

# 行政院國家科學委員會專題研究計畫 成果報告

## 建構以臨床路徑為基礎之醫療資訊系統(2/2)

計畫類別：個別型計畫

計畫編號：NSC93-2213-E-029-008-

執行期間：93年08月01日至94年07月31日

執行單位：東海大學工業工程研究所

計畫主持人：王偉華

共同主持人：陳貽善

計畫參與人員：陳#24419；昕、楊仕蒼、林秀鈴

報告類型：完整報告

報告附件：出席國際會議研究心得報告及發表論文

處理方式：本計畫可公開查詢

中 華 民 國 94 年 9 月 30 日

## 中文摘要

本研究以系統化方法建構臨床路徑，應用資料採礦技術尋找某疾病隱含的多種療程。在分群機制上，採用改良相似度量測方法進行資料群聚分析，藉此改良現有臨床路徑建立之方式，提昇臨床路徑建立之效率、發展病患之適切療程，提供予醫療院所在制訂臨床路徑時之參考依據。並根據病患的特徵，以支援向量機判別所屬療程類別，提供予醫師臨床療程建議之參考，確保病患獲得即時且效益高的醫療照護，避免重複和不必要的診斷、降低醫療費用之浪費，達到確保醫療品質及控制醫療費用之目標。本研究選取「剖腹生產」與「小兒肺炎」兩種疾病進行機制驗證，其中，「剖腹生產」案例為變異性較低之個案，且健保局有相關規定之診斷關係群，「小兒肺炎」案例為變異性較大之個案，目前健保局無相關規定之診斷關係群，利用研究機制分別對病患特徵與療程特徵進行分群，接著進行群組對應與建構病患特徵的支援向量機分類器，藉由不同病例的試驗，驗證研究機制的可行性。實證結果顯示對於不同病例的個案，應用本機制皆能產生適切的臨床路徑藍圖。

關鍵詞：總額預算、臨床路徑、資料群聚、ROCK、支援向量機

## **Abstract**

This research proposed a systemic method to construct the clinical path and using data mining approach to develop the associated treatments for the disease. We adopted a new similar standard in clustering analysis on the clustering mechanism. In this way, the time consumed in constructing clinical path will be reduced. Develop appropriate treatments with patient and offer the blueprint for the medi-cares while constructing the clinical path. According to the patient's feature, we differentiate the treatment category offers blueprint to doctor while deciding clinical path by support vector machine. This research chooses “Caesarian operation” and “Pneumonia of Pediatrics” to verify the researchable mechanism. Using the mechanism to cluster patient's feature and treatment’s feature individually, then mapping two clusters and constructing support vector machine by patient’s feature. The result shows that there is good performance in two kinds of diseases.

**Keyword:** Global Budgeting, Clinical Pathway, Cluster Method, ROCK, Support Vector Machine

# 目錄

中文摘要.....	i
Abstract.....	ii
報告內容.....	1
1.前言.....	1
2.研究目的.....	1
3.文獻探討.....	2
3.1 總額支付制度 ( Global Budgeting ) .....	2
3.2 臨床路徑 ( Clinical Pathway ) .....	2
3.2.1 臨床路徑的定義.....	2
3.2.2 臨床路徑的目的與特點.....	3
3.2.3 發展臨床路徑的驅力.....	3
3.2.4 臨床路徑的益處.....	3
3.3 知識挖掘與資料採礦.....	4
3.3.1 資料採礦模式.....	4
3.4 ROCK 演算法.....	5
3.5 支援向量機器(Support Vector Machine).....	6
3.5.1 SVM 基本表示法.....	6
3.5.2 邊界 ( margin ) 及 Support Vector .....	6
3.5.3 特徵空間 ( feature space ) 學習.....	7
4.研究方法.....	7
4.1 資料範圍.....	7
4.2 研究工具.....	7
4.3 研究機制建立.....	8
4.4 資料收集.....	9
4.5 資料前處理.....	9
4.6 新相似度量測標準之 ROCK 演算法.....	10
4.7 建構病患特徵與療程特徵之配合.....	13
4.8 建構 SVM 分類器與模式評估.....	13
5.結果與討論.....	15
5.1 驗證結果.....	15
5.2 「剖腹生產」案例.....	15
5.2.1 資料特徵值、資料前置分析及處理.....	15
5.2.2 資料群聚、評估與群集對應.....	16
5.2.3 建構 SVM 分類器與評估.....	18
5.2.4 「剖腹生產」案例試驗結論.....	19
5.3 「小兒肺炎」案例.....	19
5.3.1 資料特徵值、資料前置分析及處理.....	19
5.3.2 資料群聚、評估與群集對應.....	20
5.3.3 建構 SVM 分類器與評估.....	22

5.3.4 「小兒肺炎」案例試驗結論.....	23
5.4 結論與建議.....	23
參考文獻.....	24
研究成果自評.....	25

# 報告內容

## 1.前言

全民健康保險 (National Health Insurance, 全民健保) 早期是以論量計酬制 (Fee for Service) 做為支付的標準, 醫療費用之申報依據健保支付標準與藥價基準, 由於民眾就醫的經濟障礙去除, 所以醫療需求全面大幅增加, 醫療院所也樂於以量制價, 造成醫療資源浪費與醫療費用成長率居高不下。中央健保局為使醫療費用之上漲能有效控制於合理範圍內, 遂著手改革支付制度。計劃逐步推動論病例計酬制度 (Per case or case payment) 醫療費用總額支付制度 (Global Budgeting) 及論人支付制度 (Capitation), 以規範各醫療單位的年度收入 (朱樹勳, 2000)。

目前我國全民健保的支付制度已改採總額預算制度為主, 診斷關係群 (Diagnosis Related Groups, DRGs) 為輔的支付形態。健保局欲藉前瞻性支付制度, 並輔以合理門診量、住院費用部分負擔上限、自主管理、卓越計劃等小型計畫, 促使醫療院所重視醫療資源浪費之問題, 著手控制醫療費用合理發生。總額預算制度及管理措施為醫療院所帶來的問題, 主要為醫療院所之收入受限於支付標準及藥價基準, 治療過程亦需遵守健保規範。醫院依其經營「定位」之需要, 得選擇目前支付制度或是調整版的 DRGs 或是支付標準相對值表 (Resource-Based Relative Value Scales, RBRVs) 做為計酬之準則, 如何在確保醫療品質的前提下, 調整醫療服務專科別、照護別之結構以及用藥與用料則是當前醫院管理的重要課題 (莊逸洲, 2004)。

醫界引進了產業界的一些措施, 來達成上述目的, 例如全面品質管理 (Total Quality Management, TQM) 個案管理 (Case Management) 成果管理 (Outcome Management) 和臨床路徑 (Clinical Pathway) 等。根據國內外實證研究顯示, 無論實施任何科別之臨床路徑, 對於醫療資源耗用、醫療成本及醫療品質方面都有正向結果 (Marrie *et al.*, 2000; Kelly *et al.*, 2000; Pearson *et al.*, 2001; Marja *et al.*, 2002; Susan Jones *et al.*, 2003; 張慧朗, 1995; 王炯琅, 2000; 黃三桂, 2000; 許幼青, 2000; 曾劍英, 2001; 潘德樑, 2002)。

傳統臨床路徑之制定方法, 由臨床上各專業人員共同參與, 以統計性資料為參考, 歷經設計、選擇、評估等階段制定而成。然而路徑制定過程需要反覆以人力協商方式評估及修正路徑, 路徑制定的時間相當漫長且效率不彰 (莊莉瑩, 2001; 李淑芬, 2002)。另外, 國內某些醫療院所以國外醫院實行之臨床路徑為發展臨床路徑之雛型, 修改其中醫療項目以符合療程所需, 但因國情及國人體質之不同, 路徑內容仍需以人力協商方式進行大幅度修改, 路徑制訂的時間亦漫長且效果不彰。

## 2.研究目的

研究目的為建構出以系統化之臨床路徑建立機制, 改良現有臨床路徑建立之方式, 以提昇臨床路徑建立之效率、發展病患之適切療程, 提供予醫療院所在制訂臨床路徑時之參考依據, 並建立病患分類機制, 提供予醫師臨床療程建議之參考, 確保病患獲得即時且效

益高的醫療照護。本研究期望藉由機制之運作，可大幅縮短傳統方法所花費之協商時間，並達到確保醫療品質與醫療費用控制之目的。

### 3.文獻探討

#### 3.1 總額支付制度 (Global Budgeting)

總額支付制度是指相關健康保險團體 (含付費者、醫療供給者與保險主管機關)，就特定範圍的醫療服務，如牙醫門診、中醫門診、西醫門診，或住院服務等，預先以協商方式，訂定未來一段期間 (通常為一年) 內健康保險醫療服務總支出 (預算總額)，以酬付該服務部門在該期間內所提供的醫療服務費用，並藉以確保健康保險維持財務收支平衡的一種醫療費用支付制度 (李玉春, 2001)。因此，總額支付制度的規劃重點，即是希望透過集體協商來解決消費者與供給者的利益衝突；另外，在供給方面，則以提升專業自主權及藉由同儕制約來促進醫療服務價與量的合理提供，亦即希望資源的配置能更有效率 (周麗芳, 2001)。

我國總額預算制度係採支出上限制 (Expenditure Cap)，即依據醫療服務成本及其服務量的成長情形來設定健保支出年度的預算總額，並以相對點數來反映醫療服務的各项服務成本，即每點支付金額是由預算總額除以實際總服務量 (點數) 的回溯性計價方式而得；當實際總服務量點數超過原先設定的預算總額時，每點支付金額將會下降，反之將增加。由於固定年度總預算而不固定每點支付金額，使得年度醫療費用總額能有效控制。研究指出支出上限制對於控制醫師服務成本有其效果 (Chinn-Ping Fan、Kong-Pin Chen、Kamhon Kan, 1998)。

