文章编号:1673-0291(2026)04-0066-14 DOI:10.11860/j.issn.1673-0291.20250088

PSO-BP优化MGM(1,*n*)模型的风积沙路基沉降预测研究

马丽娜[1],张 欣[1],梁永迁[2],梅磊磊[2]
(1.兰州交通大学 土木工程学院,兰州 730070;2.中交路桥建设有限公司,北京 101100)

摘 要:准确预测沉降量对保障路基施工质量和公路长期安全运营具有重要意义.针对风积沙抗剪强度低,且用于路基填筑时易产生较大沉降变形而影响路面结构安全的问题,以G219线风积沙路段为研究对象,提出一种高精度的PSO-BP-MGM(1,*n*)路基沉降预测模型.首先,通过埋设监测仪器采集沉降数据作为建模样本;然后,将多变量灰色模型(Multivariable Grey Model, MGM(1,*n*))与粒子群优化算法(Particle Swarm Optimization,PSO)、反向传播神经网络(Back Propagation Neural Network,BP)结合,构建PSO-BP-MGM(1,*n*)综合预测模型,该模型以MGM(1,*n*)捕捉沉降趋势,并利用PSO-BP对MGM(1,*n*)的预测残差进行非线性修正,以弥补MGM(1,*n*)非线性拟合能力不足、BP神经网络小样本易过拟合的局限;最后,将该模型应用于G219线风积沙路基沉降预测.研究结果表明:PSO-BP-MGM(1,*n*)模型的沉降预测值与沉降实测值吻合度最高;相较MGM(1,*n*)模型,其最大平均绝对百分比误差(Mean Absolute Percentage Error,MAPE)、均方根误差(Root Mean Square Error, RMSE)、误差平方和(Sum of Squared Errors,SSE)分别降低1.341%、0.528、1.817;较双曲线模型,其最大MAPE、RMSE、SSE分别降低2.21%、0.965、5.523;PSO-BP-MGM(1,*n*)模型的灰色绝对关联度均在0.995以上,优于MGM(1,*n*)模型与双曲线模型;可综合考虑各监测点的相互影响,适用于多点联合预测;PSO-BP模型对MGM(1,*n*)模型预测的残差进行进一步建模与修正,可有效挖掘残差序列中隐含的规律性成分,提升综合模型的预测精度,可为风积沙地区路基沉降控制及类似地质条件下的沉降预测提供参考.

关键词:风积沙路基;MGM(1,*n*)模型;PSO-BP模型;残差修正;沉降预测
中图分类号:U416.1 **文献标志码**:A

Study on settlement prediction for aeolian-sand subgrades based on PSO-BP-optimized MGM(1,*n*) model

Ma Lina[1], *Zhang Xin*[1], *Liang Yongqian*[2], *Mei Leilei*[2]
(1.School of Civil Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;2.Zhongjiao Road and Bridge Construction Co., Ltd., Beijing 101100, China)

Abstract: Accurate settlement prediction is essential for ensuring subgrade construction quality and the

收稿日期:2025-06-26;**修回日期**:2026-04-07
基金项目:甘肃省科技重大专项计划(25ZDWA006);中国国家铁路集团有限公司科技研究开发计划课题(N2024G047)
Foundation items: Gansu Provincial Science and Technology Major Project (25ZDWA006); Science and Technology Research and Development Program of China State Railway Group Co., Ltd. (N2024G047)
第一作者:马丽娜(1985—),女,陕西渭南人,教授,博士.研究方向为特殊土工程、隧道工程. **email**:malina198546@126.com.
通信作者:张欣(2000—),男,四川泸州人,硕士生. **email**:1337631963@qq.com.

引用格式:马丽娜,张欣,梁永迁,等.PSO-BP优化MGM(1,*n*)模型的风积沙路基沉降预测研究[J].北京交通大学学报,2026,50(4):66-79.
Ma Lina, Zhang Xin, Liang Yongqian, et al. Study on settlement prediction for aeolian-sand subgrades based on PSO-BP-optimized MGM(1,*n*) model[J]. Journal of Beijing Jiaotong University, 2026, 50(4): 66-79. (in Chinese)

long-term safe operation of highways. Aeolian sand has low shear strength and can undergo substantial settlement deformation when used as subgrade fill, thereby compromising pavement structural safety. Taking an aeolian-sand section of National Highway G219 as the study site, this study proposes a high-accuracy PSO-BP-MGM(1, n) model for subgrade settlement prediction. First, settlement data collected using embedded monitoring instruments are used as modeling samples. Next, a hybrid model is constructed by integrating the Multivariable Grey Model (MGM(1, n)) with Particle Swarm Optimization (PSO) and a Back Propagation (BP) neural network. The MGM(1, n) model captures settlement trends, while PSO-BP performs nonlinear correction of the MGM(1, n) prediction residuals, thereby compensating for the limited nonlinear fitting capability of MGM(1, n) and reducing the tendency of BP neural networks to overfit small samples. Finally, the proposed model is applied to settlement prediction for the G219 aeolian-sand subgrade. The results show that the settlement predictions obtained using the PSO-BP-MGM(1, n) model agree most closely with the measured values. Compared with the MGM(1, n) model, the maximum reductions in Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE), and Sum of Squared Errors (SSE) are 1.341 percentage points, 0.528, and 1.817, respectively; compared with the hyperbolic model, the corresponding maximum reductions are 2.21 percentage points, 0.965, and 5.523. All absolute grey relational grades for the PSO-BP-MGM(1, n) model exceed 0.995, outperforming those of the MGM(1, n) and hyperbolic models. The proposed model accounts for interactions among monitoring points and is therefore suitable for joint multi-point prediction. By further modeling and correcting the MGM(1, n) prediction residuals, PSO-BP effectively identifies systematic components hidden in the residual sequences and improves the overall prediction accuracy. The proposed approach can support subgrade settlement control in aeolian-sand regions and settlement prediction under similar geological conditions.

Keywords: aeolian-sand subgrade; MGM(1, n) model; PSO-BP model; residual correction; settlement prediction

路基是公路的基础承重结构,其沉降变形直接影响路面结构安全与公路运营寿命.传统上,公路路基主要以砂石土等材料筑造.新疆荒漠地区风积沙资源丰富,但其他筑路材料匮乏,故常用风积沙作为筑路材料.风积沙抗剪强度低,主要靠颗粒间摩擦力抵抗剪切变形,因缺乏黏结力导致其易发生滑动和剪切变形[1].路基变形对道路交通安全构成严重威胁,准确预测路基沉降对有效预防路基变形危害至关重要,是开展路基预防工作的前提.

当前,基于实测变形进行变形预测的常见方法有两类.第一类是曲线预测法,如Asaoka法[2]、双曲线法[3-4]、三点法[5]等.第二类是灰色模型(Grey Model, GM)[6-7]与机器学习法[8-10],如文献[11]利用四参数Logistic模型分析雄安新区高速公路路基沉降特征;文献[12]根据数值模拟结果建立灰色模型,预测了不同工况地表和管线的沉降值;文献[13]提出一种基于粒子群优化算法(Particle Swarm Optimization,PSO)的双向长短期记忆神经网络(Bidirectional Long Short-Term Memory, Bi-LSTM)预测模型,实现了对下穿现有隧道引起地面沉降的准确、稳定预测.

此外,研究发现不同预测方法各有优势,基于各方法的不同特性,可将其组合应用于预测场景,以实现优势互补.文献[14]将邓英尔、双曲线、灰色费尔哈斯3种模型进行组合后提出预测模型,其精度显著优于单独的预测模型.

灰色模型具有不需要大量样本、计算工作量小等优点.目前关于灰色模型预测的研究,不仅聚焦于组合应用层面,更注重对各类优化方法的探索与改进.文献[6]通过三次样条插值优化灰色模型背景值的选择,并用于预测隧道顶板沉降;针对灰色系统模型在变形预测中存在预测结果不理想的问题,文献[15]给出马尔可夫残差修正模型,使灰色模型的预测精度明显提高;文献[16]对灰色模型的参数进行组合优化,得到预测效果较好的多变量灰色模型.

由于神经网络具有强大的非线性拟合能力、泛化能力与鲁棒性,其也常常被用于工程预测.文献[17]

提出一种泛化性较好，且能捕获沉降数据时空特性的深度神经网络模型；文献[18]设计一种改进的蜣螂优化算法-反向传播神经网络-自适应提升算法的组合预测模型，可有效解决预测时间短的问题；文献[19]利用混合蛙跳算法和Elman神经网络模型对合肥重点城区地表变形进行了准确预测.

但神经网络进行预测需要大量的样本数据，在一定程度上限制了神经网络的适用范围.若将灰色模型与神经网络相互结合，使神经网络捕捉非线性能力的优点与灰色模型建模所需样本量少、精度高的优点相结合，有望得到较精准的预测模型.文献[20]提出一种基于灰色模型与反向传播(Back Propagation, BP)神经网络相结合的桥梁预拱度预测方法，预测精度优于两者单独预测结果；文献[21]结合灰色理论建立基于灰色最小二乘支持向量机的基坑变形时序预测模型，可以更好地预测波动较大的数据；文献[22]应用神经网络的非线性回归分析确定区间数据，结合灰色预测推导出能源需求上下限的趋势；文献[23]用灰色模型进行样本预测后，将BP神经网络用于修正灰色模型预测结果的残差，提高了灰色模型的预测精度；文献[24]提出一种灰色离散Verhulst模型与BP神经网络组合的预测模型，更好地预测了基坑沉降；文献[25]运用支持向量机，通过二次对数复合函数平滑优化和序列权重优化改进了单变量灰色模型(Grey Model, GM(1,1))模型，并用改进的模型预测了轨道的不平顺区间，为轨道不平顺预测提供了一种新思路.

