

適境化行為模式探勘於行動車輛 資訊服務中之事件預測

苑守慈

政治大學資訊管理系

謝宜錚

輔仁大學資訊管理系

摘要

Telematics 乃是結合通訊及資訊，主要概念是指汽車的通訊及資訊技術，在生活應用上是指以汽車作為與外在環境資源的互動，結合無線通訊技術將資訊及多媒體等內容作單向或雙向傳輸的系統。而 Telematics 之內容與服務提供部分則扮演著服務是否獲得消費者青睞的關鍵角色。本研究嘗試結合 Telematics 與車險業者以提出一個能獲得消費者青睞的 Telematics 應用服務創新的範例。本研究藉由對車險業者其顧客交易資料，考量「人」、「地點」、「時間」此三維度，來分析、學習並預測顧客的行為模式，進而進行適境化、個人化之 Telematics 資訊提供。例如，當顧客於特定時間行經特定的區域時，Telematics 對顧客進行資訊提供，而提供的資訊服務包含三種類別：失竊、刮傷、緊急救援相關警告及內容訊息。本研究亦提出一個新的適境化行為模式探勘模式以達到適人、適地、適時之 Telematics 資訊提供。

關鍵詞：行動車輛資訊服務、時空資料庫、類神經網路、屬性導向歸納法

Contextualized Behavior Mining for Event Prediction in Telematics

Soe-Tsyr Yuan

MIS Department, National Chengchi University

Yi-Cheng Shia

Information Management Department, Fu-Jen University

Abstract

Telematics is a combination of automotive telecommunications and information processing that offers to drivers and their passengers useful wireless voice and data (e.g., location-specific security, information, and in-vehicle multimedia contents/services). This paper presents a new telematics application that is of collaboration with the auto insurance industry. Taking into account the three aspects (person, location, and time), the application analyzes, learns, and predicts a customer's contextualized behavior, timely furnishing the customer with the important contextualized information in prevention of mishap. A combination of data mining and mobile location-based services is applied in this application so as to provide auto customers with certain precautions information that is personalized and contextualized. Such precautions information is regarding steal, scrape, and emergency when customers passing through certain locations at certain time. The main contribution of this paper rests on the presentation of a novel telematics application (using a new modeling of two learning methods) that embodies the distinguished value of mishap event prevention.

Keywords: Telematics, spatial-temporal databases, neural network, attribute-oriented induction

壹、緒論

近一、兩年以來，汽車業界或相關研究機構皆對 Telematics 的前景懷抱著無比的樂觀。Telematics 乃是結合通訊及資訊，主要概念是指汽車的通訊及資訊技術，在生活應用上是指以汽車作為與外在環境資源的互動，結合無線通訊技術將資訊及多媒體等內容作單向或雙向傳輸的系統。也就是說，Telematics 系統拜無線通訊、公眾網路及全球衛星系統（GPS）的技術進步下，車輛將是一個人行動資訊及通訊的網路系統中心，個人可傳輸、接收並處理於辦公室、家庭間的資訊及事項 [2]。

因此各大車廠及周邊系統配合廠商該如何創造在 Telematics 產業內的價值乃是一個重要之課題。一般而言，主要的價值創造在於內容（content）及軟體（software）等應用及整合系統。而其中在內容與服務提供部分，又扮演著 Telematics 服務是否獲得消費者青睞的關鍵角色。

在內容與服務提供部分，本研究嘗試結合 Telematics、產險業者¹、各大車廠及周邊系統配合廠商、Geographical Content Provider（GIS）、Context Provider（GPS）、行動通訊服務業者、服務/內容提供者、內容整合者、汽車整合服務業者（TSP）進行策略聯盟，提出一個相關研究方法與以獲得消費者青睞的應用服務的一個新的範例。

車險業者之顧客群經常遇見若干困擾事件：(1) 車子失竊案件層出不窮 (2) 交通事故天天在上演 (3) 還有最令有車人士痛恨的刮傷事件。那如何將行動通訊這項載具之三大特性的輕巧、移動及便利，及定位服務技術、顧客關係管理運用在 Telematics 與車險業之結合上呢？

本研究針對車險業者其顧客交易資料，本研究將考量「人」、「車」、「時間」、「地點」、「事件」資料，來分析、學習並預測顧客的行為模式，進而進行因人、因時、因地預測三事件（失竊、刮傷、緊急救援）在某階度上的安全/危險程度且進行一次比一次更好的行動車輛資訊服務提供（如表 1）。換言之，期透過表 1 各項服務的提供，希望能盡量避免惱人的失竊、刮傷、緊急救援三事件的發生。

表 1：Telematics 與車險業之結合之資訊服務

事 件	服 務			
失竊	警告訊號	鄰近安全地段	停車場資訊	商家資訊
刮傷	警告訊號	鄰近安全地段	停車場資訊	商家資訊
緊急救援	警告訊號	地形描述	緊急救援資訊	

¹ 產險中的車險符合本研究所需特性（有顧客交易紀錄、資訊提供層面明確、資訊取得的需求是即時性的）、且與人們生活息息相關，因此本研究期望藉此應用領域發展相關研究方法與創新服務應用。

於本研究中，有若干研究假設：

- 「三事件」與「時間」存在著某種相依關係：
 - 某事件一般會發生在某特定時間點。
 - 「特定時間點」定義為尖峰時段、非尖峰時段及夜間三種。
- 「地點」一般是由區、路、段、號四個階度所組成。本研究將依據顧客所在時間、地點，預測三事件在區、路、段各階度的安全/危險程度。
- 「安全/危險程度」可分成安全、危險及高危險三種。

本研究之研究方法「適境化行為模式探勘」除分析「人」此一因素資料外，亦將事件發生的「時間」及「地點」資料納入考量。就算在同一定點上，三事件上的安全/危險程度將隨著時間的變化而有所不同。並且藉由運用與顧客互動上的位移性，來進行的資訊提供。

另外，本研究對「地理資訊」的處理方式有別於以往，過去相關研究 [11, 12] 僅能習得顧客大致的行為模式，再「以地點為索引值」過濾出符合顧客所需的資訊，並進行資訊提供。本研究能精確地習得顧客在各階度中，各時間點上的行為模式，亦即「將地點整個拿來分析」。

本論文內容主要有四部分：第一部分為本研究之相關研究，第二部分為研究方法，第三部分研究方法之製作，第四部分為研究方法評估。

貳、相關研究

一、時空資料庫 (Spatio-Temporal Databases)

D.J. Peuquet 提出時空資料的三大主軸[3, 4]時間、空間、屬性，從這三大主軸中來建立不同的時空資料模式：區位導向 (location-based)、地物導向 (feature-based)、以及時間導向 (time-based) 三種。

區位導向的資料模式是以地表物件所在位置為主，也就是這個地物在哪裡 (where)，其主軸是空間；地物導向的重點則是地物的屬性，亦即是這個地物是什麼 (what)，其主軸是屬性；而時間導向則是關切此一地物的時間性，其代表的意涵為此地物是何時發生改變的 (when)，其主軸是時間。

由此我們可以勾勒出時空資料三種資料模式彼此之間的互動關係 [1, 3, 7, 9]：

- 時間與空間固定：主要觀察的重點在於地表某物件在固定時間與固定空間狀態下的屬性值。
- 時間與屬性固定：其重點在於觀察某特定時間點上，地表空間中哪些物件具有相同屬性值。
- 空間與屬性固定：當地表物件的空間位置固定，屬性狀態也固定時，所觀察的重心就是在該物件能維持這種固定狀態多久。

- 時間固定：當時間因子固定時，所關注的焦點就是空間與屬性之間的差異，由於時間因子的固定，因此我們所得到的資訊是在某個時間點上，地表空間的屬性情況。
- 空間固定：若把空間因子固定之後，所觀察的重點就是在該空間中，其屬性值是否隨著不同時間而發生變化。
- 屬性固定：將屬性值固定之後，所觀察的重心則是具有相同屬性值得地表空間中，隨著時間狀態改變而產生變化情況。

本研究之研究方法乃考量屬性固定之互動關係。

二、屬性導向歸納法 (Attribute-Oriented Induction Approach – AOI)

屬性導向歸納法是一種以歸納為基礎的資料分析技術，主要做法是利用事先定義好的概念階層，配合一些歸納技術，如屬性移除(attribute removal)、概念樹爬升(concept-tree climbing)、門檻值控制(threshold control)等，來完成資料庫中相關資料的歸納 [5]。

概念階層是處理歸納過程中所必備的知識，一個概念階層通常有「一般-至-特別」(general-to-specific)的順序性，最一般化的概念是以"ANY"來表示，最特別的概念則對映到資料庫中某一特定的屬性。由屬性導向歸納法，我們可以歸納出不同的知識規則，例如特性規則(Characteristic Rule)、差別規則(Discrimination Rule)、數量規則(Quantitative Rule)等等。

同時屬性導向歸納法，除了可以運用在關聯式資料庫，亦可作用於進階資料庫，包括：物件導向資料庫、推論(deductive)資料庫及空間資料庫系統(spatial database systems)、時空資料庫(spatial-temporal databases)。例如，可藉由 Attribute-Oriented Induction 來探索、挖掘在空間資料庫(spatial database)中非空間資料(non-spatial data)與空間資料(spatial data)間的關係，以執行 spatial data mining 之工作 [6, 10]。

本研究之適境化行為模式探勘模式將提出一較適用於本研究之屬性導向歸納方法。

參、研究方法

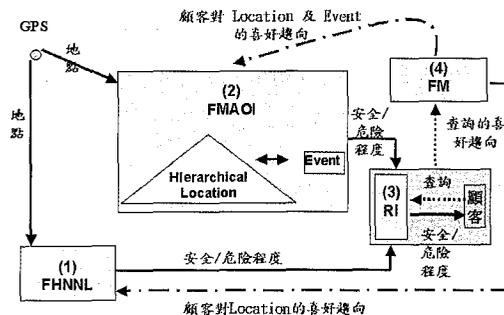


圖 1：適境化行為模式探勘之研究架構

本研究以車險此一產業為創新行動車輛資訊服務 Telematics 之研究對象，並考量「人」、「時間」、「地點」此三維度，來分析、學習並預測顧客的行為模式，進而進行因人、因時、因地且一次比一次更好的行動車輛資訊提供。

