

基於超連結圖譜表示法學習之跨領域音樂推薦演算法
Cross-domain Music Recommendation Based on
Superhighway Graph Embedding

研究生：楊昇芳 Student : Sheng-Fang Yang
指導教授：蔡銘峰 Advisor : Ming-Feng Tsai



中華民國一百零八年九月
September 2019

致謝

隨著自己從無到有完成一篇自己的論文，使我有很大的成就感。回首這兩年來充實的學習與各種經驗，便覺得這段時間很值得，不只是在專業領域上有了一定的基礎及認識，也對自己未來許多可能有多了一層的把握。首先我要先感謝我的指導老師蔡銘峰老師，從大學時代修習老師的程式設計課程開始，經過一年的扎實訓練使我奠定我的程式能力基礎，也讓我在我研究所的課業上更遊刃有餘。而在研究所的生涯中，老師時常會給予我在專業領域研究上面的建議，也給予我機會，讓我可以進入KKBOX產學合作計畫裡面，實際與業界接軌並觀察業界上對於資料的處理方式與眾多實務上的經驗等，使我受益良多；另外也要感謝中研院的王釗茹老師，帶領我們組逐步完成研討會的論文讓我也能有機會實際出去見見世面，在每次的小組討論上，也經常能夠給予我一些新的想法。再來，我要感謝實驗室的夥伴們，感謝伯新帶我進入這嶄新的領域，也適時地給予我一些建議；感謝裕勝在我研究所的生涯中與我互相砥礪，共同精進；感謝喻能，除了補足我在數學方面的不足之外，在生活上不只互相激勵同時也排解我很多煩惱；感謝俊翔跟文毓，點綴了我在研究所時期的生活，使我的生活多了一些樂趣；感謝志明學長，他總是能在我需要幫助的時候給予我很大的幫忙，也提供了我很多有用的資訊與知識；感謝鼎翔學長，除了帶領我在KK專案上的工作上軌道之外，也給了我很多處事的經驗與建議；感謝聖傑學長，不管是在KK專案上或是在研討會論文上，都能給我一些新的方向或建議；還要感謝我的家人們，讓我不用擔心生活上的瑣事，能全心投入。有了他們一路上的陪伴，才有了現在的我，也期許我在未來人生的路上，能夠發揮所長，成使社會進步的一份子。

楊昇芳

國立政治大學資訊科學系

July 2019

基於超連結圖譜表示法學習之跨領域音樂推薦演算法

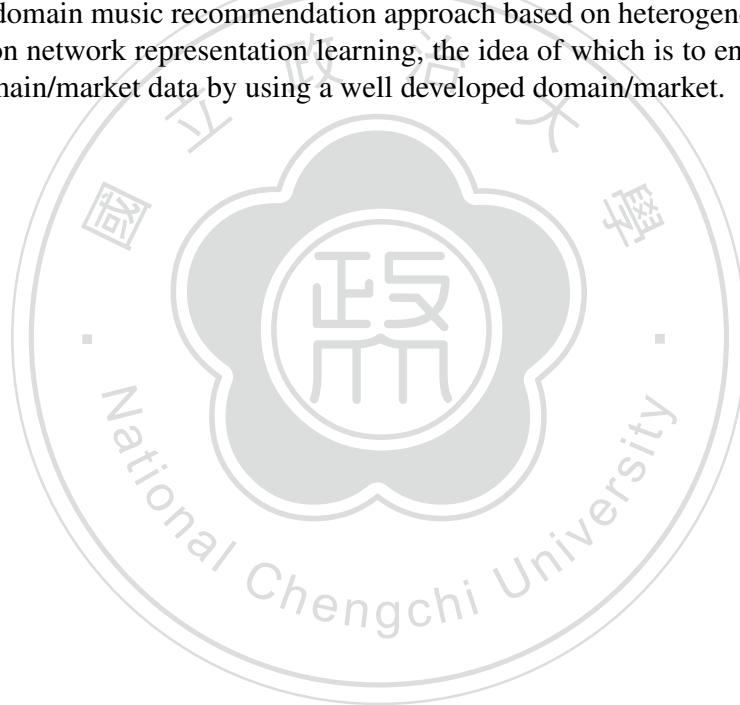
中文摘要

近年來大數據以及機器學習技術的蓬勃發展，推薦系統被廣泛應用於各種實務上，而音樂串流系統中的音樂推薦也變成一項具有挑戰性的工作，尤其在各個不同市場中，群體的聆聽習慣也會有所不同。因此，我們使用了異質性網路表示法學習（Heterogeneous Information Network Embedding），可以將網路中不同類型之節點投影於低維度向量空間中，並基於此空間來完成後續相關之音樂推薦工作。又因對於新開發市場，用戶與歌曲聆聽紀錄等互動的資訊極為稀少且會因少數用戶而影響整體推薦的傾向，這便稱為資料的「稀疏性」問題，而資料的稀疏性通常是實務上一個很具有挑戰性的任務，其對於推薦系統整體的推薦效果影響是很巨大的。於是，本論文提出了一個基於異質性網路表示法學習的音樂推薦系統，透過加入網路資訊較為豐富的市場作為輔助來幫助改進新開發市場之推薦效果。



Abstract

In recent years, big data and machine learning technology have been rapidly growing, and recommendation systems have been widely used in various real-world applications, such as music recommendation in music streaming services. However, for different domains, the recommender systems will be different, because of the distinct user behavior data. Therefore, this thesis aims to use Heterogeneous Information Network Embedding to project the nodes in a network/domain into another network/domain on the basis of the low-dimension representations of the nodes. Therefore, this paper proposes a cross-domain music recommendation approach based on heterogeneous information network representation learning, the idea of which is to enrich the new domain/market data by using a well developed domain/market.



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 網路表示法學習	4
2.2 推薦系統	5
2.3 遷移式學習	6
第三章 研究方法	8
3.1 問題定義	8
3.2 異質性網路建圖	8
3.3 建立超連結圖譜	10
3.4 網路表示法學習	12
3.4.1 Deepwalk	12
3.4.2 Large-Scale Information Network Embedding	12
3.4.3 Heterogeneous Preference Embedding	14
3.5 推薦系統	14
第四章 實驗結果與討論	16
4.1 資料集	16
4.2 實驗設定	17
4.3 評估標準	19
4.4 實驗結果分析與討論	21
4.4.1 準確率表現	21
4.4.2 召回率表現	21
4.4.3 平均準確率均值表現	22
4.4.4 新穎度表現	23
4.5 實例分析	24
4.5.1 實例分析-以推薦系統為例	24
4.5.2 實例分析-以網路表示法學習為例	24
第五章 結論	29
參考文獻	30

圖目錄

圖 3.1 音樂串流服務之異質性網路圖	9
圖 3.2 目標與來源市場的異質性網路二分圖結構	9
圖 3.3 超連結圖譜之連接示意圖	11
圖 3.4 LINE的相似度網路圖	13



表目錄

表 4.1	A、B市場資料集數據統計	16
表 4.2	訓練集中共有歌曲佔訓練集之歌曲重疊率	17
表 4.3	準確率表現	21
表 4.4	召回率表現	22
表 4.5	平均準確率均值表現	22
表 4.6	Top-N 新穎度表現	23
表 4.7	推薦系統之實例	25
表 4.8	網路表示法學習實例一之一	26
表 4.9	網路表示法學習實例一之二	27



第一章

緒論

1.1 前言

隨著各式科技日新月異的發展，人們的各種行為也在不斷轉換，而音樂也漸漸地從實體商店轉向網路上就可輕鬆取得、聆聽；同時，音樂串流服務也蓬勃發展起來，使用者可利用音樂串流服務來聆聽各式各樣的音樂，隨之而來的，大量的音樂資訊與使用者紀錄也不斷地產生。如何利用這些使用者與音樂的資訊來改善服務的品質就變成一項非常重要的議題，而推薦系統（Recommendation system）又在其中扮演著重要的角色。

推薦系統是一種訊息過濾系統，用於預測用戶對物品的「評分」或「偏好」，近年來因為網路的發展而廣泛運用於各類商品與服務中，像是電影、書籍、新聞、音樂、商品甚至餐廳或金融商品等。推薦系統主要可以分成三種類型：協同過濾（Collaborative Filtering）[24]、基於內容推薦（Content-based Recommendation）[19]與混合式推薦（Hybrid Recommendation）[4]。協同過濾方法根據用戶的歷史行為例如觀看、聆聽、點擊、評價等行為，再利用相似喜好的用戶群的使用行為來推薦；基於內容推薦主要使用物品的離散特徵例如類別、屬性等來推薦類似性質的相似物品；混合式推薦則是將上述兩種方法融合起來以期達成更佳的推薦效果。在網路服務快速發展的現今，大量的物品、使用者紀錄能被推薦系統所使用。雖然這些紀錄含有豐富的訊息，但在硬體的限制下，運算的成本極為龐大，如何在考量計算的時間與空間複雜度成本下利用這些資訊，是一個相當富有挑戰性的任務。

表示法學習（Embedding）[2]是目前很熱門的技術，在現今人工智能領域中許多的問題都廣泛的被使用。表示法學習的做法主要是將一個物品的屬性或其鄰近資訊壓縮成一個向量的表示形式，在自然語言處理（Natural Language Processing）領域裡，像是 word2vec [17]，它透過類神經網路學習句子裡每個詞，並將之轉化成向量的表示式，不只便於做後續的應用，也具有很大的彈性。網

