

文章编号:1005-0523(2019)03-0016-08

基于相空间重构的 CRTSII 型轨道板温度梯度预测分析

申建康,何越磊,李再伟,路宏遥

(上海工程技术大学城市轨道交通学院,上海 201620)

摘要:为研究和预测 CRTSII 型轨道板非线性温度梯度随时间的变化规律,达到及时预警和降低轨道板病害发生的目的。本文运用 C-C 方法对 CRTSII 型轨道板非线性温度梯度时间序列进行最优相空间重构;在相空间重构的基础上,采用有反馈和记忆功能的 NARX 动态神经网络对非线性温度梯度时间序列进行预测分析。结果表明:基于对 CRTSII 型轨道板温度梯度时间序列的最优相空间重构,利用 NARX 动态神经网络方法对未来时间 $T=30 \gamma \cdot \tau$, $\gamma=1, 2, 3, \dots$, 内的 CRTSII 型轨道板温度梯度进行预测。当 $\gamma=1$ 时,即 2016-11-17T08:00/2016-11-17T13:00 时间内共 11 个部分采样节点的温度梯度预测结果表明,预测值与真实值有较好的吻合度。所以该方法在 CRTSII 型轨道板的非线性时间序列系统预测中具有一定的科学价值和实用价值。

关键词:轨道板;温度梯度;时间序列;相空间重构;NARX 动态神经网络

中图分类号:U213.2+44

文献标志码:A

CRTSII 型板式无砟轨道结构是我国高速铁路使用较为广泛的轨道结构之一。其作为一种混凝土结构长期暴露在大气环境中受外部高速载荷和自身非线性温度梯度的影响,在个别地段出现轨道板上拱离缝、翘曲变形;宽窄接缝掉块、露筋等结构病害^[1-5]。严重地影响着轨道板的服役性能和线路安全。因此,提高轨道板温度梯度等相关参数的准确性预测,对降低病害发生和改善轨道板服役性能等具有重要意义。

目前,针对无砟轨道结构的非线性系统及其预测分析方面的研究已经取得了较大的进步。文献[5]利用实测的温度分布数据,验证了基于热传导理论的轨道结构温度场计算公式,并定性分析了气象数据资料变化引起的轨道结构温度分布和温度场变化规律;文献[6]在研究日温差、日照时数和风速对轨道板竖向温度梯度的影响规律基础上,通过建立误差反向传播的多层人工神经网络的方法,将长期观测的轨道板温度场数据和气象参数作为训练样本。从而实现了对轨道板竖向温度梯度的预测;文献[7]运用数值模拟分析的方法,阐明了严寒地区冬、夏两季极端天气条件下 CRTSII 型轨道板的温度特性作用机理;文献[8]采用数理统计分析法,定性分析了高温状态下轨道板温度和温度梯度的日变化规律,并拟合轨道板最大温度梯度与对应顶部温度的关系曲线。文献[9]在传热学基本原理的基础上,考虑边界条件,建立了轨道结构温度场分析模型,并以日照时长、日总辐射量、日平均气温和日温差为自变量,回归分析提出了轨道结构竖向温度分布预估模型,可为精确计算轨道结构温度效应提出参考。以上研究成果均为推动深入认识无砟轨道结构温度特性作用机理和变化规律上做出了贡献,并从定性的角度为我国无砟轨道结构设计以及养护维修提供了一些建设性意见。

但在已有相关轨道板温度和温度梯度的研究中,一般预测模型主要是在时间域中进行研究,缺乏结合非线性时间序列自身结构特性的建模和预测研究。另外,我国各条高速铁路运营环境存在较大差异性,地域性特征较为突出。因此,在针对各地的实际环境情况的基础上,需要进一步对轨道板变形与温度场之间的作

收稿日期:2018-11-22

基金项目:国家自然科学基金项目(51478258);上海市科委重点支撑项目(16030501400);上海工程技术大学研究生科技创新项目(E3-0903-17-01126)

