

旋转机械运行状态优化组合模型 变权重 RBF 预测方法

王吉芳^{1,2}, 费仁元¹, 徐小力², 刘 鑫²

(1. 北京工业大学 机械工程与应用电子技术学院, 北京 100124;

2. 北京信息科技大学 机电系统测控北京市重点实验室, 北京 100192)

摘 要: 针对现有各种非平稳非线性特征旋转机械运行状态预测方法适用性差、精度不高的难点问题, 提出一种旋转机械运行状态优化组合模型变权重 RBF 预测方法, 该方法通过对单一预测模型进行优选, 对输入样本进行加权处理, 采用径向基神经网络进行变权重组合模型动态建模, 从而充分利用了已知的有效信息, 强调了新旧信息对设备未来运行状态发展产生的不同影响。经实测数据验证, 获得了比单一预测模型及定权重 RBF 组合预测方法精度更高的预测结果。该方法程序实现简便, 预测精度高, 对预测问题的适用性广。

关键词: 组合模型; 变权重; 状态预测; RBF 网络

中图分类号: TH 183; TP 206

文献标志码: A

文章编号: 0254-0037(2013)01-0007-07

Rotating Machinery Condition Optimization Prediction Method of Variable Weight Combination RBF Model Research

WANG Ji-fang^{1,2}, FEI Ren-yuan¹, XU Xiao-li², LIU Xin²

(1. College of Mechanical Engineering and Applied Electronics Technology, Beijing University of Technology, Beijing 100124, China;

2. Beijing Key Laboratory-Measuring and Control of Mechanical & Electrical System Laboratory, Beijing Information Science and Technology University, Beijing 100192, China)

Abstract: In order to improve the forecast accuracy and adaptability for rotating machinery working conditions with unsteady and nonlinear features, an optimization prediction method of variable weight RBF combination model was suggested. This model was built based on variable weight RBF network. The samples were weighted according to the time to output and the combined models were selected according to the average relative error while the model built. As a result, the sufficient effective information was used, and the fact that new and old information taking different effect on the future state was stressed. The method was verified by measured data. The accuracy of variable weight RBF combination forecasting method was better than single RBF model and single weight combination forecasting methods. This method is simple to program and more adaptable on prediction with high forecast accuracy.

Key words: model; variable weight; condition prediction; RBF network

1969 年 Bata 和 Granger 提出了“组合预测”^[1]的思想, 认为不同的预测模型有着不同的适用范围

和优势, 从信息的利用角度看, 为了扬长避短, 尽可能地改善系统的预测性能, 提高预测精度, 将对同一

收稿日期: 2011-05-08.

基金项目: 国家自然科学基金资助项目(50975020).

作者简介: 王吉芳(1963—), 女, 教授, 主要从事机电系统自动化技术研究、机械设备故障监测及诊断方面的研究, E-mail: wjffz@sina.com.

问题的不同预测模型按一定方式进行组合,从而给出更好的预测结果,就是组合预测。

组合预测方法的关键是要寻找各单项方法预测结果对最终预测结果的影响关系,即各单项预测方法的权系数。目前,在确定权重时主要有定权系数^[2-6]和变权系数2种方法^[7-9]。显然,不同的预测方法对于不同的预测问题会表现出不同的预测能力。有的方法对瞬态变化敏感,适于中短期预测;有的方法善于把握长期趋势,表现出优越的中长期预测能力。对复杂的非线性问题,如果将权系数设定为常值,就无法适应非平稳的复杂变化,无法获得最佳预报效果。

在变权系数方法中,文献[7]采用BP神经网络进行组合模型的权值训练,通过在BP网络前增加预处理层来考虑不同模型权重随着单项预测误差的改变而变化的变权重思想,但BP神经网络需要大量的样本进行训练,且存在局部极小值问题。文献[8]给出了逐点外推和回归法2种确定组合模型权值的方法,但逐点外推法的取值相当于等权分配法,而回归法的应用要求观测样本量较多,且要求各单项预测方法在时点序列上的权系数具有一定规律性。文献[9]在2个单项模型预测的基础上,利用RBF进行了组合模型建模,但文中采用模型拟合段数据作为RBF模型的输入进行建模,而不是根据单项模型的预测能力进行组合模型的训练建模,方法上存在不足^[10]。

