College and Job 职业教育发展, 2026, 15(11), 64-70
Published Online November 2026 in Hans. https://www.hanspub.org/journal/ve
https://doi.org/10.12677/ve.2026.1511463

Hans汉斯

职业教育数据驱动的精准教学与评价

吴志伟，杨得国，曹瑞光

西北师范大学人工智能与计算机学院，甘肃 兰州

收稿日期：2026年10月3日；录用日期：2026年10月28日；发布日期：2026年11月9日

摘 要

职业教育数字化转型的核心在于利用数据智能实现规模化因材施教。针对当前精准教学实践中存在的数据孤岛、分析表层化、干预滞后、评价单一等问题，本文提出一个名为智慧教学决策支持系统的集成化技术框架。该框架包含多源数据感知与融合层、智能分析中枢层、精准干预与动态评价层。其中，智能分析中枢层创新性地整合了基于图神经网络的学业风险预测模型与过渡网络分析，实现了对学生多维表现及学习过程时序模式的深度挖掘。本文以高职《Python程序设计》课程为案例，展示了该框架的实施全流程。实证结果表明，应用该框架的班级在通过率、学习投入度及高维能力发展上均显著优于对照组。本研究为构建教学、评价、干预一体化提供了可落地的技术路径与实证参考。

关键词

精准教学，教育数据挖掘，过渡网络分析，图神经网络

Data-Driven Precise Teaching and Evaluation in Vocational Education

Zhiwei Wu, Deguo Yang, Ruiguang Cao

College of Artificial Intelligence and Computer Science, Northwest Normal University, Lanzhou Gansu

Received: October 3, 2026; accepted: October 28, 2026; published: November 9, 2026

Abstract

The core of the digital transformation of education lies in leveraging data intelligence to realize large-scale personalized teaching. Aiming at the prevalent problems in current precision teaching practices, including data silos, superficial data analysis, delayed intervention and simplistic evaluation, this paper proposes an integrated technical framework named the Intelligent Teaching Decision Support System. The framework consists of three layers: multi-source data perception and fusion, intelligent analysis hub, and precise intervention and dynamic evaluation. Within the intelligent analysis hub, a graph

文章引用: 吴志伟, 杨得国, 曹瑞光. 职业教育数据驱动的精准教学与评价[J]. 职业教育发展, 2026, 15(11): 64-70.
DOI: 10.12677/ve.2026.1511463

neural network-based academic risk prediction model and transition network analysis are innovatively integrated to conduct in-depth mining of students' multi-dimensional performance and temporal patterns of learning processes. Taking the college course Python Programming as a case study, this paper elaborates on the entire implementation process of the framework. Empirical results demonstrate that the classes adopting this framework achieve significantly better outcomes than the control group in terms of pass rates, learning engagement and the development of high-dimensional competencies. This study provides a practical technical pathway and empirical reference for constructing an integrated system of teaching, evaluation and intervention.

Keywords

Precision Teaching, Educational Data Mining, Transition Network Analysis, Graph Neural Network

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

当前，职业教育领域正经历由经验驱动向数据驱动的范式转型。大数据与人工智能技术为理解复杂学习过程、实现个性化学习提供了前所未有的可能[1]。数据驱动的精准教学旨在通过采集、分析与解释多模态学习数据，形成精准的学情诊断，进而实施差异化教学干预与持续优化的评价[2]。

数据驱动的职业教育精准教学并非单纯技术堆砌，其底层需要学习理论作为支撑。建构主义学习理论强调学习是学习者主动建构知识、在问题解决过程中生成个人理解的过程，这就要求教学评价不能只聚焦期末结果，需要捕捉学生学习过程中的行为、调试、犯错、反思等过程性证据，为本研究开展时序学习行为挖掘、多维动态评价提供教育学依据。而联结主义学习理论认为知识是节点之间相互联结形成的网络，学生的学业表现不是单一成绩指标，而是历史成绩、课堂参与、代码调试行为、情感状态等多要素相互作用的复杂关联系统。这为本研究采用图神经网络(GNN)建模学生多特征关联、构建学生特征图提供了理论支撑。