作者简介:申建康(1992—),男,硕士研究生,研究方向为交通工程结构维护与保障。

通讯作者:何越磊(1972—),男,教授,硕士生导师,研究方向为轨道交通基础设施检测技术与安全评估。

用机理进行研究。其中,通过实测轨道板温度数据,实现准确预测轨道板温度梯度数值及其发展趋势也是研究环节之一。因此,为实现准确预测轨道板非线性温度梯度和降低 CRTSII 型轨道板的病害发生率的目的,本文根据相空间重构具有可以从系统特性角度提取其相关非线性时间序列结构特征信息的优点,并结合 NARX 动态神经网络所具备的反馈记忆型网络的优点。本文做了以下研究:首先,通过对 CRTSII 型轨道板非线性温度梯度时间序列进行最优相空间重构,将非线性时间序列中蕴含的信息充分地显露出来,并将其扩展到合适的维数上^[10-13]。其次,将重构后的温度梯度时间序列最优相空间与 NARX 动态神经网络结合,从而实现了 CRTSII 型轨道板竖向温度梯度的有效预测分析。

1 温度梯度的数据获取

文章选用华东地区某典型客运专线作为监测对象,线路运营速度为 300 km/h,轨道结构为 CRTSII 型板式无砟轨道结构。分别在轨道板板表/板底安装 PT-100 型温度传感器,按 1 次/30 min 的频率分别对轨道板板表/板底温度的温度数据进行采集。经过对该线路长期在线数据采集和监测,逐渐形成了 CRTSII 型轨道板板表/板底的动态温度时间序列。本次测试共采集 15 553 组数据,历时 11 个月(2016-08-01/2017-06-20)。根据 CRTSII 型轨道板结构,其竖向正温度梯度为

$$G = \frac{T_b - T_d}{\Delta x} \times 1\ 000 \quad (1)$$

式中: G 为温度梯度,°C/m; T_b, T_d 分别为轨道板板表和板底温度,°C; Δx 为轨道板板表与板底之间的距离,mm。因此,将采集的轨道板板表/板底温度数据代入等式(1),可得 CRTSII 型轨道板非线性温度梯度的时间序列,如图 1 所示。




图 1 轨道板温度梯度时间序列

Fig.1 Temperature gradient time series of track slab

2 CRTSII 型轨道板温度梯度的相空间重构

2.1 相空间重构原理

相空间的重构理论是研究非线性时间序列重要方法之一。Takens 定理^[14]认为一个未知的、确定的动力系统所产生的非线性时间序列能够重构出该未知系统的动力学形式。所以通过对一维时间序列的维数进行扩充和延拓,可以将时间序列中蕴含的信息充分地显露出来。而恰当的时间延迟 τ 和嵌入维数 m ,将是时间序列相空间重构质量好坏的关键。

设某非线性系统中的一维时间序列为 $x_1, x_2, \dots, x_i, \dots, x_N$, 根据时间延迟和嵌入维重构方法,选择 τ 为嵌入延迟时间, m 为嵌入维数,重构相空间中的点为

$$X(i) = \{x(i), x(i+\tau), x(i+2\tau), \dots, x[i+(m-1)\tau]\} \quad (2)$$

式中: $j=1, 2, \dots, N-(m-1)\tau$ 。重构相空间的序列矩阵为

$$\begin{bmatrix} x(1) & x(1+\tau) & x(1+2\tau) & \cdots & x[1+(m-1)\tau] \\ x(2) & x(2+\tau) & x(2+2\tau) & \cdots & x[2+(m-1)\tau] \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x(i) & x(i+\tau) & x(i+2\tau) & \cdots & x[i+(m-1)\tau] \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x[N-(m-1)\tau] & x[N-(m-2)\tau] & x[N-(m-3)\tau] & \cdots & x(N) \end{bmatrix} \quad (3)$$

2.2 温度梯度时间序列的相空间重构

目前,对于采集的一维温度梯度时间序列,本文采用 C-C 方法^[15],即:同时估计延迟时间 τ 和嵌入维数 m 。1996 年, KUGIUMTZIS D 提出时延 τ 与嵌入维数 m 之间满足 $\tau_w = (m-1)\tau$, 并且要求 $\tau_w \geq \tau_p$, 这

里 τ_w, τ, τ_p 分别代表嵌入窗、最优时延、时间序列的平均轨道周期。

定义一维时间序列 $\{x(i)|i=1, 2, \dots, N\}$, 以时延 τ 和嵌入维数 m , 进行相空间重构得

$$X(i) = \{x(i), x(i+\tau), x(i+2\tau), \dots, x[i+(m-1)\tau]\} \quad (4)$$

$X(i)$ 为相空间中的相点, 则嵌入时间序列的关联积分为

$$C(m, N, r, \tau) = \frac{2}{M(M-1)} \sum_{1 \leq i < j \leq M} \theta(r - d_{ij}), r > 0 \quad (5)$$

