

基于可解释动态集成学习的泵管内混凝土输运非稳态智能评估方法

赵国欣^{1,2}, 唐昀超³, 万 帅⁴, 陈 犇⁵, 陈 正^{1,2}

(1. 广西大学土木建筑工程学院, 南宁 530004; 2. 广西大学广西防灾减灾与工程安全重点实验室, 南宁 530004; 3. 广东省城市生命线工程智能防灾与应急技术重点实验室, 东莞理工学院, 广东 东莞 523000; 4. 新疆大学机械工程学院, 乌鲁木齐 830049; 5. 中国电建集团华东勘测设计研究院有限公司, 杭州 311100)

摘 要: 针对长距离混凝土泵送过程中流变非稳态特征显著、极易诱发堵管灾变, 且传统物理监测预警滞后、工程现场故障样本严重稀缺等行业痛点, 本工作提出了一种基于可解释动态集成学习的泵管内混凝土输运非稳态智能评估新方法。依托大跨径钢管混凝土拱桥灌注工程, 自主研发高频压力传感系统以获取多维泵压时程序列; 深度融合流变学物理先验知识, 提取了斜率、标准差及极差等表征流变阻力演化的时域统计特征参量。针对故障工况导致的极端类别不平衡难题, 引入合成少数类过采样技术重构特征空间数据分布, 有效破除模型训练偏倚。在此基础上, 构建基于贝叶斯优化的动态自适应集成学习架构对泵送演化态进行高精度感知。实验结果表明: 所提动态自适应集成模型有效克服了非平衡数据陷阱, 在测试集上的总体预测准确率达 0.92。特别是对“压力累积”与“堵管”两类极危演化态的识别准确率分别提升至 91.43% 和 88.00%, 显著优于单一基模型及传统投票策略。此外, 引入沙普利加性解释方法深度解构模型决策黑箱, 证实泵压变化曲线斜率为判定堵管状态的核心主导特征, 其演化规律与管内摩阻及流变阻力机制高度吻合, 赋予了数据驱动模型清晰的物理合理性。本工作成功验证了基于时序特征非侵入式监测的可行性, 有效破解了小样本故障工况下的漏报难题, 为功能型水泥基材料的智能化施工、早期预警调控及人工智能落地应用提供了可靠的理论与技术支撑。

关键词: 混凝土泵送; 时序特征空间; 动态集成学习; 可解释人工智能; 非平衡数据重构; 输运非稳态

中图分类号: TQ745 文献标志码: A 文章编号: 0454-5648(2026)08-2602-12

网络出版时间: 2026-07-10



混凝土泵送技术凭借其施工连续性强、输送效率高、显著优势, 已广泛应用于大跨径钢管混凝土拱桥及高层建筑等重大工程中^[1]。然而, 在长距离或复杂管路泵送工况下, 受材料流变性能波动、管路空间拓扑结构以及泵送工艺参数等多源因素的深度耦合影响, 管内混凝土的输运状态常呈现出强烈的非稳态特征。这种流变行为的不稳定性极易诱发管内阻力异常突增, 进而演变为堵管事故^[2-4]。堵管不仅导致混凝土浇筑被迫中断、造成严重的工期延误与经济损失, 其高压状态下的疏通作业更伴随管路爆裂等严峻的安全隐患^[5]。因此, 探索并建立一套能够实时感知、准确定量评估泵管内混凝土非稳态输运特征的智能监测方法, 对于保障施工安全与提升工程质量具有重要的现实意义。

纵观当前工程实践与理论研究, 工程现场对混

凝土泵送状态的监测与管控主要涵盖“传统物理监测”与“人工智能驱动的数据监测”两大技术流派。在传统物理监测范畴, 早期探索多侧重于事后处置与经验性管理优化, 如王安肖等^[6]通过质量管理活动优化堵管后的处置流程, 康真等^[7, 8]则依托贝叶斯网络识别宏观风险因子。为实现过程动态监测, 杜婷等^[9]与王本武^[10]尝试利用管壁振动信号或应力反演流态, 但史青录等^[11]指出, 泵车臂架复杂的机械振动背景噪声极易湮灭微弱的流体特征, 导致极高的误报率。相较之下, 管内直测压力信号被广泛认为是反映流变阻力演化的最直接参量。在此基础上, Shen 等^[12]、李富民^[13]与徐支松等^[14]建立流变参数与压力损失的映射关系, 侯象煜等^[15]、高艳玲等^[16]与闫乃晴等^[17]则针对不同工程场景研发了压力采集系统。然而, 上述基于物理信号的监测策

收稿日期: 2026-02-28。 修订日期: 2026-03-14。

基金项目: 国家自然科学基金面上项目(52478242); 广西科技重大专项(桂科 AA23073017)。

第一作者: 赵国欣(1999—), 男, 博士研究生。

通信作者: 陈 正(1982—), 男, 博士, 教授。

Received date: 2026-02-28. Revised date: 2026-03-14.

First author: ZHAO Guoxin (1999—), male, Doctoral candidate.

E-mail: guoxinzha@st.gxu.edu.cn

Correspondent author: CHEN Zheng (1982—), male, Ph.D, Professor.

E-mail: chenzheng@gxu.edu.cn

略普遍受限于“静态阈值判别”的传统思维——即仅当压力峰值突破安全红线时才触发报警。事实上,混凝土堵管本质上是一个流变阻力渐进累积的动态过程,在“正常状态”与“彻底堵塞”之间存在着一段关键的“压力累积”演化中间态。静态阈值法割裂了这一连续的演化链条,导致预警存在严重滞后性,难以在拥堵初期实施前置干预,极易错失最佳疏通时机。

