

文章编号: 1674—8247(2022)06—0063—06

DOI:10.12098/j.issn.1674-8247.2022.06.012

基于改进自然选择粒子群算法的铁路客运量组合预测研究

杨 飞 王 洋

(中铁工程设计咨询集团有限公司, 北京 100055)

摘 要:为提高铁路客运量的预测精度,引入基于自然选择的粒子群算法以解决铁路客运量组合预测模型权重分配问题,借助对数函数和正弦函数非线性变化的特点对基于自然选择粒子群算法的权重和学习因子进行改进,并结合BP神经网络和ARIMA模型对北京市铁路客运量进行组合预测。研究表明:(1)改进基于自然选择的粒子群算法在权重分配过程中展现出更好的寻优能力和收敛速度;(2)相比于BP神经网络和ARIMA模型和等分权重法赋值的组合预测模型,改进基于自然选择的粒子群算法求解权重的组合预测精度更高,预测年度平均预测相对误差分别提高了1.934%、5.009%和1.118%。

关键词:自然选择理论;粒子群算法;铁路客运量;组合预测;权重

中图分类号:U293.13

文献标识码:A

Study on Combination Forecast of Railway Passenger Volume by Improved Particle Swarm Optimization Algorithm Based on Natural Selection

YANG Fei WANG Yang

(China Railway Engineering Design Consulting Group Co., Ltd., Beijing 100055, China)

Abstract: In order to improve the forecast accuracy of railway passenger volume, the particle swarm optimization (PSO) algorithm based on natural selection is introduced to solve the weight allocation problem of combination forecast model for railway passenger volume. The author carried out the combination forecast of railway passenger volume in Beijing by improving the weight and learning factors of PSO algorithm based on natural selection according to the characteristics of nonlinear variation of logarithmic function and sinusoidal function, and in combination with the BP Neural Network and ARIMA model. The results show that: (1) The improved PSO algorithm based on natural selection shows better optimization ability and convergence speed in the process of weight allocation. (2) Compared with the "BP Neural Network + ARIMA model + value assignment by equal weight method" combination forecast model, the combination forecast by solving the weight by the improved PSO algorithm based on natural selection has a higher accuracy. The average relative forecast errors in three forecast years are increased by 1.934%, 5.009% and 1.118% respectively.

Key words: natural selection theory; particle swarm optimization algorithm; railway passenger volume; combination forecast; weight

收稿日期:2021-10-12

作者简介:杨飞(1995-),男,助理工程师。

引文格式:杨飞,王洋. 基于改进自然选择粒子群算法的铁路客运量组合预测研究[J]. 高速铁路技术,2022,13(6):63-68.

YANG Fei, WANG Yang. Study on Combination Forecast of Railway Passenger Volume by Improved Particle Swarm Optimization Algorithm Based on Natural Selection[J]. High Speed Railway Technology, 2022, 13(6):63-68.

随着旅客出行需求和运输服务水平的不断提高,我国旅客运输市场竞争越发激烈。合理准确的铁路客运量预测可为制定铁路客运宏观发展战略和编制客运计划提供依据,也可为铁路管理者合理分配资源、提高运输市场竞争力提供重要依据。

近年来,为提高铁路客运量的预测精度,较多学者通过组合预测的方法对铁路客运量预测结果进行改进。众多组合预测过程中,权重取值方法成为较多学者研究的重点。游文倩^[1]通过最优权重法对组合预测模型的权重进行赋值,并将其应用于 GDO 组合预测领域中;刘春红^[2]从最优权重和残差优化角度对单一预测模型权重进行赋值,进一步预测了猪舍氨气浓度;王秀梅^[3]基于误差平方和最优的思想将偏最小二乘法、ARIMA 模型和指数平滑法预测结果进行组合,对农产品冷链物流需求进行预测;褚鹏宇^[4]采用广义回归神经网络对预测模型的权重进行赋值,建立了变权重组合的灰色预测模型;苏丽敏^[5]以误差平方和最小为目标函数,结合最大熵原理构建了变权组合预测模型;李佩^[6]以平均误差最优为目标来给组合预测权重赋值;周宏^[7]用最小二乘原理对 ARIMA 和 SARIMA 模型的权重进行分配,并将其用于高速公路短时交通流预测。

