

李鹏远, 牛豪爽, 刘毅豪. 基于深度学习和多目标优化的混凝土配合比设计及性能预测研究[J]. 水利水电技术(中英文), 2025, 56(4): 194-210. DOI: 10.13928/j.cnki.wrahe.2025.04.016

LI Pengyuan, NIU Haoshuang, LIU Yihao. Concrete mix proportion design and performance prediction based on deep learning and multi-objective optimization [J]. Water Resources and Hydropower Engineering, 2025, 56(4): 194-210. DOI: 10.13928/j.cnki.wrahe.2025.04.016

基于深度学习和多目标优化的混凝土配合比设计及性能预测研究

李鹏远¹, 牛豪爽², 刘毅豪^{1,3}

(1. 许昌职业技术学院, 河南 许昌 461000; 2. 河南理工大学 土木学院, 河南 郑州 454003;
3. 许昌市数字化建造技术与装备重点实验室, 河南 许昌 461000)

摘要:【目的】混凝土作为国民经济建设的基石, 其抗压强度的精确预测对于工程结构的设计和安全至关重要。通过深度神经网络(DNN)模型预测混凝土抗压强度, 并提出 RF-NSGA-II 算法以优化混凝土配合比, 实现抗压强度和成本的双重优化。【方法】构建了包含不同隐藏层和神经元数量的 15 种 DNN 模型架构, 评估其性能并选取最佳模型, 采用超参数优化策略和贝叶斯优化策略, 提升 DNN 模型的预测性能, 比较 DNN 模型与支持向量回归(SVR)和随机森林(RF)模型的性能。基于 RF-NSGA-II 算法, 优化混凝土配合比, 以满足强度要求和成本控制。【结果】研究结果显示, 最优模型为 3 个隐藏层和 64 个隐藏单元(3L-64u)的 DNN 模型, 经过优化 DNN 模型在 MAE 和 MSE 上分别降低了 18%和 27%, 优化后的 DNN 模型相比 SVR 和 RF 模型在 MAE 和 MSE 上分别减少了 4%和 12%、11%和 15%。【结论】通过案例验证, DNN3-L64u-BOP 模型预测结果与试验值吻合良好, RF-NSGA-II 算法优化的混凝土配合比方案有效降低成本, 满足工程强度要求。基于贝叶斯优化的 DNN 模型能较好地预测混凝土抗压强度, RF-NSGA-II 算法在多目标优化混凝土配合比方面展示出优异的性能, 具有实际工程应用价值。

关键词: 混凝土; DNN; 抗压强度; 预测; 优化; 力学性能; 影响因素; 深度学习

DOI: 10.13928/j.cnki.wrahe.2025.04.016

开放科学(资源服务)标志码(OSID):

中图分类号: TU528; TP183

文献标志码: A

文章编号: 1000-0860(2025)04-0194-17



Concrete mix proportion design and performance prediction based on deep learning and multi-objective optimization

LI Pengyuan¹, NIU Haoshuang², LIU Yihao^{1,3}

(1. Xuchang Vocational and Technical College, Xuchang 461000, Henan, China; 2. School of Civil Engineering, Henan Polytechnic University, Zhengzhou 454003, Henan, China; 3. Xuchang Key Laboratory of Digital Construction Technology and Equipment, Xuchang 461000, Henan, China)

收稿日期: 2024-04-12; 修回日期: 2024-06-05; 录用日期: 2024-06-07; 网络出版日期: 2024-08-05

基金项目: 国家自然科学基金项目(42372331)

作者简介: 李鹏远(1988—), 讲师, 学士, 主要从事专业土木工程研究。E-mail: 18539023132@163.com

通信作者: 刘毅豪(1995—), 讲师, 硕士, 主要从事土木工程研究。E-mail: 13243160872@163.com

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

Abstract: [Objective] Concrete, as the cornerstone of national economic construction, necessitates the accurate prediction of its compressive strength for the design and safety of engineering structures. This study aims to predict concrete compressive strength using Deep Neural Network (DNN) models and proposes the RF-NSGA-II algorithm to optimize concrete mix proportions, achieving dual optimization of compressive strength and cost. [Methods] Fifteen DNN model architectures with different hidden layers and neuron numbers were constructed and evaluated for performance, selecting the best model. Hyperparameter optimization strategies and Bayesian optimization were employed to enhance the predictive performance of the DNN model. The performance of the DNN model was compared with Support Vector Regression (SVR) and Random Forest (RF) models. The RF-NSGA-II algorithm was used to optimize concrete mix proportions to meet strength requirements and cost control. [Results] The result showed that the optimal model had 3 hidden layers and 64 neurons (3L-64u). After optimization, the DNN model's MAE and MSE decreased by 18% and 27%, respectively. Compared to the SVR and RF models, the optimized DNN model reduced MAE and MSE by 4% and 12%, and 11% and 15%, respectively. [Conclusion] Case validation demonstrated that the DNN3-L64u-BOP model's predictions aligned well with experimental values, and the RF-NSGA-II algorithm effectively reduced costs while meeting engineering strength requirements. The Bayesian-optimized DNN model successfully predicted concrete compressive strength, and the RF-NSGA-II algorithm exhibited excellent performance in multi-objective optimization of concrete mix proportions, showing significant practical value in engineering applications.

Keywords: concrete; DNN; compressive strength; prediction; optimization; mechanical properties; influencing factors; deep learning

0 引言

混凝土是现代建筑中不可或缺的结构材料,其抗压强度是确保建筑物稳定与耐用的关键性能指标^[1-3]。以往的研究和实践经验表明,混凝土中使用的原材料及其用量是影响混凝土性能的关键参数。例如,适量的硅粉和粉煤灰作为辅助胶凝材料可以显著提高混凝土强度,而高效减水剂和矿物添加剂可以提高其抗冻性。传统的混凝土配合比设计方法主要通过多次重复试验获得混凝土抗压强度值,也有学者采用公式分析方法和统计方法获得最佳混凝土抗压强度^[4-6]。但仍需进行一定数量的试验来收集基础数据,基于所得配合比配制的混凝土预测性能与实际性能存在较大差距。因此,仍需要反复进行实验室测定。

基于线性回归的抗压强度预测模型只能描述输入与输出间简单的线性关系,在处理更复杂的数据关系时则显得十分困难^[7-9]。随着计算机技术的飞速发展,机器学习,深度学习模型能较好的处理混凝土抗压强度与其配比参数之间的复杂非线性关系^[10-12]。同时,深度学习方法因其在处理大规模、高维度数据方面的优势,可以较好提取复杂数据中高维特征。例如,李风增^[13]使用水、水泥、细骨料、粗骨料、高炉矿渣、粉煤灰、减水剂等七个因素作为输入,构建了基于人工神经网络(ANN)模型来预测混凝土强度。CHOPRA^[14]比较了使用人工神经网络(ANN)、随机森林(RF)和决策树(DT)模型预测混凝土抗压强度的

性能,基于深度学习模型的ANN模型相较于普通机器学习模型有较好的预测准确度。方涛等^[15]通过研究发现,人工神经网络可以准确预测混凝土实时强度,预测准确率超过96%,为结构工程安全和理论发展提供支持。尽管深度学习模型在预测混凝土抗压强度方面具有一定的应用前景,但许多现有模型仍采用未经超参数调优的简易结构。超参数的选择与调优对模型性能有显著影响,但目前关于其影响的研究相对较少^[16-18]。此外,绝大多数现有研究依赖于实验室环境中收集的数据,现场混凝土数据的匮乏和商业保密等原因,进一步限制了模型的实用性和广泛应用^[19-21]。在实际工程领域中,获得最佳混凝土抗压强度并不是唯一的目标,基于最佳配比下获得低成本,高强度的混凝土才是所有工程人所期望的。

而混凝土配合比优化及成本控制则属于多目标问题,在工程项目的设计优化中,往往需要协调多个相互冲突的目标,以实现性能最佳、成本最低的最终设计^[22-24]。在多目标优化算法方面,遗传算法是最常用的多目标算法之一,其灵感来自遗传学和自然选择定律。ZAVALA等^[25]发现非支配排序遗传算法II版(NSGA-II)仍然是结构设计优化中最常用的多目标元启发式方法。NSGA-II结合了快速非支配排序、精英保留和拥挤距离三种方法,能够快速找到最优解并进行选择性排序,保持 Pareto 最优解的多样性,使种群能够共同竞争,从而得到最优解,增强结果收敛性。此外,父代的优秀个体成功地保留在后代中,以确保种群的最佳健康和多样性。之前的研究已经证

明, NSGA-II 框架是可用于多目标优化的最通用的工具之一。BAYKASOGLU 等^[26]以高强混凝土抗压强度、成本和可加工性为优化指标, 提出了基于 NSGA-II 的高强混凝土多目标优化模型, 实现高强混凝土以抗压强度、成本和可加工性为优化目标的配比最优解。通过上述研究发现, NSGA-II 这种多目标优化方法可以有效的实现基于多种约束下的混凝土配比优化。

基于此本研究旨在, 通过深度神经网络(DNN)技术结合广泛的配比因素, 包括水泥、高炉矿渣、粉煤灰、水、减水剂、粗骨料、细骨料、养护时间、抗压强度等, 构建一个综合预测现场混凝土抗压强度的非线性模型。采用 1 030 组公开的混凝土配比数据, 评估了 15 种不同的深度神经网络模型结构(不同隐藏层, 不同隐藏单元), 以确定最佳网络架构。通过均方误差(MSE)和平均绝对误差(MAE)的指标选择了最优模型, 并通过超参数调优进一步提高了模型的预测准确性。采用了基于机器学习的模型进行比较, 以验证所提模型的有效性。通过使用测试数据集, 包含训练和验证过程中未见过的数据, 以确保模型的可靠性和泛化能力。并基于野山河隧道实际混凝土设计要求, 采用文章所提模型进行混凝土抗压强度预测, 并提出一种 RF-NSGA-II 开发的多目标智能框架实现混凝土 7 d 抗压强度、28 d 抗压强度以及成本之间的多目标配比优化, 确保设计的混凝土抗压强度满足规定要求的同时最小化其成本。

