

文章编号:1007-9629(2026)03-0301-09

基于深度学习的水工混凝土空隙结构研究

唐 然^{1,2}, 陈灯红^{1,2,*}, 刘 方³, 王乾峰^{1,2}

(1.三峡大学 防灾减灾湖北省重点实验室,湖北 宜昌 443002; 2.三峡大学 土木与建筑学院,湖北 宜昌 443002; 3.西京学院 土木工程学院,陕西 西安 710123)

摘要:考虑定量化表征水工混凝土的三维空隙结构几何形态参数,系统分析空隙结构几何形态参数的分布规律及内在相关性。同时,采用 SHAP 法开展可解释性分析,揭示输出目标与输入特征之间的复杂映射关系;基于深度神经网络(DNN)构建水工混凝土空隙形态特征与总空隙率的定量关联模型。结果表明:等效半径与磨圆度、空隙数量与熵、表面积与磨圆度之间存在较强的正相关性,欧拉特征数与分形维数呈现负相关性;对特征重要性进行排序,输入特征压缩至 5 个;构建的 DNN 预测模型训练集和测试集的决定系数分别为 0.90 和 0.93,预测精度较高;本研究建立的空隙结构几何形态参数表征体系为水工混凝土性能优化提供了量化分析的工具模型与理论支撑。

关键词:水工混凝土;空隙结构;几何形态参数;工业 CT;机器学习

中图分类号:TV431

文献标志码:A

doi:10.3969/j.issn.1007-9629.2026.03.003

Void Structure of Hydraulic Concrete Based on Deep Learning

TANG Ran^{1,2}, CHEN Denghong^{1,2,*}, LIU Fang³, WANG Qianfeng^{1,2}

(1. Hubei Key Laboratory of Disaster Prevention and Mitigation, China Three Gorges University, Yichang 443002, China; 2. College of Civil Engineering and Architecture, China Three Gorges University, Yichang 443002, China; 3. School of Civil Engineering, Xijing University, Xi'an 710123, China)

Abstract: The geometric characteristics of the three-dimensional void structure in hydraulic concrete were quantitatively characterized, and the distribution patterns and internal correlations of void geometric parameters were systematically analyzed. In addition, interpretability analysis was performed using the Shapley additive explanations (SHAP) method to elucidate the complex mapping relationships between the output target and input features. A quantitative association model between void morphological features and total porosity was constructed using a deep neural network(DNN). The results show that a strong positive correlation is observed between equivalent radius and roundness, number of voids and entropy, as well as surface area and roundness. In contrast, a negative correlation is found between Euler characteristic and fractal dimension. Feature importance is ranked, and input features were reduced to five. The constructed DNN prediction model achieves correlation coefficient of 0.90 and 0.93 for the training and testing sets, respectively, indicating high prediction accuracy. The geometric characterization system for void structures established in this study provides a quantitative analytical tool and theoretical support for the performance optimization of hydraulic concrete.

Key words: hydraulic concrete; void structure; geometric shape parameter; industrial CT; machine learning

收稿日期:2025-05-07; 修订日期:2025-06-30

基金项目:国家自然科学基金资助项目(52079072);陕西省混凝土结构安全与耐久性重点实验室开放基金(SZ02401);土木工程防灾减灾湖北省引智创新示范基地(2021EJD026)

第一作者:唐 然(1995—),女,四川达州人,三峡大学博士生。E-mail:tangran627@163.com

通讯作者:陈灯红(1983—),男,湖北广水人,三峡大学教授,博士生导师,博士。E-mail:d.chen@ctgu.edu.cn

混凝土内部空隙结构是影响其渗透性、抗冻性及力学性能的重要因素,内部几何形态特征与空间分布规律对水工混凝土的性能具有关键作用^[1-3]。因此,定量表征混凝土三维空隙结构几何形态参数,不仅可以为基于机器学习的混凝土性能预测算法提供多尺度特征输入,还可以通过材料改性实现水工混凝土微观结构调控,对指导工程实践具有重要意义。

传统孔结构表征依赖压汞法、扫描电镜等物理检测手段。唐明等^[4]使用压汞法得到了混凝土空隙体积及孔径分布情况,并通过计算分形维数对混凝土空隙结构进行评价。元成方等^[5]使用氮吸附法研究了不同高温环境下聚丙烯纤维混凝土内部孔径分布情况与比表面积变化。然而,这些测试手段虽能获取孔隙率、孔径分布等参数,但普遍存在精度低等缺点。

工业计算机断层扫描(CT)可以通过X射线断层扫描技术与灰度阈值分割算法来实现混凝土内部微米级空隙结构的三维重构,已成功应用于检测混凝土内部骨料分布情况和混凝土内部微裂缝扩展等

领域^[6-8]。混凝土的空隙结构具有复杂、多样、无序的特点^[9-11]。现有的研究大多局限于对空隙率等简单的空隙结构参数进行定性描述或简单的参数关联,缺乏对复杂形态学参数的深度挖掘与深入定量模型的研究^[12-14]。本文使用工业CT技术对水工混凝土进行X射线断层扫描,分析了空隙结构形态参数间的相关性,并基于深度学习方法建立了空隙结构形态参数与总空隙率的映射关系。

1 原材料及研究方法

1.1 原材料

水泥为海螺牌P·O 42.5普通硅酸盐水泥,其物理性能如表1所示;粉煤灰为F类Ⅱ级粉煤灰,化学组成(质量分数,文中涉及的组成、水胶比等除特别说明外均为质量分数或质量比)如表2所示;细骨料为天然河砂,细度模数为2.72,中砂;粗骨料为5~20 mm连续级配石灰岩碎石,表观密度为2 828 kg/m³;水为实验室自来水;外加剂为聚羧酸高效减水剂,其羟值为25 mg KOH/g,固含量为20%。

表1 水泥的物理性能

Table 1 Physical performance of cement

Soundness	Specific surface area/(m ² ·kg ⁻¹)	Setting time/min		28 d compressive strength/MPa	28 d flexural strength/MPa
		Initial	Final		
Qualified	354.2	215	278	50.4	8.9

