

強化電影類型偏好之互動式 推薦方法

Interactive Movie Recommendations with Strengthened
Analysis of Genre Preferences

吳怡瑾*

I-Chin Wu

臺灣師範大學圖書資訊學研究所教授

Professor

Graduate Institute of Library & Information Studies

National Taiwan Normal University

戴君樺

Chun-Hua Dai

輔仁大學資訊管理所研究生

Graduate Student

Graduate Institute of Information Management

Fu Jen Catholic University

【摘要 Abstract】

推薦技術在電子商務網站可挖掘潛在商業價值並扮演重要角色，過去廣受歡迎協同式過濾推薦系統能透過找到與使用者偏好相似的使用者，進而推薦與興趣相符合的商品，但協同式過濾不能克服冷啟動和評分稀疏的問題。本研究著眼於此，以電影推薦為研究對象，提出有別於以往混合過濾（hybrid filtering）方

* 通訊作者：吳怡瑾 icwu@ntnu.edu.tw

投稿日期：2018年08月11日；接受日期：2018年11月5日

法，透過使用者對電影類型（genre）與導演進行定錨程序以量測使用者類型偏好穩定度，提供更準確的個人化推薦結果。近期研究指出使用者的偏好穩定性將影響他們的決策過程，特別是經驗性商品；因此，是否能透過量測使用者的偏好穩定度提供有效推薦是值得探討的議題。具體來說，研究以關聯規則分析電影類型關聯，改善評分稀疏問題並透過電影類型與導演定錨程序強化計算使用者的電影類型偏好。本研究採用層級分析法（Analytic Hierarchy Process，簡稱 AHP），透過一系列成對比較進行電影類型與導演定錨程序推薦符合使用者偏好的電影。實驗結果顯示經過類型合併後能有效的改善使用者與電影評分數據稀疏性的問題，且經過導演強化類型定錨過程後能提升推薦準確度，特別是偏好穩定度低的使用者，本研究結果將可提供電子商務推薦網站參考。

E-commerce often relies upon buyer recommendation techniques given their potential commercial value as well as recommendation systems' ability to accurately predict user interests. For these systems, collaborative filtering (CF) enables websites to recommend products for target users based on the preferences of peers with similar interests. While CF can expand a user's profile of interests, it cannot overcome the problems of cold start and sparse ratings. Since recent studies have shown that the stability of users' preferences influences their decision making, especially concerning experiential goods, measuring such stability regarding these goods is worth investigating. This study thus proposes integrating genre- and director-based anchoring processes to identify users' preferences for movie genres and measure preference stability in order to provide more precisely personalized recommendations. Specifically, we overcome the problem of sparse ratings by analyzing associations among movie genres and directors. By employing the analytic hierarchy process (AHP), we thus infer user preferences for movie genres via a series of interactive genre- and director-based anchoring processes, which ultimately provides effective, precisely interactive movie recommendations. The experimental results show that the system can tackle the sparse rating problem by merging similar genres and then can increase recommendation ability by strengthening analysis of genre preferences

via directors, especially for users with unstable preferences for movie genres. The research results can serve as a reference for e-store business.

【關鍵字 Keyword】

層級分析法；導演定錨程序；類型定錨程序；偏好穩定度；推薦系統
Analytic Hierarchy Process (AHP)；Director-based anchoring; Genre-based anchoring; Preference stability; Recommendation system

壹、緒論

推薦技術在電子商務中有潛在的商業價值，若推薦系統若能準確預測出消費者對於購買商品的偏好，便能促進電子商品的交易買賣並增加公司的銷售量，最為人知曉與廣受歡迎的線上語音串流服務公司網飛 (Netflix.com) 即善於收集使用者電影偏好與播放行為進行電影推薦並獲得十分好的評價 (Molina, 2018)。推薦系統也被認為是特殊的個人化的系統，目的是基於先前評分的项目或產品的特徵來預測哪些是使用者感興趣的產品或服務 (Lekakos & Giaglis, 2006)。自 1990 年代中期以來，大量的研究都集中在如何獲得足夠數量的明確評分，並用來構建使用者的評分側寫檔 (user profile, 簡稱 UP) 進而預測使用者的喜好 (Balabanović & Shoham, 1997; Dahlen, Konstan, Herlocke, Good, Borchers & Riedl, 1998; Konstan, Miller, Maltz, Herlocker, Gordon & Riedl, 1997)。目前，一般歸類推薦技術為基於內容的過濾推薦法、協同過濾推薦法和混合式 (hybrid) 過濾方法 (Adomavicius & Tuzhilin, 2005; Deshpande & Karypis, 2004; Molina, 2018)。著名電影網站 IMDb (互聯網電影數據庫)，其中有大量會員，採用了基於內容和協同過濾的方法推薦電影。

現有的電影推薦系統著重於蒐集足夠多使用者的評分、評論資訊作為預測基準後，再以協同過濾推薦的方法參照特定使用者的背景資訊來預測其對電影的偏好。為解決協同過濾技術的缺點，即系統開始使用時會遭遇稀疏評分和冷啟動問題 (即一個人只能對所有项目的一小部分評分)，造成推薦品質的不穩定的問題，本研究將分析電影類型之間的關聯性，以解決稀疏評分之問題，進而透過系統與使用者互動蒐集使用者對電影類型的偏好，再以此評分作為進行使用者類型偏

好 UP 的調整。最近的研究顯示使用者的喜好穩定性將影響他們的決策過程，擅長行銷的商家可以學習使用者的偏好，進而替顧客量身訂造個人化的推薦；因此，量測使用者的偏好穩定度提供有效推薦是值得探討的議題（Kwon, Cho & Park, 2009; Shen & Ball, 2011; Simonson, 2005, 2008）。本研究提出以定錨理論為基礎之過濾方法來開發一個互動式的推薦系統，理論上，定錨計算將採用層級分析法（Analytic Hierarchy Process，簡稱 AHP）之成對比較方法（pair wise comparison method）概念，AHP 為 1971 年匹茲堡大學教授 Saaty 所發展出來的著名多準則決策方法（Saaty, 1977, 1980）。層級分析法是一種用於處理複雜化、非結構化和多屬性決策的決策輔助工具，AHP 使用成對比較法，以求取準則或替代方案間的相對權重或重要性（relative importance, priority weights）。使用成對比較法時可以讓決策者著重於兩個項目的比較，能夠減輕決策者的思考負擔並快速的在兩個項目中作出選擇。Simonson（2005）指出使用者的偏好通常是在選擇產品或服務過程中逐漸建構出來，因此根據使用者偏好提供客製化推薦為可進行之研究。基於以上相關研究，研究建構的系統透過一系列成對比較程序來推論使用者偏好的電影類型和導演，透過 UP 變動來分析使用者的偏好穩定度與電影推薦準確度之間的關係。

茲歸納本研究主要目的：(1) 研究透過分析電影類型之間的關聯性以解決數據稀疏性問題並預計將驗證起始評分數量與推薦精確度的關聯；(2) 研究透過以電影類型與導演為基礎的定錨程序（anchoring process）分析其與使用者類型偏好穩定度並建立推薦策略假設；(3) 研究更進一步進行導演定錨程序並分析導演與電影類型（風格）關聯度，最後分析影響推薦精確度之因素及建立考量偏好穩定度之推薦策略。

貳、文獻探討

一、推薦系統

推薦系統是一種特殊的個人化系統，依先前訂定的項目或項目的特點預測使用者對現有產品或服務的興趣（Lekakos & Giaglis, 2006）。一般情況下，使用者都有自己過去對電影的偏好的紀錄，推薦系統可以提供根據使用者過去的偏好來判定可能是使用者會感興趣的產品。推薦系統大致上可分為三種（Konstan et al., 1997）：內容為

基礎過濾推薦 (content-based filtering)、協同式過濾推薦 (collaborative filtering)，不同的推薦技術能解決不同的推薦問題，但仍各自存在問題，因此學者提出混合式推薦過濾方法 (hybrid filtering)，即結合基於內容過濾法和協同過濾法 (Adomavicius & Tuzhilin, 2005; Balabanovi & Shoham, 1997; Ma, Liu, King & Lyu, 2011)，改善上述推薦系統缺點並結合其優點，表 1 為三種推薦技術之相關文獻列表並簡介幾個近期研究。

如前言所述，在內容為基礎過濾推薦方式主要根據使用者過去的偏好，分析項目評分與物件 (item) 屬性的關聯進而建立預測模型，該方法被證實有很好的推薦效果，但缺乏偶然發現 (serendipitous findings) 的能力。近期相關研究為 Chen, Yang, Hsia, Chen & Tsai (2016) 採用 Heterogeneous Preference Embedding (HPE) 方法，提出基於使用者、歌曲與播放清單網路圖的推薦概念，也就是根據使用者對過去音樂的偏好建立推薦的播放清單 (即多首歌曲的組合)，有別於過去以單個項目 (歌曲) 的推薦方式，研究結果顯示比相關的方法有更優異的推薦效能。

