

## 基于融合机器学习方法的机制砂混凝土徐变显式建模

梅生启<sup>1,2</sup>, 武 腾<sup>1,3</sup>, 王兴举<sup>2</sup>, 程相旭<sup>3</sup>, 刘 哲<sup>3</sup>, 李星艳<sup>3</sup>, 李雪峰<sup>3</sup>

(1. 省部共建交通工程结构力学行为与系统安全国家重点实验室, 石家庄 050043;

2. 石家庄铁道大学交通运输学院, 石家庄 050043; 3. 石家庄铁道大学土木工程学院, 石家庄 050043)

**摘 要:** 针对既有混凝土徐变模型在多源机制砂混凝土徐变数据的适用性不足问题, 提出了一种融合机器学习的机制砂混凝土徐变显式建模方法, 用以提升模型精度和增强结构可解释性。首先, 收集了 81 组机制砂混凝土徐变试验数据, 评估了现有模型(MC2010、ACI209、B3、B4、GL2000)和机制砂混凝土修正模型的适用性, 发现决定系数( $R^2$ )最大仅为 0.57, 存在明显低估或高估机制砂混凝土徐变行为。然后, 采用 Feature Tokenizer Transformer、PINNs、TabNet 与 XGBoost 机器学习算法进行机制砂混凝土徐变预测, 测试集  $R^2$  最高可达 0.98, 验证了机器学习模型在机制砂混凝土徐变预测方面的优势。最后, 基于特征分析, 采用自动特征工程与筛选(AutoFeat)与神经符号回归(NSR)进行显式模型构建。AutoFeat 通过 XGBoost-SHAP 与皮尔逊相关系数进行特征筛选, 分别构建了一阶、二阶和三阶模型,  $R^2$  最高达到 0.96; NSR 则基于函数符号组合自动挖掘变量间的非线性关系, 最终构建的表达式模型在测试集上取得  $R^2 = 0.86$ , 具有良好的结构透明性与物理合理性。两种建模计算结果显示, 石粉掺量、水胶比、加载龄期、持荷时间与抗压强度是机制砂混凝土徐变的主要影响因素。本工作所提出方法在特征简化的同时保持了模型精度, 为机制砂混凝土徐变预测提供了一种兼具准确性与解释性的建模思路。

**关键词:** 机制砂混凝土; 徐变预测; 融合机器学习; 显式建模

中图分类号: TU17 文献标志码: A 文章编号: 0454-5648(2025)11-3101-13

网络出版时间: 2025-10-11



砂是混凝土生产的关键原材料之一, 据统计全球每年砂资源消耗量达到 400~500 亿  $t$ <sup>[1]</sup>。机制砂代替河砂已成为解决天然砂资源短缺问题的主要可行路径<sup>[2]</sup>。

与河砂相比, 机制砂经过机械破碎且未经过自然筛选, 导致颗粒表面粗糙、棱角分明和含有石粉等特点<sup>[3]</sup>。在机制砂混凝土徐变研究方面, 邓翀等<sup>[4]</sup>、汪丽娟等<sup>[5]</sup>、Pilegis 等<sup>[6]</sup>研究发现机制砂替代率与混凝土徐变呈现非线性相关关系。在取代率小于 40%, 机制砂对徐变有一定抑制作用。当比例继续增大, 混凝土徐变增加明显。在机制砂母岩岩性影响方面, Li 等<sup>[7]</sup>和王兆平等<sup>[8]</sup>发现石灰岩质机制砂混凝土徐变系数约比凝灰岩机制砂混凝土大 20%。其原因可能归结于表观密度与细度模数等参数影响了机制砂在混凝土中的界面特性<sup>[3]</sup>。多位学者对石粉含量对机制砂混凝土徐变性能的影响进行了研究, 普遍认

为石粉含量与徐变之间存在“双相效应”。陈维敏等<sup>[9]</sup>指出, 当石粉含量为 5% 时, 机制砂混凝土的徐变系数相比普通混凝土降低了 74.9%; 但当石粉含量升至 10% 和 15% 时, 徐变系数则分别上升了 105.2% 和 120.9%。而兰聪等<sup>[10]</sup>、盖珂瑜等<sup>[11]</sup>的研究表明, 在不同实验条件下, 更高或更低的石粉含量可能更为适宜, 反映出“最佳掺量”因条件差异而具有不确定性。总体而言, 尽管多数研究均证实石粉对徐变具有“先抑后增”的双相影响特征, 但受机制砂性质、混凝土配合比、水胶比及养护制度等多种因素的综合影响, 不同研究所得到的最优石粉含量存在差异, 尚难形成统一明确的结论。

在机制砂混凝土徐变预测方面, 已有研究人员展开相关研究。郑怡等<sup>[12]</sup>、赵江山<sup>[13]</sup>基于实验数据对 ACI209 模型进行修正, 建立了机制砂混凝土徐变预测模型。然而, 参数校准依赖于特定实验条件,

收稿日期: 2025-06-03。 修订日期: 2025-06-30。

基金项目: 国家自然科学基金项目(52108161); 河北省燕赵黄金台聚才计划骨干人才项目(HJYB202521); 河北省高等学校科学研究项目青年拔尖人才项目(BJK2024127)。

第一作者: 梅生启(1990—), 男, 博士, 副教授。

Received date: 2025-06-03. Revised date: 2025-06-30.

First author: MEI Shengqi (1990—), male, Ph.D., Associate Professor.

E-mail: cshqmei@stdu.edu.cn

限制了模型泛用能力。龙勇等<sup>[14]</sup>基于贫数据迭代法进行机制砂高强混凝土徐变建模,拟合模型主要服务于机制砂高强混凝土徐变计算。

近年来,机器学习方法不断被用于再生骨料混凝土<sup>[15]</sup>、超高性能混凝土<sup>[16]</sup>及含矿物掺合料的混凝土<sup>[17]</sup>徐变预测研究,表现出良好的拟合精度和泛化能力。与传统预测模型相比,机器学习方法能够更好地处理多因素耦合作用、非线性关系等复杂问题。然而,其缺点也较为明显,如模型“黑箱性”强、缺乏物理可解释性、对数据质量和数量依赖较大,难以反映徐变的物理机制。针对上述问题,部分学者尝试引入可解释算法,以提升模型的透明度和稳定性<sup>[18–19]</sup>。同时,也有研究采用显式建模直接生成预测公式,但生成的公式往往过于冗长复杂,难以在实际工程中推广应用<sup>[20–22]</sup>。

针对上述问题,本工作提出了一种融合隐式与显式建模的方法。首先,创建了一个机制砂混凝土徐变数据集。随后,利用 Tabular Network (TabNet)、Feature Tokenizer Transformer (FT-Transformer)、物理信息神经网络(PINNs)以及极端梯度提升算法(XGBoost)多种先进隐式机器学习模型对机制砂混凝土徐变数据进行预测,并基于模型输出进行特征重要性分析,从中筛选出关键影响因素。最后,采用 AutoFeat 对筛选出的特征进行多项式特征自动生成与筛选,构建多阶显式模型,实现对徐变的高精度预测。引入神经符号回归(NSR),基于函数符号组合自动挖掘变量间的非线性关系,生成结构简洁且具有物理意义的表达式模型。通过该流程,既发挥了隐式模型强大的拟合能力,也保证了显式模型的透明性和可解释性,实现了机制砂混凝土徐变预测的精准化和结构优化。