近年来,以机器学习为核心的数据驱动方法凭借其强大的高维特征挖掘能力,在工程监测交叉领域展现出变革性潜力^[18-23]。目前相关人工智能(Artificial Intelligence, AI)赋能研究主要聚焦于材料流变性能预测与设备参数调控2个维度^[24-27]。在流变预测方面,大量学者开发了基于基因表达式编程(Gene Expression Programming)、极端梯度提升(eXtreme Gradient Boosting, XGBoost)、高斯过程回归(Gaussian Process Regression)、多层感知器神经网络(Multilayer Perceptron Neural Network)和径向基函数神经网络(Radial Basis Function Neural Network)等架构的预测模型^[28-30]。Coenen等^[31]及Shen等^[12]进一步利用卷积神经网络(Convolutional Neural Network)、长短期记忆网络(Long Short-Term Memory)等深度网络建立了材料组分、搅拌扭矩与流变指标的映射关联。然而,此类研究多服务于配合比设计或浇筑前的数值估算,难以高频实时地反馈长距离输运过程中的非稳态波动。在智能优化维度,饶红艳等^[32]、殷志强^[33]与肖时耀^[34]着力于利用智能算法对泵车功率进行动态匹配与调试,其核心诉求在于机械效能的提升而非流体物态的识别。在极少数涉及波形分析的前沿探索中,熊慎等^[35]虽尝试引入聚类算法进行波形无监督识别,但此类方法难以输出具有明确物理安全含义的确定性状态标签,难以直接赋能工程决策。尽管现有AI技术取得了一定进展,但要真正实现泵送非稳态的泛在智能感知,仍须跨越三大核心技术挑战:1) 状态刻画的二元化缺陷,现有研究多将工况简单对立为“正常”与“堵塞”,剥离了“压力累积”这一关键孕灾过渡态,致使模型缺乏早期捕捉能力,阻碍了从“事后识别”向“事前预警”的方法跨越;2) 极端类别不平衡引发的多数类陷阱,海量实测数据中正常样本占据绝对主导,稀缺的故障样本极易被传统分类模型(如标准投票法)边缘化,导致模型对异常工况的识别精度与召回率严重缩水;3) 预测精度与可解释性的深度矛盾,传统知识驱动模型虽具有物

理透明性但拟合能力受限,而高精度的前沿集成模型却深陷“黑箱”泥沼,缺乏表征流变规律的可解释性,严重制约了其在工程一线的推广互信。

针对上述技术瓶颈,本工作面向功能型水泥基材料智能建造的实际需求,提出了一种基于可解释动态集成学习的泵管内混凝土输运非稳态智能评估新方法。该方法深度融合了流变学物理机理与前沿机器学习架构,旨在从底层算法逻辑上攻克数据不平衡与早期预警缺失的行业难题。首先,依托大跨径钢管拱桥实测高频泵压时程序列,结合流变动力学先验知识,提取出斜率、标准差及极差等表征流变阻力演化的时域统计特征参量;其次,前瞻性地引入合成少数类过采样技术(Synthetic Minority Over-sampling Technique, SMOTE),逆向重构训练集的特征空间分布,有效破除了因故障样本稀缺诱发的模型训练偏倚;在此基础上,创新构建了基于贝叶斯优化的动态自适应集成融合架构。该架构可精准捕捉不同基模型在异构样本上的预测置信度差异并进行动态赋权,突破了传统硬/软投票机制的性能上限,实现了对正常态、压力累积预警态及堵管灾变态的高保真精准解耦。此外,本工作创造性地将沙普利加性解释方法(SHapley Additive exPlanations, SHAP)引入模型评估闭环,从数据驱动视角全景式解析了核心特征对泵送状态决策的驱动逻辑,验证了其与实际流变阻力机制的物理一致性。本工作不仅为长距离混凝土泵送提供了一套高精度、强鲁棒的非侵入式智能预警方案,也为复杂工况下的小样本故障诊断与可解释AI应用落地提供了可靠的理论依据与技术方法。

1 实验

针对长距离混凝土泵送过程中流变状态非稳态特征显著、且现场实测数据易受机械噪声干扰及故障样本稀缺等共性难题,本工作构建了一套融合物理机理特征与数据驱动算法的智能评估框架。如图1所示,该技术路线主要由数据感知与特征工程、特征空间分布重构以及动态自适应集成模型构建3个核心环节有机串联而成。首先,依托实测工程采集高频泵送压力时序信号,基于流变学机理提取表征流体阻力演化的斜率、标准差及极差等关键物理特征;其次,引入SMOTE算法重构特征空间分布,消除类别不平衡导致的数据偏倚;最后,结合贝叶斯超参数寻优与动态自适应集成融合策略,实现对泵送非稳态的高精度识别。




图1 混凝土泵送状态智能评估技术路线图

Fig. 1 Technical route of intelligent evaluation for concrete pumping state

1.1 实验与数据获取

1.1.1 工程概况与泵送工艺 本工作依托广西正龙红水河特大桥主拱肋管内混凝土灌注工程开展。该桥主桥全长 316 m，计算跨径 305 m，拱肋采用钢管混凝土桁架式结构。单片拱肋包含 4 根主弦管(全桥共 8 根)。主弦管管径(φ)为 1100 mm，壁厚分布为 20~24 mm。管内核心混凝土采用 C60 自密实微膨胀混凝土，单根拱肋平均灌注量约为

306.79 m³。主弦管混凝土灌注采用多级接力顶升泵送工艺，以应对长距离输运过程中的流变阻力损耗，确保钢管内混凝土的密实度与均匀性。单根拱肋钢管在半跨范围内设置 2 处进浆支管，灌注过程遵循对称加载、均衡输送的原则，利用泵车压力将高性能混凝土由拱脚向拱顶连续顶升，期间无须振捣。单侧拱肋灌注工艺示意图如图 2 所示。




图2 正龙红水河特大桥及其单侧拱肋管内混凝土分段灌注示意图

Fig. 2 Schematic diagram of the Zhenglong Hongshui River Bridge and segmental concrete filling in a single arch rib tube

1.1.2 泵压数据采集系统设计 为高频、高信噪比地获取管内流变阻力信号, 本工作自主设计了一套嵌入式压力动态监测系统, 如图 3 所示。该系统选用标准 D125 无缝高压泵管截取的 0.5 m 短节作为载体, 在管壁预制孔径为 26 mm 的安装孔, 采用嵌入式焊接工艺接入高频动态压力传感器, 确保感应面与内壁完全平齐, 以消除边界流场涡流干扰并杜绝漏气漏浆现象。传感器支持最高 600 Hz 采样频率, 量程为 $-0.1\sim 60.0$ MPa, 响应时间 2 ms, 精度等级 0.1%满量程(Full Scale, FS), 可敏锐捕捉微弱的动态流态突变。系统部署于泵车尾部后 1 m 处的直管段, 传感器采集的时序信号经无线采集仪传输至计算机进行实时存储与分析, 从而精准刻画泵送系统的出口压力时序特征。