#### 3.2 臨床路徑 (Clinical Pathway)

臨床路徑起源於 1950 年代，最早是工業界用於界定並管理產品製程中的主要關鍵階段 (rate-limiting steps)，而後被迅速的運用到每個不同的製造層面，例如造船、城市設計、產品設計，1960 年代後漸漸被引用到醫療界 (Horowitzs, 1967)。

##### 3.2.1 臨床路徑的定義

早期臨床路徑由於使用的機構特性不同，而有不同的名稱，例如：關鍵路徑 (critical path)、臨床草案 (clinical protocols)、臨床指引 (clinical guideline)、臨床標竿 (clinical benchmarking)、個案管理 (case management)、複合式照護路徑 (Multidisciplinary Pathway of Care, MPCs) 或整合式照護路徑 (Integrated Care Path, ICPs) 等，Corbert and Androwich (1994) 則建議統一以「臨床路徑」稱之。目前大家一致認為臨床路徑是由醫院集合各種背景的專家，依據某種疾病或手術方法，訂定一種大家認同的治療模式，讓病人由住院至出院都依此模式來接受治療，並依據臨床結果來評估分析檢討其變異 (Dewoody and Price 1994; Heacock and Brobst 1994; 林秀緞, 1999)。

綜合而言，臨床路徑是由不同專業背景的人員 (multidiscipline)，包括醫師、藥師、護理師、麻醉師、檢驗師、營養師、復健師、社工師、個案管理師及相關醫務行政人員等，針對某一特定診斷或特定處置(手術)，參考臨床實際作業流程、保險給付規定、相關研究結果、成本會計分析資料與專家意見等，共同發展一個從入院到出院過程照護指引，以後再根據監控與分析的結果，不斷地予以更新或修正，除了引導並標準化醫療照護小組成員每

天的工作外，並隨時監測結果(變異)，依此方式來控制醫療成本，維護並改善醫療品質 (Blegen *et al.*, 1995; 廖美南、盧美秀, 1997)。

### 3.2.2 臨床路徑的目的與特點

其基本目的是希望藉由觀察和記錄病人的醫療過程與結果，找出最具成本效益的治療模式，同時可維護醫療品質，並依情況而做適當改善，以增進醫療效率。

臨床路徑到底與平常的醫療路徑有何差異？平常醫療路徑為不同醫師，依據各自的醫療行為與計劃，因此彼此間的差異與品質不一，而臨床路徑是由醫師及相關人員組成的團隊，經由溝通和討論，並且須持續不斷評估及修正路徑，達成共識且減少差異，以提高醫療水準。亦即若在不同的照護模式下，不同的醫師可能有不同的照護方式，其產生的結果即可能不同，此不確定性造成醫院成本與品質的控制難以掌握，增加經營管理的困難度，實不是良好的醫療管理方針，惟有實施臨床路徑才可能控制醫療成本與維護品質(王炯琅, 2000)。

臨床路徑的選擇，基本上是以案例多(如疝氣、前列腺肥大、子宮肌瘤、闌尾炎等)或費用高的疾病診斷或手術處置(如冠狀動脈繞道術)為優先，故目前大多數以健保局之論病例計酬項目為選擇對象；在推動初期一般選擇比較單純的疾病或手術，較不會造成併發症者，可以減少個案間的差異性(variance)及縮小醫療人員間的不同意見。發展初期，必須詳細記錄開始施行及最後的差異，加以分析檢討(楊榮森, 2000)。

### 3.2.3 發展臨床路徑的驅力

臨床路徑的施行，是近年來許多醫療機構熱衷於推行的活動。許多的專家學者認為醫療上臨床路徑的發展，主要受到三個驅力的影響(莊逸州等人, 2000)：

1. 醫療體系逐日增加的財務壓力(financial pressure)。
2. 新醫療技術的快速引進。
3. 新的資料顯示不適當的醫療照護與結果(inappropriate care and resultant), 浪費了極為驚人的醫療資源。

### 3.2.4 臨床路徑的益處

臨床路徑既然為醫療團隊根據不同的專業對某些疾病或處置訂出目前認為最好的治療方法，其實成效究竟如何？從國內外許多的文獻資料可以看出其好處如下(朱樹勳, 2000)：

#### 一、降低住院天數及醫療費用

新英格蘭醫學中心(New England Medical Center)心肌梗塞病人，平均住院天數從9天降為7天，心導管病人平均住院天數從5天降為2天(Gouvein, 1995)。台大醫院單純闌尾切除術平均住院日從5.6天降為3.12天(吳敬堂, 2000)；Stanford University Medical Center 實施全膝關節置換術，整個醫療費用從\$21,709 降至\$17,919。台大醫院剖腹產總費用亦從\$33,091 降至\$29,639，無論藥費、檢驗費、治療費都有顯著降低；其他手術處置實施臨床路徑者，幾乎都有明顯的下降(朱樹勳, 2000)。

#### 二、減少變異的發生

臨床路徑為減少變異的一種工具(Anderson and Pestian, 2000)。臨床路徑為由各醫療專業人員共同設計一套治療照護標準，故可減少病患住院時因醫護人員治療程序的不同而



造成變異的發生。

### 三、 提高病患滿意度

四、 臨床路徑可增進醫護人員與病患及家屬之溝通，透過病人版臨床路徑，病人及其家屬可瞭解整個住院過程，預知每天安排之檢查及治療，對於病人心理的調適及與病人家屬溝通助益頗大，且對於安全出院醫囑效率滿意度增加( Lawson *et al.* , 1997 ; Goode , 1995 ; Leibman *et al.* , 2000 ; De Luc , 2000 )。促進照護及資訊持續性

每一個臨床路徑發展期間，醫師、護士與其他人員依據資料、專家的意見或共識，規劃與協調病患治療的各層面作業與工作。臨床路徑可擬訂跨專科治療計劃，詳細將治療步驟及照護過程納入計劃，可作為照護專業人員及病患瞭解整個照護資訊的工具，可讓所有團隊更瞭解病患照護過程，並預知達到之照護結果( Ireson , 1997 ; Van Wersch *et al.* , 1997)。

### 五、 提昇照護品質

臨床路徑完成後，成員依據執行結果加以分析、評估檢討每位病患之差異，以求不斷改進並符合 PDCA 之原則，避免資源不當使用，以提供最好的照護（許幼青，2001）。

## 3.3 知識挖掘與資料採礦

知識發掘 ( Knowledge Discovery in Database , KDD ) 是一連串的程序，根據 Fayyad 等人 ( 1996 ) 對知識發掘的步驟包括：先理解應用的領域與熟悉相關知識，接著建立目標資料集，並專注所選擇的資料子集；再由目標資料中作前置處理，去除錯誤及不一致的資料；然後作資料簡化與轉換的工作；再經由資料探勘的技術形成型樣、作迴歸分析或找出分類型態，最後經過解釋與評估成為有用的知識。由此可知資料採礦 ( Data Mining ) 是知識挖掘的核心，知識挖掘的整個流程包括有資料選擇、資料處理、資料轉換、資料探勘、以及說明與評估。

### 3.3.1 資料採礦模式

目前資料採礦較廣泛應用的模式方程式有以下數種 ( Adriaans and Zantinge , 1996 ; Agrawal *et al.* , 1996 , Fayyad *et al.* , 1996 )：

1. 分類模式 ( Classification )：依據事先定義的資料特徵屬性進行分類預測，分類模式常應用於目標行銷、客戶保留、醫療診斷問題。
2. 迴歸模式 ( Regression )：找出資料輸入與輸出變數之關聯性，用於預測或控制系統之輸出結果。
3. 群聚模式 ( Clustering )：依據資料的特性分為若干個群組，並經過不斷的訓練與學習，會呈現群組的特徵。主要是呈現不同群組間之差異與群組內之共同特徵。分群模式為非監督式 ( unsupervised ) 的學習，有別於分類模式或類神經網路 ( Neural Networks ) 的監督方式 ( supervised )。
4. 關聯分析 ( Link analysis )：用來描述資料庫中欄位與欄位的關係 ( 項目間關聯性 )，如應用關聯式法則於超級市場，找出已知交易記錄中各種銷售項目 ( items ) 之間的關聯性。
5. 時序性分析 ( Sequence analysis )：針對資料的順序關係進行採礦，例如在時間上的順序、行為上的順序等，而主要是希望能找出分析趨勢或順序的資訊。

### 3.4 ROCK 演算法

ROCK ( Robust clustering Algorithm for Categorical Attributes ) 演算法是階層式演算法中的一支，ROCK 以連結性 ( connectivity ) 定義  $C_i, C_j$  的群間適合度  $g(C_i, C_j)$  (1)，式 2 值越大，表示  $C_i, C_j$  越相似 ( Guhay、 Rastogi and Shim , 1999 )。

$$g(C_i, C_j) = \frac{\text{link}[C_i, C_j]}{(n_i + n_j)^{1+2f(\theta)} - n_i^{1+2f(\theta)} - n_j^{1+2f(\theta)}} \quad (1)$$

$$E_i = \sum_{i=1}^k n_i * \sum_{p_q, p_r \in C_i} \frac{\text{link}(p_q, p_r)}{n_i^{1+2f(\theta)}} \quad (2)$$

式中，分子為  $C_i, C_j$  的交叉連結數  $\text{link}[C_i, C_j]$ ，定義為  $C_i, C_j$  的兩兩物件間連結數總和，即  $\sum_{p_q \in C_i, p_r \in C_j} \text{link}(p_q, p_r)$ ，而連結數  $\text{link}[P_q, P_r]$  定義為  $P_q$  和  $P_r$  共有鄰居的數目； $\theta$  為 threshold，若相似度  $\text{sim}(P_q, P_r) \geq \theta$  則  $P_q$  和  $P_r$  為鄰居；分母為  $(n_i + n_j)^{1+2f(\theta)} - n_i^{1+2f(\theta)} - n_j^{1+2f(\theta)}$  是  $C_i$  和  $C_j$  兩個群的交叉連結期望值， $n_i, n_j$  為  $C_i, C_j$  包含的物件個數， $f(\theta)$  定義為  $\frac{1-\theta}{1+\theta}$ 。

