

AI学业预警个性化帮扶对学业困难学生 学业表现的干预效果分析*

高婷¹, 田婷²

- 广州新华学院计算机与人工智能学院, 广东 东莞 523133
- 中山大学数学学院, 广东 广州 510275

摘要: 针对传统学业预警滞后、帮扶同质化问题, 本研究融合集成学习与因果推断算法: 基于2 003名学生数据构建AdaBoost模型, 实现学业风险精准分层与实时监测; 利用因果森林模型量化干预净效应, 设计多维度个性化帮扶方案. 研究选取三类不同办学层次高校, 每校各设置50名实验组(AI预警+个性化帮扶)与50名对照组(传统预警+常规帮扶)学生, 开展两学年干预追踪. 结果显示, 实验组平均绩点提升35.70%, 高于对照组的19.40%; 其学习行为规范率与学业适应性量表得分提升亦优于对照组($P < 0.05$). 研究表明, 大样本验证的AI预警可精准识别学业风险诱因, 个性化帮扶能实现靶向干预, 二者协同对学业困难学生学业表现具有正向作用, 可为不同层次高校学业支持体系建设提供可推广路径.

关键词: AI学业预警; 个性化帮扶; 学业困难学生; 干预效果; 因果推断

中图分类号: G434 文献标志码: A 文章编号: 2097-0137(XXXX)XX-0001-12

Intervention effect analysis of AI-based academic early warning and personalized support on the academic performance of at-risk students

Gao Ting¹, Tian Ting²

- School of Computer and Artificial Intelligence, Guangzhou Xinhua University, Dongguan 523133, China
- School of Mathematics, Sun Yat-sen University, Guangzhou 510275, China

Abstract: To address the lagging nature of traditional academic early-warning systems and the homogenization of support interventions, this study innovatively integrates ensemble learning with causal inference algorithms. An AdaBoost model, validated on data from 2 003 students, was employed to achieve precise stratification and real-time monitoring of academic risk. A causal forest model was then used to quantify the net effects of interventions, enabling the development of multidimensional personalized support strategies. Three types of higher education institutions at different tiers were selected, with each type including 50 students in the experimental group (AI-based early warning and personalized support) and 50 students in the control group (traditional early warning and conventional support). Following two academic years of intervention and longitudinal tracking, the results showed that the experimental group achieved an average GPA increase of 35.70%,

* 收稿日期: 2026-01-04 录用日期: 2026-04-14 网络首发日期: XXXX-XX-XX

基金项目: 广东省重点学科研究项目(2022ZDJS152);

广东省本科高校数学教学指导委员会认定教改项目(GDSXJG202326)

作者简介: 高婷(1989年生), 女; 研究方向: 思想政治教育; E-mail: gaoting1721@xhsysu.edu.cn

通信作者: 田婷(1985年生), 女; 研究方向: 统计学; E-mail: tiant55@mail.sysu.edu.cn



ZR20260003

significantly higher than the 19.40% observed in the control group. Improvements in learning behavior compliance rates and academic adaptability scale scores were also significantly greater in the experimental group ($P < 0.05$). The findings demonstrate that AI-based early-warning models validated on large-scale datasets can accurately identify underlying academic risk factors, while personalized support enables targeted interventions. The synergistic effect of these two approaches produces a significant positive impact on the academic performance of at-risk students, providing a replicable framework for the development of academic support systems across higher education institutions of varying tiers.

Key words: AI-based academic early warning; personalized support; at-risk student; intervention effect; causal inference

随着我国高等教育进入内涵式发展阶段,高校招生规模持续扩张,学业困难学生群体问题日益凸显.教育部(2024)数据统计显示我国高校每学年接收学业预警的学生占比约为5%~8%,该群体规模庞大,其学业发展状况直接影响高等教育人才培养质量与办学水平的提升,因此,对学业困难学生实施精准化、个性化学业帮扶,已成为新时代提升高等教育质量、落实人才培养目标的核心议题之一.

当前传统学业预警模式多依赖滞后性评价指标,帮扶策略呈现同质化特征,缺乏针对性与靶向性,难以满足学业困难学生的个性化需求,制约了学业帮扶的实际成效.近年来,人工智能技术快速迭代并与高等教育领域深度融合,为学业支持体系的智能化转型、精准化升级提供了重要技术支撑与可行路径.

基于此,系统探究AI学业预警与个性化帮扶相结合的干预模式,科学评估其对学业困难学生学业表现的干预效果,不仅能够有效突破传统学业支持体系的局限与瓶颈,更对完善高校学业支持机制、推动高等教育高质量发展具有重要的理论价值与实践意义.

1 文献综述

1.1 AI在学业预警中的应用研究

近年国外AI学业预警研究呈现高精度、可解释、闭环化的发展特征:Choi et al.(2025)系统梳理了用于学生成绩预测的可解释人工智能(XAI)相关研究,为该方向的可解释性建模与应用提供了全面的文献梳理与研究框架;Wan et al.(2026)通过多模态融合技术整合混合学习行为数据,实现了更精准的学生学业成绩预测,为智能学习分析提供了高效可行的建模方法.国内研究聚焦预警指标体系构建与算法优化:李志鹏等(2023)聚焦类别不平衡联邦学习,提出CBFL方法,通过数据生成与类别均衡采样解决客户端分布异构问题;张桂銜等(2026)采用因果驱动的自适应去噪策略与图神经网络融合多源学习数据,有效降低噪声与虚假关联干扰,显著提升学生学业状态诊断的精准度.既有研究已验证AI技术在学业风险识别中的时效与精度优势,但存在三方面的局限:一是多聚焦预警环节,缺乏预警—干预闭环设计;二是风险分层较粗糙,难以满足个性化干预需求;三是风险诱因分析停留在相关性层面,缺乏因果机制探索.本研究构建AdaBoost多分类预警模型,并通过特征重要性分析锁定核心风险诱因,为个性化帮扶提供靶向干预依据,弥补预警与干预脱节的缺陷.

