

DOI:10.13409/j.cnki.jdpme.20250430099

# 基于机器学习的连续刚构桥施工线形预测研究\*

左鸿鹏<sup>1</sup>, 王冰<sup>2</sup>, 陈朋<sup>1</sup>, 张红彦<sup>1</sup>, 王力<sup>2</sup>

(1. 山西交院试验检测有限公司, 山西太原 030032; 2. 兰州交通大学土木工程学院, 甘肃兰州 730070)

**摘要:** 针对连续刚构桥施工过程中因复杂环境因素引起的材料参数时变性问题, 传统有限元分析方法受限于单一设计参数假设, 难以准确模拟施工过程中影响参数的实际变化状态, 从而导致桥梁施工期线形控制精度不足等关键技术难题。为此提出一种基于机器学习的连续刚构桥施工线形智能预测方法。首先通过参数化有限元建模, 系统模拟多因素耦合作用下的施工挠度响应, 构建完备的挠度预测样本数据库。分别基于支持向量机(SVM)、随机森林(RF)、长短期记忆网络(LSTM)以及粒子群优化反向传播神经网络(PSO-BP)建立4种连续刚构桥施工线形机器学习预测模型, 并对其预测精度进行对比分析。研究表明: RF和ELM模型的预测精度相对较低; LSTM模型预测精度较好, 预测最大误差为1.2 mm; PSO-BP模型则展现出最优的预测性能, 其训练集和测试集的拟合优度分别达0.996和0.992, 预测挠度绝对误差仅0.55 mm, 相对误差均小于10%; 采用PSO-BP神经网络算法可实现连续刚构桥施工挠度的精准预测, 有效提升该类桥施工线形控制水平, 提高合龙精度, 该研究成果可为桥梁工程智能化施工提供必要参考。

**关键词:** 连续刚构桥; 桥梁施工; 机器学习; 施工线形

**中图分类号:** TU443 **文献标识码:** A **文章编号:** 1672-2132(2025)06-1411-10

## Research on Construction Alignment Prediction of Continuous Rigid-frame Bridges Based on Machine Learning

ZUO Hongpeng<sup>1</sup>, WANG Bing<sup>2</sup>, CHEN Peng<sup>1</sup>, ZHANG Hongyan<sup>1</sup>, WANG Li<sup>2</sup>

(1. Shanxi Traffic Construction Engineering Quality Inspection Center Co., Ltd., Taiyuan 030032, China;

2. School of Civil Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

**Abstract:** Given the time-varying characteristics of material parameters caused by complex environmental factors during the construction of continuous rigid-frame bridges, the traditional finite element analysis method is limited by the assumption of a single design parameter, and it is difficult to accurately simulate the actual changing state of the influencing parameters during the construction process, which leads to key technical problems such as insufficient alignment control accuracy during bridge construction. Therefore, this study proposed an intelligent prediction method for construction alignment of continuous rigid-frame bridges based on machine learning. First, parametric finite element

\* 收稿日期: 2025-04-30; 修回日期: 2025-06-17

基金项目: 甘肃省联合科研基金重点项目(24JRRA869)、山西交通控股集团科技创新项目(23-JKKJ-6)资助

作者简介: 左鸿鹏(1987—), 男, 高级工程师, 硕士研究生。主要从事公路工程桥隧构造物检测、监测及稳定性评价方面的研究。E-mail: 616628409@qq.com

通信作者: 王力(1993—), 男, 副教授。主要从事大跨度桥梁施工控制理论与人工智能应用研究。

E-mail: wanglilzjtu@126.com

modeling was used to simulate the construction deflection response under the coupling of multiple factors, and a complete deflection prediction sample database was constructed. On this basis, four construction-alignment prediction models based on support vector machine (SVM), random forest (RF), long short-term memory network (LSTM), and particle swarm optimization backpropagation neural network (PSO-BP) were established, and their prediction accuracy was compared and analyzed. The results showed that the prediction accuracy of RF and ELM models was relatively low. The LSTM model exhibited better prediction accuracy, with a maximum prediction error of 1.2 mm. The PSO-BP model showed the best prediction performance. Its  $R^2$  values for the training set and the test set were 0.996 and 0.992, respectively. The absolute error of the predicted deflection was only 0.55 mm, and the relative error was less than 10%. The PSO-BP neural network enables accurate prediction of construction deflection, effectively improves the alignment control level of continuous rigid-frame bridge construction, and enhances the closure alignment accuracy of the bridge. The findings provide an important technical reference for the intelligent construction of bridge engineering.

**Keywords:** continuous rigid-frame bridge; bridge construction; machine learning; construction alignment

## 0 引言

连续刚构桥因其结构整体性好、跨越能力强,在现代桥梁工程中广泛应用。其施工多采用悬臂浇筑法,通过逐段浇筑并张拉预应力钢束形成桥梁整体线形<sup>[1]</sup>。然而,实际施工过程中,混凝土收缩徐变、预应力损失、温度效应等因素导致材料参数与设计值存在偏差<sup>[2]</sup>,加之施工荷载的动态变化,使得桥梁施工线形往往偏离设计目标。若线形误差累积过大,将影响结构受力安全及行车舒适性,甚至导致后期调索、顶升等补救措施,增加工程成本。因此,高精度施工线形预测是确保桥梁施工质量的关键<sup>[3-4]</sup>。

