

郝沛毅、龔千芬、張俊陽、蔣榮先、鄭詠恆 (2020), 『嶄新的即時 POI 推薦系統－使用即時事件、圖文 / 時間內容感知資訊與樹狀卷積網路』, 中華民國資訊管理學報, 第二十七卷, 第四期, 頁 495-536。

嶄新的即時 POI 推薦系統－使用即時事件、 圖文 / 時間內容感知資訊與樹狀卷積網路

郝沛毅*

國立高雄科技大學智慧商務系

龔千芬

國立高雄科技大學智慧商務系

張俊陽

國立高雄科技大學智慧商務系

蔣榮先

國立成功大學資訊工程學系

鄭詠恆

國立成功大學資訊工程學系

摘要

基於位置的社群網路 (LBSN) 近來變得十分流行, 這歸功於智慧手機的爆炸式增長, 使得用戶可以輕鬆地執行 LBSN 程序。越來越多使用者在這些平台上與好友分享打卡資訊跟生活點滴。興趣點 (POI) 推薦系統是 LBSN 的核心服務, 也是最近熱門的研究焦點。目前研究主要是分析用戶的打卡序列, 來探勘使用者的偏好, 可是, 這些方法沒有考量到時間與事件這兩項關鍵因素, 我們認為這兩項因素會影響使用者拜訪興趣點的意願。例如, 一個平常不運動的使用者, 會因為一個演唱會的契機而在體育館打卡, 如果系統只考慮使用者對於興趣點的固有偏好, 則會忽略了這種情境。

本研究的目的是建立一個結合即時事件偵測的興趣點推薦系統。我們的主要貢獻是考慮正在進行的事件、合適的時機與 POI 的特性, 以上述三個基礎來推薦合適的 POI。我們的方法可以從大量的具地理標記的推文中, 偵測出即時事件,

* 本文通訊作者。電子郵件信箱: haupy@nkust.edu.tw
2020/03/20 投稿; 2020/05/19 修訂; 2020/09/25 接受

並且透過本研究研發的樹狀卷積神經網路，來學習即時事件與時間感知資訊的嵌入特徵表示。此外，我們的方法可以從標記在興趣點的文字評論與拍攝照片中，捕抓興趣點的圖文內容感知特徵，並且以卷積神經網路來學習興趣點的圖文嵌入特徵向量。最終，這些 POI 的即時嵌入特徵將融合到矩陣分解式的協同過濾推薦演算法，以建構即時的 POI 推薦系統。

關鍵詞：事件嵌入、興趣點推薦、矩陣分解、深度學習、卷積神經網路

Hao, P.Y., Kung, C.F., Chang, C.Y., Chiang, J.H. and Cheang, W.H. (2020), 'Real-time POI recommendation based on event embedding, textual & visual/time-aware information and tree structured CNN', *Journal of Information Management*, Vol. 27, No. 4, pp. 495-536.

Real-Time POI Recommendation Based on Event Embedding, Textual & Visual/Time-Aware Information and Tree Structured CNN

Pei-Yi Hao*

Department of Intelligent Commerce,
National Kaohsiung University of Science and Technology

Chien-Feng Kung

Department of Intelligent Commerce,
National Kaohsiung University of Science and Technology

Chun-Yang Chang

Department of Intelligent Commerce,
National Kaohsiung University of Science and Technology

Jung-Hsien Chiang

Department of Computer Science and Information Engineering,
National Cheng Kung University

Weng-Hang Cheang

Department of Computer Science and Information Engineering,
National Cheng Kung University

Abstract

Purpose— Location-based social networks (LBSN) have recently become popular due to the explosive growth of smartphones, giving users easy access to LBSN applications. More and more users have shared check-in information and daily life with friends on these platforms. The point of interest (POI) recommendation system is one of the core services of the LBSN.

* Corresponding author. Email: haupy@nkust.edu.tw

2020/03/20 received; 2020/05/19 revised; 2020/09/25 accepted

Design/methodology/approach — This study proposes a novel real-time POI recommendation system. The proposed approach is capable to detect real-time event from the huge amount of geo-tagged tweets in LBSN, and learn the embedding representation of the real-time event and time-aware information of a given POI. Besides, the proposed approach captures the content characteristic of POI from the text and photos tagged at the corresponding POI, and learn the embedding representation of the textual and visual characteristic of a given POI. Finally, we incorporate the real-time POI embedding into the matrix factorization model to build the real-time POI recommendation system.

Findings—Firstly, multimodal embedding with considering various types (spatial, temporal and textual) of features performs well in learning semantic meaning on keywords. Thus it is effective for us to build the event detection from messy short-texts on social media. Besides, the proposed model considers time-aware information of the POIs by extracting ongoing events and recommend for suitable users in different time period. Evaluation on the dataset with geo-tagged tweets in NYC demonstrates the effectiveness of our study.

Research limitations/implications—Our POI Intrinsic Embedding metric is trained by textual information. It only considers textual features of POIs. However, other types of information such as geographical features like latitude and longitude, popularity features like the flow at different time period can be applied in the embedding metric in the future work.

Practical implications—The POI recommendation applications are of significance in two aspects: helping users explore new interesting places in a city and facilitating business owners to launch advertisements to the target customers.

Originality/value—This study is, to the best of our knowledge, the first attempt to apply tree-based CNN for the real time event detection and POI recommendation in Taiwan.

Keywords: event embedding, POI recommendation, matrix factorization, deep learning, convolutional neural networks

壹、緒論

基於位置的社群網路 (location-based social networks; LBSN) 近來變得非常流行，這歸功於智慧手機的爆炸式增長，使得用戶可以輕鬆地執行 LBSN 應用程序。根據 EMarketer 的預測，2019 年全球有 23 億人使用智慧手機，這也造就全球線上 LBSN 蓬勃發展。典型的 LBSN 系統 (諸如 Foursquare 和 Facebook Places) 允許用戶分享其簽到行為 (check-in, 即打卡)，包括訪問過的位置的地理訊息 (緯度和經度)，並在所訪問的位置 (也稱為興趣點, point of interest; POI) 上撰寫評論與拍照。LBSN 現在是非常受到歡迎，例如，Foursquare 每月在全球吸引超過 5500 萬人使用它的服務，並在 2019 年之前總共記錄了 120 億次簽到記錄。在 LBSN 中收集的大量數據的驅動下，激發了興趣點 (point-of-interest; POI) 推薦系統的熱門研究主題的出現，它企圖對每個用戶建議一個該用戶可能會感興趣並且願意訪問的 POI 列表，以改善 LBSN 應用程序中的用戶體驗。POI 推薦應用程序在兩個方面具有重要意義：(1) 幫助用戶探索城市中新的有趣地點；(2) 幫助企業主 (例如，POI 商店的老闆) 發掘其目標客戶，並對他們發布廣告。

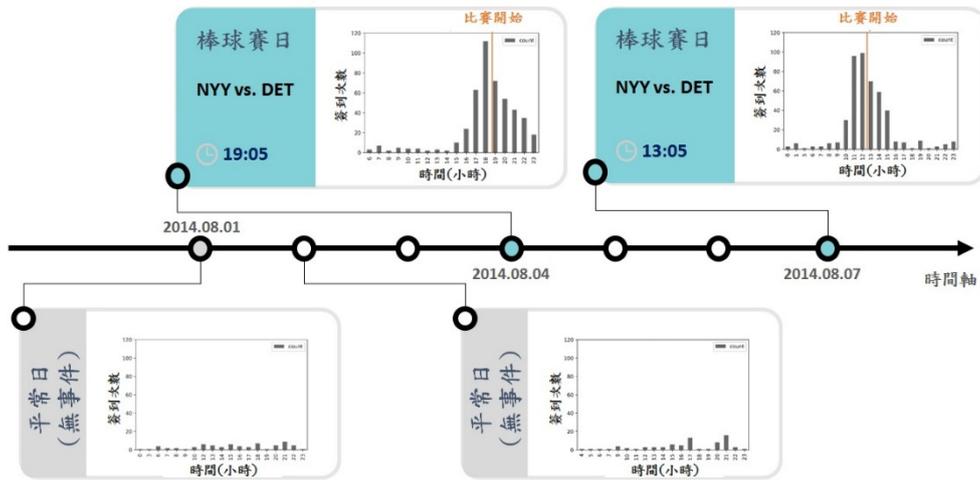
POI 推薦是推薦系統 (recommendation systems; RS) 的一個分支，許多研究透過借鑒傳統推薦系統 (例如電影推薦) 的想法來解決此任務。但是，LBSN 中 POI 推薦的情況非常特殊，他將線上網路服務與實體世界的地理位置聯繫起來，與在 Netflix 上觀看電影或在亞馬遜上購物的推薦系統不同，POI 推薦系統有兩個重要的特徵：地理影響力與時間特徵。例如，用戶白天在辦公室周圍的 POI 處簽到，而晚上則在酒吧中簽到。這些特殊的地理與時間特徵，使得 POI 推薦比傳統推薦系統更具有挑戰性。許多研究人員聚焦於研究簽到的順序，以了解用戶的偏好 (Zhang et al. 2014b; Zhao et al. 2016a)，但是這些方法忽略 POI 所包含的訊息。最近的研究工作表明，整合 POI 相關的文字訊息，可以提高 POI 推薦的效能。例如，Liu 與 Xiong (2013) 透過隱含狄利克雷分布 (latent dirichlet allocation; LDA) 來挖掘 POI 相關的文字訊息所隱含的主題，並且根據隱含的主題來推薦 POI。Wang 等 (2017b) 利用卷積神經網路 (convolutional neural networks; CNN) 來挖掘 POI 相關介紹文字訊息的潛在特徵。儘管這些工作主要聚焦於捕抓 POI 的內在訊息 (intrinsic information) 的隱含嵌入特徵 (embedding vector)，但是，這些方法忽略了兩個重要的關鍵因素，其中一個是時間因素，在給定用戶和當前時間的情況下，我們期望推薦用戶一個當前時段最適合他 / 她的 POI。另一個是事件的因素。我們假設事件會直接影響用戶去訪問某個 POI 地點的期望，即使他們不是基於對該 POI 地點的偏好，而想要訪問該 POI 地點。舉例來說，Coldplay 的粉絲也許很少會到紐約市立棒球場觀看比賽，但是，他們會因為 Coldplay 在紐約市立棒球場舉辦演唱會，而去體育場簽到 (打卡, check in)。但是，過去考慮時

間因素的 POI 推薦系統，皆未考慮即時事件的影響因素。

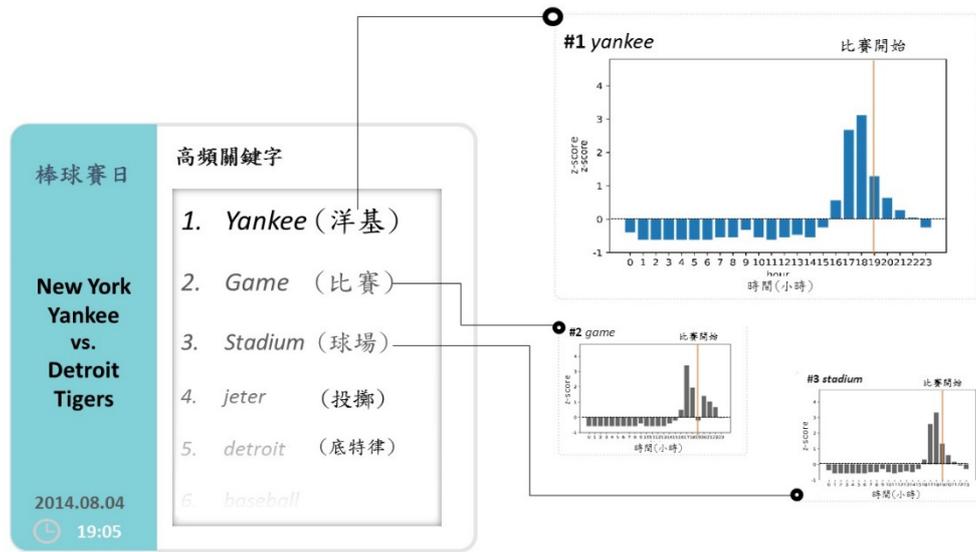
本研究的核心想法是我們假設用戶對一個 POI 地點感到興趣，並不單純只是因為該 POI 能夠吸引他 / 她的目光焦點 (eye-catching)，而是因為該 POI 地點有一個他們感興趣的事件 (event) 正在發生，為了說明事件發生的重要性，首先，我們利用數據分析來回答以下兩個問題：(1)POI 推文的分布行為是否會因為事件發生而改變？(2)當事件發生時，POI 的推文有什麼特性？為了回答這兩個問題，我們將一天分為數小時，並且按照時間的順序來分析特定 POI 及其帶有地理標記的帖子 (geo-tagged posts)，然後觀察簽到記錄 (check-ins) 與帖子內容，如圖 1 所示，我們觀察到兩個明顯的現象：(1)事件發生時，簽到的次數會明顯增加，如圖 1(a)所示，在舉行棒球比賽的日期，洋基體育場簽到的次數比沒有比賽的時間顯著增加；(2)我們發現活動當天發布的推文中，特定 (異常) 的關鍵字的出現頻率很高，如圖 1(b)所示，在洋基隊比賽的時間點，yankee (洋基)、game (比賽) 與 stadium (球場) 是在打卡記錄中出現次數最高的關鍵字，但是這些關鍵字在其他時間與地點，並沒有這麼頻繁出現。因此頻率較高的關鍵字，可以幫助我們良好地描述該事件。

顯然地，帶有地理標記的帖子 (geo-tagged posts) 能夠提供事件的即時訊息，基於上述理由，我們提出一個以事件為導向的 POI 推薦系統，它可以根據社群媒體上的文字訊息，來即時偵測事件的發生。我們使用的文字資料來源有兩個：(1)用戶在 POI 簽到記錄內的文字資訊，它可能攜帶了即時事件 (real-time event) 發生的訊息，或是 POI 的時間感知資訊 (time-aware information)；(2)用戶對於 POI 的評論，它則攜帶了 POI 內部固有的資訊，它可能是 POI 的特色，或是用戶參訪後的評價。在本研究中，我們將使用 POI 的簽到記錄與評論等文字訊息作為輔助資訊，來幫忙提升 POI 推薦的效能。由於傳統的詞袋 (bag of words) 模型，忽略了文字順序所攜帶的語義資訊，而卷積神經網路 (convolutional neural networks; CNN) 能夠更優雅的處理文字順序所攜帶的語義，因此本研究將採用 CNN 來進行文字探勘分析。不過，傳統的 CNN 適用於處理 2D 的圖像資訊，對於自然語言複雜的結構關係，無法有效予以分析處理，因此，本研究將提出一個創新的樹狀卷積網路 (tree-based CNN)，用來處理複雜的句子文法結構，更有效地擷取句子中所攜帶的語義特徵。此外，用戶在 POI 地點的拍照資料，也透露 POI 的特色，以及它吸引用戶興趣的特點，因此本研究也將採用先進的 CNN 網路來擷取 POI 的圖像特徵，並且透過深層神經網路逐層映射，來結合 POI 地點的圖像與文字特徵，以取得更高階層的圖文感知特徵，並用來改善推薦系統的效能。具體來說，本研究的 POI 推薦系統包含三個主要特徵：(1)可以在社群媒體上進行即時事件追蹤，提取 POI 的最新且高度關注的訊息；(2)可以捕獲關於 POI 的固有資訊 (intrinsic information) 和時間感知資訊 (time-aware information)；(3)可以捕獲關

