

# 线上线下混合式教学中的学业预警研究

邓远杰, 赵胜利, 陈思瑞, 杨航

重庆理工大学, 重庆

收稿日期: 2026年4月15日; 录用日期: 2026年5月9日; 发布日期: 2026年5月18日

## 摘要

随着在线教学平台的普及和学习分析技术的发展, 教育大数据的应用在评估线上课程学习效果中日益凸显其重要性。本研究旨在识别影响线上课程学生学习效果的关键特征, 建立学习效果预测模型, 实现对线上课程学生学习效果的综合评价。在特征选择上, 本文利用相关系数变量选择、互信息变量选择、基于随机森林递归式变量选择、Lasso嵌入法和SHAP法这五种方法对特征进行选择分析, 最终利用TOPSIS综合筛选特征, 最终筛选出8个变量参与模型的预测, 综合五种方法使得我们能够全面、准确地识别出影响学习效果的关键特征。在预测模型构建上, 本文选取随机森林、LightGBM以及BP神经网络三种经典机器学习与深度学习模型, 对学生学习成绩进行量化预测, 并采用粒子群算法对各模型进行超参数优化, 提升模型拟合与泛化能力。为客观量化模型性能, 本研究选取均方误差与拟合优度作为核心评价指标, 通过对比分析三种模型的预测效果, 结果显示BP神经网络算法在均方误差、拟合优度及整体预测稳定性方面均表现最优。研究结果表明, 神经网络模型成功地评估了线上课程学生的学习效果, 其预测准确性和解释能力为在线教育的发展和个性化教学提供了重要的理论依据和实践指导, 可以帮助教育者识别出哪些教学资源和学习活动对学生的学习效果有显著影响, 从而能够进行更加有针对性的教学干预, 优化教学策略, 最终提高学生的学习成绩。

## 关键词

特征筛选, 机器学习, 深度学习

# Research on Academic Early Warning in Blended Online and Offline Teaching

Yuanjie Deng, Shengli Zhao, Sirui Chen, Hang Yang

Chongqing University of Technology, Chongqing

Received: April 15, 2026; accepted: May 9, 2026; published: May 18, 2026

## Abstract

With the widespread adoption of online teaching platforms and the advancement of learning analytics technology, the application of educational big data has increasingly highlighted its importance in assessing the learning outcomes of online courses. This study aims to identify key features influencing student performance in online courses, establish a predictive model for learning outcomes, and achieve a comprehensive evaluation of student learning effectiveness in online courses. In terms of feature selection, this paper employs five methods—correlation coefficient-based variable selection, mutual information-based variable selection, recursive feature elimination based on random forests, Lasso embedding, and SHAP—to analyze and select features. The TOPSIS method is then used for comprehensive feature screening, ultimately identifying eight variables for model prediction. By integrating these five approaches, we achieve a thorough and accurate identification of key features influencing learning outcomes. For predictive model construction, this study selects three classical machine learning and deep learning models—Random Forest, LightGBM, and BP neural networks—to quantify student academic performance. Particle swarm optimization is applied to fine-tune hyperparameters for each model, enhancing both fitting and generalization capabilities. To objectively evaluate model performance, mean squared error and coefficient of determination are chosen as core metrics. Comparative analysis of the three models' predictive effectiveness reveals that the BP neural network algorithm demonstrates superior performance in terms of mean squared error, coefficient of determination, and overall predictive stability. The research findings indicate that the neural network model successfully evaluated the learning outcomes of students in online courses. Its predictive accuracy and interpretative capabilities provide crucial theoretical foundations and practical guidance for the development of online education and personalized teaching. This model helps educators identify which teaching resources and learning activities significantly impact student performance, enabling more targeted instructional interventions, optimizing teaching strategies, and ultimately improving student academic achievement.

