

文章编号: 2095-2163(2020)03-0223-05

中图分类号: U213.2

文献标志码: A

基于非等时距灰色理论与 BP 神经网络的钢轨波磨预测

陈 鑫, 尧辉明

(上海工程技术大学 城市轨道交通学院, 上海 201620)

摘 要: 针对钢轨波磨发展预测, 结合实际现场测量的波磨数据进行深入分析, 提出了一种基于非等时距灰色模型与 BP 神经网络的钢轨波磨组合预测模型。该模型具有灰色理论所需数据样本量小以及 BP 神经网络非线性拟合能力强的优点, 可根据少量非等时间间隔测量的原始波深数据预测钢轨未来波磨发展。将某线上行地铁钢轨波磨波深历史数据用于模型训练并进行预测分析, 结果对比显示, 组合模型预测结果的平均绝对误差较单一的灰色模型明显减小, 其预测精度检验等级达到 1 级。证明了这种预测方法在钢轨波磨预测中的有效性, 从而为工务部门制定轨道养护与打磨策略提供重要的指导意义。

关键词: 钢轨波磨; 非等时距; 灰色模型; BP 神经网络

Prediction of rail corrugation based on non-equal interval grey model and BP Neural Network

CHEN Xin, YAO Huiming

(School of Urban Rail Transportation, Shanghai University of Engineering Science, Shanghai 201620, China)

[Abstract] Aiming at the prediction of the development of rail corrugation, in-depth analysis is carried out based on actual field-measured rail wave data, and a combined model of rail corrugation based on non-equal interval grey model and BP neural network is proposed. The model combines the advantages of less data required by grey theory and strong nonlinear fitting ability of BP neural network. It can predict the future development of rails based on the original wave depth values measured by a small number of non-equal time intervals. The historical data of rail wave wear depth on a certain line are used for model training and prediction analysis. The results show that the average absolute error of the combined model prediction results is significantly reduced compared to the single gray model, and the prediction accuracy test level reaches level 1. It proves the effectiveness of this prediction method in the prediction of rail grinding, which provides important guiding significance for the development of track maintenance and polishing strategy by the public works department.

[Key words] rail corrugations; non-equal interval; grey model; BP Neural Network

0 引言

钢轨波浪形磨耗, 简称波磨, 是指在钢轨投入使用之后, 轨顶沿纵向表面出现的有一定规律性的波形不平顺现象, 是钢轨损伤的一种主要形式^[1]。利用波磨测量数据对钢轨进行科学管理与维护, 合理安排钢轨打磨周期, 可以有效控制波磨发展, 保障行车安全, 因此了解和掌握钢轨波磨发展规律并进行预测意义重大。

灰色系统理论与 BP 神经网络算法是被广泛应用于各个场合的 2 种常用预测模型。由于钢轨波磨形成与发展有着十分复杂的机理, 目前暂无相关学者利用灰色算法与 BP 神经网络算法进行相关的波磨预测研究。但在与钢轨波磨类似的轨道不平顺状态预测领域, 灰色算法与 BP 神经网络得到大量应

用。曲建军等人^[2]将灰色理论引入轨道质量预测领域, 在灰色理论基础上建立了轨道不平顺 TIT- $CGM(1, 1) - PC$ 灰色非线性预测模型; 彭丽宇等人^[3]将 BP 神经网络用于铁路轨道几何不平顺预测, 其建立的双隐层 BP 网络具有较高的预测精度; 马帅等人^[4]采用 BP 神经网络对 TQI 时间序列中的低频部分建模, 针对客货共线无砟轨道 TQI 特性进行不平顺预测; 韩晋等人^[5]提出了一种运用 BP 神经网络对灰色模型预测的残差校正的轨道质量预测方法; 马子骥等人^[6]基于非等时距灰色模型建立了灰色算法与 Elman 神经网络的轨道质量组合预测模型。