目前,在铁路客运量组合预测研究领域中,权重赋值方法存在计算量大、组合预测精度不佳等缺点。而群体智能算法因其精度高、应用广泛等优点,已成为解决优化问题的热门算法,但群体智能算法也存在陷入局部最优等问题。因此,本文基于自然选择的粒子群算法,对其权重和学习因子进行改进,应用改进基于自然选择的粒子群算法求解 ARIMA 模型和 BP 神经网络预测的铁路客运量的权重,对铁路客运量进行组合预测。

1 铁路客运量组合预测模型

假设运用 m 种模型对某一研究区域的铁路客运量进行预测,则组合预测模型的计算公式为:

$$Q = \sum_{i=1}^m w_i \times q_i \tag{1}$$

式中: Q ——铁路客运量组合预测值;

w_i ——第 i 个预测模型的权重,且 $\sum_{i=1}^m w_i = 1$;

q_i ——第 i 个模型的预测值;

m ——预测模型的数量。

预测方法的选择是影响铁路客运量预测精度的关键,本文选择 ARIMA 模型和 BP 神经网络作为时

间序列预测和非线性预测模型的代表进行组合预测研究。

(1) ARIMA 模型

ARIMA(p, d, q)模型的一般形式为:

$$\begin{cases} \Phi(B) \nabla^d X_t = \Theta(B) a_t \\ E(a_t) = 0, \text{var}(a_t) = \sigma_a^2, E(a_t a_s) = 0, s \neq t \\ EX_s a_t = 0, \forall s < t \end{cases} \tag{2}$$

式中: $\nabla^d = (1 - B)^d$ ——高阶差分;

$\Phi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \cdots - \varphi_p B^p$ ——自回归相关系数多项式;

$\Theta(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \cdots - \varphi_q B^q$ ——移动平均系数多项式;

a_t ——零均值且方差同为 σ_a^2 的白噪声;

p ——自回归阶数;

q ——移动平均阶数;

d ——差分阶数。

(2) BP 神经网络

BP 神经网络拓扑结构如图 1 所示,其基本思想是梯度下降法,学习过程包括正向传播和反向传播。正向传播过程中,将铁路客运量及其影响因素等信息经输入层传至隐含层,最后传至输出层。判断输出的值与实际值的误差精确度,若输出值误差不理想,将误差按照输出层 - 隐含层 - 输入层进行反向传播,通过反复训练和比较使误差最小。




图 1 BP 神经网络拓扑结构图

2 基于自然选择粒子群算法的权重分配方法

2.1 基于自然选择的粒子群算法基本原理

基本粒子群算法(PSO)中,假设第 i 个粒子在第 t 次迭代的位置和速度分别是 $x_{i,t}$ 和 $v_{i,t}$,粒子通过监督个体和种群极值来更新位置和速度,进一步逼近最优解^[8],其更新公式为:

$$v_{i,t+1} = w \times v_{i,t} + c_1 \times rand \times (pbest_i - x_{i,t}) + c_2 \times rand \times (gbest_i - x_{i,t}) \quad (3)$$

$$x_{i,t+1} = x_{i,t} + \lambda \times v_{i,t+1} \quad (4)$$

式中: w ——权重,取 0.4~0.9;

c_1 和 c_2 ——学习因子,取值范围均为 0~4;

$rand$ ——生成 0~1 之间的随机数;

$pbest$ ——个体极值;

$gbest$ ——群体极值;