## 1 既有模型对比分析

目前混凝土徐变的规范推荐模型有 MC2010<sup>[23]</sup>、ACI209<sup>[24]</sup>、GL2000<sup>[25]</sup>、B3<sup>[26]</sup>和 B4<sup>[27]</sup>。此外,龙勇等<sup>[14]</sup>基于贫数据迭代法对机制砂高强混凝土进行徐变建模,郑怡<sup>[28]</sup>和赵江山<sup>[13]</sup>基于 ACI209 模型进行改进,通过实验徐变数据的系统校准,构建了机制砂混凝土的徐变预测模型,修正后的模型如式(1)和式(2)所示。

$$\varphi(t, t_0) = 1.95 \times \frac{(t - t_0)^{0.75}}{16.13 + (t - t_0)^{0.75}} \quad (1)$$

$$\varphi(t, t_0) = 1.84 \times \frac{(t - 28)^{0.66}}{10.26 + (t - 28)^{0.66}} \quad (2)$$

式中:  $t$  表示持荷时间(d);  $t_0$  表示加载龄期(d)。

为综合对比既有模型对多源机制砂混凝土徐变的预测效果,从 23 篇文献中收集了 2441 个机制砂混凝土徐变数据<sup>[3, 4, 8–13, 28–42]</sup>,采用既有规范推荐模型,预测机制砂混凝土徐变如图 1 所示。




图 1 既有模型预测机制砂混凝土徐变结果

Fig. 1 Results of traditional model predicting the creep of concrete with mechanism sand

从图 1 可以看出既有规范推荐模型并不能精准的预测多源数据背景下的机制砂混凝土徐变。其中 MC2010 的决定系数( $R^2$ )最高,为 0.57;其次 ACI209,为 0.55; B3 为 0.49; B4 和 GL2000 模型高估了徐变,  $R^2$  为 0.31 和 0.35。由此可见传统模型不能精准的预测机制砂混凝土徐变,无法有效反映机制砂材料特性对徐变发展的影响。

图 2 展示了修正模型,以及基于贫数据迭代法构建的模型与机制砂混凝土徐变实测数据之间的对比结果。




图 2 既有机制砂混凝土徐变修正模型预测结果

Fig. 2 Prediction results of established mechanism sand concrete creep model

从图 2 可以看出,文献[13]、[14]、[28]中提出

的修正模型  $R^2$  分别为 0.47、0.46 和 0.57。由此可见，既有的机制砂混凝土徐变预测模型仍难以实现对徐变的精准预测。这可能源于该类模型多基于本身实验数据，对传统模型进行参数修正而构建，虽能在特定条件下提高拟合精度，但由于模型高度依赖原始实验工况，导致其泛化能力不足，难以推广至其他类型或不同工况下的机制砂混凝土徐变研究中。

## 2 基于机器学习的机制砂混凝土徐变预测

### 2.1 选择输入参数

混凝土徐变影响因素众多，可分为内部因素和外部因素。内部因素主要包括水胶比、砂含量、粗骨料含量、减水剂掺量、体表比以及抗压强度等。外部因素包括加载龄期、养护环境相对湿度、温度、试验时环境相对湿度、加载应力水平和持荷时间等<sup>[27]</sup>。为筛选确定计算中输入参数，统计了现有文献中所选取参数，见表 1。

表 1 文献中提取的输入参数

Table 1 Input parameters extracted from literature

| Input parameters                                                        | References |
|-------------------------------------------------------------------------|------------|
| $T, f, t_0, w/c, RH, V/S, T, wr, \sigma, H_0, a/c, c, \text{type, cem}$ | [18]       |
| $dt, f, t_0, w/c, RH, V/S, H_0, T, \sigma, a/c, C$                      | [43]       |
| $dt, f, t_0, w/c, RH, v/s, \sigma, E, T, a/c$                           | [44]       |
| $w/c, f, t_s, t_0, b, FA, SF, w, Fa, Ca$                                | [17]       |
| $dt, \sigma/f, RCA, W, w/c, RAC/NAC, H_0, RH, E$                        | [15]       |
| $t, f, w/c, E, a/c, Teure, \text{Steel fiber}, \sigma/f, sf, V/S$       | [16]       |

从表 1 可以看到，抗压强度、持荷时间、加载龄期、水胶比、湿度和骨料含量是文献中共同考虑的参数。考虑机制砂材性特征，增加选取砂表观密度、细度模数、石粉含量和机制砂取代率作为输入参数。

综上所述，确定了 15 项输入变量用于机制砂混凝土徐变的机器学习计算：水胶比( $w/c$ )、粗骨料含量( $CA$ )、砂的表观密度( $AD$ )、减水剂含量( $wr$ )、体表比( $V/S$ )、养护相对湿度( $RH$ )、加载龄期( $t_0$ )、细度模数( $FM$ )、石粉掺量( $SP$ )、试验时环境相对湿度( $TH$ )、应力水平( $\sigma$ )、持荷时间( $dt$ )、砂含量( $S$ )、机制砂替代率( $PM$ )和抗压强度( $f_c$ )。

### 2.2 数据处理

为提升预测模型的有效性与泛化能力，构建了包含 2441 个机制砂混凝土徐变柔量的数据集，数据集已同步上传至本期刊论文公开平台，数据来源覆盖 23 篇公开文献<sup>[3, 4, 8-13, 28-42]</sup>，涵盖水胶

比、加载龄期、应力水平、抗压强度、机制砂石粉含量等多个影响因素，具有良好的代表性。输入参数的分布情况如图 3 所示，从中可以看出各变量在不同取值区间内分布较为均匀，数据整体具有良好的均衡性和多样性。

考虑到部分文献中存在个别变量缺失的情况，在数据整理阶段进行了严格的数据清洗与预处理。对缺失率较高、无法合理补全的数据样本予以剔除；对少量缺失但变量重要性较高的样本，则根据相似样本的均值进行插值补全，以尽可能保留有价值的信息并维持样本数量的完整性。

此外，为减小不同输入参数在取值范围和量纲上的差异对模型计算的影响，本工作采用归一化方法对所有连续型变量进行了归一化处理，如式(3)，将数据统一映射至 $[0,1]$ 区间，以提升模型训练的稳定性与预测精度<sup>[45]</sup>。

$$Z = \frac{X - \mu}{\sigma} \quad (3)$$

式中： $\mu$  表示该特征的均值； $\sigma$  表示总体的标准差。

### 2.3 特征选择

特征选择能够识别数据集中不相关的特征，增强模型性能，加速模型训练。选择互信息(MI)法来进行特征选择<sup>[46]</sup>。与  $t$  检验和方差分析不同，MI 的计算不依赖于数据的分布，MI 方法通过评估每个输入和输出之间的相关性，并从数据集中筛选与输出变量相关性较低的参数来实现特征选择的过程<sup>[47]</sup>。图 4 计算了 15 个参数的 MI 值，从结果可以得到养护相对湿度 MI 值最低，这主要是由于实验设计中对该变量考虑较少。因此，最终确定采用除养护相对湿度的 14 个参数作为机器学习建模的输入特征。

