

基于人工智能的学生学业动态预警与精准干预模型构建研究

陈光田¹, 吴瑞亮^{1*}, 吴佳敏¹, 肖世校¹, 洪成蹊²

¹集美大学诚毅学院教务部, 福建 厦门

²集美大学诚毅学院数学与数字科学系, 福建 厦门

收稿日期: 2026年8月21日; 录用日期: 2026年10月5日; 发布日期: 2026年10月12日

摘要

高校预警工作已成为提升人才培养质量的关键举措, 其核心目标是从简单的管理向促进学生发展的方向转变。当前, 各高校在实践中存在预警的滞后与标准单一、帮扶措施不够精准等问题。本文以多源时序数据为基础, 通过特征提取与机器学习实现风险分级, 形成“监测-预警-干预-反馈-优化”的闭环。研本文进一步提出数据治理、试点调优和制度固化的实施路径, 为独立学院提升学业支持的前瞻性、精准性和协同性提供参考。

关键词

人工智能, 学业预警, 数据治理, 精准干预

Research on the Construction of an Artificial Intelligence-Based Dynamic Early Warning and Precise Intervention Model for Student Academic Performance

Guangtian Chen¹, Ruiliang Wu^{1*}, Jiamin Wu¹, Shixiao Xiao¹, Chengxi Hong²

¹Academic Affairs Department, Chengyi College, Jimei University, Xiamen Fujian

²Mathematics & Digital Science School, Chengyi College, Jimei University, Xiamen Fujian

Received: August 21, 2026; accepted: October 5, 2026; published: October 12, 2026

*通讯作者。

文章引用: 陈光田, 吴瑞亮, 吴佳敏, 肖世校, 洪成蹊. 基于人工智能的学生学业动态预警与精准干预模型构建研究[J]. 职业教育发展, 2026, 15(10): 181-190. DOI: 10.12677/ve.2026.1510426

Abstract

Early warning systems in higher education have become essential to improving talent development, with their focus shifting from administrative control to student development. However, current practices often suffer from delayed warnings, uniform criteria, and insufficiently targeted support. Using multi-source time-series data, this study integrates feature extraction and machine learning to classify academic risk and establishes a closed loop of “monitoring—warning—intervention—feedback—optimization.” It further proposes an implementation framework encompassing data governance, pilot-based refinement, and institutionalization, offering a reference for independent colleges to enhance the proactiveness, precision, and coordination of academic support.

Keywords

Artificial Intelligence, Academic Early Warning, Data Governance, Precise Intervention

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. 引言

1.1. 研究背景与意义

随着人工智能与教育数字化的发展，高校学业管理具备了由结果判断转向过程识别的技术条件。传统学业预警多开展于在期末成绩或不及格学分达到阈值后，难以及时反映学习行为的连续变化。多源学习数据、预测模型与干预机制的结合可以推动教育管理由“经验驱动”转向“数据驱动”[1]，并实现可持续监测、及时支持和动态调整的工作机制。

1.2. 国内外研究现状评述

1.2.1. 学习分析与学业过程监测研究

学习分析研究逐渐由学业结果评价转向学习过程监测。已有研究将学业成就与学业风险的预测指标划分为倾向性指标、人机交互指标和人际交互指标，其中涉及既往学业表现、初始知识、学习驱动力、学习行为及学习互动等信息[2]。相关国外学习预警研究主要集中于预警指标甄选、预警起始时间探测和预警模型效果评价，并提出应进一步关注学习过程动态指标，以提高风险识别的及时性[3]。课堂学习投入智能测量研究进一步将数据来源扩展至多模态学习行为，但在复杂学习状态表征、多模态特征融合和模型可解释性等方面仍存在不足[4]。

