

DOI:10.3969/j.issn.1003-5060.2023.06.011

基于 GM-RBF 不定权组合模型的输电线塔杆 倾斜预测分析与应用

王洪武¹, 李俊鹏¹, 张继伟¹, 黄然², 朱宇³, 宋宝⁴

(1. 云南电网有限责任公司 输电分公司, 云南 昆明 650033; 2. 云南电网有限责任公司 电力科学研究院, 云南 昆明 650217; 3. 北京空间飞行器总体设计部, 北京 100094; 4. 安徽理工大学 空间信息与测绘工程学院, 安徽 淮南 232001)

摘要:为了解决目前输电线塔杆倾斜姿态监测中出现的预测不准确、不及时和预测误报率高等问题,文章提出一种基于灰色模型-径向基函数(grey model-radial basis function, GM-RBF)不定权组合模型的输电线塔杆倾斜姿态预测方法,对昆明市某地区一处输电塔杆200 d的北斗逆向网络载波相位差分技术(real-time kinematic, RTK)数据,使用 GM-RBF 不定权组合预测模型对铁塔姿态进行预测。该方法不仅能有效规避灰色模型(grey model, GM)自身误差大的缺点,减弱神经网络中训练样本随机性对建模精度的影响,还可以消除因最小二乘定权组合影响整体模型精度的问题。实验表明:对于短期塔杆倾斜预测,GM-RBF 不定权组合预测模型在 X、Y、P 向和倾斜角的预测精度与 GM 预测精度相当,优于径向基函数(radial basis function, RBF)神经网络模型和 GM-RBF 定权组合模型的精度;对于长期塔杆倾斜预测,GM-RBF 不定权组合模型在 X、Y、P 向和倾斜角的预测精度分别优于 GM 预测模型约 57.28%、48.07%、43.02%、42.08%,优于 RBF 预测模型约 2.04%、2.31%、3.60%、2.02%,优于 GM-RBF 最小二乘定权组合模型约 2.97%、2.36%、6.23%、4.73%。
关键词:北斗逆向网络载波相位差分技术(RTK)数据;输电线塔杆;倾斜姿态监测;GM-RBF 不定权组合模型
中图分类号: TM754 **文献标志码:** A **文章编号:** 1003-5060(2023)06-0788-07

Prediction analysis and application of transmission line tower inclination using GM-RBF uncertain weight combination model

WANG Hongwu¹, LI Junpeng¹, ZHANG Jiwei¹, HUANG Ran², ZHU Yu³, SONG Bao⁴

(1. Transmission Branch, Yunnan Power Grid Co., Ltd., Kunming 650033, China; 2. Electric Power Research Institute, Yunnan Power Grid Co., Ltd., Kunming 650217, China; 3. Beijing Institute of Spacecraft System Engineering, Beijing 100094, China; 4. School of Spatial Information and Geomatics Engineering, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: In order to solve the problems of inaccurate prediction, untimely prediction and high false alarm rate in the current inclination attitude monitoring of transmission line tower, this paper proposes a method of inclination attitude prediction of transmission line tower based on grey model-radial basis function(GM-RBF) uncertain weight combination model. For the 200 d real-time kinematic(RTK) data of BeiDou reverse network of a tower in a certain area of Kunming City, the attitude of the tower is predicted based on the GM-RBF uncertain weight combination prediction model. This method can not only effectively avoid the shortcomings of GM itself, and reduce the influence of the randomness of training samples in neural network on the modeling accuracy, but also eliminate the problem that the accuracy of the whole model is affected by the least-squares fixed weight combination. The results show that in the short-term inclination prediction of transmission tower, the accuracy of GM-RBF uncertain weight combination prediction model is about the same as that of GM prediction model in the prediction of X, Y and P directions and overall inclination angle of transmission tower, which is better

收稿日期:2021-09-08;修回日期:2021-10-29

基金项目:江苏省“六大人才高峰”高层次人才资助项目(XYDDX-045);西宁市科技资助项目(2019-Y-12)和无锡市科技发展资金资助项目(N20201011)

作者简介:王洪武(1972—),男,云南昆明人,云南电网有限责任公司高级工程师。

than those of RBF neural network prediction model and fixed weight combination prediction model based on least squares method; in the long-term inclination prediction of transmission tower, the accuracy of GM-RBF uncertain weight combination prediction model is about 57.28%, 48.07%, 43.02% and 42.08% better than that of GM prediction model in the prediction of X , Y and P directions and overall inclination angle of transmission tower, respectively. It is about 2.04%, 2.31%, 3.60% and 2.02% better than that of RBF prediction model and about 2.97%, 2.36%, 6.23% and 4.73% better than that of fixed weight combination prediction model based on least squares method, respectively.

