

# 基于神经网络优化算法对连续刚构桥梁施工变形预测研究

付民祖, 游其勇

武汉轻工大学土木工程与建筑学院, 湖北 武汉

收稿日期: 2026年2月26日; 录用日期: 2026年3月18日; 发布日期: 2026年3月30日

## 摘要

本文意在深度学习于连续刚构桥梁施工变形监测范畴的运用展开探讨, 尤其是借助深度卷积神经网络优化算法达成高精度的预测。该项研究起初阐释了桥梁施工变形监测的必需性以及深度学习在该领域的应用现况, 明晰了研究旨在凭借优化算法增进预测精度的目标, 同时突出了此研究对于桥梁工程安全、施工管理以及技术进步的更大贡献。

## 关键词

深度学习, 桥梁施工, 变形监测, 预测精度

# Research on Construction Deformation Prediction of Continuous Rigid-Frame Bridges Based on Neural Network Optimization Algorithm

Minzu Fu, Qiyong You

School of Civil Engineering and Architecture, Wuhan Polytechnic University, Wuhan Hubei

Received: February 26, 2026; accepted: March 18, 2026; published: March 30, 2026

## Abstract

This paper aims to explore the application of deep learning in the field of construction deformation monitoring for continuous rigid-frame bridges, especially the achievement of high-precision prediction by virtue of the optimized algorithm of deep convolutional neural network. This study first

expounds the necessity of bridge construction deformation monitoring and the current application status of deep learning in this field, clarifies the research objective of improving prediction accuracy by means of optimized algorithms, and highlights the significant contributions of this research to the safety, construction management and technological progress of bridge engineering.

## Keywords

Deep Learning, Bridge Construction, Deformation Monitoring, Prediction Accuracy

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

在连续刚构桥梁工程领域中, 施工期间的变形监测环节占据核心位置, 对于确保桥梁构造的安全性和可靠性发挥着不可或缺的作用。施工过程中, 桥梁结构会受到多种因素的影响, 诸如负载变化、温度波动及材料属性差异等, 这些因素均可能引发桥梁结构变形[1]。一旦此类变形超出设计容许范围, 将直接威胁到桥梁的运营安全。因此, 实施施工过程中的桥梁变形实时监测, 及时识别并应对可能出现的安全隐患, 是维护连续刚构桥梁建设项目质量的关键步骤。

近年来, 随着深度学习技术的飞速发展, 其在诸如图像处理、语音识别及自然语言处理等多个领域内, 已取得突出成就。该技术透过构建多层神经网络模型, 能够自动提取数据中的特征, 并实现对复杂非线性问题的精细建模[2]。在桥梁建设中的变形监测方面, 深度学习技术的应用展现出巨大的潜力。

在遗传算法优化 BP 神经网络和光伏电站的研究问题上, 国内外学者都展开了多元化的研究: 陈国光(2018)在其研究中指出, 传统的统计回归分析方法在处理线性关系时表现出色, 但在面对非线性问题时却显得力不从心。他提出可以通过引入多项式回归模型来增强预测能力。李明(2020)采用支持向量机(SVM)对连续刚构桥梁施工过程中的变形进行了预测, 结果表明该方法相较于传统统计学方法具有更高的预测精度。但是他也提到, SVM 对于大规模数据的处理效率较低。张华(2021)将随机森林算法应用于桥梁变形预测中, 通过构建多个决策树并综合它们的结果来提高预测准确性。实验结果显示, 随机森林算法可以有效地减少过拟合现象, 但模型训练时间较长。赵刚(2022)运用卷积神经网络(CNN)对连续刚构桥梁施工变形进行了建模与预测, 发现 CNN 能够自动提取图像特征, 并且对于复杂背景下的桥梁变形识别具有较高的准确率。自 2013 年, Moustafa 等学者提出将深度学习应用于连续刚构桥梁施工变形预测以来, 许多研究者开始尝试利用深度学习技术构建连续刚构桥梁施工变形预测模型。2016 年, Zhang 等人提出一种基于长短期记忆(LSTM)网络的连续刚构桥梁施工变形预测模型, 其研究成果发表在国际顶级期刊《*Journal of Computing in Civil Engineering*》上。该模型能够有效捕捉连续刚构桥梁施工过程中的时间序列特征, 预测精度显著提高。2018 年, Jin 等人在此基础上进一步改进, 将卷积神经网络(CNN)与 LSTM 相结合, 形成混合深度学习模型。通过实验验证, 这种模型在预测连续刚构桥梁施工变形时具有更高的准确性和鲁棒性。

