

# 行政院國家科學委員會專題研究計畫 成果報告

## 非監督式中文寫作自動評閱系統之研究與設計 研究成果報告(精簡版)

計畫類別：個別型  
計畫編號：NSC 98-2221-E-009-141-  
執行期間：98年08月01日至99年08月31日  
執行單位：國立交通大學資訊工程學系(所)

計畫主持人：李嘉晃

計畫參與人員：碩士班研究生-兼任助理人員：楊瑞敏  
碩士班研究生-兼任助理人員：紀孝承  
碩士班研究生-兼任助理人員：陳佑州  
碩士班研究生-兼任助理人員：鐘喻安  
博士後研究：劉建良

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 99 年 10 月 31 日

行政院國家科學委員會補助專題研究計畫  成果報告  
 期中進度報告

## 非監督式中文寫作自動評閱系統之研究

計畫類別： 個別型計畫  整合型計畫

計畫編號：

執行期間：2009 年 8 月 1 日至 2010 年 8 月 31 日

計畫主持人：李嘉晃

共同主持人：

計畫參與人員：劉建良、楊瑞敏、紀孝承、鐘喻安、陳佑州

成果報告類型(依經費核定清單規定繳交)： 精簡報告  完整報告

本成果報告包括以下應繳交之附件：

赴國外出差或研習心得報告一份

赴大陸地區出差或研習心得報告一份

出席國際學術會議心得報告及發表之論文各一份

國際合作研究計畫國外研究報告書一份

處理方式：除產學合作研究計畫、提升產業技術及人才培育研究計畫、列管計畫及下列情形者外，得立即公開查詢

涉及專利或其他智慧財產權， 一年 二年後可公開查詢

執行單位：國立交通大學資訊工程學系(所)

中 華 民 國 99 年 10 月 29 日

# 非監督式中文寫作自動評閱系統之研究

An Unsupervised Chinese Automated Essay Scoring System

計畫編號：

執行期限：98年8月1日至99年8月31日

主持人：李嘉晃 國立交通大學資訊工程

## 一、中文摘要

自動寫作評閱的研究，在自然語言中佔了重要的一環，尤其是在中文研究上甚是艱難，雖然陸陸續續已有評閱系統之研究產生，但目前的系統皆只針對文章單一方面給分，無法有效提供使用者在寫作技巧上哪方面較微弱之資訊。因此本文提出一個非監督系統，針對中文寫作評分不同面向，分別給予分數以及分數的統整，除了給予使用者在立意取材以及結構組織上的分數外，也根據使用者所寫作的文章給予錯別字回饋的資訊。實驗結果在不同面向上能有相當程度的正確率，在分數統整上，正確率可達到 94%。此外錯別字判斷的正確率能達到 72%，可作為老師批閱或是學生寫作上的輔助工具。

## 二、英文摘要 (Abstract)

The research of the automated essay scoring is important in the natural language, especially difficult in the Chinese research. Although some scoring systems have been proposed, all these systems only score the article one-way. They can't provide which aspect in the article technique may strengthen to the user efficiently. Thus, the paper proposes an unsupervised system. This system could grade essays multi-face and give the information of misspell to the user. The adjacent rate in the overall experiment is about 94%, and in the misspell judgment is about 72%.

## 三、計畫緣由與目的

各個國家的語言教育，皆脫離不了聽、說、寫、讀這四個方面，而在這四個方面中，尤其以“寫”這一環最為重要，寫作不僅可以培養一個人的表達能力、文學素養，甚至可以激發、訓練一個人的組織與思考以及增進創造、理解等能力。因此在各個語言教育階段中，均重視語言寫作能力的訓練。

但現階段的作文批閱的形式，皆需要耗費大量的人力、物力以及時間，最重要的還是批閱者的主觀不同，但除了批閱者的主觀意識外，另一項重大的問題是批閱者如何在長時間的作業下，還能維持一定的批閱標準。因此單純利用人工來進行作文的批閱，很難達到客觀以及公平性。

在英語批閱研究中，自動作文評分 (Automated Essay Scoring, AES) 已經發展許久，甚至已經應用在大行的語文考試中，例如：Graduate Management Admission Test (GMAT) 已使用E-rater作為批閱文章的輔助工具[1]。而華語批閱研究中，也針對寫作上由最初所提出的自動建構中文作文評分系統[2]，到之後的貝氏[3]、SVM[4]、修辭[5]、非監督式[6]、結構化[7]...等評分系統。

然而目前的中文系統無論是監督式評分系統(指需要一定的篇數且已經過人工評定分數的同一主題文章作為系統的訓練資料)或者非監督式評分系統(無需訓練資料，僅需一定數量的同一主題文章)，皆只針對單一個面向來作評分，並不符合中文寫作的評分標準上[8]所針對的主要四大面向立意取材、結

構組織、遣詞造句及錯別字與標點符號等。因此無法有效的反映出學生再寫作技巧上較為薄弱的部份。

本研究之目的，再於建立一套不需要訓練資料且可針對作文上不同角度分別給分，最後在有一個總結分數，並且給予錯別字上的回饋，此系統在單一面向評分上是不需要事前藉由人工評定分數來當訓練資料，僅需要一定的同主題文章數，便可藉由文章特徵的資訊、文章間的相似度進行自動評分的，而在整合分數上亦不需要訓練資料，是藉由分別單一面向所評定出的文章與分數分佈作為參考，進行調整性的分數整合。

早在1966年Ellis Page 就提出的一種簡單的評分方法 PEG (Project Essay Grader)[9]，這也是第一個英文的評分系統，但系統並未包含了NLP技術，系統主要包含 training stage與scoring stage，training stage主要是找出依賴文章的間接特徵如：作文字數、標點符號、形容詞數…等，再經由scoring stage進行多元迴歸分析，來計算出文章分數。但因為它使用文章的間接特徵，並未加入文章的直接特徵如：結構組織、句法等資訊，所以使用者容易針對這個弱點，撰寫出一篇較長的文章瞞過系統，得到較高的分數。

因此在PEG之後，Landauer提出了一個利用文章的語意關係來進行評分，此系統 Intelligent Essay Assessor (IEA)[9]，主要是利用LSA為基底，進而找出文章間的語意資訊進行評分，系統除了評分外，它也會針對文章 grammar、style與mechanics給予回饋資訊。

然而上述兩個系統它們所著重的文章特點不盡相同，PEG是著重於style，而IEA著重於content，很難用於大型考試上。於是就有後來的E-rater的產生[9]。E-rater系統已經被美國商業學校入學測驗考試 (GMAT)所使

用，在評分的過程中，分為三個階段：結構、組織、內容。在結構部分中主要分析出句法的種類如：不定詞、從屬子句等。在組織部份分析句法的概念如：修辭結構，句子跟句子之前的連接詞等。最後在內容部分，評估文章內所用到的詞語跟主題是否能吻合。文章會由三個階段得到統整的資訊以及些許的回饋。

在中文的自動評閱系統上，是近幾年才陸續有人提出。最早期也是根據文章的表面特徵如：詞語數、成語數等。再加入譬喻以及排比所建立出的評分系統[5]。之後才提出根據同主題文章的訓練，得出能反映文章好壞的直接特徵：義元[2]。以及利用統計的方式，擷取出符合這個主題的結構概念[7]，再針對各篇文章上的結構，比較之間的相似程度進行評閱。

除了利用特徵擷取來評分外，也有人提出利用Bayesian、SVM等學習機器來進行評分[3][4]，利用文章的特徵與人工評定好的分數當作訓練資料建立出的機器評分規則，再針對測試文章進行評分。但這些系統都需要一定同主題及人工評定過的文章數當作訓練文章，仍須人工的方式介入。於是一個非監督式的評分系統構想就由陳[6]所提出，根據文章間所共同用到的詞語，來做互相評分的依據，其正確率依然與監督式的系統相差不遠。

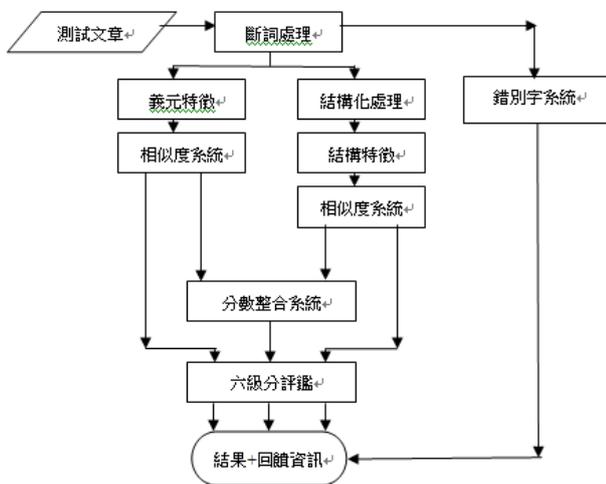
以上中文自動評閱雖然分為針對特徵擷取、機器學習、非監督式與監督式等來評分，但都只針對文章寫作上單一角度上來做評分，不像英文系統IEA、E-rater，可以從不同的角度上評分，並統整分數進而給予回饋資訊。很難反映出使用者在寫作上在那一方面出現問題。

#### 四、想法與討論

此章節中，將描述整個系統的架構與流

程，首先在3.1小節中，用一張系統架構圖來了解系統整個運作的流程，圖中各個模組的執行內容將在後續幾小節中做詳細的介紹。

### (一) 系統架構



圖一. 系統架構圖

本系統裡面共包含5個模組：

1. 斷詞處理
2. 特徵擷取-包含兩個部份:義元特徵、結構化特徵
3. 相似度(評分)系統
4. 分數整合系統
5. 錯別字系統

當一定的文章數資料進入系統時，系統開始運作。首先第一步對每篇文章進行斷詞的處理，再經由特徵擷取取出每篇文章的義元特徵與結構特徵當作後續相似度評分系統的評分依據，藉由相似度內的投票演算法每個時間修正評分的結果直到結果達到穩態為止，在此階段結束後進入分數整合系統，即會根據兩個方向所評出的分數、文章數進行訓練找出一個最佳比例來進行整合。最後這些分數會參考歷史資料的成績分配情況轉換成六級分成績。文章在系統評出分數後也會根據斷詞以及bigram資訊進行錯別字判斷。