表2 粉煤灰的化学组成

Table 2 Chemical composition (by mass) of fly ash

Unit: %				
SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	MgO	CaO
56.96	23.67	4.63	1.50	1.50

水工混凝土的配合比如表3所示,水胶比均为0.40。依据GB/T 50081—2019《混凝土物理力学性能试验方法标准》及SL/T 352—2020《水工混凝土试验规程》制作尺寸为100 mm×100 mm×100 mm的混凝土试件并标准养护28 d。

表3 水工混凝土的配合比


Table 3 Mix proportion of hydraulic concrete

Unit: kg/m ³					
Coarse aggregate	Fine aggregate	Cement	Fly ash	Water	Admixture
1 031.0	776.0	365.0	75.0	165.0	8.1

1.2 X-CT图像处理

采用Multiscale-Voxel45型工业CT对养护28 d后的混凝土试件进行扫描。图像体素尺寸为139 μm,图像大小为3 072×3 072像素。物质的密度越大,

CT数值越大,表现在CT扫描图像上亮度越高,灰度值也就越大。反之,在CT扫描图像上的亮度越低,灰度值越低。图1(a)为水工混凝土试件的中部切片。采用Voxel Studio软件进行预处理,并结合商业软件AVIZO将图像转换为8位灰度图像(取值范围为0~255),完成射线硬化矫正与中值滤波降噪处理,得到切片图像,如图1(b)所示。



(a) Original slice

(b) Treated slice

图1 混凝土试件的CT切片

Fig. 1 CT slice of concrete specimen

图2为混凝土CT图像的灰度直方对比图。由图2可见:灰度直方图的频数呈波动变化趋势,原因

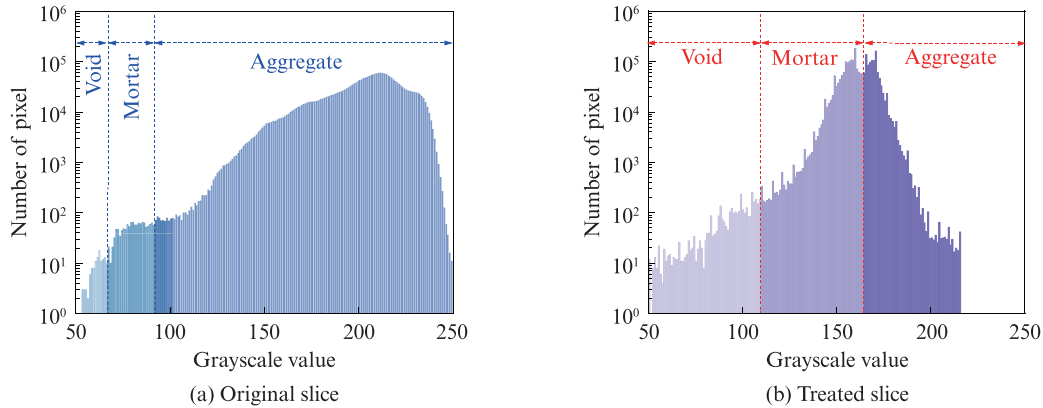


图2 混凝土CT图像的灰度直方对比图
Fig. 2 Gray square contrast image of concrete CT image

在于混凝土材料的不均匀性;混凝土骨料与砂浆、空隙的灰度值各不相同。通过处理后切片得到的灰度直方图更能体现混凝土内部真实的骨料、砂浆和空隙分布占比情况。

1.3 三维空隙结构几何形态参数表征

混凝土内部具有复杂、无序、多样的空隙结构。通过工业CT扫描水工混凝土试件,获得三向(x、y和z轴)的数据切片,将其进行三维重构阈值分割,提取空隙形态特征。同时,试件被均匀地分割成尺寸为25 mm×25 mm×25 mm的64个正方体切分块,分别获取空隙

特征数据。最终建立了192组空隙结构数据集。

采用表面积(S_a)、欧拉特征数(E_p)、等效半径(r_{vol})、平坦度(E_f)、磨圆度(φ)、伸长率(E_r)、长宽比(A_r)、分形维数(D_f)、空隙数量(N)和熵(H)对三维空隙结构几何形态参数进行表征。以上10个参数的定义公式^[15]如表4所示。其中: d_L 、 d_i 、 d_s 分别为基于“盒子原理”统计出的空隙长轴、中轴和短轴尺寸(如图3所示)^[15]; V 为空隙体积; $I(x, y)$ 为切片图像中像素点(x, y)的灰度值; $P(I)$ 为灰度值出现的概率分布。

表4 空隙结构几何形态参数
Table 4 Geometric shape parameters of void structure

Parameter	Formula	Parameter	Formula	Parameter	Formula
Surface area	S_a	Elongation ratio	$E_r = \frac{d_i}{d_L}$	Flatness	$E_f = \frac{d_s}{d_i}$
Euler characteristic	E_p	Aspect ratio	$A_r = \frac{d_L}{d_s}$	Roundness	$\varphi = \sqrt[3]{\frac{d_s \times d_i}{d_L^2}}$
Number of void	N	Fractal dimension	$D_f = \frac{3 \ln S_a}{\ln V}$		
Entropy	$H = -\sum_{x,y} \{P[I(x,y)] \ln P[I(x,y)]\}$	Equivalent radius	$r_{vol} = \left(\frac{3V}{4\pi}\right)^{1/3}$		




图3 空隙几何尺寸
Fig. 3 Geometric dimensions of voids

1.4 深度学习

深度神经网络(DNN)作为深度学习(DL)的一种重要实现方式,是基于多层次非线性变换的神经网络结构。采用逐层特征提取与抽象建模的模式,

能有效提升模型对复杂数据的表征与处理能力,实现其过程的高度自动化。模型样本特征从输入层开始,经过每一层的处理后传至输出层。每一层中,下层神经元接受上层神经元传递的信息先进行加权计算再通过激活函数引入非线性变换,增强模型的表达能力。随后,基于损失函数反向传播计算误差,利用优化器不断调整神经元之间的权重和偏置,从而使预测结果不断逼近真实值,最终实现从输入到输出的复杂非线性映射,如式(1)、(2)所示。

$$z_i = \sum_{i=1}^n w_i x_i + \rho \tag{1}$$

$$\gamma_i = \sigma(z_i) \tag{2}$$

式中： x_i 为输入特征； w_i 和 ρ 为权重和偏置； z_i 为节点的净输入； σ 为非线性激活函数（如 ReLU 或 Tanh 等）； γ_i 为节点的激活值。

