

基于实测数据的地铁隧道长期沉降预测模型研究

李翔宇^{1,2}, 李新源³, 李明宇⁴, 聂俊霞⁵, 冯晓波⁶

(1. 建筑安全与环境国家重点实验室, 北京 100013; 2. 中国建筑科学研究院有限公司 地基基础研究所, 北京 100013;
3. 徐州工程学院 土木工程学院, 江苏 徐州 221018; 4. 郑州大学 土木工程学院, 河南 郑州 450001;
5. 中铁十五局集团城市轨道交通工程有限公司, 河南 洛阳 471499; 6. 新华通讯社机关事务管理局, 北京 100803)

摘要: 基于上海地铁二号线的实测沉降数据, 运用遗传算法(GA)和粒子群算法(PSO)对传统BP神经网络进行了优化, 以弥补BP神经网络在网络结构、权值和阈值选择上的随机性以及容易局部收敛等缺陷, 据此提出了两种新型隧道长期沉降预测模型, 即GA-BP神经网络和PSO-BP神经网络模型; 并对比研究了经验曲线、BP神经网络、GA-BP神经网络以及PSO-BP神经网络等模型方法的优缺点及预测效果。研究发现, 上各神经网络模型均取得了较为满意的预测结果, 其中PSO-BP神经网络模型的预测精度最佳, 且运算速度最快, 是文中所提方法中最适用的盾构隧道长期沉降预测模型。

关键词: 盾构隧道; 长期沉降预测模型; GA-BP神经网络模型; PSO-BP神经网络模型; 经验曲线模型

中图分类号: U45

文献标志码: A

文章编号: 1006-7930(2021)02-0186-08

Research on prediction model of the long-term subsidence of shield tunnels based on in-situ monitoring data

LI Xiangyu^{1, 2}, LI Xinyuan³, LI Mingyu⁴, NIE Junxia⁵, FENG Xiaobo⁶

(1. State Key Laboratory of Building Safety and Built Environment, Beijing 100013, China;
2. Institute of Foundation Engineering, China Academy of Building Research, Beijing 100013, China;
3. School of Civil Engineering, Xuzhou Institute of Technology, Xuzhou 221018, China;
4. School of Civil Engineering, Zhengzhou University, Zhengzhou 450001, China
5. Urban Rail Transit Engineering Company Limited of China Railway 15th Bureau, Luoyang 471499, China;
6. Government Offices Administration, Xinhua News Agency, Beijing 100803, China)

Abstract: Based on in-situ monitoring data of Shanghai metro line 2, two new subsidence prediction models of tunnels, GA-BP neural network model and PSO-BP neural network model are proposed. These two models optimize the conventional BP neural network model by means of genetic algorithm(GA) and particle swarm optimization(PSO) in order to remedy the defects of BP neural network model, i.e. the randomness of selection on network structure, weight values and threshold values, as well as the inclination to local convergence. A comparative analysis is carried out between empirical curve, BP neural network model, GA-BP neural network model and PSO-BP neural network model, about their strengths, weaknesses and prediction effects. The results show that, PSO-BP neural network model turns to be the best model with optimal accuracy and fast operation speed, which is the most suitable prediction model for the long-term subsidence of shield tunnels, although the above prediction models have achieved appropriate prediction.

Key words: shield tunnel; prediction model of the long-term subsidence; GA-BP neural network model; PSO-BP neural network model; empirical curve model

盾构法是在地面下暗挖隧道的一种施工方法, 可以有效控制施工对周围环境影响, 在城市地铁施工中得到了广泛应用^[1]。在盾构隧道施工结束后, 周围土体因受到扰动存在大量潜在的变形, 而且运营期间隧道也会受地铁线路周围工程地质

条件变化和人类活动等因素的影响, 致使盾构隧道发生长期沉降, 其中, 建设在软弱、高压缩性土体中的隧道沉降最为显著^[2-3]。运营隧道的沉降实测数据综合反映了隧道在多种因素共同作用下的变形情况, 基于隧道沉降实测数据, 选取合理

