

基于注意力机制的双向长短期记忆网络的 在线工程实践评价框架

马坤,邵永伟,郑楠,陈贞翔,杨波

(济南大学信息科学与工程学院,山东 济南 250022)

摘要:在虚拟学习环境下,工程实践课程通常以小组方式在线协同完成一个实践项目,但现有在线教学平台缺少基于学习行为数据的深度挖掘,教师难以像线下实践那样感知学习者的学习状态,从而无法进行十分客观公正的评价。为此,提出基于注意力机制的双向长短期记忆网络的在线工程实践评价框架,通过在线实践行为数据构建注意力机制的双向长短期记忆网络模型(GEP-BiLSTM)预测学生能否通过未来的实践考核。实践表明,所提方法可在学生出现学业预警前进行更有针对性的帮扶,从而提升工程实践的教学效果。

关键词:教育数据挖掘;长短期记忆网络;实践评价;注意力机制;工程实践

DOI:10.11907/rjdk.231757

中图分类号:G434

文献标识码:A

开放科学(资源服务)标识码(OSID):

文章编号:1672-7800(2024)008-0281-06



An Online Engineering Practice Evaluation Framework Based on BiLSTM with Attention Mechanism

MA Kun, SHAO Yongwei, ZHENG Nan, CHEN Zhenxiang, YANG Bo

(School of Information Science and Engineering, University of Ji'nan, Ji'nan 250022, China)

Abstract: In a virtual learning environment, engineering practice courses usually collaborate online in groups to complete a practical project. However, existing online teaching platforms lack deep mining based on learning behavior data, making it difficult for teachers to perceive the learning status of learners like in offline practice, thus making it difficult to conduct very objective and fair evaluations. To this end, a bidirectional long short-term memory network based on attention mechanism is proposed as an online engineering practice evaluation framework. Based on online practice behavior data, a bidirectional long short-term memory network model with attention mechanism (GEP-BiLSTM) is constructed to predict whether students can pass future practical exams. Practice has shown that the proposed method can provide more targeted assistance to students before they encounter academic warnings, and can improve the teaching effectiveness of engineering practice.

Key Words: educational data mining; long short-term memory network; practical evaluation; attention mechanism; engineering practice

0 引言

虚拟学习环境(Virtual Learning Environment, VLE)是由信息技术构建的多媒体学习系统,目的是在虚拟世界中模拟和改善现有教学机制^[1,2]。学生是VLE的主体,VLE能记录并跟踪大规模学生行为数据为学习者提供决策支

持^[3]。虚拟学习环境下,教师难以像线下实践那样感知学习者的学习状态,而现有在线教学平台专注于在线授课与实践资源建设,缺少基于学习行为数据的深度挖掘。因此,如何对学生在线工程实践(Group Engineering Practice, GEP)效果进行评价已成为一项具有挑战性的任务^[4]。

目前,通常构建基于学生学习行为数据的机器学习模型提前预测学生未来在线工程实践的结果,在学生实践过

收稿日期:2023-07-12

扫描二维码阅读全文:



基金项目:山东省普通高等学校实验教学和教学实验室建设研究项目(2024045);山东省高等教育学会高等教育研究专项课题(SDGJ2023C05);济南大学教学研究项目重点项目(JZ2403, JZ2212);山东省优质专业学位教学案例库项目(SDY-AL2022102)

作者简介:马坤(1981-),男,CCF会员,济南大学信息科学与工程学院副教授,研究方向为教育数据分析、自然语言处理、大数据处理。

程中发挥了监督和预警作用,能为教师调整教学方法提供依据,提升工程实践质量,降低学生工程实践失败的风险^[5]。学生在线工程实践的行为数据主要以小组为单位参与工程实践课程时产生的数据,反映了小组与个人的实践过程,具体包括小组讨论次数、提交代码次数、提交代码有效率、可交付成果数等^[6]。然而,现有模型更注重学生在线工程实践行为中学生个人的学习行为数据,忽略了学生在小组中的阶段性实践行为分析。