现有学习分析研究表明，过程性学习行为能够为学业风险识别提供比单一结果指标更加丰富的信息，但不同来源学习数据的融合以及学习状态连续变化的刻画仍有进一步研究空间。

1.2.2. 教育数据挖掘与学业风险识别研究

教育数据挖掘已广泛应用于学业表现分析和风险识别。有研究以大学生在校成绩为主要数据，通过关联规则分析不同不及格课程之间的联系，据此开展课程不及格和留级风险预警[5]。此类方法具有规则清晰、易于解释的特点，但主要依赖已经发生的成绩结果。

随着数据来源扩展，学业预测逐渐由单一成绩数据向多维教育数据发展。在数据处理方法上，有研

研究提出熵估计方法进行特征构造或风险度量[6], 本文借鉴了其多维教育数据处理的理论方法。有研究从社会及人口统计特征、学校环境、个人特征和学生投入四个维度构建学业表现分析框架, 并采用决策树、贝叶斯网络、人工神经网络和支持向量机进行分类预测[7]。另有研究将校园行为数据用于学业预警, 通过数据预处理、特征提取和不同算法建立学生行为特征与学业风险之间的关系[8]。

现有教育数据挖掘研究已由成绩关联规则逐步发展到多维特征分类, 但部分研究仍以静态数据和一次性预测为主, 对风险特征随学习过程发生的连续变化关注不足[5] [7] [8]。

1.2.3. 机器学习在学业预警中的应用研究

机器学习已成为学业预警的重要技术路径。早期研究利用遗传算法和 BP 神经网络建立高校学业预警模型, 通过历史数据预测学生未来学业状态[9]。此后, 集成学习逐渐应用于学业风险预测, 有研究将关联规则与随机森林结合, 在分析课程关联关系的同时对学生学业状况进行动态监测和风险识别[10]。

针对传统预警模型数据来源单一、学习行为静态等问题, 有研究整合多个数据平台, 利用深度学习建立学业预测模型, 以提高学业监测的实时性和动态性[11]。近年来, 图神经网络进一步被用于处理学业预测中的多源异构数据、时序变化及关系信息, 但相关研究仍面临模型可解释性、多模态融合及可扩展性等问题[12]。

由此可见, 学业预警算法已形成由 BP 神经网络、传统分类算法向随机森林、深度学习和图神经网络发展的技术路线[9]-[12]。但模型复杂度提高的同时, 风险成因解释和实际应用仍是需要解决的问题。

1.2.4. 现有研究不足与本文研究贡献

综合已有研究, 当前学业预警主要存在以下不足: 一是部分研究仍主要使用成绩、不及格课程等静态结果数据[5], 虽然逐渐引入学生投入、校园行为和平台数据[7] [8] [11], 但多源数据的时序变化利用仍不充分; 二是预测算法已从传统分类和神经网络发展至随机森林、深度学习和图神经网络[9]-[12], 但复杂模型的可解释性仍有不足[4] [12]; 三是已有研究较多关注风险识别和预测性能, 对风险成因解释以及预警结果与后续教育干预之间的衔接关注不足[3]。

针对上述问题, 本文主要从三个方面进行拓展: 第一, 构建多源时序动态预警机制。整合教务、课堂、作业和在线学习数据, 将学生基础属性与出勤变化、作业延迟、在线活跃度等动态行为特征结合, 实现由静态结果预警向学习过程动态监测转变。第二, 构建兼顾风险识别与风险解释的机器学习模型。采用 XGBoost 进行风险分类, 在输出风险等级的同时保留主要风险影响因素, 为教师人工复核和风险归因提供依据。第三, 建立预警与精准干预闭环。根据风险等级匹配相应的干预主体和干预方式, 并将干预结果反馈至模型, 形成“监测 - 预警 - 人工研判 - 精准干预 - 反馈 - 优化”的运行机制。

1.3. 研究内容、方法与框架

本文围绕“数据 - 识别 - 干预 - 反馈”展开: 第一, 整合教务、课堂、在线学习和学生工作等多源时序数据, 形成动态学业数据体系; 第二, 通过特征工程提取出勤变化、作业延迟、在线活跃度等风险信号, 并利用机器学习进行风险分级; 第三, 建立风险等级与干预主体、干预方式之间的匹配机制; 第四, 以干预结果作为反馈数据, 持续修正预警规则与策略。