### (二) 中文斷詞處理

斷詞在自然語言上是不可或缺的技术，任何的系統只要是牽扯到語言的都必須先分辨文章中的各個詞才能進行詞性標記、句法

分析、資訊擷取等進一步的處理。相對於英文最顯而易見的差異，在於中文語法並沒有空白隔開每一個詞。若斷詞結果不正確，容易造成語意全然的不同，因此中文的自動斷詞成為重要的工作。

目前系統採用的斷詞法乃是長詞優先斷詞法，雖然其正確率在現有的演算法中並不算最好，但效果已達一定的水準，且系統進計算文章間共同出現的材料，並不去探討文章語法，因此對斷詞錯誤的會有較高的容忍度。

在此利用一個簡單的例子說明此演算法：

「 下 課 鐘 聲 響 」..... (1)

這個句子可能的斷詞有下列數種詞組：

「 ( 下 ) ( 課 ) ( 鐘 ) ( 聲 ) ( 響 ) 」..... (2)

「 ( 下 課 ) ( 鐘 ) ( 聲 ) ( 響 ) 」..... (3)

「 ( 下 課 ) ( 鐘 聲 ) ( 響 ) 」..... (5)

.....

首先此演算法會針對字串中最長有意義的字串進行判斷，因此先從(1)斷出(下課)，再由剩餘的字串(鐘聲響)中斷出(鐘聲)以及(響)，即為結果。

### (三) 詞語特徵

由於系統要針對文章立意取材以及結構組織兩部份做評分，所以我們需要先擷取出所有文章在這兩部份的詞語特徵以及結構特徵來當作相似度系統比較評分的依據，再分別進行評分。因此我們在此小節以及下一小節提到特徵如何擷取。

首先針對詞語特徵的擷取，本系統中是利用文章的義原來當作文章的詞語特徵，我們根據知網(HowNet)將所有文章中的詞語轉化為義原。

在此利用一個簡單的例子說明轉化過程：

「大家的動作由緩慢轉變成快速」

經過斷詞處理後，會變成：

「 (大家) (的) (動作) (由) (緩慢) (轉變)

成)(快速)」再經過義原轉換的處理，可得知各詞語的主義原如下：

表一. 義原轉換

詞語	主義原
(大家)	{human 人}
(的)	{FuncWord 功能詞}
(動作)	{do 做}
(由)	{FuncWord 功能詞}
(緩慢)	{slow 慢}
(轉變成)	{become 成為}
(快速)	{fast 快}

因此此段話共有七個詞語，但只包含六個不同的義原，而我們即取這六個不同義原當作詞語特徵。

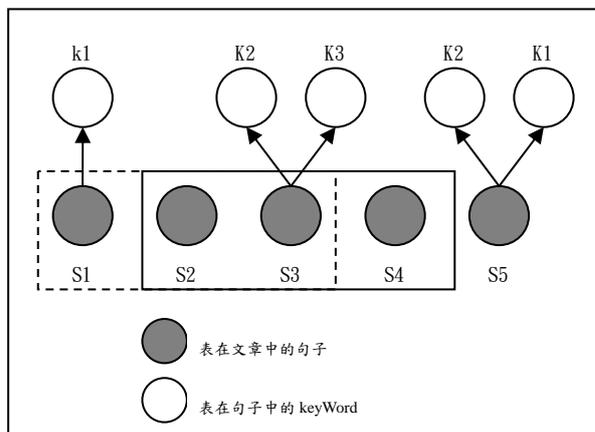
#### (四) 結構特徵擷取

系統必須先利用全部數量同主題的文章資料建立詞語的非對稱關係矩陣，其主要是觀察詞與詞共同出現的次數以及單獨出現的次數，來得知兩者之間的從屬關係，例如：[合作社]與[麵包]共同出現的次數100，[合作社]單獨出現的次數200，[麵包]單獨出現的次數100次，表示[合作社]除了跟[麵包]一起出現100次外，還跟其他的詞一起出現過；反觀[麵包]只會跟[合作社]同時出現，因此可知[麵包]應該是[合作社]的子概念，利用這種方式就可來建立出屬於這個主題的概念階層圖，再依據所建立出來的概念圖對每篇文章作結構特徵擷取的處理。

#### ●詞語非對稱關係矩陣：

針對每篇文章每一句所抽出來的keyWord在一個滑動的固定區間裡統計兩兩keyWord出現的次數並加以累加記錄。最後除予詞語在全部文章出現的總次數。

在此利用一個簡單圖說明如何針對每篇文章做處理：



圖二. 計算詞語出現關係圖

在上圖中，我們所設定區間為3，在虛線區間內的句子S1、S2、S3中出現k1、k2、k3這三個keyWord，代表它們的關係較為接近，因此分別將兩兩keyWord計錄一次，即從每個keyWord的角度去看。在滑動區間為實線部份，此時區間內的句子S2、S3、S4中只出現k2、k3 keyWord，所以僅計錄k2、k3兩個keyWord的部份。

因此詞語非對稱關係矩陣其陣列內容可根據下列公式計算：

$$r_{i,j} = \frac{\sum_{t \in T} \sum_{s \in t} occ(w_i, w_j)}{frequency(w_i)}$$

$r_{i,j}$  : 為陣列第i列，第j行的內容。

s : 文章t (text)中的句子。

T : 指全部文章。

occ( $w_i, w_j$ ): 詞語i與詞語j是否同時出現。(Binary Value)

frequency( $w_i$ ) : 詞語 $w_i$ 在全部文章出現的總次數。

依照上面公式我們就可將圖二轉換成矩陣，即下表：

表二、非對稱關係矩陣

	k1	k2	k3
k1	0	1.5	1
k2	1.5	1	2
k3	2	4	0

如此一來，我們就可以依據矩陣對稱格內容得知兩個詞之間的關係，此部份我們會在下一小節提到。

### ●概念圖

由 3.4.1 小節得到的詞語非對稱關係矩陣，為了得知兩個詞語  $w_i$ 、 $w_j$  從屬的情況，經由觀察可得知當  $r_{i,j}$  高於  $r_{j,i}$ ，表在文章中當  $w_i$  出現緊接著伴隨  $w_j$  出現的機率頗高；反之當  $r_{i,j}$  低於  $r_{j,i}$ ，表  $w_i$  出現緊接著伴隨  $w_j$  出現的機率較低，因為  $w_i$  也可能跟別的詞出現。例如我們再 3.4 節中一開頭所舉的例子， $w_i$  為[合作社]； $w_j$  為[麵包]； $r_{i,j}$  等於 0.5； $r_{j,i}$  等於 1，得知當[合作社]出現而[麵包]伴隨出現的機率為 0.5，有 0.5 會跟其他詞出現。因此[合作社]應該為[麵包]的 superordinate。

因此可根據下列演算法，建構出屬於此主題的概念圖：

#### Algorithm 1：建立概念圖演算法

```

for i=1 to n
  for j=1 to n
    if  $r_{i,j} > r_{j,i} + e$  then  $a_{i,j} = subordinate$ 
    else if  $r_{i,j} < r_{j,i} + e$  then  $a_{i,j} = superordinate$ 
    else  $a_{i,j} = correlation$ 
now_level = 0
do{
  for i=1 to n
    if  $a_{i,j} \in \{superordinate, correlation, processed\}$  for all j
      then the level of word  $i = now\_level$ ;
  for j=1 to n
    if the level of word  $j$  has been given
      then  $a_{i,j} = processed$ , for all i
  now_level = now_level + 1
}while(now_level <= threshold) or ( $\forall i$  word  $i$  has been given)

```

由上述演算法主要先標示陣列中每個詞的從屬關係，接著判斷是否有一整列的陣列內容皆不屬於 subordinate，表示這一系列所代表的詞是現階段層級最高的，於是標記 now\_level，並將詞所對應的行標示 processed，代表已處理過。此演算法會一直做到所有詞語都被標記層級或者已經超過預設的階層數。

### ●擷取

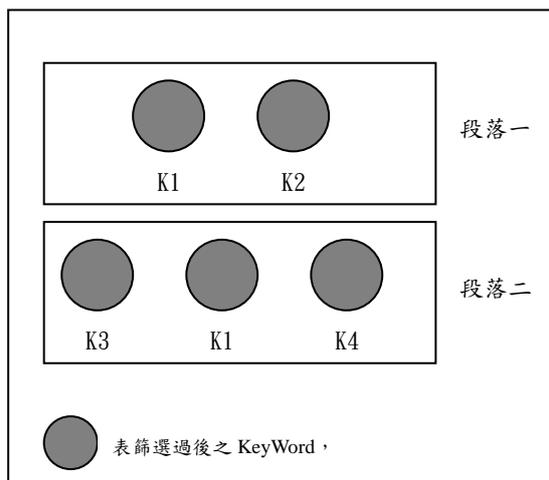
利用所建立出的概念圖，對每篇文章做結構特徵的擷取，首先必需先篩選每個段落的 keyWord，針對每個段落所得 keyWord 對應其概念圖所在之層級，取最高層級三層範圍內的 keyWord 當作能代表此段意義之主要

詞語。

篩選 keyWord 後，隨即將每兩段所取得的主要 keyWord，做 Bi-word 的配對當作此篇文章之結構特徵。在此部份如果我們配對取的越長的話，在相似度系統的比較上，文章跟文章之間就會越難比對到，因此取 Bi-word 使系統能更有彈性。

