

物理信息引导的 3D 打印混凝土智能设计方法

耿松源^{1,2}, 龙武剑^{1,2,3,4}, 李豪道^{1,2}, 罗启灵^{1,2,4}, 冯甘霖^{1,2}

(1. 深圳大学土木与交通工程学院, 广东 深圳 518060; 2. 广东省滨海土木工程耐久性重点实验室, 广东 深圳 518060;
3. 深圳市低碳建筑材料与技术重点实验室, 广东 深圳 518060;
4. 深地工程智能建造与健康运维全国重点实验室, 广东 深圳 518060)

摘 要: 3D 打印技术能够有效提升建造效率并拓展结构设计的自由度, 因而在建筑领域具有广阔的应用前景。然而, 该技术在建筑行业中的推广及规模化应用仍面临挑战, 主要体现为混凝土材料多性能协同调控难, 以及打印工艺参数决策智能化程度不足等。为此, 本工作提出一种融合物理信息与数据驱动的混合建模框架, 以实现面向目标材料性能的 3D 打印参数智能设计。该框架首先建立了基于物理信息方程(Physical Information Equation, PIE)的流变性能预测模型, 并利用该模型与 PIE 构建挤出螺杆转速数据库, 随后结合目标流量、喷嘴尺寸与打印层高等关键参数, 实现对打印速度的精确求解。本工作提出的智能化参数设计方法, 为混凝土多性能协同调控提供了量化工具, 显著提升了工艺参数优化的效率与可靠性。这为改善 3D 打印混凝土的成型质量与工艺稳定性提供了坚实的理论依据与方法支持, 对推动该技术在建筑工程中的应用与推广具有积极意义。

关键词: 3D 打印混凝土; 机器学习; 物理信息方程; 融合策略; 打印参数优化

中图分类号: TU528 文献标志码: A 文章编号: 0454-5648(2026)08-2579-23

网络出版时间: 2026-07-09



随着科技的飞速发展, 3D 打印技术作为智能制造的代表性技术之一, 在诸多制造领域展现出广阔的应用前景。该技术凭借其高精度、快速成型以及材料高效利用等特点, 革新了传统制造模式^[1]。3D 打印技术在建筑领域前景广阔, 它能大幅提升施工效率、减少材料浪费, 并能建造出传统工艺难以实现的复杂构型, 有望推动建筑业迈向更高效、更创新的发展阶段^[2]。然而, 尽管潜力巨大, 该技术在建筑行业的规模化推广及应用仍面临一些核心技术挑战。首要挑战源于材料性能的多目标协同调控困难。建筑用混凝土材料需兼顾工作性、强度、耐久性等多种性能, 而这些性能之间往往存在相互制约关系, 使得适用于 3D 打印的材料设计变得极为复杂。其次, 现有 3D 打印工艺的智能化水平仍有待提升。打印设备在复杂多变的实际施工环境中, 其自适应调整与全过程自动化决策能力仍显不

足, 制约了技术实用化进程^[3]。在此背景下, 人工智能技术, 特别是其分支机器学习(Machine Learning, ML), 凭借强大的数据挖掘与非线性映射能力, 为上述问题的解决提供了新途径^[4]。在混凝土材料研究中, ML 技术已被广泛应用于材料性能预测与配合比设计, 能够深入揭示组分、工艺与性能间的复杂关联, 为材料优化提供数据驱动式的指导^[5]。例如, 蒋志鹏等^[6]利用鲸鱼算法优化的 BP 神经网络, 实现了对超高性能混凝土早期收缩的高精度预测。余睿等^[7]则提出了一个综合数据处理与贝叶斯优化的 XGBoost 框架, 较为准确地预测了超高性能混凝土的多项性能(决定系数 $R^2 > 0.95$), 并展示了其在配合比精细化设计中的应用潜力。梅生启等^[8]针对机制砂混凝土徐变, 融合多种先进 ML 算法进行显式建模, 获得了优于传统机理模型的预测效果(R^2 最高达 0.98)。不仅如此, ML 在推动混凝土材料

收稿日期: 2026-01-25。 修订日期: 2026-03-11。

基金项目: 国家自然科学基金——区域创新发展联合基金集成项目(U25A6016); 深圳市科技计划基础研究面上项目(JCYJ20240813143004006); 广东省“特支计划”科技创新领军人才(2023TX07G066)。

第一作者: 耿松源(1997—), 女, 博士研究生。

通信作者: 龙武剑(1977—), 男, 博士, 教授。

Received date: 2026-01-25. Revised date: 2026-03-11.

First author: GENG Songyuan (1997—), female, Doctoral candidate.

E-mail: gengsongyuan2022@email.szu.edu.cn

Correspondent author: LONG Wujian (1977—), male, Ph.D., Professor.

E-mail: longwj@szu.edu.cn

的绿色低碳化方面也作用显著。Shahrokhishahraki 等^[9]通过 ML 模型优化了水泥用量,为实现可持续混凝土结构的碳减排提供了有效路径。Peng 等^[10]更进一步,开发了混合 ML 与多目标优化的智能设计框架,成功协同优化了再生骨料混凝土的力学性能、碳排放与成本。

在 3D 打印混凝土这一具体领域,ML 方法同样展现出良好的适用性。近期研究集中于利用 ML 精准预测打印材料的流变性能与可打印性。例如, Geng 等^[11]首次提出了基于随机森林(Random Forest, RF)算法的通用理论框架,用于同时预测 3D 打印混凝土的流变性能和可打印性,模型表现出优异的预测精度(R^2 为 0.84~0.99)。马宗方等^[12]则结合白鲸优化算法与集成学习(Ensemble Learning, EL),构建了高精度模型,以优化混凝土打印沉积线状态,为工艺参数调控提供了新方法。在智能优化设计方面, Geng 等^[13]提出了一个面向多场景需求的智能多目标优化框架,实现了在满足可打印性及强度要求的同时,显著降低打印混凝土的成本(44%~57%)与碳排放(19%~22%)。为了进一步提升模型的可解释性与物理合理性, Geng 等^[14]创新性地提出了物理信息方程(Physical Information Equation, PIE)与 ML 协同驱动的双路径框架,实现了打印参数与材料流变属性的智能匹配,增强了过程控制的可靠性。此外, Zafar 等^[15]通过集成 ML 与专家知识,优化了含多种添加剂的可打印水泥基材料的流变性能。Zhao 等^[16]开发了基于深度学习(Deep Learning, DL)的自动分析系统,用于量化 3D 打印混凝土的微观缺陷,建立了工艺参数与宏观性能的微观桥梁。Schossler 等^[17]则系统比较了多种回归模型,并利用多目标优化技术来平衡 3D 打印混合物的性能、成本与环境影响。

尽管 ML 技术在 3D 打印混凝土研究中取得了上述进展,但单纯依赖数据驱动的方法仍存在固有局限。首先,ML 模型的性能高度依赖于大量高质量的训练数据,而这在实际工程中往往难以充分获取。其次,此类模型的泛化能力通常有限,当应用于训练数据未能覆盖的新工况或复杂环境时,其预测可靠性可能显著下降。此外,ML 模型常被视为“黑箱”,其内部决策机制缺乏清晰的物理解释,这在一定程度上削弱了其在实际工程中的指导价值^[18]。与之相比,基于明确物理定律构建的 PIE 则能直观地揭示变量间的内在物理关联,提供更高的模型透明度^[19]。然而,单一的 PIE 方法在处理高

度非线性、多因素耦合的复杂系统时,也常因简化假设、计算效率低下及变量维度有限而存在局限。因此,将物理信息与数据驱动方法相融合,利用 PIE 引导 ML 模型的学习过程,同时借助 ML 增强 PIE 处理复杂问题的能力,可望实现优势互补,构建出兼具高精度与强泛化能力的预测模型^[20]。本工作的核心创新在于,提出了一套完整的物理-数据混合驱动框架,旨在解决匹配材料属性的打印参数优化难题。该框架通过 2 种不同的融合策略(“PIE 嵌入 ML”与“PIE 串联 ML”),分别实现了对 3D 打印混凝土流变性能与挤出螺杆转速(Extrusion Screw Speed, ES)的准确预测,并推导出基于目标流量(Q)、喷嘴尺寸(Printing Nozzle Diameter, PN)与打印层高(Printing Layer Height, PH)的打印速度(Printing Speed, PS)计算方程,为工程应用提供了系统的解决方案。该方法不仅致力于提升预测精度,更注重增强模型的可解释性与物理一致性。

本工作主要涵盖以下内容:首先,采用“PIE 嵌入 ML”的融合策略,将控制流变行为的物理方程作为约束条件引入卷积神经网络(Convolutional Neural Networks, CNN)的损失函数中,构建出物理信息约束的 CNN 融合模型(Physics-Informed Convolutional Neural Networks, PICNN),用于精确预测混凝土的流变参数;其次,基于“PIE 串联 ML”策略,综合利用密度方程、伯努利方程、扭矩方程等一系列物理方程,并结合 PICNN 模型预测所得的流变参数,建立 ES 先验数据库,进而采用 RF 算法训练高精度的 ES 预测模型;最后,基于 Q 、PN 与 PH 等关键参数,理论推导出 PS 的计算方程,并辅以典型工况案例说明其应用方法,以优化打印过程。实验结果表明,该混合驱动方法能够可靠地匹配材料属性与打印参数,具备良好的工程应用可行性。本工作通过物理机理与数据智能的深度融合,为 3D 打印混凝土的性能预测与工艺优化提供了新范式,对推动该技术在建筑领域的实用化进程与行业智能化转型具有积极意义。

1 研究方法论

1.1 机器学习算法理论基础

ML 作为人工智能的核心领域,使计算机系统具备从数据中自主学习并改进的能力。其核心在于通过算法解析数据,挖掘内在规律与特征,并据此进行预测或决策。在众多 ML 分支中,DL 与 EL 因其各自优势而得到广泛应用。DL 通过深层神经

网络结构实现对复杂数据的高层次特征抽象与学习, 可视为 ML 在处理更复杂模式识别任务上的延伸, 尤其适用于需进行端到端非线性映射的应用场景。EL 则通过构建并结合多个基学习器(即个体模型)来提升整体模型的性能与稳健性, 其核心思想在于“集思广益”, 能够有效提高小规模数据集下的预测精度与泛化能力^[21]。

