

運用知識圖於公務人員的課程推薦

謝政彥¹, 沈錫坤²

國立政治大學資訊科學系

E-mail: {109753207¹, mkshan²}@nccu.edu.tw

摘要

公務人員為推動國家政策、提升國家競爭力，本職學能必須與時俱進。但公務人員每年在職研習的時間與次數有限，因此若能透過課程推薦技術，將可協助公務人員有效地選讀相關訓練課程。然而公務人員在數十年公務生涯中，會歷經不同服務機關、職等、職務等歷練，教育程度及年齡也會改變，因此課程推薦需考慮公務人員修課時背景，包括職務相關背景及影響喜好相關背景。此外課程推薦須具備可解釋性方能有效協助公務人員理解並進行選課決策。針對商品的推薦，現已有分別考慮情境背景或具備可解釋性的推薦技術。但較少有兩者兼具的研究。本研究提出運用知識圖的公務人員研習背景課程圖，並結合長短期記憶模型的推薦模型。此模型考量公務人員歷年的公務相關背景及個人人口統計背景。經實驗顯示本論文所提出的課程推薦模型，準確率極高且具有可解釋性。

關鍵字：課程推薦、知識圖、公務人員

Abstract

In order to promote national policies and enhance national competitiveness, public servants must keep pace with the times in their professional skills. However, the time and frequency of on-the-job training for civil servants each year are limited. Therefore, if courses can be recommended through technology, it will help civil servants to effectively choose relevant training courses. However, during their decades of public service, civil servants will experience different service agencies, grades, positions, etc., and their education level and age will also change. Therefore, course recommendations need to take into account the background of civil servants, including job-related background and relevant background that affects preferences. Moreover, the general adult learning habit is to find answers through understanding, so course recommendations must be "explainable" to effectively assist civil servants in understanding and making course selection decisions. Generally, there are recommendation systems that consider context or interpretability for product recommendation, but it is not common to have both. This study proposes a Civil-servant Profile Course Graph using knowledge graph and combined with the

LSTM recommendation model. This model can take into account the decades of job-related background and personal demographic background of civil servants and make recommendations. The courses have been reviewed to be explainable and the experimental evaluation results have shown good performance.

Keywords: Recommendation System, Knowledge Graph, Course, Civil Servant

1. 緒論

公務人員任職期間會歷經不同職務，而不同的職務往往需要不同職能才能勝任。此外，為因應時代趨勢、變革與挑戰，公務人員本職學能亦必須與時俱進，如何協助公務人員在有限的學習時間，推薦研習適合的課程，深具實用價值。

公務人員課程推薦有別於大學的課程推薦，大學課程屬於正規教育，在修業年限、畢業學分、必修課程等都有規範；而公務人員訓練課程則屬於非正規教育，是針對研習需求的在職訓練，並無修業年限、畢業學分等規定。

公務人員數十年公務生涯中，會歷經不同服務機關、職等、職務等歷練，教育程度及年齡也會改變，因此課程推薦需考慮公務人員修課當時的背景，包括職務、教育程度及年齡等人口統計資料。此外，成人學習希望透過理解找到答案，課程推薦的「可解釋性」可以協助理解並進行選課決策。

現有商品推薦技術雖然分別有考慮背景(Context)或可解釋性(Explainability)的研究，但並沒有兼顧背景及可解釋性的研究。本研究主要目的在根據公務人員研習紀錄、研習當時的公務背景資料及課程基本資料，提出能滿足公務人員終身學習需求、兼顧數十年公務生涯歷練、教育程度及年齡改變，及具有可解釋性的公務人員課程推薦系統，以協助公務人員選課的決策參考。

2. 文獻研究

2.1 推薦系統

推薦系統是一種訊息過濾系統，為目標用戶提供與其相關或有興趣的項目建議。推薦系統的底層技術分為 3 大類，包括基於內容的推薦系統(Content-based Recommendation System)、基於協

¹ 現任職於行政院人事行政總處公務人力發展學院

同過濾的推薦系統(Collaborative Filtering-based Recommendation System) 及混合過濾技術 (Hybrid Filtering Technique) [1][10]。