在此針對篩選過後的 keyWord 說明其特徵擷取：

某篇文章其段落為二，每個段落所篩選之 keyWord 如下所示



圖三、特徵擷取示意圖

因此我們擷取「(k1) (k3)」、「(k1) (k1)」、「(k1) (k4)」、「(k2) (k3)」、「(k2) (k1)」、「(k2) (k4)」等 Bi-word，當作此篇的結構特徵。

### (五) 相似度評分系統

此系統的基本假設為：如果一篇文章使用的材料（詞語、結構）與高分文章越相似，或與低分文章越不相似，則此篇文章為高分文章的機率越高；反之，低分的機率越高。

但在系統一開始時，所有的測試文章都不會帶任何附加資訊，因此我們並不知道文章分數以及其分佈圖。所以我們需要在系統一開始時，先針對每篇文章給予一個初始分數，以便於系統能正常運作。

因此在系統一開始會先針對文章的成語數、好意原數、名詞數、句號數這四個間接特徵加總當作文章的初始分數（即公式中  $Z_{i,j,(t-1)}$ ,  $t=0$ ）。而這些特徵皆與文章分數有正向關係。

在根據下列公式進行評分：

$$W_{w,j,t} = \sum_{i \neq j} F_{w,i} * Z_{i,j,(t-1)} \quad (1)$$

$$S_{j,t} = \sum_w (2F_{w,j} - 1) * W_{w,j,t} \quad (2)$$

$$Z_{i,j,t} = \frac{\left( S_{i,t} - \sum_{k \neq j} S_{k,t} / (N-1) \right)}{\sigma_t}$$

$W_{w,j,t}$ ：時間為  $t$  時，詞語  $w$  對於文章  $j$  的分數。

$F_{w,i}$ ：詞語  $w$  是否在文章  $i$  中出現。(Binary Value)

$S_{j,t}$ ：時間為  $t$  時，文章  $j$  的分數。

$Z_{i,j,t}$ ：時間為  $t$  時，文章  $i$  對於文章  $j$  的  $Z$  分數 ( $Z$ -Score)。

$N$ ：文章總數。

$\sigma_t$ ：時間為  $t$  時，所有文章分數之標準差。

在此我們稱欲計算分數的文章稱目標文章且從詞語的角度來觀看(結構同理)。

在公式(1)中主要是計算出所有出現詞語  $w$  文章對目標文章的權重，亦可說是詞頻與出現文章  $Z$ -score 的乘積。所以當一個詞語的詞頻很低，則此詞語權重必然不高。公式(2)中計算目標文章的分數，其根據詞語  $w$  出現與否給定分數，如果詞語  $w$  在目標文章出現則會賦予正向的分數，否則為負向。公式(3)為文章的  $Z$ -Score 表文章分數與平均值的差異度。

當一篇文章在  $t-1$  時間所得的分數高於平均許多，則目標文章從此篇文章得到較高的分數，反之亦然。在公式中除於標準差是要讓每個  $t$  都能收斂在一定區間，避免分數的無限成長。由此相似度的加權可得知，目標文章的分數會往相似度越高的文章慢慢趨近。

系統隨著時間  $t$  不斷的增加，其文章的分數也會不斷的改變，當文章數量達到一定時，其分數會趨於一個穩態的狀態。

## (六) 六級分評鑑

當相似度評分系統趨於穩態的狀態後，便利用最後的評分結果，來轉換成六級分成績。我們假設當文章達到一定數量時，其分佈會趨近歷史資料的分佈，也就是說各級分

文章佔測試資料比例均與歷史資料接近，於是我們將歷史資料的成績用常態分配來計算出各級分的  $Z$ -Score 區間，再由相似度評分最後的結果所在的區間決定其分數。

由歷史資料 1~5 級分文章佔樣本的累積比率 6.5%、25.1%、55.6%、85.8%、99.0%，轉化成常態分布之  $Z$ -Score 可得到五個門檻 -1.5196、-0.6711、0.1405、1.0703、2.3204， $Z$ -Score 低於 -1.5196 給予 1 級分，介於 -1.5196 到 -0.6711 給予 2 級分，以此類推

## (七) 分數整合評分系統

在此我們假設評閱者在批改作文時，是根據作文四個面向給予不同的比例，給予統整的分數。所以此階段主要是為了得知在哪個比例下所計算出來的分數是比較符合評閱者。利用 3.4 相似度評分系統中所分別得知文章立意取材與結構組織兩個面向文章分數及其各級分的分佈，進行最佳比例的尋找。本系統中將針對這兩個面向所得到的評分做不同比例的處理。

經上述所言，此系統基本假設為：若是由最佳比例所評定出之分數應與從立意取材、結構組織分別評定出的分數相差不遠；反之，當由最差比例所評定出之分數應該與兩者其一或是兩者的分數差距較大。

因此，系統一開始會針對不同比例先進行整合評分，再將整合出來的各級分文章根據下列所屬的類型，進行誤差權重的計算。

$$P_i = \frac{1}{Pf_{i,w,g} * Pf_{i,s,g}}, \text{ if } G_{i,now} \in G_{i,w} \cap G_{i,s} \quad (3)$$

$$P_i = \frac{|G_{i,w} - G_{i,now}| + |G_{i,s} - G_{i,now}| * \frac{Pf_{i,w,g} + Pf_{i,s,g}}{Pf_{i,w,g} * Pf_{i,s,g}}}{2}, \text{ if } G_{i,now} \in G_{i,w} - G_{i,s} \text{ or } G_{i,now} \in G_{i,s} - G_{i,w} \quad (4)$$

$$P_i = \left( |G_{i,w} - G_{i,now}| + |G_{i,s} - G_{i,now}| \right) * \frac{Pf_{i,w,g} + Pf_{i,s,g}}{Pf_{i,w,g} * Pf_{i,s,g}}, \text{ if } G_{i,now} \notin G_{i,w} \cup G_{i,s} \quad (5)$$

$P_i$  : 文章*i*所得到的誤差權重。  
 $G_{i,now}$  : 文章*i*在現在比例所評定的分數。  
 $G_{i,w}$  : 文章*i*依比例評定的分數對應立意取材(word)分數的文章集合。  
 $G_{i,s}$  : 文章*i*依比例評定的分數對應結構組織(structure)分數的文章集合。  
 $P_{fi,w,g}$  : 文章*i*在立意取材中所在級分(grade)的篇數。  
 $P_{fi,s,g}$  : 文章*i*在結構組織中所在級分(grade)的篇數。

在上述公式中可以得知，當一篇文章經過整合評定出來的分數與立意取材和結構組織評出來皆相同時，其類型落在公式(3)中。其所得到的誤差權重會較低；反之，權重會較高。例如：某篇文章被整合評定為1級分，也屬於立意取材和結構組織一級分中，其誤差權重應該經由公式(3)得出。

然而公式(4)、(5)前半項  $|G_{i,w} - G_{i,now}| + |G_{i,s} - G_{i,now}|$  主要是用來區隔文章類型落在(4)、(5)內，但文章分數不盡相同的誤差權重。例如：某篇文章(整合評分:1分;立意取材:1分;結構組織:6分)，另一篇(整合評分:1分;立意取材:1分;結構組織:3分)，其誤差權重應該為前者較高。

再由已知的文章誤差權重，經過下列公式，進行目前比例的誤差權重。

$$Error\ ratio = \sum_{i=1}^6 \left( \sum_{v_j \in i} P_j \right)^2 \quad (6)$$

$P_i$  : 文章*i*所得到的誤差權重。  
 Error Ratio : 目前比例誤差權重。

在公式(6)中，內部  $\sum$  計算目前比例中每個級分的誤差，而對各個級分誤差值做平方，主要是為了讓差距能夠有所顯著，最後得到目前比例的誤差權重。當對每個比例皆做完誤差權重的計算後，即可得知產生越小權重的比例，應當對文章分數及其分佈為最佳的。

## (八) 文章錯別字判斷

文章錯別字主要分作同音異字、異音異字兩種，而通常作文上普遍嚴重的錯誤通常在於同音異字上，因此本系統是針對同音異字來做判斷。

### ●錯別字判斷系統流程

在這部分系統基本假設為：當文章中存在錯別字時，經過斷詞處理後。因無法找到對應的詞語，而會被斷成連續的一字詞。因此系統基本內部的判斷，會針對斷詞後被斷成連續一字詞的做處理，其流程我們根據《國語一字多音審訂表》將連續的一字詞轉換成注音型式後，再將注音型式的連續字由最長比對演算法在《國語一字多音審訂表》(以下簡稱注音表)，中尋找對應的格式。

在此利用一個簡單的例子說明其基本判斷過程：

「今天天氣好熱」  
 因為句子中有錯字，斷詞後會變成：  
 「(今天)(天)(汽)(好)(熱)」  
 針對連續一字詞做注音轉換如下：  
 「ㄊㄩㄣ ㄧ ㄋㄞ ㄎㄨㄛ ㄏㄞ ㄏㄜ ㄏㄜ ㄏㄜ」  
 最長比對演算法，由最長的字串開始在注音表中搜尋：  
 「ㄊㄩㄣ ㄎㄨㄛ ㄏㄞ ㄏㄜ ㄏㄜ ㄏㄜ」 .....(1)  
 「ㄊㄩㄣ ㄎㄨㄛ ㄏㄞ」 .....(2)  
 「ㄊㄩㄣ ㄎㄨㄛ」 .....(3)