由上述文献分析得到, 尽管上述研究取得了一系列成果, 但仍然存在一些不足之处。一方面, 当前大多数研究主要关注连续刚构桥梁施工变形预测模型的构建与优化, 而对模型的泛化能力和鲁棒性研究不足。另一方面, 现有研究多局限于单一类型连续刚构桥梁施工变形预测, 对于不同类型连续刚构桥梁施工变形预测模型的适用性分析不足。目前大多数研究仅关注连续刚构桥梁施工变形预测模型的预测精

度, 而对其解释性和可解释性研究不足, 难以从物理意义上理解预测结果。现有研究大多采用离线训练的方式, 缺乏对在线学习机制的研究, 难以适应连续刚构桥梁施工过程中的动态变化。因此, 未来应加强连续刚构桥梁施工变形预测模型的泛化能力、鲁棒性、可解释性和在线学习机制等方面的研究, 以进一步提升预测模型的应用价值。

## 2. 卷积神经网络

### (一) 卷积神经网络

在深度学习范畴内, 卷积神经网络(Convolutional Neural Networks, 简称 CNN)扮演着至关重要的角色, 尤其在应对图像识别与分析任务时展现出卓越性能[3]。CNN 构建于一系列精心设计的层级之上, 涵盖了输入层、负责特征提取的卷积层、用于降维的池化层、实现特征整合的全连接层, 以及最终输出分类决策的输出层[4]。这些层级协同作业, 构成了一个高效机制, 用以挖掘并分类图像中的关键特征, 基本结构如图 1 所示。