## Keywords

Feature Selection, Machine Learning, Deep Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 绪论

### 1.1. 研究背景及意义

互联网与教育信息化的发展推动了线上线下混合式教学的兴起，有效弥补了传统大班教学在个性化支持与学生互动方面的不足。该模式融合面授与在线学习优势，教师通过学习管理平台收集学习行为数据，精准把握学情；学生则可自主安排学习进程，提升参与度与主动性。教师依据数据反馈调整教学节奏与内容，实现更具弹性和互动性的教学，从而提高学习效率与质量。然而，在强调自主学习的背景下，部分学生因缺乏自我规划能力，容易出现学业滞后。为此，可引入机器学习与深度学习技术，构建学业预警模型。通过分析混合式教学过程中产生的学习数据，及早识别存在风险的学生，并为其提供针对性支持，以提升学业成功率和学习体验。

面对海量、复杂的学习行为数据，挖掘关键影响因素并建立科学的预警模型，对教学改革与教育信息化具有重要意义：对学生，有助于及时发现问题、调整学习策略；对教师，可精准定位教学瓶颈、优化

教学设计；对管理者，能为教育决策提供依据，推动混合式教学普及与教育质量整体提升。

## 1.2. 本文研究思路

本文共分为五个章节。第一章绪论，阐明线上课程学习效果评价的研究背景、意义、国内外现状及本文研究思路。第二章理论基础，明确定义学习效果，概述多种特征选择方法与三种预测模型的原理。第三章数据处理与分析，对线上教学数据进行清洗、描述性统计，并综合四种方法筛选关键特征，构建评价指标体系。第四章模型构建与对比，基于所选特征建立并优化预测模型，对比其性能，选用最优模型进行学习效果预测。第五章总结，概括研究成果。

## 1.3. 研究现状

国内的相关研究中有很多用综合评价方法对学生的整体学习情况进行评价。在学习行为分析上，赵慧琼[1]等对学习行为数据采用多元回归分析法进行分析，结合问卷调查等方式探究影响学习成绩的因素。马晓[2]等构建了人际、任务、内容和系统四个维度的行为特征，并基于这四个特征进行聚类，分析这些行为特征与学习效果的相关性。李华[3]等人将“线上 + 线下”混合学习模式应用与教学实践之中，基于三年的实践研究提出了以学习态度、学习方式、交流协作和学习效果为核心要素的学习者学习行为评估指标体系。宗阳[4]等从 MOOCs 在线学习出发构建了学习行为指标，应用逻辑回归分析学习行为对学习成绩的影响，发现提交作业测试可以作为 MOOCs 学习成绩预测的关键指标。在学习成绩预测上，郎波[5]等人使用平台上产生的学生日常学习数据为样本，选取了相关性最强的五种因素，通过 BP 神经网络对学生成绩进行预测，并与其他模型进行对比研究，结果表明该模型预测结果相对较好。Hussain [6]从学习者的在线学习数据中提取 30 学习特征，采用逻辑回归与决策树进行成绩预测，这些方法全面地考虑各种学习因素，提高预测准确性。

学术研究应用多种机器学习和深度学习方法预测学习效果，在算法、参数、特征与数据方面呈现多样性，提升了预测的准确性、稳定性和实用性。然而，仍面临数据时间跨度不合理、特征选择困难、模型泛化能力不足、难以适应复杂数据及模型选择难题，需进一步创新。

## 2. 相关理论基础概述

### 2.1. 线上课程学习效果预测原理

定义(学习效果预测)给定学生  $m$  的学习行为样本特征  $X_2 = \{x_{m1}, x_{m2}, x_{m3} \dots x_{mn}\}$  预测  $Y_m$ 。  $Y_m$  表示学生的课程总评类别标签，  $Y_m$  有 1 和 0 两个状态，分别表示学生  $m$  课程总评成绩合格(达到阈值)和不合格(达不到阈值) [7]。

### 2.2. 特征选择方法

#### 2.2.1. 相关系数法

相关系数法可刻画变量相关程度，筛选适配模型的特征，提升预测准确度。主要有皮尔森、肯德尔、斯皮尔曼三种：皮尔森适用于线性、正态分布的连续数据；肯德尔针对分类变量；斯皮尔曼基于等级计算，适用范围更广。斯皮尔曼的计算公式如下：

$$\rho_s = \frac{\sum_{i=1}^N (R_i - \bar{R})(S_i - \bar{S})}{\left[ \sum_{i=1}^N (R_i - \bar{R})^2 \sum_{i=1}^N (S_i - \bar{S})^2 \right]^{\frac{1}{2}}} \quad (1)$$