在本工作中, 针对 2 种不同的模型融合策略, 分别选用了 DL 与 EL 中的代表性算法。为确保算法选择的合理性与科学性, 在前期实验中对多种常用模型的性能, 评估指标包括 R^2 、均方根误差(Root Mean Square Error, RMSE)以及训练时间等。对于“PIE 嵌入 ML”的融合策略, 其关键在于对模型损失函数引入物理约束, 这要求模型具备强大的表征学习能力和灵活的损失函数定义。因此, 本工作对比了 CNN、循环神经网络(Recurrent Neural Networks, RNN)和长短期记忆网络(Long Short-Term Memory, LSTM) 3 种具有较强表征能力的 DL 模型, 实验结果表明, CNN 在屈服应力(Yield Stress, YS)和塑性黏度(Plastic Viscosity, PV)预测任务中均取得了最优性能: 其在测试集上的 R^2 分别达到 0.96 和 0.95, RMSE 分别为 198.92 Pa 和 0.37 Pa·s, 优于 RNN ($R^2=0.91$ 、0.89; RMSE=312.45 Pa、0.58 Pa·s)和 LSTM($R^2=0.93$ 、0.91; RMSE=278.33 Pa、0.49 Pa·s)。此外, CNN 在训练时间上也具有优势, 约为 RNN 的 60%、LSTM 的 70%, 展现出更高的计算效率。因此, 本工作选择 CNN 作为该策略下的代表算法。

对于“PIE 串联 ML”的融合策略, 其核心是基于物理方程构建先验数据库后进行数据驱动预测, 此场景对模型的鲁棒性和抗过拟合能力要求较高。因此, 本工作对比了 RF、支持向量回归(Support Vector Regression, SVR)和梯度提升决策树(Gradient Boosting Decision Tree, GBDT) 3 种具有较好稳健性的浅层及 EL 模型。结果显示, RF 在 ES 预测任务中表现最为优异: 测试集 R^2 为 0.97, RMSE 为 2.39 r/s, 显著优于 SVR ($R^2=0.89$, RMSE=5.12 r/s)和 GBDT ($R^2=0.93$, RMSE=3.78 r/s)。同时, RF 在训练时间与模型稳定性方面也表现良好, 具备较强的工程适用性。因此, 本工作选择 RF 作为该策略下的代表算法。

1.1.1 卷积神经网络原理与架构 CNN 是一种专为处理具有类似网格结构数据(如图像、序列)而设计的 DL 模型。典型 CNN 架构通常由交替堆叠

的卷积层、池化层以及末端的全连接层构成。在卷积层中, 模型通过卷积核在输入数据上进行滑动卷积操作, 以提取局部特征, 并利用参数共享机制显著减少模型参数量, 提升训练效率。池化层(如最大池化)则通过对特征图进行下采样, 在保留最显著特征的同时, 进一步压缩数据维度, 增强模型的平移不变性并降低计算复杂度。全连接层位于网络末端, 负责将前面各层提取的分布式特征映射到最终的样本标签空间, 以完成回归或分类任务。CNN 的主要优势在于其强大的自动特征学习能力, 无须烦琐的人工特征工程; 同时, 其局部感知、权值共享及层次化结构特性, 使其在处理高维、结构化数据时表现出色^[22]。

1.1.2 随机森林算法与集成学习机制 RF 是一种经典的 EL 算法, 它通过构建大量决策树并集成其预测结果(对于回归任务, 通常取所有决策树输出的平均值)来提升模型性能。RF 采用 Bootstrap Aggregating (Bagging)技术, 从原始训练集中进行有放回的随机抽样, 生成多个不同的训练子集, 并在每个子集上独立训练一棵决策树, 以此引入样本随机性。此外, 在每棵决策树的节点分裂过程中, RF 会随机选取一个特征子集, 并仅从该子集中寻找最佳分裂特征与分裂点, 此举进一步引入了特征随机性。这 2 种随机性机制共同作用, 极大地增强了模型的多样性, 从而有效降低了模型方差, 使其在处理高维数据时表现出强大的抗过拟合能力和良好的泛化性能^[23]。

1.2 模型超参数优化策略

1.2.1 关键超参数定义与搜索空间 超参数是在模型训练开始前预先设定, 而非通过训练学习得到的参数, 它们直接决定了模型的结构、复杂度与学习过程, 对最终性能至关重要。传统超参数优化方法(如网格搜索、手动调参)不仅过程烦琐耗时, 且极易陷入局部最优。为解决此问题, 本工作采用智能优化算法对超参数空间进行自动化、全局化的高效搜索, 以期找到能使预定义性能评估指标最优的超参数组合。参考相关文献[24, 25], 本工作确定了 CNN 与 RF 模型所需调优的关键超参数及其搜索范围, 如表 1 所示。

1.2.2 优化目标函数的确立 在超参数自动优化过程中, 需要一个可量化的目标函数来指导搜索方向。优化算法的任务即是通过迭代, 寻找使该目标函数值最小化的超参数组合。鉴于 RMSE 能够直观且灵敏地反映预测值与真实值之间的偏差, 且

其量纲与原始数据一致，便于解释，本工作选择 RMSE 作为超参数优化的目标函数，其计算公式见式(1)。

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (t_i - p_i)^2}{n}} \quad (1)$$

式中： t_i 为第 i 个样本的真实值； p_i 为对应的模型预测值； n 为样本总数^[26]。

1.2.3 超参数调优流程与终止准则 超参数优化过程的终止条件决定了搜索何时停止。常见的终止条件包括达到最大迭代次数、性能收敛至稳定平台、超过时间或计算资源限制、或达到预设的性能阈值等。综合参考前期研究经验^[13]并经过多次预实验验证，本工作将最大迭代次数设定为 3000 次，作为超参数优化过程的终止条件。

1.2.4 基于蜣螂优化器的智能调参算法 为选择高效的超参数优化器，本工作对比了遗传算法 (Genetic Algorithm, GA)、粒子群优化 (Particle Swarm Optimization, PSO) 和蜣螂优化器 (Dung Beetle Optimizer, DBO) 3 种智能优化算法的性能。初步计算结果表明：在优化精度方面，PSO 与 DBO 的优化效果相近，且均优于 GA；在计算效率方面，GA 与 DBO 的收敛速度显著快于 PSO。上述结果凸显了 DBO 在实现高精度与高效率平衡方面的优势，因此本工作最终采用 DBO 进行超参数自动调优。DBO 是一种受蜣螂滚粪球、舞蹈、繁殖、觅食等自然行为启发的新型元启发式优化算法，其通过模拟蜣螂的多种智能行为来平衡全局探索与局部开发，具体原理与迭代流程详见文献[27]。

表 1 CNN 与 RF 模型的超参数定义与取值范围

Table 1 The definition and range of hyperparameters of CNN and RF

Model	Hyperparameters	Definition	Range
CNN	Kernel size	Filter size in each convolutional layer	[3×3, 5×5]
	Stride	Stride of the convolutional kernel	[1–2]
	Num channels	Number of output channels in the convolutional layer	[16–512]
	Pooling kernel size	Window size used for downsampling in the pooling layer	[2×2, 3×3]
	Pooling stride	Stride of the pooling kernel	[1–2]
	Learning rate	Step size for updating weights in each iteration of the network	[0.001–0.010]
RF	Max depth	Maximum depth of DTs	1–20
	Min samples split	Minimum number of samples for the split	2–10
	Min samples leaf	Minimum number of samples at the leaf node	1–10
	Max DT	Ensemble's largest number of DT representations	1–1000
	Max features	Number of features considered during the selection of the best splitting	0.4–1.0

1.3 模型性能评估指标

为客观量化所构建模型的预测性能与泛化能力，本工作采用 3 种广泛使用的统计指标进行综合评估： R^2 、RMSE 和平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE)。 R^2 衡量模型对目标变量方差的解释程度，越接近 1 表示拟合优度越高；RMSE 反映预测值与真实值之间的绝对误差；MAPE 则从相对误差的角度评估预测精度。其计算公式如式(1)~式(3)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (t_i - p_i)^2}{\sum_{i=1}^n (t_i - \bar{t}_i)^2} \quad (2)$$

$$\text{MAPE} = \frac{\sum_{i=1}^n \left| \frac{t_i - p_i}{t_i} \right|}{n} \times 100\% \quad (3)$$

式中： $\bar{t}_i$ 指真实值的平均值。

1.4 物理信息卷积神经网络模型的构建

1.4.1 基准 CNN 模型的损失函数 损失函数是 ML 模型训练的核心，其功能在于量化模型预测输出与真实目标之间的差异，从而为模型参数的优化提供梯度方向。对于回归任务，RMSE 因其良好的数学性质(处处可导)和对大误差的敏感性而常被用作损失函数。因此，本工作将基准 CNN 模型的损失函数 L_{Data} 定义为 RMSE。

1.4.2 嵌入物理信息方程的混合损失函数设计

为使 CNN 模型对流变参数的预测不仅拟合数据，更能遵循已知的物理规律，本工作将描述流变行为的 PIE 作为软约束嵌入到损失函数中。根据文献[28]，混凝土流变参数与配合比之间存在如下[式(4)和式(5)]经验物理关系。

$$\begin{aligned} \sigma(\text{YS}) = & 327.99 + 2.71 \times [m(\text{S}) / m(\text{B})] - \\ & 194.03 \times [m(\text{W}) / m(\text{B})] - \\ & 145.99 \times [m(\text{FA}) / m(\text{OPC})] + \\ & 419.18 \times [m(\text{SF}) / m(\text{OPC})] + 287.42 \times m(\text{F}) \end{aligned} \quad (4)$$

$$\begin{aligned} \eta(\text{PV}) = & 7.89 + 1.74 \times [m(\text{S}) / m(\text{B})] - \\ & 3.70 \times [m(\text{W}) / m(\text{B})] + \\ & 3.96 \times [m(\text{FA}) / m(\text{OPC})] - \\ & 0.49 \times [m(\text{SF}) / m(\text{OPC})] + 2.73 \times m(\text{F}) \end{aligned} \quad (5)$$