通过搭建 DNN 模型，以空隙结构形态学参数包括 S_a 、 E_p 、 r_{vol} 、 E_t 、 φ 、 E_r 、 A_r 、 D_t 、 N 和 H 作为输入变量，以空隙率 (P) 作为输出目标。通过最小化均方误差 (MSE) 进行反向传播优化，学习类型为监督学习。在回归方程不明确的前提下，基于试验数据建立输入变量与输出目标之间的非线性映射关系，从而实现输出目标空隙率的高精度预测。

采用 SHAP 法开展可解释性分析，从全局、局部层面揭示输出目标与输入特征之间的复杂映射关系。将每一个输出目标 P 分为大空隙（空隙体积 $V > 1.0 \text{ mm}^3$ ）、中空隙 ($0.1 \text{ mm}^3 < V \leq 1.0 \text{ mm}^3$) 及小空隙 ($V \leq 0.1 \text{ mm}^3$) 进行 SHAP 可解释分析。同时，对特征重要性进行排序，优选特征参数数量，构建 DNN 模型，建立水工混凝土空隙形态特征与总空隙率的定量关系。最后，验证 DNN 模型的适用性与精确性。

在贝叶斯优化框架下，对回归网络的参数进行系统性配置^[16-17]。模型训练使用 Adam^[18] 优化器，设置 3 个全连接隐藏层，每个隐藏层设置 128 个神经元，非线性激活函数为 Tanh，初始学习率设定为 0.001，最大训练轮数为 200，每个小批量的样本数量为 4，最大迭代次数为 6 600 次。为提升训练的稳定性，训练前将试验数据进行归一化预处理，每轮训练结束后重新随机排列训练数据。

同时，在训练过程中采用 5 折交叉验证法对模型进行交叉验证^[19]，最终将 5 次验证结果的评估指标（均方误差、决定系数等）进行平均，作为模型性能的综合评价指标。通过对 DNN、随机森林 (RF)、支持向量回归 (SVR)、极端梯度提升 (XGBOOST) 模型的分析，比较几种模型的精确性与适用性。同时，为了定量评估模型的预测准确性，分别采用 MSE、决定系数 (R^2)、平均绝对误差 (MAE)、平均绝对百分比误差 (MAPE) 和均方根误差 (RMSE) 对模型的训练效果进行评价。深度学习过程如图 4 所示。

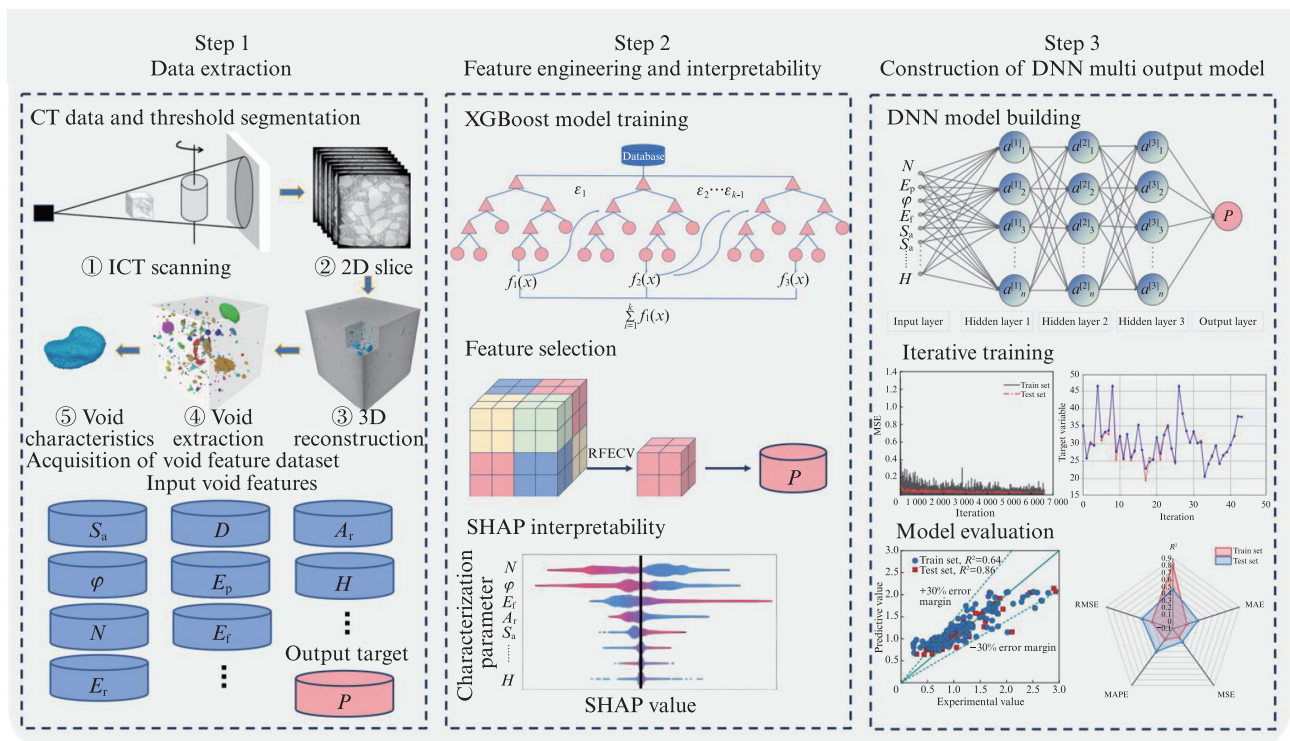


图4 机器学习过程

Fig. 4 Machine learning process

2 空隙结构几何形态表征分析

通过皮尔逊相关系数 (r) 及显著性概率 (p) 对表征参数间的相关性进行分析，表 5 列出了 $|r| \geq 0.75$ 和 $p \leq 0.01$ 的显著相关性组合。由表 5 可知：