为了解决了这一问题,本文提出基于注意力机制的双向长短期记忆网络(Bidirectional Long Short-Term Memory network-Attention, BiLSTM-Attention)的在线工程实践评价框架,主要工作为:①以学生小组为单位进行在线工程实践行为特征提取,预处理数据集后使用z-score方法对数据进行归一化,然后构建实践行为组向量;②提出基于注意力机制的双向长短期记忆网络模型,通过Embedding层降维组向量,在BiLSTM层进行高级特征抽取,加权合并高级特征和Attention层的权重向量以得到新的组向量;③构建基于注意力机制的双向长短期记忆网络的在线工程实践评价框架(GEP-BiLSTM),使用BiLSTM-Attention对实践行为特征作二分类,判断学生小组能否通过实践考核,以达到评价学生小组工程实践成效的目的。

1 相关工作

1.1 深入挖掘教育数据

数据挖掘是基于大数据技术而生成的新兴技术手段,具有高度的合理性和科学的严谨性,近年来已成为改善学习和教学环境的有效工具^[7,8]。其中,部分学者研究学生成绩的数据挖掘算法^[9];部分学者研究分析评价模型抽取学生学习特征,将学生毕业时的学业成绩和毕业后3~5年的发展情况作为现有计算机模型的优化依据,模型的预测结果也可作为选择帮扶学生的依据^[10]。Burgos等^[11]通过预测学生在期末考试中获得的成绩,为不及格的学生设计指导行为工具来降低辍学率。Fernandes等^[12]通过梯度提升机模型研究学生的人口统计数据与其从学期活动中获得的成绩之间的关系。Xu等^[13]根据学生使用互联网的行为与学习成绩之间的关系,通过机器学习方法评价学生的成绩,结果表明互联网连接频率特征与学业成绩呈正相关,而互联网流量特征与学业成绩呈负相关。张鹏^[14]将神经网络方法与其他数据挖掘方法进行比较发现,前者更适用于解决数据挖掘问题。Rebai等^[15]提出基于机器学习的模型识别影响学业成绩的关键因素,并确定这些因素间的关系。Waheed等^[16]提出在学习管理系统中设计带有人工神经网络的模型,认为深度学习模型在早期评价学生表现中是一个重要的工具。Bernacki等^[17]基于行为的评价模型识别后期课程中可能失败的学生,并及时提供帮助。

1.2 在线工程实践评价

现有工作基于学生在虚拟学习环境中的学习行为数据,通过传统机器学习模型预测学习效果。梯度提升树根据评价分数、学生点击率和最终成绩评价学生的参与度,在英国开放大学课程上的评价效果较好^[18]。部分学者发现,使用固定长度的数据评价学生成绩能使机器学习的效果更好,但处理从点击流、评价流和虚拟学习环境的交互事件日志生成的大规模数据时效果较差^[19]。Stacking方法结合多个基分类器并通过元模型总结评价结果,相较于任一单一基分类器而言,在提取学生数据的特征时性能更优^[20,21]。

在深度学习方法中,循环神经网络学习虚拟学习环境每个学习阶段的每周序列数据^[22];基于3个隐藏层的快速人工神经网络模型,通过16个与日常生活有关的特征评价学生表现^[23]。然而,当前关于学生成绩评价的方法多集中在分析过去学习成绩,例如多层感知器神经网络忽略了用户的阶段学习行为^[24,25]。

为此,本文提出一种小组阶段特征提取和双向长短期记忆神经网络相结合的方法(Group Engineering Practice Prediction Framework based on Bidirectional Long Short-Term Memory network, GEP-BiLSTM)。通过捕获序列向前和向后数据的信息,并融合注意力机制对输入的工程实践阶段性数据特征进行权重分配,以提升数据的利用率。该框架主要包含数据预处理、构建组向量、基于BiLSTM-Attention的二分类,整体框架如图1所示。

2 建模方法

2.1 以学生小组为单位的在线工程实践行为特征提取

2.1.1 数据预处理

步骤1:数据填充。由于实践小组因客观原因并未全程参与,导致数据集存在缺失,因此用0填充数据,代表该小组在该阶段中未产生此活动。

步骤2:数据标准化。使用z-score方法对数据进行归一化处理,将不同量级的数据转换成统一量级,以保证数据之间的可比性。

$$X^* = \frac{x - \mu}{\delta} \quad (1)$$

式中: μ 为数据均值, δ 为数据标准差。

步骤3:数据整理。以阶段为单位整理数据,使每一阶段的活动特征相似,并且各阶段分组情况和组内学生都相同,即第*i*周*j*组与第*i*-1周*j*组的学生相同。同时,每位学生的数据ID唯一,只参与一个小组的工程实践活动。