ROCK 演算法有 2 個參數，分別為： $\theta$  與  $k$ 。 $\theta$ ，鄰近點門檻值，依據資料集中任兩筆記錄之相似度判斷兩點是否為鄰近點； $k$ ，欲群聚之最少組數。可依應用領域特性選擇計算任兩點之相似度。ROCK 之群聚程序如下述：

1. 計算任意兩點的相似度。若相似度大於或等於門檻值，則判定此兩點互為鄰近點 ( neighbors )。使用 Jaccard 係數：

$$\text{sim}(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (3)$$

例：若  $\theta=0.5$ ； $A=\{a, c, d\}$ ； $B=\{a, b, d, e\}$ ； $C=\{a, c, d, e\}$ ； $D=\{a, c, e\}$ 。

使用 Jaccard 係數來評量兩點之間相似度，則

$$\begin{aligned} \text{sim}(A, B) &= |A \cap B| / |A \cup B| = 2/5 = 0.4 < 0.5 \\ \text{sim}(A, C) &= |A \cap C| / |A \cup C| = 3/4 = 0.75 > 0.5 \\ \text{sim}(A, D) &= |A \cap D| / |A \cup D| = 2/4 = 0.5 = 0.5 \\ \text{sim}(B, C) &= |B \cap C| / |B \cup C| = 3/5 = 0.6 > 0.5 \\ \text{sim}(B, D) &= |B \cap D| / |B \cup D| = 3/5 = 0.6 > 0.5 \\ \text{sim}(C, D) &= |C \cap D| / |C \cup D| = 3/4 = 0.75 > 0.5 \end{aligned}$$

(A, C) \ (A, D) \ (B, C) \ (B, D) 與 (C, D) 互為鄰近點。

2. 計算任意兩點之間鏈結的 ( link ) 個數。當任意兩點  $p_i, p_j$  有  $n$  個共同鄰近點時，其  $\text{links}(p_i, p_j)=n$ 。

例：由步驟 1 之鄰近點結果計算得

$$\begin{aligned} \text{link}(A, B) &= 2 ; \text{link}(A, C) = 1 ; \text{link}(A, D) = 1 ; \\ \text{link}(B, C) &= 1 ; \text{link}(B, D) = 1 ; \text{link}(C, D) = 2 ; \end{aligned}$$

3. 計算將任兩群組間群聚於同一群族適合度 ( goodness measure )。兩群組  $c_i$  與  $c_j$  之適合度以(1)表示。

例：if  $k=3$ ，

$$\begin{aligned} f(\theta) &= (0.5/1.5) = 0.667 ; 1+2f(\theta) = 2.334 ; \\ g(A, B) &= 2 / (2^{2.334} - 1^{2.334} - 1^{2.334}) = 0.6575 ; \\ g(A, C) &= 1 / (2^{2.334} - 1^{2.334} - 1^{2.334}) = 0.3287 ; \end{aligned}$$

$$g(A,D)=1/(2^{2.334} - 1^{2.334} - 1^{2.334})=0.3287 ;$$

$$g(B,C)=1/(2^{2.334} - 1^{2.334} - 1^{2.334})=0.3287 ;$$

$$g(B,D)=1/(2^{2.334} - 1^{2.334} - 1^{2.334})=0.3287 ;$$

$$g(C,D)=2/(2^{2.334} - 1^{2.334} - 1^{2.334})=0.6575 ;$$

4. 選取群聚適合度最大值之兩群組，將其合併為一個新群組，並刪去原有兩個群組。若群聚適合度之最大值為零時，停止演算程序。

例：群聚適合度最大值之兩群組為(A, B)或(C, D)，若選擇合併(A, B)則群組數為 3 組：(A, B)，(C)，(D)。

5. 重複步驟 1 至 4，直至群組總數為 k，則停止演算程序。

ROCK 之演算時間與所需記憶體之複雜性為  $O(n^2 + nm_m m_a + n^2 \log n)$ ， $m_m$  為鄰近點個數之最大值； $m_a$  為鄰近點個數之平均值； $n$  為輸入資料之記錄筆數。

### 3.5 支援向量機器(Support Vector Machine)

支援向量機器 (SVM, Vapnik 1998) 是由 Vladimir Vapnik 在 1979 年開始研究發展並於 1998 年發表的一種分類方法。為一種機器學習 (machine learning) 的方法，可應用於分類 (pattern classification) 以及迴歸 (regression)。它可以同時降低訓練錯誤 (training error) 以及測試錯誤 (testing error)，現在成為機械學習 (machine learning) 與資料採礦 (data mining) 標準工具之一 (黃彥文, 1999)。

SVM 分類器是建立在最小誤差估計 (risk minimization) 之上，而經驗的最小誤差估計 (empirical risk minimization) 是最常用的技術，其目的是找尋一些參數設定使誤差降到最

$$\text{低： } R_{emp}(\alpha) = \frac{1}{2l} \sum_{i=1}^l |y_i - f(x_i, \alpha)| \quad (4)$$

經驗的最小誤差函式在 (4) 中  $\alpha$  是可調整的參數， $y_i$  是所期待的輸出， $x_i$  是給定的輸入。結構的最小誤差估計法 (Structural Risk Minimization, SRM) 其目的是學習分類器在待估測的誤差 (expected risk) 中如何找最小值。SVM 就是以 SRM 為基礎引申而來。

#### 3.5.1 SVM 基本表示法

一般對於 SVM 當中因子基本表示法如下：

$x$ ：一個向量，描述一筆資料的各個特徵值 (attribute)

$y$ ：為 +1 或 -1，表示兩種類別 (class)

$D$ ：為決定函數 (decision function)

$$D(x) = (w \cdot x) + w_0, \quad w = \sum_i y_i \cdot x_i \quad (5)$$

支持向量分類的目標是在高維度的特徵空間中找出一個區分平面 (separating hyperplanes)。而此區分平面 (separating hyperplanes) 可以找出最大的“margin” (李姿儀, 2000)。

#### 3.5.2 邊界 (margin) 及 Support Vector

Hyperplane 的  $D(x) = 0$ ，而距離 hyperplane 最近的資料點就是所謂的 support vector，因此將 support vector 代入 Decision function 的值為  $D(x) = 1$  與  $D(x) = -1$ 。而其餘資料點代入 Decision function 必定大於 1 或小於 -1，若資料點代入 Decision function 大於 1 為其中一類，小於 -1 則為另一類。

Support vector 與 hyperplane 的距離為  $1/\|w\|$ ，由於經由計算可以得到可能不只一個 hyperplane 來將這些資料分開，因此 SVM 會找到  $\text{margin} = 2/\|w\|$  為最大的 hyperplane，則此 hyperplane 就是最理想的 hyperplane，也就是說資料可以依最理想的 hyperplane 做最明確的分類。

### 3.5.3 特徵空間 (feature space) 學習

在大部分的情況下，資料沒有辦法被線性的分類，因此要把資料映射 (map) 到特徵空間，意味著若資料無法在所在的維度下明確的分類，SVM 會將資料轉換至高維度之後再做分類，轉換公式如下：

$$\Phi: R^n \rightarrow R^m, m > n \quad (6)$$

觀察對偶問題，發現在對偶問題中，資料的處理都是用到向量內積 (inner product)，因此若要在特徵空間學習，只要能計算出資料在特徵空間中的內積值就可以了，並不需要直接把資料映射到特徵空間。而將資料轉換至高維度之後，在計算式 2.11 時必須耗費時間來做內積的運算。

$$k(x, y) = \Phi(x) \cdot \Phi(y) \quad (7)$$

因此 SVM 便會定義 kernel function 來簡化內積運算，以加快運算的速度，Kernel function 定義如下：

SVM 中所定義的 kernel function 有下列幾種：

Simple dot:  $k(x, y) = x \cdot y$

Polynomial:  $k(x, y) = (x \cdot y + 1)^p$

Radial basis function:  $k(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right)$

Sigmoid kernel:  $k(x, y) = \tanh(k(x \cdot y) - \theta)$

## 4. 研究方法

### 4.1 資料範圍

本研究探討群聚演算法中，改良式相似度量測標準應用於臨床路徑的建立機制。本研究選擇之「剖腹生產」案例，為療程特徵複雜度較低之個案，並以健保局規定之 DRGs 為治療程序的準則，作為實證研究的第一病例；「小兒肺炎」為療程特徵複雜度較高之個案，目前健保局並無相關規定的 DRGs，以此案例探討其進行臨床路徑管理之可行性與效益評估，驗證研究機制於不同科別之可行性，作為實證研究的第二病例。

### 4.2 研究工具

研究原始資料為文字檔格式，資料前處理步驟應用 Microsoft Excel 與 Microsoft Access 軟體。先以 Microsoft Excel 作為轉換格式的工具，將處理過的資料輸入資料庫中，再匯入 MATLAB 做為各項研究步驟的輸入資料。以 MATLAB 作為整合介面的工具，應用 MATLAB 應用軟體處理病患特徵群集及療程特徵群集運算，並應用 MATLAB 應用軟體將資料轉換為 LIBSVM 可使用之格式。建立支援向量機是利用 MATLAB 介面的 LIBSVM 程式，藉由調整適當參數組合，建構與訓練 SVM 分類模式。

MATLAB 應用軟體為一套應用於數值計算、數據視覺化及動態模擬的軟體，具有簡易的程式語法結構，本研究以此語法進行病患特徵群集、療程特徵群集以及 SVM 分類器的程

