

doi:10.11835/j.issn.1005-2909.2026.01.020

欢迎按以下格式引用:文海家,张家兰,杨海清,等.基于随机森林的翻转混合教学效果评价与提升策略[J].高等建筑教育,2026,35(1):181-189.

基于随机森林的翻转混合教学效果评价与提升策略

文海家,张家兰,杨海清,王桂林,谢强

(重庆大学土木工程学院,重庆 400045)

摘要:探索了一种基于机器学习的混合式教学效果评价方法,利用随机森林算法,基于成绩、行为、情感等多种类型和来源的数据,构建了混合式教学评价模型,并通过特征重要性分析提出针对性的教学提升策略。以中国大学MOOC开设的国家级一流本科线上课程地学景观探秘·审美·文化为例,收集了376名学生的问卷数据,进行了模型训练和验证。结果表明,优化后的随机森林模型拟合优度提高40%、残差平方均值降低7%,模型预测成绩对比学生实际成绩 R^2 达到0.92,可有效地预测和分析学生的学习效果;学习过程参与、线上线下学习途径、手机使用、形成性评价、学习时间投入、收获感等是影响学习效果的关键因素;据此提出了针对性的混合式教学效果提升策略。研究提出的方法可为优化混合式教学设计、提高混合式教学质量、促进个性化教育提供参考。

关键词:混合式教学;学习者行为;学习效果;随机森林;提升策略

中图分类号:G511

文献标志码:A

文章编号:1005-2909(2026)01-0181-09

随着信息技术的发展和普及,网络教育为保障教育质量和教育公平提供了有效的途径和手段^[1]。据统计,截至2020年,全球慕课学习者已超过1.3亿,涉及课程超过1万门。我国2013年进入慕课元年,至今已经建设、运行的在线课程数量已稳居世界第一。然而,慕课面临着诸多挑战和问题,如参与度低、完成率低、质量难以保证、效果难以评估等^[2]。混合式教学将慕课或其他在线资源与面对面教学相结合,形成一种新型的教育模式。该模式兼顾了线上学习的灵活性和面对面教学的临场体验,为学习者提供了更加丰富多样的学习资源和环境^[3-5],又可构建以学生为中心、注重生成性教学的有效模式^[6],进而提升教学效果和人才培养质量,兼有高阶性、创新性和挑战度的金课典型特征^[7]。

混合式教学有助于提升教育质量和效果,但也面临诸多挑战与问题:一是如何有效评价学习效果并识别影响学习效果的重要因素,这已成为研究焦点^[8-10];二是如何基于关键学习行为制定有效的提升学习效果策略^[11-14]。关于混合教学学习效果的评价研究^[15-16],基于日志数据、点击流数据等

修回日期:2024-04-03

基金项目:重庆市高等教育教学改革研究重点项目(222012);重庆大学教学改革研究项目(2021Y37)

作者简介:文海家,教授,工学博士,主要从事岩土工程研究,(E-mail)jhw@cqu.edu.cn。

方法分析学习者在混合教学中的行为特征,并探究其与学习效果之间的关系^[17-21],可揭示学习者的部分行为模式,但缺乏对学习者的心理状态和情感状态考量^[22]。近年来,以机器学习为代表的人工智能在高校人才培养领域得到了广泛的研究和应用^[23],机器学习能够构建有效的评价模型,预测和分析学习者的学习效果,并找出影响学习效果的重要因素^[24-25]。随机森林(RF)是一种基于多个决策树的集成学习算法,能够有效地处理高维、非线性和缺失数据的问题,评估每个特征对模型预测能力的贡献程度,在自然、社会科学研究领域广泛使用^[26-28]。

本研究采用随机森林方法,构建混合式教学评价模型,并通过特征重要性分析找出影响混合式教学效果的关键因素。利用混合式教学过程中产生的多源异构数据,包括成绩、行为、情感等类型和来源的数据,构建一个更加全面和客观的评价模型;预测和分析混合式教学中学习者的成绩,评估每个学习行为指标对模型的贡献程度,找出影响混合式教学效果的关键因素;根据关键因素的特点,提出针对性的混合式教学效果提升策略,以期优化教学设计、提升教学质量、促进个性化教育提供参考。