1 算法模型

1.1 机器学习

1.1.1 随机森林

随机森林(RF)作为集成学习的典范, 通过构建多个决策树并汇总它们的预测结果来提升分类准确性, 其模型示意如图 1 所示。其能力在防止模型过拟合方面尤其突出, 通过增加树的数量来减少误差, 有效管理离群值和非线性数据^[27-30]。

1.1.2 支持向量机

支持向量回归(SVR)是从支持向量机(SVM)衍生出的一种回归分析工具, 核心是寻找一个超平面, 该平面能够最大化正负样本间的间隔, 从而提升分类的准确度如图 2 所示。在 SVR 中, 该方法被扩展以估计与输出值相关的函数, 这对于解决非线性回归问题尤为重要, 现有研究已经应用传统的 SVM 模型来评估混凝土的抗压强度^[31-33]。

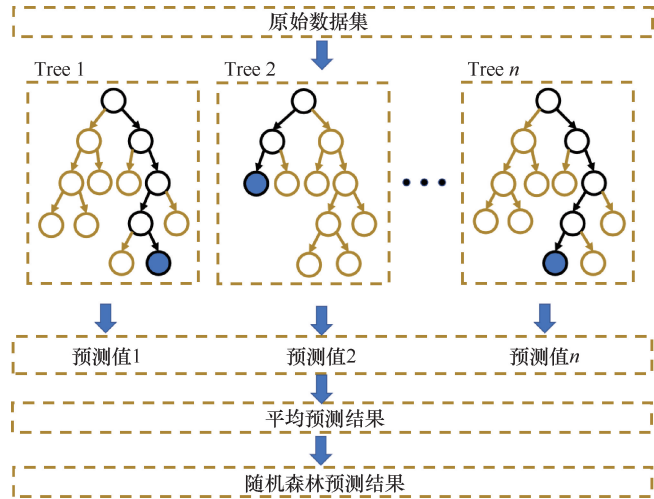


图 1 随机森林模型

Fig. 1 Random forest model




图 2 SVM 模型结构

Fig. 2 SVM model structure

1.1.3 遗传算法

近年来, 不断提出解决多目标优化问题的新方法。其中, 遗传算法(NSGA-II)被认为是解决此类问题的有效方法, 可以在一次模拟中找到多个 Pareto 最优解。NSGA-II 是一种改进的遗传算法, 它基于 Pareto 最优的概念执行多目标进化策略, 即对种群中的个体进行非支配排序, 然后按照数值从小到大的顺序选择个体^[34-36]。基于 NSGA-II 进行多目标优化的步骤如下。

(1) 确定初始种群大小为 N , 经过选择、交叉和变异操作后获得第一代的后代种群大小为 N , 将这两

个种群合并以获得大小为 $2N$ 的种群。

(2) 对 $2N$ 规模的种群进行非支配排序, 以确定个体的非支配层次。按照支配度的降序保留个体, 直到下一代的后代集合大于初始种群的大小。此时记录下非支配等级 L 。

(3) 使用拥挤距离对层中的个体进行排序, 选择更稀疏的点以防止局部最大和最小值。计算个体 I 的拥挤距离的公式为

$$D = \frac{1}{m} \sum_{k=1}^m |f_{i+1}^k - f_{i-1}^k| \quad (1)$$

式中, m 为优化目标的数量; f_{i+1}^k 为值 k 第 $i+1$ 的个体目标函数; f_{i-1}^k 为值 k 第 $i-1$ 的个体目标函数。

(4) 在选择下一代亲代种群后, 通过再次进行选择、交叉和变异操作获得新的后代种群。

(5) 重复步骤(2)一步骤(4), 直到迭代次数达到设定的迭代次数, 并获得 Pareto 最优解。

1.2 深度学习

深度学习(Deep Neural Networks, DNN)是一种基于神经网络的机器学习技术, 其特点是具有多层(深层)结构, 如图3所示。通过多层的神经网络结构, 深度学习能够从原始数据中自动学习出有用的特征表示, 进而完成诸如分类、回归、聚类等任务^[37-39]。




图3 深度学习模型结构示意图

Fig. 3 Schematic of deep learning model structure

DNN 模型通过重复执行正向和反向传播来学习。前者接受输入, 将其乘以可训练的权重, 增加偏差, 并使用激活函数预测结果。数据从输入层开始, 经过每一层的处理后传至输出层。在每个节点, 将输入数据与权重相乘, 加上偏置, 然后通过激活函数处理, 得到该节点的输出。其公式为

$$z_i = \sum_j w_{ij} x_j + b_i \quad (2)$$

$$a_i = \sigma(z_i) \quad (3)$$

式中, x_j 为输入数据; w_{ij} 和 b_i 为权重和偏置; σ 为激活函数(如 ReLU 或 Sigmoid); z_i 为节点的净输入; a_i 为节点的激活值。

后者通过区分预测值和实际值之间的误差来学习权重和偏差。通过计算输出层的误差, 并将误差反向传播至每一层, 来更新模型的权重和偏置, 以最小化某种损失函数。其公式为

$$\frac{\partial L}{\partial w_{ij}} = \delta_i a_j \quad (4)$$

$$w_{ij} = w_{ij} - \alpha \frac{\partial L}{\partial w_{ij}} \quad (5)$$

式中, L 为损失函数; α 为学习率。

2 数据收集及分析

2.1 数据收集

采用基于 Github (<https://github.com/>) 所公开的 1 030 个混合混凝土参数用于构建计算模型的数据集。该数据集包括以下特征: 水泥、高炉矿渣、粉煤灰、水、减水剂、粗骨料、细骨料、养护时间、抗压强度。除抗压强度外, 将其余 8 个特征作为模型输入, 抗压强度作为模型输出^[40-42]。

2.2 数据描述性统计

图4显示了数据集中主要因素在数据集中的分布。水泥分布在 $145 \sim 166 \text{ kg/m}^3$ 之间, 高炉矿渣分布在 $0 \sim 47 \text{ kg/m}^3$ 之间。粉煤灰主要分布在 $0 \sim 22 \text{ kg/m}^3$ 之间。水主要分布在 $183 \sim 195 \text{ kg/m}^3$ 之间。而减水剂主要分布在 $0 \sim 12.5 \text{ kg/m}^3$ 之间。粗骨料分布在 $900 \sim 1\,000 \text{ kg/m}^3$ 之间, 细骨料分布在 $763 \sim 825 \text{ kg/m}^3$ 之间。除某些例外情况外, 养护时间值绝大多数分别固定在 7 d 和 28 d, 抗压强度分布在 $10 \sim 40 \text{ MPa}$ 之间。

此外对原始数据集进行了统计学上的分析, 其统计学结果如表1所列。在对原始数据集中的变量进行了显著性测试, 结果表明所有变量(水泥、高炉矿渣、粉煤灰、水、减水剂、粗骨料、细骨料和养护时间)以及抗压强度指标均显示出显著性($P < 0.05$)。这表明可以拒绝数据遵循正态分布的原假设, 换句话说, 这些变量的分布并不是正态的。

2.3 数据相关性分析

为防止模型存在数据冗余, 从而影响模型的预测精度, 通过计算数据集中的两两变量之间的相关系数, 判断是否存在冗余特征变量, 需确定变量间存




图 4 输入和输出参数的分布

Fig. 4 Distribution of input and output parameters

表 1 输入参数和输出参数统计学特征

Table 1 Statistical characteristics of input and output parameters

变量名	样本量	平均值	标准差	偏度	峰度	K-S 检验
水泥	1 030	281.168	104.506	0.509	-0.521	0.079(0.000***)
高炉矿渣	1 030	73.896	86.279	0.801	-0.508	0.261(0.000***)
粉煤灰	1 030	54.188	63.997	0.537	-1.329	0.351(0.000***)
水	1 030	181.567	21.354	0.075	0.122	0.074(0.000***)
减水剂	1 030	6.205	5.974	0.907	1.411	0.218(0.000***)
粗骨料	1 030	972.919	77.754	-0.040	-0.599	0.064(0.000***)
细骨料	1 030	773.580	80.176	-0.253	-0.102	0.086(0.000***)
养护时间	1 030	45.662	63.170	3.269	12.169	0.337(0.000***)
抗压强度	1 030	35.818	16.706	0.417	-0.314	0.041(0.000***)

注: * 表示 $P < 0.05$; ** 表示 $P < 0.01$; *** 表示 $P < 0.001$ 。

在相关关系, 如图 5 所示。

在混凝土配比参数与抗压强度相关性研究中, 水

泥的用量展现出显著的正相关性, 其相关系数达到 0.498, 表明水泥用量的增加有助于提升混凝土的抗




图5 各变量相关性矩阵热图

Fig. 5 Heatmap of correlation matrix for variables

压强度。同时, 减水剂的使用也与抗压强度呈现出较为明显的正相关性, 具有 0.366 的相关系数, 这意味着减水剂参量促进混凝土抗压强度的提高。此外, 养护时间与抗压强度间的正相关关系也值得关注, 其相关系数为 0.329, 表明延长养护时间对增强混凝土的抗压强度具有正向影响。

反观负相关方面, 水的用量与抗压强度呈现出负相关性, 相关系数为 -0.290 , 这指出水的用量增加导致混凝土抗压强度的降低。粉煤灰的用量与抗压强度之间也展现出负相关性, 相关系数为 -0.106 , 暗示着粉煤灰的用量会轻微削弱混凝土的抗压强度。而粗骨料和细骨料的用量与抗压强度的负相关性也应被注意, 其相关系数分别为 -0.165 和 -0.167 , 这表明粗骨料和细骨料的用量对混凝土抗压强度产生较小的负面影响。相较之下, 高炉矿渣与抗压强度的相关性较为微弱, 相关系数为 0.135, 表明高炉矿渣的用量对混凝土抗压强度的影响相对较小。水泥用量、减水剂的使用和养护时间可能对混凝土抗压强度产生显著影响, 而高炉矿渣、粉煤灰、水、粗骨料和细骨料的影响相对较小。

