

# 基于机器学习的 CFST 柱高温剩余强度 系数预测方法

宋岩升<sup>1</sup>, 肖 广<sup>1</sup>, 王浩然<sup>1</sup>, 王光远<sup>2</sup>

(1. 沈阳建筑大学土木工程学院, 辽宁 沈阳 110168;

2. 辽宁省交通高等专科学校道路与桥梁工程系, 辽宁 沈阳 110122)

**摘 要** 目的 为提高计算精度和速度, 利用机器学习模型泛化数据, 以预测 CFST 柱的高温剩余强度系数。方法 利用生成对抗网络将搜集到的 110 个试验结果泛化生成 407 组数据, 据此训练机器学习模型, 并使用试验结果评估其性能, 以确定最优模型; 然后使用生成数据输入建立的模型预测 CFST 柱高温剩余强度系数, 并和现有计算方法进行对比。结果 建立的随机森林模型在性能度量上表现最好, 拟合优度达到 0.947 7, 均方误差为 0.001 8, 精度为 94.7%; 预测结果误差在  $\pm 10\%$  内的数据为 83%, 在  $\pm 20\%$  内的数据为 100%; 剩余强度系数主要影响因素依次为温度、钢材屈服强度、混凝土抗压强度和横截面积, 钢管厚度影响很小。结论 提出的预测方法优于现有计算方法, 具有更快的计算速度、更小的结果误差以及更强的模型可解释性, 该方法可为 CFST 柱抗火设计提供参考。

**关键词** 钢管混凝土柱; 剩余强度系数; 机器学习; 抗火设计

中图分类号 TU392

文献标志码 A

**引用格式:** 宋岩升, 肖广, 王浩然, 等. 基于机器学习的 CFST 柱高温剩余强度系数预测方法[J]. 沈阳建筑大学学报(自然科学版), 2024, 40(5): 867-875. (SONG Yansheng, XIAO Guang, WANG Haoran, et al. Research on prediction method of residual strength index of CFST columns at high temperature based on machine learning [J]. Journal of Shenyang jianzhu university(natural science), 2024, 40(5): 867-875.)

## Research on Prediction Method of Residual Strength Index of CFST Columns at High Temperature Based on Machine Learning

SONG Yansheng<sup>1</sup>, XIAO Guang<sup>1</sup>, WANG Haoran<sup>1</sup>, WANG Guangyuan<sup>2</sup>

(1. School of Civil Engineering, Shenyang Jianzhu University, Shenyang, China, 110168; 2. Department of Road and Bridge Engineering, Liaoning Provincial College of Communications, Shenyang, China, 110122)

收稿日期: 2023-07-03

基金项目: “十三五”国家重点研发计划项目(2018YFC1504303); 辽宁省教育厅科学研究项目(LJKZ0560, LNJJC201906); 辽宁省教育厅基本科研项目(JYTMS20230150)

作者简介: 宋岩升(1975—), 男, 副教授, 主要从事结构抗火等方面研究。

**Abstract:** The purpose of this study is improving calculation accuracy and speed, machine learning models were employed to generalize data for predicting the residual strength index of CFST columns under high temperatures. A Generative Adversarial Network was used to generalize and generate 407 datasets from the 110 collected experimental results. These were then used to train machine learning models, with the experimental results used to evaluate their performance and determine the optimal model. The generated data were input into the established model to predict the high-temperature residual strength index of CFST columns, and the results were compared with existing calculation methods. Comparative analysis with available experimental results showed that the Random Forest model had the best performance in terms of metrics, achieving a goodness-of-fit of 0.947 7, a mean squared error of 0.001 8, and an accuracy of 94.7%. The prediction error for 83% of the data was within the  $\pm 10\%$  range, and for 100% of the data, it was within the  $\pm 20\%$  range. The main influencing factors for the residual strength index, in order of importance, were temperature, steel yield strength, concrete compressive strength, and cross-sectional area, with steel tube thickness having a minimal impact. The findings demonstrate that the proposed prediction method outperforms existing calculation methods, offering faster computation speed, smaller result errors, and stronger model interpretability. This method can provide a reference for fire-resistant design of CFST columns.

