

机器学习预测混凝土材料耐久性的研究进展

刘 晓^{1,2}, 王思迈^{1,2}, 卢 磊^{1,2}, 陈美祝³, 翟 跃^{1,2}, 崔素萍^{1,2}

(1. 北京工业大学材料与制造学部, 工业大数据应用技术国家工程实验室, 北京 100124; 2. 北京工业大学材料与制造学部, 新型功能材料教育部重点实验室, 北京 100124; 3. 武汉理工大学, 硅酸盐建筑材料国家重点实验室, 武汉 430070)

摘 要: 基于实验研究的混凝土材料耐久性评价周期长、成本高、效率低, 传统经验公式对耐久性的预测精度有限且无法根据性能反推混凝土的配合比设计, 因此开发新型高效的材料质量控制和性能预测工具已是当务之急。通过梳理建立机器学习模型的流程, 总结常用算法的基本工作原理和优势, 归纳基于机器学习的各耐久性指标预测算法, 探讨其应用效果和发展方向, 为机器学习技术在混凝土领域的深度开发和应用提供了依据。

关键词: 混凝土; 耐久性; 机器学习; 算法; 预测

中图分类号: TP181; TQ178 文献标志码: A 文章编号: 0454-5648(2023)08-2062-12

网络出版时间: 2023-05-05



Development on Machine Learning for Durability Prediction of Concrete Materials

LIU Xiao^{1,2}, WANG Simai^{1,2}, LU Lei^{1,2}, CHEN Meizhu³, ZHAI Yue^{1,2}, CUI Suping^{1,2}

(1. National Engineering Laboratory for Industrial Big-Data Application Technology, Faculty of Materials and Manufacturing, Beijing University of Technology, Beijing 100124, China; 2. Key Laboratory of Advanced Functional Materials of Ministry of Education, Faculty of Materials and Manufacturing, Beijing University of Technology, Beijing 100124, China; 3. State Key Laboratory of Silicate Materials for Architectures, Wuhan University of Technology, Wuhan 430070, China)

Abstract: The durability evaluation of concrete materials based on the related experiments has a low economic efficiency ratio. The prediction accuracy of the conventional empirical formula for durability is restricted and the proportions of concrete mix cannot be calculated according to the performance. It is thus necessary to develop a novel and efficient material quality control and performance prediction tool. In this review, the process of building machine learning models was stated. The basic working flow and advantages of common algorithms, as well as the durability index prediction algorithms based on machine learning were summarized. Its application effects and development direction were discussed. This review can provide a basis for the in-depth development and application of machine learning technology in the field of concrete.

Keywords: concrete; durability; machine learning; algorithm; prediction

随着计算机科学的快速发展, 人工智能技术逐渐成熟, 机器学习作为其重要分支, 能够对海量信息进行筛选整理并发掘其中的规律, 提高数据的利用效率, 是大数据背景下不可或缺的工具之一^[1-3], 也代表了当前数据挖掘处理技术与模型预测计算相结合的先进方向。近年来, 机器学习在材料科学领域诸多方面的应用研究取得了较大进展, 包括材料

性能预测、新材料设计等^[4]。目前机器学习已经广泛应用于金属材料^[5]和无机非金属材料中的电解质与电极材料^[6-7]、热电材料^[8]等领域, 而在无机非金属建筑材料和高分子材料领域的相关研究仍处于起步阶段。

混凝土作为基础设施建设的首选材料, 力学性能和耐久性是其评价主要指标。其中以抗压强度为

收稿日期: 2022-11-11。 修订日期: 2022-12-10。

基金项目: 国家自然科学基金面上项目(51578025); 河北省自然科学基金面上项目(E202210028)。

第一作者: 刘 晓(1983—), 男, 博士, 教授。

Received date: 2022-11-11. Revised date: 2022-12-10.

First author: LIU Xiao (1983—), male, Ph.D., Professor.

E-mail: liux@bjut.edu.cn

主的力学性能测试方法简单、实验周期短,所以已经存在大量针对不同类型混凝土力学性能的实验,基于机器学习的混凝土力学性能预测模型也得到了较为充分的研究^[9]。相比之下,混凝土的耐久性评价指标更多、测试方法丰富、实验周期长、成本高,可供建立机器学习预测模型的数据较为有限,相关研究尚不充分^[10]。

混凝土材料的耐久性受诸多因素的直接影响。传统的耐久性预测模型普遍为“机理驱动”,其价值在于借助耐久性的相关理论,建立各因素与混凝土材料耐久性的本构关系,阐明材料耐久性的原理。此类模型能够以某一耐久性指标劣化的机理为基础,选择影响该指标的主要因素作为变量,通过设定与调节参数,对实验数据进行拟合与回归分析,建立经验公式模型,实现材料耐久性的预测^[11-12]。但该方法精度有限,并且在如矿物掺合料等原材料种类发生变化时,模型将不再适用;此外,传统模型虽然可以建立自变量与因变量之间的显式关系式,能够在一定程度上指导混凝土配合比设计的优化,但由于自变量较多,反算过程的工作量较大,求解最优配合比存在一定难度。相比之下,基于机器学习的混凝土材料耐久性预测模型的核心优势有 4 个方面: 1) 可以在考虑更多自变量的同时达到更高的预测精度,对组成复杂的现代混凝土材料具有良好的兼容性; 2) 能够显示出各因素对耐久性影响的权重和影响方式; 3) 可以依据输出参数反求输入参数,即根据已知函数值求解自变量; 4) 基于机器学习的混凝土材料耐久性预测是“数据驱动”型的预测模型,当数据种类全面、数据量丰富时,训练产生的预测模型将具有普适性。基于上述 4 点,机器学习预测模型不但可以用于预测材料耐久性,还可以对混凝土的配合比设计进行优化。本文梳理了建立机器学习预测混凝土耐久性模型的完整流程和常用算法,综述了该领域的研究进展,展望了机器学习预测混凝土材料耐久性的研究和发展方向。

1 机器学习的常规流程

如图 1 所示,构建机器学习预测模型的流程主要有 3 个步骤^[13-15]: 数据收集、模型建立、模型评价。

数据收集阶段的主要任务是建立训练机器学习模型所需的数据集。在材料科学领域,特别是混凝土领域,原始数据普遍来源于已发表的文献^[16]。随

后需要对数据进行预处理^[17],包括特征选择、归一化等。数据归一化的主要目的是尽可能减小离群值对模型训练的影响,也能够在一定程度上提升模型的预测精度。特征选择的意义在于降低数据维数、提升机器学习的效率、获得更强的模型泛化能力。相互之间具有干扰性的输入变量以及与预测任务无关的变量会被剔除,其余变量则作为机器学习的输入变量,真正参与模型训练的过程。




图 1 机器学习工作流程^[15]

Fig. 1 Workflow of machine learning^[15]

