

運用子群組探勘技術之智慧學習推薦系統於護理教育中的應用與滿意度評估

Design and Empirical Evaluation of a Subgroup Mining–Based Personalized Learning

Recommendation System in Nursing Education

張韶宸^{1*}, 謝閔元²

^{1,2} 元智大學 資訊傳播研究所

*changsc@saturn.yzu.edu.tw

【摘要】 在過去的護理學科教學中，學生經常面臨兩個核心問題，包含對自身學習問題的理解程度不足，以及自我學習安排能力有限。在此情況下，當學生接觸到大量學習資訊時，往往缺乏有效的判斷與篩選能力，導致難以針對自身不足進行有效的學習與補強。因此，根據學生的學習狀況給予個人化的學習引導是當前教育環境中重要的議題。此外，醫療衛生教育的教學模式仍以傳統教育為主，需要投入大量人力與時間來評估學生的學習效果。子群組探勘是一種具高度彈性的機器學習與資料探勘方法，旨在從資料集中發掘具有顯著特徵或行為模式的特定子群。該技術已廣泛應用於醫學、市場研究、生物學及社會科學等領域，能有效揭露資料中潛藏的模式與關聯性，子群組探勘重於分析資料中與使用者關注之目標變數相關的有趣關係，藉此探索不同個體或群體間的特性差異。本研究的目標在於建構一套基於子群組探勘技術的新型學習系統，探討此方法對於護理學生的系統滿意度，以解決傳統學習方法在學習成效評估與個別化學習建議上的限制。

【關鍵字】 推薦系統、子群組探勘、資料探勘

Abstract—In traditional nursing education, students often encounter two fundamental challenges: an insufficient understanding of their own learning difficulties and limited ability to effectively plan and manage self-directed learning. Under such circumstances, when students are exposed to a large volume of learning materials, they frequently lack the capacity to critically evaluate and filter information, which in turn hinders their ability to address personal learning deficiencies in a targeted and effective manner. As a result, providing personalized learning guidance based on students' individual learning conditions has become a critical issue in contemporary educational environments. Furthermore, teaching models in medical and healthcare education remain predominantly traditional, requiring substantial human resources and time to assess students' learning outcomes. This reliance on manual evaluation limits the scalability and efficiency of instructional support. To address these challenges, this study proposes a nursing learning recommendation system based on subgroup discovery. Subgroup discovery is a flexible machine learning and data mining approach that aims to identify specific subgroups within a dataset that exhibit statistically significant characteristics or behavioral patterns. This technique has been widely applied in fields such as medicine, market research, biology, and social sciences, where it effectively uncovers latent patterns and meaningful associations within data. Unlike global modeling approaches, subgroup discovery focuses on identifying interesting relationships between data attributes and user-defined target variables, thereby enabling the exploration of characteristic differences among individuals or groups. The objective of this study is to develop a novel learning system grounded in subgroup discovery techniques to overcome the limitations of traditional learning methods in learning performance evaluation and personalized learning recommendations.

Keywords: Recommendation system, Subgroup discovery, Data mining

1.前言

在目前的護理學習環境中，學生上課和參加考試的方式仍然比較僵化(Kermansaravi et al.,2015)，並且缺少一些基於科技的創新和變革(Benner et al., 2009; Kermansaravi et al., 2015)。由於流行病期間對醫療照護人力的高度需求，加上師資人力不足與實體教學受限，以及在非流行病時期學生於課堂中所學習的知識往往需要持續更新以因應時代變遷。而現行教科書亦難以跟上醫療照護知識的快速發展，使得護理教學領域進行教學模式革新的需求已不容忽視。隨著數位學習的發展，醫療照護教育亦逐漸呈現由傳統教學轉向線上學習(Kavanagh,2021)與自我導向學習活動(Lalitha & Sreeja, 2020)的趨勢。與此同時，過去的研究指出學生在進行線上學習時，往往需要指導或回饋來獲得即時的學習支援，避免學生迷失學習方向(Michel et al., 2021)。推薦系統是自學網站中最常使用的學習回饋形式之一(De Medio et al., 2020)，此方法也在數位學習領域也得到了廣泛應用(Zhang et al.,2021)。因此，如何提供學生有效的推薦結果，是目前學者關注的問題

