arXiv:2301.01593v1 [cs.CY] 1 Jan 2023

基于信息感知图表示学习的多视图慕课质量评估

Lu Jiang[1], Yibin Wang[1], Jianan Wang[1*], Pengyang Wang[2*], Minghao Yin[1,3] *

[1]东北师范大学计算机科学与信息技术学院，中国[2]澳门大学计算机与信息科学系，中国[3]教育部应用统计重点实验室，东北师范大学，长春，中国{jiangl761、wangyb856、wangjn}@nenu.edu.cn，pywang@um.edu.mo，ymh@nenu.edu.cn

摘要

本文研究大规模开放在线课程质量评估问题，该问题对于改进课程材料、提高学生的学习效率以及改善用户服务至关重要。尽管当前研究取得了良好的效果，但仍难以应对慕课平台中实体之间复杂的交互与关系。为应对这些挑战，我们将该问题表述为基于课程表示学习的任务，并提出一种用于多视图慕课质量评估的信息感知图表示学习方法（IaGRL）。具体而言，我们首先构建慕课异构网络（HIN），以表示慕课平台中实体之间的交互与关系。随后，基于元路径将慕课异构网络分解为多个单关系图，以刻画课程的多视图语义。进而，可将课程表示学习转化为多视图图表示任务。不同于传统的图表示学习，学习得到的课程表示应满足以下三类有效性要求：（1）原始课程组合与学习得到的课程表示在表达能力上保持一致；（2）各视图中的表示与统一表示保持一致；（3）课程表示与慕课平台表示相互对齐。因此，我们提出利用互信息来保持课程表示的有效性。我们在真实世界MOOC数据集上进行了大量实验，以验证所提方法的有效性。

引言

近几十年来，大规模开放在线课程（MOOC）凭借丰富的课程材料、中间反馈以及学生与教师之间的交互，已广泛用于在线辅导和自主学习。其中，MOOC课程质量评估是MOOC平台管理中的重要任务之一，有助于改进课程材料、提高学生的学习效率（Jiang 等，2021），并改善用户服务（例如，课程推荐（Wang 等，2022；Jiang 等，2022a）、认知诊断（Jiang 等，2022b）等）。

当前的MOOC质量评估研究主要涉及两个方面：（1）人工评估（Wang 等人 2021），由领域专家依据预定义评分标准评估课程质量；（2）自动评估（P´erez- Mart´ın、Rodr´ıguez-Ascaso 和 Molanes-Lopez 2021；Be- tanzos、Costa-juss`a 和 Belanche 2017），依据平台中的历史记录自动判断课程质量。尽管取得了可喜的成果，现有研究仍存在一些局限：首先，基于人工的方法耗时费力。此外，在大多数情况下，专家并不具备评估MOOC平台上每门课程所需的完整领域知识。其次，大多数自动化方法将学生评论作为评估课程质量的标准。然而，学生对MOOC质量的评价存在偏见且具有主观性，无法得出统一评估。事实上，MOOC平台上的课程质量评估是一个涉及多方的复杂过程，可以从不同视角进行考察。因此，整合不同视角下的语义和观点，为课程形成统一表示，是实现合理MOOC质量评估的关键。

然而，要实现这一目标，我们面临两个独特的挑战。首先，如何设计合适的数据结构，以捕捉慕课平台中不同类型实体之间的复杂交互？其次，我们应如何保证多视图表示的有效性？接下来，我们将概述应对这些挑战的方法。

首先，在慕课平台上，我们观察到，除了学生和课程之外，还存在多种类型的实体，以及不同实体之间的多种类型的关系。复杂的大规模开放在线课程数据结构通常以异构信息网络（MOOC异构信息网络）的形式表示（Shi 等人，2017）。考虑到 MOOC 平台上多种实体的参与，以及实体与课程之间的交互对 MOOC质量评估的影响，如果仅依赖单一视图，就难以全面评估 MOOC质量。仅利用一种类型的交互可能会忽略课程与其他实体之间的重要关系。例如，“学生点击课程”和“教师上传课程”具有不同的语义，尽管它们都与同一门课程相关。这些异构关系从多视图中提供了丰富的信息。因此，需要将这些异构关系纳入课程实体的表示学习中，

*通讯作者 版权所有 © 2023年，人工智能促进协会（www.aaai.org）。保留所有权利。

为解决上述问题，我们使用元路径（Sun 等人，2017）作为指导，在 MOOC异构信息网络中捕获课程的多视图表示。

其次，尽管可以通过在MOOC异构信息网络上进行表示学习来获得多视图节点嵌入，但如何保证学习得到的课程表示有效，仍然是一项挑战。具体而言，课程表示的有效性体现在三个方面：（1）课程表示应保留与原始课程组合相同的语义；（2）每个视图中的表示应与课程的统一表示保持一致；（3）课程表示应与MOOC平台的整体表示相协调。这三类有效性表明，三对表示之间存在很强的相关性。因此，为确保有效性，我们旨在最大化以下三组相关性：课程表示与原始课程组合之间的相关性、统一课程表示与各个视图之间的相关性，以及课程表示与平台表示之间的相关性。本文采用互信息（MI）这一强大的相关性度量，来量化每对表示之间的相关性。

总之，我们提出了一种用于多视图慕课质量评估的**信息感知图表示学习方法（IaGRL）**。主要贡献如下:

- 我们将MOOC质量评估问题形式化为一项多视图图表示学习任务。
- 我们构建了MOOC异构信息网络，并提出利用元路径提取不同视角下MOOC关系的语义。
- 我们确定了课程表示的三种有效性，并提供了一个信息感知的课程表示学习框架。
- 我们在真实世界MOOC数据集上进行了大量实验，以验证所提出方法的有效性。