但目前风积沙路基沉降预测研究方法多集中于利用室内试验获得的变形特性.文献[26]利用动三轴试验建立了考虑动应力幅值、含水率及围压的风积沙累积塑性应变预测模型；文献[27]也利用动三轴研究风积沙的弹性变形，采用弹性应变预测模型对典型试样的结果进行预测.而基于工程实测数据对实际路基工程进行沉降预测的研究却相对匮乏.

综上所述，目前在路基沉降预测领域，针对灰色模型的优化及其组合运用的研究颇为广泛，尤其将灰色模型与神经网络等进行结合、优化的应用更为普遍，具有较高的实用性.然而，针对风积沙路基工程，目前仍缺乏可直接应用于实际工程沉降预测的有效方法.鉴于此，本文以G219线喀什地区叶城县至恰热克风积沙路段为依托，选取典型断面埋设单点沉降计，自动采集断面监测点的沉降数据，运用采集的沉降数据，建立多变量灰色模型(Multivariable Grey Model, MGM(1,n))初步预测路基沉降；然后，将PSO算法用于优化BP神经网络，建立PSO-BP模型用于修正灰色模型残差，提出适用于预测风积沙路基沉降的PSO-BP-MGM(1,n)模型，可推广应用于其他复杂地质条件下的路基沉降预测.

1 工程概况及路基监测方案

1.1 工程概况

G219线叶城县至恰热克地区的K63+100～K66+300、K69+300～K74+200以及K75+200～K75+300路段属于风沙区.该区域沿线主要为风积沙地质，因此在道路建设中，主要采用风积沙填筑路基的方式，工程类型包括填方和挖方.研究表明，路基填筑高度与变形量呈正相关，较高的填筑高度会产生更大的变形[28]，因此在预测研究方面更具价值.根据路基断面设计图，选取填方高度较高的K64+420断面进行沉降分析，该断面的填筑高度为5.402 m.

1.2 路基监测方案

路基变形主要研究竖向方向的变形，即沉降[29].鉴于此，选定断面埋设单点沉降计JMDL-4720AT(基于电感磁通调频技术，非接触式测杆线圈设计，量程200 mm，灵敏度0.01 mm，精度0.5%FS，数据采集间隔为10 min)，用于采集测点的沉降变形数据；配置太阳能供电装置与远程传输装置，将实时采集的变形数据同步上传至云平台.

路基中心为断面填筑最高、附加应力最集中处，即沉降盆峰值点；而左右行车道为运营期直接承受车辆荷载的核心区域.基于此，共布设3台单点沉降计，分别位于路基中心及左右行车道.通过多点协同观测的方式，持续追踪路基的沉降变形动态.风积沙路基横断面的沉降监测点布置如图1所示.

2 MGM(1,n)模型优化思路

2.1 MGM(1,n)模型原理

传统道路沉降预测常采用GM(1,1)，但该模型仅基于单个监测点建模预测.实际工程中，同一监测断面往往布设多个监测点，各点变形会受不同程度相互影响.工程中常借助灰色关联理论判断各监测点间的关联程度：灰色关联度越大，彼此相关性越高[30].文献[30]在此基础上扩展出MGM(1,n)模型，通过综合考虑同一断面各监测点的相互影响，有效提升了灰色模型的预测精度.

2.1.1 灰色关联度计算

假定路基监测断面共有n个变形监测点，将采集到的共m个周期的变形数据作为原始序列，第i个监测点的沉降原始序列$\boldsymbol{X}_i^{(0)}$为

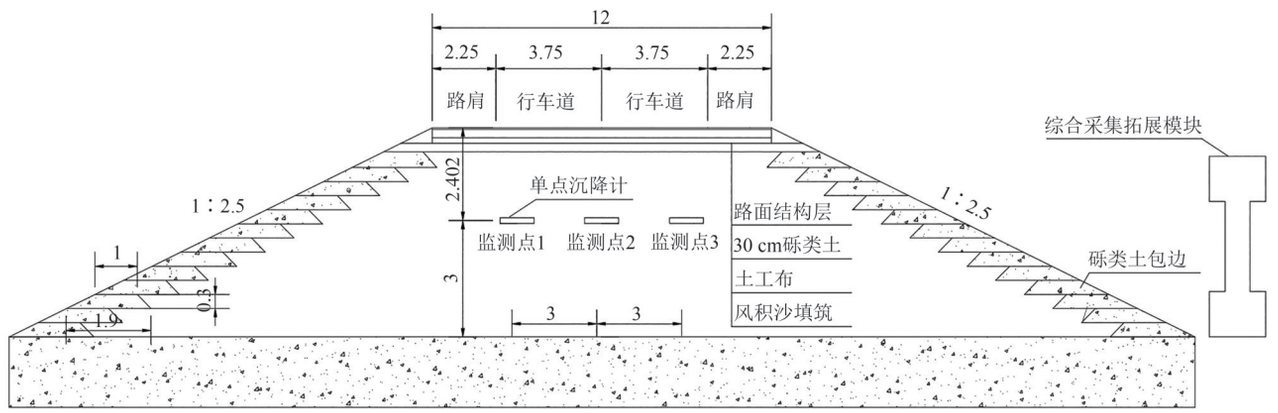


图1　监测点布置示意(单位:m)

Fig.1　Layout of monitoring points (unit: m)

$$\boldsymbol{X}_i^{(0)}=\left\{x_i^{(0)}(1),\ \cdots,\ x_i^{(0)}(k),\ \cdots,\ x_i^{(0)}(m)\right\} \tag{1}$$

式中:i为监测点编号,i=1,2,…,n;k为离散对应时刻,k=1,2,…,m;m为沉降原始序列的总周期;$x_i^{(0)}(k)$为第i个监测点在k时刻的原始序列值.

将第i个监测点的原始序列$\boldsymbol{X}_i^{(0)}$作为参考序列$\boldsymbol{x}_0$,其他n−1个实测序列作为比较序列$\boldsymbol{x}_j$.则参考序列与比较序列的归一化值分别为

$$x_0'(k)=\frac{x_0(k)}{\max\left(x_0(k)\right)} \tag{2}$$

$$x_j'(k)=\frac{x_j(k)}{\max\left(x_j(k)\right)} \tag{3}$$

式中:$x_0'(k)$、$x_j'(k)$分别为序列$\boldsymbol{x}_0$、$\boldsymbol{x}_j$在k时刻的归一化值;$x_0(k)$、$x_j(k)$分别为参考序列$\boldsymbol{x}_0$、比较序列$\boldsymbol{x}_j$在k时刻的原始序列值;$\max\left(x_0(k)\right)$、$\max\left(x_j(k)\right)$分别为参考序列、比较序列中的最大值.

则参考序列$\boldsymbol{x}_0$与比较序列$\boldsymbol{x}_j$在k时刻的灰色关联系数$\xi_j(k)$为[31]

$$\xi_j(k)=\frac{\min\limits_j\min\limits_k\left|x_0'(k)-x_j'(k)\right|+\rho\max\limits_j\max\limits_k\left|x_0'(k)-x_j'(k)\right|}{\left|x_0'(k)-x_j'(k)\right|+\rho\max\limits_j\max\limits_k\left|x_0'(k)-x_j'(k)\right|} \tag{4}$$

式中:ρ为分辨系数,ρ越小,分辨率越大,一般$\rho\in[0,1]$,具体取值视情况而定,当$\rho\leqslant$0.546 3时,其分辨力最好,通常ρ取0.5[31];$\min\limits_j\min\limits_k\left|x_0'(k)-x_j'(k)\right|$与$\max\limits_j\max\limits_k\left|x_0'(k)-x_j'(k)\right|$分别为所有比较序列与参考序列在各时刻的最小绝对差值与最大绝对差值.

取各点灰色关联系数$\xi_j(k)$的计算平均值为灰色关联度r_j,用以判断各个序列间的联系是否紧密,其表达式为

$$r_j=\frac{1}{m}\sum_{k=1}^{m}\xi_j(k) \tag{5}$$

$r_j\geqslant$0.5,即可认为比较序列与参考序列有关联,且r_j越大,相互联系越紧密[31].

2.1.2　MGM(1,n)模型建立

通过灰色模型关联度判定各监测点之间具有相互影响后,进一步建立MGM(1,n)模型,建立方法如下.

利用原始序列生成一次累加序列为

$$\boldsymbol{X}^{(1)}=\begin{bmatrix}x_1^{(1)}(1)x_2^{(1)}(1)\cdots x_i^{(1)}(1)\cdots x_n^{(1)}(1)\\ x_1^{(1)}(2)x_2^{(1)}(2)\cdots x_i^{(1)}(2)\cdots x_n^{(1)}(2)\\ \vdots\quad\vdots\quad\vdots\quad\vdots\\ x_1^{(1)}(k)x_2^{(1)}(k)\cdots x_i^{(1)}(k)\cdots x_n^{(1)}(k)\\ \vdots\quad\vdots\quad\vdots\quad\vdots\\ x_1^{(1)}(m)x_2^{(1)}(m)\cdots x_i^{(1)}(m)\cdots x_n^{(1)}(m)\end{bmatrix} \tag{6}$$

式中:$x_i^{(1)}(k)$为第i个监测点在k时刻的一次累加值,$x_i^{(1)}(k)=\sum\limits_{j=1}^{k}x_i^{(0)}(j)$,$k$=1,2,…,$m$.