過去的研究採用 K 近鄰演算法進行推薦，該演算法基於學生的過往表現推薦其未來應修讀的課程，並根據學生的程度調整課程難度(Mondal et al.,2020)。然而，該系統難以判斷學生在先驗知識方面有哪些不足之處。另一方面，也有學者嘗試將 K 均值聚類和 Apriori 演算法應用於推薦和決策的判斷(Lalitha & Sreeja, 2020)，以改善推薦結果不完善之問題。此外，透過應用子群組探勘演算法(Pieters et al., 2010)，可以有效地發現學習單元和學習群體之間的關係，並利用先前收集的數據對預建模型進行調整，從而避免冷啟動問題(Talaghzi et al., 2023)。然而，現有研究仍較少針對學生知識缺口辨識與可解釋之學習單元推薦進行整合性探討。故本研究旨在運用子群組探勘方法，建立能同時辨識學生能力不足、連結學習單元特徵，並提供具解釋性推薦依據的學習推薦機制，以補足現有研究在診斷性與教學應用面向上的不足。

2.文獻綜述

2.1.學習型推薦系統

為因應資訊量快速成長所導致的資訊過載問題，推薦系統逐漸成為一項重要且必要的解決方案。其核心概念在於透過分析使用者的歷史行為資料與偏好特徵，建立相應的推薦模型，並自動產生符合使用者需求的推薦結果，最終為每位使用者提供具個人化特性的推薦清單(El Idrissi et al., 2023)。推薦系統不僅能根據使用者已明確表現出的偏好推薦相關內容，亦能挖掘使用者尚未直接表達的潛在興趣，進而推薦可能具有吸引力的新項目(Talaghzi et al., 2023)。透過有效識別使用者的潛在需求，並自大量可選項目中篩選出最具相關性的內容，推薦系統能在一定程度上緩解資訊過載所帶來的認知負擔與決策困難 (Mu, 2018)。在實際教學應用中，不同學科亦展現出學習推薦系統的多樣化運用方式。例如，在數學學習情境中，Dai et al.(2024)設計了一套數學測驗推薦系統，根據學生的作答歷程與能力表現推薦合適的練習題目，並進一步提供推薦理由與學習解釋。研究結果顯示，具解釋性的推薦不僅能提升學生的學習成效，亦有助於學生理解自身學習狀態，顯示推薦系統可作為課堂與課後差異化學習的重要支援工具。另一方面，在外語學習領域，Xia et al.(2024)則透過分析學習者於數位學習平台中的大量行為資料，動態調整學習內容與學習路徑，實現個人化外語學習歷程。其研究指出，透過推薦系統所建構的個人化學習路徑，有助於提升學習投入程度與學習效率。

然而，學習推薦系統的效能高度依賴模型是否能即時反映學習者狀態的變化。相關研究指出，為維持推薦結果的準確性與穩定性，模型需整合學習者的歷史學習資料與近期學習行為，以提升推薦之個人化程度與適切性(Talaghzi et al., 2023)。因此，如何從使用者行