(1) 欧拉特征数与分形维数呈现负相关关系。欧拉特征数是拓扑学中表征多孔介质连通性的指标^[20]。而分形维数是量化空隙边界的复杂程度和空间填充能力^[21]。分形维数越高，空隙表面越粗糙、结构越复杂并且分支越多。

(2)当分形维数增加,空隙的分支增多,空喉(连通通道)数量增加,从而导致欧拉特征数下降。反之,当分形维数减少,空隙结构越简单,孤立空隙占比高,联通性能降低,从而导致欧拉特征数上升。

图5为两两参数关系统计。由图5可见:

(1)空隙数量与熵、等效半径与磨圆度呈现线性正相关关系,表面积与磨圆度服从多项式分布,均呈现出较高的拟合程度。随着空隙数量的增加,熵也逐渐增加,并且早期增长趋势较缓,后期增长趋势逐渐变大。这是由于熵通常用于量化空隙分布的复杂性和无序性^[22]。早期少量空隙独立存在,对整体无序度的影响有限,熵增速率较慢。

(2)混凝土中空隙数量的增多直接破坏了原本致密的微观结构,导致内部颗粒分布更加多样。这种无序性的提升表现为熵的增大。随着表面积的增加,磨圆度也逐渐增加,但趋势平缓。磨圆度是描述

表5 各表征参数间的相关性

Table 5 Correlation between various characterization parameters

Feature 1	Feature 2	<i>r</i>	<i>p</i>
S_a	φ	0.96	0
r_{vol}	H	-0.90	0
N	H	0.89	0
r_{vol}	N	-0.86	0
r_{vol}	φ	0.84	0
E_f	φ	-0.82	0
r_{vol}	E_f	-0.81	0
φ	H	-0.79	0
E_f	N	0.78	0
S_a	E_f	-0.77	0
E_f	H	0.76	0

空隙几何表面光滑性的参数^[23]。这可能是由于空隙的扩展使其表面积逐渐增加,由不规则状空隙(低磨圆度)逐渐向圆空隙(高磨圆度)发展。

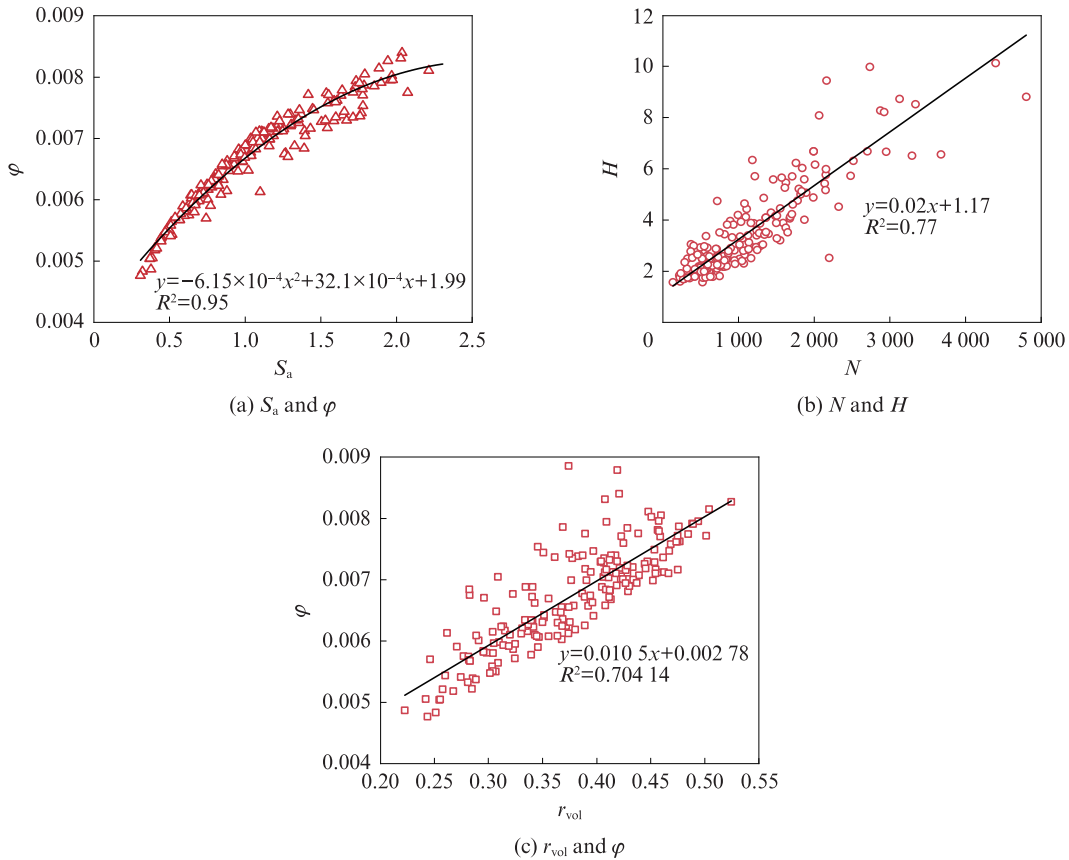


图5 两两参数关系统计

Fig. 5 Statistics of pairwise parameter relationships

3 基于深度学习的空隙结构分析

3.1 模型的可解释性

图6为SHAP特征贡献值及累计重要性排序。图中横轴代表预测分级空隙率的各输入特征SHAP

值分布,SHAP正值代表与分级空隙率预测结果呈正相关,反之则呈负相关。纵轴左端由上至下为输入特征对分级空隙率预测结果的重要性排序。采用递归特征消除交叉验证法(RFECV),去除冗余特征,减少特征数量。小空隙率、中空隙率和大空隙率较