協同式過濾推薦則可以根據尋找與使用者興趣相似的同好以協助使用者找到更多感興趣的物件，但存在稀疏矩陣與相關的冷啟動 (cold-start) 的問題，而混合式推薦過濾方法則是嘗試結合以上兩種過濾方法的優點與克服缺點，提供更精準與有趣的推薦結果 (Adomavicius & Tuzhilin, 2005; Balabanovi & Shoham, 1997; Deshpande & Karypis, 2004; Ma et al., 2011)。近期研究 Xue、Dai、Zhang、Huang 與 Chen (2017) 基於類神經網路提出 Deep Matrix Factorization (DMF) 模型透過計算與同好與物件的相似度進行電影與音樂推薦，模型同時收集使用者評分與隱性的回饋，透過深度語意結構進行學習與模型建立。該研究採用知名的 MovieLens 100K (ML100k)、MovieLens 10M (ML1m)、Amazon music (Amusic) 與 Amazon movies (Amovie) 資料集進行實驗，研究結果顯示推薦效果優於多個協同式過濾方法。Wu 與 Hwang (2013) 的電影推薦研究提出基於模糊理論的混和式電影偏好過濾方法 (G-Fuzzy) 以電影類別解決冷啟動評分的問題，再進行後續的協同式過濾推薦，研究結果顯示推薦精準度 (Precision) 會比未使用模糊推論情況更高；此外，研究以 α -cuts 方法能夠快速進行使用者分群以增快計算效率，該研究結果與方法提供未來設計互動式電影推薦系統之基礎。

表 1
推薦系統文獻列表

推薦系統種類	推薦方法		作者 (發表年分)
以內容為基礎	Linear regression & Feature weighting		Debnath, Ganguly & Mitra (2008)
	Explicit factor models		Zhang, Tang, Zhang & Xue (2014)
	Preference embedding based on a user-song-playlist graph		Chen et al. (2016)
協同過濾	Memory-based	User-based	Breese, Heckerman & Kadie (1998)
		Item-based & top-n	Deshpande & Karypis (2004)
		User- and item-based & top-n	Xue, et al. (2017)
	Model-based	Top-N algorithm	Yuan, Cong & Lin (2014)
		Model-based	Ma, et al. (2011)
Social network recommendation		Hu, Gao & Pan (2013)	
混和推薦	Feature-based collaborative filtering recommender		Yu, Xu, Ester, & Kriegel (2003)
	Content		Kardan & Ebrahimi (2013)
	Memory-based collaborative filtering & similarity model combines the local context		Liu, Hu, Mian, Tian & Zhu (2013)
	Naïve Bayes algorithm & Pearson correlation coefficient		Lekakos & Caravelas (2006)
	Implicit social recommendation		Ma (2013)
	Genre-based hybrid movie preference filtering approach		Wu & Hwang (2013)

二、定錨理論與偏好發展

基於心理學理論，定錨點 (anchor point) 的判定是一個以刺激與參考差異為基礎的想法 (Helson, 1964; Tversky & Kahneman, 1974)。

根據啟發式使用者一開始會使用推薦的參考點（錨），並根據他們的評估對其進行調整；因此，使用者獲得第一錨後，他或她感覺到額外的資訊後會漸進的調整。Tversky 與 Kahneman（1974）提出，從一開始的初始值到最終的答案是透過使用者不斷的評估而得到的。定錨比較有兩種效應，分別為同化效應與對比效應。

- 同化效應（assimilation effect）：任何系統性的轉移偏向定錨點時，就稱為同化效應。在消費者做選擇時，當選擇偏向初始值（定錨點），就是產生了同化效應。
- 對比效應（contrast effect）：任何系統性的轉移偏離定錨點時，就稱為對比效應。消費者做選擇時，當選擇迴避初始值（定錨點），逐漸偏離定錨點，就是產生了對比效應。

顧客是否有穩定的偏好進而影響決策在行為決策理論為重要的探討議題，相關研究指出顧客的決策過程中和自己的偏好類型有關係（Bettman, Luce & Payne, 2008; Shen & Ball, 2011; Simonson, 2005, 2008）。Rentfrow 與 Gosling（2003）研究顯示使用者的偏好與他 / 她的個性和先備知識有關係。Simonson（2005）提出顧客的偏好通常是在選擇中被建構出來的，而非顯示潛在重要的意義，根據個人偏好來提供客製化的有效性。另有研究指出顧客往往沒有明確定義或預先存在的偏好，只在他們對提供產品或服務做出選擇時會顯示其偏好（Häubl & Murray, 2003）。Simonson（2005）從尋找客制化提供最大價值的條件中發現透過客戶偏好發展維度。提出了以下四個條件：

- (1) 顧客已經擁有明確定義且合理穩定的偏好；
- (2) 顧客自己不確定自身偏好，或是不確定為他們提供的選項是否最合適自己；
- (3) 通過收集有關個人顧客資訊，供應商可以透過這些偏好來制定屬於他們的偏好的選項；
- (4) 顧客可以辨識自己顯性偏好並提供給供應商做參考。

考慮這四個條件，提供客制化是需要穩定且有良好定義的顧客偏好和顧客對自己偏好的洞察力。因此，客制化對應到在客戶的偏好發展中的兩個關鍵，分別為 (1) 偏好穩定：在這個程度上的顧客有穩定且發達的偏好與 (2) 自我洞察力：客戶對自身偏好的洞察力，包括他們對自己的偏好的穩定性和清晰度。

另外也有研究顯示人們存在有偏好的穩定度，所謂偏好穩定度是透過對相同類別商品採不同的屬性選擇的反覆量測中客觀的評估顧客選擇一致性的過程（Shen & Ball, 2011）。Wu 與 Niu（2015）提出以

定錨為基礎之混合式過濾方法 (anchor-based hybrid filtering approach, AHF) 以量測使用者電影類型偏好穩定度，該實證研究透過招募 30 位不同電影類型偏好穩定度之研究生進行電影推薦，研究結果顯示當使用者有穩定的偏好且偏好明顯時，可以根據他們過去評分的記錄進而推斷出使用者對電影類型的偏好，採用基於類別的過濾方法是較有效的推薦方法；另一方面，對於偏好不穩定的使用者來說是很難給予客製化的推薦，因此，使用研究提出的 AHP 方法可顯著改善使用者側寫檔進而推論使用者目前之電影類型偏好。該研究主要限制在仍無法有效改善推薦系統的評分稀疏問題，故本研究預計透過電影類型關聯分析與經導演強化類型定錨程序以解決此問題進而提高電影推薦精確度。

參、研究問題與架構定義

一、研究問題

本研究主要研究問題如下：

研究問題一：一般來說，大部分的商業推薦系統有許多的項目和使用者。因此，使用者項目評分矩陣將是非常稀疏的，故有評分稀疏問題 (rating sparsity problem)，即許多項目缺乏使用者評分，故透過稀疏矩陣計算出的相似性以作出預測，其準確度有待商榷。本研究為解決此問題，透過關聯規則分析電影類型與類型之間的關聯性，合併相似類型電影以強化電影屬性關聯，並可透過類型評分取代電影項目評分，解決評分稀疏問題。

研究問題二：偏好發展問題 (Preference development problem) 為推薦系統透過分析產品的評分和使用者之間的關係來預測使用者的偏好 (Cheung, Kwok, Law & Tsui, 2003)。然而，一些研究人員認為使用者偏好穩定性將影響他們的決策過程；因此，考慮使用者偏好的穩定性以提供有效推薦的問題是值得探討的議題 (Bettman et al., 2008; Shen & Ball, 2011; Simonson, 2005, 2008; Wu & Niu, 2015)。研究透過電影屬性與導演定錨程序推論使用者的內在電影類型偏好，進而提升推薦的準確率。

在電影屬性關聯分析部分，研究主要目的為透過電影類型來降低電影項目維度並透過關聯規則分析電影類型與類型之間的關聯性以合併相似類型電影，解決評分稀疏問題。我們亦分析導演風格與電影類

型之間的關聯性，以導演屬性強化分析使用者之偏好類型，以取得更精確的使用者電影類型偏好，再以此進行電影推薦。在定錨程序部分，我們使用的層級分析法（AHP），透過一系列成對比較的互動過程中定錨出使用者喜歡的電影類型或導演，藉以確定使用者對特定電影類型或導演的偏好。AHP 方法為眾多準則決策法（Multiple Criteria Decision Making, MCDM）中一個簡單而實用性的專家決策方法，可用來解決複雜及非結構化的多準則決策問題（Saaty, 1980）。本文採用 AHP 方法主要取其運算流程當中透過電影類型成對比較的過程，可降低使用者需要在眾多屬性間進行類型或電影排序的認知負擔與困難度，即層級分析法能將原本無法計量的感覺或偏好加以量化後，建立成對比較矩陣來求取兩個比較項目間的優先偏好順序。為了探討偏好穩定的問題，原有的系統定義電影的偏好是以使用者偏好的電影類型為基礎，即對電影類型有穩定和不穩定的偏好，先前研究表明經過類型定錨過程後能明顯提升推薦精確度，且頗具實務上的應用性，故以此為基礎進行本研究（Wu & Niu, 2015），其中 AHP 方法可參考本文附錄 A（Saaty, 1977, 1980）。

本研究基於此更進一步透過關聯規則分析與合併電影類型再透過類型推論使用者偏好之電影以進行導演偏好之定錨程序。由於進行成對比較時所使用的電影是由使用者評分的所有電影中以計算出最喜歡和最不喜歡兩種類型（對比效果），所以我們同時也可以從成對比較的數據中觀察使用者偏好穩定度的高低。如果使用者已有穩定的偏好，他們可能會喜歡系統透過發現他們偏好而推薦的客制化選項。如果提供的選項不符合系統推論的使用者偏好，則可能歸因於使用者的偏好不穩定，因此在採行不同推薦方法之前先識別使用者的偏好狀態是必要的。