**Key words:** concrete-filled steel tube columns; residual strength index; machine learning; fire resistant design

钢管混凝土(Concrete-Filled Steel Tube, CFST)柱强度高、耐久性好、抗震性好,被广泛应用于高层建筑、桥梁、港口码头等建筑物、构筑物中。高温会导致其承载力下降,剩余强度系数是衡量 CFST 柱抗火性能的重要指标之一。近年来,国内外对 CFST 柱高温剩余强度的试验研究取得了很多成果,杨华等<sup>[1]</sup>对 13 根 CFST 柱进行恒定高温试验,提出了高温后 CFST 柱轴压剩余强度和轴压模量简化计算公式。韩海林等<sup>[2-3]</sup>对圆截面和方截面 CFST 柱进行升温试验,研究了其升温后力学性能和剩余强度变化规律,并提出了剩余强度系数概念。在 CFST 柱的设计阶段,需要有一种可靠的方法来预测其高温剩余强度的变化,从而做出更合理的设计方案。然而,现有的计算方法考虑影响因素不够全面,并且计算过程复杂;经验公式与理论计算结果存在一定偏差,应用受到限制。目前,机器学习被广泛应用于各个领域,从纯粹理论研究和模型研究发展到以解决实际问题为目的的应用研究<sup>[4]</sup>。机器学习具有很强的泛化能力和很高计算效率,在一定程度上可以

解决上述问题。陆征然等<sup>[5]</sup>通过 BP 神经网络预测有缺陷圆形钢管混凝土短柱的承载力,预测结果和试验结果的误差在 5% 以内。孟庆成等<sup>[6]</sup>通过卷积神经网络对混凝土裂缝进行智能检测,准确率达到 97.98%。王庆贺等<sup>[7]</sup>通过建立随机森林模型确定了影响栓钉抗剪承载力的主要因素。小样本数据在机器学习模型的训练过程中效果不理想,容易产生过拟合或欠拟合,无法真正反映出每个输入参数对输出结果的影响,而 CFST 柱抗火试验所获得的剩余强度系数数据较少,I. Goodfellow 等<sup>[8]</sup>提出一种无监督深度学习模型(Generative Adversarial Network, GAN),利用试验数据通过对抗训练生成数据。因此,笔者利用 GAN 将小样本试验数据生成大量新数据,以此训练机器学习模型,经评估和分析后选择随机森林模型,该方法相较于现有方法,能够准确和快速地预测高温下 CFST 柱的剩余强度系数,同时建立的模型能够直观地反映温度等参数对剩余强度系数的影响。

1 数据库的建立

韩林海<sup>[3]</sup>提出的 CFST 柱高温剩余强度系数(Residual Strength Index,RSI)计算公式为

$$K_{RSI} = \frac{N_u(t)}{N}$$
 (1)

式中: $N_u(t)$ 为 CFST 柱高温剩余强度,kN; $N$ 为 CFST 柱常温极限强度,kN。

1.1 初始数据的选取

影响 CFST 柱高温剩余强度系数的主要影响因素有温度  $T$ 、混凝土抗压强度  $f_c$ 、截面边长或直径  $D$ 、截面面积  $A$ 、长细比  $\lambda$ 、钢管厚度  $t_s$  和钢材屈服强度  $f_y$  等 7 个变量<sup>[2,9-11]</sup>,因而从文献中收集初始数据时遵循以下原则:

(1)只选用以普通混凝土为填充物的钢管混凝土柱,内加型钢、钢筋以及纤维增强物等不考虑在内。

(2)只选用普通碳素钢钢管,不锈钢钢管、铝管等不在考虑范围内。

(3)试验数据中至少包括混凝土抗压强度、截面边长或直径、截面面积、钢管厚度、钢材屈服强度和温度 6 个参数,且长细比和剩余强度系数可以通过已知数据计算得出。

据此,笔者共收集了 110 组 CFST 柱的试验数据,建立了用于机器学习的初始数据库,参数统计如表 1 所示,数据分布如图 1 所示。这 110 组数据将作为 GAN 的输入数据和预测模型的测试集。

表 1 初始数据统计结果

Table 1 The initial data statistical results

指标	$f_c$ /MPa	$D$ /mm	$A$ /mm <sup>2</sup>	$\lambda$	$t_s$ /mm	$f_y$ /MPa	$T$ /°C	剩余强度系数
最大值	83.70	330	85 527.33	44.4	10	463.2	1 029	0.99
最小值	27.20	100	9 160.61	4.2	1.8	176.5	300	0.34
平均值	46.67	155.26	22 054.37	14.21	3.88	300.25	733.49	0.69
标准偏差	12.59	54.27	17 873.98	12.25	1.54	86.21	220.54	0.19