模型建立阶段首先需要选择适当的算法,通常集成算法的预测准确度更高,但其通过编程建立模型的过程更为复杂^[18-19]。随后进行模型训练和模型评估,包括对模型内部的参数进行调整,提升模型预测准确性,防止欠拟合和过拟合的发生。过拟合是学习器将训练样本自身的特点也归为了数据集整体的一般特征;欠拟合与之相反,是学习器尚未学习到训练样本的一般性质。二者均会导致模型的泛化能力下降,但解决方法有所差异。通常只需增加训练轮数或对模型进行调整即可解决欠拟合的问题;而过拟合无法完全消除,一般通过留出验证集、交叉验证、调节模型参数等方式减小其发生的风险^[10, 20]。

最后一个阶段需要对训练得到的最优模型进行解释、检验和评价。机器学习模型是计算机程序自动构建的,其具体的训练和学习过程并未被展示。模型解释的意义在于辅助人们理解机器学习模型的学习过程和学习内容,以及模型对每一组输入数据做出相应决策的原因和决策的可靠性^[21],是模型评价阶段的重要环节。最常用的手段是通过 Shapley additive explanations 分析(SHAP),将输入变量对输出结果的贡献进行量化和排序,并判断正、负相关性^[12]。检验与评价则是依据模型对测试集数据预测的均方根误差(RMSE)、平均绝对误差(MAE)、绝

对百分比误差(MAPE)、相关系数(R^2)等指标进行的^[22]。此外,可以引入综合评价指标 OBJ^[23–25],同时考虑模型在训练集和测试集的预测误差,对模型的泛化能力进行评价。

2 机器学习的常用算法

2.1 人工神经网络

人工神经网络(ANN)是由大量的神经元相互连接所组成的网络,神经元的结构如图 2 所示。与动物的神经网络组成相似,独立的神经元功能简单,但大量神经元所构成的如图 3 所示的神经网络则具有强大的功能。ANN 算法的实现过程是在运算过程中,输入层神经元负责输入数据,不对数据进行处理;隐含层和输出层的每个神经元都会以上一层网络中的神经元输出信号作为输入,若该输入信号达到阈值则会激活该神经元,处理过的信号会被传输给多个后续单元。神经元之间相互制约,最终将各单元的输出结果加权汇总,得到输出数据^[26–27],实现从输入到输出的非线性映射。ANN 的优势在于容错性高,对环境的适应能力强,具有自学习功能,可以在模型训练过程中自行调节神经元之间的连接权重^[26]。




图 2 神经元结构^[14]

Fig. 2 Structure of neurons^[14]




图 3 人工神经网络结构^[14]

Fig. 3 Structure of ANN^[14]

为了进一步提升 ANN 算法的对复杂规律的学习能力,可通过增加隐层数目实现该目标。若仍然使用传统 ANN 算法的训练模式,则可能导致模型不收敛。近年来,随着图形处理器(GPU)和中央处理器(CPU)协同计算模式的发展,计算机的计算能力有了极大的提升,基于 ANN 算法的深度学习理论也开始得到关注。以深度神经网络(DNN)为例,模型不再使用传统的整体训练模式,而是先进行逐层预训练,再对整个含有多隐层的神经网络进行微调^[14]。与传统的 ANN 相比,类似 DNN 的深度学习模型的性能更加优异,但深度学习的理论和方法在具体研究领域的应用尚不成熟^[28]。

2.2 支持向量机

支持向量机(SVM)作为一种智能算法,能够解决分类问题和回归问题,用于解决回归问题时,也可称为支持向量回归(SVR)。该模型可用于学习输出和输入参数之间的线性或非线性关系。为了学习输入参数多、数据维数高的非线性关系,SVM 算法的实现过程是通过引入 1 个非线性映射函数,将低维空间中的非线性关系映射为高维空间的线性关系,再在该高维空间寻求最优回归超平面,使所有样本到该超平面的距离最小^[13, 29–30]。只要输入数据的维数是有限的,那么必然存在 1 个高维空间,使得数据在该空间内具有线性规律。

SVM 算法需要少量样本即可展开训练,但应用于大规模训练样本的效果不佳。

2.3 决策树

决策树(DT)是基于树状结构完成分类或回归任务的一种算法。一棵决策树包含一个根节点、数个内部节点和数个叶节点^[31–32]。DT 的工作原理如图 4 所示,其实现过程是先将数据由根节点输入决策树,标有“ R_i ”的节点为叶节点,对应决策结果,且不再有后续输出;其余为非叶节点,分别对应数据不同的类别属性;非叶节点的各个分支代表了对该节点属性的不同测试结果。

相较其它算法,决策树算法的规则简单、易于理解,计算量较小,但数据的类别较多时,可能会产生较多的错误决策。

2.4 遗传算法

遗传算法(GA)是受生物种群遗传和进化启发而产生的一种人工智能算法^[34]。遗传程序设计(GP)是以 GA 为基础,针对解决复杂的科学与工程问题发展而来的算法,能够充分展现输出结果的复杂性,但该算法训练模型耗时长、占用计算机存

存储空间大^[35]。




图 4 决策树算法结构^[33]
Fig. 4 Structure of Decision Tree^[33]

在 GA 和 GP 的基础上衍生的基因表达式编程 (GEP) 算法兼顾二者优点, 更适合实际应用。GEP 算法的工作模式与 GA、GP 相似, 其实现过程是先为全部个体创造 1 组固定长度的染色体并对个体进行适应性评估, 再选择适应性最强的个体进行繁殖。新个体迭代数次, 直至获得最优解决方案^[36]。该算法的优势在于可以给出输出变量与输入变量的数学表达式, 所建立的模型具有较强的泛化能力和较高的预测准确性^[35]。近年来, 该算法在土木工程领域得到广泛关注, 并成功应用于混凝土性能的预测^[37]。

2.5 集成算法

集成算法是由独立算法组合而成的一个更优的算法, 组合方法主要有顺序集成方法和并行集成方法。

通过算法串联组合构成的顺序集成方法的实现过程是每一次训练为上一次训练失败的样本分配更大的权重, 进行重点学习和训练, 如此循环多次, 取每次训练的结果加权平均值作为最终输出。目前应用于混凝土耐久性预测的算法主要有梯度提升 (GB)、轻量级梯度提升机 (Light GBM)、极端梯度提升 (XGB)、自适应提升 (AdB)、梯度提升决策树 (GBDT) 等^[38]。

通过算法并联构成的并行集成方法的实现过程是在每一次训练时都重新分配训练集和测试集, 将每次训练结果的平均值作为最终输出。随机森林算法 (RF) 是 1 种基于决策树的并行集成算法, 也是目前应用最为广泛算法之一^[39]。随机森林内包含了很多决策树, 每一棵决策树独立进行决策, 每一棵决策树分配到的训练集和测试集各不相同, 但都包含于原始数据集, 随机森林模型最终的输出结果由每