路表示法學習（ Network Embedding ）則是社群網路領域中基於表示法學習的應用。例如我們可以將用戶與用戶之間的交互關係建成一張圖，將用戶節點及其鄰居的關係，類比成類似於句子中詞與詞的關係並使用表示法學習技術將用戶節點投影至較低維度的向量空間中以便做後續的應用。目前有許多基於 word2vec 的網路表示式的方法像是 DeepWalk [20] 、 LINE [25] 等都被廣泛地運用在資料探勘、社群網路分析等領域上。

網路表示法學習的方法大多應用於同質性網路（ Homogeneous Information Network ）中，而大多實務上的資料並不是同質性網路而是異質性網路（ Heterogeneous Information Network ）。異質性網路是一種包含兩種以上屬性節點與連結的圖，像學術社群中，可能有作者、論文、領域、學校或研究單位等多種節點，以及像是一個人可以有一個學校、一篇論文有多名作者、一篇論文可以引用多篇論文等各種交互關係，而音樂推薦系統也有用戶、歌曲、歌手、語言等不同類型資訊可供使用，因此，將之建成異質性網路圖在模型中可以隱含更多更豐富的資訊，也有助於後續的推薦。

1.2 研究目的

稀疏性（ Sparsity ）一直是現實資料中一個很嚴重的問題，稀疏性是指用戶與物品間互動過少，會導致模型在推薦時會傾向於推薦那些已經有紀錄的物品而不會推薦那些跟用戶喜好相似但沒被觀察到的物品，這時，我們可以利用相似類型但用戶紀錄豐富的領域來幫助並增強較弱領域的推薦效果，這個運用了遷移學習（ Transfer Learning ）方法的推薦系統，我們稱之為跨領域推薦（ Cross-domain Recommendation ）。另外我們也可以利用額外的外部資訊（ External Information ）來增強推薦系統的效果。

在音樂串流服務中，用戶與歌曲數量極為龐大，而根據統計，一個用戶平均聆聽歌曲量不過數百至數千首，這表示音樂串流服務中關於用戶聆聽紀錄的資料會存在著很大的稀疏性問題，且用戶聆聽紀錄往往多會偏向於集中於聆聽熱門的歌曲，而傳統使用矩陣分解（ Matrix Factorization ）的做法會因稀疏性問題而降低推薦的效果，而其使用方均根誤差（ Mean Square Error ）的評分標準只在乎準確度，但在音樂推薦上，我們並不希望用戶被侷限在那些他已經聽過的歌，而是希望能拓展歌曲的廣度的同時也能推薦回用戶所喜好的音樂。因此，如何在提升歌曲廣度又不至於太發散且能推回使用者感興趣的音樂，便是音樂推薦系統中一個重要的議題。

本論文旨在建立一個音樂推薦系統，透過一個有彈性的建圖策略，利用含有較豐富之用戶聆聽紀錄的 A 市場，用以豐富 B 市場之資訊並將之建成異質性網路圖，並利用網路表示法學習，將用戶與歌曲投影至低維度的向量空間中，再透過

基於查詢推薦（Query-based Recommendation）的方式，達成用戶之於歌曲的推薦結果。此方法使用於 KKBOX 真實的資料集中，並能使推薦的效果有所提升。



第二章

相關文獻探討

2.1 網路表示法學習

詞向量（Word Embedding）在現今自然語言處理等領域中已成為一種常用的特徵值並被廣泛的使用。鑑於以前傳統模型表示法多為 One-hot 表示法（One-hot Representation）或是 TF-IDF（Term Frequency-Inverse Document Frequency），在大量的文本資料中，向量的維度會變得極高且很稀疏，在計算上會十分地困難，因此詞向量的目的，便是透過類神經網路學習，並將詞投影至低維度的連續向量空間中，使向量變得稠密有助於節省計算上的空間與時間。而網路表示法學習（Network Embedding）則從此概念延伸，將網路期望利用網路節點間交互連結的結構，取得網路節點的向量表示法作為此節點的特徵值並使用於後續更多的應用中。

自從 word2vec 提出詞向量的概念後，許多人前仆後繼地根據此概念去做發展。Perozzi 等人是第一個將詞向量的思想用於網路圖中的，他們參考了 word2vec 的特性，將網路節點類比成詞，再透過隨機遊走（Random Walk）的方式產生節點序列以模擬類似於句子的形式，再通過 Skip-Gram 模型訓練得出節點的向量表示式 [20]。Grover 等人則定義了另外一種基於廣度優先搜尋（Breadth-first Search）與深度優先搜尋（Depth-first Search）的走動策略，透過可控制參數 p 與 q 來調整走動的方式，可使模型具有更好的彈性 [11]。Tang 等人則是提出了不同於 word2vec 的目標函式來優化網路表示法的向量，透過制定不同相似度的函式來保留圖的局部與全局資訊，以改進網路表示法的向量 [25]。Chen 等人則是針對使用者的偏好，將異質性網路透過有權重的隨機遊走策略來得到網路表示法的向量 [5]。

2.2 推薦系統

推薦系統最早其實是一種資訊檢索工具，根據你輸入的請求，將物件例如網頁、文件等做相關度排序後推回相關的結果。這門學問在這近二十年內逐漸成為一門獨立的學問並且在學術及實務上都有許多豐碩的成果。1994年GroupLens研究團隊推出第一個自動化推薦系統並提出了協同過濾（Collaborative Filtering）技術，這也是最早使用協同過濾的系統之一[24]。2005年Adomavicius等人將推薦系統統整並分為3個主要類別，即基於內容的推薦、協同過濾的推薦和混合推薦的方法[1]。2009年，Koren等人提出了基於矩陣分解（Matrix Factorization）的協同過濾系統，這也是目前業界普遍使用的技術之一[12, 13]。基於內容的推薦主要是使用物品的離散特徵或是元資料（Metadata）例如類別、屬性等來推薦類似性質的相似物品；而協同過濾主要可以分成基於用戶（User-based）和基於物品（Item-based）等兩種類型。基於用戶的協同過濾是根據用戶對物品的喜好，推薦與用戶很相似的用戶所喜好的物品；基於物品的協同過濾則是目前業界最廣泛使用的方法，其核心概念就是建立於一種假設，即對於三個物品A、B、C，如果有大多數喜歡A的用戶同時也喜歡B，代表物品A與B很相似，因此對於喜歡A的用戶就會推回物品B而不是物品C，例如在新聞推薦中，用戶看過這篇報導，系統會推薦看過這篇報導的人也看過的其他類似的新聞，雖然這項技術在很多實務上都有很不錯的效果，但還是會常常會遇到資料太稀疏，或是冷啟動（Cold Start）問題的挑戰。

近年來硬體與網路的快速進展，開始有人試著使用更多其他外部來源使用者或物品等的額外資訊（Meta Information）來輔佐加強推薦的效果，有些研究者也發現這些資訊對於改善個人化的推薦有幫助，因此有研究嘗試加入這些資訊來增加推薦的準確度。Li等人嘗試使用使用者對於電影的評分來改進使用者對於書籍評分的協同過濾推薦系統，發現也有所改善[15]。而除了這些文本資料以外，有研究也開始嘗試使用圖像資訊來增進使用者的偏好。McAuley等人使用了圖像特徵來增強協同過濾的準確性[16]。另外Zhang等人則是整合了用戶與使用者交互關係的結構資訊、物品的文本特徵以及物品的圖像資訊串接在一起經過多層的神經網路學習使用者與物品的表示法，在推薦問題上得到不錯的成效[26]。

基於查詢推薦是推薦系統在實際推薦場景中最常使用的技術之一，原因是因為對於用戶來說，物品的數量實在太多，而且用戶只會關注在前面且真的相關的物品，因此某種程度上，推薦問題可視為資訊檢索問題。因此，Learning to Rank技術便在實際推薦的應用上起了很大的作用，而Learning to Rank依照其模型種類大致可分為PointWise、PairWise、ListWise三種。PointWise的rank比較關注的點是單一件物品的關係，在訓練時只針對一件物品與用戶、查詢物品等的相關性進行優化，像是矩陣分解（Matrix Factorization）或是分解式機器（Factorization Machine）[22]就屬於這種類型。矩陣分解將用戶對於物品的使用

