國立政治大學資訊科學系
Department of Computer Science
National Chengchi University

碩士論文
Master's Thesis

基於翻譯序列推薦模型於跨領域推薦系統之強化方法

Employing Translation-based Recommendation for Improving Cross-domain Recommendation Performance

研 究 生：王均捷
指導教授：蔡銘峰

中華民國 一百一十 年 八 月
August 2021

DOI:10.6814/NCCU202101565

基於翻譯序列推薦模型於跨領域推薦系統之強化方法

Employing Translation-based Recommendation for Improving Cross-domain Recommendation Performance

研 究 生：王均捷　　Student：Chun-Chieh Wang

指導教授：蔡銘峰　　Advisor：Ming-Feng Tsai

國立政治大學

資訊科學系

碩士論文

A Thesis

submitted to Department of Computer Science

National Chengchi University

in partial fulfillment of the Requirements

for the degree of

Master

in

Computer Science

中華民國 一百一十 年 八 月

August 2021

DOI:10.6814/NCCU202101565

致謝

首先，我要感謝指導教授蔡銘峰老師的指導。這兩年來，由於COVID-19 疫情的關係不常與老師會面，但老師總能在忙碌之餘抽空協助我解決問題，也會偶爾關心我的身心狀態，是十足的「優秀教育者」以及「和藹好父親」的榜樣。希望我在未來的路途中，也能像老師一樣作爲他人的明燈指引其方向；也希望我未來也能賺多一點錢，才能跟老師一樣每天欣賞天空畫布。

再來，我要感謝研究室的陳志明學長和莊喻能學長：若沒有他們兩位學長的推薦與拉拔，我不會加入 KKLAB 團隊做產學合作；若沒有他們的提點及技術支援，這篇畢業論文也很難在期限內完成。畢業後，我肯定會非常懷念最後半年幾乎每晚都在 Dead by Daylight 這款遊戲中與兩位學長約跑的日子。

然後，我要謝謝同一屆的實驗室同學們陳先灝、盧佳妤和段寶鈞，伴我度過如此開心的兩年碩士生活，並且終於在互相掩護和彼此支持之下，順利一同畢業了！

最後我要感謝我的家人，因爲他們支持我所做的任何荒謬決定；要不是他們在我決定一心投入產業的時候勸我唸研究所，我不會多出兩年學生身分進修，也不會留下許多精采的回憶。如果老師的指導是我人生方向的指引，那麼家人的支持肯定是心靈層面的最強後盾。家裡那張紅木圓桌，父親在上面完成他的博士論文、姊姊在上面完成了她的碩士論文，這次輪到我在上面完成我的碩士論文了。

王均捷

國立政治大學資訊科學系

August 2021

DOI:10.6814/NCCU202101565

基於翻譯序列推薦模型於跨領域推薦系統之強化方法

中文摘要

若我們有足夠多的歷史資料，就可以用很多不同的方法去建立一個聰明的推薦系統。但在某些情況下，比如一個新的社交媒體平台或電商平台上線時，我們沒有足夠的使用者物品互動資料來建構出好的推薦系統。其中一個強化跨領域推薦（cross-domain recommendation）的解決方案，是藉由將「來源領域（資訊含量較多之領域）」的資料加入「目標領域（資訊量相對較少的領域）」來提升資訊量，然後對「目標領域」進行推薦。

本論文採用圖形學習表示演算法，結合改良並善用翻譯序列推薦模型（Translation-based Recommendation，TransRec）的推薦優勢，特化模型訓練時採樣方法、改變翻譯序列合併方法，並引入貝氏個人化推薦（Bayesian Personalized Ranking，BPR）中負採樣（negative sampling）的概念，訓練得到推薦系統任務導向之表示向量，藉此改善推薦結果。本研究旨在通過改良後的翻譯序列推薦模型「TransRecCross」來強化跨領域推薦效果。驗證本論文的新方法時，使用了 Amazon Review 系列資料集中的其中四個，並在論文最後比較了加入不同比例的來源領域資料後的推薦結果，以驗證本論文提出之方法的可靠程度。

關鍵詞：推薦系統、翻譯序列推薦、跨領域翻譯序列推薦、跨領域推薦、圖形學習、貝氏個人化推薦

DOI:10.6814/NCCU202101565

Employing Translation-based Recommendation for Improving Cross-domain Recommendation Performance

Abstract

There are plenty of ways to apply an intelligent domain-specific recommendation system if we have an enormous amount of data. Unfortunately, in some scenarios like running a new social media platform or online store, we do not have enough user-item interactions data to build a sound recommendation system. One of the solutions is to apply cross-domain recommendation techniques: we can increase the amount of information by gathering the user-item interaction information from the ”source domain” into the ”target domain,” and then implement the recommendation system based on the ”target domain.”

This thesis adopts graph learning representation algorithm with extending the advantages of TransRec (Translation-based Recommendation): specializes the sampling method, changes the translating method, and then applies the negative sampling concept of BPR (Bayesian Personalized Ranking), then train and get the recommendation-oriented representation vectors to improve the recommendation system performance. This study aims to improve the cross-domain recommendation performance via a reformed translation-based recommendation model named ”TransRecCross.” In our experiments, comprehensive comparisons conducted on four datasets from Amazon Review have verified the effectiveness of the proposed TransRecCross.

國立政治大學 National Chengchi University

Keywords: recommendation system、TransRec、TransRecCross、cross-domain recommendation、graph learning、BPR

DOI:10.6814/NCCU202101565

目錄

致謝 **1**

中文摘要 **2**

Abstract **3**

第一章　緒論 1
1.1　前言 1
1.2　研究目的 2
第二章　相關文獻探討 4
2.1　圖形學習表示法 4
2.2　個人化推薦系統 5
2.3　跨領域推薦 7
第三章　研究方法 9
3.1　問題定義 9
3.1.1　先備知識 9
3.1.2　研究動機 12
3.2　TransRecCross模型 13
3.2.1　符號定義 13
3.2.2　模型介紹 14
3.2.3　採樣細節分析 17
第四章　實驗結果與討論 19
4.1　資料集 19
4.2　比較基準模型 20
4.3　實驗設定與驗證標準 22
4.3.1　實驗設定 22
4.3.2　驗證標準 22
4.4　實驗結果 24
4.4.1　跨領域推薦領域結果 24
4.4.2　驗證跨領域強化能力 27
第五章　結論 31
參考文獻 32

國立政治大學 National Chengchi University

DOI:10.6814/NCCU202101565

圖目錄

圖 1.1　不同領域中的使用者互動情形 2
圖 1.2　如何強化跨領域推薦之示意圖 3

圖 2.1　協同過濾法概念圖 5
圖 2.2　矩陣分解法示意圖 6
圖 2.3　貝氏個人化推薦示意圖 7
圖 2.4　不同跨領域推薦形式之示意圖 8

圖 3.1　TransE 模型概念圖 10
圖 3.2　TransE 模型細節示意圖 10
圖 3.3　TransRec 模型概念圖 11
圖 3.4　TransRec 模型細節示意圖 11
圖 3.5　TransRecCross 模型概念圖 13
圖 3.6　TransRecCross 模型細節示意圖 14
圖 3.7　TransRecCross-Pref 模型細節示意圖 15
圖 3.8　TransRecCross-BPR 模型細節示意圖 15
圖 3.9　TransRecCross-BPR 模型細節示意圖 16
圖 3.10　TransRecCross 情形一採樣方式示意圖 17
圖 3.11　TransRecCross 情形二採樣方式示意圖 17
圖 3.12　TransRecCross 情形三採樣方式示意圖 18

圖 4.1　不同 Book 資料比例對 CDs and Vinyl 之推薦結果 27
圖 4.2　不同 Book 資料比例對 Digital Music 之推薦結果 28
圖 4.3　不同 Book 資料比例對 Industrial and Scientific 之推薦結果（調整前） 29
圖 4.4　不同 Book 資料比例對 Industrial and Scientific 之推薦結果（調整後） 29

DOI:10.6814/NCCU202101565

表目錄

表 3.1　符號定義 13

表 4.1　各領域資料之圖形相關統計 20
表 4.2　目標領域與來源領域之使用者交集統計 20
表 4.3　跨領域推薦結果 26

國立政治大學
National Chengchi University

DOI:10.6814/NCCU202101565

第一章

緒論

1.1 前言

日常生活中，我們會接收來自各方的大量資訊，進而造成選擇上的困難；又或者想要了解某件事情、找到某個東西，但在資訊的汪洋大海中總是找不到自己要的解答。推薦系統即是人們爲了解決上述的困難而提出的解決方案；換句話說，推薦系統驗算法可以說是一個聰明的訊息過濾方法。

推薦系統已隨處可見：從電商平台到影音串流服務、甚至是廣告投遞和社群媒體，只要是具備個人化服務的平台，基本上都具備推薦系統的應用。可能沒有任何一個電商、社群平台或影音串流服務商會特別告訴大家自己使用了什麼樣的推薦系統，但實際上他們都早已內建推薦演算法：像是社群媒體經營者需要不斷關注臉書（Facebook）社群平台的「演算法」並計算自身的貼文「觸及率」，其實就是在適應臉書的「推薦演算法」並計算自己的「點閱率（Click Though Rate，CTR）」或「轉換率（Conversion Rate，CVR）」，他們要想辦法讓自己發布的訊息順利被演算法推播到目標對象面前。同樣的，以電商來說，他們平台上可能有非常多不同品牌但相同的物品，而如何從細微的區別中將買家最可能喜歡的物品推薦給他，正是推薦系統需要完成的事情。

推薦系統與我們生活密不可分，大多數現有技術皆是藉「使用者的歷史紀錄」作爲其偏好的判斷依據，所以「已擁有大量歷史資料」是啓動任何推薦系統前的先備條件。我們在最近經常使用的演算法有內容導向過濾法（Content-Based Filtering）、協同過濾法（Collaborative Filtering）或混合兩種方法的混合型過濾法（Hybrid Filtering）。內容導向過濾法顧名思義就是根據某使用者過去喜好的物品，擷取出其內容或評價後把同樣類型的物品推薦給該使用者。這種演算法只考慮單一使用者的喜好，非常的值觀。協同過濾法則不考慮物品內容，而是根據其他使用者對物品們的評價或互動來決定某使用者的喜好。比方說，甲、乙兩位皆喜歡香蕉、蘋果等水果：此時若甲喜歡鳳梨，那乙應該有很大機率也喜歡鳳梨。

DOI:10.6814/NCCU202101565

混合型過濾法即是結合了兩者的優點，既能透過不同使用者的喜好關係來推論使用者偏好，也可以利用物品的內容來做後續的調整，不過相對來說運算量可能會大增。

在眞實環境中，不是所有事情都那麼地美好：推薦系統一直有所謂冷啓動（cold-start）問題，也就是當我們完全沒有使用者與物品的互動資料時，就沒辦法爲使用者進行推任何推薦。即便不是完全冷啓動，依然常遇到歷史資料過於稀疏或大量缺乏的狀況，而這將成爲建立推薦的一大困難，如圖 1.1 ，不同Domain有不同的使用者互動情形：圖中顯示左側 Domain A 有大量與使用者互動資訊，右側 Domain B 則非常稀少；使用者跟物品的互動非常的少將會造成推薦的障礙。這種狀況最常發生在一間公司成立新的平台或服務的時候，因爲即便該企業已有大量使用者、既有的平台或服務已有大量歷史使用者紀錄，但新平台或服務仍尚未累積足夠多的使用者紀錄。

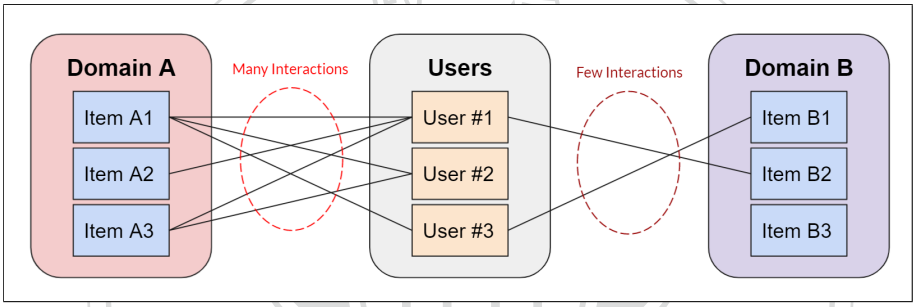

圖 1.1: 不同領域中的使用者互動情形

此外，速度和模型參數量也是一個重點：由於網際網路的速度日益提升、雲端服務的崛起，推薦系統運算的即時性、更新速率對於一般企業將會是一個考量。實務上，一個服務的架構中可能有很多不同的微服務需要在不同時機啓動並進行運算，所以我們不希望消耗太多資源在進行僅僅是推薦的單一任務上。以目前學術界來說，端對端（end-to-end）之深度學習模型的效果最好、最方便使用，給予輸入即可得到輸出；可是一般企業若選擇深度學習模型作爲推薦模型，超大量的參數量可能會在更新訓練模型時產生過多運算支出。