3 基于深度神经网络模型混凝土性能预测模型构建

3.1 深度神经网络模型架构

通过构建 15 种具有不同层数和隐藏单元数量的 DNN 模型结构, 以选出最佳的预测模型实现混凝土抗压强度准确预测。DNN 模型网络架构的超参数设置列在表 2 中。为了比较每个模型的性能, DNN 层

的数量分别为 3、5 和 7, 隐藏层内的隐藏单元数量为 16、32、64、128 和 256。采用“10 折交叉验证”方法以在选择模型结构期间进一步性能评估^[43-44]。“ k 折交叉验证”方法将数据集划分为 k 个训练-验证组, 以便可以对所有数据进行验证, 并且训练将执行 k 次, 如图 6 所示。

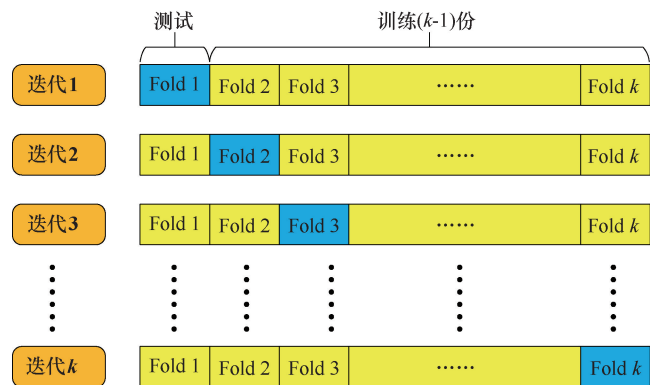


图6 交叉验证流程

Fig. 6 Cross-validation process

3.2 模型超参数优化

为了优化深度神经网络(DNN)模型的预测性能, 研究中采取了贝叶斯优化的超参数调优策略。开始时, 确定了最佳的隐藏单元大小, 以减少训练过程中噪声并提升模型稳定性的关键。确定隐藏单元大小后, 进一步通过 dropout 和归一化技术来减少过拟合并增强模型的泛化能力。通过这些调整, 模型的性能得到了显著提升。随后评估不同超参数组合对模型性能的影响, 并选择了那些在均方误差(MSE)和平均绝对误差(MAE)损失基准上表现最佳的参数。这些调优后的 DNN 模型随后与其他机器学习模型进行了性能比较。为进一步提高所选模型收敛的速度, 文章采用贝叶斯优化模型对超参数的偏差校正。

贝叶斯优化, 基本假设为^[44]

$$y = f(x) \quad (6)$$

式中, y 为先验概率。

每个新数据 (x_{data} , $f(x_{\text{data}})$) 出现后, 都会得到 y 的后验概率 $p(y | (x_{\text{data}}, f(x_{\text{data}})))$, 并将后验概率迭代更新为下一个数据的先验概率。

优化问题中, 下一个数据点 $x_{\text{next_data}}$ 基于当前状态并通过特殊规则获得^[37]。同样, 在贝叶斯优化中, 基于当前 y 的后验概率, 获取函数定义为

$$a_n(x | n_{\text{data_point}}) \quad (7)$$

式中, 函数是 $x \rightarrow R$, 效用函数对当前信息下的结果

y 的不同“效用”进行加权。因此, 仅选择最大化 a_n 。

基于目前的后验概率 $p(y|x)$ 建模, 高斯过程回归建模是最经典的模型。该模型的步骤可以总结如下^[37-38]。

第一步: 多维正态分布的似然函数。

基于当前的初始化数据 $\{(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_{n_0}, f(x_{n_0}))\}$, 假设似然函数是一个多维正态分布, 其表达为

$$\begin{pmatrix} y_1 \\ y_2 \\ \dots \\ y_{n_0} \end{pmatrix} \sim N \left(\begin{pmatrix} u_0(x_1) \\ u_0(x_2) \\ \dots \\ u_0(x_{n_0}) \end{pmatrix}, \Sigma_{n_0 \times n_0} \right) \quad (8)$$

$$\Sigma_{n_0 \times n_0} = \begin{bmatrix} k_{11} & \dots & k_{n_0 1} \\ \vdots & \ddots & \vdots \\ k_{n_0 1} & \dots & k_{n_0 n_0} \end{bmatrix} \quad (9)$$

在观察到 n_0 数据的地方, 表明 n_0 服从 n_0 维多维正态分布, u_0 表示均值向量中的先验信息。至于协方差矩阵, 如果 x_i 和 x_j 非常相似, 则相应的 y_i 和 y_j 具有很高的相关性。因为假设 f 是连续的, 所以当 x 的距离更近时, 对应的 y 也会更近。也就是说, 协方差矩阵是 $\{x_1, x_2, \dots, x_{n_0}\}$ 的函数。 k_{ij} 采用核函数 $k_{ij} = K(x_i, x_j)$, 协方差矩阵必须是非负正定矩阵。由于高斯核函数对应的映射函数可以将样本投影到无限维空间, 因此本研究采用了该映射函数, 传统上表示为

$$K(x_i, x_j) = e^{-\lambda \|x_i - x_j\|^2} \quad (10)$$

第二步: 高斯过程: 新数据和先前数据继续构成多维正态分布。

当用当前数据点计算 $p(y|x)$ 的分布时, 假定一个新的数据点 $(x^*, f(x^*))$, 一个新的分布构成前一个数据点和新数据点, 并表示为

$$\begin{pmatrix} y_1 \\ y_2 \\ \dots \\ y_{n_0} \\ y_* \end{pmatrix} \sim N \left(\begin{pmatrix} u_0(x_1) \\ u_0(x_2) \\ \dots \\ u_0(x_{n_0}) \\ u_0(x^*) \end{pmatrix}, \Sigma_{(n_0+1) \times (n_0+1)} \right) \quad (11)$$

$$\Sigma_{(n_0+1) \times (n_0+1)} = \begin{bmatrix} k_{11} & \dots & k_{1n_0} & k_{1*} \\ \dots & \dots & \dots & \dots \\ k_{n_0 1} & \dots & k_{n_0 n_0} & k_{n_0*} \\ k_{* 1} & \dots & k_{* n_0} & k_{**} \end{bmatrix} \quad (12)$$

式中, $u_0(x^*)$ 是任何 x^* 的先验概率的初始平均值, 也可以在确定先验概率时确定。

第三步: 边际分布, 求 y^* 的边际概率分布。

根据多维正态分布的性质, 由下式给出

$$y_* | x^* \sim N \left(\overline{K_*}^T \Sigma_{n_0^* n_0}^{-1} (\overrightarrow{y_{n_0}} - \overrightarrow{u_{n_0}}), k_{**} - \overline{K_*}^T \Sigma_{n_0^* n_0} \overline{K_*} \right) \quad (13)$$

也就是说, 对于每个 x^* , $y^* | x^*$ 可以根据当前数据计算。

用当前数据得到 y 的概率分布后, 确定下一个迭代点 $x_{\text{next_data}}$ 。因此, 采用了采集函数, 这是一种可以权衡现有结果和可能探索的效用函数。按点 $x_{\text{next_data}}$ 计算 y 的后验概率, 使获取函数获得最大值。并逐步迭代, 直到满足算法停止条件。

表 2 列出了贝叶斯优化模型超参数。通过设置适当的学习率和寻找具有最优误差的点来减少训练时间是很重要的。通过对单个参数进行了适当的学习, 可高效的降低模型的误差。此外, 文章在调整超参数之前, 将学习率设置为 0.001 和 0.01, 根据不同隐藏单元数的 DNN 模型的学习率进行比较, 选择最佳学习率。

表 2 贝叶斯优化参数设定

Table 2 Parameter settings for Bayesian optimization

参数	起始
核函数(Kernel)	RBF 核
先验分布(Prior)	高斯先验
采集函数(Acquisition Function)	期望改进(EI)
采集函数权重(Acquisition Function Weight)	一般不需要, 由采集函数本身的性质决定
迭代次数(Number of Iterations)	100
初始样本大小(Initial Sample Size)	10

表 3 列出了用于模型优化的超参数的试验值。使用 ReLu 作为激活函数, 90% 和 10% 的数据分别用于学习和验证数据集。隐藏单元大小被设置为 16、32、64 和 128, 以比较基于隐藏单元大小的性能。为了得到最优的 DNN 模型, 根据所选择的隐藏单元大小, 对不同隐藏层和隐藏单元的 DNN 模型作为变量进行性能评估。

3.3 评价指标

在本研究中采用几个具有代表性的预测性能评估指标, 通过非线性回归模型的性能比较, 得到最优模型。这些标准包括均方误差 (MSE) 以及平均百分比误差 (MAE), MSE 和 MAE 值越低表示的预测结果更准确。上述统计参数通过以下表达式计算

表3 DNN 模型参数值

Table 3 DNN model parameter values

参数名	值
验证集比例	10%
隐藏单元	16, 32, 64, 128
激活函数	ReLU
丢弃率	0.1
训练迭代	2 000
早停参数	MSE
评价指标	MAE, MSE

$$MSE = \frac{\sum_{i=1}^n (x_i - y_i)^2}{n} \quad (14)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (15)$$

式中, n 为数据集的总数; x_i 和 y_i 分别为预测值和真实值。

3.4 模型仿真结果

文中比较了 15 种不同的模型结构。根据图 7 所示的模型性能评估结果(3, 5, 7 表示隐藏层层数; 18-u, 116-u, 132-u, 164-u, 1128-u 表示隐藏单元个数), 模型的平均绝对误差(MAE)介于 1.85 至 2.68 之间, 而均方误差(MSE)在 7.00 至 8.47 之间波动。拥有 64 个隐藏单元的模型呈现了较低的 MSE 值, 表明适中数量的隐藏单元有助于减少预测误差。

