塊中各個不同的屬性值視為商品資料項，則可將一個色塊中的屬性資料轉換為一筆交易資料的形式。因此，包含多個色塊的一張影像相當於一個交易資料庫，可從其中探勘色塊屬性值的關聯規則。

由於各個色塊屬性值範圍很大，若以各個屬性值直接轉換為一種商品資料項，則資料項的種類將會過多，因而使得產生的關聯規則過於繁瑣，因此亦必須對色塊屬性值進行量化。

	A	B	C	D
O1	12	5	14	0
O2	23	3	29	6
O3	47	16	17	3
O4	24	14	12	9
O5	30	13	20	10
O6	32	1	22	18

色塊屬性值

↓

T1	A1	B0	C1	D0
T2	A2	B0	C2	D0
T3	A4	B1	C1	D0
T4	A2	B1	C1	D0
T5	A3	B1	C2	D1
T6	A3	B0	C2	D1

屬性資料項

圖二

如圖二，在此例子中色塊屬性值以除以 10 後再取整數的方式量化，接著再轉換為交易資料項目表示。例如以 A1 代表 A=0，以 C2 代表 C=2。

## (三) 色塊屬性關聯規則特徵

大多數產生關聯規則的方法為依最小支持度找出交易式資料中的常出現項目，再由常出現項目產生候選的關聯規則，最後保留下來的是支持度與確信度皆高於最小門檻值的可靠關聯規則。

在本論文中，我們以色塊屬性值關聯規則的形式來表示一張影像的特徵，並使用這些特徵來分類判斷。若只選取可靠關聯規則，會遇到以下幾個問題。

(1) 最小支持度與最小確信度的制定方式：這兩個門檻值會影響找出關聯規則的多寡。其中，最小支持度值的制定應考慮原始資料的屬性值分佈特性。若資料屬性值皆分為 2 種值，將最小支持度定在 30% 偏低；若屬性值皆分為 10 種值，此時最小支持度定在 15% 便偏高。因此，對不同類型的影像應採用不同的最小支持度與最小確信度。

(2) 關聯規則數量控制：若產生過多的關聯規則，則不容易顯現出分類特徵；而若產

生過少的關聯規則，則可能遺漏掉部份資訊。因此，應列出所有最基本且完整的關聯規則作為特徵。

(3) 可能找出必然關聯規則：有些關聯規則則是明顯可知的，例如一色塊關聯規則『大小=1 → 最小限制矩形寬度=1，確信度 100%』，此一關聯規則雖然其確信度為 100%，但代表的是不需探勘即必然已知成立的規則。我們稱這類關聯規則為『必然關聯規則』，為精簡特徵表示，必須加以去除。

(4) 無法保留否定關聯規則：以最小支持度及確信度判斷是否保留關聯規則只能得到『常出現』資料項目的關聯規則，而無法得到『不常出現』項目的關聯規則。例如『色調=1 → 亮度=3，確信度 1%』此一關聯規則，它亦同時隱含『色調=1 → 亮度≠3，確信度 99%』；卻會因為無法達到最小確信度而被去除，我們將這類關聯規則稱為『否定關聯規則』。

根據以上討論，在本論文中對影像色塊屬性值資料項目尋找其二元關聯規則，且不以最小支持度及確信度作篩選，而以所有支持度大於 0 的關聯規則及其支持度與確信度作為一張影像的特徵；在分類過程再進一步對這些特徵進行萃取。我們採用決策樹演算法挑選出最適於分類的特徵以及其支持度與確信度分界值，並將『必然關聯規則』之特徵篩除。由於我們並未將低於最小支持度與最小確信度的關聯規則去除，若有『否定關聯規則』特徵適於分類，亦會被決策樹演算法挑選出來。決策樹建構過程將在第四節介紹。

本論文使用二元關聯次數累計表來輔助尋找二元關聯規則。二元關聯次數累計表為一個二維陣列，其行與列表示一張影像中所有色塊屬性值量化後所取出的各資料項。利用此結構，僅需作一次資料掃描，便可以得到資料項間所有的二元關聯次數。二元關聯次數累計表的建構方式如下：

以圖三中的色塊資料為例，首先我們將所有屬性資料項的種類列出，並決定其順序性，此順序即代表該資料項在二元關聯次數累計表中的索引位置。

Block 1	A1, B0, C1, D0
Block 2	A2, B0, C2, D0
Block 3	A4, B1, C1, D0
Block 4	A2, B1, C1, D0
Block 5	A3, B1, C2, D1
Block 6	A3, B0, C2, D1