1.2 研究目的

本論文旨在提供一個強化跨領域推薦（cross-domain recommendation）的新思路，能有效地利用「來源領域（資訊含量較多之領域）」的資料，來協助「目標領域（資訊量相對較少的領域）」進行推薦，而非解決冷啓動（cold-start）問題或在效果上打敗所有最新的推薦模型。

本論文採用圖形學習表示演算法訓練得到推薦系統任務導向之表示向量，藉由歷史紀錄較多、資訊較充足的「領域」的使用者操作資料來大幅改善或強化另

DOI:10.6814/NCCU202101565

一個領域的推薦結果；如圖 1.2 所示，利用 Domain A 較豐富的使用者互動資料來提升 Domain B 的推薦表現。演算法的部分，本論文結合改良並善用序列推薦模型（Translation-based Recommendation，TransRec） 的推薦優勢，特化模型訓練時採樣方法，並引入貝氏個人化推薦（Bayesian Personalized Ranking，BPR）中負採樣（negative sampling）的概念來更進一步改善推薦結果。

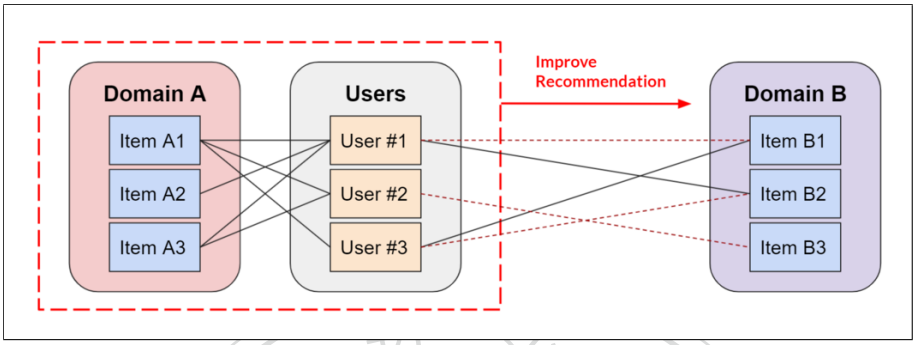

圖 1.2: 如何強化跨領域推薦之示意圖

國立政治大學 National Chengchi University

DOI:10.6814/NCCU202101565

第二章

相關文獻探討

2.1 圖形學習表示法

在現實中的所有資料都是類比訊號，我們需要將他們數位化才能提供電腦運算。通常搭建推薦系統前，我們要有使用者或物品的詳細資料，然而物品沒辦法直接塞進電腦、使用者也是活生生的人類，電腦無法直接對他們進行任何運算。最早想到折衷解決辦法的人，取出想要目標物件的可量化屬性，爲其建構出一個表示向量（embedding），以利電腦根據這組向量對此物件做任何運算。其中對具代表性的是自然語言學門中的詞向量（word embedding）的發展歷程：傳統自然語言處理在表示一個單詞時，經常使用一位有效表示法（One-hot representation）或 TF-IDF（Term Frequency - Inverted Document Frequency） [17] 組成代表該單詞的向量；但這兩者在面對巨量資料、也就是單詞量很多的文章時，會產生維度非常大且稀疏的向量，進而導致運算成本非常昂貴，於是學者們決定使維度降低，使用主成分分析（Principle Component Analysis，PCA）或自動編碼器（Autoencoder）等等降維手段將稀疏且高維度的向量映射到較低維度的空間中。但學者們並沒有因此而滿足，他們認爲降低維度的動作類似一種資訊壓縮、會導致資訊遺失，在一開始就應該得到較稠密的向量 [23] ；這造就了 Word2vec 的誕生，利用移動窗格（moving window）的概念搭配 Skip-gram 和 CBOW 的不同訓練方式去整合前後文單詞訊息，最終得到對應的單詞表示向量。後來此概念延伸出了圖形學習表示法（graph embedding），把一張關係網路中的每個互動或關係連結直接使用類神經網路去訓練、進行資訊整合並壓縮，最後其表示的節點或邊將得到一組稠密的低維度之表示向量。若用二分圖（bi-part graph）來形容的話，使用者和物件是點（node）、他們之間的互動就是邊（edge）。

圖形學習法有非常多種，各有各的優勢和想要解決的問題，不過大多數的目標都是在於如何有效地整合高階資訊（high-order information）、更有效率的在節點之間遊走並獲取重要訊息。像是利用隨機遊走（Random Walk）以去大

DOI:10.6814/NCCU202101565

量探索高階資訊的 Deepwalk [16] 、以深度優先搜尋（Depth-first Search，DFS）與廣度優先搜尋（Breadth-first Search，BFS）兩種不同的遊走策略來改善向量品質的 Node2vec [6] 、考慮「相鄰節點的相鄰節點」以達成二階近似（second-order proximity）來做到大量資訊整合的 LINE（Large-scale Information Network Embedding） [21] 等等。

2.2 個人化推薦系統

傳統的推薦方法主要可分爲三種：內容導向過濾法（Content-Based Filtering）、協同過濾法（Collaborative Filtering）或混合兩種方法的混合型過濾法（Hybrid Filtering）。內容導向過濾法主要是依照內容某使用者過去喜好的物品，擷取出對應的內容與評價後把同樣類型的物品推薦給該使用者；協同過濾法則是現在大多推薦演算法的基礎，其精隨在於根據眾人的偏好來判斷彼此的偏好，而若把使用者與物品之關係圖用相鄰矩陣（adjacency matrix）表示的話，每個人在矩陣中恰好能得到一個表示向量，且此向量與物品的表示向量之餘弦相似度（cosine similarity）應該要近似於 1。如 2.1 所示，使用者 1 和使用者 2 都喜歡物品 1 和物品 2，所以若使用者 2 喜歡物品 3，使用者 1 應該也會喜歡物品 3 。

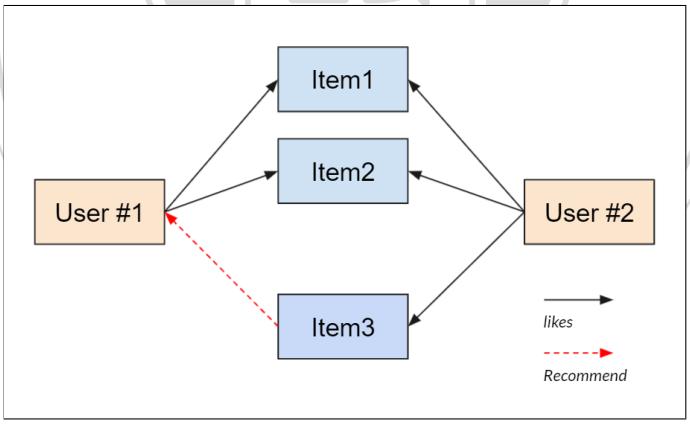

圖 2.1: 協同過濾法概念圖

協同過濾法若改以模型時做來區分的話，又分爲記憶體導向協同過濾（Memory-based Collaborative Filtering）和模型導向協同過濾（Model-based Collaborative Filtering） [1] 。記憶體導向即是直接將使用者與物品之關係圖用相鄰矩陣表示，最後運用矩陣運算方法最大化每個對應在矩陣中的之值，令該表示向量與相鄰之表示向量餘弦相似度近最大化。此相鄰矩陣的應用也可依照推薦任務的不同分爲使用者對使用者（user-user）和物品對物品（item-item）兩種。使用者對使用者的推薦較適合在物品數量過大且具時效性的情境，如社群平台或新聞媒體網站的個人化推播，因爲對應物品的熱度是全體使用者炒作出來的，而在社群中最具討論度、最有熱度的話題肯定會被大多數使用者接受；物品對物品的推薦比

DOI:10.6814/NCCU202101565

較適合電商平台或其他販售商，因爲有些物品可能一直都沒什麼被討論度、沒有驚人的銷售量，卻不斷持續被購買，而物品對物品的推薦方式不會忽略這種隱含資訊。協同過濾法除了上述的記憶體導向之外，還有模型導向的方法：也就是用學習模型來取代矩陣運算的工作，直接將使用者和物品的表示向量映射到固定維度的向量空間，但同時保留兩向量相似度的方法，例如使用奇異值分解（Singular Value Decomposition，SVD）取近似值的矩陣分解法（Matrix Factorization，MF）和使用倒傳播（Backpropagation，BP）的 KNN（k-Nearest Neighbor） [7] [22] 。畢竟推薦系統所使用的訓練資料量極大，多數涵蓋數以憶計的使用者與物件互動次數，記憶體導向那種暴力矩陣運算的推薦方法很難同時處理大量資料，故需要仰賴模型來得到學習表示向量。當然，完全循環地運算所有的使用者物件互動並不效率，如同更新深度學習模型權重時需要切批次（batch）一樣，會使用採樣（sampling）的技巧來更新表示向量。 [28]

協同過濾法若以更新方法作爲區別的話，可以分爲逐點方法（point-wise） [14][15] 和成對方法（pair-wise） [18][20] 兩種。逐點方法假設使用者不喜歡所有沒有互動過的物品，所以會將未互動過的物品歸類爲負向回饋；而成對方法則假設使用者喜歡互動過的物品更甚於沒互動過的物品，所以只會針對使用者以及其曾經互動過的物品進行學習。這邊我們可以很好想像，逐點方法的更新一次只需要兩個節點，也就是一個「pair」；而成對方法需要三個，也就是一個「triplet」。逐點方法基本上就是單純用矩陣分解法 [5] 實作，使用的資訊單純是由「使用者」、「物品」以及「是否有互動」這三種成分所組成；其中使用者與物品的互動關係即包含了購買、瀏覽或評論等等，其訓練方式即是如圖 2.2 所示，正採樣（positive sampling）以及負採樣（negative sampling）並行。

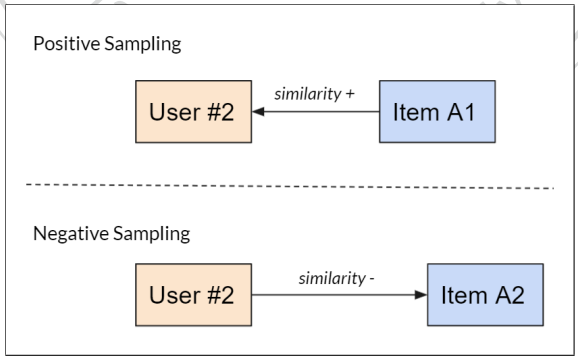

圖 2.2: 矩陣分解法示意圖

成對方法最出色的就是後來經常被使用的貝氏個人化推薦（Bayesian Personalized Ranking，BPR） [19] 。貝氏個人化推薦是一個非常具特色的推薦方法，他針對逐點方法中負採樣（Negative sampling）的做法稍稍做了改變，把負採樣與正採樣物件間的相似度也納入考量，使其對於模型的更新更加細緻；如圖 2.3 ，User 2 喜歡 item A1 但沒見過物品 item A1 ，那麼在貝氏個人化推薦中我們不僅會將 User 2 拉近 item A1 、將 User 2 疏遠 item A2，也會把 item A1 和 item A2 的距離

DOI:10.6814/NCCU202101565

拉遠。爾後，學者們從矩陣分解法和貝氏個人化推薦延伸出許多特別應用於推薦系統的向量表示學習方法，如基於隨機遊走重啓機制（Random Walk with restart）進行改良的 APP（Asymmetric Proximity Preserving graph embedding） [29] 、用隨機遊走分別學習使用者視角與物品視角的分布後整併的 CSE（Collaborative Similarity Embedding） [4] 、基於隨機遊走進行加權式整合節點資訊的 HOP-rec（High-order Proximity for implicit Recommendation） [25] 、以使用者物品關係圖中的偏好（preference）作爲出發點去訓練模型的 HPE（Heterogeneous Preference Embedding） [3] 等等。

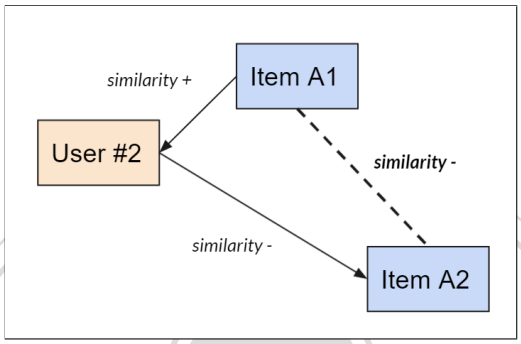

圖 2.3: 貝氏個人化推薦示意圖

隨著硬體的進步，深度學習模型在學界重新嶄露頭角，推薦系統也成爲了深度學習的應用場景 [10] [26] 。最常見的深度學習網路是以圖相關深度模型作爲基礎的圖卷積網路（Graph Convolutional Network），特色是可以藉由不斷整合鄰居資訊（neighborhood information）來蒐集更高階（higher-order）的資訊。後來，大家發現知識圖譜（knowledge graph）的重要性後，開始研究更加複雜的圖、更加複雜的使用者物件互動、甚至更複雜的關係如物件與物件之交互作用。這時出現了許多知識圖譜與注意力機制（attention mechanism）的相關研究，如 GAT 、KGAT 和許多使用了注意力機制的端對端推薦方法等等，特色是在圖方面的資訊整合能力更全面、運算也更細膩。