优预测模型的输入特征数量分别为2、3、5。预测小空隙率的较优特征组合为 N 、 S_a ；预测中空隙率的较优特征组合为 N 、 D_f 、 S_a ；预测大空隙率的较优特征组合为 D_f 、 S_a 、 φ 、 N 、 E_r 。

由图6(a)~(c)可知,空隙数量、空隙数量、分形维数分别为影响小空隙率、中空隙率、大空隙率结果的重要特征。这是由于小空隙和中空隙作为混凝土中空隙占比较大的空隙类型,因此小空隙和

中空隙的数量与空隙率呈现较强的相关性。此外,大空隙的形态复杂性和空间分布决定其有效空隙率,因此大空隙分形维数与其空隙率呈现较强的相关性。基于3种空隙的空隙率特征贡献值(绝对SHAP平均值),通过加权计算量化了各特征对分级空隙率的影响程度,得出特征重要性排序结果从大到小依次为 D_f 、 N 、 S_a 、 φ 、 E_r 、 A_r 、 E_p 、 H 、 r_{vol} 、 E_f (见图6(d))。

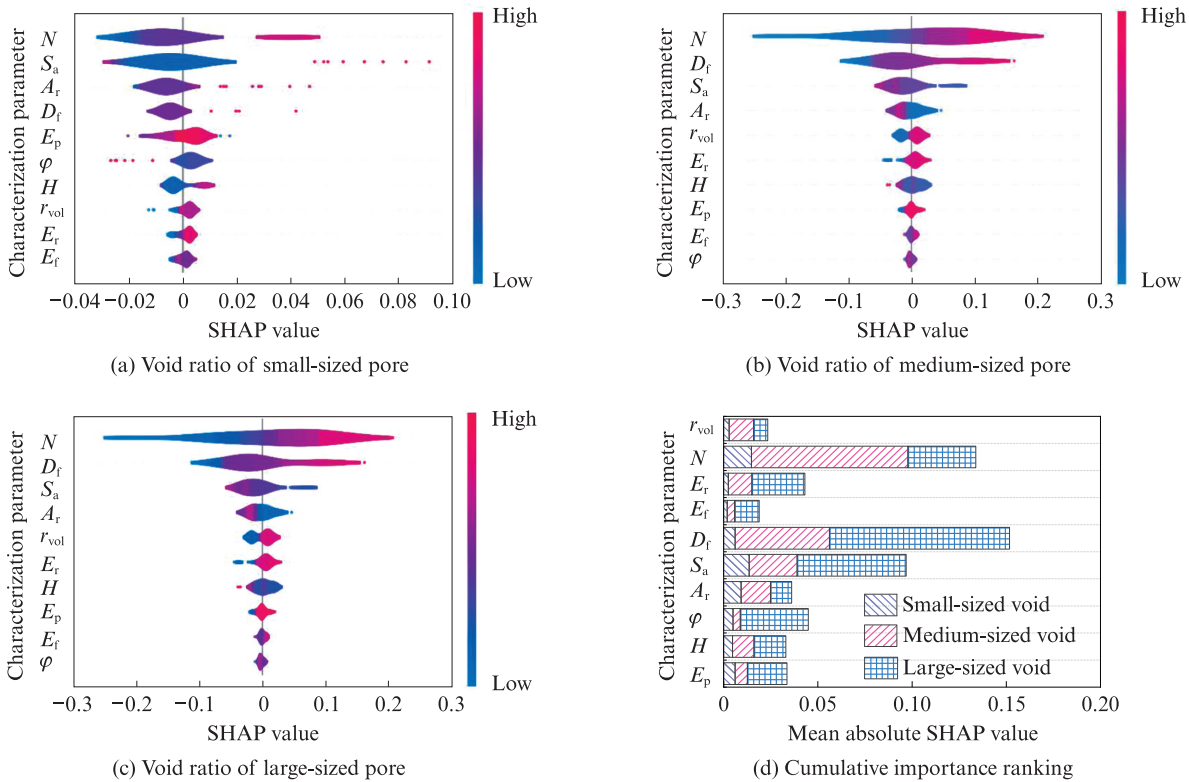


图6 SHAP特征贡献值及累计重要性排序
Fig. 6 SHAP feature contribution value and cumulative importance ranking

3.2 输入特征相关性分析

通过结合预测分级空隙率的较优特征组合结果与特征重要性排序结果,共整合得到了预测空隙率目标的5个重要特征。针对筛选出的5个关键特征变量,本研究通过皮尔逊相关系数矩阵的量化分析,构建了空隙几何特征间相关性热力图,具体结果如图7所示。由图7可见:热力图通过色阶梯度直观呈现了特征之间的线性关联程度;当 $|r|>0.8$ 时,呈现高度相关;当 $|r|=0.5\sim 0.8$ 时,呈现中度相关;当 $|r|=0.3\sim 0.5$ 时,呈现低度相关;当 $|r|<0.3$ 时,呈现不相关。最终建立了构建深度神经网络的特征子集为 S_a 、 E_r 、 D_f 、 φ 、 N 。