### 2.4 机器学习模型与评估标准

采用 4 种具有代表性的机器学习模型对机制砂混凝土徐变性能进行建模与计算分析，分别为 TabNet、FT-Transformer、PINNs 以及 XGBoost。各模型在结构化数据建模、非线性特征提取及物理规律融合方面具备不同优势。

TabNet 是一种面向结构化数据的学习模型，其设计基于注意力机制，通过多阶段的可学习特征选择模块，实现对输入特征的动态稀疏聚焦<sup>[48]</sup>。该机制使模型能够在每一决策步骤中自动识别和利用最具信息量的特征，显著减少冗余数据的干扰，提升模型的泛化能力和训练效率。此外，TabNet 具备良好的可解释性，注意力权重为模型的决策过程提供

了直观的特征重要性评估，便于进行结果分析和验证。相较于传统的基于树模型或全连接神经网络，TabNet 在处理高维、多样化的结构化数据时表现出

更优的预测性能和更强的鲁棒性。TabNet 模型的训练参数设置如下：ax\_epochs=300，patience=30，batch\_size=256，virtual\_batch\_size=128。




图3 参数数据分布

Fig. 3 Parameter data distribution




图4 互信息计算结果

Fig. 4 MI Result

FT-Transformer 是一种基于 Transformer 架构、专门面向结构化数据建模的深度学习模型<sup>[49]</sup>。该模型通过引入特征标记器(Feature Tokenizer)，将每个数值型或类别型特征映射为统一维度的向量表示，并构建为一组“特征 token”输入至多层 Transformer 编码器中，从而挖掘特征之间的高阶非线性交互关系。与传统模型相比，FT-Transformer 在建模结构化特征时具有更强的表达能力与泛化能力，且无需复杂的特征工程。在本工作中，FT-Transformer 模型由 3 个核心模块组成：特征嵌入层、Transformer 编码器与回归预测层。嵌入层使用线性层(nn.Linear)将输入特征映射为统一维度的嵌入向量(embed\_dim=64)；

Transformer 主干结构由 2 层 nn.TransformerEncoder 构成, 每层包含多头注意力机制(n\_heads=4)和前馈网络模块, 采用 Dropout=0.1 防止过拟合; 输出通过 2 层 MLP(含 ReLU 激活)映射为最终预测值。

PINNs 是一类将物理规律以显式形式引入神经网络训练过程的建模方法<sup>[50]</sup>。该方法由 Raissi 等<sup>[51]</sup>于 2019 年系统提出, 旨在融合数据驱动与物理约束, 从而提高对复杂系统的建模准确性与泛化能力。PINNs 在传统神经网络的损失函数中引入物理约束项, 例如由偏微分方程(PDEs)、守恒定律、边界条件或本构关系等所定义的残差项, 使得神经网络在学习数据的同时, 也能遵循基本的物理定律。在 PINNs 建模中, 损失函数由 2 部分组成。

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{data}} + \lambda \cdot \mathcal{L}_{\text{physics}} \quad (4)$$

式中:  $\mathcal{L}_{\text{total}}$  为传统预测误差;  $\mathcal{L}_{\text{physics}}$  为基于先验物理规律构建的约束项。本工作中, 引入的物理约束项主要基于混凝土徐变的时间增长趋势, 构造如下约束:

$$\frac{dJ(t)}{dt} \geq 0, \quad J(0) = 0$$

该约束表示徐变柔量  $J(t)$  随时间单调递增, 且初始值为零。此条件以残差形式嵌入神经网络中, 确保模型在学习过程中遵循基本徐变演化规律。 $\lambda$  为权重系数, 设定为 10, 以平衡数据拟合与物理约束的相对重要性。

XGBoost 采用顺序训练策略, 通过顺序训练多个弱学习器来创建一个强学习器。每一步都训练一个弱学习者, 使用梯度下降优化算法最小化损失函数<sup>[52]</sup>。通过贝叶斯和 10 折交叉验证来微调 XGBoost 模型的超参数。核心调节参数包括 learning\_rate=0.05, max\_depth=3, subsample=0.8, colsample\_bytree=0.58, n\_estimators=500。

ML 模型的性能可通过以下 3 种评价指标进行评估:  $R^2$ 、均方根误差(RMSE)和平均绝对误差(MAE)。

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (5)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (6)$$


$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (7)$$

式中:  $x_i$  为数据库中第  $i$  个样本点的徐变模量;  $\hat{x}_i$  为


机器学习模型预测的第  $i$  个样本点的值;  $\bar{x}$  为徐变柔量的平均值。

### 3 机制砂混凝土徐变隐式预测结果

为了使机器学习的模型具有较好的泛化能力, 训练集和测试集分别按照 80% 和 20% 进行划分, 分别对 4 种机器学习模型进行训练和测试, 真实值与预测值结果如图 5 所示, 数据点越接近  $y=x$ , 说明预测结果越精确。表 2 为 4 种模型的性能评估指标,  $R^2$  值越高、RMSE 和 MAE 值越低, 模型的整体表现越理想。



(a) Training set



(b) Test set

图 5 机器学习模型的预测结果  
Fig. 5 Prediction results of ML models

从上述结果可以看出, XGBoost 模型在各项指标中表现最佳, 测试集  $R^2$  达到 0.98, RMSE 和 MAE 分别为  $1.60 \times 10^{-6}/\text{MPa}$  和  $1.15 \times 10^{-6}/\text{MPa}$ 。相比之下, 其他机器学习模型在预测机制砂混凝土徐变方面也取得了较高的精度, 测试集  $R^2$  均超过 0.95, RMSE 和 MAE 均控制在较低水平。这说明隐式数据驱动模型在拟合复杂非线性关系方面具有显著优势。

然而, 尽管隐式模型预测精度高, 但其“黑箱”特性难以解释变量之间的物理意义和数学机制。因此, 为进一步提升模型的可解释性和工程适用性,

构建显式预测模型, 以揭示输入变量与徐变发展之间的数学表达式, 并为实践提供便捷的计算方法与理论依据。

表 2 模型性能评估指标  
Table 2 Indicators for assessing model performance

| Model          | Parameter    | $R^2$ | RMSE $\times 10^{-6}/\text{MPa}^{-1}$ | MAE $\times 10^{-6}/\text{MPa}^{-1}$ | Training time/s |
|----------------|--------------|-------|---------------------------------------|--------------------------------------|-----------------|
| Tabnet         | Training set | 0.97  | 2.53                                  | 1.83                                 | 52.7            |
|                | Test set     | 0.96  | 2.812                                 | 2.001                                |                 |
| FT-Transformer | Training set | 0.98  | 1.94                                  | 1.23                                 | 74.6            |
|                | Test set     | 0.97  | 2.43                                  | 1.40                                 |                 |
| PINNS          | Training set | 0.96  | 2.69                                  | 1.91                                 | 158.3           |
|                | Test set     | 0.95  | 2.92                                  | 2.17                                 |                 |
| XGBoost        | Training set | 0.99  | 1.23                                  | 0.92                                 | 8.4             |
|                | Test set     | 0.98  | 1.60                                  | 1.15                                 |                 |

$R^2$  is the coefficient of determination; RMSE is the root mean square error; MAE is the mean absolute error.

