

## 基于图神经网络的学业表现预测方法研究综述

翟洁, 陈乐旋, 庞智玉

### 引用本文

翟洁, 陈乐旋, 庞智玉. 基于图神经网络的学业表现预测方法研究综述[J]. 计算机科学, 2026, 53(2): 16-30.

ZHAI Jie, CHEN Lexuan, PANG Zhiyu. [Survey on Graph Neural Network-based Methods for Academic Performance Prediction](#) [J]. Computer Science, 2026, 53(2): 16-30.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

**Similar articles recommended (Please use Firefox or IE to view the article)**

#### [基于异构图注意力网络的智能合约漏洞检测方法](#)

Heterogeneous Graph Attention Network-based Approach for Smart Contract Vulnerability Detection

计算机科学, 2026, 53(2): 423-430. <https://doi.org/10.11896/jsjcx.241200144>

#### [融合对比学习的掩码图自编码器](#)

Contrastive Learning-based Masked Graph Autoencoder

计算机科学, 2026, 53(2): 145-151. <https://doi.org/10.11896/jsjcx.250100155>

#### [基于轻量级教育大模型的个性化实践学习资料动态推荐](#)

Dynamic Recommendation of Personalized Hands-on Learning Materials Based on Lightweight Educational LLMs

计算机科学, 2026, 53(2): 48-56. <https://doi.org/10.11896/jsjcx.250800002>

#### [基于方向感知孪生网络的知识概念先序关系预测方法](#)

Direction-aware Siamese Network for Knowledge Concept Prerequisite Relation Prediction

计算机科学, 2026, 53(2): 39-47. <https://doi.org/10.11896/jsjcx.250600005>

#### [个性化教育资源推荐综述](#)

Review of Personalized Educational Resource Recommendations

计算机科学, 2026, 53(2): 1-15. <https://doi.org/10.11896/jsjcx.250700184>

# 基于图神经网络的学业表现预测方法研究综述

翟洁 陈乐旋 庞智玉

华东理工大学信息科学与工程学院 上海 200030

(zjbzj@ecust.edu.cn)

**摘要** 目前,学业表现预测作为个性化教育支持系统的核心环节,已成为教育数据挖掘领域的研究热点,在教学决策优化与学生发展指导中发挥重要作用。然而,传统预测方法难以有效应对教育场景中多源异构数据的复杂关联、时序演化及群体依赖等挑战,导致预测精度与泛化能力受限。图神经网络凭借强大的关系建模与表示学习能力,为应对上述问题提供了新范式。因此,许多学者致力于将图神经网络应用于学业表现预测的研究中。针对当前基于图神经网络的学生学业表现预测任务的研究工作进行系统性综述,首先从问题定义出发,解析学业表现预测的核心挑战;接着梳理了图神经网络的基础知识和常用模型;然后分类综述了静态特征建模、融合静态和动态特征建模以及新兴大模型技术赋能等学业表现预测方法的代表性模型及应用场景,在此基础上,系统性总结和分析了基于图神经网络的学业表现预测方法的评估相关数据集及指标;最后从模型的可扩展性、可解释性、多模态语义信息融合以及动态图预训练等维度展望未来研究方向。

**关键词:**图神经网络;学业表现预测;静态特征;动态特征;大模型;教育数据挖掘

**中图分类号** TP391

## Survey on Graph Neural Network-based Methods for Academic Performance Prediction

ZHAI Jie, CHEN Lexuan and PANG Zhiyu

School of Information Science and Engineering, East China University of Science and Technology, Shanghai 200030, China

**Abstract** Currently, academic performance prediction, as a core component of personalized educational support systems, has become a focal point of research in the field of educational data mining, playing a significant role in optimizing teaching decisions and guiding student development. However, traditional prediction methods struggle to effectively address the challenges posed by the complex correlations, temporal evolution, and group dependencies inherent in multi-source heterogeneous data within educational contexts, resulting in limitations in prediction accuracy and generalization capabilities. Graph Neural Networks (GNNs), leveraging their powerful relational modeling and representation learning abilities, provide a novel paradigm for addressing these challenges. Consequently, numerous researchers are dedicated to applying GNNs to academic performance prediction research. This paper presents a systematic review of current research efforts on GNN-based academic performance prediction tasks. Starting from the problem definition, it analyzes the core challenges of academic performance prediction. It then outlines the foundational knowledge and common models of GNNs. Subsequently, it categorizes and reviews the representative models and their application scenarios for academic performance prediction, including static feature modeling, combined static and dynamic feature modeling, and techniques empowered by emerging large model technologies. Building on this, the paper systematically summarizes and analyzes the evaluation-related datasets and metrics used for GNN-based academic performance prediction methods. Finally, it prospects future research directions from perspectives such as model scalability, interpretability, multimodal semantic information fusion, and dynamic graph pre-training.

**Keywords** Graph neural network, Academic performance prediction, Static features, Dynamic features, Large models, Educational data mining

到稿日期:2025-08-01 返修日期:2025-10-22

基金项目:上海高校市级一流课程建设项目(沪教委高[2025]5号);2024年度教育部产学研合作协同育人项目;2024年度教育部-华为“智能基座”产教融合协同育人基地一流课程项目

This work was supported by the Shanghai Municipal-Level First-Class Courses Development Project (Shanghai Municipal Education Commission Document [2025] No. 5), 2024 Ministry of Education Industry-University Cooperative Education Project and 2024 Ministry of Education-Huawei “Intelligent Base” Industry-Education Integration Collaborative Education Base First-Class Course Project.

通信作者:陈乐旋(1492821750@qq.com)

## 1 引言

近年来,个性化教育的蓬勃发展对学生学业表现的精准预测提出了更高要求。学业表现预测作为个性化教育支持系统的核心环节,在教学决策优化、学业风险预警与学生发展指导中扮演着关键角色,已成为教育数据挖掘领域的研究热点。然而,教育场景中蕴含的数据具有多元异构(如静态属性、动态行为)、时序演化(如知识状态变化、行为模式迁移)及群体依赖(如同伴互动、协作效应)等复杂特性<sup>[1]</sup>。传统预测方法(如统计模型、序列模型)难以有效建模这些复杂的关联结构和动态变化,导致预测精度与泛化能力受限<sup>[2]</sup>。

图神经网络(Graph Neural Network, GNN)凭借其强大的关系建模与表示学习能力,为应对上述挑战提供了新范式<sup>[3]</sup>。GNN能够将教育实体(学生、课程、题目等)及其复杂关系(选课、互动等)自然地建模为图结构数据,并通过消息传递机制有效聚合邻域信息,从而捕捉实体间的相互影响和学习过程的动态演变。这种内在的适配性使得基于GNN的方法在提升学业表现预测的准确性和预测结果的可解释性方面展现出显著潜力。与此同时,大模型技术的兴起已经彻底改变了教育数据挖掘的各个领域,目前大模型赋能的图神经网络已表现出优越的性能,这为开展基于图神经网络的学业表现预测提供了更多机遇与挑战<sup>[4]</sup>。

当前基于GNN的学业表现预测研究已取得积极进展,但其方法体系仍需系统梳理。鉴于此,本文旨在对基于图神经网络的学业表现预测方法进行系统性综述。

本文主要贡献如下:

1)系统解析了学业表现预测任务的核心挑战及其图结构关联性、多尺度预测性和动态演化性三大核心特性,为图神经网络在该领域的应用奠定了问题基础与适配性依据。

2)归纳了基于GNN的学业表现预测方法体系,从静态特征建模、融合静态和动态特征建模以及大模型赋能3个维度分类梳理和评述了各类代表模型的技术原理与性能优势。

3)系统总结了该领域的常用评估数据集与指标,并从模型的可扩展性提升、可解释性优化、多模态语义信息融合、动态图结构与预训练机制等维度展望了未来重点研究方向,为后续研究提供技术路线参考。需要说明的是,由于学业表现预测涉及教育数据挖掘、图表示学习、大模型等多个领域,本文难以涵盖所有相关技术,仅致力于对基于图神经网络的学业表现预测方法进行系统性梳理,为该领域研究提供借鉴。

## 2 问题描述

本章首先介绍了学生学业表现预测任务的问题描述,然后详细梳理了学业表现预测方法的基本概念,最后分析了学业表现预测任务的挑战与核心特性。

### 2.1 学业表现预测问题描述

个性化教育的持续发展促使学生评估方法呈现多样化态势。教学设计本身存在差异,学生因此常采用不同的学习策略和行为模式<sup>[5]</sup>。这些个体差异推动教育系统更加重视因材施教和个性化支持的需求<sup>[6]</sup>。学业表现预测是一种有效且准确的教育数据挖掘方法,具备前瞻性特征,已成为个性化教育

支持系统的核心要素。该方法通过挖掘学生行为数据、课程交互数据等多源信息,构建预测未来学业表现的模型。这些预测结果可为教学辅助决策、课程推荐、学业预警等环节提供数据支持,同时也有助于实现对学生学习潜能的精准识别与个性化培养目标的达成<sup>[7]</sup>。

学业表现预测问题的研究对象具有多层级特征。其预测主体可分为微观层面的学生个体(如学生在特定课程的表现)、中观层面的学习群体(如班级的统计表现)以及宏观层面的课程资源(如课程的难度评估)。本研究聚焦学生个体作为核心预测主体,旨在对其未来学业表现进行估计,而群体与课程主体仅作为环境变量参与建模<sup>[8]</sup>。

学业表现预测本质上是教育数据挖掘中的一项核心任务,其目标是基于学生的历史数据,构建“特征-结果”映射模型,从而量化过去或当前学习状态与未来学业结果之间的关联规律。而基于图神经网络的学业表现预测方法令 $G=(V, E, X)$ 表示一个图结构,其中 $V$ 表示学生或课程等实体节点, $E$ 表示行为或关系边, $X \in R^{(|V| \times d)}$ 表示节点的属性特征。目标是学习一个函数 $f$ ,使得对任一学生节点,能够预测其未来学业表现。常见的预测任务包括分类任务和回归任务,分类任务往往指预测学生是否通过课程、是否退学或预测学业表现等级(如优秀、通过、挂科)等,常见的回归任务往往预测学生总分、绩点等<sup>[9]</sup>。

### 2.2 学业表现预测方法基本概念

根据研究目标与特征来源,本文将当前基于图神经网络的主流学业表现预测方法分为基于静态特征的预测方法和融合静态和动态特征的预测方法两类。

静态特征指固定不变或长期稳定的学生背景属性。典型的静态特征有人口统计学变量(性别、年龄)、课程属性(课程学分、类型)、入学信息(入学成绩、专业背景)、基础能力测试结果等<sup>[10]</sup>。形式上,预测模型 $\hat{y}=f(S)$ 使用特定的静态特征向量 $S=(s_1, s_2, \dots, s_m)$ 作为输入,其中 $s_i$ 为某一静态属性,预测目标是学业表现预测值 $\hat{y}$ ,映射函数 $f(\cdot)$ 建立了特征向量与学业表现预测值 $\hat{y}$ 之间的关系。该方法数据易获取,适用于入学初的学业风险早期预警和学业表现长期趋势分析<sup>[11]</sup>。但在实际场景中,学生学习过程中实时生成的动态行为特征也会对学业表现产生很大影响,而仅关注静态特征的预测方法难以利用这些动态变化信息进行更准确的预测。

由此,研究者开始关注动态特征信息的捕获。动态特征指随时间变化的学生行为轨迹数据。典型示例如在线学习平台的点击轨迹(视频播放、课件下载)、作业提交记录(提交时间、修改次数)、课堂互动数据(提问频率、讨论参与度)等<sup>[12]</sup>。例如,在在线教育场景中,可通过分析学生每周的视频观看完成率、论坛发言次数等时序行为数据,预测其结课考试通过率。若行为序列为 $B=(b_1, b_2, \dots, b_t)$ (其中 $b_t$ 为 $t$ 时刻的行为特征),则预测模型可表示为 $\hat{y}=g(B)$ ,其中 $g(\cdot)$ 为时序映射函数。基于动态特征信息的方法能实时反映学习状态的变化,支持早期预警和过程性学业干预。

当前主流的大部分预测模型常结合静态特征和动态特征,以实现更准确的学业表现预测,这种融合策略有效利用了

静态特征的长期稳定性与动态特征的实时变化性,两者在时序和性质上形成互补,显著减少了单一数据源的预测盲区,从而能在复杂学业场景下获得更鲁棒、更精准的预测结果。

随着大模型技术在教育数据挖掘领域的不断创新,大模型赋能的学业表现预测方法也展现出更强的特征提取与结构挖掘能力,能够深度融合多源异构教育数据,进一步提升预测模型在复杂场景下的预测能力<sup>[13]</sup>。