的预测模型, 来推算隧道沉降规律, 是研究隧道沉降预测的重要方法^[4]. 目前, 对地铁隧道长期沉降的预测研究还比较少, 主要从经验曲线模型、灰色系统理论、BP 神经网络模型等方法进行研究。李明宇(2011)^[5]采用函数 $g = ae^{-lgt/b} + c$ 对隧道长期变形规律进行了分析。余腾等(2017)^[6]基于南京地铁二号线部分区间沉降监测数据, 采用 GM(1, 1)灰色模型对轨行区沉降进行预测研究。但曲线模型需要较多原始速度, 且收敛速度较慢, 灰色预测模型所需参数较少, 但预测结果精度较低。朱伟刚等^[7]、乔金丽等^[8]采用 BP 神经网络对长春地铁 2 号线、广州地铁 2 号线的地表沉降进行了预测, 取得了较好的成果。影响隧道长期沉降的因素具有很大的模糊性和随机性, BP 神经网络由于其独特的联结结构和并行信息处理方法, 具有良好的非线性映射能力、自学习功能和较高的鲁棒性, 可以对现有的沉降数据进行自我学习, 并将学习结果存储在神经元的阀值和神经元间的连接权值中, 具有良好的自适应性和容错性, 因此, 对于隧道长期沉降预测问题具有一定的适用性。近年来, 随着对 BP 神经网络研究的进一步深入, 其收敛速度慢、多个局部最小点、隐含层节点不确定性等固有缺陷对其实际应用带来了很大的阻碍^[9]。因此, 如何优化人工神经网络以克服其缺点已成为人工神经网络研究的热点之一。

本文将基于上海地铁二号线的实测沉降数据, 利用遗传算法(GA)和粒子群算法(PSO)对 BP 网络进行优化, 从而建立 GA-BP 和 PSO-BP 神经网络预测模型, 并通过对比多种模型方法的预测结果, 探讨其中最优的隧道长期沉降预测模型。

1 针对 BP 神经网络的 GA 和 PSO 优化算法

BP(Back Propagation)神经网络是由 Rumelhart 和 McClelland 等人在 1986 年提出的, 该神经网络在多层神经网络模型的基础上加入了误差反向传播学习算法, 该算法的基本思想主要为梯度下降法, 即在网络学习过程中, 使网络的输出与期望输出的误差在向后传播的同时修正连接权值, 以实现其误差均方值最小, 从而解决多层前向神经网络的学习问题。

为了实现更好地拟合与预测地铁隧道长期沉降, 对 BP 神经网络的缺陷进行优化十分必要。在优化过程中应重点解决以下两个问题: 一是要求寻找全局最优点, 二是要求有较高的收敛速度。

本文分别采用遗传算法和粒子群算法对 BP 神经网络进行优化, 下面将对这两种算法的原理和工作流程进行介绍。

1.1 遗传算法与粒子群算法

1.1.1 遗传算法

遗传算法 (Genetic Algorithm, 简称 GA) 是 1962 年由美国 Michigan 大学 Holland 教授提出的, 其借鉴自然界遗传机制和生物进化论思想, 是一种启发式群体概率性迭代优化方法。GA 算法将问题的求解转化成了“染色体”适者生存的过程, “染色体”群体通过选择、交叉和变异等遗传操作不断迭代进化, 最终收敛到“最适应环境”的个体, 求得问题的最优解^[10]。遗传算法具有简单实用、自适应性好、并行处理及全局寻优能力强、不易陷入局部最优解等优点, 但也存在个体容易早熟等缺点。图 1 描述了遗传算法的基本流程^[11-12]。

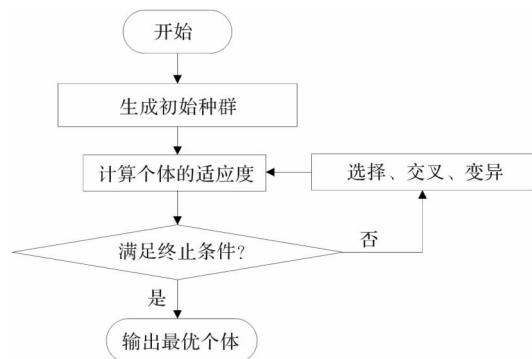


图 1 遗传算法的工作流程图^[11-12]

Fig. 1 Work flow chart of GA

1.1.2 粒子群算法

粒子群算法 (Particle Swarm Optimization, 简称 PSO) 是 1995 年由 Eberhart 和 Kennedy 提出的一种基于种群的随机迭代算法^[13-14]。该算法受鸟群觅食行为的启发, 假设一个由 m 个粒子组成的群体在 D 维搜索空间中以一定的速度飞行^[15], 每个粒子在搜索时, 根据自己搜索到的历史上的最优位置和在整个群体的历史最优位置对其位置和速度进行变化, 以尽快到达全空间最优位置附近。PSO 算法保留了基于种群的全局搜索策略, 具有计算简单、高效等优点^[16]。PSO 算法中粒子位置在每一代的更新方式可用图 2 来描述^[17-18]。

1.1.3 遗传算法和粒子群算法的比较

遗传算法(GA)和粒子群算法(PSO)作为优化算法, 具有很多相同点^[17]: 它们都力图在自然特性的基础上模拟个体种群的适应性; 都属于全局优化方法, 采用一定的变换规则求解; 都通过随