2.3 跨領域推薦

領域推薦（domain-specific recommendations）是推薦系統研究中一個的研究領域，目標是找到一個方法可以在不同主題的物品。在一般推薦系統中，我們會推薦物品給特定領域的使用者，讓使用者可以在特定領域中得到更精確的推薦物品，所以我們經常將不同領域資料分開，是因爲使用者在不同主題中的偏好經常截然不同；也就是說，即使使用者在特定領域中的喜好與另一位使用者相似，在另一個領域中卻可能大有不同，所以用同一種模型或方法來建模、做偏好學習的話，通常會得到不準確的結果。

而跨領域推薦中，我們會使用同一種模型或方法，讓使用者可以在不同主題

DOI:10.6814/NCCU202101565

領域中得到更精確的推薦物品。其中有兩種主流的方法 [30] ，其中一種是先對所有領域的資料集分別進行資料探勘前處理、得到許多額外資訊和分布結果後再進行圖形學習訓練 [27] [12] ，而另外一種是將不同領域的使用者或物品映射到同一個向量空間中，再進行圖形學習訓練 [13] 。雖然這兩種方法都可以讓使用者在不同領域中得到更精確的推薦物品，但是其中一種方法的效果比較好，而另一種方法的效果比較差。

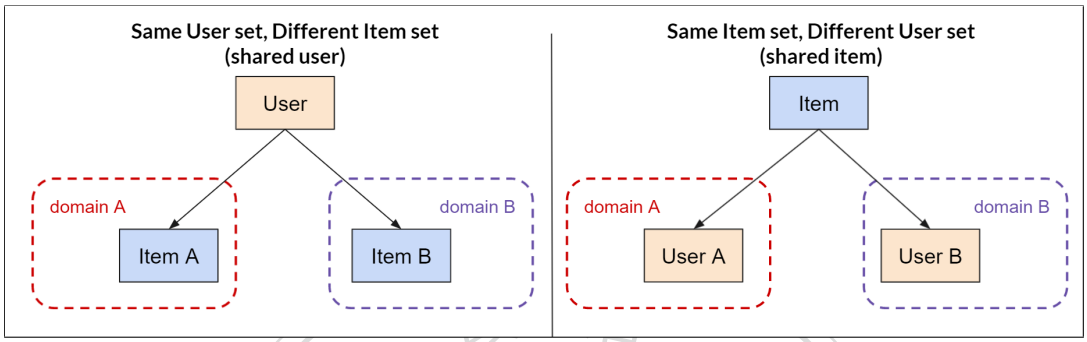

圖 2.4: 不同跨領域推薦形式之示意圖

國立政治大學 National Chengchi University

DOI:10.6814/NCCU202101565

第三章

研究方法

3.1 問題定義

推薦系統一直有所謂冷啓動（cold-start）的問題，也就是當我們完全沒有使用者與物品的互動資料時，就沒辦法爲使用者進行推任何推薦。即便不是完全冷啓動，依然常遇到歷史資料過於稀疏或大量缺乏的狀況，而這將成爲建立推薦的一大困難。這種狀況最常發生在一間公司成立新的平台或服務的時候，因爲即便該企業已有大量使用者、既有的平台或服務已有大量歷史使用者紀錄，但新平台或服務仍尚未累積足夠多的使用者紀錄。

本論文想要研究的是如何在不取用額外屬性資料（meta data）、單純利用使用者物品互動（user-item interaction）資料，強化跨領域（cross-domain）之推薦結果。

3.1.1 先備知識

TransE

TransE [2] 是一種知識圖譜（knowledge graph）的圖形學習表示方法。在一般關係網路中，兩節點的互動關係可以簡單以 (u, v) 一個二元組（pair）來表示，也就是「節點 u 和物節點 v 有互動」的意思。而在 TransE 這個方法當中，由於關係網路使用的是知識圖譜類型的複雜網路，於是將節點與節點的關係看作是 (h, r, t) 這樣一個三元組（triplet），也就是「頭節點、關係、尾節點」的形式；除了原本的兩節點之外，也考慮到了兩節點之間的關係。TransE做了一個假設：若頭節點和尾節點之間確實有一層「關係」的話，頭節點向量加上關係向量後應該要與尾節點向量相同。

DOI:10.6814/NCCU202101565

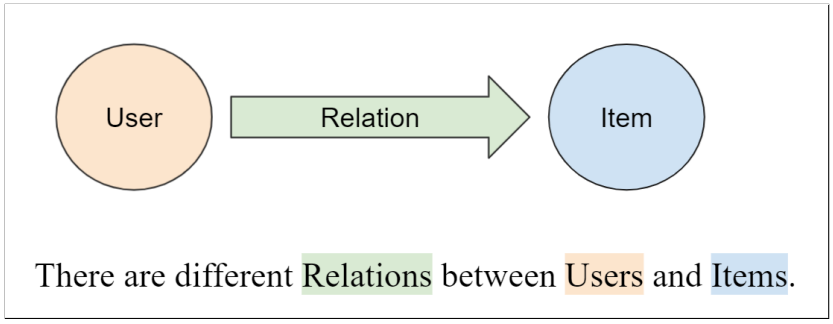

圖 3.1: TransE 模型概念圖

將節點和關係都用向量表示之後，TransE要優化的目標函數（Objective function）是結合負採樣（negative sampling）和max-margin的損失函數（loss function），用式子 3.1 來得到「頭節點向量 $\vec{h}$ 加上關係向量 $\vec{r}$ 後與尾節點向量 $\vec{t}$ 相減」之值，藉此評估採樣中某樣本的分數，最後得到損失函數如式子 3.2 ，其中 d_{pos} 表示正採樣的分數、 d_{neg} 表示負採樣的分數；負採樣的方法是保留 r ，然後抽換掉 h 或 t 。最小化這個損失函數可以使正採樣的分數越來越高而負採樣的分數越來越低，但是兩個得分差距大到接近邊際值（margin） γ 的程度就足夠了，因爲差距繼續拉大的話得到的 loss 也依然是 0 ，不用浪費時間繼續計算。若以圖 3.2 來說，就是 $\vec{u}+\vec{r}=\vec{v}$ 且目標是最小化 $\{\vec{u}+\vec{r}-\vec{v}\}$ 。

$$d = \|\vec{h}+\vec{r}-\vec{t}\| \tag{3.1}$$

$$\mathrm{L} = \sum [\max(0, d_{\text{pos}} - d_{\text{neg}} + \gamma)] \tag{3.2}$$

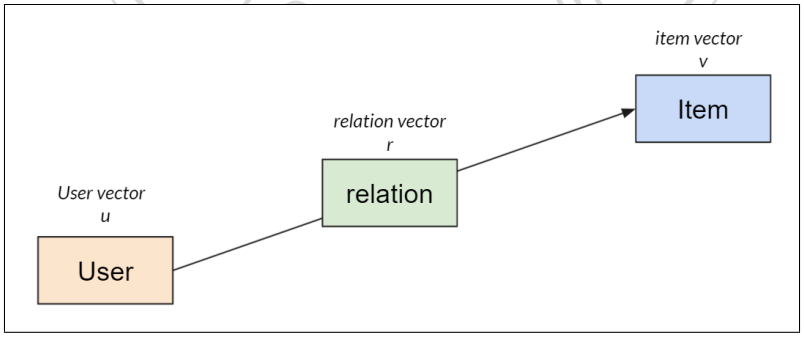

圖 3.2: TransE 模型細節示意圖

隨著學者們根據 TransE 爲基礎持續進行研究，發展出了 Translation-based 的圖形學習表示體系，如運用超平面（Hyperplane）方法去增加 TransE 假想平面維度的 TransH [24] ，以及除了節點與關係之外建立更多映射空間去學習不同關係之間之連結的 TransR [11] 。

DOI:10.6814/NCCU202101565

TransRec

TransRec [8] 受到 TransE 啓發後，針對序列推薦做出改良後提出的圖形學習表示方法。它特別的地方在於可以透過很好的建模方式，去預測使用者的行爲序列以及下一個物品的推薦；舉例來說，我有一個使用者依照時間順序購買的物品序列，那麼我希望能透過此序列建模，得到該使用者下一個或甚至下下個可能購買的物品。矩陣分解法爲基礎的很多推薦演算法都僅對使用者和物品的互動行爲進行建模，無法將時間或隱含的先後來由資訊納入其中，故無法滿足我們對於序列推薦的需求。TransRec藉由空間的概念，使訓練過程涵蓋了時間變化的資訊，並不單單只是訓練節點與其彼此之間的表示向量。

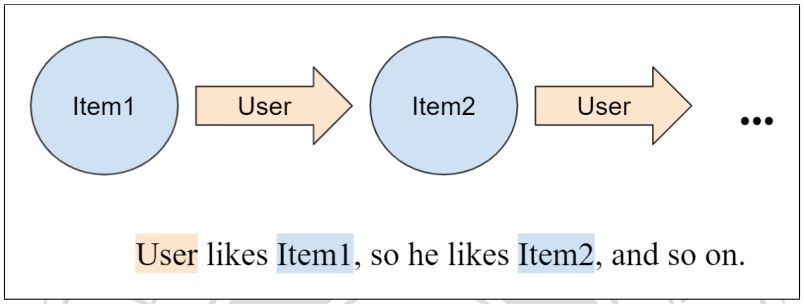

圖 3.3: TransRec 模型概念圖

延續 TransE 的概念，我們可以發現 TransRec 這邊有一個設計上的巧思：它將 TransE 中的關係（relation）改成使用者，於是得到了類似於「如果將一個物品順利推薦給某使用者，那我們可以推測該使用者可能購買的下一個物品」。如果以圖 3.4 來表達的話，可以看到 $\vec{v_1} + \vec{u_1} = \vec{v_2}$，意即一個物品表示向量加上使用者表示向量時，會等於對使用者推薦的下一個物品之表示向量。

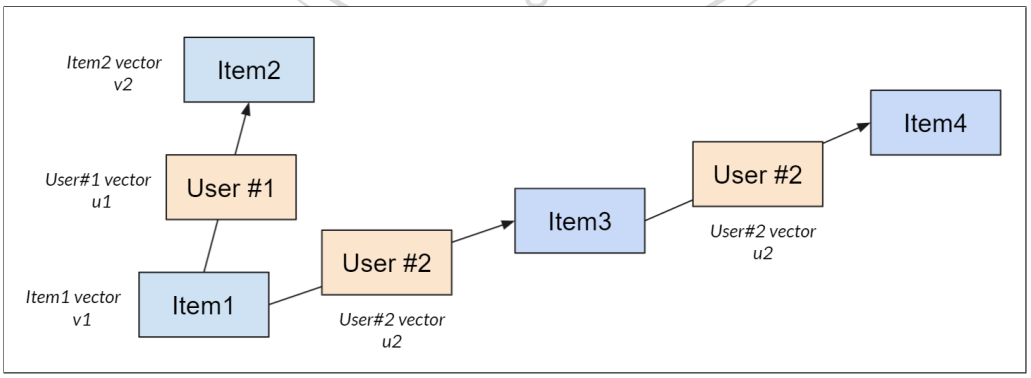

圖 3.4: TransRec 模型細節示意圖

有趣的地方是，TransRec 會將使用者喜歡的物品放在使用者向量延伸的位置上，可是這樣的序列推薦會過度依賴使用者向量，導致太熱門的物品會被過度推薦給所有人。於是 TransRec 的解決方法是增加了一個偏置項（bias term）β

DOI:10.6814/NCCU202101565

來降低熱門物品的權重，當物品被越多的用户喜歡時，它的 β 值就越低：如式子 3.3 所示，u 是使用者、i 是使用者先互動的物品、j 是使用者在與 i 互動後才互動的物品。因爲他們採用的採樣訓練方式是序列貝氏個人化推薦（Sequential Bayesian Personalized Ranking, S-BPR） [9] ，故可得目標函數如式子3.4，其中 Θ 爲我們想要訓練得到的表示向量組和偏置項 β 、$\vec{i}$ 和 $\vec{j}$ 代表物品的表示向量、$\vec{u}$ 是使用者的表示向量，而 j' 爲負採樣得到的物品。

$$\mathrm{Prob}(j \mid u, i) \propto \beta_j - d\left(\vec{i} + \vec{u} - \vec{j}\right) \tag{3.3}$$

$$\hat{\Theta} = \arg\max_{\Theta} \ln \prod_{u} \prod_{j} \prod_{j'} \mathrm{Prob}\left(j >_{u,i} j' \mid \Theta\right) \mathrm{Prob}(\Theta) \tag{3.4}$$

3.1.2 研究動機

本章節一開始的問題定義中曾提到，本論文想要研究如何在不取用額外屬性資料、單純利用使用者物品互動關係網路的狀況下，達到快速強化跨領域推薦結果。在經過評估後，綜合 Translation-based 的系列模型特色，我們延伸出幾個研究動機：