3 个隐藏层结构的模型 MAE 为 1.87, MSE 为 7.22, 相比于其他多层或单层模型, 这一结构实现了更准确的预测。然而, 模型的复杂度和训练时间随着层数的增加而上升, 因此需要在模型精度和计算效率之间做出权衡。在众多模型中, 具有 3 个隐藏层和 64 个隐藏单元(3L-64u)的模型表现最佳, MAE 为 1.858 6, MSE 为 6.995 3, 因此, 这一结构被选为本研究中的最优 DNN 模型。




图7 不同模型框架误差比选

Fig. 7 Error comparison of different model frameworks

在对比深度学习模型(DNN)与传统的机器学习模型(随机森林 RF 和支持向量回归 SVR)时, 采用包含 100 棵树的 RF 模型, 设置了最小节点分割样本数为 2, 以及叶节点的最小样本数为 1。对于 SVR 模型, 选用了径向基函数作为核函数, 其中 γ (gamma) 值是根据输入变量的数量和输入值方差的逆比来设置的, 而决策边界的宽度 C 设定为 1.0, ε (epsilon) 值为 0.1。

模型的性能通过 10 折交叉验证法评估, 该方法可以减少评估误差和偏差。在此评估中, RF 模型的平均绝对误差(MAE)为 1.724 1, 均方误差(MSE)为 6.321 5, 而 SVR 模型的 MAE 和 MSE 分别为 1.888 5 和 6.392 1, 如图 8 所示。3L-64u DNN 模型的性能与机器学习模型相比误差略低(MAE 和 MSE 分别 1.716 2, 6.317 2), 需要进一步的超参数优化以提升性能。




图8 3L-64u 和机器学习模型预测性能比较

Fig. 8 Comparison of prediction performance between 3L-64u and machine learning models

在优化深度神经网络(DNN)模型时, 通过细致的超参数调整, 可大幅提升模型性能。通过调整隐藏单元数量, 绘制了模型损失随隐藏单元变化的图像(见图 9)。在试验中, 测试了不同的隐藏单元大小(16、32、64 和 128), 发现当隐藏单元大小为 16 或 128 时, 模型的训练误差高于验证误差, 这表明模型未能有效学习。与此同时, 隐藏单元大小为 32 时, 虽然训练和验证损失趋于收敛, 但损失的方差较大, 导致结果不稳定。试验表明, DNN 结构为 3L-64u 时模型训练和验证过程中显示出了稳定的损失收敛性, 验证了其作为最佳隐藏单元量大小的合理性。

进一步对 3L-64u 及其超参数优化后版本(3L-64u-BOP)、随机森林(RF)、和支持向量回归(SVR)模型进行了彻底的误差评估如图 10 所示。结果显示, 优化后的 DNN 模型在 MAE 和 MSE 上表现出比 RF

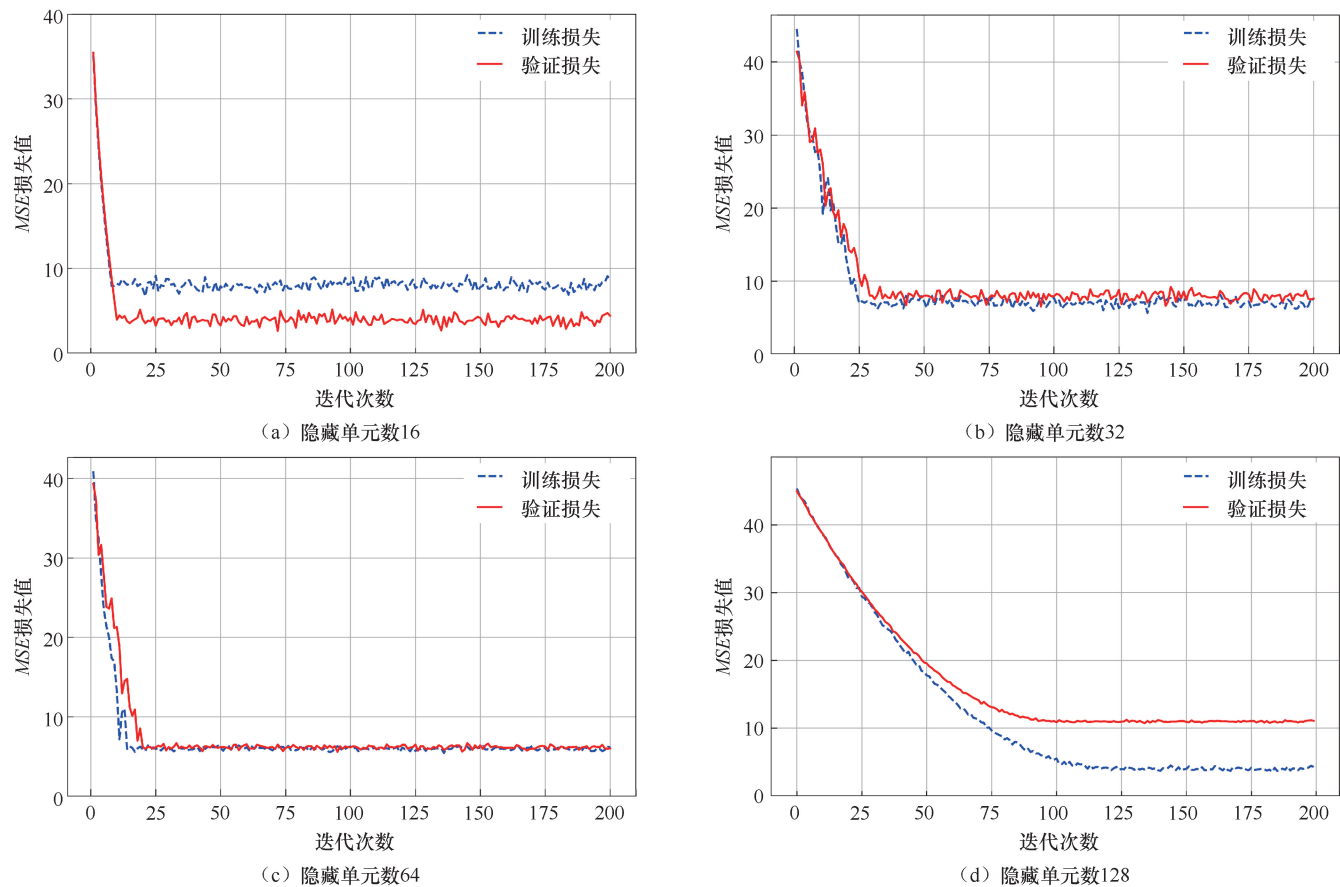


图9 3L-64u 模型不同隐藏单元损失

Fig. 9 Loss graph for different batches of 3L-64u model

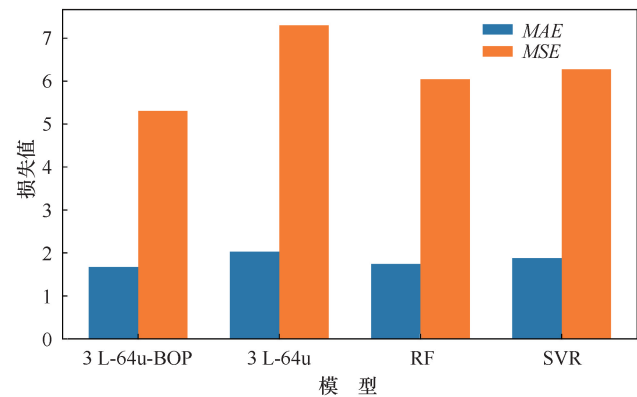


图10 3L-64u-BOP、3L-64u、RF 和 SVR 模型的平均 MAE/MSE

Fig. 10 Average MAE/MSE of 3L-64u-BOP, 3L-64u, RF, and SVR models

和 SVR 更低的误差, 这说明 DNN 模型在预测性能上具有优势。特别地, 与 3L-64u 相比, 3L-64u-BOP 模型在 MAE 和 MSE 上分别显示出约 18% 和 27% 的误差降低。这些结果展示了基于贝叶斯优化的超参数调优对于提升 DNN 模型性能的重要性。与 RF 和 SVR 模型相比, 3L-64u-BOP 模型在 MAE 上降低了 4%~11%, 在

MSE 上降低了 12%~15%。这进一步证明了超参数优化对于提升模型性能的有效性, 即使是在先前显示出较高性能的机器学习模型对比中也是如此。

图 11(a) 提供了通过 10 折交叉验证得出的代表性预测结果的可视化, 其中对比了最优化的 DNN 模型 (3L-64u-BOP) 与 SVR 和 RF 模型的预测能力。在散点图中, 实际的抗压强度值由红点表示, 而模型预测值与真实值之间的偏差通过竖线体现。观察 3L-64u-BOP 模型的散点分布, 可以看出大多数预测值紧密围绕实际值排列, 这表明该模型具有最佳的预测性能。

图 11(b) Taylor 图进一步揭示了各模型的预测准确度 and 稳定性。DNN3-L64u-BOP 模型不仅均方误差值最低, 仅为 4.04, 且标准差为 2.01, 表现出最小的预测变异性。其高相关系数 (0.987) 也强调了预测值与实际值之间的强线性关系。与之形成对比的是, 尽管 DNN3-L64u 模型的相关系数也较高 (0.961), 但其更高的均方误差 (12.92) 和标准差 (3.59) 显示了较大的预测不稳定性。RF 和 SVR 模型的性能相似, 但 RF 模型的均方误差和标准差略优于 SVR, 相关系数分别为 0.951 和 0.945。