2.1.2 组向量构建

每个小组的实践信息以阶段为单位进行记录,其中第*i*个阶段的信息由各组在第*i*阶段的基本信息和活动情况组成。基本信息包括成员人数、每个学生id、学期、女性成员占比、组长性别等;活动情况包括本阶段会议时长、单人




Fig. 1 GEP-BiLSTM framework

图1 GEP-BiLSTM框架

参加会议平均时长、非编码可交付成果花费时长、编码可交付成果花费时长、组长管理时长、组员响应次数等。以阶段为单位的小组栈附上阶段序列,组成第*i*阶段的向量 F_i ,并传递至Sequential模型。对于每个第*i*阶段的小组栈,其组向量被追加到第*i*周,因此组向量经过padding操作后长度相等。

2.2 BiLSTM-Attention模型

如图2所示,BiLSTM-Attention模型的框架包含5个部分:①输入层将组向量输入模型;②Embedding层将组向量映射为低维向量;③BiLSTM层从Embedding层中得到更具代表性的高级特征;④Attention层生成权重向量,将每个时间步的阶段级特征乘以权重向量后进行加权,将其合并为组级特征向量;⑤输出层使用组级特征向量进行最终评价。




Fig. 2 BiLSTM Attention framework

图2 BiLSTM-Attention框架

2.2.1 Embedding层

Embedding层的作用是将组向量映射为低维向量,具体实现步骤:给定小组实践序列特征 $g_{it} = \{f_1, f_2, \dots, f_n\}$, g_{it} 代表第*i*个小组在第*t*个阶段的实践特征, f_a 代表第*a*个特征值, n 为正整数。首先,为了消除各特征值的单位限制,将每个序列特征进行归一化处理,归一化过程如式(2)~式(4)所示。

$$f'_i = \frac{f_i - \bar{f}}{m} \quad (2)$$

$$\bar{f} = \frac{1}{n} \sum_{i=1}^n f_i \quad (3)$$

$$m = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2} \quad (4)$$

式中: f'_i 代表特征 f_i 经归一化后产生的新特征; $\bar{f}$ 为均值; m 为标准差。

经过归一化产生新的特征序列 $g'_t = \{f'_1, f'_2, \dots, f'_n\}$ 和特征向量 $G'_t = [g'_{(i,1)}, g'_{(i,2)}, \dots, g'_{(i,t)}]^T \in R^{t \times n}$ 后计算协方差矩阵 D (见式(5)),然后通过协方差矩阵 D 计算特征向量及其对应的特征值,并将特征值从大到小排序,选取前*k*个最大的特征值和对应的特征向量形成新的矩阵 $P \in R^{t \times k}$ 。最后,计算出矩阵 $X_i = G'_i P$, $G_i \in R^{t \times k}$, 矩阵 $X_i = \{x_1, x_2, \dots, x_t\}$ 表示第*i*个小组从时间1到*t*的实践记录, $x_i = D_{pi}$, $i = \{1, 2, \dots, t\}$, p_i 表示*D*的第*i*个主特征向量。

$$D = \frac{1}{t} G'_t G'^T_t \in R^{n \times n} \quad (5)$$

2.2.2 BiLSTM层

循环神经网络会记忆已出现的信息,并将其应用于当前神经元输出的计算中,但存在梯度消失等问题。长短期记忆递归神经网络(Long Short Term Memory, LSTM)是经过改良的循环神经网络,其记忆单元在更新时会加上当前的输入,并结合输入门、遗忘门和输出门特点,能有效解决循环神经网络的梯度消失问题,具体数学表达如式(6)~式(11)所示。式中主要符号含义如表1所示。

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (7)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (8)$$

$$c_t = f_t c_{t-1} + i_t \tilde{C}_t \quad (9)$$

$$o_t = \tanh(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_{co}) \quad (10)$$

$$h_t = o_t \tanh c_t \quad (11)$$

然而,LSTM为单向神经网络,而BiLSTM为双向的,由

向前和向后的LSTM组合而成,其前后输入相同,但信息传递方向相反。通过拼接正向和反向LSTM结果向量得到最终输出结果能更好地捕捉双向的语义依赖,具体操作过程如图2所示。