一、研究数据

(一) 数据来源

本研究基于中国大学MOOC开设的一流本科线上课程——地学景观探秘·审美·文化,在重庆大学每学期配套开设2~3个教学班的混合式课程地学景观文化^[7]。本研究以2018年春季学期至2022年春季学期为观测周期,在连续5年、累计9轮的课程实施过程中,采用问卷调查法对学生学习行为与学习效果的关联性数据进行持续追踪采集。

学习者的学习行为信息通过问卷调查法获取。问卷设计目标为综合考察学生在课程兴趣、学习预期、时间投入、线上线下教学活动参与度、师生及生生互动情况、自主学习能力等维度的表现。基于上述目标,问卷共设计21个问题(见表1)。依托教学过程中使用的移动端手机APP,分别于每学期前两周(Pr)、期中(Mi)及期末(Po)三个时间节点发放:学期前问卷聚焦学习期望、动机与时间投入规划;期中问卷侧重调查学习过程中的各类参与行为;期末问卷则对学习过程参与度、学习满意度等内容进行全面调研^[15]。

为降低不同教师教学班的影响,只选用了同一名教师持续9个学期开设的教学班,共529名学生选修本课程,其中有7名学生缺考无成绩,其余522人中40人未参与或者只完成了1个问卷调查,有482人参与2个问卷调查,376人参与完成3个问卷调查。

(二) 数据预处理

以参与了3个问卷的376人学习行为数据样本。对问卷调查结果进行量化区分:单一选项可直接区分量化,而多项选择则先将选项质数赋值后叠加量化,以便能绝对区分不同学生的不同选项。此外,在研究过程中发现,少数异常数据对模型拟合效果有影响,需要对数据进行离群点检验,再进行异常数据的剔除处理。针对数据中的异常值,本研究采用离群点检验方法进行处理,具体通过判断单个最大标准化残差值的显著性来识别离群点。在本研究中,设定最大标准化残差绝对值大于2即认定为离群点。

二、研究方法过程

(一) 学习行为与效果回归的随机森林算法与参数优化

随机森林是一种基于多个决策树的集成学习算法,在有效处理高维、非线性问题方面有明显的

优势。主要步骤:(1)从原始数据集中有放回地抽取多个子样本,每个子样本的大小与原始数据集相同;(2)对每个子样本构建一棵决策树,每次分裂节点时,从所有特征中随机选择一部分特征,并从中选取最优的特征进行分裂;(3)将所有决策树组成一个森林,对于每个测试样本,让所有的决策树进行预测,并取平均值作为最终预测结果。

表1 混合式教学过程参与情况调查问卷表

序号	问题	题型
Pr1	每周投入本课程学习的时间有多少	单选
Pr2	翻转混合教学模式比传统课堂教学模式,你觉得自己的学习负担是	单选
Pr3	你觉得投入本课程学习的时间每周多少时间合适	单选
Pr4	采用翻转混合教学,到这门课结束时,你预期的收获将如何	单选
Mi1	学期过半,你的收获如何	单选
Mi2	你在线上参与的学习活动最多的三项是	多选
Mi3	你在线下(课堂)学习参与最多的三项活动是	多选
Mi4	你课堂上使用手机的情况是	多选
Mi5	本课程成绩形成性考核评价中,你参与/完成过哪几项	多选
Mi6	本课程成绩形成性考核评价中,你参与度最高、完成得较好的是哪三项	多选
Mi7	本课程成绩采用形成性考核评价,你预期自己的成绩如何	单选
Po1	本课程采用翻转混合模式,与其他模式比,你投入的学习时间你	单选
Po2	对自己本课程的学习效果评价,与其他教学模式相比	单选
Po3	相比本课程开始时调查问卷中对本课程学习效果与收获,你认为是否达到预期	单选
Po4	你在线上(除在教室上课外)投入的学习时间,每周大概是	单选
Po5	你在线上(除在教室上课外),从哪些途径学习过本课程的内容	多选
Po6	你在线下课堂从哪些途径学习过本课程的内容	多选
Po7	你学习过程中遇到的问题主要采用什么方式解决	多选
Po8	学习过程中各种途径,你与同学、助教、老师的互动情况	单选
Po9	在课堂上,你用手机上网的情况	多选
Po10	课堂上你投入本课程学习的情况	单选