机优化方法更新种群和搜索最优点；搜索过程都是从问题解的一个集合开始，具有隐含并行搜索特性；都根据个体的适配信息进行搜索，均不受函数约束条件的限制等。

同时，GA 算法和 PSO 算法也存在很大的不同，具体如下：

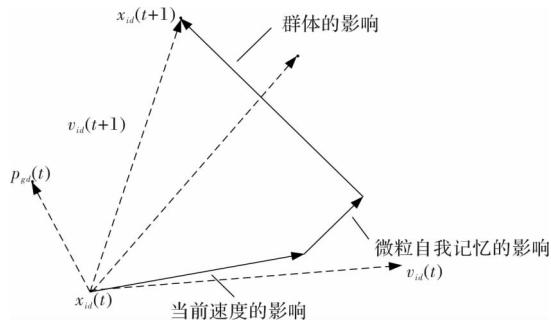


图 2 粒子位置更新示意图^[17-18]

Fig. 2 Schematic diagram of particle position update

(1) PSO 算法相对于 GA 算法，不但具有全局寻优能力，而且具有较强的局部寻优能力。

(2) PSO 算法具有记忆性，所有粒子保存以前较优的知识；而 GA 算法没有记忆性，随着种群的改变以前的知识会被破坏。

(3) GA 算法中需要编码和遗传操作，较为复杂，而 PSO 算法中的粒子通过自己的速度和位置进行更新，参数较少，一般情况下收敛速度也要快于 GA 算法。

(4) 两者共享机制不同。在 GA 算法中，染色体之间相互共享信息，使得整个种群都向最优区域移动；而 PSO 算法中的粒子仅通过当前搜索到最优点进行共享信息，属于单项信息共享机制。

1.2 遗传算法优化 BP 神经网络

通过把遗传算法和 BP 神经网络相结合，利用遗传算法中的选择、交叉、变异等操作寻找最优的 BP 神经网络初始权值与阈值，再由 BP 算法进行训练，从而建立基于遗传算法优化 BP 神经网络（简称 GA-BP 神经网络），以期克服传统 BP 神经网络的缺点，获得较快的收敛速度和较高的预测精度。

GA-BP 神经网络的基本流程^[12] 具体如下：

① 种群初始化，即：首先确定 BP 神经网络结构，通过对权值和阈值编码得到遗传算法的初始种群。

② 根据个体的进化不断更新 BP 神经网络的初始权值和阈值，用实测数据训练 BP 神经网络后预测输出，将式(1)所示均方误差函数作为适应度函数，计算每个个体的适应度，并判断是否符合优

化标准。如果符合，则转向③。如不符合，则按适应度对个体进行选择、交叉、变异操作，产生新的个体，重新进行适应度判断，直至符合。

$$MSE = \frac{1}{M} \sum_{m=1}^M (y_m - \hat{y}_m)^2 \quad (1)$$

式中， M 为测试样本总数； $m=1, 2, \dots, M$ ； y_m 为测试样本真实值， \hat{y}_m 为测试样本预测值。

③ 将以上得到的最优个体按顺序拆分，作为 BP 神经网络的初始权值和阈值。

④ 进行 BP 神经网络的前向传播，计算全局误差，并判断是否符合要求，如果符合，则结束网络的学习。如果不符，进行 BP 神经网络的反向传播，更新权值和阈值后重新进行前向传播和误差判断，直至符合。

1.3 粒子群算法优化 BP 神经网络

粒子群算法具有收敛速度快、鲁棒性高、全局搜索能力强等特点，本节将建立粒子群算法优化的 BP 神经网络（简称 PSO-BP 神经网络）。主要构建思路为：首先把 BP 神经网络的权值和阈值转换为粒子的维度，之后采用误差函数或预测准确率作为粒子的适应度定义，通过 PSO 算法迭代得到最优的权值和阈值，之后赋予 BP 神经网络进行预测，以期改善传统 BP 神经网络对初始权值过于敏感以及容易陷入局部极小值等不足。

PSO-BP 神经网络的工作流程^[19] 具体如下：

① 初始化。初始化 BP 神经网络结构，包括设定网络的输入层、隐含层、输出层的神经元个数和学习率参数等；初始化粒子群，包括粒子的规模 M 及每个粒子的位置向量 x_i 及速度向量 v_i 、每个粒子的个体极值 p_i 和全局最优值 p_g 、迭代误差精度 ϵ 、加速度因子 c_1 和 c_2 、最大惯性权重 w_{\max} 、最小惯性权重 w_{\min} 、最大速度 v_{\max} 、最大位置 x_{\max} 及最大迭代次数 K 等。

