

基于机器学习的桥梁混凝土自然碳化深度预测

唐朝阳¹, 邱俊峰², 周星舒³, 陈峰¹, 卓卫东³(1. 福建省公路事业发展中心 福建 福州 350001; 2. 福建省交通规划设计院有限公司 福建 福州 350004; 3. 福州大学
土木工程学院 福建 福州 350108)

摘要: 为实现一般大气环境下在役桥梁混凝土自然碳化深度的快速准确预测, 首先建立包含 496 组实测样本的桥梁混凝土自然碳化数据集, 采用人工神经网络(ANN)、支持向量机(SVM)和随机森林(RF)算法, 筛选优化特征组合。在此基础上, 分别采用回归树以及 Bagging、RF、XGBoost 和梯度提升回归树(GBRT) 4 种树基集成学习算法, 构建桥梁混凝土自然碳化深度预测模型, 并采用可解释性机器学习方法对特征影响进行量化分析。结果表明: 国内现行相关标准的半经验半理论模型对桥梁混凝土自然碳化深度的预测结果具有很大的离散性, 而基于 GBRT 算法建立的预测模型性能优异, 预测值与实测值之比的平均值为 1.06, 变异系数为 0.25。通过 SHAP 分析发现, 混凝土抗压强度和龄期是影响桥梁混凝土自然碳化的最重要参数, 且分别与碳化深度呈负相关和正相关关系; 桥址环境的 CO₂ 浓度和年平均温度亦有较大影响, 且两者均与碳化深度呈正相关; 其它参数的影响均较小。

关键词: 桥梁工程; 预测模型; 集成学习; 自然碳化; 一般大气环境

中图分类号: U444

文献标识码: A

Machine Learning-Based Prediction of Natural Carbonation Depth of Bridge Concrete

TANG Chaoyang¹, QIU Junfeng², ZHOU Xingyu³, CHEN Feng¹, ZHUO Weidong³

(1. Fujian Provincial Highway Development Center, Fuzhou, Fujian 350018, China; 2. Fujian Communications planning & design institute Co., LTD, Fuzhou, Fujian 350004, China; 3. College of Civil Engineering, Fuzhou University, Fuzhou, Fujian 350108, China)

Abstract: To achieve rapid and accurate prediction of the natural carbonation depth of in-service bridge concrete under ordinary atmospheric environments, a dataset consisting of 496 groups of field-measured concrete carbonation samples from bridges was first established. Artificial Neural Network (ANN), Support Vector Machine (SVM) and Random Forest (RF) algorithms were adopted to select optimal parameters. On this basis, regression trees and four tree-based ensemble learning (EL) algorithms including Bagging, RF, XGBoost and Gradient Boosting Regression Tree (GBRT) were separately adopted to develop prediction models for the natural carbonation depth (NCD) of bridge concrete, and interpretable machine learning methods were applied to quantitatively analyze the influence of each parameter. The results show that: the semi-empirical semi-theoretical model specified in relevant current Chinese standard produces highly scattered predictions for NCD of bridge concrete, while the EL model built with GBRT algorithm achieves outstanding performance, with an average ratio of predicted values to measured values of 1.06 and a coefficient of variation of 0.25. SHAP analysis reveals that concrete compressive strength and service age are the two most critical parameters affecting the natural carbonation of bridge concrete, which are negatively and positively correlated with NCD, respectively. The CO₂ concentration and annual average ambient temperature at the bridge site also exert considerable positive impacts on NCD, while the remaining parameters have relatively minor effects.