本文将灰色理论与 BP 神经网络引入钢轨波磨预测领域, 提出了一种非等时距灰色模型与 BP 神

基金项目: 上海市科委地方院校能力建设项目(15590501400); 上海工程技术大学研究生科研创新项目(0240-E3-0903-19-01198)。

作者简介: 陈 鑫(1994-), 男, 硕士研究生, 主要研究方向: 钢轨波浪形磨损检测技术研究; 尧辉明(1980-), 男, 博士, 副教授, 硕士生导师, 主要研究方向: 轨道车辆安全检测、监测预警算法、工程技术研究等。

通讯作者: 陈 鑫 Email: cx17621629813@163.com

收稿日期: 2019-09-28

神经网络^[7]的钢轨波磨组合预测模型。该模型可根据少量非等时间间隔测量的原始波磨数值预测钢轨波磨发展。将某线上行地铁钢轨波磨实测历史波深数据用于模型训练并进行预测分析,得到了较好的预测精度,证明了这种预测方法在钢轨波磨预测中的有效性。

1 预测模型理论依据

钢轨波磨的形成与发展受轮轨间自激振动与反馈振动、通过车辆质量与速度、车辆制动、自然气象等外部因素以及钢轨本身初始不平顺、材料塑性、材料微观结构等内部因素共同影响^[8],且这些因素无法被量化,从而使得波磨的发展具有很强的随机性与复杂性。从系统的角度看,钢轨波磨发展是一个受到多因素影响的灰色系统,其中,波深数值为可计算的“白色信息”,而其他不确定影响因素均为“灰色信息”,无法量化分析所有影响因素。灰色预测理论对这种信息不完全明了的系统能够进行很好的预测分析,并且可以满足在信息量较少的条件下进行建模^[9]。因此,将灰色模型用于钢轨波磨预测,可以把受各种复杂因素影响的波磨波深量当作是与时间相关的灰色量,从波磨波深自身数据使用其中的有用信息来建立模型,发现其一定的规律性并做出相应预测。BP神经网络是一种应用十分广泛的人工神经网络模型,其自适应学习功能和容错性功能都非常强,特别是在处理非线性系统时更是拥有独特的优势。BP神经网络可以通过对一定样本的学习以任意精度逼近函数,并且具有较高的预测精度^[10]。所以采用BP神经网络对灰色预测模型的初步预测残差值修正拟合,可以减少波磨数据产生的随机性与复杂性,进一步提高模型的预测精度。

2 建模过程

2.1 非等时距GM(1,1)的建立

由于钢轨波磨波深数据的采集周期较长,还不可避免地会受不确定、主观、客观的因素影响,直接导致波深数据序列的不等时距性,传统的等时距GM(1,1)模型难以满足非等时距数据样本的建模要求。因此,采用非等时距GM(1,1)预测模型对钢轨波磨发展进行预测,其主要过程如下:

(1)级比检验及非等时距序列的生成。设在某段时间内原始波深序列值为: $X^{(0)}(t_i) = \{x^{(0)}(t_1), x^{(0)}(t_2), x^{(0)}(t_3), \dots, x^{(0)}(t_n)\}$ 计算历史测量序列的级比:

$$k(t_i) = \frac{x^{(0)}(t_{i-1})}{x^{(0)}(t_i)}, i = 2, 3, \dots, n, \quad (1)$$

当得到的级比 $k(t_i)$ 位于区间 $(e^{-\frac{2}{n+1}}, e^{\frac{2}{n+2}})$ 中时,原始数据可直接用于预测建模,并在完成预测之后进行还原。否则,需要选取合适的 C 对 $x^{(0)}(t_i)$ 进行平移变化,即:

$$x^{(0)}(t_i) = x^{(0)}(t_i) + C, i = 1, 2, \dots, n, \quad (2)$$

由于钢轨波磨测量任务不是定期进行,所以波深序列的检测时间并非为等差分布,假设数据 $x^{(0)}(t_i)$ 所对应的测量时间为 t_i ,则有原始波磨波深样本间的时间差为:

$$\Delta_{t_i} = t_i - t_{i-1} \neq \text{const}, i = 2, 3, \dots, n, \quad (3)$$