或觀看偏好視爲評分並做成評分矩陣，並藉由隨機梯度下降（Stochastic gradient descent）法將此評分矩陣分解成兩個低維度的用戶特徵值 U 與物品特徵值 V ，這些低維的特徵值可以某一程度上代表這個用戶（物品）的特性，再用這些特徵向量做後續相關性的評分；矩陣分解比較普遍的版本則是分解式機器，分解式機器將多種特徵像是評分、種類、屬性等考慮進來，並考慮特徵之間其實不是完全獨立而是有一定的關係的，例如：在網路商店中，購買化妝品或保養品的用戶通常爲女性，而購買運動類商品的通常爲男性。因此，如果能夠找出這些特徵，對推薦物品會很有幫助。分解式機器藉由學習這些特徵間的交叉關係來建立用戶與物品的特徵向量來評估這些物品的相關性。PairWise 的 rank 關注的點爲兩件候選物品之間相關性的排序，在訓練時不只是根據物品的相關性且還對兩件物品之間的相關性排序進行優化，一般常見的方法則是貝氏個人化排序（Bayesian Personalized Ranking）模型 [23]。貝氏個人化排序對於用戶與物品的評分矩陣，依據與用戶有正向回饋的物品（有評分）及與用戶有負向回饋（無評分）的物品做成一個訓練對來學習之間的關係，直觀上的意義即爲：使用者相對於沒有評分的物品來說更喜歡有評分過的物品。相對於 PointWise，PairWise 因爲有對物品間的相關性做排序，針對兩個無相關的物品依然有一個偏好的順序而不是都一視同仁的認爲沒有關係，所以能更精準的得到用戶對於物品之間的偏好。ListWise 考慮的是對用戶來說，整體物品推薦的排序並對其進行優化，LambdaMART 為其中一種方法。LambdaMART 搜尋結果的排序問題轉成回歸決策樹（Decision Tree Regression）問題，將每次迭代出來的決策樹進行加總並對其損失函數的梯度進行優化。

2.3 遷移式學習

我們人類在作爲一個學習者，在學習的時候通常會有固定的模式來運用、轉移原有的知識來學習新知道而不是直接真的從零開始學習。也就是說，當我們遇到一個新任務時，我們會應用之前學習經驗中的相關知識來學習。如果新任務對我們以前的經驗越相關，我們就越容易掌握它，這就是遷移式學習 [18]。遷移式學習是一個機器學習上的研究議題，傳統上一般的機器學習都專注在一個特定的任務、領域上做學習，因此他們會在這個任務中表現很良好，但當他們將模型運用至其他的任務時，並沒有辦法有相同的表現，因爲他們無法將前一任務學習到的知識保留並轉移至新任務上，即使新任務與舊任務很類似。而遷移式學習的概念就是將學習一個知識的過程、模式、規律等相關能力與技術拿來解決類似或相同的任務上，也就是目標是通過利用來源任務（Source Task）中的部分知識來改進目標任務（Target Task）中的學習。如果來源任務與目標任務相關性越高，那遷移的效果就越好、越容易。最簡單的例子例如：我們先學會騎腳踏車，那我們在學騎機車時就會比較容易，因爲我們已經先從過去學習騎腳踏車的情境中先學會了如何平衡、操縱等技術；假如來源任務與目標任務相關性越低甚至不相關，

則有可能會有負遷移的發生，來源任務所遷移出的知識反而阻礙了目標任務的學習。遷移學習根據來源與目標的領域禍任務是否相同而可以分成歸納遷移學習（Inductive Transfer Learning）、非監督式遷移學習（Unsupervised Transfer Learning）和轉換遷移學習（Transductive Transfer Learning）三種，歸納遷移學習只專注於透過從來源任務中遷移相關知識以便在目標任務中獲得更高的效果；非監督式遷移學習專注於解決目標領域中的非監督學習問題，如聚類，降維，密度估計等等。遷移式學習一直都被廣泛運用於各式任務上，近年來由於深度學習技術的興起而更為蓬勃發展。Raina等人嘗試透過大量未標注的資料特徵來達到對目標資料的分類效果[21]。Dai等人則是同時將來源資料與目標資料一起做分群來影響目標資料的分群[8]。Ganin等人則是透過分類器在兩個領域間的相似性來使特徵擷取在沒有目標資料標記的情況下也能學習到特徵[9]。Bocsi等人利用過往A品牌的機器手臂的關節運動等資訊運用至B品牌的機器手臂上，也有著良好的表現[3]。Cremonesi等人將跨領域的資訊來改善推薦系統的品質[7]。He等人利用物品相關的資訊，配合注意力機制（Attention）將資訊合理地遷移至目標資料做學習[10]。



第三章

研究方法

在此章節中，我們將會詳細地介紹我們所使用的方法。在 3.1 小節中，我們會敘述我們想要解決的問題；在 3.2 小節中，我們會描述建圖之方法；在 3.3 小節中，我們將介紹我們如何連接不同領域市場並建立關係；在 3.4 小節中，我們會介紹我們所使用的網路表示法學習框架。

3.1 問題定義

一般在協同過濾方法中，我們常常會將用戶與物品的交互關係建成一個鄰接矩陣 $M = (m_{ij}) \in \mathbb{R}^{|U| \times |I|}$ ，其中 U 為用戶集合而 I 為物品集合， m_{ij} 為用戶 i 與物品 j 的關係，這個關係可以是有無看過、評分或點擊次數等不同類型。而對於這個鄰接矩陣 M 我們也能以一個二分圖 G 來表示，即 $G = (U, I, E)$ ，其中 $E = \{(U_i, I_j) | i \in U, j \in I\}$ 。在本論文中，我們定義兩個不同市場 G_T 與 G_S 。 G_T 為我們推薦系統要解決的目標市場，而 G_S 則為我們用來做跨領域推薦的來源市場，我們的目標就是要將這兩個市場透過一個函式 \mathcal{F} 來建立其之間的交互關係，進而增強網路的稠密性，再將其利用網路表示法學習出每個節點的向量表示式，再來做後續的推薦。

3.2 異質性網路建圖

異質性網路（ Heterogeneous Information Network ）為一種具有多種節點屬性的資訊網路。一個異質性網路可以表示成 $G = \{V, E, A\}$ ，其中 V 為節點集合、 E 為邊的集合而 A 為節點相對應之屬性集合， $|A| \geq 2$ 。例如在音樂串流服務中，歌曲可能也會帶有許多屬性，像是歌手、歌詞、曲風、語言等資訊。在現實世界裡的資料大多都是以這樣子的離散資料的形式儲存在資料庫中，而這些離散資料很

難直接使用網路表示法的框架進行訓練，因此我們必須先將資料進行萃取，取出我們關注的資料並將之建成一張網路圖才能繼續做後面的網路表示法學習訓練。在此小節中，我們會詳細敘述我們如何將原始資料建成異質性網路圖並使用超連結圖譜進行跨領域結合。

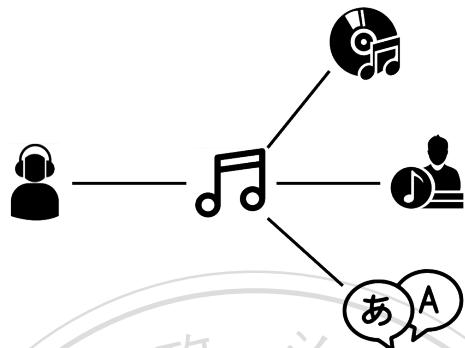


圖 3.1: 音樂串流服務之異質性網路圖

首先，我們要先確認我們要使用哪種類型的資訊。在本論文中，我們主要是利用用戶對於歌曲的互動關係，即用戶對於歌曲聆聽的紀錄來建圖。因此我們針對兩個跨領域市場的聆聽紀錄做提取並將每一個用戶對於每一首歌曲的互動紀錄做累積加總而得到兩個鄰接矩陣：目標市場 $M_T = (m_{ij}) \in \mathbb{R}^{|U_T| \times |I_T|}$ 與來源市場 $M_S = (m_{xy}) \in \mathbb{R}^{|U_S| \times |I_S|}$ ，之後我們便可根據這兩個矩陣將資料轉換成兩個異質性網路圖 $G_T = (U_T, I_T, E_T)$ 與 $G_S = (U_S, I_S, E_S)$ ， G_T 為目標市場之網路圖而 G_T 為來源市場之網路圖。而 G_T 與 G_S 分別有自己的用戶群集合 U_T 、 U_S 以及歌曲集合 I_T 、 I_S ，其中 $U_T \cap U_S = \emptyset$ ， E_T 與 E_S 分別為兩個市場的聆聽紀錄次數之集合。接著，我們將利用超連結圖譜，將兩個跨領域市場的異質性網路圖做連結。

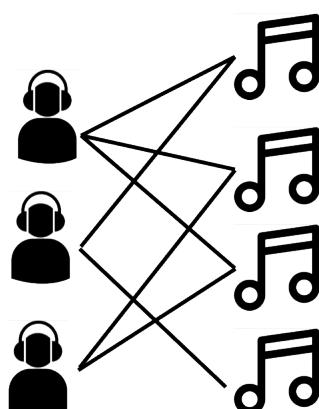


圖 3.2: 目標與來源市場的異質性網路二分圖結構

3.3 建立超連結圖譜

超連結圖譜（ Superhighway Graph ） [14] 是一個遷移學習的策略，根據兩個領域間兩兩不同用戶之間所共享的歌曲，合理地建立用戶間的邊。而透過這個超連結的邊，可以使得我們在遷移來源領域的知識或資訊的過程能有較好的效果。以下我們定義什麼是超連結圖譜以及超連結圖譜的做法：對於兩個市場 $G_T = (U_T, I_T, E_T)$ 與 $G_S = (U_S, I_S, E_S)$ ，我們有一個共享的歌曲集合 \hat{I} ， $\hat{I} = I_T \cap I_S \neq \emptyset$ ，則我們可以透過一個歌曲 $i \in \hat{I}$ 使得用戶 $u_i \in U_T$ 與用戶 $u_j \in U_S$ 有所連結，這個路徑我們稱為橋樑（ bridge ）。將來源市場資訊結合進目標市場，最簡單也最直覺的方式就是把兩個市場圖 G_T 與 G_S 直接合併成一張圖 G 再進行網路表示法的訓練。但是這個會有一個問題：在網路圖上， G_T 市場的用戶要與 G_S 市場的用戶做連結必然得要透過這座橋樑上的歌曲才能達成，也就是整張圖裡兩個市場僅能透過 \hat{I} 集合的歌曲來進行連結，這樣子的資訊傳播我們覺得過於薄弱，某方面上只增強了橋樑上節點的資訊，其他節點則因離橋梁過遠而導致依然只擁有單一市場的資訊。為了要豐富跨領域市場的連結性，我們使用超連結圖譜（ Superhighway Graph ）來建立連結，下面我們介紹超連結圖譜的做法。