式中: $\sigma(\text{YS})$ 为屈服应力(Pa); $\eta(\text{PV})$ 为塑性黏度(Pa·s); $m(\text{S})$ 、 $m(\text{B})$ 、 $m(\text{W})$ 、 $m(\text{FA})$ 、 $m(\text{OPC})$ 、 $m(\text{SF})$ 、 $m(\text{F})$ 分别代表砂(S)、胶凝材料(B)、水(W)、粉煤灰(FA)、水泥(OPC)、硅灰(SF)、PVA 纤维(F)的含量(kg)。

需要强调的是, 上述 PIE[式(4)和式(5)]是基于特定原材料通过回归分析建立的经验关系式, 其本身并非普适物理定律, 因此对原材料体系和配合比范围存在一定依赖性。正因如此, 本工作并未将其作为绝对真理强制执行, 而是将其作为软约束引入模型训练过程。具体而言, 定义物理信息损失项 L_{PIE} , 用于衡量 CNN 模型预测的流变参数与 PIE 计算的流变参数之间的差异。


PICNN 模型的总体损失函数 L_{Total} 则由数据损失项 L_{Data} 和物理损失项 L_{PIE} 加权求和构成[式(6)~式(8)]。

$$L_{\text{Total}} = w_1 \times L_{\text{Data}} + w_2 \times L_{\text{PIE}} \quad (6)$$

$$L_{\text{Data}} = \text{RMSE}_{\text{CNN}} \quad (7)$$

$$L_{\text{PIE}} = |F_{\text{PIE}} - F_{\text{CNN}}| \quad (8)$$

式中: w_1 和 w_2 分别为两项损失的权重系数, 在模型训练过程中通过超参数优化算法自适应确定; RMSE_{CNN} 为 CNN 模型的均方根误差; F_{CNN} 为 CNN 模型的流变参数预测值; F_{PIE} 为 PIE 的流变参数计算值。这种设计使得模型能够在不同原材料体系中平衡物理一致性与数据拟合精度: 当数据与经验公式一致时, 模型倾向于同时满足两者; 当原材料体系与 PIE 存在差异时, 模型可通过调整权重在数据驱动部分捕获新的规律, 从而有效提升泛化能力。PICNN 融合模型的损失函数修正流程如图 1 所示。



Note: $m(\text{S})$, $m(\text{B})$, $m(\text{W})$, $m(\text{FA})$, $m(\text{OPC})$, $m(\text{SF})$, and $m(\text{F})$ represent the mass (in kg) of sand(S), binder(B), water(W), fly ash(FA), ordinary portland cement(OPC), silica fume(SF), and PVA fiber(F), respectively. $\sigma(\text{YS})$ denotes the yield stress (Pa), and $\eta(\text{PV})$ denotes the plastic viscosity (Pa·s). The terms $m(\text{S})/m(\text{B})$, $m(\text{W})/m(\text{B})$, $m(\text{FA})/m(\text{OPC})$, and $m(\text{SF})/m(\text{OPC})$ represent the corresponding mass ratios.

图 1 PICNN 融合模型损失函数修正流程

Fig. 1 Process of modifying the loss function for the PICNN fusion model

此外, 上述 PIE 的输入参数仅为各组分质量, 未显式考虑胶凝材料的化学成分。这是由于在实际

工程应用中, 材料用量往往是影响流变性能最直接且易于调控的因素, 并且文献[28]已验证该方程在

常见胶凝材料范围内具有良好的预测能力。本工作所构建的数据库(见 2.1 节)涵盖了多个文献中不同化学成分的原材料,使得模型能够通过数据驱动的方式间接学习到化学成分的隐含影响,进一步增强了模型的泛化性与适用范围。未来研究可将化学成分参数(如氧化物含量)作为输入特征,以构建更具物理深度和解释性的流变性能预测模型。


1.4.3 物理约束与数据损失项的权重自适应调优

在 PICNN 的混合损失函数[式(6)]中,权重系数 w_1 和 w_2 决定了数据拟合精度与物理规律一致性

之间的平衡。这 2 个权重系数本身可被视为重要的超参数。为确保模型能在数据驱动与物理约束之间找到最优平衡点,本工作将 w_1 和 w_2 纳入超参数自动调优的范畴,利用第 1.2 节所述的 DBO 算法对其进行优化搜索。

1.5 物理-数据混合驱动研究框架总览

本工作提出的物理-数据混合驱动打印参数优化框架,其总体流程如图 2 所示。该框架系统地展示了从数据准备、物理信息融合模型(PICNN)构建、到打印参数(ES、PS)的预测与计算的全过程。



Note: $\rho(\text{CD})$ represents concrete density, PD denotes the pressure difference, T is the torque, Q refers to the concrete output volume rate, D is the nozzle diameter, L represents the distance between ports, $\sigma(\text{YS})$ is the yield stress, $\eta(\text{PV})$ is the plastic viscosity, ES denotes the extrusion screw angular velocity, and PS represents the printing speed.

图 2 本工作总体流程图

Fig. 2 The general flow chart of this study

2 基于 PICNN 的混凝土流变参数预测

2.1 流变实验数据集与特征分析

本工作用于构建 3D 打印混凝土流变参数预测模型的数据来源于本课题组实验数据以及经过同行评审的公开文献^[29-41]。最终整理得到的 YS 和 PV 数据库分别包含 274 组和 284 组有效数据。表 2 与表 3 分别列出了 2 个数据库的详细统计信息(包括均值 M 、标准差 SD 、最小值 Min 、分位数、最大值 Max 和样本数 C)。由表 2 和表 3 可知, YS 与 PV 预测模型均设置了 9 个相同的输入特征参数,分别为: OPC 含量、 SF 含量、 FA 含量、 S 含量、触变剂(TA)含量、早强剂(ESA)含量、减水剂

(SP)含量、 W 含量和 F 含量。该特征集全面涵盖了影响混凝土流变行为的关键材料组分与物理属性。需要说明的是,本工作所采用的 YS 数据均为动态屈服应力,即混凝土在流动状态下维持流动所需的最小剪切应力。在 3D 打印混凝土研究中,动态屈服应力主要影响材料的泵送性、挤出性和 PS 的匹配,与本工作优化打印参数的目标高度契合。各文献中 YS 的测试方法均采用动态测试协议(如恒定剪切率测试或 Herschel-Bulkley 模型拟合),符合 3D 打印混凝土对泵送性与挤出性评价的需求。表 2 中 YS 的较大变异范围反映了不同配合比、矿物掺合料、外加剂以及纤维掺量对动态屈服应力的显著影响,这种广泛分布为本工作构建高泛化能力的 ML

模型提供了丰富的样本空间。同时,该数据类型与
本工作引入的 PIE 所基于的测试条件一致,确保了
后续物理约束引入的合理性。

本工作所用流变数据中,约 65%来源于课题组
实验测试结果,约 35%来源于公开发表的同行评审
文献。为尽可能减小不同来源数据间因测试设备、
测试制度差异可能引入的系统误差,在数据预处理
阶段采取了以下措施:首先,在数据筛选方面,优
先选取配合比组分明确、涵盖表 2 和表 3 所列 9 种
关键材料含量的数据,且流变参数(YS、PV)必须
采用旋转流变仪或同轴圆柱体流变仪测试获得、测
试方法清晰可查,同时排除配合比信息不完整、流
变参数明显异常或测试条件未说明的数据点;其
次,在数据清洗流程中,依次剔除缺失关键组分的

样本、对同一文献中重复或高度相似的配合比进行
去重处理,并采用箱线图法识别异常值,将超出上
下四分位数以外 3 倍四分位距(IQR)的样本视为异
常值予以剔除;最后,为消除不同特征量纲的影响,
在模型训练前对所有输入特征进行 Z-score 标准化
处理(即减去均值后除以标准差),使各特征服从均
值为 0、标准差为 1 的分布,而输出变量(YS、PV)
则保持原始量纲以利于结果解释。经上述处理,最
终 YS 数据库包含 274 组有效数据,PV 数据库包
含 284 组有效数据,其分布特征详见表 2 和表 3。
此外,本工作采用的 DL 和 EL 算法本身对数据噪
声具有一定鲁棒性,能够在训练过程中降低个别离
群样本的影响,进一步增强了模型对测量误差的容
忍度。

表 2 YS 数据库统计指标
Table 2 The statistical indicators of the YS database

Indicators	Input									Output
	$m(\text{OPC})/\text{kg}$	$m(\text{SF})/\text{kg}$	$m(\text{FA})/\text{kg}$	$m(\text{S})/\text{kg}$	$m(\text{TA})/\text{kg}$	$m(\text{ESA})/\text{kg}$	$m(\text{SP})/\text{kg}$	$m(\text{W})/\text{kg}$	$m(\text{F})/\text{kg}$	$\sigma(\text{YS})/\text{Pa}$
M	284.62	20.50	10.20	400.50	0.80	1.50	25.30	220.50	0.50	600.50
SD	216.59	38.20	24.50	300.20	1.20	2.10	70.50	80.30	1.80	800.20
Min	20.00	0.00	0.00	0.00	0.00	0.00	0.00	20.00	0.00	11.00
25%	100.00	0.00	0.00	100.00	0.00	0.00	0.00	220.00	0.00	120.00
50%	100.00	0.00	0.00	500.00	0.00	0.00	0.00	220.00	0.00	450.00
75%	500.00	30.00	0.00	750.00	0.60	3.30	0.30	330.00	0.00	800.00
Max	1000.00	295.08	200.00	1926.00	7.50	8.00	500.00	392.10	9.10	4940.00
C	274.00	274.00	274.00	274.00	274.00	274.00	274.00	274.00	274.00	274.00

Note: M refers to mean; SD refers to standard deviation; Min refers to minimum; 25%, 50%, and 75% refer to the corresponding percentiles; Max refers to maximum; C refers to count.