3.3 预测模型的建立与评估

基于相关性分析,建立了空隙结构形态参数与空隙率的映射关系。数据集包含5个输入特征(S_a 、

E_r 、 D_f 、 φ 、 N),1个输出目标(总空隙率)。数据集按照3:7的比例划分为测试集及训练集,进行DNN迭代训练,训练过程如图8所示。

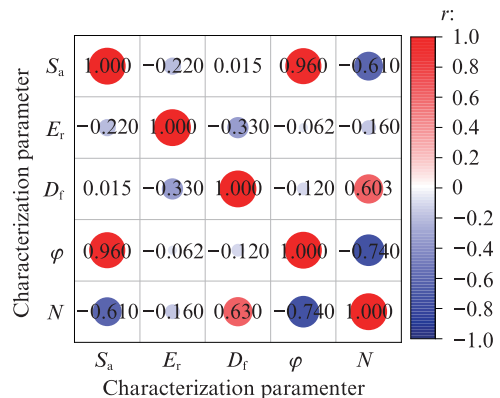


图7 输入特征相关性热力图
Fig. 7 Input feature correlation heatmap

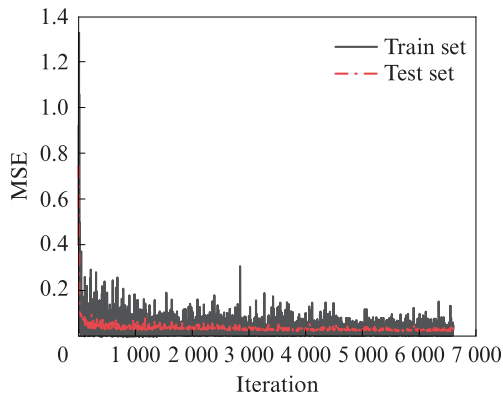


图8 深度神经网络模型训练过程

Fig. 8 Training process of deep neural network model

图9为4种预测模型的评估指标。MSE、MAE、MAPE和RMSE的值越小, R^2 越接近1,说明模型预测值与试验值之间的误差就越小。由图9可见:

(1)构建的DNN网络模型能够保持较高的预测精度,可以较好地预测水工混凝土空隙形态特征与总空隙率的定量关系。RF、SVR、XGBOOST预测

模型训练集和测试集的 R^2 分别为0.79和0.56、0.82和0.60、0.99和0.51;DNN预测模型训练集和测试集的 R^2 分别为0.90和0.84。综合其他3种方法训练集和测试集的预测精度较高。

(2)DNN预测模型训练集和测试集的MSE、MAE、MAPE和RMSE分别为0.02和0.04、0.11和0.14、0.11和0.14、0.15和0.18。对于混凝土材料空隙结构预测,基于DNN的建模方法相较于RF、SVR、XGBOOST算法展现出显著优势。这是由于DNN通过6~8层全连接网络构建的深层网络,能够逐层提取空隙特征的非线性组合,捕捉到其他模型忽略的细节。相比RF和XGBOOST的树结构分割以及SVR的核空间映射,DNN的Tanh激活函数组合可表达更复杂的函数空间,处理高维和非线性数据,尤其适合混凝土复杂的空隙结构关系^[24]。随着混凝土材料获取数据手段的提升(如CT图像、声发射信号等),机器学习模型为水工混凝土性能优化提供了量化分析的技术支撑与智能工具。