### 2.2.2. 互信息法

互信息衡量两随机变量间的相互依赖程度，反映其共享信息的多少。在特征选择中，它用于评估连续变量间的相关性：互信息值越高，表示变量依赖性越强；值越低则相关性越弱。其计算基于一个变量引入后另一变量不确定性的减少程度，常用于筛选信息量大的特征以提升模型性能，公式为：

$$I(X;Y) = \iint p(x,y) \log \frac{p(x,y)}{p(x)p(y)} dx dy \quad (2)$$

公式中  $p(x,y)$  是  $X$  与  $Y$  的联合密度函数， $p(x)$  与  $p(y)$  分别是  $x$  与  $y$  的密度函数。

### 2.2.3. 基于 Lasso 嵌入法

相比于包裹法和过滤法，嵌入法可以避免过拟合，降低模型复杂度，能够较好平衡准确性和计算成本。Lasso 的嵌入法是利用 Lasso 回归方法进行特征选择，将特征放入模型中，与模型训练过程合并在一起，然后通过目标函数中加入正则化实现特征选择。考虑特征选择和模型预测的损失函数，正则项能够让许多变量的系数为零，因此可以达到变量选择的结果。

### 2.2.4. SHAP 法

SHAP 基于合作博弈论的 Shapley 值，量化各特征对机器学习模型预测的贡献，是重要的模型解释方法。它可实现全局解释，明晰模型整体行为与特征重要性排序；也能完成局部解释，确定特征对单个预测的具体贡献，还可辅助模型诊断，识别偏见、过拟合等问题。

## 2.3. 线上课程学习效果预测模型

### 2.3.1. 随机森林模型

随机森林一种将重采样技术、随机生成模型两种方式进行结合的方式，重构出森林，Bagging 算法，该算法通过自助采样法从原始数据中有放回地抽取多个样本子集，并为每个子集独立训练一棵决策树。在树的生长过程中，节点根据最优特征进行划分，以追求更高的节点纯度，即该节点样本尽可能属于同一类别。最终，这片森林通过集体决策给出预测结果[8]。

### 2.3.2. LightGBM 模型

GBDT 是一种基于 Boosting 的集成学习算法，通过迭代构建一系列决策树，每棵树重点修正前一棵树的预测误差，从而逐步提升模型精度，尤其擅长处理回归问题。LightGBM 是其高效实现，核心原理相似，但通过多种优化策略显著提升了训练速度与内存效率，特别适用于大规模数据集，并在许多场景中展现出更优的预测性能。

### 2.3.3. BP 神经网络

BP 神经网络是一种常见的多层前馈网络，包含输入层、隐藏层和输出层。它通过误差反向传播算法，调整神经元间的连接权重，以学习输入与输出之间的映射关系。输入层：负责接收外部信号，该层神经元仅起到缓冲作用，不进行计算，直接将数据传递给下一层。隐藏层：位于输入层和输出层之间，可以有一层或多层，这是网络进行特征提取和非线性变换的核心区域，隐藏层越多，网络结构越深，理论上能拟合越复杂的函数关系。输出层：接收隐藏层的处理结果，并输出最终的预测值。

## 3. 混合式预警模型关键特征提取和行为分析

### 3.1. 数据来源

本文研究数据取自某高校超星平台与教务系统，为同一教师同学期不同班级的 365 条教学数据，含章节学习次数、成绩等 15 个变量。研究先预处理数据，提取预警模型关键特征并建模，再借助 SHAP 框

架分析影响学生学业的相关特征，以此构建学业预警模型助力学生完成学业。

### 3.2. 数据预处理

#### 3.2.1. 缺失值处理

该数据包含重修学生的学习行为数据，为保证数据的整体性，因此将重修学生的数据删除，对数据进行缺失值的判断，各变量的缺失比例如下表 1 所示。

Table 1. Variable missing proportion

表 1. 变量缺失比例

变量名称	缺失比例	变量名称	缺失比例
章节学习次数	0.0	视频观看时长	0.0
线上综合成绩	0.0	提交作业数	0.0
课堂签到情况	0.67	总讨论数	0.0
获赞数	0.0	课程音视频得分	0.0
作业得分	0.0	分组任务得分	0.67
高等数学 1	0.0	高等数学 2	0.0
线下平时作业成绩	0.0	视频观看反占比	0.0
卷面成绩	0.0		