Key words: bridge engineering; prediction model; ensemble learning; natural carbonation; ordinary atmospheric environment

混凝土桥梁在长期服役过程中, 空气中的 CO₂ 会扩散至混凝土中, 与混凝土内部的碱性物质发生物理化学反应, 使混凝土碱性降低, 此过程称为混凝土碳化^[1]。混凝土碳化导致的钢筋锈蚀是混凝土桥梁结构最普遍的影响耐久性的问题之一^[2]。

一般大气环境下混凝土自然碳化的预测模型, 对于混凝土桥梁的耐久性设计、在役混凝土桥梁养护及

耐久性能评估, 都有重要的指导作用^[2]。目前已建立多种预测混凝土碳化深度的确定性模型, 主要分为理论模型、经验模型和半经验半理论模型三类^[3]。然而, 由于在役混凝土桥梁的材料性能、环境条件等都存在较大不确定性, 且影响混凝土自然碳化的各因素之间存在复杂的耦合关系, 既有确定性模型难以准确评估其自然碳化深度。为此, 一些研究者考虑材料及环境的变异性, 提出预测混凝土碳化深度的随机模型^[4-6]。虽然随机模型在理论上具有优势, 然而由于其参数标定及模型计算复杂, 导致其实用性不佳。近年来, 机器学习 (ML) 技术的兴起为混凝土碳化预测提供了新的强大工具。早期研究多采用单一的机器学习算法建立混凝土碳化深度预测模型, 如吴贤国等^[7]采用随机森林 (RF) 算法, 初步构建了预测混凝土早期碳化深度的 RF 模型; Hosseinnia 等^[8]采用多基因遗传编程 (MGGP) 构建预测模型, 并利用 MGGP 生成可直接计算碳化深度的显式公式, 很具特色。近年来, 一些研究者探讨集成多种机器学习算法的混合模型, 如 Chen 等^[9]探讨了结合人工神经网络 (ANN) 与支持向量机 (SVM) 的混合模型的性能, 发现混合模型对粉煤灰混凝土碳化深度的整体预测性能优于单一 ANN 和 SVM 模型; Huang 等^[10]发现集成壮丽细尾鹌鹑优化算法 (SFOA)、鲸鱼迁徙优化算法 (WMA)、核极限学习机 (KELM) 与核密度估计 (KDE) 的混合模型, 对粉煤灰混凝土碳化深度预测的整体性能最优; Chen 等^[11]探讨了结合自然梯度提升算法 (NGBoost) 与仿生优化算法的混合模型, 研究发现, 结合 NGBoost 与小龙虾优化算法 (COA) 的混合模型, 对碱激发矿渣混凝土碳化深度预测结果最优。由于影响混凝土碳化的因素众多, 且存在复杂的耦合关系, 故输入参数优化选择对 ML 模型十分重要。Chen 等^[9]采用灰色关联分析筛选了混合模型的输入参数; Duan 和 Cao^[12]基于统计学方法筛选输入参数, 发现 5 个输入参数即可逼近全参数模型的预测效果; Ehsani 等^[13]分别采用传统 ReliefF 特征选择算法和结合 ANN 的多目标进化 (MOEA/D-ANN) 算法, 探讨了输入参数选择问题, 结果表明, MOEA/D-ANN 算法能够有效筛选最优关键变量, 显著提升了 ML 模型的预测性能。上述研究都基于混凝土加速碳化试验数据, Duan 等^[14]从国内公开文献中收集了 448 组桥梁混凝土碳化实测数据, 分别采用 RF、SVM、K-近邻 (KNN) 和 XGBoost 算法, 构建桥梁混凝土自然碳化预测模型, 结果表明, 使用径向基核函数的 SVM 模型的精度和召回率最高, 分别达 91% 和 86%。Majlesi 等^[15]基于伊比利亚-美洲国家自然暴露站实测数据构建 ANN 模型, 实现了最长达 10 年龄期的混凝土自然碳化深度预测。Chan 等^[16]构建了一个包含 8194 个样本的混凝土自然碳化数据集, 并基于数据驱动评估了树基 ML 模型对碳化速率的预测性能, 发现 CatBoost 模型预测效果最优。