為與學習資料中有效萃取並建構具判別力的特徵，以支援個人化學習推薦系統的設計與實作，已成為當前相關研究的重要核心議題。

2.2.子群組探勘

子群組探勘是一種資料探勘方法，主要用於識別與特定目標變數高度相關且具有代表性的顯著模式或規則(Herrera et al., 2011)。在教育資料探勘領域中，隨著公開資料集的增加，相關方法被廣泛應用於學習行為分析與學習模式發現 (Mihaescu & Popescu, 2021)。與傳統分類或預測模型不同，子群組探勘並非以整體資料的預測準確率為唯一目標，而是著重於發現資料集中某些具特定特徵的子群體，並描述這些子群體在目標變數上的顯著行為表現。此一技術的核心特色在於同時結合了預測歸納與描述歸納的特性，使其不僅能指出「哪些條件與結果有關」亦能清楚說明「在什麼樣的情境或條件下」該結果特別明顯(Atzmueller & Puppe, 2006)。具體而言，子群組探勘的目標在於找出一組可解釋的規則，用以描述整體資料中的特定子集。這些子集必須同時滿足兩項關鍵條件：其一，子群體在樣本數量上需達到一定規模，以避免僅反映個別或偶然現象；其二，該子群體在目標變數上的表現需具有統計顯著性，亦即其行為或結果與整體母體存在明顯差異(Lavrač et al., 2004)。透過此種方式，子群組探勘能在兼顧可解釋性與實用價值的情況下，協助研究者或系統設計者深入理解資料中潛藏的結構與規律。在教育科技與學習分析的研究中，資料探勘方法常被用於分析學習者在數位學習環境中所留下的行為資料，以探索不同學習者群體在學習行為與學習成果上的差異。例如，(Romero & Ventura, 2020)指出，教育資料探勘技術可透過分析學習平台中的行為資料來發現具有代表性的學習模式與學習者群體；而(Luna et al., 2022)則在 MOOC 學習資料中運用子群組探勘方法，從大量學習行為紀錄中識別出不同類型的學習者子群體，並以可解釋的規則描述其學習參與與互動模式。這些研究顯示，透過資料探勘方法識別學習者子群體，有助於理解學習行為模式，並為個人化學習支持與學習推薦系統的設計提供重要依據。

3. 基於子群組探勘技術的護理學科學習推薦系統

3.1.資料預處理

為評估此推薦系統之有用性與易用性，本研究邀請 47 位參與者參與此研究活動，作為研究數據資料收集來源之對象。所有參與者皆具有三年以上護理相關學科的學習背景，平均年齡為 22 歲。本研究與兩位具有多年教學經驗的護理教師，根據教學內容設計了 50 題測驗題，其內容涵蓋了兒科護理的所有主題。同時，本研究將所有題目根據答案和選項的特徵進行分類。例如，題目是「關於缺鐵性貧血並需要注射治療」，那麼題目會根據關鍵字(例如血液、藥物和診斷等)給出該題目的特徵值，題目也會給出關鍵字的特徵值。

BloodCare Diagnosis CoMedication	BloodCare Nursing	BloodCare Nursing	Parenting	Nursing Parenting
No. 1	No. 2	No. 3	No. 4	No. 5

圖 1. 問題單位的特徵值

在賦予每道問題特徵值後，學生的答題結果會根據問題與選項的特徵值累計，提供對應的學習結果歸因，進而作為後續推薦學習內容使用。例如，如果學生第一題答錯，則血液、診斷和藥物特徵值的計數器加一。根據上述規則，每位學生的答案狀態如圖 2 所示。此外，本研究將兒科護理主題分為 13 個類別，然後根據每位學生的答案情況統計數據，對每位學生在每個特徵值上的答案情況進行評分。

	Symptoms	Diagnosis	Nursing	CoMediation	BloodCare	Parenting	Development	BehaviorObservation	Testing	NervousSystem	Newborn	Preterm	InfectiousDiseases
H091221	3	7	4	3	2	3		1	1	3	1		1
H091231	6	5	4	2	1	2		2		2	2	1	2
H091241	3	6	5	1	2	2		1	1	3	2		1
H091254	4	5	5	1	3	1	2	1	2	2	1		3
H091266	4	3	3	3	1						1		4
H091276	4	3	1		2	1		2				1	2
H091277	6	5	3	2	2	2	2	2		3			4
H091291	9	7	9	5		2	5	2	3	5	3	3	7
H091295		1	1								1		
H091301	10	8	7	4	1	1		2	1	3	3	1	7
H091306	2	3	3							2	4		
H091314		1	1	1			1		1				1
H091321	3	4	5	1	1					2	4		2
H091330	1	3			1	1	3	2	1				