Key words: BeiDou reverse network real-time kinematic(RTK) differential data; transmission line tower; inclination attitude monitoring; grey model-radial basis function(GM-RBF) uncertain weight combination model

输电线路塔杆是输电线路与地面搭接的构筑物,是电力系统的重要组成部分,其安全状态是影响电力系统运行的重要因素。输电线塔杆易因自然环境条件或人为破坏等因素发生沉降、倾斜,危及人们的生命财产安全,造成电力故障^[1-3]。国内外诸多学者针对输电线塔杆倾斜姿态问题进行了一系列研究,文献[4-7]提出采用力学分析方法研究风对塔杆的影响,分析塔杆在风作用下的动态特性和稳定性状态;文献[8-11]提出利用各类传感器对塔杆的异常情况进行监测。但是缺少对塔杆的结构进行异常监测的方法和模型,而且只能间接反映塔体发生较大变形时的应力,不能及时发现负荷平衡参数、隐蔽故障(如塔体微小形变)或局部构件的屈服失效。因此,建立一个输电线塔杆倾斜姿态预测模型,快速及时地获取塔杆的倾斜情况,并准确获得相关塔杆的具体位置成为电力系统亟待解决的问题。使用北斗高精度定位数据,构建铁塔预测模型及时准确地实时监测塔杆的倾斜姿态变化情况,来解决上述存在的问题十分必要。

本文使用北斗逆向网络载波相位差分技术(real-time kinematic, RTK)数据,基于不定权的灰色模型-径向基函数(grey model-radial basis function, GM-RBF)神经网络加权组合预测模型对铁塔姿态进行预测,不但避免了灰色模型(grey model, GM)预测方法存在的理论误差,提高了神经网络的训练速度和预测精度,更加减弱了定权加权组合模型对铁塔的倾斜姿态整体预测精度的影响。有利于精确地对电力铁塔倾斜进行全天候监控、预警,以满足电力信息化支撑功能的需求,保障输电线路的安全运行。

1 GM-RBF 组合模型

1.1 GM 模型

常见的灰度预测模型有 GM(1, 1)、GM(2,

1)、DGM 和 Verhulst 模型^[12]。其中,GM(1, 1)模型是一阶微分方程,只含有 1 个变量的灰色模型,适用于有较强指数规律的序列;另外 3 个预测模型适用于预测具有饱和的 S 形序列或者单调的摆动发展序列缺陷。

本文预测中选择 GM(1, 1)模型,下面就 GM(1, 1)原理进行介绍^[13-14]。设原始数据序列(也称为参考序列)为 $X^{(0)} = \{X_{(1)}^{(0)}, X_{(2)}^{(0)}, X_{(3)}^{(0)}, \dots\}$,对原始序列进行一次累加生成 $X^{(1)}$ 序列,即

$$X^{(1)} = \{X_{(1)}^{(1)}, X_{(2)}^{(1)}, X_{(3)}^{(1)}, \dots\} \quad (1)$$

其中, $X_{(k)}^{(1)} = \sum_{i=0}^k X_{(i)}^{(0)}$ 。

根据灰度理论,建立 $X_{(k)}^{(1)}$ 关于时间 t 的连续可微函数,且满足一阶微分方程:

$$\frac{dX^{(1)}}{dt} + aX^{(1)} = b \quad (2)$$

其中: a 为预测系统的发展系数; b 为灰度作用量。

因此,可得到 GM(1, 1)的时间响应函数为:

$$\hat{X}_{(t)}^{(1)} = \left(X_{(1)}^{(1)} - \frac{b}{a} \right) e^{-at} + \frac{b}{a} \quad (3)$$

最后通过累减得到预测值为:

$$\hat{X}_{(k+1)}^{(0)} = \hat{X}_{(k+1)}^{(1)} - \hat{X}_{(k)}^{(1)} \quad (4)$$

1.2 径向基函数神经网络

径向基函数(radial basis function, RBF)神经网络是一种具有单隐层的 3 层前馈网络的神经网络,其网络结构如图 1 所示。

RBF 神经网络是一种性能良好的前向网络,其激励函数一般是高斯函数。具有最佳逼近、训练简洁、学习收敛速度快以及克服局部最小值问题的性能,目前已经证明 RBF 神经网络能够以任意精度逼近任意连续的函数,且具有全局逼近能力,从根本上解决了 BP(back propagation)神经网络的局部最优问题,而且拓扑结构紧凑,结构参数可实现分离学习,收敛速度快。因此已经被广泛应用于模式识别、非线性控制和图像处理等