1.2 个性化帮扶策略的相关研究

国内外个性化帮扶策略相关研究均围绕精准化、适配性展开.国外侧重实证干预模式创新:Rosholm et al.(2025)采用两阶段随机对照试验,测试一对一教学、小群体教学及结合教师指导的三种干预方案,依据学生数学“知识漏洞”实施靶向训练,12周干预使低成就学生成绩提升23%,证实适配性分组的有效性.国内侧重多维度体系构建:刘凤娟等(2022)构建起基于知识图谱的个性化学习模型,并从动机激发、知识建构、意志提升、能力增强四个维度搭建“四位一体”协同支持机制,同时设计出相应系统原型,为个性化学习研究提供了兼具理论创新性与实践参考价值的新路径.但传统策略缺乏基于风险诱因的精准分层干预,难以匹配

学生个性化风险特征. 本研究以 AdaBoost 预警模型输出的“风险等级+核心诱因”为依据, 构建“学业提升—行为干预—心理支持”三维体系, 实现风险诱因与帮扶措施的精准匹配, 弥补传统策略适配性不足的短板.

1.3 干预效果评估相关研究

国外干预效果评估侧重量化方法创新与多维评估验证: Baker et al. (2025) 研究发现多模态教学与同伴协作学习能显著降低学习者的认知负荷与焦虑水平, 强调情境化知识建构对情绪调节的关键作用. 国内聚焦本土高校精准帮扶实证、制度优化与协同干预: 晋欣泉等 (2025) 立足国内高校多源学业大数据开展实证研究, 精准识别学困生形成诱因与演化规律, 为构建教学、管理、数据多主体协同的学业预警与精准干预机制提供了量化依据与实践路径. 但现有评估体系存在因果逻辑不足且对个体异质性获益关注不足的缺陷. 本研究采用的因果森林模型, 控制核心协变量满足因果推断前提, 输出“平均干预效应 (ATE)+个体干预效应 (ITE)”, 量化 AI 帮扶的整体优势, 识别出高风险学生与核心特征薄弱学生的异质性获益, 实现整体效果、群体差异与特征针对性的多维度评估.

2 研究设计

2.1 研究对象

本研究选取三所不同办学层次高校 (研究型大学、应用型本科、高职高专) 的学生为研究样本, 分为模型验证样本与准实验研究样本: 其中模型验证样本涵盖 2020 级、2021 级共 2 003 名学生, 覆盖不同专业与学业水平, 用于 AdaBoost 学业预警模型与因果森林干预效应模型的构建与验证; 准实验研究样本采用分层抽样方法, 从三所高校各抽取 50 名实验组与 50 名对照组学生, 学业困难标准按学校层次差异化设定 (研究型大学: 绩点 < 2.5 且 ≥ 1 门不及格; 应用型本科: 绩点 < 2.5 且 ≥ 2 门不及格; 高职高专: 绩点 < 2.0 且 ≥ 2 门不及格). 经独立样本 t 检验验证, 实验组与对照组在性别比例、专业分布、初始绩点 (实验组 2.004 ± 0.24 vs 对照组 2.006 ± 0.22) 及学业困难类型等方面均无统计学显著差异 ($P > 0.05$), 即无统计学意义, 组间具有良好可比性.

2.2 研究方法

本研究采用准实验设计, 将学业困难学生分为实验组 (AI 预警+个性化帮扶) 与对照组 (传统预警+常规帮扶), 以两学年为干预追踪周期. 研究过程中通过文献研究法系统地对 AI 学业预警和个性化帮扶领域的相关理论及既有实证成果予以梳理. 数据分析环节, 基于 Python 平台调用 scipy.stats 统计检验库, 对两组学生在干预前后的学业成绩与学习行为数据开展独立样本 t 检验和配对样本 t 检验 (Maier et al., 2025). 以 $P < 0.05$ 作为统计学显著性判断标准, 若检验结果满足该阈值, 则认定干预效果或组间差异具备统计学意义.

2.3 数据收集与评估指标体系的构建

数据来源包含高校教务管理系统 (用于获取学业成绩数据)、在线学习管理平台 (记录学习行为数据) 及信效度良好的学业适应性量表 (于干预前后分别对该量表进行施测, 结果显示其 Cronbach's α 系数为 0.88, 表明量表具有良好的内部一致性信度).

在学业成绩影响因素的变量选取上, 本研究聚焦与学业表现高度关联的学习行为维度, 纳入四类核心数据指标: 作业提交的及时性与完成质量记录、课堂考勤的出勤率与缺勤原因统计、在线学习平台的时长分布与模块访问轨迹、师生互动的频次与内容主题记录. 这些学习行为数据复杂且多变, 呈现出非线性维度的特性. 以大一年级数据为例, 其他年级数据结构相同. 为明确本研究的数据分析逻辑起点, 首先对纳入研究的核心变量开展描述性统计: 针对连续变量, 报告其均值与标准差, 以体现数据的集中趋势与离散程度; 针对离散变量, 则报告各类别的占比, 以呈现样本的分布特征. 具体统计结果见表 1.