基於內容的推薦系統主要是要發掘 User 過往感興趣的 Item 特徵，以推薦與這些特徵類似的 Item 給 User。User 喜好特徵可由其歷史交易 Item 來萃取 [1] [2][5][12]。

基於協同過濾的推薦系統是一種運用眾人智慧的推薦技術，基本想法是 User 彼此間可能有相同或類似的喜好，根據過往的喜好資料便可以用來推薦，又可分為 Memory-based 及 Model-based 的協同過濾[4]。

2.2 課程推薦

個人化的課程推薦除了可透過前述推薦系統技術外[4]，相關研究的議題還包含學習路徑[3][7][8]、學習設計[3]、以先備知能為概念的修課順序[3]、依照學習時間限制的推薦[7]等，通常需要具備領域知識的專家投入。一般推薦系統推薦出來的課程通常是以集合或 Top-N 方式排序，比較少有學習路徑、學習地圖等具有先後順序的概念。

從課程本質來看，數位學習課程在學習路徑、學習設計等議題，有較多的探討，這可能是數位學習課程比較容易拆解成不同學習單元[7]，不同學習單元間存在先備知能的關係[3]。現有研究主要在幫助大學生的選課策略，相關技術包括基於馬可夫鏈(Markov Chain)的協同過濾[6]及隨機遊走(Random Walk with Restarts)[9]。

3. 研究方法

本研究提出一個運用知識圖的公務人員研習背景課程圖(Civil-servant Profile Course Graph, CPC Graph)，結合長短期記憶模型(Long Short Term Memory, LSTM)等神經網絡，建立考量公務人員的公務背景，個人人口統計背景，並具可解釋性的公務人員課程推薦系統。

3.1 建立公務人員研習背景課程圖

本研究首先根據公務人員研習紀錄(User-Course Interactions)、學員基本資料(User Profile)及課程基本資料(Course Profile)，找出 (h, r, t) 三元組關係，其中 h, t 為不同的 Entities，而 r 則為 Entities 間的關係(Relationships)，據以建立公務人員研習背景課程圖 CPC Graph，包括 User-Profile-Course Tripartite Graph 及 Course Knowledge Graph 兩大部分(如圖 1)。




圖 1. 本研究公務人員研習背景課程圖

User-Profile-Course Tripartite Graph 運用 User 研習課程及其公務背景資料所建置。以圖 1 為例，u4 有研習課程 c1，則有 $(u4, \text{研習}, c1)$ 三元組關係，u4 節點與 c1 節點間會建立 Edge，其 Edge 是研習關係；反之亦有 $(c1, \text{被...研習}, u4)$ 三元組關係，因此 u4 與 c1 間的 Edge 是雙向的，只是 Edge 關係不同。同理，User 與其公務背景也會建立 Edge，例如 $(u4, \text{曾服務於}, \text{教育部})$ 、 $(\text{教育部}, \text{曾有部屬}, u4)$ 。此外，藉由參訓紀錄，將公務背景與課程間建立 Edge，例如 $(\text{教育部}, \text{薦送同仁參加}, c3)$ 、 $(c3, \text{被...薦送參訓}, \text{教育部})$ 。Course Knowledge Graph 則是由課程基本資料所建立的，例如 c3 適合薦任人員研習，則會有 $(c3, \text{參訓資格}, \text{薦任})$ 、 $(c3, \text{研習資格}, \text{薦任})$ 等關係；同理課程與課程的關鍵字詞亦有 $(c3, \text{關鍵字詞包括}, \text{規劃})$ 、 $(\text{規劃}, \text{屬於關鍵字詞}, c3)$ 等關係。

3.2 路徑萃取

建立 CPC Graph 之後，如果 User 節點在 CPC Graph 上可以走到某一 Course 節點，代表有機會研習這門 Course。而 (User, Course) Pair 之間通常會有多條 Paths。以圖 1 的 u4 為例，u4 曾經研習 c1 課程，在公務背景部分，u4 是「薦任」人員、在教育部及彰化縣政府服務過，透過路徑萃取， $(u4, c3)$ Pair 有多條不同的 Paths，包括 $\langle u4 \rightarrow c1 \rightarrow u2 \rightarrow c3 \rangle$ 、 $\langle u4 \rightarrow \text{薦任} \rightarrow c1 \rightarrow u2 \rightarrow c3 \rangle$ 等。以 $\langle u4 \rightarrow c1 \rightarrow u2 \rightarrow c3 \rangle$ 為例，可以解釋為 u4 與 u2 都研習過 c1，而 u2 也研習過 c3，因此推薦 c3 給 u4。這屬於 Collaborative-base 的推薦。