Table 1 Main symbol meanings in LSTM structural expressions

表1 LSTM结构表达式中主要符号含义

符号	含义
i_t	输入门的输出结果
f_t	遗忘门的输出结果
o_t	输出门的输出结果
σ	sigmoid激活函数
W	权重矩阵
$\tilde{C}_t$	新增加的信息
b	偏置向量
c_t	在t时刻的更新状态
h_t	该单元在t时刻的输出

2.2.3 Attention层

为得到时间序列中各项数据与预测值的关联关系,在层中计算不同时刻的数据特征状态对预测值的注意力值,具体数学表达式如式(12)一式(14)所示。式中主要符号含义如表2所示。

$$u_t = \tanh(W_w H_t + b_w) \quad (12)$$

$$a_t = \frac{\exp u_t^T u_w}{\sum \exp u_t^T u_w} \quad (13)$$

$$v_t = \sum a_t H_t \quad (14)$$

Table 2 Main symbol meanings in the Attention structure expression

表2 Attention结构表达式中主要符号含义

符号	含义
u_t	未归一化的注意力分数
H_t	BiLSTM层的输出向量
W_w	权重系数
a_t	新的加权系数
v_t	Attention层的输出向量
b_w	偏差系数

3 实验数据集与参数设置

3.1 实验数据集

本文使用SETAP数据集^[5]、DEEDS数据集^[26]验证所提框架的有效性。为了减少过拟合问题,首先对数据集进行五折交叉验证,将训练集随机分为5个子集,其中一个子集用于验证,另外4个子集用来训练,最终结果为5次实验结果的平均值,每个数据集按照4:1的比例划分训练集和测试集。

3.1.1 SETAP数据集

SETAP数据集包含学生参与项目的记录。在项目期间,学生参加同一门软件工程课程,SETAP项目分为过程阶段和产品阶段^[5]。在过程阶段,记录学生的学习能力及他们在团队环境中有效参与软件工程过程的数据;在产品

阶段,数据包括学生开发满足特定需求的软件的能力。项目主要特征包括成员人数、每个学生id、学期、女性成员占比、组长性别、本阶段会议时长、单人参加会议平均时长、非编码可交付成果花费时长、编码可交付成果花费时长、组长管理时长、组员响应次数等。

本文实验共有383名学生参与,将其分成74个小组,每组3~7人,共记录了超过300 000条数据并存储在11个对应各项目的学习目标文件组(T1-T11)中。这些组与5个预定义的阶段(M1-M5)相关联,可分为早期的高级需求、详细的需求和规范、原型开发和评审、实现beta发布、测试和最终交付。

最后,每个团队共记录了116个产品特征和84个过程阶段特征,专家根据各团队最终成果将团队分为高于预期的团队(表现良好,标签为“A”)与低于预期的团队(表现较差,标签为“F”)。

3.1.2 DEEDS数据集

DEEDS数据集由数字电子教育和设计平台实施捕捉并记录学生在6次会议和在课堂作业中的实时互动情况及考试成绩,包括学生在各类题目上花费的时间、学习环境、活动类型、活动总数、平均空闲时间等特征^[26]。共有115名学生参与实验、完成作业和考试的数据,但有7名学生未参与实验阶段。

3.2 参数设置

在实验中,考虑到迭代训练效果应贴合自身数据集特性,因此本文经过实验分析后设置学习率 learning rate=0.000 01、一次训练所选取的样本数 batch size=20、随机失活方法 dropout=0.5。

4 实验结果与分析

4.1 评价指标

本文通过4种度量指标评价分类器的性能,准确率(Accuracy, ACC)用来衡量被学习成效评价为失败的数据与真正学习成效为失败的数据之间的相关性;精确率(Precision, P)表示所有学习成效被评价为失败的数据中真正为失败的比例;召回率(Recall, R)表示所有学习成效为失败的数据中被正确评价的比例;F1-score(F1)为精确率和召回率的加权调和平均值,可提供更全面的评价。以上指标均为数值越高效果越好,具体数学表达式如式(15)一式(17)所示。

$$Accuracy = \frac{|TP| + |TN|}{|TP| + |TN| + |FP| + |FN|} \quad (15)$$

$$Precision = \frac{|TP|}{|TP| + |FP|} \quad (16)$$

$$Recall = \frac{|TP|}{|TP| + |FN|} \quad (17)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (18)$$