經過搜尋後，我們經由(3)可在注音表找到對應的組合，變轉換回國字型式「天氣」，剩餘的字皆不做更動，基本判斷最後結果即為「今天天氣好熱」。

由上述判斷中，可得知具有一定判斷性效果。但之間未考慮詞與詞之間的關係，可能會對許多原本是對的句子照成誤判的情形。

在此舉一個簡單嚴重誤判例子說明：  
 「上課鐘一打」  
 斷詞後如下：  
 「(上課)(鐘)(一)(打)」  
 針對連續一字詞做處理：  
 「ㄕㄨㄥ ㄨㄛ ㄓㄨㄥ ㄧ ㄉㄚ」

√ 「.....」(1)  
 「 出 又 一 ㄥ 」  
 一 .....」(2)  
 系統由(2) 在注音表找到對應的組合為「中醫」，即將其轉換，最後結果為「上課中醫打」。

因此我們為了避免這種情形時常發生，即加入了中研院平衡語料庫 bigram 雙詞語的資訊，此資訊可以得知哪些詞語的配對是可能出現的。例如：[上課] [鐘] 此配對在 Bigram 中有出現；然而[上課] [中醫]在 Bigram 是沒出現過的。當作系統進入基本錯別字判斷的門檻。

其運作過程針對斷詞後的每個詞，進行下述演算法：

Algorithm2：錯別字檢查演算法

```

If ( $W_{i-1}W_i \in \text{Bigram}$ ) and ( $W_iW_{i+1} \in \text{Bigram}$ )
  then print  $W_i$ ;
else if ( $W_{i-1}W_i \in \text{Bigram}$ ) or ( $W_iW_{i+1} \in \text{Bigram}$ )
  then begin
    processed by the Base-Work;
    if ( $W_{i-1}W_i^* \in \text{Bigram}$ ) then print  $W_i^*$ ;
    else print  $W_i$ ;
  end
  
```

$W_i$ ：斷詞後第  $i$  個欲檢測的詞語。

$W_{i-1} W_i$ ：斷詞後第  $i-1$  個詞與第  $i$  個詞所構成的 bi-word。

Base-Work：基本內部的錯別字判斷。

$W_i^*$ ：經過 Base-Word 所跟換的詞。

因此嚴重誤判的例子經過上述演算法後其流程與結果如下：

「上課鐘一打」

經斷詞後如下：

「(上課)(鐘)(一)(打)」

首先判斷第一個詞語(上課)，再系統中我們將字首前 bi-word 與字尾後

bi-word 視為 true。

「( ) (上課)」=true 且 「(上課) (鐘)」=true

發現在 Bigram 皆可搜尋到 Bi-word，即印出(上課)，再判斷第二個詞：

「(上課) (鐘)」=true 且 「(鐘) (一)」=false.....(1)

在(1)中無法在 Bigram 搜尋到「(鐘)(一)」，因此認為可能有錯誤字產生，隨之進入基本內部的判斷(即針對連續一字詞)。如下：

「出又ㄥ 一 ㄨㄩˇ」

「出又ㄥ 一」

根據注音表可找到對應的詞「中醫」後再判斷前半部 Bi-word。

「(上課)(中醫)」=false.....(2)

在轉化後，依然在 Bigram 資訊中搜尋不到如(2)，因此不對詞語做任何更改的動作，即印出(鐘)。以此類推，最後的結果為「上課鐘一打」，不會照成誤判的情況，且對錯誤的字依然仍有效的更正。

### ●系統修正

在3.7.1節中，系統只針對每篇文章連續一字詞作處理，但其可能在斷詞時所產生出的結果無法達到預期。如下：

表三、例外狀況

文章	詞語	斷詞
1	「藍球場」	「(藍)(球場)」
2	「藍球」	「(藍)(球)」

再系統中文章2所出現的詞語被斷為連續的一字詞，因此會更正為「藍球」，而文章1詞語中的(藍)也是錯誤的字詞，但因非斷成一字詞，因此系統不做任何判斷。

為了避免上述這種情況，我們建立成為系統錯字表，其收集系統對每篇文章所改出來的錯別字配對。且在搭配422常用錯別字，在系統最後對全部文章做檢測，以避免漏網之魚。

## (九) 實驗過程與討論

### [一] 相似度評分系統

#### ●實驗資料

本實驗採用的實驗資料為三所學校之國中二年級學生所撰寫的作文文章，其題目為「下課十分鐘」，這些作文將其輸入成電子檔時保留所有的錯別字以及標點符號，以維持學生所撰寫的原貌。所有的資料共有689篇，每篇皆由二到三名的老師所批閱，其分

數範圍為一至六級分，再取平均並四捨五入後當做該篇文章的評閱分數。

### ●實驗流程

將所有文章先經過斷詞處理後，再從文章擷取出結構、詞語兩部分的特徵當作系統演算法判斷的依據並分別做相似度評分系統的運作，當系統分別依照兩種特徵進行運作，直到文章分數達到穩態後，最後根據其文章的Z-Score分佈區間評定文章六級分的分數。

### ●評鑑方式

本系統之實驗所採取的評鑑方式是針對正確率(Adjacent)以及精確率(Exact)兩項指標當作評鑑系統之效能。

正確率:系統、人工評分之誤差一分內之文章數/文章總數。

精確率:系統、人工評分必須完全相同之文章數/文章總數。

因為不同評閱者的背景知識、主觀認知不盡相同，使得對文章之評分標準也會有所不同。因此本實驗認為誤差一分內皆屬正確之批閱。

### ●實驗結果

其分別針對詞語以及結構上評分，結果如下表所示：

表四、採詞語特徵之系統評分結果表

系統評分 \ 人工評分	一分	二分	三分	四分	五分	六分	正確率	精確率
一分	45 篇	29	12	3	1	0	91.1%	64.4%
二分	128 篇	20	52	39	16	1	86.7%	40.6%
三分	210 篇	2	45	86	67	10	94.3%	41.0%
四分	208 篇	0	7	59	107	35	96.6%	51.4%
五分	91 篇	0	0	6	44	40	93.4%	44.0%
六分	7 篇	0	0	0	2	5	71.4%	0%
合計	689 篇	51	116	193	233	91	93.0%	45.6%

表五、採結構特徵之系統評分結果表

系統評分 \ 人工評分	一分	二分	三分	四分	五分	六分	正確率	精確率
一分	45 篇	16	21	7	1	0	82.2%	37.8%
二分	128 篇	12	45	49	17	5	82.8%	36.7%
三分	210 篇	4	44	93	60	7	93.8%	36.7%
四分	208 篇	2	19	72	77	32	87.0%	38.0%
五分	91 篇	0	6	23	29	22	68.1%	19.8%
六分	7 篇	0	0	0	4	3	42.9%	14.3%
合計	689 篇	44	135	244	188	69	85.1%	36.7%

## [二]分數整合評分系統

### ●實驗流程

此部分會使用經由相似度系統分別對兩個面向評分所得到的文章分數、各級分之文章分佈以及文章尚未轉化成六級分之Z-Score，做為整合評分系統之初始資料。當所有資訊輸入系統進行比例誤差權重的計算，根據系統所得出的最小誤差之比例，進行整合評分，最後再根據文章Z-Score分佈區間評定文章六級分的分數。其評鑑方法也是與4.1.3小節相同。

### ●實驗結果

由系統得出之最佳比例所進行整合評分，結果如下表所示：

表六、整合評分系統之結果表

系統評分 \ 人工評分	一分	二分	三分	四分	五分	六分	正確率	精確率
一分	45 篇	24	17	3	1	0	91.1%	53.3%
二分	128 篇	9	59	44	15	1	87.5%	46.1%
三分	210 篇	0	45	98	64	3	98.6%	46.7%
四分	208 篇	0	8	51	125	24	96.2%	60.1%
五分	91 篇	0	0	8	45	37	91.2%	40.7%
六分	7 篇	0	0	0	1	6	85.7%	0.0%
合計	689 篇	33	129	214	251	71	94.2%	49.8%

### ●效能比較與分析

目前各系統之效能如下表所示：

表七、各系統效能比較表

	正確率	精確率
整合評分系統	94.2%	49.8%
詞語相似度系統	93.0%	45.6%
結構相似度系統	85.1%	36.7%
結構系統	82.0%	39.0%
完全三級分	78.9%	30.3%
ID3 決策樹	93.9%	42.2%
支援向量機	93.6%	49.4%
貝氏學習機(w/o rules)	93.4%	50.3%
貝氏學習機(with rules)	96.2%	55.8%

上述各系統主要可分為二種類型：第一種需要一定數量文章做為訓練資料之評分模型。如：貝氏學習機[4]、支援向量機[5]、ID3 決策樹[6]以及結構系統[8]等評分模型。其中貝氏學習機除了原始模型外，另有加入特殊規則的版本。第二種類型即為不需要訓練資料，僅需文章數量達到一定程度方能進行評分之評分模型(即表四中底色為藍色之部分)，其中詞語相似度系統為非監督式評分系統[7]之修改。

由上表可得知，系統在不需要訓練資料下，針對文章兩個面向進行分別評分其效果皆能與使用訓練資料之模型相差不遠。而在整合評分系統上，其正確率及準確率已超過大部分之模型，僅略差於加入規則的貝式學習機。而且系統批閱之誤差與人工批閱者之誤差已十分接近，其具有一定的可信度，因可以當作人工批閱時之輔助的依據。

### ●文章分批實驗

此部分將針對文章不同資料量來進行整合評分系統之實驗。其主要目的是想得知系統所取出之最佳比例來進行評分是否合理。因此我們將取各級分之文章前 100%、90%、80%、70%、60%、50%六種不同的文章數來進行實驗。