式撰寫。

### 4.3 研究機制建立

本研究之研究機制設計，如圖 1。本研究機制設計分為兩大部分：(1) 建立病例病徵與療程配合之臨床路徑；(2) 建構 SVM 分類器。

#### (1) 建立病例病徵與療程配合之臨床路徑

首先，進行資料收集及資料前處理，將 2/3 資料量分割為訓練資料，篩選所需欄位與進行初步資料欄位的型態轉換。訓練資料欄位中包含三種類別的資料內容，分別為：病患管理資料、病患特徵資料及療程特徵資料。本研究將訓練資料依照不同類別先行分割為三種不同表格。本研究著重於臨床路徑之建立，擷取其中病患特徵資料與療程特徵資料為研究資料集。應用改良相似度量測標準之 ROCK 演算法將兩種資料集進行分群，分群結果產生的資料，本研究稱為病患特徵群集與療程特徵群集。其中療程特徵群集，評估其分群所得結果之療程正確性方式有兩種方式：

1. 屬於健保局有規定之 DRGs 案件。評估各療程群集的醫令組合是否滿足 DRGs 的必做項目規範。若不符合規範，則回到群組化步驟進行參數調整。
2. 屬於非健保局有規定之 DRGs 案件。由專業醫師評估各療程群集醫令組合的合理性。若無法達到專業之要求，則回到群組化步驟進行參數調整。

將病患特徵群集與療程特徵群集進行配合，形成符合病例病徵與療程配合之臨床路徑。

#### (2) 建構 SVM 分類器

建立病患特徵與療程類別之對應模型，藉由 SVM 分類器提供予醫師臨床路徑之建議。以訓練資料集作為訓練、建構 SVM 之資料集，訓練資料集中以病患特徵項目為 SVM 的輸入變數，病患特徵群集類別為輸出變數。完成 SVM 分類器訓練後，分類器可被應用於預測病患所屬療程類別。分類器之評估，則進行分類器模擬測試。以測試資料集為 SVM 模擬之輸入資料，所得分類器之準確率做為評估分類器之考量依據。

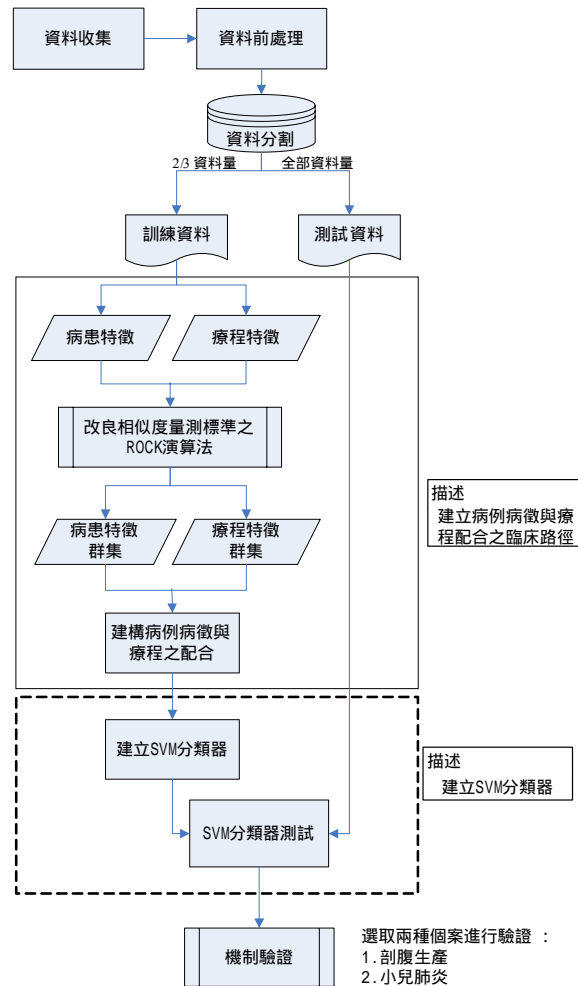


圖 1 研究機制流程圖

#### 4.4 資料收集

本研究資料收集之對象為「健保局已規定 DRGs 案例」與「健保局未規定 DRGs 案例」，以中區某醫院提供於八十九年度之婦產科「剖腹生產」與九十年度小兒科「小兒肺炎」之健保申報資料為研究對象。資料內容包括：病患管理資料、病患特徵資料及療程特徵資料。病患管理資料為醫療院所在申報健保費用時所需使用之欄位，病患特徵資料為醫療院所對病患檢驗後所產生的診斷資料欄位，其中記錄的代碼格式符合現行標準規定之 ICD-9 碼，療程特徵資料為醫生由病患的診斷結果，依照專業判斷後所決定之醫令執行項目，其中記錄的代碼格式亦符合 ICD-9 碼。

#### 4.5 資料前處理

因本研究的研究所需，擷取所收集資料中的病患特徵資料及療程特徵資料進行研究。病患特徵資料主要記錄病患的檢驗及診斷結果，療程特徵資料主要記錄病患就醫過程的醫療行為。前處理之研究工具為 Microsoft Excel 與 Microsoft Access。本研究為簡化演算法的計算程序及提高演算效率，設計所需的資料模式。為滿足研究流程中研究方法所需資料型式，本研究之資料前處理分為三個部分，如下所述：

1. 特徵資料集的資料型態轉換。基於演算法則的考量，利用替代碼方式，應用 VBA (Visual Basic for Applications) 處理資料型態轉換。例如：年齡為連續型資料分佈，經由替代碼處理，將「出生日期」轉換為「生產年齡」，考量演算法的資料型態，將「生

產年齡」再次轉換為「生產年齡類別」。根據醫學上之定義：女性之適當生產年齡介於 20 至 35 歲之間。本研究將產婦的生產年齡區分為三個類別：(1)未滿 20 歲；(2)介於 20 歲與 35 歲之間；(3)35 歲以上。

2. 簡化療程記錄集。因原始資料集並未提供各項醫令的單次執行次數、數量，僅提供總執行次數、數量。本研究療程分析的考量因素不納入醫令執行次數（假設 5）。又醫院資訊系統因考量作業需求，將同一筆醫令的立即與長期醫囑分為兩筆記錄。所以病歷中同一筆醫令有重覆記錄的情形存在，本研究則刪除執行日數為一天的醫令記錄，以維持每項醫令於各住院日療程的被執行次數為一次。例如：某產婦療程記錄中，5 月 3 日「傷口換藥」及 5 月 3 日至 6 日「傷口換藥」。於此案例，將刪除執行單日的醫令記錄。
3. 訓練資料量與測試資料集。病患特徵資料集與療程特徵資料集以隨機方式選取三分之二資料量為訓練資料集，進行病患特徵分群、療程特徵分群及訓練 SVM 分類器；完整資料量為測試資料集，以評估整體架構的可應用性。

#### 4.6 新相似度量測標準之 ROCK 演算法

ROCK 演算法以群間的交叉連結數作為群間相似度，也就是強調物件間的連結性，若兩物件的共有鄰居數多（即連結數多），則表示兩物件較相似，其群聚成效優於傳統的群聚演算法，更可以較好的方式呈現群聚結果；因此本研究以 ROCK 演算法為基礎，應用修改相似度量測標準進行群聚分析（姚輝林，2004）。

由於 ROCK 演算法不能處理數值型態的資料，必須先行將數值型態的資料轉換為種類型態資料。舉例來說，在剖腹生產案例中，產婦年齡由 17 歲到 43 歲，此時必須將年齡轉換為「生產年齡類別」的種類型資料，如最適生產年齡為 20 歲到 35 歲，則可將產婦年齡分為三種類型，分別為低於最適生產年齡、最適生產年齡與高於生產年齡（資料轉換的部份需要有領域專家協助，確保資料轉換後的正確性）。

目前相似度量測相關研究中，有採用向量空間量測的符合係數（matching coefficient）、Jaccard 係數（Jaccard coefficient）、Simple matching coefficient、Dice coefficient、Overlap coefficient、Cosine 等利用物件的共通性來評估物件間的相似度，或透過機率計算，量測物件間的共同相關性（correlation）來評估物件間的相似度的相互資訊（mutual information）等。共同相關性與相互資訊法均適合使用在數值型資料，但對於種類型的資料，應用上有其困難。表 1 整理幾種適合種類型資料的向量空間相似度量測定義。

表 1 向量空間的相似度量測

相似度量測	定義
matching coefficient	$ T_i \cap T_j $
Dice coefficient	$2 T_i \cap T_j /( T_i + T_j )$
Jaccard coefficient	$ T_i \cap T_j /(T_i \cup T_j)$
Overlap coefficient	$ T_i \cap T_j /\max( T_i , T_j )$
Cosine	$ T_i \cap T_j /\sqrt{( T_i  \times  T_j )}$

其中對於種類型問題，較常見到的是 Jaccard 係數跟符合係數，由於 Jaccard 係數比符合係數這種相似度量測多了正規化 (normalize) 的考量，是比較客觀合理的相似度方式，因此是最常被使用的相似度量測，其係數值介於 0 與 1 之間。

Jaccard 係數有其缺點，當某一項目在資料當中出現的機會很高，Jaccard 係數在估計相似度時，往往有「高估」的情形發生。舉例來說：若研究賣場顧客，是否有數種顧客群；針對不同顧客做不同的促銷方案。將顧客在賣場購買商品的種類，蒐集成為資料集。顧客 A 購買「啤酒」，順便買了包「免洗杯」。顧客 B 購買「烏龍茶」，也買了「免洗杯」。顧客 C...凡是購買瓶裝飲品的顧客，多數都購買了「免洗杯」。「免洗杯」這個項目，很明顯的增加顧客間購買商品的相似度；也許購買「啤酒」與購買「烏龍茶」的顧客，之間的相似度並不強烈，卻因「免洗杯」這類「較不重要」的商品，被歸為同一類顧客。這是因為「啤酒」、「烏龍茶」與「免洗杯」對於相似度的計算上，佔有相同的權重。