一棵决策树输出的结果共同决定。该算法一方面可以避免欠拟合、最大限度消除过拟合, 另一方面可以准确识别数据的变化趋势和规律, 排除异常值的影响。

3 基于机器学习的混凝土耐久性预测

3.1 抗氯离子渗透性预测

混凝土的抗氯离子渗透性是最重要的耐久性评价指标之一, 也是广大学者最早开始使用机器学习进行预测的性能之一。

早期的研究主要选择水胶比、水泥用量、矿物掺合料用量等混凝土配合比相关的变量作为输入, 采用 SVM、ANN 等独立算法建立模型^[40], 对氯离子渗透系数进行预测。有研究显示, 在数据量较小的情况下, SVM 比 ANN 的预测更准确^[41-42], 在此基础上, 基于 SVM 的集成算法预测模型得以建立, 在满足预测精度需求的基础上拓宽了 SVM 的适用范围^[43]。与较为复杂的 ANN 相比, SVM 属于简单模型, 学习能力相对较弱。当变量较少、数据量较小时, 学习能力过强的算法会将样本中存在的“噪声”也纳入数据规律中, 从而造成过拟合, 增加模型的泛化误差^[14], 因此 SVM 更适合数据量小的情况。随着数据量或变量增加, 输出变量与输入变量的非线性关系更加复杂, 可能导致简单模型无法收敛, ANN 等学习能力更强的复杂模型的泛化误差逐渐降低并低于 SVM 等简单模型, 因此 ANN 在多变量、大样本量的情况下表现更优。此外, 基于 ANN 算法的深度学习理论中的卷积神经网络 (CNN) 算法具备较强的抗干扰能力, 在面对存在异常数据的数据集时, 仍然具有较高的预测准确性^[44]。

除混凝土材料的 4 种基本组成外, 矿物掺合料同样会影响材料的渗透性。实验和机器学习模型预测相互印证, 表明掺入 9%~13% 硅灰和 35%~40% 粉煤灰的三元胶凝体系的早期抗氯离子渗透性能更优; 若追求更优的长期抗渗性能, 则可以使用 10% 硅灰替代硅酸盐水泥的二元胶凝体系^[45]。计算机或机器学习模型无法直接读取矿物掺合料的种类, 因此可通过编号赋值的手段, 先将其转化为计算机可读的数据类型, 再参与建立模型的过程。矿物掺合料的种类无法直接作为模型输入, 但可以通过将其赋值并输入模型, 实现对不同龄期和不同矿物掺合料种类及掺量的混凝土的氯离子渗透性的准确预测^[46]。编号赋值的方法同样适用于其它无法直接作为模型输入的数据类型, 可使机器学习预测模型

覆盖更多参数。

与完全抽象的机器学习模型相比,预测方程能直观地展示各种因素对混凝土抗渗性的影响。在输入参数较少且主要为混凝土配合比相关的参数时,可以利用线性或非线性回归构建精度较高的公式预测模型,其中幂函数模型的预测准确性较高, R^2 超过 0.99^[47]。利用多元线性回归(MLR)算法对 942 组实验数据进行学习并建立氯离子扩散系数的预测方程,在考虑养护时间、矿物掺合料种类等复杂参数的条件下,估算误差不大于 7%,基本实现了对混凝土抗氯离子渗透性能的粗略估算^[48]。基因遗传规划(MGGP)和多元自适应回归样条(MARS) 2 种新算法可用于建立砂浆氯离子渗透性的预测方程,并且与 ANN 和 SVM 算法的预测准确性达到同等水平^[49]。

输入变量过多可能不利于提升模型的预测精度,通过 RF 算法从 12 个变量中选取 5 个对高性能混凝土氯离子扩散系数具有较大影响的参数作

为输入,利用最小二乘支持向量机(LSSVM)和带精英策略的遗传算法(NSGA II)构成的集成算法 LSSVM-NSGA II 建立氯离子扩散系数预测模型,其预测精度远高于 ANN 模型, RMSE 降低了 15.18%。另外依据该模型,综合考虑抗氯离子渗透性和成本,对混凝土配合比设计进行了优化,在抗氯离子渗透性提高了 30.71%的基础上,成本降低了 1.84%^[50]。

传统的混凝土配合比设计方法很大程度上依赖于设计者的经验,而基于机器学习的混凝土配合比设计则更科学、更系统,实现了定量的配合比优化。例如,使用 NSGA II 算法与 RF 构成的 RF-NSGA II 集成算法就可以实现混凝土的配合比优化。分别以氯离子扩散系数和冻融循环后的相对弹性模量为抗渗性和抗冻性指标,通过该算法获得了在保证氯离子渗透系数不大于 $3.2 \times 10^{-10} \text{ m}^2/\text{s}$ 的情况下相对弹性模量不低于 85%的最优混凝土配合比设计,且实验值与模型给出的预测值相符^[51]。模型所给出的混凝土配合比及相应的优化指标如表 1 所示。

表 1 混凝土配合比设计及优化指标
Table 1 Concrete proportioning design and optimization index

Water-binder ratio	Mix proportion/(kg·m ⁻³)					w(Compound superplasticizer)/%	Optimization objective	Ref.
	Cement	Fly ash	Slag	Fine aggregate	Coarse aggregate			
0.30	420	72		670	1 081	0.92	Chloride ion permeability coefficient; relative dynamic elastic modulus; cost	[50]
0.40	357.64	62.46		816.00	1 115.27	4.95	Chloride ion permeability coefficient; relative dynamic elastic modulus; cost	[51]


w is mass fraction.

快速氯离子渗透实验同样可以用于评价混凝土的抗氯离子渗透性。通过 SHAP 分析对 Light GBM 和 XGB 算法建立的快速氯离子渗透实验结果的预测模型进行解释:氯离子渗透性与抗压强度、龄期和偏高岭土的掺量呈负相关,骨料含量对抗氯离子渗透性的影响不显著;水胶比为 0.30~0.35、抗压强度高于 70 MPa 的高强混凝土和偏高岭土掺量为 15%的混凝土表现出了较强的抗氯离子渗透能力^[52]。

除抗氯离子渗透性外,也有针对混凝土在盐酸侵蚀下的质量和体积损失进行预测的相关研究^[53],但仍然较少。机器学习模型在预测时产生的误差主要有 2 个来源^[14, 54–55]: 1) 收集到的部分数据本身存在误差或错误,会对机器学习模型产生误导; 2) 模型训练不足导致欠拟合,或模型复杂度过高、模型训练过度导致过拟合,进而导致模型的泛化能力较差。

独立算法建立的模型普遍较为简单,在面对实验研究和工程实际中所使用的组分复杂的混凝土和庞大的抗渗性能测试数据量时,预测准确度欠佳;相比之下,集成算法在输入参数较多或数据量较大的情况下,预测准确度普遍较高。如图 5 所示的 ANN 算法与诸如人工蜂群算法(ABC)、粒子群优化算法(PSO)、GA 等群体智能化优化算法组合所构成的二元集成算法,预测准确性较 ANN 独立算法有了进一步提升^[56],能够准确预测氯离子快速渗透实验(RCPT)的测试结果。

