

# 轨道沉降组合模型研究与分析

陈观辉

廉江市自然资源测绘中心, 广东 廉江

收稿日期: 2024年6月17日; 录用日期: 2024年7月10日; 发布日期: 2024年7月17日

## 摘要

地铁轨道结构变形是影响地铁安全运营的重要因素, 尤其是在沉降变形方面, 因此针对地铁轨道沉降的变形监测, 同时根据监测结果对轨道的沉降变形趋势进行准确判断具有重要意义。本文以某市地铁2号线轨道监测数据为例, 发挥小波分析与极限学习机(Extreme Learning Machine, ELM)模型在数据处理、数据预测中的优势, 将粒子群优化(Particle Swarm Optimization, PSO)算法用于ELM模型参数优化中, 构建基于小波去噪的PSO-ELM组合预测模型, 实现地铁轨道的沉降变形预测研究。通过小波分析进行监测数据去噪, 解决了监测数据不稳定带来的预测结果的干扰问题; 通过构建PSO-ELM组合预测模型, 解决了模型参数选取随机性带来的预测精度受限问题。将本文提出的小波去噪PSO-ELM模型与单一ELM模型、小波去噪ELM模型沉降预测结果进行对比分析, 结果表明本文提出组合预测模型预测精度最高, 同时预测误差不会随预测期数的增加产生明显变化, 具有较高的稳健性与适应性。

## 关键词

地铁轨道, 沉降预测, 小波去噪, 粒子群优化, 极限学习机

# Research and Analysis of a Combined Model for Track Settlement

Guanhui Chen

Lianjiang Natural Resources Surveying and Mapping Center, Lianjiang Guangdong

Received: Jun. 17<sup>th</sup>, 2024; accepted: Jul. 10<sup>th</sup>, 2024; published: Jul. 17<sup>th</sup>, 2024

## Abstract

The deformation of subway track structure is an important factor affecting the safe operation of subway, especially in terms of settlement deformation. Therefore, it is of great significance to monitor the deformation of subway track settlement and accurately judge the trend of track set-

文章引用: 陈观辉. 轨道沉降组合模型研究与分析[J]. 测绘科学技术, 2024, 12(3): 231-239.

DOI: 10.12677/gst.2024.123029

tlement deformation based on the monitoring results. This article takes the monitoring data of the subway line 2 in a certain city as an example, and leverages the advantages of wavelet analysis and Extreme Learning Machine (ELM) models in data processing and prediction. The Particle Swarm Optimization (PSO) algorithm is applied to optimize the ELM model parameters, and a PSO-ELM combined prediction model based on wavelet denoising is constructed to achieve the prediction of subway track settlement deformation. By using wavelet analysis to denoise monitoring data, the interference problem of prediction results caused by unstable monitoring data has been solved; By constructing a PSO-ELM combined prediction model, the problem of limited prediction accuracy caused by the randomness of model parameter selection has been solved. The proposed wavelet denoising PSO-ELM model was compared and analyzed with the settlement prediction results of a single ELM model and wavelet denoising ELM model. The results showed that the proposed combined prediction model had the highest prediction accuracy, and the prediction error did not change significantly with the increase of prediction periods, demonstrating high robustness and adaptability.

## Keywords

Subway Tracks, Settlement Prediction, Wavelet Denoising, Particle Swarm Optimization, Extreme Learning Machine

Copyright © 2024 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

当前,城市化进程不断推进,越来越多的人口向城市涌入,在为城市发展与建设提供劳动力的同时带来了巨大的生活住房压力、交通压力等。作为城市交通中的重要一种,地铁具有准时、便捷等优势,能够大大减轻城市交通压力。然而,受外界环境、地表形变以及自身荷载等因素影响,地铁在运营过程中会产生不同程度变形,尤其是在高程方向,我国大城市均出现过关于地铁运营的安全事故,给人民生命财产安全造成巨大隐患。因此,针对地铁运营过程中的变形监测,保障人们出行安全具有重要意义,同时,根据当前监测结果对地铁的变形趋势进行准确判断,分析地铁变形量是否在安全范围内尤为必要。