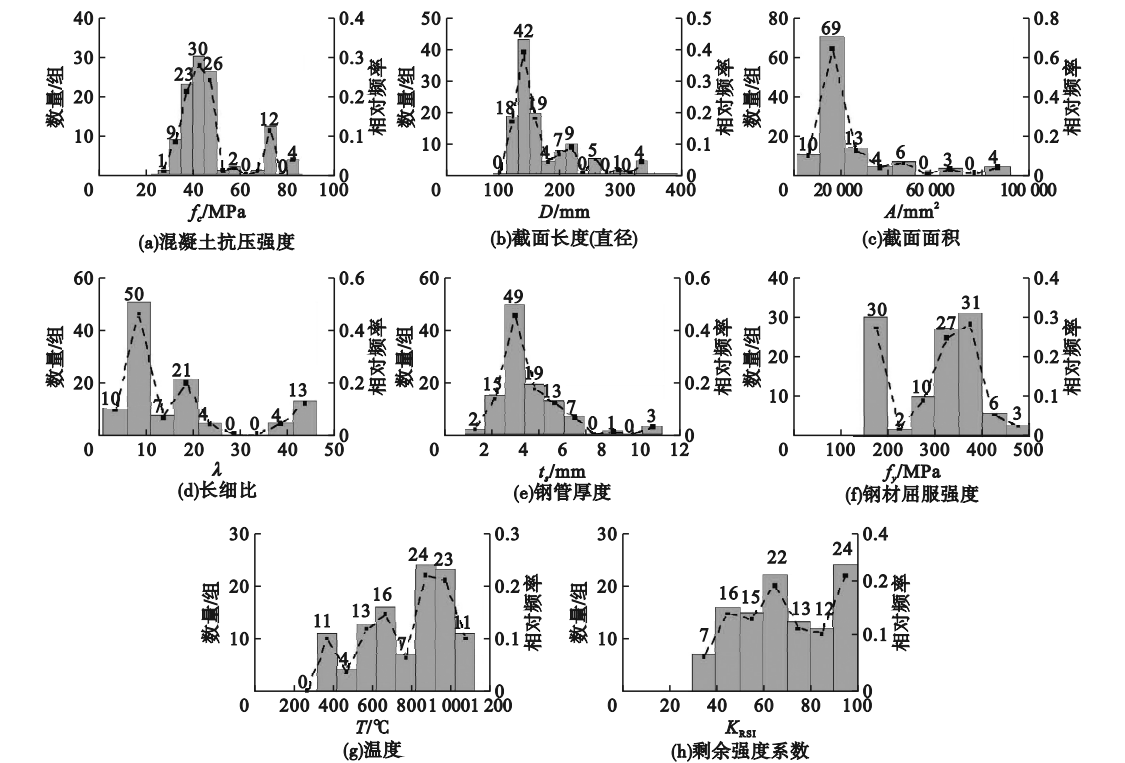


图 1 初始数据的分布情况

Fig. 1 Distribution of initial data

1.2 新数据的生成

GAN 由两个神经网络组成:生成器和判别器。生成器负责利用试验数据生成新的数据,判别器负责对试验数据和生成数据进行分类。GAN 的目标是通过不断地对抗训练使生成器生成的合成数据越来越接近试验数据,从而提高生成器的性能。笔者构建了一个输入输出均为 8 个参数的 5 层网络结构的生成器和一个 4 层网络结构的判别器,如图 2 所示。图 2 中,生成器  $G$  的输入为随机噪声  $z$ ,例如高斯噪声,生成的数据记为  $G(z)$ ;判别器  $D$  的输入为真实(试验)数据  $x$  和生成数据  $G(z)$ ,输出  $DG(z)$  为生成数据  $G(z)$  与真实数据相似的概率。训练过程的目标函数为:

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)} [\lg D(x)] + E_{z \sim P_z(z)} [\lg (1 - D(G(z)))]$$
 (2)

式中: $V(D, G)$  为损失函数; $P_{data}(x)$  为真实数据分布; $P_z(z)$  为随机噪声分布; $E$  为数学期望; $D(x)$  为真实数据经判别器后的输出;

$D(G(z))$  为生成数据经判别器后的输出。

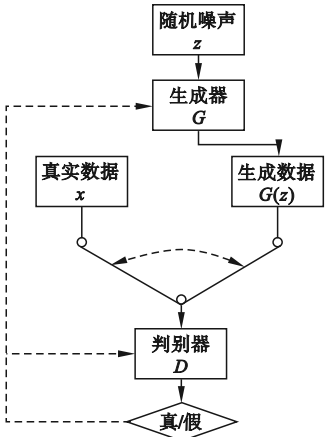


图 2 GAN 的基本结构

Fig. 2 The basic structure of GAN

利用此 GAN 模型生成了 500 组 CFST 柱数据,剔除其中无实际意义的数据,筛选后保留 407 组数据作为机器学习模型的训练集,数据分布如图 3 所示,训练集中数据统计如表 2 所示。