- 相對於很多如 Deepwalk 、 LINE （Large-scale Information Network Embedding）或 HOP-rec （High-Order Proximity for implicit Recommendation） 這種強調獲得更高階資訊（high-order information）的驗算法比起來， Translation-based 模型中的 TransRec 相對更直白地爲人與物品之間的關係建模。如果這樣的建模方法延伸到跨領域的範疇，將資訊量大的領域當成是使用者的背景資料、資訊量小的領域當成是使用者下一個想要互動的目標資料，是否也能取得像 TransRec 在序列推薦任務上優異的表現呢？畢竟 Translation-based 模型確實在序列推薦任務中擁有更加出色的泛化表現，尤其是在關係建模的技巧中更是獨樹一格；若採用 Translation-based 模型的關係建模技巧，是否在跨領域推薦中也能夠受益？

- Translation-based 模型的最初始版 TransE 簡單地將頭節點表示向量與尾節點表示向量相加，然後使用矩陣分解法的近似函數（loglikelihood）更新，即取得不錯的效果。倘若採用貝氏個人化推薦的採樣方法和損失函數，會不會得到更好的效果？

- 目前 Translation-based 相關模型的使用者物品一階合併方法皆是相加；倘若我們改採相乘的方式將使用者與物品的一階資訊合併，會不會取得更好的效果？

DOI:10.6814/NCCU202101565

3.2 TransRecCross模型

本論文基於 Translation-based 序列推薦模型，提出一個特化的模型，在此簡稱 TransRecCross ，是一個透過改變採樣方式來提升跨領域推薦效果的圖形學習表示模型。 TransRecCross 模型的核心假設是「使用者因爲在某個領域喜歡某些物品，所以才在另一個領域中喜歡某個物品」，概念圖如 3.5 所示。

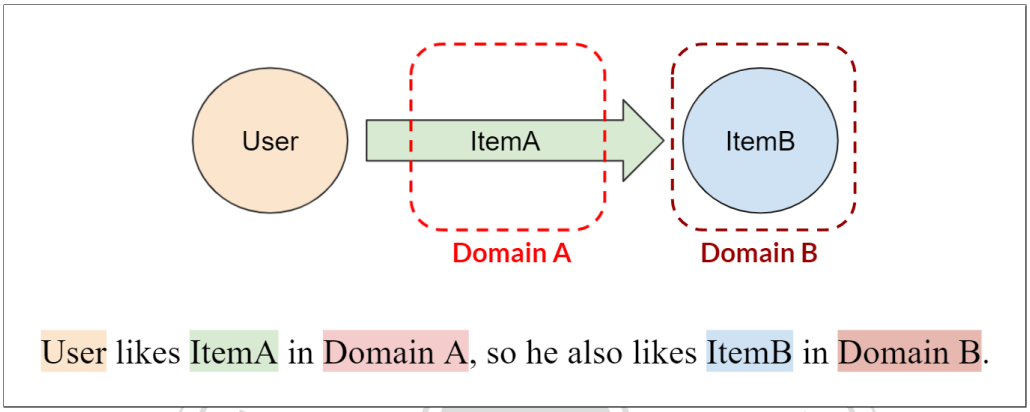

圖 3.5: TransRecCross 模型概念圖

3.2.1 符號定義

開始討論模型細節之前，我們先定義各種符號的意義：

表 3.1: 符號定義

符號	定義與解釋
$\mathcal{U}, \mathcal{I}$	使用者集合、物品集合
$\mathcal{S}, \mathcal{S}^u$	資訊較多的領域中的物品 $\mathcal{S} \in \mathcal{I}$、使用者 u 在 $\mathcal{S}$ 中的互動過的物品集合
$\mathcal{T}, \mathcal{T}^u$	資訊較少的領域中的物品 $\mathcal{T} \in \mathcal{I}$、使用者 u 在 $\mathcal{T}$ 中的互動過的物品集合
$\mathcal{U}^{\mathcal{S}}, \mathcal{U}^{\mathcal{T}}$	在資訊較多的領域中的使用者集合、在資訊較少的領域中的使用者集合
u, i, j	使用者 $u \in \mathcal{U}$，物品 $i, j \in \mathcal{I}$
$\vec{u}, \vec{i}, \vec{j}$	u, i, j 的表示向量
$d(\vec{x}, \vec{y})$	x 和 y 兩者之間的歐氏距離
Θ	目標訓練參數，即所有學習表示向量
σ	激發函數sigmoid
$\Omega(x)$	L2正規化函數

DOI:10.6814/NCCU202101565

3.2.2 模型介紹

本論文藉由兩種不同優化方式和兩種不同向量距離計算方式，共分爲四個不同的模型 TransRecCross 、 TransRecCross-Pref 、 TransRecCross-BPR 和 TransRecCross-Pref-BPR，並且會在下一個章節中做出效果比較與探討：

- **TransRecCross**：最基本的模型，單純使用矩陣分解法中的 loglikelihood 進行向量更新。以圖 3.6 來說，$(\vec{u_1}+\vec{v_1})$ is similar to $\vec{v_2}$ ， user 會喜歡 item2 是因爲 item1 。

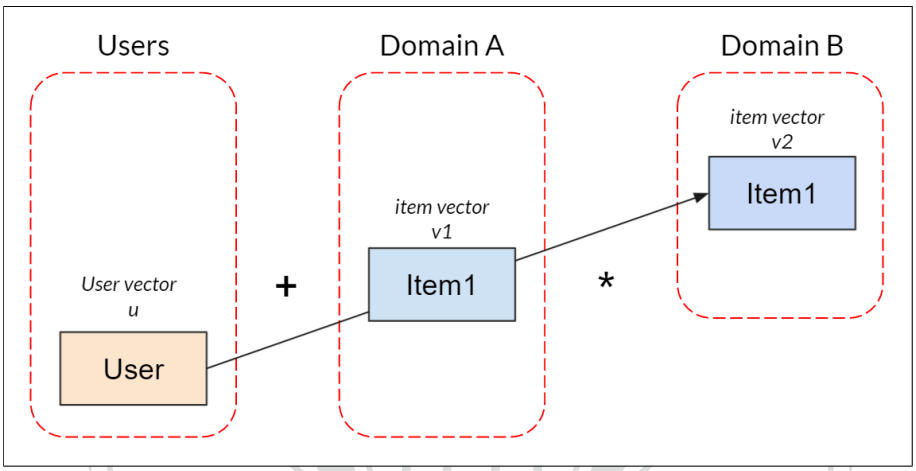

圖 3.6: TransRecCross 模型細節示意圖

在 TransRecCross 中，由於我們是「使用者因爲在某個領域喜歡某些物品，所以才在另一個領域中喜歡某個物品」，所以我們可以用式 3.6 之 $\mathcal{L}_{org}$ 作爲損失函數、式 3.7 作爲目標函數，利用梯度下降（Stochastic Gradient Descent，SGD）更新表示向量。其中 j' 是負採樣的物品，在均勻分布（uniform distribution）下隨機抽出。

$$\widehat{p_1}_{u,i,j} = d\left(\vec{i}+\vec{u},\vec{j}\right) \tag{3.5}$$

$$\mathcal{L}_{org} = \sum\left[\gamma + \widehat{p_1}_{u,i,j} - \widehat{p_1}_{u,i,j'}\right] \tag{3.6}$$

$$\hat{\Theta} = \arg\max_{\Theta}\left[\sum_{u\in\mathcal{U},i\in\mathcal{S}^u}\sum_{j\in\mathcal{T}^u}\ln\sigma\left(\widehat{p_1}_{u,i,j}\right) - \sum_{u\in\mathcal{U},i\in\mathcal{S}^u}\sum_{j'\notin\mathcal{T}^u\cup\mathcal{S}^u}\ln\sigma\left(\widehat{p_1}_{u,i,j'}\right) - \Omega\left(\Theta\right)\right] \tag{3.7}$$

- **TransRecCross-Pref**：由於過去 Translation-based 的系列模型皆是以相加作爲使用者與物品的一皆資訊合併方法，故在此我們嘗試將使用者與物

DOI:10.6814/NCCU202101565

品的向量不再將兩兩相加而是做逐點相乘（$\odot$），以此作爲使用者之偏好（preference）進行向量更新。以圖 3.7 來說，(u_1's preference of v_1) is similar to $\vec{v_2}$，「user 喜歡 item1」這件事與 item2 有關。

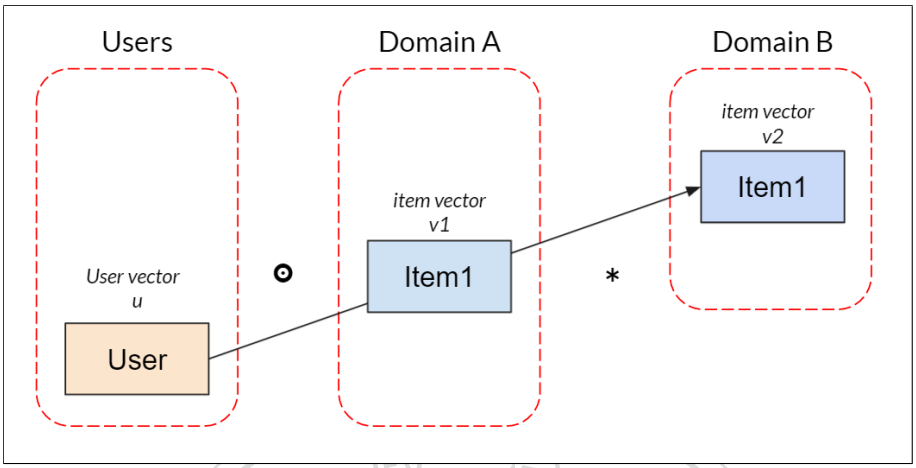

圖 3.7: TransRecCross-Pref 模型細節示意圖

在 TransRecCross-Pref 中，我們想嘗試將偏好相關的訊息隱含在訓練模型裡，故採樣得到的使用者 u 和物品 i 之表示向量是用點相乘後的結果與物品 j 計算距離。這時損失函數會變 $\mathcal{L}_{org}$：

$$\widehat{p}_{2u,i,j} = d\left(\vec{i} \odot \vec{u}, \vec{j}\right) \tag{3.8}$$

$$\mathcal{L}_{pref} = \sum \left[\gamma + \widehat{p}_{2u,i,j} - \widehat{p}_{2u,i,j'}\right] \tag{3.9}$$

$$\hat{\Theta} = \arg\max_{\Theta} \left[\sum_{u \in \mathcal{U}, i \in \mathcal{S}^u} \sum_{j \in \mathcal{T}^u} \ln \sigma\left(\widehat{p}_{2u,i,j}\right) - \sum_{u \in \mathcal{U}, i \in \mathcal{S}^u} \sum_{j' \notin \mathcal{T}^u \cup \mathcal{S}^u} \ln \sigma\left(\widehat{p}_{2u,i,j'}\right) - \Omega\left(\Theta\right) \right] \tag{3.10}$$

- **TransRecCross-BPR**：基於 TransRecCross 模型，將純粹 loglikelihood 的計算方式改成貝氏個人化推薦法的更新模式。

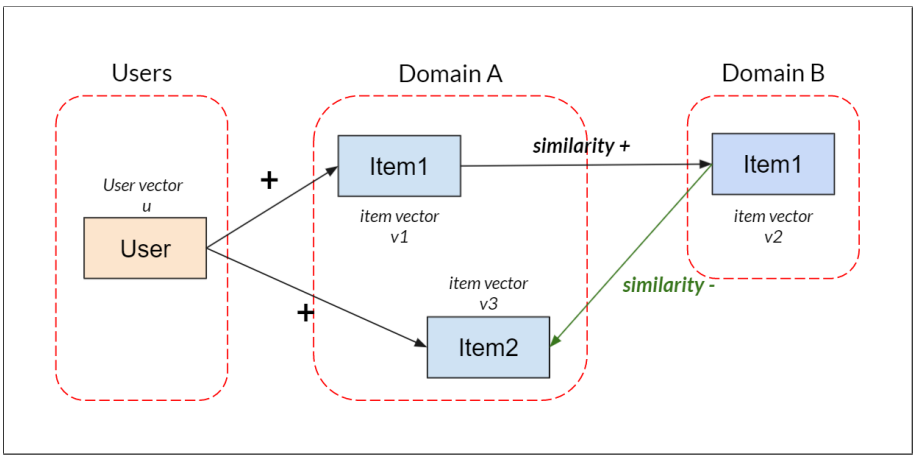

圖 3.8: TransRecCross-BPR 模型細節示意圖

DOI:10.6814/NCCU202101565

在 TransRecCross-BPR 中，我們改採貝氏個人化推薦的更新方式並調用 L2 正規化，得到式 3.12 中的損失函數以及如式 3.13 的目標函數：

$$\widehat{p_1}_{u,i,j} = d\left(\vec{i} + \vec{u}, \vec{j}\right) \tag{3.11}$$

$$\mathcal{L}_{org} = \sum \left[\gamma + \widehat{p_1}_{u,i,j} - \widehat{p_1}_{u,i,j'}\right] \tag{3.12}$$

$$\hat{\Theta} = \arg\max_{\Theta} \sum_{u \in \mathcal{U}, i \in \mathcal{S}^u} \sum_{j \in \mathcal{T}^u} \sum_{j' \notin \mathcal{T}^u \cup \mathcal{S}^u} \ln \sigma\left(\widehat{p_1}_{u,i,j} - \widehat{p_1}_{u,i,j'}\right) - \Omega(\Theta) \tag{3.13}$$