λ ——速度系数,一般取 1。

基于自然选择的粒子群算法是基于基本粒子群算法,其基本思想是在每次迭代中,根据计算的适应度值用群体中较好的一半粒子替换较差的一半粒子,且保留粒子记忆的历史最优值。

2.2 改进基于自然选择的粒子群算法

基本的基于自然选择的粒子群算法一般采用固定权重和学习因子的方法来寻求最优解,权重一般取 0.4~0.9,学习因子一般取 2。粒子群算法具有较好的鲁棒性,一般情况下权重和学习因子取经验值即能满足精度要求。然而,当仿真环境更复杂或对优化精度有更高要求时,权重和学习因子取值对求解精度和速度有一定的影响。因此,本文基于对数函数和正弦函数非线性变化的思想来优化基于自然选择粒子群算法的权重和学习因子取值,从而提高算法的寻优能力。

权重优化原理为:初始迭代时,为保证基于自然选择粒子群算法的全局搜索能力,赋予权重较大的值。为保证该算法能寻找到最优解,迭代过程中逐渐减小权重取值。基于对数函数在其定义域大于等于 1 时非线性变化的特点,权重 w 优化为:

$$w = w_{\max} - (w_{\max} - w_{\min}) \times \log_{10} \left(\frac{iter}{ger} \times 9 + 1 \right) \quad (5)$$

式中: w_{\max} ——权重最大值;

w_{\min} ——权重最小值;

ger ——最大迭代次数; $iter$ 为当前迭代次数, $0 < iter \leq ger, iter \in N^*$ 。

权重取值规律如图 2 所示。

由图 2 可知,当迭代次数为 0 时,权重取到最大经验值,且下降的加速度较大,基于自然选择的粒子群算法在迭代初期的全局搜索能力变强。随着迭代次数的增加,以对数函数非线性变化的规律逐渐赋予权重越来越小的值,且权重下降的加速度越来越小,能保证迭代末期在可行域范围内更细致地寻找最优解。

学习因子优化原理为:随着迭代次数的增加,




图2 权重非线性变化趋势图

c_1 最佳取值范围为 2.5~0.5 间递减, c_2 最佳取值范围为 0.5~2.5 之间递增^[9]。在最优取值范围内,为保证迭代初期的全局搜索能力,使初始时个体粒子自身学习能力较大,让 c_1 的取值随迭代次数的增加呈正弦函数非线性减少,同时让 c_2 随迭代次数的增加逐渐增大,加强粒子在后期的群体学习能力。基于该思想,改进的学习因子为:

$$c_1 = 2 \times \left(1 - \sin \left(\frac{iter}{ger} \times \frac{\pi}{2} \right) \right) + 0.5 \quad (6)$$

$$c_2 = 2 \times \sin \left(\frac{iter}{ger} \times \frac{\pi}{2} \right) + 0.5 \quad (7)$$

学习因子取值规律如图 3 所示。




图3 学习因子非线性变化趋势图

由图 3 可知,学习因子 c_1 初期取到最大值 2.5,且下降的加速度较大,初期搜索能力更强;同时,让 c_2 的取值逐渐增大,且加速度逐渐变小,加强了迭代后期的搜索精度。

2.3 改进基于自然选择的粒子群算法优化权重

改进基于自然选择的粒子群算法优化权重的过

程如图4所示。

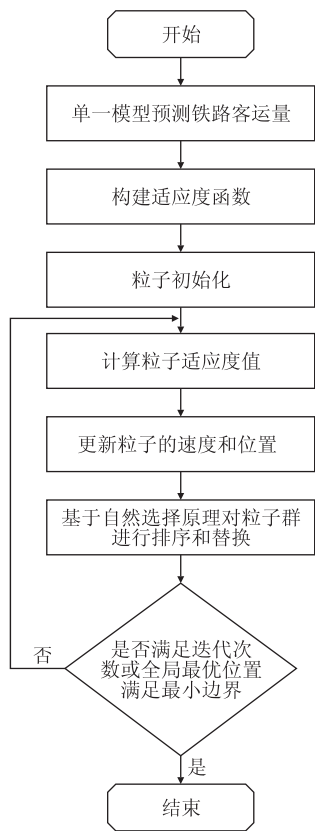


图4 改进基于自然选择的粒子群优化权重算法图

- (1)根据所选单一预测模型预测铁路客运量。
- (2)根据铁路客运量预测结果构建适应度函数。以组合预测精度最优为目标确定适应度函数 $f(\omega)$,即所有预测年份的预测相对误差的绝对值最小。因此,适应度函数定义为:

$$f(\omega) = \frac{1}{n} \sum_{i=1}^n \frac{\left| X_i - \sum_{j=1}^m q_j w_j \right|}{X_i}$$