考虑到同一断面上的n个监测点相互影响,生成序列建立的n元一次常微分方程组为

$$\begin{cases}\dfrac{\mathrm{d}x_1^{(1)}(t)}{\mathrm{d}t}=a_{11}x_1^{(1)}(t)+a_{12}x_2^{(1)}(t)+\cdots+a_{1n}x_n^{(1)}(t)+b_1\\ \dfrac{\mathrm{d}x_2^{(1)}(t)}{\mathrm{d}t}=a_{21}x_1^{(1)}(t)+a_{22}x_2^{(1)}(t)+\cdots+a_{2n}x_n^{(1)}(t)+b_2\\ \vdots\\ \dfrac{\mathrm{d}x_n^{(1)}(t)}{\mathrm{d}t}=a_{n1}x_1^{(1)}(t)+a_{n2}x_2^{(1)}(t)+\cdots+a_{nn}x_n^{(1)}(t)+b_n\end{cases} \tag{7}$$

令$\boldsymbol{A}=\begin{bmatrix}a_{11} & a_{12} & \cdots & a_{1n}\\ a_{21} & a_{22} & \cdots & a_{2n}\\ \vdots & \vdots & & \vdots\\ a_{n1} & a_{n2} & \cdots & a_{nn}\end{bmatrix}$,$\boldsymbol{B}=[b_1\ \ b_2\ \ \cdots\ \ b_n]^{\mathrm{T}}$.

式中：$\boldsymbol{A}$为MGM(1,n)模型的影响系数矩阵，a_{11}～a_{nn}为系数；$\boldsymbol{B}$为MGM(1,n)模型的趋势项向量，b_1～b_n为常数；t为k时刻对应的连续时间自变量.

则式(7)的矩阵形式为

$$\frac{\mathrm{d}\boldsymbol{X}^{(1)}(t)}{\mathrm{d}t}=\boldsymbol{A}\boldsymbol{X}^{(1)}(t)+\boldsymbol{B} \tag{8}$$

式中：$\boldsymbol{X}^{(1)}(t)=\left[x_1^{(1)}(t),x_2^{(1)}(t),\cdots,x_n^{(1)}(t)\right]^{\mathrm{T}}$.

式(7)对应解的时间响应式为

$$\boldsymbol{X}^{(1)}(t)=\boldsymbol{e}^{\boldsymbol{A}t}(\boldsymbol{X}^{(1)}(0)+\boldsymbol{A}^{-1}\boldsymbol{B})-\boldsymbol{A}^{-1}\boldsymbol{B} \tag{9}$$

转化为对应的离散时间响应式为[31]

$$\hat{\boldsymbol{X}}^{(1)}(k)=\boldsymbol{e}^{\boldsymbol{A}(k-1)}(\boldsymbol{X}^{(1)}(1)+\boldsymbol{A}^{-1}\boldsymbol{B})-\boldsymbol{A}^{-1}\boldsymbol{B} \tag{10}$$

式中：$\boldsymbol{X}^{(1)}(k)$为原始序列经一次累加之后，k时刻的状态向量；$\hat{\boldsymbol{X}}^{(1)}(k)$为预测沉降序列在$k$时刻的一次累加序列.

令$\boldsymbol{I}$为单位矩阵，$\boldsymbol{e}^{\boldsymbol{A}(k-1)}$为矩阵指数，其表达式为

$$\boldsymbol{e}^{\boldsymbol{A}(k-1)}=\boldsymbol{I}+\sum_{i=1}^{\infty}\frac{\boldsymbol{A}^i}{i!}(k-1)^i \tag{11}$$

$\boldsymbol{A}$、$\boldsymbol{B}$与MGM(1,n)模型的综合参数矩阵$\boldsymbol{H}$有关，$\boldsymbol{H}=\begin{pmatrix}\boldsymbol{A}\\ \boldsymbol{B}^{\mathrm{T}}\end{pmatrix}$，根据最小二乘法，$\boldsymbol{H}$为

$$\boldsymbol{H}=(\boldsymbol{L}^{\mathrm{T}}\boldsymbol{L})^{-1}\boldsymbol{L}^{\mathrm{T}}\boldsymbol{Y} \tag{12}$$

式中：$\boldsymbol{L}$为背景值矩阵；$\boldsymbol{Y}$为去掉第一时刻的原始序列，表达式分别为

$$\boldsymbol{L}=\begin{bmatrix}z_1^{(1)}(2) & z_2^{(1)}(2) & \cdots & z_n^{(1)}(2) & 1\\ z_1^{(1)}(3) & z_2^{(1)}(3) & \cdots & z_n^{(1)}(3) & 1\\ \vdots & \vdots & & \vdots & \vdots\\ z_1^{(1)}(m) & z_2^{(1)}(m) & \cdots & z_n^{(1)}(m) & 1\end{bmatrix} \tag{13}$$

$$\boldsymbol{Y}=\left[x_i^{(0)}(2)\ \ x_i^{(0)}(3)\cdots x_i^{(0)}(m)\right]^{\mathrm{T}}\quad i=1,2,\cdots,n \tag{14}$$

式中：$z_i^{(1)}(k)(i=1,2,\cdots,n;k=2,3,\cdots,m)$为模型的背景值.当模型的一次累加序列元素$x_i^{(1)}(k)\neq x_i^{(1)}(k-1)$时，优化后的背景值$z_i^{(1)}(k)$为[31]

$$z_i^{(1)}(k)=\frac{x_i^{(0)}(k)}{\ln\dfrac{x_i^{(0)}(k)}{x_i^{(0)}(k-1)}}+x_i^{(1)}(k)-\frac{(x_i^{(0)}(k))^2}{x_i^{(0)}(k)-x_i^{(0)}(k-1)} \tag{15}$$

当$x_i^{(1)}(k)=x_i^{(1)}(k-1)$，由于式(15)中$\dfrac{x_i^{(0)}(k)}{\ln\dfrac{x_i^{(0)}(k)}{x_i^{(0)}(k-1)}}$、$\dfrac{(x_i^{(0)}(k))^2}{x_i^{(0)}(k)-x_i^{(0)}(k-1)}$趋近于无穷大，$z_i^{(1)}(k)$不可按照式(15)计算.此时$z_i^{(1)}(k)$的表达式为

$$z_i^{(1)}(k)=0.5x_i^{(1)}(k)+0.5x_i^{(1)}(k-1) \tag{16}$$

根据式(10)得出预测的一次累加序列$\hat{\boldsymbol{X}}^{(1)}$，将$\hat{\boldsymbol{X}}^{(1)}$的元素作累减还原，可得$k$时刻的预测沉降值$\hat{\boldsymbol{x}}^{(0)}(k)$为

$$\hat{\boldsymbol{x}}^{(0)}(k)=\hat{\boldsymbol{x}}^{(1)}(k)-\hat{\boldsymbol{x}}^{(1)}(k-1) \tag{17}$$

式中：$\hat{\boldsymbol{x}}^{(1)}(1)=\hat{\boldsymbol{x}}^{(0)}(1)$；$\hat{\boldsymbol{x}}^{(1)}(k)$为$k$时刻的一次累加预测值.

2.2 PSO-BP模型构建

人工神经网络是受神经元结构启发设计出的一种计算模型.BP神经网络通常由输入层、隐藏层和输出层组成.输入层接收外部数据，隐藏层可以有一层或多层，对输入数据进行非线性变换和特征提取，输出层给出最终的预测结果.各层之间通过权重连接，权重决定了神经元之间信号传递的强度，BP神经网络架构如图2所示.图2中：x_1～x_4为输入层输入值；h_1～h_5为隐藏层神经元；$W_1^{\,l}$是输入层到隐藏层的第l个权值；$W_2^{\,l}$是隐藏层到输出层的第l个权值；$B_1^{\,l}$是隐藏层的第l个阈值；B_2是输出层的阈值；y为输出层的输出值.

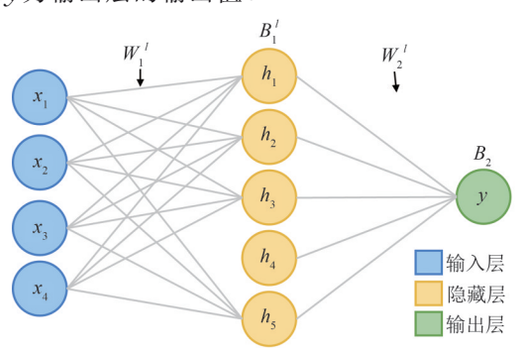


图2 BP神经网络架构

Fig.2 Architecture of the BP neural network

PSO算法是一种基于群智能方法的优化技术，灵感来源于鸟群、鱼群等生物群体的集体行为.PSO算法中粒子作为基本概念，在解空间中具有速度和位置2种属性，分别决定其方向和距离.每个粒子遵守不碰撞、速度协调、向相似群体靠拢的规则.根据自身与群体最优位置，粒子通过更新自身速度和位置以寻找最优解[32].

PSO-BP模型的构建分为6个步骤.

步骤1：数据归一化.通过mapminmax函数将输入值缩放到[0,1]范围内，加速神经网络收敛.

