

貝氏統計於選擇式聯合分析法之個人與市場 區隔參數之推論

A Bayesian Approach to the Inference of Individual and Segment Level Parameters in Choice-Based Conjoint Analysis

劉秀雯¹ Hsiu-Wen Liu 任立中² Lichung Jen 林育理³ Yu-Li Lin
東吳大學企業管理學系 台灣大學國際企業學系 南台科技大學企業管理系

¹Department of Business Administration, Soochow University, ²Department of International Business, National Taiwan University, and ³Department of Business Administration, Southern Taiwan University of Science and Technology

(Received October 8, 2008; Final Version November 5, 2010)

摘要：傳統的選擇式聯合分析法主要針對整體市場的偏好參數做推論，無法準確的針對個人層次的參數做推論。層級貝氏的方法可有效推論個人層次參數，因其模式結合整體與個人偏好的資訊，並以整體資訊作為先驗分配以輔助個人層次參數的推論。然而，我們認為若進一步以區隔的資訊作為先驗分配，應可再提升參數的準確率。基於此觀點，本研究提出設定消費者異質性偏好服從具有潛藏區隔特性的混合常態分配模型，改進過去層級貝氏方法對消費者異質性服從常態分配假設的限制。同時，並提出此模型的市場區隔方法。因此，本研究模型主要優點為可從一次的分析中，產生個人層次偏好係數、市場區隔層次偏好係數，以及市場區隔大小的資訊。最後本研究以旅遊產品為例，說明此模型在選擇式聯合分析法的應用。

關鍵詞：市場區隔、層級貝氏統計、選擇式聯合分析法

本文之通訊作者為劉秀雯，e-mail: hsiuwen@scu.edu.tw。

作者感謝國科會計畫經費贊助 (NSC97-2410-H-218 -001)，並衷心感謝兩位匿名審查委員之細心斧正及寶貴意見。

Abstract : Doing choice-based conjoint analysis, it is a typical approach to estimate part-worths at the aggregate level. However, hierarchical Bayes approach could overcome the limit. The Bayesian approach integrates the aggregate level part-worths as prior information to adjust the individual level part-worths and thus individual level part-worths could be inferred more precisely. Theoretically, the precision of individual level part-worths could be improved if the segment level part-worths are used as prior information. In view of the above reason, a hierarchical Bayes choice model with mixture of normals prior is proposed to improve the prior for the inference of individual part-worths. The proposed model overcomes the limits of traditional Bayesian approaches because the traditional approach could not provide both segment and individual levels part-worths in a conjoint analysis. In this paper, the authors illustrate how multivariate mixture of normals model could improve the understanding of those latent segments hidden in the data. Specifically, the model provides a solution for the understanding of individual preference and identifies consumer segments in an analysis. With an application to a travel service conjoint study, we show how this modeling approach could help us to uncover individual and segment levels parameters in a choice-based conjoint analysis.

Keywords: Market Segmentation, Hierarchical Bays Inference, Choice-based Conjoint Analysis

1. 緒論

如何針對消費者需求的異質性做市場區隔，以發展相對應的行銷策略，一直是行銷領域非常重視的主題，尤其是應用於新產品開發的聯合分析法。聯合分析法可用來分析產品的屬性特質如何影響消費者購買決策問題，因此對於廠商在新產品或服務提供的屬性開發相關決策，能提供顧客導向的策略方案建議。聯合分析法的發展也隨著電腦與統計技術的進步，在近十多年來有了長足的發展。尤其是選擇式聯合分析法 (choice-based conjoint analysis) 已逐漸被認定為聯合分析法的最佳選擇 (Desarbo *et al.*, 1995)。因為相較於傳統的聯合分析法，選擇式聯合分析法讓受訪者從幾個選擇方案中選擇一個他最喜歡的方案，而不是要求消費者將所有的可能方案做評分或排序，因此較能模擬消費者真實的購買情境。同時，聯合分析法在參數的推論方面亦有許多進展，其中以可推論市場區隔參數的潛藏區隔模式 (latent class model)，以及可推論個人化參數的層級貝氏模式 (hierarchical Bayes model) 為兩大主流。雖然潛藏區隔模式具有發現市場區隔的優點，卻無法產生穩定的個人化參數推論；而層級貝氏模式具有穩定的個人化參數

推論，卻無法產生市場區隔化的參數。如何整合上述兩種方法，使模式能同時具有「潛藏區隔模式」能掌握市場區隔結構的優點，以及「層級貝氏模式」能有效推論個人化參數結構的優點，卻能同時避免上述兩種模式的缺點，為本研究的主要動機。

過去的層級貝氏模式在個人化參數的推論上一般都假設消費者異質性 (consumer heterogeneity) 為多維常態分配 (multivariate normal distribution)，然而常態分配的假設卻有一些限制：(1) 在聯合分析法中，欲估計的參數整體分配無法在事前由研究資料得知，因此更一般化的分配而不是特定的分配較佳。(2) 常態分配的特性使模式不易發現不對稱分配或多峰分配的現象。因此，若能以更一般化的分配假設將可改進層級貝氏模式對消費者異質性服從常態分配假設的限制。雖然 Allenby *et al.* (1998) 曾提出以貝氏混合常態分配的模式 (mixture of normal distribution) 來配適消費者的偏好分配，改進上述以常態分配來配適消費者偏好的缺點。但其目的是以更彈性的假設來推論參數的整體分配而不是用於探討偏好之市場區隔，其主要的原因是此模型在馬可夫鏈蒙地卡羅 (Markov chain Monte Carlo; MCMC) 方法的後驗分配上可能存在編碼移轉的問題，例如在 r 次的吉普斯抽樣 (Gibbs Sampling) 可能將第 1, 2, 3 區隔的人分別編碼為 1, 2, 3，但是在 $r+1$ 次可能會變成 1, 3, 2。因此，要彙整所有後驗分配的市場區隔資訊實際上不可得。因此，針對混合常態分配的編碼移轉的問題，本研究欲研究出一套最佳化的方法以彙整市場區隔資訊。

基於上述原因，作者提出設定消費者異質性偏好服從具有區隔特性的混合常態分配的選擇式聯合分析法，改進過去層級貝氏模式對消費者異質性服從整體市場常態分配假設的限制。值得一提的是，層級貝氏的推論方式結合整體市場與個人偏好的資訊，以整體資訊作為先驗分配輔助個人化參數的推論。因此，若能將整體的資訊改進為以市場區隔的資訊作為先驗分配，理論上可進一步提升參數推論的準確率。

本研究所提出的分析層級貝氏混合多維常態模式的市場區隔方法，探討其在聯合分析法中市場區隔的領域之實用性，主要的研究目的可歸納為三點：

- (1) 結合潛藏區隔模式與層級貝氏的優點，提供了一套兼具「發掘消費者偏好結構之市場區隔」與「瞭解消費者個人化的偏好結構」特性的模式。
- (2) 改進過去層級貝氏模式假設消費者異質性為常態分配的限制，以更一般化的混合常態分配來配適未知的消費者異質性偏好的整體分配。
- (3) 針對混合常態分配的編碼移轉的問題，本研究提出一套最佳化的方法，用以彙整市場區隔資訊。

首先，作者將聯合分析中與市場區隔相關的文獻做一回顧。其次說明本研究的統計模式，接著透過一個選擇式聯合分析法的實證研究驗證本模式的成效，最後為研究結果的討論與未來研究建議的說明。

2. 文獻探討

聯合分析法可用以瞭解消費者對產品屬性的效用，是行銷領域瞭解市場偏好的重要方法，自從 Green and Rao (1971) 提出後，許多學者不斷提出新的方法，主要的目的有二：(1) 改進參數估計的方法，提升模型的正確預測能力 (Allenby and Ginter, 1995; Ogawa, 1987 等)。(2) 提升市場區隔的決策品質 (Desarbo *et al.*, 1995; Green, 1977; Moriarty and Venkatesan, 1978; Ogawa, 1987 等)。然而此兩目的並不衝突，研究者經常以滿足上述條件為目標 (Currim, 1981; Ogawa, 1987)。因此，作者首先將針對聯合分析法中，與參數估計相關的市場區隔方法做一回顧與比較，其次針對出本研究所提出的方法在聯合分析方法的理論定位做一說明。

2.1 聯合分析之市場區隔方法回顧

市場區隔方法的分類：市場區隔依「事前」或「事後」區隔以及「描述性」或「預測性」之特性可分為四種方法：(1) 事前描述性區隔；(2) 事前預測性區隔；(3) 事後描述性區隔；(4) 事後預測性區隔 (Wedel and Kamakura, 2000)。Wedel and Kamakura (2000) 認為事後預測性的市場區隔對行銷人員是最具效力的方法。此乃因事前區隔方法的缺點是管理者很難在事前決定對其產品市場而言有意義的市場區隔準則。事後區隔則根據分析的結果做討論，可反應在同一個區隔的消費者對某些看法或行為具有相同傾向。而描述性區隔方法的缺點是區隔的結果只能描述市場狀態，無法用來預測行為意圖。預測性的區隔方法則考慮自變數和依變數的關係，因此區隔的結果比較能用來預測消費者實際的購買偏好與行為。聯合分析法在市場區隔的發展扮演非常關鍵性的角色，因為聯合分析法的特性可協助廠商瞭解與進行事後預測性的市場區隔。Green (1977) 即提出聯合分析法可協助廠商進行更好的市場區隔決策，而此種基於產品屬性偏好的區隔方法又被稱為利益區隔。

組成區隔法與兩階段法：Green (1977) 以及 Green and DeSarbo (1979) 提出組成區隔法 (componential segmentation)，代表聯合分析法的新延伸，其特性是結合產品分析與顧客特質的正交排列，考慮產品的屬性組合與消費者特性的組合對產品評價的交互作用以辨認市場區隔，亦即以產品利益和顧客特質分析市場區隔。其中，消費者的特性大多是根據其個人背景變項作為市場作區隔的基礎。因此，此方法能分辨區隔的有效性大量依賴於區隔變數的資訊，然而個人背景變項在區隔市場的能力上成效卻有限。另一些學者則提出兩階段法改進事前區隔的缺點 (Currim, 1981; Hauser and Urban, 1977; Moriarty and Venkatesan, 1978)，目的在找出對於屬性效用具有同質性的市場區隔。其方法是請受訪者評估每種方案購買的可能機率，然後個別的分析每位受訪者對屬性的重視程度 (或成份效用值)，接著再根據重視程度進行分群，接著再進行一次個別分析，此種市場區隔的方法是基於消費者對屬性偏好的相似性來區隔。Moore (1980) 比較過上述兩種方式後發現兩階段法優於組成區隔法。然而兩階段法的第一階段的有效性仍然備