為此，(姚輝林，2004) 研究提出不同的相似度量測標準—不同項目的權重應該要有所區別。對於區分不同群集的重要性較強的項目，計算相似度時應該有較大的權重；反之對於區分不同群集的重要性較弱的項目，計算相似度時應該有較小的權重。換句話說，出現頻率很高的項目，對於各筆資料的區隔程度便很低。相反地，如果有一個項目出現的次數很低，那麼若有兩筆資料同時都有這項目，則此項目對兩筆資料之相似性就有很高貢獻。亦即這樣的項目，對各筆資料間的區隔程度很高。

根據上述的原則，可以依照「項目發生頻率」來判別單一項目的重要與否。若是發生頻率較低的，對於群聚過程的相似度判斷，便屬於「較重要項目」。而發生頻率較高的，對於群聚過程的相似度判斷，便屬於「較不重要項目」。如此，便可以區別出不同項目對於相似度判斷的權重。因此新的相似度計算定義如下：

$$a = |X \cap Y|$$

$$b = |X \cup Y|$$

$f$  = 共同含有的「頻繁」項目之個數

$r$  = 共同含有的「特殊」項目之個數

$$\text{相似度 } sim(X, Y) = \frac{a - f}{(b - f) - r}$$

依照修改過後的相似度計算標準結合 ROCK 演算法，首先定義參數  $\theta_f$  為頻繁項目門檻值、 $\theta_r$  為特殊項目門檻值及  $\theta_s$  為 ROCK 演算法的相似度門檻值， $k$  為最小群組數，整體演



算步驟如下：

1. 首先判斷何者為頻繁項目或特殊項目，計算任意兩點的相似度。若相似度大於或等於門檻值，則判定此兩點互為鄰近點 ( neighbors )

$$\text{新的相似度計算方式： } \text{sim}(X,Y) = \frac{a-f}{(b-f)-r}$$

其中，  $a=|X \cap Y|$ ，  $b=|X \cup Y|$

$f$ =共同含有的「頻繁」項目之個數

$r$ =共同含有的「特殊」項目之個數

2. 計算任意兩點之間鏈結的 ( link ) 個數。當任意兩點  $p_i, p_j$  有 1 個共同鄰近點時，其  $\text{links}(p_i, p_j)=1$ 。
3. 計算將任兩群組間群聚於同一群族適合度 ( goodness measure )。兩群組  $c_i$  與  $c_j$  之適合度以  $g(c_i, c_j)$  表示。  $\text{link}[C_i, C_j]$  ( the numbers of cross link between  $C_i$  and  $C_j$  ) 表群組  $i$  與群組  $j$  之間的鏈結數，將群組  $i$  之任一點與群組  $j$  之任一點間的鏈結個數總後得到  $\text{link}[C_i, C_j]$ 。
4. 選取群聚適合度最大值之兩群組，將其合併為一個新群組，並刪去原有兩個群組。若群聚適合度之最大值為零時，停止演算程序。
5. 重複步驟 1 至 4，直至群組總數為  $k$ ，則停止演算程序。

由於 Jaccard 係數對於每一項目均判斷為相同權重，修改後的相似度量測係數係數，根據各項目出現頻率的不同，對於各項目有不同的權重設定，演算法的流程如下 ( 圖 2 )：

1. 依照各項目出現頻率，區分為較重要項目、普通項目以及較不重要項目。
2. 依照不同權重，計算每筆資料之間的相似度。
3. 依據資料相似度，計算連結數。
4. 依據連結數計算群組適合度函數。
5. 將適合度最大的兩群集合併為一群，直到適合度最大值等於零，或已達到最少群集數  $k$ ，終止演算程序。

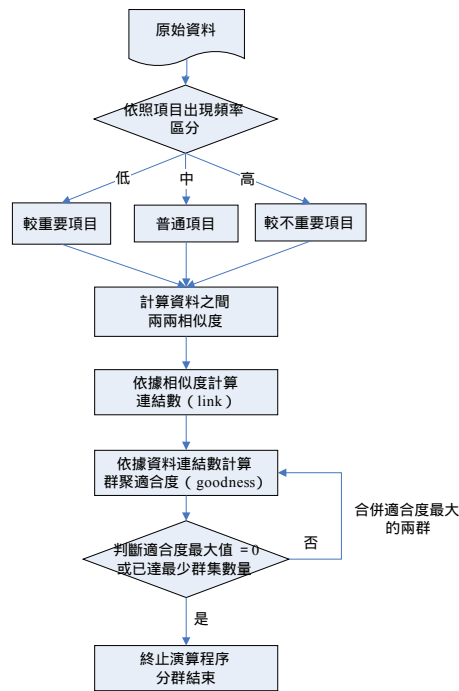


圖 2 群聚方法流程圖

經由此步驟之群聚演算法後可得病患特徵群集與療程特徵群集，其中不同療程特徵群集代表不同醫令項目組合之臨床路徑，以健保局規定之DRGs為評估準則，評估各臨床路徑的醫令組合是否符合DRGs之必做項目規定，判斷該臨床路徑是否為一合理之臨床路徑。若不符合必做項目規定，則重新調整療程相似度門檻值( $\theta_s$ )，直到形成之醫令組合符合健保局之相關規定。此研究步驟，將得到一或多個臨床路徑藍圖，由領域專家評估療程醫令組合之合理性，透過領域專家之篩選可得最終之臨床路徑。

#### 4.7 建構病患特徵與療程特徵之配合

將病患特徵資料與療程特徵資料，應用新相似性係數之 ROCK 演算法分別加以分群，可得病患特徵群集與療程特徵群集。依照各病患特徵群集對應各療程特徵群集資料筆數之比率，採取最大比率之對應方式，將病患特徵群集與療程特徵群集加以配合。

#### 4.8 建構 SVM 分類器與模式評估

在應用SVM建構分類器時，Kernel function的選擇是一個重點。在選擇Kernel function時，RBF kernel以非線性方式將資料映射至高維度空間，所以RBF可處理類別標籤與非線性特性，而線性kernel為RBF的一個特例 (Keerthi, 2003)，Keerthi文中提及在線性kernel中的處罰參數  $C$  與RBF kernel參數  $(C, \gamma)$  有相同的效能，故本研究選擇RBF Kernel為建構SVM分類器之Kernel function。LIBSVM為一個整合型的SVM應用軟體，可應用於SVM分類、回歸與分配估算，並且支援多類分類機制。本研究以LIBSVM做為建構分類機制之分類工具，應用MATLAB應用軟體建構整體分類模式。下段說明LIBSVM的主程式及分類準確性驗證方式。

## 1. LIBSVM 資料型態:

LIBSVM 的檔案格式如下

```
[label] [index1]:[value1] [index2]:[value2] ...
```

```
[label] [index1]:[value1] [index2]:[value2] ...
```

其中：label 或稱之 class，分類的種類。

Index 為有順序的索引。

value 就是用來訓練的資料內容值。

例如，1 1:0 2:5 3:3 表示此筆資料的分類為 1，第一個特徵值數值為 0，第二個特徵值數值為 5，第三個特徵值值為 3。

## 2. LIBSVM 主程式說明

### svmtrain

訓練 (train) 過程當中會接受特定格式的輸入，產生一個 "Model" 檔。這個 model 可以想像成 SVM 的內部資料，因為預測 (predict) 需要 model 才能進行預測動作。

此外，在建立 Model 時可設立參數，參數意義表示如下：

-s svm\_type : set type of SVM

0 -- C-SVC

1 -- nu-SVC

2 -- one-class SVM

3 -- epsilon-SVR

4 -- nu-SVR

-t kernel\_type : set type of kernel function

0 -- linear:  $u \cdot v$

1 -- polynomial

2 -- radial basis function

3 -- sigmoid

-d degree : set degree in kernel function

-g gamma : set gamma in kernel function

-r coef0 : set coef0 in kernel function

-c cost : set the parameter C of C-SVC, epsilon-SVR, and nu-SVR

-n nu : set the parameter nu of nu-SVC, one-class SVM, and nu-SVR

-p epsilon : set the epsilon in loss function of epsilon-SVR

-m cachesize : set cache memory size in MB

-e epsilon : set tolerance of termination criterion

-h shrinking: whether to use the shrinking heuristics, 0 or 1

-b probability\_estimates: whether to train a SVC or SVR model for probability estimates, 0 or 1

-wi weight: set the parameter C of class i to  $weight \cdot C$ , for C-SVC

依照上述不同參數設定組合，可建立符合需要之適切 Model。

## svmpredict

透過 svmtrain 程式訓練完成的 Model，再加上給定的輸入（新值），兩者輸入 svmpredict 程式中，經由運算輸出預測（predict）新值所對應的類別（class）。

### 3. 本研究使用 LIBSVM 說明

透過撰寫的 MATLAB 轉換程式，將病患特徵與療程特徵資料集轉換成 LIBSVM 能使用的格式，接著利用程式將資料訓練成 Model，訓練完之模式作為未來新病患進入醫院時，依此 Model 將病人分類為哪一種類別的病患，並建立符合該病人病徵之臨床路徑。

所有資料量以隨機方式選取三分之二資料量為訓練資料集，訓練 SVM 分類器之模式；所有資料量做為測試資料集，測試模式可正確分類的比率，以評估整體架構的可應用性。

## 5. 結果與討論

### 5.1 驗證結果

以「剖腹生產」與「小兒肺炎」兩案例進行實證研究，用來測試、驗證本研究方法之合理性與可行性。其中，「剖腹生產」案例各臨床路徑的療程醫令組合，與健保局規定之 DRGs 進行療程合理性分析，驗證臨床路徑之正確性。「小兒肺炎」案件的各療程類別之臨床路徑交由專業醫師進行療程合理性評估，證實療程群集之醫令組合之可信賴程度，此研究步驟為確保本研究臨床路徑建立機制，可應用於判定各疾病實行臨床路徑之可行性與驗證此模式應用於各科別之可行性。