式中: N 为时间序列的长度; r 为搜索半径; $d_{ij} = |X_i - X_j|_{(\infty)}$ 表示相点距离; 若 $x < 0$, 则 $\theta(x) = 0$; 若 $x \geq 0$, 则 $\theta(x) = 1$ 。

定义时间序列的检验统计量为

$$S_1(m, N, r, \tau) = C(m, N, r, \tau) - C_m(1, N, r, \tau) \quad (6)$$

对 $S_1(m, N, r, \tau)$ 采用分块平均的策略, 即有 $S_2(m, N, r, \tau)$ 。当 N 足够大时, 存在反映时间序列自相关特性的函数 $S_2(m, N, r, \tau)$; 由选取的最大和最小半径 r 定义差量 $\Delta S_2(m, \tau)$ 。由此可通过以上定义量计算出统计量: $\bar{S}_2(t), \Delta \bar{S}_2(t)$; 综合考虑定义指标

$$S_{2\text{cor}}(t) = \Delta \bar{S}_2(t) + |\bar{S}_2(t)| \quad (7)$$

将 $\Delta \bar{S}_2(t)$ 的第一个局部极小值点定义为最优时延 τ ; 将 $S_{2\text{cor}}(t)$ 的全局最小值点定义为嵌入窗 τ_w 。

轨道板温度梯度时间序列相空间重构步骤如下:

1) 计算时间序列的平均周期。轨道板温度梯度时间序列的平均周期可以通过快速傅里叶变换 FFT 将时间序列由时域变换到频域, 并根据变换后序列的频率信息计算其平均周期 τ_p 。本文选用功率对周期加权求加权平均的方法计算平均周期^[6]

$$\tau_p = \frac{\sum_{n=1}^N \frac{F^2(n)}{f_n}}{\sum_{n=2}^N F^2(n)} \quad (8)$$

$$f_n = 2\pi \frac{n-1}{N}, n=1, 2, \dots, N \quad (9)$$

其中: $F(n)$ 为温度梯度时间序列 FFT 变换; f_n 为变换中所用到的频率。所以, 轨道板非线性温度梯度时间序列的平均周期为 49.65 min。

2) 基于 C-C 方法: 同时估计温度梯度的最优时延 τ 和嵌入维数 m 。将温度梯度时间序列作为定义的一维时间序列输入。结果如图 2。




图 2 CRTSII 型轨道板温度梯度时间序列的 C-C 曲线

Fig.2 C-C curve of temperature gradient time series for CRTSII track slab

3) 根据 C-C 方法原理, 可得 CRTSII 型轨道板温度梯度时间序列的最优时延 τ 和时间序列的嵌入窗 τ_w 。又 KUGIUMTZIS D 提出: 当 $\tau_w \geq \tau_p$ 时, 最优时延 τ 与嵌入维数 m 之间满足

$$\tau_w = (m-1)\tau \quad (10)$$

通过计算可知, 时间序列的嵌入窗 $\tau_w=132$ 大于其自身平均周期 $\tau_p=49.5$, CRTSII 型轨道板温度梯度时间序列的最佳时延 $\tau=11$, 最佳嵌入维数 $m=13$, 最佳嵌入窗 $\tau_w=132$ 。

3 基于 NARX 动态神经网络的温度梯度预测

由于非线性时间序列在内部具有确定的规律性, 它表现出时间序列在时间延迟状态空间中的相关性, 这种特性使得系统似乎有着某种记忆性, 同时又难于用通常的解析方法把这种规律表达出来, 而经过最优相空间重构后的温度梯度时间序列就可以将其内部蕴含的信息充分地显露出来。再结合 NARX 动态神经网络, 即有反馈记忆型神经网络, 来对非线性时间序列进行有效的短期预测。

3.1 NARX 动态神经网络的时间序列短期预测步骤

本文针对相空间重构后的 CRTSII 型轨道板温度梯度时间序列进行了 NARX 动态神经网络预测分析。预测步骤如下:

1) 由 2.2 节, 可知对 CRTSII 型板温度梯度时间序列进行相空间重构的合理参数, 即最优时延 τ 和嵌入维 m 。根据 Takens 定理, 我们将轨道板温度梯度时间序列进行相空间重构, 得到一个 m 维的状态向量

$$X(i) = \{x(i), x(i+\tau), x(i+2\tau), \dots, x[i+(m-1)\tau]\} \quad (11)$$

在重构得到的相空间中, 存在着光滑的非线性映射 $f: R_m \rightarrow R_1$, 即

$$x(i+\tau) = f[x(i)] \quad (12)$$

2) NARX 神经网络结构设计。输入层: 将训练的时间序列数据进行相空间重构, 相点 $X(i)$ 作为输入, 即输入的是一个向量, 是由 m 嵌入维个采集数据组成。 $m=13$ 即为模型的输入层神经元个数。