针对变形体沉降预测,不少专家学者进行了大量研究,并取得了积极成果,通过不断总结、积累与归纳,目前常用的沉降预测方法有时间序列法、BP神经网络模型、支持向量机、回归分析法以及灰色预测模型等[1]-[3],其中时间序列法是对随时间变化的多维数据序列进行分析,根据数据的变化趋势进行预测,然而该方法对于长段时间的预测效果较差,并且无法充分发掘非线性数据之间的联系[4];BP神经网络模型是应用最为广泛的神经网络模型,该模型能够快速处理非线性数据,但是存在收敛速度慢、易陷入局部极值等缺陷[5];支持向量机是一种二元分类的线性分类器,目前广泛应用于各领域预测中,但是该方法涉及的参数设置较多且复杂,不同参数设置对结果的影响不同,因此存在一定局限性;回归分析法通过对变量之间的关系进行解释,基于因果效果的角度实现沉降预测,但是该算法对于非线性关系的描述不够准确;灰色预测模型是一种常用的预测方法,该模型所需建模信息少、运算方便,是小样本预测问题的有效工具,但是在处理较大样本数据时,会产生较大误差,使预测目标失效。

极限学习机(Extreme Learning Machine, ELM)模型的泛化能力强,只需要对模型的隐层节点数进行设置,即可实现小样本数据预测。针对模型中的关键参数,包括最优输入权值与隐含层偏置,引入粒子群

优化(Particle Swarm Optimization, PSO)算法进行优化。此外,地铁在运营过程中,受各种因素影响,沉降监测数据往往表现出非线性、非平稳性特征,对于模型的预测产生较大干扰,因此,本文首先通过小波分析对沉降监测数据进行处理,将处理后的沉降数据作为 PSO-ELM 模型的输入,结合 PSO-ELM 模型建立基于小波去噪的 PSO-ELM 模型,通过实验对模型的预测性能进行分析。

## 2. 原理介绍

### 2.1. 小波分析多尺度分解

小波分析中,信号的多尺度分解细化主要通过基函数的移动与伸缩实现,分解后的信号具有不同频率,其中低频信号的平滑性与稳定性较为优异,能够准确反映出原始信号的趋势,小波分解可表示为:

$$Wf(a,b) = \int_{-\infty}^{\infty} f(t) \phi(a,b)(t) dt \quad (1)$$

式(1)中,  $a$ 、 $b$  分别为尺度因子与平移因子;  $\phi(a,b)(t)$  为连续小波,由小波母函数生成,  $f(t)$  重构公式为:

$$f(t) = C_{\phi}^{-1} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{Wf(a,b)}{a^2} \phi(a,b)(t) da db \quad (2)$$

式(2)中,  $C_{\phi}$  为小波基函数;小波分析效果好坏取决于小波基函数与合适的软硬阈值,本文将通过实验确定最优小波基函数。

### 2.2. 极限学习机

ELM 网络结构如图 1 所示,包括输入层、隐含层与输出层,该算法与其他神经网络存在区别,主要表现在隐藏节点参数独立于训练集或目标函数。

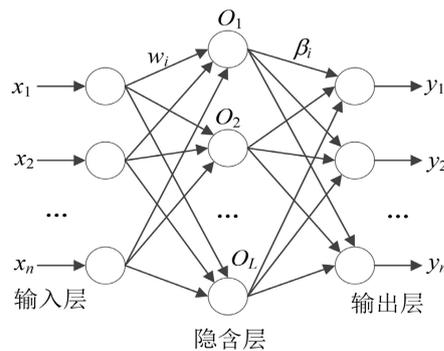


Figure 1. Extreme learning machine network structure

图 1. 极限学习机网络结构

假设对于  $N$  个样本  $(x_i, t_i)$ ,  $x_i$ 、 $t_i$  为输入与期望输出, ELM 训练模型为:

$$y_i = \sum_{j=1}^L \beta_j g(w_j \cdot x_i + b_j), j = 1, 2, \dots, N \quad (3)$$