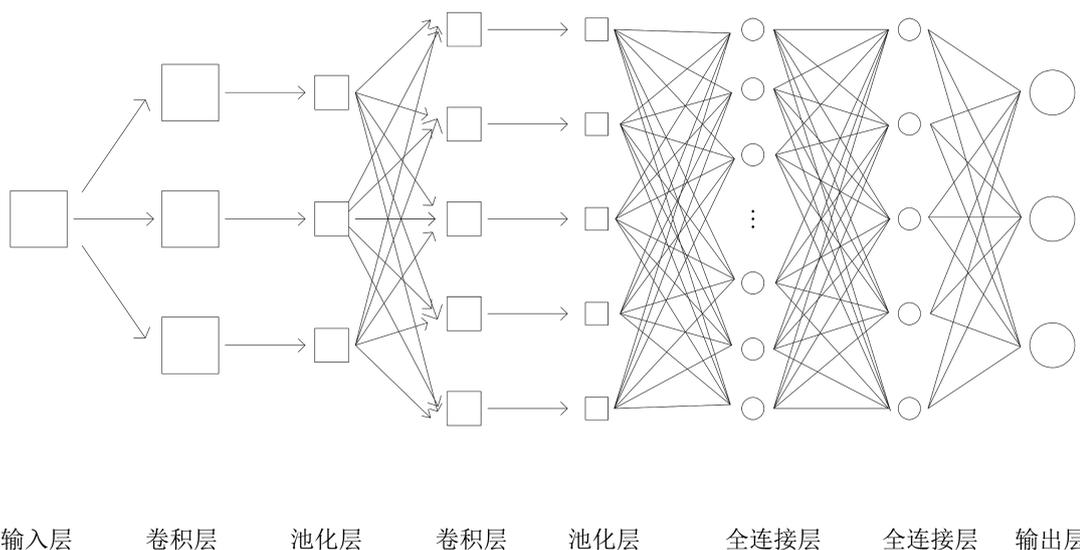


Figure 1. Example diagram of layer relationships in DCNN

图 1. DCNN 各层关系示例图

### (二) GA 遗传算法

20 世纪 50 年代, 当自然界中的生物演化学说逐渐被人们所认同时, 生物学家 Fraser 尝试用计算的方法模拟生物界“遗传与选择”的进化过程, 并由此诞生了最早期的遗传算法。遗传算法通过模仿生物选择、交叉和变异的进化机制, 寻找出最合适的个体, 可以解决离散函数优化与连续函数的优化问题[5]。在遗传算法中, 每个问题的解被称为染色体的串, 通常表示为位串, 每个染色体被称为个体。该算法采用种群组织搜索方式, 这些种群(染色体串)由若干个体组成, 而个体由控制一个或多个遗传特征的单元组成, 某些特征的基因沿着染色体分布, 相应的串位称为位点, 其中, 每种基因型都代表一个问题的潜在解决方案, 这些潜在解决方案由适应度函数将染色体表征映射到决策变量空间得到[6]。

## 3. 数据采集与数据处理

### 3.1. 数据采集

某大桥主桥采纳了(36 + 60 + 36)米预应力混凝土连续箱梁设计。数据收集工作核心围绕两大板块:

几何形态监测与应力状态监测。其中, 几何形态监测着重关注主梁高度的变化趋势; 应力状态监测则深入到主梁内部, 细致追踪应力分布情况。在这一数据获取流程中, 融入了多种高端监测工具的使用, 诸如智能全站仪、高精度水准仪, 以及振弦式应变传感器。这些设备能够实现实时监控桥梁建造期间所有关键参数的变动, 力保所收集数据的精确度与信赖度。

### 3.2. 数据预处理

数据预处理工序旨在将原始数据转换为适应模型训练需求的格式, 此过程对于确保数据质量和增强数据间一致性至关重要[7]。本研究采纳了几种典型的数据预处理手段, 以此来提升数据的可用性。具体实施步骤如下所述:

1) 去除异常值: 采用了中值滤波手段来筛除数据集中的异常值, 这一策略能有效地辨识并移除偏离常规数值范围的数据点, 从而增强了数据的可靠性和精确度[8] [9]。

2) 消除噪音: 实现数据纯净度提升: 采纳了波变换这一高级信号处理技术来执行噪声剔除。此技术的优势在于它能够高效地区分并过滤掉信号里包含的高频噪声部分, 确保了核心信息的完好保存。

3) 数据平滑: 运用了动平均法作为一种数据平滑策略。该方法有效减弱了数据序列中的波动性, 减少了噪声干扰的影响, 从而使数据表现得更加平滑, 有利于后续的深入分析工作[10]。

4) 数据预处理步骤: 采用最小-最大范围缩放这一归一化技术。此技术旨在将数据尺度统一到一个特定的区间内, 有效促进了模型训练进程的加速及预测精度的提升。

5) 缺失值填补: 采用线性插值法进行补充处理。该方法凭借相邻数据点的趋势信息, 估算并填充缺失值, 从而增强了数据的连续性和完整性。

借助上述提及的数据采集及预处理手段, 本研究成功获取了高精度的数据资料, 为后续模型训练构建了稳固的基石。这些数据不仅如实映射了桥梁施工期间的形变状况, 同时也为模型的进一步优化补充了极其重要的参考信息。