1 组合模型的优化

尽管目前已经研究了很多线性和非线性预测模型,但由于预测问题的复杂性和多样性,不可能找到一种可以解决所有预测问题的预测方法,不同的预测方法有其不同的预测性能,为了提高组合模型的通用性,可以将适合不同规律预测的尽可能多的单项预测模型放到模型库中,但在进行组合预测时,并不是参与组合的单项模型越多越好^[6],即不需要将所有的单项预测模型都放到组合中,应该根据各种模型的特点,将适用于求解问题的模型放到组合当中。如果将不适应的模型强行放到组合方法中,势必将错误的信息引入到建模过程,这样只能增加模型的不可靠性,甚至是建立了错误的模型,因此,组合模型建模时,必须对模型库中的模型(参与组合的模型)进行优选,将不适用的单项模型予以剔除。

尽管在单项方法建模过程中,经过模型的适用

性检验或样本的拟合,但各单项模型对预测问题的适用程度不一样,在拟合阶段精度很高的模型,在预测阶段却可能并不适合,提出组合预测的目的就是要通过对单项预测结果不满意的模型进行组合,使其得到满意的预测结果,所以,严格地进行模型适应性检验的意义在这并不重要。本文提出,为了增加组合预测的适用范围,应该在预测初期针对被预测问题的特点,建立3种以上的单项模型,以覆盖问题的各种变化趋势(如果问题并不复杂,变化趋势比较固定,也可以少建单项模型),对于有3种以上单项模型的组合模型,按以下步骤进行模型的优化选择:

1) 建立模型的优化目标 根据待预测问题的要求,预先设定一个合适的平均相对误差阈值 Δ_0 ,当然,这个阈值并不是待预测问题的期望平均误差阈,而是大于期望的预测平均相对误差阈。因为组合预测方法会使得其真实的预测精度高于参与组合的各单项预测的精度。

平均相对误差的公式为

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (1)$$

2) 模型优选 分别用各单项模型预测组合模型训练段的数据,计算预测段(与组合模型训练数据段实际值相比)的平均相对误差,对模型进行优选。优选时,大于平均相对误差阈值的单项模型可以从组合中剔除。如经过剔除后所剩模型数量大于3个,则进一步进行模型优选,将平均相对误差最大者的模型从组合模型中剔除,最终保留2~3种(本文保留3种)相对适合的模型。如剔除后所剩模型数量小于等于3个,可以保留平均相对误差最小的3种模型。

经过以上2个步骤,完成组合模型的优化过程。

2 变权重RBF神经网络架构的思想及数学模型

变权重RBF神经网络^[11]是在传统3层前馈RBF神经网络的基础上变化而来,其拓扑结构如图1所示。从结构上看,它与传统的3层前馈RBF神经网络的差别是输入层和隐含层之间增加了联接权关系 $\omega_i(q)$ 。

对于输入层,各节点输入值由外界传入,其输出为

$$\hat{x}_p'(q) = \omega_p(q) \hat{x}_p(q) \quad (2)$$

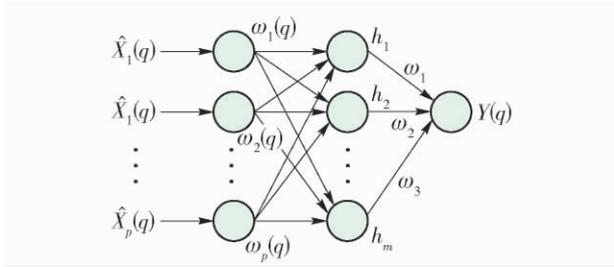


图 1 变权重 RBF 神经网络拓扑结构

Fig. 1 Topological diagram of improved weighted RBF neural network

式中: $\omega_i(q) = \frac{q}{\sum_{q=1}^Q q}$ ($q = 1, 2, \dots, Q$); Q 是组合训练样本数量; $\sum_{i=1}^p \omega_i(q) = 1$ ($i = 1, 2, \dots, p$).

对于隐含层, 其输入值为 $\hat{x}_i(q)$, 第 i 个隐单元输出值表示为

$$h_i = \varphi(\|X - r_i\|) \quad (1 \leq i \leq m)$$

式中: m 是隐含层神经元数; $\varphi(\cdot)$ 为隐单元的变换函数(即 RBF 基函数); $X = [\hat{x}_1, \hat{x}_2, \dots, \hat{x}_p]$.

输出层输出

$$y(q) = \sum_{i=1}^m h_i \omega_i \quad (3)$$

式中 ω_i 为第 i 个隐单元到输出之间的连接权值.