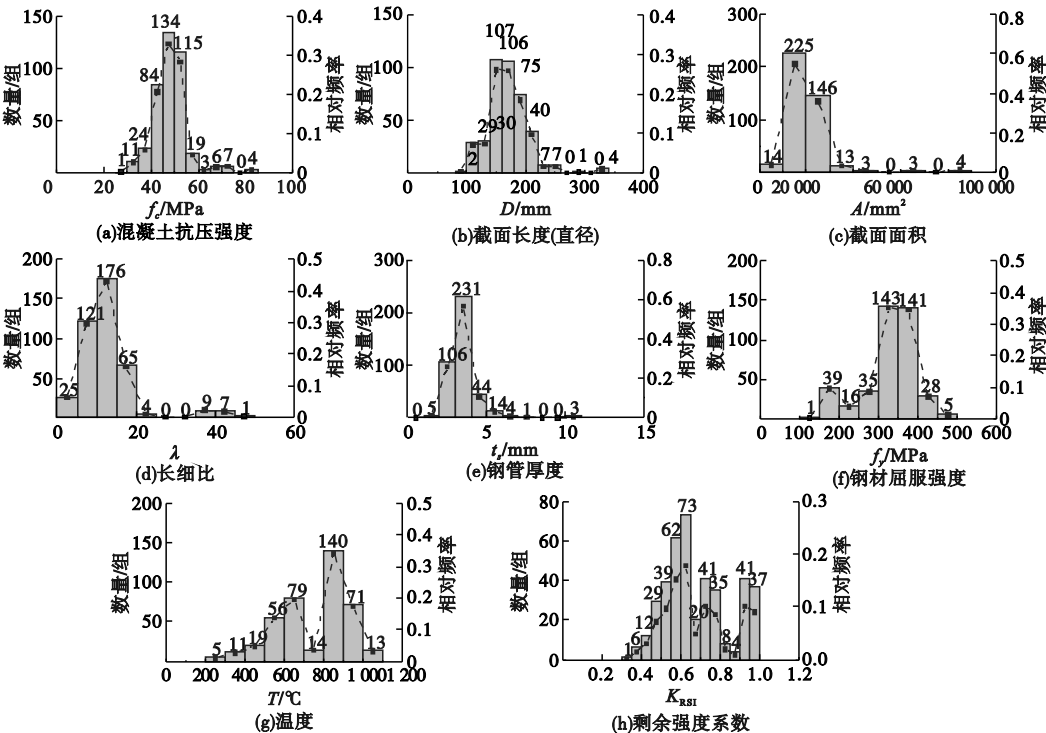


图 3 生成数据的分布情况

Fig. 3 Distribution of generated data

表 2 生成数据统计结果

Table 2 The generated data statistical results

指标	$f_c/\text{MPa}$	$D/\text{mm}$	$A/\text{mm}^2$	$\lambda$	$t_s/\text{mm}$	$f_y/\text{MPa}$	$T/^\circ\text{C}$	剩余强度系数
最大值	84.32	330.3	85 551.62	45.13	10.81	480.85	1 024.17	0.99
最小值	26.63	98.49	5 641.44	3.25	1.02	128.49	278	0.34
平均值	48.44	169.33	20 488.68	12.18	3.42	326.61	753.63	0.67
标准偏差	7.5	33.89	9 511.14	6.93	1	66.89	178.21	0.16

对比表 1 和表 2 中相应参数,可知初始数据和生成数据具有相似的中心趋势和数据范围,二者可以近似地看作是从同一个总体中提取出来的样本数据。图 3 描述了混凝土抗压强度、温度、剩余强度系数等数据的分布情况。

2 机器学习模型的选择

2.1 性能度量指标

常用于回归任务的机器学习模型有随机森林(Random Forest, RF)<sup>[12-13]</sup>、支持向量机(Support Vector Machine, SVM)<sup>[14-15]</sup>、岭回归(Ridge Regression, RR)、罗素回归(Lasso Regression, LR)和贝叶斯回归(Bayesian Regression, BR)等。上述模型源自不同的算法,对 CFST 柱高温剩余强度系数预测的表现也各不相同,需要通过预测结果对比对其性能进行度量。