### 2.3 学业表现预测方法问题挑战及特性分析

尽管学业表现预测任务在个性化教育中价值显著,但当前研究仍面临诸多挑战。

1)数据异质性强<sup>[14]</sup>。教育数据来源广泛、类型多样(如静态属性、动态行为序列、课程资源),且格式异构(数值、类别、时序、文本),有效融合多源异构信息进行统一建模难度大。

2)时序演化复杂<sup>[15]</sup>。学生学习行为具有连续性和动态演化特征(如知识状态变化、兴趣转移),传统方法难以精准捕捉长期依赖关系与行为模式的时变规律。

3)群体依赖难建模<sup>[16]</sup>。学生学业表现受同伴互动、协作关系等群体效应影响显著,孤立建模个体难以反映真实学习环境中的复杂社会依赖网络。

基于上述挑战,本文提炼出学业表现预测任务需把握的核心特性。

1)图结构关联性<sup>[17]</sup>:教育场景中实体(学生、课程、资源)间天然存在复杂的关联网络(如选课关系、成绩依赖、行为交互),其结构蕴含关键预测信息。

2)动态演化性<sup>[18]</sup>:学生状态(知识水平、参与度)与交互关系(协作、竞争)随时间持续演变,要求模型能有效追踪状态迁移与结构演化过程。这些特性为图神经网络的应用提供了内在契合点。

3)群体互构性:学业表现的形成本不仅依赖个体努力与时间演化,更深度嵌套于社会化学习网络中。学生通过与同伴的协作互动、竞争关系、知识共享形成动态群体效应,这种跨个体的互构机制使学业表现呈现群体层面的联动特征与整体趋势。

## 3 图神经网络基础概述

本章梳理了图神经网络相关知识概述,包括图神经网络基础知识和常用于学业表现预测任务的代表模型。

### 3.1 图神经网络基础知识

#### 3.1.1 图结构数据表示

图结构数据是图神经网络处理的核心对象,其本质是通过节点与边的拓扑关系描述实体间的复杂关联<sup>[19]</sup>。在数学形式上,图可定义为 $G=(V,E)$ ,其中 $V=\{v_1, v_2, \dots, v_n\}$ 表示节点集合, $E=\{e_1, e_2, \dots, e_m\}$ 表示边集合。节点代表实体(如学生),边则代表实体间的关系(如成绩相关性)。根据节点和边的类型多样性,图可分为同构图和异构图。同构图由单一类型的节点和单一类型的边组成,结构简单,适用于实体和关系较为统一的场景,例如仅包含学生节点和表示成绩相关性的边的图;异构图则支持多种类型的节点和边,能刻画更复杂的多面交互,例如同时包含学生、课程、教师等节点,以及

“学生-选课”“教师-授课”“学生-互助”等多种边的图<sup>[20]</sup>。每个节点通常携带描述自身属性的特征信息,称为节点特征。这些特征既可以是静态的,如学生的性别、专业等相对固定的属性,也可以是动态的,如随时间变化的学习时长、阶段性测验成绩等。例如,在学生学习行为分析中,节点特征可包含学生的课程成绩、日常行为数据等。边特征作为可选元素,用于描述关系的属性(如关系强度或类型)。对于动态变化的图结构,如学生间互助关系随时间的建立与消失,其时间演化规律可结合 LSTM 等模型进行捕捉,以有效学习图中节点与边的时序特征<sup>[21]</sup>。

#### 3.1.2 消息传递机制

图神经网络的核心在于其消息传递(Message Passing, MP)机制,该机制通过迭代方式捕捉图中节点的结构化依赖关系<sup>[22]</sup>。其核心流程包含聚合、更新、传播 3 个步骤。

1)邻居信息聚合:节点从其邻居(包括直接或间接相连的节点)收集信息。聚合操作可采用多种函数实现,如均值(Mean)、求和(Sum)、取最大值(Max)或基于注意力的加权(Attention-weighted)策略<sup>[23]</sup>。例如,GraphSAGE<sup>[24]</sup>模型通过均匀采样固定数量的邻居节点,采用“均值聚合器(Mean Aggregator)”或注意力加权(如 GAT 模型)整合邻居特征;而 MPNN<sup>[25]</sup>框架则通过消息函数计算邻居信息的加权和。

2)节点状态更新:节点将自身特征与聚合后的邻居信息结合,更新其表示。更新过程通常通过非线性变换实现。例如,GGNN<sup>[26]</sup>模型利用门控循环单元(Gated Recurrent Unit, GRU)将历史状态与聚合信息融合。

3)迭代传播:通过多轮消息传递,节点逐步捕获高阶邻域依赖关系。例如,经典图神经网络模型通过迭代收敛至不动点,确保深层拓扑信息被充分编码;而图卷积网络通过堆叠多层卷积操作,使节点接收多跳邻居的信息<sup>[27]</sup>。

#### 3.1.3 图神经网络的核心架构

本节将介绍几种构建图神经网络模型的核心架构,它们是实现消息传递的关键。

##### 1)图卷积网络

为了高效处理图结构数据并解决节点半监督分类问题(即仅部分节点有标签),Kipf<sup>[28]</sup>提出了图卷积网络(Graph Convolutional Network, GCN)这一基础模型。GCN 的核心思想是设计一个直接在图上操作的、可扩展的神经网络层间传播规则,将图的结构信息(邻接矩阵)与节点自身特征信息相结合,进行有效的信息传播与特征学习。

GCN 的层间传播规则可视为图卷积的一阶近似。其关键步骤是通过对邻接矩阵添加自连接并进行对称归一化,使得每一层节点的表示是其自身特征与一阶邻居节点特征的聚合(加权平均),再经过一个可学习的权重矩阵 $W^{(l)}$ 变换和非线性激活函数 $\sigma(\cdot)$ (如 ReLU)。

$$H^{(l+1)} = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}) \quad (1)$$

其中, $H^{(l)}$ 表示第 $l$ 层的节点表示矩阵, $H^{(0)} = X$ 是节点的初始特征矩阵。这种设计允许模型在训练过程中,通过监督信号(有标签节点的损失)驱动,将标签信息通过图的边结构有效地传播到未标记节点,同时学习融合了图结构和节点特征的层次化表示。

GCN 通过引入“重归一化技巧 (Renormalization Trick)”,有效解决了深层网络训练中可能出现的数值不稳定(梯度爆炸/消失)问题,进一步提升了模型的稳定性和性能。GCN 的计算效率高,能有效处理大规模图数据,成为后续 GNN 研究的基础框架。

## 2) 图注意力网络

图注意力网络(Graph Attention Network, GAT)模型在信息传播机制上进行了关键创新<sup>[22]</sup>。区别于 GCN 中固定的、基于图结构的归一化权重, GAT 的核心在于为每个中心节点与其邻居节点之间的连接动态地计算一个权重系数  $\alpha_{ij}$ :

$$\alpha_{ij} = \text{softmax}_j(\text{LeakyReLU}(\mathbf{a}^T [W_h \mathbf{i} \parallel W_h \mathbf{j}])) \quad (2)$$

其中,  $\parallel$  表示向量拼接, LeakyReLU 是激活函数。中心节点  $i$  在第  $l+1$  层的新表示  $h_i^{(l+1)}$  如下:

$$h_i^{(l+1)} = \sigma(\sum_{j \in \mathcal{N}_i} \alpha_{ij} W_h h_j^{(l)}) \quad (3)$$

其中,  $j \in \mathcal{N}_i$  表示其所有邻居节点(通常包括自身节点),  $\sigma$  表示非线性激活函数。

通过引入注意力机制, GAT 能够根据节点特征自适应地学习邻居节点的重要性, 无须依赖预先定义的图结构信息。这使得模型能够区分不同邻居节点对中心节点表示的贡献差异, 对节点特征各异或连接具有不同语义重要性的图尤其有效。此外, 学习到的注意力权重本身提供了一种对模型决策过程的直观解释, 有助于理解网络在节点分类等任务中信息聚合的过程。GAT 通过堆叠自注意力层实现节点特征聚合, 无需昂贵矩阵运算或先验图结构知识, 解决了图神经网络的局限性。

### 3.1.4 池化和读出

在神经网络中, 池化操作<sup>[29]</sup> (Pooling Operators) 是实现层级特征提取的关键机制, 其核心原理是通过粗化 (Coarsening) 图结构与节点特征, 生成数据的局部摘要, 从而让模型能够学习到越来越抽象和粗糙的输入图表示。通过将消息传递层与池化层交织, 池化操作能够逐步提炼全局图属性, 为构建深层 GNN 奠定基础。

常用的池化方法包括平均池化 (Average Pooling) 和最大池化 (Max Pooling), 其中平均池化对特征图的局部区域内所有值取平均值, 而最大池化则选取局部区域中的最大值。这类方法通过对所有节点特征进行简单的统计聚合来实现图的粗化, 操作简便但可能丢失局部结构细节。此外, 还有基于分簇或节点评分的层次化聚合方法, 如密集型池化算子 Diff-Pool, MinCutPool 和 DMoN, 它们通过可训练的聚类分配矩阵将节点划分为超级节点, 并利用凸组合聚合特征, 能较好地保留消息传递层的表达能力。

读出 (READOUT) 操作<sup>[30]</sup> 在图分类或回归等任务中发挥关键作用, 其核心目标是将经过多层消息传递后得到的节点级特征聚合起来, 生成一个固定大小的图级别表示 (Graph-Level Representation), 通常通过全局池化操作来实现。这个图级别的表示向量随后可以被送入一个分类器或回归器, 以完成整个图的任务。常用的读出函数包括对所有节点特征进行求和、均值或最大值运算, 这些函数能够有效整合节点特征中的结构信息与内容信息。

多样化的池化方法与读出函数相互配合, 前者通过层级

粗化提炼全局属性, 后者则将处理后的节点特征转换为图级表示, 共同为深层 GNN 在各类任务中的性能提升提供支持。

## 3.2 图神经网络模型

图神经网络涉及很多模型类别, 其中常用于学业表现预测任务的包括同构图神经网络和异构图神经网络。在其基础上, 学者融入时序和超图模块, 拓展得到了时序图神经网络和超图神经网络。

### 3.2.1 同构图神经网络

同构图神经网络 (Homogeneous Graph Neural Network) 是指处理同构图的图神经网络模型, 其中图中所有节点和边属于同一类型, 节点间的关系结构相对统一。在学业表现预测任务中, 同构 GNN 常被用于构建学生关系图或课程依赖图, 以挖掘学生之间或课程之间的潜在关联。

典型的同构 GNN 模型算子包括前文提到的 GCN, GAT 等。GCN 模型通过多层卷积操作逐步聚合多跳邻居信息, 适用于学生节点或课程节点的表示学习。在学业表现预测中, GCN 常被用于构建学生关系图, 以预测未来的学业表现。而 GAT 在该领域常用于融合多视图或多拓扑图结构, 如 MT-GNN<sup>[31]</sup> 中采用注意力机制融合不同相似度度量构建的图表示。此外, GraphSAGE<sup>[24]</sup> 在学业表现预测中常用于处理学生交互图或行为图, 例如 Lai 等<sup>[32]</sup> 提出的 GSDSA 模型中采用 Jaccard 系数和 Pearson 相关系数构建学生相似图, 并通过 GraphSAGE 进行邻居采样与特征聚合。

同构图神经网络通过不同的信息聚合机制对同构学生图或课程图进行表示学习, 为学业表现预测提供了丰富的结构信息与特征融合方式, 尤其在捕捉学生间潜在关系、课程依赖结构等方面具有显著优势, 成为当前教育数据挖掘中的重要工具之一。

### 3.2.2 异构图神经网络

异构图神经网络 (Heterogeneous Graph Neural Network) 是处理包含多种类型节点或边的图结构数据的扩展模型, 广泛应用于学生表现预测任务中, 以捕捉学生、课程、题目等多类实体和选修、先行、包含等多种类型边之间的复杂关系。

在学业表现预测领域中, 许多学者构建了不同类型的异构图结构。例如, Li 等<sup>[33]</sup> 将学生、问题和交互行为建模为 3 类节点, 并通过 Edge2Node 策略将交互边转换为虚拟节点, 构建了“学生-交互-问题”三元异构网络 (Student-Interaction-Question, SIQ) 以进一步提升模型性能。Wu 等<sup>[34]</sup> 则明确构建了包含学生、习题和知识点的三元异构图 (Heterogeneous Relation Graph, HRG), 其中包含“学生-习题”之间的“回答”关系和“习题-知识点”之间的“包含”关系。该研究采用图卷积网络 (GCN) 学习节点嵌入, 并使用门控图神经网络 (GGNN) 对学生的学习状态进行动态建模, 对复杂知识结构和动态认知变化具有强建模能力, 并在冷启动场景中显示出较强鲁棒性, 体现了异构图神经网络在复杂教育场景学业表现预测中的优势。