二、研究架構

在此章節中，我們介紹互動式電影推薦系統 iMovie 架構。如圖 1 所示。

顯性偏好擷取模組：該模組主要負責管理系統上的使用者評分的行為。此模組將會記錄使用者對電影類型之評分以計算出原始 *UP* 作為使用者調整依據。

隱性定錨偏好學習模組：此模組擷取使用者對電影類型和導演的偏好，隨後識別使用者對電影類型和導演的偏好穩定度，再做出進一步的推薦。使用者經過類型與導演的成對比較後，系統會分別計算出調整過

第一次的 *UP* 和調整第二次的 *UP*。在這裡我們採用皮爾森 (Pearson correlation coefficient) 關聯分析來推斷使用者對電影類型和導演的偏好穩定度。

推薦模組：本系統將根據使用者對電影類型和導演的偏好資料來推薦電影。我們採用了以電影類型為基礎的推薦方法，透過導演成對比較強化電影類型之權重以測得使用者的最終偏好，結合後端資料庫採用內容式過濾方法推薦相關電影給使用者。

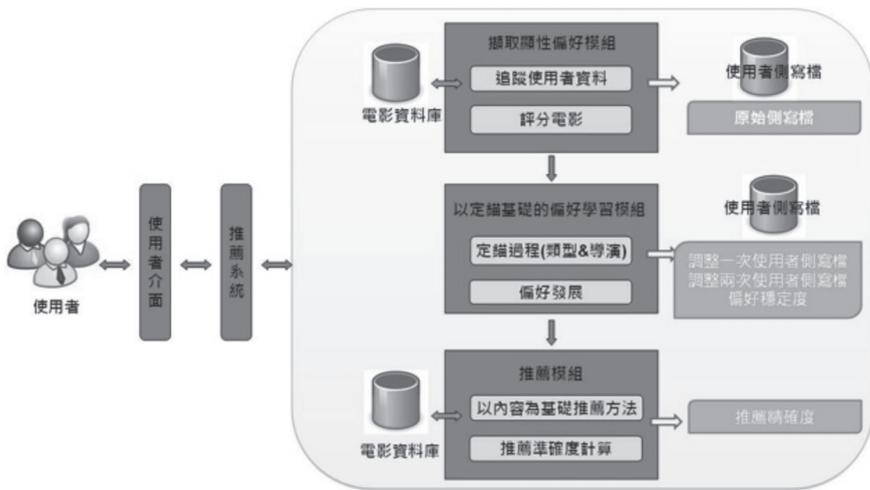


圖 1 iMovie 系統模組與流程

肆、強化電影類型偏好分析之互動式電影推薦程序

本章節主要針對研究提出之 iMovie 系統模組進行強化類型屬性關聯之互動式電影推薦程序的介紹，詳細步驟如下所述。

第一步：計算出使用者對每種電影類型的平均評分

每部電影有一至三種電影類型，計算出使用者對每種電影類型的平均評分，使用公式 (1)：

$$Genre_{user,i,j} = \frac{\sum_{k=1}^{n_j} r_k}{n_j} \times Genre_j \quad (1)$$

其中 r_k 表示評分分數屬於類型 j 電影， n_j 是屬於 j 類型的電影數， $Genre_{user\ i, j}$ 表示第 i 個用戶對電影類型 j 的評分、 $Genre_j$ 是該電影類型的合併係數（若無被合併狀況即為 1）。值得注意的是，如果有一個特定的電影類型沒有被評分過，我們會給該電影類型一個平均評分，即為使用者對所有類型電影的平均評分以解決空白值問題。

第二步：建立使用者電影類型的側寫檔 (UP)

每位使用者的電影的偏好被表示為一組電影類型的分數的 UP ，如公式 (2)：

$$UP_{user_i} = \{Genre_{i,1}, Genre_{i,2}, \dots, Genre_{i,n}\} \quad (2)$$

電影一般有一個或多個類型，公式 (2) 概括了使用者目標電影的評分值，接著我們會計算類型平均評分。公式 (3) 中， $Genre_{i,j}$ 代表 $movie_t$ 中第 j 個已經被 $user_i$ 評分的類型。 $BV_{i,t}$ 代表屬於目標 $movie_t$ 的類型總數， BV 是 UP 的子集，包含使用者 i 對 $movie_t$ 的類型評分。 $User_i$ 被評分和 $P_{user_i,t}$ 代表的是電影 t 的預測分數。推薦電影的值是來自於公式 (2)，其中還沒被使用者評分的電影必須被填上電影所屬類型的平均評分。

$$P_{user_i,t} = \frac{\sum_{j \in BV_{i,t}} Genre_{i,j}}{|BV_{i,t}|} \quad (3)$$

第三步：電影類型偏好定錨 (Genre-based Anchoring)

進行 Anchor 時，會列出使用者原始評分中最喜歡和最不喜歡的電影類型中的電影，即採用對比效果；透過兩兩成對比較過程中讓使用者給予評分，降低評分的負擔。研究之電影類型定錨過程與畫面，分別如圖 2 與圖 3(a) 所示。

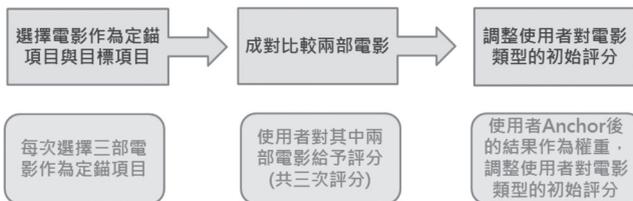


圖 2 電影類型定錨過程



圖 3(a) 電影類型定錨畫面



圖 3(b) 電影導演定錨畫面

第四步：調整以電影類型為基礎的側寫檔 (UP)

經過層級分析法計算的電影類型權重後，我們會正規化使用者以電影類型為基礎的 UP ，再以正規化的 UP 與先前步驟獲得的權重相乘。因為某些電影類型在定錨過程中並未被選擇，為了避免失去每個類型原始 UP 的相對順序，我們會使用公式 (4) 進行正規化處理。其中 r_i 為類型 i 的評分、 n 為電影類型總數、 GR_i 為經過正規化的類型 i 的評分。

$$GR_i = \frac{r_i}{\sum_{i=1}^n r_i} \quad (4)$$

經過正規化使用者每個類型的原始評分後，再乘上從層級分析法所產生的權重進行 UP 調整。值得注意的是，其中在定錨過程中被選擇類型將被乘上其從 AHP 產生的權重，如公式 (5)。為了保持未被選擇的類型的相對順序，未被選擇的類型的評分將被乘以最高權重。 GR_j 為類型 j 經正規化的評分、 w_j 為類型 j 從 AHP 產生的權重、 pw_j 為類型 j 的權重比例。

$$pw_j = GR_j \times w_j \quad (5)$$

第五步：導演強化類型分析定錨 (Director-based Anchoring)

本步驟目的為透過分析導演風格對應電影類型調整以 UP ，因此可以透過導演強化電影類型之關聯。進行第二次 anchor 時，會列出使用者原始評分中評分較高且評分部數最多、第二與第三多的電影導演，作為使用者進行 Director-based Anchoring 時第一、第二以及第三喜歡的

導演並進行成對比較，即為採用同化效果。接著使用者兩兩成對比較過程中給予評分，研究使用 Saaty 相對重要性尺度 (Saaty, 1977)，共有三次評分，成對比較之導演定錨畫面如圖 3(b) 所示。研究會建構使用者對該電影導演的評分的矩陣，並透過層級分析法 (AHP) 計算導演偏好的權重，並再次調整 UP，此步驟採用方法同第三步驟。

最後研究使用第二次導演成對比較後的評分作為該導演的權重，對應該位導演的導演風格 (電影類型) 後乘上該導演的權重以便調整類型評分，如公式 (6)。pw_j 為類型 j 經第一次類型定錨後的權重比例、DG_{k,j} 為該導演 k 對應類型 j 的權重、w_d 為導演的權重比例。gw_j 為經兩次成對比較後類型 j 的權重比例，m 為每回合成對比較之導演數量。

$$gw_j = pw_j + \sum_{j=1}^m (DG_{k,j} \times w_d) \quad (6)$$

其中，DG_{k,j} 為該導演 k 所導的電影之類型 j 的分佈比重，G_{k,j} 為導演 k 導過的電影中屬於類型 j 的電影數量，n 為電影類型總數，計算公式如公式 (7)：

$$DG_{k,j} = \frac{G_{k,j}}{\sum_{j=1}^n G_{k,j}} \quad (7)$$

第六步：計算使用者類型偏好穩定度

研究分別使用的定錨理論的對比和同化效果，以獲得使用者對電影類型之偏好。從技術上來說，使用者以類型為基礎的 UP 將透過成對比較類型與導演的結果進行調整，因此我們可以分析原始 UP 和調整過的 UP 之間變化的差異，瞭解使用者對電影類型的偏好是否穩定。我們採用皮爾森相關係數來分析使用者 i 的穩定度，即 Stability_i。相關值域的範圍為 [-1,1] 內，較容易識別偏好變化，如果係數高於或等於 0.7，使用者的偏好是高度穩定的；相關係數低於 0.7，使用者的偏好是中度或低度穩定。穩定度公式如公式 (8) 所示，R_{i,j} 為使用者 i 在原始 UP 中對類型 j 的評分，R'_{i,j} 為使用者 i 調整後 UP 中對類型 j 的評分，m 為電影類型數目。

$$Stability_i = \frac{\sum_{j=1}^m (R_{i,j} - \bar{R}_i)(R'_{i,j} - \bar{R}'_i)}{\sqrt{\sum_{j=1}^m (R_{i,j} - \bar{R}_i)^2 \sum_{j=1}^m (R'_{i,j} - \bar{R}'_i)^2}} \quad (8)$$