定义与问题陈述

我们介绍关键定义和问题陈述，然后概述所提出的方法。表1总结了一些重要符号。

定义与问题陈述

定义 1 大规模开放在线课程异构信息网络（HIN）大规模开放在线课程异构信息网络定义为 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$，其节点类型映射函数为 $\phi: \mathcal{V} \rightarrow \mathcal{N}$，边类型映射函数为 $\psi: \mathcal{E} \rightarrow \mathcal{R}$。具体而言，大规模开放在线课程异构信息网络包含四种类型的节点：学生（记为 *U*）、教师（记为 *T*）、课程（记为 *C*）和学科（记为 *S*）。它还包含三种类型的链接：“点击”，用于表示学生与课程之间的关系；“上传”，用于表示教师与课程之间的关系；以及“包含”，用于表示学科与课程之间的关系。大规模开放在线课程异构信息网络定义为以下三元组事实

表1：符号与定义

符号	定义
$\mathcal{G}$	给定的大规模开放在线课程异构图
$\mathcal{V}, \mathcal{E}$	节点、边的集合
v, e	MOOC异构信息网络节点、边
$\mathcal{MP}$	一组元路径
$\mathbf{X}$	课程的特征矩阵
$\mathbf{A}$	基于不同元路径的邻接矩阵
$\tilde{\mathbf{D}}$	基于不同元路径的对角矩阵
$\tilde{\mathbf{h}}$	多视图课程表示
$\mathbf{W}$	图卷积网络层的权重
$\mathbf{h}$	统一课程表示
α^{MP_i}	各元路径的重要性
$\mathbf{M}$	平台表示
$\mathcal{D}$	基于互信息的判别器
$\lambda_q, \lambda_j, \lambda_s, \lambda_y$	不同损失函数的权重

：（*1*）<学生，”点击”，课程>；（*2*）<教师，”上传”，课程>；以及（*3*）<学科，”包含”，课程>。

定义 2 基于 MOOC异构信息网络的元路径 基于 *MOOC*异构信息网络的元路径 MP 定义为形式为 $\mathcal{V}_1 \xrightarrow{\mathcal{E}_1} \mathcal{V}_2 \xrightarrow{\mathcal{E}_2} \cdots \xrightarrow{\mathcal{E}_l} \mathcal{V}_{l+1}$（缩写为$\mathcal{V}_1, \mathcal{V}_2, \cdots, \mathcal{V}_{l+1}$）的路径，用于描述对象 $\mathcal{V}_1, \mathcal{V}_2, \cdots, \mathcal{V}_{l+1}$之间的复合关系 $\mathcal{E} = \mathcal{E}_1 \circ \mathcal{E}_2 \circ \cdots \circ \mathcal{E}_l$，其中 $\circ$ 表示关系上的复合算子。在 *MOOC*异构信息网络中，两个课程可以通过多条路径相连，例如 $C \xrightarrow{upload} T \xrightarrow{upload^{-1}} C$, $C \xrightarrow{click} U \xrightarrow{click^{-1}} C$, $C \xrightarrow{include} S \xrightarrow{include^{-1}} C$。元路径集合定义为 $\mathcal{MP} = \{MP_1, MP_2, \cdots MP_{||MP||}\}$。

定义3 问题陈述 本文研究慕课质量评估问题。我们将该问题表述为一项信息感知图表示学习任务。形式上，我们旨在找到一个映射函数f: $\mathcal{G} \rightarrow \boldsymbol{h}$，以 *MOOC*异构信息网络 $\mathcal{G}$ 为输入，并输出信息感知表示 $\boldsymbol{h} = \{\boldsymbol{h}_1, \boldsymbol{h}_2, ..., \boldsymbol{h}_N\}$，用于评估 *MOOC*平台上的课程质量。

方法

本节首先概述我们提出的框架，然后详细介绍具有有效性保证的多视图课程表示学习。

框架概述

图1展示了所提出的两阶段框架概览：(1) 第一阶段：学习多视图课程表示；(2) 第二阶段：课程表示有效性保证。具体而言，在第一阶段，我们从MOOCHIN中提取了三条元路径，并通过元路径构建了三种不同视角下的课程邻接矩阵。随后，我们提出利用图卷积网络（GCN）（Kipf和Welling 2016a），通过编码器-解码器范式学习不同视角下的课程表示。我们按照对比学习的惯例，通过最小化重构损失来实现这一目标。在第二阶段，我们利用互信息最大化来确保