表 3 PV 数据库统计指标
Table 3 The statistical indicators of the PV database


Indicators	Input									Output
	$m(\text{OPC})/\text{kg}$	$m(\text{SF})/\text{kg}$	$m(\text{FA})/\text{kg}$	$m(\text{S})/\text{kg}$	$m(\text{TA})/\text{kg}$	$m(\text{ESA})/\text{kg}$	$m(\text{SP})/\text{kg}$	$m(\text{W})/\text{kg}$	$m(\text{F})/\text{kg}$	$\eta(\text{PV})/(\text{Pa}\cdot\text{s})$
M	285.37	20.61	10.21	399.87	0.80	1.49	25.22	220.51	0.50	19.95
SD	215.82	38.08	24.42	299.75	1.19	2.09	70.39	80.25	1.79	14.89
Min	20.00	0.00	0.00	0.00	0.00	0.00	0.00	18.00	0.00	0.55
25%	100.00	0.00	0.00	100.00	0.00	0.00	0.00	220.00	0.00	5.00
50%	100.00	0.00	0.00	500.00	0.00	0.00	0.00	220.00	0.00	10.00
75%	470.00	30.00	0.00	750.00	0.60	3.30	0.30	330.00	0.00	20.00
Max	1000.00	295.08	200.00	1926.00	5.00	8.00	500.00	392.10	9.10	93.25
C	284.00	284.00	284.00	284.00	284.00	284.00	284.00	284.00	284.00	284.00

在上述数据基础上,为深入探究各特征之间的
内在关联及其对输出变量的影响,本工作分别对
YS 数据库和 PV 数据库进行了皮尔逊相关系数
(Pearson correlation coefficient, 记为 r)分析,得到
的相关系数矩阵如图 3a (YS 数据库)和图 3b (PV 数
据库)所示。分析结果揭示了: 1) 胶凝材料组分与


流变参数的相关性。在 YS 数据库中, SF 与 YS 呈
现显著的正相关($r=0.82$), SP 与 YS 也呈中等正相
关($r=0.59$), 表明 SF 和 SP 对提高 YS 具有重要作
用。SF 的微细颗粒填充效应和火山灰活性可增强
浆体内聚力; 而 SP 在适宜掺量下通过分散水泥颗
粒, 反而可能因释放更多自由水而略微提高 YS (需

结合具体配合比分析)。值得注意的是, FA 与 YS 呈弱的负相关($r=-0.09$), 可能与 FA 的球形颗粒形态降低内摩擦有关。在 PV 数据库中, 各胶凝材料

组分与 PV 大多呈负相关, 其中 OPC 与 PV 的负相关最强($r=-0.48$), 这是因为在测试的配合比范围内, OPC 的增加伴随着用水量的同步增加(OPC 与



(a) YS database



(b) PV database

Note: OPC refers to ordinary portland cement, SF refers to silica fume, FA refers to fly ash, S refers to sand, TA refers to thixotropic agent, ESA refers to early strength agent, SP refers to superplasticizer, W refers to water, F refers to fiber, YS refers to yield stress, and PV refers to plastic viscosity.

图3 YS 和 PV 数据库特征相关性矩阵

Fig. 3 Correlation matrices of features in YS and PV databases

W 的相关系数高达 0.97), 从而稀释了浆体黏度。2) W 与流变参数的负相关关系。W 与 YS ($r=0.23$) 和 PV ($r=-0.47$) 表现出不同的相关性。W 与 YS 的弱正相关看似反常, 但结合数据库特征分析, W 与 OPC 高度正相关($r=0.96$), 说明在数据集中水胶比基本稳定, OPC 增大时 W 也相应增加, 水泥的增强效应可能掩盖了水的稀释效应, 导致 W 与 YS 呈现正相关。而 W 与 PV 的明显负相关则符合经典流变学规律: 水增加使浆体变稀, PV 降低。3) SP 与流变参数的相关性。SP 与 YS 呈中等正相关($r=0.59$), 但与 PV 几乎无关($r=0.005$)。这可能是因为 SP 的主要作用是分散水泥颗粒, 降低 YS, 但若配合比中 OPC 较高, SP 的分散效应可能被水泥水化的增强效应所抵消, 导致 YS 不降反升; 而 PV 对 SP 的响应则更为复杂, 受颗粒级配和絮凝结构共同影响。4) TA 与流变参数的相关性。TA 与 YS 呈弱的负相关($r=-0.15$), 与 PV 也呈弱的负相关($r=-0.19$)。可能的原因是数据库中 TA 与其他组分(如 S, TA 与 S 在 YS 数据库中相关系数为 0.71)存在交互作用。5) F 与流变参数的相关性。F 与 YS 相关性极弱($r=0.03$), 与 PV 呈弱的正相关($r=0.07$)。纤维的加入理论上会增加浆体内部摩擦, 提高 PV, 但本数据库中 F 普遍较低, 因此对宏观流变性能的影响尚未充分显现。6) 特征间的共线性分析。各输入特征之间的相关系数绝对值大多低于 0.8, 表明不存在严重的多重共线性问题, 适合作为 ML 模型的输入。值得注意的高相关性包括: OPC 与 W ($r=0.96\sim0.97$), 反映了水胶比在设计中的稳定性; OPC 与 S ($r=0.68\sim0.71$), 表明 OPC 与 S 通常同步调整以维持砂浆的工作性; TA 与 S($r=0.71\sim0.77$), 可能与 TA 常与细骨料协同使用有关。这些关联为后续 PIE 的构建提供了数据基础。

此外, 为评估本工作数据库的广泛性与代表性, 对所收集文献中采用的胶凝材料化学成分进行了统计与对比。主要胶凝材料包括 OPC、FA 和 SF。参考文献[29-41]中 OPC 的矿物组成范围大致为: C_3S 45%~60%(质量分数, 下同), C_2S 15%~30%, C_3A 5%~12%; FA 多为 F 类或 C 类, 烧失量(质量分数)在 2%~8%之间; SF 的 SiO_2 含量普遍高于 85%。这些材料特性涵盖了 3D 打印混凝土研究中常见的胶凝材料类型, 表明本数据库具有良好的代表性, 能够支持 PIE 与 ML 融合模型的训练与验证。

2.2 物理约束损失函数的构建与实现

基于第 1.4.2 节所述的通用框架, 针对 YS 和

PV 的预测, 对混合损失函数进行了具体化。对于 YS 预测, 其总体损失函数 $L_{YS\text{Total}}$ 由数据驱动损失项 $L_{YS\text{Data}}$ 和物理信息损失项 $L_{YS\text{PIE}}$ 加权构成, 具体形式如式(9)~式(11)所示。

$$L_{YS\text{Total}} = w_{YS1} \times L_{YS\text{Data}} + w_{YS2} \times L_{YS\text{PIE}} \quad (9)$$

$$L_{YS\text{Data}} = \text{RMSE}_{YSCNN} \quad (10)$$

$$L_{YS\text{PIE}} = |F_{YS\text{PIE}} - F_{YSCNN}| \quad (11)$$

式中: RMSE_{YSCNN} 为用于预测 YS 的 CNN 模型的均方根误差(Pa); F_{YSCNN} 为 CNN 模型的 YS 预测值(Pa); $F_{YS\text{PIE}}$ 为 PIE 的 YS 计算值(Pa); 权重系数 w_{YS1} 和 w_{YS2} 为无量纲参数, 根据 2.3 节的超参数调优结果, 均设定为 0.5。

同理, 对于 PV 预测, 其损失函数定义为式(12)~式(14)。

$$L_{PV\text{Total}} = w_{PV1} \times L_{PV\text{Data}} + w_{PV2} \times L_{PV\text{PIE}} \quad (12)$$

$$L_{PV\text{Data}} = \text{RMSE}_{PVCNN} \quad (13)$$

$$L_{PV\text{PIE}} = |F_{PV\text{PIE}} - F_{PVCNN}| \quad (14)$$

式中: RMSE_{PVCNN} 为用于预测 PV 的 CNN 模型的均方根误差(Pa·s); F_{PVCNN} 为 CNN 模型的 PV 预测值(Pa·s); $F_{PV\text{PIE}}$ 为 PIE 的 PV 计算值(Pa·s); 权重系数 w_{PV1} 和 w_{PV2} 为无量纲参数, 根据 2.3 节的超参数调优结果, w_{PV1} 和 w_{PV2} 分别设定为 0.4 和 0.6。


2.3 模型超参数协同优化过程

在超参数优化过程中, DBO 算法的种群大小设置为 100, 每个个体的维度(即待优化超参数数量)为 5。图 4 展示了 PICNN 模型分别在 YS 与 PV 预测中的超参数优化迭代过程。图 4a 和图 4b 为 YS 预测的优化过程。随着迭代次数增加, RMSE 持续下降, 并在约第 1080 次迭代后趋于稳定, 表明模型已收敛。优化至第 3000 次迭代时, RMSE 最终降至 93.96 Pa。值得注意的是, 模型在第 638 次迭代后 RMSE 即已保持在较低水平, 体现了 DBO 算法快速收敛与高效优化的能力。YS 预测对应的 PICNN 模型最佳超参数如表 4 所示。图 4c 和图 4d 展示了 PV 预测的优化过程, 其收敛趋势与 YS 预测相似。该模型在第 723 次迭代后基本收敛, 最终 RMSE 为 0.25 Pa·s。同样地, DBO 在该任务中也表现出较高的优化效率。PV 预测的最佳超参数也汇总于表 4。


在 PICNN 模型的权重优化过程中, 目标函数设定为最小化测试集上的 RMSE。通过将物理损失项与数据损失项的权重系数(w_1 、 w_2)纳入 DBO 算法的协同搜索空间(取值范围为 0.1~0.9), 算法在优化网络结构超参数的同时自动探索权重组合, 使总

体损失函数能够有效平衡物理约束强度与数据拟合程度。该设计隐含了物理一致性与预测性能之间的权衡：若物理损失权重过高，模型可能过度偏离实测数据导致 RMSE 上升；反之，若数据损失权


重过高，物理约束作用减弱，模型预测可能丧失物理合理性，同样不利于泛化性能。DBO 算法的全局搜索能力确保了权重配置能够收敛至使 RMSE 最小的区域。




(a) Evolution of RMSE across training iteration stages in YS prediction



(b) Analysis of model convergence point and early iteration error in YS prediction



(c) Evolution of RMSE across training iteration stages in PV prediction



(d) Analysis of model convergence point and early iteration error in PV prediction

Note: RMSE refers to root mean square error, which evaluates the accuracy of the prediction model by measuring the square root of the average squared difference between the predicted and actual values.