#### 1. 結果與討論

其分批資料量所得到結果如下表所示：

表八、分批資料量結果表

資料量	詞語	結構	整合	系統比例
100%	689 篇 正確率:0.930 準確率:0.456	正確率:0.851 準確率:0.367	正確率:0.942 準確率:0.498	7:3
90%	620 篇 正確率:0.931 準確率:0.474	正確率:0.853 準確率:0.376	正確率:0.952 準確率:0.495	7:3
80%	551 篇 正確率:0.911 準確率:0.452	正確率:0.853 準確率:0.376	正確率:0.949 準確率:0.481	7:3
70%	483 篇 正確率:0.901 準確率:0.433	正確率:0.845 準確率:0.375	正確率:0.932 準確率:0.468	7:3
60%	414 篇 正確率:0.891 準確率:0.444	正確率:0.860 準確率:0.379	正確率:0.935 準確率:0.454	7:3
50%	343 篇 正確率:0.892 準確率:0.437	正確率:0.866 準確率:0.367	正確率:0.913 準確率:0.449	6:4

表五中其評鑑方式亦是根據 4.1.3 小節相同。由表中可得知系統可根據立意取材及結構組織之部分做最佳比例之分數整合，其效果也達一定的水準。唯有在資料量 50% 時，系統所找出的比例為 6:4(表四中底色為藍色之部分所示)，即 60% 詞語以及 40% 結構，但實際上其最佳比例應為 7:3，但因系統是依據立意取材及結構組織的文章分佈，所算出之誤差權重，因此我們可認為其原因，應為文章資料量過少或者些許文章所得到的誤差權重太大，所造成其結果。

### [三]文章錯別字判斷

我們利用 4.1.1 小節中所提的資料，取各級分前 50%，來做錯別字判斷系統的測試資料。此資料已經由人工的方式找出文章中錯字的部份，其錯別字分類為兩種：第一種同音異字上的錯誤，第二種其餘的錯誤如：多一個字、少一撇、異音異字等錯誤字。

### ●實驗流程與評鑑方式

首先將每篇文章斷詞後，分別輸入原始系統(即尚未修改前之系統)以及修改後之系統進行實驗，其目的是想得知修改過後之系統是否能有效提升正確率。在本系統只針對同音異字做正確率與錯誤率之計算，當作此系統之效能。

正確率:系統與人工得出錯別字之總數/人工得出錯別字之總數。

錯誤率:系統誤判錯字之總數/系統得出錯別字之總數。

## ●實驗結果

其兩個系統所得到之結果如下表所示：

表九、系統尚未修改前之結果表

	結果
人工評定為同音錯別字	286 字
人工評定為其他錯別字	203 字
系統評定為同音錯別字	221 字
系統誤判	4 字
系統之正確率	67.48%
系統之錯誤率	12.66%

表十、系統修改後之結果表

	結果
人工評定為同音錯別字	286 字
人工評定為其他錯別字	203 字
系統評定為同音錯別字	236 字
系統誤判	4 字
系統之正確率	72.72%
系統之錯誤率	11.86%

由表七中可得知，系統經過修正後其效果會有明顯的增加，所得結果足以證明此初階系統之可信度，往後可做為輔助糾正文章錯別字的工具。

## 五、計畫成果與自評

### ●研究總結

在本論文中，我們所提出的中文寫作多面向評分系統，有別於以往的評分系統，本系統將不再需要事前訓練資料，且不再是以單面向、主觀的方式來給予評分，我們希望在評分上能達到更高的可信度，因此提出了針對多面向來進行評分的方式，根據文章的結構、詞語…等特徵，將各分數加以統整，在上述的實驗中，利用此方法所得之正確率達到 94.2%，證明了多面向整合的評分方式較為客觀，且其實驗結果之整合分數比傳統的評分系統更足以採信；此外，針對錯別字與各特徵都將給予回饋，使用者可藉由此回饋資訊得知在寫作上有哪些需要改進的部份，以提升寫作能力。

目前成果部分，有一篇論文已經被 IEEE Intelligent Systems 期刊接受[10]，兩篇

論文被 Expert Systems with Applications 期刊接受[11][12]，另外在決策樹方面我們提出一個簡化多值化決策樹的方法，該論文已經被 ISICA 2008 [13] 接受，該論文也會收錄於 LNCS 期刊；此外關於 CAES 研究部分，也分別發表於國際學術會議 NLPKE [14] 以及 APERA 2008 [15]，另外也有一篇論文發表於相關期刊中 [16]。另外尚有一篇論文被 ICNC' 10 Conference 接受並且已經刊出 [17]。

### ●未來工作

本論文目前雖然已針對作文寫作上四個面向當中的立意取材及結構部分上做統整上的評分，且在錯別字判斷中給予回饋的錯誤資訊，但系統尚未包含中文作文評分的全部標準，即少了遣詞造句及錯別字與格式上的分數，因此希望未來能加入這兩個面向上的評分，使系統更能符合人工批閱的模式。

## 六、參考文獻

- [1] Jill Burstein. "The E-rater Scoring Engine: Automated Essay Scoring With Natural Language Processing." Automated Essay Scoring: A Cross-Disciplinary Perspective. pp. 113-121, 2003.
- [2] 蔡沛言，「自動建構中文作文評分系統：產生、篩選與評估」，國立交通大學，碩士論文。(2005)
- [3] 林信宏，「基於貝氏機器學習法之中文自動作文評分系統」，國立交通大學，碩士論文。(2006)
- [4] 粘志鵬，「基於支援向量機之中文自動作文評分系統」，國立交通大學，碩士論文。(2006)
- [5] 張佑銘，「中文自動作文修辭評分系統設計」，國立交通大學，碩士論文。(2005)
- [6] 陳彥宇，「非監督式中文寫作自動評閱系統」，國立交通大學，博士論文。(2007)
- [7] 張道行，「Conceptualization Methodology for Chinese Automatic Essay Scoring」，國立交通大學，博士論文。(2007)
- [8] 國中中學學生基本學力測驗推動委員會 URL: <http://www.bctest.ntnu.edu.tw/>

- [9] S. Valenti, F. Neri, and A. Cucchiarelli. "An overview of current research on automated essay grading." *Journal of Information Technology Education*, Vol. 2, pp.319-330, (2003)
- [10] Yen-Yu Chen, Chien-Liang Liu, Tao-Hsing Chang, and Chia-Hoang Lee (2010). "An Unsupervised Automated Essay Scoring System." To be appeared in *IEEE Intelligent Systems*
- [11] Chien-Liang Liu, Chia-Hoang Lee, Ssu-Han Yu, Chih-Wei Chen (2011). Computer assisted writing system, *Expert Systems With Applications* Vol. 38, Issue 1, pp. 804-811 (SCI)
- [12] Chien-Liang Liu, Chia-Hoang Lee, and Ping-Min Lin (2010), "A fall detection system using k-nearest neighbor classifier", *Expert Systems With Applications*, Vol. 37, Issue 10, 7174-7181, 2010 (SCI)
- [13] Chien-Liang Liu and Chia-Hoang Lee. Simplify Multi-valued Decision Trees, The 3rd International Symposium on Intelligence Computation and Applications (ISICA 2008), LNCS 5370, 581–590
- [14] Chang, T. H., Lee, C. H., Tsai, P. Y. & Tam, H. P. (2008). *Automated essay scoring using set of literary sememes*. Paper presented at the IEEE International Conference on Natural Language Processing and Knowledge Engineering, 403-407, Beijing, China.
- [15] Chang, T. H., Tam, H. P., Lee, C. H. & Sung, Y. T. (2008). *Automatic Concept Map Constructing Using Topic-specific Training Corpus*. Paper presented at APERA 2008, Singapore.
- [16] Chang, T. H., Lee, C. H., Tsai, P. Y. & Tam, H. P. (2009). Automated essay scoring using set of literary sememes. accepted by *Information: An International Interdisciplinary Journal*, 12(2).
- [17] Chien-Liang Liu, Emery Jou and Chia-Hoang Lee (2010), "Analysis and Prediction of Trajectories Using Bayesian Network", The 6th International Conference on Natural Computation (ICNC'10), Vol 7, 3808-3812, Yantai, China



The 6<sup>th</sup> International Conference on Natural Computation

The 7<sup>th</sup> International Conference on Fuzzy Systems and

Knowledge Discovery

(ICNC'10-FSKD'10)

研討會

出國報告書

姓名：劉建良

會議舉辦地點：大陸山東省煙台

會議日期：**August 10-12, 2010**

ICNC'10-FSKD'10 國際會議研討會是由中國煙台大學主辦，該會議所收錄之論文也將會由 IEEE Xplore 以及 EI Compendex 所 index。我們這次所發表的論文題目為「Analysis and Prediction of Trajectories Using Bayesian Network」，主要是利用 Bayesian Network 技術對 GPS 軌跡資訊作分析以及預測。

該會議總共舉辦三天，第一天所邀請到的 Keynote Speaker 包括 Gary G. Yen 教授、Derong Liu 教授以及 Qiang Yang 教授。其中 Gary G. Yen 教授目前是 IEEE 雜誌的主編，而 Qiang Yang 目前也是 IEEE Intelligent Systems 的 Associate Editor。其中最令我印象深刻的是 Qiang Yang 教授的演講，他目前的主要研究方向為 Machine Learning、Data Mining 以及 Social Network 分析。我目前的研究主題也在這方面上，所以他的演講給了我不少的啟發。在演講中，他提到目前他的其中一個研究題目為 link prediction。這邊的 link 不僅只是一般的網路 link 還可以延伸到 social network 上面人與人之間的 link。如何從既有的資訊中，去更進一步的得到使用者與使用者的關係，甚至可以預測可能的關係或關連性等等。目前 Facebook 即是大量使用了類似之技術。此外，Qiang Yang 還提到一個 transfer learning。傳統的機器學系必須有一個假設前提，training data 以及 testing data 甚至於未來未知的 data 必須具備相同的統計分佈。Qiang Yang 認為該假設在實際應用上會有很大的限制，因此他們希望可以延伸，甚至於把一些從不同資料類型中學習到的 learning model，可以套用到完全不同類型的資料中。未來或許可以成為我的另一研究方向。

此外，該會議主要是著眼於智慧型系統相關技術，包括 Fuzzy、類神經網路、資料探勘等等，在三天的研討會中，讓我從中聽到不少的新方法，收穫良多。

# Analysis and Prediction of Trajectories Using Bayesian Network

Chien-Liang Liu, Emery Jou, and Chia-Hoang Lee

**Abstract**—In this paper, we proposed a novel approach based on Bayesian network to predict a moving object’s future location under uncertainty. The approach includes space-partitioning schemes, popular region extraction, transformation of trajectory sequence and region sequence, frequent sequential pattern mining and the Bayesian network construction. Popular regions are used to approximate a moving object’s trajectory sequences. The analyzers could determine the regions they are interested in and the system could choose the frequent region patterns including these regions to construct the Bayesian network. The popular regions will be regarded as random variables of the Bayesian network and the traversal paths of regions are used to construct the arcs between nodes of the Bayesian network. The local probability distribution at each node is obtained from the empirical data. We propose several algorithms to transform the trajectory information into the Bayesian network structure. The experiment shows that the Bayesian network allows us to perform inference and get the probabilities of all possible states of an unobserved node under the current observed data.