其中, const 表示常量,当 $\Delta_{t_i} \neq \text{const}$ 时称为非等时距GM(1,1)模型^[11]。

对原始波深数据序列做一阶累加生成,将测量时间差记为 Δ_{t_i} ,那么新生成的序列为:

$$x^{(1)}(t_i) = \sum_{k=1}^i x^{(0)}(t_k) \Delta_{t_k}, i = 2, 3, \dots, n, \quad (4)$$

令 $x^{(1)}(t_1) = x^{(0)}(t_1)$,其中有:

$$x^{(1)}(t_1) = \frac{1}{n} \sum_{k=1}^n x^{(0)}(t_k) \Delta_{t_k}, \quad (5)$$

(2)非等时距灰色模型的建立。记上述对非等时距样本序列进行一次累加时得到新序列 $X^{(1)}$ 为: $X^{(1)} = \{x^{(1)}(t_1), x^{(1)}(t_2), \dots, x^{(1)}(t_n)\}$, (6)

然后由一阶累加生成式子建立GM(1,1)模型,通过改进灰色作用量,使得改进模型的白化微分方程为:

$$\frac{dx^{(1)}(t)}{dt} + ax^{(1)}(t) = u, t \in [0, \infty). \quad (7)$$

对式(7)左右两边在区间 $[t_{i-1}, t_i]$ 上进行积分以离散化:

$$x^{(0)}(t_i) \Delta_{t_i} + a \int_{t_{i-1}}^{t_i} x^{(1)}(t) dt = u \Delta_{t_i}, i = 2, 3, \dots, n, \quad (8)$$

其中,有:

$$z^{(1)}(t_i) = \int_{t_{i-1}}^{t_i} x^{(1)}(t) dt, i = 2, 3, \dots, n, \quad (9)$$

称 $z^{(1)}(t_i)$ 为 $x^{(1)}(t_i)$ 在区间 $[t_{i-1}, t_i]$ 上的白化背景值,通常可将其简化^[12]为:

$$z^{(1)}(t_i) = \frac{(x^{(1)}(t_i) + x^{(1)}(t_{i-1}))}{2} \Delta_{t_i}, \quad (10)$$

再将其离散化得到差分方程为:

$$x^{(0)}(t_i) \Delta_{t_i} + az^{(1)}(t_i) = u \Delta_{t_i}, \quad (11)$$

其中, a 为发展系数,是系统发展态势, a, u 为灰色作用量,反映的是数据变化的不确定关系。

利用最小二乘法求得参数 a, u 的估计值为:

$$(a, u)^T = (B^T B)^{-1} B^T Y, \quad (12)$$

其中:

$$B = \begin{bmatrix} -z^{(1)}(t_2) & 1 \\ -z^{(1)}(t_3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(t_n) & 1 \end{bmatrix}, Y = \begin{bmatrix} x^{(0)}(t_2) \\ x^{(0)}(t_3) \\ \vdots \\ x^{(0)}(t_n) \end{bmatrix}, \quad (13)$$

将参数 a, u 代入上述微分方程中求解相应的时间响应函数为:

$$\hat{x}^{(1)}(t_i) = \left(x^{(0)}(t_i) - \frac{u}{a} \right) e^{-a(t_i-t_1)} + \frac{u}{a}, \quad i = 2, 3, \dots, n, \quad (14)$$

从而得到 GM(1,1) 初步预测值为:

$$\hat{x}^{(0)}(t_i) = \hat{x}^{(1)}(t_i) - \hat{x}^{(1)}(t_{i-1}), i = 2, 3, \dots, n, \quad (15)$$