針對兩個跨領域的異質圖 G_T 與 G_S ，我們可以藉由超連結圖譜演算法函式 \mathcal{F} 建立一個候選者集合 \hat{U}_T 與 \hat{U}_S ，其中 $\hat{U}_T \subseteq U_T$ 、 $\hat{U}_S \subseteq U_S$ ，然後我們對於候選者列表中每個用戶 $u_i \in \hat{U}_T$ 與用戶 $u_j \in \hat{U}_S$ 兩兩之間建立直接的連結關係，候選者集合建立的方式是根據 3.1 式

$$\hat{U}_d = \left\{ u \mid u \in U_d, \frac{|\mathcal{N}(u) \cap \hat{I}|}{|\mathcal{N}(u)|} \geq \alpha \right\}, \quad (3.1)$$

來選擇用戶進入候選者集合，其中 $d \in \{S, T\}$ ， $\mathcal{N}(u)$ 是用戶 u 的所有鄰居的集合， α 是我們的可調控參數，即我們選擇某用戶作為候選者的門檻值。如此，我們便可從 3.1 式得到的兩個候選者集合 \hat{U}_T 與 \hat{U}_S 中針對兩兩之間的用戶建立新的超連結邊，數量為 $|\hat{U}_T| \times |\hat{U}_S|$ 條；而兩兩用戶對的連結的權重 w 我們定義為：

$$w = \beta \times |\mathcal{N}(u_i) \cap \mathcal{N}(u_j)|, \quad (3.2)$$

其中 $u_i \in \hat{U}_T$ 、 $u_j \in \hat{U}_S$ ， β 為我們調控權重比率的參數。最後，我們便可利用超連結圖譜得到一個新的圖 G ：

$$G = \mathcal{F}(G_T, G_S) = \{U_d \cap I, E_{U_d \cap I} \oplus E_{super}\} \quad (3.3)$$

其中 $d \in \{S, T\}$ 。這些經由 3.1 式連結的用戶 — 用戶的連結邊因為所共享的歌曲資訊比例很高，意義上即是他們的聆聽偏好會很接近，因此這些用戶 — 用戶的邊就隱含了很強烈的偏好關係，接著，我們就可以使用網路表示法訓練這張圖。

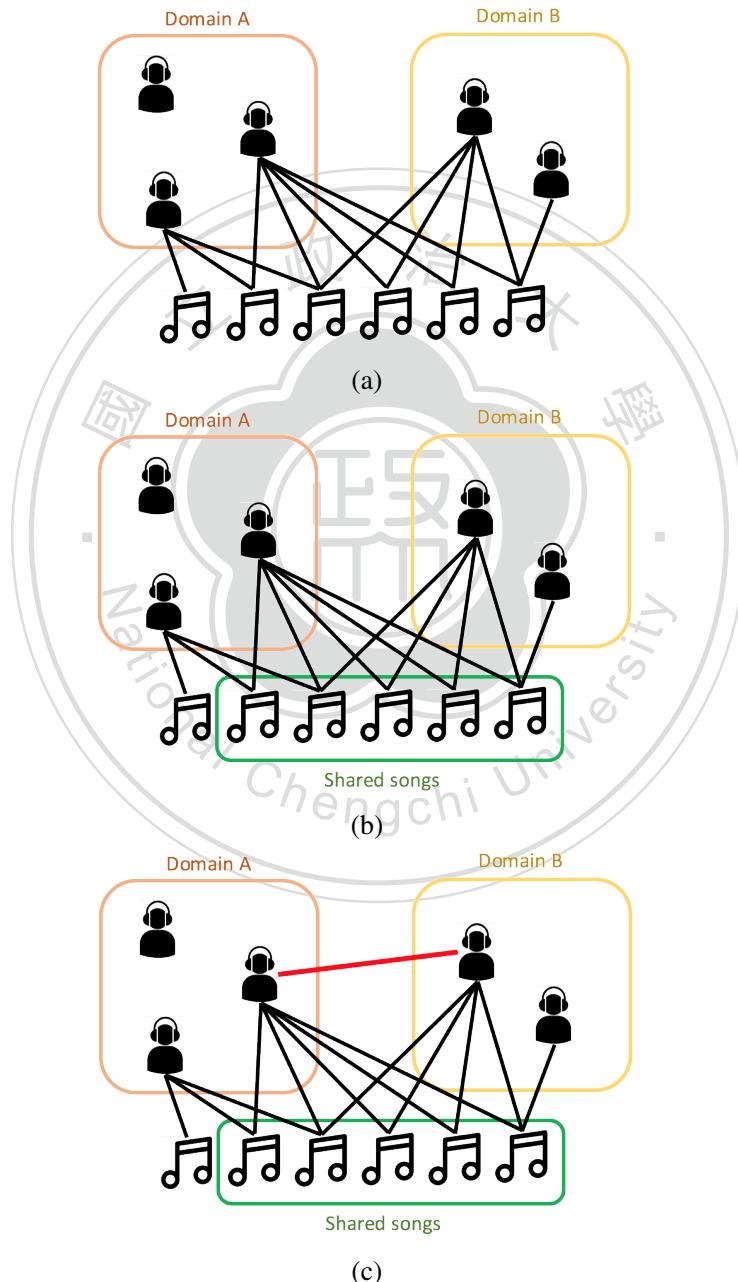


圖 3.3: 超連結圖譜之連接示意圖

如圖 3.3 所示，我們根據兩個領域間兩兩不同用戶之間所共享的歌曲，依照我

們所設定的參數，合理地建立一個用戶間的邊。而透過這個超連結的邊，可以使得我們在遷移來源領域的知識或資訊的過程能夠更加順利，而設定一個合理的建邊規則也能夠有效的防止負遷移（ Negative transfer ）的發生。

3.4 網路表示法學習

在本論文中，我們挑選了三種網路表示法學習的方法來訓練異質圖來得到用戶與歌曲的網路表示法，分別為 Deepwalk 、 LINE 及 HPE ，下面我們會介紹各個方法。

3.4.1 Deepwalk

Deepwalk [20] 萃取了 word2vec 在處理自然語言中文本句子單詞的做法並將此概念以另一種形式使用於社群網路等圖之中。輸入一個給定的網路圖 G 中， Deepwalk 以隨機遊走的方式，將圖中的節點遊走的路徑以類似句子形式的節點序列去解析，並優化以下目標函式：

$$\mathcal{L}(V) = \frac{1}{|V|} \sum_{i=1}^V \sum_{i-t \leq j \leq i+t, j \neq i} \log \Pr(v_j | v_i) \quad (3.4)$$

以及其條件機率：

$$\Pr(v_j | v_i) = \frac{\exp(\mathcal{V}_j \cdot \mathcal{V}_i)}{\sum_{v \in V} \exp(\mathcal{V}_v \cdot \mathcal{V}_i)} \quad (3.5)$$

其中 j 是節點 $i \in V$ 的 context ， t 為其視窗大小（ window size ）， \mathcal{V}_i 為 i 的向量表示法， \mathcal{V}_j 為其鄰居節點之向量表示法。此方法開啓往後網路表示法的先河，方法在思想上可說是很創新且在分類問題中得到不錯的改進，也因為擴展性佳，實作上也很迅速，也常被應用於實際任務中。

3.4.2 Large-Scale Information Network Embedding

與 Deepwalk 類似， LINE [25] 提供了一個可擴展的方法以便用於處理現實世界中的大量資料。他們定義了兩個明確的目標函式來保留網路結構並優化此網路表示法，以下我們分別來做說明。第一個稱為一階相似度（ First-order Proximity ），即當兩個節點有直接連結時，一階相似度就是這兩個點的邊的權重；若兩點沒有

直接連結的邊，則一階相似度為 0。因此當邊上的權重越高，我們便說這兩個點越相似。第二個稱為二階相似度（Second-order Proximity），即當兩個節點之間共享的鄰居節點越多時，我們便說這兩個點越相似。以圖3.4為例子：

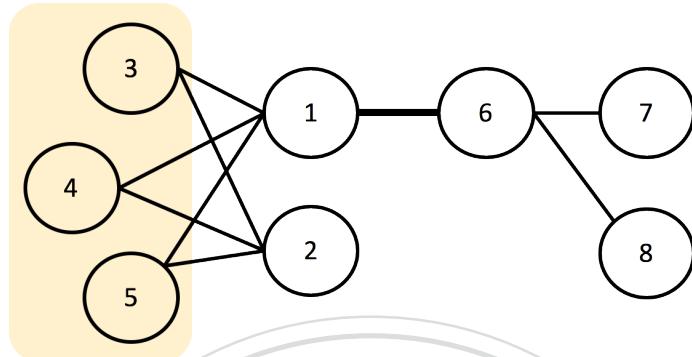


圖 3.4: LINE的相似度網路圖
其中邊的粗細代表邊的權重

以點 1 為例子，以一階相似度來說，跟點 1 最相似的點為點 6，因為點 1 與點 6 直接相連且點 1 與點 6 邊的權重（邊的粗細）大於其他與點 1 連接的點；以二階相似度來說，跟點 1 最相似的點為點 2，因為點 1 與點 2 擁有共同的鄰居點 3、4、5。