→ A1、A2、A3、A4、  
B0、B1、C1、C2、  
D0、D1

色塊資料

圖三

這組色塊資料中共有 10 種屬性資料項，因此其二元關聯次數累計表為 10 乘 10 之陣列。

圖四顯示建構出的二元關聯次數累計表，表中斜對角線以外的非零項表示該對應的兩個項目有同時出現的次數，對角線則顯示任一個項目在資料庫中出現的次數。

	A1	A2	A3	A4	B0	B1	C1	C2	D0	D1
A1	1				1		1		1	
A2		2			1	1	1	1	2	
A3			2		1	1		2		2
A4				1		1	1		1	
B0					3		1	2	2	1
B1						3	2	1	2	1
C1							3		3	
C2								3	1	2
D0									4	
D1										2

圖四

由這些非零項我們可以列出所有資料項目間二元關聯規則及其支持度與確信度。例如圖十中[A1, B0]之值為 1，由[A1,A1]可知 A1 出現次數為 1 次，由[B0,B0]可知 B0 出現次數為 3 次，因此列出  $A1 \rightarrow B0$  及  $B0 \rightarrow A1$  兩個二元關聯規則，其支持度皆為 1， $A1 \rightarrow B0$  之確信度為  $\text{Support}(A1 B0) / \text{Support}(A1) = 1/1 = 100\%$ ，而  $B0 \rightarrow A1$  之確信度為  $\text{Support}(A1 B0) / \text{Support}(B0) = 1/3 = 33.33\%$ 。

#### 四、動態多決策樹分類方法

##### (一) 建立決策樹訓練資料

由第三節的方法，我們取出一張影像中所有的色塊屬性關聯規則及其支持度與確信度作為影像的特徵。在我們實驗中，一張影像存在約 600 至 800 個色塊屬性關聯規則，因此接下來我們以決策樹演算法選出對分類重要的色塊屬性關聯規則並產生影像的分類規則。

在執行決策樹演算法前，須將一張影像中的色塊屬性關聯規則轉換為決策樹演算法所需要的型式。我們將影像中的色塊屬性關聯規則列為屬性，以每個色塊屬性關聯規則在一張影像中的確信度與支持度表示其屬性值。若一影像 I 中有一色塊屬性關聯規則  $A \rightarrow B$ , confidence=X, support=Y，則此影像有確信度屬性  $C(A \rightarrow B)$ ，其屬性值為 X；以及支持度屬性  $S(A \rightarrow B)$ ，其屬性值為 Y。

在一張影像中，若有一色塊屬性關聯規則  $A \rightarrow B$ ，其支持度為 X，則色塊屬性關聯規則

$B \rightarrow A$  之支持度亦必為 X；故一張影像中  $S(A \rightarrow B)$  之屬性值必等於  $S(B \rightarrow A)$ ，因此以  $S(A \rightarrow B)$  即可包含這兩個支持度屬性值。圖五的例子顯示了五張影像的色塊屬性關聯規則及其轉換後的資料。

經過整理後，其屬性為所有訓練用影像支持度屬性與確信度屬性聯集的總數，而資料的筆數則為訓練用影像的總數。

Image 1	Image 2	Image 3
$A \rightarrow B, \text{conf}=25\%$ supp=10%	$A \rightarrow B, \text{conf}=65\%$ supp=12%	$A \rightarrow B, \text{conf}=11\%$ Supp=21%
$B \rightarrow A, \text{conf}=74\%$ supp=10%	$B \rightarrow A, \text{conf}=24\%$ supp=12%	$B \rightarrow A, \text{conf}=22\%$ Supp=21%
$C \rightarrow A, \text{conf}=17\%$ supp=5%	$C \rightarrow A, \text{conf}=37\%$ supp=3%	$C \rightarrow B, \text{conf}=76\%$ supp=13%
$A \rightarrow C, \text{conf}=82\%$ supp=5%	$A \rightarrow C, \text{conf}=32\%$ supp=3%	$B \rightarrow C, \text{conf}=12\%$ supp=13%
Class=C1	Class=C1	Class=C2

Image 4	Image 5
$C \rightarrow A, \text{conf}=22\%$ Supp=4%	$C \rightarrow A, \text{conf}=14\%$ supp=31%
$A \rightarrow C, \text{conf}=77\%$ Supp=4%	$A \rightarrow C, \text{conf}=19\%$ supp=31%
$C \rightarrow B, \text{conf}=13\%$ Supp=9%	$D \rightarrow B, \text{conf}=23\%$ supp=4%
$B \rightarrow C, \text{conf}=31\%$ Supp=9%	$B \rightarrow D, \text{conf}=29\%$ supp=4%
Class=C2	Class=C2