2.4 AI 学业预警模型构建

AdaBoost 算法的样本权重更新公式为:

$$w_{m+1,i} = \frac{w_{m,i}}{Z_m} \exp(-\alpha_m y_i h_m(x_i)), \quad (1)$$

表1 研究数据变量汇总表
Table 1 Summary of research variables

变量类别	变量名称	变量类型	统计描述
学生成绩信息	平均绩点	连续	均值 = 2.00; 标准差为 0.22
学习行为特征	高数周平均线上学习时长/min	连续	均值 = 23.35; 标准差 = 7.53
	作业完成率/%	离散	完成率 = 49.5%
	课堂出勤率/%	离散	出勤率 = 83% (出勤: 89人次; 缺勤: 7人次; 迟到: 11人次)
	师生沟通效果	连续	均值 = 3.1; 标准差 = 0.67
学业结果变量	学业适应性量表得分	连续	均值 = 3.11; 标准差 = 0.43
	学业干预	离散	实验组: 对照组 = 1 : 1

$$Z_m = \sum_{i=1}^N D_m(i) \exp(-\alpha_m y_i G_m(x_i)), \quad (2)$$

$$\alpha_m = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_m}{\varepsilon_m} \right), \quad (3)$$

其中 $D_m(i)$ 为第 m 轮迭代中第 i 个样本的权重 (初始值为 $1/N$, N 为样本量); $w_{m,i}$ 为第 m 轮迭代中第 i 个样本的权重; Z_m 为归一化因子, 确保权重和为 1; α_m 为第 m 个弱分类的权重; ε_m 为第 m 个弱分类器的预测标签; y_i 为样本真实标签 (0 = 低风险, 1 = 中风险, 2 = 高风险); $G_m(x_i)$ 为第 m 个弱分类器的预测标签; $h_m(x_i)$ 为第 m 个弱分类器的预测结果。

通过整合学生大一学年课堂出勤、作业提交、在线学习时长、师生沟通情况等多维度学习行为数据, 借助多轮弱分类器的自适应优化, 弱分类器选用单特征决策树, 迭代次数设为 50 次, 依据模型训练集准确率收敛性确定, 样本权重初始值 $1/N$, 经 10 轮迭代后模型稳定性最优, 可精准识别学业风险潜在特征, 对存在学业困难倾向的学生实施提前预警与分级干预, 为制定个性化帮扶策略提供数据支撑, 进而助力学生学业表现的改善与提升。在模型构建中, 运用了五种模型算法 (AdaBoost、支持向量机 SVM、LightGBM、随机森林、XGboost) 开展准确率 (Accuracy)、F1 分数和召回率 (Recall) 等对比, 结果表明 AdaBoost 算法为最优模型 (表 2)。准确率、召回率、F1 分数、AUC 值的公式如下:

准确率

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}, \quad (4)$$

召回率

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (5)$$

F1 分数

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \quad (6)$$

$$\text{F1} = 2 \cdot \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}, \quad (7)$$

AUC 值

$$\text{AUC} = \frac{1}{2} \sum_{i=1}^{n-1} (x_{i+1} - x_i)(y_i + y_{i+1}), \quad (8)$$

式中 TP (真阳性) 表示模型预测为高风险, 且学生实际为高风险的样本数量; TN (真阴性) 表示模型预测为非高风险 (低/中风险), 且学生实际为非高风险的样本数量; FP (假阳性) 表示模型预测为高风险, 但学生实际为非高风险的样本数量; FN (假阴性) 表示模型预测为非高风险, 但学生实际为高风险的样本数量; (x_i, y_i) 为

ROC 曲线上的坐标点(假正率,真正率)。

表2 模型性能评估指标
Table 2 Model performance evaluation indicators

模型名称	准确率(Accuracy)	召回率(Recall)	F1分数	AUC	过拟合程度 ¹⁾
AdaBoost	0.8569	0.8009	0.7767	0.8462	0.0293
SVM	0.8487	0.7956	0.7431	0.8284	0.0436
LightGBM	0.8034	0.7789	0.7658	0.8460	0.2180
随机森林	0.8389	0.7743	0.7432	0.8205	0.1346
XGBoost	0.8152	0.7382	0.7174	0.8230	0.2275

1) 过拟合程度中数值越小,过拟合风险越低。

本研究对学业成绩类与学习行为类数据予以清洗,运用AdaBoost算法开展训练与预测,绘制预测风险与真实风险的对比曲线,以评估模型的预测准确性。

指标体系构建方面,整合两类核心指标,涵盖7项具体观测维度:学业基础类指标(如既往平均绩点、核心课程成绩、入学成绩)、学习行为类指标(包括课堂出勤率、作业提交及时率、在线学习时长和互动参与度等)。以2020级和2021级学业困难学生的历史数据作为训练集(样本量为2003),按7:3的比例划分训练集与测试集,最终模型准确率达85.69%,召回率为80.09%。