目前桥梁线形预测主要依赖最小二乘法、灰色理论法和有限元数值模拟等方法<sup>[5-7]</sup>。最小二乘法对数据分布要求严格,难以处理非线性时变工况;灰色理论法适用于小样本预测,但对参数敏感性高,泛化能力不足;有限元法虽能模拟复杂边界条件,但计算效率低且依赖精确的材料本构模型且有限元模型建模周期相对较长、材料参数单一、运算量大,难以满足适应施工参数的实时变化。

近年来,机器学习方法在桥梁施工挠度预测中展现出优势。其通过数据驱动建模,能够挖掘施工参数与线形响应的非线性映射关系,降低对机理模型的依赖。现有研究表明,机器学习方法在桥梁结

构健康监测<sup>[8]</sup>、损伤识别与定位<sup>[9-10]</sup>、混凝土材料强度预测<sup>[11]</sup>以及病害智能诊断<sup>[12-13]</sup>等方面均取得了突破性应用成果。相较于传统基于物理机理的计算方法,机器学习方法核心优势在于其能够通过自适应学习机制,自主构建输入参数与输出响应之间的复杂非线性映射关系,而无需依赖精确的数学解析模型或繁琐的本构方程<sup>[14]</sup>。这种特性使其特别适用于解决工程实践中存在显著不确定性的复杂问题。对于桥梁施工方面,L. Wang等<sup>[15]</sup>将BP算法应用于连续刚构桥施工建造之中,为此类桥梁施工预测提供指导,周双喜等<sup>[16]</sup>基于思维进化算法优化的极限学习机模型,对大跨度连续刚构桥施工过程中的立模高程进行预测。其研究成果为桥梁施工线形控制提供了有效的技术手段,具有重要的工程应用价值。

以上研究结果表明机器学习方法可有效应用于桥梁施工当中,且研究结果对于实际施工问题具有较高的参考价值。然而,上述研究未考虑施工阶段各材料参数的离散型,仅考虑单一参数下桥梁挠度的预测,本文考虑在不同施工阶段各材料参数离散型特征,通过将材料参数输入有限元模型进行计算得到相应的挠度值,形成数据库并选取四种算法进行训练,探究各算法对桥梁施工挠度的预测性能并根据评价结果进行模型比选,以期为该类型桥型的设计与施工提供参考。

# 1 数据库的形成

## 1.1 工程背景

以山西省某高速公路桥梁为研究对象,该桥梁的主跨结构设计为(45+2×80+45)m,两条行车道宽23 m,两条防撞护栏长1 m,主梁设计采用单箱单室变截面连续箱梁,其中边跨部分的箱梁顶宽为12.5 m,底宽为7.0 m,悬臂长度为2.75 m。合龙段梁高2.5 m,横向布置包括两条11.5 m宽的行车道和两条0.5 m宽的防撞护栏。主梁设计采用单箱单室变截面连续箱梁,其中边跨部分的箱梁顶宽为12.5 m,底宽为7.0 m,悬臂长度为2.75 m。合龙段梁高2.5 m,顶板和底板的厚度均为0.3 m。0号块中心高度为5.0 m,顶板厚度为0.5 m,底板厚度为0.8 m。从悬臂端到0号块根部,箱梁的高度按二次函数变化。使用MIDAS Civil软件建立全桥有限元模型,如图1所示。




图1 桥梁有限元模型

Fig.1 Finite element model of bridge

该桥主梁和下部结构均采用梁单元建模,全桥模型包含227个节点和191个单元,施工过程划分为45个施工阶段。由于采用对称悬臂施工工艺,分析时选取5号墩中跨T构作为研究对象。桥梁0号块长9.0 m,合龙现浇段长度2 m,悬臂部分由10个节段组成,节段长度依次为4 m、3.5 m和3 m。施工方案为:0号段采用支架/托架现浇,1~10号节段采用挂篮悬臂浇筑,边跨现浇段通过桥墩托架施工。每个悬臂现浇梁段包含四个施工工序:挂篮安装移动及立模、混凝土浇筑、结构强度形成、预应力钢束张拉。具体悬臂浇筑划分如图2所示。

为验证所建立有限元模型的准确性,将桥梁施工过程中的挠度实测数据与有限元模拟计算结果进行对比分析,结果如图3所示。




图2 悬臂浇筑分段

Fig.2 Cantilever casting segments (cm)




图3 有限元与实测值对比

Fig.3 Comparison between FEM results and field measurements

根据图3所示的对比分析结果,实测数据与有限元计算结果呈现出良好的吻合性,其最大相对误差控制在5%以内。研究表明,该有限元模型能够有效预测施工期桥梁结构的实际受力状态,为后续施工控制提供了可靠的理论依据。图3中橙色线条将前5桥梁节段施工所产生挠度与后5桥梁节段施工所产生挠度进行划分,可明显展示出随桥梁节段施工所产生挠度的变化情况。由图3可知,在连续刚构桥施工的初始阶段,由于结构整体刚度较大,各施工参数随节段推进的变化对挠度影响相对较小,误差累积效应难以准确表征。为确保机器学习算法的训练效果,需积累充分的样本数据。此处选择能够有效反映施工挠度的时变特征的桥梁施工节段,其长度 $d$ 与悬臂长度 $L$ 的比值( $d/L$ )分别为0.233、0.216、0.178、0.151和0.131,对应桥梁后5节段,这些桥梁施工节段能够有效反映施工挠度的时变特征。