ClassT	C1	C1	C2	C2	C2
$S(A \rightarrow B)$	10%	12%	21%		
$C(A \rightarrow B)$	25%	65%	11%		
$C(B \rightarrow A)$	74%	24%	22%		
$S(C \rightarrow A)$	5%	3%		4%	31%
$C(C \rightarrow A)$	17%	37%		22%	14%
$C(A \rightarrow C)$	82%	32%		77%	19%
$S(C \rightarrow B)$			13%	9%	
$C(C \rightarrow B)$			76%	13%	
$C(B \rightarrow C)$			12%	31%	
$S(D \rightarrow B)$					4%
$C(D \rightarrow B)$					23%
$C(B \rightarrow D)$					29%

圖五

##### (二) 動態多決策樹演算法

我們提出動態多決策樹演算法將 C4.5 [9] 作了以下兩個擴增。

(1) 動態決定屬性值分割：ID3 演算法應用於數值屬性資料的分類正確率較差。進行決策樹演算之前先將屬性數值值域範圍分割為幾個子集，再以符號代表這些子集，則可將數值屬性值轉為較少的符號屬性值，提高分類正確率。C4.5[9]將數值屬性皆分為兩個子集，並利用亂度決定最佳的分割邊界，轉換屬性值之後再進行決策樹建構。論文[15]指出，在建立決策樹過程，每次分支判斷時動態決定數值屬性值域範

圍的方式可以進一步提高分類正確率。因此，我們將 C4.5 的數值屬性轉換由靜態產生改為動態產生。

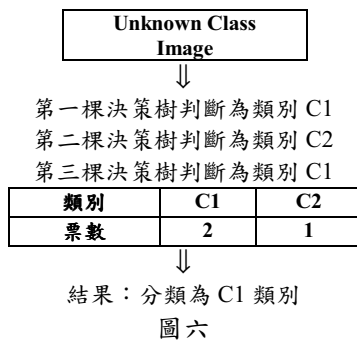
(2) 建立多決策樹：傳統決策樹演算法僅建立一個決策樹。但是在屬性維度高的狀況下，建立一個決策樹只使用了所有屬性中一小部份的屬性，因而有可能遺漏掉其它對分類重要的屬性。因此，在建立一決策樹後，我們使用訓練資料中未被已建構好之決策樹使用過的屬性，繼續建構決策樹。

由於論文篇幅所限，詳細演算法請參考[1]。

### (三) 多決策樹分類方法

#### (1) 多決策樹投票法

動態多決策樹演算法所產生的多決策樹可以視為多個分類決策者。一未知類別的影像，可能被第一個決策樹分類至類別一，而被第二個決策樹分類至類別二。每個決策樹擁有一票，由多個決策樹進行投票，則得票數最高的類別便是最後的分類決策結果。我們稱此決策方法為多決策樹投票法，圖 6 為其示意圖。

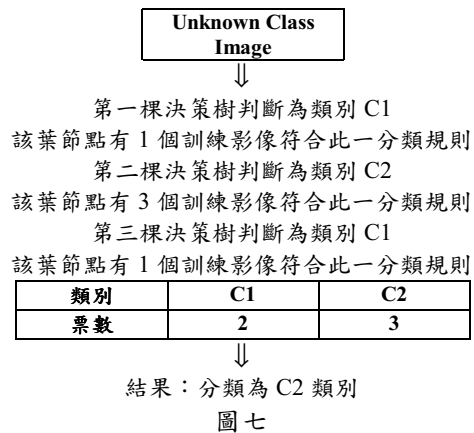


#### (2) 多決策樹加權投票法


決策樹的葉節點將訓練影像分割為數個子集，每個葉節點中所包含的影像數量並不相同。若一葉節點中所包含的訓練影像數量較多，表示決策樹中根節點至此葉節點路徑上所形成之分類規則有較多的訓練影像符合，亦代表有較多的訓練影像符合此一分類規則。因此，以落在葉節點上的訓練影像數量作為分類決策投票的加權，更能反應出決策樹上各分類規則間重要度的差異。我們稱此方法為多決策樹加權投票法，圖七為其示意圖。

若訓練影像中各個類別的影像數量不相同，則多決策樹加權投票法可能產生不公平的投票結果。例如，若訓練影像中有 20 張森林影像與 40 張沙漠影像，則建立出來的多決策樹中沙漠類別的葉節點其影像數加權將會較高。為了避免這種情形，我們將葉節點的

加權值先以訓練影像中同類別的影像數標準化，再進行加權投票。



圖八為一個決策樹葉節點投票加權值標準化的例子，訓練影像中有 10 張影像屬於 C1 類別，20 張影像屬於 C2 類別：



因此，在同一個決策樹中，同一類別之葉節點投票加權值在標準化後其總和為 1。

#### (3) 分類決策結果模糊化

多決策樹投票法與多決策樹加權投票法皆以得票數最高之類別為分類決策結果，其分類結果並非模糊型式。將分類決策結果以模糊型式[10]表示可以表達分類決策的明確程度，並提供更多的資訊。因此，以下我們介紹將分類決策結果模糊化的方法。