對於一階相似度來說，它表示的是網路圖中最局部的訊息（邊的相連與否），因此對於網路圖的結構，它就無法保存的很完整。而對於二階相似度來說，因為它處理的是節點與其周邊鄰居的關係，因此比較能夠保存較多網路結構的資訊在網路表示法中，所以在本論文中，我們使用二階相似度來訓練網路表示法。在二階相似度計算中，每個節點都會有兩種形態，一個是節點自己，另一個則是會成為其他節點的 context，因此對於每一個點，我們都會有兩種向量表示法：點本身的向量表示法以及點的 context 的向量表示法。針對一個有向邊 (v_i, v_j) ，對於從 v_i 他生成的 context 節點 v_j 的機率為：

$$\Pr(v_j|v_i) = \frac{\exp(\mathcal{V}_{v_j} \cdot \mathcal{V}_{v_i})}{\sum_{v_k \in V} \exp(\mathcal{V}_{v_k} \cdot \mathcal{V}_{v_i})} \quad (3.6)$$

我們的目標是要優化下列目標函式：

$$O_{LINE2} = - \sum_{(i,j) \in E} w_{i,j} \log \Pr(v_j|v_i) \quad (3.7)$$

其中， \mathcal{V}_{v_i} 為 v_i 的向量表示法， \mathcal{V}_{v_j} 為 context 節點 v_j 之 context 的向量表示法， E 為抽樣到的邊的集合， $w_{i,j}$ 是邊的權重。

3.4.3 Heterogeneous Preference Embedding

HPE [5] 與上述兩項工作相似但不盡相同，原本 HPE 便是以基於查詢意圖（query intention）的推薦問題做為首要的任務目標，所以他的網路表示法學習跟上述兩項工作相比有做了一些更動。HPE 主要是根據使用者的偏好來進行學習，所以與 Deepwalk 類似但不同的是他為了學習到使用者的偏好，透過有權重的隨機遊走生成訓練的節點對，因此抽樣下一步的節點時，權重越高的越有機會被選中成為訓練的節點對而不像 Deepwalk 機率是均勻分佈的。以圖3.4為例，當我們選中點 1 進行下一步的抽樣時，點 6 比起點 1 其他的節點對（點 3、4、5）更容易被抽中做為訓練的節點對，另外，與 LINE 類似，假設我們已經抽到點 6 當作點 1 的 context 時，我們也會同時抽樣點 6 的節點對（即點 1、7、8）當作點 1 的 context。這也代表著我們在做抽樣的同時也會將抽樣的節點附近的節點 context 也考慮進來，間接學習了這個節點的一些偏好和資訊。HPE 依照這個異質性網路節點進行抽樣並更新節點的向量表示式，機率公式如下：

$$\Pr(v_j | \mathcal{V}_{v_i}) = \begin{cases} 1, & \text{if } v_j \in \text{Context}(v_i) \\ 0, & \text{otherwise} \end{cases} \quad (3.8)$$

而類似於 LINE，HPE 主要優化下列目標函式：

$$O_{HPE} = - \sum_{(i,j) \in E} w_{i,j} \log \Pr(v_j | \mathcal{V}_{v_i}) + \lambda \sum_i \|\mathcal{V}_{v_i}\|^2 \quad (3.9)$$

其中， E 表示我們抽樣到的邊的集合， $w_{i,j}$ 代表邊的權重，而加入一個正規化的參數是為了避免過度擬合的情形發生。此外，HPE 還加入了異步的隨機梯度下降法（Asynchronous Stochastic Gradient Descent）對3.9式進行最佳化。

3.5 推薦系統

經由上述 3.3 小節與 3.4 小節的流程後，我們可得到跨領域市場網路異質圖經由超連結圖譜強化後，再透過網路表示法學習訓練出來，每個用戶的向量表示法 r_u 與歌曲的向量表示法 r_i ，其中向量表示法的維度皆為 d 且皆遠小於用戶及歌曲的數量。在推薦系統中，我們使用訓練完成的表示法，根據每個使用者 u 及其聆聽之歌曲 q 預測出使用者對於每首歌曲 i 的分數

$$Score_{u,q,i} = p \times (r_u \cdot r_i^T) + (1 - p) \times (r_q \cdot r_i^T) \quad (3.10)$$

其中， $q, i \in |I|$ ， $u \in |U|$ ， $p \in [0, 1]$ ，之後我們再根據此分數，取出前 k 首排序分數最高的歌曲，生成個人化的推薦列表。



第四章

實驗結果與討論

在此章節，我們將會討論與分析我們的架構和方法所得到的表現結果。在 4.1 小節中我們會敘述一下我們所使用的資料集以及其資料特性，並且展示其相關的統計數據。而在 4.2 小節，我們會說明並提供實驗的模型所使用的參數以及我們的比較方法。在 4.3 小節，我們則會介紹我們所使用得評估指標。在 4.4 小節中，我們會比較及分析我們方法與其他方法的表現。最後，在 4.5 中，我們會透過實例的展示來觀察此系統的表現。

4.1 資料集

在此篇論文中我們使用 KKBOX 於音樂串流平台的聆聽紀錄作為資料集來實驗。KKBOX 收集了所有用戶在自家音樂串流平台中所做出的聆聽行為，每一筆資料都詳細地記錄了一個用戶在什麼時間點聽了哪一首歌、從哪種裝置登入、聆聽時間以及地區。本論文選出了新興的 A 市場作為目標資料集，處理了 2018 年 5 月至 8 月於 A 市場的所有聆聽紀錄，並將 5 至 7 月的資料當做訓練資料集（以下簡稱訓練集 A），8 月的資料當做測試資料集（以下簡稱測試集 A）；而另一方面，我們也選出了我們用來輔佐且有豐富資訊的 B 市場作為來源資料集，同樣也處理了 2018 年 5 月至 7 月的資料當做訓練集（以下簡稱訓練集 B）。

表 4.1: A、B 市場資料集數據統計

資料集	訓練集 A (2018/5-2018/7)	測試集 A (2018/8)	訓練集 B (2018/5-2018/7)
$ U $	1580	1548	249640
$ I $	22170	12276	558601
$ S $	63938	31848	22258342
$t(\cdot)$	40.47	20.57	89.16
$k(\cdot)$	288.40	111.48	629.40
稀疏度	0.182%	0.168%	0.016%

其中， $|S|$ 為所有用戶 - 歌曲不重複之聆聽組合， $t(\cdot)$ 為用戶平均聆聽的歌曲數量， $k(\cdot)$ 為用戶對於歌曲的平均聆聽次數，稀疏度定義為所有用戶 — 歌曲不重複之聆聽組合佔所有可能組合的比率，即為 $\frac{|S|}{|U| \times |I|}$ 。

在此次資料集的設定將 5 月到 7 月來作為訓練集來預測 8 月的原因是因為我們期望利用過往的歷史資料來預測未來的趨勢或對未來作決策，而這也是在實務上比較實際的做法。在我們提出的超連結圖譜建圖法中，歌曲在不同市場的重疊率是一項很重要的因素，因為我們建立超連結的基準在於這兩個不同資料集中的使用者，他們聽過的歌曲集合的重疊率是否超過一定的門檻值。下表所示為訓練集 A、B 整體歌曲的重疊率，由此表可以發現到，歌曲的重疊性分別對於兩個資料集有著顯著的差異。對於比較小的資料集的使用者來說，這些重疊的歌曲數越高，對於所連接的使用者，他們的偏好便會與自己越相近，因此能夠一定程度的幫助到小資料集學得更好。

表 4.2: 訓練集中共有歌曲佔訓練集之歌曲重疊率

資料集	重疊率
訓練集 A	78.09%
訓練集 B	3.09%

4.2 實驗設定

此章節會說明我們挑選的幾個表示法學習方法，用來當成我們推薦系統的訓練基礎模型與加上我們的建圖方法後所學習的模型並詳加敘述相關的參數設定。

- **DeepWalk**：DeepWalk 利用隨機走動生成一串節點序列，並以網路結構類似於句子的假設之訓練方式來產生網路表示法。在訓練 Deepwalk 時，我們設定表示法的維度（Dimensions）為 100，對每個節點當做起點的次數（Walk Times）為 20 次，每次遊走的距離（Walk Step）為 40 步，給定的視窗大小（Window Size）為 3，每次負抽樣的數量（Negative Samples）為 5 次。

- **LINE**：在 LINE，我們使用二階相似度作為我們的網路表示法訓練標準，其意義為節點之間所擁有的相同鄰居越多，我們就說他們越相似。在訓練 LINE 上，我們設定表示法的維度（ Dimensions ）為 100，取樣次數（ Samples Times ）設定為 20 億次，每次負抽樣的數量（ Negative Samples ）為 5 次。
- **HPE**： Heterogeneous Preference Embedding 可以將使用者的異質資訊結合起來學習，並根據學習到的使用者的偏好進行相關的推薦。我們設定 HPE 表示法的維度（ Dimensions ）為 100，取樣次數（ Samples Times ）設定為 20 億次，每次負抽樣的數量（ Negative Samples ）為 5 次，每次遊走的距離（ Walk Step ）為 3 步，正規化的參數（ Regularization Term ）為 0.01 。