## 1.2 数据获取

在连续刚构桥施工过程中,施工荷载的时变特性与材料参数的随机性共同作用,导致桥梁结构挠度呈现显著的非确定性变化,根据文献研究成果<sup>[17-18]</sup>,连续刚构桥施工挠度主要受以下几个参数影响:混凝土容重( $\gamma_c$ )、混凝土弹性模量( $E_c$ )、张拉控制应力( $\sigma$ )、施工均布荷载( $P$ )、系统温度( $T$ )。由于实际施工时环境的复杂性与不确定性,上述参数实际数值与设计数值产生偏差,因此,将上述参数

值作为主要的变化参数。此外为模拟桥梁施工过程中各施工节段的变化引入悬臂梁节段长度与悬臂长度之比( $d/L$ )作为决定性参数,由此得出各个桥梁施工节段的挠度值。

为准确模拟施工过程中各影响参数的随机特性,假设各参数在实际施工工况下的取值服从正态分布,并确定其分布数值。由文献[19]可知服从正态分布且位于区间  $[\mu - 2.5\sigma, \mu + 2.5\sigma]$  的概率为 99.38%。根据规范<sup>[20]</sup>对各影响参数选择五个分布水平,分别为  $\mu - 2.5\sigma, \mu - \sigma, \mu, \mu + \sigma, \mu + 2.5\sigma$ 。影响参数具体数值范围如表 1 所示。

对表 1 中各影响参数值采用拉丁超立方采样(LHS)选取不同材料数值,以模拟在桥梁实际施工状态中的各影响参数的不同情况,将所得到的影响

表 1 影响参数的确定分布数值

Table 1 Distribution parameters of influential factors

变量	均值 $\mu$	标准误差 $\sigma$	分布类型	标注
$\gamma_c/(\text{kN}\cdot\text{m}^{-3})$	26	1.04	正态分布	混凝土容重
$E_c/\text{GPa}$	34.5	2.38	正态分布	混凝土弹性模量
$\sigma/\text{MPa}$	1 395	55.8	正态分布	张拉控制应力
$T/^\circ\text{C}$	15	2.5	正态分布	系统温度
$P/(\text{N}\cdot\text{m}^{-2})$	117.85	5.892	正态分布	均布荷载

参数数值作为参数输入有限元模型中,通过计算得到不同影响参数值对应不同节段施工所产生的挠度,并探究各个变量对桥梁挠度的影响幅值,通过有限元模型计算共得到 515 组数据,从计算数据中选取部分计算结果,如表 2 所示。

表 2 关键参数及挠度计算结果

Table 2 Key parameters and deflection calculation results

编号	弹性模量 $E_c/$ GPa	混凝土容重 $\gamma_c/$ ( $\text{kN}\cdot\text{m}^{-3}$ )	预应力 $\sigma/\text{MPa}$	施工均布荷载 $P/$ ( $\text{N}\cdot\text{m}^{-2}$ )	温度 $T/^\circ\text{C}$	$d/L$	挠度 $D_z/\text{mm}$
1	28.33	23.4	1 255.5	0.103 12	2.5	0.233	-2.892 21
2	28.33	24.96	1 395	0.123 74	27.5	0.216	-5.565 5
3	28.33	26	1 534.5	0.111 96	20	0.178	-8.698 88
4	28.33	27.64	1 339.2	0.132 58	15	0.151	-13.883 4
5	28.33	28.6	1 450.8	0.117 85	10	0.131	-22.794 6
6	32.03	23.4	1 534.5	0.123 74	15	0.131	-16.727 5
7	32.03	24.96	1 339.2	0.111 96	10	0.233	-2.823 97
8	32.03	26	1 450.8	0.132 58	2.5	0.216	-5.276 83
9	32.03	27.64	1 255.5	0.117 85	27.5	0.178	-8.465 63
10	32.03	28.6	1 395	0.103 12	20	0.151	-13.059 6
11	34.50	23.4	1 450.8	0.111 96	27.5	0.151	-9.753 33
12	34.50	24.96	1 255.5	0.132 58	20	0.131	-16.977 3
13	34.50	26	1 395	0.117 85	15	0.233	-2.792 94
14	34.50	27.64	1 534.5	0.103 12	10	0.216	-5.331 2
15	34.50	28.6	1 339.2	0.123 74	2.5	0.178	-8.276 6
16	36.97	23.4	1 395	0.132 58	10	0.178	-6.199 71
17	36.97	24.96	1 534.5	0.117 85	2.5	0.151	-9.921 52
18	36.97	26	1 339.2	0.103 12	27.5	0.131	-16.834 6
19	36.97	27.64	1 450.8	0.123 74	20	0.233	-2.841 87
20	36.97	28.6	1 255.5	0.111 96	15	0.216	-5.284 76
21	40.68	23.4	1 339.2	0.117 85	20	0.216	-3.879 5
22	40.68	24.96	1 450.8	0.103 12	15	0.178	-6.184 81
23	40.68	26	1 255.5	0.123 74	10	0.151	-9.776 45
24	40.68	27.64	1 395	0.111 96	2.5	0.131	-16.773 4
25	40.68	28.6	1 534.5	0.132 58	27.5	0.233	-2.752 37