若一組多決策樹 MDT 用於分類  $C_1, C_2, C_3, \dots, C_n$  共  $n$  個類別，且一影像  $I$  經由 MDT 加權投票後，各類別之得票數分別為  $V_1,$

$V_2、V_3...V_n$ ，則該影像屬於類別  $C_X$  之關係程度值表示為  $\text{Membership}(C_X)$ ：

$$\text{Membership}(C_X) = V_X / (V_1 + V_2 + V_3 + \dots + V_n)$$


我們將影像 I 之模糊分類結果以模糊分類向量表示：

$$\text{FCV}_I = [\text{Membership}(C_1) \text{ Membership}(C_2) \text{ Membership}(C_3) \dots \text{Membership}(C_n)]$$

以圖五為例，該圖中類別 C1 得票數為 2 票，類別 C2 得票數為 3 票；故該影像屬於類別 C1 之關係程度值為 0.4，屬於類別 C2 之關係程度值為 0.6；而其模糊分類向量為 [0.4 0.6]。

#### (四) 分類規則精簡

由建構出來的決策樹根節點至各個葉節點路徑上之判斷條件皆形成一個分類規則，葉節點之投票加權值則稱為該分類規則之重要度，如圖九。



IF  $C(A \rightarrow C) < 0.2$  and  $C(D \rightarrow A) < 0.7$   
then Class=C1, Importance=0.3

IF  $C(A \rightarrow C) < 0.2$  and  $C(D \rightarrow A) \geq 0.7$   
then Class=C2, Importance=0.4

IF  $C(A \rightarrow C) \geq 0.2$  and  $S(C \rightarrow B) < 0.14$   
then Class=C1, Importance=0.7

IF  $C(A \rightarrow C) \geq 0.2$  and  $S(C \rightarrow B) \geq 0.14$   
then Class=C2, Importance=0.6

圖九

由於建構決策樹時所採用的屬性種類很多，由多決策樹中各個決策樹產生的分類規則之數量相當大，若能精簡這些分類規則，則可以提高分類時的速度。假設多決策樹 MDT 可分類出  $C_1、C_2...C_n$  共  $n$  個類別，MDT 中有  $M$  個決策樹。將分類決策結果為類別  $C$  之分類規則依照重要度由高至低排序，若前  $K$  個分類規則之重要度之合恰大於所有類別  $C$  分類規則重要度之合的  $X\%$ ，則稱此  $K$  個分類規則為**類別 C 前  $X\%$  重要之分類規則**。

依以上的定義，我們以『取各類別前  $X\%$  重要之分類規則』作為精簡分類規則的方法。

#### (五) 動態模糊多決策樹

模糊理論(fuzzy-set theory)[10]是一種描述事物其不明確性與含糊性的方法。影像之語意概念本身具有不明確性，因此使用模糊理論可以更適當地表達影像的類別。例如一張影像其森林類別的關係程度值為 0.7，其沙漠類別的關係程度值為 0.3，代表此影像較近似森林類別，而較不近似沙漠類別。

在本節，我們設計了對動態多決策樹分類決策結果模糊化的函式，但是在動態多決策樹建構過程中並未使用模糊理論。因此我們將[16]中之模糊決策樹方法擴增為動態決定屬性值關係程度函數並建立多決策樹，以將模糊理論導入決策樹建構過程中，同時可讓訓練用影像的類別以模糊型式表示。

其中動態找出一個最佳分割屬性值，並將屬性值表示為小於最佳分割屬性值之模糊集及大於等於最佳分割屬性值的模糊集。兩個模糊集的關係程度函數訂定方法如下：

已知  $0 \leq X \leq 1、0 \leq Y \leq 1$ ，

$$\text{Membership}(X, < Y) = 0.5 * (Y - X) / Y + 0.5, X < Y$$

$$= 0.5 * (1 - X) / (1 - Y), X \geq Y$$

$$\text{Membership}(X, \geq Y) = 1 - \text{Membership}(X, < Y)$$

例如屬性值 0.4 屬於『小於 0.2』集合的關係程度值為  $\text{Membership}(0.4, < 0.2) = 0.5 * (1 - 0.4) / (1 - 0.2) = 0.375$ ，屬於『大於等於 0.2』集合的關係程度值為 0.625；屬性值 0.4 屬於『小於 0.8』集合的關係程度值為  $\text{Membership}(0.4, < 0.8) = 0.5 * (0.8 - 0.4) / 0.8 + 0.5 = 0.75$ ，屬於『大於等於 0.8』集合的關係程度值為 0.25。

