

融入课程知识图谱的 KMAKT 预测

王炼红¹, 林飞鹏¹, 李潇瑶², 湛桂枝³, 周莉¹

(1. 湖南大学电气与信息工程学院, 湖南 长沙 410082; 2. 中南林业科技大学计算机与信息工程学院, 湖南 长沙 410004;
3. 湖南汽车工程职业学院信息工程学院, 湖南 株洲 412001)

摘要: 现有多数深度知识追踪模型的知识追踪结果的可解释性弱, 且忽视了习题与知识点的内在关联性对知识追踪效果与预测结果的影响。针对上述问题, 提出一种用于学生表现预测的结合课程知识图谱与多头注意力机制的知识追踪(KMAKT)模型。首先, 采用 Word2Vec 和双向长短期记忆(BiLSTM)网络将习题作答序列数据转换为低维稠密向量, 利用图嵌入模型 TransR 进行课程知识图谱嵌入表示, 并使用多头注意力机制计算过往习题作答序列对当前知识状态的贡献程度; 然后, 通过注意力网络挖掘前驱知识对预测结果的影响程度; 最后, 通过多层神经网络获取预测结果, 提高模型的可解释性与预测精度。实验结果表明, KMAKT 模型在 ASSISTments2017 数据集上的受试者工作特征曲线下的面积(AUC)、准确率和 F1 值相比于深度知识追踪(DKT)模型分别提升了约 5.20、4.20 和 2.40 个百分点, 具有较好的预测性能。在湖南大学信号与系统(HNU_SYS)子数据集上的知识追踪可视化结果验证了 KMAKT 模型的知识追踪结果符合教育学认知规律且具备一定程度的可解释性。

关键词: 表现预测; 课程知识图谱; 注意力机制; 知识追踪; 长短期记忆网络; 语义特征

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0069345

Prediction Using KMAKT Integrated with Course Knowledge Graph

WANG Lianhong¹, LIN Feipeng¹, LI Xiaoyao², CHEN Guizhi³, ZHOU Li¹

(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, Hunan, China;
2. College of Computer and Information Engineering, Central South University of Forestry and Technology, Changsha 410004, Hunan, China;
3. College of Information Engineering, Hunan Automotive Engineering Vocational College, Zhuzhou 412001, Hunan, China)

【Abstract】 Most existing deep knowledge tracking models have weak interpretability of knowledge tracking results and overlook the impact of the inherent correlation between exercises and knowledge points on the effectiveness of knowledge tracking and prediction results. To address these issues, this study proposes a course Knowledge graph and Multi-head Attention mechanism-based Knowledge Tracing (KMAKT) model to predict student performance. First, Word2Vec and Bidirectional Long Short-Term Memory (BiLSTM) networks are used to convert exercise answering sequence data into dense low dimensional vectors. The graph embedding model TransR is used to embed the course knowledge graph representation, and a multi-head attention mechanism is used to calculate the contribution of past exercise answering sequences to the current knowledge state. Subsequently, the influence of the precursor knowledge on the prediction results is explored using attention networks. Finally, prediction results are obtained using multi-layer neural networks, and the interpretability and prediction accuracy of the model are improved. The experimental results show that on the ASSISTments2017 dataset, the Area Under receiver operating Characteristic (AUC), accuracy, and F1 value of the KMAKT model are improved by approximately 5.20, 4.20, and 2.40 percentage points, respectively, as compared to conventional Deep Knowledge Tracking (DKT). Therefore, The KMAKT model has good prediction performance. The visualization results of knowledge tracking on the Hunan University Signal and System (HNU_SYS) sub-dataset verify that the KMAKT model conform to the cognitive laws of education and have a certain degree of interpretability.

【Key words】 performance prediction; course knowledge graph; attention mechanism; knowledge tracing; Long Short-Term Memory (LSTM) network; semantic feature

0 引言

随着信息技术与人工智能的不断深入发展, 如

何准确地刻画学生画像并追踪学生知识状态的变化是实现个性化智慧教育的关键问题^[1-3]。知识追踪是实现智慧教育的重要手段之一。基于传统认知诊

收稿日期: 2024-02-02 修回日期: 2024-04-23

基金项目: 国家自然科学基金(62377010); 湖南省教育厅科学研究重点项目(22A0021)。

通信作者 E-mail: wanglh@hnu.edu.cn

断模型的静态知识追踪算法^[4-6]和贝叶斯知识追踪(BKT)模型^[7-8]因具备的可解释性强而倍受研究者关注。但是,以上算法和模型在表征复杂度上的局限性导致它们在处理大规模数据集时表现欠佳,难以精准适应涉及海量学生群体、广泛习题类型与深层次知识点交织的复杂追踪需求。