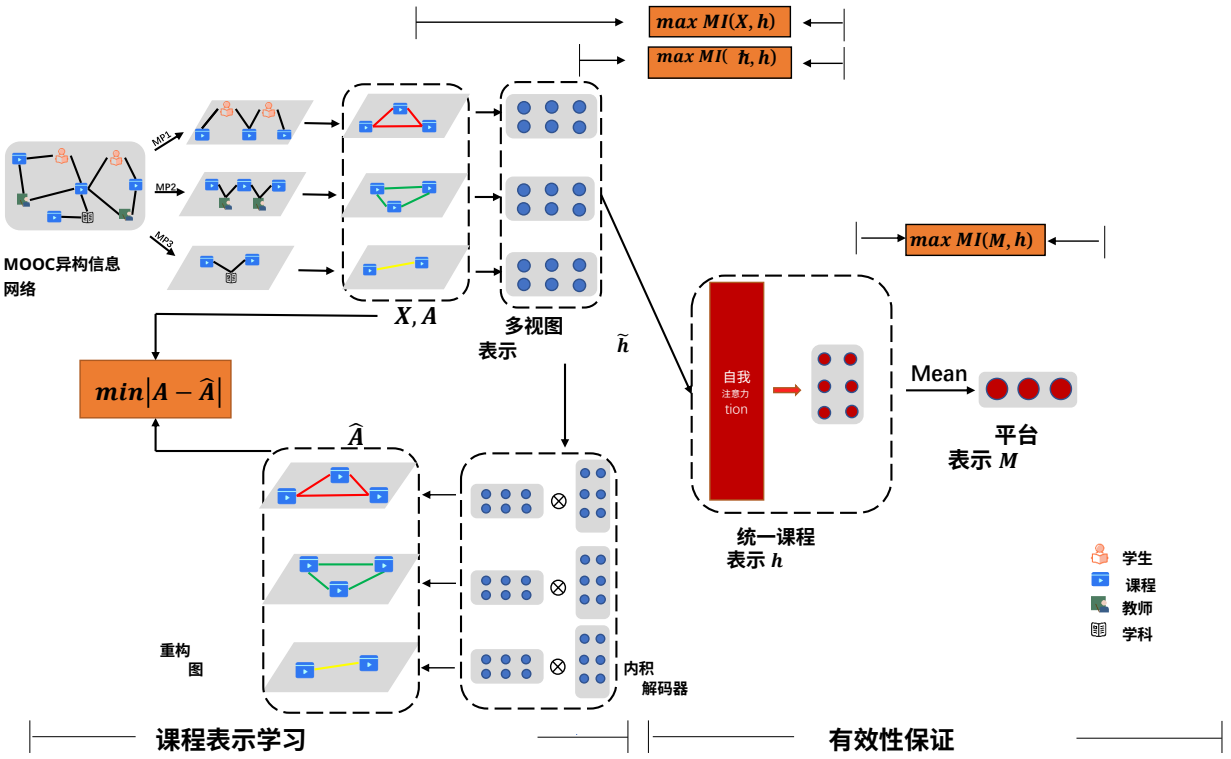


图1：框架概述。

三类课程表示有效性：(i) 原始课程档案与学习得到的课程表示在表达能力上的一致性；(ii) 各视角下的表示与统一表示之间的一致性；以及(iii) 课程表示与大规模开放在线课程平台表示之间的对齐。

课程表示学习

多视图表示。给定 MOOC异构信息网络 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$，其包含一组元路径 $\mathcal{MP} = \{MP_1, MP_2, \cdots MP_{||MP||}\}$ 及对应的邻接矩阵 $\mathbf{A} = \{A_1, A_2, \cdots A_{|MP|}\}$，其中 $|MP|$ 表示元路径的数量。令 $\mathbf{X} = \{X_1, X_2, \cdots X_n\}$表示MOOC异构信息网络的课程属性矩阵。本文使用一个d维向量来表示课程属性，用于描述课程内容，包括标题、摘要等。课程属性矩阵通过 Doc2Vec（Le 和 Mikolov，2014）模型生成。

为提高泛化性，我们以无监督方式使用 GCN 学习多视图表示。我们采用广义优势估计（GAE）（Schulman 等，2016），以编码器—解码器范式学习表示。具体而言，编码器是一个 GCN，其逐层传播规则如下，多视图课程表示可表示为：

$$\tilde{\mathbf{h}} = (\tilde{\mathbf{D}}^{-\frac{1}{2}}\tilde{\mathbf{A}}\tilde{\mathbf{D}}^{-\frac{1}{2}})\mathbf{X}\mathbf{W}, \quad (1)$$

其中 $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ 是对应于包含自连接的单一元路径的邻接矩阵，$\mathbf{I}$ 是单位矩阵。$\mathbf{D}_{ii} = \sum_i \mathbf{A}_{ij}$ 是对角矩阵，$\mathbf{W}$ 是权重。解码器通过对学习到的表示进行内积来重建邻接矩阵：

$$\hat{\mathbf{A}} = sigmoid(\tilde{\mathbf{h}}\tilde{\mathbf{h}}^T) \quad (2)$$

目标是最小化原始邻接矩阵 $\mathbf{A}$ 与重构后的邻接矩阵 $\mathbf{A}$之间的重构损失。我们遵循 VGAE（Kipf 和 Welling，2016b）的实现进行采样和损失优化：将相连的邻居作为正节点，将不相连的节点作为负节点，并从中采样若干节点以构建数据样本。我们希望重构后正样本彼此相连，而负样本彼此不相连，因此将重构问题转化为分类任务，并使用交叉熵损失进行优化。

$$\mathcal{L}_q = -log\hat{\mathbf{A}}_{pos} - log(1 - \hat{\mathbf{A}}_{neg}), \quad (3)$$