式中:TP(True Positive)指正样本被正确识别为正样

本; TN (True Negative) 指负样本被正确识别为负样本; FN (False Negative) 指负样本被错误识别为正样本; FP (False Positive) 指正样本被错误识别为负样本。正样本指学习成效被评价为成功, 负样本指学习成效被评价为失败。

4.2 SETAP数据集实验结果

本文在 SETAP 数据集上使用 11 种模型进行比较实验, 实验结果如表 3 所示。其中, RandomForest 为一种使用 Bagging 思想的决策树集成方法, 在 Bagging-DecisionTree 的基础上增加了特征的随机性; BalanceRandomForest 在随机森林模型上进行了改进, 在处理某些样本数量少的数据时性能良好; DecisionTree 将数据集细分为子集, 构建树形结构作出决策; EextraTree 为 RandomForest 的一种变体, 在构建 DecisionTree 时进一步增加了随机性; AdaBooot 和 GradientBossting 均应用了集成学习方法, 通过构建、训练多个弱学习器后得到强学习器; CatBoost 使用了梯度提升算法; Stacking 将多种基学习器的预测结果作为输入, 然后构建一个元学习器输出最终的预测结果, 通过堆叠可利用不同学习器的优势; DNN 深度神经网络具有多个隐藏层, 可提取数据的高级特征; LSTM-Attention 基于循环神经网络, 对序列数据的处理方面表现良好, 并结合注意力机制可提高特征提取效果。

Table 3 Experimental results of different models on the SETAP dataset

表 3 不同模型在 SETAP 数据集上的实验结果				
模型	ACC	R	P	F1
RandomForest	0.520	0.200	0.080	0.214
Bagging-DecisionTree	0.680	0.200	0.008	0.114
BalancedRandomForest	0.520	0.600	0.120	0.295
DecisionTree	0.440	0.300	0.130	0.181
ExtraTrees	0.520	0.400	0.180	0.248
AdaBoost	0.440	0.300	0.213	0.248
GradientBoosting	0.520	0.300	0.147	0.194
CatBoost	0.600	0.200	0.080	0.114
Stacking	0.520	0.300	0.147	0.194
DNN	0.720	0.714	0.500	0.588
LSTM-Attention	0.720	0.857	0.500	0.632
GEP-BiLSTM	0.800	0.625	0.714	0.667

由表 3 可知, 虽然部分模型在 Accuracy 指标下相较于本文所提模型得分较高, 但在其余 3 个指标下的得分普遍较低, 综合考虑 4 个评价指标的得分后可得 GEP-BiLSTM 在 SETAP 数据集上的表现优于其他模型。同时, 将传统机器学习方法 (RandomForest、Stacking) 与深度学习方法 (DNN、LSTM) 进行比较, 也证明了神经网络方法优于传统机器学习方法。

4.3 DEEDS数据集实验效果

在 DEEDS 数据集上, GEP-BiLSTM 模型及比较模型的实验效果如表 4 所示。由此可知, 虽然 DNN、LSTM-Attention 的准确度相较于 GEP-BiLSTM 略高, 但 GEP-BiLSTM

在其他 3 个指标上的得分分别为 0.900、0.944 和 0.915, 明显优于其余模型, 在综合考虑 4 个评价指标的得分后可得 GEP-BiLSTM 的表现更优, 证明了 GEP-BiLSTM 在 DEEDS 的数据集上表现较好。

Table 4 Experimental results on the DEEDS dataset

表 4 在 DEEDS 数据集上的实验结果				
模型	ACC	R	P	F1
RandomForest	0.767	1.000	0.700	0.800
Bagging-DecisionTree	0.846	0.800	0.900	0.819
DecisionTree	0.833	0.800	0.700	0.733
ExtraTrees	0.733	0.800	0.600	0.667
DNN	0.933	0.800	0.800	0.800
LSTM-Attention	0.933	0.800	1.000	0.800
GEP-BiLSTM	0.923	0.900	0.944	0.915