领域^[15]。




图1 RBF网络结构

设原始变形监测数据序列为 $X^{(0)} = \{X_{(t_1)}^{(0)}, X_{(t_2)}^{(0)}, X_{(t_3)}^{(0)}, \dots\}$, $t = \{t_1, t_2, t_3, \dots\}$ 。

使用RBF神经网络方法,建立如下网络:

$$\text{net} = \text{newrb}(t, x^{(0)}, \text{goal}, \text{spread}) \quad (5)$$

然而,通常采集的监测物的变形数据序列为非等间距的。若要处理该类数据,需利用RBF神经网络的方法对数据进行插值,使之成为等间距数

据序列。设插值后的变形监测数据序列为 $T^{(1)} = \{T_{(t_1)}^{(1)}, T_{(t_2)}^{(1)}, T_{(t_3)}^{(1)}, \dots\}$, 则利用神经网络训练得到的变形监测数据序列为:

$$X_1^{(0)} = \text{sim}(\text{net}, T^{(1)}) \quad (6)$$

1.3 GM-RBF 加权组合模型

GM预测模型对于非线性问题的求解精度和长期预测精度等方面存在不足,RBF神经网络预测模型具有收敛速度偏慢和数据利用率低等缺点,因此本文对2种预测模型进行优化组合,综合2种模型的优势提出一种GM-RBF组合预测模型。

实际中,由于输电塔杆变形呈非线性、不稳定性 and 随机性变化,使得各个单一模型对各期的预测结果都有所不同,而权值的比重直接影响组合模型的预测精度。因此本文探讨了2种不同的加权组合模型,结构框架如图2所示。

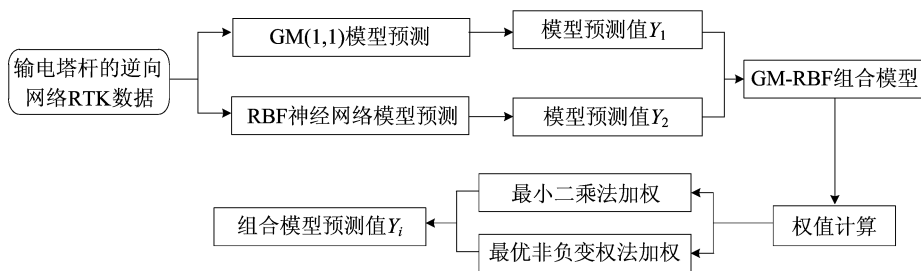


图2 GM-RBF加权组合模型数据流程图

1.3.1 GM-RBF 最小二乘法定权组合模型

首先针对原始的变形监测数据序列分别进行GM预测模型和RBF神经网络预测模型建模;然后通过精度评定分析其预测精度是否合格,若精度不合格则重新对原始数据进行建模,反之则进行下一步对2个模型进行优化组合;最后利用构建的组合模型生成出最终变形预测值。在最小二乘加权组合中,利用最小二乘的方法来确定每个模型的预测权重,具体过程如下:设GM预测模型的变形数据预测值序列为 $GM_i = \{GM_1, GM_2, GM_3, \dots\}$, RBF神经网络预测模型的变形数据预测值序列为 $RBF_i = \{RBF_1, RBF_2, RBF_3, \dots\}$, $i = 1, 2, 3, \dots, n$ 。由此可以得到预测值与实测值之间的残差 v 为:

$$v_i = aGM_i + bRBF_i - \hat{P}_i, \quad i = 1, 2, 3, \dots, n \quad (7)$$

其中: a, b 分别为GM预测模型和RBF神经网络预测模型的预测权重; \hat{P}_i 为*i*时刻的观测值。可得:

$$\sum_{i=1}^n v_i^2 = \sum_{i=1}^n (aGM_i + bRBF_i - \hat{P}_i)^2 = \min \quad (8)$$

也可改写成:

$$\mathbf{V}^T \mathbf{V} = \min \quad (9)$$

此外,可以将(7)式写成:

$$\mathbf{V} = \mathbf{B}\mathbf{X} - \mathbf{L} \quad (10)$$

其中

$$\mathbf{V} = [v_1 \quad v_2 \quad v_3 \quad \dots \quad v_n]^T;$$

$$\mathbf{B} = \begin{bmatrix} GM_1 & GM_2 & GM_3 & \dots & GM_n \\ RBF_1 & RBF_2 & RBF_3 & \dots & RBF_n \end{bmatrix}^T;$$

$$\mathbf{X} = \begin{bmatrix} a \\ b \end{bmatrix}; \quad \mathbf{L} = [\hat{P}_1 \quad \hat{P}_2 \quad \hat{P}_3 \quad \dots \quad \hat{P}_n]^T。$$