其中$\mathbf{A}^{pos}$ 和$\mathbf{A}^{neg}$ 分别根据公式 3 从正课程节点对和负课程节点对中得出。

统一课程表示。经过图自编码器，我们学习每条元路径的表示。然而，不同元路径的重要性并不相同。为了解决这一问题，我们采用异构

深度图信息最大化（HDGI）（Ren 等人，2019年）的思想，并利用自注意力机制融合在不同元路径的引导下学习到的课程嵌入，生成统一课程嵌入。具体而言，我们按如下方式学习不同元路径的自注意力权重：

$$\mathbf{h} = \sum_{i}^{|MP|} att(\tilde{\mathbf{h}}_i), \tag{4}$$

其中，att(·)表示自注意力函数，**h** 表示统一课程表示，它整合了不同元路径的自注意力权重。本文主要关注多视图中的课程。为了使来自不同元路径的表示具有可比性，我们通过线性变换，将每个课程在不同视角下的表示进行转换。参数为共享权重矩阵$\mathbf{W}'$和共享偏置向量 $\vec{b}$。基于不同视角的区分能力，我们引入不同视角共享的注意力向量 $\vec{q}$，以计算每个视角的重要性。元路径的重要性可按如下方式计算：

$$a^{MP_i} = \frac{1}{|MP|} \sum_{j=1}^{|MP|} tanh(\vec{q}^T \cdot [\mathbf{W}' \cdot \tilde{\mathbf{h}}_j^{MP_i} + \vec{b}]) \tag{5}$$

接着，我们使用 softmax 函数对元路径的重要性进行归一化，每个元路径的归一化权重可按如下方式计算：

$$\alpha^{MP_i} = \frac{exp(a^{MP_i})}{\sum_{j=1}^{|MP|} exp(a^{MP_j})} \tag{6}$$

自注意力统一课程表示**h** 可表示如下：

$$\mathbf{h} = \sum_{i=1}^{|MP|} \alpha^{MP_i} \tilde{\mathbf{h}}_i \tag{7}$$

有效性保证

原始课程组合-表示一致性。 学习得到的课程表示应能在描述课程时与原始课程组合达成一致。我们将此称为原始课程组合-表示一致性。我们使用互信息（MI）量化统一视图中由课程节点学习得到的表示**h** 与大规模开放在线课程原始特征的表示**X** 之间的一致性。遵循 DIM 和 DGI（Velickovic 等人，2019）的思路，我们定义了一个 Jensen-Shannon 互信息估计器，用于估计并最大化**X** 与**h**之间的互信息：

$$\begin{aligned} MI(\mathbf{X}, \mathbf{h}) :=& \mathbb{E}_{\mathbf{X}}[-sp(-\mathcal{D}(\mathbf{X}, \mathbf{h}^{(MP)}))] + \\ & \mathbb{E}_{\bar{\mathbf{X}}}[sp(\mathcal{D}(\mathbf{X}, \mathbf{h}^{(MP)}))], \end{aligned} \tag{8}$$

其中，sp 是 softplus 函数， $sp(c) \times log(1+e^c)$，$\mathbf{X}^-$是正样本集，**X** 是负样本集。我们将在后文介绍如何生成正样本和负样本。由于采用标准二元交叉熵（BCE）的噪声对比型目标能够有效地最大化互信息，因此我们将损失函数定义为：

$$\begin{aligned} \mathcal{L}_j = -\frac{1}{|MP|} \sum_{j=1}^{|MP|} \sum_{i} & \mathbb{E}_{\mathbf{X}}[log \mathcal{D}_j(\mathbf{X}_i^{(MP_j)}, \mathbf{h}_i)] - \\ & \mathbb{E}_{\bar{\mathbf{X}}}[log(1 - \mathcal{D}_j(\tilde{\mathbf{X}}_i^{(MP_j)}, \mathbf{h}_i))], \end{aligned} \tag{9}$$

其中，$\mathcal{D}_j$ 表示一个判别器，用于判断给定的样本对是正样本还是负样本。对于第 k个视角，我们将正样本视为样本对（$X^{(MP_j)}{}_i$， $\mathbf{h}_i$），并将负样本视为样本对（$\tilde{X}^{(MP_j)}{}_i$，$\mathbf{h}_i$）。

多视图一致性。 尽管我们将异构图分解为不同视角，但预期每个视角中的课程表示在语义上与统一课程表示保持一致，这被定义为多视图一致性。我们提出利用互信息来衡量多视图一致性。首先，我们得到多视图˜表示 **h** 和统一课程表示**h**。具体而言，**h** 一方面通过自注意力获得，另一方面，˜**h** 通过图卷积网络编码器获得。然后，我们使用神经˜网络估计互信息（**h**；**h**），以最大化统一课程表示 **h** 与˜多视图表示 **h**之间的互信息。我们采用类似的噪声对比损失函数：

$$\begin{aligned} \mathcal{L}_s = -\frac{1}{|MP|} \sum_{j=1}^{|MP|} \sum_{i} & \mathbb{E}_{\mathbf{X}}[log \mathcal{D}_s(\mathbf{h}_i, \tilde{\mathbf{h}}_i^{(MP_j)})] - \\ & \mathbb{E}_{\bar{\mathbf{X}}}[log(1 - \mathcal{D}_s(\mathbf{h}_i, \acute{\mathbf{h}}_i^{(MP_j)}))], \end{aligned} \tag{10}$$

其中， $\mathcal{D}_s$ 表示用于区分正 -́向一致配对的判别器，$\mathbf{h}_i$i 是统一课程表示。$\mathbf{h}_i$ 是**h** 经随机打乱后的结果。对于第 k个视图，我们将正样本设计为配对（$\mathbf{h}_i$, ˜$\mathbf{h}_{(MP_j)\,i}$），将负样本设计为配对（$\mathbf{h}_i$, ́$\mathbf{h}_{(MP_j)\,i}$）。目标是最小化 $\mathcal{L}_s$，这等价于最大化~MI（$\mathbf{h}, \mathbf{h}$）。