### 1.3 参数敏感性分析

为确定各项参数对桥梁施工挠度的影响,对各项参数进行敏感性分析,所选试验数据如表2所示,通过有限元模型计算得到不同参数组合下的桥梁施工挠度响应值,利用公式(1)计算正交试验所对应结果。

$$\begin{cases} R_j = \max\{K_{1j}, K_{2j}, \dots, K_{nj}\} - \min\{K_{1j}, K_{2j}, \dots, K_{nj}\} \\ K_{ij} = \frac{1}{n} \sum_{i=1}^n Y_i \end{cases} \quad (1)$$

式中,  $K_{ij}$  为参数  $J$  在  $i$  水平下的平均值;  $n$  为参数  $J$  在  $i$  水平下的测试数量;  $Y_i$  为第  $i$  个响应值。

通过  $R_j$  的值来判断参数敏感性,结果如图4所示,由图4可看出各个参数对连续刚构桥施工挠度的影响程度,其中影响最大的为决定参数  $d/L$ ,其次是张拉控制应力  $\sigma$ 、混凝土容重  $\gamma_c$ 、混凝土弹性模量  $E_c$ ,系统温度  $T$  以及施工均布荷载  $P$  影响较小。




图4  $R_j$ 直方图

Fig.4 Histogram of  $R_j$

### 1.4 数据处理

根据有限元模型计算所得数据库进行算法的训练,将  $\gamma_c$ 、 $E_c$ 、 $\sigma$ 、 $P$ 、 $T$  以及  $d/L$  作为输入参数,桥梁施工挠度  $D_z$  作为输出参数。本文共选取 515 组数据对不同算法进行训练,其中训练集数据 450 组,测试集数据 65 组。

由于不同参数对桥梁施工挠度计算结果的影响程度不同,在算法训练前需对数据库中数据进行归一化处理,以获得更好的训练效果,本文采用 Min-Max 方法进行归一化处理(式(2))。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

式中,  $x$  为原始数据;  $x_{\min}$  为数据最小值;  $x_{\max}$  为数据最大值;  $x'$  为归一化的数据,值域在  $[0 \sim 1]$ 。

## 2 机器学习算法基本原理

为比较不同机器学习算法对桥梁施工挠度的预测性能,本文选择四种不同的机器学习算法并采用相同数据库进行训练,各算法训练成熟后可对桥梁施工期挠度进行预测,各机器学习算法原理如下。

### 2.1 长短期记忆网络(LSTM)

长短期记忆网络(Long Short-Term Memory, LSTM)是一种特殊的循环神经网络,用于解决长序列中的长期依赖问题。它通过引入门机制,控制信息的流入、保留和输出,从而在避免梯度消失或爆炸的情况下捕获较长序列的依赖关系。

LSTM 通过引入细胞状态和门控单元来控制信息流动,具体包含以下几个部分:

#### (1) 遗忘门

遗忘门决定了上一个时间步的细胞状态是否需要保留或遗忘。遗忘门通过一个 sigmoid 激活函数  $Q$  (输出在 0 和 1 之间) 来控制。输入为当前输入  $x_t$  和上一个隐藏状态  $h_{t-1}$ , 计算公式为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

式中,  $\sigma$  为逻辑激活函数;  $W_f$  和  $b_f$  分别为遗忘门的权重矩阵和偏置项;  $[h_{t-1}, x_t]$  是前一时间步的隐藏状态和当前时间步的输入。

#### (2) 输入门

输入门决定当前时间步的新信息是否要更新到细胞状态中,它包含两个部分,见公式(4)、(5):

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

式中,  $i_t$  为输入门的输出;  $\tilde{C}_t$  为候选记忆单元状态;  $W_i$ 、 $W_c$  和  $b_i$ 、 $b_c$  分别是相关权重和偏置。

#### (3) 细胞状态更新

细胞状态结合了遗忘门和输入门的输出来更新,计算公式为:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (6)$$

#### (4) 输出门

输出门控制 LSTM 的最终输出,即新的隐藏状态  $h_t$ 。它将新的细胞状态  $t$  调整后输出,计算公式为:

$$o_i = \sigma(W_o \cdot [h_{i-1}, x_i] + b_o) \quad (7)$$

$$h_i = o_i \cdot \tanh(C_i) \quad (8)$$

式中,  $o_i$  为输出门 sigmoid 函数的输出;  $C_i$  为更新后的记忆单元状态;  $h_i$  为最终的隐藏状态输出。

## 2.2 粒子群优化反向传播(PSO-BP)

BP(Back Propagation)神经网络作为一种经典的多层前馈神经网络,通过误差反向传播机制实现参数优化,具有结构简单、实现方便等优点。该算法采用前向传播计算输出误差,再通过反向传播梯度更新网络参数,经过多次迭代直至收敛。然而,该算法存在三个显著局限性:首先,深层网络训练时易出现梯度消失问题;其次,优化过程容易陷入局部最优解;最后,其收敛速度较慢且对学习率参数敏感,这些缺陷限制了其在复杂工程问题中的应用效果。

为克服BP神经网络的上述不足,本文引入粒子群优化算法(Particle Swarm Optimization, PSO)进行改进。PSO是一种模拟鸟群觅食行为的群体智能优化算法,其基本流程如图5所示。该算法通过在解空间中初始化一组“粒子”(即候选解),在迭代过程中,每个粒子根据个体历史最优解(pbest)和群体全局最优解(gbest)动态调整其位置和速度。具体而言,粒子的速度和位置更新计算遵循式(9)和式(10)所示的数学模型。