上述设备安装在泵车尾部后 1 m 处的泵管直管段上, 整体立面示意图见图 4, 该位置流态相对稳定, 能准确反映泵送系统的出口压力特征。

1.1.3 泵送压力数据介绍与状态定义 泵压时

序数据包含显著的周期性机械脉动特征, 如图 5 所示。由于 S 管分配阀换向诱发的压力骤降段不反映实际流变阻力, 因此在特征工程预处理阶段将其作为非稳态机械噪声予以剔除, 严格保留主油缸推进阶段的有效持压信号。结合现场施工日志与实测时序波形, 本工作从流变物理机制出发界定了 3 种关键输运演化态。其中, 正常状态表现为泵送连续平稳,




图 3 混凝土泵送压力监测设备图

Fig. 3 Concrete pumping pressure monitoring equipment




图 4 混凝土泵送压力监测设备安装图

Fig. 4 Installation diagram of concrete pumping pressure monitoring equipment




图 5 泵送过程测到的泵压数据示例

Fig. 5 Example of pumping pressure data measured during the pumping process

单冲程内压力波动较小且峰值处于额定范围内, 表征流变性良好与阻力稳定; 压力累积状态(预警态)表现为相邻多个冲程周期压力峰值呈阶梯式单调上升, 表征管内摩阻力异常增益, 是发生堵管事故的核心前兆特征; 堵管状态(灾变态)则表现为压力急剧飙升, 波形呈现触顶直线或剧烈的不规则高频振荡, 并常伴随主油缸憋压, 表征管路已被完全阻塞。经时序切片与去噪处理, 提取各推进持压过程的斜率、标准差及极差作为特征变量, 受限工程现场难以同步获取瞬时管内真实流速, 精确推导流变摩阻系数存在困难, 因此本工作采用这 3 个时域统计参量作为流变状态的宏观替代变量。在主油缸恒速推进

的假定下,压力曲线的斜率可直接表征管内流变摩擦阻力的瞬态增长速率;而标准差与极差则用于定量表征管壁润滑层的稳定性与宏观流态的紊乱程度。基于上述赋予了物理内涵的特征变量,最终构建了包含 691

个多维样本的原始验证数据集,其中包含正常样本 541 个(标记为 0 类样本)、压力累积样本 88 个(标记为 1 类样本)及堵管样本 62 个(标记为 2 类样本),表 1 展示了整体数据集的描述性统计表。

表 1 数据集描述性统计表
Table 1 Descriptive statistics of the dataset

Variable	Count	Mean	Std.	Min	25%	50%	75%	Max
Label	691	0.307	0.627	0	0	0	0	2.000
X1	691	0.182	0.675	-0.277 0	-0.007	0.004	0.034	4.725
X2	691	0.437	2.112	0.000 2	0.001	0.003	0.007	22.690
X3	691	0.749	1.811	0.050 0	0.160	0.220	0.450	12.710

Note: Variable: variable name (including dependent variable Label and independent variables X1, X2, X3); Count: number of observations; Mean: arithmetic mean; Std.: standard deviation; Min: minimum value; 25%, 50%, 75%: 25th, 50th (median), and 75th percentiles; Max: maximum value.

1.2 机器学习模型

1.2.1 集成模型 针对混凝土泵送压力信号中潜藏的高维非线性边界及现场环境引入的随机噪声干扰,单一分类模型在处理时变特征域时难以兼顾偏差与方差,泛化鲁棒性受限。集成学习通过组合多个弱分类器,利用模型间的特征互补性显著提升决策边界的刻画精度。针对堵管异常样本极高的敏感度要求,基于串行迭代策略的 Boosting 架构在挖掘此类不平衡结构化数据特征时表现更优。以梯度提升决策树(Gradient Boosting Decision Tree, GBDT)为例(图 6 展示了 GBDT 的原理示意图),其本质是加法模型与前向分布算法的结合。该算法摒弃了传统优化算法直接在该参数空间中搜索最优解的方式,而是通过迭代地训练决策树来拟合前一轮模型的负梯度,即残差的近似值。在数学表达上,假设经过 $m-1$ 轮迭代后的强学习器为 $F_{m-1}(x)$,则第 m 轮的目标是找到一个基学习器 $h_m(x)$,使得整体目标函数 L 最小化,其加法模型可表示为式(1)。

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x) \quad (1)$$

式中: x 为输入的特征向量; $h_m(x)$ 为第 m 棵决策树的预测结果; γ_m 为该树的权重系数。为了使模型沿着损失函数下降最快的方向更新,算法利用损失函数 $L(y, F(x))$ 关于当前模型 $F_{m-1}(x)$ 的负梯度作为残差的近似值。对于第 i 个样本,其负梯度计算公式如式(2)所示。

$$r_{mi} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F_m(x) = F_{m-1}(x)} \quad (2)$$

在此基础上,第 m 棵决策树拟合上述残差 r_{mi} ,并通过线性搜索确定最优步长 γ_m ,从而实现模型预测偏差的逐级修正。这种基于梯度的提升策略使得模型能够深入挖掘泵压时程信号特征中非线性的复

杂边界,从而有效区分正常泵送状态与异常状态。




图 6 GBDT 模型原理示意图

Fig. 6 Schematic diagram of the GBDT model principle

1.2.2 动态自适应集成融合架构 模型融合是突破单体算法分类性能上限的核心策略。传统的硬投票法忽略基分类器的预测置信度差异,极易受低精度模型误判影响;而软投票法采用的全局等权重策略则无法捕捉基模型在不同样本空间的局部拟合优势。为此,本工作构建了一种动态自适应集成融合架构,摒弃静态固定权重分配,转而每个待测样本精准计算各基模型的动态融合权重。

该方法首先获取所有基模型对样本的三分类概率分布,随后针对每个样本,将各基模型的三分类概率最大值作为其预测置信度,对置信度归一化得到样本专属动态权重。然后,基于动态权重加权融合各基模型概率分布,取加权概率和最大类别为样本最终预测结果,对整个数据集所有样本依次执行该流程,并结合分类性能指标验证方法有效性。