课程-平台对齐。 毫无疑问，各门课程彼此不同，但课程表示需要与同一语义范围内的大规模开放在线课程平台表示对齐。为实现课程-平台对齐，我们首先将平台表示视为大规模开放在线课程异构信息网络中课程的图级表示。基于此，我们通过对所有课程表示取平均值，得到平台摘要向量**M**：

$$\mathbf{M} = \sigma(\frac{1}{N} \sum_{i=1}^{N} \mathbf{h}_i), \tag{11}$$

其中 σ 是 Sigmoid函数， N 是课程节点的数量。我们继续利用互信息来捕捉

课程-平台对齐。为了最大化课程-平台对齐，我们引入互信息，并基于 Jensen-Shannon 散度与互信息之间的关系，使用判别器的二元交叉熵损失来最大化平台表示与统一课程表示之间的互信息，如下所示：

$$\mathcal{L}_y = -\sum_i \mathbb{E}_{\mathbf{X}}[log\mathcal{D}_y(\mathbf{h}_i, \mathbf{M})] - \mathbb{E}_{\bar{\mathbf{X}}}[log(1-\mathcal{D}_y(\bar{\mathbf{h}}_i, \mathbf{M}))], \tag{12}$$

其中， $\mathcal{D}_y$ 表示判别器，用于为采样的课程-平台配对提供概率分数；**h** 表示统一课程¯表示。**h** 是对**h** 进行随机打乱后的结果。我们将正样本设计为配对（$\mathbf{h}_i$,**M**），将¯负样本设计为配对（$\bar{\mathbf{h}}_i$,**M**）。目标是最小化 $\mathcal{L}_y$，这等价于最大化 MI**(h, M)**。

优化

模型的损失包括：(i) 用于图重构的对比学习损失 λ_q（公式 3）；(ii) 原始作品集表示一致性学习损失 λ_j（公式 9）；(iii) 多视图一致性学习损失 λ_s（公式 10）；以及 (iv) 课程-平台对齐学习损失 λ_y（公式 11）。目标是最小化总体损失 $\mathcal{L}$，如下所示：

$$\mathcal{L} = \lambda_q\mathcal{L}_q + \lambda_j\mathcal{L}_j + \lambda_s\mathcal{L}_s + \lambda_y\mathcal{L}_y \tag{13}$$

其中， λ_q、 λ_j、 λ_s 和 λ_y 分别是 $\mathcal{L}_q$、 $\mathcal{L}_j$、 $\mathcal{L}_s$ 和$\mathcal{L}_y$的权重。上述损失可以通过梯度下降进行优化，优化完成后即可学习得到节点的表示。

实验

在实验中，我们旨在回答以下三个研究问题：

- **Q1.** 我们提出的**IaGRL** 在大规模开放在线课程质量评估任务中的表现如何?
- **Q2.** 元路径如何影响课程质量评估性能?
- **Q3.** 不同的学习损失如何影响课程质量评估性能?

接下来，我们将介绍真实世界大规模开放在线课程数据的统计信息和实验设置，并在该数据上将**Ia-GRL**与几种基线方法进行比较。

数据描述

我们在真实世界大规模开放在线课程数据上评估了模型性能。这些数据构成了一个大规模开放在线课程异构信息网络，包含 4 种类型的实体和 3 种类型的关系。课程得分范围为 0 到 5。在数据预处理步骤中，我们筛除了链接少于 3 个的用户。数据预处理后，我们将数据集划分为两个互不重叠的集合：其中 20% 作为测试集，其余 80% 作为训练集。表 2 展示了该数据集的详细统计数据。

表 2：数据集的统计数据和描述

属性	描述	统计数据
学生	学习过课程的用户	4931
课程	学习材料	10919
教师	上传过课程的用户	1213
学科	一个知识领域	35
Time	时间范围	2015—2018年

基线方法与评估指标

我们将所提出方法的性能与以下基线方法进行比较：

(1) 多层感知机。 多层感知机（MLP）是一种前馈监督人工神经网络结构。MLP 可以包含多个隐藏层，以实现分类建模。

(2) DeepWalk。 DeepWalk 模型是一种近期提出的网络嵌入方法，它通过截断随机游走扩展了 word2vec 模型（Mikolov 等，2013）（Perozzi、Al-Rfou 和 Skiena，2014）。

（3）DeepWalk+F. DeepWalk+F模型不仅在随机游走后加入邻居特征，还加入了实践的属性特征。

（4）GCN。图卷积网络（GCN）基于完全图的拉普拉斯矩阵或邻接矩阵进行信息聚合（Kipf和Welling，2016a）。

（5）图自编码器。图自编码器（GAE）学习节点表示，我们使用嵌入层通过GCN对节点进行编码（Schulman等，2016）。

（6）GraphSAGE。GraphSAGE提出了邻域批次采样，以通过最大值、最小值和LSTM聚合函数实现可扩展训练（Hamilton、Ying和Leskovec，2017）。

（7）图注意力网络。图注意力网络（GAT）将多头注意力机制引入聚合函数，学习每个节点邻域对于信息聚合的重要性（Velickovic等，2017）。

(8)GATv2。 GATv2通过采用一种动态的图注意力变体，解决了GAT使用静态注意力机制时存在的简单图问题；与GAT相比，该变体的表达能力更强（Brody、Alon 和 Yahav，2021）。

最后五种是图表示学习方法。为了评估模型在大规模开放在线课程质量方面的表现，我们采用了两种广泛用于评估多分类性能的评估指标，例如准确率和宏平均**F1**。具体而言，准确率衡量用户评分被成功评定的准确度，而宏平均**F1**有助于在数据不平衡的情况下全面考量模型性能。对于这两项指标，数值越大，性能越好。