### 5.2 「剖腹生產」案例

「剖腹生產」案例資料來源為中區某醫學中心於民國八十九年健保申報資料，該案例為療程特徵複雜度較低之個案，並且健保局有相關規定之 DRGs 治療程序準則，該資料集資料量為 749 筆。由於剖腹生產為療程較單純案件，其案件數量不大且最大住院天數僅為 15 天，所以不刪去特殊案件。剖腹案件之平均住院天數為 6.55 天，眾數為 5 天。

#### 5.2.1 資料特徵值、資料前置分析及處理

「剖腹生產」資料原始欄位共包含三十一個屬性特徵，由於研究機制中的 ROCK 演算法是處理種類型的資料，資料前處理步驟將原始資料欄位中的數值進行資料類型轉換。在資料分割步驟，將 749 筆剖腹生產資料，以隨機方式分割三分之二資料量共 500 筆為訓練資料，而測試資料為全部的 749 筆資料。依照資料欄位特徵，將原始資料欄位分割為三種類別資料集，分別為病患管理資料集、病患特徵資料集與療程特徵資料集，擷取病患特徵資料集與療程特徵資料集（表 2 與表 3）進行資料分析，資料分割步驟可以圖 3 表示。

表2 病患特徵資料集 (剖腹生產)

編號	欄位名稱	欄位值說明
1	病患代碼	原「身份證號」, 以流水號方式編碼
2	生產年齡類別	原「出生日期」, 1:未滿 20 歲, 2:介於 20~35 歲間, 3:35 歲以上
3	ICD-9 主診斷	國際疾病分類碼 (ICD-9-CM)
4	次診斷 1	同上
5	次診斷 2	同上
6	次診斷 3	同上
7	次診斷 4	同上

表3 療程特徵資料集 (剖腹生產)

編號	欄位名稱	欄位值說明
1	病患代碼	原「身份證號」, 以流水號方式編碼
2	生產年齡類別	原「出生日期」, 1:未滿 20 歲, 2:介於 20~35 歲間, 3:35 歲以上
3	主手術碼	國際疾病分類碼 (ICD-9-CM)
4	次手術 1	同上
5	次手術 2	同上
6	次手術 3	同上
7	次手術 4	同上




圖 3 資料分割示意圖 (剖腹產)

### 5.2.2 資料群聚、評估與群集對應

在進行分群時，病患代碼並不真正參與群聚性的分析，僅當作索引使用。資料群聚時應用新相似度測量標準之 ROCK 演算法，應用時需設定四個係數： $\theta_f$ 、 $\theta_r$ 、 $\theta_s$  及  $k$  值，係數值設定的高低並不直接與資料或案例本身相關，也就是由試驗者自行設計係數值的高低。本研究以以下水準進行試驗，其中  $\theta_f$  與  $\theta_r$  試驗兩組水準 (0.1, 0.9) 與 (0.2, 0.8)， $\theta_s$  試驗水準為 (0.9, 0.8, 0.7, 0.6)， $k$  值設為 2，試驗水準組合以表 4 表示。

表4 試驗水準組合 (剖腹生產)

K: 最小群組數				
2				
$(\theta_f, \theta_r)$	(0.1, 0.9)			
(0.2, 0.8)	$\theta_s$ : 相似度門檻值			
	0.9	0.8	0.7	0.6

依照試驗水準組合，分別對病患特徵資料集與療程特徵資料集進行試驗，每個資料集進行八次不同試驗水準，其群聚結果如表 5 所示。可發現病患特徵群集集中分佈在第一群組，表示一般產婦在診斷上的變異性不大，然而就醫學的病例而言，特殊且數量較少的個案是最重要的部分，如以 $(\theta_f, \theta_r, \theta_s, k)=(0.1, 0.9, 0.7, 2)$ 水準為例，可發現各個群組的診斷碼皆不相同，且差異性大，以最大群組 1 與其他群組比較為例，群組 1 與群組 2 在生產年齡類別與主診斷部分是相同的，而次診斷 1 與次診斷 2 則相異，群組 1 與群組 3 在病患特徵上皆不相同，群組 1 與群組 4 的生產年齡類別、次診斷 1 與次診斷 2 皆不相同，依此類推。由比較中可得知，病患特徵的分群在生產年齡類別與次診斷的差異上，會造成較大的影響，也就是說，造成病患真正差異上的是生產年齡與次診斷的檢驗上。

表5 病患特徵與療程特徵資料群聚結果 (剖腹生產)

	試驗水準							
	$(\theta_f, \theta_r, k)=(0.1, 0.9, 2)$				$(\theta_f, \theta_r, k)=(0.2, 0.8, 2)$			
	$\theta_s$				$\theta_s$			
	0.9	0.8	0.7	0.6	0.9	0.8	0.7	0.6
病患特徵資料集群數	11	11	8	8	10	10	8	8
療程特徵資料集群數	6	6	3	3	4	4	3	3

群集正確性評估是根據健保局規定之 DRGs 標準，比較不同水準組合下的療程特徵群集的醫令項目，經比較後可發現在水準 (0.2, 0.8, 0.7, 2) 下，建構的所有臨床路徑醫令項目皆符合 DRGs 的必做項目，因此選取該水準建構剖腹生產案例，可得到病患特徵群集八群、療程特徵群集三群。接著進行病患特徵與療程特徵群集的對應步驟，群組間的對應採取資料群組筆數之比率，選取最大比率的對應方式，可得到病患特徵群組與療程特徵群組的配合。如表 6 所示，病患特徵群組 1 對應療程特徵群組 1、病患特徵群組 2 對應療程特徵群組 1、病患特徵群組 3 對應療程特徵群組 2、病患特徵群組 8 對應療程特徵群組 2 等等的配合。

表6 病患特徵群集與療程特徵群集對應 (剖腹生產)

病患特徵群集對應療程特徵群集	筆數	比率	*: 選取標準
PF1 → TF 1	378	77.3%	*
PF 1 → TF 2	109	22.3%	

PF 1→ TF 3	2	0.4%	
PF 2→ TF 1	5	100%	*
PF 3→ TF 2	1	100%	*
PF 4→ TF 2	1	100%	*
PF 5→ TF 2	1	100%	*
PF 6→ TF 3	1	100%	*
PF 7→ TF 2	1	100%	*
PF 8→ TF 2	1	100%	*

PF：病患特徵群組 TF：療程特徵群組

### 5.2.3 建構 SVM 分類器與評估

利用 500 筆病患特徵資料建構 SVM 分類器。首先，應用撰寫的 MATLAB 程式將訓練資料轉為 LIBSVM 資料型態，病患特徵名稱以代碼方式表示，資料整體轉換如下：

```
[label] [index1]:[value1] [index2]:[value2] ...
```

```
2 F1:2 F2:65421 F3:65421 F4:64421
```

```
3 F1:3 F2:64251 F3:65421 F4:66602 F5:9981
```

```
2 F1:2 F2:65811 F3:65101 F4:65421 F5:64421
```

...

資料進行轉換後，在建構 SVM 分類器前需選定其中參數的設定，依據 3.3.5 小節的探討，進行 SVM 分類器模式訓練。本研究建構之 SVM 分類器參數設定如下：

```
-s svm_type : C-SVC
-t kernel_type : radial basis function
-d degree : 3
-g gamma : 1/6
-c cost : 1
-m cachesize : 40
-e epsilon : 0.001
-h shrinking: 1
-wi weight: 1
```

運用原始 749 筆產婦資料評估 SVM 分類器的正確性，將原始病患資料分割為 3 種類型資料集，擷取其中的病患特徵資料集，投入訓練完的模式中進行產婦類別分類，得到結果如下：

Accuracy = 99.733% (747/749) (包含訓練資料)

Accuracy = 99.20% (247/249) (不包含訓練資料)

正確分群的產婦為 747 位，正確率達 99.733%，其中錯誤分群的兩筆產婦為編號 115 與編號 210 的產婦。編號 115 號產婦由原本第三群產婦群組錯分為第一群產婦群組、編號 210 號產婦由第五群產婦群組錯分為第 1 群產婦群組，兩者錯分的結果，皆造成其療程類別由第 2 療程類別轉變為第 1 療程類別，第 2 療程類別的醫令與第 1 療程類別的差異在於 BREVIBLOC100MG/VIAL 醫令的區別，該醫令項目是第 1 療程類別未包含的，其為第 2 療程類別的特殊醫令項目，該醫令項目適應症為上心室心搏過速，手術中及手術後心搏過速，高血壓使用之，此為一重要之醫令項目。本研究旨在提供一參考性的臨床路徑樣式，

決定最後臨床路徑仍須由專家判定。在決定產婦臨床路徑時，錯誤分類的 2 個個案可由專家醫生判斷後，加入缺少之重要醫令項目。

### 5.2.4 「剖腹生產」案例試驗結論

「剖腹生產」案例是複雜度較低之個案。透過研究機制將病患特徵資料集分為 8 群、療程特徵資料集分為 3 群，其中病患特徵群集集中在 1 群上，療程特徵群集亦集中於 1 群，區別病患特徵群集的要素為生產年齡類別與次診斷，區別療程特徵群集的要素為主手術的差異，符合案例的實際特性；所建立的 SVM 分類器運用於病患的分類，正確率達 99.733%。由結果可得知，研究機制在該個案的驗證上有不錯的成效，是一個可行的建構臨床路徑方式。

### 5.3 「小兒肺炎」案例

「小兒肺炎」案例資料來源為中區某醫學中心於民國九十年健保申報資料，「小兒肺炎」案例為療程特徵複雜度較高之個案，且健保局無相關規定之 DRGs 治療程序準則，該資料集資料量為 912 筆。小兒肺炎的資料集中住院天數的分佈較廣且差異性大，本研究刪去小兒肺炎中住院天數超過 23 天的案件，共 11 筆。因此，小兒肺炎的研究資料總筆數為 901 筆。