(3)背景值的优化。模型的拟合以及预测精度取决于参数 a, u , 而参数 a, u 的求解又依赖于背景值 $z^{(1)}(t_i)$ 的构造形式。传统背景值求解是在区间 $[t_{i-1}, t_i]$ 上使用梯形公式来代替曲线 $x^{(1)}(t_i)$ 与时间横轴围成的面积,但当 $x^{(1)}(t_i)$ 在 $[t_{i-1}, t_i]$ 上急剧变化时,近似满足指数形式,会造成精度误差。为了减少此误差,本文利用 $x^{(1)}(t_i) = qe^{rt}$ 形式拟合一次累加序列,其中 q, r 均为常系数,则有背景值表达式优化为:

$$z^{(1)}(t_i) = \frac{x^{(1)}(t_i) - x^{(1)}(t_{i-1})}{\ln x^{(1)}(t_i) - \ln x^{(1)}(t_{i-1})} * \Delta t_i. \quad (16)$$

2.2 基于BP神经网络的预测残差修正

由于波磨波深产生的复杂性与随机性,灰色模型初步预测值可能会存在较大误差,因此需要对预测残差序列进行修正,克服单一预测模型精度不足问题。BP神经网络模型不仅能够解决许多复杂的、不确定性的、非线性的问题,还具有信息利用率高、防止信息失真的特点,因而特别适用于对灰色预测模型的残差序列进行修正^[5]。通过将不等时距 GM(1,1)模型与BP神经网络相结合应用于波磨波深发展的预测,能使其达到更好的预测效果。根据BP神经网络模型的基本原理与学习算法^[13],利用BP神经网络进行残差修正方法的流程如图1所示。

根据以上所述建模原理,得到基于BP神经网络对非等时距 GM(1,1)初步预测值进行残差修正的钢轨波磨组合预测模型,其具体实施步骤如下:

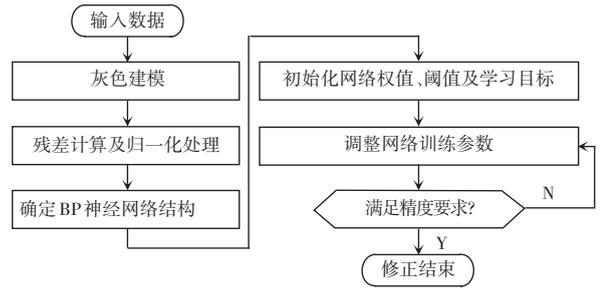


图1 BP神经网络预测残差修正流程图

Fig. 1 BP neural network prediction residual correction flowchart

(1)建模前,首先需要对输入数据进行级比检验判断是否满足灰色建模的要求,如不满足,则应先对数据进行平移变化。

(2)将上一步骤处理完的数据进行非等时距累加处理,得到一阶累加序列 $x^{(1)}(t_i)$ 。

(3)将得到的 $x^{(1)}(t_i)$ 输入至非等时距 GM(1,1),使用优化后的背景值表达式(16)代替传统背景值表达式(9),求得参数 a, u 的估计值。

(4)求出最终的时间响应函数并求得初步预测值 $\hat{x}^{(0)}(t_i)$ 和残差序列 $w^{(0)}(t_i)$ 。

(5)对残差数据序列 $w^{(0)}(t_i)$ 进行归一化处理,使其位于 Sigmoid 函数能处理的范围内,然后输入到BP神经网络中。

(6)确定BP神经网络模型结构、激励函数、训练方法以及调整训练的参数。

(7)使用训练好的BP神经网络计算得到残差修正值 $\hat{w}^{(0)}(t_i)$,然后将其与初步预测值 $\hat{x}^{(0)}(t_i)$ 相加得到最终预测值:

$$x(t_i) = \hat{x}^{(0)}(t_i) + \hat{w}^{(0)}(t_i), i = 1, 2 \dots n.$$

2.3 预测模型精度检验

为验证本文建立的波磨波深预测模型的可靠性,采用小概率误差 p 和后验差 C 对算法精度进行检验^[14]。 $x(t_k)$ 为预测值, $x^{(0)}(t_k)$ 为实测值。