深度知识追踪(DKT)模型^[9]通过有效地捕捉、组织和利用海量学习序列数据,在大规模数据集上表现出色,但在模型的可解释性方面表现较差,难以厘清隐藏状态是如何代表学习者的知识状态,诸多研究者对 DKT 模型结构进行了改进研究^[10-15]。文献[12]提出了融合遗忘信息的深度知识追踪模型,考虑了学习者的整个交互序列来表示复杂的遗忘行为。针对 DKT 模型不能很好地处理数据稀疏问题,文献[13]将 Transformer 引入知识追踪领域,提出了基于自注意力的知识追踪(SAKT)方法,挖掘待预测习题与过往交互序列的相关性。文献[14]提出了基于对抗训练的知识追踪(ATKT)模型,降低了模型过度拟合风险,增强了泛化能力。文献[15]提出了一种动态知识追踪(EKT)框架,引入注意力机制计算文本语义来建模习题资源特征。文献[16]通过挖掘题目之间多维度、深层次的语义关联信息,构建一种涵盖习题、语义和作答结果的注意力结构,在损失函数中引入具有可解释性的正则化项和权衡因子,实现对模型预测性能与可解释强度的调控。文献[17]将能力因素引入学习反馈归因,提出线性图潜在能力(LGLA)模型,构建了知识和能力双重追踪框架,具有较好的可解释性和可理解性。

以上研究未深入挖掘知识点语义关联结构等信息与学习者知识状态变化的相互作用,且神经网络的“黑箱”特性使得知识追踪结果难以取得较高置信度,而引入高度语义化的知识图谱技术可在一定程度上缓解此类问题。

知识图谱技术是知识可视化的最新研究进展,因其具备卓越的信息表达能力,可在各个知识点间构建起复杂的非线性语义关联关系,有效应对在线学习环境中的个性化推荐、学习进度监控、成效评估等多方面的挑战,深度赋能个性化学习辅助领域^[18-19]。其根据应用范围的不同可分为通用知识图谱和领域知识图谱。课程知识图谱是领域知识图谱在教育领域的应用形式。文献[20]重点探讨了课程内部知识点与学习资源的关联性,据此构建课程知识图谱,实现学习路径个性化定制与学习资源精准推荐,优化学习流程并提升学习资源的获取效率与

匹配度。文献[21]针对学生使用在线学习平台时发帖内容的语义与上下文,构建多维知识图谱,增强知识间的全局关联性,提出基于知识图谱的细粒度、多上下文感知的学习路径推荐方法,为具备相似知识点水平和学习偏好的学生推荐个性化的学习路径。文献[22]考虑到课程之间的知识关联性,结合知识图谱实现跨课程视频推荐,使得学习者可以高效地在不同课程间探索与巩固知识,但未深入挖掘课程知识图谱中知识点关联性对学生知识状态的潜在影响。

总之,现有的深度知识追踪对学习者的学习诊断预测依赖了海量的历史作答数据,主要存在如下问题:1)由于深度神经网络(DNN)的“黑箱”特性,导致知识追踪结果可解释性较弱;2)现有模型未考虑过往期习题作答序列数据与知识状态对预测习题作答结果的影响,未能关注到对待预测习题有较大影响的已作答习题序列;3)现有模型未能关注到前驱知识点的掌握程度对当前习题作答结果预测的影响,忽视了知识学习的顺序性与内在关联性对学习效果的潜在影响。

为了解决上述问题,本文提出了结合课程知识图谱与多头注意力机制的知识追踪(KMAKT)模型,旨在融合知识图谱的语义特性与深度学习网络表征能力强的优势,深入探索知识关联性对学生知识状态的影响,提高学生的习题表现预测性能。

1 相关理论基础

1.1 深度知识追踪

深度知识追踪模型是以学生的习题作答序列数据为依据,建模追踪学生的知识状态变化情况。诸多研究表明:应用长短期记忆(LSTM)网络处理习题作答序列,可以取得良好的知识追踪效果^[15,23]。本文使用 LSTM 网络作为主干网络,执行后续学生知识状态建模与追踪任务,LSTM 网络单元结构如图 1 所示。

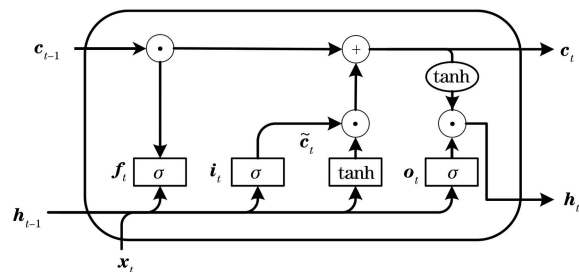


图 1 LSTM 网络单元结构

Fig.1 Structure of LSTM network unit

在图 1 中, f_t 为遗忘门,用于控制前一个网络单元记忆内容的遗忘度, i_t 为输入门,负责接收前一个网络单元的内容, \tilde{c}_t 表示当前单元从输入数据中提取出的有效信息,根据输出门 o_t 和当前单元记忆内容 \tilde{c}_t 计算 t 时刻的学生知识状态参数 h_t 。具体计算过程如式(1)~式(6)所示:

$$i_t = \sigma(x_t W_{x_i} + h_{t-1} W_{h_i} + b_i) \quad (1)$$

$$f_t = \sigma(x_t W_{x_f} + h_{t-1} W_{h_f} + b_f) \quad (2)$$

$$o_t = \sigma(x_t W_{x_o} + h_{t-1} W_{h_o} + b_o) \quad (3)$$

$$\tilde{c}_t = \tanh(x_t W_{x_c} + h_{t-1} W_{h_c} + b_c) \quad (4)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (5)$$