② 利用式(2)更新每个粒子的速度，限制在区间 $[-v_{\max}, v_{\max}]$ 中；利用式(3)更新每个粒子的位置，限制在区间 $[-x_{\max}, x_{\max}]$ 中。

$$v_{id}^k = w_i \cdot v_{id}^{k-1} + c_1 \cdot r_1 \cdot (p_{id}^{k-1} - x_{id}^{k-1}) + c_2 \cdot r_2 \cdot (p_{gd}^{k-1} - x_{id}^{k-1}) \quad (2)$$

$$x_{id}^k = x_{id}^{k-1} + v_{id}^k \quad (3)$$

式中， $i=1, 2, \dots, m$ ； $d=1, 2, \dots, D$ ； k 表示第 k 次迭代； c_1 和 c_2 为加速度因子，为非负常数； r_1 和 r_2 为 $[0, 1]$ 上均匀分布的随机数； w_i 为惯性权重，调整大小可改变搜索能力的强弱。

③ 利用下式(4)计算各个粒子的适应度值，为

$$f_i = \frac{1}{N} \sum_{j=1}^N (T_j^i - O_j^i) \quad (4)$$

其中, N 是训练集的样本数, T_i^j 是第 i 个样本的第 j 个网络输出节点的理想输出值, O_i^j 是第 i 个样本的第 j 个网络输出节点的实际输出值。

④计算粒子群的全局最小适应值 $f_g = \min(f_1, f_2, \dots, f_N)$; 若当前迭代次数达到最大迭代次数或网络的训练误差达到精度要求($f < \epsilon$), 则迭代停止, 转到步骤⑤; 否则, 计算各个粒子的个体极值 p_i 和全局极值 p_g 位置, 转到②继续更新粒子的速度和位置。

⑤输出全局极值 p_g 的位置所确定的网络权值和阀值, 代入 BP 神经网络求出预测值, 最后得出与实际值的误差平方和。

2 基于优化 BP 神经网络的隧道沉降预测模型

2.1 遗传算法优化 BP 神经网络预测模型

按照 1.2 节基本流程, 本文建立了基于 GA-BP 神经网络的隧道沉降预测模型, 并采用 MATLAB 软件编写了相关程序以方便预测计算。

由对运营地铁隧道实测沉降数据的研究可知^[5], 地铁隧道沉降表现出与地面沉降趋于一致的变形规律, 而且对地面沉降的观测较为方便, 数据也较为容易采集。因此本文将地面沉降和监测时间作为输入参数, 以隧道沉降值作为输出参数, 建立了多参数 GA-BP 神经网络模型, 同时也建立了以时间为输入参数的单参数 GA-BP 神经网络作为对比。

本文采用上述建立的两种遗传算法优化 BP 神经网络模型对上海地铁二号线隧道测点 S2205(里程 1.3 km)的长期沉降数据进行预测分析。分析过程中, 以第 1~11 样本作为输入数据, 以第 12~18 样本作为输出数据, 对其进行预测试算, 不断对神经网络模型的参数进行调整, 经过多次验算得到了较为合理的网络参数。其中, 遗传算法对应的运行参数为: 初始种群为 20, 交叉概率 0.8, 变异概率 0.05, 进化代数为 100; BP 神经网络的运行参数为: 学习速率为 0.05, 训练误差精度为 0.000 1。

表 1 地铁二号线测点 S2205 沉降预测模型输出值与实测值
Tab. 1 GA-BP prediction model output values and the measured values of S2205 of metro line 2

样本序号	时间/d	隧道沉降		样本序号	时间/d	隧道沉降/mm				
		实测值/mm				实测值	多参数 试算值	单参数 试算值	多参数 预测值	单参数 预测值
1	1	0.00		10	1 247	27.50	—	—	—	—
2	91	-0.71		11	1 461	37.76	—	—	—	—

通过预测计算得到试算值(12~16)和外推预测值(17~18), 见表 1. 图 3 是以表 1 中的实测值和模型输出值为纵坐标, 以监测时间为横坐标绘制的预测结果对比图。

从图 3 中可以看出, 由单参数输入 GA-BP 和多参数输入 GA-BP 两种神经网络预测模型对测点 S2205 第 1 613 天~2 708 天(第 12~18 个数据样本)的沉降预测结果均与现场实测值非常接近, 且相比而言, 多参数模型的预测精度较高。以第 2 708 天的预测结果为例, 多参数与单参数两种模型预测的相对误差分别为 0.4% 和 1.3%, 可见效果是令人满意的。以上结果也说明, 如果缺乏地面沉降数据, 使用单参数模型进行预测也能保证预测的准确性。