公路混凝土桥梁的设计使用年限一般为 50 年或 100 年^[17], 实际使用寿命更长, 因此, 龄期和环境因素对桥梁混凝土自然碳化深度都有重要影响。然而, 既有 ML 模型大都采用混凝土室内加速碳化或短期自然暴露试验数据, 无法准确考虑在役混凝土桥梁的龄期和环境因素; 此外, 大部分 ML 模型本质上属于“黑箱”, 可解释性较差。针对此问题, 本文利用 142 座不同龄期的在役混凝土桥梁现场耐久性检测数据, 以及公开文献中筛选的 354 组桥梁混凝土自然碳化实测数据, 构建一般大气环境下桥梁混凝土自然碳化数据集; 选择关键材料和环境条件参数, 采用精度高、泛化能力强的树基集成学习算法, 构建桥梁混凝土自然碳化深度预测模型, 并引入 SHAP 对预测模型进行了解释。本研究为在役混凝土桥梁自然碳化深度预测提供了一种可行的智能化方法, 预测结果可供在役混凝土桥梁养护及耐久性能评估参考。

1 算法基本原理与预测模型构建流程

1.1 GBRT 算法基本原理

集成学习 (EL) 通过构建并结合多个弱学习器 (基学习器) 来完成训练任务, 常可获得比单一学习器显著优越的模型泛化性能和稳定性^[18]。本文分别使用 Bagging、RF、XGBoost 和梯度提升回归树 (GBRT) 4 种集成学习算法构建预测模型, 并与单一的回归树 (RT) 模型进行对比。这 4 种集成学习算法均为基于回归树的同质的集成学习算法, 即基学习器都是回归树。考虑到本文的主要研究内容, 这里仅对 GBRT 算法的基本原理进行简要介绍。

假设桥梁混凝土自然碳化深度的预测模型在数学上可视为一个复杂的非线性映射函数 $y=F(X)$, 其中,

$X=(x_1, x_2, \dots, x_p)^T$ 为 p 个输入参数组成的随机特征向量 (考虑 p 个影响因素); y 为目标变量 (桥梁混凝土自然碳化深度)。对于给定的训练数据集 D , 采用 GBRT 算法构建预测模型的核心目标是构造估计函数 $\hat{F}(X)$, 以逼近真实的非线性映射函数 $y=F(X)$, 该估计函数需使得指定损失函数 L 在全体训练数据集 D 联合分布下的数学期望达到最小^[19], 即满足下式

$$\hat{F}(X) = \arg \min_F E_{y,X} L(y, \hat{F}(X)) = \arg \min_F E_X [E_y (L(y, \hat{F}(X))) | X] \quad (1)$$

式中: $L=L(y, \hat{F}(X))$ 为损失函数。

由于上述映射函数 $y=F(X)$ 未知, 故在 GBRT 算法中以 CART 回归树^[20]作为基学习器对 y 进行预测 (即构建 RT 模型), 并采用加法模型 (additive model) 得到最终模型的预测结果, 其数学表达式如下

$$\hat{F}(X) = \sum_{m=1}^M \beta_m h_m(X; a_m) \quad (2)$$

式中: β_m 为加权系数; M 为指定的基学习器数量; $h_m(X; a_m)$ 为第 m 颗回归树函数; a_m 为回归树参数, 包括单棵树的分裂变量、分裂点以及叶子节点均值。

采用 GBRT 算法建立预测模型的流程可参见文献[19], 其基本思想是采用 CART 回归树^[20]作为基学习器, 将损失函数的负梯度作为当前模型残差的近似值, 并采用前向分步算法, 顺序引入新的基学习器拟合残差, 使得每个基学习器加入到前序模型后损失函数最小化; 将所有基学习器的预测值进行线性组合得到最终模型的预测结果。因此, GBRT 算法本质上是前向分步算法、梯度下降优化与加法模型的结合体。

1.2 预测模型构建流程

图 1 为本文构建桥梁混凝土自然碳化深度预测模型的流程图, 其主要步骤如下:

1) 构建桥梁混凝土自然碳化数据集, 将数据集按 80% 和 20% 的比例随机划分为训练集和测试集。对于桥梁混凝土自然碳化深度预测, 某些特征原始数据的取值范围可能具有重要意义, 例如龄期 t 、混凝土抗压强度 f_{cu} 等, 若对这些特征进行归一化, 可能会丢失这些信息。本文采用回归树和基于树的 EL 算法, 可以保留特征的原始含义, 无需对原始数据进行标准化、归一化处理^[18]。