由上表可以得到课堂签到情况和分组任务得分的缺失比例为 0.67，由于缺失比例过大，视频观看反占比等于视频观看时长除以所有视频总时长，这两个变量具有高度相关性，由于视频反占比能更好反映学生观看视频的比例，所以将特征变量视频观看时长删除，经过缺失值处理后，数据剩余量为 351 条，12 个特征。

#### 3.2.2. 异常值处理

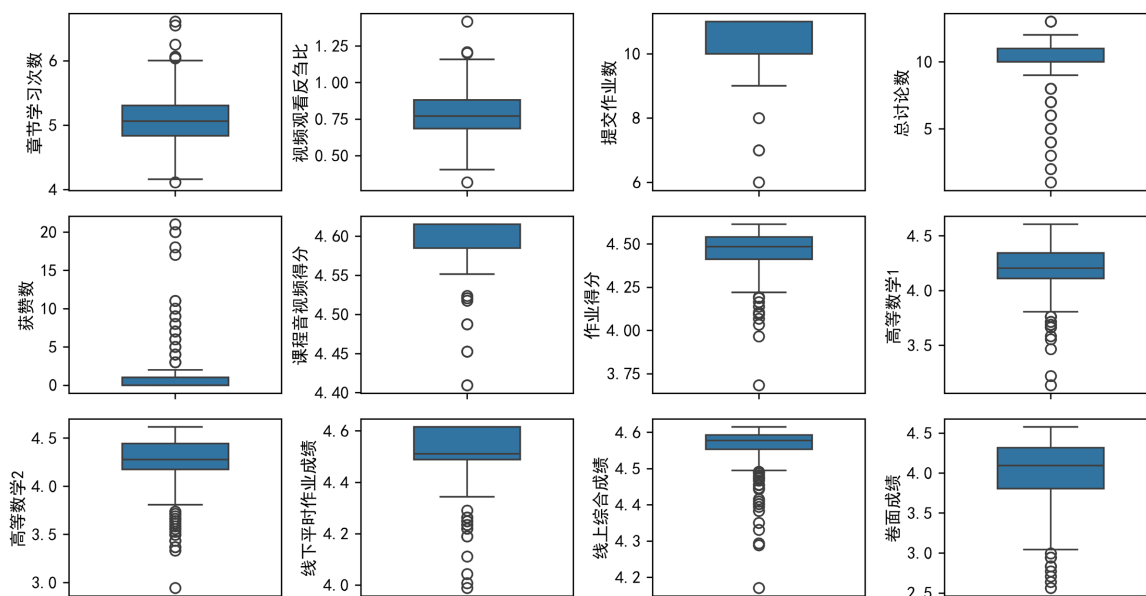


Figure 1. Outlier detection

图 1. 异常值检测

本研究对异常值的检测采用了箱线图的方式,使用箱线图对 12 个特征进行检测,检测结果如图 1 所示。

根据上述结果,除卷面成绩外,其余变量的箱线图外波动值均为真实有效数据,故保留,但针对视频观看反判比大于 5 的极端值,结合对应卷面成绩分析,判断为学生临时集中刷课行为所致,为降低该异常值对模型的影响,采用均值替换这些高反判比数据进行修正。