受質疑，因為這些資訊可能是建立在有偏誤的個人化參數的推論上。

預測區隔方法與逐步分群法：Ogawa (1987) 以及 Kamakura (1988) 提出層級預測區隔方法 (hierarchical predictive segmentation approach)。此方法的特性是將消費者分群，使整個模式在市場區隔中的正確預測率最大化。Kamakura (1988) 亦證明此法在區隔的正確預測機率優於兩階段法。然而此法的缺點在於先前一階段的錯誤分群會影響到整個模型的估計結果。另外，模式有參數限制的問題，經常因自由度不夠使參數無法被估計出來。因此，DeSarbo *et al.* (1989) 提出逐步分群迴歸 (clusterwise regression analysis) 的方法來改進上述的問題。逐步分群迴歸其原理為根據前一次估計的消費者偏好結構將相似的消費者分群，然後重新估計一次每個人的偏好結構，反複上述步驟，直到模式的預測正確性無法再提昇為止。然而，此方法屬於實務上的一個解決方法，其缺點是並非經由良好的統計理論來推論參數，因此較不具備良好的統計特性，在學術上的應用亦較少。

模糊逐步分群迴歸法與潛藏區隔模式：上述的方法除 DeSarbo *et al.* (1989) 之外，皆不容許市場區隔有重疊的特性，也就是區隔間具有完全互斥性，換句話說，某一個人屬於 A 群的機率 100%，其屬於另一 B 群的機率為 0%。然而，隨著市場區隔理論與方法的發展，容許市場區隔有重疊特性的模式逐漸被認定為較佳的方法，因為與實際市場的狀況較接近 (Arabie *et al.*, 1981)。且 Kamakura (1988) 亦指出非重疊性的市場區隔模式可能減低區隔的預測正確率。因此，Wedel and Steenkamp (1989) 提出使用模糊逐步分群迴歸法 (fuzzy clusterwise regression analysis) 法，將消費者分屬於不同區隔的資訊以機率的方式來表示。雖然模糊的方法提供了一套有利的方法，但缺點是研究者需要主觀的設定一些模糊權重的參數，因此不具有良好的統計特性。此外，參數的解經常為局部最佳解，不一定為全局最佳解。隨後 Kamakura *et al.* (1994) 致力於發展潛藏區隔模式 (latent class model)。上述方法的特性是在一次的參數估計中，可得到不同偏好市場區隔的資訊，並且容許區隔具有重疊的資訊。然而此方法也有兩個關鍵性的缺點 (1) 假設同一區隔內消費者偏好具同質性，故被評價為是較不符合實際情況的假設。(2) 參數的解不一定是最佳解，因受限於局部最小值的影響。

層級貝氏個人化參數推論法：Allenby and Ginter (1995) 首次將層級貝氏模式應用於聯合分析法個人偏好參數之推論，此法基於貝氏統計的原理有效結合整體市場與個人偏好的資訊，並以整體市場資訊作為先驗分配以輔助個人化參數的推論。此方法被認為較具有穩健的個人化參數估計的能力，許多研究證實層級貝氏模式具備穩健的個人化參數估計的能力 (林婷鈴等, 民 96; 任立中等, 民 95; 任立中等, 民 96; Allenby and Ginter, 1995; Allenby *et al.*, 2004)。Allenby and Ginter (1995) 將層級貝氏模式與潛藏區隔模式的正確預測率做一比較，發現層級貝氏模式的預測正確性優於潛藏區隔模式。由於層級貝氏可得到個人化的偏好結構，使一對一行銷成為可行的方法 (即一人區隔)。廠商可根據顧客個人化的偏好提供產品推薦，有效提升其經營與獲利能

力 (Rossi and Allenby, 2003)。

表 1 為作者根據上述幾個關鍵的市場區隔特性，將學者所提出聯合分析法之參數估計方法做一綜合比較。這些關鍵特性分別為：(1) 應用於選擇式聯合分析法、(2) 基於統計推論的特性、(3) 容許集群間具有重疊的特性、(4) 可推論個人化的偏好參數，以及(5) 同時推論個人化與市場區隔參數。而選擇式的聯合分析法因其較能模擬消費者真實的購買情境的特性，故被列為一個良好的特性。早期的學者多是針對排序性或評分性的聯合分析法提出推論市場區隔偏好參數的方法 (Green, 1977; Green and DeSarbo, 1979)，而近期學者則多是以選擇式聯合分析法為主 (Kamakura and Russa, 1989)。Allenby and Ginter (1995) 與 Allenby *et al.* (1998) 提出的層級貝氏法主要在個人化參數的推論，故不具市場區隔的特性。另外，在個人化參數的推論方面，在傳統的聯合分析法中，迴歸分析被應用於針對每一個個人的資料做一次迴歸分析，因此雖可得出個人化的參數，但其所估計的參數預測能力較差。相對的，層級貝氏的統計推論方法被認為較具較佳的個人化參數估計的能力 (Allenby and Ginter, 1995; Allenby *et al.*, 1998; Jen *et al.*, 2009)。

2.2 本研究在聯合分析方法的定位與討論

從上述文獻回顧可知學者不斷提出新的方法目的在 (1) 改進參數估計的方法，提升模型的正確預測能力。(2) 提升市場區隔決策資訊品質。前者的發展至目前以層級貝氏的參數估計法為最佳代表，後者則以潛藏區隔模式為最佳代表，本研究試圖整合此兩種方法的優點。首先，本研究所之統計模式承襲層級貝氏方法的優點，故可提升模型在推論個人化偏好參數的正確預測能力。其次，本研究使用混合常態分配來配適整體消費者偏好的分配，並提出能選擇最適編碼資訊的市場區隔法，因此可以同時推論個人化與市場區隔層次的參數，且由於混合常態的特性，本研究所提出的模型亦具有容許區隔重疊的特性。本研究所提出之層級貝氏模式可同時符合表一所有條件的特性。值得一提的是，在理論上，本研究的貝氏統計模式具有非常好的統計特性，在對個人的參數推論上，是以具有以相似偏好結構的人們作為其先驗分配，因此可強化對個人的參數估計。亦即當個體的參數資訊不足時，將以同一區隔內群體的訊息作為先驗分配來強化對個體參數的估計，有別於過去以整體市場資訊作為先驗分配的層級貝氏統計方法。因此，本研究的模式不但在理論上提供了一套更優於過去的方法。策略上，此模式提供更豐富的資訊以協助管理者進行市場區隔決策的預測與分析。

表1 聯合分析之市場區隔方法比較

代表性研究	方法名稱	應用於選擇式聯合分析法	具備良好統計推論特性的方法	容許集群間具有重疊的特性	可推論個人化的偏好參數	同時推論個人化與市場區隔參數
Green (1977); Green and DeSarbo (1979)	組成區隔法		✓			
Hauser and Urban (1977); Moriarty and Venkatesan (1978); Currim (1981)	兩階段法				✓	
Ogawa 1987; Kamakura (1988)	層級預測區隔法	✓			✓	✓
DeSarbo <i>et al.</i> (1989)	逐步分群迴歸			✓		
Wedel and Steenkamp (1989)	模糊逐步分群迴歸			✓		
Kamakura and Russa (1989)	逐步間斷選擇模式	✓		✓		
Kamakura <i>et al.</i> (1994)	潛藏區隔模式	✓	✓	✓	✓	
Allenby and Ginter (1995)	層級貝氏模式常態異質性假設	✓	✓		✓	
Allenby <i>et al.</i> (1998)	層級貝氏模式混合常態異質性假設	✓	✓		✓	
本研究	層級貝氏選擇式聯合分析法的市場區隔模型	✓	✓	✓	✓	✓

資料來源：本研究整理

3. 模式

3.1 模式說明

本研究之目的在於以混合常態模式作為層級貝氏邏輯模式 (hierarchical Bayes Logit model) 之消費者異質性偏好分配之假設，並提出混合常態模式之市場區隔的方法。在以下的內容中，作者將依序說明此統計模式之理論基礎、參數的推論方法以及取得市場區隔資訊的方法。

根據隨機效用模型 (random utility model)，假設某一位消費者在面對 J 個不同選擇時，他是選擇對他而言效用最高的一個選擇。以 U_j 表示消費者對 j 的效用是高於所有其他的選擇。若將 U_j 區分為可被研究者觀察到的效用 V_j ，以及不可觀察到的效用 ε_j 兩個成份。則 $U_j = V_j + \varepsilon_j$ 。則消費者選擇 j 的機率可表示為 (1)式

$$\begin{aligned} \Pr(y = j | X, \beta) &= \Pr(U_j > U_c \text{ for all } c) \quad c = 1, \dots, J \quad c \neq j \\ &= \Pr(\varepsilon_c < (V_j - V_c) + \varepsilon_j \text{ for all } c) \\ &= \int_{-\infty}^{\infty} \dots \int_{\varepsilon_c = (V_j - V_c)}^{\infty} f(\varepsilon_c, \varepsilon_j) d\varepsilon_j d\varepsilon_c \end{aligned} \quad (1)$$

假設 $\varepsilon_1 \dots \varepsilon_j$ 服從極值分配 (Type I extreme value distribution) 亦即 $F(\varepsilon_j) = \exp(-e^{-\varepsilon_j})$ 。且令 $V_j = x_j' \beta$ ，其中 x_j 代表 j 產品的屬性編碼 (模式之解釋變數)。 β 代表屬性之偏好係數，則 (1)式可改寫成 (2)式，而 (2)式又稱為邏輯模式 (Logit Model)。

$$\Pr(y = j | X, \beta) = \frac{\exp(x_j' \beta)}{\sum_{m=1}^J \exp(x_m' \beta)} \quad (2)$$

選擇式聯合分析常引用邏輯模式來表示消費者 i 在面對許多選擇中選擇某一產品的機率。現在假設有 n 個受訪者 $i = 1, 2, \dots, n$ ，每個受訪者面對 S 組不同的產品購買情境 $s = 1, 2, \dots, S$ 。每個模擬的購買情境有 J 個選擇。則 (2) 式可更精細的寫成 (3) 式。

$$\Pr(y_{is} = j | X_{is}, \beta_i) = \frac{\exp(x_{isj}' \beta_i)}{\sum_{m=1}^J \exp(x_{ism}' \beta_i)} \quad (3)$$

(3)式中 X_{is} 代表消費者 i 在第 s 次的選擇組合中所面對的 J 個不同選擇之產品屬性組合， x_{isj} 則更精準的表示消費者 i 在第 s 次的選擇組合中之第 j 個產品的屬性 (為統計模式中的解釋變數)。 $\Pr(y_{is} = j | X_{is}, \beta_i)$ 表示在給定此消費者 i 的偏好結構 (β_i)，以及其所面對第 s 次的選擇情境下 (X_{is})，會選擇 j 產品的機率。 y_{is} 代表第 i 個消費者，在第 s 個購買情境的選擇 ($y_{is} = 1, 2, \dots, J$)。 β_i 代表消費者 i 的偏好結構 ($i = 1, 2, \dots, n$)，為模式需推論的參數，也就是個人化的偏好