预警流程方面,每周自动采集学生学习行为数据,借助模型实时计算生成风险等级(低、中、高),并对中高风险学生触发预警,同时推送深度风险成因分析报告。

2.5 个性化帮扶策略制定

个性化帮扶策略制定的核心是依托AI预警系统输出的风险因素分析结果,构建涵盖“学业提升”“行为干预”和“心理支持”三个维度的帮扶体系。

在学业提升维度,针对基础薄弱型学生(核心致因:绩点较低、知识存在较多漏洞),实施“智能题库精准推送+一对一薄弱知识点辅导+知识图谱复盘可视化”策略:依据学生的作业、测试数据识别其知识漏洞,每日推送具有针对性的习题;针对薄弱知识点由教师开展一对一辅导,辅导结束后及时提交辅导记录;每月生成知识图谱复盘报告,直观展现学生的知识掌握状况。针对方法不当型学生(核心致因:学习时长充足但效率低下、复习缺乏规划),采用“AI定制学习路径+高效学习方法培训+学习效率实时监测优化”策略:结合教学大纲与学生的学习节奏,制定个性化的学习计划;每月开展学习方法培训;借助在线学习平台监测学习效率,当连续5天学习效率低于阈值时,推送优化建议。

在行为干预维度,针对行为习惯偏差型学生(核心致因:学习时长不足、作业提交延迟、出勤情况不稳定),采取“智能打卡提醒+同伴互助小组监督”策略:智能打卡系统与课程表绑定,早上推送当日学习任务,每晚提醒完成打卡,若连续3天未打卡则触发辅导员电话沟通;将学生划分为互助小组,每周组织学习交流会,相互监督任务完成情况。

在心理支持维度,针对心理动力不足型学生(核心致因:学习积极性较低、情绪波动较大、学业方向迷茫),采用“心理咨询疏导支持+学长姐结对帮扶”策略:由专业人员定期提供心理咨询服务,缓解学生的焦虑情绪;为每位学生匹配优秀学长姐,定期开展交流活动,分享学习经验与职业规划。

为清晰展现本研究的“AI学业帮扶闭环体系”的可操作性、可复制性逻辑,构建了从数据采集到动态调整的全流程操作框架,其核心环节通过“输入-处理-输出”的递进关系构成完整链路,具体操作流程见图1。

3 实证分析结果

3.1 AI学业预警模型

本研究聚焦于学生学业风险预测任务,构建了基于AdaBoost算法的多分类模型,并通过混淆矩阵、特

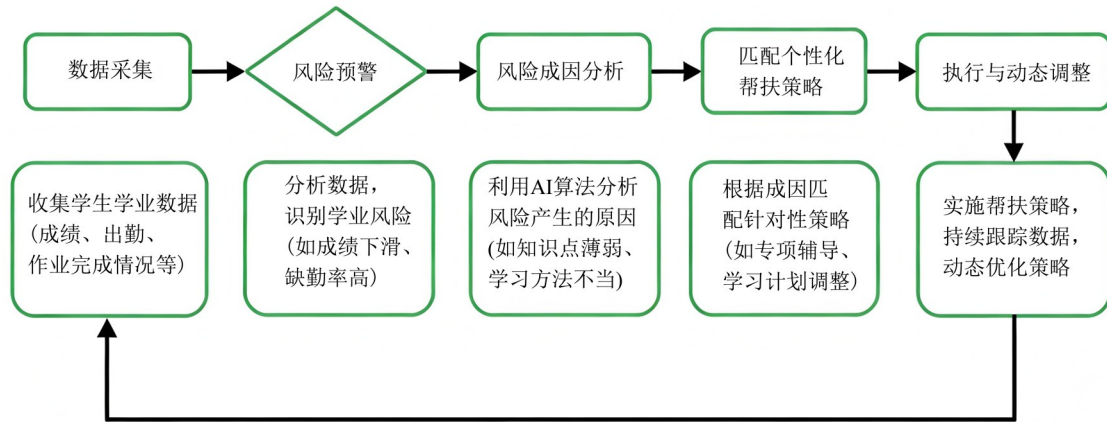


图1 AI学业帮扶完整闭环流程图

Fig. 1 Closed-loop flowchart of AI academic assistance

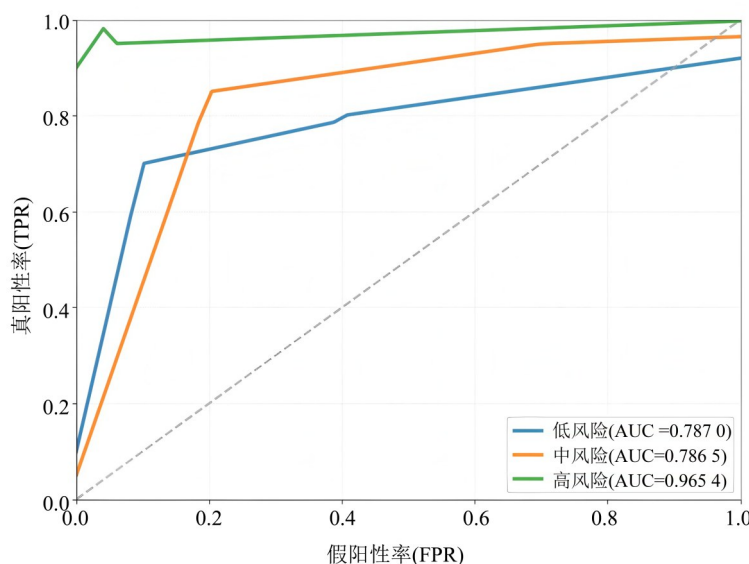


图2 AdaBoost多分类ROC曲线

Fig. 2 Multi-class ROC curves of AdaBoost model

征重要性分析、ROC-AUC 曲线以及多模型对比等多维度评估方式,验证该模型在学业风险分层识别中的有效性.