输出层: 输出结果为一个指标, 所以取输出神经元个数为 1。

隐含层: 本文选用单隐含层, 采用经验公式 $s = \sqrt{n+m} + a$ 来确定隐含层神经元的个数 s 。其中: n 为输出层神经元个数; m 为输入层神经元个数; a 为 1~10 之间的常数。所以本文设隐含层神经元个数 $s=10$ 。

反馈线: 将过去的 d 个时延输出值反馈给输入层, 即当前输出值

$$y(i) = f[x(t-1), \dots, x(t-d), y(t-1), \dots, y(t-d)] \quad (13)$$

其中, d 为相空间重构最优时间延迟 $\tau=11$ 。

3) 建立 NARX 神经网络。利用 Matlab 中的神经网络工具箱, 可以直接在 Matlab 中调用相关函数和参数设置来实现 NARX 神经网络模型的学习、训练、预测仿真过程。

4) 输入训练数据和目标数据训练神经网络。

5) 输入已有数据预测目标时间内数据。

基于以上步骤, 实现 CRTSII 型轨道板温度梯度时间序列的 NARX 动态神经网络的预测模型设计。

3.2 预测数据参数的选取及模型训练

本文选取 CRTSII 型轨道板温度梯度数据 (2016-08-01T00:00/2016-11-17T07:30) 构成时间序列 $\{x(i)\}$, $t=1, 2, \dots, n, n=5\ 200$ 。利用 3.2 节所求的时间延迟和嵌入维对该时间序列的前 5 000 个数据 (2016-08-01T00:00/2016-11-13T03:30) 和后 200 个数据 (2016-11-13T04:00/2016-11-17T07:30) 分别进行重构。从而得到 NARX 神经网络模型所用的输入训练相空间 $X(i), i=1, 2, \dots, 4\ 868$ 和输入预测相空间 $Y(j), j=1, 2, \dots, 69$ 。

根据重构后的相空间性质, 选取时间序列 $\{x(t)\}, t=144, 145, \dots, 5\ 011$, (2016-08-03T23:30/2016-11-13T09:30) 为训练输出目标数据, 设 $x(i+m \cdot \tau)$ 为训练输出预测数据; 选取时间序列 $\{x(t)\}, t=5\ 143, 5\ 144$,

..., 5 211 (2016-11-16T03:30/2016-11-17T13:00) 为预测输出目标数据, 设为 $y(j+m \cdot \tau)$ 为输出预测数据。其中, 目标时间 2016-11-16T03:30/2016-11-17T07:30 中的数据为已知数据; 2016-11-17T08:00/2016-11-17T13:00 中的数据为待预测数据, 即预测值个数为 $\tau=11$ 。

对于未来时间

$$T=30\gamma \cdot \tau, (\text{min}), \gamma=1, 2, 3, \dots \tag{14}$$

若 $\gamma=2$ 进行预测, 则将以

$$Y(j+\tau)=[y(j+\tau), y(j+2\tau), \dots, y(j+m \cdot \tau)], j=1, 2, \dots, 69 \tag{15}$$

作为输入相空间, 将其输入到原训练好的 NARX 神经网络模型中, 得到预测输出 $y[j+(m+1)\tau]$, 该预测输出的后 11 个数据将作为预测结果, 所以可得到未来时间 $30 \text{ min} \times 2 \times 11=660 \text{ min}$ 内的 22 个待预测值。以此递推, 根据 γ 的适当取值即可得到未来短期时间 T 内的待预测值。篇幅限制, 本文只针对 2016-11-17T08:00/2016-11-17T13:00 时间内的 CRTSII 型轨道板温度梯度数值进行了预测。学习后的 NARX 神经网络模型性能如图 3 和表 1 所示。




表 1 NARX 动态神经网络学习阶段的预测性能
Tab.1 Prediction performance of NARX dynamic neural network learning stage

学习阶段	均方差	相关系数
训练	3.71853e-0	9.94958e-1
验证	10.61021e-0	9.84203e-1
测试	14.35190e-0	9.79085e-1