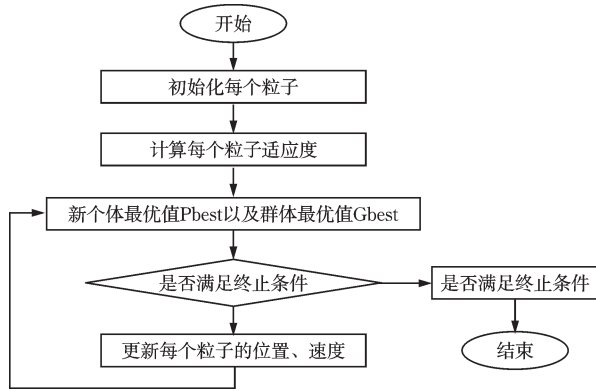


图5 粒子群算法流程

Fig.5 Particle swarm algorithm flowchart

$$V_{id}^{k+1} = \omega V_{id}^k + C_1 r_1 (P_{id}^k - X_{id}^k) + C_2 r_2 (G_{id}^k - X_{id}^k) \quad (9)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (10)$$

式中,  $i=1, 2, \dots, N$ ,  $N$  为粒子群规模;  $d=1, 2, \dots, D$  为搜索维度;  $P$  为粒子群个体中的最优解值;  $G$  为整

体粒子群的全局最优解值;  $k$  为当前迭代次数;  $V_i = \{V_{i1}, V_{i2}, \dots, V_{iD}\}$  为第  $i$  个粒子的速度矢量;  $X_i = \{X_{i1}, X_{i2}, \dots, X_{iD}\}$  为第  $i$  个粒子的位置矢量;  $\omega$  为惯性权重;  $C_1, C_2$  为学习因子,其数值大小的设置会影响全局及局部搜索能力。

PSO算法通过群体协作机制实现高效搜索,在各类优化问题中展现出良好的性能。具体算法流程如图5所示。

采用基于粒子群优化算法(PSO)来优化BP神经网络模型,通过将两种算法相结合,能够有效克服各自算法的局限性。利用粒子群算法的全局搜索能力,可以高效地寻找最优解,优化神经网络的连接权重和偏置,同时提升整体搜索效率。此外,结合BP神经网络的局部搜索能力,能够使搜索过程更加精细。将这两种算法结合使用,可以在全局和局部范围内同时寻找最优解,从而显著提升神经网络的性能。

## 2.3 随机森林(RF)

随机森林(Random Forest, RF)是一种基于集成学习框架的机器学习算法,其核心特征在于融合了随机子空间和随机分裂选择机制。该算法采用Bootstrap重采样技术,通过有放回抽样从原始数据集中生成多个差异性训练子集,并运用随机子空间方法构建各子集对应的决策树模型。在模型集成阶段,RF算法通过聚合分析大量决策树的预测结果获得最终输出。对于回归问题,其预测结果为所有基决策树输出的算术平均值计算方法见公式(11),这种集成策略有效提升了模型的泛化能力和预测稳定性。

$$\bar{H}(x) = \frac{1}{k} \sum_{i=1}^k [h_i(x = Y)] \quad (11)$$

式中,  $\bar{H}(x)$  为组合随机森林模型;  $h_i(x)$  为单颗决策树模型;  $Y$  为输出结果;  $k$  为决策树数量。

## 2.4 极限学习机(ELM)

极限学习机(Extreme Learning Machine, ELM)是一种高效的单隐层前馈神经网络算法。其特点在于:随机初始化输入层参数后,直接通过广义逆矩阵求解输出层权重,省去了传统反向传播的迭代过程。这种方法不仅训练速度快,还具有良好的泛化能力,特别适合处理大规模数据建模问题。具体地对于训练集  $T = (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ ,

我们将输入样本  $X = x_1, x_2, \dots, x_n$ , 通过某种函数, 如 sigmoid 函数或 ReLU 函数, 映射到高维特征空间, 得到新的输入矩阵  $H = [h_{ij}]_{K \times n}$ ,  $h_{ij} = g(z_k)$ ,  $g(z_k)$  为隐含层第  $K$  个神经元的激活函数。随机初始化隐含层与输出层之间的连接权重  $W_{K \times m}$ , 其中  $m$  为输出层神经元数, 即样本类别数。用矩阵表示, 输出层的输出  $Y = [y_i]_{m \times n}$  可表示为  $Y = W \cdot H$ 。

### 2.5 评价标准

采用 MAE(平均绝对误差)、RMSE(均方根误差)、 $R^2$ (拟合优度) 三个统计指标评估预测数据的质量, 评价标准具体计算公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

式中,  $\bar{y}$  为  $n$  个样本平均值;  $y_i, \hat{y}_i$  分别为预测样本实际值和预测值。

## 3 结果分析

### 3.1 模型评价

本文基于 MATLAB 2023b 数值计算平台完成了各智能算法的程序实现与模型训练。经充分训练后, 所建立的预测模型可有效应用于桥梁施工挠度的实时预测。各算法在训练集和测试集上的性能评估结果如图 6、7 所示。

由图 6、图 7 的数值分析结果表明, 所有算法的训练集与测试集拟合优度 ( $R^2$ ) 均达到 0.95 以上, 满足工程预测的精度标准 ( $R^2 \geq 0.90$ ), 这表明各预测