圖 2.個別學生的回覆情況

根據所有學生的錯誤數量總計，將錯誤數量將學生分為三個等級：得分高於 75%的考生為 1 級(優秀)，得分低於 75%的考生為 2 級(良好)，得分高於 50%的考生為 3 級(尚可)，得分低於 50%的考生為 4 級(有待加強)。

3.2.推薦系統模型構建

在進行推薦之前，本研究預先設定目標概念，並採用加權相對精度（Weighted Relative Accuracy, WRAcc）作為子群組探勘的評估指標。WRAcc 為子群組探勘中常用的評估方法，其特點在於同時考量子群組的涵蓋比例以及子群組內目標事件發生率與整體資料之間的差異，能有效找出具有代表性的子群組模式。相較於僅依賴準確率或信賴度的評估方式，WRAcc 可避免因子群組樣本數過小而造成的偏差。因此，具有較好的穩定性與解釋性（Gómez-Bravo et al., 2025）。在本研究中，以答題狀況作為目標特徵值，其分析結果如圖 3 所示。

15 subgroups found; target table = en one; quality measure = WRAcc; target value = 3.0

Nr.	Depth	Coverage	Quality	Probability	Positives	p-Value	Conditions
1	1	22	0.162517	0.772727	17	-	Diagnosis = '3.0'
2	1	15	0.162064	0.933333	14	-	Preterm = '3.0'
3	1	20	0.159348	0.8	16	-	InfectiousDiseases = '3.0'
4	1	22	0.14124	0.727273	16	-	Totalscore = '3.0'
5	1	15	0.140788	0.866667	13	-	CoMediation = '3.0'
6	1	20	0.138072	0.75	15	-	Nursing = '3.0'
7	1	13	0.116342	0.846154	11	-	BehaviorObservation = '3.0'
8	1	19	0.104572	0.884211	13	-	BloodCare = '3.0'
9	1	20	0.095518	0.65	13	-	Newborn = '3.0'
10	1	14	0.064735	0.642857	9	-	Parenting = '2.0'
11	1	19	0.062019	0.578947	11	-	NervousSystem = '3.0'
12	1	22	0.056134	0.545455	12	-	Development = '3.0'
13	1	23	0.04708	0.521739	12	-	Testing = '3.0'
14	1	17	0.037574	0.529412	9	-	Parenting = '3.0'
15	1	9	0.024898	0.555556	5	-	NervousSystem = '2.0'

圖 3. CORTANA 操作結果

此統計數據表明，將症狀指定為目標概念且目標值設為 3.0(需要加強)的學生，在診斷、新生兒和傳染病方面也表現出較高的加強相關性。透過指定不同的單元作為目標概念，設定目標值設為 3.0，然後取每個特徵值下需要加強的子組的前三個特徵值作為判斷基準，經過多次計數後，最終得到統計結果圖。

根據統計結果，在所有目標特徵值中，診斷是最常被提及的特徵值，其次護理、症狀和藥物，其餘相關性較低的參數則根據學生在該科目的表現進行優先排序。如果學生在該科目表現不佳，則該科目會優先推薦。基於上述分析結果，本研究進一步據此建構學習推薦系統模型，並將相關演算法與推薦邏輯實作於系統架構中。最終，該模型整合至網頁式學習平台，提供學習者即時且個人化的學習建議，以支援其後續學習規劃與能力提升。系統介面如圖 4 所示。介面右上角設有進度條，用以即時顯示學生作答的完成進度；每一題目均提供四個選項，供學生進行選擇。