式(3)中,  $y_i$  为模型的输出;  $\beta_j$ 、 $w_j$  分别为隐含层与输出层、输入层与隐含层神经元连接权;  $g(x)$  为激励函数;  $b_j$  为隐含层神经元偏置。

ELM 中,  $w_j$  与  $b_j$  是随机设置的, ELM 的高精度预测精度主要是通过训练  $w_j$  与  $b_j$  实现, 即:

$$\sum_{j=1}^N \|t_i - y_i\| = 0 \quad (4)$$

综合式(3)、式(4)，可改写为：

$$t_j = \sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) \quad (5)$$

对于式(5)，以矩阵形式表达：

$$\mathbf{T} = \mathbf{H} \cdot \boldsymbol{\beta} \quad (6)$$

式(6)中， $\mathbf{T}$  为输出矩阵； $\mathbf{H}$  为隐含层输出矩阵； $\boldsymbol{\beta}$  为连接权值矩阵。

对 ELM 网络的训练目标进行优化：

$$\text{Minimize} : \|\mathbf{H} \cdot \boldsymbol{\beta} - \mathbf{y}\| \& \|\boldsymbol{\beta}\| \quad (7)$$

使用线性系统  $\mathbf{H} \cdot \boldsymbol{\beta} = \mathbf{T}$  关于  $\boldsymbol{\beta}$  的最小二乘解表示 ELM 的训练过程：

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \cdot \mathbf{T} \quad (8)$$

式(8)中， $\mathbf{H}^+$  为  $\mathbf{H}$  的广义矩阵。

ELM 具有运行高效、操作简单等优势，但由于  $w_i$  与  $b_i$  是随机产生的，导致模型训练效果有时较差，因此本文考虑使用粒子群优化算法对 ELM 模型进行参数优化。

## 2.3. 粒子群优化的 ELM 模型

### 2.3.1. 参数控制

(1) 假设输入层为  $In$ ，输出层为  $Ou$ ，隐含层节点数可表示为：

$$Mi = \sqrt{In + Ou} + \alpha \quad (9)$$

式(9)中， $Mi$  为隐含层节点数； $\alpha$  为 1 至 10 之间整数。

(2) 采用式(10)递减线性方式确定粒子算法中权重  $w$ ，使用式(11)、式(12)经验方式确定  $c_1$  和  $c_2$  加速因子：

$$w_{\text{clter}} = w_{\text{max}} - \frac{w_{\text{max}} - w_{\text{min}}}{Ma} \cdot cl \quad (10)$$

$$c_1 = cl \cdot \frac{(c_{1e} - c_{1s})}{Ma} + c_{1s} \quad (11)$$

$$c_2 = cl \cdot \frac{(c_{2e} - c_{2s})}{Ma} + c_{2s} \quad (12)$$

上式中， $cl$ 、 $Ma$  为当前迭代次数与总迭代代数； $w_{\text{min}} = 0.25$ ， $w_{\text{max}} = 0.95$ ； $c_{1s} = 2.75$ ， $c_{2s} = 0.5$ ， $c_{1e} = 1.25$ ， $c_{2e} = 2.25$ 。

(3) 适应度函数。文中粒子群算法的适应度函数可表示为：

$$F(i) = \frac{\text{mae}}{Q} = \frac{\sum_{k=1}^Q (t_k - y_k)}{Q^2} \quad (13)$$

式中， $Q$  为训练样本数； $t$  为神经元期望值； $y$  为实际输出值。

### 2.3.2. 组合算法描述

充分利用 ELM 模型的预测能力以及 PSO 算法的自适应能力与全局性搜索能力，将二者结合，提升组合算法的寻优能力，包括 ELM 模型拓扑结构的优化、模型参数的优化等，对于整体搜索效率的提升有