於 POI 的圖像資訊 (phot information)。



(a)



(b)

圖 1：(a)洋基體育場每日簽到人數分佈範例；(b)洋基體育場棒球比賽當天發布的推文中，高頻關鍵詞的出現分佈

貳、文獻回顧

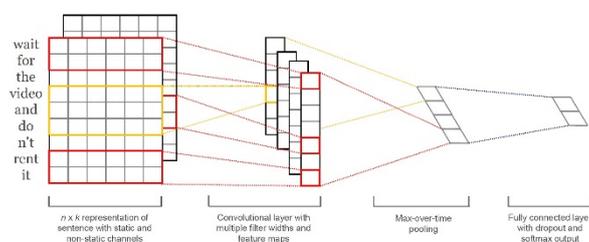
一、深度學習與詞嵌入向量

文字探勘是網路搜尋、訊息過濾與情感分析等許多應用的重要元件，傳統的文字探勘工作主要集中在三個議題：特徵工程，特徵選擇和使用不同類型的機器學習演算法。最廣泛使用的特徵是詞袋特徵 (bag of words; BOW)，以及在單詞和字符級別上的 n -gram 重疊特徵。然而，這些特徵遭受到資料稀疏的問題，例如使用詞袋模型時，在數千萬個詞彙中，一篇文章可能只使用其中的數百個詞彙而已，在社群媒體的短句子探勘問題中，稀疏問題更嚴重。最近，深度神經網路和表徵學習 (Bengio et al. 2013) 為解決資料稀疏問題提供新的方案 (Mikolov et al. 2013)。其基本思想是透過 skip-gram (從當前詞預測上下文) 或 continuous bag of words (CBOW, 從上下文來預測當前詞) 神經語言模型將每個單詞從稀疏的 1-V 編碼 (這裡 V 是詞彙量大小)，經由隱藏層投影到較低維度的向量空間上，稱為詞嵌入向量 (embedding vector)，它是一個實數值的向量，讓我們能夠透過簡單地計算兩個嵌入向量之間的歐基里德距離或餘弦距離，來測量對應字詞之間的語義相關性。詞嵌入向量極大幅度地緩解了資料稀疏的問題 (Bengio et al. 2013)。詞嵌入向量雖然提供了字詞的語義資訊，但是該如何將它們轉換成句子的語義資訊，甚至轉換成整篇文章的語義資訊，仍然是一個持續進展的研究課題，Iyyer 等 (2015) 使用詞嵌入向量與深度神經網路進行文章分類，為了將詞嵌入向量轉換成文章向量，他們使用一個簡單的做法，他們不考慮文章中字詞出現的順序性，而是將文章中出現的字詞所對應的詞嵌入向量進行算術平均，所得的向量即為文章向量。但是，根據研究統計，文章中 20% 的語義來自於字詞的順序 (例如，cats climb trees 與 trees climb cats 是截然不同的) (Wen et al. 2016)。因此，遺失字詞在文章中出現的順序資訊，使得這些簡化的模型無法勝任複雜的文字探勘任務。反之，循環神經網路 (recurrent neural network; Recurrent NN)、遞迴神經網路 (recursive neural network; Recursive NN) 與卷積神經網路 (convolutional neural network; CNN)，由於可以更優雅的處理字詞的順序性，因此更加受到研究者的青睞。在最近的研究中，Shirani-mehr 學者比較不同深度學習網路模型對電影評論進行情緒分析的結果，根據他的實驗結果顯示，CNN 的正確率比 Recursive NN 與 Recurrent NN 還要優異 (Shirani-mehr 2015)。因此，在研究將以 CNN 為基礎，建構適合處理文字探勘與文章串列的樹狀卷積網路。

二、文字探勘與卷積神經網路

卷積神經網路 (convolutional neural networks; CNN) 是目前深度神經網路

(deep neural network) 領域的發展主力，在圖片辨別上甚至可以做到比人類還精準的程度。Facebook 的 DeepFace 人臉識別技術已經達到 97.25% 正確率，幾乎可以媲美人類，靠的也是 CNN 技術 (Taigman et al. 2014)。CNN 也能處理其他型態的資料，技巧是將任何型態的資料轉換成類似圖片的格式。Kim (2014) 首先提出使用 CNN 進行句子分類任務，為了處理文字資料，CNN 使用詞嵌入向量將文章轉換成要輸入 CNN 的矩陣 (如圖 2 所示)，也就是說，矩陣中第 i 行代表文章中第 i 個單詞的詞嵌入向量，這個矩陣相當於是一幅圖像。令 $\mathbf{x}_{i:i+j}$ 表示單詞 $x_i, x_{i+1}, \dots, x_{i+j}$ 的串列，卷積運算會使用一個濾波器 $\mathbf{w} \in \mathbb{R}^{h \times k}$ ，將它應用到一個內含 h 個字的窗口中，以產生一個新的特徵。例如，特徵 c_i 是將濾波器套用到單詞窗口 $\mathbf{x}_{i:i+h-1}$ 而生成的，計算公式為 $c_i = f(\mathbf{w} \cdot \mathbf{x}_{i:i+h-1} + b)$ ，其中 b 是一個偏差項， f 是一個非線性激發函數，例如 \tanh 或 relu 。將濾波器 $\mathbf{w} \in \mathbb{R}^{h \times k}$ 應用於字詞串 $\{\mathbf{x}_{1:h}, \mathbf{x}_{2:h+1}, \dots, \mathbf{x}_{n-h+1:n}\}$ 後，將產生一個特徵圖 $\mathbf{c} = [c_1, c_2, \dots, c_{n-h+1}]$ 。接著，我們對特徵圖採用最大值池化操作，並將最大值 $\hat{\mathbf{c}} = \max\{\mathbf{c}\}$ 作為此特定濾波器所對應的特徵，這個想法是為每個特徵圖捕獲最重要的特徵。最大值池化 (pooling) 方案可以輕鬆解決輸入句子的長度可變的問題，因為不管特徵圖中有多少個值，只需要提取其中的最大值。最終池化層的輸出為各個特徵圖的最大值組成的一維向量，向量長度等於濾波器的數量。Kim 的 CNN 模型可以使用多個濾波器 (可以有不同大小的窗口) 來獲取多個特徵。這些特徵匯集到 CNN 的倒數第二層，並傳遞到完全連接的 softmax 層，其輸出是分類類別上的機率分佈。Hu 等 (2014) 使用 CNN 網路解決句子匹配 (sentence matching) 問題，其目的是要判斷兩個句子是否在語義上是相同的，即便兩個句子中出現的字詞是不一樣的，句子匹配可應用於轉述偵測 (paraphrase detection)、抄襲偵測與文章摘要等應用。Nguyen 與 Grishman (2015) 則是提出使用 CNN 於關係擷取的任務中，其目的是要判別同一個句子中的兩個命名實體是否有特定的關係，由於傳統的實體關係提取需要複雜的特徵如位置、附近詞和詞性等，其為了避開傳統方法中複雜的特徵工程，因此提出使用 CNN 自動從句子中學習特徵。



圖片來源：Kim (2014)

圖 2：Kim 提出的針對句子分類的 CNN 網路模型結構

儘管上述研究獲得了成功，但是從語言學的角度來看，CNN 存在一個主要的局限性：針對圖像辨識而發明的 CNN，只考慮句子在表面上的連續字串（ n -gram），而忽略長距離依賴性，但是，後者在許多語義表達中起著重要的作用，例如否定、從屬和抽離等，都可能影響句子的情感、主觀性或其他分類。卷積運算很適合找出局部特徵，以圖像辨識的任務來說，出現在相鄰位置的應該是有關聯的，然而，在自然語言中並不是如此，相關的短語可能被很多其他詞彙所隔離。圖 3 顯示一個範例，這句對電影的評論明顯是正面的情緒，但是 CNN 卻很難正確判定其正面情緒，因為有很多視窗會包含“shortcoming”這個強烈負面的字眼，而“shortcoming”與“despite”之間的距離又非常遙遠。因此無法透過濾波器很恰當找出局部的特徵，雖然我們可以透過增加濾波器的寬度來找到遠距的關聯，但是這樣會增加問題的複雜度，而且更關鍵的問題是，兩個相關短語之間所間隔的字詞數目可以是任意的。因此我們不可能找到恰當的濾波器作為特徵擷取器，為了克服這個問題，本研究將導入句法相依樹的資訊，以圖 3 為例，導入句法相依樹上的相依路徑後，可以輕鬆捕抓到“despite-shortcoming”這個語義，進而將情緒反轉，而且根據相依路徑上的局部子路徑“moving-stories”是相當正面的。

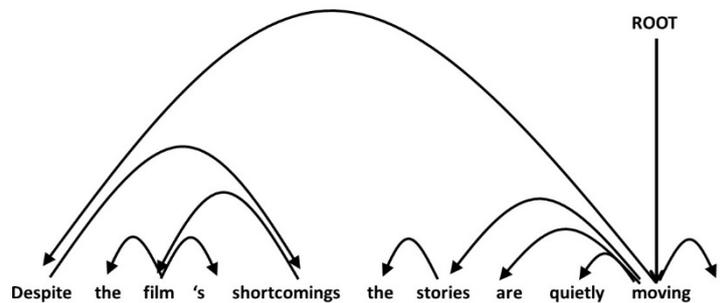


圖 3：依賴樹（dependency tree）的範例

三、興趣點推薦系統

近年來，社群網路在全世界廣泛發展，根據 Statista¹上顯示的統計數據，越來越多的人傾向於社群媒體上與朋友和家人分享日常生活。幾個著名的基於位置的社群網路（location-based social networks; LBSN），例如 Facebook 和 Twitter，都提供了地理標記（簽到，亦即打卡 check-in）服務，用戶可以透過打卡來分享他/她正在進行的活動與位置。對於快速成長的 LBSN 社群網路，興趣點（point-of-interest; POI）推薦已經成為一個熱門的研究問題，它可以透過從大量的簽到行為

¹ <https://www.statista.com/statistics/278414/number-of-worldwide-social-network-users/>

中挖掘用戶的偏好，用來幫助用戶發現有趣的位置。由於物理的限制和異質類訊息混雜（例如，POI 位置的地理訊息與用戶評論的文字訊息），導致 POI 推薦系統特殊的時空屬性（spatial and temporal properties）。圖 4 顯示 POI 推薦的四個關鍵因素：時間動態、地理影響、社群關係和內容指示。

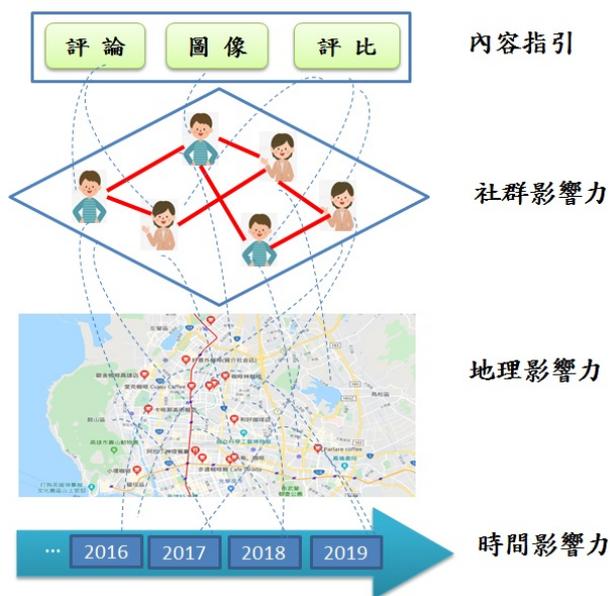


圖 4：影響 LNSNs 的因素

（一）地理影響力（geographical influence）

地理影響力（geographical influence）是 POI 推薦系統不同於傳統商品推薦系統的關鍵因素，在針對用戶的簽到活動進行分析後，顯示用戶是在有地理限制的地區上行動，並且，更喜歡訪問用戶簽到點附近的其他 POI。地理限制的特徵可以縮小 POI 推薦的候選集，並且減輕數據稀疏性的影響。過去許多研究試圖利用地理影響力來改善 POI 推薦系統。其中三種具有代表性的機率模型係採用冪律分佈模型、高斯分佈模型（Cho et al. 2011）和核密度估計模型（Zhang & Chow 2013），來捕獲 POI 推薦中的地理影響因素。另外，有鑑於用戶訪問的 POI 總是散佈在有限制的區域空間，而且通常是在本地區域內流行的 POI，因此，Liu 等（2019）提出區域協同排名（local collaborative ranking; LCR）演算法，這可以減輕簽到數據稀疏性的問題。此外，由於傳統方法通常直接使用歐幾里德距離，而不考慮交通因素。因此，Yan、Zhao 與 Guo（2018）提出了一個個性化的 POI 推薦系統，以餐廳推薦為例，該系統整合了用戶個人資料、餐廳特徵、用戶的歷史行為特徵與地鐵網路特徵。具體來說，它提取地鐵網路的特徵（例如，通過站的

數量，等待時間和轉移時間），並使用循環神經網路（RNN）模型來對用戶行為建模。

（二）時間影響力（temporal Influence）

時間影響力對於 POI 推薦是至關重要的，因為對簽到活動的物理限制，導致三種特定的模式：週期性、連續性和非均勻性。LBSN 中用戶的簽到行為，經常表現出週期性的模式（periodic pattern）。例如，用戶總是在中午去餐館，晚上在夜總會裡玩樂。此外，用戶會在工作日訪問辦公室周圍的地方，並且，在周末到購物中心購物。這現象激發了利用周期性模式進行 POI 推薦的研究。用戶的簽到序列（check-in sequences）中經常也會呈現連續性（consecutiveness）的樣式，尤其是循序的簽到模式。循序簽到（successive check-ins）的 POI 地點通常是彼此相關的。例如，用戶在餐館用餐後可能會在夜總會玩。這種頻繁的循序簽到模式，可能意味著夜總會與餐廳在地理位置上是相鄰的，並且從場所功能面的角度來看是相關的。Zhao 等（2016a）對 Foursquare 和 Gowalla 的簽到數據進行分析，觀察到許多連續簽到是高度相關的：在 Foursquare 和 Gowalla 中，有超過 60% 的連續簽到行為發生在 4 個小時之內；超過 90% 的連續簽到行為發生在不到 32 公里（半小時的行駛距離）內。Zhang、Kong 與 Yu（2014）提出了一個可加式馬爾可夫模型（additive Markov model）來學習兩個連續簽到之間的傳遞機率。Zhao 等（2016b）提出時空潛在排名模型，它藉由 POI-POI 潛在交互作用來捕獲循序模式。