机器学习的性能度量是指对机器学习模型进行评估和比较的一系列指标和方法,它们用于衡量模型在预测能力、准确性和稳定性等方面的表现。在回归任务中,经常使用的度量指标有拟合优度( $R^2$ )、均方误差( $K_{\text{MSE}}$ )和精度( $K_A$ )<sup>[4]</sup>:

$$R^2 = 1 - \frac{SSR}{SST} = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

$$K_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

$$K_A = 1 - \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\bar{y}_i} \times 100\% \quad (5)$$

式中: $y_i$  为真实值; $\bar{y}$  为模型平均值; $\hat{y}$  为模型预测值; $n$  为数据点个数。

2.2 模型选择及分析

将 GAN 生成的 407 组 CFST 柱数据输入随机森林、支持向量机、岭回归、罗素回归和贝叶斯回归模型中进行训练,将 110 组初始数据作为测试集,用拟合优度、均方误差和精度三个指标来评估模型的预测性能,拟合优度高、均方误差低、精度高表明模型的预测效果较好,反之则表明预测效果较差。5 个模型预测性能如表 3 所示,预测结果如图 4 所示。

表 3 机器学习模型的性能度量

Table 3 The performance measurement of five machine learning models

模型类别	拟合优度	均方误差	精度/%
随机森林	0.947 7	0.001 8	94.70
支持向量机	0.558 7	0.015 6	83.30
岭回归	0.559 4	0.015 8	83.10
罗素回归	0.537 4	0.016 4	82.90
贝叶斯回归	0.557 9	0.015 7	83.20

从表 3 中可以看出随机森林模型的拟合优度最大,表明其拟合性能更好。该模型的均方误差最小,精度最大,说明预测结果更精确,更贴近试验数据。

图 4 表明相较于其他 4 个模型,随机森林模型的预测值更接近于真实值,数据的离散程度更小,更趋近于理想曲线,并且没有产生无实际意义的数据。究其原因,第一,随机森林是通过构建多个决策树来预测的集成学习方法,具有较强的泛化能力,能够有效地避免过拟合的问题;第二,随机森林可以很好地处理非线性关系,相比之下,岭回归、罗素回