- **TransRecCross-Pref-BPR**：基於 TransRecCross-Pref 模型，將 loglikelihood 的計算方式改成貝氏個人化推薦法。

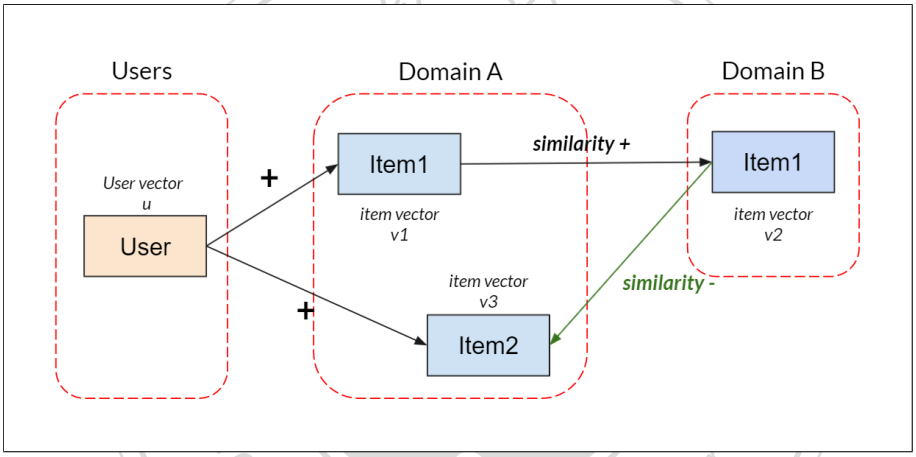

圖 3.9: TransRecCross-BPR 模型細節示意圖

在 TransRecCross-Pref-BPR 中，我們想嘗試將偏好相關的訊息隱含在 TransRecCross-BPR 裡。與 TransRecCross-Pref 一樣，我們採樣得到的使用者 u 和物品 i 之表示向量是用點相乘後的結果與物品 j 計算距離，得到式 3.15 的 $\mathcal{L}_{pref}$ 損失函數和式 3.16 的目標函數：

$$\widehat{p_2}_{u,i,j} = d\left(\vec{i} \odot \vec{u}, \vec{j}\right) \tag{3.14}$$

$$\mathcal{L}_{pref} = \sum \left[\gamma + \widehat{p_2}_{u,i,j} - \widehat{p_2}_{u,i,j'}\right] \tag{3.15}$$

$$\hat{\Theta} = \arg\max_{\Theta} \sum_{u \in \mathcal{U}, i \in \mathcal{S}^u} \sum_{j \in \mathcal{T}^u} \sum_{j' \notin \mathcal{T}^u \cup \mathcal{S}^u} \ln \sigma\left(\widehat{p_2}_{u,i,j} - \widehat{p_2}_{u,i,j'}\right) - \Omega(\Theta) \tag{3.16}$$

DOI:10.6814/NCCU202101565

3.2.3 採樣細節分析

我們的任務是跨領域推薦，理想上會希望所有使用者都在不同領域中有至少一個以上的互動；但現實的狀況永遠不是完美的，很常發生使用者沒有某個領域中互動資料的情形。我們可以在此根據使用者與物品於不同領域中的互動關係，把上述任務分成四種不同的情況：

- 情形一：使用者在資訊較多的領域和資訊較少的領域中，與物品都有互動，則我們以圖 3.10 的方式進行採樣。

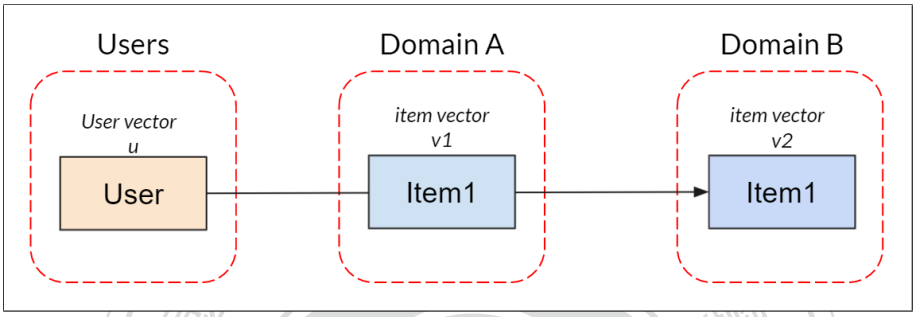

圖 3.10: TransRecCross 情形一採樣方式示意圖

- 情形二：使用者在資訊較多的領域與物品都有互動，但在資訊較少的領域中沒有任何與物品的互動，則我們以圖 3.11 的方式進行採樣。

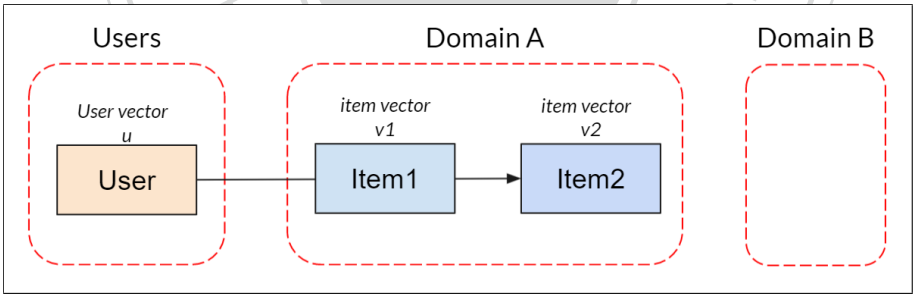

圖 3.11: TransRecCross 情形二採樣方式示意圖

- 情形三：使用者在資訊較少的領域與物品都有互動，但在資訊多較的領域中沒有任何與物品的互動，則我們以圖 3.12 的方式進行採樣。

DOI:10.6814/NCCU202101565

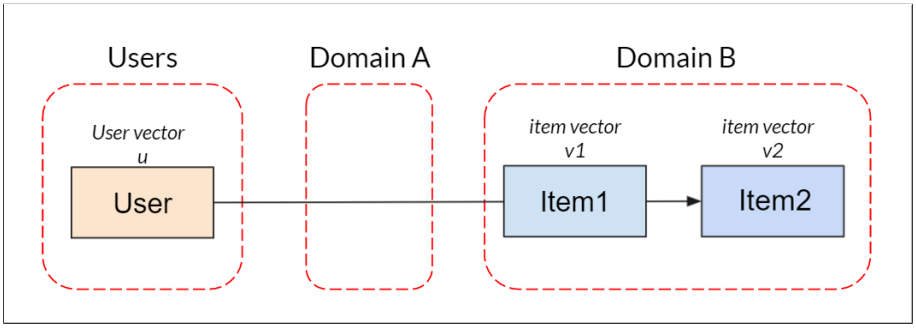

圖 3.12: TransRecCross 情形三採樣方式示意圖

- 情形四：其他情境如使用者在資訊較少或資訊較多的領域中僅有一個以下的互動物品，則我們不採取行動。

國立政治大學 National Chengchi University

DOI:10.6814/NCCU202101565

第四章

實驗結果與討論

4.1 資料集

本論文應用之場景爲對同一個使用者在不同領域的推薦，也就是共同使用者之跨領域推薦，故我們需要大量使用者與不同領域之物品互動的資料。跨領域推薦任務中，常被拿來使用的有中國社交平台豆瓣的電影與書籍評價、 Netflix Prize 與 MoveLens 中對於使用者對電影的評價，以及 Amazon 提供的 Amazon Review 公開資料集。本論文採用 Amazon Review 2018 年版本的資料集[1]，因爲豆瓣的資料集較難統整且較難與其他論文做比較，而 Netflix Prize 與 MovieLens 的資料集屬於共同物品之跨領域資料，而非共同使用者之跨領域資料。

我們這邊定義資料較多較齊全的領域爲「來源領域（Source Domain）」，而資料較少的領域稱作「目標領域（Target Domain）」，也就是我們想要強化推薦的領域。本論文從 Amazon Review 資料集中選擇的領域有四個，其中 Books 作爲來源領域，而 CDs and Vinyl 、 Digital Music 和 Industrial and Scientific 作爲目標領域：

- **Books**： 此領域資料爲 Amazon 使用者對各種實體書籍的評價紀錄。雖然 Amazon 現在有許多其他相關產品，但該企業本身是線上電子書商起家的，故 Books 領域的歷史紀錄最悠久、資料也最多，非常適合作爲來源領域。截至 2018 年爲止，此資料集爲 Amazon Review 所有資料集中，使用者評價總量最多之資料集，所以非常適合作爲來源領域。

- **CDs and Vinyl**： 此領域資料爲 Amazon 使用者對實體音樂光碟片以及黑膠唱片的評價紀錄。截至 2018 年爲止，此資料集評價總量不到 Books 資料集之一半，故以比例上來說此資料集適合作爲一般目標領域。

[1] Amazon Review 2018: https://nijianmo.github.io/amazon/index.html

DOI:10.6814/NCCU202101565

- **Digital Music**： 此領域資料爲 Amazon 使用者對各種非實體光碟之音樂的評價紀錄。截至 2014 年爲止，此資料集爲 Amazon Review 所有資料集中，使用者評價總量排名倒數第三之資料集，很適合作爲資料量偏少的目標領域。

- **Industrial and Scientific**： 此領域資料爲 Amazon 使用者對各種工業用具和科學材料的購買評價紀錄。作爲一個 2018 年才出現的新分類，使用者評價總量在 Amazon Review 所有資料集中也是排名倒數的，適合作爲資料量非常稀疏之目標領域。

	#user	#item	#edge	density(%)
Books	13,911,803	2,756,950	43,537,386	1.14×10^{-4}
CDs and Vinyl	1,770,052	412,833	3,966,745	5.43×10^{-4}
Digital Music	781,581	432,026	1,460,076	4.32×10^{-4}
Industrial and Scientific	1,023,300	147,663	1,435,081	9.50×10^{-4}

表 4.1: 各領域資料之圖形相關統計

爲了使測試過程順利進行，我們要避免測試時遇到沒有對應資料的情況。所以切訓練與測試資料集時，我們要先取出同時存在於來源資料集與目標資料集的使用者，然後取出那些使用者與目標領域的互動資料；如果以圖形（graph）來形容的話，就是把其邊（edge）提取出來，最後再將其切分出四分之一作爲測試資料集。可以從表 4.2 中觀察到，「共同使用者在目標領域中互動的總數」佔「目標領域的互動總數」之五到六成，故將切分出的測試資料控制在恰好一半，使其約莫佔目標領域總互動數之四分之一。

	overlapping users		overlapping edges	
	% of source	% of target	% of source	% of target
CDs and Vinyl	5.51	43.38	14.19	57.49
Digital Music	2.83	50.34	7.99	59.03
Industrial and Scientific	3.23	43.86	7.48	48.74

表 4.2: 目標領域與來源領域之使用者交集統計

4.2 比較基準模型

本論文將 TransRecCross 與其他近10年來經常使用於推薦系統的圖形學習表示演算法進行比較。我們基準線並沒有納入 EMCDR 等等的演算法，是因爲我們想要比較的對象是未使用深層網路或多層類神經網路映射的推薦方法。爲求公平，我們將許多參數和模型參數量限制在同標準與規格之下，於是選出了下列模型：

DOI:10.6814/NCCU202101565

- **MF**（Matrix Factorization）：矩陣分解法是推薦系統中協同過濾法裡面最基礎且簡易實作的一種演算法，其原理是將使用者與物品映射到某維度的空間中，並將其乘積定義爲兩者之互動關係。矩陣分解法並不考慮多層次之資訊和互動分佈，亦沒有實作負採樣。

- **BPR**（Bayesian Personalized Ranking）[19]：貝氏個人化推薦是一種改良後的矩陣分解優化方法，特色是稍稍改變逐點方法中的負採樣，把負採樣與正採樣物件間的相似度也納入考量，使其對於模型的更新更加細緻。

- **DeepWalk** [16]：深度遊走的概念爲使用隨機遊走（Random Walk）進行採樣後，再利用 Word2vec 中 Skip-gram 的更新方法進行表示向量的學習。深度遊走可以藉由隨機遊走的深度優先、重複走訪特性，達成高階資訊的整合，但缺點就是太過依賴隨機性，所以想要獲得良好的學習表示向量需要大量運算時間。

- **LINE**（Large-scale Information Network Embedding）[21]：上述 DeepWalk 採用的隨機遊走採樣是一種深度優先的走訪方式，而 LINE 改採用廣度優先的走訪方式，能穩定地提供所謂二階相似度（second-order proximity）的高階資訊。

- **APP**（Asymmetric Proximity Preserving graph embedding）[29]：只要是 Random Walk 相關的高階資訊整合，都建立在所有互動權重皆等價的假設之上，可是一階、二階等等不同階的資訊權重明顯不該是等價的。APP 是一種基於隨機遊走的圖形學習表示法，它的特色是透過保留圖形的非對稱結構，可以得到互動資訊適當的權重，進而得到合理的推薦結果。