此外，這些 Paths 的長度包括 3、4、5、6 等，又或者更長，本研究係以長度最長為 6 來進行，以減少計算量。Path 長度若小於 6，不足部分則用 Padding 方式補足，如此確保每條 Path 的長度一致，以利於後續計算。

3.3 訓練推薦模型

本研究的推薦模型以 Wang 等學者提出 Knowledge-aware Path Recurrent Network (KPRN) 推薦模型為基礎[11]，提出 mKPRN 模型(如圖 2)。與 KPRN 模型最大不同之處在於 mKPRN 將每條 Path 經過 LSTM 產出的最後 1 個 Hidden Layer，

在進入 Fully Connected Layers 之前，先接上 User 研習課程時的人口統計背景(包括教育程度、性別及年齡)的 Embedding 資料，再做為 Fully Connected Layers 的輸入，以將人口統計背景資料納入進行模型訓練。

mKPRN 模型包括 Entity Embedding Layer, LSTM Layer, Demographic Feature Embedding Layer, Fully Connected Layer 及 Weighted Pooling Layer, 分述如下：




圖 2. 本研究提出 mKPRN 模型

Entity Embedding Layer 前述路徑萃取的每條 Path，可以表示為以 Entities 及 Relationships 為元素的序列，例如 $u4 \xrightarrow{r1} c1 \xrightarrow{r2} u2 \xrightarrow{r3} c4$ ，其中 $u4$ 、 $c1$ 、 $u2$ 及 $c4$ 是 entities， $r1$ 、 $r2$ 及 $r3$ 是 relationships。而每個 entity 都有其類型 (Entity Type)，例如 u 代表 user、 c 代表 Course。接著將 Entities、Entity types 及 Relationships 進行 Embedding，用一組可以自行定義 Dimension Size 的向量來代表。由於 Path 可以表示成 (Entity, Entity Type, Relationship) 的序，其中 Relationship 代表與下一個 Entity 的關係，例如 $(u4, user, r1) \rightarrow (c1, course, r2) \rightarrow (u2, user, r3) \rightarrow (c4, course, <end>)$ 。將 Entity、Entity Type 及 Relationship 的 Embedding 表示式接在一起 (Entity, Entity Type, Relationship) 成為 Triplet Embedding。

LSTM Layer 接著運用 LSTM 模型，將前述 Path (Entity, Entity Type, Relationship) Triplet Embedding 作為輸入資料 (如圖 3)，藉由模型的長短記憶功能，其最後一層的 Hidden Layer (h_6) 可視為 Path Embedding 資料。




圖 3. 透過 LSTM 產出路徑嵌入資料示意圖

Demographic Feature Embedding 將 User 研習 Course 時的人口統計資料，包括教育程度、性別及年齡，進行 Embedding 後連接再一起，做為其 Demographic Feature Embedding 資料，方法同 Entity Embedding Layer。

Fully Connected Layer 將 Path Embedding 資料接上 Demographic Feature Embedding 資料後，再做為 Fully Connected Layer 的輸入。

Weighted Pooling Layer 由於 (User, Course) Pair 會有多條由 User 走到 Course 的 Paths (如式子(1))，且每條 Path 經過模型計算後會得到這條 Path 的分數，因此同一 (User, Course) Pair 會有很多分數 (如式子(2))，必須經過彙整運算，才能計算出這個 (User, Course) Pair 的預測機率分數 $\hat{y}_{(u,c)}$ (如式子(3)、(4))。本研究參考 Wang 等學者的 Weighted Pooling 方法[11]，其中 γ 超參數 (Hyperparameter) 控制指數權重，得以將分數高的 Path 賦予更高的權重。mKPRN 模型的輸入是 User-Course 組合中的路徑，其輸出則是這個 User-Course 組合的機率分數，分數越高代表這位 User 研習這門 Course 的機率越大。此外，mKPRN 模型不僅考慮每條路徑的分數外，路徑數越多，代表走到的機會越高。