結構，在聯合分析法中亦稱為成份效用值 (part-worth)。

透過層級貝氏的參數推論方法，可協助我們推論出個人化的參數偏好結構。(4)式之 $\pi(\beta_i | Data)$ 為消費者 i 之個人化的偏好結構參數之後驗分配，根據貝氏統計的理論，對個人化參數的後驗分配之推論是結合個人選擇資料的資訊 $\ell_i(Data | \beta_i)$ 與群體的先驗資訊 $p(\beta_i)$ 的結果。若個人化參數的資訊不穩定時 (變異較大時)，可藉由結合群體的資訊產生較佳的結果。因此，若能事先將相似的消費者分群，以此集群的消費者的資訊作為先驗資訊 $p(\beta_i) \sim N(\mu_k, \Sigma_k)$ (若消費者 i 屬於第 k 個市場區隔)， μ_k 為第 k 個區隔內所有樣本偏好結構之平均數， Σ_k 為第 k 個區隔內所有樣本偏好結構之共變異數矩陣)，則相對於以所有樣本的資訊作為先驗資訊如 $p(\beta_i) \sim N(\bar{\beta}, \Sigma_\beta)$ ($\bar{\beta}$ 為所有樣本偏好結構之平均數， Σ_β 為所有樣本偏好結構之共變異數矩陣)，理論上將可因為較佳的先驗資訊而產生較佳的後驗分配之推論。

$$\begin{aligned} \pi(\beta_i | Data) &\propto \ell_i(Data | \beta_i) \cdot p(\beta_i) \\ &\propto \left(\prod_{s=1}^S \prod_{j=1}^J \Pr(y_{is} = j | X_{is}, \beta_i)^{\delta_{isj}} \right) \cdot p(\beta_i) \end{aligned} \quad (4)$$

在 (4)式中 $\prod_{s=1}^S \prod_{j=1}^J \Pr(y_{is} = j | X_{is}, \beta_i)^{\delta_{isj}}$ 代表第 i 個消費者所有產品選擇的聯合機率分配。 δ_{isj} 是一個指標變數， δ_{isj} 為 1 若消費者 i 在第 s 次的選擇中，選擇 j 產品。 δ_{isj} 為 0 若選非 j 產品。舉例來說，若消費者 i 在第 s 次的選擇中，從三個可能選擇中選擇了第 2 個產品則 $\delta_{is2}=1$ ， $\delta_{is1}=\delta_{is3}=0$ ， $\prod_{j=1}^J \Pr(y_{is} = j | X_{is}, \beta_i)^{\delta_{isj}}$ 值如 (5)式所列

$$\begin{aligned} &\prod_{j=1}^J \Pr(y_{is} = j | X_{is}, \beta_i)^{\delta_{isj}} \\ &= \left(\frac{\exp(x_{is1}' \beta_i)}{\sum_{m=1}^3 \exp(x_{ism}' \beta_i)} \right)^0 \cdot \left(\frac{\exp(x_{is2}' \beta_i)}{\sum_{m=1}^3 \exp(x_{ism}' \beta_i)} \right)^1 \cdot \left(\frac{\exp(x_{is3}' \beta_i)}{\sum_{m=1}^3 \exp(x_{ism}' \beta_i)} \right)^0 = \left(\frac{\exp(x_{is2}' \beta_i)}{\sum_{m=1}^3 \exp(x_{ism}' \beta_i)} \right)^1 \end{aligned} \quad (5)$$

本研究的目的則在運用層級貝氏方法來推論個人化 β_i 與偏好之市場區隔化的參數 μ_k, Σ_k 。更具體來說，本研究以混合多維常態分配來配適消費者偏好結構的特性。若消費者偏好以三個常態分配所組成的混合常態來配適，則這三個常態分配則代表了三個市場區隔的偏好資訊，為使觀念易於理解，本文命名省略多維概念。多維則是因為模式對於產品屬性的偏好是一次推論多個屬性偏好，故稱之為偏好結構。運用多維常態分配來代表市場區隔資訊的原因是，因為在同一個多維常態分配中之消費者具有相似的偏好結構，可符合行銷中市場區隔的定義。若有 K 個市場區隔時，消費者 i 的個人化參數結構 β_i 可能來自其中一個多維常態母體。例如假設研究者以兩個多維常態來配適消費者異質性偏好結構時模式時，消費者 i 可能來自第一個多維常態母體或來自第二個多維常態母體。 $\beta_i \sim N(\mu_1, \Sigma_1)$ 或 $\beta_i \sim N(\mu_2, \Sigma_2)$ 。若消費者 i 來自第一個常態母體時， $ind_i=1$ 。 $\beta_i \sim N(\mu_1, \Sigma_1)$ 。故以 (6) 式來表示消費者異質性服從

混合常態分配，以 ind_i 類別標籤來代表他所來自的多維常態母體 ($ind_i = 1, \dots, K$)。

$$\beta_i \sim N(\mu_{ind_i}, \Sigma_{ind_i}) \quad (6)$$

此外，模式中相關參數之先驗分配可採用貝氏統計中自然共軛之機率分配設定，故將模式中其他相關參數之先驗分配作如下的設定。因 ind_i 所代表的類別標籤為名目變數 $ind_i = 1, \dots, K$ ，其自然共軛之先驗機率分配服從多項式分配，如 (7) 式所示 $ind_i \sim \text{Multinomial}(\pi_i)$ 。其中 π_i 代表消費者 i 來自 K 個多維常態母體的機率 ($\pi_i = \pi_{i1}, \pi_{i2}, \dots, \pi_{ik}$)。(8) 式之 π 為 K 個機率值，代表每個多維常態母體相對大小的資訊，可用來反應每個市場區隔大小的資訊，其自然共軛之先驗分配服從 Dirichlet(α) 分配。(9) 式之 μ_k 為第 k 個多維常態的平均數，其自然共軛先驗機率為常態分配 $\mu_k \sim N(\bar{\mu}, \Sigma_k \otimes a_\mu^{-1})$ 。 $\bar{\mu}$ 為整體樣本偏好的平均數， a_μ^{-1} 為一個先驗參數 (prior)， Σ_k 為第 k 個多維常態分配的共變異矩陣，其自然共軛先驗分配為 Inverse-Wishart 分配，如 (10) 式所示 $\Sigma_k \sim IW(v_0, V_0)$ 。其中 v_0, V_0 為一個先驗資訊¹。

$$ind_i \sim \text{Multinomial}(\pi_i) \quad (7)$$

$$\pi \sim \text{Dirichlet}(\alpha) \quad (8)$$

$$\mu_k \sim N(\bar{\mu}, \Sigma_k \otimes a_\mu^{-1}) \quad (9)$$

$$\Sigma_k \sim IW(v_0, V_0) \quad (10)$$

值得一提的是，在貝氏統計中，使用自然共軛先驗 (natural conjugate prior) 分配具有方便推論的好處。舉例來說，如 (11) 式所列，在貝氏迴歸模式中，其欲推論的參數 β 之概似函數 $\ell(Data|\beta)$ 服從常態分配，若假設其先驗分配 $p(\beta)$ 服從常態分配，則其後驗分配 $\pi(\beta|Data)$ 亦服從常態分配。然而，當研究者依其研究目的認為該模式之先驗分配服從混合常態分配時，則 (10) 式之 $\pi(\beta|Data)$ 將服從一未知的分配。在過去統計計算能力未發達的時候研究者將無法推論出 $\pi(\beta|Data)$ 的值，但今日已可透過 Metrolis-Hasting 的抽樣方法來推論。

$$\pi(\beta|Data) \propto \ell(Data|\beta) \cdot p(\beta) \quad (11)$$

3.2 參數的推論方法

根據貝氏統計之理論，欲推論參數的後驗機率分配可從此分配中抽出無數次的值所形成之分配來代表。若此後驗分配符從已知的分配則可用吉普斯抽樣方法 (上述利用自然共軛先驗分配所形成之後驗分配的參數 $ind_i, \pi_i, \mu_k, \Sigma_k$)，若不符從已知的分配 (如 $\pi(\beta_i|Data)$) 可使用 Metrolis-Hasting 的抽樣方法 (Chib and Greenberg, 1995)，上述兩種方法皆屬於廣義的 MCMC

¹ 其中貝氏推論之混合常態模式的理論有興趣的讀者請參考 Rossi *et al.* (2005) 一書之 3.9 節，或 Allenby *et al.* (1998) 之研究。

(Markov chain Monte Carlo) 的方法。故欲推論上述模式的所有參數必需要運用到吉普斯抽樣和 Metrolis-Hasting 兩種方法，詳細的參數推論方法請參見附錄二。作者並以模擬的資料與參數來探測此模式所推論之參數與真實設定參數的差異來評估模式的優劣，結果發現模式回估參數的能力良好²。

3.3 取得市場區隔資訊

從後驗分配之每一次吉普斯抽樣中，我們可以得到個體是屬於哪一個區隔的編碼資訊 ind_i ，我們可以用這些編碼資訊來建立每一回抽樣中受訪者的相似矩陣 $[a_{ij}^r]_{n \times n}$ ，其中 a_{ij}^r 代表第 r 次吉普斯抽樣之相似矩陣內的元素³，此相似矩陣為 n 行與 n 列的矩陣， n 代表總人數。作者以每一回吉普斯抽樣之相似矩陣內元素總平均值來代表對此模式之相似矩陣的最終推論，我們稱此矩陣為「後驗平均之相似矩陣」並以 $[\bar{a}_{ij}]_{n \times n}$ 代表此矩陣內的每一個元素， $\bar{a}_{ij} = \sum_r^R a_{ij}^r / R$ ， R 為扣除 burn in 階段後之吉普斯抽樣總次數。作者認為可比較每一回吉普斯抽樣的相似矩陣，找出最接近後驗平均之相似矩陣的那一次吉普斯抽樣的編碼資訊來代表消費者所屬之市場區隔的編碼資訊。

作者提出三種比較兩個矩陣相似性的方法，第一種是選取兩矩陣相減之總和絕對誤差值最小的方法。第二種是兩矩陣相減之總和平方誤差值最小的方法，第三種是根據兩個矩陣的總變異最小的方法。請參考 (12) 至 (14) 式。 $f(a_{ij}^r, \bar{a}_{ij})$ 為損失函數 (loss function)。 a_{ij}^r 代表第 r 次吉普斯抽樣之相似矩陣內的元素。 \bar{a}_{ij} 代表後驗分配平均值之相似矩陣內的元素。 \bar{a}_{ij}^r 代表第 r 次吉普斯抽樣之相似矩陣內的元素之總平均 ($\bar{a}_{ij}^r = \sum_i^n \sum_j^n a_{ij}^r / n^2$)。 \bar{a}_{ij} 代表後驗分配平均值之相似矩陣內的元素之總平均 ($\sum_i^n \sum_j^n \bar{a}_{ij} / n^2$)。故方法一與方法二之函數代表某一次的吉普斯抽樣之相似矩陣內的元素與後驗分配平均值之相似矩陣內的元素之差異，二者皆有取差異總和最小之意。而方法三之函數則有取某一次的吉普斯抽樣之相似矩陣內的元素與後驗分配平均值之相似矩陣內的元素的變異總和最小之用意。

$$\text{評估方法 I: } \min \text{ Loss } f(a_{ij}^r, \bar{a}_{ij}) = \sum_{i=1}^n \sum_{j=1}^n |a_{ij}^r - \bar{a}_{ij}| \quad r = 1, \dots, R \quad (12)$$

$$\text{評估方法 II: } \min \text{ Loss } f(a_{ij}^r, \bar{a}_{ij}) = \sum_{i=1}^n \sum_{j=1}^n (a_{ij}^r - \bar{a}_{ij})^2 \quad r = 1, \dots, R \quad (13)$$

$$\text{評估方法 III: } \min \text{ Loss } f(a_{ij}^r, \bar{a}_{ij}) = \sum_{i=1}^n \sum_{j=1}^n (a_{ij}^r \cdot \bar{a}_{ij} - \bar{a}_{ij}^r \cdot \bar{a}_{ij})^2 \quad r = 1, \dots, R \quad (14)$$