- **HPE**（Heterogeneous Preference Embedding）[3]：HPE 透過大量權重化隨機遊走（Weighted Random Walk），來達到類似於搜尋引擎的資訊過濾效果，提升對推薦項目的泛化性。

- **HopRec**（High-Order Proximity for Implicit Recommendation）[25]：HopRec 理論上是基於使用者與物品互動之現行最優（state-of-the-art）的推薦圖形學習表示法，是一個可以穩定整合高階資訊的方法。

- **CSE**（Collaborative Similarity Embedding）[4]：CSE 是一個基於使用者與物品互動的公認強基準線（strong baseline）推薦圖形學習表示法。CSE 採樣出一對使用者與物品後，會對使用者和物品分別進行隨機遊走、整合高階資訊，最後才利用剛剛整合的高階資訊更新彼此的表示向量。

- **TransRec**（Translation-based Recommendation）[8]：TransRec 是 Translation-based 的序列推薦演算法，亦可套用在一般推薦任務上。它能夠很好地建構出使用者與物品之間的關聯性和順序。

DOI:10.6814/NCCU202101565

4.3 實驗設定與驗證標準

4.3.1 實驗設定

本論文把目標領域資料切分爲兩部分，分別爲「訓練資料」與「測試資料」，而來源領域不會切分，因爲來源領域的資料都將作爲訓練資料。切訓練與測試資料集時，我們會取出同時存在於來源資料集與目標資料集的使用者，再取出那些使用者與目標領域的互動資料，最後再將約莫 50% 作爲測試資料，其餘 50% 作爲訓練資料。以目標領域整體資料佔比來說，切分出的測試資料約爲原資料集資料總數之 25% 左右。本章節沿用第三章之符號定義：若以符號表示，測試資料集數量即爲 $\lceil \sum_u |\mathcal{T}^u| \times 50\% \rceil$ ，其中 $u \in \{\mathcal{U}^S \cap \mathcal{U}^T\}$ 。

模型參數的部分，本論文將每一種演算法之「邊採樣（edge sampling）」次數控制在 10^7 次、每次邊採樣後的最大負採樣次數爲 5 次、表示向量維度皆是 64 維；初始學習速率（learning rate）爲 2.5×10^{-2} ，隨採樣數量增加而下修學習速率，其最低學習速率爲 2.5×10^{-5} ；如果遇到需要隨機遊走的演算法，設其隨機遊走最大深度爲 20 、 skip-gram 的窗口大小爲 5 、總遊走次數爲 3 ；如果需要給定邊際值（margin）的話，將邊際值大小設定爲 8.0 ，而 L2 正規化（L2-Regularization）中的 λ 值爲 10^{-3} 。

4.3.2 驗證標準

一般推薦任務分爲兩階段，第一階段爲召回階段，如以召回（Recall）爲主要目的的 Top-N 任務，希望從大量物品中過濾並擷取出固定數量的物品推薦給使用者；而第二階段則是精準排序階段，如點閱率（Click Though Rate，CTR）任務，目標是從第一階段那些已經過濾出的物品中，依照使用者可能喜好的順序更精確地排列物品、甚至預測使用者的互動情形。本實驗選擇的推薦任務爲 Top-N 任務，目標是從海量的物品中擷取出使用者可能喜歡的物品，實作方法是從使用者過去曾互動過的物品中隨機選擇 5 項物品、採用內積和作爲相似度指標，在表示向量空間中搜尋與它們最相似的其他物品。

命中率（**Hit rate**）

命中率（HR）是一個直觀的評價指標，它的概念是「在推薦的 N 個物品中，使用者喜歡或互動過的物品之比例有多少」。在 Top-N 任務中，命中率的計算方式爲對於使用者 u 得到推薦的物品集合 $\mathcal{R}^u$ 後，得到對使用者正確推薦的數量 $|\mathcal{R}^u \cap \mathcal{I}^u|$ ，然後直接計算正確推薦的比例並累加取平均值；由於是 Top-N 推

DOI:10.6814/NCCU202101565

薦任務，故 $|\mathcal{R}^u| = N$ 、 $|\mathcal{R}^u \cap \mathcal{I}^u| \leq N$ 。 計算公式如式 4.1 所示：

$$\text{HR} = \frac{1}{|\mathcal{U}|} \sum_{u \in \mathcal{U}} \frac{|\mathcal{R}^u \cap \mathcal{I}^u|}{|\mathcal{R}^u|} \tag{4.1}$$

命中率能夠很直觀的評價推薦結果，但缺點是當大多數使用者喜好的物品數量小於 N 時，命中率就會因爲分母 $|\mathcal{R}^u|$ 過大而降低。

召回率（**Recall**）

召回率是除了命中率之外，另一個經常被使用在評估推薦結果的評價指標，它的概念是「在推薦的物品中使用者喜歡的物品，佔該使用者所有喜歡之物品的比例有多少」。在 Top-N 任務中，召回率的計算方式爲對於使用者 u 得到推薦的物品集合 $\mathcal{R}^u$ 後，得到對使用者正確推薦的數量 $|\mathcal{R}^u \cap \mathcal{I}^u|$ ，再得到使用者所有喜歡的物品數量 $|\mathcal{I}^u|$ ，最後才計算正確推薦的比例並累加取平均值。計算公式如式 4.2 所示：

$$\text{Recall} = \frac{1}{|\mathcal{U}|} \sum_{u \in \mathcal{U}} \frac{|\mathcal{R}^u \cap \mathcal{I}^u|}{|\mathcal{I}^u|} \tag{4.2}$$

當然，召回率也有一些缺點，例如當大多數使用者喜好的物品數量遠大於 N 時，明明 N 個物品全部推薦正確、命中率接近 100% ，召回率卻反而因分母 $|\mathcal{I}^u|$ 過大而拉低然後失眞。

平均準確率均值（**Mean Average Precision**）

命中率和召回率並沒有考慮推薦結果的排序，所以如果我們想要更加細緻地評估推薦結果，可以透過平均準確率均值（mAP）評估。平均準確率均值爲平均準確率（Average Precision，AP）的均值，它的概念是「如果我們已經得到一系列排序過的推薦結果，若推薦正確的物品在排序上越靠前、排名越前面的話，平均準確率均值就會越大」。平均準確率均值計算公式如式 4.3 所示，其中 AP_u 代表對使用者 u 推薦結果之平均準確率：

$$\text{mAP} = \frac{\sum_{u \in \mathcal{U}} \text{AP}_\text{u}}{|\mathcal{U}|} \tag{4.3}$$

平均準確率的公式如式 4.4 所示，其中 $\mathcal{R}_i^u$ 爲推薦給使用者 u 的物品中排序第 i 個的物品 ；而 δ 是一個用來表示使用者 u 是否眞的喜歡該物品的指標函數，其

DOI:10.6814/NCCU202101565

定義如式 4.5 所示：

$$\mathrm{AP_u} = \frac{1}{|\mathcal{I}^u|} \sum_{l=1}^{|\mathcal{R}^u|} \frac{\sum_{m=1}^{l} \delta\left(\mathcal{R}_m^u\right)}{l} \tag{4.4}$$

$$\delta(x) = \begin{cases} 1, & \text{if } x \in \mathcal{I}^u \\ 0, & \text{otherwise} \end{cases} \tag{4.5}$$

4.4 實驗結果

我們進行了三種不同的實驗，分別爲「加入 0% 來源領域資料（僅有目標領域資料）」、「加入 50% 來源領域資料（隨機一半的來源領域資料）」和「加入 100% 來源領域資料（所有來源領域資料）」。「僅有目標領域資料的實驗結果」主要是拿來和「加入所有來源領域資料後的實驗結果」來做比較，可作爲跨領域推薦結果的參考；「僅加入一半來源領域資料的實驗結果變化」則用來觀察模型的強化方法的可靠性。

4.4.1 跨領域推薦領域結果

包含了來源領域和目標領域資料的跨領域強化推薦結果如兩頁後之表 4.3 所示。排除 TransRec 這種 Translation-based 的方法，我們可以得知 DeepWalk 和 HopRec 等等含有大量高階資訊整合方法的模型在這類型的跨領域推薦任務中屬於效果較穩定之基準線，分別於三種不同的資料集中表現出不錯的推薦效果：在 CDs and Vinyl 的基準線推薦結果中，DeepWalk 的平均準確率均值較排名第二的 TransRec 高出 24% 左右，直接遠遠超過大多數方法；在 Digital Music 的基準線推薦結果中，TransRec 的平均準確率均值較第二名的 DeepWalk 高出 9% 左右、召回率較第二名的 HopRec 高出 8% 左右，命中率則是遠遠超過第二名 HopRec 約 40% 以上；在 Industrial and Scientific 的基準線推薦結果中，DeepWalk 的平均準確率均值較第二名的 TransRec 高出 8% 左右，但召回率的部分卻是 TransRec 排名第一。

我們亦發現到，即便 random walk 相關模型的主要目的並不是拿來做推薦使用，效果卻比較其他傳統推薦方法好。我們將其原因歸納爲評估方法不同所導致：由於本論文實驗設計皆使用共用使用者（shared user），所以訓練時的採樣目標也會以目標領域爲主；然而傳統的推薦方法會平等的考慮到所有領域的使用者及物品，故在此實驗設計下表現相對的差。

根據三個不同的資料集推薦任務，我們可看出 TransRec 在所有基準線模型中

DOI:10.6814/NCCU202101565

有著相對不錯的推薦結果：除了強化 CDs and Vinyl 推薦的任務以外，TransRec 在強化 Digital Music 推薦和強化 Industrial and Scientific 的推薦任務中都展現出不錯的效果，甚至在強化 Digital Music 推薦的任務中領先三種不同的 TransRecCross 模型，暗示著 Translation-based 的圖形學習表示法本身可能已具備較強的跨領域推薦潛力、 Translation-based 在重複的使用者跨領域推薦中可輕易取得較佳推薦效果。其實這是可以預見的，畢竟其他模型的訓練目標都是「使用者－物品」爲單位的二元組優化方法（pair optimizer）或「使用者－正採樣得到之物品－負採樣得到之物品」爲單位的三元組優化方法（triplet optimizer），但 Translation-based 的圖形學習表示法卻一定是「使用者－物品甲－物品乙」爲單位的三元組優化方法或「使用者－正採樣得到之物品甲－正採樣得到之物品乙－負採樣得到之物品」爲單位的四元組優化方法（quaternion optimizer），所以進行一次邊採樣時所涵蓋的資訊量較大。雖然 Translation-based 的圖形學習表示法無法整合大量高階資訊、面對能夠整合高階資訊和取得分布資訊的方法稍顯弱勢，但在面對兩個以上的圖形（graph）時，圖與圖之間的關係可以藉由 Translation-based 本身具有的「翻譯序列（translation）」特色而建模，並取得品質較高之表示向量。翻譯序列的概念即爲第三章的圖 3.3 和圖 3.5 所示，使用者可以藉由一個自己喜歡的物品連結至另一個自己喜歡的物品、或一個使用者可以藉來源領域喜歡的物品連結至目標領域喜歡的物品。

從表中我們亦可以見到 TransRecCross 系列方法表現相對其他所有模型都還要優異，證明了我們特化 TransRec 的採樣方式後得到 TransRecCross 這種強化推薦方法是有效的：在強化 CDs and Vinyl 推薦的任務中，平均準確率均值大幅領先最佳基準線 10% 以上；在強化 Digital Music 推薦的任務中，雖然表現最差的 TransRecCross 模型之平均準確率均值低於最佳基準線 23% 左右，但加入貝氏個人化推薦方法後的 TransRecCross-BPR 高於最佳基準線之平均準確率均值 7% 以上；在強化 Industrial and Scientific 推薦的任務中，雖然平均準確率均值僅小幅優於最佳基準線 4.5% 左右、並不是非常顯著的表現提升，但召回率和命中率皆是穩定優於最佳基準線模型的 13% 以上。跨領域任務中最重要的是目標領域的推薦效果，所以很明顯其他專注在整合單一領域之高階資訊的推薦方法對跨領域推薦並沒有顯著的幫助。 TransRecCross 的好處就是我們將推薦專注於目標領域：運用 TransRec 中翻譯序列的方法，強調以「來源領域與目標領域資料」去提升「目標領域推薦效果」，降低了不少抽樣所造成的隨機不穩定性。