根据(9)式可解算位置参量 \mathbf{X} 为:

$$\mathbf{X} = (\mathbf{B}^T \mathbf{P} \mathbf{B})^{-1} \mathbf{B}^T \mathbf{P} \mathbf{L} \quad (11)$$

其中, \mathbf{P} 为观测值权阵,为 $n \times n$ 的单位矩阵。

1.3.2 GM-RBF 不定权组合预测模型

相较于单一的预测模型,GM-RBF不定权组合预测模型与GM-RBF最小二乘法定权组合预测模型一样,均综合了各个预测模型的优点,从而达到优化预测结果的目的。然而,对于GM-RBF最小二乘法定权组合模型而言,模型中确定的权值 a 、

b 是恒定不变的,由此得到的预测值不能很好地反映输电塔杆的变形状况。因此,GM-RBF 不变权组合预测模型可以很好地消除这一弊端,其获取的权值是变动的。具体过程如下。

设输电塔杆的实际变形值为 Y_t , GM 与 RBF 预测模型得到的预测值记为 $Y_{t,m}$ 。其中: m 为预测模型类别, $m=1$ 代表 GM 预测模型, $m=2$ 代表 RBF 预测模型; t 为预测时期, $t=1, 2, \dots, n$ 。可得:

$$\hat{Y}_t = \sum_{i=1}^2 W_{t,m} Y_{t,m} \quad (12)$$

其中: \hat{Y}_t 为输电塔杆组合预测模型在第 t 时期的预测值; $W_{t,m}$ 为第 i 种预测模型在第 t 时期的加权系数。 $W_{t,m}$ 满足:

$$\begin{cases} \sum_{i=1}^2 W_{t,m} = 1, \\ W_{t,m} \geq 0 \end{cases} \quad (13)$$

其中: $m=1, 2; t=1, 2, \dots, n$ 。

设 $e_{t,m}$ 、 e_t 分别为 m 模型与组合模型在第 t 时期的输电塔杆预测误差,则有:

$$e_t = Y_t - \hat{Y}_t = \sum_{i=1}^2 W_{t,m} e_{t,m} = [W_{t,1} \quad W_{t,2}] [e_{t,1} \quad e_{t,2}]^T \quad (14)$$

可以得出:

$$e_t^2 = [W_{t,1} \quad W_{t,2}] [e_{t,1} \quad e_{t,2}]^T [e_{t,1} \quad e_{t,2}] [W_{t,1} \quad W_{t,2}]^T = \mathbf{W}_t^T \mathbf{E}_t \mathbf{W}_t \quad (15)$$

其中

$$\begin{aligned} \mathbf{W}_t &= [W_{t,1} \quad W_{t,2}]^T; \\ \mathbf{E}_t &= [e_{t,1} \quad e_{t,2}]^T [e_{t,1} \quad e_{t,2}] = \begin{bmatrix} e_{t,1} e_{t,1} & e_{t,1} e_{t,2} \\ e_{t,2} e_{t,1} & e_{t,2} e_{t,2} \end{bmatrix} \end{aligned} \quad (16)$$

由此可确定最优变权系数的规划模型,即

$$\min f = \mathbf{W}^T \mathbf{R} \mathbf{W} \quad (17)$$

$$\text{s. t. } \begin{cases} \mathbf{W}^T \mathbf{R}_n = 1; \\ W_{t,m} \geq 0, \quad t = 1, 2, \dots, n \end{cases} \quad (18)$$

其中, $\mathbf{R}_n = [1 \quad \dots \quad 1]^T$ 。

2 输电塔杆倾斜测量模型

根据塔杆结构,可将塔杆的倾角、塔高与面位移之间的关系进行简化,模型如图3所示。

根据图3塔杆的参数关系,可以得到塔杆面形变量 ΔP 的计算公式为:

$$\Delta P = \sqrt{\Delta X^2 + \Delta Y^2} \quad (19)$$

其中: ΔX 为 X 方向的形变量; ΔY 为 Y 方向上的形变量。计算公式为:

$$\begin{cases} \Delta X = X_i - X_0, \\ \Delta Y = Y_i - Y_0 \end{cases} \quad (20)$$