2. 理论基础

教育数据挖掘(EDM)是以数据处理、特征识别以及预测分析为理论基础的研究方法。借助高效的数据挖掘手段, 对复杂教育数据进行量化分析, 及时把握隐藏的学习行为特征与内在逻辑规律。

学习分析(LA)将传统单纯以“预测结果”的学习分析转变为对学生学习过程及其学习情境的深入理

解与分析, 从对数据的简单预测转变为对数据的深入解读, 并进一步将分析结果与教学支持相衔接。该理论为我们对学业风险的解读和下一步的干预策略提供了相应的教育视角和理论依据。

预警管理理论关注风险从出现到处置的全过程。借助其对风险的全过程的监测、识别、诊断及预控, 借助将其巧妙的引入到学业的预警机制中, 不仅可以为风险等级的划分提供清晰的管理逻辑, 也为其预警触发条件设置以及后续处置流程的设计都提供了依据。

人本主义教育理论则强调学生在教育过程中的主体地位, 更好地体现了对学生的尊严和对人的价值的充分的尊重和发掘。将其与实际的师生沟通、对学生持之以恒的引导等多方面的措施相结合, 达到提升学习效率, 使学生学有所成。

上述四类理论回应了“如何从数据中识别规律”“如何理解学生学习过程”“如何开展风险处置”以及“技术最终应服务于何种教育目标”等现实问题, 由此构成从技术分析到教育治理相互衔接的理论闭环。

3. 独立院校学业预警现状分析与 AI 应用可行性

3.1. 独立院校学业预警工作现状及问题诊断

目前, 独立院校的学业预警工容易出现预警时间滞后、风险原因难以准确判断以及干预方式较为粗放等问题。从实际运行情况来看, 不少预警往往是在学生已经出现明显学业困难甚至学业失败之后才被触发。此时问题已经积累到一定程度, 可供开展帮扶的时间与空间较为有限, 不仅增加了后续问题解决的难度, 也可能进一步加重学生学业压力, 产生无助感和挫败感, 并可能伴随焦虑、厌学等心理问题[13]。

3.2. 构建 AI 赋能学业预警系统的必要性和可行性

构建 AI 赋能的学业预警系统具有明确的必要性和充分的可行性。其必要性在于该系统能通过对学习过程数据的实时分析, 实现从滞后预警到早期精准干预的转变, 有效提升学生毕业率与就业质量; 同时, 它可将管理者从繁琐的事务中解放出来, 实现精细化管理与决策科学化。建设 AI 学业预警系统的主要作用, 是从学习过程数据中提前发现异常变化, 使干预时间前移。学院现有教务、学工和在线学习平台已积累一定数据, 机器学习工具也具备应用条件。

4. AI 驱动的动态预警与精准干预模型构建

4.1. 总体设计与原则

本文按照“数据采集 - 风险识别 - 人工研判 - 干预反馈”运行。通过整合多源数据实现系统性评估, 依托实时更新确保动态跟踪, 基于算法模型实现早期预测, 建立从预警评估的完整闭环, 最终形成人机优势互补的协同机制, 为学业质量提升提供智能化支撑[14]。

4.2. “数据层 - 算法层 - 应用层”三层架构

数据层汇集教务、课堂和在线学习信息。入学成绩、专业等作为相对稳定特征, 出勤、作业提交和在线活跃度作为动态特征。数据完成清洗、标准化、脱敏和权限控制后进入模型。

算法层从动态数据中提取出勤下降、作业延迟增多、活跃度降低等信号, 并比较随机森林、XGBoost 等分类模型。XGBoost 通过迭代修正残差提高分类效果[15]。

输出包括风险等级和主要风险特征, 供教师复核。模型输出高、中、低风险等级, 同时保留主要风险特征, 便于后续人工解释和处置。数据模型算法示意图如图 1 所示。




Figure 1. Schematic diagram of the principle and iterative process of the XGBoost algorithm