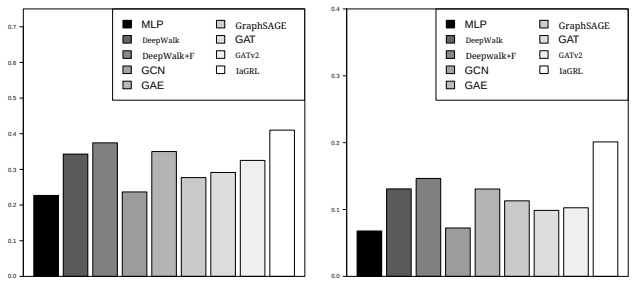
参数设置

对于 Deepwalk 和 Deepwalk+F，我们设置游走次数= 80、表示维度 = 128、游走长度 = 20 和窗口大小 = 10。对于图卷积网络、图自编码器和 GraphSAGE，我们设置层数 = 2、输入特征维度=128,

输出特征维度 = 128 和学习率 = 0.001。对于图注意力网络和GATv2，我们设置层数 = 2、每层的注意力头数 = [2,1]、输入特征维度 = 128、输出特征维度 = 128 和学习率 = 0.003。对于我们的模型，我们设置学习率 = 0.001、l2 = 0.001、dropout = 0.1、输入特征 = 128 和输出特征= 128。我们使用的设备是两块配备 24GiB 内存的 RTX 6000，并使用 CUDA=11.2。

总体性能（Q1）

在本节中，我们比较了所有模型在真实世界数据集上的总体性能。总体而言，图2显示，我们的模型在准确率和宏平均F1指标上均优于其他基线方法。与代表节点属性的多层感知机（MLP）相比，基于随机游走的方法（DeepWalk、Deepwalk+F）、基于图卷积网络的方法（GCN、图自编码器、GraphSAGE、图注意力网络、GATv2）以及基于信息的方法（我们提出的方法）在对大规模开放在线课程异构网络建模时表现更佳。与基于随机游走的方法DeepWalk和DeepWalk+F相比，我们提出的框架还考虑了异构图嵌入，以及所学习表示的信息感知能力。与基于图卷积网络的方法相比，我们提出的方法所提供的信息保证进一步提升了所学习表示的合理性。总之，结果验证了融合多视图和信息感知能力能够提高表示学习的质量。



(a) 准确率。 (b) 宏平均F1。

图2：我们的方法与其他基线方法在整体评估准确率和宏平均F1方面的比较。

元路径的影响（Q2）

在本部分实验中，我们分析元路径对方法性能的影响。我们在所提出的方法中同时考察单一元路径及其组合。具体而言，我们选取三种元路径来表示课程对之间的关联性，包括 MP1：$C \rightarrow T \stackrel{-1}{\rightarrow} C$、MP2：$C \rightarrow U \stackrel{-1}{\rightarrow} C$ 和 MP3：$C \rightarrow S \stackrel{-1}{\rightarrow} C$。为分析元路径的影响，我们从三个方面研究其性能：（1）使用单视图注意力权重；（2）使用单一课程相关元路径及其组合；（3）基线方法中的元路径。

与注意力权重相比。我们计算了本方法中各元路径对应的注意力权重重要性，结果如表3所示。从表中可以看出，来自教师视角的MP_1, 最为重要，其次分别是来自学科视角的MP_3和来自学生视角的MP_2。不难理解，在从多个视角评估课程质量时，教师对课程质量的影响更为重要。一个有趣的发现是，学生视角对课程质量的影响最小，甚至低于作为客观视角的学科视角。一种可能的解释是，我们的数据来自一个面向初等教育的MOOC平台。一方面，学生的认知水平尚处于初级阶段；另一方面，学生点击课程的行为受到教师引导，因此主观性较弱。

表3：各元路径的重要性。

权重	MP_1	MP_2	MP_3
α^{MP_i}	**0.4655**	0.2242	0.3103

与不同元路径的组合进行比较。我们将本方法与单一元路径及其组合进行比较。结果如表4所示，可以发现，每种单一元路径的表现各不相同，性能排名为 MP1> MP3>MP2，而单一元路径的组合也呈现出相同的趋势。这表明，不同元路径代表不同的关系，包含更多元路径的组合会带来更好的表现；结合全部三种元路径时，性能最佳。

表4：本方法在不同元路径组合下的结果。

元路径	准确率	宏平均F1
MP_1	0.3596	0.1529
MP_2	0.3407	0.1397
MP_3	0.3543	0.1707
元路径$_1$ 和元路径 2	0.3697	0.1536
元路径$_1$ 和元路径 3	0.3864	0.1783
元路径$_2$ 和元路径 3	0.3656	0.1742
元路径$_1$ 和元路径$_2$ 和元路径 3	**0.4101**	**0.2011**

与基线方法中的元路径进行比较。此外，为了进一步验证元路径的效果，我们研究了基于图卷积网络方法的基线方法中的元路径。结果如表5所示。从表5中可以发现，与原始算法相比，加入元路径组合后性能更佳。尤其是在图卷积网络和 GraphSAGE 方法中，性能提升十分显著。