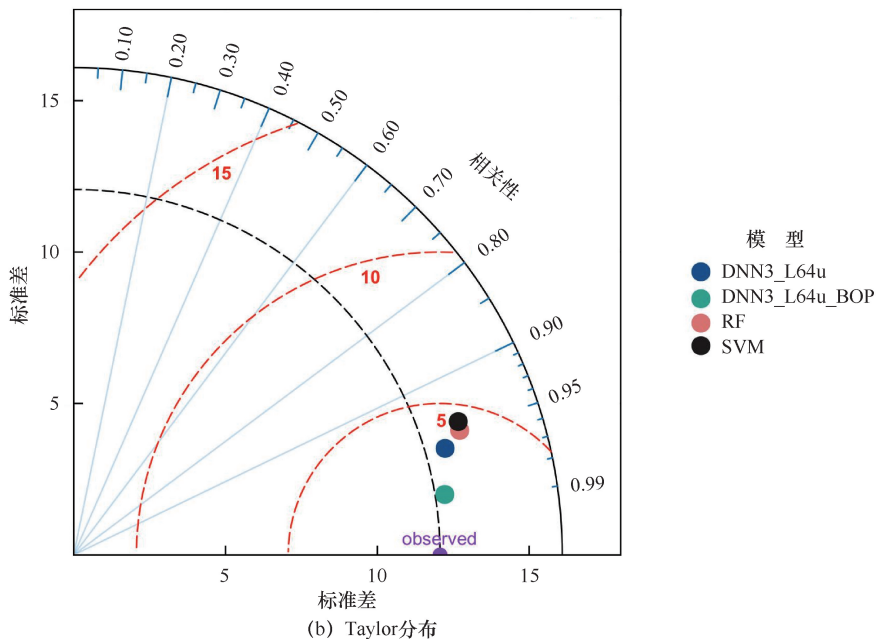



图 11 各模型预测值与真值分布情况

Fig. 11 Distribution of predicted and actual values for each model

4 基于多目标优化方法的混凝土配合比设计

4.1 基于 RF-NSGA-II 的混凝土配合比多目标优化

4.1.1 适应度函数构建

在基于遗传算法的优化过程中, 适应度是描述个体表现的主要指标, 是优化的驱动力, 也是选择个体

的依据。为了提高优化过程的计算速度和精度, 将训练后的 RF 获得的混凝土抗压强度指标与配合比之间的回归关系用作 NSGA-II 的适应度函数。这样就可以准确地描述输入变量与输出目标之间复杂的非线性关系, 克服了生成的混合设计收敛速度慢、与实际情况偏差大的问题。基于 RF 的回归函数为

$$\text{Randomforest}(X_1, X_2, \dots, X_n) = \frac{1}{k} \sum_{i=1}^k (h_i(x) = Y) \quad (15)$$

式中, X_1, X_2, \dots, X_n 为用于预测的 RF 的输入变量; $h_i(x)$ 为单个决策树模型; Y 为输出变量(或目标变量), 并且 k 表示 RF 模型中决策树的数量。抗压强度目标函数可以表示为

$$f_1 = \max\{RF[g_1(X_1, X_2, \dots, X_n)]\} \quad (16)$$

混凝土经济成本的目标函数, 可以表示为

$$f_2 = \min \sum_{i=1}^n v_i x_i \quad (17)$$

式中, x_i 代表混凝土的组成成分; v_i 为该组成成分单位质量所对应的价格。

4.1.2 约束条件

约束经常出现在多目标优化问题中, 可以分为两大类。第一类由范围约束组成, 适用于应在一定限制范围内的输入变量, 例如混凝土和水泥材料的用量。第二类由比例约束组成, 适用于水胶比和砂比等输入变量。约束条件的一般形式为

$$b_{il} < x_i < b_{iu} \quad (18)$$

式中, x_i 代表设计参数; b_{il} 和 b_{iu} 分别表示值的下限和上限设计参数。

4.1.3 多目标优化

确定适应度函数和约束条件, 就可以基于 NSGA-II 实现混凝土配合比参数的多目标优化, 以获得同时满足混凝土强度要求且经济成本最低的最优配合比参数的 Pareto 解集。通过 NSGA-II 获得 Pareto 解集的关键步骤如下。

(1) 确定初始种群大小, 并经过选择、交叉和变异操作后获得第一代种群。

(2) 合并父代和子代种群, 通过快速非支配排序确定个体的非支配等级, 并按其非支配等级的降序保留个体。

(3) 应用精英策略保留父代和子代中最精英的个体, 并通过遗传算法的基本操作生成新的子代种群。

重复此循环, 直到达到最大迭代次数或满足算法的另一个终止条件; 然后, 输出 Pareto 最优解集。

由于 NSGA-II 最终得到的解是一隐藏单元满足 Pareto 效率的解, 因此仍然需要确定理想最优解。本文采用理想点法从 Pareto 前沿获取最优解。 E 点的计算公式 $(\eta_{E_{point}}, Z_{E_{point}})$ 基于理想点的最优值为

$$U_n = \left[\left(\frac{(\eta_{Pareto} - \eta_{E_{point}})}{\eta_{E_{point}}} \right)^2 + \left(\frac{(Z_{Pareto} - Z_{E_{point}})}{Z_{E_{point}}} \right)^2 \right]^{1/2} \quad (19)$$

式中, $(\eta_{Pareto}, Z_{Pareto})$ 为最优 Pareto 边界点的坐标; $(\eta_{E_{point}}, Z_{E_{point}})$ 为理想点的坐标。

最优点是 Pareto 集中最接近理想点的点

$$U_{opt} = \min(U_n) \quad (20)$$

理想点法可用于从 Pareto 前沿解集中确定最优解, 使得多目标方法能够获得最优结果。

4.2 案例分析

4.2.1 工程背景

野河山隧道技术标准为双向四车道。左洞起讫桩号为 ZK12+917—ZK21+047, 全长 8 130 m, 为特长隧道, 隧道底板最大埋深 529 m; 右洞起讫桩号为 YK12+930—YK21+065, 全长 8 135 m, 为特长隧道, 隧道底板最大埋深 532 m。隧洞采用钢拱架+金属网+喷射混凝土+系统锚杆联合支护。原材料包括亚泰 P.O 42.5 水泥、双辽一级粉煤灰、项目区骨料以及混合高效减水剂。为了提高工程效率和质量, 采用了所提出的预测模型进行 C40 混凝土配合比设计。研究选取寻找一段 IV 类围岩的试验段, 采用钢纤维混凝土+预应力锚杆的单层衬砌支护方式, 在减少成本的同时, 提高工作效率。为此, 确定满足强度要求的喷射混凝土配比成了亟需解决的问题。本文建立了 DNN3-L64u-BOP 模型来对该洞段的喷射混凝土 7 d、28 d 抗压强度进行预测, 采用 RF-NSGA-II 模型进行最佳配合比设计及成本控制。

4.2.2 力学性能测试

根据混凝土试验操作规程, 把拌好的混凝土浇注到 150 mm×150 mm×150 mm 的试模中进行机械振捣, 振捣均匀密实后, 放入标准养护室, 温度为 $(20 \pm 2)^\circ\text{C}$, 相对湿度大于 95%, 图 12 为制作的混凝土试块。




图 12 混凝土试验试块

Fig. 12 Concrete test specimen

采用型号为 WEW-1000A 万能试验机进行加载试验。连续均匀加载, 加载速度为 0.5~1.0 MPa/s, 混凝土试块强度如表 4 所列。

表 4 混凝土试块单轴抗压强度试验结果

Table 4 Uniaxial compressive strength test results of concrete specimens

No.	水泥/kg·m ⁻³	粉煤灰/kg·m ⁻³	水/kg·m ⁻³	减水剂/kg·m ⁻³	粗骨料/kg·m ⁻³	细骨料/kg·m ⁻³	7 d 抗压强度/MPa	28 d 抗压强度/MPa
1	380	95	228	0	932	594	28.47	36.45
2	266	114	228	0	932	670	31.57	45.85
3	198.6	132.4	192	0	978.4	825.5	21.31	28.02
4	304	76	228	0	932	670	36.56	47.81
5	139.6	209.4	192	0	1 047	806.9	24.32	28.24
6	427.5	47.5	228	0	932	594	27.48	37.43
7	237.5	237.5	228	0	932	594	29.21	30.08
8	332.5	142.5	228	0	932	594	20.48	33.02
9	190	190.0	228	0	932	670	30.11	40.86
10	374	189.2	170.1	10.1	926.1	756.7	42.17	61.09
11	313.3	262.2	175.5	8.6	1 046.9	611.8	43.21	59.80
12	425	106.3	153.5	16.5	852.1	887.1	44.56	60.29
13	425	106.3	151.4	18.6	936.0	803.7	43.76	61.80
14	375	93.8	126.6	23.4	852.1	992.6	48.23	56.70
15	475	118.8	181.1	8.9	852.1	781.5	49.34	68.30
16	469	117.2	137.8	32.2	852.1	840.5	41.25	66.90
17	425	106.3	153.5	16.5	852.1	887.1	43.25	60.29
18	388.6	97.1	157.9	12.1	852.1	925.7	36.65	50.70
19	425.0	106.3	153.5	16.5	852.1	887.1	48.36	60.29
20	318.8	212.5	155.7	14.3	852.1	880.4	35.81	55.50
21	401.8	94.7	147.4	11.4	946.8	852.1	47.25	68.50
22	362.6	189.0	164.9	11.6	944.7	755.8	59.12	71.30
23	323.7	282.8	183.8	10.3	942.7	659.9	58.21	74.70
24	379.5	151.2	153.9	15.9	1 134.3	605.0	39.17	52.20
25	362.6	189.0	164.9	11.6	944.7	755.8	54.21	71.30
26	286.3	200.9	144.7	11.2	1 004.6	803.7	48.94	67.70
27	362.6	189.0	164.9	11.6	944.7	755.8	51.69	71.30

4.2.3 基于 DNN3-L64u-BOP 的混凝土性能预测模型

利用训练集学习建立基于 DNN3-L64u-BOP 的混凝土单轴抗压强度预测模型;然后,使用基于工程试验所得数据作为测试集来验证第四节中基于训练集建立的预测模型。模型经过训练和测试后,在基于实际工程背景下所得数据集中预测结果如图 13 所示。根据模型的训练结果,可以得出以下结论。