随机森林算法参数选择对模型效果具有重要影响^[27]。为了优化模型的参数,采用for循环的简易方法,对影响模型性能的两个主要参数^[28]进行不同的组合尝试。Ntree即决策树的数量,取值范围为100~1 000;Mtry即每次分裂节点时随机选择的特征数量,取值范围为1~10。采用10折交叉验证(10-fold Cross Validation)方法对每种参数组合的模型性能进行评估,选取均方误差(MSE)作为评估指标,并将MSE取值最小时对应的参数组合作为最优参数组合。研究中使用R语言编写代码,实现随机森林回归优化模型。

(二) 特征筛选方法

采用递归特征消除(RFE)方法选择特征,降低数据维度,提高模型效果^[27-28]。递归特征消除是一种基于模型的特征选择方法,其主要步骤:(1)从所有特征开始,训练一个模型,并计算每个特征的重要性或系数;(2)移除最不重要或最小系数对应的特征,得到一个新的特征子集;(3)重复上述过程,直到达到预设的特征数量或者模型性能最优。

使用R语言编写代码,调用caret包中的rfe函数可实现递归特征消除方法。选择随机森林作为基模型,使用默认的参数设置,特征选择的结果将用于后续的回归分析。

(三) 模型性能评价指标

为了对随机森林回归模型优化效果进行评估,选择残差平方均值和拟合优度作为参数优化前后模型评价的指标。为评估模型对学习者行为-学习效果的预测能力,采用决定系数(R^2)和均方根误差(RMSE)评估最终的模型预测效果。使用最优参数组合训练随机森林回归模型和评价指标数据集进行学习成绩预测,计算预测成绩与真实成绩之间的 R^2 和RMSE,并将其作为模型拟合效果的评估指标。 R^2 反映了模型对数据变异性的解释能力,越接近1越好;RMSE反映了模型预测误差的大小,越小越好。

(四) 学习行为重要性分析方法

将学生的期末成绩作为因变量,各种学习行为指标作为自变量,确定学习行为影响学习成绩的因子排序,针对关键因子提出改进策略。不同的分析方法原理不同,对特征重要性的分析结果可能存在差异。自变量、因变量的相关性大小是反映重要性的常用方式,可以对数据集进行 Pearson 相关分析;特征重要性评估,即每个特征对模型预测能力的贡献程度,是随机森林优点之一。随机森林回归分析可提供%IncMSE 和 IncNodePurity 值两种特征排序方法:%IncMSE 是基于模型在袋外数据(Out-of-Bag, OOB)上的预测误差,对于每个特征,随机打乱其在 OOB 数据上的取值,再计算模型的预测误差,计算打乱前后预测误差的百分比增加量,作为该特征的重要性;IncNodePurity 是基于模型中每个节点的不纯度(Impurity),对于每个特征,计算其在所有节点中出现时导致不纯度减少的总量,作为该特征的重要性。

使用 R 语言 randomForest 包中的 randomForest 函数实现随机森林回归,并使用 importance 函数提取特征重要性。

三、结果分析与讨论

(一) 特征相关性

初步判断自变量与因变量之间的相关性与重要性,以及分析各自变量之间相关性(独立性)。表2是基于数据的学习行为指标与成绩之间的 Pearson 相关与重要性系数。图 1a)是评价指标与成绩之间相关性与重要性雷达图,图 1b)所有变量间相关性热力图。由此分析发现,除个别因子外,评价指标与成绩之间的相关性与重要性基本一致;评价指标的 Pearson 相关系数均较小,表明自变量与因变量主要是一种非线性相关关系,一般的统计回归方法不适合;自变量之间的 Pearson 相关系数都较小,表明评价指标间的独立性能得到保证,适用于高度非线性分析的机器学习模型建模分析。