### 3.2.3 时序图神经网络

时序图神经网络 (Temporal Graph Neural Networks, TGN) 是神经网络的一个重要分支, 专注于处理具有时序

动态性的图结构数据。在学业表现预测任务中,学生的行为数据(如在线学习活动、答题记录等)往往具有强烈的时间依赖性,传统的静态神经网络难以捕捉其演化规律,因此时序图神经网络成为该领域的重要建模工具。

时序图神经网络的核心思想是在图结构的基础上引入时间维度,通过对节点和边随时间变化的动态建模,捕捉学生行为序列中的时序模式和状态演变。例如,Huang等<sup>[35]</sup>提出的APP-DGNN模型通过双图结构分别捕捉局部时序行为与全局属性关系,将时序信息和结构信息融合建模。该模型通过动态图卷积操作提取特征,并结合局部-全局表示学习模块进行预测,在早期风险学生识别任务中表现突出。

时序图神经网络通过将时间信息融入图结构,能够更准确地建模学生学业表现的动态变化过程,为早期预警和个性化干预提供了有力支持。

### 3.2.4 超图神经网络

传统神经网络受限于二元边的建模能力,难以捕捉复杂数据中普遍存在的高阶关联。为解决此问题,Feng等<sup>[36]</sup>提出超图神经网络(Hypergraph Neural Network, HGNN)框架,其核心是引入超图结构以建模多个节点之间的复杂关系,并通过谱域卷积实现高效的信息传播与特征学习。

HGNN以超图 $G=(V, \epsilon, \mathbf{W})$ 为基础,其中 $V$ 为节点集, $\epsilon$ 为超边集, $\mathbf{W}$ 为超边权重对角矩阵,利用超图关联矩阵 $\mathbf{H} \in \mathbf{R}^{|V| \times |\epsilon|}$ 定义节点与超边的连接关系。在正则化框架下,其表示学习目标可表示为:

$$\Omega(f) = \frac{1}{2} \sum_{e \in \epsilon} \sum_{(u,v) \in v} \frac{w(e)h(u,e)h(v,e)}{\delta(e)} \left( \frac{f(u)}{\sqrt{d(u)}} - \frac{f(v)}{\sqrt{d(v)}} \right)^2 \quad (4)$$

其中, $d(v)$ 和 $\delta(e)$ 分别表示节点和超边的度。该目标通过约束同一超边内节点表征的平滑性,实现对高阶关联的有效建模<sup>[37]</sup>。

为避免高阶特征分解的高计算复杂度, HGNN引入了Chebyshev多项式,近似将谱卷积操作简化为:

$$g * x \approx \theta \mathbf{D}_v^{-\frac{1}{2}} \mathbf{H} \mathbf{W} \mathbf{D}_e^{-1} \mathbf{H}^T \mathbf{D}_v^{-\frac{1}{2}} x \quad (5)$$

其中, $\theta$ 为可学习参数; $\mathbf{D}_v, \mathbf{D}_e$ 分别为节点和超边的度矩阵。基于此,单层HGNN卷积操作形式为:

$$X^{(l+1)} = \sigma(\mathbf{D}_v^{-1/2} \mathbf{H} \mathbf{W} \mathbf{D}_e^{-1} \mathbf{H}^T \mathbf{D}_v^{-1/2} X^{(l)} \Theta^{(l)}) \quad (6)$$

其中, $\sigma$ 为激活函数, $\Theta^{(l)}$ 为第 $l$ 层的可训练权重。该机制实质上实现了“节点-超边-节点”的高阶特征聚合,有效增强了节点表示的上下文表达能力。相比GCN, HGNN可自然地处理多模态或异构数据,并具备更强的结构建模灵活性与表达能力。HGNN通过高效的谱卷积设计,兼顾了传统超图学习的高阶建模能力与图神经网络的训练效率,成为当前高阶图结构学习中的重要方法之一。

## 4 基于图神经网络的学生学业表现预测方法

基于图神经网络的学生学业表现预测方法是当前教育数据挖掘领域的前沿研究方向,其核心在于利用图结构建模学生、课程、习题或学习行为间的复杂关联,并通过GNN的图表示学习能力提取实体关系中的关键信息,以提高对未来学业表现

的预测准确性。根据前文的分类标准,本章将基于图神经网络的学业表现预测方法分为基于静态特征的学业表现预测方法、融合静态和动态特征的学业表现预测方法以及大模型赋能的学业表现预测方法,并分析了各方法代表模型的核心优势和适用场景,如表1所列<sup>[31-35, 38, 40-41, 43-46, 48]</sup>。

### 4.1 基于静态特征的学业表现预测方法

本节分析基于静态特征学业表现预测方法的代表性模型,包括使用多拓扑图神经网络的MTGNN模型、使用图结构密度采样聚合的GSDSA模型,以及融合图卷积神经网络与遗传算法的GGCNN模型。

#### 4.1.1 MTGNN模型

考虑到具有相似特征学生的学业表现之间存在一定关联性, Li等<sup>[31]</sup>提出了一种基于多拓扑图神经网络的学生学业表现预测新流程,称为MTGNN。该方法将学业表现预测问题建模为图上的半监督节点分类任务,其中每个节点代表一名学生,节点标签对应学生学业表现,如通过/失败/退学。

MTGNN将反映学生个体特性的多种静态数据作为节点特征输入,具体包括学生的人口统计特征、学习历史信息以及尤为关键的在虚拟学习环境(VLE)中的学习行为数据。例如,学生在讨论论坛、课程主页以及音视频链接上的点击行为等。MTGNN的核心创新点在于其处理学生间关系的方式。模型提出为每个学生节点基于余弦相似度( $s_{ij}^c$ )、皮尔森相关系数( $s_{ij}^p$ )、谷本系数( $s_{ij}^g$ )3种不同相似度来构建多个具有不同拓扑结构的学生关系图。3种相似度的计算公式分别如下:

$$s_{ij}^c = \frac{(v_i \odot \mathbf{p})^T (v_j \odot \mathbf{p})}{\|v_i \odot \mathbf{p}\| \cdot \|v_j \odot \mathbf{p}\|} \quad (7)$$

$$s_{ij}^p = \frac{(\| (v_i - \bar{v}_i) \odot \mathbf{p} \|)^T (\| (v_j - \bar{v}_j) \odot \mathbf{p} \|)}{\| (v_i - \bar{v}_i) \odot \mathbf{p} \| \cdot \| (v_j - \bar{v}_j) \odot \mathbf{p} \|} \quad (8)$$

$$s_{ij}^g = \frac{(v_i \odot \mathbf{p})^T (v_j \odot \mathbf{p})}{\|v_i \odot \mathbf{p}\|^2 + \|v_j \odot \mathbf{p}\|^2 - (v_i \odot \mathbf{p})^T (v_j \odot \mathbf{p})} \quad (9)$$

其中, $\mathbf{p}$ 为可学习参数向量。

每个图通过计算节点特征向量之间的相似度并设置阈值生成邻接矩阵。对于每个基于不同相似性度量构建的图,使用共享参数的图卷积网络(GCN)分别学习节点嵌入 $H_m^{(L)}$ 。为了有效融合来自不同拓扑的信息, Li等开发了一种基于差异的注意力机制来计算每个图嵌入的重要性权重 $k_m$ 。该机制首先计算各图嵌入与平均嵌入的差异 $\Delta H_m^{(L)}$ ,然后通过一个包含可学习向量的函数计算注意力系数:

$$k_m = \frac{\exp(\text{LeakyReLU}(\tilde{\mathbf{W}}_l \Delta H_m^{(L)} \tilde{\mathbf{W}}_r))}{\sum_{i=1}^M \exp(\text{LeakyReLU}(\tilde{\mathbf{W}}_l \Delta H_i^{(L)} \tilde{\mathbf{W}}_r))} \quad (10)$$

最后,统一的图表示由各拓扑嵌入加权求和得到并用于最终的节点分类(学业表现预测)。这种设计使得模型能够自适应地融合来自不同关系视图的信息,并根据预测任务动态调整各拓扑图的贡献权重。

该方法的有效性通过在OULAD数据集上进行实验得到了验证,相较于传统机器学习方法以及仅使用单一拓扑图的GCN, MTGNN在预测学生通过/挂科、通过/退学等分类任务上,在各项评估指标上均取得了更优的性能。该方法适用于需要融合多重静态特征的场景,例如早期学业预警,教师可以在课程进行中的第5, 10, 15, 20周等多个时间点对可能存

在挂科或退学风险的学生进行预测,从而及时提供个性化辅导和学习计划调整,帮助学生改善学习状态。

#### 4.1.2 GSDSA 模型

GSDSA<sup>[32]</sup>(Graph Structure Density-based Sampling-Aggregation)是一种基于图结构密度的采样聚合图神经网络模型,旨在通过高效利用图结构信息预测学生学业表现。该方法将学业表现预测问题转换为图上的节点分类任务,节点标签对应离散化的学业表现等级(如优秀、通过、挂科),节点特征包含学生的静态属性,如人口统计信息、历史成绩及学习行为数据等。

GSDSA 将数据预处理后通过 Pearson 相关系数计算学生节点间的相似度,当两个学生节点和的 Pearson 相关系数  $Pearson(v, u) > 0.7$  时,认为它们存在强线性相关。为了克服 Pearson 系数仅识别线性关系且可能忽略均值差异的局限性, GSDSA 引入了一个额外的约束条件:仅当两个节点既存在强线性相关,同时满足以下约束时才在两节点间添加一条无向边。通过遍历所有学生节点对,生成所需的图结构数据集。

$$\frac{1}{c} |\sum u_i - \sum v_i| < 0.15 \quad (11)$$

为解决深层图神经网络因邻居数量指数增长而影响计算效率的问题, GSDSA 创新性地提出了一种基于图结构密度的采样策略。对于给定节点  $v$ , GSDSA 在采样阶段限制每轮聚合的邻居节点数为超参数  $k$ 。具体步骤为:首先,定位节点  $v$  的所有一阶和二阶邻居,构成集合  $N_{1,2}(v)$ ;随后,使用 Jaccard 系数计算  $v$  与集合  $N_{1,2}(v)$  中每个邻居节点  $u$  之间的结构相似度;计算完成后,对  $N_{1,2}(v)$  中的所有节点进行降序排序;若存在 Jaccard 系数相等的节点,则进一步引入节点自身的特征信息细化排序,使用 Pearson 相关系数计算节点  $v$  与  $u$  的特征相似度;最终,从排序后的集合中选取前  $k$  个节点作为本次采样的邻居节点。这种采样策略优先选择结构相似度高且特征相似的邻居节点,有效减小了采样方差,提升了后续分类的准确性。

实验表明, GSDSA 在多个学生数据集上的分类准确率显著超越传统机器学习方法及经典图神经网络。该方法适用于中小规模教育场景的静态成绩分类,在图结构较复杂但计算资源有限时,具备较高效率和性能保障。GSDSA 为教育数据挖掘提供了新的视角,可基于学习管理系统、开放在线课程(MOOCs)等网络教育平台的学生行为数据,通过分析学生多维数据与学业表现的关系,实现对学生学业风险的早期识别。该预测结果有助于教育者及时调整教学策略,制定新的教育方法,从而对可能不及格的学生进行早期干预,降低学生流失率,提升教学质量。

#### 4.1.3 GGCNN 模型

Li<sup>[38]</sup>创新性地提出了融合图卷积神经网络和遗传算法的学业表现预测框架 GGCNN。该方法通过构建异构图,将学生特征与课程特征纳入统一图结构进行联合建模。图中包含两类节点:学生节点涵盖人口统计特征、学业历史及课外活动等静态属性;课程节点则集成课程标题、学分、先修条件等元数据。节点间通过三类边连接:注册边表示学生选课行为,先修边表示课程依赖关系,相关性边则基于成绩相似性构建