### 五、演算法效能評估

#### (一) 分類正確率測試

##### (1) 正確率測試方法

我們將已知類別的影像分為訓練集與測試集兩個集合，將訓練集影像用以建立影像分類決策規則，再以這些影像分類決策規則分類測試集影像，若分類決策結果與影像已知類別相同則為一個正確分類結果，反之則為錯誤分類結果。若測試集影像共有  $T$  張，其中  $C$  張為正確分類結果，則分類正確率為  $C/T$ 。

##### (2) 實驗用影像

我們使用的實驗用影像共有五組，其來源為由 Coral Professional Photos CD-ROM 以關

關鍵字查詢合適類別的影像，接著再以人工粗略篩選掉類別不明確的影像。實驗影像的數量與類型如圖十所示。

影像組別	影像總數	訓練集影像數	測試集影像數	影像類型	類別數
Set1	819	592	227	自然風景	2
Set2	560	300	260	自然風景*	2
Set3	300	240	60	動物	4
Set4	400	300	100	材質	5
Set5	720	450	270	交通工具	3
Set6	480	360	120	交通工具*	3

圖十

其中 Set2 的影像為 Set1 中的影像再進一步以人工挑選，去除掉無法確定類別的影像；Set6 的影像亦為 Set5 中的影像再以人工篩選不確定類別的影像。Set3 與 Set4 由於影像數量較少，因此不再進行篩選。自然風景影像分為沙漠及森林兩種類別；動物影像分為大象、馬、獅子、老虎四種類別；材質影像分為人造品、雲彩、數學碎形圖案、植物、礦物五種類別；交通工具分為飛機、車輛、船三種類別。

#### 實驗一：與 C4.5 的比較

本實驗中我們比較動態多決策樹分類方法及 C4.5[9]對各種類型實驗影像的分類正確率。本實驗中動態多決策樹分類方法固定產生 40 棵決策樹，取以前 N 棵決策樹 (N=1,2,3,...,40) 分類效果最好的正確率作為圖中顯示之分類正確率。

影像組別	C4.5	動態多決策樹
Set1	81.5%	85.02%
Set2	85.77%	90.38%
Set3	60.00%	75.00%
Set4	60.00%	87.00%
Set5	64.07%	78.89%
Set6	66.67%	85.83%

圖十一

由圖十一可看出，我們所提出的動態多決策樹分類方法分類正確率明顯優於 C4.5。此外，比較 Set1 與 Set2 之分類正確率以及 Set5 與 Set6 之分類正確率，可知影像經過進一步以人工挑選去除不明確類別之圖形，可提高分類的效果。

#### 實驗二：與模糊決策樹的比較

本實驗中我們以色塊屬性關聯規則為特徵，比較動態模糊多決策樹分類方法及模糊決策樹[18]對各種類型影像的分類正確率。本實驗中動態模糊多決策樹與模糊決策樹之

Significant Level 皆為 0.5，Truth Level 皆為 0.9；模糊決策樹進行資料模糊化步驟時，以 0.5 為分割邊界將各屬性值個別分為『小於 0.5』及『大於等於 0.5』兩個模糊集。動態模糊多決策樹分類方法固定產生 40 棵模糊決策樹，取以前 N 棵決策樹 (N=1,2,3,...,40) 分類效果最好的正確率作為圖中顯示之分類正確率。

影像組別	模糊決策樹	動態模糊多決策樹
Set1	70.93%	82.82%
Set2	85.00%	91.54%
Set3	68.33%	81.67%
Set4	59.00%	86.00%
Set5	58.89%	77.78%
Set6	70.83%	88.33%

圖十二

由圖十二可看出，我們所提出的動態模糊多決策樹分類方法分類正確率明顯優於模糊決策樹。此外，比較 Set1 與 Set2 之分類正確率以及 Set5 與 Set6 之分類正確率，可知若影像經過進一步以人工挑選去除不明確類別之圖形，可以提高分類的效果。

#### 實驗三：動態模糊多決策樹與動態多決策樹的比較

本實驗中我們分別以動態多決策樹方法及動態模糊多決策樹建立 40 棵多決策樹，同樣以前 N 棵決策樹 (N=1,2,3,...,40) 分類效果最好之正確率作為圖中顯示之分類正確率作比較。

影像組別	動態多決策樹	動態模糊多決策樹
Set1	85.02%	82.82%
Set2	90.38%	91.54%
Set3	75.00%	81.67%
Set4	87.00%	86.00%
Set5	78.89%	77.78%
Set6	85.83%	88.33%