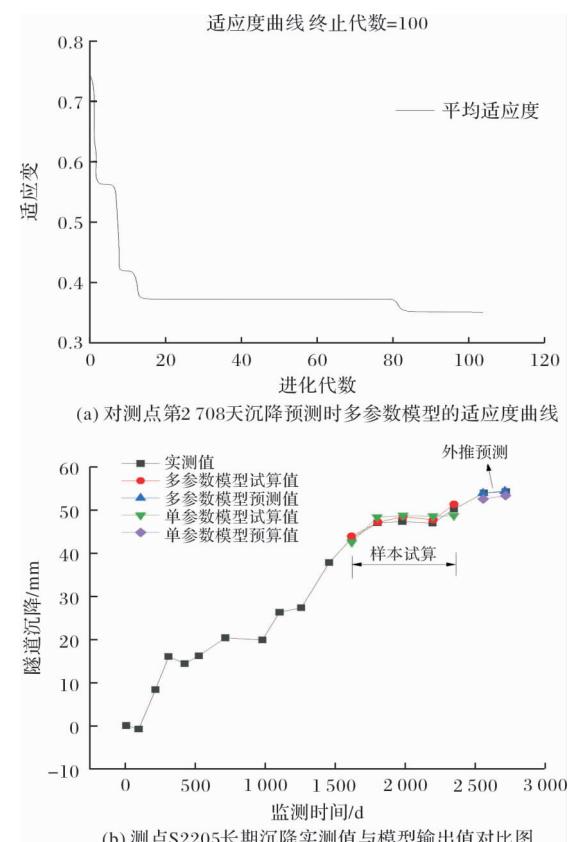


图 3 基于 GA-BP 神经网络的测点 S2205 长期沉降预测

Fig. 3 Long-term settlement prediction of S2205 based on GA-BP neural network

续表 1

样本序号	时间/d	隧道沉降		隧道沉降/mm					
		实测值/mm	样本序号	时间/d	实测值	多参数 试算值	单参数 试算值	多参数 预测值	单参数 预测值
3	213	8.46	12	1 613	43.79	43.85	42.76	—	—
4	305	15.98	13	1 797	47.10	47.06	48.58	—	—
5	428	14.24	14	1 978	47.64	48.41	48.6	—	—
6	517	16.25	15	2 192	47.22	47.66	48.58	—	—
7	701	20.09	16	2 343	50.44	51.3	48.74	—	—
8	974	20.05	17	2 557	54.04	—	—	53.75	52.58
9	1 096	26.44	18	2 708	54.15	—	—	53.94	53.42

2.2 粒子群算法优化 BP 神经网络预测模型

根据 1.3 节工作流程, 本文采用 MATLAB 软件编写了单参数输入和多参数输入两种 PSO-BP 神经网络预测模型的程序。其中, 第一种网络模型输入层的两个节点为测量时间和隧道测点对应的地面沉降值, 输出层为隧道的沉降值; 第二种网络模型输入层则只有测量时间 1 个节点。本文采用以上两种神经网络预测模型程序对隧道测点 S2205 (里程 1.3 km) 的长期沉降数据进行了预测研究。分析过程中, 以第 1~11 样本作为输入数据, 以第 12~18 样本作为输出数据。首先通过对第 12~16 个样本的预测试算获得了神经网络模型的具体参数(其中, PSO 算法的运行参数为: 初始粒子群规模为 20 个, 进化次数为 500, 加速度因子 $c_1=c_2=$

1.9; BP 神经网络运行参数为: 学习速率为 0.05, 训练误差精度为 0.000 1), 之后利用以上模型对第 2 557 天和 2 708 天的隧道沉降进行了预测, 具体结果见表 2 和图 4。从图表中可以发现, 采用 PSO-BP 神经网络预测模型对测点 S2205 第 1 613 天~2 708 天(第 12~18 个数据样本)的隧道沉降进行预测得到的结果与实测值基本一致, 多参数模型预测的精度和稳定性要优于单参数预测模型, 且程序运行的速度要快于 GA-BP 神经网络模型。因此可以认为, 采用 PSO 算法优化 BP 神经网络的连接权值和阀值, 不仅发挥了神经网络的泛化能力, 提高了神经网络的收敛速度和学习能力, 而且也克服了传统 BP 神经网络易陷局部最优解的缺点。

表 2 地铁二号线测点 S2205 沉降预测模型输出值与实测值

Tab. 2 PSO-BP prediction model output values and the measured values of S2205 of metro line 2

样本序号	时间/d	隧道沉降		隧道沉降/mm					
		实测值/mm	样本序号	时间/d	实测值	多参数 试算值	单参数 试算值	多参数 预测值	单参数 预测值
1	1	0.00	10	1 247	27.50	—	—	—	—
2	91	-0.71	11	1 461	37.76	—	—	—	—
3	213	8.46	12	1 613	43.79	43.84	42.98	—	—
4	305	15.98	13	1 797	47.10	47.12	46.81	—	—
5	428	14.24	14	1 978	47.64	47.76	49.25	—	—
6	517	16.25	15	2 192	47.22	47.30	47.12	—	—
7	701	20.09	16	2 343	50.44	49.97	50.15	—	—
8	974	20.05	17	2 557	54.04	—	—	53.70	54.84
9	1 096	26.44	18	2 708	54.15	—	—	54.36	54.48