本研究依據偏好穩定程度並根據過去研究經驗將使用者分為偏好穩定者和偏好不穩定者 (Wu & Niu, 2015)。

伍、實驗設計與評估方法

一、實驗設計與流程

本實驗過程共分為三個實驗，如表 2 所示，表 3 為詳述實驗三的推薦方法，目的在分析使用者進行類型與導演成對比較後調整的 *UP* 是否會影響最後推薦電影的精確度。本實驗中 iMovie 的系統框架核心是結合定錨過程和以類型為基礎的推薦方法，提出的定錨過程是透過一系列電影成對比較後，用以衡量使用者對電影類型和電影導演的偏好。

表 2
實驗設計

實驗	實驗一 (Experiment 1)	實驗二 (Experiment 2)	實驗三 (Experiment 3)
前端策略	Genre-based (以類型為基礎) 評分電影 1、2、3 部 (共三組)	Genre-based (以類型為基礎) 評分電影 1、2、3 部 (共三組)	Genre-based (以類型為基礎) 評分電影 1、2、3 部 (共三組)
定錨過程		定錨過程 (類型)	定錨過程 (類型 & 導演)
推薦策略	基於內容推薦法	基於內容推薦法	基於內容推薦法

表 3
各實驗之推薦方法

	方法	描述
前端推薦策略	以類型為基礎 (Genre-based)	<ul style="list-style-type: none"> 基於使用者對電影類型的評分得到使用者對電影類型的基礎偏好。
	以類型和導演為基礎進行定錨 (Genre-based & Director-based Anchoring)	<ul style="list-style-type: none"> 以定錨的對比和同化效果衡量使用者對電影類型的偏好。 利用定錨過程的結果調整該使用者對電影類型的基礎偏好。

後端推薦演算法	以內容為基礎的過濾法 (Content-based filtering)	<ul style="list-style-type: none"> • 以使用者原始及調整後對類型的評分，衡量使用者對電影類型的偏好。 • 以類型為基礎從電影資料庫中過濾出使用者偏好的電影，並推薦給使用者。
---------	--------------------------------------	--

二、受試者評估指標

本實驗所使用的前端電影推薦系統 iMovie 為實驗室建立專為收集使用者對電影的評分，我們招募 50 位大學與研究所學生並從中篩選出 31 位喜愛且經常看電影的學生，針對本實驗系統 iMovie 電影資料庫中的電影進行評分的任務，共計 938 部電影。本文選擇對象盡量男生與女生比例均衡，並且選擇電影喜愛度評等為「非常喜歡」或「喜歡」的使用者，五等第評等為「非常喜歡」、「喜歡」、「普通」、「不喜歡」、「非常不喜歡」五個等級；最後為半年內有觀看電影的紀錄。故根據篩選後資料顯示 31 位受試者中，男生與女生比例分別為 58% 與 42%，年齡均為 21-30 歲之間的學生，全數在一年內均為觀看五部以上電影，其中有 5 人（16%）一年內會看 10 部以上電影。研究使用以內容為基礎的推薦過濾法推薦電影給使用者並以精確率（precision）評估推薦結果。在使用者經過兩次成對比較（類型、導演），系統共可以得到三組使用者不同時期的 UP，分別是原始 UP、經第一次類型成對比較後調整 UP 以及經過第二次導演成對比較後調整 UP，每組 UP 中共有 19 種電影類型之評分。研究將以該使用者 UP 之電影類型分數順序依序從高分至低分給予 $Score_{i,j}$ ，即使用者 i 對於類型 j 之評分，前十喜好電影類型依照喜好程度依序由高到低給予 9 至 0 分，其中 9 分為最喜愛；而該使用者之不喜愛電影類型依不喜愛程度依序由高到低給予 -9 至 -1 分，其中 -9 分為最不喜愛。我們將以 $Score_{i,j}$ 總和找出 iMovie 系統電影資料庫中過濾出符合使用者偏好之電影並推薦給使用者。電影評分計算如公式 (10)，其中 $Movie_{score, i}$ 為使用者 i 對該電影之評分總和， $score_{i,j}$ 為使用者之喜好或不喜好類型 j 之對之應分數。

$$Movie_{score,i} = \sum_{j=1}^n score_{i,j} \quad (9)$$

研究依公式 (9) 中 $Movie_{score, i}$ 排序取前十部電影推薦給使用者 i ，在使用者評分系統推薦之電影列表過後，我們將使用使用者對推薦列表的平均評分做為評估指標，比較以電影類型為基礎和定錨混合過濾推薦法的有效性。

陸、強化類型屬性關聯與偏好分析結果

一、以關聯分析降低電影類型重複率

為解決電影類型之間重複率高的問題，研究使用 Apriori 演算法分析電影類型間的關聯性，進而將相似類型統整為同一類型。重新統整過的類型間的關聯性也會降低，成為獨立不模糊的類型。例如：家庭片和溫馨片、戰慄片和驚悚片經過關聯分析後可歸為同類型，以減少使用者對於類型的模糊不確定性，能更準確地在類型與類型之中選出喜歡或不喜歡；此外，透過合併電影類型，能降低使用者一開始需要評分的電影數量，減少使用者的負擔。表 4 顯示透過分析電影類型關聯之後，我們從 30 種電影類型降低為 19 種電影類型。

表 4
合併電影類型後的電影類型與部數

類型	部數		類型	部數	
劇情	Plot	373	奇幻	Fantasy	81
動作	Action	340	恐怖	Horror	72
喜劇	Comedy	237	動畫	Animation	46
驚悚	Thriller	205	浪漫	Romantic	45
冒險	Adventure	183	戲劇	Drama	41
懸疑	Suspense	137	戰爭	War	32
犯罪	Crime	124	勵志	Inspirational	28
科幻	Science	123	溫馨家庭	Family	21
愛情	Love	96	紀錄片	Documentary	14
音樂歌舞	Musical	29			

共 19 種類型，938 部電影

二、導演風格與電影類型關聯分析

研究分析導演風格與電影類型間的關聯，在使用者進行第二次以導演為基礎的定錨過程後，以此權重去調整使用者以電影類型基礎的 UP，即本研究之以導演強化電影類型偏好分析。研究針對資料庫中超

過或等於五部作品的導演進行導演風格與電影類型的關聯分析，未進行導演風格與電影類型的關聯分析之導演的權重則一律為 0，每位導演與電影類型關聯分數如公式 (8) 所示。在使用者進行第二次以導演風格的定錨時，將以表 5 之對應類型做為導演風格權重做為調整以類型為基礎的 UP 。

表 5
20 位電影導演之風格對應表

導演	對應電影類型	權重	導演	對應電影類型	權重
大衛·芬奇	Plot	0.280	泰倫斯·馬利克	Plot	0.429
丹尼·鮑伊	Plot	0.250	麥可·漢內克	Plot	0.381
史蒂芬·史匹柏	Adventure	0.162	傑森·瑞特曼	Plot	0.381
伍迪·艾倫	Comedy	0.380	凱薩琳·畢格蘿	Thriller	0.238
艾方索·柯朗	Thriller、 Plot、 Science、 Fantasy、 Family、 Drama	0.143	達倫·阿羅諾夫斯基	Plot	0.214
李安	Romantic	0.276	彭發、彭順	Thriller、 Suspense	0.286
彼得傑克森	Action、 Adventure	0.231	湯姆·胡柏	Drama	0.182
昆丁·塔倫提諾	Thriller	0.250	葛斯·范·桑	Family	0.303
柯安兄弟	Comedy、 Plot	0.238	詹姆士·柯麥隆	Action	0.273
朗霍華	Drama	0.154	喬柯恩	Crime	0.333

三、實驗結果

(一) 評估使用者之偏好穩定度

我們使用 Pearson 相關係數計算出使用者之偏好穩定度。當相關係數高於或等於 0.7 時，代表使用者的偏好隨著時間推移與過去的偏好有強烈的關係，不容易隨著時間改變自身的偏好。反之，當相關係

數低於 0.7 時，代表使用者的偏好容易隨著時間或其他原因而改變。因此我們依據使用者之偏好穩定度歸類為偏好穩定使用者（穩定度 ≥ 0.7 ）和偏好不穩定使用者（穩定度 < 0.7 ）。

本實驗將計算出使用者兩種偏好穩定度，分別是經過第一次類型定錨後之偏好穩定度與經過第二次導演定錨後之偏好穩定度。本實驗判斷使用者之偏好穩定度的方式是取決於兩次偏好穩定度，當同一使用者兩次（類型定錨過程、導演定錨過程）偏好穩定度皆低於 0.7 時，則會將此使用者歸類為偏好不穩定者；反之，當使用者其中一個偏好穩定度大於 0.7 時，該使用者則為偏好穩定者。表 6 為本實驗中 31 位實驗者之偏好穩定與不穩定之人數分布狀況。本研究判斷使用者之偏好的方式能中和兩次的偏好穩定度，計算出最後偏好穩定的人數分布狀況約為 80.6%，和先前 Wu 與 Niu（2015）研究的結果一致的是偏好不穩定使用者的佔有比例相對於偏好穩定的使用者來說較少，從數據發現本研究之偏好不穩定使用者的比例遠低於偏好穩定使用者。由偏好穩定度分布情形可發現，經過導演定錨過程後能改變使用者對電影類型的偏好且有一定的高比例能更符合使用者之真正的電影類型偏好。