（三）社群影響力（social influence）

LBSN 的朋友們通常會擁有許多共同的興趣，而非朋友關係的用戶，則較少擁有共同興趣，根據這個假設的啟發，探索利用社群影響力來增強 POI 推薦系統效能的研究工作油然而生。實際上，傳統的推薦系統已經廣泛探索如何利用社群影響因素來增強推薦效能。基於社群朋友為基礎的協同過濾（friend-based collaborative filtering; FCF）方法來進行 POI 推薦，其基本概念是要從朋友群中找到相似用戶，而不是從 LBSN 中的所有用戶，如此便可以減少尋找相似用戶的計算成本，並且提高效率。但是，它忽略那些與目標用戶雖然不是朋友關係，但是卻擁有許多相同簽到記錄的相似用戶的影響力。此外，傳統的 POI 推薦系統僅根據用戶之間的相似性、受歡迎程度或地理影響提出建議，並未考慮個人之間的社會信任（social trust）。Zhu 等（2019）首先提出識別信任群集（trust clusters）的演算法，然後整合用戶偏好、地理影響力和信任關係，以提高 POI 推薦的質量。另外，協同推薦方法的核心是尋找志趣相投的人（即，所謂的鄰居）的意見來進行預測。因此，選擇適當的鄰居對於獲得良好的預測結果，扮演關鍵重要的腳色，Rios、Schiaffino 與 Godoy（2018）便是根據社群媒體的朋友關係與地理因

素，提出不同的策略來挑選適當的鄰居。儘管社群影響力能夠顯著改善傳統的推薦系統的效能，但是，對於 POI 推薦的應用中，社群影響力能帶來的改進卻是有限的 (Gao et al. 2015)。其原因可以解釋如下：LBSN 用戶的朋友可以不受地理因素限制，他可以擁有許多不同城市甚至不同國家的線上朋友；相反的，簽到活動則需要考慮用戶與 POI 位置的地理因素限制。因此，LBSN 中的朋友可能擁有共同的興趣，但可能不會訪問共同的位置。例如，來自不同城市的喜歡義大利美食的朋友，將訪問他們自己居住區域的義大利美食餐廳，這種現象不同於 Netflix 和 Spotify 中的線上電影和音樂推薦方案。

(四) 內容指引 (content indications)

在 LBSN 中，用戶創建的內容包括 POI 相關的評論與照片，儘管並不是每個簽到記錄都伴隨著用戶創建的內容，但是，可用的內容 (例如用戶評論和照片) 仍然可用於增強 POI 推薦的效能 (Wang et al. 2017a)。一方面，用戶評論提供許多額外訊息，這些訊息是簽到行為無法提供的。例如，在義大利餐廳的簽到記錄，並不一定意味著用戶喜歡這家餐廳。用戶可能只是喜歡義大利菜，而不喜歡這家餐廳，甚至不喜歡這家餐廳的味道，或只是單純的打卡送小菜的促銷活動。與簽到記錄相比，用戶評論 (tips 與 comment) 則提供顯式的偏好訊息，這是簽到記錄的補充內容。並且可用於深入了解用戶的簽到行為，以改善 POI 推薦效能。Yang 等 (2013) 提出了一種情感增強的 POI 位置推薦方法，他是第一個利用註釋來增強 POI 推薦的代表性研究工作，該方法利用用戶評論來調整簽到的偏好估計。他使用 SentiWordNet 自然語言處理技術收集並分析了 LBSN 中的原始提示 (tips)，將其轉換為多個名詞短語。然後，給每個評論指派一個情感分數，例如，對「合理的價格」、「好地方」和「漫長的等待時間」生成情緒分數，並根據估計的情緒，生成 POI 位置的用戶的偏好得分。另一方面，POI 相關的照片也會顯示用戶的簽到偏好。例如，發布許多建築照片的用戶，更有可能去訪問著名的地標。相同地，當用戶發布許多有關食物的圖像時，他應該就有更多的動機去逛餐廳。因此，圖像具有改善 POI 推薦效能的潛力。Wang 等 (2017a) 是利用照片內容來增強 POI 推薦的第一個代表性研究工作，給定用戶-POI 簽到矩陣、用戶圖像與 POI 圖像，他提出視覺特徵增強 POI 推薦框架 (visual content enhanced POI recommendation; VPOI)，來利用視覺內容改善 POI 推薦的效能。Zhang 等 (2019) 亦探索運用地理影響力與圖像內容，來改善 POI 推薦的效能。

底下概述本研究相較於現有文獻的獨特性與貢獻，相較於傳統的詞嵌入模型 (Bengio et al. 2013; Mikolov et al. 2013) 僅考慮詞彙之間的語意相似度，本研究所提出的多模式嵌入模型 (multimodal embedding) 透過將 POI 地點、關鍵字與時間單位統一地映射至嵌入空間，使得它們在嵌入空間之間的距離，可以代表它們

之間的相似度。透過多模式嵌入模型，我們可以計算不同類型的物件（例如 POI 地點、關鍵字與時間單位）之間的相似度，讓本研究在透過詞彙分析進行 POI 推薦時，詞彙中所攜帶的時空資訊，更能夠滿足 POI 推薦中的特殊時空限制。其次，相較於傳統的 CNN 模型 (Kim 2014; Nguyen & Grishman 2015) 只考慮句子在表面上的連續字串 (n -gram)，而忽略長距離依賴性，本研究提出的樹狀卷積神經網路將導入句法相依樹的資訊，由於句法剖析樹的相依路徑上的局部子路徑，能夠更有效率的表現句子中的遠距相依性（如圖 3 所示），所以本研究提出的樹狀卷積神經網路可以更有效率的捕抓句子中的遠距相依性。最後，相較於傳統 POI 推薦系統僅考慮時空限制、社群影響與內容指引 (Yan et al. 2018; Liu et al. 2019)，本研究的獨特貢獻則是率先導入即時事件於 POI 推薦系統，有鑑於用戶會因為參加 Coldplay 的演唱會事件，而去紐約市立棒球場簽到，而不是因為用戶喜歡棒球場這個 POI 地點，所以在 POI 推薦時考量即時事件可以提升推薦效能。

參、研究方法

本研究主要目的是開發一個即時的 POI 推薦系統，此推薦系統不僅考慮 POI 的固有訊息 (intrinsic information)，例如，其他用戶對於此 POI 的文字介紹與拍照圖像，還考慮 POI 的即時訊息 (real time information)，例如，正在此 POI 上進行的活動。本系統從社群媒體上大量的具地理標籤貼文 (geo-tagged post) 中捕抓 POI 的即時事件訊息 (real-time event) 與時間感知資訊 (time-aware information)，並且透過學習 POI 的嵌入特徵來融合這些訊息，這些訊息可做為附加資訊 (auxiliary information) 來改善以矩陣分解為基礎的協同過濾式推薦系統。我們的系統架構如圖 5 所示。

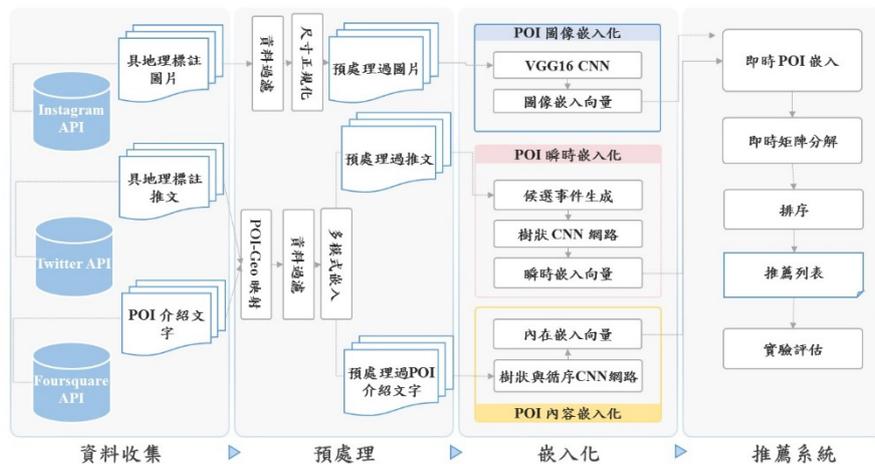


圖 5：系統架構圖

一、資料收集

本研究採用 Zhang 等 (2016) 中的 NY 資料集，NY 資料集由 2014.08.01-2014.10.31 期間紐約市 (New York City; NYC) 帶有地理標籤的推文 (geo-tagged tweets) 所組成。接著，我們使用 Foursquare API²來收集有關紐約市所有 POI 的文字評論和描述 (Foursquare 是最受歡迎的 LBSN 之一)，以獲取豐富的 POI 內在固有文字描述資訊。另外，為了取得豐富的 POI 圖像資訊，我們使用 (Wang et al. 2017a) 所收集的資料集，它包含 2015 年 10 月至 2016 年 2 月期間，使用 Instagram API 從社群媒體網站 Instagram 收集在紐約市的簽到圖像記錄。Instagram 允許用戶在實際位置進行簽到後發布圖像，並通過他 / 她的手機將圖像與地理標籤相關聯。

二、資料預處理

對於每個帶有地理標籤的推文 (geo-tagged tweet)，我們都可以獲取有關作者 (用戶)、文字內容、發佈時間和座標等訊息。但是，簽到記錄 (check-in record) 是隱式的，因為帶有地理標籤的推文 (geo-tagged tweet) 僅包含地理座標資訊，而不是直接提供 POI 的名稱 (如圖 6 所示)。在這種情況下，我們將帶有地理標籤的推文 (geo-tagged tweet) 的簽到記錄，映射到 500 米內最近的 Foursquare POI，並且認為用戶已經訪問了該 POI，以建構明確的 POI 簽到記錄。我們過濾掉沒有映射到 POI 的地理標記推文 (geo-tagged tweet)，並且按照 (Zhang et al. 2016) 的建議，將訪問者人數少於 5 個的 POI 予以過濾，此外，簽到記錄少於 10 個的用戶也予以過濾。此外，我們也過濾掉沒有文字評論或描述的 POI，預處理後的數據集統計訊息顯示在表 1。對於 POI 的圖像內容部分，(Wang et al. 2017a) 收集用戶在 POI 簽到地點發布的相關圖像，並且刪除帶有“selfie (自拍)”標籤的圖像，因為大多數帶有“selfie”標籤的圖像中，身體 / 臉部幾乎佔據了整個圖像空間，所以它們沒有包含足夠的訊息來描述 POI 的特徵，刪除這些圖像可以減少雜訊並且提高性能。另外，我們再自行手動刪除沒有標記為“selfie”但實際是自拍的照片，同時，沒有對應到本研究整理後的 POI 地點的照片也予以刪除，整理後的結果顯示在表 1。

² <https://developer.foursquare.com/places-api>

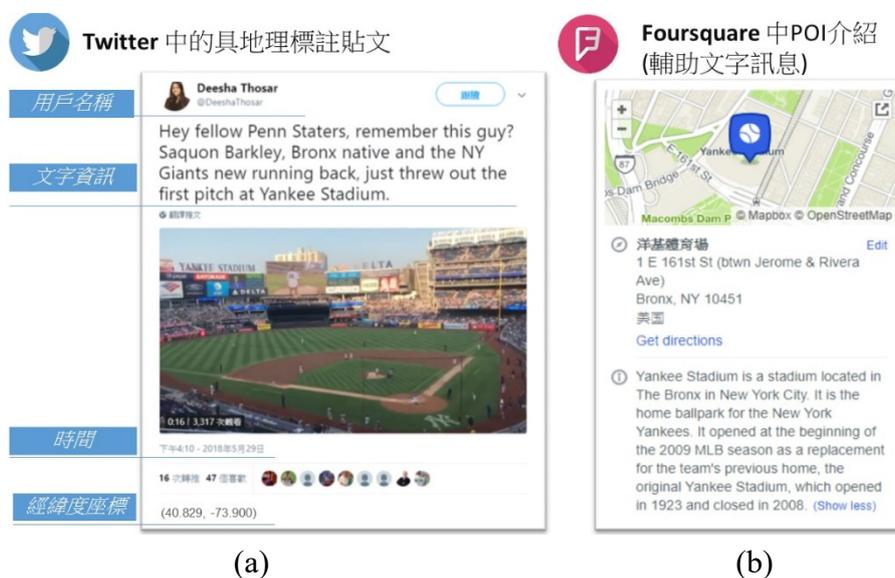


圖 6：(a)帶有地理標籤的推文 (geo-tagged tweets)；(b)Foursquare 中 POI 描述的範例

表 1：資料過濾

	Twitter				Foursquare	Instagram
	用戶數目	check-ins 數目	平均 check-ins 次數 ³	稀疏率	POIs 數目	圖像數目
原始	94,514	1,180,159	12.36	99.76%	5,279	464,358
處理過	12,685	506,750	39.95	98.67%	2,994	232,415

三、事件與 POI 嵌入特徵學習

如前所述，本研究假設用戶會因為想要加入他們感興趣的事件，而前往特定的 POI 簽到。亦即是說，事件的發生也是影響用戶決策的因素。本系統從社群媒體上大量的具地理標籤貼文 (geo-tagged post) 中捕抓 POI 的即時事件訊息 (real-time event) 與時間感知資訊 (time-aware information)，並且透過學習 POI 的嵌入特徵來融合這些訊息，這些訊息可做為附加資訊 (auxiliary information) 來改善以矩陣分解為基礎的協同過濾式推薦系統。為了學習表示 POI 的嵌入特徵向量，首先，我們構建關鍵字、位置與時間的多模式嵌入學習 (multimodal embedding)，該嵌入模型將關鍵字、位置和時間映射到相同的嵌入特徵空間，使得嵌入特徵能夠描述關鍵字、位置與時間之間的語義關係。接著，我們使用多模式嵌入學習所學習得到的詞嵌入向量 (word embedding) 與本研究開發的嶄新的

³ 對每一個用戶的簽到 (check-ins) 次數的平均值

樹狀卷積網路 (tree-based CNN) 網路，來挖掘 POI 的地理標記帖子 (geo-tagged posts) 與評論的文字資料，以追蹤是否有事件發生，並且捕捉 POI 的固有內在資訊 (intrinsic information)、時間感知資訊 (time-aware information) 與圖像資訊 (visual information)，在本章中，我們將詳細描述如何得到事件和 POI 的嵌入向量，本研究所提出的興趣點嵌入向量 (POI embedding) 包含：

- POI 瞬時嵌入向量：融入興趣點發生的即時事件與時間感知的訊息。
- POI 內在固有嵌入向量：融入興趣點相關介紹的文字訊息。
- POI 圖像嵌入向量：融入興趣點所拍照片的圖像訊息。

(一) 多模式嵌入 (multimodal embedding)

當事件發生時，他通常會在事件發生的期間內，由事件發生地點的 POI 周圍的相關推文 (tweet) 反映出來。不同類型的活動具有不同的活動時間。例如，人們會更喜歡在陽光下遠足，而不是在月光下遠足。相反地，人們喜愛在夜間到第五大街等處購物。因此，受到 *TrioVecEvent* (Zhang et al. 2017) 的啟發，本研究設計一種多模式嵌入模型 (multimodal embedding)，我們使用在特定 POI 地點中出現的數百萬個帶有地理標籤的推文來訓練嵌入模型，並將所有關鍵字、POI 地點和時間單位都嵌入到一個相同的潛在空間。給定一個具地理標籤的推文 d ，表示為 $\langle t_d, l_d, c_d \rangle$ ，其中 t_d 是推文發佈的時間單位， l_d 是其推文簽到 (check-in) 的地理資訊，而 c_d 是推文的文字內容。對於時間單位 t_d ，許多研究人員在分析每週不同時段的 POI 簽到 (check-in) 模式後，發現在週末 (星期六和星期日) 具有類似的簽到模式，而在工作日 (星期一至星期五) 則具有另一種簽到模式 (Zhao et al. 2016a)。