ROC 曲线与 AUC 值是评估二分类模型性能的关键指标.其中,ROC 曲线以假阳性率(FPR,即非高风险学生被误判为高风险的比率)为横轴,以真阳性率(TPR,即高风险学生被正确识别的比率)为纵轴,直观呈现模型在不同阈值下的分类效能;AUC 值则对 ROC 曲线下的面积进行量化,其取值越趋近于 1,表明模型的分类效能越强.

本研究围绕“高风险学生识别”这一核心任务绘制 ROC 曲线

(图 2:基于测试集 601 名学生数据,模型在低假阳性率(FPR < 0.10)区间真阳性率(TPR)均大于 0.90,高风险类别 AUC 值 0.965 4,契合学业预警“优先避免高风险漏判”需求).结果表明:该 AdaBoost 模型的高风险类别 AUC 值达到 0.965 4,接近 1 的理想区分水平,这意味着模型能够有效区分高风险与非高风险学生.具体而言,在测试集中随机抽取 1 名高风险学生与 1 名非高风险学生时,模型正确判定高风险学生的概率为 96.54%.

同时,ROC 曲线整体偏离“随机猜测线(AUC = 0.50)”,且在低 FPR 区间(FPR < 0.10)仍维持较高的 TPR (TPR > 0.90),这体现出模型在“降低误判”的同时,能够高效识别高风险群体,契合学业预警“优先避免高风险漏判”的实际要求.

为进一步细化模型于不同风险等级的分类表现,构建混淆矩阵(表 3).结果显示,低风险识别准确率达到 89.42%,中风险识别准确率为 85.62%,高风险识别准确率达 92.23%,在各风险等级的分类表现均处于较高水准,为模型后续对新数据的预测提供了有力保障.

为衡量模型中各输入变量对预测结果的贡献程度,绘制特征重要性比例图(图 3:学习完成度均值、沟通效果最小值两项特征累计重要性占比超 60%,为核心风险特征;模型自动剔除 13 项次要特征,降低复杂程

度)。结果显示,“学习完成度均值”和“沟通效果最小值”这两项特征的重要性占比超 60%,其中“学习完成度均值”以 0.433 9 的重要性数值居首位,“沟通效果最小值”以 0.256 2 居第二。此结果与教育学中“学习任务完成质量是学业风险的核心诱因、基础沟通效果决定学业衔接效率”的共识高度相符,证明该模型能够精准捕捉真实教学场景中的关键影响要素。该模型将“作业提交率”“出勤分数”等 13 项次要特征的重要性设定为零,剔除冗余信息,既避免次要特征对核心判断的干扰,也降低了模型的复杂程度。

AdaBoost 采用“迭代调整样本权重与弱分类器集成”的方法开展模型训练。弱分类器的“简易性”(例如单特征决策树)以及集成过程的“投票机制”,本质上降低了模型对训练集噪声的依赖,其过拟合程度为 0.029 3。该模型在训练集的准确率达 85.69%,于独立测试集的准确率为 83.46%,二者差值为 2.23%。同时,测试集的高风险 AUC 值(0.965 4)与训练集(0.987 1)近乎相同,证明模型未出现“过度拟合训练数据”的现象,能稳定适配新的学生样本,适用于本研究的 AI 学业预警。