#### 4 机制砂混凝土徐变预测显式建模

为提升模型的可解释性并明确各输入参数对混凝土徐变的影响, 本研究采用了 2 种显式建模方法: Autofeat 与 NSR。其中, Autofeat 通过构造非线性特征组合, 并结合基于 XGBoost-SHAP (SHapley Additive exPlanations)值的特征重要性分析, 筛选出关键影响参数后再进行建模, 从而确保最终表达式的简洁性与代表性。相比之下, NSR 方法在建模过程中能够自动完成特征选择与组合运算的表达式构建, 无需人为设定特征筛选策略, 直接输出具有物理意义的数学模型。2 种方法分别从“人为特征解释”与“结构自动生成”2 个角度对混凝土徐变的建模过

程进行了探索与对比, 为实现高性能与高可解释性的平衡提供方法。

##### 4.1 Autofeat 显式数学模型

4.1.1 参数重要性分析 若某特征的 SHAP 重要性值(以其平均绝对 SHAP 值衡量)低于 1.0 的阈值, 则认为该特征对模型预测影响甚微, 如图 6 SHAP 特征重要性所示。低于该阈值的特征将在建模过程中被剔除。该筛选标准的合理性体现在以下两个方面: 1) 模型简化: 剔除贡献较小(SHAP<1)的特征可有效降低模型复杂度, 缓解过拟合风险, 同时保持预测精度。2) 重点突出关键因素: 保留对徐变预测具有显著影响的特征(如  $dt$ 、 $w/c$ , SHAP > 1)可增强模型的可解释性。




图 6 基于 XGBoost-SHAP 的参数重要性排序  
Fig. 6 XGBoost-SHAP Importance

可以看出,实验湿度、应力水平、体表比、细度模数、减水剂、砂的表观密度以及粗骨料等参数的 SHAP 值始终低于 1.0 的显著性阈值,表明其对徐变预测的单独贡献有限。这一影响力的降低主要归因于实验条件的限制及参数与徐变机制之间的弱耦合关系。如试验中对湿度的严格控制使得样本间的湿度变化极小,而统一的减水剂种类与掺量则掩盖了减水剂含量对徐变的调控效应。此外,部分参数与混凝土长期徐变缺乏直接的物理-力学耦合关系,如体表比主要影响干燥收缩而非持续徐变。因此,这些特征因实验差异性较小或与核心变量存在功能冗余,在建模中被边缘化处理。

通过基于 SHAP 阈值( $\geq 1.0$ )的筛选准则有效识别了影响徐变的核心因素,同时剔除非关键特征,提升模型计算效率与可解释性。最终确定 6 个关键特征( $dt$ 、 $w/c$ 、 $t_0$ 、 $f_c$ 、 $S$ 、 $SP$ )构成特征集 I,作为模型的主要输入变量。

值得注意的是,与其他机制砂参数相比,石粉含量在 SHAP 重要性排序中排名靠前,这说明石粉含量是导致普通混凝土与机制砂混凝土的徐变不同的主要原因。石粉作为机制砂中的细颗粒成分,可填充水泥浆与骨料之间的空隙,提高界面过渡区的致密性,抑制微裂纹发展,降低徐变。但石粉含量过高也可能增加需水量、降低有效胶结性,增加徐变。

**4.1.2 Pearson 相关性分析** 针对前节所识别的 6 个参数,皮尔逊相关系数矩阵(见图 7)显示水胶比与抗压强度之间存在中等强度的负相关关系( $r = -0.54$ )。回归分析中,参数间较强相关性易导致多重共线性,进而影响模型估计的精度与物理意义。尽管水胶比对  $J_{creep}$  预测有较强相关性( $r = 0.63$ ),




图 7 Pearson 相关性矩阵

Fig. 7 Pearson correlation matrix

但高相关特征共存容易造成冗余问题。因此,依据方差膨胀因子(VIF)诊断结果,水胶比被排除在建模特征之外。最终保留的 5 项特征( $dt$ 、 $t_0$ 、 $f_c$ 、 $S$ 、 $SP$ )构成了新的特征集 II。精简特征后的模型兼顾预测精度与变量间的独立性,进一步提升了建模质量。

基于既有分析流程,对 3 种参数组合(特征集 I、II 和完整特征集 III)下的模型精度进行了全面评估。从表 3 的对比指标来看,3 种特征组合在预测精度上的差异极小( $\Delta RMSE$  小于 1.5%,  $\Delta R^2$  小于 0.05),这表明,特征集 I 和 II 已有效提取了控制机制砂混凝土徐变的主要因素。

表 3 不同组合的模型性能

| Table 3 Performance with different combinations |          |       |                                      |
|-------------------------------------------------|----------|-------|--------------------------------------|
| Parameter                                       |          | $R^2$ | MAE $\times 10^{-6}/\text{MPa}^{-1}$ |
| Set I                                           | Test set | 0.98  | 1.20                                 |
| Set II                                          | Test set | 0.98  | 1.35                                 |
| Set III                                         | Test set | 0.99  | 1.13                                 |

在机制砂混凝土徐变分析中,显式建模能有效揭示材料性能与多重变量之间复杂的非线性作用机制。传统建模方法常因关键参数难以量化或未被纳入建模过程而存在局限。机器学习通过大规模实验数据挖掘重要因子,并形成可解析的模型表达式。这一数据驱动的方法可实现输入变量与输出响应之间的直接关联,从而提升预测精度与模型稳健性。

在实际应用中,经验数据或收集的数据往往难以充分反映问题的内在动态特性。因此,AutoFeat 作为一种关键的方法框架,用于构建合理的输入参数并提升预测模型的整体性能<sup>[53]</sup>。AutoFeat 包括 2 个阶段如式(8):第一阶段是基于原始变量生成拓展特征空间,涵盖线性、交互和非线性变换;第二阶段则从中筛选具有代表性的特征,并基于优化的线性组合构建数学模型。该策略利用非线性变换(包括多项式扩展、对数变换与指数映射)增强了模型捕捉非线性关系的能力,从而缓解数据稀疏与特征不足的问题。

$$\Phi(x) = \left\{ \sqrt{x}, 1/x, x^2, x^3, \exp(x), \sin(x), \cos(x), \log(x), 2^x, \dots \right\} \quad (8)$$

在一阶建模阶段,仅基于原始变量及其一次变换项构建模型。对应集合 I、II 和 III,获得的显式表达式的拟合  $R^2$  分别为 0.71、0.71 和 0.72,表明各组合在基础层面均具备一定的拟合能力,且组合 II 已能覆盖关键的影响因素,详见式(9)~式(11)。在此基础上,进一步实施二阶特征生成策略,即在原有基础上加入变量之间的交互项,构建集合 II 的