近年来,随着计算机算力提升,机器学习技术逐渐走向成熟,包含更多输入参数的预测模型得以建立^[57–58],表明机器学习预测模型开始具备更广的适用范围。此外,也有众多学者将新型算法用于建立混凝土抗氯离子渗透性能预测模型,使用的算法包括 GB、GBDT、Gaussian 过程回归(GPR)等,为后续研究提供了更多选择^[38, 59]。

图 5 测试集 RCPT 的预测值与实验值对比^[56]Fig. 5 Comparison between predicted and experimental RCPT of testing data set^[56]

3.2 抗碳化能力预测

除氯离子渗透之外, 碳化同样是导致混凝土性能劣化的原因之一, 也是钢筋混凝土早期性能下降的主要原因之一^[2]。

SVM 和 ANN 是最早应用于预测混凝土碳化深度的机器学习模型。基于固定配合比的预应力混凝土的碳化深度测试数据集, 以预应力水平和碳化时间为主要输入变量, 使用上述 2 种算法对预应力混凝土的碳化深度进行预测, 前者展现出了极高的预测精度, 误差不超过 0.5%^[60]。而在额外引入了环境相对湿度、CO₂ 浓度等因素后, ANN 算法仍然能够准确预测混凝土的碳化深度, 最大误差低于 5 mm^[61]。

基于 DNN 建立的混凝土碳化深度预测模型与日本建筑协会提出的经验公式模型和传统的有限元分析相比, 该模型的预测更为准确^[62]。此外, GBRT 算法也被用于碳化深度的预测, 特征分析表明抗压强度与水胶比对碳化深度的影响最大, 本质原因是这 2 个因素与混凝土的孔隙结构高度相关, 进而影响了混凝土的抗碳化能力^[63]。基于 GP 模型虽然在预测精度上稍逊于 ANN, 但其给出了预测公式, 使预测模型更为直观^[64]。

对比 SVM-ANN 集成算法和 ANN、SVM 2 种独立算法, 集成算法的预测精度更高、通用性更强^[19]; 也有 SVM 与群体优化算法组合的集成算法成功预测了混凝土的碳化深度, 对训练集的 R^2 达到 0.95, 对测试集的 R^2 高达 0.98^[65]。ANN 与群体智能化优化算法构成的集成算法也被用于碳化深度的预测研究中, 并且准确度优于 RF 和 ANN 独立算法^[66]。表 2 总结了近期基于机器学习的耐久性预测研究, 集成算法更能胜任多输入参数的复杂预测, 因此可见, 寻找优质的算法组合可能成为机器学习预测模型的一个研究方向。

还有研究^[67]提出了 1 种名为 CaPrM 的模型, 工

作流程如图 6 所示。该模型包含了 ANN、DT 以及 2 种基于 DT 的集成算法, 选取包含混凝土配合比、新拌混凝土性能、硬化混凝土性能和碳化实验相关的共 25 个参数作为输入变量, 构建碳化深度预测模型。该模型的优势在于可以根据数据集的变化, 从四种算法中自主选择更优的算法提升预测精度。该模型几乎考虑了影响混凝土碳化过程的所有因素, 具备作为混凝土材料抗碳化能力评价工具的潜力。

3.3 抗冻性预测

冰冻破坏是寒冷地区混凝土材料性能劣化的最主要原因之一, 因此对混凝土冰冻破坏机理的研究和抗冻性的预测尤为重要。而混凝土冰冻破坏过程复杂, 传统上用于抗冻性预测的数学理论模型和经验公式局限性较大。由于混凝土抗冻性测试手段、实验流程的不同, 用于模型训练的原始数据仍有较大局限性^[12], 因此机器学习预测混凝土抗冻性的相关研究较少。

如表 2 所示, 以依据 ASTM C666 标准中流程 A 测试得到的再生骨料混凝土冻融循环耐久性因数 (DF) 作为抗冻性评价指标, 选取包含引气类型、再生骨料处理方法等为输入参数, 分别利用 ANN、GPR、MARS 算法建立预测模型, 结果显示 ANN 对 DF 的预测精度最高, 对复杂关系的学习能力更强, 引气与否是影响再生骨料混凝土冻融耐久性的最大因素, 这也与广泛实验中获得的经验结论一致^[68]。

通过递归特征消除 (REF) 从 12 个指标中选取 6 个对混凝土抗冻性影响最为显著的指标作为预测模型的输入参数, 使用 RF 算法预测冻融循环后的混凝土相对动态弹性模量。经过特征选择后的模型预测误差极小, RMSE 仅为 0.077, 模型预测效果显著优于未经特征选择的 SVM、GBDT 等算法建立的模型^[69]。

与独立算法相比, 当输入参数较多时, 集成算法通常展现出更高的预测准确度。例如, 利用广义极限学习机 (GRELM) 算法可以构建二元和三元集成算法, 对硅灰和钢纤维改性的混凝土进行耐磨性和基于抗压强度的冻融循环耐久性 (FT) 的预测。选取包含混凝土配合比、新拌混凝土性能等方面的 9~12 个输入参数, 分别建立耐久性预测模型。三元集成算法的预测准确度始终高于二元算法和独立算法, 最高可以达到 91%, 即使在如图 7 所示的输入参数较多的情况下也能达到 74% 的预测准确度^[70]。

表 2 近期基于机器学习的耐久性预测研究总结

Table 2 Summary of recent research on durability prediction based on machine learning



Durability index	Algorithm	Input	Output	Statistical Index	Dataset size	Training/%	Validation/%	Testing/%	Ref.
Anti-chloride ion penetration	SVM; ELM;	C ₃ A; w/b ratio; cement;	Chloride	R^2 ;	127	70		30	[38]
	KNN; GB;	fly ash; GGBFS; silica	diffusion	RMSE;					
	Light GBM;	fume; aggregate; water;	coefficient	MAE;					
	XGB; RF;	specific surface		MAPE					
	AdB								
	LSSVM-NSGA II	Water-binder ratio; cement; fly ash; slag; fine aggregate; coarse aggregate; compound superplasticizer	Chloride ion permeability coefficient; relative dynamic elastic modulus	R^2 ;	100	80		20	[50]
				RMSE					
Carbonation resistance	GBRT	Weighted density; water absorption of gravel; water absorption of RCA; blast furnace slag; metakaolin; fly ash; cement; silica fume; water; w/b ratio; sand; gravel; exposure time; recycled aggregate; superplasticizer; compressive strength; CO ₂ concentration;	Carbonation depth	R^2 ;	713	70		30	[63]
				RMSE;					
				MAE					
	SVM-PSO;	Cover binder; fly ash; time of exposure; relative humidity;	Carbonation depth	R^2 ;	50	80		20	[65]
	SVM-GWO;	CO ₂ concentration; w/b ratio		MSE;					
	SVM-SOA;			MAE;					
	SVM-CSO			MAPE					
Frost resistance	ANN; GPR;	Water; cement; sand; gravel;	Durability	R^2 ;	142	80		20	[68]
	MARS	RCA; fly ash; RCA replacement ratio; water absorption; RCA treatment method; air-entraining type	factor	RMSE;					
				MAPE					
Resistance to sulfate attack	ANN; SVM;	Cement; water; volume	Durability	R^2 ;	143	80		20	[74]
	DT; GPR;	replacement ratio of RA; RA	factor	RMSE;					
	XGB; RF;	water absorption; initial		MAPE					
	GB; AdB	compressive strength before sulfate attack; type of cation; solution concentration; maturity under a wet state; maturity under a dry state; number of cycles							
Resistance to corrosion of reinforcement	RF; KNN;	Cement; limestone powder;	Corrosion	R^2 ;	80	85		15	[76]
	ANN; SVM	water; coarse aggregate; fine aggregate; exposure time	potential	RMSE					