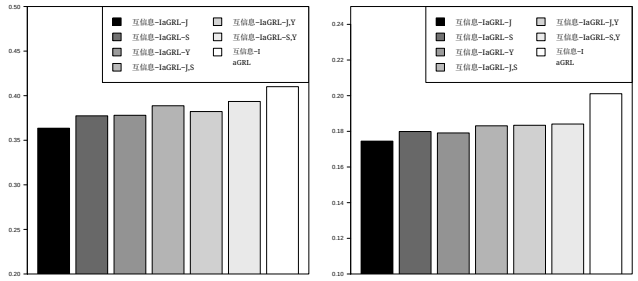
表5：基线方法上不同元路径组合的结果。

方法	准确率	宏平均F1
GCN	0.2368	0.0724
图卷积网络 & 元路径 $i=1,2,3$	**0.3466**	**0.0857**
GAE	0.3501	0.1307
图自编码器 & 元路径 $i=1,2,3$	**0.3555**	**0.1686**
GraphSAGE	0.2770	**0.1130**
GraphSAGE 与元路径$_{i=1,2,3}$	**0.3620**	0.1092
GAT	0.2914	0.0987
图注意力网络 & 元路径 $i=1,2,3$	**0.3187**	**0.1076**
GATv2	0.3252	0.1026
GATv2 与元路径$_{i=1,2,3}$	**0.3258**	**0.1220**

对 $\mathcal{L}_j$、 $\mathcal{L}_s$、 $\mathcal{L}_y$ 的分析（Q3）

为了分析表示原始组合一致性、多视图一致性以及课程-平台对齐的贡献，我们定义了所提出模型的六个变体：(1) MI-IaGRL-J，在基础模型中加入 $\mathcal{L}_j$；(2) MI-IaGRL-S，在基础模型中加入 $\mathcal{L}_s$；(3) MI-IaGRL-Y，在基础模型中加入 $\mathcal{L}_y$；(4) MI-IaGRL-J,S，在基础模型中加入 $\mathcal{L}_j$ 和 $\mathcal{L}_s$；(5) MI-IaGRL-J,Y，在基础模型中加入 $\mathcal{L}_j$ 和 $\mathcal{L}_y$；以及(6) MI-IaGRL-S,Y，在基础模型中加入 $\mathcal{L}_s$ 和 $\mathcal{L}_y$。

如图3所示，我们在实验中比较了 MI-IaGRL-J、MI-IaGRL-S、MI-IaGRL-Y、MI-IaGRL-J,S、MI-IaGRL-J,Y、MI-IaGRL-S,Y 和 MI-IaGRL。随着损失函数组合从单个增加到两个、再增加到三个，各项指标值总体呈上升趋势。结果表明，将原始组合表示一致性、多视图一致性和课程-平台对齐结合起来，能够显著提升慕课质量评估的性能。



（a）准确率。 （b）宏平均F1。

图3：对 $\mathcal{L}_j$、 $\mathcal{L}_s$、 $\mathcal{L}_y$的分析。

相关工作

我们的工作与以下两个既有研究领域相关，包括慕课质量评估和图表示学习。

慕课质量评估

我们的工作与慕课质量评估有关。关于慕课质量评估的既有研究主要涉及两个方面：（1）人工评估（Wang 等人 2021）；（2）自动评估（P´erez-Mart´ın、Rodr´ ıguez-Ascaso 和 Molanes-Lopez 2021；Betanzos、Costa-juss`a 和 Belanche 2017）。基于人工的方法由领域专家依据预定义评分标准评估课程质量。例如，Wang 等人基于十项原则框架探讨了教学设计的质量分析（Wang 等人 2021）。基于人工的方法能够准确评估课程质量，但不适用于大规模应用。越来越多的自动化方法应运而生，例如，Zhuo 等人 基于综合模糊评价，在 MOOC平台上设计了一种教学质量评估模型（Zhuo 和 Dong 2017）。

图表示学习

与注重效率的传统图优化方法（Chen 等人 2023；**？**）不同，图嵌入方法侧重于信息提取。图嵌入旨在将图中的节点投影到一个 d维向量空间中，其中节点的表示既能反映节点之间的关系，又能保留节点的语义信息。图嵌入方法可分为同质图嵌入（node2vec（Grover 和 Leskovec 2016）、struct2vec（Ribeiro、Saverese 和 Figueiredo 2017）以及 Deepwalk（Perozzi、Al-Rfou 和 Skiena 2014））和异质图嵌入（ metapath2vec（Dong、Chawla 和 Swami 2017）、HHNE（Wang、Zhang 和 Shi 2019）、SHNE（ Zhang、Swami 和 Chawla 2019））。然而，上述方法忽略了互信息。为了处理图的信息感知问题，已有多种方法被提出，包括 DGI（Velickovic 等人 2019）和 HDGI（Ren 等人 2019）。

结论

本文研究了基于 MOOC 异构信息网络的大规模开放在线课程质量评估问题，并提出一种用于多视图慕课质量评估的信息感知图表示学习框架。具体而言，首先，我们将大规模开放在线课程质量评估问题表述为一项多视图图表示学习任务。其次，我们构建 MOOC异构信息网络，并提出利用元路径从不同视角提取 MOOC关系的语义。第三，我们确定了课程表示的三种有效性：（i）原始课程组合与学习得到的课程表示在表达能力上的一致性；（ii）各视角下的表示与统一表示之间的一致性；以及（iii）课程表示与慕课平台表示之间的对齐。最后，我们在真实世界大规模开放在线课程数据上开展了大量实验，以验证所提方法的有效性。

致谢

本研究获得中央高校基本科研业务费（2412019ZD013）、国家自然科学基金委员会（项目编号：61976050、61972384、61806050、62106040）、吉林省科学技术厅（20200201280JC）、澳门特别行政区科技发展基金（项目编号：SKL-IOTSC-2021-2023，资助对象：Pengyang Wang）以及澳门大学启动研究基金（项目编号：SRG2021-00017-IOTSC，资助对象：Pengyang Wang）的支持。