本研究方法稱之為適境化行為模式探勘，其研究架構（如圖 1）可分為四個部份：

- Feedback-Driven Hierarchical Neural Network Learning (FHNNL)：以顧客個人的歷史交易紀錄顧客個人交易紀錄來學習顧客個人的行為模式。
- Feedback-Driven Mutated Attributed Oriented Induction (FMAOI)：參考所有顧客交易紀錄來獲知一般大眾的行為趨向。
- Recommendation Integration (RI)：將 FHNNL、FMAOI 預測、推論、調整所得的結果透過一規則加以整合並進行推薦。
- Feedback Mechanism (FM)：紀錄顧客與系統的互動（對 Location 及 Event 查詢的喜好趨向），以清楚了解其喜好趨向，以供 FHNNL、FMAOI 決定將預測、推論到哪一階度²，進而提供一次比一次更好的資訊，使顧客一次比一次更滿意的資訊提供。

本研究在地理資料的處理上，本研究假設如下：

- 若某事件發生於 A1 路及 A2 路轉角處或交叉路口時，則 A1 路及 A2 路皆登錄曾發生過該事件。
- 僅考慮某事件發生於某區、或某路、或某段上，並不考慮發生於某區、或某路、或某段的左、右邊。
- 若某條路橫跨 A、B 兩區時，則該路同隸屬於 A、B 兩區。

茲將於下列章節詳細說明適境化行為模式探勘研究架構的四個部份。

一、FHNNL

FHNNL 主要以 Hierarchical Neural Networks 精確地習得顧客個人的行為模式，來預測顧客所在時間、地點上三事件（失竊、刮傷、緊急救援）在某一階度（區、路、段）可能發生的機率及其安全/危險程度。並依據大台北區市區道路的規劃表達出 Location（區、路、段）的階層性架構，提供顧客作區、路、段的上下查詢。同時亦參考 FM 中 Location（區、路、段）的紀錄作為作為 Neural Network 選擇的指標（區、路、段）。茲將說明 FHNNL 之動機與方法：

為何要使用 Hierarchical Neural Network (HNN) ？

從過去研究中，Neural Network 被驗證可以精確地從個人紀錄當中學習個人的行為模式，包含曾經發生的及隱含的行為趨向。因此本研究選擇了 Neural Network 作為個人

² 這說明了為何 FHNNL 有「Feedback-Driven」及「Learning」兩個字眼、為何 FMAOI 有「Feedback-Driven」字眼、並且呼應了先前提到的構想：「進行一次比一次更好的資訊提供」。

紀錄的學習。而其訓練資料為「人」、「車」、「肇事時間」、「肇事地點」與該顧客在該定點當時的時間下所發生的「事件」。預測結果為偷竊、刮傷、緊急救援三事件可能會發生的機率及安全/危險程度。

然而 Location 可分為區、路、段、號四個階度。若以四個 Neural Network 分別學習並預測三事件在「所有區」、「所有路」、「所有段」、「所有號」上可能會發生的機率及安全/危險程度，則會有四個獨立的 Neural Networks，其會存在下列兩個問題：(1) 若要将段、號此兩個階度表達成 category 的型態有其困難度且頗為繁雜 (2) 在提供顧客作區、路、段、號的上下查詢時，所耗的時間將比較久。

因此將 Location 上的每個節點(×區、××路、×××段³)各以一個 Neural Network (行成 Hierarchical Neural Networks, 如圖 2 所示) 來學習並預測三事件在該節點上可能發生的機率及安全/危險程度。如此 FHNNL 在提供顧客作區、路、段、號的上下查詢時，所耗的時間將比較快且有效率。

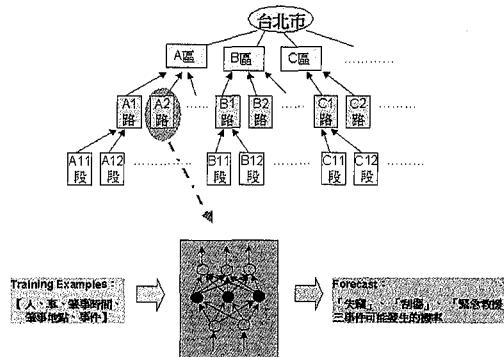


圖 2：FHNN 之 Hierarchical Neural Networks 示意圖

如何參考 FM 中 Location 的紀錄，來進行 Neural Network 的選擇？

除了透過顧客個人交易資料來訓練 HNN，還需要參考顧客與系統的互動紀錄，即 FM 中 Location 的紀錄，其主要目的是想透過 FM 中 Location 的紀錄來了解顧客個人的喜好趨向，並作為 Neural Network 選擇的指標(區、路、段)。

當系統第一次使用，Neural Network 的選擇預設為「路」。當系統第二次起使用時，Neural Network 的選擇將依據 FM 中 Location 紀錄(區、路、段)的最大值者，亦即最常被查詢者(請參考圖 3 運作解說圖)。

³ 由於一般人查詢偏好不會細微到「號」，因此本系統限定最低階度為「段」，亦即 HNN 所表達出的階層性架構包含區、路、段三階度。

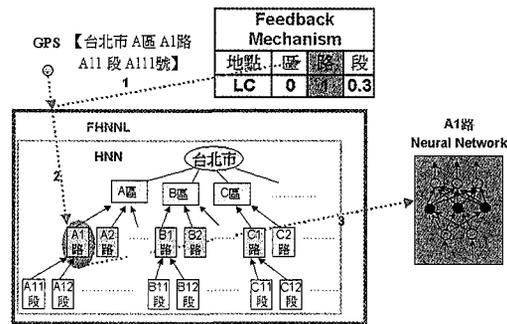


圖 3：FHNN 中參考 FM 中 Location 的紀錄之示意圖

已預測出三事件在某一階度 (EX:A 區) 可能發生的機率, 如何判斷其安全/危險程度呢?

在預測出三事件在某一階度 (比方, A 區) 可能發生的機率, FHNNL 將判定其安全/危險程度。以下以「失竊事件」為例, 而「刮傷事件」、「緊急救援事件」亦然:

$NN_steal_score = 2$, if $steal_prob > 0.7$;

$NN_steal_score = 1$, if $steal_prob > 0.3$ and $steal_prob \leq 0.7$;

$NN_steal_score = 0$, if $steal_prob \leq 0.3$;

其中, $steal_prob$: 為 FHNNL 預測所得「失竊事件」在該階度 (比方, A 區) 可能發生的機率; NN_steal_score : 2, 1, 0 分別代表高危險區、危險區、安全區。

二、FMOAI

本研究利用 Location 的階層性架構, 提供了與顧客互動的機制。換言之, 透過以 Location 不同階度的查詢來提供 Location 與事件 (Event) 間的關係及相關資訊。然而 FHNNL 只能學習單一顧客的行為模式。而與車險業者相關之行動車輛資訊提供, 所有顧客曾經發生事件的趨向 (亦即參考所有人的行為模式) 亦是重要的。因此本研究發展 MAOI (MUTATED AOI) 的方式來參考所有顧客的交易紀錄並粗略地推論事件發生的趨向。

FAOI 參考所有顧客的交易資料粗略地架構出 Hierarchical Location (區、路、段) 與 Event (失竊、刮傷、緊急救援) 的關聯圖, 來推論顧客所在時間、地點上三事件 (失竊、刮傷、緊急救援) 在某一階度 (區、路、段) 曾經發生的實際次數及其安全/危險程度。並依據大台北區市區道路的規劃表達出 Location (區、路、段) 的階層性架構, 提供顧客作區、路、段的上下查詢。同時亦參考 FM 中 Location 與 Event 的紀錄, 作為 MAOI 決定搜尋索引值的指標 (區、路、段) 及調整三事件曾經發生次數的依據。請參考圖 4 FMAOI 之示意圖。

而以 MAOI (MUTATED AOI) 方式所架構出的 Location 與 Event 對應表格其運作方式如下, 在系統開始使用前, 先以 Count 值統計三事件分別在各區、路、段上曾經發生

的實際次數，以便系統進行推論、推薦。在系統運作後，顧客群可能會有新的交易紀錄陸續產生，因此，系統將每隔一段時間再以 Count 值重新統計三事件分別在各區、路、段上曾經發生的實際次數。而 Location 與 Event 對應表格，換個角度來看，就好比失竊、刮傷、緊急救援三事件各有一相對應 Hierarchical Location (區、路、段) 的架構，且每個定點記錄著事件曾經發生的實際次數。

其中，本研究參考 Location 與 Event 對應表格來進行推論所採用的 AOI 方式是經過變形的 (將之稱為 MUTATED AOI, MAOI)。在假設已推論出失竊事件在大台北各區、路、段上曾經發生的實際次數的前提下，表 2 說明 MAOI 方式是如何分別進行安全/危險程度的判別動作。

表 2：MAOI 方式是如何在各段、路、區上分別進行安全/危險程度的判別動作。

若顧客所欲查詢的為「段」，則計算「段」此一階段，若其值符合下列任一規則，則以「2」(高危險區)、「1」(危險區)、「0」(安全區)表示之：

$$AOI_steal_score = 2, \text{ if } frequency_steal > total_steal / branch_num ;$$

$$AOI_steal_score = 1, \text{ if } frequency_steal \leq total_steal / branch_num \text{ and } frequency_steal > \alpha (total_steal / branch_num) ;$$

$$AOI_steal_score = 0, \text{ if } frequency_steal \leq \alpha (total_steal / branch_num) ;$$

其中，frequency_steal：失竊事件在「某段」上曾經發生的實際次數；
total_steal：大台北發生失竊事件的總數；
branch_num：大台北一共有多少「段」；
AOI_steal_score=(1)2：高危險區、(2)1：危險區、(3)0：安全區
 α ：值將以實驗的方式找出其最佳值(請參考本節最後 FMAOI Algorithm 的局部說明)。

若顧客所欲查詢的為「路」，則計算「路」此一階段，若其值符合下列任一規則，則以「2」(高危險區)、「1」(危險區)、「0」(安全區)表示之：

$$AOI_steal_score = 2, \text{ if } frequency_steal > total_steal / branch_num ;$$

$$AOI_steal_score = 1, \text{ if } frequency_steal \leq total_steal / branch_num \text{ and } frequency_steal > \alpha (total_steal / branch_num) ;$$

$$AOI_steal_score = 0, \text{ if } frequency_steal \leq \alpha (total_steal / branch_num) ;$$