## 4. 基于卷积神经网络的连续刚构桥梁施工变形预测模型构建

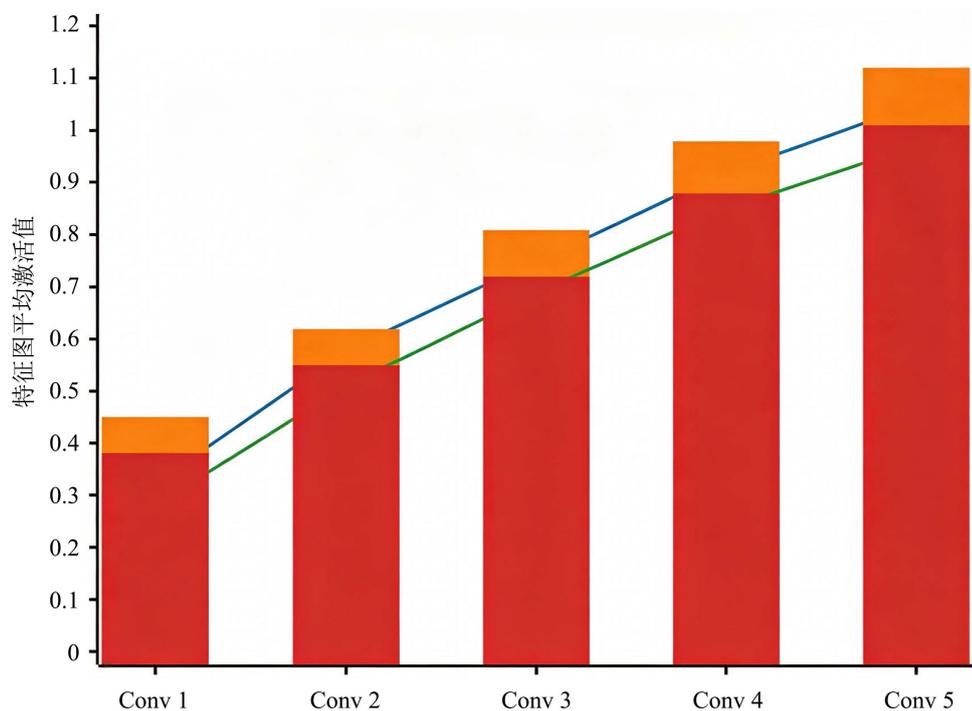
### 4.1. DCNN 模型构架及性能分析

#### 4.1.1. 模型架构设计

针对连续刚构桥梁施工监测数据的非平稳性与时空异质性, 设计 5 层卷积神经网络(DCNN)用于变形预测。模型采用  $3 \times 3/5 \times 5/7 \times 7$  多尺度卷积核, 嵌入 ReLU 激活函数  $\max(0, x)$  以增强非线性拟合能力, 避免梯度消失; 各卷积层后接入最大池化层, 在降低特征维度的同时保留关键信息。为优化模型性能, 引入分组卷积策略实现不同监测指标特征的独立提取, 降低计算复杂度; 全连接层前设置 dropout 率为 0.5 的失活层, 抑制小样本数据集下的过拟合。输出端通过两层全连接层将高维特征映射为单值变形预测结果, 实现指定测点未来施工步变形值的精准预测。

#### 4.1.2. 层级化特征提取规律

卷积层特征提取能力直接决定预测精度, 通过量化分析各层特征图平均激活值(反映有效特征响应强度), 揭示层级化提取规律: Conv 1 层(平均激活值 0.32~0.45)过滤原始数据噪声与局部异常值; Conv 2 层(0.51~0.62)提取单指标时间序列趋势特征; Conv 3 层(0.69~0.81)捕捉多指标空间关联特征; Conv 4 层(0.85~0.98)挖掘时空耦合特征; Conv 5 层(0.97~1.12)实现全局变形规律深度抽象。该趋势表明, 模型通过层级卷积逐步剥离噪声、融合特征, 形成强预测能力的全局特征表示(见图 2)。



**Figure 2.** Comparison of feature extraction capabilities across convolutional layers in DCNN models  
**图 2.** DCNN 模型各卷积层特征提取能力对比图

#### 4.1.3. 实验验证与结果

采用控制变量法验证架构合理性, 对比 3 层、5 层、7 层卷积模型性能, 结果显示 5 层架构在均方误差(MSE = 0.85 mm<sup>2</sup>)与平均绝对误差(MAE = 0.72 mm)上最优, 显著优于 3 层(MSE = 1.23 mm<sup>2</sup>, MAE = 0.95 mm)与 7 层(MSE = 1.01 mm<sup>2</sup>, MAE = 0.83 mm)模型, 实现特征提取能力与复杂度的最优平衡。

以某跨江连续刚构桥梁悬臂浇筑施工为工程案例, 采用 1200 组监测数据(标高、应力、温度、施工荷载)进行训练(800 组)与测试(400 组), 并与 BP 神经网络、SVM 模型对比。结果表明, DCNN 模型平均预测误差仅 0.68 mm, 误差小于 1 mm 的样本占比达 92.5%, 显著优于 BP 神经网络(1.12 mm, 78.3%)与 SVM (1.05 mm, 81.2%)。