图 3 NARX 动态神经网络学习各阶段性能曲线

Fig.3 NARX dynamic neural network learning the performance curve at each stage

均方差 MSE 越小代表训练输出结果与目标数据误差越小; 输出结果与目标数据的相关系数 R 越接近 1。由表 1 可得在 NARX 动态神经网络学习的 3 个阶段中均方差和相关系数均基本满足预测要求。该训练后的神经网络可以用于预测未来短期内 CRTSII 型轨道板温度梯度数据走势。通过 NARX 动态神经网络对输入数据和目标数据学习得到输出结果与目标数据的对比以及误差如图 4、误差自相关如图 5 所示。




图 4 NARX 动态神经网络学习后温度梯度输出数据与目标数据对比及其误差

Fig.4 Comparison and error of temperature gradient output data and target data after learning from NARX dynamic neural network

表 2 CRTSII 型轨道板温度梯度的预测性能

Tab.2 Prediction performance of temperature gradient for CRTSII track slab

评价指标	预测结果
均方差	2.026 91e-0
相关系数	9.813 44e-1

3.3 预测结果及分析

将 CRTSII 型轨道板温度梯度时间序列作为基础数据,预测未来短期时间内的温度梯度数据发展。预测方法如 3.2 节所述。本文只针对将 2016-11-17T08:00/2016-11-17T13:00 时间内的 CRTSII 型轨道板温度梯度数值设为待预测值,预测结果及误差如图 6 虚线右侧部分所示。虚线左边为所设已知温度梯度数值,预测结果与真实值对比如表 3 所示。误差自相关图和预测结果性能分别如图 7 和表 2 所示。




图 6 温度梯度预测输出数据与待预测数据对比及其误差图

Fig.6 Comparison of temperature gradient prediction output data with the waiting for prediction data and the error map

通过预测值与真实值的绝对和相对误差分析,可知 CRTSII 型轨道板温度梯度时间序列的预测结果存在较小偏差,只有极个别的预测结果略显偏大,但都在可接受的范围内。总体结合表 4 所示的均方差 MSE 和相关系数 R 可知,预测结果较为可靠。基本能够满足对未来时间 $T=30\gamma \cdot \tau, (\text{min}) \gamma=1, 2, 3, \dots$, 内的预测需求和工程实际需要。

4 结论

CRTSII 型轨道板温度梯度作为轨道板病害发生的重要指标之一。本文在应用 C-C 方法对温度梯度时间序列进行了最优相空间重构的基础上,引入 NARX 动态神经网络,对 CRTSII 型轨道板的非线性温度梯度时间序列进行未来短期预测,且将预测结果与真实值对比。结果表明:

- 1) CRTSII 型轨道板的非线性温度梯度时间序列存在最优相空间。且其最优时延 $\tau=11$, 最优嵌入窗 $\tau_m=133$, 最优嵌入维数 $m=13$;




图 5 NARX 动态神经网络学习后温度梯度输出数据与目标数据误差自相关图像

Fig.5 Autocorrelation between temperature gradient output data and target data after learning from NARX dynamic neural network




图 7 温度梯度预测输出数据与待预测数据的误差自相关图

Fig.7 The error autocorrelation of temperature gradient prediction output data and the waiting for prediction data

表3 CRTSII型轨道板温度梯度部分预测结果与真实值对比
Tab.3 Comparison of predicted temperature gradients and real values for CRTSII track slab

时间	2016-11-17T08:00	2016-11-17T08:30	2016-11-17T09:00	2016-11-17T09:30	2016-11-17T10:00	2016-11-17T10:30	℃/m
预测值	-8.96	-12.97	-9.01	-10.65	-10.07	-7.80	
真实值	-9.77	-9.77	-9.62	-9.54	-8.62	-9.00	
绝对误差	0.81	3.20	0.61	2.11	1.45	2.11	
相对误差	0.083	0.327	0.063	0.116	0.168	0.133	
时间	2016-11-17T11:00	2016-11-17T11:30	2016-11-17T12:00	2016-11-17T12:30	2016-11-17T13:00	...	
预测值	-8.73	-7.67	-6.93	-5.90	-5.16	...	
真实值	-8.38	-7.69	-7.69	-5.92	-6.08	...	
绝对误差	0.35	0.02	0.76	0.02	0.92	...	
相对误差	0.042	0.003	0.099	0.003	0.151	...	