图4 PICNN 模型超参数优化迭代过程

Fig. 4 Iterative process of hyperparameter tuning for the PICNN model

经优化后，最终确定的权重组合(YS 预测： $w_{YS1}=0.5$, $w_{YS2}=0.5$ ；PV 预测： $w_{PV1}=0.4$, $w_{PV2}=0.6$)

在搜索空间中使测试集 RMSE 达到最小。这一结果表明，在给定数据集和物理方程约束下，上述权

重能够有效平衡物理规律与数据分布之间的关系: 既保证模型预测符合基本物理趋势, 又充分拟合实验数据特征, 从而兼顾物理一致性与预测精度。由于优化目标直接为 RMSE, 任何偏离该最优权重的组合(无论是偏向数据还是偏向物理)均会导致预测误差增大, 这从优化原理上验证了所得权重配置的合理性。

表 4 PICNN 模型最佳超参数

Table 4 Optimal hyperparameters for the PICNN model

Hyperparameter	Prediction target	
	YS	PV
Kernel size	3×3	3×3
Stride	1	1
Num channels	65	27
Pooling kernel size	2×2	2×2
Pooling stride	1	1
Learning rate	0.001	0.001
Weight CNN	0.5	0.4
Weight PIE	0.5	0.6

2.4 训练过程中损失函数演变规律分析

PICNN 模型的可训练参数(如卷积层与全连接层的权重与偏置)通过 Adam 优化器在训练过程中持续更新, 以最小化总体损失函数。这些内部参数与超参数在定义、作用机制及调优方式上存在明显差异, 具体对比如表 5 所示。本工作将训练周期(Epoch)设置为 3000 轮, 以确保模型充分学习。

图 5 展示了 PICNN 模型在训练集上损失函数的演变过程。对于 YS 预测模型(图 5a), 其初始损失值较高(661.31 Pa)。在训练前期(前 500 Epochs), 损失值迅速下降, 表明模型正在快速捕捉数据中的基本特征。随后(500~3000 Epochs), 损失下降趋于平缓, 最终稳定在 69.75 Pa, 显示模型逐渐逼近最优解并进行精细化调整。PV 预测模型(图 5b)则表现出更为平稳的下降趋势。其初始损失为 0.47 Pa·s, 随着训练进行, 损失持续缓慢降低, 最终收敛至 0.16 Pa·s。整体训练过程中损失曲线平滑下降, 反映了模型结构设计与优化算法配合良好, 训练稳定性与收敛性比较可靠。

表 5 PICNN 模型内部参数与超参数对比

Table 5 Differences between internal parameters and hyperparameters of the PICNN model

Comparison item	Internal parameters	Hyperparameters
Definition	Internal learnable parameters of the model. They are learned from the training data and used to represent the features and patterns of the data	Settings parameters during the model establishment and training process. They are not learned from the training data but are manually specified before training begins
Scope of influence	They directly influence the model's output and are core components of the model. Adjusting internal parameters directly alters the model's predictive capability	They influence the model's establishment and training process but do not directly affect the model's output. The selection of hyperparameters impacts the model's structure, learning process, and performance
Tuning principle	During the training process, dynamic tuning is conducted through optimization algorithms to minimize the loss function. In each iteration, internal parameters are updated based on the gradient of the loss function to gradually optimize the model's performance	They are fixed parameters set before training and then remain unchanged or periodically adjusted during the training process to optimize model performance
Tuning method	Optimization typically involves minimizing the loss function, often achieved through the use of backpropagation algorithms to compute gradients and update parameters	To determine the optimal solution, different combinations of hyperparameters are experimented with and evaluated. Techniques such as crossvalidation, grid search, or metaheuristic search can be employed for this purpose

2.5 PICNN 模型预测性能对比验证

2.5.1 与纯数据驱动 CNN 模型的对比 图 6 和图 7 对比了 PICNN 与基准 CNN 模型在训练集和测试集上的损失表现。在 YS 预测中(图 6), PICNN 模型在训练集和测试集上的平均损失分别为 192.66 Pa 和 198.92 Pa, 均显著低于 CNN 模型对应的 237.66 Pa 和 307.80 Pa。图中展示的损失差值(PICNN 损失-CNN 损失)在测试集上全部为负值,

在训练集上也绝大多数为负值, 这表明 PICNN 模型无论在数据拟合还是泛化能力方面均优于纯数据驱动的 CNN 模型。在 PV 预测中(图 7), 同样观察到 PICNN 模型的损失值全面低于 CNN 模型。PICNN 在训练集和测试集上的平均损失分别为 0.32 Pa·s 和 0.37 Pa·s, 而 CNN 模型分别为 0.50 Pa·s 和 0.77 Pa·s。对应的损失差值也以负值为主。上述结果一致表明, 引入物理信息约束有效提升了模型

的预测精度与泛化鲁棒性。

2.5.2 与纯物理驱动 PIE 的对比 为评估 PICNN 模型输出与物理规律的一致性, 本工作进一步将其与纯物理驱动 PIE 的预测结果进行对比。两者损失值越接近, 表明 PICNN 模型越符合物理约束。图 8 和图 9 展示了 PICNN 模型与 PIE 在 YS 与 PV 预测上的损失对比及误差分布。可以看出, 无论在训练集还是测试集上, PICNN 的损失值与 PIE 的损失值均十分接近。误差分布也显示, 两者

的差异普遍保持在较低水平(YS 测试集平均绝对误差为 62.25 Pa, PV 测试集平均绝对误差为 0.11 Pa·s)。为量化这一致性, 进一步计算了 PICNN 与 PIE 预测损失之间的 RMSE 和 MAPE, 结果见表 6 与表 7。所有指标均处于较低数值, 例如 YS 测试集的 MAPE 为 6.17%, PV 测试集的 MAPE 为 2.70%。这些结果定量证明, PICNN 模型在保持较高预测精度的同时, 其输出严格遵循了已知物理规律, 体现了物理信息嵌入的有效性。




图 5 PICNN 模型损失函数演变

Fig. 5 Loss function evolution for the PICNN model

3 基于流变性能预测的打印参数智能优化

3.1 基于物理先验数据库的挤出螺杆转速智能预测

3.1.1 多物理方程耦合的数据库构建流程 为实现对 ES 的精准预测, 本工作采用“PIE 串联 ML”策略, 首先构建了 1 个包含 274 组数据的 ES 数据库。用于训练 RF 模型的 8 个输入参数及其赋值方法如表 8 所示。其中, 混凝土密度 $[\rho(\text{CD})]$ 、进出口压差(PD)和所需扭矩(T)这 3 个关键输入参数需通过物理方程计算得到式(15)~式(17)。


$$\left\{ \begin{aligned} \rho(\text{CD}) &= m(\text{CM}) / V(\text{CV}) \\ m(\text{CM}) &= m(\text{OPC}) + m(\text{SAC}) + m(\text{SF}) + \\ &\quad m(\text{FA}) + m(\text{S}) + m(\text{TA}) + \\ &\quad m(\text{ESA}) + m(\text{SP}) + m(\text{W}) + m(\text{F}) \\ V(\text{CV}) &= m(\text{OPC}) / \rho(\text{OPC}) + \\ &\quad m(\text{SAC}) / \rho(\text{SAC}) + m(\text{SF}) / \rho(\text{SF}) + \\ &\quad m(\text{FA}) / \rho(\text{FA}) + m(\text{S}) / \rho(\text{S}) + \\ &\quad m(\text{TA}) / \rho(\text{TA}) + m(\text{ESA}) / \rho(\text{ESA}) + \\ &\quad m(\text{SP}) / \rho(\text{SP}) + m(\text{W}) / \rho(\text{W}) + \\ &\quad m(\text{F}) / \rho(\text{F}) \end{aligned} \right. \quad (15)$$

$$\text{PD} = \rho(\text{CD}) \times \left(\frac{1}{2} \times (v_2^2 - v_1^2) + g \times L \right) \quad (16)$$

$$\begin{cases} T = r \times F \\ F = \mu \times N \\ N = \rho(\text{CD}) \times g \times \text{PPV} \end{cases} \quad (17)$$

式中: $\rho(\text{CD})$ 为混凝土密度(kg/m^3); $m(\text{CM})$ 为混凝

土质量(kg); $V(\text{CV})$ 为混凝土体积(m^3); $m(\text{OPC})$ 、 $m(\text{SAC})$ 、 $m(\text{SF})$ 、 $m(\text{FA})$ 、 $m(\text{S})$ 、 $m(\text{TA})$ 、 $m(\text{ESA})$ 、 $m(\text{SP})$ 、 $m(\text{W})$ 、 $m(\text{F})$ 和 $\rho(\text{OPC})$ 、 $\rho(\text{SAC})$ 、 $\rho(\text{SF})$ 、 $\rho(\text{FA})$ 、 $\rho(\text{S})$ 、 $\rho(\text{TA})$ 、 $\rho(\text{ESA})$ 、 $\rho(\text{SP})$ 、 $\rho(\text{W})$ 、 $\rho(\text{F})$



Note: Training set is the data used to fit the model parameters during training, while the test set is the independent data used to evaluate the model's performance; The blue curve shows the error distribution (actual vs. predicted) on the training set, reflecting how well the model fits the seen data; The orange curve shows the error distribution on the test set, representing the model's predictive performance on new, unseen data; The horizontal axis represents the range of error values (in Pa). By comparing the two curves—especially their relative positions and the gap between them—we can assess the model's generalization ability.

图 6 PICNN 与 CNN 模型在 YS 数据集上的损失对比及误差分布

Fig. 6 Comparison of loss and error distribution between PICNN and CNN models on YS dataset




图7 PICNN 与 CNN 模型在 PV 数据集上的损失对比及误差分布

Fig. 7 Comparison of loss and error distribution between PICNN and CNN models on PV dataset

分别指 OPC、SAC、SF、FA、S、TA、ESA、SP、W、F 的质量(kg)与密度(kg/m^3); PD 为混凝土进出口压力差(N/m^2); v_1 和 v_2 分别为混凝土进口与出口流速, 本工作分别设定为 0.05 m/s 和 0.1 m/s ; g 为重力加速度(9.80 m/s^2); L 指进出口高度差(m); T 为挤出螺杆所需扭矩($\text{N}\cdot\text{m}$); r 为螺杆半径(0.05 m); F 为螺杆表面摩擦力(N); μ 为摩擦系数(0.6); N 为垂直于螺杆和混凝土接触表面的正压力(N); PPV 为打印管道体积(0.00157 m^3).