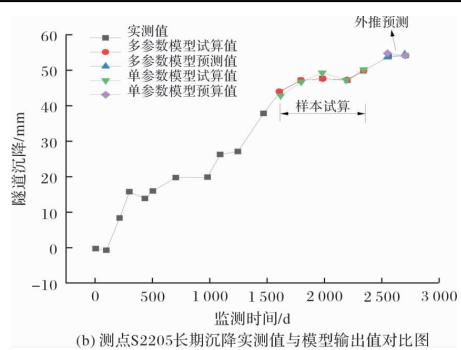
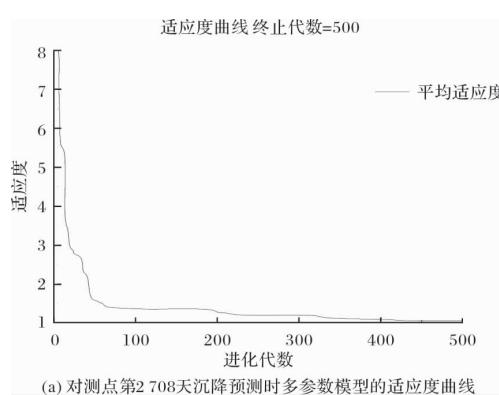


图 4 基于 PSO-BP 神经网络的测点 S2205 长期沉降预测

Fig. 4 Long-term settlement prediction of S2205 based on PSO-BP neural network

2.3 预测结果比较

由前文分析可知, 通过遗传算法和粒子群算法优化 BP 神经网络的参数而形成的 GA-BP 和 PSO-BP 神经网络适应于预测盾构隧道的长期沉降问题, 且随着监测数据的更新与增加, 预测模型的可靠性也会不断提高。除了以上两种优化神经网络外, 本节还基于相同的学习样本研究了传统 BP 神经网络和双曲线经验模型的预测效果, 之后通过综合对比分析, 探讨最适合的隧道长期沉降预测模型。

为了方便分析四种预测模型的准确性, 本文将采用绝对误差(AE)、相对误差(RE)、平均绝对误差(MAE)和平均相对误差(MAPE)来评价预测的效果。它们的计算公式分别见式(4)~式(7), 其中 MAPE 能真实地反映预测精度, 是比较不同条件下误差大小的一个较优指标, 预测精度设为A($A=1-MAPE$)。

$$AE = Y_i - y_i \quad (4)$$

$$RE = |Y_i - y_i| / y_i \quad (5)$$

$$MAE = \sum_i^n |Y_i - y_i| / N \quad (6)$$

$$MAPE = \frac{1}{N} \sum_i^n \frac{|Y_i - y_i|}{y_i} \quad (7)$$

表 3 不同预测模型的相对误差和绝对误差

Tab. 3 Relative and absolute errors of different prediction models

时间/d	实测值/mm	PSO-BP 神经网络模型		GA-BP 神经网络模型		BP 神经网络模型		双曲线经验模型	
		AE/mm	RE/%	AE/mm	RE/mm	AE/mm	RE/mm	AE/mm	RE/%
1 613	43.79	0.05	0.1	0.06	0.1	-1.32	3.0	-4.48	10.2
1797	47.10	0.02	0.0	-0.04	0.1	0.25	0.5	-4.59	9.7
1 978	47.64	0.12	0.3	0.77	1.6	-0.71	1.5	-2.16	4.5
2 192	47.22	0.08	0.2	0.44	0.9	-0.48	1.0	1.56	3.3
2 343	50.44	-0.47	0.9	0.86	1.7	-1.52	3.0	0.54	1.1
2 557	54.04	-0.24	0.4	-0.29	0.5	-0.48	0.9	-0.10	0.2
2 708	54.15	0.16	0.3	-0.21	0.4	-0.34	0.6	1.78	3.3

表 4 不同预测模型的精度对比

Tab. 4 Comparison of accuracy of different prediction models

参数	PSO-BP 神经网络模型	GA-BP 神经网络模型	BP 神经网络模型
MAE/mm	-0.04	0.23	-0.66
MAPE/%	0.31	0.76	1.50
预测精度/%	99.69	99.24	98.50

(2) 双曲线经验模型拟合得到的结果误差最大, 预测精度只有 95.39%, 明显低于神经网络模

式中, y_i 为实测沉降值, Y_i 为预测沉降值, N 为待预测的沉降测点数。

表 3 显示了不同预测模型的相对误差和绝对误差, 表 4 为不同预测模型的精度对比情况, 图 5 为四种模型外推预测结果的对比示意图。综合分析上述图表可以得到以下结论:

(1) 采用 PSO-BP 神经网络模型对 7 个检验样本预测的平均绝对误差为 -0.04 mm, 平均相对误差为 0.31%; GA-BP 神经网络模型得到的平均绝对误差为 0.23 mm, 平均相对误差为 0.76%; 而 BP 神经网络的两种误差分别为 -0.66 mm 和 1.50%。可见优化后 BP 神经网络的预测精度有了很大的提高, 预测效果均优于原 BP 神经网络。四类模型中经验曲线模型预测误差最大, PSO-BP 神经网络模型误差最小, 这说明基于同样的训练样本和神经网络参数, PSO-BP 神经网络模型的预测能力最优; 同时, 在使用 MATLAB 程序运算过程中, 优化后 BP 神经网络的收敛速度和运行时间均快于传统 BP 神经网络, 而且 PSO-BP 神经网络明显快于 GA-BP 神经网络。

型的预测结果。由此可见, 曲线经验模型可用于对隧道沉降进行粗略的估算, 当进行较为精确的

预测时应采用神经网络模型。主要原因是,运营地铁隧道的长期沉降规律复杂多变,采用公式简单、参数很少的经验曲线模型很难对其进行精准地拟合,而神经网络模型通过对实测数据样本的训练,能够自动修正网络参数以实现对隧道长期变形特性较好的非线性映射。

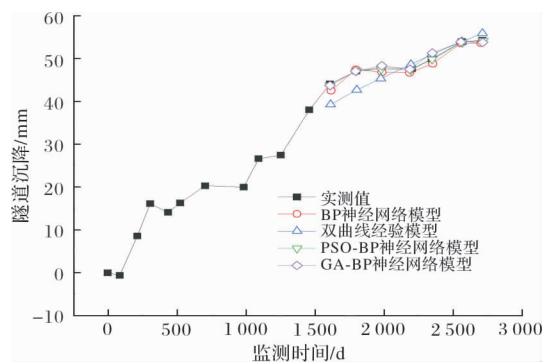


图 5 不同预测模型对测点 S2205 沉降外推预测对比

Fig. 5 Comparison of extrapolation prediction of S2205 by different prediction models

通过以上分析可以发现,本文建立的 GA-BP 和 PSO-BP 神经网络克服了传统 BP 神经网络存在的收敛速度慢、易陷入局部极小点等缺点,据此建立的预测模型对盾构隧道长期沉降具有很高的预测精度。其中,PSO-BP 神经网络模型的预测效果最佳,运算速度最快,是本文介绍的四种模型中最为适用的隧道长期沉降预测模型。

3 结论

隧道变形的稳定可控是地铁安全运营的重要保障之一,建立一种高精度、简便实用的隧道长期沉降预测模型,以实现对隧道未来变形的科学预报。本文利用遗传算法和粒子群算法对 BP 神经网络进行优化建立了 GA-BP 和 PSO-BP 两种神经网络预测模型。之后根据已整理统计的上海地铁隧道沉降数据,分别采用 BP 神经网络、GA-BP 神经网络、PSO-BP 神经网络和双曲线经验模型对隧道的长期沉降进行了预测研究,并对比分析了各模型的优缺点和预测效果。研究发现,以上各模型的预测精度均超过了 95%,其中双曲线经验模型的误差最大,而 PSO-BP 神经网络模型的预测精度最佳,且运算速度最快,是文中所提方法中最为适用的盾构隧道长期沉降预测模型。

参考文献 References

- [1] 刘建航,侯学渊. 盾构法隧道[M]. 北京:中国铁道出版社,1991.
LIU Jianhang, HOU Xueyuan. Shield tunnels [M]. Beijing: China Railway Press, 1991.
- [2] 谢雄耀,王培,李永盛,等. 甬江沉管隧道长期沉降监测数据及有限元分析[J]. 岩土力学, 2014, 35(8): 2314-2324.
XIE Xiongyao, WANG Pei, LI Yongsheng, et al. Long-term settlement monitoring data and finite element analysis of Yongjiang immersed tunnel [J]. Geotechnical Mechanics, 2014, 35(8): 2314-2324.
- [3] MAIR, R J, TAYLOR R N. Bored tunnelling in the urban environment[A]// Proc. 14th Int. Conf. Soil Mech. Found. Engng. Hamburg: Germany Society of Soil Mechanics and Foundation, 1997:2353-2385.
- [4] 张金菊. 盾构隧道引起土体变形分析研究[D]. 杭州:浙江大学, 2006.
ZHANG Jinju. An analytical study of soil deformation caused by shield tunnel[D]. Hangzhou: Zhejiang University, 2006.
- [5] 李明宇. 运营地铁盾构隧道纵向变形和受力特征及规律研究[D]. 上海:同济大学, 2011.
LI Mingyu. Longitudinal deformation and force characteristics and regularity study of operating subway shield tunnel[D]. Shanghai: Tongji University, 2011.
- [6] 余腾,胡伍生,孙小荣. 基于灰色模型的地铁运营期轨行区沉降预测研究[J]. 现代测绘, 2017, 40(2): 33-36.
YU Teng, HU Wusheng, SUN Xiaorong. Prediction analysis for the settlement of metro rail line interval based on the grey model during traffic operation[J]. Modern Mapping, 2017, 40(2):33-36.
- [7] 朱伟刚,徐超. BP 神经网络算法在长春地铁二号线地表沉降预测中的应用[J]. 测绘与空间地理信息, 2018, 41(12):211-214.
ZHU Weigang, XU Chao. Application of BP neural network algorithm to surface settlement prediction of Changchun metro line two[J]. Geomatics & Spatial Information Technology, 2018, 41(12):211-214.
- [8] 乔金丽,范永利,刘波,等. 基于改进 BP 网络的盾构隧道开挖地表沉降预测[J]. 地下空间与工程学报, 2012, 8(2):352-357.
QIAO Jinli, FAN Yongli, LIU Bo, et al. Predicting the surface settlement by shield tunneling based on