DNN3-L64u-BOP 模型可以根据混凝土配合比准确预测抗压性能。从图 13 可以直观地看出,模型获得的测试集样本的预测值与实际值吻合较好。根据计算结果:7 d 抗压强度实际值与预测值的 MSE 为 6.07, R^2 为 0.946, MAE 为 2.15;28 d 抗压强度实际值与预测值的 MSE 为 6.85, R^2 为 0.967, MAE 为 2.33。因此,基于 DNN3-L64u-BOP 的预测结果表明该模型对于实际工程中混凝土力学性能的预测是有效的,可以作为代理模型来实现混凝土配合比与抗压强度之间的映射,以提高混凝土设计的效率。

根据野河山隧道喷射混凝土技术要求,7 d 抗压

强度应大于等于 30 MPa,28 d 抗压强度应大于等于 40 MPa。为满足这一要求,现场试验共设计了 27 组配合比,制备试块、养护、抗压试验总耗时 3 个月,由此可见,采用传统的混凝土配合比设计方法费时费力。因此本文提出 DNN3-L64u-BOP 模型,按照设计的配合比方案输入水、水泥、粉煤灰、水、减水剂、粗骨料、细骨料 7 种原材料参数值,即可得到抗压强度预测值。若预测值满足设计要求,再进行试块的制备及抗压强度试验,若不满足要求则调整设计方案,筛选如表 4 中 1、3、5、6、7、8、等明显不达标的配合比方案,减少工作量,提高工作效率,更好地推进工程进展。

4.2.4 基于 RF-NSGA-II 的混凝土配合比多目标优化

4.2.4.1 适应度函数的建立

RF-NSGA-II 是一种有效的多目标优化算法。在迭代计算过程中,必须对生成的个体的适应度进行评估。为了提高评估的准确性和效率,将训练好的 RF 代理模型用作关于混凝土抗压程度的适应度函数的基

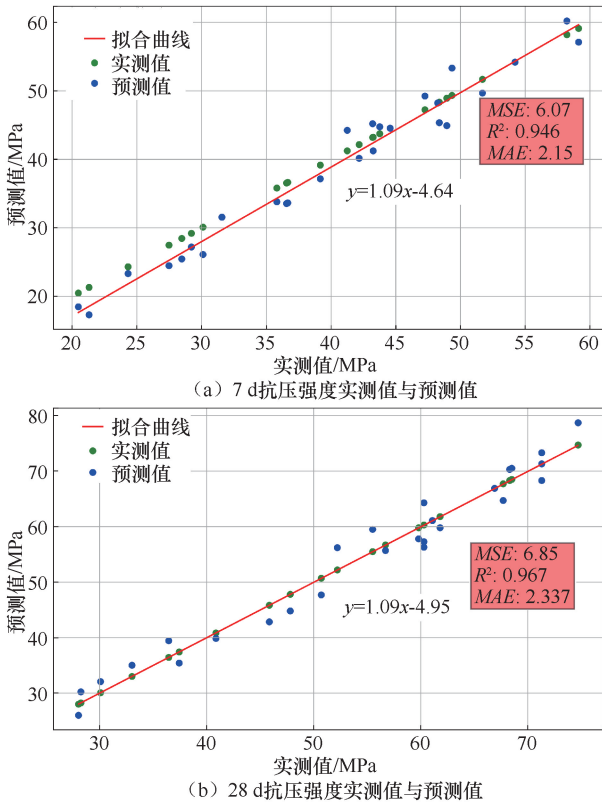


图 13 实测混凝土抗压强度预测结果

Fig. 13 Measured concrete compressive strength prediction results

础, 并使用多项式函数作为关于混凝土成本的适应度函数^[45-46]。

关于混凝土抗压强度的目标函数 $\max f_1$, 可按式求得

$$f_1 = \max \{ RF [g_1(x_1, x_2, \dots, x_6)] \} \quad (21)$$

式中, $x_1, x_2, x_3, x_4, x_5, x_6$ 分别表示水泥、粉煤灰、水胶比、粗骨料、细骨料、减水剂等参量。

4.2.4.2 混凝土成本函数

混凝土的单位成本可以通过根据原材料价格建立多项式来计算。此时, 混凝土原材料的实际价格取决于水泥、水、粉煤灰、细骨料、粗骨料、减水剂的单价, 分别为 0.35 元/ m^3 、0.002 元/ m^3 、0.38 元/ m^3 、0.125 元/ m^3 、0.13 元/ m^3 、4.65 元/ m^3 。关于经济成本的目标函数为

$$\min f_2 = 0.35x_1 + 0.002x_3(x_1 + x_2) + 0.38x_2 + 0.125x_4 + 0.102x_5 + 4.65x_6(x_1 + x_2) \quad (22)$$

4.2.4.3 可变约束

对于本例中准备采用的 P. O 42.5 水泥和粉煤灰作为胶凝材料, 并添加混合高效减水剂以增强混凝土的和易性。根据我国混凝土设计规范和工程实践的要求, 混凝土配合比中各组分的掺量应在合理的范围内, 混

凝土强度也应满足一定的要求如表 5 所列。并基于现成施工设计标准混凝土约束条件由式 (22) 确定

$$\begin{cases} 275 \leq x_1 \leq 500 \\ 0 \leq x_2 \leq 150 \\ 0.3 \leq x_3 \leq 0.5 \\ x_1 + x_2 \geq 330 \\ 600 \leq x_4 \leq 900 \\ 700 \leq x_5 \leq 1300 \\ 5\% \leq x_6 \leq 2.0\% \\ f_{cu, 0} \geq f_{cu, k} + 1.645\sigma \end{cases} \quad (23)$$

式中, $f_{cu, 0}$ 为施工时混凝土的配制强度; $f_{cu, k}$ 为设计混凝土立方体的抗压强度标准值; σ 为工程中使用的混凝土强度的标准偏差。

表 5 混凝土配合比的约束条件

Table 5 Constraint conditions of concrete mix proportion

组成成分	添加量/ $kg \cdot m^{-3}$
水泥	275 ~ 510
粉煤灰	0 ~ 160
水胶比	0.3 ~ 0.4
细骨料	600 ~ 900
粗骨料	700 ~ 1300
减水剂	0.5 ~ 2.0

4.2.4.4 多目标优化结果及分析

在优化过程中, NSGA-II 对生成的个体进行交叉、变异等操作。因此, 在迭代计算过程之前需要设置几个参数, 包括生成种群的大小、代数以及交叉和变异的系数。考虑到优化效果和计算的收敛速度, 将种群规模设置为 40, 最大迭代数 (作为终止准则) 设置为 60, 交叉算子的系数设置为 0.7, 变异算子的系数设置为 0.01。如上所述建立目标函数、变量约束和模型参数后, 基于 NSGA-II 的 60 次迭代得到 40 种 Pareto 优化的混凝土配合比, 如图 14 所示。

通过多目标优化得到的 Pareto 图中的每个点都是基于定义的目标的非支配解。在这种情况下, 每种方案都不能严格优于另一种方案, 因为具有高抗压性的混合比也具有高成本。多目标优化后找到的每个点对应的解可以认为是最优解。因此, 仍然需要根据项目需求选择最合适的解决方案。本研究采用理想点法在三种情况下得到最终解: A 点代表结合混凝土的抗压和成本要求得到的最优平衡解; B 点代表不考虑成本, 获得混凝土最佳抗压性最优方案; C 点代表无论抗压性如何, 最大限度降低混凝土成本的最佳解决方案。为了进一步验证文章所提 RF-NSGA-II 多目标优

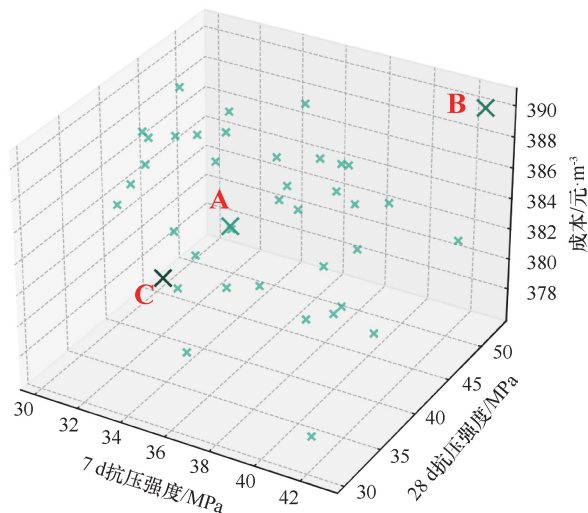


图 14 目标优化的 Pareto 解集

Fig. 14 Pareto solution set for target optimization

化结果所得方案, 文中对该优化方案进行试验验证, Pareto 解集中 A、B、C 点对应混凝土配合比情景下的抗压强度目标值、成本目标机以及基于优化配比下试验所得抗压强度与成本如表 6 所列。

表 6 Pareto 解集中 A、B、C 点对应的目标值和混凝土配合比

Table 6 Objective values and concrete mix proportions corresponding to points A, B, and C in the Pareto solution set

指标		A	B	C
	x_1	413	422	410
	x_2	74.3	78	72
	x_3	0.32	0.32	0.31
	x_4	670	673	667
	x_5	1 095	1 103	1 094
	x_6	0.98	1.12	0.93
RF-NSGA-II	7 d 抗压强度/MPa	32.86	42.71	30.25
	28 d 抗压强度/MPa	47.02	52.41	45.18
	成本/元·m ⁻³	403.74	410.38	400.80
试验值/MPa	7 d 抗压强度	33.36	41.87	31.47
	28 d 抗压强度	46.77	53.41	44.14
误差/%	7 d 抗压强度	1.52	1.97	4.03
	28 d 抗压强度	0.53	1.91	2.23

RF-NSGA-II 方案计算出的预期抗压强度与实际结果相差不大, 表明该预测方法准确可行。从三个 Pareto 解集中所得 A、B、C 的试验结果可以看出, 误差结果均在 10% 以内, 在可接受的范围内。并且试验组的抗压性满足野河山隧道喷射混凝土技术要求。