其中: (X_i, Y_i) 为当前测量点坐标; (X_0, Y_0) 为初始测量点坐标。

由图3可知倾角 θ 的计算公式为:

$$\theta = \arcsin(\Delta P/H) \quad (21)$$

其中, H 为当前塔杆高度。




图3 塔杆倾角、高度与面位移的关系模型

3 实验与讨论

3.1 样本数据与预测效果分析

为验证优化 GM-RBF 不定权组合预测模型的预测精度及其有效性,以及更好地评价模型确切的精度指标,本文以昆明市某地区一处输电塔杆 2020 年 12 月 1 日至 2021 年 5 月 2 日的北斗逆向网络 RTK 数据为例,该监测点的监测数据共有 200 期,分别采用 GM 预测模型、RBF 神经网络预测模型、GM-RBF 最小二乘定权组合预测模型和 GM-RBF 不定权组合预测模型对铁塔监测数据的前 100 期数据建模,在模型建立成功后,利用已建立的模型预测后 100 期的变形量,然后将预测值与实测值进行比较,计算模型的残差,检验模型的精度。

铁塔的部分监测数据见表1所列。

表1中,观测日期为2020年12月1日至2020年12月10日。GM预测模型、RBF神经网络预测模型和2种加权GM-RBF组合模型预测值与实测值比较如图4所示。从图4可以看出,在预测的100期的数据中,在 X 、 Y 、 P 方向和塔杆倾斜角预测值在约为20期处发生转折变化。其中,前2期GM预测模型精度和GM-RBF不定

权组合预测模型精度相当,均优于 RBF 神经网络预测模型和 GM-RBF 最小二乘定权组合模型,其中在 X 方向上的效果最为明显;后 80 期的预测中,GM 预测模型、RBF 神经网络预测模型和 GM-RBF 最小二乘定权组合预测模型的预测值偏于实测值,GM 预测模型的预测值与实测值偏离较大,RBF 神经网络预测模型和 GM-RBF 最小二乘定权组合预测模型预测效果优于 GM 预测模型。整体从 100 期的预测效果看,GM-RBF 不定权组合预测模型明显优于 GM 预测模型、RBF 神经网络预测模型和 GM-RBF 最小二乘定权组合预测模型。

表 1 铁塔前 100 期在不同方向上的形变量及倾斜角

观测日期	X 方向形变量 $\Delta X/m$	Y 方向形变量 $\Delta Y/m$	P 方向形变量 $\Delta P/m$	倾斜角 $\Delta S/(\text{°})$
12-01	-0.001 2	0.001 3	0.001 7	3.032 4
12-02	-0.001 9	-0.000 1	0.001 9	3.261 1
12-03	-0.001 0	0.002 8	0.002 9	5.096 1
12-04	-0.001 1	0.002 7	0.002 9	4.997 1
12-05	0.000 5	0.002 8	0.002 8	4.875 1
12-06	0.000 6	0.003 3	0.003 3	5.749 0
12-07	0.000 5	0.002 9	0.002 9	5.044 0
12-08	0.000 5	0.002 0	0.002 0	3.533 5
12-09	0.000 5	0.002 0	0.002 0	3.533 5
12-10	-0.000 5	0.000 8	0.000 9	1.617 0