表2 评价指标与成绩之间的 Pearson 相关与重要性系数

学习行为	Pr1	Pr2	Pr3	Pr4	Mi1	Mi2	Mi3
相关系数	0.08807806	0.1739265	0.08355324	-0.005373704	0.1767143	-0.02964087	0.1135407
重要性	1.1029913	1.8080697	1.3838237	1.8435192	0.6868697	1.5204869	2.3080523
学习行为	Mi4	Mi5	Mi6	Mi7	Po1	Po2	Po3
相关系数	0.2399467	0.2637389	-0.05008387	0.3914239	0.1538678	0.188922	0.0892075
重要性	3.2014602	1.9491413	1.0598455	4.4726768	0.8490293	1.8151958	0.7556027
学习行为	Po4	Po5	Po6	Po7	Po8	Po9	Po10
相关系数	0.1014122	0.2259584	0.2049301	0.07818391	0.209682	0.2564073	0.1810186
重要性	1.0849606	2.2368044	0.1369580	1.0936003	1.2728826	2.4747898	0.4540543

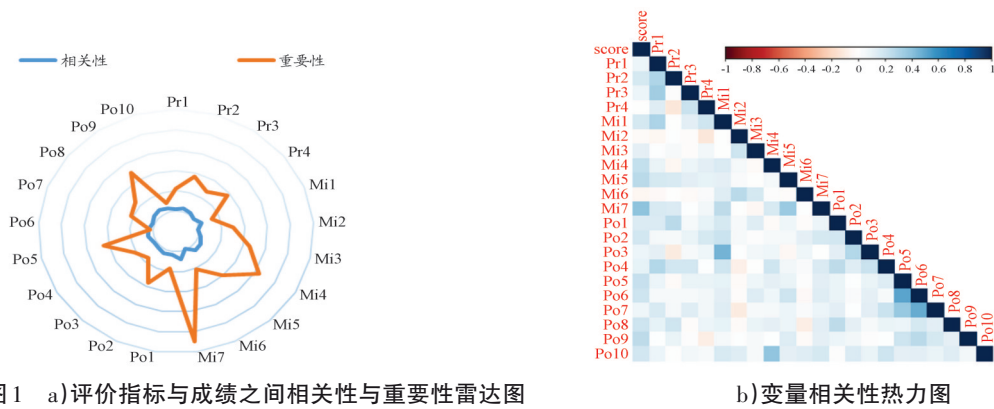


图1 a)评价指标与成绩之间相关性与重要性雷达图

b)变量相关性热力图

(二) 模型优化

机器学习模型的优化主要包括评价指标筛选和算法参数优化。

1. 学习行为指标筛选

采用前述递归特征消除法(RFE),以RMSE最小为目标进行优化,得到评价指标的筛选结果。

图2为学习行为指标个数-RMSE的关系曲线,当采用19个指标时, RMSE为3.515,达到最小值。其中前5个评价指标分别为: Mi7, Mi6, Po8, Po9和Pr1,而Mi1和Pr4两个指标被剔除。




图2 递归特征消除法筛选学习行为指标

2. 随机森林模型参数优化

随机森林算法参数的个数及取值范围根据文献结合经验初步选定^[28]。采用R语言对前述随机森林模型参数进行优化。由决策树数量变化误差曲线可以确定Ntree大于800时,误差曲线平缓不变(图3),采用Ntree=800代入,得到最优解Mtry=5。




图3 决策树数量变化误差曲线

为了检验参数优化的效果,对优化前后模型性能进行比较,结果如表3所示。由此可见,采用优化后算法参数(Ntree=800, Mtry=5),得到模型的残差平方均值为18.205,拟合优度为20.17。采用默认参数(Ntree=500, Mtry=7),得到模型的残差平方均值为19.530,拟合优度为14.1。可见,在进一步优化算法参数后,模型残差平方均值降低,拟合优度提高,整体性能显著提升。

表3 随机森林参数优化前后模型性能

	Ntree	Mtry	残差平方均值	拟合优度
优化后	800	5	18.205	20.17
优化前	500	7	19.530	14.10

(三) 模型预测效果

将优化前、后的随机森林模型用于学生成绩预测,并将预测成绩作为纵坐标、实际成绩作为横坐标进行拟合分析,对比分析模型的预测效果。表4为优化前、后模型的预测性能参数,图4为优化前、后模型预测成绩-实际成绩的拟合曲线。由此可见,随机森林方法构建的学生学习行为-学习效果预测模型比较理想,经优化后模型的预测效果更佳。

表4 随机森林参数优化前后模型的预测效果

	拟合曲线	RMSE	R ²
优化后	$Y=0.623x+34.524$	2.001	0.9201
优化前	$Y=0.635x+33.436$	2.006	0.9056