学生之间的关联,通过邻接矩阵和节点特征矩阵显式编码学术环境中的复杂依赖关系。

GGCNN 的核心创新在于设计了遗传算法优化的图卷积机制。模型采用多层特征聚合策略,每层通过归一化邻接矩阵聚合邻居信息,并利用激活函数更新节点嵌入。区别于传统梯度下降,该方法引入遗传算法动态优化网络参数:以均方误差损失函数为适应度函数,通过选择、交叉、变异操作进化权重矩阵  $W^{(D)}$  与偏置项,交叉操作交换父代参数片段生成子代:

$$\theta_{O1} = [\theta_A[1:c], \theta_B[c+1:n]] \quad (12)$$

变异操作添加随机扰动:

$$\theta_{O1} = \theta_{O1} + \alpha \cdot rand(n) \quad (13)$$

避免局部最优。实验表明,该机制可显著加速模型收敛。

在 Kaggle 数据集上的实验验证了该方法的优越性:百名场景下,平均绝对误差(MAE)降至 0.0178,确定系数  $R^2$  达 0.974;千名学生规模中, F1 分数稳定于 0.97 以上,推理时间仅 6ms。GGCNN 模型可整合至学校管理系统,学校可在学期初基于学生人口统计、过往成绩及课程属性等信息,预测出有学业困难风险的学生。例如,若模型根据该生在必修数学课程中的表现预测其可能不及格,系统便会自动触发早期干预机制,如提供学术导师辅导、定制个性化学习计划等;同时,该模型还能依据学生的强弱项为其推荐适配的课程或学习资源,从而有效提升其学术发展的平衡性与整体表现。

## 4.2 融合静态和动态特征的学业表现预测方法

本节分析融合静态和动态特征的学业表现预测方法的代表性模型,包括解决交互式题库中动态知识演化问题的  $R^2$  GCN 模型、融合三模态架构的 GNN-TINet 模型、基于双图神经网络架构的 APP-DGNN 模型、增强交互图与全局-局部优化机制的 GOAT 模型、依赖图注意力机制量化节点权重的 ACGN 模型、使用会话图知识追踪与遗忘效应建模的 SGKT 模型,以及基于多视图超图融合架构的 MVHGNN 模型。

### 4.2.1 $R^2$ GCN 模型

Li 等<sup>[33]</sup>提出的  $R^2$  GCN(Residual Relational Graph Convolutional Network)是一种专门为交互式在线题库中学生学业表现预测而提出的图神经网络方法。该方法的核心在于构建一个捕获学生节点、问题节点及其交互复杂关系的异构网络,并通过改进的图卷积机制实现对学生未来在未尝试问题上得分等级(如 0-3 级)的半监督节点分类预测。相较于传统的序列模型和静态模型,  $R^2$  GCN 能够有效建模无预设顺序的交互式题库中学生知识的演化过程,并利用同伴(Peers)的交互信息提升预测精度。

$R^2$  GCN 创新性地引入 Edge2Node 转换技术,将学生与问题之间具有多维鼠标移动特征的交互关系(边)转换为“伪节点”,从而构建包含学生节点、交互节点、问题节点的三元异构网络——学生-交互-问题(Student-Interaction-Question, SIQ)网络。该网络能够更全面地捕捉学生、问题以及其交互行为之间的复杂关联,特别是通过交互节点作为桥梁,有效地建立了不同问题节点之间的依赖关系。

针对经典 R-GCN 潜在的信息损失问题<sup>[39]</sup>,  $R^2$  GCN 在 R-GCN 的消息传递层之间引入了残差连接机制。在每一层

的更新函数中,不仅聚合邻居节点传来的消息,还保留了中心节点上一层的隐藏状态,并使用激活函数进行更新。

$$h_i^{(l+1)} = \delta(M_i^{(l+1)} + W_0^{(l)} h_i^{(l)} + b) \quad (14)$$

这种设计确保了节点在消息传递过程中能保留更多历史信息,缓解了深层网络中的信息衰减问题。

与原始 R-GCN 不同,  $R^2$  GCN 在最终的读出函数中,通过“拼接(Concat)”操作整合了节点的原始输入特征  $F_{p_i}$  以及所有中间层的隐藏状态  $h_{p_i}^0, h_{p_i}^1, \dots, h_{p_i}^k$ 。

$$y_{p_i}^A = f(\text{Concat}(F_{p_i}, h_{p_i}^0, h_{p_i}^1, \dots, h_{p_i}^k)) \quad (15)$$

这种设计使得模型在做出最终预测时,能够同时利用原始特征的低层信息、中间层的聚合信息以及最终层的高级表示,显著提升了模型的表达能力和预测鲁棒性。

该方法的有效性在 Trumpteck 从 K-12 在线数学题库产品 Learnlex 收集的真实数据集上得到了充分验证。无论是在覆盖时间较短的数据集,还是覆盖时间更长、学生更多样化的数据集上,  $R^2$  GCN 在各项关键指标上均显著优于传统机器学习模型。此外,该模型已被成功部署于 TrumpTech 公司开发的在线数学题库 Learnlex 平台中,用于支持个性化问题推荐模块。该平台通过让新注册学生完成 15 道起始题,以构建初始 SIQ 网络,进而实现对其他题目表现的准确预测,有效缓解了冷启动问题。

#### 4.2.2 GNN-TINet 模型

GNN-TINet<sup>[40]</sup>是一种融合图神经网络(GNN)、Transformer 与 InceptionNet 的混合架构,旨在应对学业表现预测中多标签分类与上下文多维数据交互的复杂性挑战。该方法通过整合异构教育数据(如学术表现、行为特征、情感状态等)构建上下文感知的图结构,利用多维特征交互提升预测精度。

该模型的核心创新首先体现在上下文感知数据预处理上。针对教育数据常见的缺失值和类别变量问题,它摒弃了传统均值填补方法,创新性地提出上下文自适应填补方法(Contextual Adaptive Imputation, CAI),基于特征间强相关性(相关系数大于 0.3)进行加权均值填补以保留上下文关联;同时提出上下文频率编码方法(Contextual Frequency Encoding, CFI),依据类别特征与相关特征的条件频率进行编码以保留隐含关联。此预处理流程结合动态范围缩放与相对性能阈值异常检测,显著提升了后续图构建的数据质量。

在模型架构层面, GNN-TINet 采用了三阶段协同机制。

1)图神经网络层:将输入数据建模为图结构,通过消息传递机制更新节点表征,层间更新函数定义为:

$$f_j^{(l+1)} = \varphi(W^{(l)} f_j^{(l)} + \sum_{k \in N_{(j)}} W_{jk}^{(l)} f_k^{(l)}) \quad (16)$$

其中,  $f_j^{(l)}$  为节点  $j$  在第  $l$  层的特征向量,  $N_{(j)}$  为其邻居集合,  $W^{(l)}$  与  $W_{jk}^{(l)}$  为可学习权重矩阵。该过程聚合局部邻域信息,编码学生间的交互模式(如同伴影响)。

2)Transformer 层:接收 GNN 输出,通过自注意力机制捕获全局依赖关系:

$$\text{Att}(\mathbf{W}, \mathbf{L}, \mathbf{B}) = \text{softmax}\left(\frac{\mathbf{W}\mathbf{L}^Y}{\sqrt{f_j}}\right)\mathbf{C} \quad (17)$$

其中,  $\mathbf{W}, \mathbf{L}, \mathbf{B}$  分别为查询、键、值矩阵;  $f_j$  为特征维度。该机制聚焦关键交互(如学习行为序列中的核心事件),增强时间动态建模能力。

3)InceptionNet 层:提取多尺度特征以适配复杂模式。其模块输出为:

$$f_{\text{out}} = \text{Concat}(f_{1 \times 1}, f_{3 \times 3}, f_{5 \times 5}, f_{\text{pool}}) \quad (18)$$

其中,  $f_{1 \times 1}, f_{3 \times 3}, f_{5 \times 5}$  为不同卷积核的输出;  $f_{\text{pool}}$  为最大化池化结果。多尺度融合可同时识别细粒度特征(如单次测验表现)与宏观趋势(如学期 GPA 演变)。

GNN-TINET 的有效性在包含 97 000 条记录的 CSPD 数据集上得到全面验证。该方法在准确率、F1 分数、AUC、PCS 及 LIF 等关键指标上均显著领先于对比模型。实验充分证明,通过异构架构集成、上下文感知预处理及定制化评估机制, GNN-TINet 能够更精准地建模多标签学生表现的复杂交互,为教育数据挖掘提供了高性能的技术范式。并且, GNN-TINet 模型提出的数据预处理流程能有效应对现实世界中教育数据不完整的挑战,能够将原始、粗糙的教育数据转换为高质量、高保真的模型输入,为后续模型实现早期识别学业风险学生、个性化教育干预等目标奠定了坚实的数据基础。

#### 4.2.3 APP-DGNN 模型

为同时捕捉在线学习行为中的动态交互模式与学生属性间的层次关系, Huang 等<sup>[35]</sup>提出了一种基于双图神经网络(Dual Graph Neural Networks, DGNN)的学业表现预测模型 APP-DGNN。该方法创新性地将交互活动与属性特征分别建模为两类图结构,分别是交互图(Interaction-based Graph)动态编码学习行为序列的时序关联和属性图(Attribute-based Graph)全局建模学生属性的相似性关系。

APP-DGNN 的核心贡献在于其双分支架构。

1)交互图卷积网络(IGCN)模块:该模块采用新型图卷积算子(Graph Convolutional Operator, GCO),通过低-高频滤波器分离学习节点自身属性与邻域关系。

$$H_i^t = \text{ReLU}(FFN - P(D_i^{\frac{A}{2}} A D_i^{\frac{A}{2}} X_i^0 W_\theta + D_i^{\frac{A}{2}} \tilde{A} D_i^{\frac{A}{2}} X_i^0 \tilde{W}_\theta)) \quad (19)$$

其中,  $\hat{A}_i = A_i + I_i$  聚合自连接,  $\tilde{A}_i = A_i - I_i$  捕获邻域交互。随后,循环神经聚合器(Recurrent Neural Aggregator, RNA)引入基于余弦相似性的注意力机制,融合多周期隐藏状态以捕捉长期依赖,最终输出局部学业表现表征  $Z^l$ 。

2)属性图卷积网络(AGCN)模块:该模块通过膨胀 k-NN 算法动态生成图拓扑,并利用关系图卷积(RGC)同时聚合相似与差异属性:

$$x_i^{l+1} = \sum_{x_j^l \in N(x_i^l)} \alpha_{i,j}^l (FFN(x_j^l + x_i^l)) + \alpha_{i,j}^H (FFN(x_j^l - x_i^l)) \quad (20)$$

增强模型对属性异质性的建模能力。RGCN 块通过多层堆叠生成全局表征  $Z^G$ 。

两类表征通过局部-全局融合模块集成。采用简化多头注意力机制对齐交互与属性空间,生成最终预测:

$$Z_i = \text{CPooling}\left(\left\{\frac{Q_i \otimes K_i}{\sqrt{d_k}} \otimes z_i^l\right\}_{i=1}^{N_i}\right) \quad (21)$$

$$Q_i = FFN(z_i^G), K_i = FFN(z_i^l) \quad (22)$$

将最终表征  $Z_i$  输入 MLP 分类器以预测学业表现(如通过/不通过、退学风险)。该融合机制兼顾学生个体行为模式与群体属性关联,为学业表现预测提供互补信息。

APP-DGNN 通过动态图处理与自适应卷积算子,解决了传统方法难以捕获交互活动时序依赖及属性特征层次关系的问题。在基于 OULAD 数据集的案例研究中,其预测“通过/不通过”的准确率达 83.96%,预测“通过/退学”的准确率达 90.18%,显著优于基线模型。此外,早期预测实验表明,仅使用第 5 周的学习日志,APP-DGNN 就能以 76.25%的准确率识别有失败风险的学生,展现了其在教学干预中的实际潜力。

#### 4.2.4 GOAT 模型

GOAT<sup>[41]</sup> (Global-local Optimized graph Transformer) 是一种专为协作学习场景中中学生学业表现预测设计的图神经网络框架,其核心在于构建动态知识概念增强的交互图 (Knowledge Concept-enhanced Interaction Graph, KCIG),并融合空间感知与时序感知模块捕获团队协作中的复杂动态。该方法以软件工程课程为研究对象,学生需组队共同完成软件项目,适用于需长期团队协作的学习场景,能够从代码提交、文档修订和问题追踪等学习工件中提取深层语义信息。

GOAT 的关键创新首先体现在其独特的数据建模方式上。GOAT 从学生提交的文档和代码中提取软件工程领域的关键知识概念(如“单元测试”“架构设计”等),并将这些概念作为特殊节点引入图中。由此构建的动态知识概念增强交互图,既包含反映学生间交互(如同团队协作修改文档/代码、跨队提交问题)的加权边(权重  $W_{ij}$  由标准化后的文档行修改数、代码行修改数或问题严重程度计算),也包含反映学生与知识概念关联强度的加权边(权重  $W_{ek}$  由标准化后的交互频率计算)。该图结构随时间步  $t$  演化 ( $G = [G_t' \mid t = 1, 2, \dots, T]$ ),动态整合了学习过程中的交互行为与知识获取。