因此，在本研究中，我們將一天劃分為 24 小時，將一週劃分為工作日和週末，總共有 48 個時間單位，用來為時間特徵建模。對於 POI 地理位置資訊 l_d ，我們使用唯一識別符的位置 ID 來標記每個 POI。我們使用類似於連續詞袋 (continuous bag-of-words; CBOW) 嵌入模型 (Mikolov et al. 2013) 的概念，來建立我們的多模式嵌入模型。*CBOW* 是一種先進的詞嵌入 (word embedding) 表徵模型，該模型在給定上下文的情況下，來預測當前文字。在我們的多模式嵌入演算法中，我們將一條推文 d 當作語料庫中的句子。對於同一個推文中的每個單元，我們使用它的上下文 (即除了預測的單元之外，其他的每個單元)，來預測該單元，該模型目標是最大化每個觀測單元 j 的可能性，定義為

$$\mathcal{L} = -\sum_{j \in C} \log P(j|d_{-j}) \quad (1)$$

其中 d_{-j} 表示在推文 d 中所有的其他單元 (除了預測單元 j 之外)，而 C 表示在所有推文中的所有單元。透過我們的多模式嵌入模型，對於時間、位置 ID 與關鍵字這

三種不同類型的資料，我們的多模式嵌入學習將把它們映射到相同的 e 維潛在空間，使得它們在 e 維潛在空間中的距離，可以表示它們（時間、位置 ID 與關鍵字）的語義相似度（如圖 7 左邊的子圖所示）。

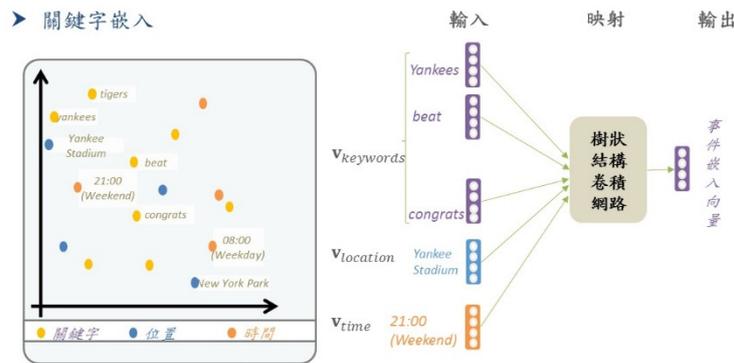


圖 7：多模式嵌入的範例

(二) 事件候選者建立 (candidate event generation)

在獲得每個關鍵詞的嵌入向量之後，我們希望透過文字訊息找到群眾高度關注的熱點話題或是異常話題（事件）。為了達到此目的，我們對於每條推文，都測量它的時間突發性（temporal burst），時間突發性分數描述該推文內容與其它推文內容（在其他時間段內）相比的異常情況。首先，我們計算每個關鍵字在不同時間區間內出現的 z 分數（ z -score）分佈， z 分數是常見的統計分析技巧，它可以測量觀察點的值與所有測量數據的平均值之間的差異。在本研究中，我們使用 z 分數來衡量關鍵字 k 的異常程度，它的定義如下：

$$z\text{-score}_{k,\Gamma,i} = \frac{x_{k,\Gamma,i} - \mu_k}{\sigma_k}. \quad (2)$$

其中， $x_{k,\Gamma,i}$ 表示關鍵字 k 在當前時間戳記 Γ 下出現在 POI i 的簽到紀錄的次數， μ_k 代表關鍵字 k 的出現次數的平均值，而 σ_k 代表關鍵字 k 出現次數的標準差。接著，推文 d 在給定時間戳記 Γ 和興趣點 POI i 的時間突發性（temporal burst）分數定義如下：

$$\text{Temporal Burst}_{d,\Gamma,i} = \frac{\sum_{k \in d} z\text{-score}_{k,\Gamma,i}}{|k|} \quad (3)$$

其中 $|k|$ 表示出現在推文 d 中的關鍵字數目。我們透過兩種標準來判斷一條推文是否為候選事件，其中一個是透過測量推文 d 的時間突發性是否大於給定閾值 δ ；另

一個是透過量測在給定時段下，用戶在該 POI 發文數量與該 POI 在其它所有時段內的發文數量相比，其 z 分數分佈是否大於給定閾值 τ 。如果同時滿足以上條件，則我們將該推文定義為候選事件。

(三) 事件向量與 POI 瞬時嵌入向量 (event vector and POI instant embedding)

POI 瞬時嵌入向量 (POI instant embedding) 試圖捕抓到在當前時刻的 POI 事件資訊或時間感知資訊，以便能夠在適當的時間點，推薦適當的 POI 給使用者。一個 POI 可以分成兩種情況：事件或非事件，我們將分別處理這兩種情況。針對候選事件推文 (事件發生情況)，我們產生事件嵌入向量，而針對非候選事件推文 (無事件發生情況)，我們則產生 POI 時間感知嵌入向量。給定一個 POI，假設我們偵測到一個事件發生在特定時間區段，則我們將對該事件建立其嵌入向量，事件嵌入 (event embedding) 向量是一個潛在特徵，他可以顯示該 POI 的當前事件的相關情況。更清楚地說，我們將為每個 POI 生成一個低維向量，而且該向量將在不同時間段內不斷更新，以清楚描述該 POI 位置當前的即時討論內容。在 POI i 與時間戳記 Γ 下的事件嵌入向量 $event_{\Gamma,i}$ 定義為：

$$event_{\Gamma,i} = \frac{\sum_{d \in D_{\Gamma,i}} tweet_d^{\text{event}}}{|D_{\Gamma,i}|} \quad (4)$$

其中 $D_{\Gamma,i}$ 代表在 POI i 與時間戳記 Γ 中所有的候選事件的推文集合，也就是說，我們對所有在 POI i 與時間戳記 Γ 中的候選事件推文的嵌入向量 $tweet_d^{\text{event}}$ 計算平均值，即可得到事件向量 $event_{\Gamma,i}$ 。至於如何建立候選事件推文的嵌入向量 $tweet_d^{\text{event}}$ ，最簡單的方法是將推文中所出現的全部關鍵字的嵌入向量進行加總並計算平均向量，所得到的平均向量即可視為該推文所對應的嵌入向量 (Hao et al. 2019)，然而，這種簡單的作法忽略了推文內關鍵字順序所攜帶的語義資訊，也忽略了推文內句法結構所攜帶的語義資訊，本研究將研發嶄新的樹狀卷積網路來得到候選事件推文的嵌入向量 $tweet_d^{\text{event}}$ ，在下一小節，我們詳細介紹樹狀卷積網路提取句法特徵的運算過程。

如果沒有候選事件發生，亦即，在非事件情況，我們將生成一個正常狀況的嵌入向量 $normal_{\Gamma,i}$ ，該向量是透過在 POI i 上對具有相同時間戳記 Γ 的所有非候選事件推文的嵌入向量進行平均運算，來計算其潛在特徵，其計算方式如下所示：

$$normal_{\Gamma,i} = normal_{t,i} = \frac{\sum_{d \in D_{t,i}} tweet_d^{\text{non-event}}}{|D_{t,i}|} \quad (5)$$

其中 $D_{t,i}$ 表示在 POI i 與時間時間戳記 Γ 中所有非候選事件推文的集合，而非候選

事件推文的嵌入向量 $tweet_d^{\text{non-event}}$ 亦是透過下一小節所介紹的樹狀卷積網路來得到，我們的 POI 瞬時嵌入向量 (POI Instant Embedding) q_i^{instant} 定義如下：

$$q_i^{\text{instant}} = \begin{cases} event_{\Gamma,i}, & \text{if } \exists d \in tweets_{\Gamma,i}, \text{ Temporal Burstiness}_{d,\Gamma,i} \geq \delta \\ normal_{\Gamma,i}, & \text{otherwise} \end{cases} \quad (6)$$

注意，POI 瞬時嵌入向量考慮時間的因素，它是由具有相同時間戳記 Γ 的推文來產生，不論是否有事件發生， q_i^{instant} 都呈現 POI i 在該時間戳記 Γ 下的推文內容，以捕抓時間感知的相關訊息。

(四) 樹狀卷積網路

自然語言句子具有複雜的結構，既為循序的符號串列，也為樹狀階層結構，了解句子的結構對理解這些句子是至關重要的。因此，一個成功的文字探勘系統不僅需要捕捉句子的內部結構，還需要捕捉它們相互作用中的豐富模式。因此，本研究提出使用嶄新的樹狀卷積網路來取得候選事件推文的嵌入向量 $tweet_d^{\text{event}}$ 與非候選事件推文的嵌入向量 $tweet_d^{\text{non-event}}$ ，樹狀卷積的概念是使用一組子樹結構特徵偵測器，沿著整個句法剖析樹上滑動來提取特徵，接著透過池化動作來匯集這些特徵，以提取最重要的特徵。如圖 8 所示，假設候選事件推文有 t 個關鍵字 x_1, \dots, x_t ，其中 x_i 是透過多模式嵌入函數來將關鍵字單元 i 映射到 e -維的潛在向量，首先，我們將輸入推文句子交給句法剖析器去分析，即可得到該推文句子的句法相依樹 (dependency tree)，相依樹中有 t 個節點 x_1, \dots, x_t ，每一個節點對應一個關鍵字。然後，我們設定一個具有固定深度的子樹特徵偵測器，稱為「樹狀卷積濾波器」。

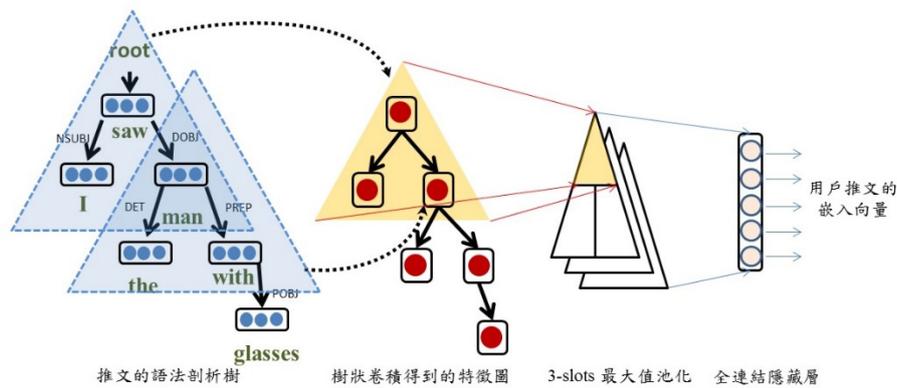


圖 8：樹狀卷積網路來取得候選事件推文的嵌入向量

圖 8 最左邊的虛線三角形即是「樹狀卷積濾波器」掃描的樹狀窗口，該樹狀

掃描窗口沿著句法相依樹滑動來造訪全部的節點，以提取句子的結構特徵，卷積運算是將每個節點對應的詞嵌入向量與跟節點位置對應的「樹狀卷積濾波器」權重進行內積運算，然後再加上一個偏移量。然而，由於句法相依樹中每個節點的分歧數目（子節點數目）不是固定的，因此，使用樹狀窗口的位置來指派節點所對應的權重向量是有困難的，克服方法是根據子節點的相依類型來指派對應的權重向量，我們認為這個策略是有意義的，因為相依類型反應了控制詞（父節點） p 與他的子節點之間的關係，因此，我們的樹狀卷積公式為

$$y_i = f(W_p \cdot v(p) + \sum_{i=1} W_{r[c_i]} \cdot v(c_i) + b) \quad (7)$$

其中 W_p 是父節點 p （控制詞）的權重向量； $W_{r[c_i]}$ 是子節點 c_i 的權重向量，子節點 c_i 與其父節點 p 的語法關係為 $r[c_i]$ ， $v(p)$ 是父節點 p 的單詞（控制詞）對應的詞嵌入向量， $v(c_i)$ 是子節點 c_i 的單詞對應的詞嵌入向量。在本研究中，我們將保留 15 種最常見的依賴類型；在語料庫中很少出現的其他依賴類型，則使用一個共享權重矩陣。 f 是一個非線性激發函數，例如線性整流單元（ReLU）或 S 形函數。將濾波器套用到句法剖析樹中的每個單詞，則可得到特徵圖 $\mathbf{y} \in \mathbb{R}^t$ ：

$$\mathbf{y} = [y_1, y_2, \dots, y_t] \quad (8)$$

其中 t 是句子的長度。如果控制詞 p 沒有子節點，則填入零元素（垂直填零），由於卷積操作是針對句法樹上每一個節點計算，所以最後得到的特徵圖是與原句法樹一模一樣的樹狀結構。接著，我們執行池化操作來匯集最重要的特徵，並且去掉大量不重要的參數，以得到更好的學習效果，由於（Kim 2014）提出的最大值池化會遺失重要特徵的位置資訊，為了保留重要特徵在句法樹出現的位置資訊，我們提出 3-slot 樹狀池化策略，根據樹根節點的位置將句法樹分成 top、lower-left、lower-right 三個區域，並提取每個區域的最大值，最終得到的結果為

$$L = [\hat{y}_1^{top}, \hat{y}_1^{lower-left}, \hat{y}_1^{lower-right}, \dots, \hat{y}_M^{top}, \hat{y}_M^{lower-left}, \hat{y}_M^{lower-right}] \quad (9)$$

其中 M 是濾波器的數目。如同圖像辨識的任務，我們可以使用多個樹狀濾波器，每個濾波器提取特定的子樹結構特徵，濾波器的數目等於池化後通道的數目。池化動作也可以克服句子長度不一樣的問題，卷積後的向量長度是由濾波器數目來決定，與句子長度無關。接著，我們將池化後的結果餵入到一個全連結的隱藏層，透過神經元的激活來對句子進行編碼，輸出結果即為該句子的嵌入向量，

$$tweet_d = f(W_{tweet} \times L + b_{tweet}), \quad (10)$$

其中 W_{tweet} 是全連結隱藏層的權重矩陣， b_{tweet} 是其偏移量向量， f 是激發函數，最終所得到的推文句子嵌入向量 $tweet_d$ 的維度等於隱藏層節點的數目。

(五) POI 內在固有嵌入向量 (POI intrinsic embedding)