以三分类任务为例，设包含 k 个基模型、预测类 $j=1, 2, 3$ ，式(3)为基模型置信度的计算过程。

$$\text{conf}_i = \max(p_{i,1}, p_{i,2}, p_{i,3}) \quad (3)$$

式中： $p_{i,j}$ 为第 i 个基模型对样本预测为第 j 类的概率； conf_i 为其置信度。其次计算含除零保护的动态权重[式(4)]。

$$w_i = \frac{\text{conf}_i}{\sum_{i=1}^k \text{conf}_i + e - 8} \quad (4)$$

式中： w_i 为第 i 个基模型动态权重(满足 $\sum_{i=1}^k w_i = 1$)；

$e-8$ 为避免除零错误。最后完成加权融合与预测[式(5)和式(6)]。

$$S_j = \sum_{i=1}^k w_i \cdot p_{i,j} \quad (5)$$

$$\hat{y} = \arg \max_{j=1,2,3} S_j \quad (6)$$

式中： S_j 为第 j 类加权概率和； $\hat{y}$ 为最终预测类别(即 S_j 最大值对应的类别)。

该机制有效兼顾了多源基模型在异构样本上的性能差异，实现了样本级自适应的高保真度融合判别。

1.3 数据重采样

在实际施工采集的海量工程数据中，堵管及压力累积等异常工况属于低频事件，导致实测数据集呈现极端的类别不平衡特性。本工作构建的原始样本集中正常状态占比达 78.3%，若直接基于该偏态分布驱动模型训练，分类器会过度倾向多数类以获取整体准确率的表面提升，造成对少数类异常特征的严重欠拟合与漏报。为从数据输入端阻断偏倚，

本工作引入 SMOTE 算法对特征空间进行过采样重构。该算法避免了简单随机复制带来的过拟合问题，基于特征空间的线性插值衍生新的少数类样本。对于少数类的目标样本 x_i ，计算其在特征空间中的 K 个近邻。从这 K 个近邻中随机选取 1 个样本 $\hat{x}_i$ ，并在 x_i 和 $\hat{x}_i$ 的连线上随机选取 1 个点作为新合成的样本 x_{new} ，其数学表达式为：

$$x_{\text{new}} = x_i + \text{rand}(0,1) \times (\hat{x}_i - x_i) \quad (7)$$

通过特征空间的插值重构，在维持原始特征分布规律的前提下增加了异常状态的样本密度，使各类样本比例达到相对平衡。此策略促使模型在训练过程中同等关注正常与异常工况的决策边界，显著提升了对早期堵管征兆的识别灵敏度。

2 模型构建与性能评估

2.1 基模型预测性能及超参数优化

为构建高精度的泵送状态识别框架，本工作首先选取工程分类任务中典型的机器学习算法作为候选基模型，包含逻辑回归(Logistic Regression, LR)、支持向量机(Support Vector Machine, SVM)以及基于决策树的集成模型，如随机森林(Random Forest, RF)、XGBoost、轻量级梯度提升机(Light Gradient Boosting Machine, LightGBM)和 GBDT。在初筛阶段，为客观评估各算法对泵送压力特征变量的捕捉能力，所有模型均基于默认参数配置进行训练。表 2 展示了各模型在默认参数下的预测值和最终的评估指标。测试结果表明，线性分类器难以有效拟合泵送状态与特征间复杂的非线性映射关系，各项指标显著偏低；SVM 模型虽然总体准确

表 2 各基模型在默认参数下的评估指标

Table 2 Performance evaluation metrics of base models under default parameters

Metric	Evaluation indicator	Base model					
	Label	LR	SVM	RF	XGBoost	LightGBM	GBDT
Precision	Class 0	0.89	0.86	0.96	0.96	0.98	0.95
	Class 1	0.63	0.67	0.72	0.66	0.62	0.70
	Class 2	0.59	1.00	0.70	0.77	0.67	0.77
	Macro avg	0.70	0.84	0.79	0.80	0.76	0.81
Recall	Class 0	1.00	1.00	0.90	0.92	0.90	0.93
	Class 1	0.37	0.11	0.69	0.73	0.69	0.66
	Class 2	0.56	0.72	0.70	0.78	0.74	0.75
	Macro avg	0.64	0.61	0.76	0.81	0.78	0.78
F1	Class 0	0.94	0.92	0.93	0.94	0.94	0.94
	Class 1	0.47	0.19	0.70	0.69	0.65	0.68
	Class 2	0.57	0.84	0.70	0.77	0.70	0.76
	Macro avg	0.66	0.65	0.78	0.80	0.76	0.79
Accuracy		0.75	0.82	0.82	0.84	0.81	0.83

率尚可，但在少数类异常工况(压力累积与堵管)的召回率上表现出明显波动，说明其对类别不平衡较为敏感且鲁棒性不足。相比之下，4 种基于决策树的集成模型凭借强大的特征组合与非线性边界划分能力，在关键评估指标上均表现优异。

基于初筛评估，本工作优选 RF、XGBoost、LightGBM 和 GBDT 作为构建模型融合层的基分类器，并实施数据与参数双重优化策略以进一步挖掘其性能潜力。在数据层面，针对训练集存在的类别不平衡问题，采用 SMOTE 算法进行过采样处理，通过在特征空间插值生成少数类样本，使各类训练样本比例达到平衡，同时确保测试集保持严格独立，以客观验证泛化能力。在参数层面，摒弃低效的传统网格搜索，采用基于树结构 Parzen 估计器(Tree-structured Parzen Estimator, TPE)的贝叶斯优化算法对 4 种基模型进行超参数寻优。该过程以宏平均 F1 值(Macro-F1 Score, Macro-F1) 分数为目标函数，通过构建概率代理模型高效逼近全局最优解，其具体配置如表 3 所示。优选 4 个基模型在最优超参数配置下的评估指标如表 4 所示，经重采样和参数寻优后，4 种基模型在测试集上的预测性能均获得了实质性提升。

表 3 优选 4 个基模型的超参数配置

Table 3 Hyperparameter configurations of the four selected base models

Base model	Hyperparameter	Value
RF	Max depth	15
	Min sample leaf	1
	Min sample	4
	N estimators	199
XGBoost	Learning rate	0.061 9
	Max depth	4
	N estimators	200
	Subsample	1.0
LightGBM	Learning rate	0.221 0
	Min child samples	5
	N estimators	50
	Num leaves	15
GBDT	Learning rate	0.218 7
	Max depth	7
	N estimators	56
	Subsample	0.746 6

2.2 动态自适应集成融合框架性能对比与评估

为进一步突破单一基模型的性能瓶颈并降低预测误差，本工作在优选的 4 个基模型之上构建了模型融合层，并分别对比了软投票(Soft Voting)、硬投票(Hard Voting)与本工作提出的动态自适应集成