二阶显式模型, 拟合度显著提升至  $R^2 = 0.91$ , 显示出交互特征对模型表达非线性关系的关键作用, 见式(12)。

为进一步提升模型性能, 继续构建三阶模型, 纳入更复杂的变量组合与非线性映射(如三变量交互项、对变量取对数再平方等)。最终获得的三阶显式模型  $R^2$  达到 0.96, 预测性能优异, 能够充分还原混凝土徐变在多因素耦合条件下的变化特征。然而, 随着建模阶次的提升, 模型结构亦愈加复杂, 变量间关系表达趋于冗余, 影响推广使用的可操作性。

$$J_{\text{creep}} = 35.28 + 0.15 \times SP + 109.35 \times w/c - 0.02 \times S - 0.18 \times t_0 - 0.34 \times f_c + 0.11 \times dt + 55.88 \times \frac{1}{t_0} - 0.01 \times dt^3 + 0.01 \times SP^2 \quad (9)$$

$$J_{\text{creep}} = 117.87 + (0.44) \times SP + (-0.04) \times S + (-0.64) \times t_0 + (-0.64) \times f_c + (0.11) \times dt + (9.39) \times \frac{1}{t_0} \quad (10)$$

$$J_{\text{creep}} = 150.42 - 0.02 \times AD - 0.97 \times wr + 58.74 \times w/c + 0.01 \times CA + 0.01 \times S + 5.33 \times SP - 0.39 \times (V/S) - 77.75 \times TH + 0.01 \times t_0 + 5.43 \times FM - 13.14 \times \sigma - 0.36 \times f_c + 0.10 \times dt + 636.64 \times SP^3 + 0.06 \times wr^3 - 0.01 \times \exp(wr) - 9.25 \times \lg(t_0) \quad (11)$$

$$J_{\text{creep}} = 337.77 + 4.65 \times SP - 0.07 \times S + 1.81 \times t_0 - 1.92 \times f_c - 0.27 \times dt + 30.94 \times \frac{1}{t_0} + 0.72 \times \frac{dt}{t_0} - 8.34 \times \frac{SP}{t_0} + 0.01 \times \frac{S^2}{f_c} - 0.13 \times \frac{SP^2}{t_0} - 0.02 \times \frac{f_c^2}{t_0} - 0.01 \times f_c^2 \times t_0 + 105.64 \times \frac{\lg(t_0)}{S} - 4205.73 \times \frac{\lg(t_0)}{f_c} - 0.81 \times SP \times \lg(t_0) \quad (12)$$

## 4.2 NSR

NSR 是一种融合符号学习与神经网络建模优势的表达式生成方法, 旨在从数据中自动提取具有明确数学结构与潜在物理意义的函数关系式<sup>[54]</sup>。该方法通过构建一套具有物理启发意义的徐变函数库, 并借助神经网络结构嵌套和基于遗传算法的符号组合搜索机制, 对输入变量进行表达式层级组合与结构演化, 从而生成可解释性强、结构清晰的显式数学模型。

在徐变函数库构建方面, 引入了多种在混凝土徐变研究中具有广泛应用背景的数学运算符, 包括加法、减法、乘法、除法、幂函数、平方根、对数函数、指数函数及三角函数等。这些函数形式在传统混凝土徐变模型(如 ACI209、B3、GL2000、B4 等)中亦频繁出现, 能够有效刻画徐变随龄期发展、加载历史及材料结构变化的非线性演化特征, 具有较强的工程物理合理性<sup>[55]</sup>。

基于上述机制, 采用 NSR 方法对构建的机制砂混凝土徐变数据库进行训练建模, 在不依赖先验模

型结构假设的前提下, 实现了输入参数的自动筛选、函数组合与显式结构表达。最终所得徐变柔量预测表达式见式(13)以紧凑的函数形式揭示了加载龄期、持荷时间、水胶比、抗压强度、石粉含量变量之间的非线性耦合关系, 展现出较强的物理解释力与预测性能。

该模型在保持物理意义合理、表达结构清晰的同时, 具有较高的预测能力, 可作为后续类比建模与参数敏感性分析的基础模型。

$$J_{\text{creep}} = C_0 \times \exp[w/c \times (\cos(\sqrt{\frac{f_c}{f_{\text{ref}}}}) + C_1)] \times$$

$$(\frac{SP}{\sin(w/c - C_2)} + \lg(\frac{dt + t_{\text{ret}}}{t_0})) + C_3 \quad (13)$$

式中:  $C_0$  为携带单位  $1/\text{MPa}$  的基础徐变柔量系数;  $f_{\text{ref}}$  用于对抗压强度进行无量纲化, 取值为  $1\text{MPa}$ ;  $t_{\text{ref}2}$  用于与持荷时间相加, 其数值为  $7.04\text{d}$ ;  $C_1$  为无量纲常数, 数值为  $5.18$ ;  $C_2$  为无量纲常数, 数值为  $0.23$ ;  $C_3$  为基础徐变柔量, 是公式的初始偏移量, 其数值为  $29.45\text{MPa}^{-1}$ 。

与 Autofeat 不同, 该模型在表达式构建过程中同步进行了特征参数选择、变换与组合操作, 充分挖掘了变量间的高阶非线性关系。加载龄期和持荷

时间在式中以对数的形式出现,这与经典徐变模型中的龄期调节函数形式高度一致,反映出龄期对徐变发展的“时效抑制效应”,即随着加载龄期的增加,材料内部结构更加稳定,水化程度更高,因而其后持续荷过程所产生的徐变呈对数趋势<sup>[56]</sup>。

此外,式中水胶比与石粉含量并未以独立变量出现,而是以指数函数中的乘积项形式耦合出现。这一结构在数学上形成了“非线性放大机制”,在物理意义上同样合理<sup>[57]</sup>。石粉含量的提高会提升浆体的细颗粒比例与需水量,从而改变实际有效水胶比,而水胶比的变化又会进一步影响混凝土的孔隙率与界面过渡区结构。两者之间本身在拌合物配比与水化反应过程中即存在耦合关系<sup>[58]</sup>。因此,该结构不仅提高了表达式的拟合灵活性,也反映出材料变量之间的实际联动机制。

整体而言,该显式模型在不依赖预设结构假设的条件下,自动识别出多个变量的非线性调制关系与耦合机制,其表达结构既符合经验判断,也在一定程度上揭示了机制砂混凝土徐变过程中的内在演化逻辑,体现出良好的物理合理性与解释价值。

值得注意的是,尽管 NSR 与 AutoFeat 显式建模采用了截然不同的建模策略。前者基于符号搜索自动构建非线性函数结构,后者则依赖特征变换与筛选机制构造线性或多项式表达式,但两者在最终生成的模型中所保留的关键特征具有高度一致性。以石粉含量、持荷时间、加载龄期与抗压强度为代表的核心变量,均在 2 个模型中反复出现。这种一致性不仅从侧面验证了所选参数对机制砂混凝土徐变影响的显著性,也说明即便在没有人干预下,NSR 仍具备识别本质驱动因子的能力。

这种参数重合性进一步提升了模型结果的可信度。AutoFeat 通过 SHAP 特征重要性评估实现变量筛选,具有明确的解释性逻辑;而 NSR 则在无监督结构搜索中,自发保留了高度相似的物理参数。这表明无论是数据驱动的特征筛选路径,还是模型结构驱动的符号回归路径,最终都指向了相似的物理机制关联。这不仅体现了模型间的互补性,也说明了显式建模在材料领域应用中的可验证性与稳定性。

为进一步验证所建立显式模型的有效性,分别基于 AutoFeat 与 NSR 得到的 2 个代表性公式对测试集实验数据进行了计算,并绘制了预测值与真实值对比图,如图 8 所示。从对比图 8 可见,2 种模型均能够较好地预测机制砂混凝土徐变。其中,