$$P_{(u,c)} = \{p_1, p_2, \dots, p_n\} \quad (1)$$

$$S_{(u,c)} = \{s_1, s_2, \dots, s_n\} \quad (2)$$

$$g(s_1, s_2, \dots, s_n) = \log \left[\sum_{i=1}^n \exp \left(\frac{s_i}{\gamma} \right) \right] \quad (3)$$

$$\hat{y}_{(u,c)} = \sigma(g(s_1, s_2, \dots, s_n)) \quad (4)$$

3.4 產出推薦課程

本研究提出的 mKPRN 模型訓練完成後，透過 User 在公務人員研習背景課程圖的隨機遊走，可以找到 User 走到不同 Courses 的路徑，如果走到某門 Course 的路徑存在，即可計算 User 研習這門 Course 的機率分數。將研習 Course 機率分數自高排到低，藉此即可推薦 top-K 的課程。再透過分析不同路徑的分數及公務人員研習背景課程圖上的領域知識，即可理解系統推薦課程的含意，達成其可解釋性。

4. 實驗設計

4.1 資料集

本研究以行政院人事行政總處公務人力發展學院 (以下簡稱人力學院) 2001 至 2019 年公務人員研習資料，包括 141,235 位公務人員、913 門研習課程及 730,681 筆研習紀錄。考量人力學院係以年度訓練計畫的辦訓型態，本研究將課程研習紀錄依照年度分成訓練資料及測試資料：

- (1) 訓練資料：2001~2018 年 (137,501 Users、695,004 Interactions)
- (2) 測試資料：2019 年 (20,893 Users、33,427 Interactions)

4.2 實驗步驟

Build CPC Graph 本研究建構之公務人員研習背景課程圖 CPC Graph 之 Entities 及 Edges 數量如表 1，其中課程基本資料種類包括課程類別、關鍵字詞、研習對象等，而學員基本資料種類包括官等、職等、主管機關、中央或地方、主管或非主管、人事或非人事人員等。

CPC Graph	數量
Entities	143,123
• Courses	913
• Users	141,235
• 課程基本資料種類	772
• 學員基本資料種類	113
• 主管機關	90
Edges	3,821,764

表 1. CPC Graph 實體及邊之數量一覽表

路徑萃取以隨機抽樣方式，分別由 Training Data 抽取 9,803 名 Users (按：分別隨機抽取後合併，扣除重複，實際 9,803 名)；由 Testing Data 隨機抽取 500 名 Users 進行路徑萃取 (Path Extraction)，以 Depth-First-Search 方法在 CPC Graph 上進行 Random Walk，Path Length 介於 3 至 6 間。本研究以 Negative Interactive Sampling 分別進行模型訓練及評估。模型訓練的取樣是 1 門有研習的課程 (1 Positive)，搭配 4 門 Path 可以走到但沒有研習的課程 (4 Negatives)，以避免 Negatives 過多造成資料 Imbalance。在模型評估時，以抽樣的 User 在 2019 年有研習的課程，逐一與 2019 年 Path 可以走的課程 (> 100 Negatives) 進行模型評估。

訓練 mKPRN 模型 本研究採用 PyTorch 的 Embedding、LSTM 及 Linear 方法，其中 Entity、Entity Type 及 Relationship 的 Embedding Dimension 分別設為 64、32 及 32，Concatenate 後的 Dimension 為 128。另教育程度、性別及年齡之 Embedding Dimension 分別設為 3、1 及 6，Concatenate 後的 Dimension 為 10。每個 Input (Entity, Entity Type, Relationship) 輸入 LSTM 後，產出 Hidden Layer，其 Dimension 設為 256。將這 Hidden Layer 接上 Demographic Feature Embedding 資料，再連接兩個 Fully Connected Layers。第 1 層 (266, 256) 採用 ReLU 作為 Activation Function，第 2 層 (256, 2) 計算 Score 值作為 Pooling Layer 的輸入。L2 Regularization Coefficient 0.0001。損失函數 (Loss Function) 採用 Negative Log Likelihood Loss，藉此當機率越大接近於 1 時，則函數整體值越接近於 0，即使得損失函數取到最小值；損失函數如公式(5)。學習優化器 (Optimizer) 採用 Adam 優化器。