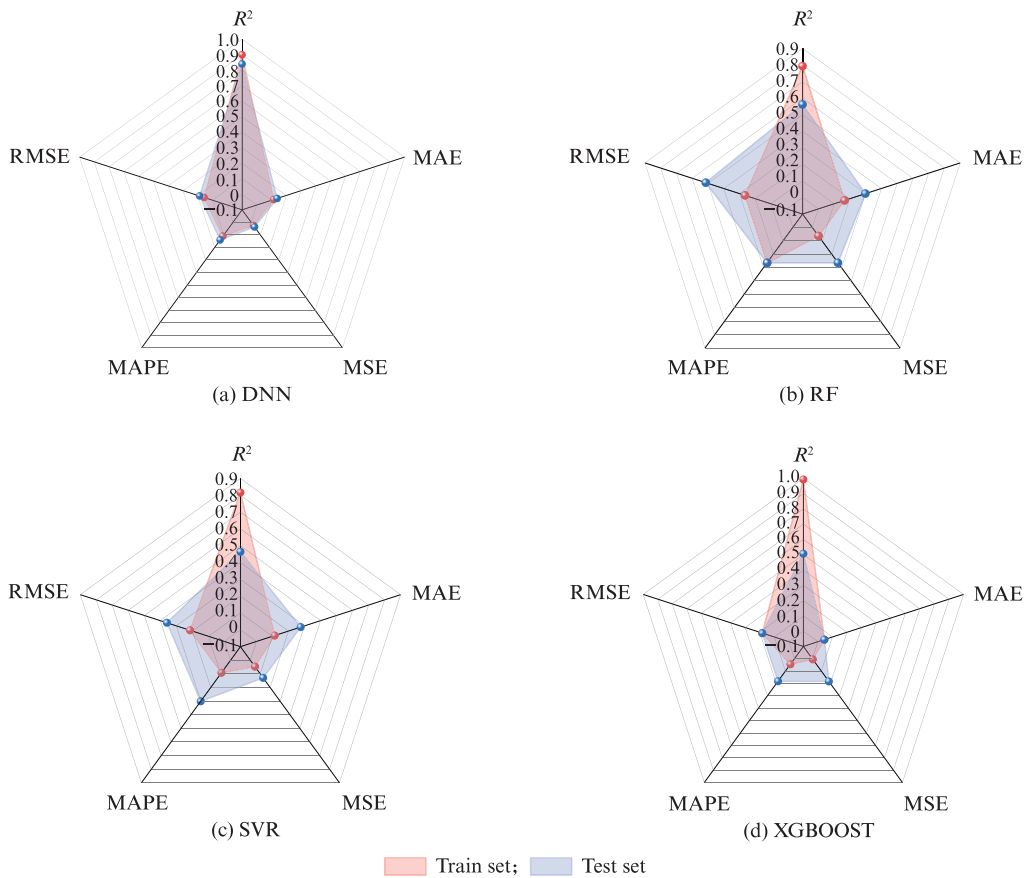


图9 4种预测模型的评估指标

Fig. 9 Evaluation indicators for four prediction models

为了更精确地评估4种模型的预测准确性,对RF、SVR、XGBOOST、DNN模型在训练集和测试集中总空隙率的试验值和预测值进行对比。图10为

试验值与预测值的比较。由图10可见:基于DNN预测模型给出的总空隙率试验值和预测值的拟合关系较好, R^2 分别为0.90和0.93;空隙数据点分布较为离

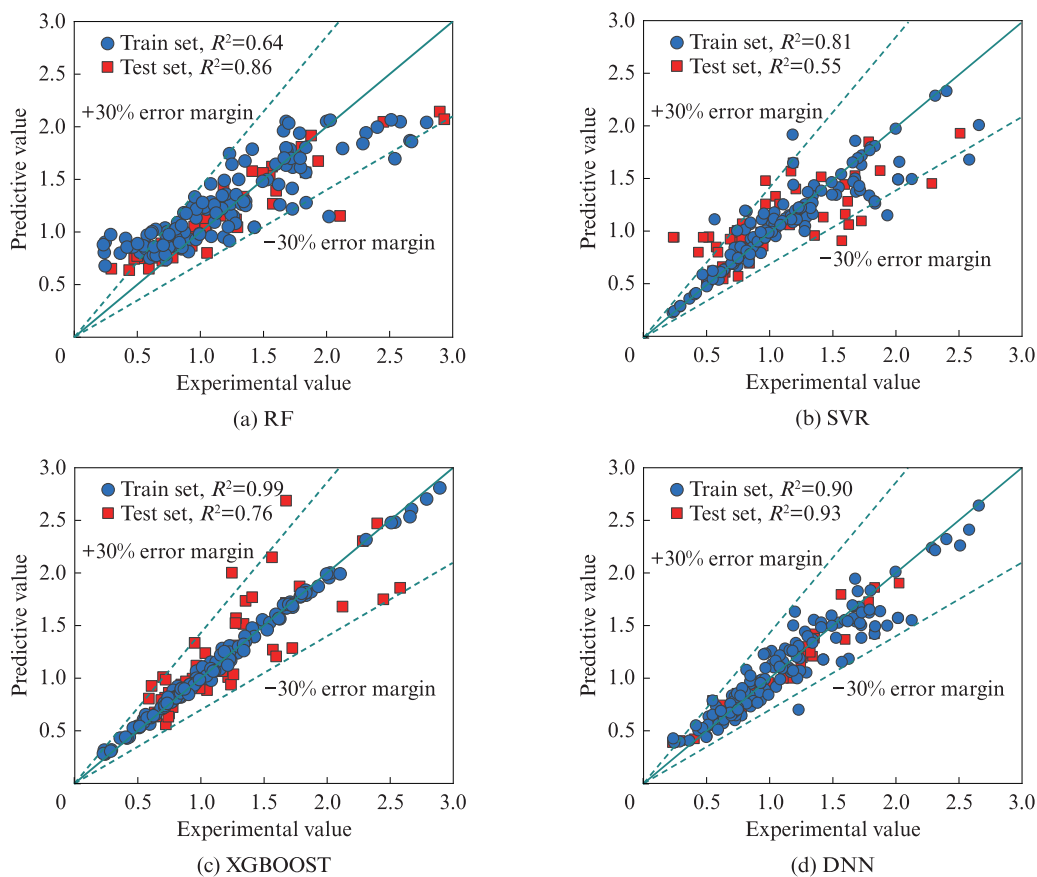


图10 试验值与预测值的比较

Fig. 10 Comparison between experimental values and predicted values

散,但DNN预测模型训练集和测试集的数据点基本分布在 $\pm 30\%$ 误差线以内。这可能是由于水工混凝土空隙自身的高度复杂性和多尺度特性,空隙形态、分布及尺寸存在天然的不均匀性和离散性^[25],Li等^[26]也发现混凝土的空隙结构具有无序、离散特性,这进一步验证了空隙分布的随机性和复杂性。

4 结论

(1) r_{vol} 与 φ 、 N 与 H 之间呈现显著正相关性,空隙数量的增加加剧了微观结构的无序性,导致熵值非线性增长。 S_a 与 φ 的多项式关系表明空隙扩展过程中几何形态向规则化演变,表面光滑性显著提升。此外, E_p 与 D_f 的负相关性反映了空隙复杂性与连通性的动态变化。

(2)预测小空隙、中空隙、大空隙空隙率的优选特征数量分别为2、3和5个,其中影响小空隙和中空隙的优选特征为空隙数量,影响大空隙的优选特征为分形维数。基于SHAP法可解释性贡献值的重要性排序,从大到小依次为 D_f 、 N 、 S_a 、 φ 、 E_r 、 A_r 、 E_p 、 H 、 r_{vol} 、 E_r 。通过皮尔逊相关性分析筛选出5个关键特征(S_a 、 E_r 、 D_f 、 φ 、 N)作为输入特征。

(3)通过对比RF、SVR、XGBOOST和DNN模

型对水工混凝土空隙率预测性能,发现DNN模型在训练集和测试集上均表现出较好预测精度,相关系数分别为0.90和0.93。对于混凝土材料空隙结构预测,基于DNN的建模方法相较于RF、SVR和XGBOOST算法展现出显著的优势。

参考文献:

- [1] TIAN Z H, ZHU X Y, CHEN X D, et al. Microstructure and damage evolution of hydraulic concrete exposed to freeze-thaw cycles[J]. Construction and Building Materials, 2022, 346: 128466.
- [2] 汪保印,张洁,熊金伟,等.废弃石粉对混凝土的性能影响及碳排放分析[J].建筑材料学报,2023,26(11):1151-1157,1206. WANG Baoyin, ZHANG Jie, XIONG Jinwei, et al. Influence of waste stone powder on properties and carbon emissions of concrete [J]. Journal of Building Materials, 2023, 26(11): 1151-1157, 1206. (in Chinese)
- [3] LIU F, TANG R, MA W W, et al. Frost resistance and meso-deterioration analysis of microcapsulated phase change materials modified concrete[J]. Journal of Building Engineering, 2022, 61:105214.
- [4] 唐明,王甲春,李连君.压汞测孔评价混凝土材料孔隙分形特征的研究[J].沈阳建筑工程学院学报(自然科学版),2001,17(4):272-275.