其中，frequency_steal：失竊事件在「某路」上曾經發生的實際次數；
total_steal：大台北發生失竊事件的總數；
branch_num：大台北一共有多少「路」；
AOI_steal_score=(1)2：高危險區、(2)1：危險區、(3)0：安全區
 α ：值將以實驗的方式找出其最佳值(請參考本節最後 FMAOI Algorithm 的局部說明)。

若顧客所欲查詢的為「區」；則計算「區」此一階度，若其值符合下列任一規則，則以「2」(高危險區)、「1」(危險區)、「0」(安全區)表示之：

$$AOI_steal_score = 2, \text{ if } frequency_steal > total_steal/branch_num;$$

$$AOI_steal_score = 1, \text{ if } frequency_steal \leq total_steal/branch_num \text{ and } frequency_steal > \alpha \cdot (total_steal/branch_num);$$

$$AOI_steal_score = 0, \text{ if } frequency_steal \leq \alpha \cdot (total_steal/branch_num);$$

其中，frequency_steal：失竊事件在「某區」上曾經發生的實際次數；
 total_steal：大台北發生失竊事件的總數；
 branch_num：大台北一共有多少「區」；
 $AOI_steal_score = (1)2$ ：高危險區、(2)1：危險區、(3)0：安全區；
 α ：值將以實驗的方式找出其最佳值(請參考本節最後 FMAOI Algorithm 的局部說

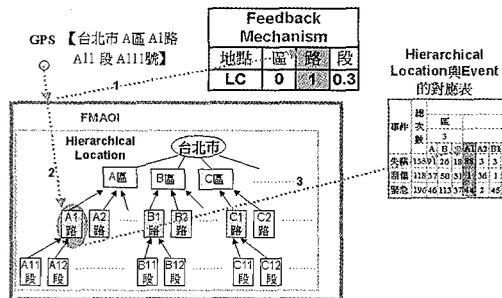


圖 4：FMAOI 中參考 FM 中 Location 的紀錄之示意圖

茲將說明 MAOI 之動機與方法：

MAOI 與 AOI 有何差別呢?

由於 MAOI 不管到任一階度都必須重新進行數值運算 (如表 3 所示)，而 AOI 則是依據前一階度所得結果再行歸納 (如表 4 所示)。因此兩者最主要的差異為，前者較為概略性，而後者較為準確。

然為何採用 MAOI 呢？其有何好處呢？因為本研究的研究對象為保險業中的車險，MAOI 若能愈精準推測出每一路段可能發生的事件 (如表 5 所示)，將可減少事件的發生。

表 3：MAOI 推論方式例子：不管到任一階層都必須重新進行數值運算再行歸納

事件次數	地點																					
	區			路			段															
3	7			14																		
失竊	A1	A2	A3	B1	B2	B3	C1	A11	A12	A21	B11	B12	B31	B32	B33	C11	C12	C21	C22	C23		
135/3	124	88	3	3	0	23	5	13	0	88	3	2	1	0	3	19	2	4	1	13	0	0
MAOI	高危險	高危險	安全	安全	安全	安全	安全	高危險	安全	高危險	危險	安全	高危險	安全	安全	安全						

區			路			段		
高危險	危險	安全	高危險	危險	安全	高危險	危險	安全
>	≤135/3	≤	>	≤135/7	≤	>	≤135/14	≤
135/3	且	0.3(135/3)	135/7	且	0.3(135/7)	135/14	且	0.3(135/14)
>	0.3(135/3)		>	0.3(135/7)		>	0.3(135/14)	
>45	≤45	≤14	>19	≤19	≤6	>10	≤10	≤3
	且>14			且>6			且>3	

表 4：AOI 推論方式例子：

上一階層是依據下一階度進行數值運算所得結果直接進行歸納

事件	總次數	地點																						
		區							路							段								
		A	B	C	A1	A2	B1	B2	B3	C1	C2	A11	A12	A21	B11	B12	B21	B31	B32	B33	C11	C12	C21	C22
失竊	135	91	24	18	88	3	3	0	23	5	15	0	88	3	2	1	0	3	19	1	4	15	0	0
AOI		安	安	安	安	安	安	安	安	安	安	安	高	安	安	安	安	安	高	安	危	安	高	安

區	路			段					
	高危險	危險	安全	高危險	危險	安全	高危險	危險	安全
門檻值	76%	51%-75%	50%	76%	51%-75%	50%	> 135/14	≤ 135/14 且 > 0.3(135/14)	≤ 0.3(135/14)
門檻值	≤ 10	≤ 3					且 > 3		

表 5：MAOI 及 AOI 推論結果之差異

事件	總次數	地點																						
		區							路							段								
		A	B	C	A1	A2	B1	B2	B3	C1	C2	A11	A12	A21	B11	B12	B21	B31	B32	B33	C11	C12	C21	C22
失竊	135	91	24	18	88	3	3	0	23	5	15	0	88	3	2	1	0	3	19	1	4	15	0	0
AOI		安	安	安	安	安	安	安	安	安	安	安	高	安	安	安	安	安	高	安	危	安	高	安
MAOI		高	危	危	安	安	安	安	安	安	安	高	安	安	安	安	安	安	高	安	危	安	高	安

如何參考 FM 中 Location 的紀錄，來決定其搜尋索引值？

MAOI 除了透過顧客交易資料來訓練，還需要參考顧客與系統的互動紀錄(即為 FM 中 Location 及 Event 的紀錄)，用以了解顧客個人的喜好趨向，其中 Location 的紀錄將影響 MAOI 搜尋索引值(區、路、段)的決定，而 Event 的紀錄將影響三事件實際發生次數的調整。將原本以所有顧客交易紀錄架構而成的推論基礎轉化成與顧客個人行為模式相符的推論基礎，則推論出的結果將會愈來愈傾向並符合顧客所想知道的。

MAOI 首先參考所有顧客交易紀錄並建立出 Hierarchical Location 與 Event 的關聯圖，以提供顧客作區、路、段、號的上下查詢。其中，在系統開始使用前，先以 Count 值統計三事件分別在各區、路、段上曾經發生的實際次數，以便系統進行推論、推薦。在系統運作後，顧客群可能會有新的交易紀錄陸續產生，因此，系統將每隔一段時間再以 Count 值重新統計三事件分別在各區、路、段上曾經發生的實際次數。

MAOI 參考 FM 的紀錄來決定其搜尋索引值(區、路、段)。系統第一次使用，MAOI 的搜尋索引值預設為「路」。當系統第二次起使用時，MAOI 的搜尋索引值的決定將依據 FM 中 Location 紀錄(區、路、段)的最大值者，亦即最常被查詢者(請參考圖 4 運作解說圖)。

如何參考 FM 中 Event 的紀錄來調整三事件在某一階度(EX：A 區)實際發生的次數？

FMAOI 進行數值的調整為了使系統推薦出來的資訊一次比一次更令顧客滿意，也就是說系統推薦出的資訊與顧客查詢的喜好趨向一致，所以必須參考 FM 中所紀錄的數值來進行數值調整。而調整的原則為「該顧客經常查詢的事件經調整後其重要性將提昇，相反地，對於不常查詢的事件經調整後其重要性將減低」。

因此在參考 FM 的紀錄後，MAOI 將調整三事件在某一階度(比方，A 區)實際發

生的比例。此種情境發生在系統第二次起使用。以下說明此調整方法：

- 當 FM 中某事件的加權值 EC 為最大值者且 EO 大於或等於 2 時,其調整方式為 $EF * (EC/EMAX) * EO * 0.5$ 。
- 當 FM 中某事件的加權值 EC 為最大值者且 EO 等於 1 時,則不進行調整。
- 其他情況,其調整方式為, $EF * (EC/EMAX)$ 。

其中, EF: 推論所得某事件在某一階度(比方, A 區)曾經發生過的個別總次數;
 EC: FM 中某事件的加權值 ($\alpha EN + (1-\alpha) EO$); EO: 顧客曾經查詢某事件的總次數,
 紀錄於 FM 中; EMax: FM 中失竊、刮傷、緊急救援加權值的最大值。

FMAOI 為何分別以 $EF * (EC/EMAX) * EO * 0.5$ 及 $EF * [EC/EMax]$ 調整公式來調整三事件在某一階度(比方, A 區)實際發生的比例?茲將說明其原委:由於 FM 中的 Event 記錄著顧客對三事件查詢的喜好趨向,透過 $[EC/EMax]$, 可以看出顧客對三事件喜好的相對強度。然若直接以 $[EC/EMax]$ 對三事件曾經發生的實際次數 (EF) 進行調整, 僅對「顧客未查詢的事件」產生作用, 而對「查詢者有查詢的事件」則無任何調整作用。

例如, 顧客 A 經常查詢失竊事件, 此時 FM 中失竊事件的加權值 EC 將為三事件中的最大值, 因此 $[EC/EMax]$ 的數值為 1, 若以失竊事件曾經發生的實際次數 (EF) 乘以 $[EC/EMax]$, 將依然維持原次數, 無任何調整作用。也就是說假設今天在該路段上, 失竊事件就顧客 A 而言為安全區, MAOI 並不會因為顧客 A 的經常查詢而學習到其喜好趨向, 轉而告知顧客 A 失竊事件在該路段上為危險/高危險區。加上由於 FM 中的 EO 將隨著顧客查詢的次數增加而遞增, 因此針對此種情況的調整方式本研究採 $EF * (EC/EMAX) * EO * 0.5$, 其中乘上 0.5 (如表 6) 的用意則是為了讓調整的幅度不會太大。而對於「查詢者無查詢的事件」之情況, 由於某事件未被查詢, 因此相較於被查詢者其 EC 非為最大值者, 因此 $[EC/EMax]$ 的數值小於 1, 此時以其曾經發生的實際次數 (EF) 乘以 $[EC/EMax]$, 次數將減少。加上若原本為高危險區, 此時經調整後將變成危險/安全區, 也正符合了我門期望的「其學習到顧客的喜好趨向」。

表 6：FMAOI 參考 FM 調整事件在某一階度發生比例之例子

Feedback Mechanism		場		路		點									
		3	7	14											
事件	失竊	刮傷	緊急救援	R	C	A	A	A	B	B	B	C	C	C	C
EO	1	3	3	2	1	1	1	1	1	1	1	1	1	1	1
EN	1	1.67	3	2	1	1	1	1	1	1	1	1	1	1	1
EC	1	2.6	4.4	2	1.5	1.5	1.5	1.5	1.5	1.5	1.5	1.5	1.5	1.5	1.5

Hierarchical Location與Event的對應表

1.調整公式為: $EF * [EC/EMax] * EO * 0.5$:
 緊急救援: ② * ④ * ⑥ * 0.5

2.調整公式為: $EF * [EC/EMax]$:
 失竊: 0 * (1/4.4)
 刮傷: 4 * (2.6/4.4)

若已推論、調整出三事件在某一階度 (EX:A 區) 可能發生的比例, 如何判定其安全/危險程度呢?