2) 筛选优化特征组合作为输入变量, 分别采用回归树以及 Bagging、RF、XGBoost 和 GBRT 等 4 种树基 EL 算法, 结合 5 折交叉验证方法进行训练。

3) 使用训练后的预测模型对未参与训练的测试集数据进行预测, 采用常规的决定系数 (R^2)、均方根误差 (RMSE)、平均绝对误差 (MAE) 作为性能指标, 对预测模型进行性能评估。为确定综合性能优越的模型, 引入如下的综合评价指标 G_1

$$G_1 = \frac{MAE + RMSE}{R^2} \quad (3)$$

式中: MAE 和 $RMSE$ 分别为平均绝对误差和均方根误差; R^2 为决定系数。可见, G_1 越小, 模型的综合性能越佳。

4) 通过随机搜索选择最优的损失函数、学习率和树的数量等超参数, 使所选模型性能达到最优。

5) 在得到最优模型后, 使用 SHAP 方法对模型进行解释。




图 1 预测模型构建流程

Fig.1 Flowchart of Prediction Model

2 数据集构建与优化特征组合

2.1 桥梁混凝土自然碳化数据集

目前,混凝土碳化数据大部分来自室内加速碳化试验或室外短期的自然暴露试验,无法准确考虑桥梁所在环境及龄期等因素。本文依托福建省普通公路桥梁耐久性调查项目,对福建东南沿海地区 5 个地级市、18 个县市具有不同龄期的 142 座在役中、小跨径公路混凝土桥梁,开展了为期半年多的资料调查,获得 142 组一般大气环境下桥梁混凝土自然碳化数据^[21]。同时,利用 Duan 等^[14]建立的国内东部区域一般大气环境下桥梁混凝土自然碳化数据集,从中筛选 354 组数据,构建了包含 496 组数据的桥梁混凝土自然碳化数据集。表 1 列出了本文构建的数据集的主要参数及范围(具体样本数据详见文献^[21]和文献^[14]),可以看出,主要影响因素包括桥梁龄期(碳化时间 t)、材料参数(混凝土立方体抗压强度 f_{cu})、桥址环境条件参数(包括气候类型、 CO_2 浓度、雨水 pH、年平均温度 T 和相对湿度 RH)以及检测位置,参数范围覆盖了我国东部区域在役公路混凝土桥梁的常规运营场景。需要指出的是,本文材料参数仅考虑 f_{cu} ,主要是因为该参数是在役混凝土桥梁易于测得的,且国内现行《既有混凝土结构耐久性评定标准》^[22]的相关计算模型中,材料参数也仅考虑 f_{cu} 。此外, CO_2 浓度系结合不同时段多次实测数据以及中国气象数据网数据,按桥梁龄期取年平均值得到;雨水 pH、温度和相对湿度均利用中国气象数据网数据和当地气象资料,按桥梁龄期取年平均值得到。

表 1 主要参数及范围

Tab.1 Main parameters and ranges

T/y	f_{cu}/MPa	气候类型	CO_2 浓度/%	雨水 pH	$T/^\circ C$	$RH/\%$	检测位置	碳化深度/mm
(0~60]	[10~60]	中温带、亚热带、暖温带、温暖带、热带	[0.037~0.052]	[4~6]	[4~26]	[51~86]	拱圈、梁、桥墩、桥台	[0.2~20.25]

2.2 优化特征组合

影响桥梁混凝土自然碳化的因素众多,且存在复杂的耦合关系。选择最重要的特征,避免使用过多不相关或冗余的特征,对防止构建的 ML 模型过拟合,提高预测精度十分关键。综合分析相关研究^[2-4,12]和国内相关标准^[22]发现,一般大气环境下,材料参数 f_{cu} 、龄期 t 和 CO_2 浓度是影响桥梁混凝土自然碳化的主要因素;年平均温度 T 、雨水 pH 和相对湿度 RH 均对自然碳化深度有一定影响,而检测位置和气候类型的影响相对较小。为探讨最优特征组合,本文选取如表 2 所列的 6 种特征组合,基于所建立的桥梁混凝土自然碳化数据集,分别采用 3 种代表性的机器学习算法(ANN、SVM 和 RF 算法),对 6 种组合分别进行建