然而，实践层面仍面临显著问题，主要有以下几个方面：

(1) 数据维度割裂：行为、认知、情感数据分散于不同系统，难以形成统一的学生数字画像[3]。

(2) 分析深度不足：多数分析停留于描述统计，缺乏对学习过程时序规律与深层次风险的前瞻性预测[4]。

(3) 干预与评价脱节：教学干预往往基于滞后反馈，且过程性评价数据未有效用于优化教学决策[5]。

为应对上述问题，本研究旨在构建一个技术透明、可落地的集成框架。本文的核心贡献在于以下几个方面：

(1) 提出一个融合多模态数据、先进分析模型与教学决策的感知、分析、干预、评价系统架构。

(2) 引入并结合了最新的图神经网络预测模型与过渡网络分析方法，分别用于提升学业风险预测的准确性以及对学习过程动态模式的洞察力。

(3) 通过详细的案例研究，验证了框架的有效性，并提供了完整的技术实现路径与效果评估。

2. 教学评价现状与核心技术

2.1. 数据驱动的教学评价研究现状

大数据教育评价的研究正逐年增长，中国和美国学者在此领域贡献突出[1]。研究目标主要集中于高

阶思维分析、学业表现预测、学习情感识别、教学管理决策与评价模式优化五个方面，算法模型日趋多样，文本模态数据最为常用，而科学学科是应用大数据技术赋能教学评价的主要领域[1]。然而，现有研究多聚焦于在线学习行为分析或单一模型的性能优化，缺乏将多维预测、过程分析与教学干预进行系统性整合的框架[6] [7]。

2.2. 关键技术基础

2.2.1. 学生表现预测模型

学生表现预测是精准教学的基础。传统模型如决策树、逻辑回归在处理多维、异构、时序的教育数据时存在局限[8]。近年来，深度学习模型展现出优势。GNN-Transformer-InceptionNet 通过整合图神经网络、Transformer 和 InceptionNet 架构，能够有效捕捉学生特征间的复杂交互与上下文依赖关系，在包含 97,000 条记录的数据集上取得了 98.5%的预测准确率[8]，另一项研究提出的多维度学生表现预测模型则通过高级数据预处理、特征工程和可解释 AI 特性，专注于处理不平衡和时序数据，实现了 76%的准确率与 0.79 的精确度[9]，这些模型为构建更鲁棒的学业预警系统提供了技术基础。

2.2.2. 学习过程时序分析

除了预测结果，理解学习行为的动态过程同样关键。过渡网络分析是一种新兴的学习分析方法，它结合了随机过程挖掘与概率图表示，可对学习过程数据进行建模、可视化和分析[10]。TNA 能够识别重要的学习事件、发现常共同出现的行为集群、揭示不同的时间模式，并进行显著性检验以消除噪声[9]。该方法为从海量行为日志中提炼有意义的学习路径模式提供了强有力的工具。

2.2.3. 干预框架与系统

预测的最终价值在于引导有效干预。研究者提出了学习分析干预范式，强调在预测风险后向相关方传递信息以实施针对性干预[7]，一个扩展的 LAI 框架即学生表现预测与行动框架，旨在为教师提供易于访问的 LAI 基础设施，允许他们基于历史课程评估数据开发课程特定的预测模型，并集成教学法知识以制定个性化学习计划[7]。这体现了将技术工具与教学法深度融合的趋势。

综上所述，当前研究在预测算法和过程分析上取得了进展，但一个能将前沿分析技术、多维数据与教学干预实践无缝衔接的综合性技术框架仍有待探索，本研究试图填补这一不足。

3. 智慧教学决策支持系统框架设计

3.1. 多源数据感知与融合层

该层负责从异构数据源中采集和治理原始数据。

(1) 数据采集：通过学习管理系统 API 收集点击流、作业提交、论坛发帖等行为数据，利用在线编程评测平台采集代码提交频率、错误类型、调试时长等认知数据，通过嵌入式问卷或情感计算接口获取学生自我报告或隐式的情感状态数据。