$$h_t = o_t \odot \tanh(c_t) \quad (6)$$

1.2 课程知识图谱

知识图谱本质上是具有实体间关系的语义网络,由三元组组成。三元组包含实体、关系和属性 3 个要素,是构成知识图谱的基础。

知识图谱分为通用知识图谱与领域知识图谱,应用于教育领域时可称为课程知识图谱,与业界开源大规模的通用知识图谱不同,在课程知识图谱中包含了与教学、学习相关的知识点前驱、后继、并行关系等,往往需要专家反复斟酌进行调整,因此通过自动化知识抽取方法进行构建难以直接达到预期目标。本文通过人工构建,使用领域知识本体“七步法”,自底向上构建课程知识本体,构建知识概念类的等级层次结构,获取课程本体实例及其关系。课程的知识图谱将知识点层级划分为课程、章节以及知识点,各节点间存在包含、顺序(前驱与后继)、并行等关系,为后续辅助学习者知识状态建模打下基础。课程知识图谱本

体构建层次架构如图 2 所示。




图 2 课程知识图谱结构

Fig.2 Structure of course knowledge graph

2 问题描述

知识追踪模型的目标是根据学生的过往学习交互序列数据,评估学生在每次交互后的知识状态。使用 $U = \{u_1, u_2, \dots, u_l\}$ 表示学生集合, I 为学生序号; $E = \{e_1, e_2, \dots, e_T\}$ 为学生已作答习题集合, T 为习题序号; $R = \{r_1, r_2, \dots, r_T\}$ 表示学生作答习题的结果。知识追踪任务实现 2 个目标:1)基于既有习题作答序列数据,预测学生在面对新习题 e_{T+1} 时的解答结果 r_{T+1} ;2)追踪并分析学生每完成一道习题后,其知识水平的变化情况。

3 KMAKT 模型设计

本文所设计的知识追踪改进模型 KMAKT 的整体框架如图 3 所示。KMAKT 模型共划分为 5 个部分,分别为习题文本嵌入表示、习题相似度计算、学生知识状态建模、前驱知识影响判定、习题作答预测结果输出。

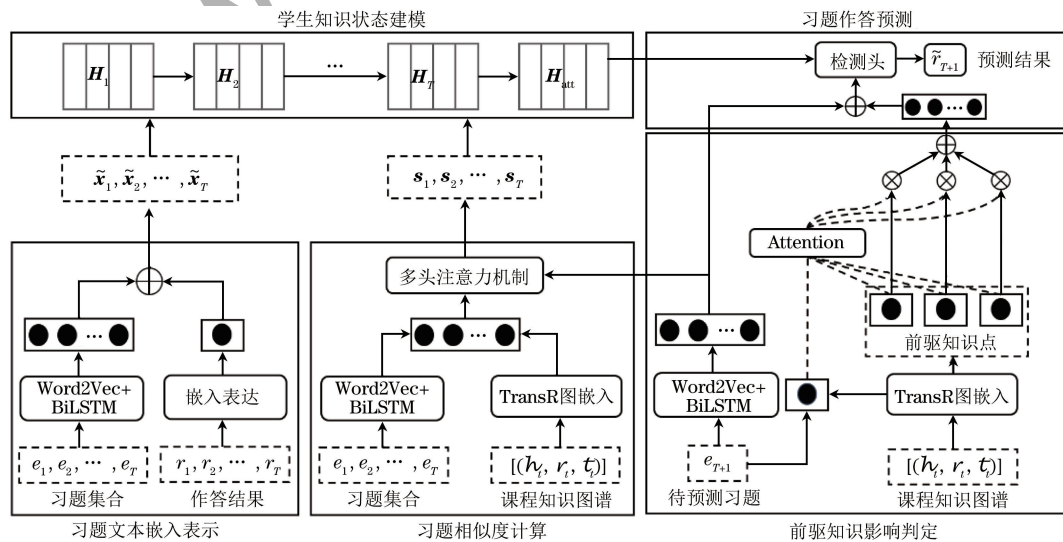


图 3 KMAKT 模型整体框架
Fig.3 Overall framework of KMAKT model

3.1 习题文本嵌入表示

本文研究的习题对象为客观题,主要由文字与公式构成。由于常见的 One-Hot 编码未能捕捉习题语义特征,因此本文研究通过双向长短期记忆(BiLSTM)网络实现习题文本嵌入任务,BiLSTM 网络结构如图 4 所示。




图 4 BiLSTM 网络结构

Fig. 4 Structure of BiLSTM network

习题文本嵌入包含词模型训练和句模型训练两个过程。首先,使用 Word2Vec 模型训练习题文本数据得到第 t 道习题的词向量组 $\mathbf{N}_t = (w_1, w_2, \dots, w_m, \dots, w_M)$,其中, w_m 表示习题文本中第 m 个分词的词向量。随后通过 BiLSTM 网络将该分词对应的前向隐向量与反向隐向量独立建模,计算过程如式(7)和式(8)所示:

$$\vec{g}_m = \sigma(w_m \mathbf{W}_{wh}^{(f)} + \vec{g}_{m-1} \mathbf{W}_{hh}^{(f)} + b_h^{(f)}) \quad (7)$$

$$\overleftarrow{g}_m = \sigma(w_m \mathbf{W}_{wh}^{(b)} + \overleftarrow{g}_{m-1} \mathbf{W}_{hh}^{(b)} + b_h^{(b)}) \quad (8)$$