在 DEEDS 数据集上各模型的 Accuracy 结果如图 3 所示。其中, 深度学习方法 (DNN、LSTM-Attention 和 GEP-BiLSTM) 的 Accuracy 得分明显高于传统机器学习方法 (RandomForest 和 ExtraTrees), 原因为 DEEDS 数据量较少, 一旦调整网络模型参数到合适值时, 深度学习在小数据集上的准确率与传统机器学习方法的效果接近。




Fig. 3 Experimental results of different models on the DEEDS dataset (Accuracy)

图 3 不同模型在 DEEDS 数据集上的实验结果 (Accuracy)

4.4 消融实验

在 SETAP 数据集上的进行消融实验的结果如表 5 所示。由此可知, 不使用组向量的 BiLSTM 模型准确率为 0.690, 召回率为 0.605; 使用组向量后模型性能显著提升, 准确率为 0.800, 召回率为 0.625, 但模型的精确率和 F1-score 存在一定程度的下降, 表明模型可能将负例样本误分类为正例样本, 也可能存在数据集正负样本比例不均衡的情况。

总体而言, 消融实验证明了构建组向量对提升模型分类效果具有积极作用。

Table 5 Ablation experimental results

表 5 消融实验结果				
模型	ACC	R	P	F1
不使用组向量的 BiLSTM 模型	0.690	0.605	0.939	0.736
GEP-BiLSTM	0.800	0.625	0.714	0.667

5 结语

本文提出 GEP-BiLSTM 框架, 根据各实践小组的学习行为数据评价学习成效。该框架由 GEP 和 BiLSTM-Attention 模型组成, 主要工作流程为: GEP 部分接收小组工程实践数据, 提取时间序列特征, 输出组向量; BiLSTM-Attention 模型处理组向量, 输出评价结果。

在两个数据集上, 将 GEP-BiLSTM 框架与 11 个模型进行比较实验的结果表明, 本文所提框架在两个数据集上的性能均优于大部分模型, 证明了提取各阶段小组特征方法和双向长短期记忆神经网络能有效提升模型性能。未来, 将进一步探讨新的技术方法, 以更准确地评价在线工程实践效果。

参考文献:

- [1] YANG W Y, XU K X. Research on the design and application of immersive virtual learning environment in universities under the background of industry 4.0[J]. Research and Exploration in Laboratory, 2023, 42(1): 243-246, 291.
杨文阳, 徐可欣. 工业 4.0 背景下高校沉浸式虚拟学习环境设计与应用研究[J]. 实验室研究与探索, 2023, 42(1): 243-246, 291
- [2] WEN L P, QIAN F D, QIU F Y. Research on a virtual learning environment model for personalized teaching processes[J]. The Chinese Journal of ICT In Education, 2010(19): 63-66.
闻立鹏, 钱福东, 邱飞岳. 面向个性化教学流程的虚拟学习环境模型研究[J]. 中国教育信息化(高教职教), 2010(19): 63-66.
- [3] BOULTON C A, KENT C, WILLIAMS H T P. Virtual learning environment engagement and learning outcomes at a "bricks-and-mortar" university[J]. Computers & Education, 2018, 126: 129-142.
- [4] XIA P. Exploration of teaching design strategies in virtual learning environment[J]. Informatization Forum, 2021(12): 55-56.
夏鹏. 虚拟学习环境中的教学设计策略探究[J]. 教育信息化论坛, 2021(12): 55-56.
- [5] ABU S A, AL-EMRAN M, SHAALAN K. Factors affecting students' performance in higher education: a systematic review of predictive data mining techniques[J]. Technology, Knowledge and Learning, 2019, 24(4): 567-598.
- [6] PETKOVIC D, SOSNICK-PÉREZ M, OKADA K, et al. Using the random forest classifier to assess and predict student learning of software engineering teamwork [C]// 2016 IEEE Frontiers in Education Conference, 2016: 1-7.
- [7] YU W Y. Data mining technology and application in the age of big data [J]. China Computer & Communication, 2023, 35(5): 1-3.
于汶雨. 大数据时代的数据挖掘技术与应用[J]. 信息与电脑(理论版), 2023, 35(5): 1-3.
- [8] JIA J L. Prediction and decision analysis model based on data mining technology [J]. Journal of Guiyang University (Natural Sciences), 2023, 18(1): 85-90.
贾静丽. 基于数据挖掘技术的预测与决策分析模型[J]. 贵阳学院学报(自然科学版), 2023, 18(1): 85-90.
- [9] SEN P C, HAJRA M, GHOSH M. Emerging technology in modelling and graphics[M]. Berlin: Springer, 2018.
- [10] KHAN A, GHOSH S K. Student performance analysis and prediction in classroom learning: a review of educational data mining studies[J]. Education and Information Technologies, 2021, 26: 205-240.
- [11] BURGOS C, CAMPANARIO M L, DE L P D, et al. Data mining for modeling students' performance: a tutoring action plan to prevent academic dropout [J]. Computers & Electrical Engineering, 2018, 66: 541-556.
- [12] FERNANDES E, HOLANDA M, VICTORINO M, et al. Educational data mining: predictive analysis of academic performance of public school students in the capital of Brazil[J]. Journal of Business Research, 2019, 94: 335-343.
- [13] XU X, WANG J, PENG H, et al. Prediction of academic performance associated with Internet usage behaviors using machine learning algorithms[J]. Computers in Human Behavior, 2019, 98: 166-173.
- [14] ZHANG P. Data mining technology and practice in the era of big data [J]. China New Telecommunications, 2021, 23(22): 68-70.
张鹏. 大数据时代的数据挖掘技术与实践[J]. 中国新通信, 2021, 23(22): 68-70.
- [15] REBAIS, YAHIA F B, ESSID H. A graphically based machine learning approach to predict secondary schools performance in Tunisia[J]. Socio-Economic Planning Sciences, 2020, 70: 100724.
- [16] WAHEED H, HASSAN S U, ALJOHANI N R, et al. Predicting academic performance of students from VLE big data using deep learning models [J]. Computers in Human Behavior, 2020, 104: 106189.
- [17] BERNACKI M L, CHAVEZ M M, UESBECK P M. Predicting achievement and providing support before STEM majors begin to fail [J]. Computers & Education, 2020, 158: 103999.
- [18] HUSSAIN M, ZHU W, ZHANG W, et al. Student engagement predictions in an e-learning system and their impact on student course assessment scores [J]. Computational Intelligence and Neuroscience, 2018, 10: 6347186.
- [19] SILVEIRA P D N, CURY D, MENEZES C, et al. Analysis of classifiers in a predictive model of academic success or failure for institutional and trace data [C]// 2019 IEEE Frontiers in Education Conference, 2019: 1-8.
- [20] YUAN T, SUN Z, MA S. Gearbox fault prediction of wind turbines based on a stacking model and change-point detection [J]. Energies, 2019, 12(22): 4224.
- [21] ADEJO O W, CONNOLLY T. Predicting student academic performance using multi-model heterogeneous ensemble approach [J]. Journal of Applied Research in Higher Education, 2018, 10(1): 61-75.
- [22] OKUBO F, YAMASHITA T, SHIMADA A, et al. A neural network approach for students' performance prediction [C]// Proceedings of the Seventh International Learning Analytics & Knowledge Conference, 2017: 598-599.
- [23] RANJEETH S, LATCHOUMI T P, SIVARAM M, et al. Predicting student performance with ANNQ3H: a case study in secondary education [C]// 2019 International Conference on Computational Intelligence and Knowledge Economy, 2019: 603-607.
- [24] AWAD M, EWAIS A. Prediction of general high school exam result level using multilayer perceptron neural networks [EB/OL]. <https://api.semanticscholar.org/CorpusID:173171474>.
- [25] PHUNGSUK R, VIRIYAVEJAKUL C, RATANAOLARN T. Development of a problem-based learning model via a virtual learning environment [J]. Kasetsart Journal of Social Sciences, 2017, 38(3): 297-306.
- [26] VAHDAT M, ONETO L, ANGUITA D, et al. A learning analytics approach to correlate the academic achievements of students with interaction data from an educational simulator [C]// Design for Teaching and Learning in a Networked World: 10th European Conference on Technology Enhanced Learning, 2015: 352-366.

(责任编辑: 刘嘉文)