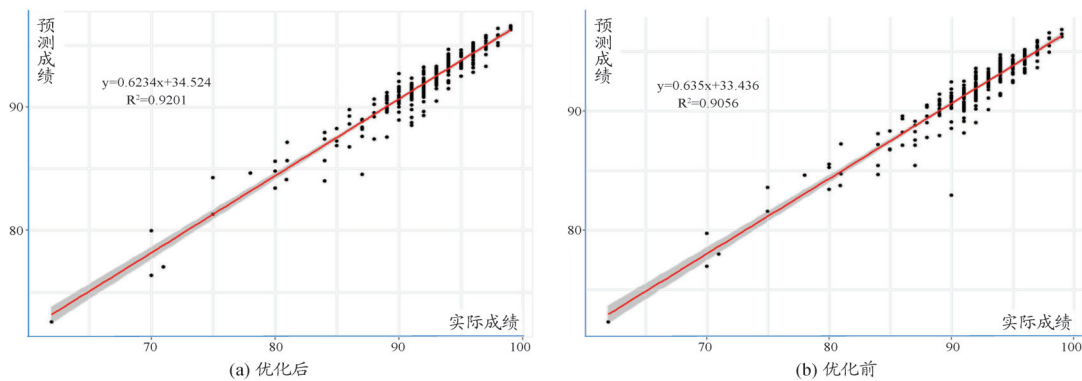


图4 模型预测效果

(四) 基于学习行为指标重要性的学习效果提升策略

要提出有效的学习效果提升策略,首先必须找出对学习效果产生重要影响的关键学习行为。前述因子相关性分析表明,单个学习行为指标对学习效果的相关性较小,不足以评价因子的重要程度,需要进一步多角度对学习行为因子的重要性进行分析。采用前述基于随机森林的%IncMSE和IncNodePurity指标,得到超参数优化后的因子重要性排序,如图5所示。结合前述Pearson相关系数进行综合分析,得到如图6所示的评价指标对学习效果影响重要性排序的箱线图。

由表2、图1、图5和图6进一步分析可以发现,不同的方法由于原理不同,得到的因子重要性排序存在一定差异。图6所示将学习行为指标重要性排序划分为高、中、低三个组,其中影响学习效果重要性最大的是Mi7等7个指标,Po10等6个指标的重要性最低。

将前述Mi7等7个指标作为学习行为对学习效果影响的关键因子,进一步得到具有针对性的线上线下混合式教学效果的提升策略。




图5 基于随机森林的因子重要性排序




图6 评价指标对学习效果影响重要性综合排序箱线图

(1)混合式教学是基于过程考核的,全过程参与对于学习效果的形成至关重要。在开始到期中这段时间,加强学习过程参与,使学习者对自己的成绩有一个清晰的预期,进而激发学生的内在动机,增强自信心和责任感,可促进学生积极主动地参与学习,提高学习效率和质量。

(2)混合式教学整合线上与线下多元教学途径及差异化课程内容,引导学生通过研习线上线下各类教学资源,系统掌握课程知识。这种教学模式能够开阔学生的学术视野,增强学习的选择性与灵活性,满足不同学生的个性化需求,可有效激发学生的学习兴趣与探索欲望,进而促进学生开展深度学习。

(3)基于手机的移动互联网终端是有效的学习工具,也符合现代青年学习者的习惯。无论线上还是线下教学,引导学习者合理使用手机进行学习、交流互动,可以扩大学生的信息来源,提高学生对学习内容的理解力,增强学生的协作能力和创造力。

(4)形成性评价是在教与学过程中进行的持续性、过程性、互动性的评价活动,旨在促进教师和学生对于教与学过程和结果进行反馈和改进,是混合式教学比较适宜的学习效果评价模式。教学过

程中要不断提醒学习者参与形成性评价项目,帮助学生明确自己的优势和不足,调整学习策略和方法,提升自主学习能力和元认知能力。

(5)学习者的投入是学习效果的重要保障,相较于传统课堂教学模式,混合式教学需要搭建适配性强、体验优良的线上学习平台和资源,以此引导学生投入时间和精力,主动利用网络资源开展自主探究、协作交流与反思评价。