式中: \vec{g}_m 表示前向隐向量; \overleftarrow{g}_m 代表反向隐向量; σ 为激活函数; $\mathbf{W}_{wh}^{(f)}$ 、 $\mathbf{W}_{hh}^{(f)}$ 、 $\mathbf{W}_{wh}^{(b)}$ 、 $\mathbf{W}_{hh}^{(b)}$ 为 LSTM 结构权重矩阵; $b_h^{(f)}$ 、 $b_h^{(b)}$ 为可调整偏置参数。

接着,将 \vec{g}_m 和 \overleftarrow{g}_m 拼接得到 w_m 的隐向量表征参数 \mathbf{g}_m 。然后通过池化层,得到习题的句模型表征向量 \mathbf{x}_t ,如式(9)所示:

$$\mathbf{x}_t = \text{MaxPool}(\mathbf{g}_1, \mathbf{g}_2, \dots, \mathbf{g}_m, \dots, \mathbf{g}_M) \quad (9)$$

最后,根据不同习题作答结果,对句模型 \mathbf{x}_t 做不同的处理:若作答结果正确,则将其拼接在 \mathbf{x}_t 后面;若习题作答结果错误,则将其拼接在 \mathbf{x}_t 前面,由此得到处理完毕的习题特征向量 $\tilde{\mathbf{x}}_t$ 。 $\tilde{\mathbf{x}}_t$ 计算方法如式(10)所示:

$$\tilde{\mathbf{x}}_t = \begin{cases} [\mathbf{x}_t \oplus r_t], & r_t = 1 \\ [r_t \oplus \mathbf{x}_t], & r_t = 0 \end{cases} \quad (10)$$

3.2 结合课程知识图谱与注意力机制的习题相似性挖掘

当前多数模型基于向量距离度量方法计算相似度,如余弦相似度、杰卡德系数等,但这些方法未能充分考虑习题的语义特征。考虑到知识点之间存在复杂的逻辑和语义关联性,采用多头注意力机制(如

图 5 所示),结合习题知识点的逻辑关联性和习题文本的语义信息,以衡量习题之间的相似度。从知识点层面挖掘习题相似度特征信息,量化学生过往作答的习题序列对新习题作答的影响。




图 5 多头注意力机制结构

Fig. 5 Structure of multi-head attention mechanism

为了将课程知识图谱引入知识追踪过程,抽取知识点实体与知识点关系构成形如 (h, r, t) 的三元组输入图嵌入模型 TransR,训练得到各知识点实体的嵌入向量表达 \mathbf{z}_t 。

结合课程知识图谱与多头注意力机制,计算获取知识点在注意力网络中不同子空间下的向量表示,捕获知识点间的相似性依赖关联关系。知识点向量 \mathbf{z}_t 在第 n 个注意力头中的查询向量 $\mathbf{q}_t^{(n)}$ 、键向量 $\mathbf{k}_t^{(n)}$ 、值向量 $\mathbf{v}_t^{(n)}$ 的计算过程如式(11)所示:

$$\mathbf{q}_t^{(n)} = \mathbf{z}_t \mathbf{W}_n^{(q)}, \mathbf{k}_t^{(n)} = \mathbf{z}_t \mathbf{W}_n^{(k)}, \mathbf{v}_t^{(n)} = \mathbf{z}_t \mathbf{W}_n^{(v)} \quad (11)$$

式中: $\mathbf{W}_n^{(q)}$ 、 $\mathbf{W}_n^{(k)}$ 和 $\mathbf{W}_n^{(v)}$ 为第 n 个注意力头中的映射矩阵参数,可将知识点向量 \mathbf{z}_t 变换到不同的子空间中。

通过缩放点积方法进行自注意力权重打分,如式(12)所示:

$$\text{Attention}(\mathbf{q}, \mathbf{k}, \mathbf{v}) = \text{Softmax}\left(\frac{\mathbf{q}\mathbf{k}^T}{\sqrt{d}}\right)\mathbf{v} \quad (12)$$

通过注意力模块挖掘习题考查知识点在不同子空间中的相似性关联参数 $\mathbf{s}_t^{(n)}$,并根据对应的权重进行聚合,计算输出当前习题 t 与待预测习题的相似性参数 \mathbf{s}_t ,具体过程如式(13)和式(14)所示:

$$\mathbf{s}_t = \text{Concat}(\mathbf{s}_t^{(1)}, \mathbf{s}_t^{(2)}, \mathbf{s}_t^{(3)})\mathbf{W}^{(o)} \quad (13)$$

$$\mathbf{s}_t^{(n)} = \text{Attention}(\mathbf{q}_t^{(n)}, \mathbf{k}_t^{(n)}, \mathbf{v}_t^{(n)}), n = 1, 2, 3 \quad (14)$$