(1)相对残差。其数学定义可表示为:

$$\varepsilon(t_k) = \frac{x(t_k) - x^{(0)}(t_k)}{x^{(0)}(t_k)} * 100\%, \quad (17)$$

(2)平均残差。其数学定义可表示为:

$$\varepsilon(avg) = \frac{1}{n-1} \sum_{k=2}^n |\varepsilon(t_k)|, \quad (18)$$

(3)残差的方差。其数学定义可表示为:

$$S_1^2 = \frac{1}{n} \sum_{k=1}^n (\varepsilon(t_k) - \varepsilon(avg))^2, \quad (19)$$

(4)原始数据的方差。其数学定义可表示为:

$$S_2^2 = \frac{1}{n} \sum_{k=1}^n \left(x^{(0)}(t_k) - \frac{1}{n} \sum_{k=1}^n x^{(0)}(t_k) \right)^2, \quad (20)$$

(5) 小概率误差精度。其数学定义可表示为:

$$p = (1 - \varepsilon(\text{avg})) * 100\%, \quad (21)$$

(6) 后验差比值。其数学定义可表示为:

$$C = S_1/S_2. \quad (22)$$

模型精度 p 值越大,说明预测精度越高,而后验差比值 C 越小,说明预测误差的离散型越小。通常可根据 p 和 C 计算结果综合评定模型精度,见表1,可将预测精度分为4级。

表1 精度检验等级参照表

Tab. 1 Accuracy inspection level reference table

模型精度等级	p	C
1级(好)	$p \geq 0.95$	$C \leq 0.35$
2级(合格)	$0.80 \leq p < 0.95$	$0.35 < C \leq 0.50$
3级(基本合格)	$0.70 \leq p < 0.80$	$0.50 < C \leq 0.65$
4级(不合格)	$p < 0.70$	$0.65 < C$

3 实例验证

本文实例验证数据来自某线上行地铁曲线段实测得到的9个月历史钢轨波磨数据^[15],见表2。其中,2013年8月测量波磨数据时刚进行了钢轨打磨,以排除之前历史波磨对波磨发展趋势研究产生影响。

表2 某线上行曲线段9个月波磨发展数据

Tab. 2 9-month wave wear development data for a line up curve segment

测量时间	平均波磨深度	平均波长
2013-08	0	0
2013-09	0.050	150
2013-10	0.116	150
2013-11	0.116	150
2013-12	0.200	167
2014-01	0.226	158
2014-02	0.239	158
2014-03	0.249	158
2014-04	0.262	156

由表2中可看出,在9个月内波磨波长数据维持在一定范围内,随时间波动较小,影响波磨发展的主要指标为波磨波深值,再结合第1节波磨预测理论,得出利用波深历史数据预测波磨发展具有一定可行性。从表2中可得到9组关于时间序列的波深样本数据,由于数据样本个数较少,选择三次样条插

值法对原始样本扩容,可得到17组等时间间隔的波深数据序列,相对测量时间间隔为半个月,如图2所示。在实际现场测量中,对波磨的测量往往是非等时间间隔的,所以最终选择其中13个波磨样本数据构成预测模型的原始非等时距波深数据,以此进行预测分析。