表 3 AI 学业风险预测模型混淆矩阵¹⁾

Table 3 Confusion matrix of AI academic risk prediction model

风险等级	预测低风险	预测中风险	预测高风险
真实低风险	296	30	5
真实中风险	12	143	12
真实高风险	0	8	95

1) 样本量为 601 人(模型验证样本测试集)。

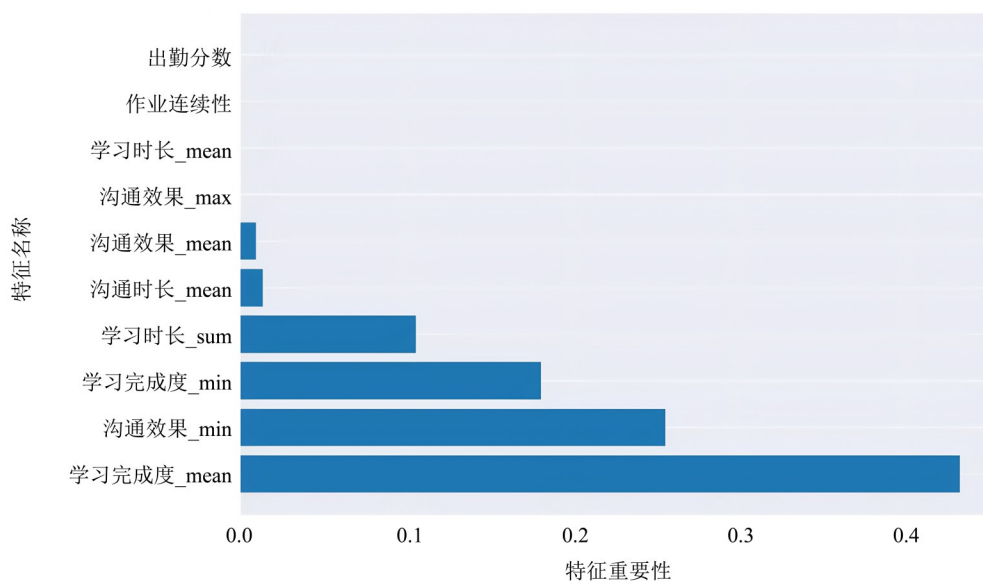


图 3 AdaBoost 特征重要性

Fig.3 Feature importance of AdaBoost model

3.2 因果森林模型

为验证上述 AI 多维帮扶策略相较于传统帮扶模式的实际效能,本研究采用因果森林模型开展干预效果的因果推断分析。此方法突破传统教育干预“重描述、轻因果”的局限。通过构建由多棵“因果树”组成的集成结构,选取“学习完成度均值、沟通效果最小值、学习时长总和”等作为核心协变量,以“是否接受 AI 帮扶”作为干预变量(其中,1 代表 AI 帮扶组,0 代表传统帮扶组),“绩点提升量(大二绩点减大一绩点)”作为结果变量,对 300 名学生的纵向数据进行模型拟合。模型参数设定为树数量 50 棵、最大深度 4 层、叶节点最小样本数 3 个,经 5 折交叉验证后,该参数组合下模型 OOB 估计值与 ATE 误差最小(< 3.00%),过拟合风险最低。

结果显示,控制协变量之后,AI 帮扶组的平均绩点提升量为 0.76 ± 0.23 ,相较于传统帮扶组的 0.43 ± 0.21

高出 0.33. 经过 1 000 次置换检验验证, 该效应的 P 值为 0.001 0 (< 0.01), 证明 AI 帮扶的整体效果在统计学上具有高度显著性, 有统计学意义. 同时, 模型的袋外(OOB)估计值为 0.32, 与 ATE 的误差小于 3.00%, 且所有核心协变量的标准化均值差(SMD)均小于 0.1 (学习完成度均值 SMD = 0.06、沟通效果最小值 SMD = 0.08), 确保干预组与对照组在基线水平上具有可比性, 满足因果推断的核心前提条件.

结合 AdaBoost 学业预警模型输出的风险等级(低/中/高), 进一步分析不同风险群体的个体干预效应(ITE)(表 4). 结果显示, 高风险学生的 ITE 是低风险学生的 3.4 倍, 且仅高、中风险群体的 ITE 通过显著性检验($P < 0.01$), 这一结果与 AI 学业预警模型的风险分层逻辑形成呼应, 证明 AI 帮扶并非“泛化提效”, 而是对学业困难学生(高、中风险)实现“精准救助”, 高度契合“分层施策”的帮扶设计初衷. 平均干预效应、袋外估计值、标准化均值差、个体干预效应的公式如下.

平均干预效应

$$ATE = E[Y(1) - Y(0)] = E[Y(1)] - E[Y(0)], \quad (9)$$

袋外估计值

$$OOBError = \frac{1}{N} \sum_{i=1}^N I(\hat{y}_i^{OOB} \neq y_i), \quad (10)$$

标准化均值差

$$S_p = \sqrt{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2 / n_1 + n_2 - 2}, \quad (11)$$

$$SMD = \frac{\bar{X}_1 - \bar{X}_2}{S_p}, \quad (12)$$

个体干预效应

$$ITE = Y_i(1) - Y_i(0). \quad (13)$$

式中 $Y(1)$ 为个体接受 AI 学业帮扶 (AI 帮扶组, $W_i = 1$) 后的学业结果; $Y(0)$ 为个体接受传统帮扶 (传统帮扶组, $W_i = 0$) 后的学业结果; S_p 为合并标准差; \bar{X}_1 、 \bar{X}_2 为 AI 帮扶组、传统帮扶组的指标均值; S_1^2 、 S_2^2 为 AI 帮扶组、传统帮扶组的指标方差; n_1 、 n_2 为 AI 帮扶组、传统帮扶组的样本量; N 为总样本量; \hat{y}_i^{OOB} 为第 i 个样本的袋外预测值 (即未参与该样本训练的决策树对其的预测结果); $I(\cdot)$ 为指示函数, 当括号内条件成立时取值为 1, 否则为 0; $Y_i(1)$ 为第 i 个学生接受 AI 帮扶后的学业表现; $Y_i(0)$ 为第 i 个学生未接受 AI 帮扶后的学业表现.

为直观展现 AI 帮扶对具有薄弱特征学生的因果效应, 以“学习完成度均值、沟通效果最小值、学习时长总和”等核心特征作为分层维度, 将学生划分为“薄弱组 (前 30%)”与“非薄弱组”. 借助因果森林模型输出两组的绩点提升量, 并绘制对比图 (图 4: 300 名学生按核心特征分为薄弱组 (前 30%) 与非薄弱组). 结果显示, 薄弱组中 AI 帮扶的绩点提升量显著高于传统帮扶. 在“学习完成度均值 < 阈值”组中, AI 帮扶使绩点提升 0.82, 为传统帮扶提升量 0.35 的 2.34 倍; “沟通效果最小值 < 阈值”组中, AI 帮扶提升 0.79, 是传统帮扶 0.37 的 2.14 倍; 在“学习时长总和 < 阈值”组中, AI 帮扶提升 0.75, 为传统帮扶 0.38 的 1.97 倍, 且三组差异均通过 0.001 0 水平的显著性检验 (标注***), 有统计学意义. 而非薄弱组中, AI 帮扶与传统帮扶的绩点提升量差异仅为 0.12~0.08, 且不具有统计学意义. 这一结果与 AI 学业预警模型的高重要性特征高度相符, 证实 AI 帮扶能够精准定位并改善学业风险的核心诱因, 达成“靶向补弱”的因果效应.