以下為我們建圖方法與表示法學習的參數設定。

- **Superhighway**：超連結圖譜根據兩個不同資料集中，一個使用者對於另一個資料集之使用者之間物品的重疊度來決定是否要建立連結，在建立連結後，對於在兩個獨立網路結構之間遊走將會更加容易，也能進一步優化其網路表示法的學習。而在超連結圖譜建圖中，我們設定兩個用戶之間共有的歌曲比例 α 值為 0.9，建立超連結的權重 β 為 1.0，以下三種網路表示法學習皆使用此設定。
- **Superhighway+DeepWalk**：在超連結圖譜建圖中，我們設定兩個用戶之間共有的歌曲比例 α 值為 0.9，建立超連結的權重 β 為 1.0。在訓練 Deepwalk 時，我們設定表示法的維度（ Dimensions ）為 100，對每個節點當做起點的次數（ Walk Times ）為 20 次，每次遊走的距離（ Walk Step ）為 40 步，給定的視窗大小（ Window Size ）為 3，每次負抽樣的數量（ Negative Samples ）為 5 次。
- **Superhighway+LINE**：在超連結圖譜建圖中，我們設定兩個用戶之間共有的歌曲比例 α 值為 0.9，建立超連結的權重 β 為 1.0。在訓練 LINE 上，我們設定表示法的維度（ Dimensions ）為 100，取樣次數（ Samples Times ）設定為 20 億次，每次負抽樣的數量（ Negative Samples ）為 5 次。
- **Superhighway+HPE**：在超連結圖譜建圖中，我們設定兩個用戶之間共有的歌曲比例 α 值為 0.9，建立超連結的權重 β 為 1.0。我們設定 HPE 表示法的維度（ Dimensions ）為 100，取樣次數（ Samples Times ）設定為 20 億次，每次負抽樣的數量（ Negative Samples ）為 5 次，每次遊走的距離（ Walk Step ）為 3 步，正規化的參數（ Regularization Term ）為 0.01 。

對於上述網路表示法，我們皆使用 ProNet 套件 [6]¹ 做訓練。

¹ProNet-core: <https://github.com/cnclabs/proNet-core>

4.3 評估標準

為了比較衡量我們的改進方法與原方法在音樂推薦效果上的表現，我們採用以下四種評估方式來評估基於查詢的推薦系統的表現：

準確率（Precision）

準確率表示在給定測試資料集中，使用者喜歡的歌曲被成功推薦的集合佔推薦清單的百分率，其公式如下：

$$Precision = \frac{\sum_{u \in U} \frac{|T_u|}{N}}{|U|} \quad (4.1)$$

其中， T_u 為使用者喜歡的歌曲在推薦清單的集合， N 為推薦回的清單數量， U 為所有使用者。準確率最高為 1，準確率越高，表示我們做出的推薦清單能夠推回越多對使用者來說有興趣的歌曲，因此能一定程度地展現出歌單的品質。

召回率（Recall）

召回率表示在給定測試資料集中，使用者喜歡的歌曲被成功推薦的百分率。其公式如下：

$$Recall = \frac{\sum_{u \in U} \frac{|T_u|}{|I_u|}}{|U|} \quad (4.2)$$

其中， T_u 為使用者喜歡的歌曲在推薦清單的集合， I_u 為使用者喜歡的所有歌曲的集合， U 為所有使用者。召回率最高為 1，我們使用召回率是為了觀察資料集中各個使用者被推薦出來的歌曲清單中，有多少比例被系統推薦出來。

由以上兩種評估的公式來看，我們可以發現在，準確率與召回率是有一定的平衡關係的，要使其中一種分數提高，勢必會使另一種評估的分數下降。例如：假定對於一個使用者來說，歌單的準確率為 1，看起來推薦效果似乎很好，但實際觀察資料後發現，其實對這一個使用者他有興趣的歌曲很多，導致很容易就推回他有興趣的歌曲。相對的這個使用者的召回率就會很低，因為系統沒有辦法推回所有他有興趣的歌曲。而每位使用者有興趣的歌曲數量也都不一樣，因此必須要同時考量這兩種數值的高低來評估推薦系統的好壞。

平均準確率均值 (Mean-average Precision)

平均準確率均值表示在給定測試資料集中，所有使用者喜歡的歌曲被成功推薦的集合佔推薦清單的百分率，其公式如下：

$$MAP = \frac{\sum_{u \in U} AP_u}{|U|} \quad (4.3)$$

其中， U 為所有使用者， AP_u 為每個使用者的平均準確率，即：

$$AP_u = \frac{\sum_{i=1}^N \frac{\sum_{j=1}^i R(Item_j)}{i}}{N} \quad (4.4)$$

其中， $Item$ 為推薦回的歌曲清單， $R(\cdot)$ 為一指示函式，當 $Item_j$ 在使用者喜歡的歌曲集合時則為 1，否則為 0。在檢索系統中，平均準確率是一項指標性的評估標準，我們在推薦回的清單中不只要考慮物品的相關性，更重要的是也要考量物品在清單中的順序關係。一般要評估我們搜尋回的清單的品質時，經常使用的是準確率，即在清單中，相關的項目佔清單的比率，但準確率並不考慮順序的關係，例如我們搜尋回 10 篇文章，最理想的情況是清單內每一篇文章都是相關的，準確率為 1，但實際上並不會有這麼完美的表現，假設系統搜回的文章皆有 4 篇相關，系統的準確率為 0.4，相關的文章不管排序在哪個位置都不會影響準確率的分數，但我們會希望好的系統對於相關的文章排序應該要在不相關的文章之前，準確率無法評估這項指標，因此就有平均準確率的評估方式出現。平均準確率考量項目在清單中的位置，對於越後面的位置給予較大的懲罰，得到的分數越低，因此對於相關的文章在清單的位置越靠前，這個分數就越大，他體現了希望越相關的東西必須要越早出現這個概念。而在這裡，我們將所有使用者的平均準確率取均值來評估整個系統推薦的品質差異。

新穎度 (Novelty)

新穎度表示在給定測試資料集中，所有使用者對於其推薦清單的歌曲偏向熱門與否的程度，其公式如下：

$$Novelty = \frac{1}{|U|} \frac{1}{N} \sum_{u \in U} \sum_{i=1}^N \frac{\ln b_s}{\ln \max(b_s, C_i)} \quad (4.5)$$

其中， C_i 為歌曲在資料集中的總聆聽次數， b_s 為可調整之閾值。新穎度的數值最大為 1，最小則趨近於 0。新穎度在影音串流等服務中業界很常使用的一種評估推薦系統品質的標準。在推薦系統中，與傳統資訊檢索系統最大的不同是，推薦系統能幫助使用者發掘出潛藏在資料裡，對於使用者來說無法找到但實際上感興趣的物品，尤其在音樂串流服務中更顯重要，因為歌曲的數量眾多，一般使用

者聽過的歌曲不過數百首且大多為較熱門的歌曲。推薦出使用者沒有聽過但卻感興趣的歌曲，一方面可以幫助使用者發掘出冷門的歌曲，也有助於使推薦系統能夠真的推出感興趣的歌曲而不是集中在熱門歌曲上。但對於使用者來說，冷門或新歌曲大多是沒有被使用者聽過的（即對使用者來說被分類為無相關），因此，若以傳統的評估方式來看的話，某種程度上是會使數值下降的，但系統可能因此能推出更廣泛的歌曲，對於服務來說是更好的。新穎度就提供了一種評量方式，用來評估這個推薦系統是否有達到廣泛推薦的效果。

在測試資料集中，我們對每位使用者生成 $k = 10$ 、 20 、 30 的基於查詢的推薦清單，再利用這些指標評估模型的好壞。

4.4 實驗結果分析與討論

4.4.1 準確率表現

Method	P@10	P@20	P@30	P@10 Improvement
Deepwalk	0.0402	0.0337	0.0302	-
Superhighway+ Deepwalk	0.0552	0.0430	0.0372	37.3%
LINE	0.0528	0.0438	0.0387	-
Superhighway+ LINE	0.0522	0.0425	0.0356	-1.1%
HPE	0.0407	0.0333	0.0298	-
Superhighway+ HPE	0.0775	0.0614	0.0525	90.4%

表 4.3: 準確率表現

由表 4.3 中我們可以得知，在 Deepwalk 與 HPE 中，我們的建圖方法在 $k = 10$ 、 20 、 30 的表現都明顯地勝過原本的方法，尤其在 HPE 中，成長幅度接近 2 倍，也表示我們的方法在某種程度上，對於推薦的效果有一定的提升；但是在 LINE 的方法上，我們的建圖策略的表現雖然沒有提升，但差異並沒有很明顯。

4.4.2 召回率表現

與準確率成績類似，在表 4.4 中我們知道，在 Deepwalk 與 HPE 中，我們的建圖方法在 $k = 10$ 、 20 、 30 的表現也都明顯地勝過原本的方法，在 HPE 中，成長幅度也超過 7 成；不過同樣地，在 LINE 的方法上，我們的建圖策略的表現是下降的，不過差異並沒有很明顯。