經過模擬資料與實際資料的測試，發現方法 I 與方法 II 的所選出的最能代表後驗相似矩陣

² 有興趣的讀者可向作者索取模擬的結果。

³ 文中第 r 次抽樣指的是 MCMC 方法扣除 burn in 階段後之第 r 次抽樣。

的第 r 回吉普斯抽樣完全相同，代表此兩方法的區隔結果完全相同。作者從許多次的模擬資料均發現，方法 I 與方法 II 的區隔資訊的參數回復能力比方法 III 好，由於方法 I 最為省時且回覆參數的能力最佳，因此，本研究將使用方法 I 做為市場區隔參數之推論方法。透過前述之方法，我們得以取得每一位受訪者所屬市場區隔的資訊。

4. 實證研究

本研究透過聯合分析法，驗證本文所提模式在同時推論消費者個人與區隔偏好之可行性。

4.1 進行步驟

以泰國旅遊產品為例，作者先與旅行業者討論，並蒐集各大網站、雜誌資訊，以彙整出重要的屬性，初步得到六個屬性：價位、旅行天數、餐飲內容、航空公司、住宿等級、旅遊平安險內容。接著設計出第一個階段的紙本問卷並進行市場調查，以確認這些屬性是消費者旅遊時所重視的屬性項目。在確認重要的產品屬性後，接著進行聯合分析法的實驗設計，然後邀請受訪者進行研究聯合分析實驗，並以電腦問卷方式進行聯合分析法的資料蒐集。最後，運用層級貝式混合常態分配來分析消費者的區隔資訊與個人化的偏好結構。

4.2 聯合分析法之實驗設計

在問卷的設計上，本研究採取呈現產品完整屬性 (full profile) 的方式，將四個不同的產品呈現在受訪者的面前，讓受訪者可以從當中選擇一個。此種聯合分析法即稱為選擇式的聯合分析法。本研究利用 Sawtooth 之聯合分析軟體的實驗設計，每位受訪者需回答 10 個題數，每個題數中受訪者被要求從四個選擇當中，點選一個他最喜歡的選擇，其中包含「以上皆不喜歡」的選項。為比較不同模式的差異，本研究將所提出的模式與總和邏輯模式做比較。在總和邏輯模式中，會估計出一組成份效用值參數以代表整體市場平均之偏好結構。相對應的，在本研究的模型中，每位受訪者個人化的成份效用值參數皆可經由本研究的模式推論出。

4.3 樣本

本研究在南部地區各大旅行社邀請受訪者參與實驗。受訪者需符合曾有出國旅遊經驗、年滿 21 歲以上且有經濟能力的條件。結果共有 287 位受訪者參與並完成實驗。關於樣本的資訊描述如下：男性佔 40.8%、女性 59.2%。已婚佔 28.6%。21-30 歲、31-40 歲以及 41 歲以上分別為 49.1%、39.4% 以及 11.5%。個人平均年薪在 30 萬以下、31-50 萬、51 萬-100 萬以及 101 萬以上分別佔 26.1%、39.0%、28.9% 以及 5.9%。

4.4 資料蒐集

資料的蒐集分成兩個階段：第一個階段決定聯合分析法產品的重要屬性與水準。第二階段蒐集聯合分析的資料。第一階段的前測問卷共有 100 位受訪者填答，回收有效問卷 73 份，使我們確認價位、天數、餐飲、航空公司、住宿與保險理賠金額等的確是消費者認為重要的屬性，重要程度在 100 分的評價上的平均分數皆在 76 分以上，其中價位 79.32 分，天數 76.71 分，飲食 86.30 分，航空公司 84.52 分，住宿 93.56 分，旅遊保險 99.45 分。在第二階段的聯合分析實驗則是邀請前來旅行業者公司內的顧客參與實驗，完成資料的蒐集。共有 287 位受訪者完成填答。每位填答者完成 10 個選擇題目（參見附錄一）。本研究將前 8 筆資料作為消費者偏好模型的建立，留最 2 筆測試模型樣本外的預測能力。因此，共用 2296 (287 x 8) 筆資訊建立模型，保留 574 (287 x 2) 筆做模型預測。

5. 結果與討論

5.1 模式配適度

表 2 為模式的估計結果。模式 1 為不考慮消費者異質性的總和邏輯模式 (aggregate Logit model)。模式 2 為考慮消費者異質性服從混合多維常態分配的模式。本研究將分別比較消費者的異質性為一個至四個多維常態分配的情況。模式 1 是透過最大概似法得出的結果。層級貝式混合多維常態聯合分析模式則是透過 MCMC 的方法推論相關的參數。模式 1 的結果顯示，其衡量模式概似函數的邊際機率值為 -2165，運用層級貝氏模式且考慮消費者異質性模式的結果使對數概似函數的值大幅提昇，代表本研究所提出的模式以及所估計的參數能反應受訪者的選擇行為的機率較高。其中，以考慮四個多維常態的值最大，其次為兩個多維常態的情況。另外，MAD 的值代表模式所預測的選擇與真實選擇的誤差，其質愈小愈好。從樣本內的 MAD 值來看，總和邏輯模式的值為 0.429，然而本研究所提出的模式使的預測誤差的情況大幅縮小⁴，MAD 值均在 0.006 以下，以考慮兩個多維常態來配適消費者異質性偏好的情況為例，在所有 287 位受訪者，共 2296 次樣本內的選擇資料中，有 2284 筆資料是完全預測正確。此結果顯示本研究模式樣本內的配適程度非常的好。在樣本外的預測方面，總和邏輯模式的 MAD 值為 0.531 最差。考慮混合兩個或三個多維常態的模式樣本外的 MAD 則幾乎沒有什麼差異。綜合上述的結果以及本研究想探究潛藏之市場區隔的目的，研究者選擇以混合兩個多維常態來反應消費者的異質性偏好結構。原因如下 (1) 此模式在樣本內與樣本外的預測能力良好，與三個多維常態的情況不分軒輊，但兩的多維常態模式的概似函數機率值較大，顯示兩個多維常態的模式較三個

⁴ 根據每位受訪者之後驗分配平均值來代表每個人的偏好結構

表 2 模式配適度

模 式	樣 本 內		預 測 MAD
	log-likelihood	MAD ²	
模式 1: 總和邏輯模式 (Logit Model)	-2165.201	0.429	0.531
模式 2: 層級貝式混合多維常態聯合分析模型			
消費者異質性為 1 個多維常態	-722.408 ¹	0.006	0.517
消費者異質性為 2 個多維常態	-543.748	0.004	0.497
消費者異質性為 3 個多維常態	-591.562	0.003	0.495
消費者異質性為 4 個多維常態	-499.347	0.003	0.517

1 為 Log marginal density 衡量模式概似函數的邊際機率 (值愈大的模式較佳) , 在貝式模式中, 使用 Newton and Raftery 所提出的透過 GHK 與 importance sampling 的方法來估計。

2 MAD (Mean absolute difference) 衡量實際資料與預測資料誤差的指標 (值愈小的模式較佳), 在本研究中每個選擇為四選一, 因此隨機預測應該有 0.25 的正確機率, 也就是 0.75 的 MAD 。

多維常態的模式佳。(2) 實際比較三個多維常態的情況時, 發現其中一個多維常態的人數很少。若從兩個多維常態的資料來看, 其人數比為 64.3% 比 35.7%, 符合本研究想探究具有代表性的市場區隔資訊。因此, 後續部份的討論將以層級貝式混合多維常態聯合分析模型之消費者異質性為兩個多維常態的結果。

5.2 區隔之參數估計結果

此模式優點是同時可獲得市場區隔的資訊以及受訪者個體個人化偏好的資訊。在此我們先呈現區隔偏好的結果。表 3 為層級貝式混合多維常態聯合分析模型之消費者異質性為兩個多維常態模式的結果 (該表使用了本研究提出之區隔方法 I)。該結果顯示, 消費者泰國旅遊的偏好結構整體而言有兩個偏好區隔, 這兩個區隔分別包含了 64.3% 與 35.7% 的消費者。第一個區隔的人數較多, 從他們的偏好的平均值顯示出此區隔的消費者最重視的屬性是住宿, 尤其是五星級飯店, 相對於民宿的選擇, 五星級飯店的偏好高出 9.225, 對四星級飯店的評價高出民宿 4.950。在價位上, 相對於 20000 元以上的套裝行程。比較偏好價位在 10000 元-15000 元之間 ($\bar{\beta} = 4.678$), 其次為 15000 元-20000 元之間 ($\bar{\beta} = 4.004$), 對於 10000 以下的套裝行程的偏好為 2.116 ($\bar{\beta} = 2.116$)。對於所搭乘的飛機, 相對於其他航空公司的偏好, 長榮航空最高 ($\bar{\beta} = 4.376$), 其次是華航 ($\bar{\beta} = 2.499$)。對於飲食方面, 比較偏好有提供餐飲, 至於是自助餐或合菜的偏好則沒有太大的差異。在保費方面, 相對於 800 萬的旅遊平安險, 此區隔的受訪者最不喜歡 100 萬的旅遊平安險 ($\bar{\beta} = -3.198$), 其次為 200 萬 ($\bar{\beta} = -1.805$)。該第一區隔整體來說, 對旅遊的天數較不重視。相對的, 第二個區隔的資訊顯示, 他們對於旅遊的天數最為重視, 而且相對於七天六夜的旅程, 他們較偏好六天五夜 ($\bar{\beta} = 4.335$), 其次為五天四夜 ($\bar{\beta} = 4.132$), 再其次為四天三

表 3 區隔之參數估計結果

屬性	水準	係數	第 1 個相似偏好群體		第 2 個相似偏好群體	
			平均數	標準差 ¹	平均數	標準差
價 位	10000 元以下	β_1	2.116	3.419	-0.672	5.752
	10001~15000 元	β_2	4.687	5.444	0.354	3.172
	15001~20000 元	β_3	4.004	3.314	1.287	3.775
	20001 元以上	--				
天 數	四天三夜	β_4	-1.511	3.286	2.559	2.948
	五天四夜	β_5	-0.959	2.635	4.132	3.300
	六天五夜	β_6	-0.986	2.842	4.335	2.914
	七天六夜	--				
飲 食	自助餐	β_7	3.278	4.541	0.683	2.118
	合菜	β_8	3.390	4.388	0.496	3.526
	自理	--				
搭 乘 飛 機	泰航	β_9	-0.069	3.373	-0.697	1.558
	華航	β_{10}	2.499	2.183	-1.996	2.538
	長榮	β_{11}	4.376	5.665	2.737	2.745
	其他航空公司	--				
住 宿	五星級飯店	β_{12}	9.225	4.503	1.353	2.245
	四星級飯店	β_{13}	4.950	2.489	1.371	1.986
	民宿	--				
旅遊平安險	100 萬	β_{14}	-3.198	2.481	-1.687	3.142
	200 萬	β_{15}	-1.805	4.741	-1.586	2.458
	300 萬	β_{16}	0.174	2.500	-0.754	5.414
	500 萬	$\beta_1 \sim \beta_{17}$	-0.460	1.073	-0.134	2.889
	800 萬	--				
區隔人數佔市場比例				0.643		0.357