融合策略的预测性能。表 5 展示了 3 种投票法的预测性能指标，传统的硬投票与软投票法虽然通过少数服从多数或概率平均机制在一定程度上提升了模型鲁棒性，将总体预测准确率稳定在 0.90 左右，但在处理类别不平衡的安全预警数据时仍存在明显局限。本工作提出的动态自适应融合策略，凭借根据验证集表现动态分配权重的机制，将总体准确率提升至 0.92，展现出更优异的泛化性能。

表 4 优选 4 个基模型的在最优超参数配置下的评估指标

Table 4 Performance metrics of the four selected base models under optimal hyperparameters

Metric	Evaluation indicator	Base model			
	Label	RF	XGBoost	LightGBM	GBDT
Precision	Class 0	0.96	0.96	0.97	0.96
	Class 1	0.73	0.68	0.64	0.78
	Class 2	0.72	0.77	0.73	0.77
	Macro avg	0.8	0.8	0.78	0.84
Recall	Class 0	0.91	0.92	0.92	0.95
	Class 1	0.73	0.8	0.72	0.69
	Class 2	0.7	0.8	0.75	0.80
	Macro avg	0.78	0.84	0.80	0.81
F1	Class 0	0.93	0.94	0.94	0.96
	Class 1	0.73	0.74	0.68	0.73
	Class 2	0.71	0.78	0.74	0.78
	Macro avg	0.79	0.82	0.79	0.82
Accuracy		0.85	0.85	0.82	0.84

表 5 3 种投票法的预测性能指标

Table 5 Prediction performance metrics of three voting methods

Metric	Evaluation indicator	Base model		
	Label	Soft voting	Hard voting	Dynamic adaptive voting
Precision	Class 0	0.98	0.98	1.00
	Class 1	0.66	0.64	0.71
	Class 2	0.69	0.73	0.76
	Macro avg	0.78	0.78	0.82
Recall	Class 0	0.93	0.93	0.93
	Class 1	0.83	0.80	0.91
	Class 2	0.72	0.76	0.88
	Macro avg	0.83	0.83	0.91
F1	Class 0	0.95	0.95	0.96
	Class 1	0.73	0.71	0.80
	Class 2	0.71	0.75	0.81
	Macro avg	0.80	0.80	0.86
Accuracy		0.90	0.90	0.92

图 7 展示了 3 种投票法的混淆矩阵图像，其中分类 0、1、2 分别代表了正常、压力累积和堵管 3 种泵送状态。进一步剖析混淆矩阵结果可知，动态自适应投票法在工程安全核心关注的异常演化态




图 7 3 种投票法的混淆矩阵图
Fig. 7 Confusion matrices of three voting methods

识别上, 其准确率与召回率显著优于传统融合方法。在 217 组正常状态测试中, 受多数类庞大基数的主导, 3 种投票法表现相近, 这也正是导致各模型总体准确率数值差异较小的直接原因; 然而, 在 35 组压力累积状态测试中, 硬投票与软投票法的召回率仅为 80.00% (28 组) 和 82.86% (29 组), 存在较多高危漏报, 而动态自适应法成功识别出 32 组, 召回率提升至 91.43%。在最具工程危险性的 25 组堵管状态测试中, 动态自适应法的召回率达到 88.00% (22 组), 显著领先于软投票法的 76.00% (19 组) 和硬投票法的 72.00% (18 组)。实验数据充分证明, 动态自适应融合机制能够有效克服非平衡

数据评估中“总体精度虚高”的多数类陷阱。尽管该方法在总体准确率上仅提升了约 2%, 但其在“压力累积”状态的召回率上相对提升了 10.3%, 在“堵管”状态的召回率上相对提升高达 15.8%。这表明改进模型显著提高了对少数类样本的预测性能, 大幅降低了关键故障工况的漏报风险, 在实际工程现场安全预警中相比传统方法具有更高的应用价值。


2.3 基于 SHAP 的模型的特征解释与讨论

为探究集成模型的内部决策依据, 揭示关键特征对泵送状态判定的驱动机制, 本工作基于动态自适应投票法的预测结果, 构建了 SHAP 值可视化分析框架, 分别从全局和局部角度进行了详细的特征解释分析。

图 8 展示了全局视角下各类特征变量对模型预测的影响机制。由图 8 可见, 模型分别以 3 种类别作为“正类”时, 特征重要性排序结果一致, 对模型决策影响最大的特征依次为斜率(X1)、极差(X3)与标准差(X2)。以最极端的堵管状态(图 8c)为例, 当 3 个特征变量取值突然变大时(对应红色散点), 此时管压力突然增大, 压力值的离散程度亦随之变大, 此时模型倾向于将样本预测为“堵管”状态。反观图 8a, 3 个特征变量取值较小时(对应蓝色散点), 对应 SHAP 值为正值, 表明此时模型倾向于将样本预测为“正常”状态。而在图 8b 中, 纵坐标右侧蓝色散点中出现紫色散点, 这表明当 3 个特征变量逐渐变大时, 管内压力逐渐增大, 模型倾向于将样本预测为“压力累积”状态。另外值得一提的是, 模型处理多分类问题时通常采用“一对多”(One vs. Rest)策略, 将“压力累积”状态视为正类时, 其余所有类别均被视为负类, 因此纵坐标左侧同时出现了红色和蓝色散点。上述分析过程和工程流变学认知具有一致性, 这反映了 SHAP 分析结果具有一定的物理合理性。

在局部视角下对单样本进行预测时, SHAP 框架中的瀑布图可对模型决策过程进行详细解释。以测试集中第 5 个样本为例, 图 9 给出了该样本对应的瀑布图。该样本的实际预测类别为 0 类, 由图 9 可知, 本次预测中对模型决策影响最大的特征依次为 X2、X1 与 X3。其中, X2 与 X1 对模型决策起正向推动作用, SHAP 值分别为 +0.21 与 +0.20, 表明二者倾向于将该样本判定为 0 类, 且 SHAP 绝对值越大, 对模型决策的贡献程度越高。X3 则对模型预测起负向作用, 即倾向于不将该样本判定为 0


类, 其 SHAP 值为-0.06, 对模型决策的影响相对较小。



Note: X1 is slope; X2 is standard deviation; X3 is range.

图 8 SHAP 分析可视化图像

Fig. 8 SHAP analysis visualization



Note: $E[f(X)]$ is the baseline expected value of the model, and $f(X)$ is the final predicted value of the model for the current sample.