步骤2:建立BP神经网络模型.确定网络结构,初始网络权重、阈值与训练参数.

步骤3:初始化PSO算法参数.对学习因子,惯性权重,种群更新次数,种群规模,粒子更新最大、最小速度等参数进行初始化.

步骤4:PSO优化.基于每个粒子初始位置计算适应度评估指标,即训练集上的均方根误差(Root Mean Square Error,RMSE),根据指标评估性能.

步骤5:PSO迭代寻优.不断更新粒子的个体最优解(P_{best})和群体历史最优解(G_{best}),并利用自适应变异防止PSO算法陷入局部最优解,即通过固定概率触发策略实现,在每次迭代中,对每个粒子生成一个[0,1]的均匀随机数,当该随机数大于0.95(变异概率为0.05)时,执行变异操作.具体方式为,随机选择一个维度,将该维度的粒子位置值重置为[−1,1]范围内的随机数,并通过边界约束将其限制在搜索边界[−2,2]内,旨在引入扰动以帮助粒子逃离局部最优区域.直至达最大迭代次数或粒子群搜索到适应阈值规定内的全局最优位置时,终止PSO算法.

P_{best}和G_{best}求解方式为

$$v_p(t+1)=wv_p(t)+c_1r_1(t)\left[P_{\text{best}_p}(t)-x_p(t)\right]+c_2r_2(t)\left[G_{\text{best}_p}(t)-x_p(t)\right] \tag{18}$$

$$x_p(t+1)=x_p(t)+v_p(t+1) \tag{19}$$

式中:$v_p(t)$为粒子p在时刻t的速度;w为惯性权重;c_1、c_2为学习因子,分别控制个体和全局的权重;$r_1(t)$、$r_2(t)$为用于增加算法随机性的随机数;$P_{\text{best}_p}(t)$为粒子p在t时刻的历史最优位置;$G_{\text{best}_p}(t)$为整个群体在t时刻的历史最优位置;$x_p(t)$为粒子p在t时刻的位置.

步骤6:网格训练与预测.将PSO搜索到的最优权值/阈值输入BP神经网络,对训练集、测试集进行预测,最后通过反归一化输出预测结果.

相较BP神经网络,PSO-BP模型通过粒子群算法自动优化权重与阈值参数,不仅可提升自适应学习能力,还可降低对初始值的依赖,从而显著增强模型的准确性与泛化性能.

2.3　PSO-BP模型优化MGM(1,n)原理

MGM(1,n)模型在处理非线性或复杂模式数据时存在局限性[33],而实际数据常因外界因素干扰呈现非线性特征.神经网络通过迭代学习能有效捕捉数据非线性规律,可弥补MGM(1,n)模型的不足.基于此,将PSO-BP模型与MGM(1,n)模型结合,构建PSO-BP-MGM(1,n)模型,如图3所示.

PSO-BP-MGM(1,n)模型的构建分为4个步骤.

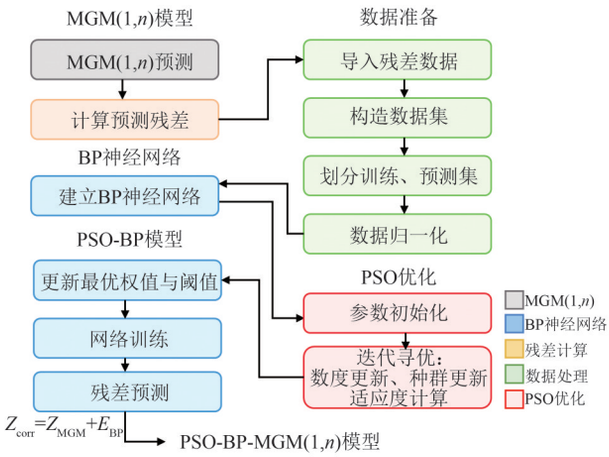


图3　PSO-BP-MGM(1,n)模型建立流程

Fig.3　Workflow for constructing the PSO-BP-MGM(1,n) model

步骤1:利用MGM(1,n)模型进行预测,计算出MGM(1,n)模型预测结果的残差E_{MGM}为

$$E_{\text{MGM}}=Z_0-Z_1 \tag{20}$$

式中:Z_0为沉降原始序列值;Z_1为MGM(1,n)模型预测值.

步骤2:将E_{MGM}输入PSO算法,由PSO算法自动寻优、更新BP神经网络的权重与阈值,提高BP神经网络模型的自适应学习能力,构建PSO-BP模型.

步骤3:由PSO-BP模型学习E_{MGM}的变化模式,对E_{MGM}进行滚动预测.

步骤4:将PSO-BP模型的残差预测结果与MGM(1,n)的预测值相加,得到PSO-BP-MGM(1,n)模型的最终预测结果为

$$Z_{\text{corr}}=Z_{\text{MGM}}+E_{\text{BP}} \tag{21}$$

式中:Z_{corr}为修正后模型的预测值,即PSO-BP-MGM(1,n)模型的预测值;Z_{MGM}为MGM(1,n)模型的预测值;E_{BP}为PSO-BP模型预测的残差值.

综上,PSO-BP-MGM(1,n)模型的核心思想是将预测任务分解为由MGM(1,n)模型完成的线性或单一模式部分以捕捉数据中的主要趋势,以及由PSO-BP模型完成的非线性或复杂修正部分.使用“模型+修正”的组合方法,可取得较好的预测效果.

3　风积沙路基沉降预测

3.1　沉降规律分析

为分析风积沙路基沉降规律,监测周期为2024年7月8日~11月5日.提取单点沉降计

JMDL-4720AT 采集到的 3 个监测点数据，对每两天的沉降实测值进行均值化处理．路基采用分层填筑施工，每层厚 30 cm，时间-填筑高度-沉降关系曲线如图 4 所示．

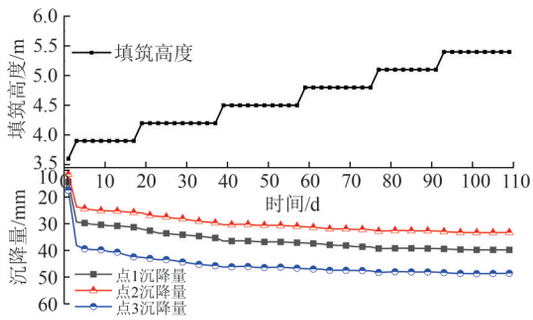


图 4 “时间-填筑高度-实测沉降”关系曲线图

Fig.4 Relationship among time, fill height, and measured settlement

由图 4 可知：各监测点沉降量随时间推移及填筑高度增加而上升；单点沉降计在风积沙虚铺整平后安装，安装后次日因振动压实出现大幅突增；此后压实影响逐渐减弱，沉降突变愈发微弱；第 92 天路基填至最大高度 5.402 m 时，监测点 3 沉降最大，达 48.537 mm；之后无填筑作用影响，沉降增速显著减缓；各测点沉降量差异源于虚铺厚度和初始压实度不同，但演化趋势一致，即初期速率较快，随后减缓并趋于稳定．

路基压实作业导致沉降计安装初期实测沉降体现出显著的非线性特征，而 MGM(1,n)模型处理非线性数据能力较差，因此初期的沉降突变数据不适用此模型．此外，综合考虑外推步长控制，即 MGM(1,n)模型的预测精度随外推步长的增加呈下降趋势，以及采样间隔合理性，且沉降观测值需满足动态变化，分别选取周期为 3 d、5 d、7 d、9 d 进行建模，通过对比不同周期的 MGM(1,n)模型的预测精度，以得出最优的建模周期．本文仅展示周期为 7 d 的建模过程．

实测沉降结果如表 1 所示．从 7 d 起，提取图 4 中的累积沉降实测数据，以 7 d 为间隔，选取共 m=15 个周期的累计沉降变形数据作为原始序列．利用灰色模型样本所需数据少的优势，选用前 10 组数据用于建模，后 5 组用于预测结果的可靠性检验．

3.2 MGM(1,n)模型建立及沉降预测

利用式(4)与式(5)对监测点 1～3 的灰色关联度进行计算，结果如表 2 所示．由表 2 可知，同一断面的 3 个沉降监测点之间的灰色关联系数均大于 0.5．由此可认为这 3 个沉降监测点之间相互关联．

表 1 单点沉降计实测沉降变形

Tab.1 Measured settlement data from single-point settlement gauges

序号	时间/d	监测点 1/mm	监测点 2/mm	监测点 3/mm
1	7	32.662	26.706	43.001
2	14	33.899	27.847	43.770
3	21	34.529	28.824	44.986
4	28	36.060	30.097	45.989
5	35	36.581	30.411	46.198
6	42	36.867	30.706	46.367
7	49	37.321	31.284	46.877
8	56	38.052	31.909	47.383
9	63	38.615	32.160	47.557
10	70	39.190	32.589	48.011
11	77	39.263	32.692	48.146
12	84	39.329	32.780	48.170
13	91	39.708	33.200	48.481
14	98	39.722	33.267	48.641
15	105	39.786	33.320	48.641