POI 內在固有嵌入向量試圖捕抓興趣點相關的文字介紹訊息，並且生成一個低維向量來表示 POI 的內在固有特徵。其背後的想法是，當用戶決定去訪問 POI 時，通常會在線上進行研究，並且參考他人的意見或評論。受到 (Kim et al. 2016; Wang et al. 2017b) 的啟發，我們設計一種基於 CNN 的 POI 內在固有嵌入模型，並考慮 POI 的描述和其他評論。POI 內在固有嵌入特徵的優點在於，它可以學習 POI 之間的語義關係，從而幫助協同過濾推薦系統 (collaborative-filtering based recommender) 找到用戶的偏好 (users' preference)。為了對 POI 建立內在固有嵌入模型，我們將所有關於此 POI 的評論按照時間順序合併到一個文檔中，並且過濾掉無價值的評論 (其「被噓」的不良響應的數量高於其「按讚」的良好響應的數量)，以保留有價值的評論。文章同時具有循序與階層結構，我們認為句子中的字詞是以階層結構組成，而文章中的句子則是以循序結構組成。為了同時處理文章中的階層與循序結構，首先，我們將有關於此 POI 所有評論的文檔中每一個句子，餵入上一節介紹的樹狀卷積網路，得到該句子的嵌入向量，令 $t_i \in R^n$ 為文章中第 i 個句子所對應的 n 維句子嵌入向量，接著，我們將此 POI 評論文檔中每一個句子的嵌入向量串接在一起 (按照發布時間順序)，得到一個文章矩陣 $\mathbf{d} \in R^{n \times L}$ ，其中 n 是句子嵌入向量的長度，而 L 是文章中句子的數目。接著，我們將文章矩陣餵給一個循序卷積網路，來學習文章的嵌入向量，如圖 9 所示。令 $t_{i:i+j}$ 表示連續句子 $t_i, t_{i+1}, \dots, t_{i+j}$ 所組成的串列，編號 m 的濾波器的權重向量 $\mathbf{w}_m \in R^{h \times n}$ 應用到文章中內含 h 個句子的窗口進行卷積運算，以產生一個新的特徵。例如，特徵 $c_{i,m}$ 是將濾波器套用到窗口 $t_{i:i+h-1}$ 而生成的，計算公式為

$$c_{i,m} = f(\mathbf{w}_m \cdot t_{i:i+h-1} + b_m) \quad (11)$$

其中， b_m 是第 m 個濾波器對應的偏差項， f 是一個非線性函數激發函數，例如 \tanh 或 relu 。濾波器的寬度和輸入矩陣的寬度 (n 維句子向量) 相等。將濾波器 $\mathbf{w}_m \in R^{h \times n}$ 應用於句子串 $\{t_{1:h}, t_{2:h+1}, \dots, t_{L-h+1:L}\}$ 後，將產生一個特徵圖

$$\mathbf{c}_m = [c_{1,m}, c_{2,m}, \dots, c_{L-h+1,m}] \quad (12)$$

其中 $\mathbf{c}_m \in R^{L-h+1}$ ，接著，我們採用最大值池化 (max pooling)，來為每個特徵圖捕獲最重要的特徵，即

$$\hat{c}_m = \max\{c_{1,m}, c_{2,m}, \dots, c_{L-h+1,m}\} \tag{13}$$

最大池化後的結果為

$$C = [\hat{c}_1, \dots, \hat{c}_M] \tag{14}$$

其中 M 是濾波器的數目。如同在圖像辨識任務，我們可以使用多個濾波器提取特定特徵。池化動作也可以克服文章長度不一樣的問題，卷積後的向量長度是由濾波器數目來決定，與文章長度無關。接著，我們將池化後的結果 C 餵入到一個全連結的隱藏層，透過神經元的激活來對 POI 介紹文章進行編碼，輸出的結果即為該 POI 的內在固有嵌入向量，

$$q_i^{\text{intrinsic}} = f(W_{\text{intrinsic}} \times C + b_{\text{intrinsic}}) \tag{15}$$

其中 $W_{\text{intrinsic}}$ 是全連結隱藏層的權重矩陣， $b_{\text{intrinsic}}$ 是其偏移量向量， f 是激發函數，最終所得到的 POI 的內在固有嵌入向量 $q_i^{\text{intrinsic}}$ 的維度等於隱藏層節點的數目。在此處，我們將所有關於此 POI 的評論按照時間順序合併到一個文檔中之目的，亦是想要捕抓評論時間順序所攜帶的語義資訊，例如，某個 POI 之前評價不錯，但是最近幾次的評價開始下滑。

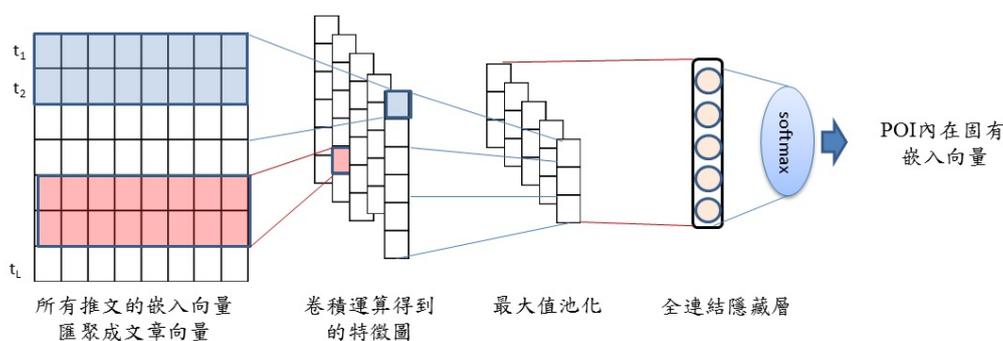


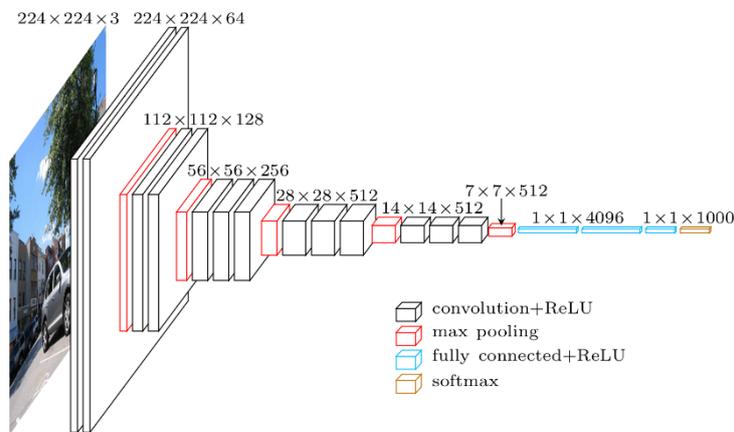
圖 9：學習 POI 內在嵌入表示特徵的循序卷積網路結構圖

(六) POI 圖像嵌入向量 (POI phot embedding)

POI 圖像嵌入向量試圖捕抓興趣點所拍攝照片的圖像訊息，為了建立 POI 的圖像嵌入表示向量，我們首先需要從圖像中提取有用的特徵。卷積神經網路 (convolutional neural networks; CNN) 是一個強大的深度網路，經常用於提取高階視覺內容特徵以進行圖像分類和目標檢測。因此，我們選擇 CNN 進行特徵提

取。我們選擇 VGG16 模型，因為它是最新的 CNN 架構 (Simonyan & Zisserman 2015)。圖 10 展示了 VGG16 的網路結構。VGG16 由 13 個卷積層，5 個最大池化層，3 個完全連接層和 1 個 softmax 層組成。VGG16 的輸入是大小為 $224 \times 224 \times 3$ 的圖像，其中 224×224 是圖像的大小，而 3 是通道數 (即 RGB 通道)。因此，我們首先將每個圖像的大小調整為 224×224 作為輸入。圖 10 中的每個立方塊都是一個特徵圖，其尺寸標示在上方。例如，最左邊的立方塊是在卷積層處理後得到尺寸為 $224 \times 224 \times 64$ 的特徵圖。相同大小的立方塊具有相同的尺寸。最後一層是用於分類的 softmax 層。VGG16 的詳細訊息請參考 (Simonyan & Zisserman 2015)。我們刪除了用於分類工作的 VGG16 的最後兩層。然後，對於每一個輸入圖像 p ，視覺內容特徵是移除最後兩層後的 VGG16 的輸出，它是 $d = 4096$ 維的向量。我們將其表示為 $CNN(p)$ 。給定圖像集合 π ，其中 π_i 表示標註到興趣點 POI i 的圖像集合，而 $p \in \pi_i$ 表示 π_i 中的一張圖像，令 d_p 為 CNN 從圖像 p 中提取的視覺特徵向量，即 $d_p = CNN(p)$ ，則興趣點 POI i 的圖像嵌入特徵向量定義為

$$\mathbf{q}_i^{\text{phot}} = \frac{\sum_{p \in \pi_i} d_p}{|\pi_i|} = \frac{\sum_{p \in \pi_i} CNN(p)}{|\pi_i|} \quad (16)$$



圖片來源：Simonyan & Zisserman (2015)

圖 10：VGG16 的網路結構

它是一個 4096 維的圖像視覺特徵向量。因為我們將 CNN 視為特徵學習函數，其權重將在學習過程中更新。受到 (Wang et al. 2017a) 的做法所啟發，我們使用預先訓練好的 VGG16，然後在即時矩陣分解中最佳化 POI 推薦的目標函數時，透過隨機降梯度演算法微調 CNN 中的權重連結參數。更多細節將在下一章中討論。

四、即時 POI 推薦系統 (real-time POI recommender)

在本章節，我們將介紹如何製作推薦系統 (recommendation system; RS) 與 POI 即時嵌入。與其他 POI 推薦系統不同，我們的主要思想是考慮正在進行的事件、合適的時機與 POI 的特性，由上述三個基礎來推薦合適的 POI。因此，我們將 RS 模型的任務簡化為二進制分類，以預測一個用戶在特定時間段內是否對某一個 POI 感到興趣。我們定義如果用戶在特定時間段內在 POI 上有簽到記錄，則代表用戶對於該 POI 感興趣，反之，如果用戶沒有在 POI 上有簽到記錄，則代表用戶對該 POI 不感興趣。首先，我們根據 T 個時間狀態，建構 T 個「用戶-POI 矩陣」，每個矩陣僅包含在相應的時間狀態下發生的簽到記錄。矩陣中的每個數值 $y_{u,i,\Gamma}$ 記錄在時間戳記 Γ 中用戶 u 和 POI i 之間的關係 (感興趣 / 不感興趣)，其中 1 對應於「感興趣」，0 對應於「不感興趣」。由於我們的資料集僅包含正樣本，即用戶的簽到記錄，因此我們需要構建負樣本，以更好地訓練模型。參考 (Pan et al. 2008) 的做法，對於給定用戶 u 在時間戳為 Γ 下的每條肯定記錄，我們隨機採樣用戶 u 在同一時間未去過的 POI j ，我們將其指定為否定簽到，評分為 0 (用戶在某時段去了 POI i ，即不可能在該時段去參訪 POI j ，亦即代表用戶在該時段應該對 POI j 不感興趣)。因此，每一個 $y_{u,i,\Gamma}$ 值定義如下所示：

$$y_{u,i,\Gamma} = \begin{cases} 1, & \forall \langle u, i, \Gamma \rangle \in \mathbf{R} \\ 0, & \forall j \in I_{-i}, \langle u, j, \Gamma \rangle \notin \mathbf{R} \end{cases} \quad (17)$$

(一) 即時矩陣分解技術 (real-time matrix factorization)

本研究使用的 POI 推薦系統是基於矩陣分解 (matrix factorization; MF) 技術 (Bokde et al. 2015)，如圖 11 所示。矩陣分解技術是協同過濾推薦演算法中最先進的方法，它從觀察到的用戶對項目的評分，來學習用戶與項目的潛在特徵 (latent features)，並且藉由用戶與項目的潛在特徵來推斷出他們之間的關係。每個用戶和項目將分別由 k 維的潛在特徵向量表示，每個維度都對應到一個潛在特徵。在我們的模型中，每個時間區段都包含一個對應的「用戶-POI 簽到矩陣」，並且，我們使用 POI 即時嵌入向量，作為矩陣分解的輔助資訊，增強了推薦系統的效能。在我們的方法中，所有「用戶-POI 簽到矩陣」皆共享相同的「用戶嵌入向量」和矩陣分解權重，但是不同時段的 POI 嵌入向量會不一樣，因此我們稱之為即時 (real time) POI 嵌入 $\mathbf{q}_{i,\Gamma}^*$ ，我們將在下一小節介紹如何得到 $\mathbf{q}_{i,\Gamma}^*$ 。

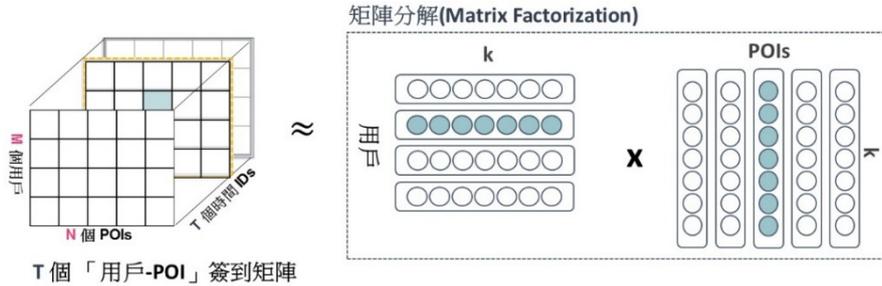


圖 11：即時矩陣分解技術

(二) 即時 POI 嵌入 (real-time POI embedding)

POI 即時嵌入的目的，是同時考慮 POI 瞬時訊息、固有訊息與圖像訊息。首先，我們將這三個向量連接成一個向量，即 $\mathbf{M}_{i,\Gamma} = \mathbf{q}_i^{\text{instant}} \oplus \mathbf{q}_i^{\text{intrinsic}} \oplus \mathbf{q}_i^{\text{phot}}$ ，其中 $\mathbf{q}_i^{\text{instant}}$ 是 POI 瞬時訊息向量 (POI instant vector)， $\mathbf{q}_i^{\text{intrinsic}}$ 是 POI 固有訊息向量 (POI intrinsic vector)， $\mathbf{q}_i^{\text{phot}}$ 是 POI 圖像訊息向量 (POI phot vector)，而 \oplus 是向量串聯運算符。接下來，我們將特徵向量 $\mathbf{M}_{i,\Gamma}$ 餵入到完全連接的多層感知網路 (multi-layer perception; MLP) 中，透過深層網路以學習更高層級的合成特徵，如下所示：

$$\mathbf{q}_{i,\Gamma}^* = f(W \times \mathbf{M}_{i,\Gamma} + g), \quad (18)$$

其中 f 表示激活函數， W 是網路隱藏層內的權重矩陣，而 $\mathbf{q}_{i,\Gamma}^*$ 則是當前時間戳記 Γ 時 POI i 的最終即時嵌入向量。

(三) 推薦系統 (recommender computation)