DOI:10.6814/NCCU202101565

	Book → CDs and Vinyl			Book → Digital Music			Book → Industrial and Scientific		
	Recall@10	HR@10	mAP@10	Recall@10	HR@10	mAP@10	Recall@10	HR@10	mAP@10
APP	0.171088	0.028947	0.107537	0.293837	0.037500	0.212194	0.231752	0.026714	0.156390
BPR	0.193319	0.031020	0.149333	0.245693	0.031461	0.148841	0.258881	0.028261	0.180938
CSE	0.211448	0.032400	0.130581	0.234323	0.029703	0.158405	0.247098	0.028292	0.164160
DeepWalk	†0.272317	†0.044154	†0.213170	0.275556	0.035200	0.215124	0.319629	†0.035931	†0.258468
HopRec	0.199481	0.027626	0.120776	0.312500	0.035870	0.201704	0.205420	0.022902	0.141685
HPE	0.200763	0.027875	0.130150	0.231000	0.033000	0.161563	0.221254	0.025261	0.146509
LINE	0.175353	0.027459	0.110761	0.234985	0.029730	0.186284	0.226927	0.025753	0.164884
MF	0.216819	0.033218	0.150663	0.247036	0.034694	0.208989	0.215192	0.024425	0.141380
TransRec	0.235806	0.034178	0.177773	†0.336857	†0.041143	†0.244112	†0.327248	0.035773	0.238091
TransRecCross	*0.399938	*0.049815	*0.237000	*0.307428	*0.037079	*0.186967	0.337666	*0.038995	0.251588
Improv.(%)	+46.86	+12.82	+11.18	-8.74	-9.88	-23.41	+3.18	+8.53	-2.66
TransRecCross-BPR	*0.414042	*0.051575	*0.239951	***0.378686**	***0.046154**	***0.261524**	***0.371577**	***0.040893**	**0.270001**
Improv.(%)	+52.04	+16.81	+12.56	+12.42	+12.18	+7.13	+13.55	+13.81	+4.46
TransRecCross-Pref	***0.457577**	***0.062393**	***0.274390**	0.349057	*0.043396	*0.205548	0.332400	0.037433	*0.240977
Improv.(%)	+68.03	+41.31	+28.72	+3.62	+5.48	-15.80	+1.57	+4.18	-6.77
TransRecCross-Pref-BPR	*0.432533	*0.054093	*0.254242	0.327236	*0.037805	*0.218612	*0.352706	*0.039486	0.260767
Improv.(%)	+58.83	+22.51	+19.27	-2.86	-8.11	-10.45	+7.78	+9.89	+0.89

表 4.3: 跨領域推薦結果

DOI:10.6814/NCCU202101565

4.4.2 驗證跨領域強化能力

跨領域推薦強化的目的是爲了能夠讓資料較多的領域去強化資料較少的領域的推薦；也就是說，優質的強化方法能夠很好應對來源領域資料減少的情形，不會因爲來源資料量變化太大而導致效果大幅改變、效果十分穩定。爲了能夠驗證 TransRecCross 是否爲不錯的跨領域推薦強化方法，本論文額外進行了納入不同訓練資料比例的實驗。此驗證的實驗中，我們將來源領域資料的比例分爲 0% 、50% 、 100% ，並觀察三種資料比例對推薦結果的影響。其中由於 TransRecCross 需要來自來源領域以及目標領域的兩種資料才能訓練，所以我們在這邊定義「加入 0% 的來源資料時，TransRecCross 會把來源領域和目標領域視爲同一個領域」，藉此來得到較爲合理的訓練結果。

下一頁之圖 4.1 爲不同比例之來源資料幫助 CDs and Vinyl 資料集的跨領域推薦結果，數值的部分皆爲平均準確率均值。從中我們可以發現， TransRecCross 的方法在加入來源資料前都沒有太好的效果，但是在加入 50% 以上之來源領域資料時，推薦效果則大幅提升。特別的是，加入 50% 的來源資料時就已經能夠獲得很好強化推薦的效果，我們認爲是由於切分出的 50% 資料已包含許多「具交集的使用者（$\mathcal{U}^S \cap \mathcal{U}^T$）」，所以強化推薦效果才能顯著提升。

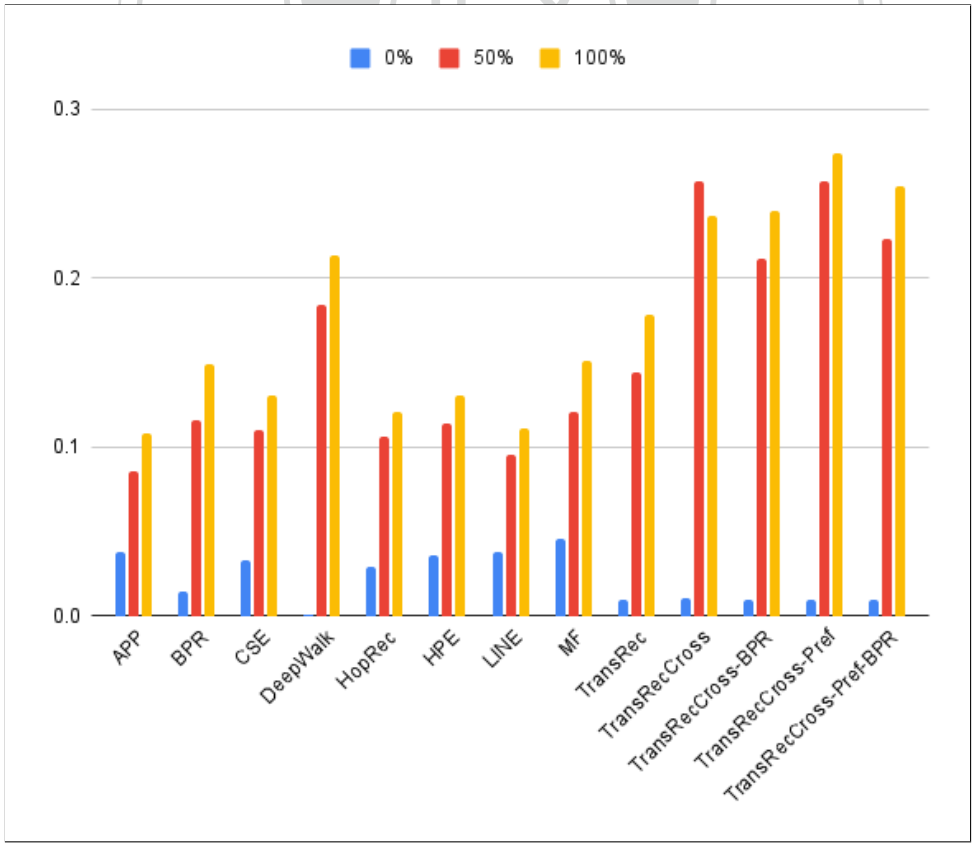

圖 4.1: 不同 Book 資料比例對 CDs and Vinyl 之推薦結果

圖 4.2 爲不同比例之來源資料幫助 Digital Music 資料集的跨領域推薦結果。

DOI:10.6814/NCCU202101565

此結果與 CDs and Vinyl 之推薦結果非常類似，也是在加入 50% 以上之來源領域資料後推薦效果大幅提升，且在加入 50% 資料時已經能夠獲得很好的強化推薦效果。

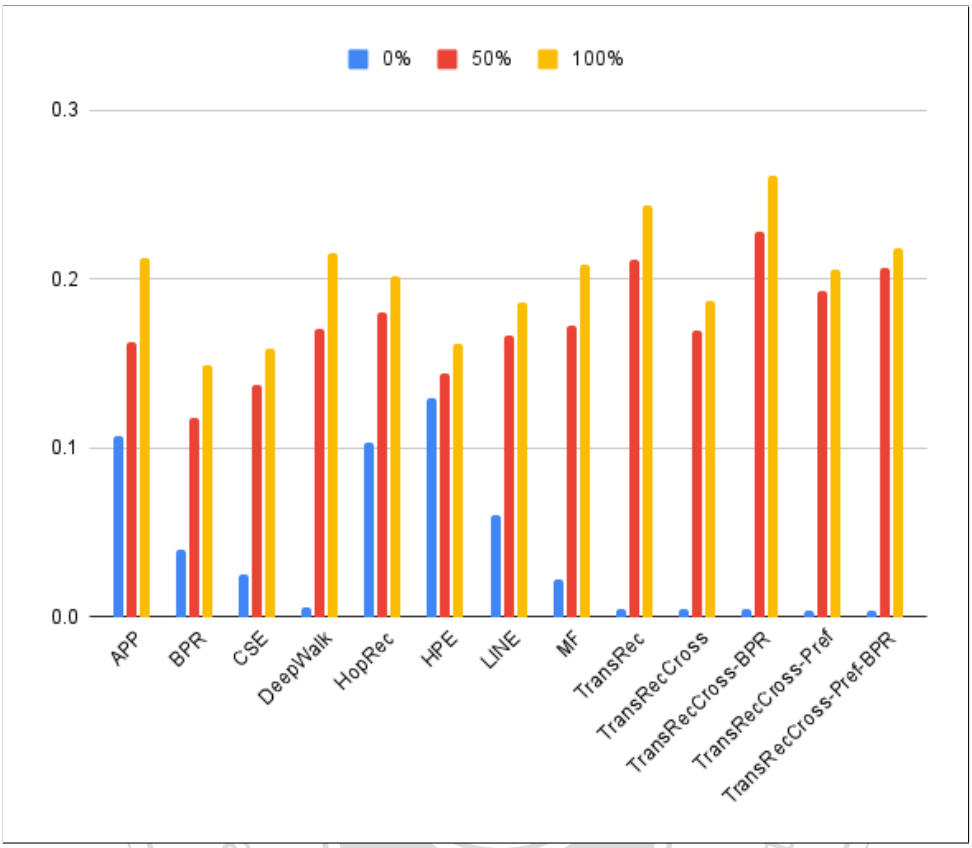

圖 4.2: 不同 Book 資料比例對 Digital Music 之推薦結果

下一頁的圖 4.3 爲不同比例之來源資料幫助 Industrial and Scientific 資料集的跨領域推薦結果，從中我們意外地發現，所有跨領域推薦結果皆劣於單一領域推薦結果。從加入 50% 來源領域資料到加入 100% 來源領域資料的效果變化中，我們可以推測推薦強化效果並不是沒有用，只是在加入所有資料之前不僅沒有幫助、甚至可能因爲混雜太多無用資訊而降低推薦效果；我們推測原因是此目標領域資料集的圖形密度（density）較高、與來源資料集的使用者交集量較低，畢竟在 CDs and Vinyl 與 Book 兩個領域中皆有評價紀錄的使用者，在 Book 資料集中的評價紀錄僅佔 Book 資料集所有評價紀錄之大約 14.19%，而 Industrial and Scientific 與 Book 兩個領域中皆有評價紀錄的使用者在 Book 資料集中的評價紀錄僅佔 Book 資料集所有評價紀錄之約莫 7.48% ，這比例僅僅是前者的一半左右；再者，此資料集爲2018年才釋出的新資料集，爲較新的資料集，故過去的大量使用者偏好資料極可能無法幫助到新領域的推薦結果。所以我們接著透過提升訓練次數，從 10^6 次邊採樣次數提升到 10^9 次，得到下一頁的圖 4.4 的結果。這個結果就比較接近前兩個資料集的推薦結果，雖然在加入 50% 的來源領域資料時依然會產生推薦效果下降的問題，但加入完整來源領域資料後推薦效果較單一領域推薦結果有些許提升。