3.3 学生知识状态建模

将习题特征工程得到的嵌入向量 \mathbf{x}_t 与习题作答结果拼接处理得到习题特征向量 $\tilde{\mathbf{x}}_t$ 。使用 LSTM 网络作为知识追踪的主干网络,通过隐状态向量 $\mathbf{H}_t = (\mathbf{h}_t^{(1)}, \mathbf{h}_t^{(2)}, \dots, \mathbf{h}_t^{(k)}, \dots, \mathbf{h}_t^{(K)})$ 表征知识点掌握程度,将每个知识掌握向量以及习题特征向量分别送入 LSTM 网络,实现了在学生作答完一道习题后对每个知识点掌握向量分别追踪。

$$\mathbf{h}_t^{(k)} = \text{LSTM}(\tilde{\mathbf{x}}_t^{(k)}, \mathbf{h}_{t-1}^{(k)}) \quad (15)$$

在计算出习题相似度后,将不同时刻的隐状态参数 \mathbf{H}_t 与习题相似度 s_t 进行加权聚合,计算得到当前学生作答 t 道习题后的知识状态矩阵参数 \mathbf{H}_{att} ,计算过程如式(16)所示:

$$\mathbf{H}_{\text{att}} = \sum_{t=1}^T s_t \mathbf{H}_t \quad (16)$$

3.4 前驱知识影响判定

知识点的学习具有先后关联顺序,学习者对前驱知识点的掌握水平将影响其后继知识点的学习。利用基于深度神经网络的注意力网络 κ 来模拟各前驱知识点的掌握水平对当前习题作答的不同程度的影响。通过课程知识图谱获取当前待预测习题所考查知识点的嵌入表示 \mathbf{z}_{T+1} 以及其所对应的前驱知识点的嵌入表示 $\mathbf{z}_{T+1,i}$,将两者拼接后送入注意力网络 κ ,计算归一化影响权重,如式(17)所示:

$$\zeta_{T+1,i} = \text{Softmax}(\kappa(\mathbf{z}_{T+1}, \mathbf{z}_{T+1,i})) \quad (17)$$

将各前驱知识点对于当前知识点的影响权重 $\zeta_{T+1,i}$ 与各前驱知识点嵌入 $\mathbf{z}_{T+1,i}$ 进行加权聚合,得到表征所有前驱知识点的影响嵌入向量 $\tilde{\mathbf{z}}_{T+1}$,计算方法如式(18)所示:

$$\tilde{\mathbf{z}}_{T+1} = \sum_{i=1}^N \zeta_{T+1,i} \mathbf{z}_{T+1,i} \quad (18)$$

3.5 习题作答结果预测输出

在模型的预测阶段,首先将待预测习题特征向量与前驱知识影响向量拼接,然后与学生知识状态矩阵 \mathbf{H}_{att} 一同输入双层神经网络中计算预测结果 \tilde{r}_{T+1} ,过程如式(19)~式(21)所示:

$$\mathbf{p}_{T+1} = [\tilde{\mathbf{x}}_t \oplus \tilde{\mathbf{z}}_{T+1}] \quad (19)$$

$$\mathbf{y}_{T+1} = \text{ReLU}(\mathbf{W}_1 \cdot [\mathbf{H}_{\text{att}} \oplus \mathbf{p}_{T+1}] + \mathbf{b}_3) \quad (20)$$

$$\tilde{r}_{T+1} = \sigma(\mathbf{W}_2 \cdot \mathbf{y}_{T+1} + \mathbf{b}_2) \quad (21)$$

在训练过程中,采用交叉熵损失函数,计算过程如式(22)所示:

$$L = - \sum_{t=1}^T (r_t \log_a \tilde{r}_t + (1 - r_t) \log_a (1 - \tilde{r}_t)) \quad (22)$$

4 实验结果与分析

4.1 数据集介绍

使用多个数据集进行实验研究,分别为湖南大学信号与系统(HNU_SYS)^[24]系列数据集(使用 HNU_SYS2 和 HNU_SYS3)、ASSISTments2017^[25]以及 Junyi^[26]数据集。对原始数据集做了数据清洗工作,例如删去作答记录数量小于 10 的无效用户、

剔除正确率小于 10% 的无效数据、交互序列长度填充与裁剪对齐等。各数据集的详细信息如表 1 所示。

表 1 数据集统计信息

数据集	学生数	习题数	知识点数	作答记录数
HNU_SYS2	770	221	50	84 320
HNU_SYS3	590	221	50	63 720
ASSISTments2017	1 709	3 162	102	942 816
Junyi	238 124	835	41	25 824 674

HNU_SYS 系列是本团队自建的公开数据集,源于中国大学大型开放式网络课程(MOOC)湖南大学国家精品课程《《信号与系统》课程》,包含 2019 年、2021 年、2022 年 1 826 名 MOOC 学习者的 169 490 条习题作答记录;ASSISTments 系列数据集以及 Junyi 数据集为知识追踪领域广泛使用的公开数据集。实验工作环境为:Windows 10 操作系统,内核采用 Intel Core i9-9900K CPU @ 3.60 GHz,内存为 32 GB。在课程专家协助下根据数据集中的知识点构建课程知识图谱,以 HNU_SYS 系列数据集为例,构建知识点三元组形式如表 2 所示。

表 2 HNU_SYS 数据集的知识图谱三元组示例

Table 2 Examples of knowledge graph triplets of the HNU_SYS dataset

头实体	尾实体	实体关系
信号的定义与分类	信号的运算	前驱
离散系统 Z 域分析	Z 变换定义与收敛域	后继
几种典型信号	冲激信号与阶跃信号	包含
信号的定义与分类	系统的分类	并列