3.3 学业成绩干预效果的分析

实验组在干预前的平均学分绩点为 2.00±0.21, 干预后提高至 2.72±0.25, 提升幅度达 35.70%; 对照组干预前平均学分绩点为 2.00±0.23, 干预后为 2.41±0.24, 提升幅度为 19.40%.

统计检验结果显示, 干预后两组的平均学分绩点存在显著差异 ($t = 5.24$, $P < 0.001 0$), 证明实验组的学业成绩提升效果优于对照组. 同时, 效应量 Cohen's d 计算结果为 1.35 (合并标准差 0.245), 高于 0.80 的“大效应”标准, 证明两组的提升效果差异不仅具有统计学意义, 还具有实际教学意义.

3.4 学习行为改善的分析

借助 AdaBoost 学业预警模型对学生学习行为实施实时监测, 在模型预警的精准干预下, 实验组各项学

表 4 不同风险等级学生的因果森林干预效应结果¹⁾

Table 4 Intervention effects of causal forest for students with different risk levels

风险等级	样本量 (人)	AI 帮扶组绩点提升量 (均值±标准差)	传统帮扶组绩点提升量 (均值±标准差)	个体干预效应 (ITE, 均值)	效应显著性 (P 值)	提升幅度差异 (百分点)
高风险	50	0.93±0.26	0.46±0.21	0.45	< 0.001 0	20.80
中风险	84	0.76±0.20	0.44±0.17	0.33	0.002 0	12.90
低风险	166	0.51±0.16	0.37±0.14	0.13	0.038 0	5.60

1) 样本量为模型验证样本中的学业困难学生, 效应显著性通过 1 000 次置换检验验证.




图 4 核心特征分组下的 AI 与传统帮扶绩点提升对比

Fig. 4 Comparison of GPA improvement between AI and traditional assistance under core feature groups

习行为指标的改善幅度均高于对照组. 差异显著性检验显示, 各项指标的组间差异 P 值均小于 0.05 (详见表 5), 证明模型预警干预对学习行为的改善效果具有统计学意义. 结果证明 AdaBoost 学业预警模型的核心价值为通过“实时监测—风险预警—及时干预”的闭环机制, 有效提前遏制不良学习行为的持续发展, 推动学生学习行为朝着积极方向转变.

表 5 各学习指标改善幅度¹⁾

Table 5 Improvement magnitudes of various learning indicators

指标	实验组改善幅度 /%	对照组改善幅度 /%	差异显著性 ($P < 0.05$)
作业按时提交率	26.90	9.20	0.047 0
课堂出勤率	17.00	3.70	0.000 0
在线学习时长达标率	40.00	25.20	0.012 0
师生沟通频率提升率	104.13	5.93	0.000 0

1) 改善幅度 = (干预后指标值 - 干预前指标值) / 干预前指标值 × 100%, 差异显著性通过独立样本 t 检验验证.

3.5 学业适应性的分析

本研究采用《大学生学业适应性量表》对实验组与对照组的学业适应性展开测量. 结果显示, 实验组干预前学业适应性总得分均值为 3.12 ± 0.45 , 干预后提升至 4.07 ± 0.38 , 提升幅度为 30.50%; 对照组干预前总得

分均值为 3.10 ± 0.42 , 干预后为 3.48 ± 0.39 , 提升幅度仅为 12.3% (图 5: 300 名学生干预后, 实验组平均绩点提升至 2.72 ± 0.25 、学业适应性提升至 4.07 ± 0.38 , 对照组分别为 2.41 ± 0.24 、 3.48 ± 0.39 ; 两组绩点差异 $t = 5.24$ ($***P < 0.001$), 学业适应性差异 $P = 0.008$).

同时, 差异显著性检验结果表明, 两组干预后的学业适应性得分差异 $P = 0.008$ (< 0.05), 证明 AdaBoost 学业预警模型的干预, 不仅能够改善具体学习行为, 还能从整体层面提高学生的学业适应性. 借助实时预警与针对性辅导, 助力学生更迅速地适应学习要求、调整学习状态, 降低因学业适应不良引发的风险. 图 6 (以对照组提升幅度为 1.0 倍, 实验组学习行为改善相对提升 2.40 倍、学业成绩 1.86 倍、学业适应性 2.48 倍, 体现 AI 预警+个性化帮扶优势) 展示了实验组在学习成绩、学习行为、学业适应性方面的提升状况.