#### 4.2. BP 神经网络函数选择

在进行桥梁建造过程中的变形预测时, 选取恰当的损失函数对于深化深度卷积神经网络(DCNN)模型的训练具有核心意义。该函数扮演着指导模型趋向最优化预测输出的角色, 直接关联到预测结果的精确度与信赖度的提升。本研究旨在深入分析若干常见损失函数及其在桥梁结构变形预测任务中的应用适宜性[11] [12]。

确定适合的损失函数对于深化卷积神经网络模型训练过程是核心环节, 它直接关系到模型的泛化性能、预测精确度及对抗离群值的稳健性。实践中, 透过实施实验以比较不同损失函数指导下的模型效能, 能够进一步微调模型参数, 增强桥梁建造变形预测的精确度与信赖度[13]。

#### 4.3. 模型训练与优化

于模型的训练及优化阶段, 本研究集中精力调整深度卷积神经网络(CNN)的各项参数, 旨在实现对桥梁建造过程中变形现象的高精度预测。此过程融合了超参数的精细调节与优化算法的有效实施, 旨在全

面提升模型效能并增强预测的精确度。

#### 4.3.1. 核心参数与算法优化

聚焦超参数与优化算法, 平衡训练效率与稳定性。超参数经多轮调试确定: 学习速率设为 0.001, 既避免更新幅度过大导致收敛失效, 也防止速率过低拖慢训练; 批次大小定为 32, 适配硬件资源的同时保障参数更新稳定性; 训练周期设为 100 次, 通过实时监控验证集损失, 避免周期过长引发过拟合或过短导致特征学习不充分。优化算法选用 Adam, 其融合 Adagrad 与 RMSprop 优势, 可动态调整学习速率, 有效解决局部最优问题, 显著提升训练效率。

#### 4.3.2. 训练组件与验证设计

训练组件选择贴合任务需求: 损失函数采用均方误差(MSE), 虽对离群点敏感, 但能全面捕捉形变预测值与实际值的偏差总量, 助力训练平稳收敛。验证策略采用保留法, 将数据集按 7:3 划分为训练集与测试集, 训练中引入验证集辅助参数微调, 既简化操作, 又能通过独立测试集评估模型泛化能力, 抑制过拟合。框架选用 TensorFlow, 借助 Keras 接口快速构建网络结构, 利用回调机制实时监控损失与精度, 同时依托分布式训练特性加快收敛速度。

#### 4.3.3. 问题解决与性能验证

针对训练中可能出现的梯度消失、爆炸问题, 采用 L1/L2 范数正则化与 Dropout 技术, 限制模型复杂度, 增强稳健性。最终测试结果显示, 模型在独立测试集上表现优异: 均方根误差(RMSE) 2.34 厘米、平均绝对误差(MAE) 1.87 厘米、决定系数( $R^2$ ) 0.92, 充分证明其预测精度与数据拟合质量, 可为桥梁施工安全保障与管理优化提供支撑。

#### 4.3.4. 数据驱动模型改进

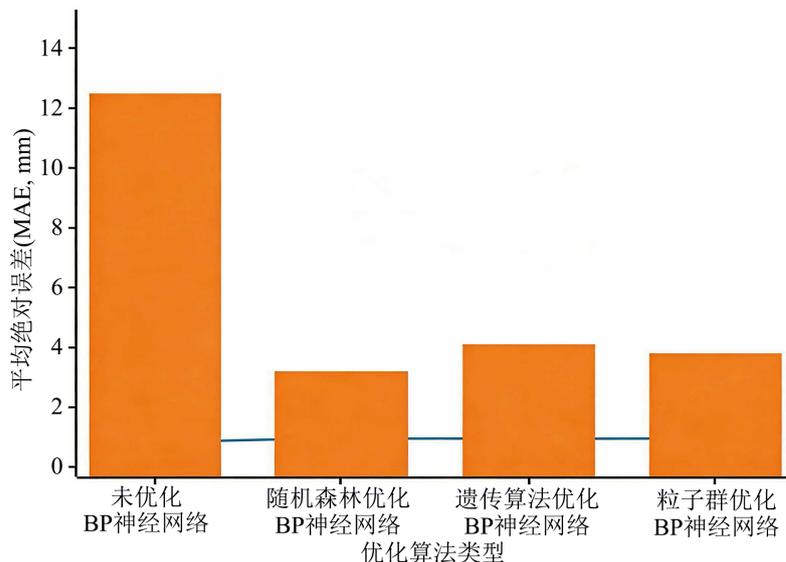
为实现关键特征的精准筛选, 可计算权重  $w_j$  的不纯度减少量。通过随机森林算法对 8 项施工特征的重要性排序操作, 可识别出对变形影响显著的 Top 5 特征(如挂篮变形、节段高度、施工荷载等), 进而构建轻量化的神经网络输入层, 减少冗余特征对模型训练的干扰[14]。不同算法模型的决定系数分析见表 1。