3.4 抗硫酸盐侵蚀预测

硫酸盐会与水泥水化产物发生化学反应，引起混凝土的膨胀性破坏，导致力学性能下降，影响材料耐久性。

美国垦务局(USBR)提供了标准化的混凝土抗硫酸盐侵蚀性能测试方法 USBR4908。该测试最大的优点在于它可以用来评估混凝土的配合比设计、矿物掺合料、化学外加剂和不同养护条件对混凝土抗硫酸盐侵蚀性能的影响，但其缺点在

于实验周期长达 1~2 a。依据 USBR4908 测试得到的混凝土抗硫酸盐侵蚀性能数据训练的 ANN 算法模型，实现了对 USBR 测试结果的准确预测，成为实验的潜在替代方案，也开创了机器学习预测混凝土抗硫酸盐侵蚀性能的先河^[71]。多项式进化回归算法(EPR)也可实现对在硫酸盐侵蚀下混凝土的质量损失的预测，预测准确性高于 ANN 模型，并选取水泥、粗骨料、细骨料、水、减水剂用量作为机器学习模型的输入参数建立了简化预

图 6 CaPrM 模型工作流程^[67]Fig. 6 Workflow of CaPrM model^[67]图 7 12 参数冻融循环耐久性预测模型对测试集的预测性能^[70]Fig. 7 Performance of the 12 parameter freezing and thawing (F-T) cycle prediction model for the testing data set^[70]

测方程, 实现了对混凝土质量损失的粗略估算^[72]。该模型还可以对混凝土配合比设计进行优化, 提供抗硫酸盐侵蚀性能最佳的混凝土配合比。Sanjukta 等^[73]将粉煤灰分别替代水泥 0%、25%和 40%的混

凝土养护 28、90 d 和 180 d 后, 置于 5%的 Na_2SO_4 溶液中分别浸泡 6、12、15、18 和 24 个月测试抗压强度, 使用这些实验数据训练 ANN 模型并预测硫酸盐侵蚀下的抗压强度损失。实验和预测模型的分析结果表明, 延长养护时间可以增强混凝土的抗硫酸盐侵蚀能力, 延缓强度劣化速度。但受实验数据限制, 该预测模型仅适用于粉煤灰替代比例小于 50%的情况。

最新的研究^[74]对比了 XGB、RF、GB、AdB 4 种集成算法和 ANN、SVM、DT、GPR 4 种独立算法对再生骨料混凝土耐久性因数的预测准确度(如表 2 所示), 该耐久性因数由硫酸盐侵蚀下的抗压强度所决定。上述算法中, 如图 8 所示 XGB 的预测准确度最高, 测试集的预测值与实验值 R^2 达到 0.925; ANN 在独立算法中的预测最为准确, 但仍然差于集成算法。输入变量的特征重要性分析结果表明, 水泥掺量和再生骨料吸水率是影响抗压强度损失的关键因素。

3.5 钢筋锈蚀情况预测

利用机器学习模型对钢筋混凝土中钢筋腐蚀程

度进行预测的研究较少。

通过 ANN 算法,能够对不同强度等级水泥和不同掺量粉煤灰制备的钢筋混凝土,在 4% NaCl 溶液环境下,混凝土中钢筋腐蚀电流的大小及其随时间的变化趋势进行预测和拟合,训练集和测试集的 R^2 分别达到了 0.999 0 和 0.998 8^[75]。

机器学习还可用于预测钢筋的腐蚀电位(如表 2 所示),并据此推测腐蚀起始时间。集成算法 RF 相比于 K 邻近算法(KNN)和 ANN、SVM 等其它独立算法,表现出了更高的预测精度,测试集预测值与实验值的相关系数最高($R^2=0.9867$)^[76]。




图 8 XGB 模型对耐久性因数的预测性能^[74]

Fig. 8 Prediction performance of XGB model for durability factors^[74]

表 3 各耐久性指标的机器学习预测模型算法

Table 3 Algorithm of machine learning prediction model for each durability index

Durability index	Algorithms
Anti-chloride ion penetration	RF-SVM ^[13,29] 、SVM ^[18,38,59] 、ANN ^[18,40,41,42,45-47,49-50,55,57-59] 、GPR ^[18,59] 、RF ^[18,38,59] 、XGB ^[38,52] 、Light GBM ^[38,52] 、GB ^[38] 、KNN ^[38] 、AdB ^[38] 、SVM-PSO ^[43] 、CNN ^[44] 、MLR ^[48,58] 、MGGP ^[49] 、MARS ^[49] 、SVM-NSGA II ^[50] 、RF-NSGA II ^[51] 、ANN-PSO ^[56] 、ANN-ABC ^[56] 、ANN-GA ^[56] 、DT ^[59] 、GBDT ^[59]
Carbonation resistance	SVM ^[16,19,60] 、ELM ^[16] 、ANN ^[19,64,66-67] 、SVM-ANN IV ^[19] 、SVM-ANN-GA ^[19] 、DNN ^[62] 、GBRT ^[63] 、GP ^[64] 、SVM-PSO ^[65] 、SVM-CSO ^[65] 、SVM-GWO ^[65] 、SVM-SOA ^[65] 、ANN-PSO ^[65] 、ANN-WO ^[66] 、ANN-BAS ^[66] 、RF ^[66] 、GPR ^[66] 、DT ^[67]
Frost resistance	GPR ^[12] 、ANN ^[112,68] 、MARS ^[68] 、GRELM ^[70] 、GRELM-PSO ^[70] 、GRELM-GWO ^[70] 、RF-REF ^[71]
Resistance to sulfate attack	ANN ^[71,73-74] 、EPR ^[72] 、RF ^[74] 、GB ^[74] 、XGB ^[74] 、AdB ^[74] 、SVM ^[74] 、DT ^[74] 、GPR ^[74]
Resistance to corrosion of reinforcement	ANN-PSO ^[53] 、ANN ^[75-76] 、SVM ^[76] 、RF ^[76] 、KNN ^[76]