(8)

- 式中: n ——预测总年度;
 X_t ——第 t 期的客运量实际值。
- (3)初始化种群粒子参数。根据粒子参数的取值范围等约束,设置初始的参数取值。
 - (4)计算粒子适应度。
 - (5)比较所有粒子适应度值,寻找到当前最优粒子适应度值及其位置,以此更新粒子的搜索位置和搜索速度。
 - (6)基于自然选择原理对粒子进行排序,用群体中最好的一半粒子替换最差的一半粒子。
 - (7)判断是否满足迭代终止条件。若满足,算法结束;若不满足,返回第4步。
 - (8)输出最优解。

3 实例研究

考虑指标获取的可操作性,选取具有代表性的地区生产总值、常住人口、人均消费水平、旅游人数、铁路运营里程等指标研究其对铁路客运量的影响^[10],以北京市1996–2016年数据为训练样本,以2017–2019年客运量为测试样本进行预测^[11–12]。

3.1 单一模型的铁路客运量预测

3.1.1 BP神经网络预测

通过MATLAB编程实现BP神经网络的预测过程,主要参数设置为:训练次数为1 000次,隐藏层为1层,神经元设为1个。BP神经网络预测基本情况如图5和图6所示。




图5 BP神经网络预测收敛过程图




图6 BP神经网络预测结果图

由图5可知,网络训练3次后收敛,验证集网络误差为0.003 493 5,训练集和测试集的网络误差低于0.003 493 5,误差精度较好;由图6可知,BP神经网络预测的拟合效果较好,2017–2019年平均预测相对

误差为 2.354%。

3.1.2 ARIMA模型预测

为兼顾预测模型的精确性和训练样本数据的完整性,借助于 SPSS 软件经过反复试验确定 ARIMA 模型的差分阶数 d 取 0 时,自回归阶数 p 取 4,移动平均阶数 q 取 1。因此,ARIMA(4,0,1) 预测结果如图 7 所示。




图7 ARIMA(4,0,1)预测结果图

由图7可知,1996—2016年ARIMA(4,0,1)预测的拟合效果非常好,但2017—2019年预测误差相对较差;ARIMA(4,0,1)平均预测相对误差为-5.43%,存在进一步优化的空间。

3.2 基于自然选择粒子群的铁路客运量组合预测

3.2.1 组合预测思路及仿真环境设置

选择BP神经网络和ARIMA(4,0,1)对铁路客运量进行组合预测,组合预测公式为:

$$Q_z = w_1 q_{bp} + w_2 q_{ar} \quad (9)$$

式中: w_1 、 w_2 ——分别为BP神经网络和ARIMA(4,0,1)模型预测权重;

q_{bp} 、 q_{ar} ——分别BP神经网络和ARIMA(4,0,1)模型预测值;

Q_z ——BP神经网络和ARIMA(4,0,1)模型组合预测值。

由权重约束条件 $w_1 + w_2 = 1$,式(9)可简化为:

$$Q_z = w_1 q_{bp} + (1 - w_1) q_{ar}$$

因此,改进基于自然选择的粒子群算法只需要求解 w_1 即可。

本节算法实验在MATLAB环境下进行,编写改进基于自然选择的粒子群算法代码求出测试样本中组合预测误差绝对值最小的权重 w_1 。

粒子群算法主要参数初始化有:种群规模为20个;最大迭代次数为300次;速度搜索区间为

-5~5。为进一步验证本文提出改进基于自然选择的粒子群算法的寻优能力和收敛速度,与基本粒子群算法和基于自然选择粒子群算法进行对比,学习率 c_1 、 c_2 均取2,权重取0.9。