$$L = -\sum_{(u,i) \in O^+} \log \hat{y}_{ui} + \sum_{(u,j) \in O^-} (1 - \log \hat{y}_{uj}) \quad (5)$$

$$O^+ = \{(u, i) | y_{ui} = 1\}$$

$$O^- = \{(u, j) | y_{uj} = 0\}$$

4.3 模型評估

本研究以矩陣分解 (Matrix Factorization, MF) 的推薦技術做為 Baseline，訓練出來的 mKPRN 模型評估依推薦課程的機率分數，自高到低排序，看在 Top-K 的範圍內是否能推薦出 User 真正參加的研習課程，相關評估方法說明下：

hit@K 以 User 在 2019 年有研習的課程，逐一與 2019 年 Path 可以走的課程 (> 100 Negatives) 進行 top-K 推薦評估， $1 \leq K \leq 10$ ，如果這門課程出現在 top-K 的推薦課程裡，即給 1 分，反之 0 分。

ndcg@K 取樣方式同前，不同的是 ndcg (Normalized Discounted Cumulative Gain) 考慮有修過的課程，出現在 Top-K 推薦課程的位置。

mAP@K 將 User 在 CPC Graph 走得到的課程均計算其機率分數，並自高到低排序，再看 Top-K 的推薦課程中，User 是否有參加研習，以計算其 mAP (mean Average Precision)。另運用相同計算原則計算 mAR@K (mean Average Recall)，再藉由兩者計算 mAF1@K (mean Average F1)。

4.4 實驗結果

本研究提出之推薦模型 mKPRN，在固定 Learning Rate 0.002、不同 Batch Size (32, 64, 128, 256) 條件下，其 Training Loss 均收斂得很快 (如圖 4)。在完成第 2 個 Epoch 訓練時即降到 8.5E-05 以下。為了驗證人口統計資料對推薦效果的影響，本研究接著實驗比較不含人口統計資料的推薦模型 mKPRN⁻，發現其訓練損失值雖隨著 Epoch 數的增加而下降，惟仍高於 0.18。




圖 4. 不同 mKPRN 訓練模型在不同 Epoch 的 Training Loss 折線圖

再檢視 Validation Loss 的表現，本研究提出之推薦模型 mKPRN，在固定 Learning Rate 0.002、不同 Batch Size，其驗證損失值雖未隨著訓練 Epoch 數的增加而持續下降，然而均低於 0.056。為了驗證人口統計資料對推薦效果的影響。本研究接著實驗不含人口統計資料的推薦模型

mKPRN⁻，其驗證損失值除未隨著訓練 Epoch 數的增加而持續下降，且均高於 0.25。

模型評估

hit 本研究 hit@K 的評估係以 User 在 2019 年有研習的課程，逐一與 2019 年 Path 可以走的課程 (> 100 Negatives) 進行 top-K 推薦評估， $1 \leq K \leq 10$ ，只要這門有修過的課程出現在 top-K 的推薦課程裡，即給 1 分，反之 0 分。本研究提出之推薦模型 mKPRN，在 $K=1$ 時 hit@K 約 0.76，自 $K=5$ 開始，其值即可達 1，相較於作為 Baseline 的 Matrix Factorization，其 hit@K 則不足 0.3，本研究提出之推薦模型 mKPRN 明顯優於 Baseline。為了驗證人口統計資料對推薦效果的影響，本研究接著實驗比較不考慮人口統計資料的推薦模型 mKPRN⁻，在 $K \leq 9$ 時略高於 Baseline 的 Matrix Factorization，僅在 $K=10$ 時，只有 Batch Size 128 及 256 的模型略低於 Matrix Factorization。茲以 Batch Size 32 訓練出來的 mKPRN 及 mKPRN⁻ 模型為例，其與矩陣分解之 Baseline，在 hit@K 的評估表現比較圖如圖 5。