圖十三

由圖十三可看出，在大部份狀況下動態模糊多決策樹分類方法有較佳的分類效果。


#### 實驗四：多決策樹數量的影響(a)

本實驗中我們以動態多決策樹方法建立多決策樹，觀察產生決策樹的數量對多決策樹加權投票法分別以各種類型影像為分類影像時，分類正確率的影響。

由圖十四可看出，對各類影像，動態多決



策樹分類方法在產生 10 至 20 棵決策樹時有最佳的分類效果；若僅針對 Set2 與 Set6(即經過人工篩選後之影像集)，則動態多決策樹分類方法在產生 5 至 10 棵決策樹時有最佳的分類效果。




圖十四

#### 實驗五：多決策樹數量的影響(b)

本實驗中我們以動態模糊多決策樹方法建立模糊多決策樹，比較產生 N 棵模糊決策樹以多決策樹加權投票法分類各種類型影像的分類正確率。本實驗中動態模糊多決策樹之 Significant Level 固定為 0.5，Truth Level 固定為 0.9。

由圖十五可看出，動態模糊多決策樹分類方法在產生 25 至 35 棵模糊決策樹時有最佳的分類效果。若僅針對 Set2 與 Set6(即經過人工篩選後之影像集)，則動態模糊多決策樹分類方法在產生 5 至 10 棵決策樹時有最佳的分類效果。



圖十五

#### 實驗六：多決策樹投票法與多決策樹加權投票法的比較(a)

本實驗中我們以動態多決策樹方法建立多決策樹，比較以多決策樹投票法與多決策樹加權投票法分類各種類型影像的分類正確率。

由圖十六可看出，在大多數情況下，動態多決策樹以多決策樹加權投票法分類較多決策樹投票法分類有稍高的正確率。

影像組別	多決策樹投票	多決策樹加權投票
Set1	84.58%	85.02%
Set2	91.92%	90.38%
Set3	73.33%	75.00%
Set4	82.00%	87.00%
Set5	77.04%	78.89%
Set6	84.17%	85.83%

圖十六

#### 實驗七：多決策樹投票法與多決策樹加權投票法的比較(b)

本實驗中我們以動態模糊多決策樹方法建立模糊多決策樹，比較以多決策樹投票法與以多決策樹加權投票法分類各種類型影像的分類正確率。

影像組別	多決策樹投票	多決策樹加權投票
Set1	85.90%	82.82%
Set2	90.38%	91.54%
Set3	76.67%	81.67%
Set4	72.00%	86.00%
Set5	75.19%	77.78%
Set6	85.00%	88.33%

圖十七

由圖十七可看出，動態模糊多決策樹以加權投票法分類在大多數狀況下有較佳的分類效果。

#### 實驗八：分類決策規則精簡方法評估(a)

本實驗中我們以動態多決策樹方法建立 40 棵多決策樹，取出 40 棵決策樹中所有的分類規則；分別比較以全部分類規則、取前 50%重要分類規則、取前 25%重要分類規則分類、及取前 10%重要分類規則對各種類型影像的分類正確率和所得分類規則的數量。

影像組別	全部	前 50%	前 25%	前 10%
Set1	84.58%	82.38%	82.82%	82.38%
Set2	91.92%	85.38%	85.38%	84.62%
Set3	73.33%	63.33%	65.00%	63.33%
Set4	82.00%	74.00%	75.00%	66.00%
Set5	77.04%	71.11%	68.15%	69.63%
Set6	84.17%	78.33%	80.00%	75.83%

圖十八

由圖十八可知，將動態多決策樹產生之分類以『取前 N%重要分類規則』的分類規則精簡方法可得到與精簡前相若或較低的分類正確率，其所降低的分類正確率約在 2%至 16%。

影像組別	全部	前 50%	前 25%	前 10%
Set1	1370	146	49	18
Set2	699	75	34	12
Set3	1519	217	82	23
Set4	1894	270	97	32
Set5	2105	238	88	28
Set6	1517	171	74	21

圖十九

由圖十九可知，以『取前 N%重要分類規則』的分類規則精簡方法可大量降低分類規則的數量。取前 10%重要分類規則，可將分類規則數量降低至原有的 1%左右；取前 25%重要分類規則，可將分類規則數量降低至原有的 5%左右；取前 50%重要分類規則，可將分類規則數量降低至原有的 10%至 15%左右。

### 實驗九：分類決策規則精簡方法評估(b)

本實驗中我們以動態模糊多決策樹方法建立模糊多決策樹，分別比較以全部分類規則、取前 50%重要分類規則、取前 25%重要分類規則分類、及取前 10%重要分類規則對各種類型影像的分類正確率和分類規則數量。