归和贝叶斯回归通常假设数据之间存在线性关系,而支持向量机虽然能够处理非线性问题,但需要选择合适的核函数,这可能导致模型的选择与调整过程变得复杂,而7个输入

参数只有截面长度或直径和截面面积存在一定的线性关系,其余参数之间都属于非线性关系。所以随机森林模型的预测值与真实值的吻合程度高于其余4个模型。

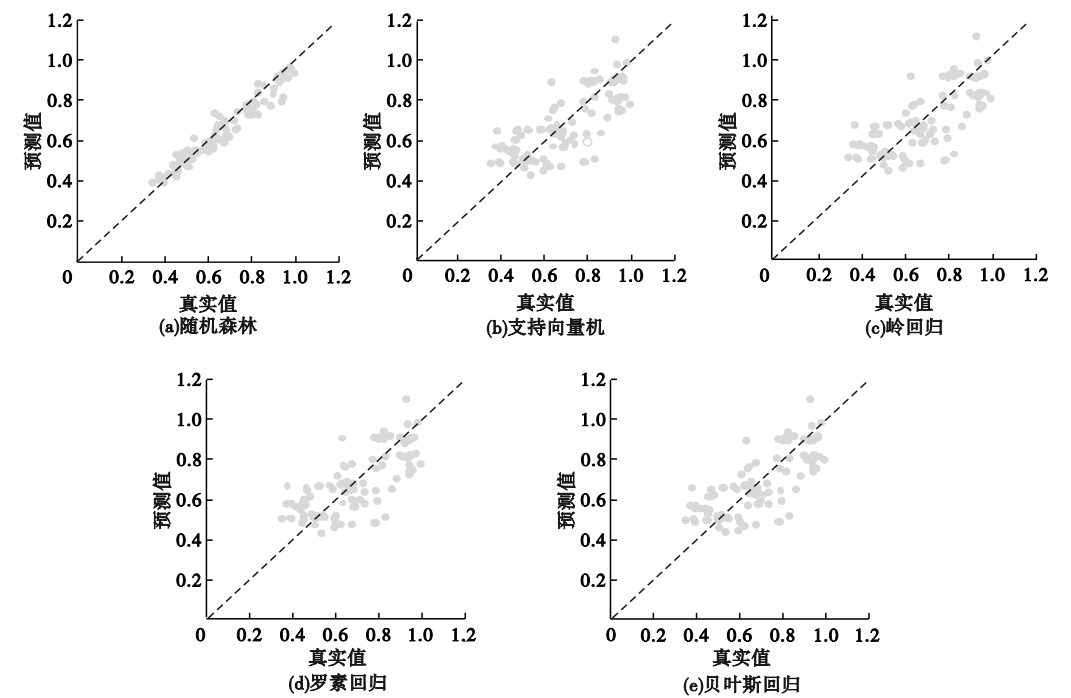


图4 五种机器学习模型的预测结果

Fig. 4 The prediction results of five machine learning modes

由此看出,随机森林模型更适用于CFST柱高温剩余强度系数的预测。

表4为选取文献[16-17]中的24组试验数据。图5为笔者建立的随机森林模型和现有方法<sup>[3,18-20]</sup>预测结果与试验值的吻合度对比。

3 预测结果分析

3.1 与现有方法的对比

表4 验证数据

Table 4 Data used for verification

数据来源	$f_c$ /MPa	$D$ /mm	$A$ /mm <sup>2</sup>	$\lambda$	$t_s$ /mm	$f_y$ /MPa	$T$ /℃	剩余强度系数
文献[16]	48.29	133	13 892	12	4.5	433	300	0.831
	48.29	133	13 892	12	4.5	433	400	0.630
	48.29	133	13 892	12	4.5	433	500	0.660
	48.29	133	13 892	12	4.5	433	600	0.492
	48.29	133	13 892	12	4.5	433	700	0.456
	48.29	133	13 892	12	4.5	433	800	0.341
	20.02	120	14 400	10.39	6	265.3	300	0.925
	20.02	120	14 400	10.39	6	265.3	400	0.787
	20.02	120	14 400	10.39	6	265.3	500	0.842
	20.02	120	14 400	10.39	6	265.3	600	0.823
	20.02	120	14 400	10.39	6	265.3	700	0.617
	20.02	120	14 400	10.39	6	265.3	800	0.613

续表 4

Continued 4

数据来源	$f_c$ /MPa	$D$ /mm	$A$ /mm <sup>2</sup>	$\lambda$	$t_s$ /mm	$f_y$ /MPa	$T$ /℃	剩余强度系数
文献[17]	39	120	9 600	11.54	3.7	337.5	400	0.917
	39	120	9 600	11.54	3.7	337.5	600	0.867
	39	120	9 600	11.54	3.7	337.5	800	0.558
	39	120	9 600	11.54	3.7	337.5	600	0.855
	39	120	9 600	11.54	3.7	337.5	600	0.891
	39	120	9 600	11.54	3.7	337.5	600	0.842
	39	120	9 600	11.54	3.7	337.5	600	0.779
	39	80	6 400	17.32	3.7	337.5	600	0.545
	39	160	12 800	8.66	3.7	337.5	600	0.844
	39	120	9 600	11.54	3.7	413.6	600	0.864
	39	120	9 600	8.66	3.7	337.5	600	0.854
	39	120	9 600	17.32	3.7	337.5	600	0.735




图 5 预测结果与试验数据的吻合度

Fig. 5 The degree of conformity between the prediction results and the experimental data

使用拟合优度、均方误差和精度这三个度量指标来评估随机森林模型和现有方法对 CFST 柱高温剩余强度系数的预测结果。表

5 为计算结果对比及误差。从表 5 可以看出,模拟预测结果的误差在  $\pm 10\%$  范围内的比例为 83%,明显高于其他 4 种方法,证明了使用此方法来预测 CFST 柱高温剩余强度系数的有效性。从性能度量指标来看,模拟模型具有较高的拟合优度和精度,以及较小的均方误差,说明其拟合效果好、预测能力强、预测值偏离真实值的程度最小。这是因为随机森林模型在处理非线性关系和高维数据时不需要对数据进行转化,而现有方法则需要去满足线性模型的假设。同时,随机森林模型可以利用多核 CPU 或者分布式计算集群来提高计算效率,在计算速度上存在着很大的优势,表 4 中的 24 组数据计算响应时间仅为 0.05 s。

表 5 结果对比及误差范围

Table 5 Results contrast and error range

数据来源	拟合优度	均方误差	精度/%	各误差范围所占比例/%		
				$\varepsilon = \pm 10\%$	$\varepsilon = \pm 20\%$	$\varepsilon = \pm 40\%$
模拟值	0.839 3	0.004 1	93.2	83	100	100
文献[3]	0.308 2	0.017 7	81.4	25	79	95
文献[18]	0.308 0	0.017 7	84.6	29	58	100
文献[19]	-0.229 7	0.031 5	70.3	33	50	79
文献[20]	0.301 5	0.017 9	83.4	25	62	100