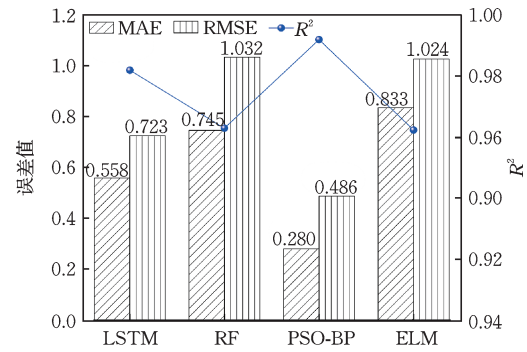


图 6 训练集预测结果

Fig.6 Prediction results of training set




图 7 测试集预测结果

Fig.7 Prediction results of test set

模型均实现了理想的训练效果。从预测性能的量化指标来看, PSO-BP 算法展现出最优异的预测能力, 其训练集和测试集的均方根误差 (RMSE) 分别为 0.486 和 0.316, 显著优于其他算法。特别是该算法在测试集上的预测结果与实际监测数据表现出高度一致性, 其最大相对误差不超过 3.5%, 充分验证了该算法在桥梁线形预测中的可靠性和准确性。LSTM 算法次之, 其训练集和测试集的 RMSE 分别为 0.723 和 0.629, 预测值与实测值仍保持较好的吻合度。相比之下, ELM 和 RF 算法的预测误差相对较大, 其训练集和测试集的 RMSE 分别为 1.02、1.087 和 1.032、1.134。各算法的预测性能指标如表 3 所示。

表 3 各算法评价标准值

Table 3 Performance metrics of compared algorithms

算法	训练集			测试集		
	$R^2$	MAE	RMSE	$R^2$	MAE	RMSE
LSTM	0.981 72	0.557 68	0.723 12	0.984 37	0.546 02	0.629 17
RF	0.962 79	0.744 62	1.031 60	0.959 20	0.835 73	1.134 20
PSO-BP	0.991 73	0.279 75	0.486 48	0.996 05	0.234 41	0.316 18
ELM	0.962 16	0.832 83	1.024 40	0.962 29	0.882 75	1.088 70

### 3.2 预测结果分析

算法训练成熟后对所选中跨T构的6~10节段进行不同影响参数下的施工挠度预测,从数据库中随机选取25组数据进行预测,并通过有限元模型计算结果进行对比以验证预测数据的准确性,为更加准确地反映各算法的预测精度引入预测挠度的相对误差百分比,对本文不同算法所产生的预测误差进行对比。不同算法预测挠度值及其相对误差如图8所示。

由图8可知,在施工节段挠度预测中,相较于其他算法,PSO-BP算法预测性能最优,最大预测误差仅0.55 mm,预测相对误差始终控制在10%以内,且表现出良好的稳定性,表明 PSO-BP算法能够更精确地预测桥梁施工节段的挠度变形。LSTM算法也可实现对桥梁挠度的预测,最大预测误差为1.22 mm,相对误差小于20%,性能仅次于 PSO-BP算法。相比之下,RF算法和ELM算法虽然在训练阶段满足精度要求,但在实际预测中存在明显不足:首先,两者的预测误差显著增大(最大相对误差分别为34.65%和31.71%);其次,预测结果表现出不稳定性。定量分析表明,RF和ELM算法的预测

准确度明显低于 PSO-BP 和 LSTM 算法。综合比较四种机器学习算法在中跨数据集上的性能表现,其优劣排序为:PSO-BP>LSTM>ELM>RF。

针对桥梁中跨T构桥梁施工节段挠度进行预测分析,各算法预测结果如图9所示,各算法预测结果与实测值所产生误差如图10所示。由图可知,PSO-BP算法和LSTM算法的预测结果与实际监测值最为接近,且产生误差最小,预测精度较高,能够满足实际工程应用需求。相比之下,ELM和RF算法在1~8节段的预测效果尚可,但在9~10节段的预测值普遍低于实际监测值,且产生误差相对较大。这种预测偏差可能导致施工过程中无法准确预估结构变形,进而影响桥梁线形控制和合龙精度。因此,在实际工程应用中,应优先考虑预测精度更高的算法,并特别注意预测值偏小的情况,以确保施工控制质量。

在工程预测领域,各类机器学习算法均具有特定的适用范围和固有的技术局限性,尚不存在适用于所有预测场景的通用解决方案。本文通过系统对比随机森林(RF)、长短期记忆网络(LSTM)、粒子群优化反向传播网络(PSO-BP)以及极限学习机(ELM)四种算法在连续刚构桥施工挠度预测中的