(6)增强学习者的获得感,使学生在学习过程中对自己的学习成果和进步有一个正向的评价和感受。获得感可以增强学生的学习满足感和成就感,激发学生的学习动力和热情,促进学生的持续学习和终身学习。

四、结语

本研究基于问卷调查、结合随机森林算法构建了混合式教学的学习者行为与学习效果的评价模型,并基于学习行为评价指标的重要性探讨了有效的学习效果提升策略。

(1)对混合教学过程中收集的问卷数据建立了评价指标体系,采用多种优化方法进行了学习者行为与学习效果预测的随机森林方法建模,优化前后模型预测结果与学习者实际成绩的拟合效果 R^2 分别达到0.90和0.92,表明模型具有较高的准确性和稳定性。

(2)通过多种特征重要性综合分析,得到影响混合教学学习效果的7个关键因素,进一步探讨了提升学习效果的针对性策略,包括:加强线上课程内容和呈现,提高线下课堂的互动性和趣味性,设计和实施有效的形成性评价项目,培养学生的自我管理能力和同伴互助能力,增强学生的自我效能感和满意度等。

(3)探索了一种新颖且有效的基于机器学习的混合式教学学习效果评价方法,运用随机森林特征重要性评估算法,为基于数据挖掘剖析影响学习效果的关键行为因素,提供了客观、量化的依据,进而为混合式教学优化教学设计、提升教学质量、推进个性化教育实施提供了参考。

本研究后续还可针对评价指标数据样本偏少、样本分布不均衡,模型泛化能力有待进一步验证,特征重要性评估方法有待完善等问题展开持续研究,可尝试扩大数据规模,平衡样本分布,验证模型在不同场景下的适用性,探索更多的特征重要性评估方法等。

参考文献:

- [1] 覃红霞, 张金丹. 在线教学与面授教学质量同等吗——基于新冠肺炎疫情期间美国高校107件在线教学案件的分析[J]. 比较教育研究, 2023, 45(6): 3-10, 45.
- [2] 刘斌, 张文兰. 在线课程学习体验的影响因素及其结构研究[J]. 现代教育技术, 2017, 27(9): 107-113.
- [3] Wang Y Q. Research on flipped classroom of big data course based on graphic design MOOC[J]. Wireless Communications and Mobile Computing, 2021, 2021(1): 4042459.
- [4] 王旭珍, 王新葵, 宋雪旦, 等. 基于MOOC的物理化学翻转课堂教学改革与实践[J]. 中国大学教学, 2019(5): 38-42.
- [5] 臧冠男. 翻转课堂教学模式下移动学习系统构建与设计[J]. 吉林广播电视大学学报, 2019(11): 67-68.
- [6] 邹维, 张东娇. “金课”就是“受学生欢迎的课”?[J]. 现代大学教育, 2020, 36(4): 105-110.
- [7] 文海家, 杨海清, 王桂林, 等. 最美慕课——地学景观探秘审美文化[M]. 重庆: 西南师范大学出版社, 2021.
- [8] 郑庆华, 董博, 钱步月, 等. 智慧教育研究现状与发展趋势[J]. 计算机研究与发展, 2019, 56(1): 209-224.
- [9] 刘洞波, 缪智文, 张碧, 等. 在线课程学习参与度影响因素分析与提升策略研究[J]. 科技资讯, 2019, 17(13): 98-99.
- [10] 杨杉. 在线课程学习参与度的提升策略研究[D]. 重庆: 西南大学, 2015.
- [11] 徐敏. 数据分析助力翻转课堂精准教学促进思维提升——以“文学批评”课程为例[J]. 中国大学教学, 2019(5): 60-65, 79.
- [12] 文海家, 王桂林, 杨海清, 等. 通识慕课建与用的思考和实践[M]. 川渝通识教育探索. 2019, (4), 79-86.
- [13] 温慧群, 穆肃. 殊途如何同归? ——不同复杂度混合教学实践效果的分析[J]. 中国远程教育, 2023(2): 64-72.