(2) 数据融合与存储：采用上下文自适应插补即一种能根据数据上下文关系智能处理缺失值的方法[7]清洗数据。为每位学生创建唯一标识，将多源数据在时间戳上对齐，并利用数据仓库技术[10]存储，形成以学生为中心的多维时序数据立方体。

3.2. 智能分析中枢层

该层是框架的大脑，包含描述性、诊断性、预测性和指导性分析模块。该层是框架的大脑，承担整个智慧教学系统的核心决策职能，集成描述性、诊断性、预测性和指导性分析四大功能模块。其中，描

述性分析模块负责汇总学习平台的历史行为与学业数据，客观呈现学生学习现状。诊断性分析模块挖掘学习过程中的薄弱环节与问题成因，定位学习困难的根源。预测性分析模块依托时序学习数据预判学生学业风险与能力发展趋势。指导性分析模块基于前述分析结果，自动生成适配不同学习者的教学干预策略与个性化学习建议。

(1) 核心预测引擎即基于改进的 GNN 模型：

设计一个轻量化的图卷积网络–注意力机制模型用于学业风险预测。模型的输入是经过预处理的学生特征图 $G=(V,E)$，其中节点 V 代表学生特征如历史成绩、参与度、代码质量指标，边 E 代表特征间的关联，模型通过图卷积层聚合邻居信息，再通过注意力机制为不同特征分配权重，最终输出风险概率。

节点特征更新的核心公式可简化为：

$$h_i^{(l+1)}=\sigma\left(\sum_{j\in N(i)}\alpha_{ij}W^{(l)}h_j^{(l)}\right)$$

其中，$h_i^{(l)}$ 是第 l 层节点 i 的特征，$N(i)$ 是邻居节点，α_{ij} 是由注意力机制计算出的权重，$W^{(l)}$ 是可训练权重矩阵，σ 是非线性激活函数。

(2) 过程模式挖掘基于 TNA：

我们将学生的连续学习行为如观看视频、完成测验、查阅资料、论坛提问编码为事件序列。利用 TNA 方法构建行为过渡网络，其中节点是学习事件，有向边的权重代表从一个事件转移到另一个事件的概率。通过计算网络的中心性指标，我们可以识别出对学习成功至关重要的枢纽行为，通过社区检测，可以发现学生自然形成的不同学习策略集群。

3.3. 精准干预与动态评价层

该层将分析结果转化为具体的教学行动和评价依据。

(1) 自适应干预引擎：根据预测引擎的风险等级和 TNA 揭示的学习模式，如浅层浏览型、深度探究型，从预设的干预规则库中匹配策略。对高风险且模式为浅层浏览型的学生，系统自动推送带有引导性问题的核心概念讲解视频和强制性基础练习。

(2) 动态评价看板：为教师和学生提供实时可视化看板。看板不仅展示传统的成绩分布，更重要的是整合了过程性评价指标，如基于代码提交日志计算的问题解决坚持度、基于论坛数据计算的协作贡献度，以及基于 TNA 路径分析得出的学习策略复杂度。这些指标共同构成一个多维的、发展的学生能力画像。

4. 案例研究：在《Python 程序设计》课程中的应用

4.1. 研究设计与实施

在某职业院校计算机专业两个平行班中开展了为期一学期的准实验研究。实验班使用本框架支持的教学，对照班采用传统教学方法即每周讲授、作业、期末项目。本案例研究对应的系统实现架构、技术选型及其功能作用如表 1 所示。

Table 1. Case study system implementation architecture and technology stack
表 1. 案例研究系统实现架构与技术栈

组件	技术选型与实现	作用
数据采集	Moodle API, Online Judge API，课堂小程序	收集行为、代码、情感数据
数据存储	MySQL (结构化数据)，MongoDB (行为日志)	存储多源异构数据
分析引擎	PyTorch Geometric 实现 GNN	运行预测模型与 TNA

续表

干预与可视化	Flask (后端 API)，Vue.js + ECharts (前端看板)	触发干预、展示分析结果
部署	Docker 容器化微服务	提高系统灵活性与可维护性