3.2 可解释性研究

随机森林模型的特征重要性是指每个特

征对模型预测结果的贡献程度,通过计算每个特征在随机森林中的平均不纯度减少(或

平均信息增益)来确定。在随机森林中,每个决策树都会对数据进行分割,而且每次分割都会减少数据的不纯度。

表6为建立的随机森林模型中输入参数

表6 各参数的特征重要性分数

Table 6 Characteristic importance scores of parameters

温度	钢材屈服强度	混凝土抗压强度	截面面积	截面边长或直径	长细比	钢管厚度
0.791 51	0.078 17	0.040 89	0.035 87	0.022 05	0.017 96	0.013 52

相关系数热力图用于显示数据集中各个变量之间联系的紧密程度。相关系数数值越大,颜色越深,表示两个变量之间的相关性越强;反之,则表示两个变量之间的相关性越弱。相关系数小于0,说明变量是负相关的,即一个变量的值越大,另一个变量的值反而越小。

图6为输入参数 $T$ 、 $t_s$ 、 $f_y$ 等和输出参数 $K_{RSI}$ 之间的相关系数热力图。由图6可知,与 $K_{RSI}$ 相关性最强的是温度,其次是钢材的屈服极限、混凝土的抗压强度、截面面积,最弱的是钢管厚度,这与随机森林模型特征重要性分数得到的参数排序基本相同,说明通过生成数据建立的随机森林模型保留了大部分初始数据本身各个参数之间的相关性。




图6 相关系数热力图

Fig. 6 Correlation coefficient heat map

4 结 论

(1)与支持向量机、岭回归、罗素回归和贝叶斯回归模型相比,笔者建立的随机森林模型在性能度量上表现最好,拟合优度达到0.947 7,均方误差为0.001 8,精度为94.7%,同时具有很强的可解释性。

的特征重要性分数。温度的重要性分数最高,然后依次是钢材屈服强度、混凝土抗压强度、截面面积,截面边长或直径、长细比,分数最低的是钢管厚度。

(2)与4种现有方法相比,笔者建立的随机森林模型预测结果误差在±10%内的数据为83%,在±20%内的数据为100%;CFST柱高温剩余强度系数结果准确率更高,预测结果精度更高,可为CFST柱抗火设计提供参考。

(3)通过可解释性研究发现,温度、钢材屈服强度、混凝土抗压强度和横截面积是影响剩余强度系数的主要因素,且影响程度依次降低,而钢管厚度影响最小。

参考文献

[1] 杨华,韩林海. 高温作用后圆钢管混凝土轴压力学性能研究[J]. 工业建筑,2001(11): 50-54.  
(YANG Hua,HAN Linhai. Mechanical behavior of concrete filled circular steel tubular stub columns after high temperatures [J]. Industrial construction,2001(11): 50-54. )

[2] 韩林海,杨有福,霍静思. 钢管混凝土柱火灾后剩余承载力的试验研究[J]. 工程力学,2001(6):100-109.  
(HAN Linhai, YANG Youfu, HUO Jingsi. Tests on the residual strength of concrete filled steel tubular columns after exposure to fire [J]. Engineering mechanics, 2001(6): 100-109. )

[3] HAN L H, HUO J S. Concrete-filled hollow structural steel columns after exposure to ISO-834 fire standard [J]. Journal of structural engineering,2003,129(1):68-78.

[4] 周志华. 机器学习[M]. 北京:清华大学出版社,2016.  
( ZHOU Zhihua. Machine learning [M]. Beijing:Tsinghua University Press,2016. )

[5] 陆征然,赵婉东,郭超. 基于BP神经网络的缺陷CFST短柱承载力预测[J]. 沈阳建筑大学学报(自然科学版),2021,37(4):702-708.  
( LU Zhengran,ZHAO Wandong, GUO Chao. Bearing capacity prediction of defective CFST