4 结论与展望

1) SVM 算法对小样本量数据集的学习能力较强,ANN 算法则更适合对大样本量的数据集进行分析;基于 ANN 算法的深度学习理论逐渐开始成熟,深度学习模型能够更高效快速地挖掘输出量与输入参数间的相关性。与独立算法相比,集成算法对多参数、大体量的数据集展现出了更强的学习能力,适用范围更广。

2) 利用机器学习技术能够对混凝土材料的耐久性进行准确预测,对配合比复杂的混凝土耐久性预测精度高于传统预测模型。SVM 和 ANN 是最早用于混凝土材料耐久性预测的算法,但因混凝土材料的组成与各耐久性指标之间极为复杂的相关性规律,上述独立算法的预测精度有限,引入智能优化算法或其它独立算法构建的集成算法展现出了更高的预测精度。MLR、MARS 等机器学习算法可用于建立混凝土材料耐久性指标的预测方程,直观地展现各因素对耐久性的影响,且该方程的预测准确性高于传统经验公式。

3) 已有部分学者开始利用机器学习技术,以高耐久性和低成本为目标进行混凝土配合比设计的优化。该方向表现出巨大的发展潜力,基于大数据的机器学习技术可以为学者提供更为准确的混凝土配合比设计,降低实验工作量、减少原料消耗,是一种极具发展前景的混凝土配合比设计及优化工具。

对于机器学习预测混凝土耐久性的未来发展,由于混凝土材料的组成复杂、耐久性评价指标多、同一耐久性指标的测试方法不唯一。人工筛选出具有可比性的数据是利用机器学习技术预测混凝土材料耐久性最为关键的一步,也是较为困难的一步。建立涵盖混凝土配合比、耐久性实验方案及实验结果等数据的完整数据库,是机器学习混凝土材料耐久性预测模型具备普适性并辅助混凝土配合比设计优化的重要基础,也是未来需要突破的关键瓶颈。基于机器学习的混凝土材料耐久性预测方法具有广阔的发展前景,由大数据驱动的机器学习技术也是促进混凝土材料领域摆脱传统试错型实验模式的重大技术革命。

参考文献:

- [1] LIU C, MA Q, LI L L, et al. Artificial intelligence metamaterials[J]. *Acta Opt Sin*, 2021, 41(8): 0823004.
- [2] TAFSESE W Z, SISTONEN E. Machine learning for durability and service-life assessment of reinforced concrete structures: recent advances and future directions[J]. *Autom Constr*, 2017, 77: 1–14.
- [3] 张丽艳, 李洪, 陈树彬, 等. 玻璃的成分和性质的模拟方法[J]. *硅酸盐学报*, 2022, 50(8): 2338–2350.
- ZHANG Liyan, LI Hong, CHEN Shubin, et al. *J Chin Ceram Soc*, 2022, 50(8): 2338–2350.
- [4] 宋庆功, 常斌斌, 董珊珊, 等. 机器学习及其在材料研发中的作用[J]. *材料导报*, 2022, 36(1): 183–189.
- SONG Qinggong, CHANG Binbin, DONG Shanshan, et al. *Mater Rep(in Chinese)*, 2022, 36(1): 183–189.
- [5] GUO S H, AGARWAL M, COOPER C, et al. Machine learning for metal additive manufacturing: towards a physics-informed data-driven paradigm[J]. *J Manuf Syst*, 2022, 62: 145–163.
- [6] 赖根明, 焦君宇, 蒋耀, 等. 机器学习原子势在锂金属负极中的应用[J]. *硅酸盐学报*, 2023, 51(2): 469–475.
- LAI Genming, JIAO Junyu, JIANG Yao, et al. *J Chin Ceram Soc*, 2023, 51(2): 469–475.
- [7] 陈翔, 富忠恒, 高宇辰, 等. 机器学习在锂电池固态电解质研究中的应用[J]. *硅酸盐学报*, 2023, 51(2): 488–498.
- CHEN Xiang, FU Zhongheng, GAO Yuchen, et al. *J Chin Ceram Soc*, 2023, 51(2): 488–498.
- [8] 盛晔, 宁金妍, 杨炯. 机器学习在热电材料领域中的应用[J]. *硅酸盐学报*, 2023, 51(2): 499–509.
- SHENG Ye, NING Jinyan, YANG Jiong. *J Chin Ceram Soc*, 2023, 51(2): 499–509.
- [9] NUNEZ I, MARANI A, FLAH M, et al. Estimating compressive strength of modern concrete mixtures using computational intelligence: A systematic review[J]. *Constr Build Mater*, 2021, 310: 125279.
- [10] LI J Q, WU Z M, SHI C J, et al. Durability of ultra-high performance concrete—A review[J]. *Constr Build Mater*, 2020, 255: 119296.
- [11] 冯德成, 吴刚. 混凝土结构基本性能的可解释机器学习建模方法[J]. *建筑结构学报*, 2022, 43(4): 228–238.
- FENG Decheng, WU Gang. *J Build Struct(in Chinese)*, 2022, 43(4): 228–238.
- [12] ZHAO N, ZHANG A L. The Prediction of Frost-Resisting Durability of Concrete Based on Artificial Neural Network[C]//*Proceedings of International Conference on Engineering and Business Management (EBM2011)*. Scientific Research Publishing, 2011: 1501–1504.
- [13] 李铁军, 胡毅, 刘茜, 等. 基于随机森林的支持向量机混凝土抗渗性预测模型研究[J]. *水电能源科学*, 2021, 39(2): 119–122.
- LI Tiejun, HU Yi, LIU Xi, et al. *Water Resour Power(in Chinese)*, 2021, 39(2): 119–122.
- [14] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 23–248.
- [15] 刘艳彪, 乔建质, 尤世界. 机器学习在碳基环境功能材料领域的应用研究进展[J]. *环境工程*, 2022, 40(6): 182–187.
- LIU Yanbiao, QIAO Jianzhi, YOU Shijie. *Environ Eng(in Chinese)*, 2022, 40(6): 182–187.
- [16] MALAMI S I, ANWAR F H, ABDULRAHMAN S, et al. Implementation of hybrid neuro-fuzzy and self-turning predictive model for the prediction of concrete carbonation depth: a soft computing technique[J]. *Results Eng*, 2021, 10: 100228.
- [17] CHEN B W, JI W, RHO S. Divide-and-conquer signal processing, feature extraction, and machine learning for big data[J]. *Neurocomputing*, 2016, 174: 383.
- [18] CAI R, HAN T H, LIAO W Y, et al. Prediction of surface chloride concentration of marine concrete using ensemble machine learning[J]. *Cem Concr Res*, 2020, 136: 106164.
- [19] CHEN Z Y, LIN J L, SAGOE-CRENTSIL K, et al. Development of hybrid machine learning-based carbonation models with weighting function[J]. *Constr Build Mater*, 2022, 321: 126359.
- [20] 李航. 机器学习方法[M]. 北京: 清华大学出版社, 2022: 3–145.
- [21] 纪守领, 李进锋, 杜天宇, 等. 机器学习模型可解释性方法、应用与安全研究综述[J]. *计算机研究与发展*, 2019, 56(10): 2071–2096.
- JI Shouling, LI Jinfeng, DU Tianyu, et al. *J Comput Res Dev(in Chinese)*, 2019, 56(10): 2071–2096.
- [22] 胡扬, 张胜利, 周文瀚, 等. 基于机器学习探索钙钛矿材料及其应用[J]. *硅酸盐学报*, 2023, 51(2): 452–468.
- HU Yang, ZHANG Shengli, ZHOU Wenhan, et al. *J Chin Ceram Soc*, 2023, 51(2): 452–468.
- [23] AZIM I, YANG J, JAVED M F, et al. Prediction model for compressive arch action capacity of RC frame structures under column removal scenario using gene expression programming[J]. *Structures*, 2020, 25: 212–228.
- [24] GANDOMI A H, ROKE D A. Assessment of artificial neural network and genetic programming as predictive tools[J]. *Adv Eng Softw*, 2015, 88: 63–72.
- [25] GANDOMI A H, BABANAJAD S K, ALAVI A H, et al. Novel approach to strength modeling of concrete under triaxial compression[J]. *J Mater Civ Eng*, 2012, 24(9): 1132–1143.
- [26] KIEWICZ J. The applications of ANNs in certain materials-analysis problems[J]. *J Mater Process Technol*, 2000, 106(1–3): 74–79.
- [27] 郭小强. 基于人工神经网络的混凝土结构抗海水侵蚀性的试验研究[D]. 天津: 天津大学, 2004.
- GUO Xiaoqiang. Experimental research on resistance of concrete structure corroded by seawater based on artificial neural network (in Chinese, dissertation). Tianjin: Tianjin University, 2004.
- [28] 韦世奎. “深度学习研究进展及应用”专题导言[J]. *北京交通大学学报*, 2017, 41(6): 2–3.
- WEI Shikui. *J Beijing Jiaotong Univ*, 2017, 41(6): 2–3.
- [29] 吴贤国, 刘茜, 王洪涛, 等. 基于随机森林和支持向量机的高性能混凝土抗渗性预测研究[J]. *硅酸盐通报*, 2021, 40(3): 829–835.
- WU Xianguo, LIU Xi, WANG Hongtao, et al. *Bull Chin Ceram Soc(in Chinese)*, 2021, 40(3): 829–835.
- [30] HARIRI-ARDEBILI M A, POURKAMALI-ANARAKI F. Support