當系統第二次起使用時, 亦即 FM 已有紀錄存在, 則 FMAOI 先參考 Location 與 Event 的對應表推論出「失竊事件」在「某段」上曾經發生的實際次數, 接著將參考 FM 中 Event 的紀錄對此數值進行調整, 並進行安全/危險程度的判別。判別方法乃是以 α (total_steal/branch_num) 該指標來區隔安全區、危險區 (如表 7 所示)。表 8 則為一相關計算例子。

表 7: FMAOI 方式是如何在各段、路、區上分別進行安全/危險程度的判別動作。

【失竊事件】

MAOI_steal_score = 2, if updated_frequency_steal > total_steal/branch_num ;
 MAOI_steal_score = 1, if updated_frequency_steal ≤ total_steal/branch_num
 and updated_frequency_steal > α (total_steal/branch_num) ;
 MAOI_steal_score = 0, if updated_frequency_steal ≤ α (total_steal/branch_num) ;

其中, updated_frequency_steal : 失竊事件在「某段」上調整後的次數(EF*|EC|EMax) ;
 total_steal : 大台北發生失竊事件的總數 ;
 branch_num : 大台北一共有多少「段」 ;
 AOI_steal_score = (a)2 : 高危險區、(b)1 : 危險區、(c)0 : 安全區 ;
 α : 通常以實驗的方式找出其最佳值。

表 8: FMAOI 安全/危險程度的判別方式例子

【失竊事件】

MAOI_steal_score = 2 - if updated_frequency_steal > total_steal/branch_num -
 total_steal/branch_num ;
 MAOI_steal_score = 1, if updated_frequency_steal ≤ total_steal/branch_num
 and updated_frequency_steal > α (total_steal/branch_num) ;
 MAOI_steal_score = 0, if updated_frequency_steal ≤ α (total_steal/branch_num) ;

其中, updated_frequency_steal : 失竊事件在「某段」上調整後的次數(EF*|EC|EMax) ;
 total_steal : 大台北發生失竊事件的總數 ;
 branch_num : 大台北一共有多少「段」 ;
 AOI_steal_score = (a)2 : 高危險區、(b)1 : 危險區、(c)0 : 安全區 ;
 α : 通常以實驗的方式找出其最佳值。

1.調整公式為: $EF * |EC| * EMax * EO * 0.5$

緊急數據: 2 * (4.4/4)

2.調整公式為: $EF * |EC|$

失竊: 0.4 (2.6/4.4)

調整: 4.4 (2.6/4.4)

路	區	段	安全	現在	危險	安全
≤	>	≤	11974	≤	11974	≤
31157	1574	11	11	11	0.3 (15/14)	11
≤6	≤6	≤6	≤6	≤6	≤6	≤6

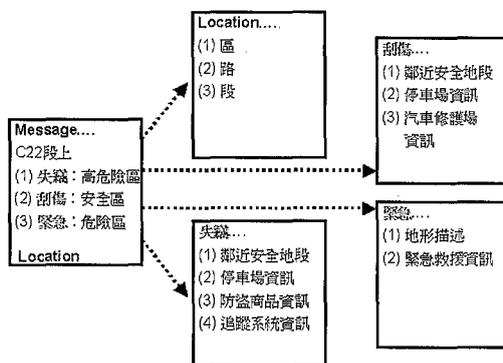
三、RI

RI 主要對 FHNNL 及 FMAOI 兩子系統預測、推論所得結果, 透過一規則加以整合, 進而推薦給顧客。其規則如下:

取 FHNNL、FMAOI 兩個子系統對在某一階度 (EX:A 區) 的同一事件推論的最大值。表 9 將以「失竊事件」為例 (而刮傷事件、緊急救援事件亦然)。之後將數值轉換成字串, 並將將警告訊息、相關資訊內容顯示於螢幕上。

表 9：RI 整合規則與呈現方式

<p>【失竊事件】</p> <p>$steal_score = \text{Max}(\text{FHNN_steal_score}, \text{FMAOI_steal_score})$;</p> <p>其中, $steal_score$: 對'失竊事件'的最後結果。</p> <p>(1) FHNNL預測結果為【失竊:2, 刮傷:0, 緊急救援:1】;</p> <p>(2) FMAOI推論結果為【失竊:0, 刮傷:0, 緊急救援:0】;</p> <p>(3) RI整合得【失竊:2, 刮傷:0, 緊急救援:1】;</p>	<p>$steal_message = \text{"高危險區"} , \text{if } steal_score = 2$;</p> <p>$steal_message = \text{"危險區"} , \text{if } steal_score = 1$;</p> <p>$steal_message = \text{"安全區"} , \text{if } steal_score = 0$.</p> <p>RI將推薦出【失竊:高危險區, 刮傷:安全區, 緊急救援:危險區】的警告訊息</p>
---	--



四、FM

在推薦的過程中將與顧客產生互動，透過 FM 將顧客的喜好趨向學習下來，並在下次推薦時，作為 FHNNL 及 FMAOI 兩子系統調整、參考的依據。那如何將系統與顧客的互動紀錄下來？

本研究將系統與顧客的互動紀錄分為兩個部分：Location Feedback 及 Event Feedback。由於人的喜好是會改變的，因此要 FM 的紀錄方式須作新、舊 Feedback 的區分，才能正確學習顧客的行為模式。那要以什麼樣的機制區分出新、舊 Feedback，及兩者所佔的比重呢？表 10 說明此機制區分出新、舊 Location Feedback（而 Event Feedback 亦然）。

表 10：FM 機制以區分出新、舊 Location Feedback

【Location】
數學函式為： $\alpha LN+(1-\alpha)LO$ ；(Event： $\alpha EN+(1-\alpha)EO$)
其中，LN：(1)本次推薦互動過程中所產生的Feedback值，且預設值為“0”；(Event：EN預設值為“1”)
(2)一旦顧客在本次推薦互動過程中，查詢了某階度，則該階度的LN值則更改為上一次三階度LO的平均值：
LO：(1)過去累積的Feedback值，且預設值為“0”；(Event：EO預設值為“1”)
(2)一旦顧客在本次推薦互動過程中，查詢了某階度，且該階度前一次也被查詢過，則該階度的LO值則加1：
α ：值將以實驗的方式找出其最佳值。

於此機制中，一旦顧客在本次推薦互動過程中，查詢了某事件，該事件的 EN 值將更改為上一次三事件 EO 的平均值。其原因如下：由於紀錄公式為 $\alpha EN+(1-\alpha)EO$ ，EN 用以紀錄顧客最新的喜好趨向，其為主要因素，相對地，EO 用以紀錄顧客過去的喜好趨向，其為參考因素；倘若 EN 的數值變化只有 0 和 1，而 EO 的數值變化則持續遞增，此時就算 $(1-\alpha)$ 再小，則 EO 將從參考因素轉為主要因素；此時唯有讓 EN 的數值變化也呈持續遞增的情況，因此一旦顧客在本次推薦互動過程中，查詢了某事件，則該事件的 EN 值將更改為上一次三事件 EO 的平均值。

五、資料分析

本研究以保險業中的車險此一產業為行動車輛資訊服務之應用之研究對象，因此首先了解該產業是如何記錄顧客的交易紀錄為首要條件。於是以親訪及電訪的方式，多次地向車險相關產業人員詢問、請教後，以了解其表單的紀錄方式（即顧客的交易紀錄，請參考附錄之說明）。

在與車險相關產業人員訪談後，發現可藉由「人」、「車子」、「肇事」3 維度來進行分析、預測顧客的需求：

- 「肇事」中的“險種”、“詳述肇事經過”說明了顧客發生哪一事件（失竊、刮傷、或緊急救援）。
- 「肇事」中的“肇事時間”，清楚了解事件是發生在上午、中午、下午、晚上或子夜。
- 「肇事」中的“肇事地點”，清楚了解事件是發生在某區某路某段某號。因此【人、車、事件、肇事時間、肇事地點】為分析、學習顧客行為模式的必要欄位。

然產險業者一般僅針對「人」、「車」、「肇事」中的“險種”進行電腦化動作，而「肇事」中的“險種”、“詳述肇事經過”、“肇事時間”、“肇事地點”等僅以書面的方式來作檔案管理。因此本研究假設已預先將相關書面資料管理的部分進行電腦化管理⁴，以作為本研究架構分析、學習並預測顧客行為模式的資料來源，進而進行資訊提供。

⁴ 車險相關產業資料全面電腦化正逐步進行中。

肆、研究方法實作系統

本研究主要以 Java2 Enterprise Edition 的技術來實作系統。

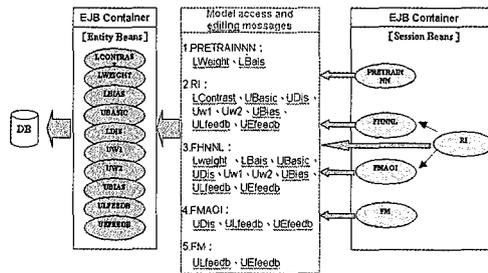


圖 5：EJB Container 中元件設計之示意圖

系統 EJB Container 實作(如圖 5 所示)可以分為五個 Session Beans【PRETRAIN-NN、RI、FHNNL、FMAOI、FM】，其中 PRETRAIN-NN 主要負責 Pre-training 的工作，FHNNL、FMAOI 主要負責顧客個人在某定點上三事件安全/危險程度的預測及推論，RI 則將預測推論的結果整合後推薦予顧客，而 FM 則運用顧客的查詢來學習其喜好趨向。至於商業運作上所要使用的資料則將透過十個 Entity Beans【L CONTRAST、LWEIGHT、LBIAS、UBASIC、UDIS、UW1、UW2、UBIAS、ULFEEDB、UEFEEDB】來與後端資料庫中的 Tables：【L_CONTRAST、L_WEIGHT、L_BIAS、U_BASIC、U_DIS、U_W1、U_W2、U_BIAS、U_LFEEDB、U_EFEEDB】進行溝通，然 Entity Beans 與 Tables 間存在著一對一的關係。