Method	R@10	R@20	R@30	R@10 Improvement
Deepwalk	0.0528	0.0540	0.0576	-
Superhighway+ Deepwalk	0.0670	0.0646	0.0681	26.9%
LINE	0.0660	0.0693	0.0782	-
Superhighway+ LINE	0.0628	0.0675	0.0702	-5.1%
HPE	0.0518	0.0543	0.0595	-
Superhighway+ HPE	0.0889	0.0915	0.0978	71.6%

表 4.4: 召回率表現

由上面兩種評估方式，我們發現在 Deepwalk 及 HPE 的方法之下，利用我們的建圖策略，皆能夠使得準確率與召回率的表現上升，這也是我們所期待的結果，表示利用我們方法推薦出來的歌單能夠更好地將使用者的偏好給擷取出來，達到個人化推薦的目的。不過值得探討的是，LINE 在加入我們的建圖策略後表現並沒有變好，反而是微幅下降，可能的原因是我們認為跟每個方法學習的方式有關：我們的建圖策略所建出來的圖已經不算是單純的二分圖，在利用二階相似度做學習的 LINE 上會因為只能抓到兩步左右的節點學習而使得用戶—用戶間的邊反而成為雜訊而使得學習效果不佳；另一方面，透過隨機遊走方式的 Deepwalk 跟 HPE，由於能夠抓到兩步以後的節點，便能透過超連結的節點邊學習更多訊息。

4.4.3 平均準確率均值表現

Method	MAP@10	MAP@20	MAP@30	MAP@10 Improvement
Deepwalk	0.0295	0.0254	0.0246	-
Superhighway+ Deepwalk	0.0346	0.0276	0.0253	17.2%
LINE	0.0358	0.0304	0.0291	-
Superhighway+ LINE	0.0367	0.0292	0.0266	2.5%
HPE	0.0292	0.0262	0.0252	-
Superhighway+ HPE	0.0509	0.0410	0.0379	74.3%

表 4.5: 平均準確率均值表現

由表 4.5 中我們可以看到， $k = 10$ 的時候，我們的建圖方法使用在上述三種網路表示法上，表現都比原本的方法要好。HPE 不只在準確率、召回率上有顯著的提升，在平均準確率均值表現上也很好，表示 HPE 在我們建圖方法的幫助下，不只能夠更符合使用者的需求找到有興趣的歌曲，這些「相關」的歌曲也大

多都會優先出現在歌單前段；在 Deepwalk 的表現上雖沒有大幅度成長，但也有一定程度的上升；特別要注意的依然是 LINE。在前段實驗結果中，我們已經知道，LINE 在使用我們的建圖策略下反而是會下降的，但在平均準確率均值表現上則有持平的表現，甚至在 $k = 10$ 時有小幅的上升，表示我們的方法雖然無法使準確率成績有所上升，但在排序上還是會有微幅的改良，而在推薦系統中，對用戶來說最重要的便是期望他所感興趣的歌曲會在歌單前面就出現，也因此，在這部分，我們的方法皆能使推薦歌單有較好的品質。

4.4.4 新穎度表現

Method	Novelty@10	Novelty@20	Novelty@30
Deepwalk	0.666	0.671	0.670
Superhighway+ Deepwalk	0.710	0.721	0.726
LINE	0.587	0.617	0.631
Superhighway+ LINE	0.690	0.700	0.710
HPE	0.746	0.750	0.750
Superhighway+ HPE	0.613	0.622	0.632

表 4.6: Top-N 新穎度表現

在表 4.6 中我們列出原本的模型與加入我們建圖策略後的模型，在新穎度上的表現。如上述 4.3 章節中所描述的，新穎度主要是在測試此模型在推薦較為冷僻或探索新歌曲的能力，這在音樂串流服務中之所以重要的原因為：雖然我們在聽音樂的時候傾向於聆聽我們喜歡的音樂，但比起聆聽已經聽過的歌曲，我們會更想要聽到沒有聽過，但是符合我們喜好的歌曲。因此，對於兩種平均準確率均值相同的推薦歌單來說，新穎程度較高的歌單也代表著在符合使用者喜好的限制之下能有著更多樣化的歌曲，也能一定程度上幫助使用者探索其他未知的歌曲。如上表所展示的，在 Deepwalk 跟 LINE 上，我們的方法在新穎度上都勝過原本的方法，但在 HPE 上，我們的方法在新穎度上反而表現不佳。我們認為原因是因為新穎度在某種程度上是與準確率、召回率及平均準確率均值三種標準有一個相互平衡的關聯關係，例如我們想讓平均準確率均值能提升，但提升的話，就表示歌單內使用者沒有聽過的歌（無相關）比率就會下降，也就減少使用者探索、拓展的機會。HPE 的表現就表示著這一點；而 LINE 雖然在準確率等評估上呈現下降趨勢，但在新穎度上卻勝過原本的方法；最令我們驚訝的是 Deepwalk，不僅在三項評估上表現勝過原本的方法，在新穎度上表現也較佳。

綜合以上評估標準，我們認為我們的方法能夠透過超連結的建邊來幫助各類網路表示法學習方法將網路學習的更好，並有效擷取使用者偏好以得到更有品質

的網路表示法來做推薦。

4.5 實例分析

4.5.1 實例分析-以推薦系統為例

在此小節中，我們透過實際的例子來展示我們的推薦系統在實際的推薦問題上是否能夠符合我們的預期以及上述方法和加入我們的方法在學習上的結果。

為了要分析我們推薦的結果是否符合我們的期望，我們於目標資料集中挑選了一名使用者，並利用他的歷史聆聽紀錄來建立推薦的清單。表 4.7列出我們使用不同方法的模型所推薦出來的結果。根據這名使用者他們歷史紀錄來推斷，這名使用者很喜歡聆聽80年代的流行及搖滾樂曲，而我們預期推薦系統也應該會推薦他80年代的流行或是搖滾歌曲。而在原本的方法推薦下，歌單裡面也混雜了像是 For Your Entertainment 、 Oh My My 這類現代歌曲，甚至是芝麻街的歌曲 Princess and the Pea 等等；而我們的方法則幾乎都會推回80年代的流行歌手及搖滾樂團，這也是符合我們期望的推薦。由此實例可以知道我們的方法可以基於協同過濾以及遷移知識來使得歌曲的特徵融合在網路表示法裡面

4.5.2 實例分析-以網路表示法學習為例

在我們的推薦系統之中，網路表示法學習的情況會很直接的影響歌曲的推薦效果，對於用戶的網路表示法也能根據需要進行相關的分析情境。透過表示法學習，我們希望：

- 能夠透過來源資訊的知識引入來解決目標資料的稀疏性問題
- 對於歌曲來說，風格類似的歌曲應該要越相近越好。也就是希望歌曲的網路表示式有用戶間協同過濾的特徵在裡面

以下，我們使用 Selena Gomez 的 Fetish 這首歌做為查詢的歌曲，針對不同方式下的網路表示法進行分析。

表 4.8 與表 4.9為我們利用 Fetish 這首歌的網路表示法在不同的方法底下進行餘弦相似度的搜尋所找出來的 10 首歌，可以看到，在原本的方法之中，除了找到了像 Demi Lovato 或 Ariana Grande 這類與 Selena Gomez 相似的女歌手風格曲之外，似乎還混雜了中文抒情、韓文流行甚至是饒舌歌曲等風格迥異的歌曲，表示

	歌曲名稱	歌手
使用者聆聽記錄	Careless Whisper Sweet Child O' Mine Wake Me Up Before You Go-Go	George Michael Guns N' Roses George Michael
Method	歌曲名稱	歌手
Deepwalk	Can't Fight This Feeling Livin' On A Prayer Rock You Like A Hurricane Bodies For Your Entertainment	Essential - 80's Bon Jovi Scorpions Drowning Pool Adam Lambert
LINE	Roll With It Oh My My Nobody But You I Believe Every Morning	Backstreet Boys JTR Backstreet Boys Elvis Presley Sugar Ray
HPE	Bodies I'm With You Never Say Goodbye Pretty Fly for a White Guy Princess and the Pea	Drowning Pool Bon Jovi Bon Jovi The Offspring Sesame Street
Superhighway+ Deepwalk	Carrie Glory Of Love Total Eclipse Of The Heart Against All Odds Cheri Cheri Lady	Europe Peter Cetera Bonnie Tyler Phil Collins Modern Talking
Superhighway+ LINE	Last Christmas Carrie Desperado The Final Countdown Fastlove	George Michael Europe Eagles Europe George Michael
Superhighway+ HPE	Carrie Without You Against All Odds Always Making Love Out Of Nothing At All	Europe Air Supply Phil Collins Bon Jovi Air Supply