-- 虛擬變數之省略變數

1 區隔係數之標準差，其數值反應同一區隔消費者對該偏好異質性的大小

夜。相較於其他航空公司，他們對長榮航空有較高的偏好 ($\bar{\beta}=2.737$)，對於華航的偏好係數是負的 ($\bar{\beta}=-1.996$)。對於餐飲以及旅遊平安保險方面，較不重視。

第二個區隔的消費者對旅遊業者來說，可能是一個容易被忽視，卻可能是高獲利的市場區隔。因第二區隔的消費者價格敏感度相對較低，也比較不在乎是否為高級飯店或是否提供餐飲，亦沒有特別重視國內或國外航空公司，而此區隔人數亦佔了三成多，算是相當值得注意的比例。相對的，第一個區隔的消費者特別重視五星級飯店所提供的價值。旅行業者若想針對此

區隔的消費者行銷，可專注在與高級飯店的合作與宣傳內容，有提供餐飲的旅遊行程、國內航空公司尤其是長榮航空亦是第一區隔所特別偏愛的。

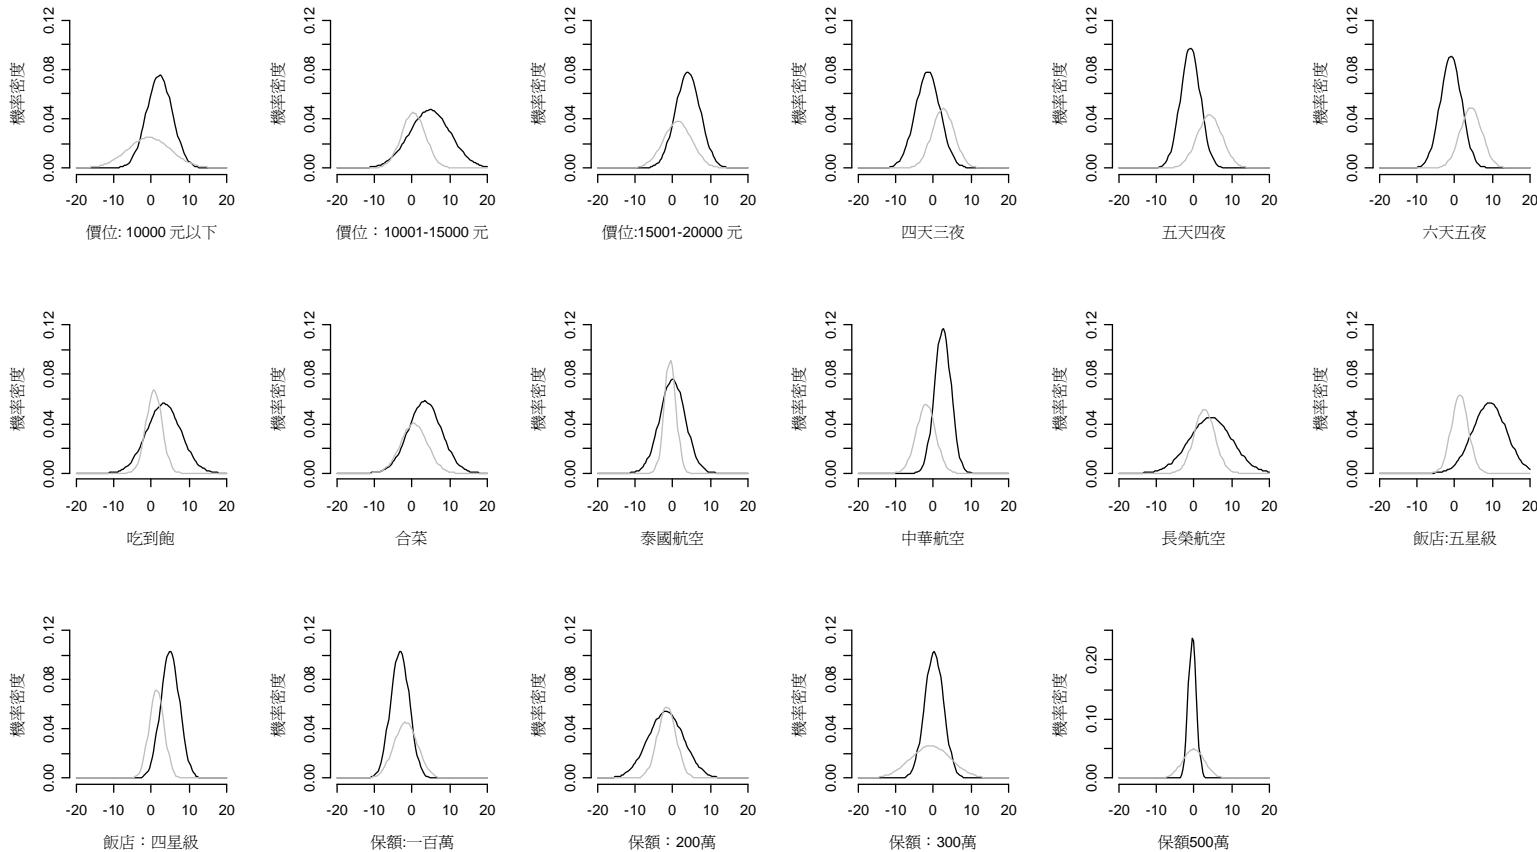
在考慮兩個群體平均值的差異後，我們應該更精細的思考同一個群體內的看法相似性的程度。此資訊可由表 3 的標準差來討論，其數值反應同一區隔消費者對該偏好異質性的相對大小。為使讀者有更清楚的輪廓，本研究以兩個區隔各自的邊際機率分配來呈現其偏好分配的情況（請見圖 1）。在此 17 個圖形中，黑色線的分配較大，為第一個市場區隔偏好的邊際分配。灰色線的區隔較小，反應的是第二個市場區隔偏好的邊際分配。此圖之橫軸代表的是消費者對產品屬性偏好的大小，縱軸代表邊際機率。從此圖形中，我們可以觀察到此兩個群體在某些屬性的水準偏好具有相似性，有些則具有差異性。例如：圖 1 的第 2 個圖即代表消費者對於價格在『10000-15000 元』產品屬性的偏好結構之兩個市場區隔的分配情況。大於 0 以上的值代表對於此產品屬性的偏好為正值，小於 0 代表對此產品屬性的偏好為負值。此圖中第二個區隔的消費者（灰色線）的偏好分配呈現一個對稱於 0 的常態分配，因此，從圖形中可看出約有一半喜歡、一半不喜歡此產品屬性。而第一個區隔為黑色的常態分配，大於 0 以上的人較多，因此第一個區隔的人相對於第二個區隔的人重視此產品屬性。

在圖 2 的黑色線條為整體市場偏好的邊際分配情況，為混合常態後驗分配的平均值，可反應整體市場的偏好結構。為了區別本研究的層級貝氏混合兩個常態異質性模式與一個常態異質性偏好邊際分配之差異。作者將一個常態異質性的情況以灰色的線條來表示。此圖顯示消費者異質性分配並不完全呈現常態分配。在此圖中可觀察到消費者的偏好呈現不對稱分配的特質，而在五星級與四星級飯店上更呈現了雙峰的特質。顯示層級貝氏混合常態模式較能發掘資料中所隱藏的消費者異質性偏好分配之結構。整體而言，研究者認為此模式不但能瞭解消費者偏好的異質性，也可以瞭解消費者偏好在不同區隔的相似或差異性。因此，相對於其他模式提供了較豐富的資訊供管理者參考。

5.3 個人化參數的推論與空間圖分析

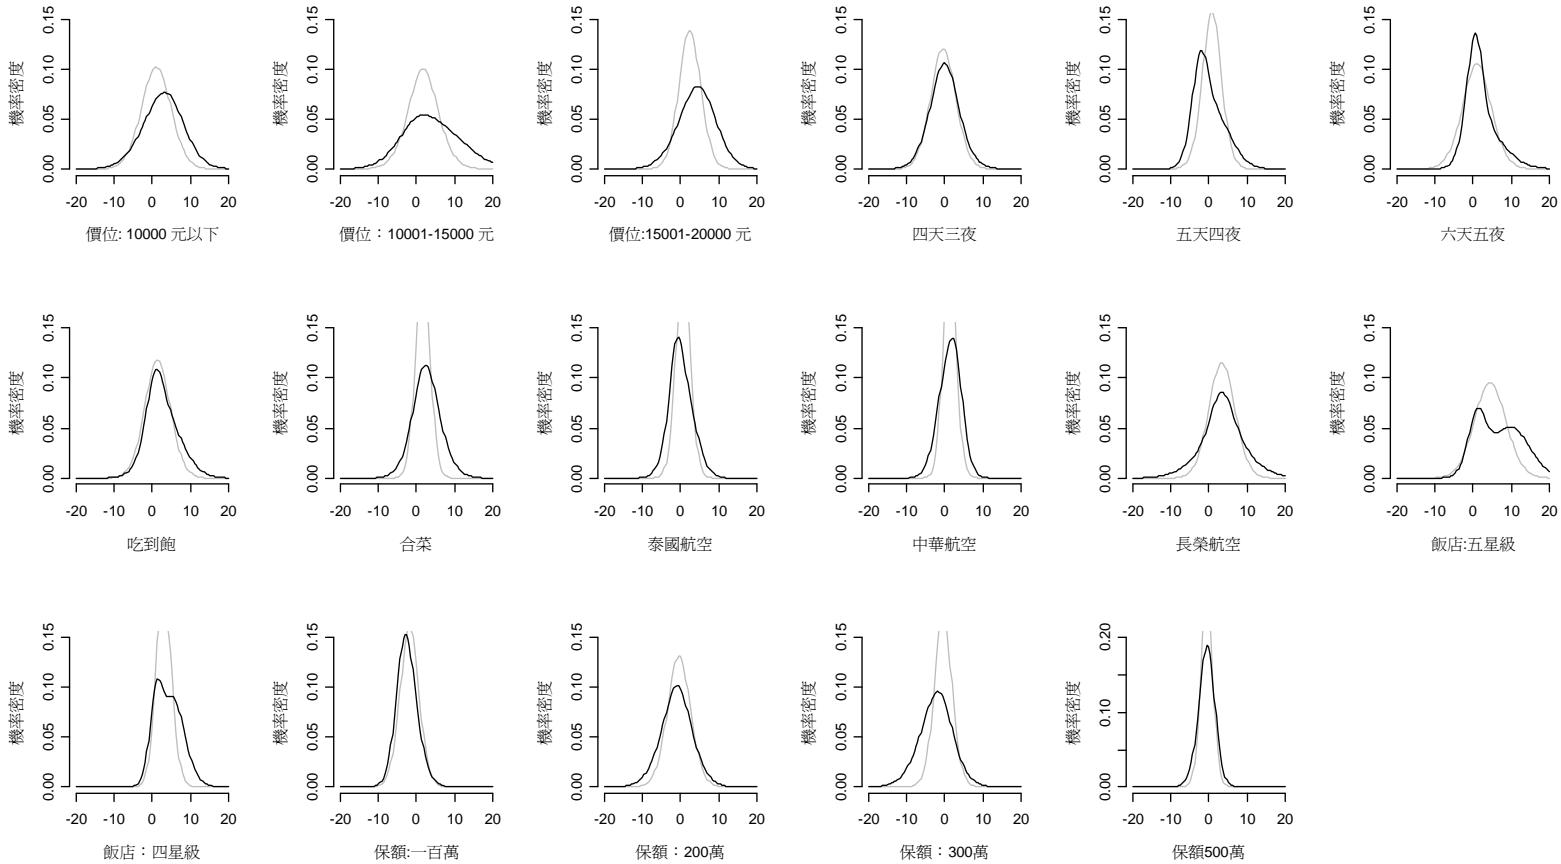
透過迴歸分析法，我們以個人化的參數的估計結果為應變數，探討受訪者個人的背景變項與其對旅遊產品屬性偏好的關連性。結果發現，個人背景變項對對旅遊產品屬性偏好差異的解釋能力很低。所有 17 個迴歸分析中，個人背景變項只有對 10000 以下的套裝行程的模式具有顯著的解釋能力。因此，表 4 只列出對價位在 10000 以下的套裝行程的偏好之迴歸分析之結果。此表顯示相對於未婚者，已婚者比較不喜歡此屬性水準。相對於年薪 50 萬以上的受訪者，年薪在 30 萬以下的受訪者較喜歡價位在 10000 以下的套裝行程。整體而言，我們發現個人背景變項對其偏好結構的解釋能力很低。