### 3.3. 混合式预警模型的关键特征提取

#### 3.3.1. 变量处理

对经过数据预处理之后的变量画出概率分布,通过观测变量的分布,以便于对这些变量有更好的处理,概率密度图如图 2 所示。

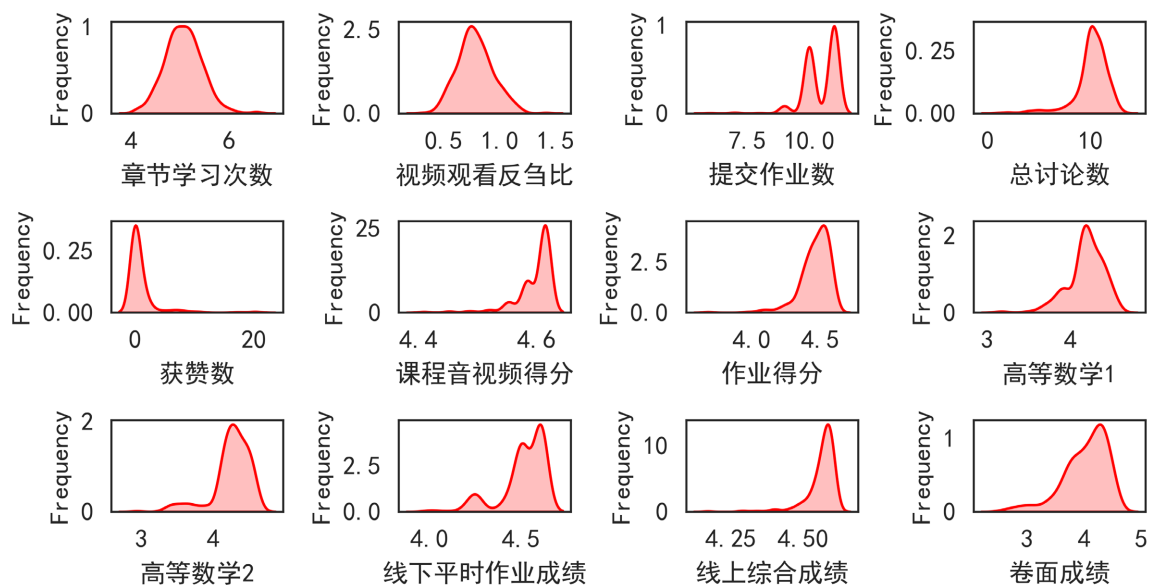


Figure 2. Data distribution diagram

图 2. 数据分布图

观察发现,提交作业数、总讨论数与获赞数为多峰分类变量。其余连续变量多呈右偏态,为提升后续建模的稳定性,将对这些右偏态数据实施对数变换,以使其分布更接近正态,让数据在更平滑的范围内分布。

#### 3.3.2. 变量筛选

本次数据集包含 12 个特征变量和 351 条数据,由于该数据量较少,变量过多,这增加了数据分析的复杂性,导致模型过拟合导致分析效果不佳,降维可以帮助简化数据,因此采用特征工程对变量进行筛选。

##### (1) 相关系数法

该数据集中包含分类变量,建立目标变量卷面成绩与其余连续变量采用斯皮尔曼相关系数,得到各变量的相关系数值如下表 2 所示。

根据相关系数分析,线下平时作业成绩与卷面成绩相关程度最高,呈现强烈正相关;高等数学 2 与高等数学 1 亦呈现较强正相关。其余变量相关性较弱,其中获赞数呈轻微负相关。

**Table 2.** Relevant coefficient values  
**表 2.** 相关系数值

变量名称	相关系数	变量名称	相关系数
章节学习次数	0.08	视频观看反刍比	0.07
线上综合成绩	0.05	提交作业数	0.07
获赞数	-0.01	总讨论数	0.0
作业得分	0.02	课程音视频得分	0.01
高等数学 1	0.26	线下平时作业成绩	0.78
高等数学 2	0.30		

(2) 互信息法

利用互信息法解释变量与目标变量卷面成绩之间的关联程度，互信息就是解释变量与被解释变量之间联合分布的熵与边缘分布熵的差。根据互信息法得到每个特征的互信息值如表 3 所示。

**Table 3.** Mutual information values of various variables  
**表 3.** 各变量互信息值

变量名称	相关系数	变量名称	相关系数
章节学习次数	0.08	视频观看反刍比	0.07
线上综合成绩	0.05	提交作业数	0.07
获赞数	0.01	总讨论数	0.0
作业得分	0.02	课程音视频得分	0.01
高等数学 1	0.26	线下平时作业成绩	0.78
高等数学 2	0.30		

根据互信息分析，线下平时成绩与卷面成绩的互信息值最高，表明两者共享信息最多，关联程度最强。高等数学 1 与高等数学 2 的互信息值显著高于其余变量，说明其对目标变量也有较强影响。其他变量的互信息值则相对较小。