4.2 评价指标

知识追踪任务属于一种机器学习任务,使用的评价指标为受试者工作特征曲线下的面积(AUC)、准确率以及 F1 值,具体计算如式(23)~式(26)所示:

$$A = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FP}} + N_{\text{FN}}} \quad (23)$$

$$R = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (24)$$

$$P = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (25)$$

$$F_1 = \frac{2 \times R \times P}{R + P} \quad (26)$$

式中:A 表示准确率; N_{TP} 表示模型预测学生作答正确的正样本数量; N_{TN} 表示模型预测学生作答错误的正样本数量; N_{FN} 为模型预测学生作答错误的

负样本数量; N_{FP} 为模型预测学生作答正确的负样本数量; R 表示召回率; P 表示精确率; F_1 表示 F1 值。

4.3 对比实验

选取 6 个典型的静态知识追踪与动态知识追踪模型作为对比实验的基准模型,分别为认知反应模型(C&RM)^[6]、BKT^[7]、DKT^[9]、动态键值对记忆网络(DKVMN)^[23]、SAKT^[13]和卷积知识追踪(CKT)^[27]。各基准模型介绍如下:

C&RM:设计能力与努力特征补偿机制,融合特征参数并建模学习者知识水平的认知诊断模型。

BKT:将每个学生的知识状态假设为一组二元变量,使用隐马尔可夫模型跟踪知识状态变化。

DKT:使用循环神经网络处理习题作答序列,实现学生知识点掌握程度的变化追踪。

DKVMN:使用动态键值网络模拟学生学习过程,存储知识概念并更新相应的掌握情况。

SAKT:使用自注意力机制计算对当前预测结果真正有效的数据,应对数据稀疏问题。

CKT:使用卷积神经网络(CNN)设计分层卷积层,通过滑动窗口处理多个连续学习交互,提取个性化学习率特征。

KMAKT 模型具有习题文本嵌入表示模块; ASSISTments2017 未提供习题文本,使用习题考查的知识点文本代替; Junyi 数据集未直接提供习题文本,可利用数据集中习题的唯一标识 name 字段,进入均一教育平台爬取习题文本,对于部分无

法获取文本的习题使用知识点文本代替。将每个数据集进行划分,80%作为训练集,20%为测试集,并将训练集的 20%作为验证集,以筛选模型最优超参数。

图 6 展示了 KMAKT 模型与各基准模型在 4 个数据集上的对比实验结果。不难发现, KMAKT 模型在 4 个数据集上均取得最佳的性能结果,模型的性能相比传统模型有较大提升。与动态知识追踪模型相比,静态模型的表现相对较差,主要原因可能是静态模型的代表能力有限,难以应对大规模数据集中海量学生知识状态变化。在 ASSISTments2017 数据集上, KMAKT 模型相比 DKVMN、SAKT 模型在 AUC 指标上提升了约 5、10 个百分点,相比 CKT 模型提升了约 4 个百分点,并且在 HNU_SYS 系列和 Junyi 数据集上也有优秀的表现,优于基线模型。主要原因可能是 DKVMN 模型利用知识点来表示习题,但未深入挖掘知识间的关联影响; SAKT 模型利用注意力机制应对数据稀疏问题,但未关注语义逻辑上的前驱知识状态对预测结果的贡献; CKT 模型利用分层卷积层捕捉个性化学习特征,未能关注知识点深层关联性对知识状态的潜在影响。因此,上述模型性能表现略差于 KMAKT 模型。实验结果表明,深度挖掘知识关联与学生知识状态的潜在影响对 KMAKT 模型预测性能的提升具有重要作用。




图 6 对比实验结果

Fig. 6 Results of comparative experiments

4.4 消融实验

为了验证习题文本嵌入表示、习题相似度计算以及前驱知识影响判定模块对 KMAKT 模型性能提升的贡献,进行消融实验,其中,“KMAKT-E”表

示保留习题文本嵌入表示模块,“KMAKT-S”表示保留习题相似度计算模块,“KMAKT-P”表示保留前驱知识影响判定模块,具体的实验结果如表 3 和表 4 所示。

表 3 各数据集上消融实验的 AUC 值

Table 3 AUC values of ablation experiments on each dataset

模型	HNU_ SYS2	HNU_ SYS3	ASSISTments 2017	Junyi
KMAKT-E	0.781 4	0.821 8	0.721 1	0.781 1
KMAKT-S	0.836 8	0.861 4	0.754 2	0.812 5
KMAKT-P	0.810 5	0.823 5	0.739 3	0.801 7
KMAKT	0.868 3	0.896 2	0.783 3	0.857 4

表 4 各数据集上消融实验的准确率

Table 4 Accuracy of ablation experiments on each dataset

模型	HNU_ SYS2	HNU_ SYS3	ASSISTments 2017	Junyi
KMAKT-E	0.821 5	0.797 4	0.681 4	0.712 2
KMAKT-S	0.863 9	0.842 2	0.702 3	0.758 5
KMAKT-P	0.832 8	0.814 1	0.694 2	0.734 1
KMAKT	0.897 2	0.864 2	0.724 1	0.801 1