DOI:10.6814/NCCU202101565

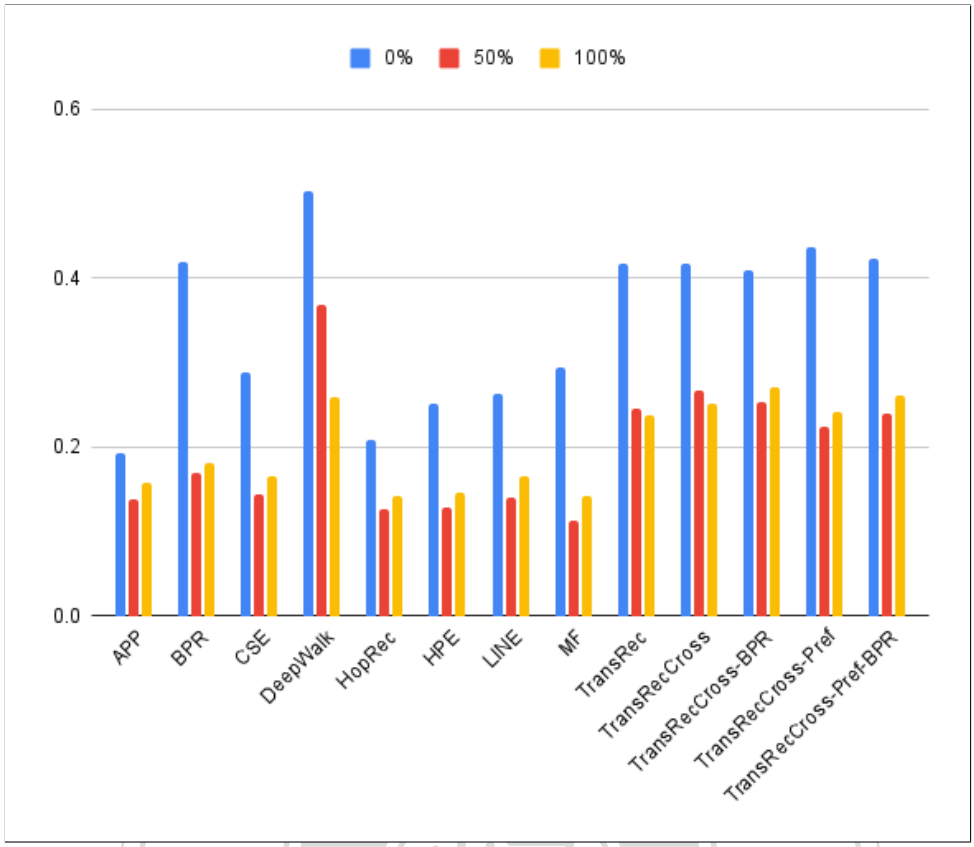

圖 4.3: 不同 Book 資料比例對 Industrial and Scientific 之推薦結果（調整前）

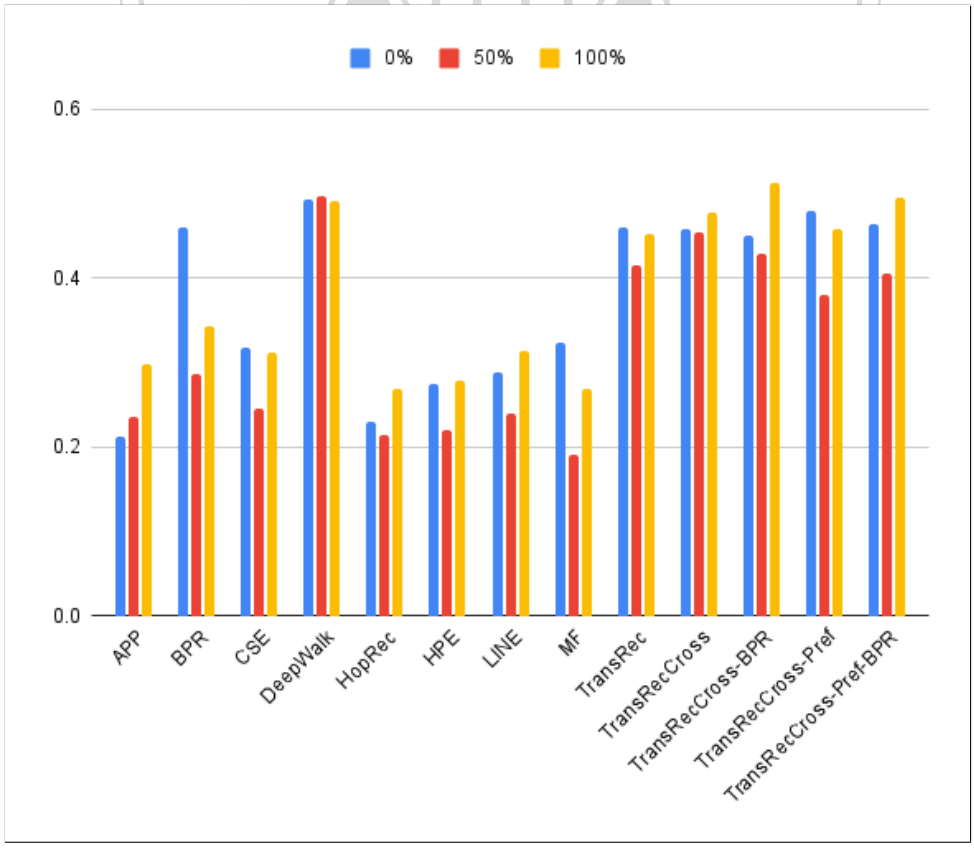

圖 4.4: 不同 Book 資料比例對 Industrial and Scientific 之推薦結果（調整後）

DOI:10.6814/NCCU202101565

綜觀上述文字討論以及圖表的分析，我們可以針對 TransRecCross 的跨領域強化能力進行一些推斷：

- 不同比例之來源領域資料混入目標領域資料的推薦結果，確實會大幅影響目標領域推薦結果之平均準確率均值。
- 若共同使用者（overlapped users）以及其共同邊（overlapped edges）的比例偏低，如 Industrial and Scientific 資料集之共同使用者與共同邊比例皆低於目標領域一半、且來源領域資料的時間軸涵蓋範圍與目標領域差異太大時，則可能發生加入數據後反而推薦效果下降的問題。（詳細數據可觀察表 4.2 與圖 4.3）
- 若發生加入來源領域資料後推薦效果下降的問題，可嘗試提升編採樣次數，效果即改善不少、幾乎都會超越未加入來源領域資料前的推薦成績。

國立政治大學 National Chengchi University

DOI:10.6814/NCCU202101565

第五章

結論

本論文提出了基於翻譯序列推薦方法（Translation-based）的一個新跨領域推薦強化方法 TransRecCross，並在跨領域推薦任務中取得不錯的成績。TransRecCross 是調整過 TransRec 之採樣行爲、並用於強化推薦的圖形學習表示方法；只要來源領域與目標領域的使用者交集夠高，可以在大多數的資料集上實現。其中本文嘗試不同的優化方法、不同的翻譯序列合併方法，得到一共四種不同的模型方法組合，分別是 TransRecCross、TransRecCross-BPR、TransRecCross-Pref 和 TransRecCross-Pref-BPR 四種模型。實驗中，本文使用來自 Amazon Review 的四個不同的資料集，分別是 Books、CDs and Vinyl、Digital Music 和 Industrial and Scientific，而 Books 作爲跨領域推薦中的來源領域、其他三個則爲目標領域，驗證對象即這三組不同領域的推薦結果。本文採用的驗證標準爲召回率、命中率以及平均準確率均值，並比較了加入不同比例的來源領域資料後的跨領域推薦結果，最終得到 TransRecCross 確實能有效強化跨領域推薦結果的結論。總結來說，我們有三個值得一提的論點：

- 雖然不能保證在最佳參數之下 TransRecCross 的表現依然會大幅超越其他基準線模型，但 TransRecCross 確實是在同實驗設定中表現最突出的模型。
- 在所有基準線模型中，使用 random walk 的相關演算法平均效果最佳（例如 Deepwalk、HPE 等等）；而 Translation-based 的系列方法（例如 TransRec 以及本論文提出的TransRecCross 等等）在這種特定任務中的推薦效果則相對佳，可輕易超越基準線。
- TransRecCross 確實能強化跨領域推薦效果，並在不同來源領域資料比例中亦能表現出穩定的強化推薦結果，是未來跨領域推薦中值得研究的方向之一。

DOI:10.6814/NCCU202101565

參考文獻

[1] P. H. Aditya, I. Budi, and Q. Munajat. A comparative analysis of memory-based and model-based collaborative filtering on the implementation of recommender system for e-commerce in indonesia: A case study pt x. In *2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS)*, pages 303–308, 2016.

[2] A. Bordes, N. Usunier, A. Garcia-Duran, J. Weston, and O. Yakhnenko. Translating embeddings for modeling multi-relational data. In C. J. C. Burges, L. Bottou, M. Welling, Z. Ghahramani, and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems*, volume 26. Curran Associates, Inc., 2013.

[3] C.-M. Chen, M.-F. Tsai, Y.-C. Lin, and Y.-H. Yang. Query-based music recommendations via preference embedding. In *Proceedings of the 10th ACM Conference on Recommender Systems*, RecSys '16, page 79–82, New York, NY, USA, 2016. Association for Computing Machinery.

[4] C.-M. Chen, C.-J. Wang, M.-F. Tsai, and Y.-H. Yang. Collaborative similarity embedding for recommender systems. In *The World Wide Web Conference*, WWW '19, page 2637–2643, New York, NY, USA, 2019. Association for Computing Machinery.

[5] Francesco Ricci, Lior Rokach, Bracha Shapira, and Paul Kantor. Recommender systems handbook. 2011.

[6] A. Grover and J. Leskovec. node2vec: Scalable feature learning for networks, 2016.

[7] G. Guo, H. Wang, D. Bell, Y. Bi, and K. Greer. Knn model-based approach in classification. In R. Meersman, Z. Tari, and D. C. Schmidt, editors, *On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE*, pages 986–996, Berlin, Heidelberg, 2003. Springer Berlin Heidelberg.

[8] R. He, W.-C. Kang, and J. McAuley. Translation-based recommendation. *Proceedings of the Eleventh ACM Conference on Recommender Systems*, Aug 2017.

DOI:10.6814/NCCU202101565

[9] A. Krohn-Grimberghe, L. Drumond, C. Freudenthaler, and L. Schmidt-Thieme. Multi-relational matrix factorization using bayesian personalized ranking for social network data. In *Proceedings of the Fifth ACM International Conference on Web Search and Data Mining*, WSDM '12, page 173–182, New York, NY, USA, 2012. Association for Computing Machinery.

[10] O. Kuchaiev and B. Ginsburg. Training deep autoencoders for collaborative filtering, 2017.

[11] Y. Lin, Z. Liu, M. Sun, Y. Liu, and X. Zhu. Learning entity and relation embeddings for knowledge graph completion. In *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence*, AAAI'15, page 2181–2187. AAAI Press, 2015.

[12] W. Lu, F. lai Chung, K. Lai, and L. Zhang. Recommender system based on scarce information mining. *Neural Networks*, 93:256–266, 2017.

[13] T. Man, H. Shen, X. Jin, and X. Cheng. Cross-domain recommendation: An embedding and mapping approach. In *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence, IJCAI-17*, pages 2464–2470, 2017.

[14] X. Ning and G. Karypis. Slim: Sparse linear methods for top-n recommender systems. In *2011 IEEE 11th International Conference on Data Mining*, pages 497–506, 2011.

[15] R. Pan, Y. Zhou, B. Cao, N. N. Liu, R. Lukose, M. Scholz, and Q. Yang. One-class collaborative filtering. In *Proceedings of the 2008 Eighth IEEE International Conference on Data Mining*, ICDM '08, page 502–511, USA, 2008. IEEE Computer Society.

[16] B. Perozzi, R. Al-Rfou, and S. Skiena. Deepwalk: Online learning of social representations. In *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '14, page 701–710, New York, NY, USA, 2014. Association for Computing Machinery.

[17] J. Ramos. Using tf-idf to determine word relevance in document queries, 1999.

[18] S. Rendle and C. Freudenthaler. Improving pairwise learning for item recommendation from implicit feedback. In *Proceedings of the 7th ACM International Conference on Web Search and Data Mining*, WSDM '14, page 273–282, New York, NY, USA, 2014. Association for Computing Machinery.

[19] S. Rendle, C. Freudenthaler, Z. Gantner, and L. Schmidt-Thieme. Bpr: Bayesian personalized ranking from implicit feedback. In *Proceedings of the Twenty-Fifth*

國立政治大學 National Chengchi University

DOI:10.6814/NCCU202101565

Conference on Uncertainty in Artificial Intelligence, UAI '09, page 452–461, Arlington, Virginia, USA, 2009. AUAI Press.

[20] S. Rendle and L. Schmidt-Thieme. Pairwise interaction tensor factorization for personalized tag recommendation. In *Proceedings of the Third ACM International Conference on Web Search and Data Mining*, WSDM '10, page 81–90, New York, NY, USA, 2010. Association for Computing Machinery.

[21] J. Tang, M. Qu, M. Wang, M. Zhang, J. Yan, and Q. Mei. Line: Large-scale information network embedding. In *Proceedings of the 24th International Conference on World Wide Web*, WWW '15, page 1067–1077, Republic and Canton of Geneva, CHE, 2015. International World Wide Web Conferences Steering Committee.

[22] K. Taunk, S. De, S. Verma, and A. Swetapadma. A brief review of nearest neighbor algorithm for learning and classification. In *2019 International Conference on Intelligent Computing and Control Systems (ICCS)*, pages 1255–1260, 2019.

[23] D. H. Tran, Z. Hussain, W. E. Zhang, N. L. D. Khoa, N. H. Tran, and Q. Z. Sheng. Deep autoencoder for recommender systems: Parameter influence analysis, 2018.

[24] Z. Wang, J. Zhang, J. Feng, and Z. Chen. Knowledge graph embedding by translating on hyperplanes. In *Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence*, AAAI'14, page 1112–1119. AAAI Press, 2014.

[25] J.-H. Yang, C.-M. Chen, C.-J. Wang, and M.-F. Tsai. Hop-rec: High-order proximity for implicit recommendation. In *Proceedings of the 12th ACM Conference on Recommender Systems*, RecSys '18, page 140–144, New York, NY, USA, 2018. Association for Computing Machinery.

[26] S. Zhang, L. Yao, A. Sun, and Y. Tay. Deep learning based recommender system. *ACM Computing Surveys*, 52(1):1–38, Feb 2019.

[27] X. Zhang. Toprec: Domain-specific recommendation through community topic mining in social network. 05 2013.

[28] Y. Zhang and X. Chen. Explainable recommendation: A survey and new perspectives. *Foundations and Trends® in Information Retrieval*, 14(1):1–101, 2020.

[29] C. Zhou, Y. Liu, X. Liu, Z. Liu, and J. Gao. Scalable graph embedding for asymmetric proximity. In *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*, AAAI'17, page 2942–2948. AAAI Press, 2017.

[30] F. Zhu, Y. Wang, C. Chen, J. Zhou, L. Li, and G. Liu. Cross-domain recommendation: Challenges, progress, and prospects, 2021.

DOI:10.6814/NCCU202101565