**Index Terms**—Trajectory Pattern Mining, Data Mining, Probability

## I. INTRODUCTION

In the last decade, data mining has been proved its capability and it has been successfully applied to a diversity of application domains. Essentially, sequential patterns mining focuses on finding inter-transaction patterns in the time-stamp ordered transaction set. Many algorithms for sequential pattern mining have been proposed, such as PrefixSpan [1] and SPADE [2]

In recent years, many researchers have attempted to discover usable knowledge about movement behavior. Various approaches have been employed in spatio-temporal data mining. In association rule mining, Giannotti et al. [3] proposed a novel form of sequential pattern, called Temporally-Annotated Sequence (TAS). Each transition in a sequential pattern is annotated with a typical transition time. Based on TAS notation, Giannotti et al. [4] proposed a density-based algorithm for discovering regions of interest and a trajectory pattern mining algorithm dynamically discovering regions of interest. Meanwhile, Jeung et al. [5] presented a novel hybrid prediction approach to estimate an object’s future locations based on its pattern information as well as an existing motion function using the object’s recent movements. In addition to association rules, probability model approaches predict a moving object’s future location using uncertainty and probability. Ishikawa et al. [6] proposed to adopt Markov chain model to estimate with high probability whether an object at some regions will move to another region in the next period. Meanwhile, Jeung et al. [7] adopted Hidden Markov Model to describe a moving object’s trajectory pattern. An object’s movements are

described by the partitioned cells, but its patterns are explained by the frequent regions.

In this paper, we introduce a novel approach based on Bayesian network to predict a moving object’s future location under uncertainty. The approach includes space-partitioning schemes, popular region extraction, transformation of trajectory sequence and region sequence, frequent sequential pattern mining and the Bayesian network construction. The system allows the analyzers to determine the regions that they are interested in and frequent region patterns including these regions will be chosen to construct the Bayesian network. These popular regions are random variables in Bayesian network. The sequence of the traversal path could be used to construct the arcs between these nodes and the local probability distribution at each node is obtained from the empirical data.

## II. RELATED SURVEY

In trajectory pattern mining, Jeung et al. [5] presented a novel approach to predict an object’s future locations in a hybrid manner utilizing both motion function and objects’ movement patterns. They proposed an indexing method called Trajectory Pattern Tree to discover trajectory patterns and manage a large number of trajectory patterns to answer predictive query efficiently.

Instead of using association rules to obtain trajectory patterns, Ishikawa et al. [6] proposed to extract the mobility statistics, which is based on Markov Chain Model, from an indexed spatio-temporal database. Assume a database stores a huge volume of trajectories of moving objects and each trajectory record starts from  $t = 0$  and ends at  $t = T$ . Based on Markov Chain Model, given a moving object’s current position  $C_0$  at a specific time  $t$ , the probability of moving to  $C_1$  at time  $t + 1$  could be obtained based on conditional probability.

Moreover, Jeung et al. [7] proposed to use Hidden Markov Model to perform trajectory pattern mining. In traditional sequential pattern mining, transition time between transactions are used to indicate the order of sequence and the temporal information will be absent in the mining rules. Temporally Annotated Sequences (TAS), introduced by Giannotti et al. [4], are extension of sequential patterns that enrich sequences with the typical transition times between original sequences.

## III. SYSTEM DESIGN

Figure 1 shows the system flow including popular region extraction, trajectory sequence to region sequence transformation, frequent region extraction and Bayesian network construction stages.

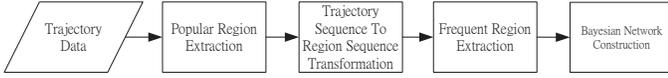


Fig. 1. System Flow

### A. Popular Region Extraction

We adopt region concept to approximate a moving object's spatio location. Thus, two objects that are located in the same region will be regarded as being at the same location. Moreover, a moving object's trajectory sequences could be transformed into region sequences. For example, if there is a trajectory sequence  $(x_1, y_1) \xrightarrow{\alpha} (x_2, y_2) | (x_1, y_1) \in R_1 \wedge (x_2, y_2) \in R_2$ , it could be transformed to  $R_1 \xrightarrow{\alpha} R_2$ .

In this paper, popular regions are adopted to approximate a moving object trajectory information. The popular region extraction process is based on the approach proposed by [4] with minor modification. The whole plane could be regarded as a grid  $G$ , which is partitioned into  $n \times m$  cells. The density of each cell  $G(i, j)$  ( $1 \leq i \leq n$  and  $1 \leq j \leq m$ ) is based on the moving object's trajectory information. Figure 2 shows a moving object's trajectory information. At time  $T_1$ , its location is at  $P_1$ . It moves to location  $P_2$  at time  $T_2$ . When the moving object's location is at position  $P_1$ , the cells around  $P_1$  (cells 1 – 9) will be assigned with equal weights. Meanwhile, linear regression approximation is adopted to describe the trajectory between two consecutive points. As shown in Figure 2, the moving function between  $P_1$  and  $P_2$  is approximated using a linear regression and the cells around this line should be assigned with equal weights as well. We extend from the start point and the virtual points will be assigned along this line. The distance between the two virtual points is the length of the cell. For each virtual point, the cells around this virtual point will be assigned with equal weights as well. In addition, each cell will be weighted once for the same moving object. Thus, the gray cells in Figure 2 will be assigned with the same weights. For each trajectory sequence, it will contribute weights to the cells along the trajectory. When the process is completed, the popular cells could be determined based on the cell's density. Simultaneously, follow the steps of *PopularRegions* algorithm mentioned in [4], these popular cells could be extended as much as possible along four directions to obtain popular regions.

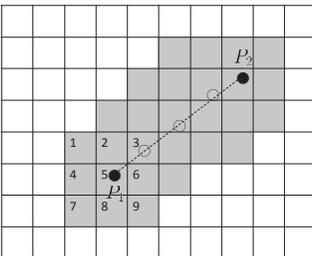


Fig. 2. Trajectory Density Computation Model

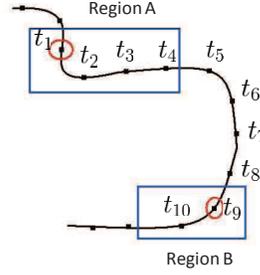


Fig. 3. Transformation Between Trajectory Sequence and Region Sequence

TABLE I  
DATABASE WITH FOUR TRANSACTIONS

Transaction ID	Sequence
1	a b c d e
2	a b c d
3	b d
4	a b

### B. Trajectory Sequence To Region Sequence Transformation

When the popular regions are extracted, the system can obtain trajectory point's corresponding region based on coordinates information. In practice, the GPS recorder keeps track of trajectory information every several seconds, so consecutive points are usually located in the same area. Line 6 – 14 performs the aggregation of regions.

For example, Figure 3 shows a trajectory sequence and it includes fourteen points. The transformation result will be  $00AAAA0000BB00$ , where 0 indicates that this point is not within any region. Although this trajectory sequence passes through *Region A* four times, it will be recorded once. Meanwhile, the trajectory points that are not within popular regions will be ignored. Furthermore, the trajectory may stay at a region for a while, but only the entry time will be taken into account. In other words, the trajectory in Figure 3 will be transformed into the region sequence  $R_A \xrightarrow{t_1-t_9} R_B$ . When the above step completes, the original trajectory sequence could be approximated by the region sequence.

### C. Frequent Sequential Pattern Mining

When the region sequences are obtained, Algorithm 1 (Modified PrefixSpan Algorithm), which is based on PrefixSpan [1] algorithm, is employed to extract frequent sequential patterns. In Algorithm 1, *DatabaseScan* procedure will get frequent 1-itemsets. For example, if we have four transactions as shown in Table I. After *DatabaseScan* procedure applying to the above sequences with the minimum support of value three, the frequent 1-itemset of the database will be  $a, b$  and  $d$ . A queue will be created to store these frequent items. Database

TABLE II  
PROJECTION RESULT

Transaction ID	Sequence
1	b c d e
2	b c d
4	b

---

**Algorithm 1** Modified PrefixSpan Algorithm
 

---

**Input:** A database  $DB$  with transaction list, minimum support  $min\_supp$ 
**Output:** Maximal Frequent List

```

1: 1-itemsetList  $\leftarrow$  DatabaseScan( $DB, min\_supp$ )
2: Queue  $\leftarrow$  CreateQueue(1-itemsetList)
3: while Queue is not empty do
4:    $e \leftarrow$  Queue.dequeue()
5:   projectedItemList  $\leftarrow$  DatabaseScan(Projection( $e, DB$ ),  $min\_supp$ )
6:   if projectedItemList is empty then
7:     OUTPUT  $e$ 
8:   else
9:     for all  $i$  such that  $1 \leq i \leq projectedItemList.Length$  do
10:      Queue.enqueue( $e.concat(projectedItemList[i])$ )
11:     end for
12:   end if
13: end while

```

---

projection will be applied to the elements in the queue. For example, the first element in queue is  $a$  and Table II shows the result of  $a$ -projection on the database.