#### 5.3.1 資料特徵值、資料前置分析及處理

「小兒肺炎」資料原始欄位共包含三十一個屬性特徵，由於研究機制中的 ROCK 演算法是處理種類型的資料，資料前處理步驟將原始資料欄位中的數值進行資料類型轉換（。在資料分割步驟，將 901 筆小兒肺炎資料，以隨機方式分割三分之二資料量共 600 筆為訓練資料，而測試資料為全部的 901 筆資料。依照資料欄位特徵，將原始資料欄位分割為三種類別資料集，分別為病患管理資料集、病患特徵資料集與療程特徵資料集，擷取其中病患特徵資料集與療程特徵資料集（表 7 與表 8）進行資料分析，資料分割步驟可以圖 4 表示。

表7 病患特徵資料集（小兒肺炎）

編號	欄位名稱	欄位值說明
1	病患代碼	原「身份證號」、「住院號」合併，以流水號方式編碼
2	ICD-9 主診斷	國際疾病分類碼 (ICD-9-CM)
3	主診斷 1	同上
4	主診斷 2	同上
5	主診斷 3	同上
6	主診斷 4	同上

表8 療程特徵資料集（小兒肺炎）

編號	欄位名稱	欄位值說明
1	病患代碼	原「身份證號」、「住院號」合併，以流水號方式編碼
2	主手術碼	同上
3	主手術 1	同上



4	主手術 2	同上
5	主手術 3	同上
6	主手術 4	同上




圖 4 資料分割示意圖 (小兒肺炎)

### 5.3.2 資料群聚、評估與群集對應

資料分割之後，擷取其中的病患特徵資料集與療程特徵資料集，個別進行資料群聚性分析，在進行分群時，病患代碼並不真正參與群聚性的分析，僅當作索引使用。資料群聚時應用新相似度測量標準之 ROCK 演算法，應用時需設定四個係數： $\theta_f$ 、 $\theta_r$ 、 $\theta_s$  及  $k$  值，係數值設定的高低並不直接與資料或案例本身相關，也就是由試驗者自行設計係數值的高低。本研究以以下水準進行試驗，其中  $\theta_f$  與  $\theta_r$  試驗兩組水準 (0.1, 0.9) 與 (0.2, 0.8)， $\theta_s$  試驗水準為 (0.9, 0.7, 0.5)， $k$  值設為 2，試驗水準組合以表 9 表示。

表9 試驗水準組合 (小兒肺炎)

K: 最小群組數			
2			
$(\theta_f, \theta_r)$	(0.1, 0.9)		
(0.2, 0.8)	$\theta_s$ : 相似度門檻值		
	0.9	0.7	0.5

依照試驗水準組合，分別對病患特徵資料集與療程特徵資料集進行試驗，每個資料集進行六次不同試驗水準，其群聚結果如表 10 所示。

表10 病患特徵與療程特徵資料群聚結果

	試驗水準					
	$(\theta_f, \theta_r, k) = (0.1, 0.9, 2)$			$(\theta_f, \theta_r, k) = (0.2, 0.8, 2)$		
	$\theta_s$			$\theta_s$		
	0.9	0.7	0.5	0.9	0.7	0.5
	病患特徵資料集群數	90	35	25	88	34

療程特徵資料集群數	569	437	176	557	390	108
-----------	-----	-----	-----	-----	-----	-----

原始資料群聚結果不甚理想，幾乎每一個病患的療程處置各自獨自一群，探究其中原因發現由於「小兒肺炎」案例無既定之 DRGs 規定，醫生在選擇療程的醫令項目時，因為本身醫療習慣的不同而選用不同之醫令項目。因為群聚研究進行的過程無醫療人員介入，造成在原始資料上之群聚效果不彰，由李淑芬（2002）論文中，可得知小兒肺炎療程醫令項目之替代性與同質性關聯如下述：

1. 醫令項 A021630277 (Taita No.2 500ml/BT) 與 A021632277 (Taita No.1 500ml/BT) 為同質性醫令，由執行率得知 A021630277 的執行率高於 A021632277。經由醫師挑選，將 A021630277 列入必做醫令項目。
2. 醫令項目 A040833157( Secorine Syrup 120ml/BT) 與 B019213199 ( Robitussin 20mg/ml) 為同質性醫令，由執行率得知 A040833157 的執行率高於 B019213199。但經由醫師挑選，卻將 B019213199 列入必做項目。醫師之考量因素為 B019213199 之藥品較好且價格亦較低，因此若欲訂定臨床路徑推薦使用 B019213199 項目。
3. 醫令項目 A028453100 ( Mucosolvan 30mg/T) 與 A037598116 ( Actein Gr. 200mg/3g/pk) 為同質性醫令，由執行率得知 A028453100 的執行率高於 A037598116。經由醫師挑選，將 A028453100 納入選擇性醫令項目。

另外，本研究經由醫令項目名稱的異同，判斷不同醫令代碼是否為同質性之醫令項目，將執行率較高之醫令項目定為代表性醫令項目，得到群組性醫令項目與代表性醫令項目。

利用群組性醫令的對應關係，將原始資料中之醫令項目進行轉換，應用設計的研究機制與相同試驗水準進行資料群聚性試驗，其結果如表 11 所示，可發現療程特徵資料集的群聚情況較為集中，以試驗水準  $(\theta_f, \theta_r, k) = (0.2, 0.8, 2)$  為例， $\theta_s$  的水準在 0.9、0.7 與 0.5 時，資料群聚分別由原本 559 群降為 117 群、390 群降為 39 群與 108 群降為 17 群，資料群聚改善情況如表 12。

表11 代表性醫令項目轉換後群聚改善結果

	試驗水準					
	$(\theta_f, \theta_r, k) = (0.1, 0.9, 2)$			$(\theta_f, \theta_r, k) = (0.2, 0.8, 2)$		
	$\theta_s$			$\theta_s$		
	0.9	0.7	0.5	0.9	0.7	0.5
代表性醫令轉換前群數	90	35	25	88	34	22
代表性醫令轉換後群數	143	48	21	117	39	17

表12 代表性醫令項目轉換後資料群聚情況

	試驗水準					
	$(\theta_f, \theta_r, k) = (0.1, 0.9, 2)$			$(\theta_f, \theta_r, k) = (0.2, 0.8, 2)$		
	$\theta_s$			$\theta_s$		
	0.9	0.7	0.5	0.9	0.7	0.5
病患特徵資料集群數	569	437	176	557	390	108

療程特徵資料集群數	143	48	21	117	39	17
群聚改善程度	74.9%	89%	88%	79%	90%	84.3%

由醫生的專業知識挑選出「小兒肺炎」案例的必做項目與選擇性項目，群集正確性評估以醫生提供之專業知識與群聚後的療程群組醫令項目相比對，比較不同水準組合下的療程特徵群集的醫令項目，經比較後可發現在水準 (0.1, 0.9, 0.7, 2) 下，建構的所有臨床路徑醫令項目皆符合醫師篩選之必做項目，因此選取該水準建構小兒肺炎案例，可得到病患特徵群集 35 群、療程特徵群集 48 群。接著進行病患特徵與療程特徵群集的對應步驟，群組間的對應採取資料群組筆數之比率，選取最大比率的對應方式，可得到病患特徵群組與療程特徵群組的配合。

### 5.3.3 建構 SVM 分類器與評估

利用 600 筆病患特徵資料建構 SVM 分類器。首先，應用撰寫的 MATLAB 程式將訓練資料轉為 LIBSVM 資料型態，病患特徵名稱以代碼方式表示，資料整體轉換如下：

```
[label] [index1]:[value1] [index2]:[value2] ...
2 F1:485 F2:5601 F3:53270 F4:5937
3 F1:486 F2:769 F3:76518 F4:7721
2 F1:481 F2:5130 F3:5119 F4:4928 F5:690
1 F1:485 F2:3829 F3:59010 F4:2765 F5:6910
...
```

資料進行轉換後，在建構 SVM 分類器前需選定其中參數的設定，依據 3.3.5 小節的探討，進行 SVM 分類器模式訓練。本研究建構之 SVM 分類器參數設定如下：

```
-s svm_type : C-SVC
-t kernel_type : radial basis function
-d degree : 3
-g gamma : 1/5
-c cost : 1
-m cachesize : 40
-e epsilon : 0.001
-h shrinking: 1
-wi weight: 1
```

運用原始 901 筆小兒肺炎資料評估 SVM 分類器的正確性，擷取其中的病患特徵資料集，投入訓練完的模式中進行小兒類別分類，得到結果如下：

```
Accuracy = 99.667% (898/901) (包含訓練資料)
Accuracy = 99.336% (299/301) (不包含訓練資料)
```

正確分群的病患為 898 位，正確率達 99.667%，其中錯誤分群的三筆病患為編號 108、編號 272 與編號 729 的病患。編號 108 號病患由原本第 15 群產婦群組錯分為第 22 群產婦群組，療程差異由第 17 群療程群組轉為第 19 群療程群組，轉換後的醫令項目缺少 Secorine Syrup 120ml/BT 與 PRISIC 5mg/T，增加了 Anti-Phen Syrup 24mg/ml 60ml/BT 醫令項目，Secorine Syrup 120ml/BT 適應症為咳嗽用藥 PRISIC 5mg/T 為胃腸蠕動劑，增加的 Anti-Phen Syrup 適應症為解熱鎮痛劑，此三項醫令項目皆為選擇性醫令項目，不為重要之醫令選擇，