数据库的输出目标——ES, 则根据文献[42]提出的关联方程式(18)计算。

$$\text{ES} = \frac{a \times \left(\frac{\text{PD} \times L^3}{T} \right)^4 + b \times \left(\frac{\text{PD} \times L^3}{T} \right)^2}{\pi^2 \times D^7 \times \left(\text{PV} \times \left(\frac{Q}{D^3} \right) + \text{YS} \right)} \times \rho(\text{CD}) \times Q^3 \quad (18)$$

式中: Q 即出口处混凝土体积流量(m^3/s); D 为打印喷嘴直径(m); YS 与 PV 分别为由第 3 节 PICNN

模型预测的 $YS(\text{Pa})$ 与 $PV(\text{Pa}\cdot\text{s})$; ES 为挤出螺杆转速(r/s); a 和 b 为模型常数, 取值参见文献[42]。该方程综合反映了挤出过程中多种物理因素的耦合作用: 1) 分子部分 $[a \times (\text{PD} \times L^3/T)^4 + b \times (\text{PD} \times L^3/T)^2]$ 代表了挤出系统的驱动能力, 其中无量纲组合

$\text{PD} \times L^3/T$ 体现了压力驱动(PD)与机械驱动(T)的相对强度, 并通过 2 次和 4 次项拟合其非线性影响; 2) 分母部分 $\pi^2 \times D^7 \times [\eta(\text{PV}) \times Q/D^3 + \sigma(\text{YS})]$ 表征了材料流动需克服的流变阻力, 其中 $\eta(\text{PV}) \times Q/D^3 + \sigma(\text{YS})$ 为总有效应力(黏性应力与屈服应力之和),




图 8 PICNN 模型与 PIE 在 YS 数据集上的损失对比及误差分布

Fig. 8 Comparison of loss and error distribution between PICNN model and PIE on YS dataset




图9 PICNN 模型与 PIE 在 PV 数据集上的损失对比及误差分布

Fig. 9 Comparison of loss and error distribution between PICNN model and PIE on PV dataset

$\pi^2 \times D^7$ 为喷嘴几何的强放大因子；3) 额外因子 $\rho(\text{CD}) \times Q^3$ 则引入了惯性效应，体现了材料密度与流量对动量通量的贡献。整体而言，式(18)建立了 ES 与材料特性 $[\sigma(\text{YS})$ 、 $\eta(\text{PV})$ 、 $\rho(\text{CD})$]、几何参数 $(D$ 、 $L)$ 及工艺条件 $(Q$ 、 PD 、 $T)$ 之间的经验关联，为 3D 打印混凝土的工艺参数智能设计提供了理论基础。

3.1.2 数据库特征分析与预处理 ES 数据库的构建基于从文献[29–41]收集的混凝土配合比数据以及本课题组的实验数据，通过上述物理方程计算、PICNN 模型预测及目标参数设定，综合生成了 274 组完整数据记录。表 9 列出了该数据库的详细统计指标，显示了各参数的数据分布特征，为模

3.1.3 随机森林模型超参数优化 采用 DBO 算法对 RF 模型进行超参数优化, 其中种群大小设置为 100, 个体维度为 5。优化过程如图 10 所示, RMSE 随迭代次数增加迅速下降, 随后进入平稳收

敛阶段, 并于第 1067 次迭代后趋于稳定。经 3000 次迭代后, 模型达到最佳 RMSE 为 2.68 r/s, 表明 DBO 算法能够有效、精确地完成超参数寻优。最终得到的最佳超参数组合见表 10。




图 10 ES 预测模型(RF)的超参数优化迭代过程

Fig. 10 Iterative process of hyperparameter tuning for the RF model used in predicting ES

表 10 RF 模型最佳超参数

Table 10 The optimal hyperparameters for the RF model


Hyperparameters	Prediction target (ES)
Max depth	10.0
Min samples split	6.0
Min samples leaf	8.0
Max DT	127.0
Max features	0.5

3.1.4 挤出螺杆转速预测结果与精度分析 基于优化后的 RF 模型, ES 的预测结果如图 11 所示。图 11a 和图 11b 分别为训练集和测试集上预测值与实际值的散点密度图, 可见数据点紧密分布于拟合线两侧, 呈现显著线性相关。模型在训练集和测试集上的 R^2 分别达到 0.99 和 0.97, RMSE 分别为 1.86 r/s 和 2.39 r/s, 表明其具有优异的预测精度。图 11c 进一步展示了预测误差的分布情况。训练集与测试集的平均误差分别为 0.70 r/s 和 1.23 r/s, 且

绝大多数误差集中于较低区间。尽管存在个别误差较高的异常点(最大误差为 17.11 r/s), 但数量极少, 不影响模型整体性能。该结果表明, 所构建的 RF 模型能够有效捕获 ES 与输入参数之间复杂的非线性关系, 具有良好的鲁棒性与可靠性。

3.2 基于质量守恒的打印速度的协同计算与案例验证

在 3.1 节中, 本工作通过“PIE 串联 ML”策略, 基于材料流变属性(PICNN 模型预测的 YS、PV)与 PIE(密度方程、伯努利方程、扭矩方程)构建了 ES 的先验数据库, 并采用 RF 算法实现了 ES 的高精度预测。然而, ES 仅是挤出系统的内部控制参数, 在实际打印过程中, 还需协同确定另一个关键工艺参数(PS), 以确保挤出的材料能够精确沉积形成目标几何形状。因此, PS 的计算是前述物理—数据混合驱动框架的最终输出环节, 也是实现“材料属性预测、挤出参数优化、打印过程规划”完整技术路线的关键一步。



Note: Density refers to the color scale, which indicates the local density of data points. Darker colors represent a higher concentration of overlapping observations in the scatter plot; Training set is the data used to fit the model parameters during training, while the test set is the independent data used to evaluate the model's performance; The green curve shows the error distribution (actual vs. predicted) on the training set, reflecting how well the model fits the seen data; The yellow curve shows the error distribution on the test set, representing the model's predictive performance on new, unseen data; The horizontal axis represents the range of error values (in r/s). By comparing the two curves—especially their relative positions and the gap between them—we can assess the model's generalization ability.

图 11 ES 预测模型的性能评估
Fig. 11 Performance evaluation of the ES prediction model

3.2.1 基于质量守恒的打印速度计算方程推导

在确定了 ES 之后, 另一个关键的打印参数 (PS) 需要被协同确定。PS 的计算基于质量守恒原理, 即单位时间内从喷嘴挤出的混凝土体积应等于打印头移动所形成的条带体积, 其基本表达式如式(19)所示。

$$PS = \frac{Q}{A_{\text{cross-section}}} \quad (19)$$

式中: PS 为打印速度(m/s); Q 为目标流量(m^3/s); $A_{\text{cross-section}}$ 为挤出条带的横截面积(m^2)。在实际工程应用中, $A_{\text{cross-section}}$ 的取值与喷嘴几何形状及材料沉积后的变形行为密切相关。本工作采用当前 3D 打印混凝土研究中常用的简化形式[式(20)]。

$$PS = \frac{Q}{PN \times PH} \quad (20)$$

式中: PN 指打印喷嘴直径(m); PH 指每层的打印层高(m)。该简化形式隐含了条带截面为矩形的假设, 即挤出材料在沉积后形成宽度等于 PN、

高度等于 PH 的矩形条带。这一假设在喷嘴为矩形或材料具有良好形状保持能力时具有近似合理性, 且公式形式简洁, 便于工程计算和参数初步设定。需要指出的是, 式(20)基于理想的几何假设, 未考虑材料挤出后因重力、上层材料压力以及材料自身触变性而产生的沉降和侧向膨胀变形。在实际 3D 打印过程中, 挤出条带往往会发生一定程度的压扁, 导致实际截面面积大于 $PN \times PH$ (若以最终成型尺寸计) 或小于 $PN \times PH$ (若以初始挤出尺寸计), 进而影响 PS 与层高、层宽之间的匹配关系。这一局限性在打印层数较多、材料 YS 较低或 PS 较快时尤为显著。进一步地, 对于圆形喷嘴, 若挤出条带保持圆形截面, 其截面积应为 $\pi \times (PN/2)^2$, 此时打印速度应修正为 $PS = 4Q/(\pi \times PN^2)$ 。然而, 在实际打印过程中, 由于重力、上层压力以及材料触变性的综合影响, 圆形挤出条带往往发生变形, 最终截面形状介于圆形和矩形之间, 使得截面面积的精确计算更为

复杂。为提升公式的通用性，可引入无量纲形状因子 k 对截面面积进行修正[式(21)]。

$$PS = \frac{Q}{k \times PN \times PH} \quad (21)$$

式中： k 取决于喷嘴几何形状、材料流变特性及打印参数，需通过实验或数值模拟确定。当条带截面为矩形时， $k=1$ ；当截面为圆形且完全保持圆形时， $k=\pi/4 \approx 0.785$ 。通过实验标定不同材料与打印参数下的 k 值，可对截面面积进行经验修正，从而更准确地计算打印速度。

针对上述问题，除引入形状因子外，还可从以下方向进行更深入的修正：1) 基于流变–沉积耦合数值模拟，建立考虑材料触变性和重力效应的截面变形预测模型，动态修正 PS；2) 在控制系统中引入闭环反馈，通过实时监测条带几何尺寸调整打印速度或流量。这些方法有望进一步提升打印参数匹配的精度，尤其适用于复杂材料体系和多层打印场景。

此外，需要指出的是， Q 的合理取值范围与材料的流变特性密切相关：若 Q 过大，可能导致挤出压力不足或材料堆积；若 Q 过小，则可能出现断丝或层间粘结不良。因此，在工程应用中， Q 的设定可参考第 3.1 节中 ES 预测模型的输入范围，或结合 PICNN 模型预测的流变参数进行动态调整。这体现了本工作所提出的物理–数据混合驱动框架中各模块之间的内在联系与协同作用。

本工作作为物理–数据混合驱动方法的初步探索，主要验证框架的有效性，且所涉及的案例均基于矩形截面假设，因此采用式(20)进行计算。未来可结合流变–沉积耦合模拟，建立更普适的 PS 计算模型。