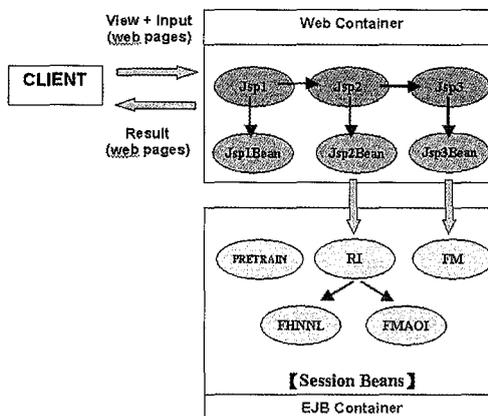


圖 6：Web Container 中元件設計之示意圖

系統 Web Container 中元件設計 (如圖 6 所示) 主要以 JSP 及 JavaBeans 的設計方式來進行元件配置。其中 JSP 的部分主要負責與顧客互動的部分, 而 JavaBeans 則負責和 EJB Container 中的元件進行溝通。系統主要分三個 JSP 及三個 JavaBeans。Jsp1 及 Jsp1Bean 負責地圖的呈現。Jsp2 負責接收顧客所在定點、顧客代碼, 並將 EJB Container 中元件處理的結果呈現給顧客。Jsp2Bean 則將 Jsp2 接收到的訊息傳輸給 EJB Container 中的元件【RI、FHNNL、FMAOI】來進行預測、推論及推薦的動作。Jsp3 負責接收顧客對 Location 及 Event 作進一步的查詢。Jsp2Bean 則將 Jsp3 接收到的訊息傳輸給 EJB Container 中的元件【FM】來進行學習的動作。

圖 7 約略顯示從顧客的角度使用本系統。首先顧客可在前端地圖介面上點選其所在位置, 並輸入其顧客代碼, 此時前端的 JavaBeans 會負責呼叫預測該定點上三事件安全/危險程度的 Session Beans, 最後透過瀏覽器將預測結果告知顧客。

若顧客想針對地區 (區、路、段) 或事件 (失竊、刮傷、緊急救援) 作進一步查詢時, 亦可藉由查詢畫面點選其所欲查詢的項目, 這時前端的 JavaBeans 亦會負責呼叫學習顧客喜好趨向的 Session Beans 進行學習動作, 並將學習後的結果提供作為下次預測的參考依據。

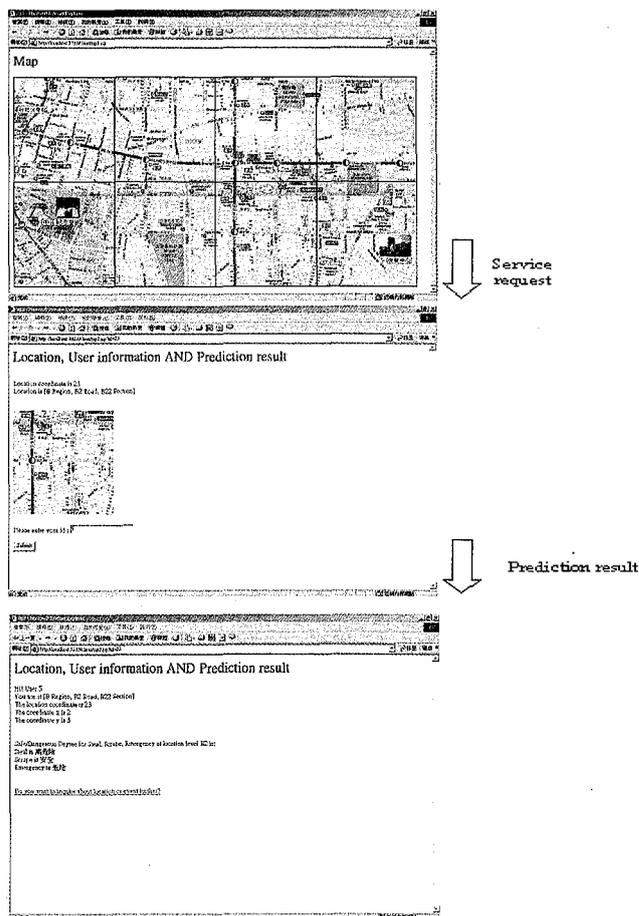


圖 7：相關系統顯示 (從顧客之使用角度)

伍、研究方法評估

本研究的實驗分別以方法論及 Telematics information 兩個層面來進行。其中方法論的部分，將分別以質及量的方式針對 FHNNL、FMAOI 及 FM 進行評估；而 Telematics information 的部分，同樣以質及量的方式針對四種情境來進行系統整體的評估。然何謂「質」的實驗方式呢？何謂「量」的實驗方式呢？所謂「質」的實驗方式即先假設一個情境，再以敘述的方式來解說在該情境下系統的推薦情況。而「量」的實驗方式亦先假設一個情境，再以系統執行後所產生的統計數據來解釋在該情境下系統的推薦成效。

在此僅就 Telematics information 的四種情境層面提出評估結果。其大致可分為兩大類：一、顧客本身無任何肇事紀錄，二、顧客本身曾有肇事紀錄。就第一大類而言，由於顧客本身無任何肇事紀錄，因此實驗方式僅需考慮、評估 FMAOI 及 FM 的互動及成效；而就第二大類而言，由於顧客本身曾有肇事紀錄，則須納入 FHNNL，述說 FHNNL、FMAOI 及 FM 的互動及成效。

表 11：Telematics information 的四種情境層面評估方式

實驗層面二：Telematics information			
情境		實驗方式	實驗指標
情境一	顧客本身無任何肇事紀錄	該顧客對系統的推薦：有查詢的動作產生 量： 僅考慮、評估 FMAOI 及 FM 的互動及成效	(1)調整趨向、 (2)學習速度及調整情況
情境二	顧客本身有肇事紀錄	該顧客對系統的推薦：無查詢的動作產生 量： 僅考慮、評估 FMAOI 及 FM 的互動及成效	(1)調整趨向、 (2)學習速度及調整情況
情境三	顧客本身有肇事紀錄	該顧客對系統的推薦：有查詢的動作產生 質： 述說 FHNNL、FMAOI 及 FM 的互動及成效	
情境四	顧客本身有肇事紀錄	該顧客對系統的推薦：無查詢的動作產生 質： 述說 FHNNL、FMAOI 及 FM 的互動及成效	

情境一、二之實驗指標為調整趨向、學習速度及調整情況。系統透過 FM 機制習得顧客對 Location 及 Event 查詢的喜好趨向，而 FMAOI 則將參考其學習結果進行調整的動作。因此對於 FMAOI 調整及學習的成效，本研究將以三個維度來做評估：調整趨向、學習速度及調整情況。而各維度的解說將分述如下：

- 調整趨向：

即 FMAOI 對各階度、各定點上三事件實際肇事總次數的調整趨向是否與顧客對 Event 查詢的喜好趨向是否正向的關係。例如，假設顧客 1 在 A11 段上經常查詢失竊事件，經 FMAOI 的調整學習後，失竊事件肇事總次數將成正向成長的情況；相對地刮傷及緊急救援事件則成下降、遞減的趨勢。

- 學習速度及調整情況：

即 FMAOI 經過多少次的調整後方能學習到顧客對 Event 查詢的喜好趨向，並從中可看出其學習所產生的變化。承上述的例子，假設在 A11 段上失竊事件的肇事情況屬於安全，由於顧客 1 經常查詢失竊事件，在經 FMAOI 數次的調整、學習後，失竊事件在 A11 段上的肇事情況已由安全轉為危險或高危險，此時則稱 FMAOI 以學習到顧客對 Event 查詢的喜好趨向，同時也從中觀察到出其學習所產生的變化。

情境一：顧客本身無任何肇事紀錄，同時該顧客對系統的推薦有查詢的動作產生

1. 實驗方法：

由於顧客本身無任何肇事紀錄，因此實驗方式僅需考慮、評估 FMAOI 及 FM 的互動及成效。其中，由於 FM 用以學習顧客對 Location 及 Event 查詢的喜好趨向，提供 FMAOI 進行推論的參考依據，而本實驗將以「顧客對 Event 查詢的喜好變化」為實驗情境，然則「顧客對 Location 查詢的喜好變化」該情境將可比照依此類推。

預設顧客對 Event 查詢的喜好變化為：刮傷（1 次）→緊急救援（30 次）→刮傷（4 次）→失竊（27 次）⁵。在上述的情境下，以實驗的方式評估 FMAOI 在參考 FM 學習的結果，需經過多少次的調整，方能使其推薦與顧客對 Event 查詢的喜好趨向成一緻的情況。

2. 實驗結果：

表 12 可觀查出 FMAOI 的學習速度。當顧客對 Event 查詢的喜好變化為刮傷→緊急救援，會在其對緊急救援查詢第 1 次後，FMAOI 即將上次推論的安全轉為危險，故稱其學習速度為 1 次。同樣地，接下來顧客對 Event 查詢的喜好變化為緊急救援→刮傷，亦會在其對刮傷查詢第 2 次後，FMAOI 即將上次推論的安全轉為高危險，故稱其學習速度為 2 次。後續，顧客對 Event 查詢的喜好變化為刮傷→失竊，亦會在其對失竊查詢第 2 次後，FMAOI 即將上次推論的安全轉為危險，故稱其學習速度為 2 次。換言之，FM 在學習顧客對 Event 查詢的喜好變化上，其學習速度非常快。