可在療程過程中由醫生判斷後加入。編號 227 號病患與編號 729 號病患，皆由原本第 31 群產婦群組錯分為第 4 群產婦群組，療程差異由第 43 群療程群組轉為第 6 群療程群組，轉換後的醫令項目缺少 Chest view 胸腔檢查與 Mucosolvan 30mg/T 沐舒痰錠醫令項目，增加了 Amolin gr. 25mg/ml 60ml/BT 抗生素項目，此三項醫令項目不為重要的醫令選擇項目，本研究旨在提供一參考性的臨床路徑樣式，決定最後臨床路徑仍須由專家判定。

### 5.3.4 「小兒肺炎」案例試驗結論

「小兒肺炎」案例是複雜度較高之個案。原始資料集在群聚效果上不顯著，經由代表性醫令項目進行轉換後，透過研究機制將病患特徵資料集分為 35 群、療程特徵資料集分為 48 群，其中病患特徵群集與療程特徵群集的分佈較為分散，此符合「小兒肺炎」的實際情況，所建立的 SVM 分類器運用於病患的分類，正確率達 99.667%。由結果可得知，研究機制在該個案的驗證上有不錯的成效，是一個可行的建構臨床路徑方式。

## 5.4 結論與建議

本研究以病患特徵資料集與療程特徵資料集為研究對象，應用新的相似度測量方法，分別進行病患特徵集與療程特徵集的群聚分析，群聚後的病患特徵群集與療程特徵群集進一步進行對應，得到病患特徵群集與療程特徵群集的配合，繼而，藉由病患特徵群集資料，建構支援向量機分類器，做為新進病患類別的判斷機制。期望藉由病患特徵判斷病患所屬臨床路徑醫令項目組合，在合理的成本控制下，使病患能接受適當的治療程序。醫療院所可透過臨床路徑管理，藉由控制臨床路徑的住院天數與醫令項目組合，達到費用控制之目標。本研究改善臨床路徑之制訂方法，提升醫療院所制訂臨床路徑效率，提高臨床路徑之管理效益。

本研究以兩種不同病例驗證機制的可行性，「剖腹生產」案例為變異性較低之個案，且健保局有相關規定之 DRGs，「小兒肺炎」案例為變異性較大之個案，目前健保局無相關規定之 DRGs，藉由不同病例的試驗，驗證研究機制的可行性。由研究實證結果，本研究之新相似度群聚方法，應用於臨床路徑建立機制達成以下目標：

1. 對於單純、變異性較低之病例，可透過本研究提供之新相似度群聚方法，建立臨床路徑。由「剖腹生產」實證結果，可有效群聚病患特徵類別與療程特徵類別，進而得到病患特徵群集與療程特徵群集的配合。
2. 對於變異性較高之病例，可由專家提供專業知識於代表性醫令項目的決定，將原始變異性較高之資料進行轉換後，仍可有效群聚病患特徵類別與療程特徵類別，得到病患特徵與療程特徵的配合。由「小兒肺炎」實證結果，可驗證研究機制在變異性較高之病例應用上，仍是一個可行方案之一。

發展各類型病例所屬的病患特徵與療程特徵配合的臨床路徑雛形，提供一定醫療品質水準下，達醫療費用控制之管理成效。由「剖腹生產」與「小兒肺炎」實證中可發現，透過支援向量機預測病患所屬療程類別，其準確率達 99% 以上。

藉由本研究提供之臨床路徑建立機制，可應用於不同病例的臨床路徑建立，所發展的臨床路徑可應用性有不錯表現，然而基於研究假設前提下，未來研究方向可由以下數點著手：

1. 若能搜集到每個醫令項目的執行次數與確切執行時間，配合現今健保制度的支付制度，可更精確控制醫療費用。
2. 研究機制中的病患特徵與療程特徵對應是採取比率式的對應方式，未來可應用更精確的

對應方式分析兩個群集的關係。

## 參考文獻

- [1] 王炯琅,「某醫院推動臨床路徑之成果及影響評估 - 以「自然生產」與「剖腹生產」為例」, 碩士論文, 2000。
- [2] 李玉春,「全民健保西醫總額支付制度之推動政策—基層與醫院預算之分立或統合」,《台灣醫界》44(7), pp.43-47, 2001。
- [3] 李淑芬,「臨床路徑之建立機制-應用資料採礦技術」, 碩士論文, 2002。
- [4] 朱樹勳,「臨床路徑的介紹」, 臨床路徑理論與實施, 翰蘆圖書, pp.10-17, 2000。
- [5] 林秀緞,「地區教學以上醫院臨床路徑實施現況、成效及其相關因素探討」, 碩士論文, 1999。
- [6] 周麗芳,「由經濟政策觀點檢視全民健保總額支付制度」,《台灣醫界》44(1), pp.45-50, 2001。
- [7] 姚輝林,「導入專家知識的資料群聚方法之研究」, 碩士論文, 2004。
- [8] 莊莉瑩,「資料挖掘機制在臨床路徑之運用」, 碩士論文, 2001。
- [9] 莊逸州,「論量計酬與論病例計酬之支付制度對費用結果與品質之影響:以長庚醫院之剖腹產與陰道分娩為例」, 中華醫誌 16(2), pp.149-159, 1997。
- [10] 張慧朗,「使用臨床路徑以改善醫療結果 - 長庚醫院實施臨床路徑的經驗」, 1995 臨床路徑研討會, 1995。
- [11] 許幼青,「不同臨床路徑對醫療資源利用與品質之影響—以全人工髖關節置換術為例」, 碩士論文, 2001。
- [12] 黃三桂,「論病例計酬制度實施前後對住院日數及醫療費用之影響 - 以痔瘡併肛門瘻管切除術為例」, 碩士論文, 1998。
- [13] 黃彥文,「資料探勘之應用 - 會員消費特徵之發掘」, 碩士論文, 1999。
- [14] 曾劍英,「於論病例計酬下, 實施臨床路徑之效益評估-以乳癌乳房全部切除手術為例之實證研究」, 碩士論文, 2002。
- [15] 楊榮森,「臨床路徑 - 理論與實務」, 翰蘆圖書, pp.19-31, 2000。
- [16] 廖美南, 盧美秀,「臨床路徑之建構」, 護理雜誌, 44(5), pp.29-33, 1997。
- [17] 潘德樑,「臨床路徑使用於論病例計酬案件之差異分析 - 以腹腔鏡子宮切除術為例」, 碩士論文, 2002。
- [18] Agrawal, R., T. Imielinski, and A. Swami, "Mining Association Rules between Sets of Items in Large Database," *Proceedings Of the ACM-SIGMOD Conference On the Management of Data*, pp.207-216, 1993.
- [19] Agrawal, R., and R. Srikant, "Fast Algorithms for Mining Association Rules," *Proceedings of Conference On Very Large Data Base*, pp.478-499, 1994.
- [20] Blegen MA, et al., "Outcomes of hospital-based managed-care: a multivariate analysis of cost and quality," *Obst Gynec*, 86(5), pp.809-14, 1995.
- [21] Chinn, P. F., P. C. Kong, and K. Kamhon, "The design of payment systems for physicians under global budget-an experimental study," *Journal of Economic Behavior & Organization*, Vol.34, pp.295-311, 1998.
- [22] Corbett C.F., I.M. Androwich, "Critical paths: Implications for improving price" *Home Healthcare Nurse*, 12(6), pp.27-34, 1994.
- [23] Dewoody S, J. Price, "A system approach to multidimensional critical paths," *Nursing Management*. 25(11), pp.47-51, 1994.
- [24] Fayyad, U., G. Piatetsky-Shapiro and P. Smyth, "From Data Mining to Knowledge Discovery in Databases," *Artificial Intelligence Magazine*, pp.37-54, 1996.
- [25] Goode C., "Impact of a care map and case management on patient satisfaction and staff

- satisfaction, collaboration, and autonomy,” *Nurs Econ*. 13(6), pp.337-349, 1995.
- [26] Guhay S., R. Rastogi, and K. Shim, “ROCK: A robust clustering algorithm for categorical attributes,” *In Proceedings of the 15<sup>th</sup> International Conference on Data Engineering*, Sydney, Australia, pp.512-521, 1999.
- [27] Heacock D. and R.A. Brobst, “A multidisciplinary approach to critical path development: A Valuable CQI tool,” *Journal of Nursing Care Quality*, 8(4), pp.38-41, 1994.
- [28] Horowitzs, J., “CPM and PERT – An overview. Critical Path Scheduling,” *Columbia Broadcasting system, Inc.*, 1967.
- [29] Keerthi, S. S. and C.J. Lin., “Asymptotic behaviors of support vector machines with Gaussian kernel,” *Neural Computation*, 15(7), pp.1667-1689, 2003.
- [30] Lawson M., B. Lapinski and E. Velasco, “Tonsillectomy and adenoidectomy pathway plan of care for the pediatric patient in day surgery,” *J Perianesth Nurs*, 12(6), pp.387-395, 1997.
- [31] Muluk, S.C., L. Painter and S. Sile, “Utility of Clinical Pathway and Prospective Case Management to Achieve Cost and Hospital stay Reduction for Aortic Aneurysm Surgery at a Tertiary Care Hospital,” *Journal of Vascular Surgery*, 25(1), pp.84-93, 1997.
- [32] Vapnik V., “The Nature of Statistical Learning Theory,” *New York, Springer-Verlag*, 1995.

## 研究成果自評

本計劃利用群聚模式(clustering)的方法，將病患以及 medical treatments 分成若干群，藉由資料關聯的方式將相關的病患連接至相關的臨床路徑。研究內容與原計畫相符。藉由 SVM 的方法，正確的判斷率達 99%以上。惟由於近年醫療糾紛頻傳，醫療資料取得極為困難。僅能利用剖腹產(變異性小)，以及小兒肺炎(變異性稍大)的個案進行探討。遺憾的是未能利用更多的高變異性的病例作為探討的對象。方法論已完成，爾後將持續與醫院合作，進行多種醫療病症的測試。期望近期內可進行專利的評估。