此外，作者使用個人背景資訊為自變數，受訪者所屬區隔的資訊編碼為應變數，以邏輯斯



註：黑色線為第一個市場區隔的偏好，灰色線為第二個市場區隔的偏好

圖 1 兩個市場區隔偏好的邊際分配之比較



註：黑色線為層級貝氏混合兩個常態異質性的邊際分配(本研究模式)，灰色線為層級貝氏常態異質性的邊際分配

圖 2 層級貝氏兩個混合常態異質性與一個常態異質性偏好邊際分配之比較

表 4 對價位在 10000 以下的套裝行程的偏好 β_1 之迴歸分析

應變數：對價位在 10000 以下的套裝行程的偏好 β_1				
	係數	標準差	t 值	顯著水準
常數項	1.84	0.93	1.98	0.05
男性	0.74	0.50	1.47	0.14
已婚	-1.25	0.66	-1.90	0.06
20-30 歲	0.44	0.96	0.46	0.64
30-40 歲	0.82	0.86	0.95	0.34
年薪 30 萬以下	1.52	0.72	2.13	0.03
年薪 30-50 萬	0.19	0.61	0.32	0.75
F-Value	2.97			0.08
R^2	0.04			

迴歸 (Logistic Regression) 模型來估計，希望能找出能區隔兩個市場的變數，結果顯示模式的預測的正確率與隨機猜測沒有什麼差異。這些資訊均顯示，若旅遊業者以個人背景變項作為市場區隔的方法，對消費者選擇產品的預測能力將是有限的，故建議旅遊業者應採用本研究模型的方法來探討旅遊市場的利益區隔與消費者的異質性偏好。

圖 3 顯示受訪者對套裝旅遊產品偏好之空間分析圖，圖中的 1 標籤編碼代表第一個群體的受訪者，2 標籤編碼代表第二個群體的受訪者。產品的屬性水準也呈現在此圖中。從此圖，我們可以看出第二群的受訪者比較注重天數的屬性，與第一群的受訪者有明顯的偏好差異。此圖顯示出兩個特點，第一，兩個群體的受訪者偏好在偏好的空間構面上，有明顯的分佈上的差異。第二，消費者的偏好不論在群間或群內都存在著異質性，故具偏好異質性的模式較能反應實際的情況。

5.4 本研究方法在市場區隔的特質討論

從市場區隔的分析方法中，本研究方法具有下列的良好特質：(1) 容許集群間具有重疊的特性，故更具彈性也更符合實際情況。因此，我們可以的觀察到在某些屬性的水準上，不同區隔的消費者的看法是很相似或是具有差異性。(2) 容許同一區隔內的消費者具有異質性。良好的模型應該要允許同一區隔內的消費者具有異質性。此模型不但考慮區隔內的消費者具有異質性之特質，亦可以推論出每一個消費者個人化的偏好結構。(3) 屬於「事後的區隔」(4) 屬於「預測性的市場區隔」。本文的方法是屬於預測性的市場區隔，乃根據消費者的選擇行為，推論其偏好結構與市場區隔資訊，因此結果較能用來預測消費者實際的購買偏好與行為，此區隔方法又稱為利益區隔，被認為是較佳的市場區隔方法。(5) 兼具「瞭解消費者個人化的偏好結構」與「發掘潛在消費者偏好結構之市場區隔」的特性。本研究的消費者異質性模式為混合多維常態模型，

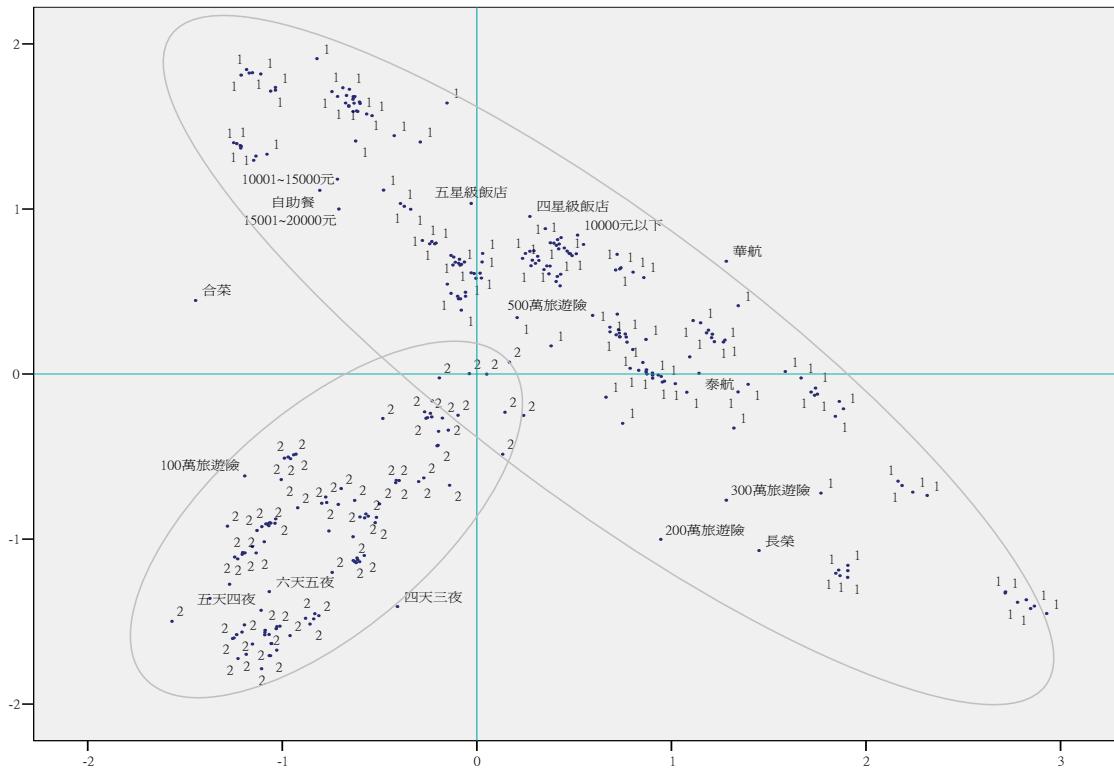


圖 3 受訪者對套裝旅遊產品偏好之空間分析圖

因此可觀察到同一區隔的人，在跨許多不同屬性/水準上的偏好狀態。(6) 運用統計分析的原理，建立分析模型。故研究者可根據此模型預測新產品組合對個體的效用、對市場區隔的效用、以及整體市場的效用：亦可根據不同產品組合對個體的效用進行新產品市場佔有率模擬分析。綜上所述，本研究的方法具有許多良好的市場區隔特性，在協助行銷經理人發展市場區隔的行銷策略上是有幫助的。

6. 結論與後續研究建議

作者提出層級貝氏選擇式聯合分析法的市場區隔模型，此方法有兩個特點。首先，此層級貝氏的模型以市場區隔的資訊做為個人偏好的先驗分配，而非過去貝氏模型以整體市場資訊作為先驗分配。其次，我們提出一套針對混合常態分配模型的市場區隔的方法，改進過去層級貝氏模型只能針對個人的參數作推論而無法有效推論市場區隔參數的缺點。不同於過去兩階段分析的方法，此模式是在一次的統計估計中，同時推論個人化參數的估計與區隔的訊息，且以市場區隔的群體的資訊輔助個人的參數估計，因此在理論與實務上皆具有良好的統計模式特性。

本研究以旅遊產品為例，說明所提出之方法可協助廠商提升新產品或服務的決策品質。本研究的受訪者皆具有旅遊經驗，因此，相較於常用的學生樣本，本研究較具有預測效度。然而，本研究亦有一些研究限制。首先，本研究是在假設觀光行程都一樣的情況下請消費者對所提供的套裝組合做選擇。然而旅遊觀光景點的規劃對旅遊的意願也有影響，因此，建議有興趣的廠商可利用此方法，再針對旅遊景點作分析。這些資訊的蒐集與分析，將可協助廠商更深入瞭解顧客。其次，未來的研究方面，可加強探討區隔數選擇的問題。一般而言，所選擇的區隔數越多，樣本內的配適情況會更好。如在本研究中，當設定四個常態來配適消費者的異質性時，其樣本內的配適情況最佳，但樣本外的預測能力 MAD 却降低。由於此模式兼具異質性參數的推論與區隔資訊的推論的用意，作者建議研究者可將焦點放在較具有代表性的區隔上較佳，作者建議亦可透過知覺圖的方法圖示區隔資訊的決策（如圖 3）。未來的研究亦可針對區隔數做分析，例如：(1) 發展統計上的判斷指標。(2) 發展能自行判斷市場區隔數的統計模式 (3) 發展可協助研究者判斷的其他圖示方法等。本研究的目的在提出一用於聯合分析法的統計模式，且此模式可同時探討市場區隔以及個人化偏好結構的特性。在本研究中，我們發現此模式的應用情況良好，例如可協助發現兩個具有相似偏好結構的市場區隔，以及推論個人化偏好參數。然而市場的情況非常多元，在極端的情況下，有時可能無法發現具有相似偏好結構的區隔。雖然我們的模式能配適各種情況的資料。然而，實際的市場區隔情況有待行銷人去分析與發掘。我們希望未來有更多的研究資料分析，測試此模式的應用性。

附錄 A：選擇式聯合分析法問卷

如果您要安排一個泰國旅遊行程，請從以下四個方案中點選您比較喜歡的選擇：

泰國航空	中華航空	長榮航空	其他航空公司
			
六天五夜	七天六夜	四天三夜	五天四夜
不含餐飲	自助餐式	合菜式	自助餐式
民宿	四星級飯店	四星級飯店	五星級飯店
500 萬旅遊平安險	300 萬旅遊平安險	100 萬旅遊平安險	800 萬旅遊平安險
15001~20000 元	20001 元以上	10001~15000 元	10000 元以下