同時從圖 8 中可以觀察到下列兩種變化：(1) 調整趨向：FM 其學習顧客對失竊事件喜好的曲線【失 (FMAOI+FM)】與顧客對失竊事件真正喜好的曲線成一緻的變化【失 (C)】；(2) 調整情況：FMAOI 在未參考 FM 學習的結果進行調整前，在該階度、該定點上的「失竊」事件屬於安全，從曲線【失 (FMAOI)】可觀察到，然由於該顧客於第 35 次起開始了『失竊』事件的查詢動作，FMAOI 在參考 FM 學習的結果並進行調整後，曲線【失 (FMAOI+FM)】頓時使「失竊」事件轉為高危險。其中 X 軸為顧客對 Event 進行查詢的次數。然而對曲線【失 (C)】而言 Y 軸則為顧客是否查詢「失竊」事件，如果有查詢則為 1，反之為 0；對曲線【區 (FMAOI)】而 Y 軸則為 FMAOI 在未參考 FM 的學習結果前所推論出該定點上失竊事件的安全/危險程度，安全為 0，危險為 1，高危險為 2；對曲線【區 (FMAOI+FM)】而 Y 軸則為 FMAOI 在參考 FM 的學習結果並經微調後所推論出該定點上失竊事件的安全/危險程度，安全為 0，危險為 1，高危險為 2。同樣地，圖 9、圖 10 亦然。

從情境一實驗所匯整出來的相關圖、表都再次地說明 FMAOI 在參考 FM 的學習結果後，其在決定推論的對象、調整各事件統計數據進而推論各事件的安全/危險程度，速度非常快且與顧客的喜好變化成一緻的情況。

⁵ 這些互動次數為隨機產生的。

情境二：顧客本身無任何肇事紀錄，同時該顧客對系統的推薦無 feedback 的動作產生

1. 實驗方法：

由於顧客本身無任何肇事紀錄，因此實驗方式僅需考慮、評估 FMAOI 及 FM 的互動及成效。其中，由於 FM 用以學習顧客對 Location 及 Event 查詢的喜好趨向，提供 FMAOI 進行推論的參考依據，而本實驗將以「顧客對 Event 查詢的喜好變化」為實驗情境，然則「顧客對 Location 查詢的喜好變化」該情境將可比照依此類推。

預設某定點上三事件的安全/危險程度為【失竊：安全、刮傷：危險、緊急救援：高危險】，而此時該顧客系統的推薦無 feedback 的動作產生，所以 FM 失竊、刮傷、緊急救援的加權值 EC 仍維持預設值。在上述的情境下，以實驗的方式評估 FMAOI 在參考 FM 學習的結果，需經過多少次的調整，方能使其推薦與顧客對 Event 查詢的喜好趨向成一致的情況。

表 12：FMAOI 在學習顧客其對 Event 查詢喜好趨向的學習速度

No	失竊	刮傷	緊急救援	失竊	刮傷	緊急救援	顧客的查詢
	統計數據	統計數據	統計數據	安全/危險程度	安全/危險程度	安全/危險程度	
0	8	40	9	安	高	危	
1	8	40	9	安	高	安	刮傷
2	0.38095	40	0.42857	安	高	危	緊急救援
3	0.29268	30.7317	9	安	高	高	緊急救援
4	0.23077	24.2308	13.5	安	高	高	緊急救援
5	0.19048	20	18	安	高	高	緊急救援
6	0.16216	17.0268	22.5	安	危	高	緊急救援
7	0.14118	14.8237	27	安	危	高	緊急救援
8	0.125	13.125	31.5	安	危	高	緊急救援
9	0.11215	11.7756	36	安	安	高	緊急救援
10	0.1017	10.6781	40.5	安	安	高	緊急救援
11	0.09302	9.76744	45	安	安	高	緊急救援
12	0.08571	8.99994	49.5	安	安	高	緊急救援
13	0.07947	8.34443	54	安	安	高	緊急救援
14	0.07407	7.77778	58.5	安	安	高	緊急救援
15	0.06936	7.28319	63	安	危	高	緊急救援
16	0.06522	6.84786	67.5	安	安	高	緊急救援
17	0.06154	6.46154	72	安	安	高	緊急救援
18	0.05825	6.11648	76.5	安	安	高	緊急救援
19	0.0553	5.80548	81	安	安	高	緊急救援
20	0.05263	5.52632	85.5	安	安	高	緊急救援
21	0.05021	5.27194	90	安	安	高	緊急救援
22	0.048	5.04002	94.5	安	安	高	緊急救援
23	0.04598	4.82759	99	安	安	高	緊急救援
24	0.04412	4.63234	103.5	安	安	高	緊急救援
25	0.0424	4.45231	108	安	安	高	緊急救援
26	0.04082	4.28571	112.5	安	安	高	緊急救援
27	0.03934	4.13101	117	安	安	高	緊急救援
28	0.03798	3.98747	121.5	安	危	高	緊急救援
29	0.0367	3.85321	126	安	安	高	緊急救援
30	0.0355	3.7277	130.5	安	安	高	緊急救援
31	0.03438	3.61042	135	安	安	高	緊急救援
32	0.03333	3.5	139.5	安	安	高	刮傷
33	0.03333	3.4585	9	安	高	危	刮傷

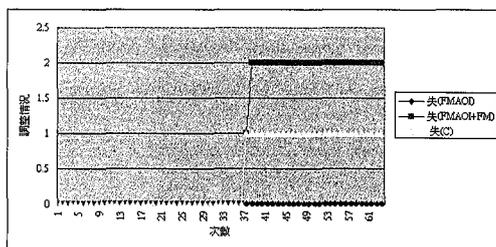


圖 8：就失竊事件，FMAOI 在參考 FM 學習的結果後的調整趨向及情況

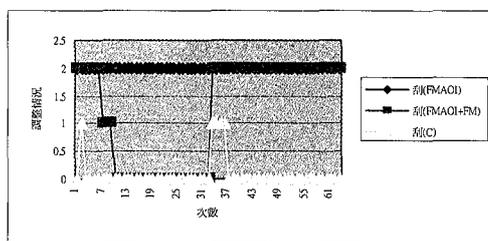


圖 9：就刮傷事件，FMAOI 在參考 FM 學習的結果後的調整趨向及情況

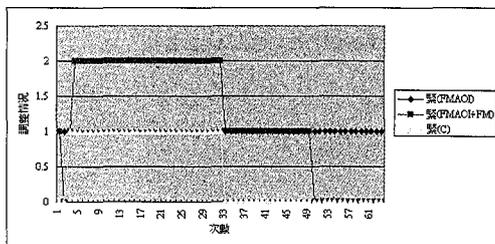


圖 10：就緊急救援事件，FMAOI 在參考 FM 學習的結果後的調整趨向及情況

2. 實驗結果：

從圖 11 中可以觀察到下列兩種變化：(1) 調整趨向：FM 其學習顧客對失竊事件喜好的曲線【失 (FMAOI+FM)】竟與顧客對失竊事件真正喜好的曲線成一一致的變化【失 (C)】；(2)調整情況：由於顧客系統的推薦無 feedback 的動作產生，因此 FM 所學習到該顧客的喜好趨向為持平、無變化。所以，FMAOI 在參考 FM 學習的結果進行調整前【失 (FMAOI)】及調整後【失 (FMAOI+FM)】並無變化。同樣地，圖 12、圖 13 亦然。

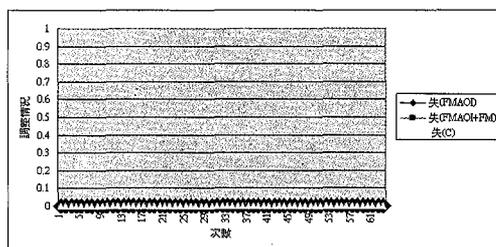


圖 11：就失竊事件，FMAOI 在參考 FM 學習的結果後的調整趨向及情況

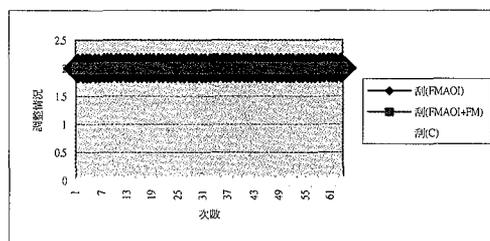


圖 12：就刮傷事件，FMAOI 在參考 FM 學習的結果後的調整趨向及情況

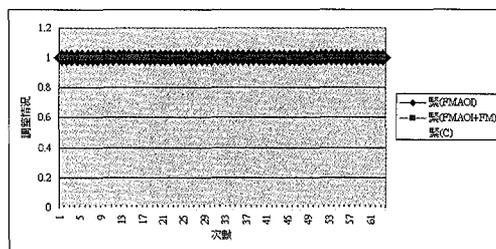


圖 13：就緊急救援事件，FMAOI 在參考 FM 學習的結果後的調整趨向及情況

從情境二實驗所匯整出來的相關圖、表都再次地說明，在顧客對系統的推薦無查詢的動作產生時，FM 中 Location 及 Event 的加權值則維持預設值，因此 FMAOI 在參考 FM 的學習結果後，其在決定推論的對象、調整各事件統計數據進而推論各事件的安全/危險程度，則依然維持預設值。因此，FMAOI 及 FM 的變化曲線與顧客的喜好變化成一緻的情況，皆屬水平狀。

情境三：顧客本身曾有肇事紀錄，同時該顧客對系統的推薦有 feedback 的動作產生

由於顧客本身曾有肇事紀錄，因此將述說 FHNNL、FMAOI 及 FM 的互動及成效。其中，由於 FM 用以學習顧客對 Location 及 Event 查詢的喜好趨向，提供 FMAOI 進行推論的參考依據，因此本實驗將分下列兩重情境來述說 FHNNL、FMAOI 及 FM 的互動及成效：「顧客對 Event 查詢的喜好變化」及「顧客對 Location 查詢的喜好變化」。

然而在述情境下 FHNNL、FMAOI 及 FM 的互動及成效前，須先預設顧客所在地點的特性、及顧客對系統推薦所反映出其對 Location 及 Event 查詢喜好趨向，如此一來才能說明 FM 如何學習顧客喜好趨向、又如何影響 FHNNL、FMAOI 的預測及推論：