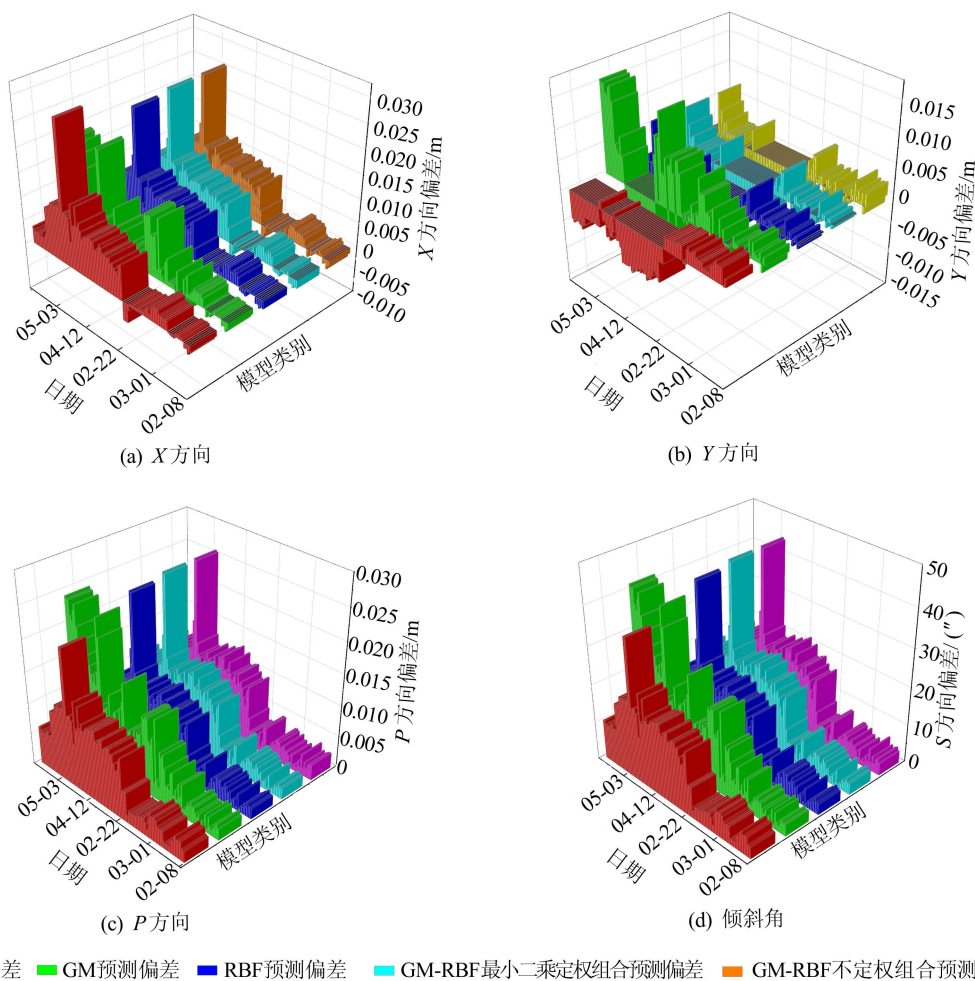


图 4 4 种模型预测值与实测值比较

3.2 预测精度分析与评价

为了量化地对比分析 4 种模型的预测精度,定义如下 2 个误差指标。

均方根误差计算公式为:

$$E_{\text{均}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - \hat{P}_i)^2} \quad (22)$$

平均绝对偏差计算公式为:

$$E_{\text{平}} = \frac{1}{n} \sum_{i=1}^n |P_i - \hat{P}_i| \quad (23)$$

根据(22)式、(23)式计算 4 种模型残差的均方根误差和平均绝对偏差,如图 5 所示,见表 2 所列。图 5 中日期为 2021 年。前 20 期对于输电塔杆的各项参数预测中,GM-RBF 不定权组合预测模型和 GM 预测模型在 X、Y、P 方向和塔杆的倾

斜角预测上的均方根误差相差幅度不大,精度表征效果相当。然而,在 X、Y、P 方向和塔杆的倾斜角预测上的它们的均方根误差优于 RBF 神经

网络预测模型分别为 22.92%、10.87%、1.14%、0.36%;优于 GM-RBF 最小二乘定权组合预测模型结果为 23.46%、11.79%、0.58%、0.28%。