数据预处理流程：采用了来自前沿研究的上下文频率编码与上下文自适应插补技术[7]，有效处理了分类变量和缺失值问题。特征工程选取了包括每周登录次数、视频暂停、回放频率、代码首次通过率、调试平均时长、论坛提问情感极性等在内的 20 个初始特征。

4.2. 核心分析示例

4.2.1. 学业风险预测模型效果

在学期第 8 周，使用截至第 7 周的数据训练 GNN-注意力预测模型，对期末是否面临挂科风险进行预测。模型在验证集上的性能如表 2 所示。

Table 2. Performance evaluation of academic risk prediction model
表 2. 学业风险预测模型性能评估

模型	准确率	精确率	召回率	F1 分数	AUC
逻辑回归	0.78	0.71	0.65	0.68	0.82
随机森林	0.83	0.80	0.75	0.77	0.89
本框架 GNN-注意力模型	0.89	0.87	0.82	0.84	0.93

结果显示，本框架采用的模型在各项指标上均优于传统基线模型，尤其在对高风险学生的识别和整体判别能力上表现突出。

4.2.2. 学习过程模式发现

对实验班所有学生的 O.J.平台行为序列进行 TNA 分析，发现了三个显著学习模式集群：

集群 A (试探－修正型)：特征为提交、错误、查阅错误提示、少量修改、再次提交。该集群学生最终成绩中等，但调试时间较长。

集群 B (规划－测试型)：特征为阅读题目、本地编写测试、首次提交通过。该集群学生成绩优秀，代码一次通过率高。

集群 C (被动－模仿型)：特征为查看他人代码、复制、提交、错误、长时间停滞。该集群与高风险预测高度相关。

教师根据 TNA 分析结果，对集群 C 学生进行了额外的编程思维与调试方法小型工作坊干预。

4.3. 教学效果评估

学期结束后，通过多维度指标对比两班效果。如表 3 所示，从学业成果、学习投入、能力发展三个维度对比了实验班与对照班的教学效果，统计检验结果显示两组在全部观测指标上均存在统计学差异。在学业成果上，实验班课程通过率 95.4%、平均期末成绩 82.3 分，高于对照班的 84.1%、76.8 分，分别达到 $p < 0.05$ 与 $p < 0.01$ 的显著性水平；学习投入层面，实验班平台周均活跃天数 4.2 天、论坛高质量帖子人均 2.5 篇，同样显著高于对照班的 3.1 天、1.3 篇；在能力发展维度，实验班复杂问题分解任务得分 8.1/10、期末项目代码可复用性评分 7.8/10，也明显优于对照班的 6.9/10 与 6.5/10。上述结果说明，应用本智慧教学决策支持系统框架开展教学，既能够有效改善学生学业表现，也可以提升学生线上学习参与

程度，并促进复杂问题解决、代码实践等高阶能力的发展。

Table 3. Comparison of teaching effects between the experimental class and the control class
表 3. 实验班与对照班教学效果对比

评估维度	具体指标	实验班	对照班	p 值显著性检验
学业成果	课程通过率	95.4%	84.1%	<0.05
	平均期末成绩	82.3	76.8	<0.01
学习投入	平台周均活跃天数	4.2 天	3.1 天	<0.01
	论坛高质量帖子人均数	2.5 篇	1.3 篇	<0.05
能力发展	复杂问题分解任务得分	8.1/10	6.9/10	<0.01
	期末项目代码可复用性评分	7.8/10	6.5/10	<0.05

5. 结论

5.1. 主要研究结论

本文针对数据驱动精准教学中的核心问题，提出了一个集成了多模态数据融合、图神经网络预测、过渡网络过程分析与自适应干预的综合性技术框架，并通过详实的课程案例验证了其有效性。研究表明，将前沿学习分析技术与教学设计深度融合，不仅能够实现更精准的学业预警，更能从过程层面揭示学习规律，为实施因材施教和开展发展性评价提供强大支持。本研究为教育数字化转型在课堂层面的落地提供了一个具有参考价值的技术方案与实践范例。