表 4.7: 推薦系統之實例

	歌曲名稱	歌手
query	Fetish	Selena Gomez
Method	歌曲名稱	歌手
Deepwalk	My Everything	Ariana Grande
	Cry Baby	Demi Lovato
	Dark Side	Bishop Briggs
	山外小樓聽夜雨	Xun
	Eye of the Needle	Sia
	Reaper	Sia
	Unstoppable	Sia
	NOMAD	Walk Off The Earth
	Rainbow	Kesha
	2! 3!	BANGTAN BOYS
LINE	Issues	Julia Michaels
	Chained To The Rhythm	Katy Perry
	Cry Baby	Demi Lovato
	Rainbow	Kesha
	Neon Lights	Demi Lovato
	Same Old Love	Selena Gomez
	Ikuyo	Kyle
	Who Says	Selena Gomez
	Bed	Nicki Minaj
	Impossible	Shontelle
HPE	Cry Baby	Demi Lovato
	Rainbow	Kesha
	Dark Side	Bishop Briggs
	Eye of the Needle	Sia
	山外小樓聽夜雨	Xun
	NOMAD	Walk Off The Earth
	Mr Lonely (feat. Fat Lip)	Portugal. The Man
	My Everything	Ariana Grande
	2! 3!	BANGTAN BOYS
	Stone Cold	Demi Lovato

表 4.8: 網路表示法學習實例一之一

	歌曲名稱	歌手
query	Fetish	Selena Gomez
Method	歌曲名稱	歌手
Superhighway+ Deepwalk	Bad Liar The Way I Are (Dance With Somebody) Sober Crying in the Club Good For You Woman Call It What You Want Kill Em With Kindness The Heart Wants What It Wants Remember I Told You	Selena Gomez Bebe Rexha Selena Gomez Camila Cabello Selena Gomez Kesha Taylor Swift Selena Gomez Selena Gomez Nick Jonas
Superhighway+ LINE	Bad Liar The Way I Are (Dance With Somebody) Sober Call It What You Want Slow Down Down The Heart Wants What It Wants Crying in the Club Woman Gorgeous	Selena Gomez Bebe Rexha Selena Gomez Taylor Swift Selena Gomez Fifth Harmony Selena Gomez Camila Cabello Kesha Taylor Swift
Superhighway+ HPE	Crying in the Club Bad Liar The Way I Are (Dance With Somebody) Back to You Friends I Got You Swish Swish ...Ready For It? Down Gorgeous	Camila Cabello Selena Gomez Bebe Rexha Louis Tomlinson Justin Bieber, BloodPop® Bebe Rexha Katy Perry Taylor Swift Fifth Harmony Taylor Swift

表 4.9: 網路表示法學習實例一之二

在學習表示法的時候還是會一定程度的受到資料稀疏性影響而會有偏差；而我們的方法所找回來的則幾乎都是風格相近的歌曲，甚至都是女性歌手居多，這比較符合我們預期的結果，也證實了遷移來源資料的知識到目標資料是有助於在目標資料上的學習。



第五章

結論

在本論文中，對於一個資訊尚未成熟的音樂串流服務的推薦系統，我們提出了一個適用的建圖策略，透過來源市場中較為豐富的使用者聆聽記錄與目標市場的資訊做結合，運用了超連結圖譜的策略，根據其共享的歌曲集合，將來源與目標的使用者節點做連結，再將圖譜以異質性網路表示法做學習，使得來源資訊的知識能合理地遷移至目標資訊，進而改善目標資訊的網路表示法，進而完成基於查詢的推薦。與原有的方法做比較，我們的方法在平均準確率均值等評估數據上皆有不錯的表現，在音樂串流服務中也很注重的新穎度表現上也取得了很好的平衡。以實際運用上來看，我們的方法能夠在資料不足的情況下，藉由遷移額外資訊的知識進來而表現達到提升，也能夠改善現實推薦系統常見的資料稀疏性的問題。

在未來展望上，我們會考慮使用不同的網路表示法來做學習，也可以將網路表示法學習到的表示式當成歌曲或用戶的特徵值再使用其他模型做訓練。另外，對於歌曲的各項其他屬性的資訊如歌手、作曲者、歌詞、曲風等等當做特徵來一起訓練也是可以嘗試的方向之一。再來，更可以結合歌曲音訊等多媒體資訊，結合近年來熱門的深度學習架構，或許能從中擷取到有用的資訊。

參考文獻

- [1] G. Adomavicius and A. Tuzhilin. Towards 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, June 2005.
- [2] Y. Bengio, A. Courville, and P. Vincent. Representation learning: A review and new perspectives. *IEEE Trans. Pattern Anal. Mach. Intell.*, 35(8):1798–1828, Aug. 2013.
- [3] B. Bocsi, L. Csató, and J. Peters. Alignment-based transfer learning for robot models. pages 1–7, 08 2013.
- [4] R. Burke. Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, 12(4):331–370, Nov. 2002.
- [5] 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, pages 79–82, New York, NY, USA, 2016. ACM.
- [6] C.-M. Chen, Y.-H. Yang, Y. Chen, and M.-F. Tsai. Vertex-context sampling for weighted network embedding. *arXiv preprint arXiv:1711.00227*, 2017.
- [7] P. Cremonesi, A. Tripodi, and R. Turrin. Cross-domain recommender systems. In *Proceedings of the 2011 IEEE 11th International Conference on Data Mining Workshops*, ICDMW ’11, pages 496–503, Washington, DC, USA, 2011. IEEE Computer Society.
- [8] W. Dai, Q. Yang, G.-R. Xue, and Y. Yu. Self-taught clustering. In *Proceedings of the 25th International Conference on Machine Learning*, ICML ’08, pages 200–207, New York, NY, USA, 2008. ACM.
- [9] Y. Ganin and V. Lempitsky. Unsupervised domain adaptation by backpropagation. In *Proceedings of the 32Nd International Conference on International Conference on Machine Learning - Volume 37*, ICML’15, pages 1180–1189. JMLR.org, 2015.

- [10] C. Gao, X. Chen, F. Feng, K. Zhao, X. He, Y. Li, and D. Jin. Cross-domain recommendation without sharing user-relevant data. In *The World Wide Web Conference, WWW ’19*, pages 491–502, New York, NY, USA, 2019. ACM.
- [11] A. Grover and J. Leskovec. Node2vec: Scalable feature learning for networks. In *Proceedings of the 22Nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD ’16, pages 855–864, New York, NY, USA, 2016. ACM.
- [12] Y. Hu, Y. Koren, and C. Volinsky. Collaborative filtering for implicit feedback datasets. In *Proceedings of the 2008 Eighth IEEE International Conference on Data Mining*, ICDM ’08, pages 263–272, Washington, DC, USA, 2008. IEEE Computer Society.
- [13] Y. Koren, R. Bell, and C. Volinsky. Matrix factorization techniques for recommender systems. *Computer*, 42(8):30–37, Aug. 2009.
- [14] K. Lai, T. Wang, H. Chi, Y. Chen, M. Tsai, and C. Wang. Superhighway: Bypass data sparsity in cross-domain CF. *CoRR*, abs/1808.09784, 2018.
- [15] B. Li, Q. Yang, and X. Xue. Can movies and books collaborate?: Cross-domain collaborative filtering for sparsity reduction. In *Proceedings of the 21st International Joint Conference on Artificial Intelligence*, IJCAI’09, pages 2052–2057, San Francisco, CA, USA, 2009. Morgan Kaufmann Publishers Inc.
- [16] J. McAuley, C. Targett, Q. Shi, and A. van den Hengel. Image-based recommendations on styles and substitutes. In *Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval*, SIGIR ’15, pages 43–52, New York, NY, USA, 2015. ACM.
- [17] T. Mikolov, I. Sutskever, K. Chen, G. Corrado, and J. Dean. Distributed representations of words and phrases and their compositionality. In *Proceedings of the 26th International Conference on Neural Information Processing Systems - Volume 2*, NIPS’13, pages 3111–3119, USA, 2013. Curran Associates Inc.
- [18] S. J. Pan and Q. Yang. A survey on transfer learning. *IEEE Trans. on Knowl. and Data Eng.*, 22(10):1345–1359, Oct. 2010.
- [19] M. J. Pazzani and D. Billsus. The adaptive web. chapter Content-based Recommendation Systems, pages 325–341. Springer-Verlag, Berlin, Heidelberg, 2007.
- [20] 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, pages 701–710, New York, NY, USA, 2014. ACM.

- [21] R. Raina, A. Battle, H. Lee, B. Packer, and A. Y. Ng. Self-taught learning: Transfer learning from unlabeled data. In *Proceedings of the 24th International Conference on Machine Learning*, ICML '07, pages 759–766, New York, NY, USA, 2007. ACM.
- [22] S. Rendle. Factorization machines. In *Proceedings of the 2010 IEEE International Conference on Data Mining*, ICDM '10, pages 995–1000, Washington, DC, USA, 2010. IEEE Computer Society.
- [23] S. Rendle, C. Freudenthaler, Z. Gantner, and L. Schmidt-Thieme. Bpr: Bayesian personalized ranking from implicit feedback. In *Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence*, UAI '09, pages 452–461, Arlington, Virginia, United States, 2009. AUAI Press.
- [24] P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom, and J. Riedl. GroupLens: An open architecture for collaborative filtering of netnews. pages 175–186. ACM Press, 1994.
- [25] 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, pages 1067–1077, Republic and Canton of Geneva, Switzerland, 2015. International World Wide Web Conferences Steering Committee.
- [26] Y. Zhang, Q. Ai, X. Chen, and W. B. Croft. Joint representation learning for top-n recommendation with heterogeneous information sources. In *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, CIKM '17, pages 1449–1458, New York, NY, USA, 2017. ACM.