圖 5. mKPRN、mKPRN⁻ 及 MF 之 hit@K 評估比較圖 (以 Batch Size 32 為例)

ndcg 在 ndcg@k 部分，本研究同樣以 User 在 2019 年有研習的課程，逐一與 2019 年 Path 可以走的課程 (> 100 Negatives) 進行 top-K 推薦評估， $1 \leq K \leq 10$ ，不同的是要考慮有修過的課程，出現在 top-K 推薦課程的位置。本研究提出之推薦模型 mKPRN 在 $K=1$ 時 ndcg@K 約 0.76，自 $K=4$ 開始，其值即可達 0.9，相較於作為 Baseline 的 Matrix Factorization，其 ndcg@K 則不足 0.13。本研究提出之推薦模型 mKPRN 明顯優於 Baseline。為了驗證人口統計資料對推薦效果的影響，本研究接著實驗比較沒有人口統計資料的推薦模型 (mKPRN⁻)，其 ndcg@k 均略高於 Matrix Factorization，但仍低於 mKPRN。茲以 Batch Size 32 訓練出來的 mKPRN 及 mKPRN⁻ 模型為例，其與 Matrix Factorization 之 Baseline，在 ndcg@K 的評估表現比較圖如圖 6。




圖 6. mKPRN、mKPRN⁻ 及 MF 之 ndcg@K 評估比較圖 (以 Batch Size 32 為例)

mAP 本研究將 2019 年 User 在 CPC Graph 可以走的到的課程，利用訓練出來的 mKPRN 模型 (Epoch = 10, Batch Size = 128, Learning Rate = 0.002) 計算研習課程機率分數，並自高到低排序，再看 Top-K 的推薦課程中，User 是否有真正參加研習，計算其 mAP@。並運用相同計算原則計算 mAR@K，藉由兩者計算 mAF1@K。本研究提出之推薦模型 mKPRN，mAR@K 在 $K=1$ 時有高達於 0.78 的表現 (如圖 7)。隨著 K 值變大 mAR@K 逐漸下降，這是因為公務人員每年來人力學院研習，以 1 至 2 門課程為主，因此 K 值變大時，分母 (K 值) 變大同時，分子 (研習課程數) 增幅有限所致。mAR@K 則隨著 K 值變大而上升，惟 K 值大於 3 以後增幅有限。mAF1@K 介於兩者之間，亦隨著 K 值增加而下降。




圖 7. mKPRN 模型在 mAP@K、mAR@K 及 mAF1@K 的評估表現折線圖 (以 Batch Size 128 為例)

推薦課程可解釋性 本研究提出 mKPRN 模型係以 CPC Graph 上的路徑萃取作為模型的輸入，透過 Path 的解析，有助於解釋系統為何推薦這門課程。茲以代碼 u036777 之 Query User 為例，mKPRN 推薦的課程是代碼 1009058 之「高階領導交流」(如圖 8)，其 2019 年之公務背景為在教育部服務、簡任第 11 職等、主管、非人事人員、曾在行政院服務過、歷任薦任官等，人口統計背景為碩士畢業、女性及年齡 47 歲等。透過在 CPC Graph 路徑萃取，可以找到 (u036777, 1009058) Pair 間存有不同 Path，舉例說明如下：

- 與 Query User 同樣曾在「行政院」服務的 u134336，研習過「卓越管理」，「卓越管理」在人力學院分類屬於「領導力發展」課程，「領導力發展」課程還有「高階領導交流」，因此系統推薦這門課給 Query User。
- Query User 是「第 11 職等」，「第 11 職等」的同仁曾研習「危機處理」，「危機處理」在人力學院分類屬於「領導力發展」課程，「領導力發展」課程還有「高階領導交流」，因此系統推薦這門課給 Query User。

由本例可知，推薦模型 (mKPRN) 可以綜合考量 Query User 的服務機關 (教育部、行政院)、職等 (第 11 職等) 等公務背景資料，以及課程知識圖的資訊 (人力學院分類、終身學習分類、關鍵字詞等)，加上其碩士畢業、女性及年齡 47 歲等因素，進而推薦「高階領導交流」。