- vector machine based reliability analysis of concrete dams[J]. *Soil Dyn Earthq Eng*, 2018, 104: 276–295.
- [31] EL ASRI Y, BENAICHA M, ZAHER M, et al. Prediction of plastic viscosity and yield stress of self-compacting concrete using machine learning technics[J]. *Mater Today Proc*, 2022, 59: A7–A13.
- [32] AHMAD A, FAROOQ F, NIEWIADOMSKI P, et al. Prediction of compressive strength of fly ash based concrete using individual and ensemble algorithm[J]. *Materials (Basel)*, 2021, 14(4): 794.
- [33] 张超慧. 超高性能混凝土精细化模拟及其力学行为分析[D]. 长沙: 湖南大学, 2021.
- ZHANG Chaohui. Elaborate simulations and analysis of mechanical behavior of ultra high performance concrete(in Chinese, dissertation). Changsha: Hunan University, 2021.
- [34] 董晓健. 基因表达式编程集成算法研究[D]. 武汉: 武汉大学, 2011.
- DONG Xiaojian. Research on gene expression programming ensembles algorithm(in Chinese, dissertation). Wuhan: Wuhan University, 2011.
- [35] IQBAL M F, JAVED M F, RAUF M, et al. Sustainable utilization of foundry waste: forecasting mechanical properties of foundry sand based concrete using multi-expression programming[J]. *Sci Total Environ*, 2021, 780: 146524.
- [36] IQBAL M F, LIU Q F, AZIM I, et al. Prediction of mechanical properties of green concrete incorporating waste foundry sand based on gene expression programming[J]. *J Hazard Mater*, 2020, 384: 121322.
- [37] ASHRAF M, IQBAL M F, RAUF M, et al. Developing a sustainable concrete incorporating bentonite clay and silica fume: mechanical and durability performance[J]. *J Clean Prod*, 2022, 337: 130315.
- [38] VAN QUAN TRAN. Machine learning approach for investigating chloride diffusion coefficient of concrete containing supplementary cementitious materials[J]. *Constr Build Mater*, 2022, 328: 127103.
- [39] GOMAA E, HAN T H, ELGAWADY M, et al. Machine learning to predict properties of fresh and hardened alkali-activated concrete[J]. *Cem Concr Compos*, 2021, 115: 103863.
- [40] HODHOD O A, AHMED H I. Developing an artificial neural network model to evaluate chloride diffusivity in high performance concrete[J]. *HBRC J*, 2013, 9(1): 15–21.
- [41] PARICHATPRECHA R, NIMITYONGSKUL P. Analysis of durability of high performance concrete using artificial neural networks[J]. *Constr Build Mater*, 2009, 23(2): 910–917.
- [42] SONG H W, KWON S J. Evaluation of chloride penetration in high performance concrete using neural network algorithm and micro pore structure[J]. *Cem Concr Res*, 2009, 39(9): 814–824.
- [43] SAFARZADEGAN GILAN S, BAHRAMI JOVEIN H, RAMEZANIANPOUR A A. Hybrid support vector regression–Particle swarm optimization for prediction of compressive strength and RCPT of concretes containing metakaolin[J]. *Constr Build Mater*, 2012, 34: 321–329.
- [44] 周双喜, 盛伟, 何顺爱. 基于深度学习的氯盐环境下高性能混凝土氯离子扩散系数的预测[J]. *混凝土*, 2019(7): 27–31.
- ZHOU Shuangxi, SHENG Wei, HE Shun'ai Concrete(in Chinese), 2019(7): 27–31
- [45] KHAN M I. Predicting properties of High Performance Concrete containing composite cementitious materials using Artificial Neural Networks[J]. *Autom Constr*, 2012, 22: 516–524.
- [46] MOHAMED O, KEWALRAMANI M, ATI M, et al. Application of ANN for prediction of chloride penetration resistance and concrete compressive strength[J]. *Materialia*, 2021, 17: 101123.
- [47] GHAFoori N, NAJIMI M, SOBhani J, et al. Predicting rapid chloride permeability of self-consolidating concrete: A comparative study on statistical and neural network models[J]. *Constr Build Mater*, 2013, 44: 381–390
- [48] NEVES R, SILVA A, DE BRITO J, et al. Statistical modelling of the resistance to chloride penetration in concrete with recycled aggregates[J]. *Constr Build Mater*, 2018, 182: 550–560.
- [49] HOANG N D, CHEN C T, LIAO K W. Prediction of chloride diffusion in cement mortar using multi-gene genetic programming and multivariate adaptive regression splines[J]. *Measurement*, 2017, 112: 141–149.
- [50] CHEN H Y, DENG T T, DU T, et al. An RF and LSSVM–NSGA-II method for the multi-objective optimization of high-performance concrete durability[J]. *Cem Concr Compos*, 2022, 129: 104446.
- [51] 吴贤国, 陈彬, 杨赛, 等. 基于RF-NSGA-II算法的高耐久性混凝土配合比优化研究[J]. *工业建筑*, 2021, 51(7): 156–161.
- WU Xianguo, CHEN Bin, YANG Sai, et al. *Ind Constr(in Chinese)*, 2021, 51(7): 156–161.
- [52] ABDULALIM ALABDULLAH A, IQBAL M, ZAHID M, et al. Prediction of rapid chloride penetration resistance of metakaolin based high strength concrete using light GBM and XGBoost models by incorporating SHAP analysis[J]. *Constr Build Mater*, 2022, 345: 128296.
- [53] HENDI A L, BEHRAMAN A, MOSTOFINEJAD D, et al. A step towards green concrete: effect of waste silica powder usage under HCl attack[J]. *J Clean Prod*, 2018, 188: 278–289.
- [54] 刘悦, 邹欣欣, 杨正伟, 等. 材料领域知识嵌入的机器学习[J]. *硅酸盐学报*, 2022, 50(3): 863–876.
- LIU Yue, ZOU Xinxin, YANG Zhengwei, et al. *J Chin Ceram Soc*, 2022, 50(3): 863–876.
- [55] JIN L B, DONG T Y, FAN T, et al. Prediction of the chloride diffusivity of recycled aggregate concrete using artificial neural network[J]. *Mater Today Commun*, 2022, 32: 104137.
- [56] NAJIMI M, GHAFoori N, NIKOO M. Modeling chloride penetration in self-consolidating concrete using artificial neural network combined with artificial bee colony algorithm[J]. *J Build Eng*, 2019, 22: 216–226.
- [57] LIU Q F, IQBAL M F, YANG J, et al. Prediction of chloride diffusivity in concrete using artificial neural network: modelling and performance evaluation[J]. *Constr Build Mater*, 2021, 268: 121082.
- [58] AL-SWAIDANI A M, KHWIES W T, AL-BALY M, et al. Development of multiple linear regression, artificial neural networks and fuzzy logic models to predict the efficiency factor and durability