在模型架构层面,GOAT 创新性地集成了空间感知、时间感知与全局-局部优化三大模块,以充分挖掘 KCIG 图蕴含的信息。空间感知模块基于改进的 EdgeGNN<sup>[42]</sup> 处理每个时间步的图快照  $G_t'$ ,其核心在于显式地将边权重信息融入节点特征聚合过程。节点  $v$  在第  $l$  层的特征更新公式为:

$$m_v^{(l)} = \text{AGGREGATE}^{(l)}(\{h_u^{(l-1)} \parallel \phi^{(l-1)}(w_{vu}) \mid u \in \mathcal{N}_1(v)\}) \quad (23)$$

$$h_v^{(l)} = \text{UPDATE}^{(l)}(h_v^{(l-1)}, m_v^{(l)}) \quad (24)$$

其中,  $\phi^{(l-1)}(w_{vu})$  为边权重的嵌入变换(如线性层),  $\mathcal{N}_1(v)$  为一阶邻居。这种设计使模型能敏感地捕捉不同交互活动的强度差异及其对节点状态的影响,有效建模特定时点学生与概念间的复杂结构关系。时间感知模块则采用 Transformer 编码器处理  $H_v^{\text{spat}}$  序列,通过掩码多头注意力机制学习动态演化。

$$\text{head}_i = \text{Softmax}\left(\text{Mask}\left(\frac{Q_i K_i^T}{\sqrt{D_m}}\right)\right) V_i \quad (25)$$

其中,  $Q_i, K_i, V_i$  由  $H_v^{\text{spat}}$  投影得到。残差连接与层归一化确保训练稳定性,输出时序增强嵌入  $H_v^{\text{temp}}$ 。该机制专注于分析节点状态随时间演变的模式,捕捉协作学习过程中长期依赖的动态趋势。

为区分团队内协同模式与团队间差异,GOAT 引入全局-局部优化模块。模型通过 READOUT 函数(如平均池化)聚合团队  $T_j$  所有成员嵌入:

$$g_j^t = \text{READOUT}(\{h_i^t \mid i \in T_j\}) \quad (26)$$

之后,采用归一化温度缩放交叉熵损失 (NT-XEnt) 拉近成员与其所属团队的嵌入距离,同时推远其他团队:

$$\mathcal{L}_t^i = -\log \frac{\exp(\text{sim}(h_i^t, g_{\text{pos}}^t)/\tau)}{\sum_{j=1}^{N_g} \exp(\text{sim}(h_i^t, g_j^t)/\tau)} \quad (27)$$

该损失与分类损失  $\mathcal{L}_{\text{class}}$  加权共同优化:

$$\mathcal{L} = \mathcal{L}_{\text{class}} + \lambda \cdot \sum_{t,i} \mathcal{L}_t^i \quad (28)$$

实验表明,  $\lambda = 1$  时达到最佳平衡。该机制显著提升了模型对团队共性及成员特异性的建模能力,使 GOAT 在协作学习预测任务中超越了 CLGT 等基线模型。

GOAT 框架在真实软件工程课程数据集上的实验验证了其优越性。GOAT 在所有数据集(来自 GitLab 平台的提交记录、问题报告和提取的知识概念)上均显著优于 AdaBoost、各类 GNN、Transformer 及先进图变换器模型等基线方法,取得了最好的预测效果。此外,GOAT 生成的可视化生活活跃度热图、概念影响力热等为教育者理解团队动态和知识掌握趋势提供了宝贵意见。

#### 4.2.5 ACGN 模型

ACGN<sup>[43]</sup> (Attention-based Graph Convolutional Network) 是一种融合了图卷积与注意力机制的学业表现预测模型,旨在捕捉课程间复杂的先修依赖关系,并利用注意力机制量化先修课程对目标课程的影响权重,提升预测精度与可解释性。相较于传统静态模型,ACGN 能建模课程间高阶依赖;相较于时序模型,其通过图结构能更灵活地捕捉非时序的知识关联。

建模时,ACGN 将学业表现预测任务转换为图回归问题,模型主要包含 3 部分,即图卷积层、注意力机制层以及多层感知机 (MLP) 预测层。对于目标课程,提取学生的历史课程子集作为节点,构建个性化课程依赖图。邻接矩阵  $\mathbf{A}$ ; 定义学期间课程依赖(当前学期课程与下一学期课程全连接),特征矩阵  $\mathbf{F}$ ; 存储学生历史成绩。

通过多层图卷积层 (GCN) 聚合课程间知识依赖信息,每层计算为:

$$H^{(l+1)} = f(H^{(l)}, \mathbf{A}) = \sigma(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} H^{(l)} \mathbf{W}^{(l)}) \quad (29)$$

其中,  $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$  为带自连接的邻接矩阵,  $\tilde{\mathbf{D}} = \Sigma_j \tilde{\mathbf{A}}$  为度矩阵。输入  $H^{(0)} = \mathbf{F}_s^c$ , 输出  $H^{(L)} = \mathbf{Z}_s^c$  为课程节点嵌入。注意力机制计算先修课程的重要性权重:

$$e_i = \text{MLP}(z_{s,i}^c) \quad (30)$$

$$\alpha_i = \frac{\exp(e_i)}{\sum_{k=1}^N \exp(e_k)} \quad (31)$$

其中,  $\alpha_i$  表示课程  $i$  对目标课程预测的贡献度。将加权节点嵌入,可得:

$$\mathbf{Z}_s^c = \begin{bmatrix} \alpha_1 z_{s,1}^c \\ \vdots \\ \alpha_i z_{s,i}^c \\ \vdots \\ \alpha_N z_{s,N}^c \end{bmatrix} \quad (32)$$

池化后得到图表示向量  $v_s^c$ , 最后将  $v_s^c$  输入 MLP, 输出预测成绩  $\hat{g}_s^c = f(v_s^c)$ 。

ACGN 方法在 George Mason University 数据集上进行了充分验证。实验结果表明,与传统静态方法和序列建模方法相比,ACGN 模型在 MAE 和 F1 等评价指标上均优于现有静态与序列建模方法,表现出更强的学业风险识别能力。该模型在早期预警与学业咨询领域具有重要应用价值,能够有效识别处于学业风险的学生,从而为其提供及时干预与个性化反馈。注意力权重的可解释性使其能够分析学生历史课程表现,识别出对目标课程具有重要影响的先修课程,为教学决策提供支持。

#### 4.2.6 SGKT 模型

SGKT<sup>[34]</sup> (Session Graph-based Knowledge Tracing) 是一种基于会话图的知识追踪模型,旨在建模学生的历史答题行为及其潜在知识状态,以提升对未来答题表现的预测能力。与传统的序列知识追踪模型(如 DKT, AKT)不同,SGKT 通过图结构显式建模题目之间的语义关系,从而更有效地模拟知识迁移、遗忘和强化过程。

模型首先构建一个异构图(HRG),节点包括学生、习题与知识点,通过高阶元路径挖掘跨类型结构依赖关系,节点表示通过图卷积网络聚合节点邻域信息迭代更新,其形式为:

$$\beta_i^l = \text{ReLU}\left(\frac{1}{N_{i,j} \in (i) \cup N_i} \sum y^l \beta_j^{l-1} + z^l\right) \quad (33)$$

其中,  $\beta_i^l$  为节点  $i$  的嵌入,  $N_i$  表示邻居节点集合,  $z^l$  为可训练偏置,  $y^l$  为层级权重系数。最终生成的习题嵌入  $\tilde{e}$  和知识点嵌入  $\tilde{k}$  将输入后续模块使用。

与此同时,SGKT 将学生答题序列建模为有向会话图(SG),节点表示“题目-答案”对,并引入门控图神经网络(GGNN)以建模知识状态的动态演化,状态更新为:

$$h_i^t = (1 - \omega_i^t) \otimes h_i^{t-1} + \omega_i^t \otimes \tilde{h}_i^t \quad (34)$$

最终形成当前时间步  $t$  的学生知识状态表示  $h_t \in \mathbb{R}^d$ 。最终预测阶段,模型融合学生当前状态、目标题目嵌入、相关知识点与历史答题信息,利用注意力机制计算加权交互并预测答题正确概率:

$$\gamma_{i,j} = \text{Softmax}_{i,j}(\mathbf{W}^T[f_i, f_j] + \mathbf{b}) \quad (35)$$

$$p_i = \sum_{f_j \in \tilde{e} \cup (h_i)} \sum_{f_j \in \mathcal{K}_{e_i} \cup (\tilde{k}_i)} \gamma_{i,j} g(f_i, f_j) \quad (36)$$

其中,  $\mathbf{W} \in \mathbb{R}^{d \times d}$  是参数矩阵,  $\mathbf{b} \in \mathbb{R}^d$  是偏置向量,  $p_i$  表示学生正确回答习题  $e_i$  的预测概率。在式(36)中,  $\tilde{k}_{e_i}$  是习题  $e_i$  的聚合邻居技能嵌入,函数  $g$  表示点积。SGKT 还设计了记忆衰减机制以模拟遗忘效应,动态调整历史行为的影响权重。

在 ASSISTments2009, ASSISTments2012<sup>1)</sup> 与 EdNet 等数据集上,SGKT<sup>2)</sup> 在 AUC 与 F1 指标上均优于主流序列知识追踪模型与图神经网络模型,展现出对复杂知识结构和动态认知变化的强建模能力,该模型在知识状态演化描述方面具有显著优势,能够直观展示学生对各知识点的掌握强弱,帮助学生快速发现知识短板并激发学习动机。此外,SGKT 在冷启动场景(如训练数据中学生数量较少或新学生答题序列较短)中也表现出较好的适应性和预测性能,尤其适用于在线

学习系统中新用户缺乏历史记录的情况,具有显著的实际应用价值。

#### 4.2.7 MVHGNN 模型

MVHGNN<sup>[44]</sup> (Multi-View Hypergraph Neural Network) 是面向学业表现预测的多视图超图神经网络模型,通过高阶超图结构建模学生多源行为数据的复杂关系,弥补传统图模型难以表达多元关联的缺陷。其核心是将学生作为节点,用超边连接行为相似的多个学生,结合超图卷积与注意力机制融合跨视图语义,实现学业等级的精准分类预测。

多视图超图构建以学生为节点,基于行为相似度构建超边,每个行为视图生成超图邻接矩阵  $\mathbf{A} = \mathbf{H}\mathbf{W}\mathbf{D}_v^{-1}\mathbf{H}^T$  ( $\mathbf{H}$  为关联矩阵,  $\mathbf{W}$  为超边权重),通过拼接融合为多视图超图结构;级联注意力模块(CAT)用自注意力机制生成视图权重,将注意力加权后的各视图邻接矩阵进行聚合,生成包含行为语义的元路径表示。具体形式为:

$$\mathcal{A}_p = \sigma\left(\prod_{l=1}^T \left(\sum_{t \in T} \alpha_{l,t} \tilde{\mathbf{A}}_t^{(l)}\right)\right) \quad (37)$$

其中,  $\alpha_{l,t}$  为第  $l$  层对第  $t$  个视图的注意力权重,  $\tilde{\mathbf{A}}_t^{(l)}$  为归一化处理后的视图邻接矩阵。超图特征嵌入通过超图卷积操作对节点表示进行迭代更新,更新公式为:

$$X^{(l+1)} = \sigma(\mathbf{D}_v^{-\frac{1}{2}} \mathcal{A}_p \mathbf{D}_v^{-\frac{1}{2}} X^{(l)} \mathbf{\Omega}^{(l)}) \quad (38)$$

其中,  $\mathbf{D}_v$  为节点度对角矩阵,  $\mathbf{\Omega}^{(l)}$  为第  $l$  层可学习权重矩阵,  $\sigma$  表示非线性激活函数。最终经 MLP 输出学业等级。

在北京工业大学真实校园学生行为数据集(BJUT-STUD)上的实验结果充分验证了 MVHGNN 模型的有效性和实用性。与多种图神经网络基线模型(如 GAT, GCN)相比, MVHGNN 在 F1 分数上取得了显著领先,在样本类别不平衡(如优秀:中等:较差 = 1:3:1)的现实场景中依然保持稳定优势,且能够识别出“规律用餐、短时上网、长时间在图书馆”等积极行为模式,为教学管理提供可解释的行为干预依据。

### 4.3 大模型赋能的学业表现预测方法

本节分析大模型赋能的学业表现预测方法的代表性模型,包括采用异构图行为建模与选择性 LLM 反馈触发的 SPAR-GNN 模型、融合符号图对比学习和 LLM 语义的 LLM-SBCL 模型,以及结合 Framelet 超图频谱分解与 LLM 结构化语义提取的 EduLLM 模型。