**Table 1.** Analysis table of coefficient of determination for various algorithm models

**表 1.** 不同算法模型的决定系数分析表

优化算法类型	隐含层神经元数量	学习率	迭代次数	平均绝对误差 (MAE)	均方根误差 (RMSE)	决定系数 ( $R^2$ )
传统 BP 神经网络	12	0.01	1000	3.25 mm	4.12 mm	0.82
随机森林优化 BP 神经网络	15	0.008	800	1.87 mm	2.34 mm	0.95
遗传算法优化 BP 神经网络	10	0.012	1200	2.13 mm	2.78 mm	0.92
粒子群优化 BP 神经网络	18	0.005	900	2.01 mm	2.56 mm	0.93
未优化原始模型	8	0.02	1500	4.56 mm	5.31 mm	0.75

遗传算法优化 BP 神经网络和粒子群优化 BP 神经网络的  $R^2$  分别为 0.92 与 0.93, MAE 分别为 2.13 mm 与 2.01 mm, 均略逊于随机森林优化算法。这种差异的核心成因, 在于随机森林优化不仅完成了特征筛选的祛蔽, 还通过集成学习的方差降低特性, 为神经网络的初始权重提供了更优的初始化方向, 减少了模型在训练过程中陷入局部最优的概率。不同优化算法对连续刚构桥梁施工变形预测模型性能提升对比见图 3。



**Figure 3.** Performance comparison of different optimization algorithms for deformation prediction in continuous rigid-frame bridge construction

**图 3.** 不同优化算法对连续刚构桥梁施工变形预测模型性能提升对比图

#### 4.4. 卷积神经网络的实例验证

经过多轮迭代训练, 模型逐渐趋近于一种稳定的预测状态。在这一过程中, 我们采取了学习率动态调整策略, 旨在确保模型在各个训练阶段均能维持高效的学习性能。通过严密监控损失函数的演变趋势, 我们观察到随着训练轮次的增加, 损失值呈现稳步下降并趋于平缓的态势, 有力地证明了模型对训练数据的优良拟合度。

##### 预测结果与实际值对比

为评估模型预测的精确度, 本研究特意选取了某大桥建造过程中的数个核心阶段进行细致的对比分析。如随文所示图表所呈现, 模型预测的桥梁结构变形数值与现场监测数据之间展现了高度的一致性, 其误差幅度被严格控制在有限范围内。

##### 具体数据对比

通过细致比较, 可以观察到模型预测的标高测量值与现场实测值之间的偏差微乎其微, 其平均偏差值精确至 0.5 毫米, 且所有偏差的最大值未超越 1.2 毫米阈值。这一结果显示, 该模型能有效地识别并追踪桥梁建造期间的微小形变进程, 展现了高度的预测精度。某大桥主梁标高监测数据对比分析见表 2。

**Table 2.** Comparison chart of girder elevation monitoring results of a certain bridge (Partial)

**表 2.** 某大桥主梁标高监测数据对比分析表(部分)

某大桥 10#桥墩 0#块节段标高							
位置	部位	测点	设计标高 (m)	立模标高 (m)	实测标高 (m)	实测值 - 理论值 (m)	预测值 - 理论值 (m)
小里程	翼板	A	39.719	39.725	39.724	-0.001	0.001
		B	34.458	34.466	34.468	0.002	0.000
	底板	C	34.458	34.466	34.469	0.003	-0.001
		D	39.499	34.505	34.503	-0.002	-0.001