图 1. XGBoost 算法原理与迭代过程示意图

应用层根据风险等级安排不同支持。高风险学生由辅导员、导师等联合研判, 必要时联系家长; 中风险由学业导师和任课教师跟进; 低风险以提醒和资源推荐为主。干预时间、措施和结果均留档, 并反馈至模型。由此, 系统不以算法直接替代教育判断, 而是形成“机器识别 - 人工研判 - 精准支持 - 效果反馈”的协同机制。

4.3. 风险特征构造与量化方法

为提高风险特征的可计算性和可复现性, 本文将原始学习行为数据进一步转换为水平、变化趋势和异常程度三类衍生特征。设学生 i 在第 t 个观测周期的某项学习行为指标为 $x_{i,t}$, 则其近期变化率可表示为:

$$\Delta x_{i,t} = \frac{x_{i,t} - x_{i,t-k}}{|x_{i,t-k}| + \varepsilon} \quad (1)$$

其中, k 为比较窗口长度, ε 为防止分母为 0 而设置的极小常数。当指标为正向学习行为时, 持续下降意味着潜在风险增加。

对课堂出勤, 可定义学生在窗口期内的缺勤率:

$$A_{i,t} = \frac{N_{i,t}^{absence}}{N_{i,t}^{class}} \quad (2)$$

其中, $N_{i,t}^{assignment}$ 为缺勤次数, $N_{i,t}^{class}$ 为应出勤课程次数。

对作业行为, 可定义延迟提交率:

$$D_{i,t} = \frac{N_{i,t}^{late}}{N_{i,t}^{assignment}} \quad (3)$$

并进一步计算连续若干周的变化趋势, 以识别偶发性迟交与持续性学习投入下降之间的差异。

对在线学习行为, 可根据登录频次、学习时长、资源访问次数等构造标准化活跃度指数:

$$L_{i,t} = \sum_{j=1}^m w_j z_{ijt}$$

(4)

其中， z_{ijt} 为标准化后的第 j 项在线行为指标， w_j 为相应权重。实际建模时可将各标准化行为变量直接输入 XGBoost，由模型学习其非线性贡献，从而减少人为赋权产生的主观偏差。

此外，对于成绩变化，可构造近期成绩下降幅度、连续不及格次数、GPA 变化率等指标。通过上述处理，将单一时间点的静态指标转换为能够反映学习状态变化方向与变化速度的时序风险特征。数据来源与数据处理的结构示意图如图 2 所示。




Figure 2. Feature engineering and risk feature system diagram for multi-source time series data
图 2. 多源时序数据特征工程与风险特征体系图

4.4. XGBoost 模型选择依据与超参数优化

本文选择 XGBoost 作为核心风险识别算法，主要基于以下三点考量。在模型的适应性方面，学生学业风险通常由成绩、出勤、作业、在线学习行为等多因素共同作用形成，变量之间可能存在明显的非线性关系和交互效应。XGBoost 基于梯度提升树逐轮拟合前序模型残差，能够有效捕捉此类复杂关系。在数据方面，本文的数据属于典型的结构化教育管理数据，既包含相对稳定的学生属性，也包含持续变化的学习行为特征，树模型对不同尺度变量具有较好的适应性。学业预警存在风险学生比例往往低于正常学生，使得数据存在类别不平衡问题，XGBoost 可通过样本权重等方式降低类别不平衡对模型训练的影响。再结论方面，XGBoost 能够输出特征重要性，并可结合 SHAP 等方法形成个体层面的风险因素解释，这与本文“机器识别 - 人工研判”的应用模式具有较高一致性。

在超参数优化方面，首先按照时间顺序划分训练集、验证集和测试集，避免未来学期信息进入历史训练数据而形成数据泄漏。在训练集内部采用交叉验证或滚动时间窗验证方式，对 `n_estimators`、`max_depth`、`learning_rate`、`min_child_weight`、`subsample`、`colsample_bytree` 以及正则化参数等进行搜索。初始阶段采用较宽参数范围进行随机搜索或网格搜索，再围绕性能较优区域进行精细搜索。