AutoFeat 所构建的线性组合模型结构较为简洁,二阶模型的  $R^2$  达到 0.91。而 NSR 自动生成的非线性表达式,则通过函数结构的嵌套与组合,在保留物理可解释性的同时,较好地捕捉了非线性机制,模型  $R^2$  达到 0.86,表现出较强的泛化能力与结构表达能力。




图 8 测试集显式模型预测结果

Fig. 8 Test set of explicit model prediction

## 5 结论

为实现对机制砂混凝土徐变性能的准确预测,基于多种机器学习方法,分别从隐式建模与显式建模 2 个方向开展了建模与分析工作,主要结论如下:

1) 通过多源数据预测,现有混凝土的徐变预测模型在面对机制砂混凝土时存在较大误差,难以有效反映其材料特性和时间相关行为,亟须建立更具针对性的新型预测模型。

2) 所构建的 TabNet、FT-Transformer、PINNs 和 XGBoost 隐式机器学习模型在预测精度方面表现优异,能够较好地捕捉机制砂混凝土徐变与各类影响因素之间的复杂非线性关系。

3) 基于 AutoFeat 与 NSR 2 种方法构建了混凝土徐变柔量的显式预测模型,均成功实现了从输入参数到目标输出的函数表达,有效提升了模型的可解释性。其中,AutoFeat 方法在特征筛选过程中结合了 SHAP 特征重要性分析和 Pearson 相关性分析,最终形成以一阶线性项为主,辅以部分二阶与三阶交互特征的显式模型,模型结构简洁,相比之下,NSR 方法则具备更强的非线性关系挖掘能力,能够自动提取关键变量并构建复杂函数形式,其最终表达式呈现出较强的嵌套结构与非线性算子组合,更能反映徐变发展过程中的潜在复杂机制。

4) AutoFeat 与 NSR 2 种显式建模方法在预测精度接近的前提下, 均可输出具备清晰数学结构的表达式, 显著增强了模型的可解释性。尽管隐式与显式建模方法在特征选择与模型结构方面存在差异, 但均能较好地拟合实际数据, 验证了混凝土徐变可通过多种路径建模。将 2 种方法有机结合, 有助于在预测精度和模型可解释性之间实现优化平衡。

#### 参考文献:

- [1] UNEP. Sand and Sustainability: 10 strategic recommendations to avert a crisis[R]. Geneva: United Nations Environment Programme, 2022.
- [2] DINH H, LIU J, ONG E L, et al. A sustainable solution to excessive river sand mining by utilizing by-products in concrete manufacturing: A state-of-the-art review[J]. *Clean Mater*, 2022, 6: 100140.
- [3] LI Y, LIU Y, JIN C, et al. Multi-scale creep analysis of river sand and manufactured sand concrete considering the influence of ITZ[J]. *Constr Build Mater*, 2022, 344: 128175.
- [4] 邓翀, 鄢佳佳, 叶仙松. 机制砂掺量对混凝土力学性能和体积稳定性的影响研究[J]. *新型建筑材料*, 2018, 45(4): 42–46.  
DENG Chong, YAN Jiajia, YE Xiansong. *New Build Mater*, 2018, 45(4): 42–46.
- [5] 汪丽娟, 乔宏霞, 刘志超, 等. 不同替代率下玄武岩机制砂混凝土性能影响试验研究[J]. *中国矿山工程*, 2021, 50(6): 54–58.  
WANG Lijuan, QIAO Hongxia, LIU Zhichao, et al. *China Mine Engineering*, 2021, 50(6): 54–58.
- [6] PILEGIS M, GARDNER D, LARK R. An investigation into the use of manufactured sand as a 100% replacement for fine aggregate in Concrete[J]. *Materials*, 2016, 9(440): 1–19.
- [7] LI H, WANG Z, HUANG F, et al. Impact of different lithological manufactured sands on high-speed railway box girder concrete[J]. *Constr Build Mater*, 2020, 230: 116943.
- [8] 王兆平, 马富山, 郎永贤, 等. 等强条件下机制砂混凝土收缩徐变试验研究[J]. *公路工程*, 2023, 48(4): 139–144.  
WANG Zhaoping, MA Fushan, LANG Yongxian, et al. *Highway Engineering*, 2023, 48(4): 139–144.
- [9] 陈维敏, 王灯灯, 韩旭东, 等. 不同石粉含量机制砂混凝土徐变研究[J]. *混凝土*, 2022, 8: 1–7.  
CHEN Weimin, WANG Dongxun, HAN Xundong, et al. *Concrete*, 2022, 8: 1–7.
- [10] 兰聪, 陈景, 刘霞, 等. 石灰石机制砂中石粉对混凝土性能的影响研究[J]. *新型建筑材料*, 2018, 45(7): 46–48+130.  
LAN Cong, CHEN Jing, LIU Xia, et al. *New Build Mater*, 2018, 45(7): 46–48+130.
- [11] 盖珂瑜, 韩江龙, 王永宝, 等. 石粉含量对 C60 机制砂混凝土徐变的影响[J]. *混凝土与水泥制品*, 2024, 3: 7–11.  
GE Gaiyu, HAN Jinglong, WANG Yongbao, et al. *China Concrete and Cement Products*, 2024, 3: 7–11.
- [12] 郑怡, 张耀庭. 石灰岩质机制砂混凝土收缩徐变性能的试验研究[J]. *土木工程学报*, 2013, 46(12): 59–65.  
ZHENG Yi, ZHANG Yaoting. *China Civ Eng J*, 2013, 46(12): 59–65.
- [13] 赵江山. 辉绿岩机制砂混凝土性能及其对桥梁结构徐变的影响研究[D]. 重庆: 重庆交通大学, 2020  
ZHAO Jingshan. Study on the performance of diabase mechanized sand concrete and its influence on the creep of bridge structure[D]. Chongqing: Chongqing Jiao tong University, 2020.
- [14] 龙勇, 韩江龙, 盖珂瑜, 等. 基于贫数据迭代法的机制砂高强混凝土徐变模型[J]. *铁道标准设计*, 2025, 69(7): 114–119.  
LONG Yong, HAN Jinglong, GE Gaiyu, et al. *Railw. Stand. Des*, 2025, 69(7): 114–119.
- [15] FENG J, ZHANG H, GAO K, et al. Efficient creep prediction of recycled aggregate concrete via machine learning algorithms[J]. *Constr Build Mater*, 2022, 360: 129497.
- [16] ZHU P, CAO W S, ZHANG Y J, et al. Interpretable Machine Learning Models for Prediction of UHPC Creep Behavior[J]. *Buildings*, 2024, 14(2080): 1–22.
- [17] BANTI A G. ANN-powered models for predicting shrinkage and creep properties of high-performance concrete using supplementary cementitious materials[J]. *J Comput Civ Eng*, 2024, 38(6): 1–14.
- [18] LIANG M F, CHANG Z, WAN Z, et al. Interpretable ensemble-machine-learning models for predicting creep behavior of concrete[J]. *Cem Concr Compos*, 2022, 125: 104295.
- [19] MAAMARY N, OGUNSANYA I G. Exploring machine learning to study and predict the chloride threshold level for carbon steel reinforcement[J]. *Cem Concr Compos*, 2024, 154: 105796.
- [20] ZOU B, WANG Y, NASIR AMIN M, et al. Artificial intelligence-based optimized models for predicting the slump and compressive strength of sustainable alkali-derived concrete[J]. *Constr Build Mater*, 2023, 409: 134092.
- [21] ZHAO Y H, HU H S, SONG C L, et al. Predicting compressive strength of manufactured-sand concrete using conventional and metaheuristic-tuned artificial neural network[J]. *Measurement*, 2022, 194: 110993.
- [22] NGUYEN N H, ABELLÁN-GARCÍA J, LEE S, et al. From machine learning to semi-empirical formulas for estimating compressive strength of ultra-high performance concrete[J]. *Expert Syst Appl* 2024, 237: 121456.
- [23] CEB-FIB. fib Model Code for Concrete Structures 2010[S]. Lausanne, Switzerland, 2010: 145–150.
- [24] AIC 209R. Prediction of Creep, Shrinkage, and Temperature Effects in Concrete Structures[S]. American Concrete Institute, 1992: 1–47.
- [25] GARDNER N J. Design provisions for drying shrinkage and creep of normal strength concrete[J]. *ACI Mater J*, 2001, 9: 1–23.
- [26] BAZANT Z P, BAWEJA S. Creep and shrinkage prediction model for analysis and design of concrete structures[J]. *Mater Struct*, 1995, 28(6): 357–365.
- [27] BAZANT Z P. Model B4 for creep, drying shrinkage and autogenous shrinkage of normal and high-strength concretes with multi-decade applicability[J]. *Mater Struct*, 2015, 48: 753–770.
- [28] 郑怡. 石灰岩质机制砂混凝土的长期变形性能研究[D]. 武汉: 华中科技大学, 2014  
ZHENG Yi. Long Term Deformation of Limestone Sand Concrete[D]. Wuhan: Huazhong University of Science and Technology, 2014.
- [29] 邓蕾, 张启志. 花岗岩机制砂对混凝土性能的影响研究[J]. *新型建筑材料*, 2020: 24–27.  
DENG Lei, ZHANG Qizhi. *E New Build Mater*, 2020: 24–27.
- [30] 张电杰, 吴源华. 石粉含量对机制砂混凝土徐变收缩性能影响试验研究[J]. *建筑结构*, 2022, 52(S1): 1512–1514.  
ZHANG Dianjie, WU Yuanhua. *Building Structure*, 2022, 52(S1): 1512–1514.
- [31] 杨剑勇, 程晓凯. 石粉对 C60 混合砂混凝土力学性能和徐变的影响[J]. *山西交通科技*, 2017, (5): 15–17.