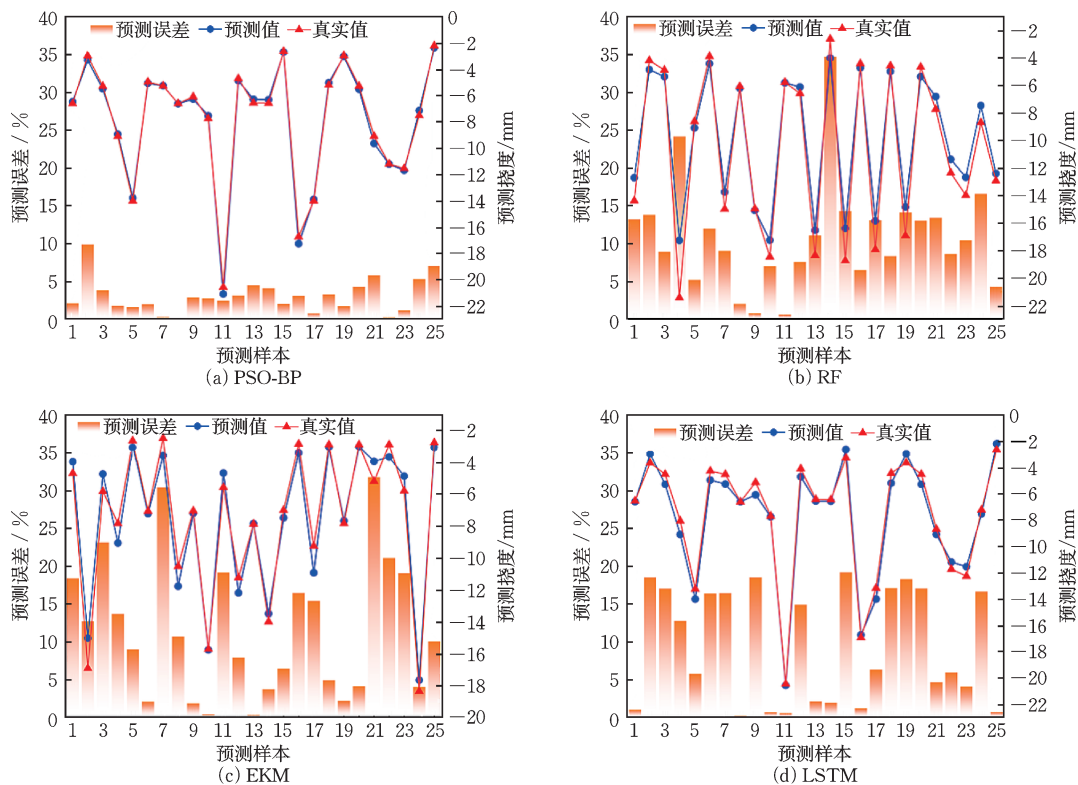


图8 不同算法预测结果

Fig.8 Prediction results of different algorithms

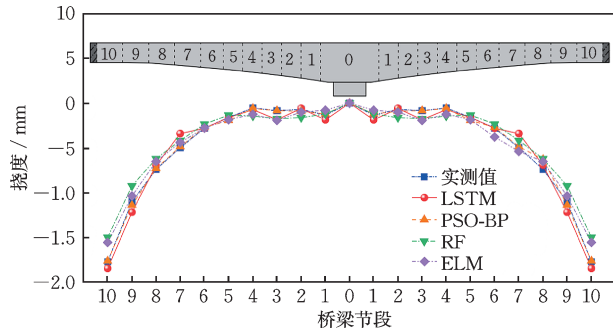


图9 桥梁施工挠度预测

Fig.9 Predicted deflection during bridge construction




图10 桥梁施工挠度预测误差

Fig.10 Deflection prediction errors during bridge construction

表现,验证了其工程适用性。结果表明,所采用的算法模型均展现出良好的泛化性能,能够将训练获得的知识迁移到新的数据集中进行有效预测。进一步分析发现,不同算法在性能表现上存在显著差异:SVM在小样本情况下表现优异但核函数选择依赖经验;RF抗噪声能力强但可解释性较差;LSTM擅长处理时序数据却需要大量训练样本;PSO-BP收敛速度快但可能陷入局部最优;ELM训练效率高但对异常值敏感。因此,在实际工程应用中,需要根据具体问题的数据特征、精度要求和计算资源等因素,选择最适合的预测方法。

## 4 结论

(1)提出了考虑多参数耦合影响的挠度预测方法。以混凝土容重、弹性模量、张拉控制应力、施工荷载和系统温度等关键施工参数作为输入变量,以连续刚构桥施工期各节段挠度为输出,建立机器学习预测模型,系统量化了各参数在施工过程中的动态变化对结构挠度的影响规律。

(2)结合现场实测挠度数据,对比分析了四种机器学习算法的预测性能发现,相较于其他三种算

法,PSO-BP算法表现出最优的预测精度,其训练集和测试集的RMSE值分别低至0.486和0.316,拟合优度分别达0.996和0.992,预测误差为0.55 mm,相对误差小于10%,验证了该算法在连续刚构桥施工期挠度预测中的可靠性。

(3)将训练完成的预测模型应用于实际梁段施工挠度预测,结果显示预测值与实测值吻合良好。该方法可为施工过程中的线形调整提供实时指导,确保桥梁合龙精度,推动桥梁施工线形控制向智能化方向发展。