(3) Lasso 回归嵌入法

Lasso 嵌入法特征选择与模型稀疏化功能，通过引入正则化项，在训练过程中将部分特征的系数压缩至零，从而实现特征筛选。各变量特征系数见表 4 所示。

**Table 4.** Characteristic coefficients of each variable  
**表 4.** 各变量特征系数

变量名称	特征系数	变量名称	特征系数
章节学习次数	0.0	视频观看反刍比	0.0
线上综合成绩	0.0	提交作业数	0.01
获赞数	-0.01	总讨论数	0.02
作业得分	0.0	课程音视频得分	0.0
高等数学 1	0.18	线下平时作业成绩	1.32
高等数学 2	0.28		

Lasso 回归结果显示, 5 个变量的特征系数为零, 表明这些变量对卷面成绩无影响。其余 6 个变量的系数非零, 其中线下平时作业成绩的系数最大, 对目标变量有显著正向影响。其他变量对卷面成绩的影响方向不一, 部分为正, 部分为负。

#### (4) SHAP 特征选择方法

SHAP 是一种基于博弈论 Shapley 值的模型解释方法, 可量化每个特征对单个预测及整体模型的贡献度, 各变量 SHAP 值见表 5 所示。

**Table 5.** SHAP values of various variables

**表 5.** 各变量 shap 值

变量名称	SHAP 值	排序	变量名称	SHAP 值	排序
章节学习次数	0.011	8	视频观看反刍比	0.010	9
线上综合成绩	0.016	5	提交作业数	0.023	4
获赞数	0.001	11	总讨论数	0.015	6
作业得分	0.012	7	课程音视频得分	0.002	10
高等数学 1	0.032	3	线下平时作业成绩	0.223	1
高等数学 2	0.033	2			

根据 SHAP 值分析, 各特征对学业成绩的影响程度差异显著。线下平时作业成绩的 SHAP 值最高, 是影响成绩的最主要因素; 高等数学 1 和高等数学 2 的相关特征贡献度次之; 课程音视频得分、获赞数等特征的 SHAP 绝对值接近零, 表明它们对学业成绩的直接影响非常有限。

#### (5) 特征选择综合处理


本研究综合了相关系数、互信息、Lasso 回归系数、以及 SHAP 值四种方法, 并运用 Topsis 法进行多准则综合评价, 计算出各特征的综合得分指数。如下表 6 所示。

**Table 6.** Comprehensive score index of variables

**表 6.** 变量综合得分指数

变量名称	综合得分指数	排序	变量名称	综合得分指数	排序
章节学习次数	0.057	7	视频观看反刍比	0.056	8
线上综合成绩	0.060	5	提交作业数	0.068	4
获赞数	0.016	11	总讨论数	0.055	9
作业得分	0.058	6	课程音视频得分	0.046	10
高等数学 1	0.163	3	线下平时作业成绩	1.000	1
高等数学 2	0.193	2			

利用 Topsis 方法得到各个变量的综合得分指数, 根据得到的变量排序, 将这些变量输入到机器学习模型中进行训练和验证, 选取拟合优度最高时的变量数量。将数据以 3:1 的比例划分为训练集和测试集, 将经过 Topsis 排序后的特征从后依次删减应用到随机森林模型当中, 以拟合优度作为模型的评价指标, 预测结果如下图 3 所示。



**Figure 3.** Scatter plot of goodness of fit based on the number of features in a random forest  
**图 3.** 基于随机森林各特征数量拟合优度散点图


通过随机森林模型的拟合优度分析, 确定当特征数量为 8 时, 模型性能最优。因此, 最终删除了获赞数、课程音视频得分和总讨论数这三个特征。保留的八个特征, 高数成绩(2)、高数成绩(1)、线下平时作业成绩、视频观看反刊比、章节学习次数、视频观看时长、提交作业数及线上综合成绩。

#### 4. 混合式教学预警模型建立

在建立模型之前, 需要划分测试集以及训练集, 训练集与测试集划分比例为 3:1, 本文用不同的方法对学生学习成绩预测建立随机森林、LightGBM 和 BP 神经网络, 其中有这三种模型对学生成绩预测有较好的预测效果, 以均方误差最小作为模型优化目标。