6 out of 10 questions answered

小兒護理學推薦系統

此系統致力於幫助學生學習小兒護理學並且快速總結薄弱點以及優先複習清單以幫助學生在學習的道路上更有效率更完整。每題得分，共50題。

1. 小華，7歲，罹患重症型β-海洋性貧血，定期接受輸血治療，有關其外觀的視診結果，下列敘述何者錯誤？
 - ☐ (A) 面色蒼白
 - ☐ (B) 四肢末端
 - ☐ (C) 嘴唇、指尖
 - ☐ (D) 眼結膜大
2. 有關特發性血小板減少症(ITP)的照護，下列敘述何者錯誤？
 - ☐ (A) 生活所需藥物需注意安全，預防受傷引起出血
 - ☐ (B) 一旦發覺時，儘快給予Aspirin以清潔
 - ☐ (C) 避免感冒，必要時可給與解熱性止痛
 - ☐ (D) 血小板低於10,000/ μ l時，只應進行靜脈活動
3. 下列何種血液疾病是屬於性聯遺傳？
 - ☐ (A) 陣發性溶血性貧血(paroxysmal nocturnal hemoglobinuria)
 - ☐ (B) 再生不良性貧血(aplastic anemia)

圖 4.兒科護理建議系統界面

當學生完成作答並提交答案後，系統將自動進行學習表現分析，如圖 5 所示，呈現學生於各學習模組中的熟悉程度。系統會根據學習推薦系統模型之分析結果，針對學生的學習狀況產生個人化的複習建議，並依其優先順序進行排序呈現。透過此介面設計，學生能清楚掌握自身在不同學習模組中的能力表現，並依據系統所提供的推薦順序進行後續複習，以提升學習效率與學習成效。




圖 5.學生的測驗結果與弱點分析推薦

4.研究方法

4.1 參與對象

本研究邀請 47 位參與者參與此研究活動，作為研究數據資料收集來源之對象。所有參與者皆具有三年以上護理相關學科的學習背景，平均年齡為 22 歲。參與者在學習前已經學習過相關學科內容，但參與者皆未使用過學習推薦系統。

4.2 研究流程

本研究之研究流程可概分為六個主要階段，首先，研究團隊與具多年教學經驗之護理專業教師共同討論課程內容，依據兒科護理核心主題設計測驗題目，並建立題目與選項之特徵分類架構。此階段主要目的在於確保測驗內容能全面涵蓋課程重點，並作為後續學習分析與推薦系統建構之基礎。

第二階段為資料蒐集與前處理。研究邀請具護理相關學習背景之學生參與測驗，學生透過學習系統完成測驗作答後，系統即蒐集其作答結果。研究者依據題目與選項所對應之特徵值，將學生的作答狀況轉換為結構化資料，並透過特徵值計數方式，累計各學習單元與能力指標的錯誤次數，以建立個別學生的學習表現輪廓。

第三階段為學習表現評分與分級。研究依據學生在各特徵值下的錯誤情形進行統計，並將學生於各兒科護理主題的學習表現轉換為量化分數。根據整體測驗結果，進一步將學生的學習表現區分為不同等級，以反映其在各學習單元中的熟悉程度，作為推薦系統判斷學習需求的重要依據。

第四階段為子群組探勘與推薦模型建構。本研究預先設定目標概念，並以加權相對精度（Wracc）作為子群組評估指標，針對不同學習單元設定需要加強之目標值，進行子群組探勘分析。透過比較各特徵值於不同目標概念下的關聯程度，辨識出與學習表現不足高度相關之學習特徵，並據此建立學習推薦規則。

第五階段為推薦系統實作與介面呈現。研究將所建構之推薦模型整合至網頁式學習平台中，學生完成測驗後，系統即自動分析其學習狀況，並以視覺化方式呈現各學習模組之熟悉程度。同時，系統依據推薦模型之判斷結果，產生個人化的學習建議與複習順序，協助學生規劃後續學習方向。

最後一階段為使用者回饋蒐集與系統評估。學生完成系統使用後，研究透過問卷方式蒐集其對學習系統之有用性與易用性回饋，以作為評估本研究所提出之學習推薦系統成效的重要依據，並提供後續系統優化與研究延伸之參考。