- short columns based on BP neural network [J]. Journal of Shenyang jianzhu university (natural science), 2021, 37(4): 702–708. )
- [6] 孟庆成, 万达, 吴浩杰, 等. 基于卷积神经网络的混凝土裂缝图像识别方法[J]. 沈阳建筑大学学报(自然科学版), 2021, 37(5): 832–840.  
(MENG Qingcheng, WAN Da, WU Haojie, et al. Image recognition method of concrete cracks based on convolutional neural network [J]. Journal of Shenyang jianzhu university (natural science), 2021, 37(5): 832–840. )
- [7] 王庆贺, 张提睿, 李永进, 等. 基于机器学习的钢-自燃煤矸石混凝土组合梁栓钉抗剪承载力研究[J]. 沈阳建筑大学学报(自然科学版), 2023, 39(2): 227–233.  
(WANG Qinghe, ZHANG Tirui, LI Yongjin, et al. Shear capacity of studs in steel-spontaneous-combustion coal gangue concrete composite beams using machine learning [J]. Journal of Shenyang jianzhu university (natural science), 2023, 39(2): 227–233. )
- [8] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C]. Advances in neural information processing systems, 2014: 2672–2680.
- [9] 吕西林, 余勇, 陈以一, 等. 轴心受压方钢管混凝土短柱的性能研究: I 试验[J]. 建筑结构, 1999(10): 41–43.  
(LYU Xilin, YU Yong, CHEN Yiyi, et al. Axial compression performance study of square concrete-filled steel tubular short column: I test [J]. Building structure, 1999(10): 41–43. )
- [10] 韩林海, 霍静思. 火灾作用后钢管混凝土柱的承载力研究[J]. 土木工程学报, 2002(4): 25–35.  
(HAN Linhai, HUO Jingsi. Bearing capacity of concrete-filled steel tubular columns after fire [J]. China civil engineering journal, 2002(4): 25–35. )
- [11] 丁发兴. 圆钢管混凝土结构受力性能与设计方法研究[D]. 长沙: 中南大学, 2006.  
(DING Faxing. Behavior and design method of concrete filled circular steel tubular structures [D]. Changsha: Central South University, 2006. )
- [12] 王奕森, 夏涛涛. 集成学习之随机森林算法综述[J]. 信息通信技术, 2018, 12(1): 49–55.  
(WANG Yisen, XIA Shutao. A survey of random forests algorithms [J]. Information and communications technologies, 2018, 12(1): 49–55. )
- [13] ZHANG H, WANG M. Search for the smallest Random Forest [J]. Interface, 2009(2): 381–388.
- [14] 汪海燕, 黎建辉, 杨风雷. 支持向量机理论及算法研究综述[J]. 计算机应用研究, 2014, 31(5): 1281–1286.  
(WANG Haiyan, LI Jianhui, YANG Fenglei. Overview of support vector machine analysis and algorithm [J]. Application research of computers, 2014, 31(5): 1281–1286. )
- [15] BRATSAS C, KOUPIIDIS K, SALANOVA J, et al. A comparison of machine learning methods for the prediction of traffic speed in urban places [J]. Sustainability, 2019, 142: 1–15.
- [16] 姜绍飞, 刘明. 高温后不同截面钢管混凝土轴压构件的实验研究[J]. 东北大学学报(自然科学版), 2002(9): 891–894.  
(JIANG Shaofei, LIU Ming. Experimental investigation on different cross section members of concrete filled steel tube (cfst) after elevated temperature [J]. Journal of northeastern university (natural science), 2002(9): 891–894. )
- [17] JIANG S F, WU Z Q, NIU D S. Experimental study on fire-exposed rectangular concrete-filled steel tubular (CFST) columns subjected to bi-axial force and bending [J]. Advances in structural engineering, 2010, 13(4): 551–560.
- [18] 余志武, 丁发兴, 林松. 高温后钢管高性能混凝土轴压短柱力学性能研究[J]. 铁道学报, 2003(4): 71–79.  
(YU Zhiwu, DING Faxing, LIN Song. Researches on mechanical behavior of high-performance concrete filled tubular steel stub columns after high temperature [J]. Journal of the China railway society, 2003(4): 71–79. )
- [19] 中华人民共和国住房和城乡建设部. 建筑钢结构防火技术规范: GB 51249—2017 [S]. 北京: 中国建筑工业出版社, 2017.  
(Ministry of Housing and Urban-Rural Development of People's Republic of China. Code for fire safety of steel structures in buildings: GB 51249—2017 [S]. Beijing: China Architecture & Building Press, 2017. )
- [20] 中华人民共和国住房和城乡建设部. 钢管混凝土结构技术规范: GB 50936—2014 [S]. 北京: 中国建筑工业出版社, 2014.  
(Ministry of Housing and Urban-Rural Development of People's Republic of China. Technical code for concrete filled steel tubular structures: GB 50936—2014 [S]. Beijing: China Architecture & Building Press, 2014. )
- (责任编辑: 王国业 英文审校: 刘永军)