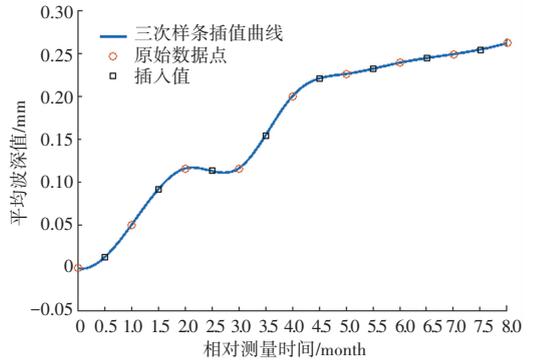


图2 三次样条插值法样本插值扩容结果

Fig. 2 Cubic spline interpolation method sample interpolation expansion result

根据前文所述的非等时距灰色预测模型建模方法,辅以 Matlab 软件进行计算,求得非等时距 GM(1,1)初步预测结果如图3所示。

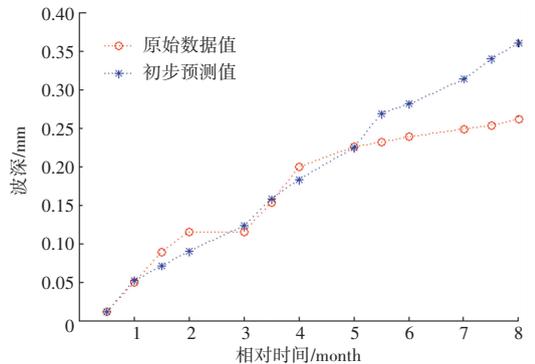


图3 非等时距 GM(1,1)初步预测结果

Fig. 3 Non-equal time GM(1,1) preliminary prediction results

由图3可见,若单纯采用非等时距 GM(1,1)模型对波磨进行预测已经能反映出波深序列的变化趋势,但拟合出时间较近的数据误差较大,单个数据点最大相对误差达到了0.374%。为此,通过结合 BP神经网络对 GM(1,1)预测模型的残差进行修正,进一步提高预测精度,减小误差。

通过 Matlab 的 BP神经网络工具箱编程,采用一个隐含层,隐含层节点数为12,并且隐含层采用 Sigmoid 函数作为传递函数。其训练方法采用收敛速度最快、均方差也较小的 LM (Levenberg-Marquardt)算法。预测类型为单步预测,即进行预测时,把残差序列 $(w^{(0)}(t_i), w^{(0)}(t_{i+1}), w^{(0)}(t_{i+2}), \dots)$

$w^{(0)}(t_{i+3})$)这4个数据网络输入,输出则是下一时刻的预测值 $\hat{w}^{(0)}(t_{i+4})$,预测 $\hat{w}^{(0)}(t_{i+5})$ 时,则把 $(w^{(0)}(t_{i+1}),w^{(0)}(t_{i+2}),w^{(0)}(t_{i+3}),w^{(0)}(t_{i+4}))$ 作为输入数据。使用原始13个波深残差数据,构建了9组数据样本,其中前5组作为训练数据,后4组用于预测数据,即组合模型预测最后4个波深值(数据样本序号为10~13号)。采用BP神经网络对残差修正预测与仅使用单纯非等时距GM(1,1)的对比预测效果如图4所示,残差修正前后预测误差分析结果见表3。

其中,数据样本序号12是为增加样本数量而插入的点,无统计意义,遂未在结果表中给出。由图4及表3不难发现,经过组合预测方法,预测误差有较为明显的减小,相对误差平均值由0.288%减小到0.118%。对前后预测模型进行精度检验见表4,结果显示,非等时距GM(1,1)模型预测精度等级为合

格,而组合预测算法的精度等级达到1级。综上实例分析所述,本文提出的基于BP神经网络对非等时距GM(1,1)初步预测残差修正的钢轨波磨组合预测模型预测效果较好,对钢轨波磨预测研究有一定可行性与可参考性。

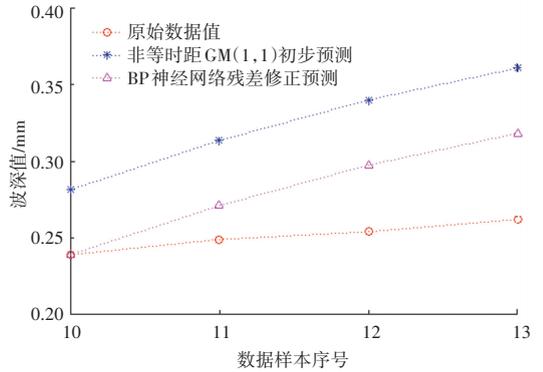


图4 残差修正前后预测效果

Fig. 4 Prediction effect before and after residual correction

表3 残差修正前后预测误差分析

Tab. 3 Analysis of prediction error before and after residual correction

数据样本序号	测量时间	原始值/mm	修正前预测值/mm	修正后预测/mm	修正前相对误差/%	修正后相对误差/%
10	2014-02	0.239	0.281	0.239	0.176	0
11	2014-03	0.249	0.314	0.271	0.261	0.088
13	2014-04	0.262	0.360	0.318	0.374	0.214