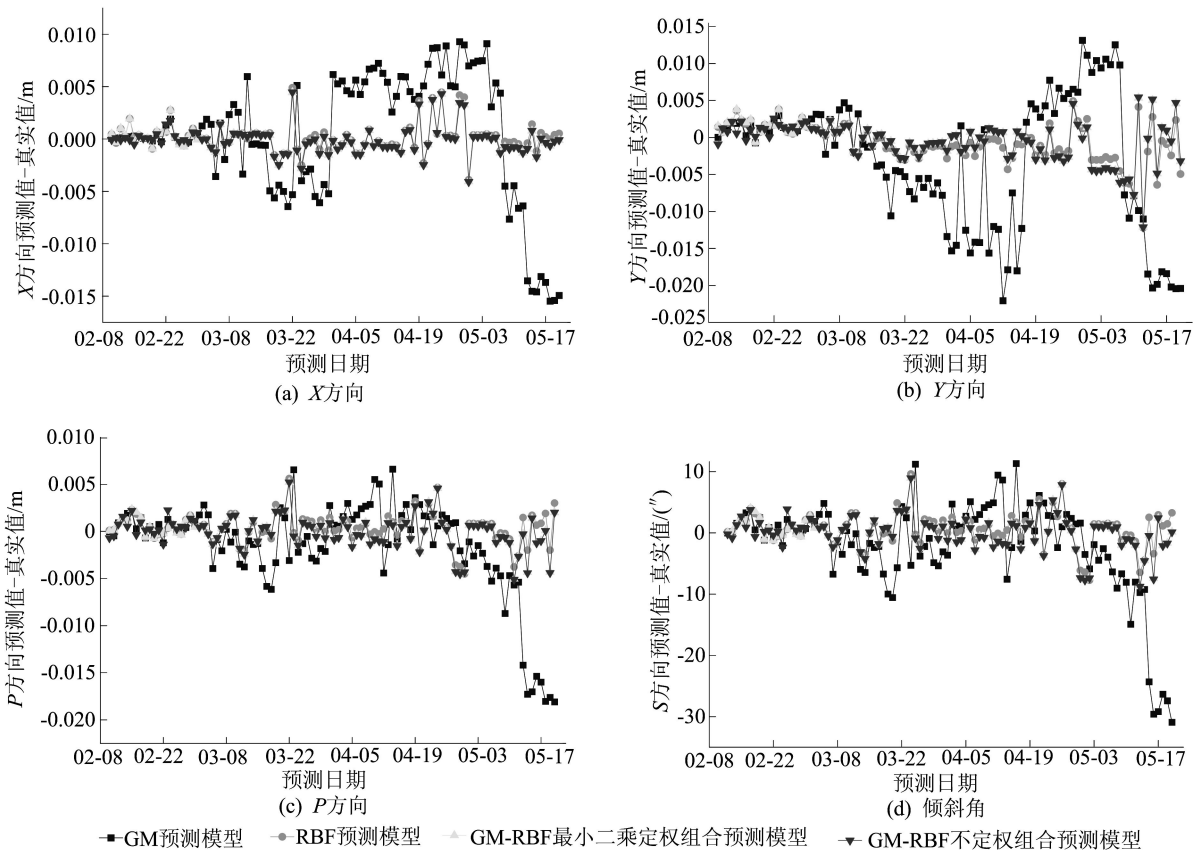


图 5 4 种模型预测值与实测值偏差

表 2 4 种预测模型在 X、Y、P 方向与倾斜角预测精度比较

模型	预测期	X/mm		Y/mm		P/mm		S/(°)	
		$E_{\text{平}}$	$E_{\text{均}}$	$E_{\text{平}}$	$E_{\text{均}}$	$E_{\text{平}}$	$E_{\text{均}}$	$E_{\text{平}}$	$E_{\text{均}}$
GM	20	0.384 2	0.619 8	1.381 1	1.175 2	0.821 8	0.906 5	1.447 1	1.206 3
	100	4.801 5	2.191 2	7.344 3	2.710 0	3.427 5	1.851 4	5.868 7	2.422 5
RBF	20	0.646 8	0.804 2	1.738 8	1.318 6	0.840 8	0.917 0	1.457 5	1.207 3
	100	0.913 1	0.955 6	2.075 9	1.440 8	1.197 3	1.094 2	2.050 6	1.432 0
GM-RBF 最小二乘定权组合	20	0.655 9	0.809 9	1.775 3	1.332 4	0.831 5	0.911 9	1.455 3	1.206 3
	100	0.930 7	0.964 7	2.077 9	1.441 5	1.265 5	1.124 9	2.169 1	1.472 8
GM-RBF 不定权组合	20	0.383 4	0.619 2	1.258 8	1.122 0	0.823 5	0.907 5	1.361 6	1.166 9
	100	0.876 2	0.936 1	1.980 9	1.407 4	1.112 7	1.054 8	1.968 7	1.403 1

从 100 期对于输电塔杆的长周期各项参数预测中可以看出,GM-RBF 不定权组合预测模型精度最优,RBF 神经网络预测模型精度次之,GM-RBF 最小二乘定权组合预测模型精度较低,GM 预测模型最低。其中,GM-RBF 不定权组合预测模型在 X、Y、P 和倾斜角的预测精度分别优于 GM 预测模型约 57.28%、48.07%、43.02%、

42.08%,优于 RBF 神经网络预测模型约 2.04%、2.31%、3.60%、2.02%,优于 GM-RBF 最小二乘定权组合预测模型约 2.97%、2.36%、6.23%、4.73%。

此外,从横向对比看出,无论是短期还是长期的 4 种模型在 X、Y 方向的预测中,Y 方向的预测均方根误差要明显高于 X 方向的预测均方根误

差,造成这种现象的主要原因是 GM 预测模型和 RBF 神经网络预测模型的预测均取决于前期的监测数据,前期监测数据的稳定趋势决定预测值的稳定性。结合前 100 期的监测数据中, X 方向的监测值变化趋势较平稳,起伏不大,然而在 Y 方向的监测值起伏剧烈,趋势变化明显,无规律,因此,在后 100 期数据的预测中,体现出 Y 方向预测的均方根误差相对较大。