圖 8. 以 CPC 圖檢視推薦課程的解釋性範例

5. 結論與未來研究

本研究透過公務人員研習紀錄、公務背景資料及課程基本資料，提出 mKPRN 模型，將公務人員研習背景課程圖 CPC Graph，與修正 LSTM 輸出之神經網絡結合，除能將公務人員數十年的公務背景及人口統計背景納入考量外，並透過路徑解析，理解課程推薦的可解釋性。本研究提出之 mKPRN 模型評估結果，包括 hit@K、ndcg@K 及 mAP@K 等，都有很好的表現。

再比較沒有人口統計資料的推薦模型 mKPRN⁻，其 hit@K 及 ndcg@K 等表現雖大多略高於 Baseline，惟仍遠低於本研究提出之 mKPRN 模型，顯見人口統計資料扮演重要角色。

鑑於本研究提出之 mKPRN 模型可以考量公務背景資料，以及人口統計背景資料，未來可以讓模型進一步預測 User 背景資料的變化或以互動方式讓 User 輸入期望未來背景資料的變化，如此即有機會為 User 自動產出課程地圖，協助公務人員預為安排適當時間研習相關課程。

6. 參考文獻

- [1] L. Anitha, M. K. Devi, and P. A. Devi, A Review on Recommender System. International Journal of Computer Applications, Vol. 82, No. 3, 2013.
- [2] D. V. Bagul, and S. Barve, A Novel Content-based Recommendation Approach Based on LDA Topic Modeling for Literature Recommendation. IEEE 2021 6th International Conference on Inventive Computation Technologies (ICICT), 2021.
- [3] G. Durand, N. Belacel, and F. LaPlante, Graph Theory Based Model for Learning Path Recommendation. Information Sciences, Vol. 251, 2013.
- [4] D. B. Guruge, R. Kadel, and S. J. Halder, The State of the Art in Methodologies of Course Recommender Systems—A Review of Recent Research. Data, Vol. 6, No. 2, 2021.
- [5] U. Javed, K. Shaukat, I. A. Hameed, F. Iqbal, T. M. Alam, and S. Luo, A Review of Content-based and Context-based Recommendation Systems. International Journal of Emerging Technologies in Learning (iJET), Vol. 16, No. 3, 2021.
- [6] E. S. Khorasani, Z. Zhenge, and J. Champaign, A Markov Chain Collaborative Filtering Model for Course Enrollment Recommendations. 2016 IEEE International Conference on Big Data, 2016.
- [7] A. H. Nabizadeh, D. Goncalves, S. Gama, J. Jorge, and H. N. Rafsanjani, Adaptive Learning Path Recommender Approach Using Auxiliary Learning Objects. Computers & Education, Vol. 147, 2020.
- [8] A. H. Nabizadeh, J. P. Leal, H. N. Rafsanjani, and R. R. Shah, Learning Path Personalization and Recommendation Methods: A Survey of the State-of-the-art. Expert Systems with Applications, Vol. 159, 2020.
- [9] A. Polyzou, A. N. Nikolakopoulos, and G. Karypis, Scholars Walk: A Markov Chain Framework for Course Recommendation. The 12th International Conference on Educational Data Mining (EDM), 2019.
- [10] S. Sharma, V. Rana, and M. Malhotra, Automatic Recommendation System Based on Hybrid Filtering Algorithm. Education and Information Technologies, Vol. 27, No. 2, 2022.
- [11] X. Wang, D. Wang, C. Xu, X. He, Y. Cao, and T. S. Chua, Explainable Reasoning over Knowledge Graphs for Recommendation. The AAAI conference on artificial intelligence, Vol. 33, No. 1, 2019.
- [12] M. Wijewickrema, V. Petras, and N. Dias, Selecting a Text Similarity Measure for a Content-based Recommender System: A Comparison in Two Corpora. The Electronic Library, Vol. 37, No. 3, 2019.
- [13] Y. Zhang, and X. Chen, Explainable Recommendation: A Survey and New Perspectives. Foundations and Trends in Information Retrieval, Vol. 14, No. 1, 2020.