然後，我們將 POI 即時嵌入向量 $\mathbf{q}_{i,\Gamma}^*$ 應用於矩陣分解，來學習用戶的嵌入向量 (潛在特徵)。矩陣分解 (matrix factorization; MF) 的基本運算如下，給定 U 個用戶和 I 個項目的「用戶-項目」評分矩陣 $Y \in \mathbf{R}^{U \times I}$ ，MF 將其分解為用戶潛在因子 P 與項目潛在因子 Q 的乘積。它使用 k 個特徵來學習用戶與項目的相關聯性，我們推薦演算法的目標函數如下：

$$\mathcal{L}_{\text{RMF}} = \overbrace{\sum_{(u,i,\Gamma) \in \mathbf{R}} (y_{u,i,t} - \mathbf{p}_u^T \mathbf{q}_{i,\Gamma})^2}^{\text{MF}} + \overbrace{\frac{\lambda_q}{2} \sum_{i \in I} \sum_{\Gamma \in \mathbf{T}} \sum_{t \in T} \|\mathbf{q}_{i,\Gamma} - \mathbf{q}_{i,\Gamma}^*\|^2}^{\text{POI embedding}} + \frac{\lambda_p}{2} \sum_{u \in U} \|\mathbf{p}_u\|^2 + \frac{\lambda_v}{2} \sum_{i \in I} \sum_{\Gamma \in \mathbf{T}} \sum_{t \in T} \|\mathbf{q}'_{i,\Gamma}\|^2 \quad (19)$$

其中 $y_{u,i,\Gamma}$ 是真實評分值 (用戶-POI 簽到矩陣的值)， \mathbf{p}_u 與 $\mathbf{q}_{i,\Gamma}$ 分別是時間戳 Γ 時的用戶 u 潛在向量與 POI i 潛在向量。目標函數的第一項強制用戶潛在向量和 POI 潛

在向量的乘積接近真值 $y_{u,i,r}$ 。第二項則是強制 POI 潛在向量 $\mathbf{q}_{i,r}$ 在不同時間段內接近 POI i 即時嵌入向量 $\mathbf{q}_{i,r}^*$ ，其中 $\mathbf{q}_{i,r}^*$ 是從公式(18)中得到， λ_q 是權衡參數 (trade-off parameter)，它在推薦正確率與即時 POI 嵌入向量的重要性之間取得平衡，當 λ_q 的值較大，矩陣分解學習的 POI 潛在向量 $\mathbf{q}_{i,r}$ 將會更接近即時 POI 嵌入向量 $\mathbf{q}_{i,r}^*$ 。當 $\lambda_q=0$ 時，我們的模型將退化為經典矩陣分解 (MF) 方法。第三項和最後一項則是模型的正則項 (regularization)，使其不會過度擬合訓練數據，參數 λ_p 與 λ_v 則是正則化參數。優化模型後，我們可以透過計算用戶潛在向量 \mathbf{p}_u 與特定時段的 POI 潛在向量 $\mathbf{q}_{i,r}$ 的內積來預測用戶對 POI 的偏好。注意，本研究的推薦方法是透過底下兩個策略來捕抓時間的影響因素：(1)在多模式嵌入向量學習中，我們從數百萬條帶有地理標籤的推文中訓練嵌入表示形式，並且將所有關鍵字、POI 地點和時間單位嵌入到相同的潛在特徵空間中，從而學習關鍵字、POI 地點和時間單位之間的語義關係。(2)給定一個 POI，我們透過學習事件嵌入向量來捕獲突發時間模式，事件嵌入向量表示在特定時間段內發生的事件。此外，它也被視為潛在特徵，顯示有關該 POI 的當前活動情況。注意， $\mathbf{q}_{i,r}^*$ 的數值是由公式(18)中的權重矩陣、樹狀與循序卷積 CNN 中的權重參數與 VGG16 網路中的權重參數決定的，在優化目標函數的過程中，我們會使用隨機梯度下降法來調整公式(19)中的權重矩陣、樹狀與循序卷積 CNN 中的權重參數與 VGG16 網路中的權重參數。更明確地說，我們會使用交替學習的策略，亦即，固定 $\mathbf{q}_{i,r}^*$ 的值，學習調整 \mathbf{p}_u 與 $\mathbf{q}_{i,r}$ 的數值；與固定 \mathbf{p}_u 與 $\mathbf{q}_{i,r}$ 的值，學習調整 $\mathbf{q}_{i,r}^*$ 的值，亦即是，學習調整公式(19)中的權重矩陣、樹狀與循序卷積 CNN 中的權重參數與 VGG16 網路中的權重參數，如此交替進行，直到收斂為止。

肆、實驗結果

本研究使用 2014 年 8 月至 2014 年 10 月的紐約市地理標記推文 (geo-tagged tweets)，經過數據收集與預處理之後，所有的推文 (tweets) 都與來自 Foursquare 的紐約市 2,994 個 POI 位置進行了地理標記對映。數據集中有 506,750 個簽到記錄 (check-ins，打卡)，我們將數據分成 8:1:1 的比例，分別作為訓練數據集、驗證數據集和測試數據集。我們使用 Keras⁴ (高級神經網路 API) 來構建深度學習模型。我們在深層網路的每一層上應用丟棄 (dropout) 策略，並設定隨機丟棄分數為 $p = 0.5$ ，dropout 策略使得神經網路不會過度記憶訓練資料，避免過度學習 (overfitting)，從而學習更強大的推理能力。此外，我們採用隨機梯度下降 (stochastic gradient descent; SGD) 並將學習速率 (learning rate) 設置為 0.01，以便學習所有目標函數。

⁴ <https://www.keras.io>

一、評量尺度

我們使用兩種基於排名的度量，來評估我們 POI 推薦系統的效能，分別是：前 K 處召回率 (Recall at K, R@K) 與排名倒數平均值 (mean reciprocal rank; MRR)。由於我們的 POI 推薦模型強調即時推薦，亦即是，用戶將在不同的時間段，收到不同的 POI 推薦列表。因此，每次用戶簽到 (打卡) 行為都被視為獨立案例。我們對真實 POI 簽到 (ground-truth POI) 地點 v 進行評分，同時也對以 v 為中心，半徑為 $\zeta = \frac{3 \text{ miles}}{\text{hr}} \times 20 \text{ mins} \times \frac{1 \text{ hr}}{60 \text{ mins}} = 1 \text{ mile}$ (= 紐約市民的平均步行速度 \times 平均耐久步行時間) 的圓形範圍內的所有 POI 地點進行評分，並且比較真實 POI 簽到地點與其圓形範圍內的其他 POI 地點的評分排名，而不是採用 (Yin 2017) 中對所有的 POI 進行評分比較，因為只有地理上接近真實 POI 簽到地點 v 的其他 POI 地點，才是真正的競爭者。我們根據推薦系統計算出來的評分分數，來對每案例 q 建立推薦列表，並依照評分分數排序為 $R_q = \{r_q^1, r_q^2, \dots, r_q^K\}$ ，其中 r_q^i 代表根據評分排序的第 i 個 POI 推薦。

(一) 前 K 處召回率 (recall at K; R@K)

前 K 處召回率經常應用於評估 POI 推薦系統的效能，簡寫為 R@K。在我們的任務中，R@K 代表在前 K 個建議中，找到的相關項目的比例。對於每個案例 $q = \langle u, \Gamma \rangle$ ，我們從推薦列表中，選擇 K 個排名最高的 POI。而 R@K 的定義如下：

$$R@K = \frac{1}{|C_{test}|} \sum_{q=1}^{|C_{test}|} \frac{|R_q \cap T_q|}{|T_q|} = \frac{1}{|C_{test}|} \sum_{q=1}^{|C_{test}|} |R_q \cap T_q| \quad (20)$$

其中 $|R_q \cap T_q|$ 代表從推薦列表的前 K 個 POI 中找到相關 POI (即，真實 POI 簽到地點) 的數目， $|T_q|$ 是相關 POI 的數目，在我們的 POI 推薦任務中，真實的 POI 簽到地點只有一個，所以 $|T_q| = 1$ ，而 $|C_{test}|$ 代表測試集中全部的案例數目。R@K 越大，代表能在前 K 個推薦中找到真實結果的比率越高，亦即是代表推薦系統的效能越好。

(二) 排名倒數平均值 (mean reciprocal rank; MRR)

MRR 對排名位置非常敏感，很適合用於評估只有一個相關結果 (即，真實 POI 簽到地點) 的推薦系統的效能。儘管 MRR 僅測量從測試集中找到第一個相關項目時的排名的倒數的平均值，但是它對每一條記錄都很敏感。MRR 的公式定義如下：

$$MRR = \frac{1}{|C_{test}|} \sum_{q=1}^{|C_{test}|} \frac{1}{\text{rank } q} \quad (21)$$

其中 $rank\ q$ 表示相關 POI (即, 真實 POI 簽到地點) 在推薦列表的排名值, 而 $|C_{test}|$ 代表測試集中全部的案例數目。MRR 值越大, 代表真實 POI 簽到地點在推薦列表的越前面 (即, 排名值越小), 亦即是代表推薦系統的效能越好。

二、效能評估

為了公平評估本研究所提出的推薦系統的預測效果, 我們將與以下最先進的推薦方法進行比較:

- **MP**: 指的是最熱門 (most popular) POI 推薦模型, 他按照訪問者的簽到數量排序來建立 POI 推薦列表。
- **MF**: 指的是矩陣分解 (matrix factorization) 推薦模型, 他是最流行的協同過濾式推薦方法。
- **CDL** (Wang et al. 2015): 指的是一種協同深度學習 (collaborative deep learning; CDL), 它將深度學習模型中的堆疊降噪自動編碼器 (stacked denoising autoencode; SDAE) 整合到機率矩陣分解中。
- **ConvMF** (Kim et al. 2016): 指的是一種上下文感知推薦模型, 該模型將卷積神經網路 (convolutional neural network; CNN) 整合到機率矩陣分解 (probabilistic matrix factorization; PMF) 中。
- **DCPR** (Wanget al. 2017b): 指的是基於深度上下文感知 POI 推薦 (deep context aware POI recommendation) 模型, 該模型從結構上學習 POI 和用戶特徵。

圖 12 顯示不同推薦模型的實驗結果。結果顯示, 本研究的即時 POI 推薦模型比其他先進推薦方法具有更好的效能。對於所有的評估指標, 本研究的推薦模型均優於矩陣分解推薦模型 MF 至少 30%, 這證明考慮 POI 的即時事件、時間與圖文感知資訊可以顯著地改善 POI 推薦效能。有趣的是, 實驗顯示最熱門推薦 MP 的性能中等, 原因在於一旦在興趣點 POI 中發生熱門事件, 用戶會更願意在社群媒體上分享自己的感受 (亦即, 在該 POI 的簽到次數與正常時間相比會顯著增加), 這是在社群媒體中的常見現象。因此, 最熱門推薦模型 MP 顯示出比矩陣分解推薦模型 MF 更好的性能是合理的。圖 12(a)顯示了前 K 處的召回率的實驗結果。召回率是一種經常用來反映推薦列表敏感性的評估指標。推薦列表越長 (亦即, 設置的 K 值越高), 可以獲得越高的召回率。反之, 推薦列表越短, 召回率越小, 但是在現實世界中, 用戶更傾向得到簡潔且較短的推薦清單。如圖 12(a)所示, 對於不同的 K 值, 本研究的即時 POI 推薦模型皆獲得比其他先進方法更高的召回率。另外, 當 K=1 時, 本研究提出的方法比 MF 與 MP 至少提高了 33%, 這證明本研究提出的方法可以在第一時間為用戶找到最佳的 POI。圖 12(b)顯示各種

推薦模型在排名倒數平均值 MRR 的實驗結果，MRR 越高，代表用戶真正喜愛的相關項目 (POI) 在推薦列表的越前面，亦即是，代表推薦系統可以更快地推薦相關項目。如圖 12(b)所示，本研究提出的方法在 MRR 評估項目獲得比其他推薦模型更優異的表現。本研究提出的方法比最熱門推薦模型 MP 提升了 9%，比矩陣分解推薦模型 MF 改進了 58%，這意味著本研究的推薦系統可以比其他方法更快地推薦正確的項目。

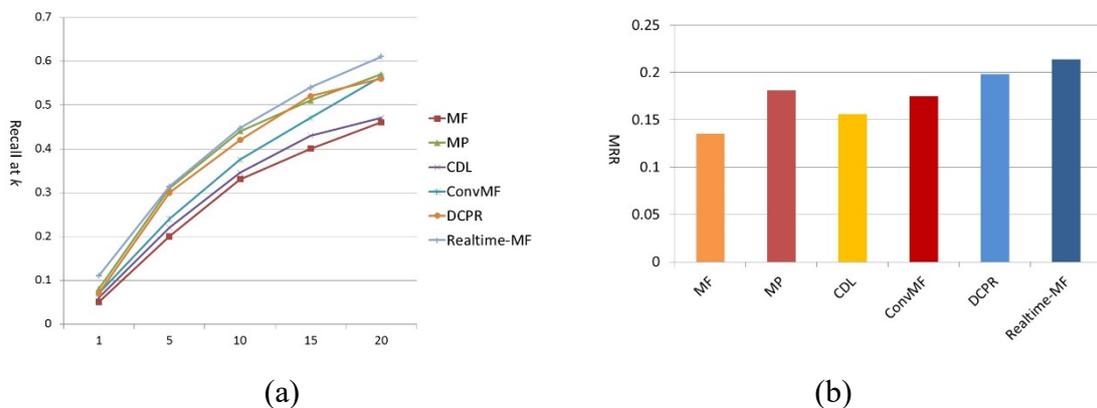


圖 12：(a)前 K 處召回率 (Recall at K) 與(b)排名倒數平均值 MRR 的實驗效能比較

三、時間複雜度分析

每一次疊代，矩陣分解法更新用戶與項目潛在因素向量 (公式(19)中的 \mathbf{p}_u 與 $\mathbf{q}_{i,r}$) 的時間複雜度是 $O(k^2 n_r + k^3 U + k^3 I)$ ，其中 n_r 是觀察到的評分的數量 (亦即是，POI 簽到的數量)， I 是項目的數目 (亦即是，興趣點 POI 的數量)， U 是用戶的數量， k 是用戶與 POI 潛在因素向量的維度，此外，即時 POI 嵌入向量 $\mathbf{q}_{i,r}^*$ 的更新時間點為學習樹狀卷積網路、圖片卷積網路 VGG16 與學習多層前向類神經網路 MLP。更新樹狀卷積網路的時間複雜度為 $O(n_f \times n \times N \times I)$ ，其中 N 是文章的長度， n 是詞嵌入向量的維度， n_f 是樹狀卷積網路中濾波器 (filters) 的數目， I 是項目的數目。更新多層前向類神經網路 MLP 的時間複雜度是 $O(|W| \times I)$ ，其中 $|W|$ 是 MLP 中要學習調整的網路連結權重參數的數量， I 是項目的數目。學習圖片卷積網路 VGG16 的時間複雜度是 $O(\text{convheight} \times \text{convwidth} \times \text{convchannel} \times \text{convnumber} \times \text{inputwidth} \times \text{inputheight} + \text{fcheight} \times \text{fcwidth})$ ，其中 convheight 與 convwidth 分別代表 VGG16 卷積層的深度與寬度， convchannel 與 convnumber 分別代表卷積網路的通道數目與濾波器數目， inputwidth 與 inputheight 分別代表輸入圖像的寬度與高度， fcheight 與 fcwidth 分別代表全連結網路層的深度與寬度。結果，每一次疊代的總時間複雜度為 $O(k^2 n_r + k^3 U + k^3 I)$

$+n_f \times n \times N \times I + |W| \times I + conv_{height} \times conv_{width} \times conv_{channel} \times conv_{number} \times input_{width} \times input_{height} + f_{C_{height}} \times f_{C_{width}}$), 而且此最佳化過程的時間複雜度與給定資料集的大小成線性等比率。