- [14] Lo C K, Hew K F. The impact of flipped classrooms on student achievement in engineering education: a meta-analysis of 10 years of research[J]. *Journal of Engineering Education*, 2019, 108(4): 523-546.
- [15] 文海家,王桂林,杨海清,等. 通识慕课混合教学全过程记录考核模式研究与实践——以“地学景观文化”为例[J]. *中国地质教育*, 2019, 28(3): 68-71.
- [16] Bredow C A, Roehling P V, Knorp A J, et al. To flip or not to flip? a meta-analysis of the efficacy of flipped learning in higher education[J]. *Review of Educational Research*, 2021, 91(6): 878-918.
- [17] Pardo A, Han F F, Ellis R A. Exploring the relation between self-regulation, online activities, and academic performance: a case study[C]//*Proceedings of the Sixth International Conference on Learning Analytics & Knowledge - LAK '16*. April 25-29, 2016. Edinburgh, United Kingdom. ACM, 2016: 422-429.
- [18] Gilboy M B, Heinerichs S, Pazzaglia G. Enhancing student engagement using the flipped classroom[J]. *Journal of Nutrition Education and Behavior*, 2015, 47(1): 109-114.
- [19] Sun Z R, Xie K, Anderman L H. The role of self-regulated learning in students' success in flipped undergraduate math courses[J]. *The Internet and Higher Education*, 2018(36): 41-53.
- [20] Al-Shabibi T S, Al-Ayasra M A. Effectiveness of the flipped classroom strategy in learning outcomes (bibliometric study) [J]. *International Journal of Learning, Teaching and Educational Research*, 2019, 18(3): 96-127.
- [21] van Alten D C D, Phielix C, Janssen J, et al. Effects of flipping the classroom on learning outcomes and satisfaction: a meta-analysis[J]. *Educational Research Review*, 2019(28): 100281.
- [22] 赵帅,黄晓婷,卢晓东. 情感指数对MOOC学生成绩的预测研究[J]. *中国大学教学*, 2019(5): 66-71.
- [23] 文海家,谢强,李英民. 土木建造类研究生学科交叉融合培养体系研究与实践[J]. *高等建筑教育*, 2023, 32(3): 100-106.
- [24] Sun Z R, Xie K. How do students prepare in the pre-class setting of a flipped undergraduate math course? A latent profile analysis of learning behavior and the impact of achievement goals [J]. *The Internet and Higher Education*, 2020(46): 100731.
- [25] Keller B. Variable selection for causal effect estimation: nonparametric conditional independence testing with random forests[J]. *Journal of Educational and Behavioral Statistics*, 2020, 45(2): 119-142.
- [26] Tan L, Main J B, Darolia R. Using random forest analysis to identify student demographic and high school-level factors that predict college engineering major choice[J]. *Journal of Engineering Education*, 2021, 110(3): 572-593.
- [27] Zhou X Z, Wen H J, Zhang Y L, et al. Landslide susceptibility mapping using hybrid random forest with GeoDetector and RFE for factor optimization[J]. *Geoscience Frontiers*, 2021, 12(5): 101211.
- [28] Zhang C, Wen H J, Liao M Y, et al. Study on machine learning models for building resilience evaluation in mountainous area: a case study of Banan district, Chongqing, China[J]. *Sensors*, 2022, 22(3): 1163.

Evaluation and improvement strategies for flipped blended teaching based on random forests

WEN Haijia, ZHANG Jialan, YANG Haiqing, WANG Guilin, XIE Qiang

(School of Civil Engineering, Chongqing University, Chongqing 400045, P. R. China)

Abstract: This paper explores a method for evaluating blended teaching effectiveness using machine learning. It constructs a blended teaching evaluation model with the random forest algorithm based on diverse data types and sources, including grades, behaviors, and emotions. Feature importance analysis is used to propose targeted strategies for teaching improvement. Using survey data from 376 students enrolled in the national top-level online course exploring geoscience landscapes: aesthetics and culture on Chinese University MOOC, the model is trained and validated. Results show that the optimized random forest model improves fit by 40%, reduces mean squared error by 7%, and achieves an R^2 of 0.92 when predicting student performance. Key factors influencing learning outcomes include participation, online-offline learning paths, mobile phone use, formative assessment, time investment, and sense of achievement. Based on these factors, targeted strategies for enhancing blended teaching effectiveness are proposed. The method provides references for optimizing blended teaching design, improving blended teaching quality, and promoting personalized education.

Key words: blended teaching; learner behavior; learning outcomes; random forest; improvement strategies

(责任编辑 梁远华)