5 结果讨论

通过深度神经网络(DNN)模型预测混凝土抗压

强度, 并提出 RF-NSGA-II 算法优化混凝土配合比, 实现抗压强度和成本的双重优化。与传统的机器学习方法相比, DNN 模型在大规模、高维度数据处理方面具有优势, 但其性能受限于数据质量和数量, 以及超参数的选择。通过贝叶斯优化策略调优超参数, 有效提升了模型的预测精度, 但在实际应用中仍需进行充分的数据预处理和特征选择。在混凝土配合比优化方面, RF-NSGA-II 算法展示了优异的多目标优化能力, 能在满足强度要求的同时实现成本最小化。相比其他多目标优化算法, RF-NSGA-II 算法结合了快速非支配排序、精英保留和拥挤距离, 优化结果的收敛性和多样性更优。然而, 遗传算法计算复杂度较高, 需在实际应用中调整算法参数。

在野河山隧道工程案例中验证了模型的准确性, DNN3-L64u-BOP 模型的预测结果与实验值吻合良好, RF-NSGA-II 算法优化的配合比方案有效降低了成本, 满足工程强度要求。相比之下, 其他研究方法在类似案例中的表现存在局限性, 如线性回归方法难以处理复杂非线性关系, 传统机器学习方法在特征提取和模型泛化能力方面较弱。

尽管取得了良好成果, 仍存在一些不足。首先, DNN 模型的训练依赖大量高质量数据, 实际获取这些数据可能困难。其次, 遗传算法计算复杂度较高, 可能在大规模应用中受限。最后, 研究主要集中在单一项目, 模型的泛化能力有待验证。未来研究应关注以下方面: 提高 DNN 模型的泛化能力, 优化遗传算法的计算效率, 增强数据预处理和特征选择, 拓展研究范围, 将本文方法应用于更多实际工程案例, 以验证其广泛适用性和可靠性。

6 结论

本研究利用深度学习技术构建了一个抗压强度预测模型, 以支持现场混凝土抗压强度的预测。此外, 进行了基于贝叶斯网络的超参数优化, 优化模型的性能与机器学习模型的性能进行了比较。并引入 RF-NSGA-II 模型实现基于实际工程的混凝土不同养护时间抗压强度与成本多目标配比优化。最终得到了以下结论。

(1) 对于 DNN 模型, 改变隐藏层数和单元数, 以测试 15 种 DNN 模型结构, 并评估混凝土抗压强度的预测性能。根据性能评估结果, 选择了 3 个隐藏层和 64 个隐藏单元的 DNN 3-L-64u 模型作为调优的基础模型。相比之下, 与机器学习模型 RF 和 SVR 的性能比较表明, DNN 3-L-64u 模型的整体预

测更加准确。

(2)为了提高选定的 DNN 3-L-64u 模型的性能,进行了基于贝叶斯模型的超参数调优(DNN 3-L-64u-BOP)。3L-64u-BOP 模型的预测性能与优化前的 3L-64u 模型以及使用测试数据的机器学习模型 RF 和 SVR 进行了比较,3L-64u-BOP 模型的性能最佳。与 3L-64u 模型相比,3L-64u-BOP 模型分别显示了约 18%和 27%的 MAE 和 MSE 的误差降低率;3L-64u-BOP 模型的 MAE 误差比 RF 低 4%,MSE 误差低 12%;3L-64u-BOP 模型的 MAE 和 MSE 误差分别比 SVR 低 11%和 15%。

(3)NSGA-II 表现出优异的多目标优化能力,可以协调混凝土抗压性最大化和成本最小化之间的权衡。所提出的混合智能 RF-NSGA-II 框架可以有效预测混凝土抗压性并优化其配合比,可为施工单位在最优化的配比情况下节省成本。此外,由于该框架易于实现、可靠性高,对于混凝土施工的工程实践具有较高的实用价值,也可为其他类似工程项目提供指导。

参考文献(References):

- [1] 陈璋,陈徐东,白银,等.粉煤灰对低胶材自密实混凝土强度及孔结构的影响[J].水利水电技术(中英文),2023,54(2):179-189.
CHEN Zhang, CHEN Xudong, BAI Yin, et al. Influence of fly ash on the strength and pore structure of low-binder self-compacting concrete[J]. Water Resources and Hydropower Engineering, 2023, 54(2): 179-189.
- [2] 孟浩,杨维武,刘海峰.沙漠砂替代率对冻融环境下混凝土抗压性能的影响[J].宁夏工程技术,2023,22(1):49-55.
MENG Hao, YANG Weiwu, LIU Haifeng. Influence of desert sand replacement rate on compressive performance of concrete in freeze-thaw environment[J]. Ningxia Engineering Technology, 2023, 22(1): 49-55.
- [3] 覃源,梁达,王玉龙,等.冷缝存在条件下混凝土力学性能试验研究[J].排灌机械工程学报,2023,41(7):677-681.
QIN Yuan, LIANG Da, WANG Yulong, et al. Experimental study on mechanical properties of concrete with cold joints[J]. Journal of Drainage and Irrigation Machinery Engineering, 2023, 41(7): 677-681.
- [4] 张凯,李北星,李广,等.片麻岩石粉掺入方式对混凝土性能的影响[J].水利水电技术(中英文),2023,54(1):187-198.
ZHANG Kai, LI Beixing, LI Guang, et al. Effect of incorporation method of gneiss powder on the performance of concrete[J]. Water Resources and Hydropower Engineering, 2023, 54(1): 187-198.
- [5] 侯艳娟,单世龙,李正宁,等.玻化粉煤灰微珠混凝土基本力学性能及水化热释放研究[J].铁道勘察,2023,49(4):7-12.
HOU Yanjuan, SHAN Shilong, LI Zhengning, et al. Research on the basic mechanical properties and heat release of hydration of glassy fly

- ash microbead concrete[J]. Railway Investigation and Surveying, 2023, 49(4): 7-12.
- [6] 李温,王海龙,张佳豪,等.胶粉煤矸石混凝土力学特性及微观结构试验研究[J].排灌机械工程学报,2023,41(2):140-146.
LI Wen, WANG Hailong, ZHANG Jiahao, et al. Experimental study on mechanical properties and microstructure of powdered coal gangue concrete[J]. Journal of Drainage and Irrigation Machinery Engineering, 2023, 41(2): 140-146.
- [7] MAJID K, FAISAL M J. Towards sustainable construction: Machine learning based predictive models for strength and durability characteristics of blended cement concrete[J]. Materials Today Communications, 2023, 37: 100-115.
- [8] GHOLAMREZA P, ZHONG T, NARIMAN S, et al. Using artificial intelligence methods to predict the compressive strength of concrete containing sugarcane bagasse ash[J]. Construction and Building Materials, 2023, 409: 124-138.
- [9] 许欣,马魁.基于不同掺量的PVA纤维混凝土力学性能研究[J].科技与创新,2023(2):83-85.
XU Xin, MA Kui. Study on mechanical properties of PVA fiber concrete with different dosages[J]. Science and Technology Innovation, 2023(2): 83-85.
- [10] 钱觉时,黄煜镔.混凝土强度尺寸效应的研究进展[J].混凝土与水泥制品,2003(3):1-5.
QIAN Jueshi, HUANG Yubin. Research progress on the size effect of concrete strength[J]. Concrete and Cement Products, 2003(3): 1-5.
- [11] 李清富,孙振华,张海洋.粉煤灰和硅粉对混凝土强度影响的试验研究[J].混凝土,2011(5):77-79.
LI Qingfu, SUN Zhenhua, ZHANG Haiyang. Experimental study on the effect of fly ash and silica fume on the strength of concrete[J]. Concrete, 2011(5): 77-79.
- [12] 张朝辉,王沁芳,杨娟.透水混凝土强度和透水性影响因素研究[J].混凝土,2008(3):7-9.
ZHANG Zhaohui, WANG Qinfang, YANG Juan. Study on factors affecting strength and permeability of pervious concrete[J]. Concrete, 2008(3): 7-9.
- [13] 李凤增.基于人工神经网络模型预测混凝土抗压强度[J].粉煤灰综合利用,2023,37(3):126-133.
LI Fengzeng. Prediction of compressive strength of concrete based on artificial neural network model[J]. Fly Ash Comprehensive Utilization, 2023, 37(3): 126-133.
- [14] CHOPRA P, SHARMA R K, CHOPRA, M T. Comparison of machine learning techniques for the prediction of compressive strength of concrete[J]. Advances in Civil Engineering, 2018, 2018: 1-11.
- [15] 贾金青,胡玉龙,王东来,等.混凝土抗压强度与孔隙率关系的研究[J].混凝土,2015(10):56-59.
JIA Jinqing, HU Yulong, WANG Donglai, et al. Study on the relationship between compressive strength and porosity of concrete[J]. Concrete, 2015(10): 56-59.
- [16] 方涛,王俊锋,张鑫月,等.基于神经网络的不同混凝土实时强度预测研究[J].混凝土,2016(12):38-43.