1. 顧客所在地點的特性：

本實驗預定 B 區為顧客所在定點，該定點上三事件的肇事統計數據為【失竊：40、刮傷：63、緊急救援：37】，而 FMAOI 的推論依據為：(1)失竊事件：高危險： >36 、危險： ≤ 36 AND >25.2 、安全： ≤ 25.2 ，(2)刮傷事件：高危險： >61.5 、危險： ≤ 61.5 AND >43.05 、安全： ≤ 43.05 ，(3)緊急救援事件：高危險： >36.58 、危險： ≤ 36.58 AND >25.61 、安全： ≤ 25.61 ，因此初次推論的結果為【失竊：高危險、刮傷：高危險、緊急救援：高危險】。

2. 顧客對系統推薦所反映出其對 Location 及 Event 查詢喜好趨向：

假設顧客 feedback⁶的情境為：

- (1) 顧客對 Location 查詢的喜好變化為：段 (9 次) → 路 (10 次) → 區 (10 次) → 段 (144 次)。
- (2) 顧客對 Event 查詢的喜好變化為：刮傷 (1 次) → 緊急救援 (30 次) → 刮傷 (4 次) → 失竊 (27 次)。

表 13、14 其中「FM 如何學習顧客喜好趨向」。而 FM 如何影響 FHNNL、FMAOI 的預測及推論。其將分兩個維度來探討：

1. FHNNL、FMAOI 如何選擇預測、推論的對象：

FHNNL、FMAOI 將參考 FM 中 Location 加權值的最大值作為預測、推論的對象。從表 13 中可發現 No1~10，段的加權值為最大值，因此 No1~10，FHNNL、FMAOI 將選擇段為預測、推論的對象；No11~20，路的加權值為最大值，因此 No11~20，FHNNL、FMAOI 將選擇路為預測、推論的對象；No21~29，區的加權值為最大值，因此 No21~29，FHNNL、FMAOI 將選擇區為預測、推論的對象；最後 No30~173，段的加權值為最大值，因此 No30~173，FHNNL、FMAOI 將選擇段為預測、推論的對象。

⁶ 互動次數為隨機產生的。

表 13：FM 在學習顧客對 Location 查詢之喜好變化時，
所進行 Location 加權值 LC 調整的變化狀況

No	區加			路加			段加			顧客的查詢
	權值 LC	區 LN	區 LO	權值 LC	路 LN	路 LO	權值 LC	段 LN	段 LO	
0	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0.05	0	1	段
2	0	0	0	0	0	0	0.417	0.333	2	段
3	0	0	0	0	0	0	0.7833	0.6667	3	段
4	0	0	0	0	0	0	1.15	1	4	段
5	0	0	0	0	0	0	1.8167	1.3333	5	段
6	0	0	0	0	0	0	1.8833	1.6667	6	段
7	0	0	0	0	0	0	2.25	2	7	段
8	0	0	0	0	0	0	2.6167	2.3333	8	段
9	0	0	0	0	0	0	2.9833	2.6667	9	段
10	0	0	0	2.9	3	1	2.9833	2.6667	9	路
11	0	0	0	3.2667	3.3333	2	2.9833	2.6667	9	路
12	0	0	0	3.6333	3.6667	3	2.9833	2.6667	9	路
13	0	0	0	4	4	4	2.9833	2.6667	9	路
14	0	0	0	4.3667	4.3333	5	2.9833	2.6667	9	路
15	0	0	0	4.7333	4.6667	6	2.9833	2.6667	9	路
16	0	0	0	5.1	5	7	2.9833	2.6667	9	路
17	0	0	0	5.4667	5.3333	8	2.9833	2.6667	9	路
18	0	0	0	5.8333	5.6667	9	2.9833	2.6667	9	路
19	0	0	0	6.2	6	10	2.9833	2.6667	9	路
20	6.0667	6.3333	1	6.2	6	10	2.9833	2.6667	9	區
21	6.433	6.6667	2	6.2	6	10	2.9833	2.6667	9	區
22	6.8	7	3	6.2	6	10	2.9833	2.6667	9	區
23	7.1667	7.3333	4	6.2	6	10	2.9833	2.6667	9	區
24	7.5333	7.6667	5	6.2	6	10	2.9833	2.6667	9	區
25	7.9	8	6	6.2	6	10	2.9833	2.6667	9	區
26	8.2667	8.3333	7	6.2	6	10	2.9833	2.6667	9	區
27	8.6333	8.6667	8	6.2	6	10	2.9833	2.6667	9	區
28	9	9	9	6.2	6	10	2.9833	2.6667	9	區
29	9.3667	9.3333	10	6.2	6	10	2.9833	2.6667	9	區
30	9.7333	9.3333	10	6.2	6	10	10.05	10	10	段
31	9.3667	9.3333	10	6.2	6	10	10.417	10.333	11	段
32	9.3667	9.3333	10	6.2	6	10	10.783	10.667	12	段
33	9.3667	9.3333	10	6.2	6	10	11.15	11	13	段

2. FMAOI 如何進行肇事統計數據的調整

FMAOI 在參考 FM 的學習結果後，將對在該定點上三事件各別曾經肇事的統計數據作調整。接下來將以顧客所在定點 B 區，及 FM 學習顧客對 Event 查詢的喜好變化之 No0 及 No30 來說明其如何影響 FMAOI 的調整及推論。其它則以此類推。

No0 下，由於三事件加權值 LC 皆為 0.05，且三事件 LO 皆為 1，所以 FMAOI 不對三事件統計數據進行調整，而其推論結果亦維持【失竊：高危險、刮傷：高危險、緊急救援：高危險】。

No30 下，由於緊急救援事件加權值 LC 皆為最大值 11.63，且其 LO 為 30，因此其調整公式為 $EF*(EC/EMAX)*EO*0.5$ ， $37*(11.63/11.63)*30*0.5=555$ 。加上 FMAOI 對緊急救援事件的推論依據為：高危險： >36.58 、危險： ≤ 36.58 AND >25.61 、安全： ≤ 25.61 ，因此推論的結果【緊急救援：高危險】。而失竊事件的調整公式為 $EF*(EC/EMAX)$ ， $40*(0.05/11.63)=0.172$ 。加上 FMAOI 對失竊事件的推論依據為：高危險： >36 、危險： ≤ 36 AND >25.2 、安全： ≤ 25.2 ，因此推論的結果【失竊：安全】。最後刮傷事件的調整公式為 $EF*(EC/EMAX)$ ， $63*(1.05/11.63)=5.688$ 。加上 FMAOI 對刮傷事件的推論依據為：高危險： >61.5 、危險： ≤ 61.5 AND >43.05 、安

全： ≤ 43.05 ，因此推論的結果【刮傷：安全】。因此最後的推論結果變為【失竊：安全、刮傷：安全、緊急救援：高危險】

從情境三的述說中說明了若該顧客曾有歷史查詢動作產生時，FHNNL、FMAOI 決定預測階度，FMAOI 的微調都將參考其歷史查詢紀錄。FM、FMAOI 系統在參考 FM 的學習結果後，的確能預測、推論、進而推薦出符合顧客喜好趨向的資訊。

情境四：顧客本身曾有肇事紀錄，同時該顧客對系統的推薦無 feedback 的動作產生

於此情境中，顧客對 Location、Event 無查詢的動作，因此 FM 中「區」、「路」、「段」的加權值 LC 維持不變，皆為 0；FM 中「失竊」、「刮傷」、「緊急救援」的加權值 EC 維持不變，皆為 0.05，且 EN、EO 也皆為 0、1。

亦即若該顧客無任何歷史查詢動作產生時，FHNNL、FMAOI 決定的預測階度將依據預設值「路」；FMAOI 的推論結果仍為一開始系統預設參考的「各區路段上，所有人曾有三事件肇事紀錄的各別統計數據」(即一般大眾的行為模式)。而如同之前情境一樣，FHNNL、FMAOI 的確能預測、推論、進而推薦出符合顧客喜好趨向的資訊。

表 14：FM 在學習顧客對 Event 查詢之喜好變化時，所進行 Event 加權值 EC 調整的變化狀況

No	失竊 加權值 EC	失竊 EN	失竊 EO	刮傷 加權值 EC	刮傷 EN	刮傷 EO	緊急救援 加權值 EC	緊急救援 EN	緊急救援 EO	顧客的 查詢
0	0.05	0	1	0.05	0	1	0.05	0	1	
1	0.05	0	1	1.05	1	2	0.05	0	1	刮傷
2	0.05	0	1	1.05	1	2	1.367	1.333	2	緊急救援
3	0.05	0	1	1.05	1	2	1.733	1.667	3	緊急救援
4	0.05	0	1	1.05	1	2	2.1	2	4	緊急救援
5	0.05	0	1	1.05	1	2	2.467	2.333	5	緊急救援
6	0.05	0	1	1.05	1	2	2.833	2.667	6	緊急救援
7	0.05	0	1	0.05	0	1	3.2	3	7	緊急救援
8	0.05	0	1	1.05	1	2	3.567	3.333	8	緊急救援
9	0.05	0	1	1.05	1	2	3.933	3.667	9	緊急救援
10	0.05	0	1	1.05	1	2	4.3	4	10	緊急救援
11	0.05	0	1	1.05	1	2	4.667	4.333	11	緊急救援
12	0.05	0	1	1.05	1	2	5.033	4.667	12	緊急救援
13	0.05	0	1	1.05	1	2	5.4	5	13	緊急救援
14	0.05	0	1	0.05	0	1	5.767	5.333	14	緊急救援
15	0.05	0	1	1.05	1	2	6.133	5.667	15	緊急救援
16	0.05	0	1	1.05	1	2	6.5	6	16	緊急救援
17	0.05	0	1	1.05	1	2	6.876	6.333	17	緊急救援
18	0.05	0	1	1.05	1	2	7.233	6.667	18	緊急救援
19	0.05	0	1	1.05	1	2	7.6	7	19	緊急救援
20	0.05	0	1	1.05	1	2	7.967	7.333	20	緊急救援
21	0.05	0	1	0.05	0	1	8.333	7.667	21	緊急救援
22	0.05	0	1	1.05	1	2	8.7	8	22	緊急救援
23	0.05	0	1	1.05	1	2	9.067	8.333	23	緊急救援
24	0.05	0	1	1.05	1	2	9.433	8.667	24	緊急救援
25	0.05	0	1	1.05	1	2	9.8	9	25	緊急救援
26	0.05	0	1	1.05	1	2	10.17	9.333	26	緊急救援
27	0.05	0	1	1.05	1	2	10.53	9.667	27	緊急救援
28	0.05	0	1	0.05	0	1	10.9	10	28	緊急救援
29	0.05	0	1	1.05	1	2	11.27	10.333	29	緊急救援
30	0.05	0	1	1.05	1	2	11.63	10.667	30	緊急救援
31	0.05	0	1	1.05	1	2	12	11	31	緊急救援
32	0.05	0	1	10.92	11.33	3	12	11	31	刮傷
33	0.05	0	1	11.28	11.67	4	12	11	31	刮傷