从表 3 可以看出, KMAKT 模型所加的习题嵌入模块、习题相似度计算模块、前驱知识影响判定模块均对模型性能有不同程度的提升, 并且 KMAKT-S 模型中结合课程知识图谱与多头注意力机制的习题相似度计算模块的提升效果最佳。例如, 在 HNU_ SYS2 数据集上, 与 KMAKT-E 模型和 KMAKT-P 模型相比, KMAKT-S 模型在 AUC 指

标上分别提升了 5.54 和 2.63 个百分点。同时, 在数据集 ASSISTment2017 以及 Junyi 上的实验数据显示, 相较于只添加单一模块的消融模型, KMAKT 模型在 AUC、准确率指标上均表现最佳, 这是因为 KMAKT 模型将课程知识图谱的丰富语义特性引入知识追踪模型, 通过多头注意力机制挖掘过往习题作答序列数据对预测结果的贡献, 并根据知识点关联性关注前驱知识点的掌握程度对当前习题作答结果预测的影响, 提升了模型的预测性能。

4.5 知识追踪结果可视化分析

为了进一步对 KMAKT 模型的知识追踪结果进行可视化分析, 以 HNU_ SYS 系列数据集为例, 挑选其中 2 个学生的部分习题样本数据, 观察其在作答过程中对各项知识点掌握水平的变化。为了更直观地展示变化情况, 从数据集的 50 个知识点中抽取 6 个关键知识点作为展示, 采用热力图形象地刻画学生知识水平变化趋势。

如图 7 所示(彩色效果见《计算机工程》官网 HTML 版), 纵坐标表示某个具体的知识点, 横坐标为当前学生的部分习题作答序列样本, 上方横向的色块表示习题所考查的某个具体知识点, 其中, “√”表示该学生答对, “×”表示该学生答错, 色块的颜色由蓝至红所代表的知识点掌握程度逐渐提高。




图 7 知识追踪结果热力图可视化展示

Fig.7 Visualization display of heat maps for knowledge tracking results

从图 7 可以比较直观地看出, 在习题作答过程中, 学生 A 和学生 B 的知识状态变化趋势均较为平滑, 符合教育学规律。具体而言, 在学生作答一道习题后, 该同学对于该习题所考查知识点的掌握程度将会发生变化(作答正确则掌握水平上升, 作答错误则下降)。以学生 A 为例, 该同学经过 20 道习题训练后, 对于“拉普拉斯变换的定义与性质”知识点的掌握程度逐渐提高, 这是因为该同学对考查该知识点的习题全部作答正确, 所以逐步掌握该知识点; 对

于“离散傅里叶变换”习题全部作答错误, 表现为该同学对于该知识点的掌握程度逐渐降低。

此外, 图 7 中的“Z 变换的定义与收敛域”是“离散系统的 Z 域分析”的前驱知识点, 可以看出, 由于学生 B 在进行习题训练时对“Z 变换的定义与收敛域”知识点的掌握程度较高, 因此对于其后继知识点“离散系统的 Z 域分析”的习题作答正确的概率相比学生 A 而言更大, 知识点掌握程度更高, 符合教育学认知规律, 即良好地掌握前置知识点有助于后

续知识的学习,因此反映了 KMAKT 模型中对前驱知识影响的判定为知识追踪预测结果提供了一定程度的可解释性。

5 结束语

神经网络的“黑箱”特性导致深度知识追踪模型输出结果的可解释性较弱,且多数深度知识追踪模型未关注习题与知识点间的内在关联性对习题作答的影响。对此,本文构建 KMAKT 模型,并在多个数据集上进行实验验证,结果表明习题考查的知识点间的相似关联性与前驱知识点的掌握程度均会在一定程度上影响当前习题的作答结果,通过可视化分析 KMAKT 知识追踪结果符合教育认知规律,具备一定程度的可解释性。在后续的研究工作中,将关注多模态学习过程数据对学生学习效果的影响,探索图神经网络等方法挖掘知识图谱的深层语义特性,构建完备的高阶知识图谱并将其与知识追踪模型进行结合研究。