For each projection result, *DatabaseScan* procedure could be applied to get the frequent 1-itemset of the projected database and the projection item could combine the new 1-itemset to obtain larger itemset. For example, the frequent 1-itemset in Table II is  $b$ , and it means that  $ab$  will be frequent itemset too and  $ab$  will be added into the queue for further process. When the above process is completed, the system could obtain frequent region patterns.

#### D. Bayesian Network Construction

As mentioned above, frequent patterns on region sequences could be discovered by sequential pattern mining. The analyzers could determine the regions they are interested in and the system could choose the patterns including these regions. These popular regions will be used to denote the random variables of the Bayesian network. In this paper, we assign each region an unique serial number. For example, if we are interested in Region 1 – 5, and the frequent region sequences including these five regions are listed as follows:

$$\begin{aligned}
 R_1 &\rightarrow R_2 \rightarrow R_3 \rightarrow R_4 \\
 R_2 &\rightarrow R_4 \rightarrow R_5 \\
 R_1 &\rightarrow R_2 \rightarrow R_3 \rightarrow R_5 \\
 R_2 &\rightarrow R_3 \rightarrow R_4 \\
 R_1 &\rightarrow R_3 \rightarrow R_5
 \end{aligned}$$

For each region sequence, we could construct a corresponding traversal path and Figure 4 shows the result. The ordering of regions in the sequence indicates the visiting ordering, and the ordering is used to represent causal relationship of the Bayesian network. When the system processes  $R_1 \rightarrow R_2 \rightarrow R_3 \rightarrow R_4$  sequence, a traversal path starting from  $R_1$  will be constructed.

Essentially, a Bayesian network represents a system of probabilistic events as nodes in a directed acyclic graph. For the graphs with loops, it is possible to use loopy belief

propagation approach to approximate inference. However, because the graph now has cycles, information can flow many times around the graph. For some models, the algorithm will converge, whereas for others it will not [9]. Meanwhile, in many applications such as tour planning and transportation routing analysis, people rarely re-visit the same place during a fixed time interval and cycle conditions in the trajectory sequence could be ignored. Thus, The region sequences with cycle condition will be removed in this paper. The construction of a Bayesian network structure using region sequences is presented in Algorithm 2, where Line 1–9 will create a region node if this region node has not been created and Line 10–20 will create the arc between parent node and child node.

In addition to the structure construction, we could construct the conditional probability table for each random variable from empirical data. In trajectory analysis, we define all the nodes as discrete-valued, where “Yes” and “No” are used to denote whether the moving objects have visited or not. As shown in Figure 4, the conditional probability table for node  $R_1$  will need to take into account two conditions: the proportion of region sequences includes  $R_1$  and the proportion of region sequences does not pass through  $R_1$ . According to the empirical sequence data, the number of paths including  $R_1$  is 3, so the proportion would be 60%; while the proportion of paths not including  $R_1$  is 40%. As for  $R_2$ , it has one parent node  $R_1$ , so it has to take into account both its parent node. The conditional probability table of  $R_2$  is presented in Figure 4, where smoothing method is adopted to avoid the zero probability problem. Therefore, when the above processes are completed, we could construct a Bayesian network with structure and parameters.

#### IV. EXPERIMENT

In Bayesian network, inference is the process of updating probabilities of outcomes based upon the relationships in the model and the evidence known about the situation at hand. Therefore, performing inference means manipulating evidence in a model and obtaining the posterior probabilities resulting from the changes in evidence. Essentially, exact and approximate inferences in Bayesian network is NP-hard, but we can

---

**Algorithm 2** Trajectory Bayesian Network Construction
 

---

**Input:** Region Sequences List (*regionSequenceList*)

**Output:** A Bayesian Network

```

1: for all  $i$  such that  $1 \leq i \leq \text{regionSequenceList.Length}$  do
2:   for all  $j$  such that  $1 \leq j \leq \text{regionSequenceList}[i].\text{Length}$  do
3:      $e \leftarrow \text{regionSequenceList}[i][j]$ 
4:     if  $\text{list.IsExist}(e)$  is False then
5:        $\text{list.add}(e)$ 
6:       create a node for  $e$ 
7:     end if
8:   end for
9: end for
10: for all  $i$  such that  $1 \leq i \leq \text{regionSequenceList.Length}$  do
11:   for all  $j$  such that  $1 \leq j \leq \text{regionSequenceList}[i].\text{Length}$  do
12:      $\text{parentNode} \leftarrow \text{regionSequenceList}[i][j]$ 
13:     if  $\text{regionSequenceList}[i][j+1]$  is not NULL then
14:        $\text{childNode} \leftarrow \text{regionSequenceList}[i][j+1]$ 
15:       if there is no arc between  $\text{parentNode}$  and  $\text{childNode}$  then
16:         create a arc from  $\text{parentNode}$  to  $\text{childNode}$ 
17:       end if
18:     end if
19:   end for
20: end for

```

---

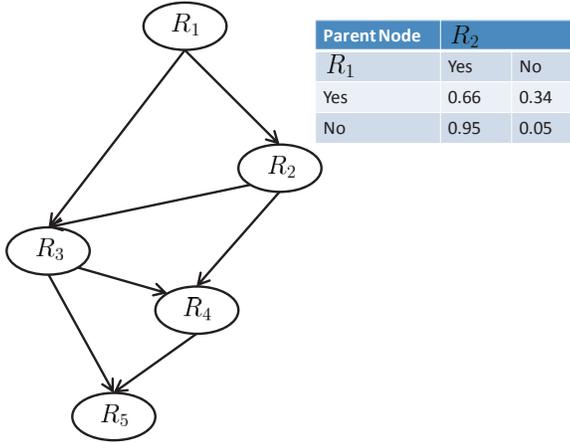


Fig. 4. Bayesian Network Structure for Region Sequences

nonetheless come up with approximations which often work well in practice. In our experiments, inference is performed by using MSBNx [10], which is a component-centric toolkit for modeling and inference with Bayesian network. MSBNx uses clique-tree propagation methods to calculate the probabilities and it provides an extensive programming interface that makes editing and evaluation of Bayesian Networks especially easy from COM-friendly languages such as Visual Basic, Jscript, and C#.

We use the trajectory data collected from GPS recorders to construct the Bayesian network. In the data set, there are 232 trajectory sequences. These trajectory sequences will be used to extract popular regions and the number of popular regions is 17. As mentioned above, the trajectory sequences does not pass through any popular region will be ignored and

the number of trajectory sequences passing through popular regions is 120. In practice, people could choose the regions they are interested in to perform the inference. We select 9 regions to construct the Bayesian network and Figure 5 shows the model result. The direction of arcs could be determined by the ordering of the regions in the sequences. For example, we have sequences  $\langle 0, 2, 4, 1, 3, 9 \rangle$  and  $\langle 0, 5, 2, 1, 3, 9 \rangle$  in the raw data, so we could construct two traversal paths:  $0 \rightarrow 2 \rightarrow 4 \rightarrow 1 \rightarrow 3 \rightarrow 9$  and  $0 \rightarrow 5 \rightarrow 2 \rightarrow 1 \rightarrow 3 \rightarrow 9$ . Moreover, the conditional probability table for each node could be constructed based on empirical sequence data as mentioned in previous section and they are presented in Figure 5.

Essentially, Bayesian network allows us to perform inference and get the probabilities of all possible states of an unobserved node under the current observed data. For example, when we have an evidence saying that the user's current location is at  $R_2$ , the system could further inference user's previous region is at  $R_0$  with a higher probability:

$$Pr(R_0 = 1 | R_2 = 1) = \frac{Pr(R_0 = 1, R_2 = 1)}{Pr(R_2 = 1)} = 0.98$$

$$Pr(R_5 = 1 | R_2 = 1) = \frac{Pr(R_5 = 1, R_2 = 1)}{Pr(R_2 = 1)} = 0.29$$

Besides, we could also derive possible reasons with a given cause. For example, when the user's current location is at  $R_0$ , the system could obtain the probability of arriving at  $R_1$  is 0.93 and the probability of arriving at  $R_8$  is 0.07. In general, a Bayesian network could be designed to represent the deep causal knowledge of a domain expert and provide probabilistic answers to many queries by computing the posterior probabil-