参考文献

Betanzos, M.; Costa-juss`a, M. R.; and Belanche, L. 2017. Tradares：一种用于在大规模开放在线课程环境中自动评估人工翻译质量的工具。应用智能, 31(3): 288–297. Brody, S.; Alon, U.; and Yahav, E. 2021. 图注意力网络的注意力程度如何？*CoRR*, abs/2105.14491. Chen, J.; Cai, S.; Wang, Y.; Xu, W.; Ji, J.; and Yin, M. 2023. 利用深度优化机制改进超大规模图中最小权重支配集问题的局部搜索。人工智能, 314: 103819. Dong, Y.; Chawla, N. V.; and Swami, A. 2017. meta-path2vec：异构网络的可扩展表示学习。载于*KDD*, 135–144. ACM. Grover, A.; and Leskovec, J. 2016. node2vec：网络的可扩展特征学习。载于*KDD*, 855–864. ACM. Hamilton, W. L.; Ying, Z.; and Leskovec, J. 2017. 大规模图上的归纳式表示学习。载于神经信息处理系统会议, 1024–1034. Jiang, L.; Wang, P.; Cheng, K.; Liu, K.; Yin, M.; Jin, B.; and Fu, Y. 2021. EduHawkes：一种用于在线学习行为建模的神经霍克斯过程方法。载于数据挖掘与知识发现研讨会, 567–575. SIAM. Jiang, L.; Wang, Y.; Xie, S.; Wu, J.; Yin, M.; and Wang, J. 2022a. 应该选择哪些课程？为在线辅导平台上的学生群体推荐课程。应用智能. Jiang, L.; Zhang, W.; Wang, Y.; Luo, N.; and Yue, L. 2022b. 利用层次信息增强在线考试平台的个性化问题推荐。计算机科学讲义（包括人工智能讲义和生物信息学讲义子系列）, 13087: 103–117. Kipf, T. N.; and Welling, M. 2016a. 基于图卷积网络的半监督分类。*CoRR*, abs/1609.02907. Kipf, T. N.; and Welling, M. 2016b. 变分图自编码器。*CoRR*, abs/1611.07308. Le, Q. V.; and Mikolov, T. 2014. 句子和文档的分布式表示。载于国际机器学习会议, 第32卷机器学习研究期刊研讨会与会议论文集, 1188–1196. JMLR.org. Mikolov, T.; Sutskever, I.; Chen, K.; Corrado, G. S.; and Dean, J. 2013. 词语和短语的分布式表示及其组合性。载于神经信息处理系统会议, 3111–3119. P´erez-Mart´ın, J.; Rodr´ıguez-Ascaso, A.; and Molanes-Lopez, E. M. 2021. 使用半自动工具的大规模开放在线课程无障碍课程学生所制作字幕的质量。*Univers.Access Inf. Soc.*, 20(4): 677–690. Perozzi, B.; Al-Rfou, R.; and Skiena, S. 2014. DeepWalk：社会表征的在线学习。载于*KDD*, 701–710. ACM. Ren, Y.; Liu, B.; Huang, C.; Dai, P.; Bo, L.; and Zhang, J. 2019. 异构深度图信息最大化。*CoRR*, abs/1911.08538. Ribeiro, L. F. R.; Saverese, P. H. P.; and Figueiredo, D. R. 2017. *struc2vec*：从结构身份中学习节点表示。载于*KDD*, 385–394. ACM. Schulman, J.; Moritz, P.; Levine, S.; Jordan, M. I.; and Abbeel, P. 2016. 使用广义优势估计进行高维连续控制。载于 Bengio, Y.; and LeCun, Y., 编, *ICLR*。Shi, C.; Li, Y.; Zhang, J.; Sun, Y.; and Yu, P. S. 2017. 异构信息网络分析综述。*IEEETrans.Knowl. Data Eng.*, 29(1): 17–37. Sun, Y.; Yuan, N. J.; Xie, X.; McDonald, K.; and Zhang, R. 2017. 利用实时上下文数据进行协同意图预测。*ACM Trans. Inf.Syst.*, 35(4): 30:1–30:33. Velickovic, P.; Cucurull, G.; Casanova, A.; Romero, A.; Li`o, P.; and Bengio, Y. 2017. 图注意力网络。*CoRR*, abs/1710.10903. Velickovic, P.; Fedus, W.; Hamilton, W. L.; Li`o, P.; Bengio, Y.; and Hjelm, R. D. 2019. 深度图信息最大化。载于*ICLR*。OpenReview.net. Wang, C.; Zhu, H.; Wang, P.; Zhu, C.; Zhang, X.; Chen, E.; and Xiong, H. 2022. 个性化且可解释的员工培训课程推荐：贝叶斯变分方法。*ACM Trans.Inf. Syst.*, 40(4): 70:1–70:32. Wang, X.; Lee, Y.; Lin, L.; Mi, Y.; and Yang, T. 2021. 通过系统分析与情感分析，对Class Central前20名慕课中18门课程的教学设计质量和学生评论进行分析。*Internet High. Educ.*, 50: 100810. Wang, X.; Zhang, Y.; and Shi, C. 2019. 双曲异构信息网络嵌入。载于*AAAI*, 5337–5344. AAAI Press. Zhang, C.; Swami, A.; and Chawla, N. V. 2019. SHNE：异构语义关联网络的表示学习。载于*WSDM*, 690–698. ACM. Zhuo, C.; and Dong, X. 2017. 基于MOOC平台的教学质量评估实用方法。国际新兴技术学习期刊, 12(3): 57–67.