#### 4.3.1 SPAR-GNN 模型

为克服传统知识追踪方法重预测轻反馈的局限,并有效融合行为模式与大型语言模型(LLM)的优势, Sun 等<sup>[45]</sup> 提出了 SPAR-GNN (Selective Pattern-Aware Reasoning with Graph Neural Networks) 框架。该方法将学业表现预测建模为异构图,包含学生、问题、技能 3 类实体节点及表征学习行为特质(如挫败感、提示依赖)的虚拟模式节点,通过共享行为信号连接面临相似挑战的学生,实现对复杂学习动态的建模。

SPAR-GNN 的核心在于异构图建模与选择性 LLM 反馈

<sup>1)</sup> <https://pykt-toolkit.readthedocs.io/en/latest/datasets.html>

<sup>2)</sup> <https://github.com/lhuang65/SGKT>

触发的结合。模型利用异构图转换层(HGTConv)学习节点表示并预测表现。区别于全量微调 LLM 的高成本做法, SPAR-GNN 仅在“风险学生”上触发 LLM 生成反馈:当学生预测得分  $\hat{y}_i < 0.4$  且表现出高频挫败感、厌倦感或提示依赖时,系统激活 LLM(如 LLaMA-3-8B)。反馈采用结构化提示模板生成解释、技巧和案例。该机制显著降低了计算开销(Token 使用和推理负载),同时保证了反馈的针对性与时效性。

此外,SPAR-GNN 通过行为相关性分析为公平干预提供依据。分析关键行为特征(如挫败感、提示频率)与预测表现的相关性,发现提示过度使用与表现不佳呈中度负相关( $r = -0.41$ ),而挫败感与表现呈弱正相关( $r = 0.12$ ),部分挫败学生仍保持学习投入。这支持了差异化干预策略(如减少高提示依赖学生的提示可用性)。在 ASSISTments 2017 数据集上,SPAR-GNN 的预测性能(AUC=0.845)显著优于多种基线模型(包括经典机器学习、深度学习及 LLM 微调方法),展现了其在精准预测与个性化、公平性支持方面的综合优势。典型应用场景包括:为受挫学生提供结合真实场景(如咖啡店案例)的技能解释与学习建议,或为过度依赖提示的学生设计分步学习策略及类比例,有效提升模型反馈的实用性和可操作性。

#### 4.3.2 LLM-SBCL 模型

针对学习者众包平台中多项选择题(MCQs)固有的数据噪声和新题目冷启动问题,Ni 等<sup>[46]</sup>提出了一种融合符号图神经网络(Signed Graph Neural Network,SGNN)与大语言模型的创新协同方法——LLM-SBCL(Large Language Model enhanced Signed Bipartite graph Contrastive Learning)。该方法将学生答题正误预测建模为带符号二分图上的边符号预测任务(正边表正确,负边表错误)。

模型核心基于带符号二分图对比学习(SBCL)<sup>[47]</sup>并融合 LLM 语义嵌入。为增强噪声鲁棒性,采用随机符号翻转对原始图进行扰动生成两个增强图。鉴于正负边语义差异显著,为每个增强图分别构建正边子图和负边子图,并利用专用图注意力网络(GAT)分别进行编码。

为解决新题冷启动,利用 gpt-3.5-turbo-0613 从 MCQ 文本中提取关键知识词及其权重,构建问题语义嵌入  $w_j$ 。 $w_j$  表示第  $j$  个问题的最终语义嵌入,是所有  $n$  个知识点嵌入  $k p_i$  的加权平均。

$$w_j = \frac{\sum_{i=1}^n h_i \cdot k p_i}{\sum_{i=1}^n h_i} \quad (39)$$

其中, $k p_i$  表示第  $i$  个知识点的嵌入, $h_i$  表示由 LLM 生成的、第  $i$  个知识点的重要性权重。模型通过可学习矩阵,将通过 SBCL 学习到的第  $j$  个问题的结构嵌入  $v_j$  与 LLM 语义嵌入  $w_j$  融合,形成统一的问题表示。

$$q_{v_j} = (v_j \parallel w_j) W_q \quad (40)$$

最终,将学生嵌入  $u_i$  与融合后问题嵌入  $q_{v_j}$  拼接,输入 MLP 进行边符号预测,并计算交叉熵损失。

$$y_{\text{pred}} = \text{MLP}(u_i \parallel q_{v_j}) \quad (41)$$

$$\mathcal{L} = \mathcal{L}_{\text{CE}} + \beta \cdot \mathcal{L}_{\text{CL}} \quad (42)$$

总损失函数  $\mathcal{L}$  为边预测损失  $\mathcal{L}_{\text{CE}}$  与对比损失  $\mathcal{L}_{\text{CL}}$  的加权和,确保在噪声和冷启动下的有效性。其中  $\beta$  控制对比损失的贡献。

在 PeerWise 平台的 5 个真实数据集上验证表明,LLM-SBCL 显著优于 GCN,GAT 等基线模型。尤其在冷启动场景下(随机隐藏 10% 题目的边作为测试集),其 Binary-F1 分数比未融合 LLM 的 SBCL 平均提升 6.4%,在 Law 课程上最高达到 0.908,证明了该协同方法提升预测准确性与鲁棒性的优势。该模型适用于学习者众包环境中的个性化题目推荐,能够依据学生历史表现和题目语义特征动态适配题目难度,为自适应学习系统提供支持。

#### 4.3.3 EduLLM 模型

EduLLM<sup>[48]</sup>是首个融合大型语言模型(LLMs)与基于 Framelet 的有符号超图神经网络(FraS-HNN)的学生表现预测框架,专注于建模学生与选择题的交互。传统方法依赖时序建模或图神经网络,难以捕捉高阶交互及语义信息,而 EduLLM 通过 LLM 提取语义特征、超图建模高阶关系填补了这一空白。超图节点包含学生和选择题实体,答题记录被编码为正负有符号超边,任务目标是预测未知超边的正负性(即答题正确与否)。

为增强题目语义建模,EduLLM 利用预训练 LLM 对选择题(MCQ)进行深度理解。MCQ 的题干、选项、答案与解析文本被重组为结构化键值对,经 LLM 抽取关键词及权重后,通过 GloVe 向量转换与加权平均生成题目语义特征表示,提升学生与问题表示的语义对齐能力。

EduLLM 采用有符号超图建模交互关系,超边可连接多个节点以适配多学生作答同一题的场景。学生与问题集构成超图节点,系统根据答题结果构建带符号超边(正确为正,错误为负),最终表示为带符号关联矩阵  $\mathbf{H} \in \{0, 1, -1\}^{N \times M}$ ,其中  $\mathbf{H}(v, e^+) = 1$  表示节点  $v$  属于正超边, $\mathbf{H}(v, e^-) = -1$  表示属于负超边,否则为 0。

FraS-HNN 专为有符号超图设计,通过 Framelet 在谱域对超图信号进行低通与高通分解,分别捕捉群体共性认知模式与个体差异。其核心谱卷积算子通过切比雪夫多项式逼近谱滤波器以降低计算成本,并通过多尺度频谱重构实现节点表示的多频建模。为避免过平滑,每一层引入残差连接调节权重平衡。

最终,学生嵌入表示与 MCQ 语义向量拼接后输入多层感知机(MLP)预测答题正确概率,并通过二元交叉熵损失优化。

EduLLM 创新性地融合 LLM 的语义建模优势与 FraS-HNN 的超图高阶关系频谱建模能力,在来自 PeerWise 平台的 5 个真实教育数据集上,其 Binary-F1 指标显著优于所有基线模型,验证了其结构建模与语义融合能力的有效性。

在实际教育环境中,EduLLM 的应用场景十分广泛。例如,可基于学生对大量案例选择题的应答超图,精准识别群体性错误概念,为教师提供针对性补讲与习题推荐依据;在医学教育场景中,该模型能通过语义超图分析预测学生在新病例选择题上的表现,早期发现知识盲区,支持个性化学习路径规划,提升临床知识掌握效率。

表 1 基于图神经网络的学业表现预测方法代表模型

Table 1 Representative models for GNN-based academic performance prediction methods

类别	代表模型	文献	图类别	核心方法	适用场景
静态特征建模	MTGNN	Li 等 <sup>[31]</sup>	同构图	自适应融合不同关系图的信息,并根据预测任务动态调整各拓扑图的贡献权重	单学期或阶段性成绩预测任务,尤其适用于需融合多重静态特征的场景
	GSDSA	Lai 等 <sup>[32]</sup>	同构图	基于图结构密度的采样策略	中小规模教育数据的静态成绩分类
	GGCNN	Li 等 <sup>[38]</sup>	异构图	遗传算法优化的图卷积机制	静态图预测但又需要高度调优的任务,早期识别低绩效学生
融合静态特征和动态特征建模	R <sup>2</sup> GCN	Li 等 <sup>[33]</sup>	异构图	构建 SIQ 异构网络,引入残差连接并在输出层对多层次信息的融合	缓解新用户冷启动问题,适用于在线题库的学业预测与自适应学习适配
	GNN-TINet	Zhang 等 <sup>[40]</sup>	异构图	采用 GNN、Transformer 与 InceptionNet 三层异构数据处理流程	多标签学生成绩预测,适合校园大数据中教育数据不完整的环境
	APP-DGNN	Huang 等 <sup>[35]</sup>	同构图	融合交互图、属性图双图神经网络与自适应卷积算子	在线学习平台的学业预测,融合交互行为的时序依赖与静态特征
	GOAT	Peng 等 <sup>[41]</sup>	异构图	融合空间感知与时序感知模块捕获团队协作中的复杂动态	项目式学习场景,适合分析团队协作对学生整体表现的影响预测
	ACGN	Hu 等 <sup>[43]</sup>	同构图	融合图卷积与注意力机制	高校大规模课程环境中,利用课程共选关系与静态属性预测学生成绩或离校风险
	SGKT	Wu 等 <sup>[34]</sup>	异构图	异构图结合 GGNN 门控机制与注意力进行知识追踪	适用于小规模教育场景和在线学习平台中新用户缺乏历史记录的情况
	MVHGNN	Li 等 <sup>[44]</sup>	超图	超图卷积与注意力机制融合跨视图语义	适用于样本类别不平衡的教学管理行为干预
LLM 赋能	SPAR-GNN	Sun 等 <sup>[45]</sup>	异构图	引入行为模式节点融合 LLM 选择性推理	适用于需结合行为信号的知识追踪场景,兼顾预测精度与反馈效率
	LLM-SBCL	Ni 等 <sup>[46]</sup>	同构图	结合 SBCL 建模题目关系与 LLM 语义表示融合	适用于自适应学习系统,依据学生历史表现和题目语义特征动态适配题目难度
	EduLLM	Li 等 <sup>[48]</sup>	超图	融合 LLM 语义特征与有符号超图的高阶结构信息	适用于需捕捉高阶交互(多学生-单问题)的学生性能预测场景

## 5 评估相关数据集和指标

基于对现有研究的系统梳理,图神经网络在学生学业表现预测领域的评估主要依托特定教育场景数据集及多维度评价指标。以下对常用公开数据集与评价指标进行归纳分析。

### 5.1 常用公开数据集

本节介绍常用于学业表现预测任务的公开数据集,如表 2 所列。

1) OULAD<sup>[49]</sup>; OULAD<sup>1)</sup> 数据集包含 2013 年和 2014 年开放大学(The Open University)提供的课程数据,涵盖学生人口统计信息、评估成绩以及与虚拟学习环境(VLE)的交互日志。数据集包含 32593 名学生在 22 个课程呈现中的注册记录、评估结果和 VLE 互动摘要,总计 10655280 条每日点击记录。学生最终成绩分为 4 类,分别是优异、及格、不及格和退学。该数据集适用于学生成绩预测、退学行为分析、VLE 使用模式挖掘、教育干预策略评估、跨课程泛化性能验证等领域研究任务,由于数据年份较早且来自单一机构,可能影响模型的时效性与泛化能力。

2) Student Alcohol Consumption<sup>[50]</sup>; Student Alcohol Consumption<sup>2)</sup> 数据集提供葡萄牙两所学校的学生成绩数据,包括针对数学课程的 395 条记录和葡萄牙语课程的 649 条记录,涵盖 33 个属性,包括学生成绩、人口统计、社会和学校相关特征等以及 3 门课程。其规模适中,特征丰富,非常适合用于学业表现预测领域的回归任务或分类任务,但由于数量有