- TANG Ming, WANG Jiachun, LI Lianjun. Research on fractal characteristics of concrete materials pore with MIP[J]. Journal of Shenyang Architecture and Civil Engineering University (Natural Science), 2001, 17(4):272-275. (in Chinese)
- [5] 元成方, 高丹盈. 聚丙烯纤维混凝土高温后的孔隙结构特征研究[J]. 华中科技大学学报(自然科学版), 2014, 42(4):122-126. YUAN Chengfang, GAO Danying. Research of the pore structure of polypropylene fiber concrete after high temperature[J]. Journal of Huazhong University of Science and Technology (Natural Science), 2014, 42(4):122-126. (in Chinese)
- [6] SHANG X Y, YANG J W, WANG S M, et al. Fractal analysis of 2D and 3D mesocracks in recycled aggregate concrete using X-ray computed tomography images [J]. Journal of Cleaner Production, 2021, 304:127083.
- [7] WANG M Z, YANG X, WANG W. Establishing a 3D aggregates database from X-ray CT scans of bulk concrete[J]. Construction and Building Materials, 2022, 315:125740.
- [8] 陈春, 李之涵, 潘伟行, 等. 工业CT对混凝土中混杂钢渣颗粒的鉴别应用[J]. 建筑材料学报, 2024, 27(4):343-349. (in Chinese) CHEN Chun, LI Zhihan, PAN Weixing, et al. Application of industrial CT to identify mixed steel slag particles in concrete[J]. Journal of Building Materials, 2024, 27(4):343-349. (in Chinese)
- [9] HUA C, TANG R, LU X C. Radon emission characteristics and pore structure evolution of self-compacting concrete with silica fume-molybdenum tailings under different curing environments [J]. Journal of Building Engineering, 2024, 97:110769.
- [10] TANG R, CHEN D H, LIU F, et al. Mechanical property and frost resistance of phase-change/nanoSiO₂ concrete in a low-temperature environment [J]. Construction and Building Materials, 2024, 439:137387.
- [11] 汤玉娟, 左晓宝, 殷光吉. 基于孔结构参数的混凝土气体扩散模型[J]. 建筑材料学报, 2015, 18(6):976-981. TANG Yujuan, ZUO Xiaobao, YIN Guangji. Gas diffusion modeling in concrete based on pore structural parameters[J]. Journal of Building Materials, 2015, 18(6):976-981. (in Chinese)
- [12] SAHA S K, PRADHAN S, BARAI S V. Use of machine learning based technique to X-ray microtomographic images of concrete for phase segmentation at meso-scale[J]. Construction and Building Materials, 2020, 249:118744.
- [13] GHAREMANI G, BAGHERI A, ZANGANEH H. The effect of size and shape of pores on the prediction model of compressive strength of foamed concrete [J]. Construction and Building Materials, 2023, 371:130720.
- [14] SHE W, ZHAO G T, CAI D G, et al. Numerical study on the effect of pore shapes on the thermal behaviors of cellular concrete [J]. Construction and Building Materials, 2018, 163:113-121.
- [15] 罗滔, 王志鹏, 张天祺, 等. 大粒径堆石料多视角三维重构及其形态学分析[J]. 水力发电学报, 2023, 42(11):92-100. LUO Tao, WANG Zhipeng, ZHANG Tianqi, et al. Multi-view 3D reconstruction and morphological analysis of large particle size rockfill material[J]. Journal of Hydroelectric Engineering, 2023, 42(11):92-100. (in Chinese)
- [16] YANG T, TANG H M, DAI J W, et al. Quantitative classification and prediction of pore structure in low porosity and low permeability sandstone: A machine learning approach[J]. Geoenery Science and Engineering, 2025, 247:213708.
- [17] 郭磊, 李泽宣, 田青青, 等. 基于XGBoost算法的胶凝砂砾石劈拉强度预测分析[J]. 建筑材料学报, 2023, 26(4):378-382, 388. GUO Lei, LI Zexuan, TIAN Qingqing, et al. Predictive analysis of cemented sand and gravel splitting tensile strength based on XGBoost algorithm[J]. Journal of Building Materials, 2023, 26(4):378-382, 388. (in Chinese)
- [18] MAHMOOD M S, ELAHI A, ZAID O, et al. Enhancing compressive strength prediction in self-compacting concrete using machine learning and deep learning techniques with incorporation of rice husk ash and marble powder [J]. Case Studies in Construction Materials, 2023, 19:e02557.
- [19] HONG Y, LI S M, WANG H L, et al. Quantitative prediction of rock pore-throat radius based on deep neural network[J]. Energies, 2023, 16(21):7277.
- [20] HOU T Y. Potential singularity of the 3D Euler equations in the interior domain[J]. Foundations of Computational Mathematics, 2023, 23(6):2203-2249.
- [21] 吴安利, 刘坤, 郝贞洪, 等. 基于分形理论的古建筑青砖冻融损伤研究[J]. 建筑材料学报, 2024, 27(8):701-710. WU Anli, LIU Kun, HAO Yunhong, et al. Freeze-thaw damage of ancient architectural blue bricks based on fractal theory[J]. Journal of Building Materials, 2024, 27(8):701-710. (in Chinese)
- [22] LEE B H, LEE S K. Effects of specific surface area and porosity on cube counting fractal dimension, lacunarity, configurational entropy, and permeability of model porous networks: Random packing simulations and NMR micro-imaging study[J]. Journal of Hydrology, 2013, 496:122-141.
- [23] ZHENG J, HRYCIEW R D. Traditional soil particle sphericity, roundness and surface roughness by computational geometry[J]. Géotechnique, 2015, 65(6):494-506.
- [24] CHOI J H, KIM D, KO M S, et al. Compressive strength prediction of ternary-blended concrete using deep neural network with tuned hyperparameters[J]. Journal of Building Engineering, 2023, 75:107004.
- [25] 张亚楠, 蔡新, 陈徐东, 等. 胶结砂砾石的三维孔隙结构与层面抗剪性能关系分析[J]. 建筑材料学报, 2026, 29(2):197-206. ZHANG Yanan, CAI Xin, CHEN Xudong, et al. Analysis of the relationship between three-dimensional pore structure and interlayer shear performance of cemented sand and gravel[J]. Journal of Building Materials, 2026, 29(2):197-206. (in Chinese)
- [26] LI F, LUO D M, NIU D T. Durability evaluation of concrete structure under freeze-thaw environment based on pore evolution derived from deep learning [J]. Construction and Building Materials, 2025, 467:140422.