参考文献

- [1] 刘三女牙. 人工智能+教育的融合发展之路[J]. 国家教育行政学院学报, 2022(10): 7-10.
LIU S Y. The road of integrated development of artificial intelligence and education[J]. Journal of National Academy of Education Administration, 2022(10): 7-10. (in Chinese)
- [2] 陈恩红, 刘淇, 王士进, 等. 面向智能教育的自适应学习关键技术与应用[J]. 智能系统学报, 2021, 16(5): 886-898.
CHEN E H, LIU Q, WANG S J, et al. Key techniques and application of intelligent education oriented adaptive learning [J]. CAAI Transactions on Intelligent Systems, 2021, 16(5): 886-898. (in Chinese)
- [3] ABDELRAHMAN G, WANG Q, NUNES B. Knowledge tracing: a survey[J]. ACM Computing Surveys, 55(11): 224.
- [4] FAN X. Item response theory and classical test theory: an empirical comparison of their item/person statistics [J]. Educational Psychological Measurement, 1998, 58(3): 357-381.
- [5] DE LA TORRE J. DINA model and parameter estimation: a didactic[J]. Journal of Educational Behavioral Statistics, 2009, 34(1): 115-130.
- [6] 王炼红, 罗志辉, 刘畅. 面向慕课学习者评估的认知反应模型[J]. 电子学报, 2023, 51(1): 18-25.
WANG L H, LUO Z H, LIU C. Cognitive and response model for evaluation of MOOC learners[J]. Acta Electronica Sinica, 2023, 51(1): 18-25. (in Chinese)
- [7] CORBETT A T, ANDERSON J R. Knowledge tracing: modeling the acquisition of procedural knowledge[J]. User Modeling and User-Adapted Interaction, 1994, 4(4): 253-278.
- [8] AGARWAL D B R, MURALEEDHARAN A. Dynamic knowledge tracing through data driven recency weights[C]//Proceedings of the 13th International Conference on Educational Data Mining, Morocco; Open Access. Berlin, Germany: Springer, 2020: 725-729.
- [9] PIECH C, BASSEN J, HUANG J, et al. Deep knowledge tracing[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems. New York, USA: ACM Press, 2015: 505-513.
- [10] SU Y, CHENG Z, LUO P, et al. Time-and-concept enhanced deep multidimensional item response theory for interpretable knowledge tracing [J]. Knowledge-Based Systems, 2021, 218: 106819.
- [11] GHOSH A, HEFFERNAN N, LAN A S. Context-aware attentive knowledge tracing [C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York, USA: ACM Press, 2020: 2330-2339.
- [12] NAGATANI K, ZHANG Q, SATO M, et al. Augmenting knowledge tracing by considering forgetting behavior[C]//Proceedings of the World Wide Web Conference. New York, USA: ACM Press, 2019: 3101-3107.
- [13] PANDEY S, KARYPIS G. A self-attentive model for knowledge tracing[EB/OL]. [2024-01-16]. <http://arxiv.org/abs/1907.06837>.
- [14] GUO X P, HUANG Z J, GAO J, et al. Enhancing knowledge tracing via adversarial training[C]//Proceedings of the 29th ACM International Conference on Multimedia. New York, USA: ACM Press, 2021: 367-375.
- [15] LIU Q, HUANG Z Y, YIN Y, et al. EKT: exercise-aware knowledge tracing for student performance prediction[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 33(1): 100-115.
- [16] 孙建文, 周建鹏, 刘三女牙, 等. 基于多层注意力网络的可解释认知追踪方法[J]. 计算机研究与发展, 2021, 58(12): 2630-2644.
SUN J W, ZHOU J P, LIU S Y, et al. Hierarchical attention network based interpretable knowledge tracing[J]. Journal of Computer Research and Development, 2021, 58(12): 2630-2644. (in Chinese)
- [17] LIU S, YU J W, LI Q, et al. Ability boosted knowledge tracing[J]. Information Sciences, 2022, 596: 567-587.
- [18] 刘凤娟, 赵蔚, 姜强, 等. 基于知识图谱的个性化学习模型与支持机制研究[J]. 中国电化教育, 2022(5): 75-81, 90.
LIU F J, ZHAO W, JIANG Q, et al. Research on personalized learning model and support mechanism based on knowledge graph[J]. China Educational Technology, 2022(5): 75-81, 90. (in Chinese)
- [19] SHI D, WANG T, XING H, et al. A learning path recommendation model based on a multidimensional knowledge graph framework for E-learning[J]. Knowledge-Based Systems, 2020, 195: 105618.
- [20] 高嘉骥, 刘千慧, 黄文彬. 基于知识图谱的学习路径自动生成研究[J]. 现代教育技术, 2021, 31(7): 88-96.
GAO J Q, LIU Q H, HUANG W B. Research on automatic generation of learning paths based on knowledge graph[J]. Modern Educational Technology, 2021, 31(7): 88-96. (in Chinese)
- [21] ZHANG S, HUI N, ZHAI P, et al. A fine-grained and multi-context-aware learning path recommendation model

- over knowledge graphs for online learning communities[J]. *Information Processing Management*, 2023, 60(5): 103464.
- [22] ZHU H P, LIU Y, TIAN F, et al. A cross-curriculum video recommendation algorithm based on a video-associated knowledge map[J]. *IEEE Access*, 2018, 6: 57562-57571.
- [23] ZHANG J N, SHI X J, KING I, et al. Dynamic key-value memory networks for knowledge tracing[C]//*Proceedings of the 26th International Conference on World Wide Web*. New York, USA: ACM Press, 2017: 765-774.
- [24] WANG L H, LI X Y, LUO Z H, et al. Multivariate cognitive response framework for student performance prediction on MOOC[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(3): 1221-1233.
- [25] FENG M Y, HEFFERNAN N, KOEDINGER K. Addressing the assessment challenge with an online system that tutors as it assesses[J]. *User Modeling and User-Adapted Interaction*, 2009, 19(3): 243-266.
- [26] CHANG H S, HSU H J, CHEN K T. Modeling exercise relationships in E-learning: a unified approach [C] // *Proceedings of the 8th International Conference on Educational Data Mining*, Washington D. C., USA: IEEE Press, 2015: 532-535.
- [27] SHEN S H, LIU Q, CHEN E H, et al. Convolutional knowledge tracing: modeling individualization in student learning process[C]//*Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Informational Data Mining*. New York, USA: ACM Press, 2020: 1857-1860.

编辑 陆燕菲