影像組別	全部	前 50%	前 25%	前 10%
Set1	85.90%	83.26%	84.58%	85.46%
Set2	90.38%	90.00%	90.00%	90.77%
Set3	76.67%	70.00%	66.67%	63.33%
Set4	72.00%	69.00%	67.00%	59.00%
Set5	75.19%	75.19%	74.04%	71.48%
Set6	85.00%	80.83%	77.50%	78.33%

圖二十

由圖二十可知，將動態模糊多決策樹產生之分類以『取前 N%重要分類規則』的分類規則精簡方法將得到相若或較低的分類正確率。依照影像類型的不同，可能降低 1%至 13%。

影像組別	全部	前 50%	前 25%	前 10%
Set1	1509	115	46	17
Set2	754	62	30	12
Set3	2649	327	90	29
Set4	3124	361	111	40
Set5	3042	251	86	28
Set6	2517	206	76	27

圖二十一

由圖二十一可知，以『取前 N%重要分類規則』的分類規則精簡方法可大量降低分類規則的數量。取前 10%重要分類規則，可將分類規則數量降低至原有的 1%左右；取前

25%重要分類規則，可將分類規則數量降低至原有的 3%左右；取前 50%重要分類規則，可將分類規則數量降低至原有的 7%至 10%左右。

### (二) 將模糊分類結果應用於影像查詢

我們使用本章第一節中的影像資料，將訓練集影像用以建立影像分類決策規則，再以這些影像分類決策規則分類測試集影像，並將模糊分類向量作為測試集的影像資料庫索引。我們定義**分類模糊比**供使用者作為查詢影像的參數。

若一影像資料庫中之影像可分為 n 個類別，資料庫中之影像 I 其模糊分類向量為  $FCV_I=[F_1 F_2 F_3 \dots F_n]$ ，則：

首位類別模糊值

$$\text{TopClassF} = \text{Top1}(F_1 F_2 F_3 \dots F_n)$$

次位類別模糊值

$$\text{SecondClassF} = \text{Top2}(F_1 F_2 F_3 \dots F_n)$$

$$\text{分類模糊比 ClassificationFuzzyRate} = \text{SecondClassF} / \text{TopClassF}$$

例如一影像之模糊分類向量為 [0.2 0.4 0.1 0.3]，則其首位類別模糊值 0.4，次位類別模糊值為 0.2，分類模糊比為 50%。若分類模糊比越高，表示首位類別與次位類別越接近，即較不確定類別；若分類模糊比越高，表示首位類別與次位類別差距越大，即較確定類別。

我們傳回首位類別與使用者指定類別相同且分類模糊比低於使用者指定之門檻值的影像，並將影像依分類模糊比由低至高排序。

查詢類別 C 之影像，整個影像資料庫中有 M 張類別 C 之影像，傳回影像為 I 張，其中有 E 張不為類別 C；我們以下式計算查詢結果的 recall 與 precision：

$$\text{recall}=(I-E)/M$$

$$\text{prediction}=E/I$$

下圖為分別以 50%、40%、30%、20%為分類模糊比門檻時的 recall：

影像組別	全部	前 50%	前 25%	前 10%
Set1	0.92	0.88	0.84	0.75
Set2	0.93	0.9	0.86	0.80
Set3	0.52	0.43	0.37	0.35
Set4	0.75	0.69	0.6	0.45
Set5	0.78	0.71	0.62	0.52
Set6	0.87	0.82	0.73	0.64

圖二十二

下圖為分別以 50%、40%、30%、20% 為分類模糊比門檻時的 precision：

影像組別	全部	前 50%	前 25%	前 10%
Set1	0.66	0.69	0.86	0.88
Set2	0.92	0.93	0.93	0.95
Set3	0.74	0.77	0.82	0.86
Set4	0.84	0.84	0.87	0.89
Set5	0.80	0.82	0.85	0.87
Set6	0.86	0.87	0.90	0.92

圖二十三

## 六、結論

在本論文中，我們提出一種影像分類的方法。此方法以影像中色塊屬性值的二元關聯規則為影像特徵，並以動態多決策樹演算法建立影像分類決策規則。我們以不同類型影像進行實作分類正確率評估，證實了本論文所提出之分類方法於不同類型之影像皆達到一定程度的分類正確率，並且優於 C4.5 與模糊決策樹。經過我們所提出的方法精簡分類規則後，決策規則數量約為精簡前的 1% 至 5%，而仍具有與精簡前相近的分類正確率。我們亦將本方法擴增為模糊型式，可接受模糊類別的訓練影像並產生模糊型式的分類結果。在我們的實驗中顯示，在某些類型的影像分類上，動態模糊多決策樹之分類效果較動態多決策樹更佳。