表 6
偏好穩定與不穩定人數分布

	人數	佔有率
全部實驗者	31	100%
偏好穩定者	25	80.6%
偏好不穩定者	6	19.4%

(二) 起始評分電影部數對推薦準確度的影響

本實驗研究新進使用者對每個類型（共 19 種）的評分部數是否對最後推薦準確度有明確影響。因此本實驗隨機抽出十位實驗者分別進行兩次實驗任務，其中差別在於對於類型評分部數分別為一部和三部，最後需要評分的總部數為 19 部和 57 部。圖 4 顯示十位實驗者之兩次（評分一部和三部）的平均推薦準確度。系統使用 10 位實驗者之分別原始、經類型與經導演 Anchor 調整後的 UP 進行電影推薦，實驗者再針對電影評分後即得到三次推薦列表之平均評分。由圖 4 之折線圖可以看出來，起始評分部數對於推薦準確度的影響並不大，因此可以推

斷新進使用者的評分部數並不需要太多部，進而能降低使用者的評分負擔與花費時間。

觀察 1：新進使用者第一次使用本電影推薦系統時，只需要評分 19 部電影（即各類型評分一部），其結果與評分 57 部電影（即各類型評分 3 部）的推薦準確度沒有顯著差異。從結果可以看出來本系統能利用少量的數據推薦出符合使用者偏好之電影。

觀察 2：此實驗結果能證實透過關聯規則分析電影類型與類型之間的關聯性以合併相似類型電影，能夠強化電影屬性關聯並透過類型評分取代電影項目評分，解決評分（數據）稀疏問題，其中以導演強化類型推薦效果是最好的。

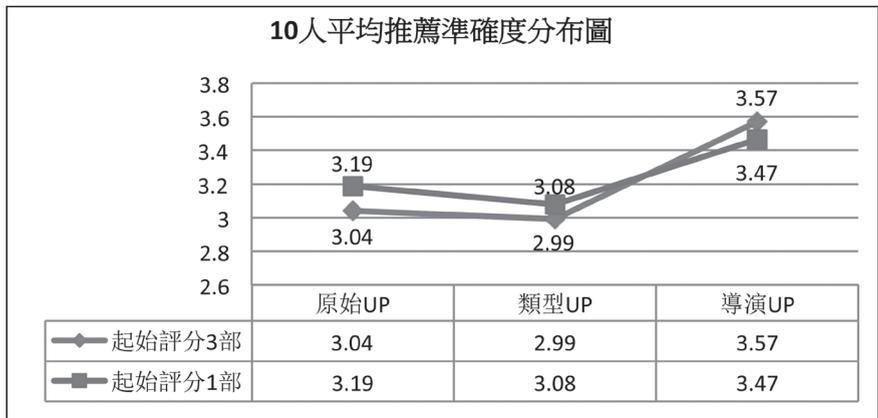


圖 4 10 位實驗者之平均推薦準確度

（三）定錨過程對推薦準確度之影響分析

本節分析使用者從開始使用實驗系統 iMovie 後，經過第一次類型定錨過程與第二次導演定錨過程後，使用者對類型偏好的變動情形以及對於最後推薦準確度之影響。本實驗所使用評估使用者對於電影推薦系統 iMovie 之標準為使用者對推薦列表之評分，系統採用使用者之三組不同的 UP（原始未調整、經類型定錨調整以及經導演定錨調整）推薦出三組電影列表（每組有 10 部電影），使用者最後對這 30 部電影進行評分，且使用者無法得知哪些電影是由哪一組 UP 推薦而出的。最後為分析使用者對推薦列表之評分狀況，即推薦結果之滿意度。

每位使用者會有進行三次電影評分的平均評分，第一回合（Round 1）平均評分是對原始未調整的 UP 推薦的電影的評分、第二回合

(Round 2) 平均電影評分是對經類型定錨調整的 *UP* 推薦的電影的評分，第三回合 (Round 3) 平均電影評分則是對經導演定錨調整的 *UP* 推薦的電影的評分。我們根據三回合評分的結果，將 31 位使用者分為三組，根據表 7 與圖 5 顯示使用者之評分平均分數狀況可以看出三組使用者的評分特徵如下：

第一組評分特徵：使用者 Round 1 比 Round 2 評分高，且 Round 3 之評分低於 Round 1。第一組使用者在經過第一次類型定錨過程後的評分降低，且經過導演定錨過程後亦降低評分分數，該組人數是最少的，共計二人。

第二組評分特徵：使用者 Round 1 比 Round 2 評分高，但 Round 3 之評分高於 Round1。第二組使用者在經過第一次類型定錨過程後的評分降低，但經過導演定錨過程後會提高評分分數，該組人數共計十人。

第三組評分特徵：使用者 Round 2 比 Round 1 評分高，但 Round 3 之評分高於 Round1。第三組使用者再經過第一次類型定錨過程後的評分會比未經過定錨過程的推薦電影之評分高，且經過第二次導演定錨過程之評分會更高，該組人數是最多，共計 19 人。

表 7
使用者對推薦列表之平均評分

組別	使用者人數	比例	Round1 平均分數	Round2 平均分數	Round3 平均分數
1	2	6.5%	2.90	2.15	2.40
2	10	32.3%	3.31	2.74	3.56
3	19	61.2%	2.82	3.14	3.51

研究摘要三組結果如下：

第一組：第一組的評分結果顯示 *iMovie* 系統推薦給該組使用者的電影沒有完全符合使用者之偏好，經過類型和導演的定錨過程後沒有明顯提升使用者對推薦電影的評分。但第一組使用者的人數僅有二位，僅占全部使用者中 6.5%，之後可以針對此個案進行研究與探討。

第二組：第二組使用者的評分分數在經過類型定錨過程後有下降的趨勢，但再經過導演定錨過程後的評分分數有提高的現象，甚至比未經定錨過程的評分分數還要高出許多，代表使用者經過導演定錨過程後能夠提升推薦的準確度。

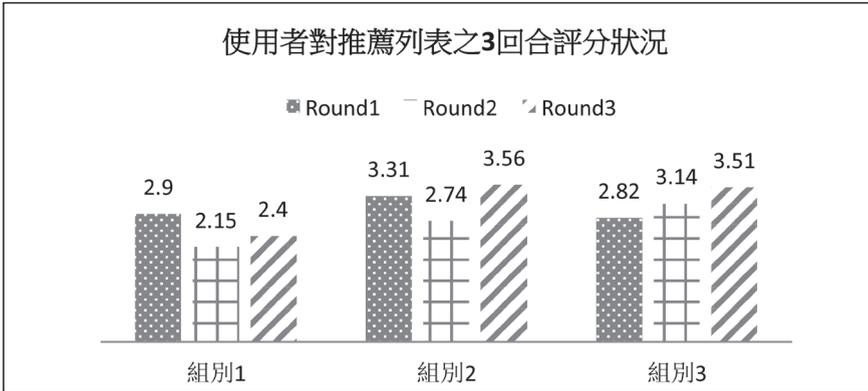


圖 5 使用者對推薦列表之 3 回合評分狀況

第三組：第三組使用者的評分分數從 Round 1 到 Round 3 的分數有漸漸提高的趨勢，代表使用者經過類型定錨過程後能提升推薦準確度，而再經過第二次的導演定錨過程後更能提升推薦準確度。

從第二組和第三組使用者的評分狀況可以發現，最後第二組 Round 3 的平均分數和第三組之 Round 3 的平均評分不相上下。研究發現只要經過導演定錨過程之後都能夠有效地提升推薦電影的準確度，經過導演定錨過程後能夠推薦更符合使用者喜好或是能引起興趣與共鳴的電影。以下歸納相關觀察與討論。

1. 偏好穩定者經過類型定錨過程後推薦準確的因素

從圖 5 可以發現組別 2 和組別 3 的使用者在經過第二次導演定錨過程後能提升最後的推薦準確度，但經過第一次類型定錨過程後組別 1 和組別 2 之偏好穩定實驗者的推薦準確度有下滑的趨勢，因此針對此現象我們提出了可解釋的因素。

組別 1 的使用者共有二位、組別 2 的使用者共有十位，且這 12 位使用者皆為偏好穩定的使用者，相較於另外 13 位偏好穩定使用者（組別 3）來說，進行第一次類型定錨過程後推薦準確度降低的情形較為特別。在實驗者填寫的前測問卷中第 16 題詢問使用者針對看某部電影的因素（電影類型、電影摘要、男女主角、導演和票房）進行排序，我們從中發現了這 12 位偏好穩定使用者在決定看某部電影的第一個決定因素絕大部分都不是「電影類型」，因此我們可以推斷，使用者在決定看某部電影的決定因素並非「電影類型」，主要是因為本實驗中類型定錨過程使用的是對比效果，也就是會列出使用者最高分和最低分的電影類型做成對比較，而這 12 位使用者第一個考慮因素並非「電

影類型」，因此對電影類型的偏好較沒有那麼明顯，因此這些使用者在經過第一次類型定錨過程時並不會顯著提升推薦準確度，甚至降低。相反的，組別 3 中偏好穩定的 13 位使用者，在經過第一次類型定錨過程後的推薦準確度皆有提升的趨勢，從這 13 位使用者看電影的決定因素排序可以發現，絕大多數的使用者都將「電影類型」視為決定是否看某部電影的第一決定要素。因此第一次類型定錨過程使用的同化效果會顯著的提升推薦準確度。

2. 影響偏好不穩定者經過類型定錨過程後推薦準確的因素

實驗中組別三中有六位偏好不穩定的使用者，在經過第一次類型定錨過程後的推薦準確度皆有提升的趨勢，從前測問卷中發現這六位使用者看電影的決定因素排序絕大多數的使用者都沒有「電影類型」視為決定是否看某部電影的第一決定要素。從偏好不穩定的使用者決定看電影的決定因素發現，偏好不穩定的人對電影屬性的偏好較廣泛，容易隨著情境而接受大家的意見，屬於多準則評估的使用者，例如容易因為電影摘要、或者是票房等因素而決定是否看該部電影。