附註：其他沒有列入的內容都相同

附圖一 選擇式聯合分析法電腦問卷

附錄 B：層級貝式混合多維常態聯合分析模式的參數的估計方法

有 N 個受訪者 ($i=1, \dots, N$)， S 次的選擇組合 ($s=1, \dots, S$)，消費者的異質性服從混合 K 個多維常態分配。則欲估計的個人化參數 β_i 的後驗機率分配可以 (A-1) 式來表示。

$$\begin{aligned} \pi(\beta_i | Data) &\propto \ell_i(Data | \beta_i) \cdot p(\beta_i) \\ &\propto \left(\prod_{s=1}^S \prod_{j=1}^J \Pr(y_{is} = j | X_{is}, \beta_i) \right)^{\delta_{isj}} \cdot p(\beta_i) \end{aligned} \quad (A-1)$$

$$\beta_i \sim N(\mu_{ind_i}, \Sigma_{ind_i}) \quad (A-2)$$

$$ind_i \sim \text{Multinomial}(\pi_i) \quad (A-3)$$

$$\pi \sim \text{Dirichlet}(\alpha) \quad (A-4)$$

$$\mu_k \sim N(\bar{\mu}, \Sigma_k \otimes a_\mu^{-1}) \quad (A-5)$$

$$\Sigma_k \sim IW(v_0, V_0) \quad (A-6)$$

(A-1) 式中 $\pi(\beta_i | Data)$ 為消費者 i 之個人化的偏好結構係數之後驗分配，根據貝氏統計理論，對個人化參數的後驗分配之推論乃結合個人選擇的資訊 $\ell_i(Data | \beta_i)$ 與群體的先驗資訊 $p(\beta_i)$ 。 X_{is} 為消費者 i 在第 s 次的選擇組合中所面對的產品屬性組合。 y_{is} 代表第 i 個消費者，在第 s 個購買情境的選擇 $y_{is}=1, 2, \dots, J$ ， $s=1, 2, \dots, S$ 。 $\Pr(y_{is} = j | X_{is}, \beta_i)$ 表個人選擇的資訊，即消費者 i 在第 s 次的選擇組合中選則 j 產品的機率。 δ_{isj} 為 1 若消費者 i 在第 s 次的選擇中，選擇 j 產品。 δ_{isj} 為 0 若選非 j 產品。(A-2) 式為先驗機率 $p(\beta_i)$ 的分配假設。本文假設消費者的 β_i 參數的先驗機率 $p(\beta_i)$ 服從混合常態分配 $\beta_i \sim N(\mu_{ind_i}, \Sigma_{ind_i})$ 。該式表示消費者 i 的個人化參數 β_i 可能來自其中一個多維常態母體，以 ind_i 來代表他所來自的多維常態母體 ($ind_i = 1, \dots, K$)。

另外，模式中相關參數之先驗分配可根據貝氏定理之自然共軛分配設定如下： ind_i 名目變數，其先驗服從多項式分配。 $ind_i \sim \text{Multinomial}(\pi_i)$ ， π_i 代表消費者 i 來自 K 個多維常態母體的機率 ($\pi_i = \pi_{i1}, \pi_{i2}, \dots, \pi_{ik}$)。(A-3) 式中 π_i 代表每個市場區隔的機率值的資訊，其先驗服從 $\text{Dirichlet}(\alpha)$ 分配。多維常態的平均數 μ_k 先驗為常態分配 $\mu_k \sim N(\bar{\mu}, \Sigma_k \otimes a_\mu^{-1})$ 。第 k 個多維常態分配的共變異矩陣 Σ_k 之先驗分配服從 Inverse-Wishart 分配，以 $\Sigma_k \sim IW(v_0, V_0)$ 表示。 α ， $\bar{\mu}$ ， a_μ^{-1} ， v_0 ， V_0 為資訊。如在混合兩個常態的情況下， d 為 β_i 的維度， $\alpha = (5, 5)$ ， $a_\mu^{-1} = 0.01$ ， $v_0 = d+3$ ， $V_0 = v_0 \cdot \text{diag}(1)_{d \times d}$ 。 $\bar{\mu}' = (0)_{d \times 1}$ 。

MCMC 的過程包含反覆下列四個步驟以推估模式的參數。

$$\begin{aligned} \text{起始值} &\quad \pi^0, \{\mu_k^0, \Sigma_k^0\}, \{\beta_i^0\} \\ \text{步驟 1} &\quad ind^1 | \pi^0, \{\mu_k^0, \Sigma_k^0\}, \{\beta_i^0\} \\ \text{步驟 2} &\quad \pi^1 | ind^1 \end{aligned}$$

$$\begin{array}{ll} \text{步驟 3} & \{\mu_k^1, \Sigma_k^1\} \mid ind^1 \quad k=1, 2, \dots, K \\ \text{步驟 4} & \{\beta_i^1\} \mid y_i, X_i, ind_i^1, \mu_k^1, \Sigma_k^1 \end{array}$$

以 π^0 代表每個市場區隔的機率大小的資訊，上標 0 代表第 0 次的 MCMC 抽樣，也就是一個起始值。給定 $\pi^0, \{\mu_k^0, \Sigma_k^0\}, \beta^0$ 等起始值，我們可以抽樣出每一個個體是屬於的哪一個多維常態母體的資訊 ind^1 ，其中 $ind^1 = (ind_1, \dots, ind_N)$ 表示在第一次 MCMC 抽樣中，標示每一個受訪者分別是屬於哪一個區隔的資訊。上標 1 代表第 1 次的 MCMC 抽樣，給定 ind^1 我們可以得知每個群體大小，故可得到 π^1 。同時，給定 ind^1 ，亦可以推估每個多維常態的平均數與共變異資訊。然後給定 $y_i, X_i, ind_i^1, \mu_k^1, \Sigma_k^1$ 使我們可以推估 β_i^1 的資訊，並以此反覆抽樣達適當次數。以上每個步驟說明如下：

步驟 1：抽出個體所屬的多維常態母體的編碼值 ind_i

給定 π 的資訊， $\pi = \pi_1, \pi_2, \dots, \pi_K$ 為每個市場區隔機率大小的資訊（其值可經由步驟 2 不斷更新）。 $\tilde{\pi}_i$ 為個體 i 分別屬於 K 個多維常態母體機率之後驗分配 $\tilde{\pi}_i = \tilde{\pi}_{i1}, \tilde{\pi}_{i2}, \dots, \tilde{\pi}_{iK}$ 。 $i=1, \dots, N$ 。每個受訪者屬於哪一個多維常態母體 ind_i 可從 Multinomial ($\tilde{\pi}_i$) 分配中隨機抽出一個值。其值的計算由 (A-8) 式而來。 $f(\beta_i \mid \mu_k, \Sigma_k)$ 為個體 i 評估其屬於第 k 個多維常態母體的邊際機率概似函數。 $\tilde{\pi}_{ik}$ 的值需除以其正規化常數 (Normalizing constant)，即個體 i 評估其在 K 個多維常態母體的概似函數的總和，才可使 $\sum_{k=1}^K \tilde{\pi}_{ik} = 1$ 。

$$ind_i \sim \text{Multinomial}(\tilde{\pi}_i) \quad \tilde{\pi}_i = \tilde{\pi}_{i1}, \tilde{\pi}_{i2}, \dots, \tilde{\pi}_{iK} \quad (\text{A-7})$$

$$\tilde{\pi}_{ik} = \frac{\pi_k \cdot f(\beta_i \mid \mu_k, \Sigma_k)}{\sum_{k=1}^K \pi_k \cdot f(\beta_i \mid \mu_k, \Sigma_k)} \quad k = 1, 2, \dots, K \quad (\text{A-8})$$

步驟 2：抽出反應每個多維常態母體相對大小的機率 π

π 為 K 個機率值，代表每個多維常態母體相對大小的，可用來反應每個市場區隔資訊的大小。 π 後驗分配為 Dirichlet($\tilde{\alpha}_1, \dots, \tilde{\alpha}_K$)， $\tilde{\alpha}_k$ 值可從 (A-10) 得到。 α_k 為 $\tilde{\alpha}_k$ 先驗資訊。

$$\pi \sim \text{Dirichlet}(\tilde{\alpha}) \quad (\text{A-9})$$

$$\tilde{\alpha}_k = \sum_{i=1}^n I(ind_i = k) + \alpha_k \quad (\text{A-10})$$

步驟 3：抽出每個多維常態母體的平均數與共變異矩陣 $\{\mu_k, \Sigma_k\}$

當知道每個消費者分屬於不同多常態母體資訊後 ind_i ，將可用此資訊將同一區隔之消費者集合起來，然後運用貝氏 SUR (Seemingly Unrelated Regression) 模型 (Rossi *et al.*, 2005) 的方法可輕易得出每個多維常態母體的平均數與共變異矩陣 $\{\mu_k, \Sigma_k\}$ 的推論。在 (A-11) 式中， B_k 是屬於 k 多維常態母體的偏好參數， ι 為 1 的向量。 μ_k 是欲估計的平均數向量。 Θ 誤差共變數矩陣。又因為假設 $\mu_k \sim N(\bar{\mu}, \Sigma_k \otimes a_k^{-1})$ $\Sigma_k \sim IW(v_0, V_0)$ (A-5, A-6)，經由推導後可得出 μ_k, Σ_k 的後驗

分配為 (A-12) 與 (A-13) 式。

$$B_k = \iota\mu_k' + \Theta_k \quad \Theta_k \sim N(0, \Sigma_k) \quad k=1, \dots, K \quad (\text{A-11})$$

$$u_k | B_k, \Sigma_k, \bar{\mu}, a_{\mu 0} \sim N(\tilde{\mu}_k, 1/(I_k + a_{\mu 0})\Sigma_k) \quad (\text{A-12})$$

$$\Sigma_k | B_k, v_o, G_0 \sim IW(v_0 + I_k, V_0 + SS) \quad (\text{A-13})$$

其中 $I_k = \sum_{i=1}^n I(\text{ind}_i = k)$, $SS = (B_k - \iota\tilde{\mu}_k)'(B_k - \iota\tilde{\mu}_k)$, $\tilde{\mu}_k = (I_k + a_{\mu 0})^{-1}(I_k \bar{\beta}_k + a_{\mu 0} \bar{\mu})$, $\bar{\beta}_k = (B_k' \iota / I_k)$
 $v_o, V_o, \bar{\mu}, a_{\mu 0}$ 為 $\{\mu_k, \Sigma_k\}$ 的先驗資訊。

步驟 4: 抽出個人化參數 $\{\beta_i\}$

已知 $y_i, X_i, \text{ind}_i, \mu_k, \Sigma_k$ 的資訊，則 β_i 的後驗分配為 (A-14) 式

$$\begin{aligned} \pi(\beta_i | X_{is}, y_{is}, \text{rest}) &\propto \ell_i(\beta_i | X_{is}, y_{is}) \cdot p(\beta_i) \\ &\propto \left(\prod_{s=1}^S \prod_{j=1}^J \Pr(y_{is} = j | X_{is}, \beta_i)^{\delta_{isj}} \right) \cdot \exp\left\{(\beta_i - \mu_{\text{ind}_i})' \Sigma_{\text{ind}_i}^{-1} (\beta_i - \mu_{\text{ind}_i})\right\} \\ \Pr(y_{is} = j | X_{is}, \beta_i) &= \frac{\exp(x_{isj}' \beta_i)}{\sum_{m=1}^J \exp(x_{ism}' \beta_i)} \end{aligned} \quad (\text{A-14})$$