##### 4.1. 随机森林模型

在随机森林模型中也有 3 个较为重要的参数: 树的数量(`n_estimators`)、最大特征数(`max_features`)以及树的最大深度(`max_depth`)。本研究首先使用默认参数进行成绩预测, 随后通过粒子群算法优化这些参数, 并基于优化后的模型重新进行预测, 以评估调参效果。初始模型的预测结果展示如图 4 所示。



**Figure 4.** Comparison of initial model predictions for random forest  
**图 4.** 随机森林初始模型预测对比图


上图是默认参数值下的随机森林模型对学生成绩的预测值与真实值对比图, 预测值也可以接近真实

值，所以随机森林模型对学生成绩的预测效果很好。利用粒子群算法寻求参数最优的训练器，对随机森林的调参过程见表 7 所示。

**Table 7.** Random forest parameter adjustment process and results  
**表 7.** 随机森林调参过程及结果

参数名称	上界值	下界值	调参结果
n_estimators	300	50	154
max_depth	20	1	14
max_feaures	20	3	17

在优化过程中，通过粒子群算法将随机森林的关键参数调整为  $n\_estimators = 154$ ,  $max\_features = 17$ ,  $max\_depth = 14$ 。模型经调参后精度得到有效提升，其学生成绩的预测值与真实值的对比情况如图 5 折线图所示。



**Figure 5.** Model prediction after random forest parameter optimization  
**图 5.** 随机森林参数调优后模型预测图

为了更直观评判两个模型的好坏，将初始模型与调优后的模型的均方误差和拟合优度做对比，如表 8 示。


**Table 8.** Evaluation criteria for random forest model  
**表 8.** 随机森林模型评判指标

模型名称	MSE	$R^2$
RFR	0.031	0.75
PSO_RFR	0.025	0.78

调参后，随机森林模型的均方误差从 0.031 降至 0.025，拟合优度从 0.75 提升至 0.78。尽管度提升幅度有限，但模型运行效率显著下降，消耗时间大幅增加。

## 4.2. LightGBM 模型

在 LightGBM 模型中也 4 个较为重要的参数：树的数量( $n\_estimators$ )、决策树深度( $max\_depth$ )、最小样本约束  $min\_child\_weight$ 、学习率( $learning\_rate$ )，LightGBM 初始模型的结果预测图如图 6 所示。




**Figure 6.** Comparison of initial model predictions for LightGBM  
**图 6.** LightGBM 初始模型预测对比图

上图是默认参数下的 LightGBM 模型对学生成绩的预测值与真实值对比图，预测值接近真实值，所以 LightGBM 模型对学生成绩的预测效果较好。对 LightGBM 模型的调参过程见表 9 所示。

**Table 9.** Parameter tuning process and results  
**表 9.** 调参过程及结果

参数名称	上界值	下界值	调参结果
n_estimators	300	50	158
max_depth	20	1	3
learning_rate	0.3	0.01	0.075
min_child_samples	20	1	10

利用粒子群最终模型各参数的值为： $n\_estimators = 158$ ， $max\_depth = 3$ ， $learning\_rate = 0.075$ ， $min\_child\_samples = 10$ 。通过参数调整后，LightGBM 模型对学生成绩预测图 7 所示。



**Figure 7.** Prediction of LightGBM model after parameter tuning  
**图 7.** LightGBM 参数调优后模型预测图

上图展示了经过参数调优后的模型预测结果,从图中可以看出,学生成绩预测值与真实值高度一致,表明模型的整体预测精度有所提升,均方误差和拟合优度见表 10 所示。

**Table 10.** Evaluation criteria for LightGBM model


**表 10.** LightGBM 模型评判指标

模型名称	MSE	R <sup>2</sup>
LGB	0.028	0.76
PSO_LGB	0.025	0.78

调参后, LightGBM 模型的均方误差从 0.028 降至 0.025, 拟合优度从 0.76 提升至 0.78。尽管提升幅度有限, 但模型运行效率显著下降, 消耗时间大幅增加。

### 4.3. BP 神经网络

在全连接层中, 通过一系列权重和偏置的线性变换以及非线性激活函数的运用, 模型能够将输入层提取的初步特征进一步映射和转换, 从而提取出更为抽象和高级的特征表示。神经网络模型的结果预测图如图 8 所示。