3. 制定適合偏好穩定與偏好不穩定的推薦策略

由前兩小節發現，我們可以將使用者先分為偏好穩定的使用者與偏好不穩定的使用者，接著可以從使用者判斷決定看電影的因素排序第一是否為「電影類型」進行第二次分類，藉此我們將使用者分為三種類型使用者。

類型 1：偏好穩定且將「電影類型」當作決定的第一因素的使用者，適合先經過類型定錨過程（對比效果）再進行導演定錨過程（同化效果）。

類型 2：偏好穩定且「電影類型」並非決定的第一因素的使用者，此類型的使用者並不容易受到類型影響，因此進行導演定錨過程（同化效果）後比較容易提升其推薦準確度，進行類型定錨過程（對比效果）對於推薦準確度並沒有太大的幫助。

類型 3：偏好不穩定且容易受到大眾意見影響者，適合經過類型定錨過程（對比效果）再進行導演定錨過程（同化效果），可以達到最好的推薦準確度。

4. 偏好穩定度與推薦準確度的關聯性

本實驗中 31 位實驗者中有六位偏好不穩定的使用者（如表 8），經數據分析發現這六位偏好不穩定使用者的實驗結果皆在組別 3 中。這六位使用者經過第一次類型定錨過程後推薦準確度都有提高的跡象，且經過第二次導演定錨過程後的推薦準確度也有提高（如表 8）。

因此可以推斷偏好不穩定的使用者在經過兩次（類型和導演）定錨過程後能夠提高推薦準確度，推薦系統可根據使用者調整後的 UP 推薦出更準確符合使用者偏好的電影，這與先前的研究發現一致，偏好不穩定的使用者經過類型定錨過程後能找出使用者較明確的偏好（Wu & Niu, 2015），本研究再加入導演定錨過程強化使用者對類型的偏好後能找推薦出使用者更喜歡的電影。

表 8
偏好不穩定使用者之推薦評分與偏好穩定度

	Round 1 平均分數	Round 2 平均分數	Round 3 平均分數
User 9	3.0	3.0	3.0
User 11	2.3	4.2	4.3
User 14	3.0	3.0	3.4
User 15	2.2	3.0	3.8
User 19	3.4	3.4	3.7
User 23	2.7	2.7	3.2

（四）使用者挑選電影的考慮順序

我們從問卷中發現了使用者挑選電影的考慮順序與實驗結果有著特別的關聯，例如問題 16：針對電影類型、導演、卡司、票房和摘要五個因素，回答挑選電影的考慮順序為何？圖 6 為使用者回答情況分布。和問題 14：使用者是否會因為導演而去看該導演所導的電影？答案分為非常不容易、不容易、普通、容易和非常不容易，其人數分別為 1 人、13 人、10 人、6 人與 1 人。

觀察 1：從問題 15 的回答狀況發現，電影類型通常為使用者前兩個考慮的順序；而導演通常不是使用者考慮看該部電影的首要要素。

觀察 2：從問題 14 的回答的狀況上看得出來使用者普遍不容易因為導演而去看該導演所導的電影，通常電影導演並非使用者的考慮因素之一，問卷中第 18 題問使用者是否有特別喜好的導演（填寫名稱），但大多數的使用者（約佔 81%）沒有填寫導演名稱，代表普遍使用者對導演並沒有特殊的偏好。

整體觀察：在實驗結果中能發現大部分使用者（佔 93.5%）在經過第二次導演定錨過程後能大幅提升推薦準確度，雖然使用者不容易因為

導演而選擇看該部電影，但在實驗過程中使用者可以透過導演看到導演導過的電影進而對導演產生好感，在使用者進行導演定錨過程中導演自然而然能和電影類型產生緊密的連結。因此我們推測導演風格能直接影響使用者對電影類型的偏好，進而能更符合使用者的偏好；另外根據問卷顯示電影摘要也將會是未來可參考的研究方向。

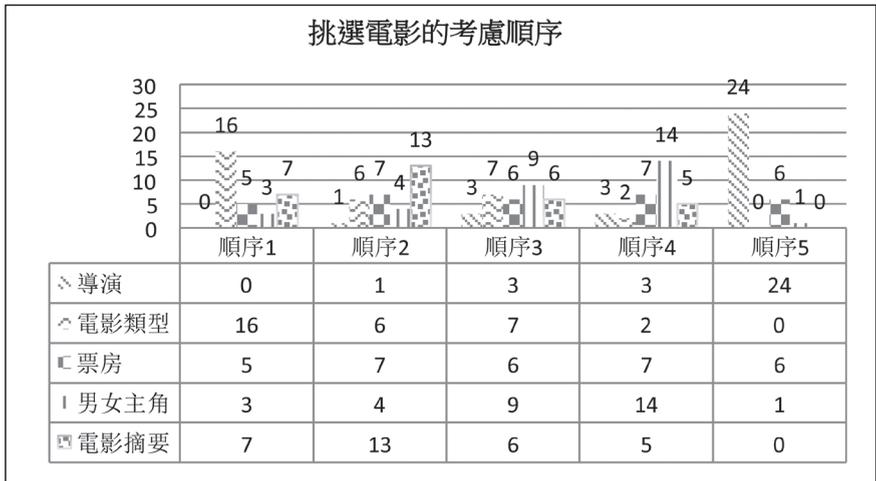


圖 6 挑選電影的考慮順序

四、綜合討論

討論 1：在實驗的第一階段中，我們比較了使用這經過第一次類型定錨過程和第二次導演定錨過程後穩定度的變化，藉由穩定度的變化觀察出使用者在進行第一次類型定錨過程後偏好穩定與不穩定者占有比例約為一半，但進行第二次導演定錨過程後幾乎大多數使用者的偏好穩定度皆會大幅改變，轉為偏好穩定的使用者，這代表著導演定錨過程能找出使用者原本不知道的偏好類型，擴展出使用者的偏好廣泛度。

討論 2：本實驗進行了起始部數的測試，另外找出十位實驗者進行不同起始部數對推薦準確度的影響，從該實驗數據發現（如圖 4），同一位使用者的起始需評分部數分別為一部和三部時，並沒有明顯影響最後的推薦準確度，證明起始部數並不需要評分至三部之多即可有準確的推薦，評分越多電影並不會提升推薦的準確度。此實驗結果能證實透過關聯規則分析電影類型與類型之間的關聯性以合併相似類型電

影能夠強化電影屬性關聯並透過類型評分取代電影項目評分，藉此可以解決評分數據稀疏的問題，用少量的起始數據即可推薦給使用者。

討論 3：有別於先前實驗結果，偏好穩定的使用者經過第一次類型定錨過程後能提升準確度，本實驗中發現有 12 位偏好穩定者經過第一次類型定錨過程後有降低推薦準確度的現象。進一步研究發現，影響這 12 位偏好穩定使用者的推薦準確度的因素為使用者本身考慮看電影的決定因子，這 12 位偏好穩定的使用者並沒有將「電影類型」視為自己決定看某部電影的重要因素，相反的另外 13 位使用者在決定看某部電影時第一個考慮的因素絕大部分都是「電影類型」。由此可見，使用者考慮看電影的因素對經過類型定錨過程後降低或提升推薦準確度有很大的影響。

討論 4：偏好不穩定的使用者在本實驗中只有六位，僅佔所有實驗者 19.4%。但這六位偏好不穩定者經過本實驗推薦系統兩次（類型和導演）定錨過程後能夠提高推薦準確度，尤其是經過第二次導演定錨過程後能更顯著提升推薦準確度。由此可推測偏好不穩定的使用者在經過導演定錨過程後，能被推薦出更符合偏好的電影。

柒、結論與未來展望

本研究提出以定錨為基礎的混合過濾推薦方法，並以電影屬性（導演）強化使用者以類型為基礎的偏好。研究首先透過分析類型與類型之間的關聯性合併類型，解決電影類型之間重複率高的問題，相對能減少新進使用者須評分的部數。研究接著分析導演風格與電影類型之間的關聯性，以導演屬性強化使用者之偏好類型，即導演隱含著電影風格與所屬類型，研究以導演與類型間的相關係數調整使用者之偏好類型評分以取得更精確的使用者電影類型偏好，再以此結果推薦電影給使用者。在偏好量測部份，研究定義電影類型偏好變動的程度評估使用者偏好穩定或不穩定，研究觀察使用者對電影類型與導演的偏好穩定度是否會影響最後的推薦準確度。

本研究所使用的電影資料庫中的電影資料雖有 938 筆，但同一個導演的電影部數並不多，期望以後可以擴展電影資料庫與導演數目，讓導演這個電影屬性能有更多的選擇，達到更好更有效的準確度。在受試者樣本部分，研究主要選擇大學部或研究所學生，研究受限於需要現場指導受試者如何操作系統，故限制了受試者族群，研究未來將擴大實驗對象以驗證實驗結果是否可以推論在大多數族群上以增加實