图 9 测试集中第 5 个样本对应瀑布图

Fig. 9 Waterfall plot for the fifth sample in the test set

上述分析从全局与局部 2 个角度, 对模型预测结果进行了较为详尽的特征解释, 且相关解释与领域知识、工程经验及物理认知相一致, 具备良好的物理合理性。然而, 仅依靠领域知识验证 SHAP 分析结果的合理性尚不充分, 若要判断其是否对应客观世界中的真实因果关系, 仍需进一步通过实践加以验证。受限于本工作实验规模较大, 且受现场工况、设备调配等多方面条件约束, 难以在实际工程

中开展多次灵活验证, 这也是本工作目前存在的不足。在后续研究中, 若能获取多场景下的实测数据并开展工程验证, 且实际结果与 SHAP 框架所得结论一致, 则可进一步证明相关结论符合客观物理因果关系。

3 结论

本工作针对混凝土长距离泵送过程中流变非稳态识别困难及故障样本稀缺的工程痛点, 提出了一种基于可解释动态集成学习的智能评估方法。通过大跨径钢管拱桥实测数据验证与多维度剖析, 得出主要结论如下:

1) 验证了时序物理特征对管内输运非稳态的表征能力。结合流变动力学机理, 从泵压时程序列中提取的斜率、标准差及极差等时域特征, 能够有效映射混凝土流体阻力与流动稳定性的动态演化。依托该特征空间构建的动态自适应集成模型, 在独立测试集上实现了 0.92 的总体预测准确率, 证实了利用外部高频压力信号进行管内状态非侵入式感知的高效性与可行性。

2) 攻克了极端类别不平衡下的小样本故障预警难题。针对现场实测数据中正常状态样本占据绝对主导(高达 78.3%)、而异常工况极度稀缺(仅占 21.7%)的偏态分布瓶颈, 本工作引入 SMOTE 技术逆向重构训练集的特征空间分布, 从底层有效消除了分类器对多数类样本的训练偏倚。辅以基于 TPE 的贝叶斯超参数寻优, 最大化释放了基模型的特征捕获潜能, 为解决实际工程中小样本异常诊断提供了可靠的数据预处理路径。

3) 论证了动态自适应集成架构在降低高危漏报率方面的核心优势。创新的动态自适应融合架构精准捕捉了不同基模型在异构样本上的预测置信度差异并进行动态赋权。在测试集验证中, 该架构对“压力累积预警态”与“堵管灾变态”的识别召回率分别提升至 91.43% (识别 32/35 组)和 88.00% (识别 22/25 组); 相较于传统软投票法(82.86%和 76.00%)与硬投票法(80.00%和 72.00%), 相对提升比例达 15.8%, 显著降低了极端险情的漏报率, 为防范泵送灾变提供了充裕的前置干预窗口。

4) 实现了模型决策逻辑的白盒化解析与物理一致性验证。借助 SHAP 归因分析全景式解构了集成模型的内部决策黑箱, 明确了泵压演化曲线的斜率骤增是触发堵管判定的绝对主导特征。这一纯数据驱动淬炼出的决策逻辑, 与管道阻塞导致流变摩

阻急剧升高的真实物理规律高度契合,使原本的黑箱模型具备清晰的物理合理性,为AI前沿技术在功能型水泥基材料智能建造中的推广互信奠定了坚实的理论基础。

参考文献:

- [1] 阎培渝,黎梦圆,韩建国,等.新拌混凝土可泵性的研究进展[J].硅酸盐学报,2018,46(2):239–246.
YAN Peiyu, LI Mengyuan, HAN Jianguo, et al. J Chin Ceram Soc, 2018, 46(2): 239–246.
- [2] 元强,李白云,史才军,等.混凝土泵送性能的流变学表征及预测综述[J].材料导报,2018,32(17):2976–2985.
YUAN Qiang, LI Baiyun, SHI Caijun, et al. Mater Rev, 2018, 32(17): 2976–2985.
- [3] LI Z G, CAO G D. Rheological behaviors and model of fresh concrete in vibrated state[J]. Cem Concr Res, 2019, 120: 217–226.
- [4] LI F M, SHEN W K, YUAN Q, et al. An overview on the effect of pumping on concrete properties[J]. Cem Concr Compos, 2022, 129: 104501.
- [5] 徐文,王睿,王勇,等.钢管拱内混凝土超长距离泵送性能[J].硅酸盐学报,2019,47(11):1574–1581.
XU Wen, WANG Rui, WANG Yong, et al. J Chin Ceram Soc, 2019, 47(11): 1574–1581.
- [6] 王安肖,路飞,濮国轩,等.基于QC小组活动的混凝土泵送堵管处理时间控制[J].云南水力发电,2024,40(9):201–204.
WANG Anxiao, LU Fei, PU Guoxuan, et al. Yunnan Water Power, 2024, 40(9): 201–204.
- [7] 康真.基于贝叶斯网络的泵送混凝土泵送质量事故风险管理[D].昆明:昆明理工大学,2023.
KANG Zhen. Risk management of pumped concrete quality accidents based on bayesian networks[D]. Kunming: Kunming University of Science and Technology, 2023.
- [8] 康真,谢洪涛,常凯.基于DEMATEL-ISM的泵送混凝土堵管事故风险因素分析[J].科技和产业,2023,23(6):264–269.
KANG Zhen, XIE Hongtao, CHANG Kai. Sci Technol Ind, 2023, 23(6): 264–269.
- [9] 杜婷,王本武,叶豪,等.混凝土泵送管道振动监测与分析[J].中南大学学报(自然科学版),2020,51(8):2143–2151.
DU Ting, WANG Benwu, YE Hao, et al. J Cent South Univ Sci Technol, 2020, 51(8): 2143–2151.
- [10] 王本武.混凝土泵送管道振动和应力监测及数值模拟研究[D].武汉:华中科技大学,2019.
WANG Benwu. Study on the monitoring and numerical simulation of the vibration and stress of concrete pumping pipe[D]. Wuhan: Huazhong University of Science and Technology, 2019.
- [11] 史青录,赵伟,智晋宁,等.基于刚柔耦合模型的混凝土泵车整机动态稳定性分析[J].中国工程机械学报,2022,20(2):101–106.
SHI Qinglu, ZHAO Wei, ZHI Jinning, et al. Chin J Constr Mach, 2022, 20(2): 101–106.
- [12] SHEN W K, JIANG C X, JIN Z Q, et al. Can concrete pumping pressure be predicted from mixture composition Insights from machine learning on full-scale pumping experiments[J]. Cem Concr Compos, 2026, 167: 106458.
- [13] 李富民.泵送对混凝土性能的影响及泵送压力损失预测研究[D].长沙:湖南大学,2024.
LI Fumin. Influence of pumping on concrete performance and prediction of pumping pressure loss[D]. Changsha: Hunan University, 2024.
- [14] 徐文松,袁世军,刘加平.基于数值模拟的新拌混凝土垂直泵送流动行为[J].建筑材料学报,2024,27(6):551–558.
XU Zhisong, YUAN Shijun, LIU Jiaping. J Build Mater, 2024, 27(6): 551–558.
- [15] 侯象煜,刘苗,殷明厂,等.大跨度拱桥高性能混凝土灌注过程监测[J].公路,2025,70(9):437–443.
HOU Xiangyu, LIU Miao, YIN Mingchang, et al. Highway, 2025, 70(9): 437–443.
- [16] 高艳玲,揭琳峰.混凝土泵车泵送系统数据采集及分析系统研究[J].科技创新与生产力,2022,43(7):133–135.
GAO Yanling, JIE Linfeng. Taiyuan Sci Technol, 2022, 43(7): 133–135.
- [17] 闫乃晴,毕梦雪,陈新春.基于组态软件的混凝土泵车泵送系统质量控制[J].工程机械,2022,53(8):118–121.
YAN Naiqing, BI Mengxue, CHEN Xinchun. Constr Mach Equip, 2022, 53(8): 118–121.
- [18] 姜占,滕乐,童昕阳,等.人工智能驱动可持续混凝土:方法、机遇、挑战[J].硅酸盐学报,2026,54(3):1016–1031.
JIANG Zhan, TENG Le, TONG Xinyang, et al. J Chin Ceram Soc, 2026, 54(3): 1016–1031.
- [19] TIAN Q, ZHOU J, HOU J W, et al. Building the future: Smart concrete as a key element in next-generation construction[J]. Constr Build Mater, 2024, 429: 136364.
- [20] 郭孟环,谢咏菲,周英武,等.基于多目标靶向性能的超高韧性地聚物复合材料智能化设计[J].硅酸盐学报,2026,54(3):823–841.
GUO Menghuan, XIE Yongfei, ZHOU Yingwu, et al. J Chin Ceram Soc, 2026, 54(3): 823–841.
- [21] 陈育,胡少伟,田铎如,等.基于压电智能骨料的微粒混凝土板裂缝监测研究[J].传感技术学报,2026,39(1):16–25.
CHEN Yu, HU Shaowei, TIAN Xinru, et al. Chin J Sens Actuat, 2026, 39(1): 16–25.
- [22] 马衍轩,于霞,徐亚茜,等.智能纤维混凝土的力场损伤响应、监测与修复研究进展[J].材料导报,2021,35(19):19081–19090.
MA Yanxuan, YU Xia, XU Yaqian, et al. Mater Rev, 2021, 35(19): 19081–19090.
- [23] 吕余辉,纪豪栋,余倩倩,等.水泥基材料中钢筋腐蚀智能预测与风险分级[J].硅酸盐学报,2026,54(3):947–956.
LYU Yuhui, JI Haodong, YU Qianqian, et al. J Chin Ceram Soc, 2026, 54(3): 947–956.
- [24] KARNAPKE R, MIKHALEV D, COTARDO D, et al. Enhancing performance and increasing safety of concrete pumps through digitalization[C]//2025 IEEE Sensors Applications Symposium (SAS). Newcastle, United Kingdom. IEEE, 2025: 1–6.
- [25] TANG S N, ZHU Y, YUAN S Q. An improved convolutional neural network with an adaptable learning rate towards multi-signal fault diagnosis of hydraulic piston pump[J]. Adv Eng Inform, 2021, 50: 101406.
- [26] HUANG J W, PENG Z W. Study of alarm filtering method based on multivariate process condition data[C]//Proceedings of the 2016 International Conference on Automatic Control and Information Engineering. Hong Kong, China. Atlantis Press, 2016: 156–160..
- [27] REN Y F, BI C Y, LU W W, et al. Research on nonconstant and discontinuous pumping characteristics of the concrete pump truck[J]. Lubricants, 2023, 11(5): 217.
- [28] MORADKHANI M A, HOSSEINI S H, AHMADI M M. Predictive

- analytics for fresh concrete rheological characteristics using artificial intelligence approaches[J]. *Mater Today Commun*, 2024, 41: 110434.
- [29] NAZAR S, YANG J, FAISAL JAVED M, et al. An evolutionary machine learning-based model to estimate the rheological parameters of fresh concrete[J]. *Structures*, 2023, 48: 1670–1683.
- [30] EL MAHDI SAFHI A, DABIRI H, SOLIMAN A, et al. Prediction of self-consolidating concrete properties using XGBoost machine learning algorithm: Rheological properties[J]. *Powder Technol*, 2024, 438: 119623.
- [31] COENEN M, VOGEL C, SCHACK T, et al. Deep Concrete Flow: Deep learning based characterisation of fresh concrete properties from open-channel flow using spatio-temporal flow fields[J]. *Constr Build Mater*, 2024, 411: 134809.
- [32] 饶红艳, 王少杰, 侯亮, 等. 基于改进粒子群优化算法的混凝土泵车全局功率匹配[J]. *东北大学学报(自然科学版)*, 2023, 44(6): 840–848.
- RAO Hongyan, WANG Shaojie, HOU Liang, et al. *J Northeast Univ Nat Sci*, 2023, 44(6): 840–848.
- [33] 殷志强. 泵送过程智能优化及安全决策研究[D]. 常州: 常州大学, 2023.
- YIN Zhiqiang. Research on intelligent optimization and safety decision-making of pumping process[D]. CHangzhou: Changzhou University, 2023.
- [34] 肖时耀. 数据驱动的混凝土泵车人工调试过程的智能识别方法研究[D]. 长沙: 国防科技大学, 2019.
- XIAO Shiyao. Research on concrete pump truck's manual testing process recognition based on data driven method[D]. Changsha: National University of Defense Technology, 2019.
- [35] 熊慎, 冯戈翎, 赵鑫, 等. 基于聚类算法的混凝土泵车泵送压力波形识别方法研究[J]. *建设机械技术与管理*, 2024, 37(5): 18–21.
- XIONG Shen, FENG Geling, ZHAO Xin, et al. *Constr Mach Technol Manag*, 2024, 37(5): 18–21.