表 2 各点灰色关联度 r_j

Tab.2 Grey relational grades between monitoring points

监测点	监测点 1	监测点 2	监测点 3
监测点 1	1	0.92	0.69
监测点 2	0.92	1	0.67
监测点 3	0.69	0.67	1

选取表 1 中前 10 个原始序列建立 MGM(1,n)模型，前 10 个原始序列生成的一次累加序列 $\boldsymbol{X}^{(1)}$ 为

$$\boldsymbol{X}^{(1)}=\begin{bmatrix} 32.662 & 26.706 & 43.001 \\ 66.561 & 54.553 & 86.771 \\ 101.090 & 83.377 & 131.757 \\ 137.150 & 113.474 & 177.746 \\ 173.731 & 143.885 & 223.944 \\ 210.598 & 174.591 & 270.311 \\ 247.919 & 205.875 & 317.188 \\ 285.971 & 237.784 & 364.571 \\ 324.586 & 269.944 & 412.128 \\ 363.776 & 302.533 & 460.139 \end{bmatrix}$$

按式(12)～(16)计算出参数 $\boldsymbol{A}$、$\boldsymbol{B}$ 为

$$\boldsymbol{A}=\begin{bmatrix} -1.00 & -0.69 & -0.01 \\ 0.79 & 0.35 & -0.38 \\ 0.29 & 0.33 & 0.27 \end{bmatrix}$$

$$\boldsymbol{B}=\begin{bmatrix} 33.04 & 26.73 & 42.44 \end{bmatrix}^{\mathrm{T}}$$

按式(10)计算出一次累加序列的预测值 $\hat{\boldsymbol{X}}^{(1)}$ 为

$$\hat{\boldsymbol{X}}^{(1)}=\begin{bmatrix}32.662 & 26.706 & 43.001\\ 66.321 & 54.030 & 87.121\\ 101.090 & 81.978 & 131.985\\ 136.643 & 110.853 & 177.743\\ 173.114 & 140.624 & 224.307\\ 209.650 & 170.816 & 271.004\\ 246.949 & 201.490 & 318.128\\ 285.801 & 232.418 & 365.995\\ 325.285 & 263.654 & 414.266\\ 364.974 & 295.591 & 462.663\\ 404.795 & 328.016 & 511.268\\ 444.799 & 360.679 & 560.143\\ 484.965 & 393.590 & 609.164\\ 525.272 & 426.674 & 658.317\\ 565.786 & 459.890 & 707.643\end{bmatrix}$$

划分第1～10个时间序列的数据为训练集,第11～15个时间序列的数据为预测集.基于式(17)累减还原处理获取预测值,进而得到各时间序列中各沉降监测点的预测结果.其中时间预测集各监测点沉降预测值如表3所示.

表3　预测集各点Z_{MGM}

Tab.3　Z_{MGM} for the test set at each monitoring point

时间序列	天数/d	监测点1/mm	监测点2/mm	监测点3/mm
11	77	39.821	32.425	48.605
12	84	40.004	32.863	48.875
13	91	40.166	33.711	49.021
14	98	40.307	33.884	49.153
15	105	40.514	34.376	49.326

为确定最优预测周期,利用平均绝对百分比误差(Mean Absolute Percentage Error,MAPE)评估MGM(1,n)模型外推预测集的精度,计算结果如表4所示.

由表4可知:①预测周期为7 d时,外推预测集的MAPE值最优.这是因为以3 d、5 d为周期时,建模序列包含沉降初期压实作业引发的非线性突变数据,且此时预测到105 d时外推次数较多(周期为3 d时需要外推15组、周期为5 d需要外推11组),导致误差逐渐累积,预测精度偏低.②预测周期为9 d时,建模序列丢失部分中期特征,信息密度不足,精度略低于7 d.③预测周期为7 d时,建模序列避开非线性阶段且保留沉降中期关键演化信息,且外推5组数据即可预测105 d,模型平均MAPE降至1.415%,MGM(1,n)模型预测精度最高.

综上,预测周期为7 d时,兼顾了非线性干扰规避、建模信息密度、外推预测次数,因此选择周期为7 d结果进行后续计算.

表4　不同预测周期外推预测集精度MAPE

Tab.4　Test-set prediction accuracy MAPE at different sampling intervals

预测周期/d	监测点1/%	监测点2/%	监测点3/%
3	2.314	2.872	2.651
5	1.926	2.211	1.912
7	1.519	1.527	1.198
9	1.762	1.893	1.312

采用预测周期为7 d的MGM(1,n)模型对各监测点沉降量进行预测,将预测值与实测值对比,计算得到残差序列E_{MGM},如表5所示.

表5　预测集各点E_{MGM}

Tab.5　E_{MGM} for the test set at each monitoring point

时间序列	监测点1/mm	监测点2/mm	监测点3/mm
11	−0.558	0.267	−0.459
12	−0.675	−0.083	−0.705
13	−0.458	−0.511	−0.54
14	−0.585	−0.617	−0.512
15	−0.728	−1.056	−0.685

3.3　PSO-BP模型修正残差

在BP神经网络结构设计中,各层神经元数及激活函数的选取,依据时序数据建模准则与沉降残差特征确定,具体如下.

输入层:神经元数为3,即采用3步滚动输入模式,选取残差序列中前3期的残差值作为输入变量,挖掘残差序列的时间关联特征,该输入维度在小样本时序数据建模中可有效平衡特征捕捉能力与过拟合风险.

输出层:神经元数为1,即以第4时刻的残差值作为预测输出,实现残差的单步预测;输出层采用Purelin线性激活函数,实现沉降残差的连续数值全范围预测,与残差实际幅值范围一致.

隐藏层:分别测试1～10个神经元的算法训练效果,以训练集RMSE最小、收敛速度最快且无过拟合为准则,确定隐藏层神经元数为5,采用Sigmoid非线性激活函数,其输出值在[0,1]区间,与残差数据经mapminmax函数归一化后的范围一致,可有效实现残差序列的非线性特征映射.

按式(20)计算出第1～15个时间序列的E_{MGM}.依据PSO文献[34]确定学习因子采用$c_1=c_2$的对称形式,在此基础上通过分级网格搜索(在学习因子为1～5的区间粗筛、4～5区间按0.2步长细分、4.4～4.6区间按0.05步长精细搜索…),以训练集均方根误差最小化为准则,最终确定$c_1=c_2=4.494$.

依据文献[35]经验,惯性权重w过小,导致

PSO局部搜索过强，神经网络拟合能力不足；而w过大，导致PSO全局搜索过强，收敛精度差，甚至不收敛.为确定适合的w，将w设置为0.1～0.9分别进行试运行，以PSO算法的最终收敛适应值作为适应指标，适应值结果如表6所示.由表6可知，w=0.4时PSO适应值最优，因此w取0.4.粒子群更新的最大与最小速度分别设置为1与－1，最大与最小边界分别为2与-2.

表 6 不同惯性权重下PSO适应值

Tab.6 PSO fitness values for different inertia weights

惯性权重	监测点1	监测点2	监测点3
0.1	0.031 2	0.036 5	0.040 1
0.2	0.020 5	0.028 2	0.035 7
0.3	0.018 7	0.021 3	0.030 9
0.4	0.014 9	0.015 7	0.028 6
0.5	0.016 6	0.016 2	0.030 4
0.6	0.015 1	0.017 4	0.029 9
0.7	0.016 3	0.016 8	0.032 5
0.8	0.015 8	0.018 7	0.031 7
0.9	0.018 6	0.019 2	0.035 3

当最大迭代次数较少时，PSO未收敛，导致BP神经网络拟合能力不足，精度偏低；最大迭代次数过多时，PSO已收敛，对BP神经网络性能无提升，造成计算浪费.为确定最大迭代次数，将最大迭代次数设置为10～50次分别运行，PSO适应值结果如表7所示.

由表7可知：监测点1与监测点2在迭代20次时已达到最优，后续迭代时PSO适应值不变；而监测点3在迭代30次时为最优，后续迭代时PSO算法的适应值不变，因此最大迭代次数取30.

表 7 不同迭代次数PSO适应值

Tab.7 PSO fitness values for different numbers of iterations

最大迭代次数	监测点1	监测点2	监测点3
10	0.034 9	0.037 5	0.116 3
20	0.014 9	0.015 7	0.104 3
30	0.014 9	0.015 7	0.028 6
40	0.014 9	0.015 7	0.028 6
50	0.014 9	0.015 7	0.028 6

PSO算法自动寻优的迭代过程如图5所示.

由图5可知：监测点1迭代10次已基本收敛；监测点2与监测点3迭代至20次时基本收敛，均迭代至30次结束；将迭代至结束时的W_1^l、W_2^l、B_1^l、B_2等参数赋予BP神经网络，设置BP神经网络的最大训练次数为100、目标误差为1×10^{-6}、学习率为0.01，构建PSO-BP模型.

PSO-BP模型预测的E_{BP}与原始E_{MGM}的对比结果如图6所示.由图6可知：训练集的残差拟合效果较为理想，E_{BP}曲线与E_{MGM}曲线高度重合；而预测集的残差拟合效果相对欠佳，这并非预测集的拟合能力不足，而是由于预测集的E_{BP}序列是基于前10个输入的E_{MGM}进行滚动预测得到的结果.对比结果说明，训练集残差拟合效果显著优于预测集的原因在于训练集的E_{BP}序列是通过输入已知E_{MGM}序列，让PSO-BP模型对已有数据进行反复拟合后得到的结果.