務應用之價值，唯研究基於 AHP 概念提出之方法因為操作簡易可提供電影推薦相關應用程式開發參考應用之。Simonson (2005) 提出的偏好發展，即使用者自身的偏好穩定度和偏好洞察力；Shen 與 Ball (2011) 的研究顯示當顧客存在有偏好穩定的信念時，推薦的效果會優於低偏好穩定信念的顧客。未來我們可以增加自我偏好洞察力維度用以分析不同類型使用者適合的推薦策略；在操作上，預計在前測問卷的部分加入偏好量表判斷使用者的偏好穩定度（張嫩嫩，2015），可以藉此判斷使用者適合先進行類型定錨過程或是導演定錨過程，也可以改變使用者進行類型或導演定錨過程時適合使用同化效果或是對比效果，進而達到更好的推薦效果與準確度。隨著偏好穩定度和自我洞察力結合，我們可以制定更精準的推薦的策略，為不同類型的客戶提供市場營銷或電子商務網站的推薦策略。

參考文獻

- 張嫩嫩 (2015)。電影偏好結構多樣性及開放性之量表建立與驗證（未出版之碩士論文）。國立台灣大學圖書資訊學研究所，臺北市。
【Chang, M. M. (2015). *The Development and Validation of Preference Diversity and Openness to Novelty Scale for Movie Preference Structure* (Unpublished master's thesis). National Taiwan University, The Graduate Institute of Library and Information Science, Taipei. (in Chinese)】
- Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734-749.
- Atthirawong, W., & MacCarthy, B. (2002). An application of the analytical hierarchy process to international location decision-making. In M. Gregory (Ed.), *Proceedings of The 7th Annual Cambridge International Manufacturing Symposium: Restructuring Global Manufacturing* (pp. 1-18). Cambridge, England: University of Cambridge.
- Balabanović, M., & Shoham, Y. (1997). Content-based, collaborative recommendation. *Communications of the ACM*, 4(3), 66-72.
- Bettman, J. R., Luce, M. F., & Payne, J. W. (2008). Preference construction and preference stability: putting the pillow to rest. *Journal of Consumer Psychology*, 18(3), 170-174.

- Breese, J. S., Heckerman, D., & Kadie, C. (1998). Empirical analysis of predictive algorithms for collaborative filtering. In *Proceedings of the Fourteenth conference on Uncertainty in artificial intelligence* (pp.43-52). Madison, WI, USA.
- Chen, C. M., Yang, C. Y., Hsia, C. C., Chen, Y., & Tsai, M. F. (2016). Music playlist recommendation via preference embedding. In *Proceedings of the Poster Track of the 10th ACM Conference on Recommender Systems*, Boston, MA, USA.
- Cheung, K. W., Kwok, J. T., Law, M. H., & Tsui, K. C. (2003). Mining customer product ratings for personalized marketing. *Decision Support Systems*, 35(2), 231-243.
- Dahlen, B. J., Konstan, J. A., Herlocke, J. L., Good, N., Borchers, A., & Riedl, J. T. (1998). *Jump-starting MovieLens: User benefits of starting a collaborative filtering system with dead data* (TR98-017). University of Minnesota.
- Debnath, S., Ganguly, N., & Mitra, P. (2008). Feature weighting in content based recommendation system using social network analysis. In *Proceeding of the 17th International Conference on World Wide Web* (pp. 1041-1042). Beijing, China.
- Deshpande, M., & Karypis, G. (2004). Item-based top-n recommendation algorithms. *ACM Transactions on Information Systems*, 22(1), 143-177.
- Helson, H. (1964). *Adaptation-level theory: An experimental and systematic approach to behavior*. New York, NY: Harper and Row.
- Hu, J., Gao, D. Z., & Pan, W. (2013). Multiangle social network recommendation algorithms and similarity network evaluation. *Journal of Applied Mathematics*, 2013.
- Häubl, G., & Murray, K.B. (2003). Preference construction and persistence in digital marketplaces: The role of electronic recommendation agents. *Journal of Consumer Psychology*, 13(1), 75-91.
- Kardan, A. A., & Ebrahimi, M. (2013). A novel approach to hybrid recommendation systems based on association rules mining for content recommendation in asynchronous discussion groups. *Information Sciences*, 219(10), 93-110.
- Konstan, J. A., Miller, B. N., Maltz, D., Herlocker, J. L., Gordon L. R., & Riedl, J. (1997). GroupLens: Applying collaborative filtering to Usenet

- news. *Communications of the ACM*, 40(3), 77-87.
- Kwon, K., Cho, J., & Park, Y. (2009). Influences of customer preference development on the effectiveness of recommendation strategies. *Electronic Commerce Research and Applications*, 8(5), 263-275.
- Lekakos, G., & Giaglis, M. G. (2006). Improving the prediction accuracy of recommendation algorithms: Approaches anchored on human factors. *Interacting with Computers*, 18(3), 410-431.
- Liu, H., Hu, Z., Mian, A., Tian, H., & Zhu, X. (2013). A new user similarity model to improve the accuracy of collaborative filtering. *Knowledge-Based Systems*, 56, 56-166.
- Ma, H. (2013). An experimental study on implicit social recommendation. In *Proceedings of the 36th International ACM SIGIR Conference on Research and Development in Information Retrieval* (pp. 73-82). Redmond, WA, USA.
- Ma, H., Liu, C., King, I., & Lyu, M. R. (2011). Probabilistic factor models for web site recommendation. In *Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval* (pp. 265-274). Beijing, China
- Molina, L.E., (2018). *Recommendation system for Netflix* (Master's thesis, VRIJE University, Amsterdam). Retrieved from https://beta.vu.nl/nl/Images/werkstuk-fernandez_tcm235-874624.pdf
- Ou-Yang, Y. P., Shieh, H. M., Leu, J. D., & Tzeng, G. H. (2008). A novel hybrid MCDM model combined with DEMATEL and ANP with applications. *International Journal of Operations Research*, 5(3), 160-168.
- Rentfrow, P. J. & Gosling, S. D. (2003). The do re mi's of everyday life: The structure and personality correlates of music preferences. *Journal of Personality and Social Psychology*, 84(6), 1236-1256.
- Saaty, T. L. (1977). A scaling method for priorities in hierarchical structure. *Journal of Mathematical Psychology*, 15(3), 234-281.
- Saaty, T. L. (1980). *The Analytic hierarchy process*, New York: McGraw Hill.
- Saaty, T.L. (1986). Axiomatic foundation of the analytic hierarchy process. *Management Science*, 32(7), 841-855.

- Shen, A., & Ball, A. D. (2011). Preference stability belief as a determinant of response to personalized Recommendations. *Journal of Consumer Behaviours*, 10(2), 71-79.
- Simonson, I. (2005). Determinants of customers' responses to customized offers: Conceptual framework and research propositions. *Journal of Marketing*, 69(1), pp 32-45.
- Simonson, I. (2008). Will I like a "medium" pillow? Another look at constructed and inherent preferences. *Journal of Consumer Psychology*, 18(3), 155-169.
- Tversky, A., & Kahneman, D. (1974). Judgment under uncertainty: Heuristics and biases. *Science*, 185(4157), 1124-1131.
- Wu, I. C., & Hwang, W. H. (2013). A genre-based fuzzy inference approach for effective filtering of movies. *Intelligent Data Analysis*, 17(6), 1093-1113.
- Wu, I. C., & Niu, Y. F. (2015). Effects of anchoring process under preference stabilities for interactive movie recommendations. *Journal of the Association for Information Science and Technology*, 66(8), 1673-1695.
- Xue, H. J., Dai, X., Zhang, J., Huang, S., & Chen, J. (2017). Deep matrix factorization models for recommender systems. In *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence* (pp. 3203-3209). Melbourne, Australia.
- Yu, K., Xu, X., Ester, M., & Kriegel, H. P. (2003). Feature weighting and instance selection for collaborative filtering: An information-theoretic approach. *Knowledge and Information Systems*, 5(2), 201-224.
- Yuan, Q., Cong, G., & Lin, C. Y. (2014). COM: A generative model for group recommendation. In *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 163-172). New York, NY
- Zhang, M., Tang, J., Zhang, X., & Xue, X. (2014). Addressing cold start in recommender systems: A semi-supervised co-training algorithm. In *Proceedings of the 37th International ACM SIGIR Conference on Research and Development in Information Retrieval* (pp. 73-82). Queensland, Australia.

附錄 A：層級分析法 (AHP)

層級分析法 (Analytic Hierarchy process；簡稱 AHP)，為 1971 年匹茲堡大學教授 Saaty 所發展出來的著名方法 (Saaty, 1977, 1980)。層級分析法是一種用於處理複雜化、非結構化和多屬性決策的決策輔助工具。層級分析法能將原本無法計量的感覺或偏好加以量化後建立成對比較矩陣來求取兩個比較項目間的優先偏好順序。Atthirawong 與 McCarthy (2002) 提出透過層級分析法解決問題有三個步驟：建構層級結構、比較判斷和重點整合。第一步是將複雜的問題分解成多個層級，從一個總體目標下降到各種標準、次級標準，以此類推直到最低標準。接著，確定各元素在每個級別的優先順序並發展比較矩陣的。成對比較矩陣求得後，即可求取各層級要素的權重，再進行整體層級權重的計算。

除了 AHP 方法亦有後續延伸發展的網絡分析程序法 (Analytic Network Process, ANP) 方法與由決策實驗室法 (DEMATEL) 和網路程序分析法 (ANP) 所結合發展出的混合式多準則決策分析方法，稱之為 DANP。ANP 方法主要解決 AHP 屬性獨立的問題，故屬性間將形成網路關係圖也造成評估過程較為複雜 (Saaty, 1986)；由於本研究主要取 AHP 運算方法之特行進行定錨設計，故 ANP 屬性評估方法並不適用於本研究。Ou-Yang, Shieh, Leu & Tzeng (2008) 於研究指出 ANP 忽略各構面間是存在著不同的影響性程度，故提出了透過 DEMATEL 與 ANP 結合來處理克服這問題；DANP 方法，雖然也可以進行屬性排序，但相對於 AHP 其評估程序仍較不直覺且較為複雜，並不適合本研究線上定錨程序使用。AHP 使用成對比較法 (pair wise comparison method)，以求取準則或替代方案間的相對權重或重要性 (relative importance, priority weights)，當使用成對比較法時可以讓決策者著重於兩個項目的比較，能夠減輕決策者的思考負擔並快速的在兩個項目中作出選擇。