模，并采用式（3）定义的综合评价指标 G_1 确定最优特征组合。

为使上述 3 种算法能处理非数值特征（如检测位置和气候类型），采用独热编码（One-Hot Encoding）将表 2 中的非数值特征转换为数值型特征，如表 3 所列。图 2 给出了特征组合的检验结果，可以看出，特征组合对模型性能有明显影响；对所有的特征组合，RF 模型的综合性能均优于 ANN 模型和 SVM 模型。其中，采用 Z3 组合的 RF 模型的 G_1 最小，故本文选取表 2 中的 Z3 组合作为优化的特征组合。

表 2 桥梁混凝土自然碳化特征组合

Tab.2 Feature Combinations of natural carbonation of bridge concrete

组合编号	特征组合
Z1	抗压强度 f_{cu} 、龄期 t 、 CO_2 浓度
Z2	抗压强度 f_{cu} 、龄期 t 、 CO_2 浓度、环境温度 T
Z3	抗压强度 f_{cu} 、龄期 t 、 CO_2 浓度、环境温度 T 、雨水 pH
Z4	抗压强度 f_{cu} 、龄期 t 、 CO_2 浓度、环境温度 T 、雨水 pH、相对湿度 RH
Z5	抗压强度 f_{cu} 、龄期 t 、 CO_2 浓度、环境温度 T 、雨水 pH、相对湿度 RH 、检测位置
Z6	抗压强度 f_{cu} 、龄期 t 、 CO_2 浓度、环境温度 T 、雨水 pH、相对湿度 RH 、检测位置、气候类型

表 3 非数值特征的 one-hot 编码

Tab.3 One-hot encoding for categorical features

检测位置	编码	气候类型	编码
拱圈	1000	中温带	10000
梁	0100	亚热带	01000
桥墩	0010	暖温带	00100
桥台	0001	温暖带	00010
		热带	00001




图 2 特征组合检验结果

Fig.2 Test results of feature combinations

3 预测模型与讨论

3.1 模型性能评估

以材料参数 f_{cu} 、碳化时间 t （龄期）以及桥址环境的 CO_2 浓度、年平均温度 T 和雨水 pH 作为输入变量（表 2 中的 Z3 组合），以桥梁混凝土自然碳化深度作为目标变量，采用 Python 的 scikit-learn 库，构建了基于回归树以及 Bagging、RF、XGBoost 和 GBRT 算法的 5 种机器学习预测模型。表 4 给出了 5 种机器学习预测模型之性能对比，可以看出，RT 模型对测试集的 R^2 仅为 0.71，且 G_1 值最大，说明单一的 RT 模型性能最弱；4 种树基 EL 模型对训练集和测试集的 R^2 平均值分别为 0.94 和 0.91，表明树基 EL 模型均具有较好的预测结果。对比分析显示，4 种树基 EL 模型中，GBRT 模型在训练集和测试集上的各项性能指标

均为最佳， G_1 值最小；RF 模型的性能指标次优，而 Baggin 模型的性能指标相对较弱。

表 4 预测模型性能对比

Tab.4 Performance comparison of prediction models

预测模型	对训练集的性能指标				对测试集的性能指标			
	RMSE/mm	MAE/mm	R^2	G_1 /mm	RMSE/mm	MAE/mm	R^2	G_1 /mm
RT	2.34	1.43	0.82	4.60	2.60	1.79	0.71	6.18
RF	1.10	0.71	0.96	1.89	1.56	1.03	0.93	2.78
Bagging	1.90	1.17	0.88	3.49	2.00	1.43	0.88	3.90
XGBoost	1.45	0.94	0.93	2.57	1.75	1.19	0.87	3.38
GBRT	0.72	0.58	0.97	1.34	0.83	0.64	0.96	1.53

3.2 超参数调优


以 GBRT 模型为优化对象，利用 scikit-learn 提供的 RandomizedSearchCV 进行随机采样和 5 折交叉验证，确定最优的损失函数、学习率和树的数量等超参数，以最大化模型的性能，从而得到了最优参数，如表 5 所列。