5.2. 研究局限与展望

本研究虽验证了智慧教学决策支持系统框架在高职《Python 程序设计》课程中的应用效果，但仍存在若干局限。首先，实验样本来源较为单一，仅选取同一所职业院校计算机专业的两个平行班级开展准实验，课程局限于编程实操类课程，样本规模有限，研究结论向不同层次院校、文科或其他工科专业推广时应当审慎。其次，本研究无法完全排除霍桑效应带来的影响，实验班师生知晓参与教学实验，师生主观投入度提升可能对教学效果产生正向干扰，难以完全剥离框架本身与心理因素对结果的贡献。

针对上述不足，后续研究可从多方面继续推进。第一，扩大研究样本，选取多所不同办学层次的职业院校，覆盖经管、机电、艺术等更多学科课程开展跨场景实证，检验框架的普适性。第二，优化实验方案，引入等待列表对照组、多轮重复实验等更为严谨的准实验设计，尽可能降低霍桑效应对实验结果的干扰。第三，借助德尔菲法集合职业教育领域多位专家，迭代完善干预规则库，细分评估不同干预策略对各类学习模式学生的作用效果。

参考文献

[1] Lin, L., Zhou, D., Wang, J. and Wang, Y. (2024) A Systematic Review of Big Data Driven Education Evaluation. *Sage Open*, **14**. https://doi.org/10.1177/21582440241242180

[2] Ogata, H., Liang, C., Toyokawa, Y., Hsu, C., Nakamura, K., Yamauchi, T., *et al.* (2024) Co-Designing Data-Driven Educational Technology and Practice: Reflections from the Japanese Context. *Technology, Knowledge and Learning*, **29**, 1711-1732. https://doi.org/10.1007/s10758-024-09759-w

[3] Aragani, V.M. and Maroju, P.K. (2025) Predictive Analytics in Education: Early Intervention and Proactive Support with Gen AI Cloud. In: Chaudhuri, S. and Ray, N., Eds., *Leveraging AI and Emotional Intelligence in Contemporary Business Organizations*, IGI Global, 350-370.

[4] Alalawi, K., Athauda, R. and Chiong, R. (2025) An Extended Learning Analytics Framework Integrating Machine Learning and Pedagogical Approaches for Student Performance Prediction and Intervention. *International Journal of Artificial Intelligence in Education*, **35**, 1239-1287. https://doi.org/10.1007/s40593-024-00429-7

[5] 吴秋晨, 白滨. 场域理论视域下高职院校教学数字化转型的关键要素、现实挑战与优化路径[J]. 中国职业技术教育, 2025(21): 69-78.

[6] 王丽娜, 徐新爱. 数智时代数据驱动的学习评价现状与发展研究[J]. 南昌师范学院学报, 2024, 45(3): 116-120.

[7] Balachandar, V. and Venkatesh, K. (2025) A Multi-Dimensional Student Performance Prediction Model (MSPP): An Advanced Framework for Accurate Academic Classification and Analysis. *MethodsX*, **14**, Article ID: 103148. https://doi.org/10.1016/j.mex.2024.103148

[8] 冯翔, 余明华, 马晓玲, 等. 基于大数据技术的学习分析系统架构[J]. 华东师范大学学报(自然科学版), 2014(2): 20-29.

[9] Zhang, X., Zhang, Y., Chen, A.L., Yu, M. and Zhang, L. (2025) Optimizing Multi Label Student Performance Prediction with GNN-TINet: A Contextual Multidimensional Deep Learning Framework. *PLOS ONE*, **20**, e0314823. https://doi.org/10.1371/journal.pone.0314823

[10] Saqr, M., López-Pernas, S., Törmänen, T., Kaliisa, R., Misiejuk, K. and Tikka, S. (2025) Transition Network Analysis: A Novel Framework for Modeling, Visualizing, and Identifying the Temporal Patterns of Learners and Learning Processes. *Proceedings of the* 15*th International Learning Analytics and Knowledge Conference*, Dublin, 3-7 March 2025, 351-361. https://doi.org/10.1145/3706468.3706513