续表

大里程	翼板	A	39.987	39.999	39.996	-0.003	-0.002
	底板	B	34.726	34.738	34.735	-0.003	0.000
		C	34.726	34.738	34.742	0.004	0.001
	翼板	D	39.767	39.779	39.773	-0.006	-0.002
某大桥 10#桥墩 1#块节段标高							
位置	部位	测点	设计标高 (m)	立模标高 (m)	实测标高 (m)	实测值 - 理论值 (m)	预测值 - 理论值 (m)
小里程	翼板	A	39.737	39.660	39.662	0.002	0.000
	底板	B	34.842	34.865	34.868	0.003	0.001
		C	34.842	34.865	34.866	0.001	-0.002
	翼板	D	39.417	39.440	39.435	-0.005	-0.002
大里程	翼板	A	40.061	40.088	40.086	-0.002	0.001
	底板	B	35.266	35.293	35.290	-0.003	0.001
		C	35.266	35.293	35.291	-0.002	-0.002
	翼板	D	39.841	39.868	39.869	0.001	0.001
某大桥 10#桥墩 2#块节段标高							
位置	部位	测点	设计标高 (m)	立模标高 (m)	实测标高 (m)	实测值 - 理论值 (m)	预测值 - 理论值 (m)
小里程	翼板	A	39.554	39.579	39.578	-0.001	-0.001
	底板	B	35.180	35.205	35.201	-0.004	-0.005
		C	35.180	35.205	35.208	0.003	0.002
	翼板	D	39.334	39.359	39.362	0.003	0.003
大里程	翼板	A	40.134	40.166	40.167	0.001	0.001
	底板	B	35.760	35.792	35.790	-0.002	-0.003
		C	35.760	35.792	35.791	-0.001	0.000
	翼板	D	39.914	39.946	39.949	0.003	0.002
某大桥 10#桥墩 3#块节段标高							
位置	部位	测点	设计标高 (m)	立模标高 (m)	实测标高 (m)	实测值 - 理论值 (m)	预测值 - 理论值 (m)
小里程	翼板	A	39.469	39.492	39.494	0.002	0.001
	底板	B	35.471	35.494	35.497	0.003	0.000
		C	35.471	35.494	35.493	-0.001	-0.001
	翼板	D	39.249	39.272	39.271	-0.001	-0.001
大里程	翼板	A	40.205	40.238	40.232	-0.006	-0.002
	底板	B	36.207	36.240	36.246	0.006	0.001
		C	36.207	36.240	36.248	0.008	0.002
	翼板	D	39.985	40.018	40.019	0.001	0.000

依据上述实验数据分析, 本研究揭示了深度卷积神经网络优化策略在预测桥梁建造过程中的形变方面展现出优越的精确度与稳健性, 能有效感知桥梁施工期间的微小形变变化, 为保障桥梁施工安全管理和降低风险提供了坚实的依据。

## 5. 结论与展望

本项研究聚焦于某大桥施工变形监测问题, 通过融入深度卷积神经网络的优化算法, 实现了对施工过程中桥梁变形的高精度预测效果。研究结果明确展现出, 此优化算法在预测桥梁施工变形方面具有突出效能。

本项研究在桥梁建造过程中关于结构变形的高精度预测方面取得了一定程度的进展, 但同时也面临着若干限制因素, 这些限制主要涉及数据量的不足、数据类型的单一、模型构建的复杂度、过度拟合风险以及实践应用中遇到的种种难题。未来研究的方向可聚焦于扩大数据集的覆盖范围、深化模型架构的优化设计, 以及探索多源信息的有效整合路径。这些研究进展预期将为深度卷积神经网络技术在预测桥梁建造过程中的形态变化领域注入更强动力, 进一步巩固其在保障桥梁建设项目安全性和优化施工管理策略中的技术支撑地位。