Interactive Movie Recommendations with Strengthened Analysis of Genre Preferences

I-Chin Wu

Professor

Graduate Institute of Library & Information Studies
National Taiwan Normal University

Chun-Hua Dai

Graduate Student

Graduate Institute of Information Management
Fu Jen Catholic University

1. Background

To boost website conversion rates and promote electronic trades of goods, E-commerce companies often rely upon product recommendation techniques for enhancing their potential commercial value, and use recommendation systems to accurately predict user interests. Among these systems, collaborative filtering (CF) enables websites to recommend products to target customers based on preferences of peers with similar interests. Since recent studies have shown that stability of users' preferences influences their decision making, especially those concerning experiential goods, it is worth investigating such stability regarding choosing or buying these goods. In this study, we thus propose integrating genre- and director-based anchoring processes to identify users' preferences for movie genres and to measure preference stability for providing more precise recommendations. It is worth noting that in this study we had overcome the problem of sparse ratings by analyzing associations among movie genres and directors. By employing the analytic hierarchy process (AHP), we thus inferred user preferences for movie genres via a series of interactive genre- and director-based anchoring processes, which ultimately provided effective and precise interactive movie recommendations. The research questions (RQs) are listed as below.

RQ 1: The CF filtering enables websites to recommend products to target users based on preferences of peers with similar interests. Although CF can expand a user's profile of interests, it cannot overcome problems of cold start and sparse ratings (i.e., an individual might only vote for a small fraction of all items) (Adomavicius & Tuzhilin, 2005; Balabanović & Shoham, 1997; Ma et al., 2011). To tackle these problems, we adopted the Apriori algorithm to investigate the relations among movie genres by merging similar genres to reduce the number of genres. We aimed to examine if this would address the rating sparsity problem by alleviating the rating burdens on users.

RQ 2: Customers' preference development situations are predicted by analyzing relationships between product ratings given by each individual and corresponding product attributes (Cheung et al., 2003). Researchers in the customer decision-making area pointed out that consumers' preference stability (PS) would influence their final decision-making, thus it is worth investigating consumers' PS for providing effective recommendations (Bettman et al., 2008; Shen & Ball, 2011; Simonson, 2005, 2008; Wu & Niu, 2015). In this study, we measured users' PS based on the users' variants of movie genres and directors via a two-phase anchoring process for investigating the effectiveness of recommendation results.

2. Methods

Our proposed interactive movie (iMovie) recommendation framework incorporates three modules, including the preference capturing module, the anchor-based preference stability measuring module, and the recommendation module.

(1) Merging similar types of movie genres

For merging similar movie genres, we adopted the Apriori algorithm to analyze associations among genres, and reduced the number of movie genres from 30 to 19 in our dataset. For example, a single movie might generally be labeled as both "thriller" and "horror", thus in our study, they were merged into one genre for avoiding ambiguity towards movie genres. This would reduce users' cognitive load for rating movies. In addition, we analyzed the associations between movie directors and genres. We assumed users' preferences of directors would imply their preferences for movie

genres. The analyzed results would help the recommendation system to predict users' preferences for movie genres.

(2) The genre- and director-based anchoring process:

After the movie genres analysis, we conducted a two-phase anchoring process for interactive movie recommendations. We asked users to rate movies of each genre to construct users' profiles (UP) based on the rating results. During the anchoring process, an AHP method was applied to calculate the weights of genres for adjusting users' profiles (UP). Initially, we selected three movies, and then two of the three movies were served as an anchor item and a target item in turns to do three rounds of pair-wise comparisons.

(3) Measuring the PS

After iterations of pair-wise comparisons, we could capture the status of users' preferences for genres. Technically, the users' profiles were adjusted based on the results of interactions. Thus, we could analyze the differences between the original UP and the adjusted UP to infer the stability of the users' preferences for movie genres. In this study, we employed the Pearson correlation coefficient to analyze a user's stability of preferences. If the user selects a movie different from his/her past preference for movie genres, we labeled the user as an unstable user. On the contrary, a stable user would have a stable preference for movie genres.

3. Evaluation Results and Discussions

We recruited fifty users to fill out pre-questionnaires and then selected thirty-one of them who were interested in watching movies in their leisure time. A front-end iMovie recommender system is built for collecting users' ratings of movies. We divided the front-end interactive recommendation process into the initial rating phase, interactive genre-based anchoring and the director-based anchoring phase. For the back-end side, we adopted the genre-based fuzzy inference approach to build the model for recommending movies to users and evaluated results in terms of precision (Wu & Hwang, 2013). Based on our research design, we could have three UPs, one at each different recommendation phase: the initial UP1, the adjusted UP2 after

genre-based anchoring, and the adjusted UP3 after genre- and director-based anchoring. Herein, we summarized the findings with associated discussions for the proposed recommendation methods.

Discussion one: We asked users to rate one and three movies respectively, which helped the system to infer users’ initial preferences for movie genres and then constructed UP to make further recommendations. The results showed that the number of initial ratings for movies would not influence the results for each phase, as shown in Figure 1. Furthermore, the precision would increase after the two-phase anchoring processes for most users (93.5%), as shown in Table 1. Only two users did not give better ratings for recommendation results based on our proposed method. In summary, we could use a small number of ratings for movies based on our proposed strengthened analysis of genre-based recommendations to solve the sparse rating problem and increase the precision of recommendation results for most users.

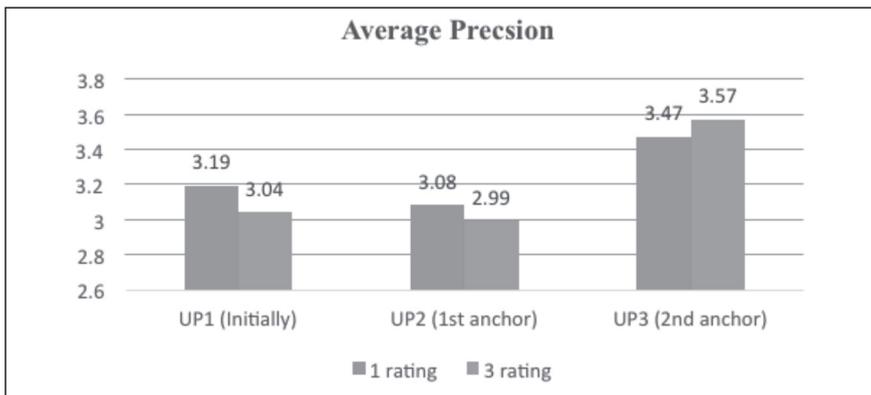


Figure 1
Average precision under various numbers of initial rating movies at each phase

Table 1
Precision of recommendation results after two-phase anchoring

Groups	Users	Percentage	UP1 (Initial)	UP 3(2 nd anchoring)
1	2	6.5%	2.90	2.40
2	29	93.5%	3.07	3.51

Discussion two: For users with a stable preference for movie genres, we found all of them gave higher ratings to the recommended movies after the genre- and director-based anchoring process. Most of them also revealed that movie genre was their first determining factor to select a movie for watching. Furthermore, although the attribute of “director” was not their primary factor to select movies, it seemed that it was helpful to apply contract effect for the director-based anchoring process. This implied that the auteurism of a director had some degree of association with movie genres. It confirmed that applying anchoring process would increase the precision of recommendations.

Discussion three: For users with an unstable preference for movie genres, none of them ranked movie genres as their first priority to select movies. However, the anchoring-based recommendations were apparently effective for all users. We found that users of this type were easily influenced by several factors, such as directors, main actors/actresses, reviews, etc., and triggered by contexts. The results were consistent with our previous research findings, that is, the anchoring processes could effectively filter out the users’ undesired movie genres, especially for users who had unstable preferences.

4. Conclusions

Based on a series of experiments, we suggest classifying users into stable preference and unstable preference groups based on our PS measuring approach. Then, we should determine if movie genre is the users’ primary criterion when selecting movies. Accordingly, we summarize three recommendation strategies for users of three types.

Type 1: Users of the first type are those who have a stable preference and regard movie genre as the first determining factor when selecting movies for watching. It is effective to apply the two-phase anchoring process to make recommendations for users of this type.

Type 2: Users of the second type are those who have a stable preference but they do not deem movie genre as the first determining factor when selecting movies. It is effective to apply the genre-based anchoring, but there will be no significant effects of applying the second phase, that is, the director-based anchoring.

Type 3: Users of the third type are those who have an unstable preference and employ multiple criteria to select movies. It is also effective to apply the two-phase anchoring process to make recommendations for them.

In this study, we proposed integrating genre- and director-based anchoring processes to identify users' preferences for movie genres and to measure preference stability for providing more precise recommendations. The experimental results showed that the system could improve the sparse rating problem by merging similar genres and then could increase recommendation effects by analysing relations between genre preferences and movie directors, especially for users with unstable preferences for movie genres. The results suggested that the stability of users' preferences is an important factor to be considered when developing effective recommendation strategies. The research results could serve as a reference for e-commerce sectors to develop strategies for making recommendations.