2) 对基于相空间重构后的 CRTSII 型轨道板温度梯度时间序列进行 NARX 动态神经网络预测的结果与真实值基本吻合,可以满足实际生产及其研究的需求。

通过本文的研究,有效的预测 CRTSII 型轨道板温度梯度在短期内的发展趋势及其数值,并寻找到了—种基于对轨道板非线性时间序列进行最优相空间重构后(扩展序列维数)的 NARX 动态神经网络的预测方法。为 CRTSII 型轨道板的病害预警及其提前维护提供参考。另外,此方法也存在一定的缺点,即最优时延 τ ,嵌入维数 m 和神经网络的隐含层 s 的参数大小对预测结果的影响较大。适当的参数是准确预测非线性温度梯度的保障。

参考文献:

- [1] 钟垚,何越磊,路宏遥,等.持续高温作用下 CRTS II 型无砟轨道层间离缝分析[J].铁道科学与工程学报,2018,15(5):1128-1133.
- [2] 刘钰,赵国堂. CRTS II 型板式无砟轨道结构层间早期离缝研究[J].中国铁道科学,2013,34(4):1-7.
- [3] 李威,刘学毅,肖杰灵,等.高温环境下列车荷载对 CRTS II 型板式轨道宽窄接缝损伤行为的影响[J].铁道标准设计,2018,62(7):32-36.
- [4] 李伟.基于有限-无限元法的 CRTS III 板式无砟轨道系统动力参数敏感度分析[J].华东交通大学学报,2017,34(3):27-33.
- [5] 王继军,尤瑞林,王梦,等.单元板式无砟轨道结构轨道板温度翘曲变形研究[J].中国铁道科学,2010,31(3):9-14.
- [6] 欧祖敏,孙璐.高速铁路无砟轨道板非线性温度效应简化计算方法[J].铁道学报,2015,37(6):79-87.
- [7] 闫斌,戴公连,苏海霆.基于气象参数的轨道板竖向温度梯度预测模型[J].华南理工大学学报(自然科学版),2014,42(12):9-13.
- [8] 郭超,陆征然,吕菲,等.严寒地区 CRTS II 型无砟轨道板温度特性研究[J].铁道工程学报,2016,33(9):29-34.
- [9] 吴斌,刘参,曾志平,等. CRTS II 型板式无砟轨道温度场特征研究[J].铁道工程学报,2016,33(3):29-33.
- [10] 黄志斌.桥上 CRTS II 型板式轨道结构竖向温度场预估模型[J].铁道科学与工程学报,2017,14(5):899-906.
- [11] 汪运.基于相空间重构理论和误差矫正模型的组合风速预测模型的研究与应用[D].兰州:兰州大学,2015.
- [12] KANTZ H, SCHREIBER T. Nonlinear time series analysis[M]. Cambridge: Cambridge University Press, 2000.
- [13] 宋春云,丁士圻,雷亚辉.基于相空间重构理论的水中混响特性提取[J].哈尔滨工程大学学报,2007(5):515-518.

- [14] 刘式达,刘式适. 物理学中的分形[M].北京:北京大学出版社,2014:20-21.
- [15] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamics, delay times, and embedding windows[J]. *Physica D*, 1999(127): 48-60.
- [16] 龚祝平. 混沌时间序列的平均周期计算方法[J]. *系统工程*, 2010,28(12):111-113.

Prediction and Analysis on Temperature Gradient of CRTSII Track Slab Based on Phase Space Reconstruction

Shen Jiankang, He Yuelei, Li Zaiwei, Lu Hongyao

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

Abstract: To study and predict the variation on the nonlinear temperature gradient of CRTSII track slab with time, for achieving early warning and reducing the occurrence of track slab diseases, this paper adopted the C-C method to reconstruct the optimal phase space of nonlinear temperature gradient time series of CRTSII track slab. On the basis of phase space reconstruction, NARX dynamic neural network with feedback and memory function was applied to predict and analyze the nonlinear temperature gradient time series. The results showed that according to the optimal phase space reconstruction of the temperature gradient time series of CRTSII track slab, the NARX dynamic neural network method was used to predict the temperature gradient inside the CRTSII track slab in the future time $T=30 \gamma * \tau, (\text{min}), \gamma=1, 2, 3, \dots, T=30 \gamma * \tau, (\text{min}), \gamma=1, 2, 3, \dots$. The temperature gradient prediction results of 11 sampling time nodes from 2016/11/17/8:00 to 2016/11/17/13:00 ($\gamma=1$) showed that the part of the predicted values was in good agreement with the real values. The study provides certain scientific and practical values in the prediction of CRTSII track slab nonlinear time series system.

Key words: track slab; time series; temperature gradient; phase space reconstruction; NARX dynamic neural network