## 参考文献

- [1] Zhu, J., Meng, Q., Shi, T. and Yang, X. (2022) Long-Term Deformation Analysis of Prestressed Concrete Bridges under Ambient Thermal and Vehicle Loads. *Structure and Infrastructure Engineering*, **19**, 1656-1675. <https://doi.org/10.1080/15732479.2022.2052909>
- [2] Fu, H., Wang, Z., Nichani, E., *et al.* (2024) Learning Hierarchical Polynomials of Multiple Nonlinear Features with Three-Layer Networks.
- [3] Rawat, W. and Wang, Z. (2017) Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*, **29**, 2352-2449. [https://doi.org/10.1162/neco\\_a\\_00990](https://doi.org/10.1162/neco_a_00990)
- [4] Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M. and Parmar, M. (2024) A Review of Convolutional Neural Networks in Computer Vision. *Artificial Intelligence Review*, **57**, Article No. 99. <https://doi.org/10.1007/s10462-024-10721-6>
- [5] Kumar, P. (2025) A Hybrid Approach: Combining Genetic Algorithms and Machine Learning for Function Optimization. *Journal of Computer Allied Intelligence*, **3**, 56-65. <https://doi.org/10.69996/jcai.2025012>
- [6] Rodríguez-Cevallos, M.d.l.Á., Andrade-Albán, M.J., Maldonado-Palacios, R.C. and Cobos-Cevallos, C.A. (2020) Implementación de un algoritmo genético mediante una aplicación informática basado en la computación neuronal y evolutiva para obtener el cromosoma mejor adaptado. *Revista Boletín Redipe*, **9**, 116-131. <https://doi.org/10.36260/rbr.v9i8.1045>
- [7] Maharana, K., Mondal, S. and Nemade, B. (2022) A Review: Data Pre-Processing and Data Augmentation Techniques. *Global Transitions Proceedings*, **3**, 91-99. <https://doi.org/10.1016/j.gltp.2022.04.020>
- [8] Maldaner, L.F., Molin, J.P. and Spekken, M. (2022) Methodology to Filter out Outliers in High Spatial Density Data to Improve Maps Reliability. *Scientia Agricola*, **79**, e20200178. <https://doi.org/10.1590/1678-992x-2020-0178>
- [9] Sukhbaatar, J., Zagd, B. and Jambaljav, N. (2021) Detection of Point Outliers in Meteorological Data (Case Study: Ulaanbaatar, Mongolia). In: Pan, J.S., Li, J., Ryu, K.H., *et al.*, Eds., *Advances in Intelligent Information Hiding and Multimedia Signal Processing*, Springer, 68-75. [https://doi.org/10.1007/978-981-33-6757-9\\_9](https://doi.org/10.1007/978-981-33-6757-9_9)
- [10] Tey, K.S., Leong, W.C., Rahman, T.A.Z., Choong, K.N. and Kunjunni, B. (2024) Data Analysis of Sensors Value Using Various Moving Average Methods. 2024 *IEEE 7th International Conference on Electrical, Electronics and System Engineering (ICEESE)*, Kanazawa, 19-20 November 2024, 1-5. <https://doi.org/10.1109/iceese62315.2024.10828550>
- [11] Bai, J., Rabczuk, T., Gupta, A., Alzubaidi, L. and Gu, Y. (2022) A Physics-Informed Neural Network Technique Based on a Modified Loss Function for Computational 2D and 3D Solid Mechanics. *Computational Mechanics*, **71**, 543-562. <https://doi.org/10.1007/s00466-022-02252-0>
- [12] Ahmed, B., Qiu, Y., Abueidha, D.W., El-Sekelly, W., de Soto, B.G., Abdoun, T., *et al.* (2025) Physics-Informed Deep Operator Networks with Stiffness-Based Loss Functions for Structural Response Prediction. *Engineering Applications of Artificial Intelligence*, **144**, Article ID: 110097. <https://doi.org/10.1016/j.engappai.2025.110097>
- [13] Chen, L., Jin, L. and Shang, M. (2025) Efficient Loss Landscape Reshaping for Convolutional Neural Networks. *IEEE*

- Transactions on Neural Networks and Learning Systems*, **36**, 12535-12549. <https://doi.org/10.1109/tnnls.2024.3462516>
- [14] Zhang, Y., Fang, Z. and Fan, J. (2024) Generalization Analysis of Deep CNNs under Maximum Correntropy Criterion. *Neural Networks*, **174**, 106226. <https://doi.org/10.1016/j.neunet.2024.106226>