表 5 最优模型参数取值


Tab.5 Parameter values of the optimal model

最优模型	参数	取值
GBRT	决策树最大深度	38
	叶子节点的最小样本数	8
	内部节点分裂所需的最小样本数	49
	回归树数量	154
	损失函数	最小二乘损失
	学习率	0.2
	最大功能数	log

图 3 给出了最优 GBRT 模型对训练集和测试集的预测结果，可以看出，最优 GBRT 模型对训练集和测试集各样本碳化深度的预测值与实测值之间的 R^2 分别为 0.97 和 0.96，RMSE 分别为 0.72 mm 和 0.83 mm，MAE 分别为 0.58 mm 和 0.64 mm。这些性能指标表明，最优 GBRT 模型对训练集和和测试集均有很好的预测结果，并具有良好的泛化能力。



(a) 对训练集的预测结果



(b) 对测试集的预测结果

图 3 最优 GBRT 模型预测结果

Fig.3 Prediction results of the optimal GBRT model

作为对比，按国内现行《既有混凝土结构耐久性评定标准》^[22]的相关计算模型，基于本文所构建的数据集，计算得到了各样本对应的桥梁混凝土自然碳化深度。图 4 给出了规范公式计算值与实测值的比较，

可以看出,其各项性能指标均较差,计算值与实测值之间的 R^2 、 $RMSE$ 和 MAE 分别为 0.22、4.22 mm 和 3.07 mm; 统计分析表明,尽管规范公式计算值与实测值之比的平均值 μ 为 1.13,较为接近,但变异系数 C_v 达到了 109%,表明两者之间的离散性很大。这说明现行标准的半经验半理论模型对于桥梁混凝土自然碳化深度的预测效果并不佳。




图 4 规范模型预测结果

Fig.4 Prediction results of the standard model

表 6 列出了最优 GBRT 模型与规范模型对全部样本数据进行预测的各项性能指标对比,可以看出,最优 GBRT 模型的各项性能指标全部占优,其预测值与实测值之比的平均值为 1.06,变异系数仅为 0.25,表明最优 GBRT 模型可用于桥梁混凝土自然碳化深度的快速准确预测。

表 6 最优 GBRT 模型与规范模型性能指标比较

Tab.6 Comparison of performance indicators between the optimal GBRT model and the standard model

模型	R^2	$RMSE/mm$	MAE/mm	μ	C_v
最优 GBRT 模型	0.97	0.74	0.59	1.06	25%
规范模型	0.22	4.22	3.07	1.13	109%

3.3 特征重要性分析

为了从全局角度分析各特征对桥梁混凝土自然碳化深度的影响程度,进而对模型进行解释,利用 Python 的 SHAP 库,计算了最优 GBRT 模型中每个特征的平均绝对 SHAP 值。图 5 显示基于平均绝对 SHAP 值的特征全局重要性,可以看出,混凝土抗压强度 f_{cu} 和龄期 t 是影响桥梁混凝土自然碳化深度的两个最重要参数,其全局平均绝对 SHAP 值分别为 2.14 和 1.21;桥址环境的 CO_2 浓度和年平均温度 T 是两个次重要参数,其全局平均绝对 SHAP 值分别为 0.87 和 0.62;而雨水 PH 的影响相对最小,其全局平均绝对 SHAP 值仅为 0.24。

图 6 为基于 SHAP 的特征蜂群图,可以看出,混凝土抗压强度 f_{cu} 是最为显著的影响参数,且 f_{cu} 与碳化深度呈负相关, f_{cu} 越大,碳化深度越小;此外,龄期 t 、桥址环境的 CO_2 浓度和年平均温度 T 也均对桥梁混凝土自然碳化深度有重要影响,且三者均与碳化深度呈正相关, t 越大,碳化深度越大;桥址环境的 CO_2 浓度或 T 越高,碳化深度也越大;雨水 pH 对桥梁混凝土自然碳化深度的影响相对较小。