在未來研究方向上，我們將考慮以下幾個部份：一、加入更多的色塊屬性，以使色塊屬性關聯規則能表達更多的影像特徵；二、將色塊屬性與其它屬性結合後產生關聯規則，使影像特徵更為豐富；三、發展可以自動篩選訓練影像的方法，以增進色塊屬性關聯規則分類方法的分類效率及正確率；四、結合網際網路資料搜尋擷取的技術，自動取得訓練用影像與其影像類別；五、將分類方法應用於網際網路影像自動分類，提供使用者以語意類別搜尋影像的功能。

## 七、參考文獻

- [1] 陳建宏，“以色塊屬性關聯規則建立影像分類決策之研究”，碩士論文，國立台灣師範大學資訊教育研究所，2001。
- [2] V. Athitsos, M.J. Swain, and C. Frankel, “Distinguishing Photographs and Graphics on the World Wide Web”, *Proceedings of the 1997 Workshop on Content-Based Access of Image and Video Libraries*, 1997.
- [3] S. Belongie, C. Carson, H. Greenspan, and J. Malik, “Color and Texture-based Image Segmentation using EM and its Application to Content-based Image Retrieval,” *Proceedings of the Sixth International Conference on Computer Vision*, Jan. 1998.
- [4] S.D. Bona and O. Salvetti, “An Enhanced Neural System for Biomedical Image Classification,” *Proceedings of the 4th IEEE Southwest Symposium on Image Analysis and Interpretation*, 2000.
- [5] C. Carson, S. Belongie, H. Greenspan, and J. Malik, “Region-Based Image Querying,” *Proceedings of the 1997 Workshop on Content-Based Access of Image and Video Libraries*, 1997.
- [6] M. Flickner, H. Sawhney, W. Niblack, J. Ashley, Q. Huang, B. Dom, M. Gorkani, J. Hafner, D. Lee, D. Petkovic, D. Steele, and P. Yanker, “Query by Image and Video Content: The QBIC System,” *IEEE Computer*, Vol. 28, No. 9, Sep. 1995.
- [7] K. Hirata, S. Mukherjea, W.-S. Li, and Yoshinori Hara, “Integrating Image Matching and Classification for Multimedia Retrieval on the Web,” *Proceedings of the IEEE International Conference on Multimedia Computing and Systems Volume I*, 1998.
- [8] W.-S. Li and K.S. Candan, “SEMCOG: A Hybrid Object-based Image Database System and Its Modeling, Language, and Query”, *14th International Conference on Data Engineering*, Feb. 1998.
- [9] J.R. Quinlan, *C4.5: Programs for Machine Learning*, Morgan Kaufmann, 1993.
- [10] T.J. Ross, *Fuzzy Logic With Engineering Applications*, McGraw-Hill, New York St., 1995.
- [11] A.W.M. Smeulders, M. Worring, S. Santini, A. Gupta, and R. Jain “Content-Based Image Retrieval at the End of the Early Years,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 22, No. 12, Dec. 2000.
- [12] D.L. Swets and J. Weng, “Hierarchical Discriminant Analysis for Image Retrieval,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 21, No. 5, May 1999.
- [13] M. Thomas, C. Carson, and J.M. Hellerstein, “Creating a Customized Access Method for Blobworld,” *Proceedings of the 16th International Conference on Data Engineering*, 1998.
- [14] L. Yue and H. Guo, “Texture Image Retrieval by Universal Classification for

- Wavelet Transform Coefficients,” *Proceedings of the 1997 International Conference on Image Processing*, 1997.
- [15] R. Gallion, C.L. Sabharwal, D. C. St. Clair and W. E. Bond, “Dynamic ID3: a Symbolic Learning Algorithm for Many-valued Attribute Domains,” *Proceedings of the ACM/SIGAPP symposium on Applied computing: states of the art and practice*, 1993.
- [16] Y. Yuan and M.J. Shaw, “Induction of fuzzy decision trees,” *Fuzzy Sets and Systems*, vol. 69, no. 2, pp.125-139, 1995.
- [17] R.C. Gonzalez and R. E. Woods, *Digital Image Processing*, Addison Wesley Longman, Inc., 1992.
- [18] S.-Y. Wur , Y. Leu, “An Effective Boolean Algorithm for Mining Association Rules in Large Databases,” *Proceedings of the 6th International Conference on Database Systems for Advanced Applications*, 1998.
- [19] S.-J. Yen , A. Chen, “An Efficient Data Mining Technique for Discovering Interesting Association Rules,” *Proceedings of the International Conference and Workshop on Database and Expert System Applications*, pages 664–669, 1997.