所帮助。本文组合 PSO 算法与 ELM 模型，构建 PSO-ELM 模型，具体实现步骤为：

- (1) 确定网络的输入层、隐含层、输出层节点数，确定粒子维数数目。
- (2) 确定 PSO 中适应度函数。
- (3) 对各维度粒子进行初始化。
- (4) 对估计最小值进行迭代处理，搜索最优输入权值与隐含层偏置，以确定粒子最优位置，将该最优位置对应数值即为输入权值与隐含层偏置的最优值。
- (5) 根据参数寻优得到最优输入权值与隐含层偏置，构建 PSO-ELM 模型，使用测试数据与模型进行验证。

### 3 实例分析

#### 3.1. 实例简介

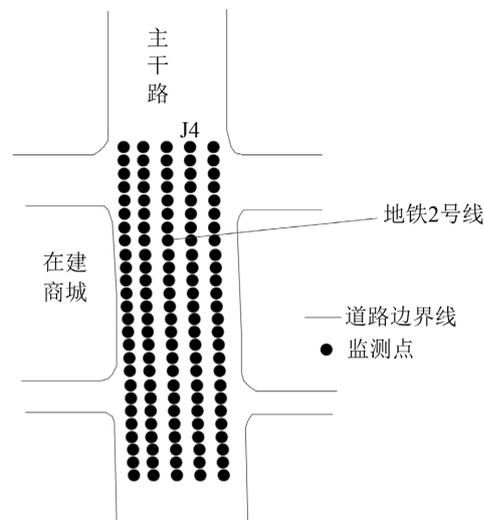


Figure 2. Distribution of deformation monitoring points

图 2. 变形监测点分布

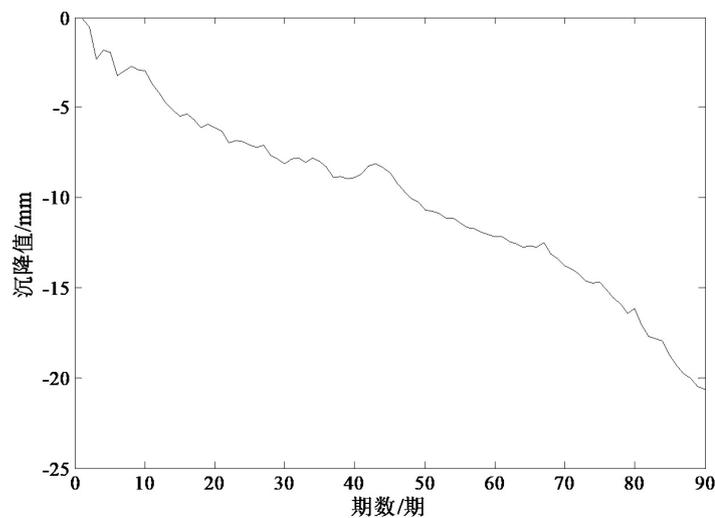


Figure 3. Settlement observation data of J4 monitoring point

图 3. J4 监测点沉降观测数据

某市在建商城与地铁 2 号线路面轨道接近, 商城基坑深度约为 34.4 m, 是地铁安全运营的较大隐患。为了保障地铁 2 号线能够商城在修建过程中的安全运营, 对该区段路面轨道进行变形监测, 布设 26 个监测断面、130 个变形监测点, 如图 2 所示。

根据《国家一、二等水准测量规范》对监测点进行沉降往返沉降观测, 在满足精度要求的情况下, 将平均值作为实测数据, 以保证实测数据的可靠性。监测周期为 2021 年 7 月 5 日至 2021 年 9 月 30 日, 共 90 期, 受篇幅限制, 以 J4 监测点数据开展实验, 该点沉降变形情况如图 3 所示。