综上所述,在短周期输电塔杆的各项参数预测中,GM 预测模型和 GM-RBF 不定权组合预测模型的预测效果较好;在长周期输电塔杆的各项参数预测中,GM-RBF 不定权组合预测模型的预测精度最优。因此,GM-RBF 不定权组合预测模型得到输电塔杆倾斜姿态的预测结果最接近实测值。

4 结 论

本文通过对 GM 模型和 RBF 神经网络 2 种预测模型进行分析,提出了一种 GM-RBF 不定权组合预测模型。结合相关实例,得出如下结论:

(1) 在短期对于电力塔杆倾斜预测中,GM 预测模型的精度与 GM-RBF 不定权组合预测模型精度相当,优于 RBF 神经网络预测模型和 GM-RBF 最小二乘定权组合预测模型。其中,GM 预测模型与 GM-RBF 不定权组合预测模型在 X、Y、P 3 个方向和塔杆整体倾斜角的预测精度优于 RBF 预测模型约 22.92%、10.87%、1.14%、0.36%;优于 GM-RBF 最小二乘定权组合预测模型约 23.46%、11.79%、0.58%、0.28%。

(2) 在长期对于电力塔杆倾斜预测中,GM-RBF 不定权组合预测模型精度最优,RBF 神经网络预测模型精度次之,GM-RBF 最小二乘定权组合预测模型精度较低,GM 预测模型最低。其中,在 X、Y、P 3 个方向和塔杆整体倾斜角的预测精度上优于 GM 预测模型约 57.28%、48.07%、43.02%、42.08%;优于 RBF 神经网络预测模型约 2.04%、2.31%、3.60%、2.02%;优于 GM-RBF 最小二乘定权组合预测模型约 2.97%、2.36%、6.23%、4.73%。

总体上,在对输电塔杆的倾斜预测中,不论是

短期还是长期预测,GM-RBF 不定权组合预测模型预测值更接近实测值。因此,GM-RBF 不定权组合预测模型有着较高的预测精度,更有利于输电塔杆的倾斜姿态预测。

[参 考 文 献]

- [1] 王身丽,杜勇,孙继雄,等. 输电杆塔变形及倾斜检测研究现状[J]. 通信电源技术,2018(11):91-92.
- [2] 孟涛. 输电线路塔杆倾斜调整作业探讨[J]. 电工技术,2018(3):122-123.
- [3] 吴先强,江敬周,李安东,等. 分体式杆塔倾斜检测系统研制及应用[J]. 电子世界,2013(20):201.
- [4] ZHANG M, ZHAO G, WANG L, et al. Wind-induced coupling vibration effects of high-voltage transmission tower-line systems[J]. Shock Vib,2017(2017):1-34.
- [5] BATTISTA R C, RODRIGUES R S, PFEIL M S. Dynamic behavior and stability of transmission line towers under wind forces [J]. Wind Eng Ind Aerodyn, 2003 (91): 1051-1067.
- [6] 王璋奇,王剑,黄增浩,等. 格构式输电铁塔的应变模态分析[J]. 华北电力大学学报,2017,44(4):62-70.
- [7] WANG F, HAN J K, WANG C C, et al. Strong wind simulation of transmission tower structures [J]. Build Struct, 2018(48):39-44.
- [8] XIA Y, ZHANG P, NI Y Q, et al. Deformation monitoring of a super-tall structure using real-time strain data[J]. Eng Struct,2014(67):29-38.
- [9] HUANG X B, LIAO M J, XU G H. Stress monitoring method applying FBG sensor for transmission line towers [J]. Electr Power Autom Equip,2016(36):68-72.
- [10] BANG H, KIM H, LEE K. Measurement of strain and bending deflection of a wind turbine tower using arrayed FBG sensors [J]. Int J Prec Eng Manuf, 2012 (13): 2121-2126.
- [11] 张光南. 一种塔杆倾斜角度监测系统的设计与实现[J]. 宝鸡文理学院学报(自然科学版),2016,36(2):62-64.
- [12] 邓聚龙. 灰色系统基本方法[M]. 武汉:华中工学院出版社,1987.
- [13] 乔世范,方理刚,刘宝琛. GM(1,1)模型与指数模型在基桩沉降预测中的应用[J]. 中国铁道科学,2005(3):53-55.
- [14] 李斌,朱健. 非等间隔灰色 GM(1,1)模型在沉降数据分析中的应用[J]. 测绘科学,2007,32(4):52-55.
- [15] 魏青云. 基于改进型灰色 RBF 神经网络的小批量产品质量控制研究[D]. 郑州:郑州大学,2012.

(责任编辑 张 镛)