## 参考文献:

- [1] 王衍英,冉文兴,吴奇峰.公路大跨度连续梁悬臂浇筑与现浇设计方案比较分析[J].公路,2023,68(8):137-141.  
Wang Y Y, Ran W X, Wu Q F. Comparative analysis of cantilever casting and cast-in-place design schemes for long-span continuous beams on highways [J]. Highway, 2023, 68(8): 137-141. (in Chinese)
- [2] Liu Y, Zheng C M, Ba H Q, et al. Analysis on the influence factors of construction linear control of continuous rigid structure bridge [J]. E3S Web of Conferences, 2021, 237: 03020.
- [3] Zheng X L, Guan D. Study on construction monitoring and control of multi-span prestressed concrete continuous beam bridge [J]. Stavební Obzor - Civil Engineering Journal, 2024, 33(1): 65-77.
- [4] Dehua L, Xu D, Kaiyue G, et al. Research of construction monitoring technology of large-span variable cross-section prestressed concrete continuous box-girder bridge [J]. Academic Journal of Architecture and Geotechnical Engineering, 2022, 4(3): 31-36.
- [5] 胡斌,李庆泽.灰色预测在大跨径刚构桥施工线形监控中的应用[J].铁道建筑,2020,60(5):38-42.  
Hu B, Li Q Z. Application of gray prediction method in construction controlling of long span rigid frame bridge [J]. Railway Engineering, 2020, 60(5): 38-42. (in Chinese)
- [6] Wan L J, Qiao J Q, Sun Q S, et al. Construction control of rigid frame-continuous girder bridge based on grey theory [J]. Journal of Engineering and Applied Science, 2024, 71(1): 171.
- [7] 宋晓东,颜永逸,李佳靖,等.基于子结构的大型桥梁有限元模型修正方法[J].桥梁建设,2021,51(2):40-46.  
Song X D, Yan Y Y, Li J J, et al. Substructure-based

- finite element model updating of long-span bridge [J]. *Bridge Construction*, 2021, 51(2): 40-46. (in Chinese)
- [8] 张建龙, 赵东月, 栗怡文, 等. 基于神经网络的桥梁健康监测与预警平台研究[J]. *计算机技术与发展*, 2022, 32(4): 205-209.  
Zhang J L, Zhao D Y, Li Y W, et al. Research on bridge health monitoring and alarming platform based on neural network [J]. *Computer Technology and Development*, 2022, 32(4): 205-209. (in Chinese)
- [9] 单德山, 石磊, 谭康熹. 联合卷积神经网络与长短期记忆深度网络的桥梁损伤识别[J]. *桥梁建设*, 2023, 53(4): 41-46.  
Shan D S, Shi L, Tan K X. Bridge damage identification based on joint CNN and LSTM deep network [J]. *Bridge Construction*, 2023, 53(4): 41-46. (in Chinese)
- [10] 石林泽, 程斌, 董华能, 等. 基于卷积神经网络的钢桥面板疲劳裂纹识别方法研究[J]. *桥梁建设*, 2023, 53(4): 62-69.  
Shi L Z, Cheng B, Dong H N, et al. Research on fatigue crack identification for steel bridge deck plates based on convolutional neural network [J]. *Bridge Construction*, 2023, 53(4): 62-69. (in Chinese)
- [11] 黄彩萍, 谢鑫, 周永康, 等. 基于改进掩码-区域卷积神经网络的混凝土病害实例分割[J]. *桥梁建设*, 2023, 53(6): 63-70.  
Huang C P, Xie X, Zhou Y K, et al. Instance segmentation of concrete defects based on improved mask-RCNN [J]. *Bridge Construction*, 2023, 53(6): 63-70. (in Chinese)
- [12] 冯琼, 谢晓扬, 王鹏辉, 等. 基于鲸鱼优化算法-反向传播神经网络的钢筋混凝土耐久性预测[J]. *吉林大学学报(工学版)*, 2025, 55(7): 2276-2285.  
Feng Q, Xie X Y, Wang P H, et al. Prediction of reinforced concrete durability based on whale optimization algorithm-back propagation neural network [J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2025, 55(7): 2276-2285. (in Chinese)
- [13] 林友勤, 郑学善, 余印根, 等. 基于BP神经网络的斜拉索损伤识别方法[J]. *南昌大学学报(工科版)*, 2023, 45(4): 370-376.  
Lin Y Q, Zheng X S, Yu Y G, et al. Damage identification method for stay cable based on BP neural network [J]. *Journal of Nanchang University (Engineering & Technology)*, 2023, 45(4): 370-376. (in Chinese)
- [14] Kaveh A. *Applications of artificial neural networks and machine learning in civil engineering* [M]. Cham: Springer Nature Switzerland, 2024.
- [15] Wang L, Xiao Z, Wang X. The application of BP neural network in continuous girder bridge construction control[C]//*Proceedings of the 30th Chinese Control Conference*. Yantai, China: IEEE, 2011: 2661-2664.
- [16] 周双喜, 邓芳明, 韩震, 等. 基于优化极限学习机的大跨径连续桥梁施工线形预测[J]. *铁道学报*, 2019, 41(3): 134-140.  
Zhou S X, Deng F M, Han Z, et al. The construction linear prediction of long-span continuous girder based on improved extreme learning machine [J]. *Journal of the China Railway Society*, 2019, 41(3): 134-140. (in Chinese)
- [17] Zheng H B, Yu X L, Hu J L, et al. Parameter sensitivity analysis of vertical deflection for long-span continuous rigid-frame bridge [J]. *Advanced Materials Research*, 2010, (163-167): 1500-1504.
- [18] Ma Y R, Chen H B, Han Q W. Sensitivity analysis of factors affecting down deflection of long-span continuous rigid frame bridge [J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 781(2): 022048.
- [19] Tong Y L. *The multivariate normal distribution* [M]. New York, NY: Springer New York, 1990.
- [20] *公路工程结构可靠度设计统一标准: TG 2120—2020* [S]. 北京: MTPRC, 2020.

(本文编辑: 池营营)