陸、結論

本論文目的乃將行動通訊這項載具的三大特性、定位服務技術及顧客關係管理運用在 Telematics 與車險業之結合上，然在應用面上其所想要達到的情境為一、透過參考所有顧客肇事紀錄及分析顧客個人肇事紀錄，來預測並推論顧客個人在某定點上三事件的安全危險程度，進而進行因人、因時、因地之不同的資訊提供，並可進行一次比一次更好的資訊提供。

在「推薦顧客個人在某定點上三事件的安全危險程度」上，主要結合了兩方面的預測、推論結果，也就是系統認為顧客「應該知道的部分」及其「想知道的部分」。所謂「應該知道的部分」，即顧客隱含而不自知的行為模式。因此本研究藉由 FHNNL 該子系統透過分析顧客個人在各定點上的歷史肇事紀錄來學習、預測顧客個人在各定點上的行為模式（三事件的安全危險程度）。而「想知道的部分」，即顧客顯性的（偏好）行為模式。因此本研究藉由 FMAOI 該子系統透過參考所有顧客在各定點上歷史肇事紀錄總數來推論、反映一般大眾在各定點上的行為模式（三事件的安全危險程度）。後續再參考 FM 系統所習得的顧客個人偏好來進行微調的動作，使得預測與顧客個人的偏好越來越一致。最後再透過 RI 子系統將兩邊預測、推論的結果加以整合後，推薦告知顧客個人其在該定點上三事件的安全危險程度。

而為確保其進行資訊提供的過程當中能讓顧客一次比一次更滿意，透過 FM 子系統學習顧客對 Location 及 Event 查詢的喜好趨向。而其學習結果將提供 FHNNL、FMAOI 決定預測階度（區、路、段）、FMAOI 調整某階度上三事件肇是紀錄次數的參考依據，進而使得整個系統在預測、推論上，其最終的結果不僅符合顧客個人的喜好趨向，同時也告知其隱含而不自知的行為模式。此即本系統達到「令顧客一次比一次更滿意之資訊提供」的機制。

然而，本研究目前僅做到決策的部分（亦即系統將預測、推論結果整合後，推薦並告知顧客其在特定定點上三事件之安全危險／程度），後端商家資訊的提供（比方：停車場、防盜系統公司、保養場、及其他緊急救援相關單位）則須進一步地結合商家資訊管理系統以提供便民的相關服務資訊。

另外未來可整合車險業與其他可能相關資料來源（如警政單位相關資料）以提高三事件之安全危險／程度之事件預測之精確度。換言之，FMAOI 可參考車險業所有顧客交易紀錄與警政單位相關資料以建立初始 Hierarchical Location 與 Event 之關聯圖。然而本研究方法與應用相信已為 Telematics 之創新服務應用提出一個好的可能方向。

而本研究方法之應用範圍並不限用於車險業，其未來亦可應用於任何和食衣住行相關、且該公司或企業有很多分公司或分店的產業，比如：旅遊業、金融業等。

例如於金融業，由於同一家銀行在不同區域或定點上都將開設分公司，若該銀行能結合商家將顧客在不同定點上的消費紀錄（刷卡紀錄）記錄下來並從中分析學習該顧客在不同定點上的消費模式，當顧客來到隸屬於該銀行某分公司的服務範圍內，系統將會針對不同的顧客推薦不同的金融產品組合，甚而藉由瞭解其消費模式自動推薦該區域

上適合顧客的商家資訊，不僅方便顧客，一旦顧客進行了消費的動作時亦增加商家收入及銀行資金流動等。

另外於旅遊業，其應用的範圍及層面就更廣了。因為旅遊業其包函了食、衣、住、行等民生問題，若能透過相關歷史資料的分析，了解顧客在不同定點上不同的行為模式(比方：旅客甲來到台北都會區其偏好享受大都會的感覺，舉凡住大飯店，逛百貨公司等；然若今天顧客甲來到了台南純樸地區，其則偏好享受鄉村的恬適，逛逛夜市，市集或田野活動等)，進而與每個區域的商家做結合自動推薦適合該顧客有關食、衣、住、行的相關資訊。這將可解決旅客若想到某旅遊景點前須事先進行相關資訊的蒐集，或就算已做了資訊的蒐集，來到該景點後才發現受騙上當了等。

換言之，本研究之貢獻在於提出一研究方法與系統雛型，讓企業了解其顧客在不同時間不同定點上的行為模式，並動態地學習顧客喜好的變化。此時企業將可獨自、或與同行企業、非同業的企業進行策略聯盟，將產品加以包裝且明確地針對目標族群進行資訊提供的動作，進而達到目標行銷的功效。

參考文獻

1. C.F. Herot, Spatial Management of Data, ACM Trans. on Database Systems, Vol. 5(3), P. 493-514, 1980.
2. Chatschik Bisdikian, Isaac Boamah, Paul Castro, Archan Misra, Jim Rubas, Nicolas Villoutreix, Danny Yeh, Vladimir Rasin, Henry Huang, Craig Simonds, Intelligent Pervasive Middleware for Context-Based and Localized Telematics Services, ACM Mobile Commerce Workshop, Atlanta, USA, 2002.
3. D.J. Peuquet, It's About Time: A Conceptual Framework for the Representation of Temporal Dynamics in GIS, Annals of the Association of American Geographers, Vol. 84, P. 441-461, 1994.
4. D.J. Peuquet and Niu Duan, An Event-Based Spatiotemporal Data Model (ESTDM) for Temporal Analysis of Geographical Data, International Journal of Geographical Information systems, Vol. 19(1), P. 7-24, 1995.
5. Jiawei Han, Yandong Cai and Nick Cercone, Knowledge Discovery in Databases: An Attribute-Oriented Approach, Proceedings of the 18th VLDB Conference Vancouver, British Columbia, Canada, 1992.
6. Jiawei Han and Yongjian Fu, Exploration of the Power of Attribute-Oriented Induction in Data Mining, in U.M. Fayyad, G. Piatetsky-Shapiro, P. Smyth, and R. Uthurusamy (eds.), Advances in Knowledge Discovery and Data Mining, AAAI/MIT Press, P. 399-421, 1996.
7. May Yuan, Temporal GIS and Spatial-Temporal Modeling, Third International Conference/Workshop on Integrating GIS and Environmental Modeling, Santa Fe, New

- Mexico, 1996.
8. Sun microsystems, Java 2 Platform Enterprise Edition Specification, v1.4, P. 1-22, <http://java.sun.com/j2ee>, 2002.
 9. Tamas Abraham, Knowledge Discovery in Spatio-Temporal Databases, Ph.D.dissertation, University of South Australia, March, 1999.
 10. Wei Lu, Jiawei Han and Beng Chin Ooi, Discovery of General Knowledge in Large Spatial Databases, Proceedings of Far East Workshop on Geographic Information Systems, 1998.
 11. Soe-Tsyr Yuan and Eva Tsao, A Recommendation Mechanism for Contextualized Mobile Advertising, Expert Systems with Applications, Vol. 24(4), P. 399-414, 2003.
 12. Soe-Tsyr Yuan and Kai-Hsiang Peng, Location Based and Customized Voice Information Service for Mobile Community, Information Systems Frontiers, Vol. 6(4), P. 297-311, 2004.

附錄

欄位分成『Others』、『人』、『車子』、『車子狀況』四維度來進行分析。以下以表格說明著對顧客交易紀錄的紀錄方式：

Others：

欄位名稱	資料型態	備註	輸入模式
被保險人	Key in		
被保險人身分證字號	Key in		
地址	Key in		
電話	Key in		
任意保險單號	Key in		
保險期間	Key in		
任意牌號	Key in		
強制保險單	Key in		
保險期間	Key in		
強制牌號	Key in		

人：

欄位名稱	資料型態	備註	輸入模式
駕駛人	文字		Key in
地址	文字		Key in
電話	文字		Key in
駕照號碼	文字		Key in
領照日期	interval scale	年/月/日	Key in
出生日期	interval scale	年/月/日	Key in
性別	nominal scale	男/女	V
婚姻	nominal scale	已婚/未婚	V
國內/國外	nominal scale	國內/國外	V
職業	nominal scale	公教/軍警/其他	V

車子：

欄位名稱	資料型態	備註	輸入模式
製造年份	interval scale	年/月/日	Key in
原始發照日期	interval scale	年/月/日	Key in
廠牌車型	文字	Key in 代碼	
車輛種類	文字	Key in 代碼	
牌照號碼	文字		Key in
使用性質	nominal scale	一般使用/業務使用	V
安全裝置	nominal scale	安全氣囊/防盜裝置 V /ABS 系統	
車庫	nominal scale	封閉式/開放式/無	V

車子狀況：

欄位名稱	資料型態	備註	輸入模式
里程數	文字	無法看出車子健康狀況需考慮(1)保養狀況<無此紀錄>(2)出廠日(3)出寧紀錄	Key in
前次紀錄	文字	月/日/金額(元) PS： 1.保險方式以年度為單位，不同年度不同車 子。 2.紀錄最近一次 次數/金額(元) EX： 3次/次理賠金額加 總	Key in
車體險紀錄	文字	次數/金額(元) EX： 3次/次理賠金額加 總	Key in
零件紀錄	文字	次數/金額(元)	Key in
溢額紀錄	文字	次數/金額(元)	Key in