4.3 研究工具

本研究所使用之研究工具包含測驗題目、學習推薦系統以及使用者回饋問卷三個部分。首先，測驗題目係依據兒科護理課程之核心學習內容，由研究團隊與具教學經驗之護理專業教師共同設計。測驗題型以選擇題為主，並針對每一題目與選項建立對應之特徵分類，以利後續學習表現分析與推薦模型建構。其次，學習推薦系統為一套網頁式學習平台，整合子群組探勘演算法以進行學習分析。系統以學生之測驗作答結果作為輸入資料，透過加權相對精度（Weighted Relative Accuracy, WRAcc）指標進行子群組評估，辨識與學習表現不足高度相關之學習特徵，並依據探勘結果產生個人化之學習建議。最後，為評估學習推薦系統之使用成效，本研究於系統使用後以問卷方式蒐集學生回饋。問卷內容主要涵蓋系統之有用性與易用性兩個構面，以了解學生對所提出學習系統之整體使用感受與滿意程度。

五.結果

本研究在台灣某大學的兒科護理課程中進行了一項實驗。學生可以使用該學習系統進行測試。測驗結束後，學生將根據其對護理課程的理解程度來了解自己的最佳和最差表現。學習系統使用完畢後，我們對學生進行了問卷調查。問卷共包含 22 題，採用李克特量表進行分級選擇。第 1 至 10 題檢視學生對學習模式的滿意度，第 10 至 22 題考察系統的適用性與易用性；在系統適用性與易用性分數中，第 10 至 15 題檢視學習系統的認知有用性，第 16 至 22

題檢視學習系統的認知易用性。我們採用的李克特量表將「非常同意」評為 5 分，將「非常不同意」評為 1 分，Cronbach's α 為 0.89。在學習模式滿意度調查中，「我覺得使用這種學習模式比以前的學習方法更具挑戰性和趣味性」這個選項的平均得分最高，為 4.68 分。在學習系統感知有用性方面，「這種學習方法(或系統)提供的學習機制使我的學習過程更加順暢」這個選項的平均得分最高，為 4.56 分。學習系統易用性方面，「學習系統的操作並不難」這個選項的平均得分也最高，為 4.56 分，為 4.5 分。「我覺得這種學習方式比以前的學習方法更具挑戰性和趣味性。」該項得分平均最高，為 4.68 分。在學習系統感知有用性方面，「這種學習方法(或系統)提供的學習機制使我的學習過程更加順暢」這一問題的平均得分最高，為 4.56 分。學習系統易用性方面，「學習系統的操作並不難」這個問題的平均得分也最高，為 4.56 分。該項得分最高，為 4.5 分。

六.結論

本研究提出了一個專為兒科護理專業學生設計的自評能力平台，該平台專注於個人化學習，並推薦學生應該學習的薄弱模組。研究結果表明，學生對該平台的易用性非常滿意平台易用性。該平台的一大優勢在於其易用性，無論是在行動裝置還是電腦平台上，都能直觀地使用，並能幫助用戶輕鬆了解自身的薄弱環節以及應該優先學習哪些模組，從而最大限度地提高學習效率。然而，儘管整體回饋積極，但仍有一些領域需要進一步討論和改進：