上式之 x_{isj} 表示消費者 i 在第 s 次的選擇組合中之第 j 個產品的屬性。(A-14) 式並不服從任何一個已知的分配形式，因此我們以高斯隨機漫步的 Metropolis-Hastings 的抽樣方法來抽出 β_i ($i=1, 2, \dots, N$)，方法如下：

$$\begin{aligned} &\text{起始狀態 } \beta_i^{old} \\ &\text{隨機抽樣 } \beta_i^{candidate} = \beta_i^{old} + \Delta_i, \quad \Delta_i \sim N(0, H_i^{-1}), \quad H_i^{-1} = scaling^2 \Sigma_i \\ &\text{令 } \gamma = \min\left\{1, \pi(\beta_i^{candidate}) / \pi(\beta_i^{old})\right\} \\ &\text{在 } \gamma \text{ 的機率下, } \beta_i^{new} = \beta_i^{candidate}, \text{ 其它 } \beta_i^{new} = \beta_i^{old} \end{aligned} \quad (\text{A-15})$$

對 N 個體依序抽樣 $i=1, 2, \dots, N$

$\pi(\beta_i^{candidate})$, $\pi(\beta_i^{old})$ 為 $\beta_i^{candidate}$ 和 β_i^{old} 的後驗機率分配，即 (A-1) 式。 Δ_i 決定隨機漫步值的變動量。作者對隨機漫步的變動量作如下的設定： $\Delta_i \sim N(0, H_i^{-1})$ ， H_i^{-1} 的值影響隨機漫步值的變動幅度。其值設定為 $H_i^{-1} = scaling^2 \Sigma_i$ 。據 Roberts and Rosenthal (2001) 的看法， $scaling$ 設定為 $scaling = 2.93 / \sqrt{d}$ (d 為 β_i 的維度) 可使 Metropolis-Hastings 方法得到良好的結果， $\Sigma_i = (\text{Hessian}_i + \Sigma_{\text{ind}_i}^{-1})^{-1}$ 代表對消費者 i 偏好之變異的近似推論。其資訊來源有二： Hessian_i 以及 $\Sigma_{\text{ind}_i}^{-1}$ ， Hessian_i 為 $\ell_i^*(\beta_i | X_{is}, y_{is})$ 的 Hessian 矩陣 (A-16)。 $\ell_i^*(\beta_i | X_{is}, y_{is})$ 是 β_i 個體偏好參數之概似函數的一個近似推論 (A-17)，用以協助我們決定 H_i^{-1} 。 $\Sigma_{\text{ind}_i}^{-1}$ 表該次 MCMC 抽樣中，消費者 i 所屬區隔的共變異矩陣，有代表 i 偏好變異矩陣之先驗之意，若消費者 i 屬第 k 個區隔，則 $\Sigma_{\text{ind}_i}^{-1} = \Sigma_k^{-1}$

(其值從步驟三得出)。故 H_i^{-1} 亦結合 β_i 個體偏好參數之概似函數 Hessian_i 與先驗資訊 $\Sigma_{ind_i}^{-1}$ ，並可透過 scaling 值調整。

$$\text{Hessian}_i = -\frac{\partial^2 \log \ell_i^*(\beta_i | X_{is}, y_{is})}{\partial \beta_i \partial \beta_i^*} \quad (\text{A-16})$$

$\ell_i^*(\beta_i | X_{is}, y_{is})$ 為一個加權平均的結果，它結合個體的概述函數資訊 $\ell_i^*(\beta_i | X_{is}, y_{is})$ ，以及整體概似函數的資訊 $\bar{\ell}(\beta)$ 。 w 為加權數值，介於 0 到 1 (設定 $w=0.1$ ，表個人的資訊給較大的權重)。 $\theta = \frac{n_i}{N_{Total}}$ 為一參數用以根據個人觀察值多寡來調整總體樣本之概似機率值的權重， n_i 為個人觀察值數目 (本研究 $n_i=8$ 樣本內)， N_{Total} 是所有觀察值數目。因 $\ell_i^*(\beta_i | X_{is}, y_{is})$ 結合個體與全體概述函數的資訊，故會有極大值。而其 Hessian_i 矩陣可透過數值分析之 Broyden-Fletcher-Goldfarb-Shanno 法求之，亦可求得 β_i 的起始值 $\{\beta_i^0\}$ 。

$$\ell_i^*(\beta_i | X_{is}, y_{is}) \propto \ell_i(\beta_i | X_{is}, y_{is})^{(1-w)} \cdot \bar{\ell}(\beta)^{w\theta} \\ \propto \left(\prod_{s=1}^S \prod_{j=1}^J \Pr(y_{is} = j | X_{is}, \beta_i)^{\delta_{isj}} \right)^{(1-w)} \cdot \left(\prod_{i=1}^N \prod_{s=1}^S \prod_{j=1}^J \Pr(y_{is} = j | X_{is}, \beta_i)^{\delta_{isj}} \right)^{w \frac{n_i}{N_{Total}}} \quad (\text{A-17})$$

$$\text{where } \theta = \frac{n_i}{N_{Total}} \quad N_{Total} = \sum_{i=1}^N n_i$$

參考文獻

- 任立中、林婷鈴、陳靜怡、李吉仁，「高科技產業產品價值創造與行銷價值專屬化之最適資源配置」，中山管理評論，第十四卷第一期，民國 95 年，11-42 頁。
- 任立中、陳靜怡，「顧客價值遷移路徑分析：馬可夫鏈模型」，台大管理論叢，第十七卷第二期，民國 96 年，133-158 頁。
- 林婷鈴、陳靜怡、任立中，「解析自有品牌策略與績效關係的迷思：層級貝氏迴歸模式之運用」，台大管理論叢，第十八卷第一期，民國 96 年，117-149 頁。
- Allenby, G. M. and Ginter, J. L., "Using Extremes to Design Products and Segment Markets," *Journal of Marketing Research*, Vol. 32, No. 4, 1995, pp. 392-403.
- Allenby, G. M., Arora N., and Ginter, J. L., "Incorporating Prior Knowledge into the Analysis of Conjoint Studies," *Journal of Marketing Research*, Vol. 32, No. 2, 1995, pp. 152-162.
- Allenby, G. M., Arora, N., and Ginter J. L., "On the Heterogeneity of Demand," *Journal of Marketing Research*, Vol. 35, No. 3, 1998, pp. 384-389.

- Allenby, G. M., Bakken, D. G., and Rossi, P. E., "The HB Revolution: How Bayesian Methods Have Changed the Face of Marketing Research," *Marketing Research*, Vol. 16, No. 2, 2004, pp. 20-25.
- Arabie, P., Carroll, J. D., DeSarbo, W., and Wind, J., "Overlapping Clustering: A New Method for Product Positioning," *Journal of Marketing Research*, Vol. 18, No. 3, 1981, pp. 310-317.
- Chib S. and Greenberg, E., "Understanding the Metropolis-Hastings algorithm," *The American Statistician*, Vol. 49, No. 4, 1995, pp. 327-335.
- Currim, I. S., "Using Segmentation Approaches for Better Prediction and Understanding from Consumer Mode Choice Models," *Journal of Marketing Research*, Vol. 18, No. 3, 1981, pp. 301-309.
- DeSarbo, W. S., Ramaswamy V., and Cohen S. H., "Market Segmentation with Choice-based Conjoint Analysis," *Marketing Letters*, Vol. 6, No. 2, 1995, pp. 137-147.
- DeSarbo, W. S., Oliver, R. L., and Rangaswamy, A., "A Simulated Annealing Methodology for Clusterwise Linear Regression," *Psychometrika*, Vol. 54, No. 4, 1989, pp. 707-736.
- Green, P. E. and Rao, V. R., "Conjoint Measurement for Quantifying Judgmental Data," *Journal of Marketing Research*, Vol. 8, No. 3, 1971, pp. 355-363.
- Green, P. E., "A New Approach to Market Segmentation," *Business Horizons*, Vol. 20, No. 1, 1977, pp. 61-73.
- Green, P. E. and DeSarbo, W. S., "Componential Segmentation in the Analysis of Consumer Trade-offs," *Journal of Marketing*, Vol. 43, No. 4, 1979, pp. 83-91.
- Hauser, J. R. and Urban, G. L. U., "A Normative Methodology for Modeling Consumer Response to Innovation," *Operations Research*, Vol. 25, No. 4, 1977, pp. 579-619.
- Jen, L., Chou, C., and Allenby, G. M., "The Importance of Modeling Temporal Dependence of Timing and Quantity in Direct Marketing," *Journal of Marketing Research*, Vol. 46, No. 4, 2009, pp. 482-493.
- Kamakura, W. A., "A Least Squares Procedure for Benefit Segmentation with Conjoint Experiments," *Journal of Marketing Research*, Vol. 25, No. 2, 1988, pp. 157-167.
- Kamakura, W. A., Wedel, M., and Agrawal, J., "Concomitant Variable Latent Class Models for Conjoint Analysis," *International Journal of Research in Marketing*, Vol. 11, No. 5, 1994, pp. 451-464.
- Kamakura, W. A. and Russell, G. J., "A Probabilistic Choice Model for Market Segmentation and Elasticity Structuring," *Journal of Marketing*, Vol. 26, No. 4, 1989, pp. 379-390.
- Moore, W. L., "Levels of Aggregation in Conjoint Analysis: An Empirical Comparison," *Journal of*

- Marketing Research*, Vol. 17, No. 4, 1980, pp. 516-523.
- Moriarty, M. and Venkatesan M., "Concept Evaluation and Marketing Segmentation," *Journal of Marketing*, Vol. 42, No. 3, 1978, pp. 82-86.
- Ogawa, K., "An Approach to Simultaneous Estimation and Segmentation in Conjoint Analysis," *Marketing Science*, Vol. 6, No. 1, 1987, pp. 66-81.
- Roberts, G. O. and Rosenthal, J. S., "Optimal Scaling for Various Metropolis-Hastings Algorithms," *Statistical Science*, Vol. 16, No. 4, 2001, pp. 351-367.
- Rossi, P. E. and Allenby, G. M., "Bayesian Statistics and Marketing," *Marketing Science*, Vol. 22, No. 3, 2003, pp. 304-328.
- Rossi, P. E., Allenby G. M., and McCulloch R., *Bayesian Statistics and Marketing*, John Wiley & Sons, 2005.
- Wedel, M. and Steenkamp, J. E. M., "A Fuzzy Cluster-wise Regression Approach to Benefit Segmentation," *International Journal of Research in Marketing*, Vol. 6, No. 4, 1989, pp. 241-258.
- Wedel, M. and Kamakura W. A., *Market Segmentation: Conceptual and Methodological Foundations*, 2nd ed., Amsterdam: Kluwer, 2000.