- YANG Jianyong, CHENG Xiaokai. Shanxi Sci Technol Commun, 2017(5): 15–17.
- [32] 何世钦, 赵盈, 王辉, 等. 加载龄期对机制砂自密实混凝土徐变性能影响[J]. 水利水电技术, 2023, 54(9): 210–219.
- HE Shiqin, ZHAO Ying, WANG Hui, et al. Water Resour Hydropower Eng, 2023, 54(9): 210–219.
- [33] 李凤兰, 罗俊礼, 赵顺波. 不同骨料的高强混凝土早期徐变性能研究[J]. 长江科学院院报, 2009, 26(2): 45–47.
- LI Fenglan, LUO Junli, ZHAO Shunbo. J Yangtze River Sci Res Inst, 2009, 26(2): 45–47.
- [34] 张剑波, 杨光辉, 胡善铨, 等. 混合砂混凝土性能研究[J]. 重庆建筑大学学报, 2002, 24(3): 86–90.
- ZHANG Jianbo, YANG Changhui, HU Shanquan, et al. Journal of Chongqing Jianzhu University, 2002, 24(3): 86–90.
- [35] 吴大鸿, 余崇俊. 桥用机制砂高强混凝土徐变试验研究[J]. 公路交通科技(应用技术版), 2016, 12(8): 177–179.
- WU Dahong, YU Chongjun. Road Traffic Science and Technology (Applied Technology Edition), 2016, 12(8): 177–179.
- [36] ZHOU M K, WANG J, ZHU L, et al. Effects of manufactured-sand on dry shrinkage and creep of high-strength concrete[J]. J. Wuhan Univ. Technol, 2008: 249–253.
- [37] 王振. 铁路工程预应力结构用机制砂混凝土性能研究[J]. 铁道建筑, 2019, 59(4): 11–16.
- WANG Zhen. Railway Engineering, 2019, 59(4): 11–16.
- [38] LI B, WANG J, ZHOU M. Effect of limestone fines content in manufactured sand on durability of low- and high-strength concretes[J]. Constr Build Mater, 2009, 23: 2846–2850.
- [39] 余佳殷. 低纬度高海拔寒区机制砂泵送混凝土配合比设计及性能研究[D]. 重庆: 重庆交通大学, 2022.
- YU Jiayin. Study on mix proportion design and performance of crushed sand pumping concrete for low latitude and high altitude cold area[D]. Chongqing: Chongqing Jiaotong University, 2022.
- [40] 蔡基伟. 石粉对机制砂混凝土性能的影响及机理研究[D]. 武汉: 武汉理工大学, 2006.
- CAI Jiwei. Research of Effects and Mechanism of Micro Fines on Manufactured Fine Aggregate Concretes[D]. Wuhan: Wuhan University of Technology, 2006.
- [41] 田建平. 高强高性能机制砂混凝土的配制及性能研究[D]. 武汉: 武汉理工大学, 2006.
- TIAN JiaPing. The preparation and study on properties of high strength and high performance MSC[D]. Wuhan: Wuhan University of Technology, 2006.
- [42] 赵静. 不同属性砂 C50 混凝土耐久性能试验研究[J]. 中外公路, 2014, 34(4): 306–310.
- ZHAO Jing. Cent Extern Highways, 2014, 34(4): 306–310.
- [43] LI K, LONG Y P, WANG H, et al. Modeling and Sensitivity Analysis of Concrete Creep with Machine Learning Methods[J]. J. Mater. Civ. Eng, 2021, 33(8): 1–13.
- [44] 梅生启, 刘晓东, 王兴举, 等. 基于参数相关性分析和机器学习算法的高强混凝土徐变预测[J]. 吉林大学学报(工学版), 2025, 55(5): 1595–1603.
- MEI Shengqi, LIU Xiaodong, WANG Xingju, et al. J Jilin Univ (Eng Technol Ed), 2025, 55(5): 1595–1603.
- [45] SUN Y B, CHENG H, ZHANG S Z, et al. Prediction & optimization of alkali-activated concrete based on the random forest machine learning algorithm[J]. Constr Build Mater, 2023, 385: 131519.
- [46] DOQUIRE G, VERLEYSEN M. Mutual information-based feature selection for multilabel classification[J]. Neurocomputing, 2013, 122: 148–155.
- [47] ARACHCHILAGE C B, HUANG G P, FAN C K, et al. Forecasting unconfined compressive strength of calcium sulfoaluminate cement mixtures using ensemble machine learning techniques integrated with shapely-additive explanations[J]. Constr Build Mater, 2023, 409: 134083.
- [48] MCDONNELL K, MURPHY F, SHEEHAN B, et al. Deep learning in insurance: Accuracy and model interpretability using TabNet[J]. Expert Syst Appl, 2023, 217: 119543.
- [49] DAI H L, WU S X, ZHAO H R, et al. FT-transformer: Resilient and reliable transformer with end-to-end ault tolerant attention[J]. Arxiv Preprint Arxiv, 2025, 2504: 1–12.
- [50] SARMA A K, ROY S, ANNAVARAPU C, et al. Interface PINNs (I-PINNs): A physics-informed neural networks framework for interface problems[J]. Comput Method Appl M, 2024, 429: 117135.
- [51] RAISSI M, PERDIKARIS P, KARNIADAKIS. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. J. Comput. Phys. 2019, 378: 686–707.
- [52] CHEN T, GUESTRIN C. XGBoost A Scalable Tree Boosting System[C]//In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining, San Francisco, 2016: 785–794.
- [53] DINESHA D, RAJITHA N, PRAVEEN E, et al. A Survey of Evaluating AutoML and Automated Feature Engineering Tools in Modern Data Science[C]//In Proceedings of the 27th International Conference on Enterprise Information Systems, Portugal, 2025: 218–225.
- [54] BENDINELLI T, BIGGIO L, KAMIENNY P. Controllable Neural Symbolic Regression[C]//In International Conference on Machine Learning, Vienna, 2023: 1–15.
- [55] TSOI H F, LONCAR V, DASU S, et al. SymbolNet: neural symbolic regression with adaptive dynamic pruning for compression[J]. Mach Learn Sci Technol, 2025, 6: 015021.
- [56] ZHANG Y, MAO J, JIN W, et al. Creep model of high-performance concrete at different loading ages[J]. Constr Build Mater, 2022, 357: 129379.
- [57] CHEN X, WU S. Influence of water-to-cement ratio and curing period on pore structure of cement mortar[J]. Constr Build Mater, 2013, 38: 804–812.
- [58] BENTZ P, PELTZ A, WINPIGLER J. Early-age properties of cement-based materials. II: Influence of water-to-cement ratio[J]. J Mater Civil Eng, 2009, 21(9): 512–517.