### 3.2. 小波去噪

考虑地铁轨道沉降监测数据具有非线性、非稳定性特征, 将小波去噪与 ELM 模型串联使用, 首先, 绘沉降监测数据进行小波去噪处理, 去噪后数据为 ELM 模型的输入。小波去噪中涉及到的参数包括分解层数、阈值调整方式、小波基函数, 对比不同参数下去噪结果的精度指标, 得到小波 1 层分解、sym4 小波基、scal = sln 阈值调整方式时的精度指标最高, 去噪效果最好。

在上述参数的基础上, 分别为选取 minimax、sqtwolog、rigrsure 以及 heursure 阈值函数进行去噪, 去噪结果如图 4 所示, 信噪比与均方根误差如表 1 所示。

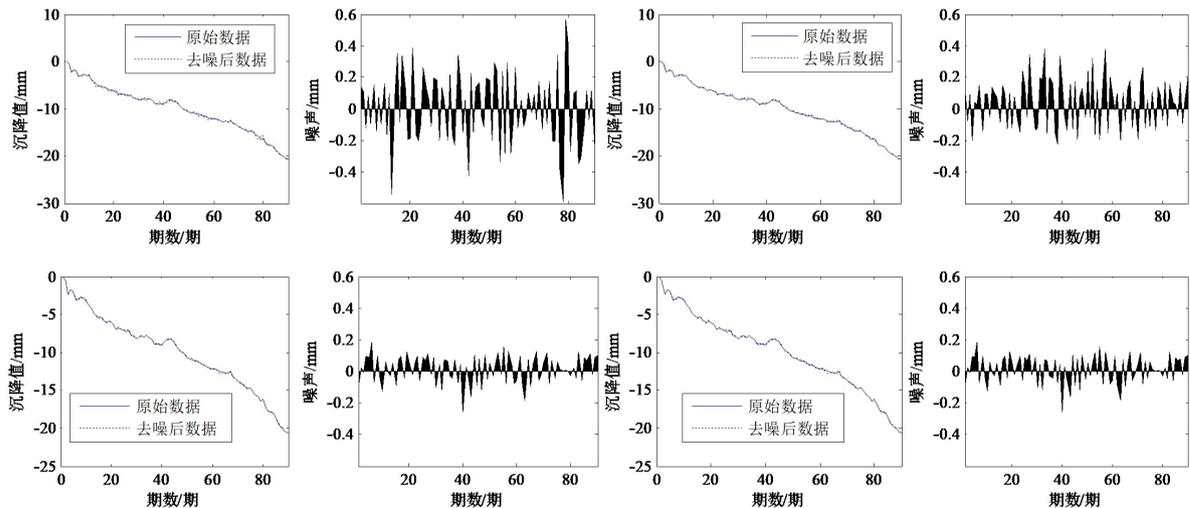


Figure 4. Comparison of denoising effects

图 4. 去噪效果对比

Table 1. Signal-to-noise ratio and root mean square error of denoised results

表 1. 去噪后结果信噪比与均方根误差

阈值函数	信噪比/dB	均方根误差/mm
sqtwolog	31.856 9	0.196 4
minimax	38.368 7	0.138 5
heursure	35.364 3	0.172 8
rigrsure	44.525 9	0.073 4

通过表 1 可知, 4 种阈值函数种, rigrsure 阈值函数去噪结果的信噪比最大、均方根误差最小, 表现出最好的去噪效果, 使用该阈值函数对沉降监测数据进行去噪处理, 对于提升 ELM 模型预测效果有较大帮助。

### 3.3. 粒子群优化的 ELM 模型应用

直接使用 ELM 模型进行预测时,可能会产生“过拟合”现象,因此,本文将数据分为训练样本、验证样本以及测试样本。使用前 80 期监测数据进行模型训练,完成模型训练后,使用训练好的模型开展沉降预测。完成去噪后,向模型中输入去噪后数据,完成学习、训练与预测后,即得到输出值。