作者贡献声明:

赵国欣: 设计论文框架、数据分析、撰写论文

唐昀超: 绘制图表、参与数据分析

万帅: 完善论文框架, 修订论文

陈犇: 实验测试、参与数据分析

陈正: 项目管理、提出研究方向

Intelligent Evaluation Method for Non-Steady Transport State of Concrete in Pump Pipe Based on Interpretable Dynamic Ensemble Learning

ZHAO Guoxin^{1,2}, TANG Yunchao³, WAN Shuai⁴, CHEN Ben⁵, CHEN Zheng^{1,2}

(1. School of Civil Engineering and Architecture, Guangxi University, Nanning 530004, China; 2. Guangxi Key Laboratory of Disaster Prevention and Structural Safety, Guangxi University, Nanning 530004, China, 3. Guangdong Provincial Key Laboratory of Intelligent Disaster Prevention and Emergency Technologies for Urban Lifeline Engineering, Dongguan University of Technology, Dongguan 523000, Guangdong, China, 4. Intelligent Manufacturing Modern Industry College, Xinjiang University, Urumqi 830049, China, 5. Powerchina Huadong Engineering Corporation Limited, Hangzhou 311100, China)

Extended Abstract

Introduction Concrete pumping technology is widely applied in major construction projects. However, under long-distance or complex conditions, concrete transport often exhibits strongly non-steady characteristics due to the coupled factors like material rheology and pipeline topologies. This instability easily induces abnormal resistance surges, evolving into severe blockages. Conventional monitoring relies on post-event management or static pressure thresholds, triggering alarms only when pressure breaches a safety limit. Essentially, concrete blockage is a progressive dynamic accumulation of rheological resistance, leaving a critical “pressure accumulation” intermediate state. Static thresholds ignore this, causing severe pre-warning lag. AI methods show a potential, while intelligent perception faces three challenges, *i.e.*, the binary classification defect overlooking the transitional state, the “majority class trap” from extreme class imbalance, and the contradiction between prediction accuracy and physical interpretability. To address these bottlenecks, this study was to propose a novel intelligent evaluation framework for non-steady concrete transport, deeply integrating rheological mechanisms with advanced machine learning architectures.

Method The research relied on the Zhenglong Hongshui River Bridge project, China. An embedded monitoring system with 600 Hz dynamic pressure sensors was seamlessly welded to the straight pipeline's inner wall near the pump outlet to acquire high-quality rheological resistance signals. During feature engineering, mechanical noises from valve reversing were eliminated, retaining only effective pressure-holding signals during main cylinder propulsion. Since deriving the exact friction coefficient *via* true flow velocity is a challenge in field engineering, macroscopic proxy variables were utilized. Assuming constant propulsion speed, the slope of the pressure curve was extracted to represent the transient growth rate of rheological friction. Standard deviation and range were extracted to quantify slip-layer stability and flow turbulence. To address extreme class imbalance in the 691-sample dataset (78.3% normal), the Synthetic Minority Over-sampling Technique (SMOTE) was applied to reconstruct the feature space, eliminating training bias. Subsequently, four ensemble algorithms (*i.e.*, RF, XGBoost, LightGBM, GBDT) optimized by the Tree-structured Parzen Estimator (TPE) were used as base learners. Finally, a dynamic adaptive ensemble fusion architecture calculated sample-specific dynamic weights based on prediction confidence, replacing conventional static voting mechanisms.

Results and Discussion The extracted time-domain features effectively map the dynamic evolution of in-tube rheological resistance. After SMOTE reconstruction and TPE optimization, the base models' potential to capture minority class abnormal conditions is maximized. During the comparative evaluation of the ensemble models, the study addresses the “accuracy paradox” inherent in highly imbalanced datasets. Conventional soft voting and hard voting models achieve an overall accuracy of approximately 0.90 simply because of the overwhelming majority class, dangerously masking high misdiagnosis rates for critical anomalies. The overall accuracy improves to 0.92 *via* implementing the dynamic adaptive fusion strategy. More importantly, the model substantially suppresses the omission rates for high-risk conditions. The recall rate for the “pressure accumulation” state reaches 91.43%, representing a 10.3% relative improvement over the soft voting method (*i.e.*, 82.86%). For the most hazardous “blockage” state, the recall reaches 88.00%, outperforming the soft voting method (*i.e.*, 76.00%) with a remarkable relative improvement of 15.8%. Furthermore, a SHapley Additive exPlanations (SHAP) visualization framework is introduced to verify the model's decision logic globally and locally. The global feature importance ranking confirms that the pressure curve slope is an absolute dominant feature triggering blockage predictions, followed by range and standard deviation. The SHAP beeswarm summary plots reveal that a sharp increase in these three features heavily biases the model toward a “blockage” decision. Conversely, smaller feature values drive the model toward a “normal” prediction. Local waterfall plots for individual samples further detail the positive and negative contributions of each feature to a specific prediction. This data-driven logic perfectly coincides with the physical reality that pipeline blockages instantly cause a sharp surge in rheological friction and severe dispersion in pressure values due to slip layer disruption. SHAP effectively explains the statistical feature attribution, and its strong alignment with engineering experience proves the model's physical rationality. Verifying strict causality requires a further extensive field validation across multiple complex scenarios.

Conclusions Time-domain physical features validated the ability to characterize in-tube non-steady transport. The slope, standard deviation, and range extracted from high-frequency pressure sequences could serve as effective macroscopic proxies for concrete fluid resistance and slip-layer stability. The combination of SMOTE feature space reconstruction and TPE Bayesian hyperparameter tuning effectively overcome the small-sample fault warning dilemma under extreme class imbalance, eliminating training bias toward majority classes. The dynamic adaptive ensemble architecture demonstrated a core advantage in suppressing high-risk omission rates. It leveraged a minor overall precision increment to drastically reduce crucial fault omission risks *via* tolerating a minimal sacrifice in majority class accuracy, delivering an ample forward-intervention window. The SHAP attribution analysis achieved a white-box deconstruction of the ensemble decision logic. The alignment between the algorithm's reliance on slope surged and the true physical laws of rheological friction endowed the model with clear physical rationality, laying a solid theoretical foundation for the trustworthy application of AI technologies in intelligent civil engineering construction.

Keywords concrete pumping; time-series feature space; dynamic ensemble learning; interpretable artificial intelligence; imbalanced data reconstruction; non-steady transport state