1. 研究限制:本研究的實驗對象主要以護理相關科系學生為主，因此研究樣本數相對有限，小樣本可能影響研究結果的統計穩定性與普遍性。此外，由於研究情境主要聚焦於護理專業課程，研究結果在其他學科領域中的適用性仍有待進一步驗證。未來研究可擴大樣本規模，並納入不同學科背景與不同學習階段的學生，以進一步檢驗本系統在多元學習情境中的適用性與有效性，並提升研究結果的外部效度。
2. 演算法最佳化:本研究之學習推薦系統主要採用子群組探勘方法，以判斷學生是否需要重新學習特定學習內容。研究結果顯示，該方法能在一定程度上有效辨識學習者於各學習單元中的能力差異，並提供具解釋性的推薦結果。然而，考量到學習行為與能力表現具有高度複雜性與動態特性，現行方法仍存在進一步最佳化的空間。未來研究可嘗試引入深度知識追蹤(Deep knowledge Trace)(Li et al.,2025)，以更精準地建模學習者在不同知識單元中的學習歷程與能力變化，進而提升推薦結果在準確性與相關性上的表現。此外，透過比較不同演算法於學習推薦任務中的效能，並分析其在可解釋性與計算成本之間的取捨，將有助於建構更具彈性與適應性的推薦系統，進而提升整體學習支持的品質(Mondal et al.,2020)。
3. 使用者參與度和積極性:內容雖然簡潔明了，但減少內容量仍是確保使用者持續參與和保持積極性的一個挑戰。未來，我們可以繼續拓展與其他學科的合作，探索與其他學科的關聯性，或嘗試運用翻轉教室策略，使護理教育更加生動有趣(Tan et al.,2017)，從而提高使用者的學習動機。

未來可能的改進方向：

1. 多媒體內容整合：在系統層面上，未來可透過模組化架構設計，將現有以文字與插圖為主的學習內容，擴充為支援影片播放、互動式模擬以及虛擬實驗室等多媒體功能。透過統一內容管理與呈現介面，系統可依據不同裝置特性(如行動裝置與桌上型電腦)自動調整多媒體呈現方式，以確保操作流暢性與使用體驗的一致性。
2. 內容拓展：在內容層面上，未來可逐步納入更多與核心學習主題相關之學科，並系統性地建立跨學科之間的知識關聯，進一步擴充學習平台的整體知識架構。透過跨學科內容的整合，系統將能更有效地辨識不同學習單元之間潛在的能力連結與學習重點，進而在分析學習歷程時提供更全面且具精準性的學習建議。此外，跨學科內容的引入有助於學習者建構整體性與結構化的知識理解，避免學習內容過度碎片化，並促進概念間的遷移與應用。
3. 學習問題最佳化：在模型建構與系統實作過程中，本研究發現，部分學習單元由於與其他單元之間的關聯性較低，或其內容本身相對獨立，導致該類單元較難與整體學習系統建立緊密的結構連結，進而影響系統於學習分析與推薦結果上的整體表現。針對此一問題，透過重新檢視並最佳化學習問題的設計方式，例如強化單元間的概念連結、調整題目結構，或引入情境化與整合式問題設計，將有助於提升不同學習單元之間的關聯程度，並改善系統對學習歷程的整體掌握。此外，本研究之實驗時間相對有限，未來研究可延長實驗期間，透過長期觀察與資料蒐集，以更全面地評估學習系統在不同學習階段中的應用效果與穩定性。若能持續針對上述問題進行系統優化並逐步實施相關改進措施，該平台將可持續發展，未來若能針對本文所探討之問題持續進行系統優化，並逐步實施相關改進措施，該平台將可持續發展，最終成為一個能為大學生提供高度個人化且具互動性的學習支持工具，並在高等教育學習情境中展現其應用價值。

參考文獻

- Atzmueller, M., & Puppe, F. (2006, September). SD-Map—A fast algorithm for exhaustive subgroup discovery. In *European Conference on Principles of Data Mining and Knowledge Discovery* (pp. 6-17). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Benner, P., Sutphen, M., Leonard, V., & Day, L. (2009). *Educating nurses: A call for radical transformation*. John Wiley & Sons.
- Dai, Y., Takami, K., Flanagan, B., & Ogata, H. (2024). Beyond recommendation acceptance: Explanation's learning effects in a math recommender system. *Research and Practice in Technology Enhanced Learning*, 19.
- De Medio, C., Limongelli, C., Sciarrone, F., & Temperini, M. (2020). MoodleREC: A recommendation system for creating courses using the moodle e-learning platform. *Computers in Human Behavior*, 104, 106168.
- El Youbi El Idrissi, L., Akharraz, I., & Ahaitouf, A. (2023). Personalized e-learning recommender system based on autoencoders. *Applied System Innovation*, 6(6), 102.
- Gómez-Bravo, D., Viguera, G., García, A., Ríos, B., Provencio, M., & Rodríguez-González, A. (2025). IGSD: a multi-criteria approach for subgroup discovery using information gain and odds ratio. *Progress in Artificial Intelligence*, 1-18.