3.2.2 多目标工况下的打印参数优化案例研究

为展示上述计算方程的实际应用，并进一步说明 PS 与 Q 、PN、PH 之间的协同关系，本工作设定了一系列在 3D 打印混凝土中常见的 Q 、PN 和 PH 取值组合，根据式(20)计算了相应的 PS 值，结果列于表 11。这些案例为实际打印过程中的参数配置提供了直观参考。例如，当 Q 较小而 PN 或 PH 较大时，需相应降低 PS 以确保挤出的材料能够充分填充路径空间；反之，当 Q 较大且 PN 较小时，则需提高 PS 以避免材料堆积。

综上，本节通过 PS 计算方程的推导与案例验证，完成了从材料流变属性预测(PICNN)–ES 预测(RF)–PS 计算的全流程闭环。该闭环不仅实现了物

理机理与数据驱动的深度融合，也为 3D 打印混凝土的工艺参数智能化设计提供了系统的解决方案。

表 11 Q 、PN、PH 常用设定值及对应的 PS 计算值
Table 11 Commonly set values for Q , PN, and PH and the corresponding PS value

Target value			Calculated value
$Q/(\text{m}^3 \cdot \text{s}^{-1})$	PN/m	PH/m	PS/ $(\text{m} \cdot \text{s}^{-1})$
0.000 02	0.01	0.010	0.200
0.000 02	0.01	0.015	0.130
0.000 02	0.01	0.020	0.100
0.000 02	0.02	0.010	0.100
0.000 02	0.02	0.015	0.067
0.000 02	0.02	0.020	0.050
0.000 02	0.03	0.010	0.067
0.000 02	0.03	0.015	0.044
0.000 02	0.03	0.020	0.033
0.000 03	0.01	0.010	0.300
0.000 03	0.01	0.015	0.200
0.000 03	0.01	0.020	0.150
0.000 03	0.02	0.010	0.150
0.000 03	0.02	0.015	0.100
0.000 03	0.02	0.020	0.075
0.000 03	0.03	0.010	0.100
0.000 03	0.03	0.015	0.067
0.000 03	0.03	0.020	0.050
0.000 04	0.01	0.010	0.400
0.000 04	0.01	0.015	0.270
0.000 04	0.01	0.020	0.200
0.000 04	0.02	0.010	0.200
0.000 04	0.02	0.015	0.130
0.000 04	0.02	0.020	0.100
0.000 04	0.03	0.010	0.130
0.000 04	0.03	0.015	0.089
0.000 04	0.03	0.020	0.067

4 结论

本工作提出了一套基于物理信息与数据驱动融合建模的 3D 打印混凝土打印参数优化框架，旨在实现打印参数与材料流变属性的精准匹配。该框架通过两种不同的融合策略，分别构建了流变性能预测模型与 ES 预测模型，并推导了 PS 的解析计算方程。主要研究成果与结论如下：

1) 提出了物理信息嵌入的流变性能预测模型，显著提升了预测精度与物理一致性。通过将描述流变行为的 PIE 作为约束项嵌入 CNN 的损失函数，构建了物理信息约束的 CNN 模型。通过超参数优化确定了物理损失与数据损失项的最佳权重组合。模型训练过程稳定收敛，与纯数据驱动的 CNN 模型和传统物理方程相比，该模型在 YS 与 PV 预测上均表现出优秀的精度与最强的泛化能

力,同时其预测结果与客观物理规律高度吻合。

2) 构建了物理信息串联的ES预测方法,实现了基于材料属性的工艺参数智能决策。通过耦合密度方程、伯努利方程、扭矩方程等一系列物理机理与前述PICNN流变预测模型,建立了ES的先验数据库。基于此数据库,采用经超参数优化的RF算法构建了ES预测模型。该模型在训练集与测试集上分别达到了0.99和0.97的 R^2 ,证明了该方法能够高精度、高鲁棒性地根据材料特性与设备条件反向推荐最优的ES。

3) 形成了完整的打印参数优化解决方案。基于质量守恒原理,推导出以 Q 、 PN 和 PH 为变量的PS显式计算方程,为打印路径规划提供了直接理论依据。最终,将流变预测、ES预测与PS计算集成,形成了从材料到工艺的完整参数优化链条。

本工作为3D打印混凝土的工艺参数设计提供了兼具物理机理可靠性与数据驱动智能化的新范式,有助于减少对传统“试错法”的依赖,提升了打印成型质量与施工效率,对推动建筑3D打印技术的智能化发展具有积极意义。未来的研究可考虑将胶凝材料的化学成分参数(如氧化物组成及矿物相比例)纳入输入特征,构建更具可解释性和机理支撑的预测模型。此外,本工作在ES预测中采用的关联方程及 T 计算均基于特定螺杆几何假设,未来可进一步将螺杆几何参数(如螺距、螺旋升角、长径比等)纳入输入特征,构建更具普适性的ES预测模型。同时,可通过数值模拟或实验设计,生成覆盖广泛几何参数的数据集,为模型的泛化能力提供更坚实的数据基础。在此基础上,进一步探索更为复杂的多目标优化场景,并深入研究打印过程中基于实时参数的动态调控策略,以实现成型质量与效率的协同优化。

参考文献:

- [1] 张超,邓智聪,马蕾,等. 3D打印混凝土研究进展及其应用[J]. 硅酸盐通报, 2021, 40(6): 1769–1795.
ZHANG Chao, DENG Zhicong, MA Lei, et al. Bull Chin Ceram Soc, 2021, 40(6): 1769–1795.
- [2] 孙晓燕,叶柏兴,王海龙,等. 3D打印混凝土材料与结构增强技术研究进展[J]. 硅酸盐学报, 2021, 49(5): 878–886.
SUN Xiaoyan, YE Baixing, WANG Hailong, et al. J Chin Ceram Soc, 2021, 49(5): 878–886.
- [3] EL-SAYEGH S, ROMDHANE L, MANJIKIAN S. A critical review of 3D printing in construction: Benefits, challenges, and risks[J]. Arch Civ Mech Eng, 2020, 20(2): 34.
- [4] MOBASHERI F, HOSSEINPOOR M, YAHIA A, et al. Machine learning as an innovative engineering tool for controlling concrete performance: A comprehensive review[J]. Arch Computat Methods Eng, 2025, 32(8): 4723–4767.
- [5] NI B W, RAHMAN M Z, GUO S C, et al. A review on properties and multi-objective performance predictions of concrete based on machine learning models[J]. Mater Today Commun, 2025, 44: 112017.
- [6] 蒋志鹏,高畅,汤金辉,等. 超高性能混凝土早期收缩性能及神经网络预测模型[J]. 硅酸盐学报, 2025, 53(5): 1098–1109.
JIANG Zhipeng, GAO Chang, TANG Jinhui, et al. J Chin Ceram Soc, 2025, 53(5): 1098–1109.
- [7] 余睿,陈飞翔,范定强,等. 基于机器学习技术的超高性能混凝土性能预测与精细化设计[J]. 硅酸盐学报, 2025, 53(5): 1165–1176.
YU Rui, CHEN Feixiang, FAN Dingqiang, et al. J Chin Ceram Soc, 2025, 53(5): 1165–1176.
- [8] 梅生启,武腾,王兴举,等. 基于融合机器学习方法的机制砂混凝土徐变显式建模[J]. 硅酸盐学报, 2025, 53(11): 3101–3113.
MEI Shengqi, WU Teng, WANG Xingju, et al. J Chin Ceram Soc, 2025, 53(11): 3101–3113.
- [9] SHAHROKHISHAHRAKI M, MALEKPOUR M, MIRVALAD S, et al. Machine learning predictions for optimal cement content in sustainable concrete constructions[J]. J Build Eng, 2024, 82: 108160.
- [10] PENG L G, MIAO X, ZHU J X, et al. Hybrid machine learning and multi-objective optimization for intelligent design of green and low-carbon concrete[J]. Sustain Mater Technol, 2025, 45: e01605.
- [11] GENG S Y, MEI L, CHENG B Y, et al. Revolutionizing 3D concrete printing: Leveraging RF model for precise printability and rheological prediction[J]. J Build Eng, 2024, 88: 109127.
- [12] 马宗方,戴溢阳,贺静,等. 基于机器学习的混凝土3D打印沉积线状态优化[J]. 工程设计学报, 2025, 32(4): 488–498.
MA Zongfang, DAI Yiyang, HE Jing, et al. Chin J Eng Des, 2025, 32(4): 488–498.
- [13] GENG S Y, LUO Q L, CHENG B Y, et al. Intelligent multi-objective optimization of 3D printing low-carbon concrete for multi-scenario requirements[J]. J Clean Prod, 2024, 445: 141361.
- [14] GENG S Y, CHENG B Y, LONG W J, et al. Co-driven physics and machine learning for intelligent control in high-precision 3D concrete printing[J]. Autom Constr, 2025, 176: 106294.
- [15] ZAFAR M S, JAVADNEJAD F, HOJATI M. Optimizing rheological properties of 3D printed cementitious materials via ensemble machine learning[J]. Addit Manuf, 2025, 109: 104889.
- [16] ZHAO H Y, WANG X Y, SUN J B, et al. Automated analysis system for micro-defects in 3D printed concrete[J]. Autom Constr, 2025, 173: 106105.
- [17] SCHOSSLER R T, ULLAH S, ALAJLAN Z, et al. Data-driven analysis in 3D concrete printing: Predicting and optimizing construction mixtures[J]. AI Civ Eng, 2025, 4: 1.
- [18] RUDIN C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead[J]. Nat Mach Intell, 2019, 1(5): 206–215.
- [19] KARNIADAKIS G E, KEVREKIDIS I G, LU L, et al. Physics-informed machine learning[J]. Nat Rev Phys, 2021, 3(6): 422–440.
- [20] MENG C Z, GRIESEMER S, CAO D F, et al. When physics meets machine learning: A survey of physics-informed machine learning[J]. Mach Learn Comput Sci Eng, 2025, 1: 20.
- [21] YANG Y Q, LV H J, CHEN N. A Survey on ensemble learning under the era of deep learning[J]. Artif Intell Rev, 2023, 56(6): 5545–5589.
- [22] CONG S, ZHOU Y. A review of convolutional neural network