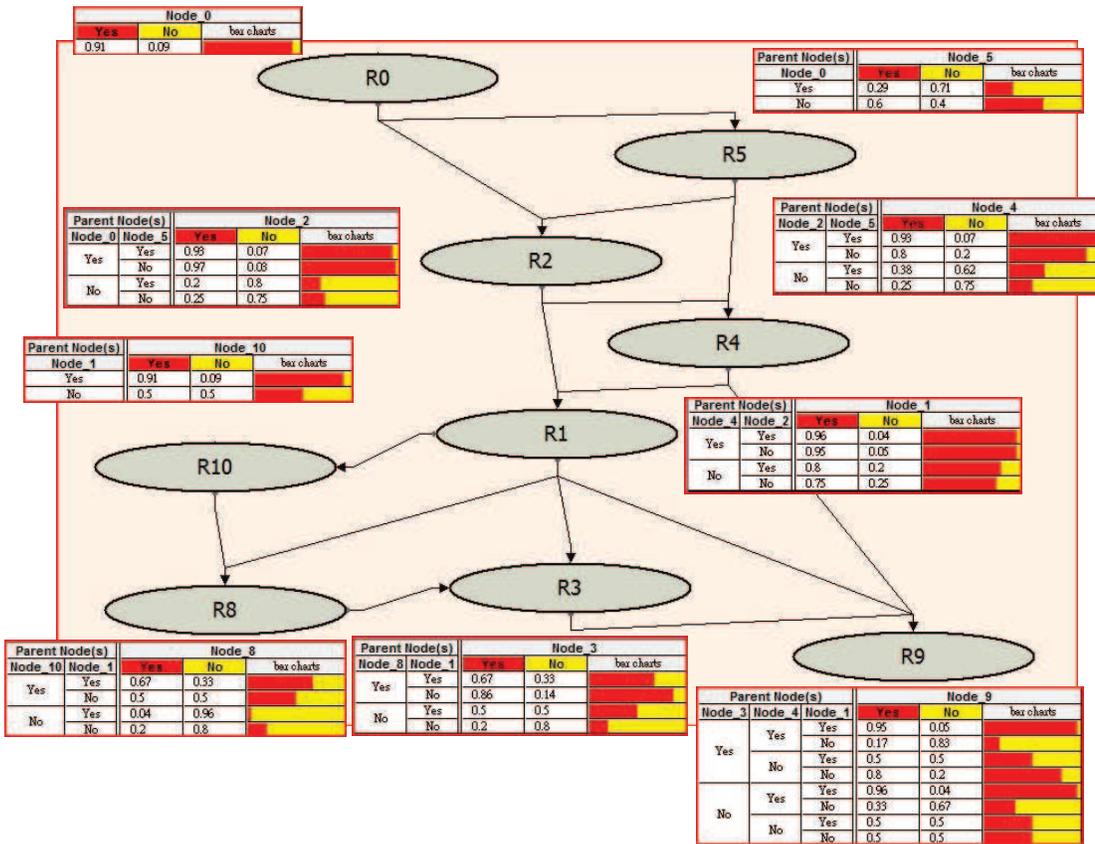


Fig. 5. Trajectory Bayesian Network Experiment

ities over query nodes  $X$ , given the evidence  $E$  encountered so far.

## V. CONCLUSION

In this paper, we proposed a novel approach based on Bayesian network to predict a moving object's future location under uncertainty. Meanwhile, we proposed several algorithms to construct a Bayesian network from the trajectory information. The approach includes space-partitioning schemes, popular region extraction, transformation of trajectory sequence and region sequence, frequent sequential pattern mining and the Bayesian network construction. The system allows the analyzers to determine the regions they would like to analyze and the system would retrieve all the frequent region patterns that include these regions. The transformation between the frequent region patterns and the Bayesian network includes two phases. The first phase is about the Bayesian network structure construction, where each popular region is regarded as a random variable in the Bayesian network. Meanwhile, the arcs between nodes of the Bayesian network are determined by the traversal paths of the frequent region patterns. In the second phase, the local probability distribution could be obtained based on empirical data. The experiment shows that the Bayesian network allows us to perform inference and get the probabilities of all possible states of an unobserved node under the current observed data.

## ACKNOWLEDGMENT

This work was supported in part by the National Science Council under the Grants NSC-97-2221-E-009-135 and NSC-97-2811-E-009-019.

## REFERENCES

- [1] J. Pei, J. Han, B. Mortazavi-Asl, and H. Pinto, "Prefixspan: Mining sequential patterns efficiently by prefix-projected pattern growth," in *ICDE 2001*, 2001, pp. 215–225.
- [2] M. J. Zaki, "Spade: An efficient algorithm for mining frequent sequences," *Machine Learning*, vol. 42, no. 1, pp. 31–60, 2001.
- [3] F. Giannotti, M. Nanni, D. Pedreschi, and F. Pinelli, "Mining sequences with temporal annotations," in *SAC '06: Proceedings of the 2006 ACM symposium on Applied computing*, 2006, pp. 593–597.
- [4] F. Giannotti, M. Nanni, F. Pinelli, and D. Pedreschi, "Trajectory pattern mining," in *KDD '07: Proceedings of the 13th ACM SIGKDD international conference on Knowledge discovery and data mining*, 2007, pp. 330–339.
- [5] H. Jeung, Q. Liu, H. T. Shen, and X. Zhou, "A hybrid prediction model for moving objects," in *The 24th International Conference on Data Engineering*, 2008, 2008, pp. 70–79.
- [6] Y. Ishikawa, Y. Tsukamoto, and H. Kitagawa, "Extracting mobility statistics from indexed spatio-temporal datasets," in *STDBM*, 2004, pp. 9–16.
- [7] H. Jeung, H. T. Shen, and X. Zhou, "Mining trajectory patterns using hidden markov models," in *DaWaK 2007*, 2007, pp. 470–480.
- [8] J. Pearl, *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann, 1988.
- [9] C. M. Bishop, *Pattern Recognition and Machine Learning*. Springer, 2007.
- [10] C. Kadie, D. Hovel, and E. Horvitz, "MSBNx: A component-centric toolkit for modeling and inference with bayesian networks," Microsoft Research Technical Report MSR-TR-2001-67, Tech. Rep., 2001.

無衍生研發成果推廣資料

98 年度專題研究計畫研究成果彙整表

計畫主持人：李嘉晃		計畫編號：98-2221-E-009-141-					
計畫名稱：非監督式中文寫作自動評閱系統之研究與設計							
成果項目		量化			單位	備註（質化說明：如數個計畫共同成果、成果列為該期刊之封面故事...等）	
		實際已達成數（被接受或已發表）	預期總達成數（含實際已達成數）	本計畫實際貢獻百分比			
國內	論文著作	期刊論文	0	0	100%	篇	
		研究報告/技術報告	0	0	100%		
		研討會論文	0	0	100%		
		專書	0	0	100%		
	專利	申請中件數	0	0	100%	件	
		已獲得件數	0	0	100%		
	技術移轉	件數	0	0	100%	件	
		權利金	0	0	100%	千元	
	參與計畫人力（本國籍）	碩士生	4	4	100%	人次	
		博士生	0	0	100%		
		博士後研究員	1	1	100%		
		專任助理	0	0	100%		
國外	論文著作	期刊論文	3	3	100%	篇	
		研究報告/技術報告	0	0	100%		
		研討會論文	2	2	100%		
		專書	0	0	100%	章/本	
	專利	申請中件數	0	0	100%	件	
		已獲得件數	0	0	100%		
	技術移轉	件數	0	0	100%	件	
		權利金	0	0	100%	千元	
	參與計畫人力（外國籍）	碩士生	0	0	100%	人次	
		博士生	0	0	100%		
		博士後研究員	0	0	100%		
		專任助理	0	0	100%		

<p>其他成果 (無法以量化表達之成果如辦理學術活動、獲得獎項、重要國際合作、研究成果國際影響力及其他協助產業技術發展之具體效益事項等，請以文字敘述填列。)</p>	<p>除了三篇期刊論文 (IEEE Intelligent Systems 一篇, Expert Systems with Applications 兩篇), 兩篇 Conference 論文 (ISICA 2008 與 ICNC'10 )之外, 目前尚有兩篇期刊論文分別於 Information Processing &amp; Management 與 IEEE Trans. on SMC -Part C 2nd revision 中。</p>
--	--

	成果項目	量化	名稱或內容性質簡述
科 教 處 計 畫 加 填 項 目	測驗工具(含質性與量性)	0	
	課程/模組	0	
	電腦及網路系統或工具	0	
	教材	0	
	舉辦之活動/競賽	0	
	研討會/工作坊	0	
	電子報、網站	0	
	計畫成果推廣之參與 (閱聽) 人數	0	



# 國科會補助專題研究計畫成果報告自評表

請就研究內容與原計畫相符程度、達成預期目標情況、研究成果之學術或應用價值（簡要敘述成果所代表之意義、價值、影響或進一步發展之可能性）、是否適合在學術期刊發表或申請專利、主要發現或其他有關價值等，作一綜合評估。

1. 請就研究內容與原計畫相符程度、達成預期目標情況作一綜合評估

達成目標

未達成目標（請說明，以 100 字為限）

實驗失敗

因故實驗中斷

其他原因

說明：

2. 研究成果在學術期刊發表或申請專利等情形：

論文： 已發表  未發表之文稿  撰寫中  無

專利： 已獲得  申請中  無

技轉： 已技轉  洽談中  無

其他：（以 100 字為限）

3. 請依學術成就、技術創新、社會影響等方面，評估研究成果之學術或應用價值（簡要敘述成果所代表之意義、價值、影響或進一步發展之可能性）（以 500 字為限）

在本論文中，我們所提出的中文寫作多面向評分系統，有別於以往的評分系統，本系統將不再需要事前訓練資料，且不再是以單面向、主觀的方式來給予評分，我們希望在評分上能達到更高的可信度，因此提出了針對多面向來進行評分的方式，根據文章的結構、詞語…等特徵，將各分數加以統整，在上述的實驗中，利用此方法所得之正確率達到 94.2%，證明了多面向整合的評分方式較為客觀，且其實驗結果之整合分數比傳統的評分系統更足以採信；此外，針對錯別字與各特徵都將給予回饋，使用者可藉由此回饋資訊得知在寫作上有哪些需要改進的部份，以提升寫作能力。

目前成果部分，有一篇論文已經被 IEEE Intelligent Systems 期刊接受，兩篇論文被 Expert Systems with Applications 期刊接受，另外在決策樹方面我們提出一個簡化多值化決策樹的方法，該論文已經被 ISICA 2008 接受，該論文也將會收錄於 LNCS 期刊；另外尚有一篇論文被 ICNC' 10 Conference 接受並且已經刊出。