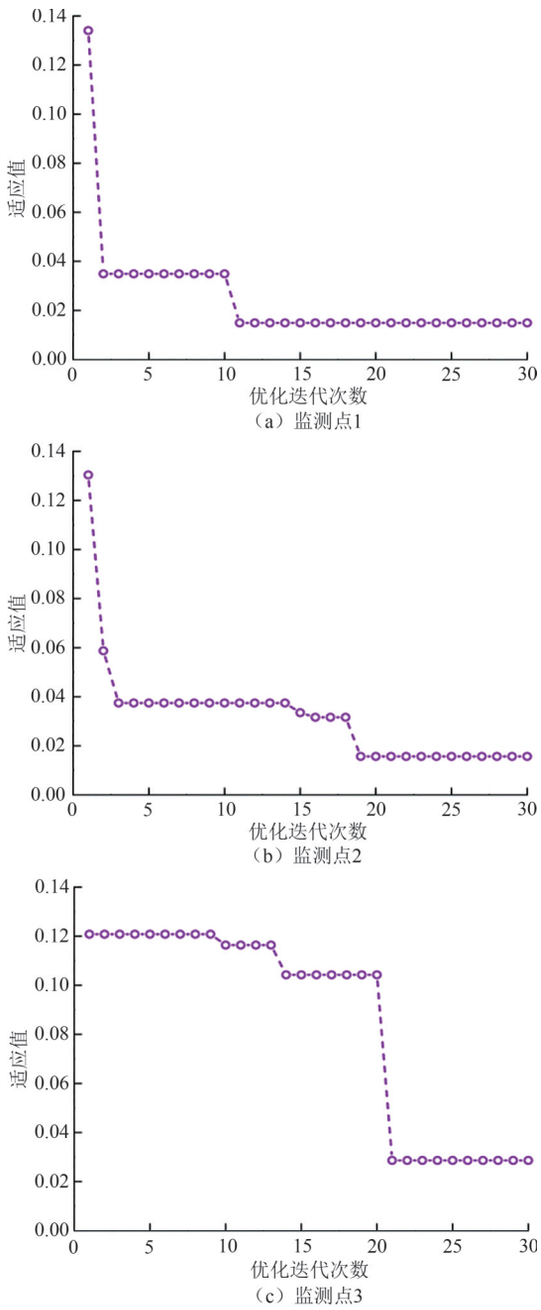


图 5 各监测点PSO算法迭代寻优过程

Fig.5 PSO algorithm iterative optimization process at each monitoring point

利用PSO-BP模型修正后的预测集节点残差结

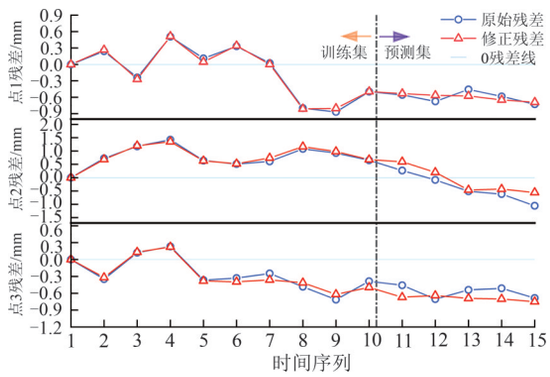


图 6　PSO-BP模型各点残差修正

Fig.6　Residual correction by PSO-BP at each monitoring point

果,计算PSO-BP-MGM(1,n)模型的预测值$Z_{\text{BP-MGM}}$如表8所示.

表 8　各点预测集 $Z_{\text{BP-MGM}}$

Tab.8　$Z_{\text{BP-MGM}}$ for the test set at each monitoring point mm

时间序列	监测点 1	监测点 2	监测点 3
11	39.287	33.020	47.935
12	39.438	32.351	48.234
13	39.589	33.249	48.340
14	39.659	33.454	48.420
15	39.823	34.220	48.678

计算PSO-BP-MGM(1,n)模型预测值的残差$E_{\text{BP-MGM}}$如表9所示.

由表9可知:①PSO-BP-MGM(1,n)模型的预测残差较小;最大残差出现在监测点2,其值为−0.5;最小残差在监测点1,其值为0.02.②从残差分布特征来看,监测点1的预测精度显著优于监测点2和3,这一结论与图6的结果高度吻合,即监测点1的残差拟合效果优于监测点2、3.

表 9　PSO-BP-MGM(1,n)模型预测集 $E_{\text{BP-MGM}}$

Tab.9　PSO-BP-MGM(1,n) for the test set at each monitoring point $E_{\text{BP-MGM}}$　　mm

时间序列	监测点 1	监测点 2	监测点 3
11	−0.024	−0.327	0.211
12	−0.108	−0.285	−0.064
13	0.119	−0.049	0.091
14	0.063	−0.187	0.191
15	−0.037	−0.500	0.063

由式(18)推导可知,只需满足$|E_{\text{MGM}}-E_{\text{PSO-BP}}|<|E_{\text{MGM}}|$,$Z_{\text{corr}}$会更接近实测沉降值.结合图6与表9可知:预测集拟合优度虽低于训练集,但预测残差分布与原始残差特征吻合时,即可提升MGM(1,n)模型预测精度.

3.4　预测结果对比

引入双曲线法对比验证PSO-BP-MGM(1,n)模型的预测精度.双曲线法基本方程为[3]

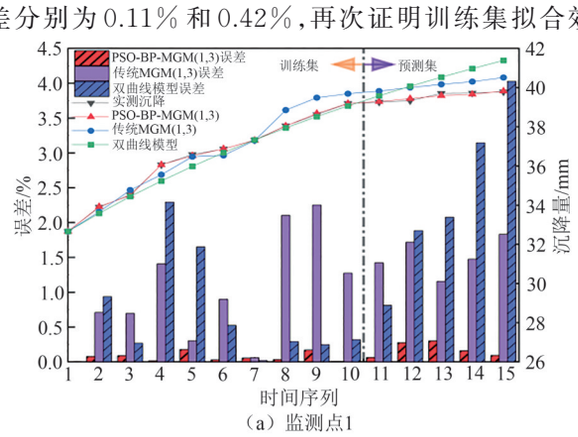
$$S_{t_{\text{p}}}=S_0+\frac{t_{\text{p}}}{a+bt_{\text{p}}} \tag{22}$$

式中:$S_{t_{\text{p}}}$为t_{p}时刻的沉降量;t_{p}为预测时刻;a、b为回归系数,可通过拟合求出;S_0为初始沉降量.

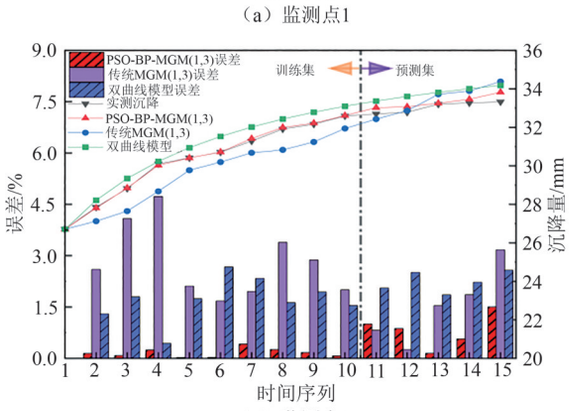
与MGM(1,n)、PSO-BP-MGM(1,n)模型相同:利用前10个原始序列拟合求解a、b,将a、b、S_0及t代入式(19)计算预测值,然后将双曲线模型预测结果与MGM(1,n)模型及PSO-BP-MGM(1,n)模型的预测结果对比分析.

监测点1~3针对双曲线模型、MGM(1,n)、PSO-BP-MGM(1,n)3种模型的沉降预测结果及误差对比如图7所示.

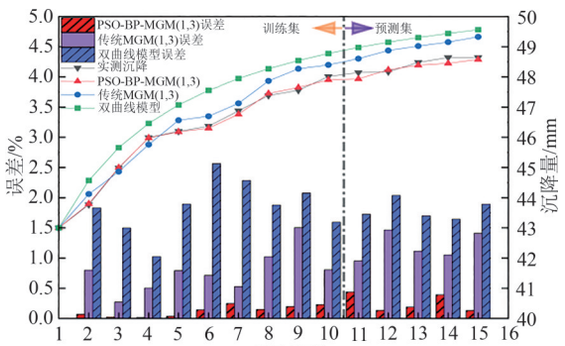
由图7可知:①各监测点中,PSO-BP-MGM(1,n)模型的沉降预测曲线与实测曲线的贴合度最高,能够准确反映实测曲线的变化趋势,表明该模型的拟合能力最强,预测结果最接近原始序列;MGM(1,n)模型的预测曲线与实测曲线亦具有一定贴合度,其对沉降趋势的刻画能力优于双曲线模型.②从误差来看,PSO-BP-MGM(1,n)模型在训练集和预测集上的误差整体较小.以监测点1为例,其训练集误差处于较低水平,预测集误差亦未出现大幅波动,说明该模型具有较好的稳定性与泛化能力.③PSO-BP-MGM(1,n)模型在训练集和预测集上的平均误差分别为0.11%和0.42%,再次证明训练集拟合效



(a) 监测点1



(b) 监测点2



（c）监测点3

图 7 监测点 1~3 各方法沉降预测结果及误差对比

Fig.7 Comparison of settlement predictions and errors obtained using different methods at monitoring points 1-3