3.2.2 改进自然选择粒子群算法优势分析

不同粒子群算法求解最优权重的适应度值随迭代次数的变化如图8所示。




图8 不同粒子群算法的寻优效果图

由图8可知,提出的改进基于自然选择的粒子群算法求解速度和精度更好^[13-14],具体包括:

(1)基于自然选择的粒子群算法求解权重的适应度值是0.004 206 820 384 781,迭代至273代时开始收敛;改进基于自然选择的粒子群算法求解权重的适应度值是0.004 206 805 448 164,迭代至182代开始收敛。改进基于自然选择的粒子群算法求解的适应度值精度能够提高0.000 000 014 936 617,迭代次数减少了91代,具有更好的寻优能力和收敛速度。

(2)基本粒子群算法求解权重的适应度值是0.004 206 910 498 023,在266次迭代后收敛。基于自然选择的粒子群算法也具有更好的寻优能力,其适应度值精度提高了0.000 000 090 113 242;相比于基本粒子群算法,改进基于自然选择的粒子群算法的寻优能力和收敛速度都有较大的提升。

3.2.3 组合预测结果分析

改进基于自然选择的粒子群算法求解 w_1 的情况如图9所示,在0~1之间求解得最优值为0.689,由此计算得 w_2 为0.311。

为进一步验证改进基于自然选择的粒子群算法求解权重的组合预测效果,将其与等分权重法赋值权重的组合预测效果进行比较(权重均取0.5)。不同预测方法测试样本的预测结果如表1所示。

由表1可知,改进基于自然选择的粒子群算法求

表 1 不同预测方法的铁路客运量预测值表

预测年份	BP神经网络预测		ARIMA模型		等分权重法		改进自然选择的PSO法	
	预测值/万人	预测误差绝对值/%	预测值/万人	预测误差绝对值/%	预测值/万人	预测误差绝对值/%	预测值/万人	预测误差绝对值/%
2017	13 699	1.257	14 258	2.775	13 978	0.759	13 873	0.002
2018	14 025	1.741	15 159	6.208	14 592	2.233	14 378	0.733
2019	14 155	4.065	15 833	7.306	14 994	1.621	14 677	0.525

解的权重具有更好的组合预测效果,具体体现在:

(1)相比于单一预测模型,改进基于自然选择的粒子群算法求解权重的组合预测精度更高,2017 – 2019 年平均相对预测误差绝对值为 0.420%,而 BP 神经网络和 ARIMA 模型的平均相对预测误差绝对值分别为 2.354%和 5.430%。




图 9 权重 w_1 取值图

(2)相比于等分权重法,改进基于自然选择的粒子群算法求解权重的组合预测效果也更好;等分权重法赋值权重后,2017 – 2019 年平均预测相对误差绝对值为 1.538%,比改进基于自然选择的粒子群算法求解权重的组合预测误差高 1.118%。

4 结束语

本文引入基于自然选择的粒子群算法用以解决组合预测模型权重分配问题,通过非线性变化的特点对基于自然选择的粒子群算法的权重和学习因子改进,并将改进基于自然选择的粒子群算法用以求解 BP 神经网络和 ARIMA 模型组合预测的权重,得到主要结论有:

(1)改进基于自然选择的粒子群算法具有更好的寻优能力,求解权重时的适应度值具有更高的计算精度,比基于自然选择的粒子群算法求解权重的适应度值精度提高 0.000 000 014 936 617。

(2)改进基于自然选择的粒子群算法具有更好的收敛速度,求解最优权重时所需的迭代次数更少,比

基于自然选择的粒子群算法求解权重迭代次数减少了 91 代。

(3)求解的权重值使得 BP 神经网络和 ARIMA 模型的组合预测效果较单一预测模型 BP 神经网络和 ARIMA 模型的预测精度和等分权重法赋值权重的组合预测精度更好,预测年度平均预测相对误差分别提高了 1.934%、5.009%和 1.118%。

参考文献:

[1] 游文倩,庄科俊. 基于组合预测模型对安徽省 GDP 的预测研究[J]. 黑龙江工业学院学报(综合版), 2020, 20(4): 103 – 107.
YOU Wenqian, ZHUANG Kejun. Prediction of GDP in Anhui Province Based on Combination Forecasting Model [J]. Journal of Heilongjiang University of Technology (Comprehensive Edition), 2020, 20(4): 103 – 107.