限且地域文化背景高度集中,这些因素可能削弱该数据集的代表性。

3) SPD24-Student Performance Data revised Features<sup>[38]</sup>; SPD24-Student Performance Data revised Features<sup>3)</sup> 数据集包括清华大学、北京大学、复旦大学、上海交通大学、浙江大学等著名高校的 9.8 万名学生数据点,涵盖 41 项特征。它旨在分析影响学生表现、幸福感和参与度的因素。这些数据包括广泛的特征,例如人口统计详细信息、学习成绩、健康状况、家长支持等。该数据集支持对学生表现的多标签预测(如“高/中/低”绩效分类),适用 GNN, Transformer 等复杂模型的结构化与序列建模,能有效验证模型在融合异构教育数据时的预测一致性与干预指导能力。但该数据集样本仅来自国内顶尖高校,可能无法代表更广泛的学生群体。

4) EdNet<sup>[51]</sup>; EdNet<sup>4)</sup> 是由 Santa 人工智能辅导系统收集的大规模教育数据集,包含超过 78 万名韩国学生的 1.3 亿余次学习交互记录,涵盖 1.3 万道题目、近 300 种技能标签及 1000 多个视频讲座。该数据集采用 4 层级结构设计(KT1-KT4),支持从简单知识追踪到复杂学习行为分析的多粒度研究。其中,KT1 提供基础答题记录,适用于逻辑回归等传统方法;KT2 增加时间序列与响应细节,支持 LSTM 等时序模型;KT3 扩展题目难度和技能标签等元数据,适用于 Transformer 架构的细粒度分析;KT4 则提供完整上下文信息(包括讲座观看记录和多步骤交互),适合图神经网络与个性化推荐系统研究。EdNet 以其大规模、分层化和行为多样化的特性,为研究者选择合适的预测方法和建模策略提供了高度灵

<sup>1)</sup> <https://doi.org/10.1038/sdata.2017.171>

<sup>2)</sup> <https://www.kaggle.com/datasets/uciml/student-alcohol-consumption>

<sup>3)</sup> <https://www.kaggle.com/datasets/nasirayub2/spd24-student-performance-data-revised-features/data>

<sup>4)</sup> <https://github.com/riiid/ednet>

活且数据充足的实验平台。但需要注意的是,大规模数据中存在较多刷题或重复尝试记录,可能引入噪声,影响行为建模的准确性。

5) ASSISTments2017<sup>[52]</sup>: ASSISTments2017<sup>1)</sup>数据集源自 ASSISTments 智能辅导系统中的学生互动。它包括来自 686 名独特学生的总共 942816 个问题解决互动,涉及 102 个

不同的问题。在这些互动中,38.2% 回答正确,其余 61.8% 回答不正确。数据集记录细粒度的响应模式,包括时间戳、技能映射和行为指标,如挫折感和暗示使用。这些特征使得它特别适合于学业表现预测领域行为感知知识跟踪和选择性反馈生成的研究。但该数据集题目数量有限,技能覆盖范围较窄,限制了模型的泛化能力。

表 2 基于图神经网络的学业表现预测方法常用数据集

Table 2 Common datasets for GNN-based academic performance prediction methods

数据集	来源	规模	缺陷	适用场景
OULAD <sup>[49]</sup>	英国开放大学 (The Open University)	32593 名学生,22 门课程、约 1.0655 千万条交互记录	数据年份较早且来自单一机构,影响模型的时效性与泛化能力	学生成绩预测、退学行为分析、教育干预策略评估、跨课程泛化性能验证
Student Alcohol Consumption <sup>[50]</sup>	葡萄牙两所学校的学生	395 条数学课程记录、649 条葡萄牙语课程记录,33 个属性特征	样本量小、地域集中,代表性有限,文化偏差显著	学业表现预测领域的回归任务或分类任务
SPD24 - Student Performance Data revised Features <sup>[38]</sup>	中国多所顶尖高校	98000 条学生数据,41 项特征	数据仅来自国内顶尖高校,无法代表更广泛的学生群体	学生表现的多标签预测,适用于 GNN,Transformer 等复杂模型的结构化与序列建模
EdNet <sup>[51]</sup>	韩国 Santa 公司旗下教育平台	78 万名学生,1.3 亿学习交互,300 技能标签,1000 多个视频讲座	大规模数据中存在大量刷题、重复尝试行为,噪声较高	图神经网络与 Transformer 模型、个性化推荐、行为序列建模、知识追踪
ASSISTments 2017 <sup>[52]</sup>	ASSISTments 在线数学辅导平台	686 名学生,942816 次交互,102 道题目	题目数量有限、技能覆盖面窄,泛化能力有限	学业表现预测领域行为感知知识跟踪和选择性反馈生成

## 5.2 评价指标

针对分类任务的学生学业表现预测,常用于评估性能的指标有:

1) 分类准确度(ACC)<sup>[40]</sup>: 正确分类的样本数占总样本数的比例。

$$ACC = \frac{TP + TN}{TP + FP + FN + TN} \quad (43)$$

其中,TP,FP,FN 和 TN 表示混淆矩阵中真阳性、假阳性、假阴性和真阴性实例的计数。

2) 召回率(Recall)<sup>[40]</sup>: 模型准确分类真阳性的比例。

$$Recall = \frac{TP}{TP + FN} \quad (44)$$

3) F1 分数<sup>[40]</sup>: 精确率(Precision)与召回率(Recall)的调和平均值。

$$F1\text{-score} = \frac{2 \times (Recall \times Precision)}{Recall + Precision} \quad (45)$$

针对回归任务的学生学业表现预测,常用于评估性能的指标有:

1) 平均绝对误差(MAE)<sup>[38]</sup>: 衡量预测值与真实值之间的平均绝对差异。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (46)$$

其中, $y_i$  表示第  $i$  个样本的真实值, $\hat{y}_i$  表示第  $i$  个样本的预测值, $n$  表示样本总数。

2) 均方误差(MSE)<sup>[38]</sup>: 衡量模型预测值与实际值之间的平均平方误差。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (47)$$

3) 决定系数(R<sup>2</sup>)<sup>[38]</sup>: 衡量预测值对真实值的拟合程度。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (48)$$

其中, $\bar{y}$  表示真实值的均值。

此外,为更贴合教育应用场景并衡量模型的长期价值,GNN-TINet 首创了定制化评估指标——预测一致性评分(PCS)<sup>[40]</sup>,用于量化模型跨时间预测的稳定性。

$$PCS = \frac{1}{N} \sum_{i=1}^N \left( \frac{1}{T_i} \sum_{t=1}^{T_i} \mathbb{I}(\hat{y}_{i,t} = y_{i,t}) \right) \quad (49)$$

学习影响因子(LIF)<sup>[40]</sup>: 评估预测变化与实际表现变化的吻合度。

$$LIF = \frac{1}{N} \sum_{i=1}^N \frac{|\Delta y_i|}{|\Delta \hat{y}_i| + \epsilon} \quad (50)$$

其中, $\epsilon$  表示极小常数。PCS 和 LIF 共同为教育决策提供了超越传统准确率指标的深入洞察。

## 5.3 模型对比分析

为了对比分析图神经网络模型在学业表现预测任务上的性能差异,本节总结了部分传统机器学习算法、MTGNN 模型和 APP-DGNN 模型在 OULAD 数据集上对学生学业风险的预测结果,包括“通过/退学”和“通过/不通过”两类任务,如表 3 所列。可以发现,基于图神经网络的模型 MTGNN 和 APP-DGNN 在所有指标上都比基于传统机器学习方法的模型表现得更好,这证明了使用图神经网络模型来预测学业成绩的有效性。并且,在基于图神经网络的模型中,融合静态和动态特征的模型 APP-DGNN 比仅基于静态特征建模的模型 MTGNN 具有更好的预测性能,这表明融合动态交互特征的图结构可以更好地编码学习行为数据以用于学业成绩预测,更容易捕获复杂学习行为中的学习状态。

<sup>1)</sup> <https://pykttoolkit.readthedocs.io/en/latest/datasets.html#assistments2017>

表3 不同模型预测学生学业风险的性能比较

Table 3 Performance comparison of different models for predicting student academic risk

模型	类别	评价指标	
		Accuracy	F1-score
SVM <sup>[53]</sup>	Pass/Fail	71.29	61.30
	Pass/Withdrawal	76.51	77.47
LR <sup>[54]</sup>	Pass/Fail	71.14	61.05
	Pass/Withdrawal	76.27	77.12
MLP <sup>[55]</sup>	Pass/Fail	73.36	62.31
	Pass/Withdrawal	79.35	80.52
GRU <sup>[56]</sup>	Pass/Fail	76.23	64.82
	Pass/Withdrawal	83.61	83.41
MTGNN <sup>[31]</sup>	Pass/Fail	80.61	73.65
	Pass/Withdrawal	86.18	87.27
APP-DGNN <sup>[35]</sup>	Pass/Fail	83.96	72.30
	Pass/Withdrawal	90.18	91.11

表4为不同算法在PeerWise平台的5个真实数据集(来自奥克兰大学的Biology和Law,来自卡迪夫大学医学院的

表4 在5个真实教育数据集上的性能比较(平均binary-F1±标准差)

Table 4 Performance comparison on five real-world educational datasets(mean binary-F1 ± standard deviation)

模型	Biology	Law	Cardiff20102	Sydney19351	Sydney23146
Random <sup>[57]</sup>	0.350±0.010	0.472±0.001	0.136±0.062	0.290±0.014	0.288±0.035
GCN <sup>[28]</sup>	0.682±0.058	0.823±0.010	0.677±0.024	0.642±0.021	0.728±0.013
GAT <sup>[22]</sup>	0.618±0.013	0.817±0.050	0.571±0.013	0.564±0.022	0.608±0.020
SGCN <sup>[58]</sup>	0.768±0.040	0.840±0.013	0.607±0.033	0.635±0.044	0.726±0.040
SBGNN <sup>[57]</sup>	0.753±0.014	0.861±0.034	0.712±0.016	0.673±0.016	0.712±0.021
SBCL <sup>[47]</sup>	0.772±0.016	0.901±0.016	0.718±0.018	0.674±0.021	0.733±0.019
LLM-SBCL <sup>[46]</sup>	0.787±0.014	0.908±0.018	0.734±0.023	0.694±0.021	0.760±0.022
EduLLM <sup>[48]</sup>	0.809±0.010	0.945±0.005	0.753±0.011	0.712±0.016	0.829±0.006

**结束语** 本文系统综述了基于图神经网络的学生学业表现预测方法的研究进展。从问题定义出发,剖析了学业表现预测的核心挑战及图建模的适应性;针对静态特征建模、结合静态特征和动态特征建模及大模型赋能3类范式,分类阐述了代表性模型的技术创新与应用场景,为后续研究提供基准支持。

尽管GNN模型已在学业表现预测中展现出良好潜力,但其应用深度与泛化能力仍面临挑战。未来研究需突破以下关键方向:

1)可扩展性与计算效率提升。当前模型在处理大规模数据时存在计算资源限制。未来需探索高效采样算法(如结合注意力机制区分邻居节点重要性),以降低计算需求、增强系统扩展性。

2)预测的可解释性优化。尽管图神经网络模型在预测学生表现方面表现出色,但其“黑盒”特性限制了在教育实际应用中的可信度和实用性。未来需重点研究图神经网络的可解释性,便于学校、教师与家长有针对性地实施干预,从而预防和规避学生可能面临的学业风险。

3)多模态语义信息融合。现有方法未充分挖掘教育资源中的丰富语义。结合大型语言模型提取文本、图像等多模态信息的语义特征,并利用符号超图神经网络建模学生与资源的非线性交互,可进一步提升预测精度。

4)动态图结构与预训练机制。当前图构建依赖静态拓扑,未来需优化邻接矩阵的动态学习机制,同时开发预训练模型框架,支持跨场景迁移微调。此外,需深入分析多拓扑

CarDiff20102,以及悉尼大学的生物化学课程Sydney19351和Sydney23146)上的性能对比,其中列出了基线模型(Random, GCN, GAT, SGCN和SBGNN),LLM-SBCL提出的带有对比学习但不包括NLP信息的SBCL以及本文重点阐述的LLM-SBCL和EduLLM模型建议的SBCL模型对高危学生预测的平均binary-F1和标准差结果。可以发现:SGCN和SBGNN考虑了有符号网络中连接边的符号,在大多数数据集上优于无符号方法(GCN, GAT);SBCL的表现一直优于SGCN和SBGNN,突出了对比学习的能力;LLM增强的变体LLM-SBCL在所有数据集上的表现都优于SBCL,展示了纳入NLP语义嵌入的好处;而EduLLM的表现始终优于所有基准模型,获得了最高的二进制F1分数。这一结果强调了基于超图的模型在捕获多尺度符号信息方面的优势。基于帧的超图卷积的使用,有效集成了低通和高通信息,有助于实现这种优越的性能。


GNN的理论优势,推动模型适应教育任务多样性。

## 参考文献


- [1] WU T, LING Q. Self-supervised heterogeneous hypergraph network for knowledge tracing [J]. Information Sciences, 2023, 624:200-216.
- [2] ZHU M, QIU L, ZHOU J. Meta-path structured graph pre-training for improving knowledge tracing in intelligent tutoring [J]. Expert Systems with Applications, 2024, 254:124451.
- [3] XIA Z, DONG N, WU J, et al. Multivariate Knowledge Tracking Based on Graph Neural Network in ASSISTments [J]. IEEE Transactions on Learning Technologies, 2023, 17:32-43.
- [4] HU S, ZOU G, YANG S, et al. Large language model meets graph neural network in knowledge distillation [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2025: 17295-17304.
- [5] MERINO-CAMPOS C. The impact of artificial intelligence on personalized learning in higher education: A systematic review [J]. Trends in Higher Education, 2025, 4(2):17.
- [6] KANCHON M K H, SADMAN M, NABILA K F, et al. Enhancing personalized learning: AI-driven identification of learning styles and content modification strategies [J]. International Journal of Cognitive Computing in Engineering, 2024, 5:269-278.
- [7] YUN Y, CAO R, DAI H, et al. Self-paced graph memory for learner GPA prediction and its application in learner multiple evaluation [J]. Scientific Reports, 2023, 13(1):21407.