4.5. 风险概率校准与预警阈值确定

XGBoost 输出学生发生学业风险的预测概率 p_i 。预警阈值的设置并非依据经验任意确定，而是在验

证集上综合模型识别能力、误报成本、漏报成本和学院实际干预资源确定。

对二分类风险识别，可首先基于 ROC 曲线计算 Youden 指数：

$$J(c) = \text{Sensitivity}(c) + \text{Specificity}(c) - 1$$

并将使 $J(c)$ 最大的阈值作为候选阈值。同时，由于学业预警更强调避免遗漏真正需要帮助的学生，还应结合 Precision-Recall 曲线，在保证高风险学生召回率达到预设要求的前提下选择具有较高 Precision 的阈值。

对高、中、低三级预警，可进一步设置两个核心边界 T_1 和 T_2 ：当 $p_i < T_1$ 时划为低风险；当 $T_1 < p_i < T_2$ 时划为中风险；当 $p_i > T_2$ 时划为高风险。阈值最终应结合漏报与误报的实际成本进行确定。由于漏报高风险学生可能造成错过最佳干预窗口，其成本通常高于一般误报，因此高风险阈值的选择应优先保证 Recall，再兼顾 Precision。


此外，学院能够提供的辅导员、导师和教师干预资源也是阈值确定的重要约束。当模型预测的高风险学生数量超过实际干预容量时，应在保证基本召回率的基础上，通过验证集重新校准阈值。阈值应随学期、专业和学生群体变化进行周期性检验，而不宜永久固定。

5. 以独立学院为案例的模型实施构想与挑战

5.1. 实施路径规划

本文以独立学院为具体研究对象，结合学业预警模型的应用条件，将模型实施过程划分为以下四个阶段。

在数据治理与平台建设阶段，学院需要逐步打通教务系统、学工系统和在线学习平台之间的数据接口，对指标口径、数据格式和使用权限进行统一规范。完成学业预警引擎的初步搭建，开发面向管理人员的可视化功能，为后续模型运行和预警处置提供平台支撑。



图注：图中 0.15、0.35 和 0.65 为模型运行机制的示意性阈值，实际应用阈值应依据验证集 ROC/PR 分析、漏报与误报成本以及学院干预资源综合确定。

Figure 3. Example of dynamic changes in risk probability and early warning triggering for typical students

图 3. 典型学生风险概率动态变化与预警触发示例图

在小范围试点阶段，可选择一个专业或某一年级为试点对象，通过限定应用范围观察模型的实际运行情况。该阶段主要考察模型风险识别的准确程度、预警时间前移情况，同时关注干预流程在实际工作中的可执行性以及师生的接受情况。图 3 为示例学生在模型中干预前后的风险概率变化情况。

在模型调优与人工复核阶段，应结合试点运行结果以及师生反馈，对模型所使用的特征、算法参数和预警阈值进行适当调整。同时进一步完善人工复核环节，对模型产生的风险结果进行必要校验，以降低误判带来的影响，并提升预警结果的可靠性和解释性。图 4 为某高风险学生个体的风险因素识别及预测得分。




Figure 4. Explanation of predictive influencing factors for high-risk student individuals (example)
图 4. 高风险学生个体(示例)预测影响因素解释

在推广应用与制度固化阶段，若前期试点基本达到预期效果，可结合学院实际情况逐步扩大模型的应用范围。教务管理部门还应将数据更新、预警处置、人工复核、效果评价以及相关责任分工纳入日常教育管理流程，使学业预警由阶段性项目逐步转变为较为稳定的管理机制。