图 5 学业成绩与学业适应性得分分布对比

Fig.5 Comparison on score distribution of academic achievement and academic adaptability

3.6 长期干预效果分析

为验证 AI 学业预警与个性化帮扶策略的两学年持续干预效果, 本研究对实验组与对照组学生开展两年学年的追踪观测. 结果显示 (图 7: $n = 300$, 实验组 94.00% 学生无不及格课程, 对照组 8.00% 学生 ≥ 2 门不及格): 实验组大一平均绩点为 2.00, 经两学年干预后, 大三平均绩点稳定在 2.72, 整体提升幅度为 35.70%, 且较大二 (2.72) 维持平稳波动; 而对照组大一平均绩点为 2.01, 大三平均绩点为 2.40, 较大二 (2.41) 出现轻微衰减, 整体提升幅度为 19.40%. 从学业风险维度看, 实验组大三“0 门不及格”学生占比达 94.00%, 较干预前 (12.00%) 实现风险的显著改善; 对照组大三仍有 8.00% 的学生存在 ≥ 2 门课程不及格的情况. 上述结果证明, AI 帮扶不仅能实现学业困难学生的短期成绩提升, 且能通过“精准预警-靶向干预”的闭环机制培养自主学习能力, 使干预效果在两学年周期内保持稳定, 显著优于传统帮扶模式的短期效应特征.

4 讨论

4.1 干预效果的核心机制阐释

AI 学业预警系统的精准赋能效应通过实时采集分析多维度数据, 实现学业风险的早期识别与精准定位, 可解决传统预警机制的滞后性问题, 为开展个性化帮扶提供了科学支撑. 而个性化帮扶的适配效应是干预有效的关键保障. 本研究构建的“学业提升-行为干预-心理支持”三维体系, 依据学生的风险类型与核心诱




图6 多维度干预效果相对提升倍数

Fig.6 Relative improvement multiples of multi-dimensional intervention effects




图7 AI与传统帮扶模式下学业困难学生两学年绩点变化趋势

Fig.7 Two-year GPA dynamics of students under AI and traditional academic assistance

因提供差异化支持,契合精准教学理论的核心诉求.因果森林模型的量化验证为干预有效性提供了科学支撑.该模型通过控制混淆变量,剥离初始学业水平、学习动机等因素对结果的干扰,精准量化AI帮扶的净效应,证实了“AI预警+个性化帮扶”与学业改善之间的因果关系.群体异质性分析结果为帮扶资源的精准配置提供了实证依据,研究表明,将帮扶资源向高、中风险学生倾斜,可显著提升帮扶资源的边际效益,实现帮扶效能的最大化.

4.2 与传统帮扶模式的差异比较

传统学业帮扶模式往往呈现出“统一化、普适性”特征,缺乏对个体差异的深度关注,易造成资源投放效

率欠佳以及干预效果未达预期的状况.本研究构建的“AI预警+个性化帮扶”新模式,以数据驱动为核心要素对学生的学业表现展开多层次、多维度的剖析与诊断,进而制定出更具针对性的干预策略,使帮扶举措契合学生个体的实际需求,提升干预措施的可操作性与实际效能.这种转变带来的直接效果是干预的长期有效性,传统帮扶模式的效果往往集中在短期,学生易出现“干预期间进步、干预结束反弹”的现象.本研究中实验组大三学生绩点稳定性优于对照组,其核心机制在于AI帮扶模式突破了传统短期成绩导向的干预局限,通过行为干预、心理赋能的协同作用,系统性培育学生的自主学习能力与学业适应素养,最终实现干预效果的长效化.

5 结 论

本研究为高校学业困难学生帮扶提供了可复制、可落地的协同体系.对于不同层次高校而言,可借鉴本研究的AI预警模型构建逻辑,结合自身学生特点优化特征指标与算法参数,实现风险的精准识别;可参照“学业提升-行为干预-心理支持”三维帮扶体系,制定符合本校实际的个性化帮扶策略,并明确执行标准与质量控制措施;可采用因果森林等先进统计方法,科学评估干预效果,持续优化帮扶方案.

参考文献:

- 晋欣泉,姜强,马志强,2025.数字时代教育变革视域下高校学困生的诱因识别与演化机理研究[J].中国高教研究,(1): 48-56.
- 李志鹏,国雍,陈耀佛,等,2023.基于数据生成的类别均衡联邦学习[J].计算机学报,46(3): 609-625.
- 刘凤娟,赵蔚,姜强,等,2022.基于知识图谱的个性化学习模型与支持机制研究[J].中国电化教育,(5): 75-81+90.
- 张桂衍,袁冠,张艳梅,等,2026.因果驱动的自适应去噪认知诊断框架[J].计算机学报,49(3): 557-573.
- 中华人民共和国教育部,2024.2023年全国普通高校本科教育教学质量报告[R].北京:中华人民共和国教育部.
- Baker D L, Moradibavi S, Liu Y, et al, 2025. Effects of interventions on science vocabulary and content knowledge: A meta-analysis[J]. Res Sci Educ, 55(6): 1517-1535.
- Choi W C, Lam C T, Pang P C, et al, 2025. A systematic literature review of explainable artificial intelligence (XAI) for interpreting student performance prediction in computer science and STEM education[C]//Proceedings of the 30th ACM Conference on Innovation and Technology in Computer Science Education: 221-227.
- Maier M, Bartoš F, Quintana D S, et al, 2025. Model-averaged Bayesian t tests[J]. Psychon Bull Rev, 32(3): 1007-1031.
- Rosholm M, Tonnesen P B, Rasmussen K, et al, 2025. A tailored small group instruction intervention in mathematics benefits low achievers[J]. npj Sci Learn, 10: 18.
- Wan H, Yue S, Li M, et al, 2026. Integrating blended learning behaviors via multimodal fusion for student performance prediction[J]. IEEE Trans Learn Technol, 19: 87-104.

(责任编辑 冯兆永)