果较好.值得注意的是,训练集的拟合结果是模型基于已知数据学习所得,直接将其与MGM(1,n)模型、双曲线模型进行精度对比,不能客观反映模型的预测能力,因此重点基于预测集数据对3种模型的预测精度进行评价.④在预测集上,MGM(1,n)模型与双曲线模型的平均误差分别为1.415%和2.14%,PSO-BP-MGM(1,n)模型的预测精度显著高于前两者;同时,MGM(1,n)模型的精度优于双曲线模型,这是因为前者考虑了监测点间的相互影响,而后者仅基于单点数据进行拟合,进一步验证了考虑多点关联性对提升沉降预测精度的有效性.利用MAPE、RMSE、误差平方和(Sum of Squared Errors,SSE)与灰色绝对关联度σ_{uv}进行预测集的精度评判.则各评价参数表达式为

$$\mathrm{MAPE}=\frac{1}{N}\sum_{k=1}^{N}\left(\frac{|\hat{x}_k-x_k|}{x_k}\right) \tag{23}$$

$$\mathrm{RMSE}=\sqrt{\frac{1}{N}\sum_{k=1}^{N}(x_k-\hat{x}_k)^2} \tag{24}$$

$$\mathrm{SSE}=\sum_{k=1}^{N}(\hat{x}_k-x_k)^2 \tag{25}$$

$$\sigma_{uv}=\frac{1+|s_u|+|s_v|}{1+|s_u|+|s_v|+|s_u-s_v|} \tag{26}$$

$|s_u|$、$|s_v|$、$|s_u-s_v|$分别为

$$|s_u|=\left|\sum_{k=2}^{N-1}x_k+\frac{1}{2}x_N\right|$$

$$|s_v|=\left|\sum_{k=2}^{N-1}\hat{x}_k+\frac{1}{2}\hat{x}_N\right|$$

$$|s_u-s_v|=\left|\sum_{k=2}^{N-1}(x_k-\hat{x}_k)+\frac{1}{2}(x_N-\hat{x}_N)\right|$$

式中:$\hat{x}_k$为始点零化处理后第k时刻的模型预测值;x_k为始点零化处理后k时刻的原始序列值;N为参与关联度精度评判的样本总数;x_N、$\hat{x}_N$分别是始点零化之后实测、预测序列的末尾时刻对应的值;s_u,s_v分别为实测序列x_k与预测序列$\hat{x}_k$的加权累积量.

灰色绝对关联度σ_{uv}为评价模型预测序列与原始序列的关联性指标,给定任意的数$\sigma_0>0$且$\sigma_0<1$,当$\sigma_{uv}>\sigma_0$时,则称该预测模型为灰色绝对关联度合格模型.

针对监测点1~3,对PSO-BP-MGM(1,n)、MGM(1,n)、双曲线模型3种预测模型的评估指标计算结果如表10所示.

表 10 3种预测模型精度对比表

Tab.10 Comparison of prediction accuracy among the three models

监测点	预测模型	MAPE/%	RMSE	SSE	σ_{uv}
监测点1	PSO-BP-MGM(1,n)模型	0.178	0.080	0.032	1.000
	MGM(1,n)模型	1.519	0.608	1.849	0.991
	双曲线模型	2.388	1.044	5.455	0.986
监测点2	PSO-BP-MGM(1,n)模型	0.816	0.309	0.476	0.995
	MGM(1,n)模型	1.527	0.606	1.835	0.994
	双曲线模型	2.241	0.746	2.784	0.986
监测点3	PSO-BP-MGM(1,n)模型	0.257	0.140	0.097	0.999
	MGM(1,n)模型	1.198	0.588	1.731	0.993
	双曲线模型	1.798	0.873	3.812	0.989

由表10可知:①在MAPE指标上,PSO-BP-MGM(1,n)模型在各监测点的预测精度均优于MGM(1,n)模型和双曲线模型,其MAPE最大可降低2.21%.②在RMSE指标上,PSO-BP-MGM(1,n)模型同样表现突出,其RMSE值最小;相较于其他模型,预测结果的偏差程度最多可减少0.965,体现了该模型预测结果的稳定性与准确性.③在SSE指标上,MGM(1,n)模型与双曲线模型的SSE值范围处于1.731~5.455区间;而PSO-BP-MGM(1,n)模型凭借高预测精度,SSE值区间为0.032~0.476,显著低于前两者,在拟合优度上更具优势.④综合MAPE、RMSE、SSE 3项误差评估指标可知,PSO-BP-MGM(1,n)模型在预测精度上显著超越MGM(1,n)模型与双曲线模型,在预测性能上表现最优;

MGM(1,n)模型在整体预测效果上优于双曲线模型,说明其在挖掘监测点间的关联信息、提升预测准确性方面具备一定效能.⑤在σ_{uv}指标上,3种模型的σ_{uv}均大于0.98,表明各模型的预测序列与实测序列之间具备高度的相关性与契合度,反映出模型在一定程度上能够有效刻画数据特征;其中,MGM(1,n)模型的σ_{uv}大于0.99,在相关性表现上优于双曲线模型;而PSO-BP-MGM(1,n)模型的σ_{uv}大于0.995,在3种模型中相关性最强,意味着其预测序列与实测序列的拟合程度最佳,能更精准地反映实际数据的变化趋势.

4　结论

1) 风积沙路基沉降主要集中在分层填筑施工阶段,其中前3 d沉降发展最快,实测沉降23.67～38.15 mm,占监测期总沉降量的59%～88%.填筑至5.402 m时,最大沉降为48.537 mm.填筑结束后,各监测点沉降量增速显著减缓,沉降-时间曲线呈明显收敛趋势,变形逐步趋于稳定.

2) MGM(1,n)模型可有效捕捉监测点关联性并提升预测精度.该模型引入灰色关联度,量化了风积沙路基各监测点之间的相关程度.研究表明,同一断面监测点灰色关联度均大于0.5,各监测点间关联性较强.模型利用各点相互影响,实现路基各点沉降趋势精准建模,突破传统双曲线模型单点数据处理的局限.

3) 经10～20次迭代后,PSO算法适应值收敛至0.01～0.03,可显著优化BP神经网络预测性能.构建的PSO-BP-MGM(1,n)模型预测效能优异:较MGM(1,n)模型,最大MAPE降低1.341%、RMSE降低0.528、SSE减少1.827;较双曲线模型,最大MAPE提升2.21%、RMSE和SSE分别降低0.965和5.523.实测验证表明,该模型预测曲线与实际沉降曲线吻合度最高,可有效预测风积沙路基沉降.

目前该路段未通车运营,监测数据时间跨度均在填筑施工期内,未考虑后期长期交通荷载影响下的沉降预测.后续研究将采集通车运营后的沉降数据,进一步验证并优化PSO-BP-MGM(1,n)模型在长期荷载作用下的预测性能.

参考文献(References):

[1] 何锐, 韩得军, 李龙龙, 等. 风积沙在道路工程中的应用研究进展[J]. 中国公路学报, 2025, 38(1): 1－30.
He Rui, Han Dejun, Li Longlong, et al. Application review of aeolian sand used in road engineering[J]. China Journal of Highway and Transport, 2025, 38(1): 1－30. (in Chinese)

[2] 袁威, 朱润田, 苏银强, 等. 软土地基分级堆载预压沉降预测方法[J]. Journal of Southeast University (English Edition), 2024, 40(1): 41－48.
Yuan Wei, Zhu Runtian, Su Yinqiang, et al. Settlement prediction method for staged preloading on soft clay ground[J]. Journal of Southeast University (English Edition), 2024, 40(1): 41－48. (in Chinese)

[3] 王子昂, 王武斌, 苏谦, 等. 新建铁路大临线临沧站站场路基沉降评估分析[J]. 铁道科学与工程学报, 2020, 17(7): 1688－1698.
Wang Ziang, Wang Wubin, Su Qian, et al. Evaluation and analysis of station subgrade settlement in Lincang station of newly built Dali-Lincang railway[J]. Journal of Railway Science and Engineering, 2020, 17(7): 1688－1698. (in Chinese)

[4] Yin L H, Sun X D, Yang P, et al. Stability analysis for subgrade settlement prediction by curve fitting methods[J]. IOP Conference Series: Earth and Environmental Science, 2018, 170(3): 032050.

[5] 常洲, 程小强, 张留俊, 等. 基于三点修正曲线模型的软岩高填路堤沉降预测[J]. 公路交通科技, 2022, 39(5): 33－40.
Chang Zhou, Cheng Xiaoqiang, Zhang Liujun, et al. Prediction of settlement of soft rock high-filled embankment based on three-point modified curve model[J]. Journal of Highway and Transportation Research and Development, 2022, 39(5): 33－40. (in Chinese)

[6] Liu W J, Zhang Z Y, Jia Y F, et al. Optimised grey model for predicting tunnel roof settlement based on ground-based radar[J]. KSCE Journal of Civil Engineering, 2025, 29(2): 100015.

[7] Qin P, Cheng C M, Su H Z. A GA-FGM-RTA combined model for predicting seawall settlement in under insufficient data volume [J]. Soft Computing, 2025, 29(2): 1133－1146.

[8] 张明聚, 秦胜旺, 李鹏飞, 等. 基于融合注意力机制BP神经网络的深基坑变形预测方法[J]. 北京交通大学学报, 2025, 49(2): 95－104.
Zhang Mingju, Qin Shengwang, Li Pengfei, et al. Deep excavation deformation prediction method based on BP Neural Network with integrated attention mechanism[J]. Journal of Beijing Jiaotong University, 2025, 49(2): 95－104. (in Chinese)

[9] 梁煜婉, 肖朝昀, 李明广, 等. 基于长短时记忆的真空预压地基沉降预测[J]. 上海交通大学学报, 2025, 59(4): 525－532.
Liang Yuwan, Xiao Zhaoyun, Li Mingguang, et al.