5.2. 伦理风险及治理机制

AI 学业预警系统处理学生成绩、出勤、在线学习行为等具有较强个人属性的数据，其应用不能仅以提高预测准确率为目标，还应遵循必要性、比例性、公平性和可解释性原则。

在数据隐私方面，应坚持“最小必要”原则，仅采集与学业风险识别具有明确关联的数据，并明确数据保存期限、访问权限和使用范围。对进入建模流程的数据进行去标识化处理，对教师、辅导员、管理人员实施基于角色的分级授权，同时建立数据访问日志和异常访问审计机制。未经充分论证，不应将与学业支持目标缺乏直接关联的敏感信息纳入风险模型。

在算法公平性方面，应关注模型是否因专业、年级或其他群体特征产生系统性误判。在模型上线前及运行过程中，可分别计算不同群体的 Recall、False Positive Rate 等指标。当不同群体之间出现持续且明显的性能差异时，应进一步检查训练样本代表性、变量选择及模型参数，并通过重新采样、特征调整或阈值校准等方式降低算法偏差。

在透明度方面，应避免将风险评分作为缺乏解释的“黑箱结论”。系统向教师呈现预警结果时，应

同时提供主要风险因素、近期变化趋势及模型置信信息；向学生开展干预时，则应明确说明预警的目的在于提供学业支持，而非进行惩罚性评价。模型预测结果原则上不应直接用于奖惩、处分等高影响决策。

建立相应的伦理治理与救济机制。学院可成立由教务、学工、信息技术、教师代表、伦理或法律相关人员以及必要的学生代表组成的 AI 教育应用伦理审查委员会，对数据范围、模型用途、算法更新和重大风险事件进行定期审查。同时为学生提供查询、更正和申诉渠道。当学生认为预警结果与实际情况明显不符时，可申请人工复核，由辅导员或学业导师结合真实学习情境作出最终判断。由此形成“算法预测 - 人工解释 - 学生反馈 - 复核纠偏”的治理闭环。

5.3. 真实环境中的实施挑战与推广策略

在实际实施过程中主要面临组织、文化和资源三个方面的挑战。

组织协同挑战。学业预警涉及教务、学工、院系、任课教师和信息技术等多个主体，不同部门的数据标准、工作目标和责任边界可能存在差异。为此，应建立跨部门学业预警工作小组，明确数据维护、模型运行、人工复核、学生沟通、干预实施和效果评价的责任主体，并通过标准操作流程(SOP)规定从预警产生到完成干预的处理时限。

文化接受挑战。教师和学生可能对算法预警产生两类相反倾向：一是过度依赖算法，将风险概率等等同于事实判断；二是对算法持排斥态度，认为技术增加管理负担或形成对学生的标签化。对此，应在推广过程中持续强调模型的“辅助决策”定位，并通过教师培训、学生说明会和试点反馈等方式提高算法素养。尤其需要避免使用“问题学生”等标签化表述，将预警信息统一表述为“需要进一步关注的学习风险信号”。

资源约束挑战。预警系统的价值并不取决于产生多少条预警，而取决于预警之后能否提供有效支持。当高风险学生数量超过导师、辅导员和课程教师的干预能力时，可能出现“预警泛滥”。因此，应建立与资源能力相匹配的分级干预机制：低风险以自动提醒、学习资源推荐为主；中风险由导师或任课教师进行轻量跟进；高风险再启动辅导员、导师及相关部门联合干预，从而将有限人工资源优先配置给最需要帮助的学生。

同时本文也面临着推广和培训方案可执行的相关问题，在实践过程中，本文提出如下的建议供方案推广与实施。

推广方式上，建议采用“单专业试点 - 跨专业验证 - 学院推广 - 常态化运行”的渐进路径。试点阶段重点验证数据质量、模型准确性和工作流程；跨专业阶段重点检验模型的迁移能力和公平性；学院推广阶段再统一技术标准和管理制度。

在人员培训方面，可实行分角色培训。对管理人员重点培训数据治理、权限管理和预警流程；对辅导员和学业导师重点培训风险解释、人工复核及学生沟通；对任课教师重点培训行为信号识别和轻量干预；对技术人员重点培训模型监控、漂移检测和系统维护。正式上线前可通过模拟预警案例开展操作演练，并建立操作手册、常见问题库和技术支持渠道。