表4 精度检验结果

Tab. 4 Accuracy test result

预测模型	平均相对误差/%	C	p	精度等级
非等时距GM(1,1)	0.288	0.088	0.84	合格
BP神经网络残差修正	0.118	0.072	0.96	1级

4 结束语

本文针对钢轨波磨发展预测,分析了波磨预测理论依据,建立了一种基于非等时距灰色模型与BP神经网络的钢轨波磨组合预测模型。将某线上行地铁实测得到的波磨波深数据经过插值预处理用于模型训练并进行了预测分析,结果显示,非等时距GM(1,1)预测模型初步预测精度等级达到合格,说明了灰色预测模型对钢轨波磨预测有一定可行性。引入BP神经网络对波磨灰色预测结果进行残差修正,使预测误差明显减小,说明组合预测能降低波磨发展趋势中的复杂性与随机性,有效克服单一预测模型精度不足问题。同时实例分析表明组合预测模型精度等级达到1级(好),证明了该模型的有效性,可为工务部门制定轨道养护与打磨策略提供重要指导意义。

参考文献

[1] 沈钢,张学华,郭满鸿. 地铁曲线钢轨波浪型磨耗的测量分析[J]. 城市轨道交通研究,2011,14(4):53.

[2] 曲建军,高亮,田新宇,等. 基于灰色理论的轨道几何状态中长期时变参数预测模型的研究[J]. 铁道学报,2010,32(2):55.
 [3] 彭丽宇,张进川,苟娟琼,等. 基于BP神经网络的铁路轨道几何不平顺预测方法[J]. 铁道学报,2018,40(9):154.
 [4] 马帅,高亮,刘秀波,等. 客货共线无砟轨道平顺状态预测模型[J]. 中国铁道科学,2019,40(3):24.
 [5] 韩晋,杨岳,陈峰,等. 基于非等时距加权灰色模型与神经网络的轨道不平顺预测[J]. 铁道学报,2014,36(1):81.
 [6] 马子骥,唐涛,刘宏立,等. 基于非等间距灰色模型和Elman神经网络的轨道质量预测[J]. 哈尔滨工业大学学报,2018,50(5):137.
 [7] 经建芳,邓富康,李康春,等. 海水腐蚀速率的不等时距灰色模型与BP神经网络模型组合预测[J]. 材料保护,2015,48(8):33.
 [8] 金学松,李霞,李伟,等. 铁路钢轨波浪形磨损研究进展[J]. 西南交通大学学报,2016,51(2):264.
 [9] 邓聚龙. 灰色系统基本方法[M]. 武汉:华中理工大学出版社,1987.
 [10] 周开利,康耀红. 神经网络模型及其MATLAB仿真程序设计[M]. 北京:清华大学出版社,2005.
 [11] 周慧,王晓光,李新战. 不等时距灰色组合预测模型的研究[J]. 数学的实践与认识,2010,40(21):107.
 [12] 舒诗湖,向高,何文杰,等. 灰色模型在城市中长期用水量预测中的应用[J]. 哈尔滨工业大学学报,2009,41(2):85.
 [13] 史峰,王小川,郁磊,等. 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.
 [14] 孙丽军,杨家冕. 非等时距灰色模型在地压灾害预测研究中的应用[J]. 金属矿山,2011(10):51.
 [15] 王二中,郭星利,张丽平. 延缓钢轨波磨发展与降低噪声的试验研究[J]. 铁道建筑,2015(8):109.