建立 ELM 预测模型时,将输入层节点数与输出层节点数分别确定为 10、1,通过试验得到当激励函数为 Sigmoid 型时,ELM 模型预测结果的精度最高,确定激励函数为 Sigmoid 型,结合 PSO 算法与 ELM 模型,构建 PSO-ELM 模型。

为测试本文提出轨道沉降预测模型的可靠性与优越性,分别使用单一 ELM 模型、小波去噪 ELM 模型、小波去噪 PSO-ELM 模型进行轨道沉降预测并对比预测精度,设置相同的网络拓扑结构。对比三种模型预测结果与实测值,如图 5 所示,相对误差如图 6 所示。

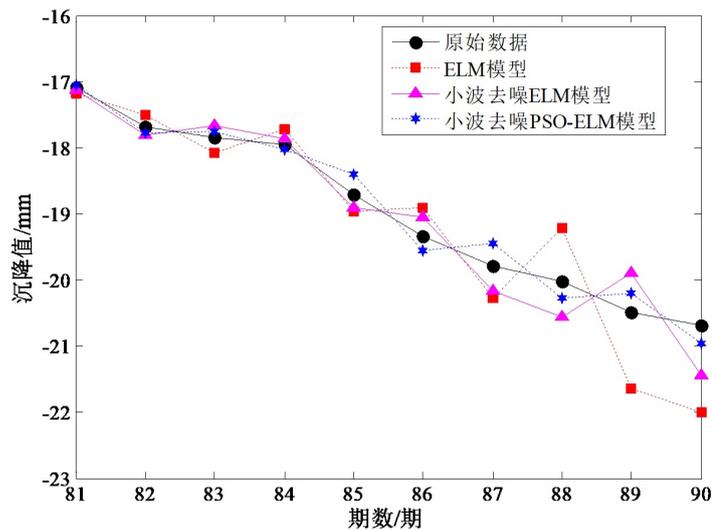


Figure 5. Prediction results of subway track settlement using three models

图 5. 3 种模型地铁轨道沉降预测结果

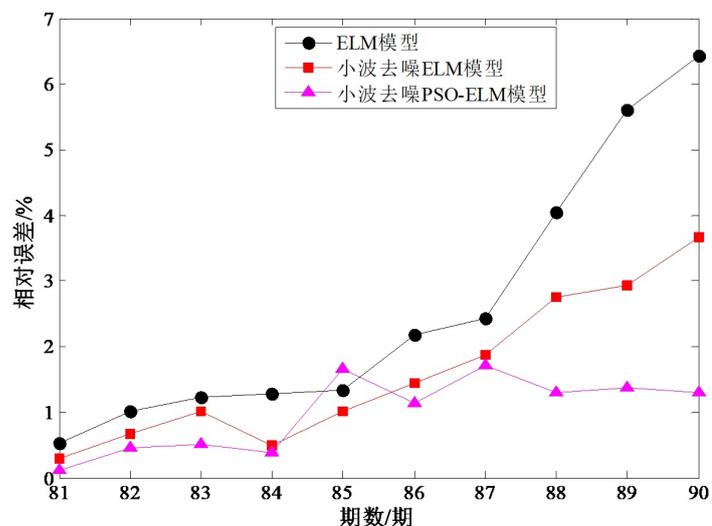


Figure 6. Relative errors of three models for predicting subway track settlement

图 6. 3 种模型地铁轨道沉降预测结果的相对误差

通过图 5、图 6 可知, 随着预测期数的增加, 单一 ELM 模型预测结果与实际值的偏差越来越大, 小波去噪 ELM 模型预测结果也在一定程度上偏离了实际值。而小波去噪 PSO-ELM 模型预测结果与实际值依然保持相对温和, 表明 PSO-ELM 模型同时具有短周期与长周期数据预测的能力, 具备较强的预测稳健性。