- [8] HUANG Q, CHEN J. Enhancing academic performance prediction with temporal graph networks for massive open online courses[J]. *Journal of Big Data*, 2024, 11(1):52.
- [9] HUSSAIN S, GAFTANDZHIEVA S, MANIRUZZAMAN M, et al. Regression analysis of student academic performance using deep learning [J]. *Education and Information Technologies*, 2021, 26(1):783-798.
- [10] LU J, LIU Y, LIU S, et al. Machine learning analysis of factors affecting college students' academic performance[J]. *Frontiers in Psychology*, 2024, 15:1447825.
- [11] PELIMA L R, SUKMANA Y, ROSMANSYAH Y. Predicting university student graduation using academic performance and machine learning: a systematic literature review[J]. *IEEE Access*, 2024, 12:23451-23465.
- [12] MORENO-MARCOSPM, MUÑOZ-MERINOPJ, MALDONADO-MAHAUAD J, et al. Temporal analysis for dropout prediction using self-regulated learning strategies in self-paced MOOCs [J]. *Computers & Education*, 2020, 145:103728.
- [13] WANG S, NI L, ZHANG Z, et al. Multimodal prediction of student performance: A fusion of signed graph neural networks and large language models [J]. *Pattern Recognition Letters*, 2024, 181:1-8.
- [14] HAO J H, WAN Y, ZHANG Y H. Research on Node Learning of Graph Neural Network Fusing Position and Structural Information [J]. *Computer Science*, 2025, 52(7):110-118.
- [15] NI Q, WEI T, ZHAO J, et al. HHSKT: A learner-question interactions based heterogeneous graph neural network model for knowledge tracing[J]. *Expert Systems with Applications*, 2023, 215:119334.
- [16] ZHOU Y, MENG X, WANG J, et al. Daily peerrelationships and academic achievement among college students: A social network analysis based on behavioral big data [J]. *Sustainability*, 2023, 15(22):15762.
- [17] ZHAO S, SAHEBI S. Graph-enhanced multi-activity knowledge tracing[C] // *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*. Cham: Springer, 2023: 529-546.
- [18] YANG H, HU J, CHEN J, et al. MAHKT: Knowledge tracing with multi-association heterogeneous graph embedding based on knowledge transfer [J]. *Knowledge-Based Systems*, 2025, 310:112958.
- [19] LAI X, ZHAO S, ZHANG Z, et al. Research on Student Performance Prediction Based on Clustered Graph Neural Networks [C] // *2024 4th International Conference on Machine Learning and Intelligent Systems Engineering (MLISE)*. IEEE, 2024: 192-195.
- [20] NAJAFABADI M K, CHEN R A, REZAZADEH J, et al. From theory to practice: The evolution and comparative analysis of homogeneous vs. heterogeneous Graph Neural Networks in recommender systems[J]. *Neurocomputing*, 2025, 624:129446.
- [21] CHEN J, WANG X, XU X. GC-LSTM: Graph convolution embedded LSTM for dynamic network link prediction[J]. *Applied Intelligence*, 2022, 52(7):7513-7528.
- [22] ZHOU J, CUI G, HU S, et al. Graph neural networks: A review of methods and applications[J]. *AI Open*, 2020, 1:57-81.
- [23] CORSO G, CAVALLERI L, BEAINI D, et al. Principal neighbourhood aggregation for graph nets[J]. *Advances in Neural Information Processing Systems*, 2020, 33:13260-13271.
- [24] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[C] // *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook, NY: Curran Associates Inc., 2017:1025-1035.
- [25] GILMER J, SCHOENHOLZ S S, RILEY P F, et al. Neural message passing for quantum chemistry[C] // *International Conference on Machine Learning*. PMLR, 2017:1263-1272.
- [26] LI Y, TARLOW D, BROCKSCHMIDT M, et al. Gated graph sequence neural networks[J]. *arXiv:1511.05493*, 2015.
- [27] YANG Y, QIU J, SONG M, et al. Distilling knowledge from graph convolutional networks[C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020:7074-7083.
- [28] KIPF T N. Semi-Supervised Classification with Graph Convolutional Networks[J]. *arXiv:1609.02907*, 2016.
- [29] BIANCHI F M, LACHI V. The expressive power of pooling in graph neural networks[J]. *Advances in Neural Information Processing Systems*, 2023, 36:71603-71618.
- [30] BUTEREZ D, JANET J P, KIDDLE S J, et al. Graph neural networks with adaptive readouts[J]. *Advances in Neural Information Processing Systems*, 2022, 35:19746-19758.
- [31] LI M, WANG X, WANG Y, et al. MTGNN: A Novel Pipeline for Student Performance Prediction Based on Multi-Topology Graph Neural Networks[J]. *Sustainability*, 2022, 14(13):7965.
- [32] LAI X C, HAO W T H, ZHANG Z, et al. Predicting Student Performance with Graph Structure Density-Based Graph Neural Networks[C] // *Machine Learning and Intelligent Computing*. PMLR, 2024:25-32.
- [33] LI H, WEI H, WANG Y, et al. Peer-inspired student performance prediction in interactive online question pools with graph neural network [C] // *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*. 2020:2589-2596.
- [34] WU Z, HUANG L, HUANG Q, et al. SGKT: Session graph-based knowledge tracing for student performance prediction[J]. *Expert Systems with Applications*, 2022, 206:117681.
- [35] HUANG Q, ZENG Y. Improving academic performance predictions with dual graph neural networks[J]. *Complex & Intelligent Systems*, 2024, 10(3):3557-3575.
- [36] FENG Y, YOU H, ZHANG Z, et al. Hypergraphneural networks[C] // *Proceedings of the AAAI Conference on Artificial Intelligence*. 2019:3558-3565.
- [37] LIU M L, MA L. Learning Path Recommendation Based on Fusion of Hypergraph Neural Network and Dynamic Knowledge Tracing [J/OL]. <https://kns.cnki.net/kcms2/article/abstract?v=hyKDWyHWvTsHP7JR3SLw4W44iVEtZDCXWMe06vXn9Xv8tNKtkDECHbnaqEaAV-qMssjw5YvMBEVn26C94yW9Hnv4IPLon46KuqWbfMYyMhj5uzSUCNZ1qhrqJAEH-ffN2Wudf6HtY-vO9-t4cdjyv70KYqMw99O7zyYw3atGPSF5e3SjptRXqQ==&-uniplatform=NZKPT&-language=CHS>.

- [38] LI T. Prediction and Optimization of Student Grades Based on Genetic Algorithm and Graph Convolutional Neural Networks [J]. *International Journal of Computational Intelligence Systems*, 2025, 18(1):59.
- [39] SCHLICHTKRULL M, KIPF T N, BLOEM P, et al. Modeling relational data with graph convolutional networks[C]// *European Semantic Web Conference*. Cham: Springer, 2018:593-607.
- [40] ZHANG X, ZHANG Y, CHEN A L, et al. Optimizing multi-label student performance prediction with GNN-TINet: A contextual multidimensional deep learning framework[J]. *PLoS One*, 2025, 20(1):e0314823.
- [41] PENG T, YUE Q, LIANG Y, et al. GOAT: a novel global-local optimized graph transformer framework for predicting student performance in collaborative learning [J]. *Scientific Reports*, 2025, 15(1):9861.
- [42] LI Y, HAO Y, ZHAO P, et al. Edge-enhanced global disentangled graph neural network for sequential recommendation[J]. *ACM Transactions on Knowledge Discovery from Data*, 2023, 17(6):1-22.
- [43] HU Q, RANGWALA H. Academic performance estimation with attention-based graph convolutional networks[J]. *arXiv*: 2001.00632, 2020.
- [44] LI M, ZHANG Y, LI X, et al. Multi-view hypergraph neural networks for student academic performance prediction[J]. *Engineering Applications of Artificial Intelligence*, 2022, 114:105174.
- [45] SUN Z, WANG J, ALAMRI A, et al. Spar-gnn: Knowledge tracing with behavioural patterns and selective llm feedback[C]// *International Conference on Artificial Intelligence in Education*. Cham: Springer, 2025:328-335.
- [46] NI L, WANG S, ZHANG Z, et al. Enhancing student performance prediction on learnersourced questions with sgnn-llm synergy[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. 2024:23232-23240.
- [47] HIRSCHFELD R, ROSE K. *Self-Sustaining Systems*[M]// *Lecture Notes in Computer Science*. Berlin: Springer, 2008.
- [48] LI M, CHENG Y, BAI L, et al. EduLLM: Leveraging Large Language Models and Framelet-Based Signed Hypergraph Neural Networks for Student Performance Prediction[C]// *Forty-second International Conference on Machine Learning*. 2025.
- [49] KUZILEK J, HLOSTA M, ZDRAHAL Z. Data descriptor: Open University learning analytics dataset. *Scientific Data*, 4, 1-8[EB/OL]. (2017-11-28) [2025-09-03]. [https://scholar.google.com/hk/scholar?hl=zh-CN&as\\_sdt=0,5](https://scholar.google.com/hk/scholar?hl=zh-CN&as_sdt=0,5).
- [50] IMRAN M, LATIF S, MEHMOOD D, et al. Student academic performance prediction using supervised learning techniques[J]. *International Journal of Emerging Technologies in Learning*, 2019, 14(14):92.
- [51] SHIN D, SHIM Y, YU H, et al. Saint+: Integrating temporal features for ednet correctness prediction[C]// *LAK21: 11th International Learning Analytics and Knowledge Conference*. 2021:490-496.
- [52] YEUNG C K, YEUNG D Y. Incorporating features learned by an enhanced deep knowledge tracing model for stem/non-stem job prediction[J]. *International Journal of Artificial Intelligence in Education*, 2019, 29(3):317-341.
- [53] ARASHPOUR M, GOLAFSHANI E M, PARTHIBAN R, et al. Predicting individual learning performance using machine-learning hybridized with the teaching-learning-based optimization[J]. *Computer Applications in Engineering Education*, 2023, 31(1):83-99.
- [54] HASSAN S U, WAHEED H, ALJOHANI N R, et al. Virtual learning environment to predict withdrawal by leveraging deep learning[J]. *International Journal of Intelligent Systems*, 2019, 34(8):1935-1952.
- [55] LEE H J J. Comparative study on predicting student grades using five machine learning algorithms[J]. *The Journal of Korea Institute of Information Technology*, 2022, 20(11):9-21.
- [56] HE Y, CHEN R, LI X, et al. Online at-risk student identification using RNN-GRU joint neural networks[J]. *Information*, 2020, 11(10):474.
- [57] HUANG J, SHEN H, CAO Q, et al. Signed bipartite graph neural networks[C]// *Proceedings of the 30th ACM International Conference on Information & Knowledge Management*. 2021:740-749.
- [58] DERR T, MA Y, TANG J. Signed graph convolutional networks [C]// *2018 IEEE International Conference on Data Mining (ICDM)*. IEEE, 2018:929-934.



**ZHAI Jie**, born in 1977, Ph.D, lecturer, master's supervisor, is a member of CCF(No. K7876M). Her main research interests include big models, teaching decision support and computer practice teaching.



**CHEN Lexuan**, born in 2001, postgraduate. Her main research interests include graph neural networks, big model technology and academic performance prediction.

(责任编辑:何杨)