- indicator of nano natural pozzolana as cement additive[J]. *J Build Eng*, 2022, 52: 104475.
- [59] LIU K H, ZHENG J K, PACHECO-TORGAL F, et al. Innovative modeling framework of chloride resistance of recycled aggregate concrete using ensemble-machine-learning methods[J]. *Constr Build Mater*, 2022, 337: 127613.
- [60] 郝文峰, 顾建祖, 汤灿. 应用小波支持向量机的预应力混凝土碳化深度研究[J]. *工业建筑*, 2009, 39(增刊1): 931–934.
- HAO Wenfeng, GU Jianzu, TANG Can. Ind Constr(in Chinese), 2009, 39(Suppl 1): 931–934.
- [61] FELIX E F, CARRAZEDO R, POSSAN E. Carbonation model for fly ash concrete based on artificial neural network: development and parametric analysis[J]. *Constr Build Mater*, 2021, 266: 121050.
- [62] LEE H, LEE H S, SURANENI P. Evaluation of carbonation progress using AIJ model, FEM analysis, and machine learning algorithms[J]. *Constr Build Mater*, 2020, 259: 119703.
- [63] NUNEZ I, NEHDI M L. Machine learning prediction of carbonation depth in recycled aggregate concrete incorporating SCMs[J]. *Constr Build Mater*, 2021, 287: 123027.
- [64] LONDHE S N, KULKARNI P S, DIXIT P R, et al. Predicting carbonation coefficient using Artificial neural networks and genetic programming[J]. *J Build Eng*, 2021, 39: 102258.
- [65] BISWAS R, LI E M, ZHANG N, et al. Development of hybrid models using metaheuristic optimization techniques to predict the carbonation depth of fly ash concrete[J]. *Constr Build Mater*, 2022, 346: 128483.
- [66] LIU K H, ALAM M S, ZHU J, et al. Prediction of carbonation depth for recycled aggregate concrete using ANN hybridized with swarm intelligence algorithms[J]. *Constr Build Mater*, 2021, 301: 124382.
- [67] TAFSESE W Z, SISTONEN E, PUTTONEN J. CaPrM: Carbonation prediction model for reinforced concrete using machine learning methods[J]. *Constr Build Mater*, 2015, 100: 70–82.
- [68] LIU K H, ZOU C Y, ZHANG X C, et al. Innovative prediction models for the frost durability of recycled aggregate concrete using soft computing methods[J]. *J Build Eng*, 2021, 34: 101822.
- [69] WU X G, ZHENG S Y, FENG Z B, et al. Prediction of the frost resistance of high-performance concrete based on RF-REF: a hybrid prediction approach[J]. *Constr Build Mater*, 2022, 333: 127132.
- [70] CEMALGIL S, GÜL E, ONAT O, et al. A novel prediction model for durability properties of concrete modified with steel fiber and Silica Fume by using Hybridized GRELM[J]. *Constr Build Mater*, 2022, 341: 127856.
- [71] HODHOD O, SALAMA G A. Analysis of sulfate resistance in concrete based on artificial neural networks and USBR4908-modeling[J]. *Ain Shams Eng J*, 2013, 4(4): 651–660.
- [72] ALANI A M, FARAMARZI A. An evolutionary approach to modelling concrete degradation due to sulphuric acid attack[J]. *Appl Soft Comput*, 2014, 24: 985–993.
- [73] SAHOO S, MAHAPATRA T R. ANN Modeling to study strength loss of Fly Ash Concrete against Long term Sulphate Attack[J]. *Mater Today Proc*, 2018, 5(11): 24595–24604.
- [74] LIU K H, DAI Z H, ZHANG R B, et al. Prediction of the sulfate resistance for recycled aggregate concrete based on ensemble learning algorithms[J]. *Constr Build Mater*, 2022, 317: 125917.
- [75] TOPÇU İ B, BOĞA A R, HOCAOĞLU F O. Modeling corrosion currents of reinforced concrete using ANN[J]. *Autom Constr*, 2009, 18(2): 145–152.
- [76] SALAMI B A, RAHMAN S M, OYEHAN T A, et al. Ensemble machine learning model for corrosion initiation time estimation of embedded steel reinforced self-compacting concrete[J]. *Measurement*, 2020, 165: 108141.