- architectures and their optimizations[J]. *Artif Intell Rev*, 2023, 56(3): 1905–1969.
- [23] MIENYE I D, SUN Y X. A survey of ensemble learning: Concepts, algorithms, applications, and prospects[J]. *IEEE Access*, 2022, 10: 99129–99149.
- [24] SEN S Y, OZKURT N. Convolutional neural network hyperparameter tuning with Adam optimizer for ECG classification[C]/2020 Innovations in Intelligent Systems and Applications Conference (ASYU). Istanbul, Turkey. IEEE, 2020: 1–6.
- [25] PROBST P, WRIGHT M N, BOULESTEIX A L. Hyperparameters and tuning strategies for random forest[J]. *WIREs Data Min & Knowl*, 2019, 9(3): e1301.
- [26] HANDELMAN G S, KOK H K, CHANDRA R V, et al. Peering into the black box of artificial intelligence: Evaluation metrics of machine learning methods[J]. *Am J Roentgenol*, 2019, 212(1): 38–43.
- [27] XUE J K, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization[J]. *J Supercomput*, 2023, 79(7): 7305–7336.
- [28] WENG Y W, LU B, LI M Y, et al. Empirical models to predict rheological properties of fiber reinforced cementitious composites for 3D printing[J]. *Constr Build Mater*, 2018, 189: 676–685.
- [29] TRAN N, VAN TRAN M, TRAN P, et al. Eco-friendly 3D-printed concrete using steel slag aggregate: Buildability, printability and mechanical properties[J]. *Int J Concr Struct Mater*, 2024, 18: 66.
- [30] WANG B L, ZHAI M G, YAO X F, et al. Printable and mechanical performance of 3D printed concrete employing multiple industrial wastes[J]. *Buildings*, 2022, 12(3): 374.
- [31] COLYN M, VAN ZIJL G, BABAFEMI A J. Fresh and strength properties of 3D printable concrete mixtures utilising a high volume of sustainable alternative binders[J]. *Constr Build Mater*, 2024, 419: 135474.
- [32] ŞAHİN H G, MARDANI A, MARDANI N. Performance requirements and optimum mix proportion of high-volume fly ash 3D printable concrete[J]. *Buildings*, 2024, 14(7): 2069.
- [33] OVER D, OZBAKAN N, ALI BUSTANI M, et al. An investigation of rheological properties and sustainability of various 3D printing concrete mixtures with alternative binders and rheological modifiers[J]. *J Sustain Cem Based Mater*, 2025, 14(3): 521–533.
- [34] 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 Jianping. The preparation and study on properties of high strength and high performance MSC[D]. Wuhan: Wuhan University of Technology, 2006.
- [35] 孙天棋. 粉煤灰-硅灰对再生混凝土物理力学性能影响研究[D]. 沈阳: 沈阳建筑大学, 2021.
- SUN Tianqi. Study on the effect of fly ash and silica fume on the physical and mechanical properties of recycled concrete[D]. Shenyang: Shenyang Jianzhu University, 2021.
- [36] 张超. 基于流变学的3D打印混凝土设计及其基本性能研究[D]. 南京: 东南大学, 2022.
- ZHANG Chao. Research on design of 3D printable concrete based on rheology and its basic properties[D]. Nanjing: Southeast University, 2022.
- [37] 卢亚. 建筑垃圾再生砂浆3D打印性能调控研究[D]. 北京: 北京建筑大学, 2024.
- LU Ya. Performance regulation of 3D printing recycled mortar from construction and demolition waste[D]. Beijing: Beijing University of Civil Engineering and Architecture, 2024.
- [38] 杨章. 3D打印钢渣—水泥基材料的制备和性能研究[D]. 焦作: 河南理工大学, 2022.
- YANG Zhang. Design and properties of 3D printing steel slag–cement based materials[D]. Jiaozuo: Henan Polytechnic University, 2022.
- [39] 孔令宇. 3D打印含石灰石粉UHPC的制备与性能[D]. 南京: 东南大学, 2023.
- KONG Lingyu. Preparation and properties of 3D-printing ultra-high performance concrete incorporating limestone powder[D]. Nanjing: Southeast University, 2023.
- [40] 金源. 白水泥基3D打印材料的组成设计优化及性能研究[D]. 济南: 济南大学, 2023.
- JIN Yuan. Research on optimal composition design and properties of 3D printed white Portland cement-based materials[D]. Jinan: University of Jinan, 2023.
- [41] LI H D, ADDAI-NIMOH A, KREIGER E, et al. Methodology to design eco-friendly fiber-reinforced concrete for 3D printing[J]. *Cem Concr Compos*, 2024, 147: 105415.
- [42] AHI O, ERTUNÇ Ö, BUNDUR Z B, et al. Automated flow rate control of extrusion for 3D concrete printing incorporating rheological parameters[J]. *Autom Constr*, 2024, 160: 105319.

作者贡献声明:

耿松源: 论文构思、设计研究方法和实验方案、撰写初稿
龙武剑: 监督指导、审阅与修订
李豪道: 调查研究、数据管理、分析/综合数据并推导结论
罗启灵: 提供资源、获取资助、项目管理
冯甘霖: 软件使用、验证、绘制图表

Physics-Informed Intelligent Design Method for 3D Printing Concrete

GENG Songyuan^{1,2}, LONG Wujian^{1,2,3,4}, LI Haodao^{1,2}, LUO Qiling^{1,2,4}, FENG Ganlin^{1,2}

(1. College of Civil and Transportation Engineering, Shenzhen University, Shenzhen 518060, Guangdong, China; 2. Guangdong Provincial Key Laboratory of Durability for Marine Civil Engineering, Shenzhen 518060, Guangdong, China; 3. Shenzhen Key Laboratory for Low-carbon Construction Material and Technology, Shenzhen 518060, Guangdong, China; 4. State Key Laboratory of Intelligent Construction and Healthy Operation and Maintenance of Deep Underground Engineering, Shenzhen 518060, Guangdong, China)

Extended Abstract

Introduction 3D printing technology offers a significant potential in the construction sector *via* enhancing build efficiency and enabling greater design freedom. However, its widespread adoption faces challenges related to the multi-objective optimization of concrete performance and the lack of intelligent decision-making for printing parameters. To address these issues, this paper was to propose a hybrid modeling framework that could integrate physics-informed and data-driven approaches for the intelligent design of 3D printing parameters tailored to target material properties. The framework first developed a rheological performance prediction model based on the physical information equation (PIE). This model, combined with the PIE, was then used to construct an extrusion screw speed (ES) database. The framework could enable accurate determination of the printing speed (PS) *via* incorporating key parameters such as the target concrete flow rate (Q), printing nozzle diameter (PN), and printing layer height (PH). The proposed intelligent parameter design method could provide a quantitative tool for the collaborative control of multiple concrete properties, significantly enhancing the efficiency and reliability of process parameter optimization. This study could offer a theoretical foundation and methodological support for improving the build quality and process stability of 3D printing concrete, thus facilitating the technology's application and adoption in construction engineering.

Methods A hybrid physics-data driven framework was developed for printing parameter optimization. This involved two distinct fusion strategies:

1. Physics-Informed Rheological Prediction (“PIE embedded in ML”): A Physics-Informed Convolutional Neural Network (PICNN) was constructed to predict rheological parameters (*i.e.*, Yield Stress–YS, and Plastic Viscosity–PV). Physical equations describing the relationship between mix proportions and rheology were embedded as soft constraints into the CNN's loss function. The Dung Beetle Optimizer (DBO) was used for hyperparameter tuning, including the weights balancing data-driven loss and physics-informed loss.

2. Physics-Serialized Extrusion Speed Prediction (“PIE serialized with ML”): An ES prior database was built *via* coupling multiple physical equations (*i.e.*, density, Bernoulli, torque) with the predicted rheological parameters from the PICNN model. A Random Forest (RF) model, optimized using DBO, was then trained on this database to predict ES intelligently based on material properties and equipment conditions.

Based on the principle of mass conservation, an explicit calculation equation for PS was derived as a function of Q , PN, and PH. This could complete the parameter optimization chain from material properties to process parameters.

Results and Discussion The PICNN model for predicting YS and PV demonstrates a stable convergence during training. Compared to the pure data-driven CNN model, the PICNN achieves significantly lower losses (*e.g.*, testing set average loss for YS: PICNN 198.92 Pa *vs.* CNN 307.80 Pa; for PV: PICNN 0.37 Pa·s *vs.* CNN 0.77 Pa·s), confirming that physical constraints enhance predictive accuracy and robustness. Furthermore, the predicted values from PICNN show a high consistency with the calculations from the pure PIE (*e.g.*, low MAPE of 6.02% for YS and 2.60% for PV on testing sets), thus proving a great adherence to physical laws.

The RF model for ES prediction, trained on the physics-generated database, achieves a high accuracy with R^2 values of 0.99 (training set) and 0.97 (testing set), and RMSE values of 1.86 r/s (training) and 2.39 r/s (testing). The scatter plots show points closely distributed around the fit line, and error distributions are concentrated at low levels, indicating the model's effectiveness in learning the complex relationships for ES prediction.

The derived equation for PS effectively establishes the quantitative relationship with Q , PN, and PH. A case study presenting calculated PS values for various common combinations of these target parameters provides a practical reference for configuring printing processes, demonstrating the applicability of the complete optimization framework.

Conclusions This study established a comprehensive physics-data hybrid modeling framework for optimizing 3D printing concrete parameters, achieving a precise matching between parameters and material rheological properties.

The physics-informed rheological prediction model (PICNN) significantly improved prediction accuracy and physical consistency for YS and PV compared to purely data-driven or purely physics-based approaches.

The physics-serialized extrusion speed prediction method, utilizing a physically-consistent database and an optimized RF model, enabled high-precision, robust intelligent recommendation of ES based on material attributes.

The complete parameter optimization solution, integrating rheological prediction, ES prediction, and PS calculation, provided a systematic and intelligent paradigm for 3D printing parameter design, reducing reliance on conventional trial-and-error methods.

This research could contribute to enhancing the forming quality and process stability of 3D printing concrete, facilitating the intelligent development of construction 3D printing technology. Future work could focus on more complex multi-objective optimization scenarios and real-time dynamic parameter control strategies.

Key words: 3D printing concrete; machine learning; physical information equation; fusion strategy; printing parameter optimization