- FANG Tao, WANG Junfeng, ZHANG Xinyue, et al. Real-time strength prediction of different concretes based on artificial neural network[J]. Concrete, 2016(12): 38-43.
- [17] 陈云龙, 马菊荣, 刘海峰, 等. 掺粉煤灰、沙漠砂高强混凝土抗压强度研究[J]. 混凝土, 2014(7): 80-84.
CHEN Yunlong, MA Jurong, LIU Haifeng, et al. Study on compressive strength of high-strength concrete with fly ash and desert sand[J]. Concrete, 2014(7): 80-84.
- [18] 肖建庄, 林壮斌, 朱军. 再生骨料级配混凝土抗压强度的影响[J]. 四川大学学报(工程科学版), 2014, 46(4): 154-160.
XIAO Jianzhuang, LIN Zhuangbin, ZHU Jun. Effect of recycled aggregate gradation on compressive strength of concrete[J]. Journal of Sichuan University (Engineering Science Edition), 2014, 46(4): 154-160.
- [19] 王振波, 周潮, 王家赫, 等. 高延性水泥基材料(ECC)开裂后渗透性研究综述[J]. 水利发展研究, 2024, 24(6): 59-64.
WANG Zhenbo, ZHOU Chao, WANG Jiahe, et al. Summary of research on the permeability of Engineered Cementitious Composites (ECC) after cracking[J]. Water Resources Development Research, 2024, 24(6): 59-64.
- [20] 徐国强, 苏幼坡, 韩佃利, 等. 基于BP神经网络的绿色混凝土抗压强度预测模型[J]. 混凝土, 2013(2): 33-35.
XU Guoqiang, SU Youpo, HAN Dianli, et al. Prediction model of compressive strength of green concrete based on BP neural network[J]. Concrete, 2013(2): 33-35.
- [21] 赵悟, 王博, 赵利军, 等. 改善搅拌过程提高混凝土强度[J]. 长安大学学报(自然科学版), 2015, 35(1): 148-153.
ZHAO Wu, WANG Bo, ZHAO Lijun, et al. Improving concrete strength by optimizing the mixing process[J]. Journal of Chang'an University (Natural Science Edition), 2015, 35(1): 148-153.
- [22] 陆岸典, 唐欣薇, 严振瑞, 等. 复合衬砌结构的预应力混凝土配比试验研究[J]. 水力发电学报, 2022, 41(11): 10-20.
LU Andian, TANG Xinwei, YAN Zhenrui, et al. Experimental study on mix proportion of prestressed concrete for composite lining structure[J]. Journal of Hydroelectric Engineering, 2022, 41(11): 10-20.
- [23] 朱正国, 崔振伟, 马超义, 等. 减震初期支护用钢纤维泡沫混凝土材料性能优化[J]. 中国铁道科学, 2022(3): 43-50.
ZHU Zhengguo, CUI Zhenwei, MA Chaoyi, et al. Performance optimization of steel fiber foam concrete materials for initial support in shock absorption[J]. China Railway Science, 2022(3): 43-50.
- [24] 曹检云, 刘国坤, 孙剑峰. 大跨度悬臂浇筑钢筋混凝土拱桥多目标索力优化研究[J]. 公路工程, 2022, 47(3): 30-34.
CAO Jianyun, LIU Guokun, SUN Jianfeng. Multi-objective cable force optimization for long-span cantilever cast-in-place reinforced concrete arch bridges[J]. Highway Engineering, 2022, 47(3): 30-34.
- [25] ZAVALA G R, NEBRO A J, LUNA F, et al. A survey of multi-objective metaheuristics applied to structural optimization [J]. Structural and Multidisciplinary Optimization, 2014, 49: 537-558.
- [26] BAYKASOĞLU A, ÖZTAŞ A, ÖZBAY E. Prediction and multi-objective optimization of high-strength concrete parameters via soft computing approaches[J]. Expert Systems with Applications, 2009, 36(3): 6145-6155.
- [27] 张海波, 管学茂, 勾密峰, 等. 废旧橡胶粒径对水泥砂浆和混凝土强度影响研究[J]. 硅酸盐通报, 2012, 31(4): 931-934.
ZHANG Haibo, GUAN Xuemao, GOU Mifeng, et al. Study on the effect of waste rubber particle size on the strength of cement mortar and concrete[J]. Bulletin of the Chinese Ceramic Society, 2012, 31(4): 931-934.
- [28] 李欣海. 随机森林模型在分类与回归分析中的应用[J]. 应用昆虫学报, 2013, 50(4): 1190-1197.
LI Xinhai. Application of random forest model in classification and regression analysis[J]. Journal of Applied Entomology, 2013, 50(4): 1190-1197.
- [29] 方匡南, 吴见彬, 朱建平, 等. 随机森林方法研究综述[J]. 统计与信息论坛, 2011, 26(3): 32-38.
FANG Kuangnan, WU Jianbin, ZHU Jianping, et al. A review of random forest methods[J]. Statistics and Information Forum, 2011, 26(3): 32-38.
- [30] 姚登举, 杨静, 詹晓娟. 基于随机森林的特征选择算法[J]. 吉林大学学报(工学版), 2014, 44(1): 137-141.
YAO Dengju, YANG Jing, ZHAN Xiaojun. Feature selection algorithm based on random forest [J]. Journal of Jilin University (Engineering Edition), 2014, 44(1): 137-141.
- [31] 李启明, 喻泽成, 余波, 等. 钢筋混凝土柱地震破坏模式判别的两阶段支持向量机方法[J]. 工程力学, 2022, 39(2): 148-158.
LI Qiming, YU Zecheng, YU Bo, et al. Two-stage SVM method for seismic damage mode discrimination of reinforced concrete columns [J]. Engineering Mechanics, 2022, 39(2): 148-158.
- [32] 熊先勇, 曾亚林, 付慧建, 等. 基于支持向量机和改进粒子群算法的钢管混凝土拱桥可靠度分析[J]. 公路工程, 2023, 48(2): 55-61.
XIONG Xianyang, ZENG Yalin, FU Huijian, et al. Reliability analysis of concrete-filled steel tube arch bridges based on SVM and improved particle swarm optimization [J]. Highway Engineering, 2023, 48(2): 55-61.
- [33] 侍莘莘. 基于支持向量机的建筑工程混凝土质量可靠性分析[J]. 安徽建筑, 2024, 31(1): 77-79.
SHI Xinxin. Reliability analysis of concrete quality in construction engineering based on SVM[J]. Anhui Architecture, 2024, 31(1): 77-79.
- [34] 高蔚. 基于深度学习的再生混凝土抗压强度预测[J]. 混凝土, 2018(11): 58-61.
GAO Wei. Prediction of compressive strength of recycled concrete based on deep learning[J]. Concrete, 2018(11): 58-61.
- [35] 王竣禾, 姜勇. 基于深度强化学习的动态装配算法[J]. 智能系统学报, 2023, 18(1): 2-11.
WANG Junhe, JIANG Yong. Dynamic assembly algorithm based on deep reinforcement learning [J]. Journal of Intelligent Systems, 2023, 18(1): 2-11.
- [36] 章玉容, 余威龙, 麻雪晴, 等. 基于深度学习的粉煤灰混凝土氯离子浓度预测[J]. 北京工业大学学报, 2023, 49(2): 205-212.
ZHANG Yuyong, YU Weilong, MA Xueqing, et al. Prediction of chloride ion concentration in fly ash concrete based on deep learning

- [J]. Journal of Beijing University of Technology, 2023, 49(2): 205-212.
- [37] 季韬,林挺伟,林旭健. 基于人工神经网络的混凝土抗压强度预测方法[J]. 建筑材料学报, 2005(6): 677-681.
JI Tao, LIN Tingwei, LIN Xujian. Prediction method for compressive strength of concrete based on artificial neural network[J]. Journal of Building Materials, 2005(6): 677-681.
- [38] 申嘉荣,徐千军. 建筑材料微观结构的人工识别研究[J]. 水利发展研究, 2023, 23(10): 72-79.
SHEN Jiarong, XU Qianjun. Research of artificial identification of microstructure of building materials [J]. Water Resources Development Research, 2023, 23(10): 72-79.
- [39] 冷发光,冯乃谦,邢峰. 提高普通混凝土强度和耐久性的正交试验研究[J]. 混凝土, 2000(1): 18-23.
LENG Faguang, FENG Naiqian, XING Feng. Orthogonal experiment study on improving strength and durability of ordinary concrete[J]. Concrete, 2000(1): 18-23.
- [40] 梁子超,李智炜,赖铿,等. 10折交叉验证用于预测模型泛化能力评价及其R软件实现[J]. 中国医院统计, 2020, 27(4): 289-292.
LIANG Zichao, LI Zhiwei, LAI Keng, et al. Evaluation of generalization ability of prediction model using 10-fold cross-validation and its implementation in R software[J]. Chinese Hospital Statistics, 2020, 27(4): 289-292.
- [41] 胡局新,张功杰. 基于K折交叉验证的选择性集成分类算法[J]. 科技通报, 2013, 29(12): 115-117.
HU Juxin, ZHANG Gongjie. Selective ensemble classification algorithm based on K-fold cross-validation [J]. Science and Technology Bulletin, 2013, 29(12): 115-117.
- [42] 王重仁,韩冬梅. 基于超参数优化和集成学习的互联网信贷个人信用评估[J]. 统计与决策, 2019, 35(1): 87-91.
WANG Chongren, HAN Dongmei. Internet credit personal credit assessment based on hyperparameter optimization and ensemble learning[J]. Statistics and Decision, 2019, 35(1): 87-91.
- [43] 崔佳旭,杨博. 贝叶斯优化方法和应用综述[J]. 软件学报, 2018, 29(10): 3068-3090.
CUI Jiayu, YANG Bo. Review of Bayesian optimization methods and applications[J]. Journal of Software, 2018, 29(10): 3068-3090.
- [44] 丁昌伟,王新,陈同俊,等. 贝叶斯优化的XGBoost在小断层地震解释中的应用[J]. 煤炭学报, 2023, 48(6): 2530-2539.
DING Changwei, WANG Xin, CHEN Tongjun, et al. Application of Bayesian optimized XGBoost in small fault earthquake interpretation [J]. Journal of China Coal Society, 2023, 48(6): 2530-2539.
- [45] 吴贤国,杨赛,王成龙,等. 基于RF-NSGA-II的建筑能耗多目标优化[J]. 土木工程与管理学报, 2021, 38(4): 263-270.
WU Xianguo, YANG Sai, WANG Chenglong, et al. Multi-objective optimization of building energy consumption based on RF-NSGA-II [J]. Journal of Civil Engineering and Management, 2021, 38(4): 263-270.
- [46] 向芷恒,王秉哲,雪景州,等. 基于NSGA-II算法解决多目标优化实际应用的研究[J]. 应用数学进展, 2023, 12(10): 4195-4207.
XIANG Zhiheng, WANG Bingzhe, XUE Jingzhou, et al. Research on solving practical multi-objective optimization problems based on NSGA-II algorithm [J]. Advances in Applied Mathematics, 2023, 12(10): 4195-4207.

(责任编辑 王海锋)