Ground settlement prediction by vacuum preloading based on LSTM[J]. Journal of Shanghai Jiao Tong University, 2025, 59(4): 525－532. (in Chinese)

[10] Yang Y F, Liao S M, Teoh B K, et al. A physics-constrained neural network for predicting excavation-induced ground surface settlement in clay[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2025, 17(5): 2665－2681.

[11] 顾玉辉, 刘江鑫, 张超, 等. 雄安新区高速公路路基沉降特征[J]. 公路交通科技, 2023, 40(S1): 207－215.
Gu Yuhui, Liu Jiangxin, Zhang Chao, et al. Subgrade settlement characteristics of expressway in Xiongan New Area[J]. Journal of Highway and Transportation Research and Development, 2023, 40(S1): 207－215. (in Chinese)

[12] 王秀英, 雷可, 王滕, 等. 洞桩法车站下穿既有管线工程的沉降预测[J]. 土木工程学报, 2021, 54(增1): 65－75.
Wang Xiuying, Lei Ke, Wang Teng, et al. Prediction of existing pipeline settlement resulting from the construction of an underground metro station using the pile-beam-arch (PBA) method[J]. China Civil Engineering Journal, 2021, 54(S1): 65－75. (in Chinese)

[13] Dong M, Guan M Z, Wang K H, et al. Machine learning-based measurement and prediction of ground settlement induced by shield tunneling undercrossing existing tunnels in composite strata[J]. Sensors, 2025, 25(5): 1600.

[14] 马学宁, 陈玉燕, 王旭. 高速铁路车站岔区高填方路基沉降组合预测研究[J]. 铁道学报, 2023, 45(1): 105－113.
Ma Xuening, Chen Yuyan, Wang Xu. Study on settlement combination prediction of high fill subgrade in turnout area of high-speed railway station[J]. Journal of the China Railway Society, 2023, 45(1): 105－113. (in Chinese)

[15] 靳鹏伟, 何永红, 陈青海. 马尔可夫残差修正模型的高铁路基变形预测[J]. 测绘科学, 2017, 42(7): 84－88.
Jin Pengwei, He Yonghong, Chen Qinghai. Deformation prediction of high speed railway subgrade based on Markov besidual error correction model[J]. Science of Surveying and Mapping, 2017, 42(7): 84－88. (in Chinese)

[16] Zeng B, Xia C, Yang Y J. Forecasting the amount of domestic waste clearance in Shenzhen with an optimized grey model[J]. Stochastic Environmental Research and Risk Assessment, 2024, 38(7): 2711－2729.

[17] 宋牧原, 杨明辉, 陈伟, 等. 基于自注意力-循环神经网络模型的盾构引发的土体沉降预测[J]. 岩土力学, 2025, 46(8): 2613－2625.
Song Muyuan, Yang Minghui, Chen Wei, et al. Prediction of shield tunneling-induced soil settlement based on self-attention recurrent neural network model[J]. Rock and Soil Mechanics, 2025, 46(8): 2613－2625. (in Chinese)

[18] 贺全鹏, 司涌波, 李少远. 基于MIDBO-BP-Adaboost的高铁路基沉降预测[J]. 北京交通大学学报, 2025, 49(3): 182－192.
He Quanpeng, Si Yongbo, Li Shaoyuan. Settlement prediction of high-speed railway subgrade based on MIDBO-BP-Adaboost[J]. Journal of Beijing Jiaotong University, 2025, 49(3): 182－192. (in Chinese)

[19] Teng C Q, Wang L, Jiang C. Urban surface deformation monitoring and prediction by integrating SBAS-InSAR and Elman neural network[J]. Survey Review, 2024, 56(394): 18－31.

[20] Li Q F, Xie J H. Bridge alignment prediction based on combination of grey model and BP neural network[J]. Applied Sciences, 2024, 14(17): 7955.

[21] 薛艳杰. 基于机器学习算法的土岩复合地层深基坑变形时序预测[J]. 现代隧道技术, 2022, 59(增2): 77－85.
Xue Yanjie. Time series prediction of deep foundation pit deformation in soil-rock composite stratum based on machine learning algorithm [J]. Modern Tunnelling Technology, 2022, 59(S2): 77－85. (in Chinese)

[22] Hu Y C, Wang W B. Nonlinear interval regression analysis with neural networks and grey prediction for energy demand forecasting[J]. Soft Computing, 2022, 26(14): 6529－6545.

[23] 张斌, 高玉祥, 陈再刚, 等. 基于GM(1, 1)-IPSO-BP的重载铁路小半径曲线钢轨磨耗预测方法[J]. 哈尔滨工业大学学报, 2024, 56(11): 115－122, 131.
Zhang Bin, Gao Yuxiang, Chen Zaigang, et al. Prediction method for rail wear of small radius curves on heavy duty railway based on GM(1, 1)-IPSO-BP[J]. Journal of Harbin Institute of Technology, 2024, 56(11): 115－122, 131. (in Chinese)

[24] Zhang C, Li J Z, He Y. Application of optimized grey discrete Verhulst-BP neural network model in settlement prediction of foundation pit [J]. Environmental Earth Sciences, 2019, 78(15): 441.

[25] 王英杰, 楚杭, 陈云峰, 等. 基于GM(1, 1)模型与相关向量机的轨道不平顺区间预测[J]. 交通运输工程学报, 2023, 23(6): 135－145.
Wang Yingjie, Chu Hang, Chen Yunfeng, et al. Interval prediction of track irregularity based on GM(1, 1) model and relevance vector machine[J]. Journal of Traffic and Transportation Engineering, 2023, 23(6): 135－145. (in Chinese)

[26] 聂如松, 钱冲, 刘婷, 等. 风积沙路基填料累积塑性应

变及预测模型[J]. 铁道科学与工程学报, 2022, 19(9): 2609－2619.
Nie Rusong, Qian Chong, Liu Xing, et al. Accumulated plastic strain of aeolian sand as subgrade filler and its prediction model[J]. Journal of Railway Science and Engineering, 2022, 19(9): 2609－2619. (in Chinese)

[27] 邹波. 列车荷载下风积沙填料弹性应变及预测模型[J]. 铁道科学与工程学报, 2024, 21(6): 2511－2522.
Zou Bo. Elastic strain and prediction model of aeolian sand filler under train-induced loading [J]. Journal of Railway Science and Engineering, 2024, 21(6): 2511－2522. (in Chinese)

[28] 陈涛,郭院成,谢春庆. 平坦地基上山区高填方路堤变形及稳定性分析[J]. 郑州大学学报(工学版), 2009, 30(3):39－43.
Chen Tao, Guo Yuancheng, Xie Chunqing. Analysis of deformation and stability of high embankment in flat ground of mountainous a rea[J]. Journal of Zhengzhou University(Engineering Science), 2009,30(3):39－43. (in Chinese)

[29] Zhang J H, Peng J H, Zhang A S, et al. Prediction of permanent deformation for subgrade soils under traffic loading in Southern China[J]. International Journal of Pavement Engineering, 2022, 23(3): 673－682.

[30] 王穗辉, 潘国荣. 基于MATLAB多变量灰色模型及其在变形预测中的应用[J]. 土木工程学报, 2005, 38(5): 24－27.
Wang Suihui, Pan Guorong. A Matlab-based multivariate grey model and its application in deformation prediction [J]. China Civil Engineering Journal, 2005, 38(5): 24－27. (in Chinese)

[31] 刘寒冰, 向一鸣, 阮有兴. 背景值优化的多变量灰色模型在路基沉降预测中的应用[J]. 岩土力学, 2013, 34(1): 173－181.
Liu Hanbing, Xiang Yiming, Ruan Youxing. A multivariable grey model based on background value optimization and its application to subgrade settlement prediction [J]. Rock and Soil Mechanics, 2013, 34(1): 173－181. (in Chinese)

[32] 王晓曼, 吕建雄, 李贤军, 等. 基于PSO-BP神经网络模型的浸胶竹束干燥过程含水率预测[J]. 林业科学, 2025, 61(5): 187－198.
Wang Xiaoman, Lv Jianxiong, Li Xianjun, et al. Prediction of moisture content during drying of phenolic resin impregnated heat-treated bamboo bundles based on PSO-BP neural network modeling [J]. Scientia Silvae Sinicae, 2025, 61(5): 187－198. (in Chinese)

[33] 马龙, 张献州, 段海东, 等. 多目标遗传算法改进的加权多点灰色模型[J]. 测绘科学, 2017, 42(4): 97－102.
Ma Long, Zhang Xianzhou, Duan Haidong, et al. A weighted multi-point gray model improved by multi-objective genetic algorithm[J]. Science of Surveying and Mapping, 2017, 42(4): 97－102. (in Chinese)

[34] Cui K. Symmetry-based convergence theory for particle swarm optimization: from heuristic to provably convergent optimization[J]. Symmetry, 2026, 18(1): 28.

[35] 黄轩, 张军, 詹志辉. 基于随机惯量权重的快速粒子群优化算法[J]. 计算机工程与设计, 2009, 30(3): 647－650.
Huang Xuan, Zhang Jun, Zhan Zhihui. Faster particle swarm optimization with random inertia weight [J]. Computer Engineering and Design, 2009, 30(3): 647－650. (in Chinese)