表 2 顯示訓練 MF、CDL、ConvMF、DCPR 與本研究的即時 POI 推薦模型的疊代次數和總計算時間 (以秒為單位)。如表 2 所示, 儘管本研究使用更多的輔助訊息 (包含即時事件、圖文感知資訊與 POI 時間感知資訊), 並且在進行每一次訓練疊代需要更多的時間, 但是, 本研究所提出的即時 POI 推薦模型比矩陣分解推薦模型 MF 需要更少的學習疊代次數, 便可以達到令人滿意的推薦效果。因此, 即使本研究提出的推薦模型每一次疊代的时间複雜度皆略高於 MF, 但是, 訓練本研究的即時 POI 推薦模型的總計算時間, 比訓練矩陣分解推薦模型 MF 的總計算時間更短。

表 2: 訓練 MF、CDL、ConvMF、DCPR 與本研究推薦模型的疊代次數與總時間

	MF	CDL	ConvMF	DCPR	Real-time MF
疊代次數	525	475	314	258	291
總訓練時間	24.3	28.3	19.3	25.4	23.1

四、參數敏感性分析

λ_q 是一個權衡參數 (trade-off parameter), 它在推薦正確率與即時 POI 嵌入向量的重要性之間取得平衡, 當 λ_q 的值較大, 矩陣分解學習的 POI 潛在向量 $q_{i,r}$ 將會更接近即時 POI 事件嵌入向量 $q_{i,r}^*$ 。當 $\lambda_q = 0$ 時, 本研究的模型將不考慮即時 POI 事件嵌入向量, 並且退化為經典矩陣分解 (MF) 推薦方法。參數 λ_p 與 λ_v 用於正則化模型。當 λ_p 與 λ_v 接近零時, 所獲得的模型僅考慮經驗風險 (empirical risk), 並且傾向於過度擬合訓練數據 (過度學習, over-fitting)。當 λ_p 與 λ_v 逼近無窮時, 它會降低推薦程序的模型複雜度, 並且獲得的推薦模型不具有記憶訓練數據的能力 (擬合不足, under-fitting)。為了評估參數 λ_q 、 λ_p 和 λ_v 對於本研究所提出推薦模型的敏感性, 本研究進行三組實驗。首先, 設置 $\lambda_p = 0.1$ 和 $\lambda_v = 0.1$, 並且觀察推薦性能如何隨著 λ_q 的變化而改變。表 3 顯示在不同 λ_q 值的前 K 處召回率與排名倒數平均值 MRR 的效能。如表 3 所示, 推薦性能對於參數 λ_q 相對敏感。對於固定的 λ_p 和 λ_v 的情形下, 召回率與 MRR 首先隨著 λ_q 值增加而提高, 然後在接近 $\lambda_q = 1$ 的位置之後, 召回率與 MRR 則是隨著 λ_q 值增加而減小。當 λ_q 值太小時, 推薦性能則如預期地接近矩陣分解推薦模型 MF。表 4 顯示參數 λ_p 如何影響推薦性能。我們設置 $\lambda_q = 1$ 與 $\lambda_v = 0.1$, 並且設置參數 $\lambda_p = 0.001, 0.01, 0.1, 1, 10, 100, 1000$ 來計算前 K 處召回率與 MRR 的效能。如表 4 所示, 召回率與 MRR 首

先隨著 λ_p 值增加而提高，然後在接近 $\lambda_p = 0.1$ 的位置之後，召回率與 MRR 則是隨著 λ_p 值增加而減小。表 5 顯示 λ_v 的選擇如何影響推薦性能，我們設置 $\lambda_p = 0.1$ 和 $\lambda_q = 1$ ，並且透過設置 $\lambda_v = 0.001、0.01、0.1、1、10、100、1000$ 來計算前 K 處召回率和 MRR，以觀察參數 λ_v 如何影響推薦效能。如表 5 所顯示，召回率與 MRR 首先隨著 λ_v 增加而提高，然後在接近 $\lambda_v = 0.1$ 附近，推薦性能則隨著 λ_v 值增加而下降。

表 3：對於不同 λ_q 值的前 K 處召回率 (R@K, K = 5) 與排名倒數平均值 (MRR)

λ_q	0.001	0.01	0.1	1	10	100	1000
R@K	0.20	0.26	0.28	0.31	0.27	0.22	0.16
MRR	0.131	0.163	0.192	0.212	0.201	0.179	0.146

表 4：對於不同 λ_p 值的前 K 處召回率 (R@K, K = 5) 與排名倒數平均值 (MRR)

λ_p	0.001	0.01	0.1	1	10	100	1000
R@K	0.24	0.29	0.31	0.30	0.29	0.28	0.25
MRR	0.164	0.193	0.212	0.209	0.201	0.187	0.169

表 5：對於不同 λ_v 值的前 K 處召回率 (R@K, K = 5) 與排名倒數平均值 (MRR)

λ_v	0.001	0.01	0.1	1	10	100	1000
R@K	0.27	0.30	0.31	0.30	0.27	0.25	0.22
MRR	0.165	0.198	0.214	0.203	0.191	0.182	0.171

五、分析不同深度模型與資料來源對於推薦效能之貢獻

本研究提出嶄新的樹狀卷積神經網路，透過語法剖析樹提供的語義關係來分析用戶的具地理標註推文與 POI 介紹的文字資料，以學習 POI 嵌入向量。為了驗證本研究所提出的樹狀卷積神經網路對於推薦效能的貢獻，本小節將本研究的樹狀卷積網路 (tree-based CNN) 與傳統用於學習文章嵌入向量的經典模型：卷積神經網路 (convolutional neural network; CNN) 與長短期記憶神經網路 (long-short term memory; LSTM) 進行效能比較，實驗結果如表 6 所顯示。由於本研究提出的樹狀卷積神經網路可以更細膩的分析語法樹上的語義關係，所以推薦效能是優於 CNN 與 LSTM。LSTM 雖然可以保留較長的記憶，在萃取遠距相依性時會有較佳的效果，但是由於它是一個有偏見 (bias) 的模型，在將文章中的詞彙循序輸入 LSTM 的過程中，後面輸入 LSTM 的詞彙對最終文章嵌入表示向量的影響，比之

前輸入 LSTM 的詞彙更大。然而，對於本研究的文字探勘任務來說，表示即時事件的重要詞彙可能出現在文章中任何地方，而不是在結尾，而且 LSTM 無法處理剖析樹上的語法關係資訊，所以效能不如本研究提出的樹狀卷積神經網路。

表 6：對於不同深度神經網路模型的前 K 處召回率 (R@K, K = 5) 與排名倒數平均值 (MRR) 的推薦效能評估

	Tree-based CNN	CNN	LSTM
R@K	0.313	0.301	0.291
MRR	0.214	0.197	0.188

此外，本論文所提出之 POI 推薦系統，結合了 POI 簽到資訊、POI 介紹文字與 POI 圖像訊息，接下來我們分析這三種不同來源的資料，對於推薦結果的影響與重要性，實驗結果如表 7 所顯示。由於本研究所採用的矩陣分解協同推薦系統，主要是透過針對「用戶-POI 簽到矩陣」進行矩陣分解來產生推薦結果，所以 POI 簽到資訊是絕對需要考慮的。如表 7 所示，分別納入 POI 介紹文字與 POI 圖像訊息，皆可以提升推薦效能，而納入 POI 介紹文字的提升效果較優於 POI 圖像訊息，這是因為文字攜帶了在 POI 舉辦的即時事件的重要資訊，這也驗證本系統所提出的即時事件偵測是可以有效提升 POI 推薦效能。此外，同時納入 POI 文字與圖像訊息的推薦效能是最佳的，代表文字與圖像資訊可以相輔相成，有效地提升 POI 推薦效能。

表 7：比較 POI 簽到資訊、POI 介紹文字與 POI 圖像訊息對於前 K 處召回率 (R@K, K = 5) 與排名倒數平均值 (MRR) 的推薦效能評估的貢獻與影響

	POI 簽到	POI 簽到+圖像	POI 簽到+文字	POI 簽到+文字+圖像
R@K	0.201	0.245	0.302	0.313
MRR	0.135	0.168	0.206	0.214

六、案例說明

(一) 多模式嵌入案例分析

本研究透過將 POI 地點、關鍵字與時間單位統一建立多模式嵌入模型 (multimodal embedding)，使得它們在嵌入空間之間的距離，可以代表它們之間的相似度，透過多模式嵌入模型的建立，我們可以計算不同類型的物件 (例如

POI 地點、關鍵字與時間單位) 之間的相似度, 圖 13 顯示輸入關鍵字「Yankee Stadium (洋基體育場)」後, 回傳與該關鍵字最相似的 POI 地點分別為: New York Yankee Museum (紐約洋基博物館)、Bleacher Creatures (布勒徹生物看台)、Hyundai Club (現代俱樂部) 與 Great Hall (洋基體育場大廳), 這些 POI 地點全部都是紐約市的體育場或運動相關的區域; 圖 14 則是顯示輸入 POI 地點「Yankee Stadium (洋基體育場)」, 回傳與該 POI 地點最相似的關鍵字分別為 hockey (曲棍球)、royals (皇家隊)、soccer (足球)、preseason (季前賽)、pirates (海盜隊)、playoff (季後賽)、pitching (投球)、mets (遇見)、sox (紅襪隊)、eagles (老鷹隊) 等, 排名靠前的關鍵字主要與紐約市的職業棒球大聯盟 (Major League Baseball; MLB, 美國的職業棒球組織) 相關。儘管「曲棍球」和「足球」與美國職業棒球大聯盟無關, 但它們也是紐約市的一種流行體育。此案例分析說明多模式嵌入模型對於提取空間和語義特徵是很有意義的。



圖 13: 輸入關鍵字「Yankee Stadium」後回傳的最相似的 POI 地點

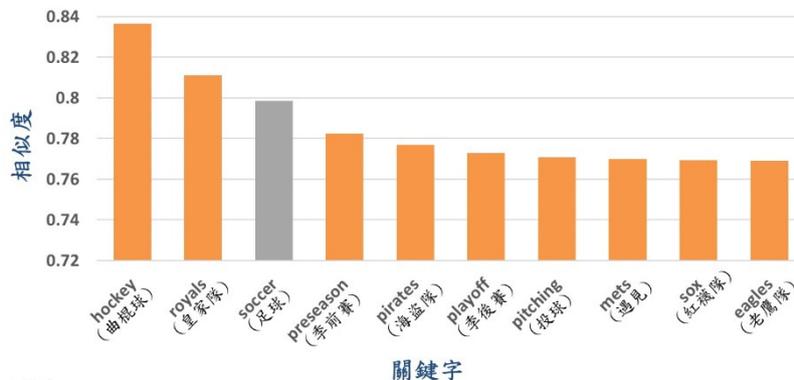


圖 14: 輸入 POI 地點「Yankee Stadium」後回傳的最相似的關鍵字

(二) 融入即時事件的推薦案例分析

本研究假設我們可以根據時間因素與即時事件來提升推薦系統的效能，在本小節中，我們使用一個有在 2014 年紐約時裝週 (NYFW2014) 於 Eyebeam Art + Technology Center 興趣點進行簽到打卡的用戶案例來說明，首先，圖 15(a)顯示用戶 1 發布的地理標記推文 (geo-tagged tweet)，如圖 15(a)所示。用戶 1 高度關注時尚與 NYFW 相關的主題。接著，圖 15(b)顯示本研究提出的推薦模型在不同時間點對用戶 1 列出的兩個 POI 興趣點推薦列表，其中左邊一個是在「正常日，亦即沒有舉辦紐約時裝週 NYFW 的日期」的 POI 推薦列表，右邊一個是在「活動日，亦即有舉辦紐約時裝週 NYFW 的日期」的 POI 推薦列表。如圖 15(b)所示，在不同的時間點，本研究提出的 POI 推薦模型可以產生不同的推薦列表，在正常日，NYFW 舉辦地點 Eyebeam Art + Technology Center 在推薦列表較後端的位置 (排序第 13 名)，而在 NYFW 舉辦的活動日，本研究提出的推薦系統成功地將 NYFW 舉辦的地點提升到 POI 推薦列表較前面的位置 (排序第 6 名)，此案例分析展示考慮時間因素與即時事件可以有效地提升 POI 推薦系統的效能。將這兩個推薦列表進行比較，我們發現，本研究提出的推薦模型可以在事件發生時，對 POI 推薦列表進行重新排序，使得相關項目可以移到推薦列表較前面的位置，這意味著推薦模型學習到的即時 POI 嵌入特徵，將有利於探索用戶與 POI 之間的即時潛在關係，從而為用戶提供更精確的即時建議。

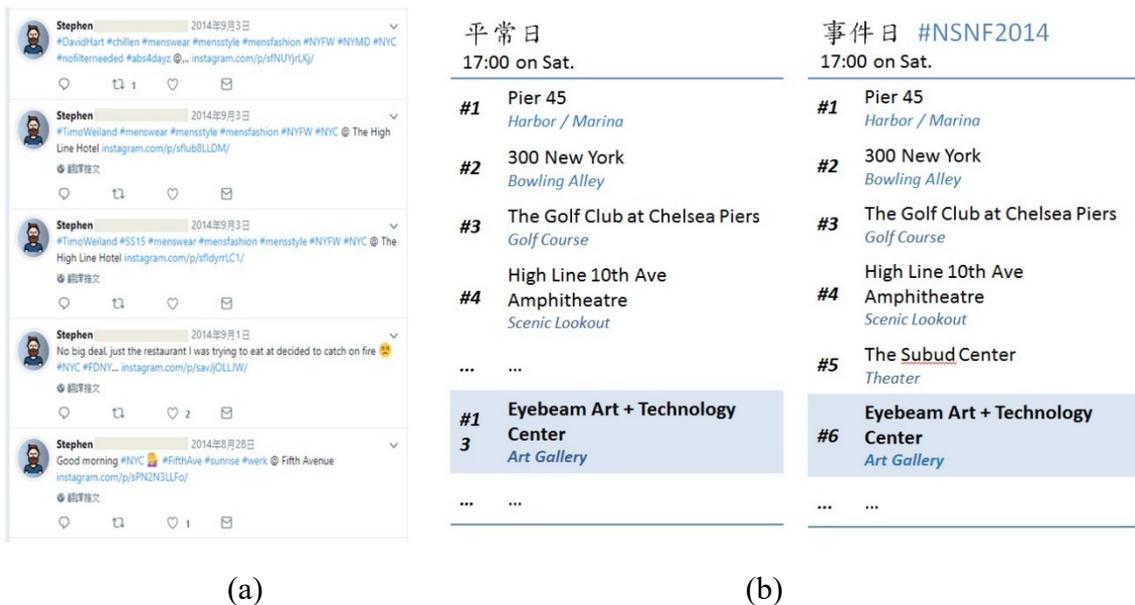


圖 15 : (a)用戶 1 在 Twitter 上發表的貼文 ; (b)在正常日與事件日所產生的推薦列表

伍、結論與未來方向

本研究開發一套嶄新的即時 POI 推薦系統，我們從不同時段的社群媒體推文資料中捕抓 POI 的固有特性與即時事件的資訊。本研究從 Foursquare 的 POI 的文字評論和描述，以及 Instagram 中的 POI 圖像資料，來學習 POI 固有特徵。本研究提出一個嶄新的樹狀卷積神經網路來優雅且有效率的處理文字中的循序資訊，以及語法樹中的語義資訊，此外，本研究開發一套具有時間感知的 POI 嵌入度量標準，透過多模式嵌入模型將不同類型的資料映射到統一的嵌入空間，從而可以在社群媒體上進行跟踪並捕獲即時事件訊息。此外，本研究透過將即時 POI 嵌入向量融合到矩陣分解演算法中，來開發即時的 POI 推薦模型，以了解用戶在不同時間片段的 POI 偏好傾向。