为进一步定量反映不同预测模型的预测效果, 统计不同模型预测结果的绝对残差均值、均方根误差 RMSE 以及平均绝对百分比误差, 结果如表 2 所示。

**Table 2.** Precision statistics of three model predictions

**表 2.** 3 种模型预测结果精度统计

期数	实测沉降 /mm	ELM 模型		小波去噪 ELM 模型		小波去噪 PSO-ELM 模型	
		预测值/mm	残差/mm	预测值/mm	残差/mm	预测值/mm	残差/mm
81	-17.08	-17.17	-0.09	-17.13	-0.05	-17.06	0.02
82	-17.69	-17.51	0.18	-17.81	-0.12	-17.77	-0.08
83	-17.85	-18.07	-0.22	-17.67	0.18	-17.76	0.09
84	-17.95	-17.72	0.23	-17.86	0.09	-18.02	-0.07
85	-18.71	-18.96	-0.25	-18.9	-0.19	-18.4	0.31
86	-19.33	-18.91	0.42	-19.05	0.28	-19.55	-0.22
87	-19.79	-20.27	-0.48	-20.16	-0.37	-19.45	0.34
88	-20.02	-19.21	0.81	-20.57	-0.55	-20.28	-0.26
89	-20.49	-21.64	-1.15	-19.89	0.6	-20.21	0.28
90	-20.68	-22.01	-1.33	-21.44	-0.76	-20.95	-0.27
残差均值			0.52		0.32		0.19
RMSE			0.66		0.39		0.22
MAPE			0.0261		0.0162		0.0099

通过表 2 对比得出, 小波去噪 PSO-ELM 模型预测结果的绝对残差均值、RMSE 以及 MAPE 均优于对比模型, 表现出了更优的预测效果, 表明沉降监测数据在经小波去噪后, 使用 PSO 算法优化 ELM 模型参数, 强化模型的鲁棒性与泛化能力, 通过实验也验证本文模型的可靠性与优越性, 具有很好的应用效果。

#### 4. 结束语

本文根据小波分析在信号去噪、PSO 算法在参数寻优、ELM 模型在数据序列预测中的优势, 提出一种基于小波去噪的 PSO-ELM 模型, 使用某段地铁轨道沉降监测数据进行沉降预测实验, 得出的结论主要有:

1) 在使用小波分析去噪时, 小波 1 层分解、阈值调整方式 scal = sln、小波基函数为 sym4、阈值函数为 rigrsure 时信噪比最大、均方根误差最小, 去噪效果最好, 能够有效剔除轨道沉降监测数据中的噪声项。

2) 通过 PSO 算法优化 ELM 模型的输入权值与隐含层偏置, 构建 PSO-ELM 模型, 能够有效提升模型的鲁棒性与泛化能力, 对比单一 ELM 模型与小波去噪 ELM 模型, 小波去噪 PSO-ELM 模型表现出更优的预测效果, 各项精度指标均更高。

3) 随着预测期数的增加, 本文提出小波去噪 PSO-ELM 模型的预测优势逐渐凸显, 表现出了更高的稳健性, 可应用于同类型沉降预测中。

### 参考文献

- [1] 朱合华, 张锋, 闫治国. 高速磁浮轨道结构沉降的高精度预测及控制策略[J]. 前瞻科技, 2023, 2(4): 61-69.
- [2] 李斯. 盾构隧道下穿高铁路基沉降监测与预警[J]. 铁道建筑, 2023, 63(11): 127-130.
- [3] 郭明, 谢璨, 宋曙光, 等. 新建市政隧道下穿多线运营铁路地表沉降研究——以郑州火车站片区操场街隧道工程为例[J]. 铁道勘察, 2023, 49(6): 37-45.
- [4] 邓洪建. 轨道交通沉降监测方法探讨[J]. 工程机械与维修, 2023(5): 77-79.
- [5] 王碧军. 铁路路基沉降段轨道整治方案研究[J]. 中国高新科技, 2023(13): 124-126.