- Herrera, F., Carmona, C. J., González, P., & Del Jesus, M. J. (2011). An overview on subgroup discovery: foundations and applications. *Knowledge and information systems*, 29(3), 495-525.
- Kavanagh, J. M. (2021). Crisis in Competency: A Defining Moment in Nursing Education. *Online Journal of Issues in Nursing*, 26(1).
- Kermansaravi, F., Navidian, A., & Yaghoubinia, F. (2015). Nursing students' views of nursing education quality: a qualitative study. *Global journal of health science*, 7(2), 351.
- Lalitha, T. B., & Sreeja, P. S. (2020). Personalised self-directed learning recommendation system. *Procedia Computer Science*, 171, 583-592.
- Lavrač, N., Kavšek, B., Flach, P., & Todorovski, L. (2004). Subgroup discovery with CN2-SD. *Journal of Machine Learning Research*, 5(Feb), 153-188.
- Li, X., Luo, F., Ouyang, J., Pino, L. R., Li, W., Ding, W., & Gu, C. (2025). A Novel Deep Knowledge Tracing Model with Problem Complexity and State Stability. *International Journal of Artificial Intelligence in Education*, 1-24.
- Luna, J. M., Fardoun, H. M., Padillo, F., Romero, C., & Ventura, S. (2022). Subgroup discovery in MOOCs: a big data application for describing different types of learners. *Interactive Learning Environments*, 30(1), 127-145.
- Michel, A., Ryan, N., Mattheus, D., Knopf, A., Abuelezam, N. N., Stamp, K., ... & Fontenot, H. B. (2021). Undergraduate nursing students' perceptions on nursing education during the 2020 COVID-19 pandemic: A national sample. *Nursing outlook*, 69(5), 903-912.
- Mihaescu, M. C., & Popescu, P. S. (2021). Review on publicly available datasets for educational data mining. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 11(3), e1403.
- Mondal, B., Patra, O., Mishra, S., & Patra, P. (2020, March). A course recommendation system based on grades. In *2020 international conference on computer science, engineering and applications (ICCSEA)* (pp. 1-5). IEEE.
- Mu, R. (2018). A survey of recommender systems based on deep learning. *Ieee Access*, 6, 69009-69022.
- Pieters, B. F., Knobbe, A., & Dzeroski, S. (2010, September). Subgroup discovery in ranked data, with an application to gene set enrichment. In *Proceedings preference learning workshop (PL 2010) at ECML PKDD* (Vol. 10, pp. 1-18).
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *Wiley interdisciplinary reviews: Data mining and knowledge discovery*, 10(3), e1355.
- Talaghzi, J., Bellafkih, M., Bennane, A., Himmi, M. M., & Amraouy, M. (2023). A combined E-learning course recommender system. *International Journal of Emerging Technologies in Learning (Online)*, 18(6), 53.
- Tan, C., Yue, W. G., & Fu, Y. (2017). Effectiveness of flipped classrooms in nursing education: Systematic review and meta-analysis. *Chinese Nursing Research*, 4(4), 192-200.

- Xia, Y., Shin, S. Y., & Shin, K. S. (2024). Designing personalized learning paths for foreign language acquisition using big data: Theoretical and empirical analysis. *Applied Sciences*, 14(20), 9506.
- Zhang, Q., Lu, J., & Zhang, G. (2021). Recommender Systems in E-learning. *Journal of Smart Environments and Green Computing*, 1(2), 76-89.