[2] 刘春红,杨亮,邓河,等. 基于 ARIMA 和 BP 神经网络的猪舍氨气浓度预测[J]. 中国环境科学, 2019, 39(6): 2320 – 2327.
LIU Chunhong, YANG Liang, DENG He, et al. Prediction of Ammonia Concentration in Piggery Based on ARIMA and BP Neural Network [J]. China Environmental Science, 2019, 39(6): 2320 – 2327.

[3] 王秀梅. 基于权重分配组合法的农产品冷链物流需求趋势预测[J]. 统计与决策, 2018, 34(9): 55 – 58.
WANG Xiumei. Demand Trend Forecast of Agricultural Cold Chain Logistics Based on Weight Distribution Combination Method [J]. Statistics & Decision, 2018, 34(9): 55 – 58.

[4] 褚鹏宇,刘澜. 基于变权重组合模型的铁路客运量短期预测[J]. 计算机工程与应用, 2017, 53(4): 228 – 232.
CHU Pengyu, LIU Lan. Short-Term Forecast of Railway Passenger Traffic Volume Based on Variable Weight Combination Model [J]. Computer Engineering and Applications, 2017, 53(4): 228 – 232.

[5] 苏丽敏,宋艳红,何慧爽. 考虑权重不确定性的变权重组合预测方法[J]. 统计与决策, 2019, 35(11): 60 – 63.
SU Limin, SONG Yanhong, HE Huishuang. Variable Weight Combination Forecasting Method Considering Weight Uncertainty [J]. Statistics & Decision, 2019, 35(11): 60 – 63.

[6] 李佩,彭斯俊. 一种新的组合权重在组合预测模型中的应用[J]. 河南科技大学学报(自然科学版), 2018, 39(2): 87 – 93.
LI Pei, PENG Sijun. Application of New Combination Weight to Combination Forecasting Model [J]. Journal of Henan University of

参考文献:

- [1] 蒋忠信. 泥石流固体物质储量变化的定量预测[J]. 山地研究, 1994, 12(3): 155-162.
JIANG Zhongxin. Aquantitative Forecast to Reserves Change of Solid Loose Materials in Debris Flow Ravine [J]. Mountain Research, 1994, 12(3): 155-162.
- [2] 钟立勋. 中国重大地质灾害实例分析[J]. 中国地质灾害与防治学报, 1999, 10(3): 1-10.
ZHONG Lixun. Case Study on Significant Geo Hazards in China [J]. The Chinese Journal of Geological Hazard and Control, 1999, 10(3): 1-10.
- [3] 刘传正. 南昆铁路八渡滑坡成因机理新认识[J]. 水文地质工程地质, 2007, 34(5): 1-5.
LIU Chuansheng. A New Discussion about Genesis and Failure Mechanism of Badu Landslides in Nanning-Kunming Railway [J]. Hydrogeology & Engineering Geology, 2007, 34(5): 1-5.
- [4] 何振宁. 区域工程地质与铁路选线[M]. 北京: 中国铁道出版社, 2004.
HE Zhenning. Regional Engineering Geology and Railway Route Selection [M]. Beijing: China Railway Publishing House, 2004.
- [5] 朱颖, 王国生. 铁路设计理念的回顾和展望[J]. 铁道工程学报, 2007, 24(1): 1-5.
ZHU Ying, WANG Guosheng. Review and Prospects for Railway Design Concept [J]. Journal of Railway Engineering Society, 2007, 24(1): 1-5.
- [6] 李永贵. 铁路选线设计中常见问题分析[J]. 高速铁路技术, 2014, 5(4): 67-72.
LI Yonggui. Analysis on Common Problems in Railway Route Selection Design [J]. High Speed Railway Technology, 2014, 5(4): 67-72.
- [7] 朱颖. 铁路选线理念的创新与实践[J]. 铁道工程学报, 2009, 26(6): 1-5.
ZHU Ying. Innovation and Practice on Railway Location Concept [J]. Journal of Railway Engineering Society, 2009, 26(6): 1-5.
- [8] 高传东, 崔鹏, 陈晓清. 山区道路选线及其相关的环境问题[J]. 世界科技研究与发展, 2004, 26(1): 59-64.
GAO Chuandong, CUI Peng, CHEN Xiaoqing. Road Route-Selection and Its Correlative Environment Problem in Mountain Areas [J]. World Sci-Tech R & D, 2004, 26(1): 59-64.
- (上接第68页)
- Science and Technology (Natural Science), 2018, 39(2): 87-93.
- [7] 周宏, 刘钊. 基于时间序列的高速公路短时交通流最优组合预测[J]. 工程与建设, 2018, 32(6): 812-814.
ZHOU Hong, LIU Zhao. Optimal Combination Prediction of Short-Time Traffic Flow in Highways Based on Time Series Approaches [J]. Engineering and Construction, 2018, 32(6): 812-814.
- [8] 李万, 冯芬玲, 蒋琦玮. 改进粒子群算法优化 LSTM 神经网络的铁路客运量预测[J]. 铁道科学与工程学报, 2018, 15(12): 3274-3280.
LI Wan, FENG Fenling, JIANG Qiwei. Prediction for Railway Passenger Volume Based on Modified PSO Optimized LSTM Neural Network [J]. Journal of Railway Science and Engineering, 2018, 15(12): 3274-3280.
- [9] 吕柏行, 郭志光, 赵韦皓, 等. 标准粒子群算法的优化方式综述[J]. 科学技术创新, 2021(28): 33-37.
LV Bailxing, GUO Zhiguang, ZHAO Weihao, et al. A Review on Optimization Methods of Standard Particle Swarm Optimization [J]. Scientific and Technological Innovation, 2021(28): 33-37.
- [10] 南敬林. 铁路客运量预测影响因素分析[J]. 综合运输, 2016, 38(2): 35-40.
NAN Jinglin. The Analysis of Influencing Factor about Railway Passenger Forecast [J]. China Transportation Review, 2016, 38(2): 35-40.
- [11] 徐森. 改进的神经网络及其时序组合模型在铁路客运量上的预测[D]. 兰州: 兰州交通大学, 2020.
XU Sen. Forecast of Railway Passenger Volume Based on Improved Neural Network and Its Time Series Combination Model [D]. Lanzhou: Lanzhou Jiatong University, 2020.
- [12] 陶海龙, 李小平, 张胜召, 等. 基于 IPSO-BP 神经网络的铁路客运量预测[J]. 铁道运输与经济, 2011, 33(9): 78-82.
TAO Hailong, LI Xiaoping, ZHANG Shengzhao, et al. Forecast of Railway Passenger Traffic Volume Based on IPSO-BP Neural Network [J]. Railway Transport and Economy, 2011, 33(9): 78-82.
- [13] 温正, 孙华克. MATLAB 智能算法[M]. 北京: 清华大学出版社, 2017.
WEN Zheng, SUN Huake. MATLAB Intelligent Algorithm [M]. Beijing: Tsinghua University Press, 2017. [LinkOut]
- [14] 姜永杰, 张书豪, 吴光, 等. 基于灰色系统及 BP 神经网络算法的边坡变形预测精度影响分析[J]. 高速铁路技术, 2020, 11(5): 13-19.
JIANG Yongjie, ZHANG Shuhao, WU Guang, et al. Influence Analysis of Slope Deformation Prediction Accuracy Based on Grey System and BP Neural Network Algorithm [J]. High Speed Railway Technology, 2020, 11(5): 13-19.