- modified BP network [J]. Chinese Journal of Under-ground Space and Engineering, 2012, 8(2):352-357.
- [9] 赵久彬, 刘元雪, 刘娜, 等. 海量监测数据下分布式BP神经网络区域滑坡空间预测方法[J]. 岩土力学, 2019, 40(7): 2866-2872.
ZHAO Jiubin, LIU Yuanxue, LIU Na, et al. Spatial prediction method of regional landslide based on distributed bp neural network algorithm under massive monitoring data [J]. Geotechnics, 2019, 40 (7): 2866-2872.
- [10] 崔学杰, 晏鄂川, 陈武. 基于改进遗传算法的岩体结构面产状聚类分析[J]. 岩土力学, 2019, 40(S1): 374-380.
CUI Xuejie, YAN Echuan, CHEN Wu. Cluster analysis of discontinuity occurrence of rock mass based on improved genetic algorithm[J]. Geotechnics, 2019, 40 (S1): 374-380.
- [11] 马春辉, 杨杰, 程琳, 等. 基于量子遗传算法与多输出混合核相关向量机的堆石坝材料参数自适应反演研究[J]. 岩土力学, 2019, 40(6): 2397-2406.
MA Chunhui, YANG Jie, CHENG Lin, et al. Adaptive inversion study of the material parameters of a heapstone dam based on quantum genetic algorithm and multi-output mixed-core correlation vector machine [J]. Geotechnics, 2019, 40(6):2397-2406.
- [12] MATLAB 中文论坛编著. MATLAB 神经网络 30 个案例分析[M]. 北京: 北京航空航天大学出版社, 2010.
MATLAB Chinese Forum. 30 case studies of MATLAB neural networks[M]. Beijing: Beijing University of Aeronautics and Astronautics Press, 2010.
- [13] KENNEDY J, Eberhart R C. Particle swarm optimization [A]//IEEE International Conference on Neural Network [C]. New York: IEEE Press, 1995: 1942-1948.
- [14] EBERHART R C, KENNEDY J. A new optimizer using particles swarm theory [A]. Sixth International Symposium on Micro Machine and Human Science. Nagoya: IEEE Service Center, 1995: 39-43.
- [15] 黄继红. 基于改进 PSO 的 BP 网络的研究及应用[D]. 长沙:长沙理工大学, 2008.
HUANG Jihong. Research and application on BP networks based on improved PSO[D]. Changsha : Changsha University of Technology, 2008.
- [16] 邵新宇. 制造系统运行优化理论与方法[M]. 北京:科学出版社, 2010.
SHAO Xinyu. Theory and method of manufacturing system operation optimization[M]. Beijing: Science Press, 2010.
- [17] 魏秀业, 潘宏侠. 粒子群优化及智能故障诊断[M]. 北京:国防工业出版社, 2010.
WEI Xiuye, PAN Hongyan. Particle swarm optimization and intelligent troubleshooting [M]. Beijing: Defense Industry Press, 2010.
- [18] 沈圆顺. 青岛地区土岩组合基坑变形特性与风险评价研究[D]. 上海:同济大学, 2012.
SHEN Yuanshun. Study on the deformation characteristics and risk evaluation of soil and rock combination pit in Qingdao[D]. Shanghai: Tongji University, 2012.
- [19] 王爱平, 江丽. 基于 PSO 的 BP 神经网络学习算法 [J]. 计算机工程, 2012, 38(21): 193-196.
WANG Aiping, JIANG Li. BP neural network learning algorithm based on PSO[J]. Computer Engineering, 2012, 38(21): 193-196.

(编辑 桂智刚)