图 5 特征重要性排序

Fig.5 Ranking of feature importance




图 6 基于 SHAP 的特征蜂群图

Fig.6 SHAP-based feature beeswarm plot

综上所述可见,提高混凝土抗压强度 f_{cu} 是延缓桥梁混凝土自然碳化的最有效措施;而对服役龄期 t 较长、或处于较高的 CO_2 浓度和温度环境的混凝土桥梁,则需采取有效的抗碳化措施。从碳化机理分析,当桥梁混凝土抗压强度 f_{cu} 较高时,其内部的氢氧化钙等碱性物质含量较多,因此能够更有效地抵抗 CO_2 侵蚀,减缓碳化速率;而随着龄期 t 的增长,混凝土内部的氢氧化钙等碱性物质将逐渐与 CO_2 反应,故导致碳化深度增加;较高的 CO_2 浓度和环境温度可加速混凝土中水分蒸发以及 CO_2 的溶解和扩散,从而加剧混凝土的碳化速率。一般认为,当雨水的pH值约小于5.6时,酸性雨水可能会加速混凝土表面自然碳化,但其影响程度受到多种因素的耦合作用,故影响相对较小。

4 结论

本文采用回归树和4种树基集成学习算法预测一般大气环境下桥梁混凝土自然碳化深度,并采用SHAP方法解释机器学习预测结果。主要结论如下:

- 1) 国内现行相关标准的半经验半理论模型对桥梁混凝土自然碳化深度的预测结果离散性很大,不适用于桥梁混凝土自然碳化评估。
- 2) GBRT 算法在桥梁混凝土自然碳化深度预测问题中性能优异,经过超参数调整优化后,预测模型对测试集的 R^2 值为0.96, $RMSE$ 为0.83 mm, MAE 为0.64 mm,具有良好的泛化能力,可用于桥梁混凝土自然碳化深度的快速准确预测。
- 3) 基于 SHAP 方法的机器学习模型解释表现出高稳健性。全局特征重要性分析表明:混凝土抗压强度和龄期是影响桥梁混凝土自然碳化的两个最重要参数,并分别与碳化深度呈负相关和正相关关系;桥址

环境的 CO₂ 浓度和年平均温度亦对桥梁混凝土自然碳化有较大影响, 且两者均与碳化深度呈正相关, 而雨水 pH 值的影响相对较小。

参考文献:

- [1] 牛荻涛. 混凝土结构耐久性与寿命预测[M]. 北京: 科学出版社, 2003.
NIU D T. Durability and life forecast of reinforced concrete structure[M]. Beijing: Science Press, 2003.
- [2] 占玉林, 斯睿哲, 臧亚美. 混凝土桥梁耐久性 2020 年度研究进展[J]. 土木与环境工程学报(中英文), 2021, 43(S1): 100-106.
ZHAN Y L, SI R Z, ZANG Y M. State-of-art review of the durability of concrete bridges in 2020[J]. Journal of Civil and Environmental Engineering, 2021, 43(S1): 100-106.
- [3] 张建忠, 周星好, 林学春, 等. 东南沿海大气环境下桥梁混凝土碳化深度预测模型修正[J]. 重庆交通大学学报(自然科学版), 2026, 45(1): 15-22.
ZHANG J Z, ZHOU X Y, LIN X C, et al. Modification of prediction model for carbonization depth of bridge concrete under southeastern coastal atmospheric environment[J]. Journal of Chongqing Jiaotong University (Natural Science), 2026, 45(1): 15-22.
- [4] 王建有, 王浚宇, 王大辉, 等. 在役混凝土结构碳化深度的贝叶斯随机模型[J]. 水电能源科学, 2023, 41(2): 154-158.
WANG J Y, WANG J Y, WANG D H, et al. Bayesian stochastic model for carbonation depth of in-service concrete structures[J]. Water Resources and Power, 2023, 41(2): 154-158.
- [5] 彭建新, 廖鹏飞, 王斌, 等. 气候变化影响下钢筋混凝土碳化损伤不确定性分析[J]. 铁道科学与工程学报, 2023, 20(8): 3181-3191.
PENG J X, LIAO P F, WANG B, et al. Uncertainty analysis of RC carbonation-induced damage affected by climate change[J]. Journal of Railway Science and Engineering, 2023, 20(8): 3181-3191.
- [6] Qin H, Wang J. Probabilistic prediction model of concrete carbonation depth considering the influence of multiple factors[J]. Structural concrete, 2023, 24(5): 6209-6238.
- [7] 吴贤国, 王雷, 邓婷婷, 等. 基于随机森林的混凝土早期碳化预测[J]. 土木工程与管理学报, 2020, 37(2): 14-19.
WU Q G, WANG L, DENG T T, et al. Prediction of early carbonization of concrete based on random forest[J]. Journal of Civil Engineering and Management, 2020, 37(2): 14-19.
- [8] Hosseinnia A, Sichani M N, Alamdari B E, et al. Machine learning formulation for predicting concrete carbonation depth: A sustainability analysis and optimal mixture design[J]. Structures, 2025, 76: 109036.
- [9] Chen Z, Lin J, Sagoe-Crentsil K, et al. Development of hybrid machine learning-based carbonation models with weighting function[J]. Construction and Building Materials, 2022, 321: 126359.
- [10] Huang S, Li C, Zhou J. Toward durability loss in buildings: Probabilistic prediction of concrete carbonation depth using machine learning and kernel density estimation[J]. Journal of Building Engineering, 2026, 124: 115983.
- [11] CHEN Y, FU Q, ZHENG W. NGBoost-based prediction of carbonation in Alkali-activated slag concrete enhanced by metaheuristic algorithms[J]. Construction and Building Materials, 2025, 500: 144257.
- [12] Duan K, Cao S. Data-driven parameter selection and modeling for concrete carbonation[J]. Materials, 2022, 15(9): 3351.
- [13] Ehsani M, Ostovari M, Mansouri S, et al. Machine learning for predicting concrete carbonation depth: A comparative analysis and a novel feature selection[J]. Construction and Building Materials, 2024, 417: 135331.
- [14] Duan K, Cao S, Li J, et al. Prediction of neutralization depth of RC bridges using machine learning methods[J]. Crystals, 2021, 11(2): 210.
- [15] Majlesi A, Koodiani H K, Rincon O T D, et al. Artificial neural network model to estimate the long-term carbonation depth of concrete exposed to natural environments[J]. Journal of Building Engineering, 2023, 74: 106545.
- [16] Chan T C, Yio M H N, Wong H S. Natural carbonation of concrete: a data-driven analysis[J]. Cement and Concrete Composites, 2026, 167: 106436.
- [17] 中华人民共和国交通运输部. 公路桥涵设计通用规范: JTG D60—2015[S]. 北京: 人民交通出版社股份有限公司, 2015.
Ministry of Transport of the People's Republic of China. General specifications for design of highway bridges and culverts: JTG D60—2015[S]. Beijing: China Communications Press Co., Ltd., 2015.
- [18] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
ZHOU Z H. Machine learning[M]. Beijing: Tsinghua University Press, 2016.
- [19] Friedman J H. Greedy Function Approximation: A Gradient Boosting Machine[J]. Annals of Statistics, 2001, 29(5): 1189-1232.
- [20] Breiman L, Friedman J H, Olshen R, et al. Classification and Regression Trees[M]. New York: Taylor & Francis Group, 1984.

[21]周星好. 基于机器学习的混凝土碳化深度预测模型[D]. 福州: 福州大学, 2024.

ZHOU X Y. Prediction model of concrete carbonation depth based on machine learning[D]. Fuzhou: Fuzhou University, 2024.

[22]中华人民共和国住房和城乡建设部. 既有混凝土结构耐久性评定标准: GB/T 51355-2019[S]. 北京: 中国建筑工业出版社, 2019.

Ministry of Housing and Urban-Rural Development of the People's Republic of China. Standard for durability assessment of existing concrete structures: GB/T 51355-2019[S]. Beijing: China Architecture & Building Press, 2019.



通信作者: 唐朝阳 (1969—), 男, 高级工程师, 研究方向为公路建设与养护管理。