系统正式运行后，应按学期形成模型运行报告，对预警数量、Recall、Precision、误报率、干预完成率、平均响应时间以及学生反馈等进行持续评估。当发现模型性能明显下降或群体间差异扩大时，应启动重新训练、阈值校准或伦理复审程序。

5.4. 未来展望

在后续真实教学场景中，可以进一步利用准确率、召回率、预警提前量、干预完成率以及学生学业变化等指标，对模型的识别效果和预警时效进行持续检验。针对不同专业和年级学生在学习基础、课程

结构和行为特征等方面存在的差异，应探索建立更具适配性的参数设置方式。

结语：本文针对独立学院现有学业预警工作中风险发现相对滞后、风险原因判断不足以及干预措施匹配度不高等现实问题，提出了基于多源数据的动态预警与分级干预模型，并围绕数据治理、小范围试点、模型调优以及制度化应用设计了相应的实施路径。

基金项目

福建省本科高校教育教学研究项目“人工智能赋能高校教育：融合应用与创新教学策略探索”(FBJY20240122)。

参考文献

- [1] 刘云梯, 潘盼, 王钰滔, 等. 高校学生学业预警机制探究与优化[J]. 科技风, 2025(22): 127-129.
- [2] 喻家宾. 管理信息化驱动高校学生管理精准化的路径研究[J]. 中国管理信息化, 2026, 29(15): 199-201.
- [3] 方增泉, 冯刘洋, 李笑笑. 全球数字教育发展的影响因素和路径研究——基于《全球数字教育发展指数报告(2025)》的 fsQCA 分析[J/OL]. 教育传媒研究: 1-15. <https://doi.org/10.19400/j.cnki.cn10-1407/g2.20260703.001>, 2026-08-31.
- [4] 王文晶, 闫俊伶. 课程绩点预测研究[J]. 山西电子技术, 2020(5): 90-93.
- [5] 王凯丽. 人工智能技术在高校智慧校园建设中的应用[J]. 信息记录材料, 2026, 27(16): 71-73.
- [6] Ren, H.P., Gong, Q. and Hu, X. (2023) Estimation of Entropy for Generalized Rayleigh Distribution under Progressively Type-II Censored Samples. *Axioms*, **12**, Article 776. <https://doi.org/10.3390/axioms12080776>
- [7] 赵俊. 基于数据挖掘技术的本科生学业预警模型研究[J]. 大数据时代, 2025(3): 65-69.
- [8] 任慧娜. 基于校园行为数据挖掘的学生学业预警模型构建分析[J]. 信息系统工程, 2026(3): 22-25.
- [9] 郭淑惠. 混合式培训中教师研修成绩的预测与应用研究[D]: [硕士学位论文]. 武汉: 华中师范大学, 2019.
- [10] 王刚涛. 基于机器学习的学业预警研究[D]: [硕士学位论文]. 西安: 西安石油大学, 2021.
- [11] 范逸洲, 汪琼. 学业成就与学业风险的预测——基于学习分析领域中预测指标的文献综述[J]. 中国远程教育, 2018(1): 5-15, 44, 79.
- [12] 俞骋. BP-Adaboost 算法在学业预警中的应用研究[J]. 科技创新与应用, 2025, 15(15): 24-27.
- [13] 吴重胜, 林金珠, 马永帅, 等. 民办高校学生学业预警系统的设计与实现[J]. 电脑编程技巧与维护, 2025(7): 8-10.
- [14] 胡乾坤, 付豪, 郑晓飞, 等. 高校本科学业预警模型研究[J]. 煤炭高等教育, 2024, 42(6): 10-17.
- [15] 崔佳杉, 年梅, 张俊. 基于 XGBoost 算法的学业成绩预警模型研究[J]. 计算机与数字工程, 2022, 50(8): 1637-1640, 1651.