**Figure 8.** BP neural network model prediction diagram

**图 8.** BP 神经网络模型预测图

上图是默认参数值下的 BP 模型对学生成绩的预测值与真实值对比图, 预测值也可以接近真实值, 所以 BP 模型对学生成绩的预测效果较好。神经网络模型评价指标见表 11 所示。

**Table 11.** Evaluation criteria for BP neural network model

**表 11.** BP 神经网络模型评判指标

模型名称	MSE	R <sup>2</sup>
BP	0.024	0.81

上表可以得到 BP 模型的均方误差为 0.024, 拟合优度为 0.979, 当拟合优度接近 1 时, 代表着模型拟合效果好, 说明神经网络模型对学生成绩预测结果比较精准。

#### 4.4. 结果对比

为预测学生成绩，构建了三种不同的预测模型，并采用均方误差 MSE 和拟合优度作为评估指标，用于衡量各模型的预测性能优劣。如下表 12 所示。

**Table 12.** Model evaluation indicators  
**表 12.** 各模型评判指标

模型名称	MSE	R <sup>2</sup>
RFR	0.031	0.75
PSO_RFR	0.025	0.78
LGB	0.028	0.76
PSO_LGB	0.025	0.78
BP	0.024	0.81

根据上表的模型对比结果可知，神经网络的拟合优度为 0.81，但整体来看，模型的拟合度都接近 0.8，可以得到通过参数调优后的模型，模型拟合度都有所提高，但通过参数调优后的模型在运行速度上有所下降。

#### 5. 总结

本研究基于某高校超星平台与教务系统数据，构建线上课程学习效果预测模型。首先，采用缺失值填充与异常值处理完成数据预处理。进而，综合运用 Pearson 相关系数、互信息、Lasso 回归、及 SHAP 四种方法，并借助 TOPSIS 法进行多准则评估，最终筛选出 8 个核心学习行为特征。在此基础上，构建并比较了随机森林、LightGBM、及 BP 神经网络三种预测模型。实验结果表明，BP 神经网络的预测性能最优，其拟合优度达到 0.81，均方误差为 0.024，展现出最强的泛化能力。

#### 基金项目

重庆理工大学本科一流课程项目(数学建模技巧, 重理工发(2023) 69 号)。

项目名称: 线上线下混合式教学中的学习预警研究——基于深度学习方法; 项目编号: gzlcx20243282。

#### 参考文献

- [1] 赵慧琼, 姜强, 赵蔚, 等. 基于大数据学习分析的在线学习绩效预警因素及干预对策的实证研究[J]. 电化教育研究, 2017, 38(1): 62-69.
- [2] 马晓, 曲建华, 徐慧敏. 交互视角下网络学习行为特征挖掘[J]. 山东师范大学学报(自然科学版), 2021, 36(3): 282-290.
- [3] 李华, 魏一通. 混合式教学中学生学习行为评估体系构建与应用研究[J]. 中国电化教育, 2020(10): 58-66.
- [4] 宗阳, 孙洪涛, 张亨国, 郑勤华, 陈丽. MOOCs 学习行为与学习效果的逻辑回归分析[J]. 中国远程教育, 2016(5): 14-22+79.
- [5] 郎波, 樊一娜. 利用学习向量化样本分类的在线学习成绩预测[J]. 计算机系统应用, 2019, 28(3): 215-222.
- [6] Hussain, S. and Khan, M.Q. (2021) Student-Performer: Predicting Students' Academic Performance at Secondary and Intermediate Level Using Machine Learning. *Annals of Data Science*, **10**, 637-655.  
<https://doi.org/10.1007/s40745-021-00341-0>
- [7] 章刘. 混合式学习行为分析与学习预警算法研究及应用[D]: [硕士学位论文]. 南京: 南京信息工程大学, 2024.
- [8] 赵翊含, 侯蒙京, 冯琦胜, 高宏元, 梁天刚, 贺金生, 钱大文. 基于 Landsat8 和随机森林的青海门源天然草地上生物量遥感估算[J]. 草业学报, 2022, 31(7): 1-14.