本研究得到以下結論。首先，考慮到各種類型（空間、時間和文字）特徵的多模式嵌入模型在學習關鍵詞的語義上表現良好。因此，能夠在社群媒體上凌亂的短文上，有效地構建即時事件檢測器，並且捕抓即時事件的嵌入潛在特徵的集合，這些潛在特徵收集了隨時間變化的即時信息，實驗結果證明，事件嵌入特徵有助於找到用戶決定去的興趣點 POI。此外，將 POI 即時事件嵌入特徵與 POI 輔助信息融合在一起，可以幫助協同過濾推薦模型來了解每個用戶與 POI 之間的關聯。本研究所提出的即時 POI 推薦模型透過擷取進行中的事件，來考慮 POI 的時間感知訊息，並且在不同時間段落，提出不同的 POI 推薦列表，以推薦在該時段最適合的 POI 給用戶，在紐約市帶有地理標籤推文的數據集進行評估實驗，證明本研究所提出 POI 推薦模型的有效性。將來，擴展本研究的即時 POI 推薦方法的方向有：

（一）融入更豐富的 POI 固有向量的輔助信息

目前，本研究的 POI 固有嵌入特徵是透過文字與圖像訊息來進行訓練。它僅考慮 POI 的文字與圖像特徵。但是，其它類型的訊息，例如地理特徵（緯度和經度）或流行度特徵（例如不同時間段的用戶流量），未來也可以應用於 POI 嵌入特徵學習。

（二）建構更有效率的機制來更新推薦系統

為了達到適性化與個人化推薦之目的，我們必須根據用戶的回饋與實際簽到的 POI 地點，來重新訓練推薦模型，然而，重新訓練模型是一項耗時且浪費資源的任務。在未來，我們將建立更有效率的更新機制，例如，採用先進先出（First in first out; FIFO）的機制，透過移動觀察窗口來添加最新的訊息並且丟棄最舊的訊息，而新的損失函數將僅需要比較最舊的訊息與最新的訊息之間的差異。

（三）從用戶在社群媒體上的活動來捕抓用戶的偏好

目前，本研究使用社群媒體上推文資料作為 POI 的輔助訊息，以捕抓 POI 的內在特徵，未來我們打算從用戶在社群媒體上的評論和帖子，來捕獲用戶的偏好訊息。

（四）在事件發生前提早產生推薦結果

目前，本系統必需等到事件已經開始，已有人前往參加、簽到，發表留言，才能感知事件發生，而無法在事件發生前「提早」產生推薦結果。所以目前本系統聚焦在推薦當前時刻下，使用者非預期且可能感興趣的 POI，以幫助用戶探索城市並且提供用戶意外的驚喜，同時滿足事件的時效性。舉例來說，對於一個平常不愛喝咖啡的使用者，如果在該用戶附近的咖啡廳，正好有該用戶喜愛的作者在舉辦簽書會，而且用戶當前時刻正好是空閒的，則透過本系統的 POI 推薦，他可以立即前往該咖啡廳參與此事件（符合事件的時效性）。或是為期一周的紐約時裝周剛開幕時，本系統從大量的簽到推文中偵測到此一事件的發生，並且將該 POI 推薦給可能會感興趣的用戶，即使用戶當前時段沒有空檔，但他可以在時裝周展覽期間，安排空檔去參與該事件。對於如何偵測到未來事件，並且在事件發生前「提早」產生推薦結果，讓用戶可以有更充裕的時間規劃行程，將會留作本研究的未來研究方向。

（五）設計分散式運算與增量模式機制來更新即時事件

深度學習系統可以分成學習（training）與測試（test）兩個階段，雖然，深度網路系統的學習是曠日廢時，但是深度學習的測試階段（亦即是，實際應用階段）則是非常快速的。以本系統的矩陣分解式協同推薦演算法為例，他的學習階段所使用的隨機梯度下降（stochastic gradient descent; SGD）演算法的時間複雜度雖然是很昂貴的，但是測試階段時，它僅需要計算用戶潛在向量與項目潛在向量的內積，這是非常快速的。而樹狀結構的卷積網路在測試階段時，也僅需要輸入文章向量，然後逐層與該層的權重向量進行內積運算即可，這也是非常迅速的，所以本研究的深度學習系統可以即時的偵測事件與推薦給使用者（並不需要重新訓練多模式模型或矩陣分解模型）。不過，在實際使用時，要即時分析大量的用戶貼文資料，剖析眾多推文內容並且匯集成單一個文章向量，以餵入深度網路進行預測，則是本系統要面對的計算瓶頸，在未來，本研究將研發能在平行系統上透過分散式運算的推文剖析程式，以同時剖析眾多推文內容並且匯集成單一個文章向量，並且設計增量模式（incremental）機制來更新每一個 POI 的事件，以達成真正的即時推薦。

（六）延伸應用到各項基於位置的服務

在這個物聯網（internet of things; IoT）時代，基於位置的服務起著重要的作

用。例如，智能手錶收集用戶的位置訊息並記錄他們的日常軌跡；智能手機中的地圖應用程序收集用戶的位置訊息，並將用戶引導到任何地點。隨著移動設備提供的基於位置的服務程序的數量激增，以及在社群網路中用戶創建的內容大幅增長，基於位置的推薦系統（location-based recommender systems; LBRS）變得越來越重要。本研究目的是建立一個基於位置的社群網路上的興趣點推薦系統，從大量具地理標註的推文中，偵測出即時事件，並且學習即時事件、時間感知、圖文內容感知資訊的嵌入特徵，再將他們融合到矩陣分解式的協同過濾推薦系統，在未來，本研究企圖將這些技術延伸應用到各項基於位置的服務：包含搜尋、運輸、醫療保健、公共安全、遊戲、環境監控等。

誌謝

本文接受行政院科技部專題研究計畫（MOST 109-2221-E-992-078 -）之補助研究經費，順利完成此篇著作之研究工作，謹此致謝。

參考文獻

- Bengio, Y., Courville, A. and Vincent, P. (2013), 'Representation learning: A review and new perspectives', *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 35, No. 8, pp. 1798-1828.
- Bokde, D., Girase, S. and Mukhopadhyay, D. (2015), 'Role of matrix factorization model in collaborative filtering algorithm: A survey', *Procedia Computer Science*, Vol. 49, pp. 136-146.
- Cho, E., Myers, S.A. and Leskovec, J. (2011), 'Friendship and mobility: User movement in location-based social networks', *Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'11)*, San Diego, CA, USA, August 21-24, pp. 1082-1090.
- Gao, H., Tang, J. and Liu, H. (2015), 'Addressing the cold-start problem in location recommendation using geo-social correlations', *Data Mining Knowledge Discovery*, Vol. 29, No. 2, pp. 299-323.
- Hao, P.-Y., Cheang, W.-H. and Chiang, J.-H. (2019), 'Real-time event embedding for POI recommendation', *Neurocomputing*, Vol. 349, No. 15, pp. 1-11.
- Hu, B., Lu, Z., Li, H. and Chen, Q. (2014), 'Convolutional neural network architectures for matching natural language sentences', *Proceedings of the Advances in Neural Information Processing Systems (NIPS 2014)*, Montreal, QC, Canada, December 8-13, pp. 2042-2050.

- Iyyer, M., Manjunatha, V., Boyd-Graber, J. and Daume, H. (2015), 'Deep unordered composition rivals syntactic methods for text classification', *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing*, Beijing, China, July 26-31, pp. 1681-1691.
- Kim, Y. (2014), 'Convolutional neural networks for sentence classification', *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qata, October 25-29, pp. 1746-1751.
- Kim, D., Park, C., Oh, J., Lee, S. and Yu, H. (2016), 'Convolutional matrix factorization for document context-aware recommendation', *Proceedings of the 10th ACM Conference on Recommender systems (RecSys '16)*, Boston, MA, USA, September 15-19, pp. 223-240.
- Liu, B. and Xiong, H. (2013), 'Point-of-interest recommendation in location based social networks with topic and location awareness', *Proceedings of the 13th SIAM International Conference on Data Mining (SDM 2013)*, Austin, TX, USA, May 2-4, pp. 396-404.
- Liu, W., Lai, H., Wang, J., Ke, G., Yang, W. and Yin, J. (2019), 'Mix geographical information into local collaborative ranking for POI recommendation', *World Wide Web*, Vol. 23, <https://doi.org/10.1007/s11280-019-00681-1>.
- Mikolov, T., Sutskever, I., Chen, K., Corrado, G. and Dean, J. (2013), 'Distributed representations of words and phrases and their compositionality', *Proceedings of the Advances in Neural Information Processing Systems (NIPS 2013)*, Lake Tahoe, NV, USA, December 5-10, pp. 1-9.
- Nguyen, T.H. and Grishman, R. (2015), 'Relation extraction: Perspective from convolutional neural networks', *Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics-Human Language Technologies (NAACL-HLT 2015)*, Denver, CO, May 31-June, pp. 39-48.
- Pan, R., Zhou, Y., Cao, B., Niu, N.N., Lukose, R., Scholz, M. and Yang, Q. (2008), 'One-class collaborative filtering', *Proceedings of the European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD 2008)*, Antwerp, Belgium, September 5-19, pp. 502-511.
- Rios, C., Schiaffino, S. and Godoy, D. (2018), 'A study of neighbour selection strategies for POI recommendation in LBSNs', *Journal of Information Science*, Vol. 44, No. 6, pp. 802-817.
- Shirani-mehr, H. (2015), 'Applications of deep learning to sentiment analysis of movie

- reviews', *Technical Report*, Stanford University, CA, USA.
- Simonyan, K. and Zisserman, A. (2015), 'Very deep convolutional networks for large-scale image recognition', *Proceedings of the 3rd International Conference on Learning Representations (ICLR 2015)*, San Diego, CA, USA, May 7-9, pp.1-14.
- Taigman, Y., Yang, M., Ranzayo, M.A. and Wolf, L. (2014), 'Deepface: Closing the gap to human-level performance in face verification', *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR '14)*, Columbus, OH, USA, June 24-27, pp. 1701-1708.
- Wang, X., Zhao, Y.L., Nie, L., Gao, Y., Nie, W. and Zha, Z.-H. (2015), 'Semantic-based location recommendation with multimodal venue semantics', *IEEE Transactions on Multimedia*, Vol. 17, No. 3, pp. 409-419.
- Wang, S., Wang, Y., Tang, J., Shu, K., Ranganath, S. and Liu, H. (2017a), 'What your images reveal: Exploiting visual contents for point-of-interest recommendation', *Proceedings of the 26th International Conference on World Wide Web (WWW'17)*, Perth, Australia, April 3-7, pp. 391-400.
- Wang, F., Qu, Y., Zheng, L., Lu, C.T. and Yu, P.S. (2017b), 'Deep and broad learning on content-aware POI recommendation', *Proceedings of the 3rd IEEE International Conference on Collaboration and Internet Computing (CIC2017)*, San Jose, CA, USA, October 15-17, pp. 369-378.
- Wen, Y., Zhang, W., Luo, R. and Wang, J. (2016), 'Learning text representation using recurrent convolutional neural network with highway layers', *Proceedings of the Neu-IR '16 SIGIR Workshop on Neural Information Retrieval*, Pisa, Italy, July 21, pp. 1-5.
- Yan, D., Zhao, X. and Guo, Z. (2018), 'Personalized POI recommendation based on subway network features and users' historical behaviors', *Hindawi Wireless Communications and Mobile Computing*, Vol. 2018, Article ID 3698198, 10 pages, <https://doi.org/10.1155/2018/3698198>.
- Yang, D., Zhang, D., Yu, Z. and Wang, Z. (2013), 'Asentiment-enhanced personalized location recommendation system', *Proceedings of the 24th ACM Conference on Hypertext and Social Media*, Paris, France, May 1-3, pp. 119-128.
- Zhang, J.D. and Chow, C.Y. (2013), 'iGSLR: Personalized geo-social location recommendation: A kernel density estimation approach', *Proceedings of the 21st ACM International Conference on Advances in Geographic Information Systems (SIGSPATIAL '13)*, Orlando, FL, USA, November 5-8, pp. 334-343.
- Zhang, J., Kong X. and Yu, P.S. (2014a), 'Transferring heterogeneous links across

- location-based social networks’, *Proceedings of 7th ACM International Conference on Web Search and Data Mining (WSDM '14)*, New York, NY, USA, February 24-28, pp. 303-312.
- Zhang, J.D., Chow, C.Y. and Li, Y. (2014b), ‘LORE: Exploiting sequential influence for location recommendations’, *Proceedings of the 22nd ACM International Conference on Advances in Geographic Information Systems (SIGSPATIAL '14)*, Dallas/Fort Worth, TX, USA, November 04-07, pp. 103-112.
- Zhang, C., Zhou, G., Yuan, Q., Zhuang, H., Zheng, Y., Kaplan, L., Wang, S. and Han, J. (2016), ‘GeoBurst: Real-time local event detection in geo-tagged tweet streams’, *Proceedings of the 39th ACM International Conference on Research and Development in Information Retrieval (SIGIR '16)*, Pisa, Italy, July 17-21, pp. 513-522.
- Zhang, C., Liu, L., Lei, D., Yuan, Q., Zhuang, H., Hanratty, T. and Han, J. (2017), ‘TrioVecEvent: Embedding-based online local event detection in geo-tagged tweet streams’, *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '17)*, Halifax, NS, Canada, August 13-17, pp. 595-604.
- Zhang, Z., Zou, C., Ding, R. and Chen, Z. (2019), ‘VCG: Exploiting visual contents and geographical influence for point-of-interest recommendation’, *Neurocomputing*, Vol. 357, No. 10, pp. 53-65.
- Zhao, S., Zhao, T., Yang, H., Lyu, M.R. and King, I. (2016a), ‘STELLAR: Spatial-temporal latent ranking for successive point-of-interest recommendation’, *Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence (AAAI-16)*, Phoenix, AZ, USA, February 12-17, pp. 315-322.
- Zhao, S., Zhao, T., King, I. and Lyu, M.R. (2016b), ‘GT-SEER: Geo-temporal sequential embedding rank for point-of-interest recommendation’, <https://arxiv.org/abs/1606.05859>.
- Zhu, J., Wang, C., Guo, X., Ming, Q., Li, J. and Liu, Y. (2019), ‘Friend and POI recommendation based on social trust cluster in location-based social networks’, *Journal on Wireless Communications and Networking*, <https://doi.org/10.1186/s13638-019-1388-2>.