## Explicit Modeling of Creep in Manufactured Sand Concrete Based on Integrated Machine Learning Approaches

MEI Shengqi<sup>1,2</sup>, WU Teng<sup>1,3</sup>, WANG Xingju<sup>2</sup>, CHENG Xiangxu<sup>3</sup>, LIU Zhe<sup>3</sup>, LI Xingyan<sup>3</sup>, LI Xuefeng<sup>3</sup>

(1. 1 State Key Laboratory of Mechanical Behavior and System Safety of Traffic Engineering Structures, Shijiazhuang 050043, China;

2. School of Traffic and Transportation, Shijiazhuang Tiedao University, Shijiazhuang 050043, China; 3 School of Civil Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

### Extended Abstract

**Introduction** With the continuous development of infrastructure in China, the demand for concrete has increased significantly. As a critical raw material in concrete production, sand has also seen a sustained rise in consumption. It is estimated that global annual sand usage ranges between 40 and 50 billion tons. Due to the non-renewable and non-recyclable nature of river sand, its excessive extraction has led to the rapid depletion of existing reserves. To enhance resource efficiency, the construction industry has gradually implemented a variety of mitigation strategies, such as incorporating recycled coarse aggregates into concrete and employing manufactured sand as a substitute for river sand. The use of manufactured sand not only alleviates the environmental degradation caused by overexploitation of river sand but also offers a practical solution to the growing scarcity of this natural resource. Manufactured sand is produced by mechanically crushing and screening rock particles. Compared with river sand, it is characterized by a rougher surface texture and a higher content of stone powder, which can significantly influence the long-term mechanical performance of concrete. Creep, defined as the time-dependent deformation of concrete under sustained loading, plays a crucial role in determining the structural stability and durability. However, existing creep models for concrete have proven inadequate in accurately predicting the creep behavior of manufactured sand concrete. In recent years, machine learning techniques have been increasingly applied to the prediction of creep behavior in recycled aggregate concrete, ultra-high-performance concrete, and concrete incorporating mineral admixtures, demonstrating excellent fitting accuracy and generalization capabilities. Compared with traditional predictive models, machine learning approaches are better suited to handling complex issues such as multi-factor coupling and nonlinear relationships. However, their limitations are also notable: these models often function as "black boxes," lacking physical interpretability, and are highly dependent on the quality and quantity of input data, making it difficult to uncover the underlying physical mechanisms of creep. To address these challenges, some researchers have introduced explainable algorithms to improve model transparency and robustness. Simultaneously, other studies have explored explicit modeling techniques to directly generate predictive formulas. Nonetheless, the resulting expressions are often overly complex and lengthy, limiting their applicability in practical engineering scenarios.

**Methods** To tackle these challenges, a novel modeling framework that integrates both implicit and explicit techniques is proposed. First, a dataset of manufactured sand concrete creep was constructed. Advanced implicit machine learning models, including the Feature Token Transformer, Physics-Informed Neural Networks (PINNs), TabNet, and XGBoost, were employed to predict the creep behavior of manufactured sand concrete. Feature importance analysis was subsequently conducted based on model outputs to identify the most influential variables. Next, AutoFeat was used to automatically generate and select polynomial features from the identified key variables, thereby constructing a high-order explicit model capable of achieving accurate creep prediction. Furthermore, neural symbolic regression (NSR) was introduced to automatically discover nonlinear relationships among variables through symbolic function composition, yielding concise, physically meaningful analytical expressions.

**Results and discussion** Existing concrete creep prediction models, when applied to manufactured sand concrete, exhibit substantial errors due to their inability to effectively capture the material-specific characteristics and time-dependent behavior. This highlights an urgent need for the development of more targeted and robust predictive models.

The constructed implicit machine learning models—TabNet, FT-Transformer, PINNs, and XGBoost—demonstrated excellent predictive performance. These models effectively capture the complex and nonlinear relationships between the creep behavior of manufactured sand concrete and various influencing factors.

Explicit prediction models for concrete creep compliance were developed based on two approaches: AutoFeat and Neural Symbolic Regression (NSR). Both methods successfully generated functional expressions that map input parameters to the target output, thereby enhancing model interpretability. The AutoFeat-based model combined SHAP-based feature importance analysis with Pearson correlation analysis during feature selection, ultimately yielding an interpretable model primarily composed of first-order linear terms, complemented by selected second- and third-order interaction terms. In contrast, the NSR method exhibited a superior

capacity for capturing nonlinear dependencies. It automatically identified key variables and constructed complex mathematical formulations characterized by nested structures and nonlinear operator combinations, providing deeper insight into the underlying mechanisms governing creep development.

**Conclusions** Under comparable levels of predictive accuracy, both AutoFeat and Neural Symbolic Regression are capable of generating explicit expressions with clear mathematical structures, significantly enhancing model interpretability. Despite differences in feature selection strategies and model architectures between implicit and explicit modeling approaches, both demonstrate strong fitting performance with respect to real-world data, thereby validating the feasibility of modeling concrete creep through multiple methodological pathways. The integrated application of both approaches facilitates an optimized balance between predictive accuracy and interpretability.

**Keywords** manufactured sand concrete; creep prediction; fusion machine learning; explicit modelling