构造基于变权重 RBF 神经网络非线性组合预测模型(以下简称变权重 RBF 组合预测模型)的流程如图 2 所示. 该方法是将样本数据分别输入到不同的单一预测模型中, 根据数据特点进行多个单一模型建模, 用建立的单一模型分别进行不同时点的预测, 根据不同模型预测时段内的平均相对误差做模型优化, 选出可以用于组合模型的各个单一模型, 并根据各单一模型的预测误差大小进行数据重构. 重构的办法是将所选定的模型中预测平均误差最大者的数据用其余模型预测数据的平均值替代, 将替代后的数据重构后作为变权重 RBF 组合模型的训练数据输入, 以单一模型预测时段的实测值为组合模型的目标输出进行变权重组合模型的训练, 获得各单一模型的动态权值, 从而建立变权重动态 RBF 组合模型. 详见图 3.

由此可知, RBF 神经网络随着单项模型预测数据的改变而变化, 能自适应的改变预测模型, 体现了动态预测的思想. 其网络训练的过程, 也是调整各组合模型权重的过程. 在已知信息的利用上, 考虑到新旧信息对事件发展所起的作用(贡献)不同, 在

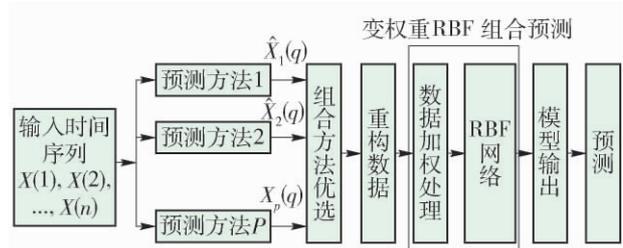


图 2 基于变权重 RBF 神经网络架构的组合预测流程

Fig. 2 Combination prediction process based on improved weighted RBF neural network architecture

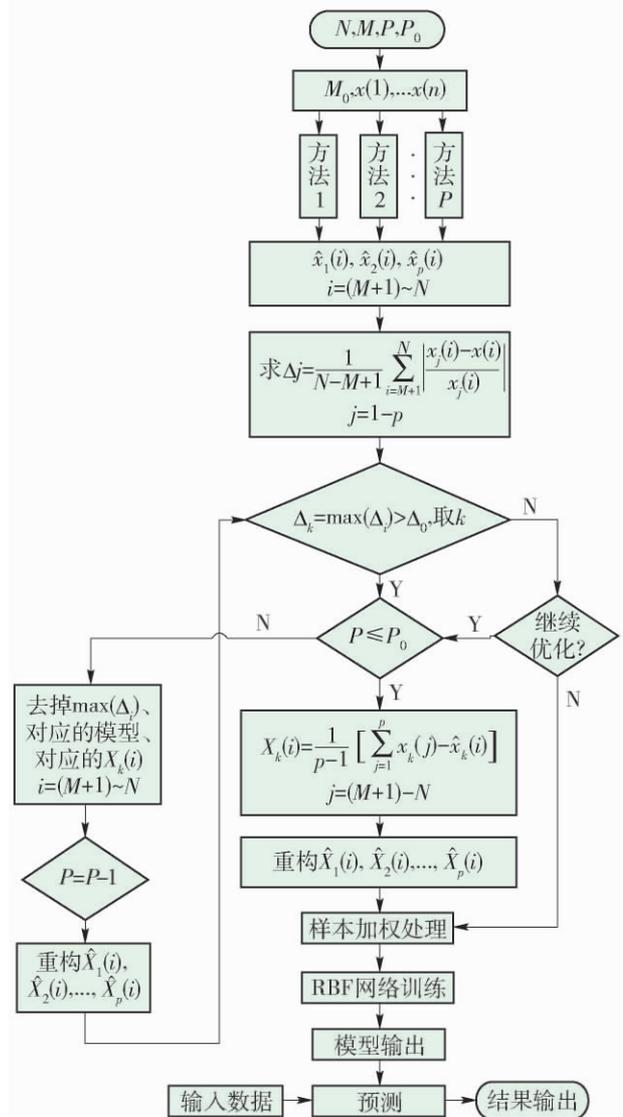


图 3 变权重组合预测模型优选及训练流程

Fig. 3 Optimization and training flow chart of improved weighted combination prediction model

预测模型中引入了样本权值 $\omega_i(q)$, 其取值依以时间为坐标的样本序列的新旧(发生时间的远近)来确定, 各样本权值之和为 1.

3 组合预测建模

在组合预测时可以根据对任务的认识,仅选取相适应的几个模型进行组合模型的训练建模,如果使用者不能对任务性质给出准确判断,或者是进行一项新任务的预测,可以按下面介绍的通用方法(见图3),由程序自主完成组合模型的优选和组合预测建模。流程图中的参数 N 表示输入原数据的个数; M 是模型训练用的数据个数; P_0 是选择的(给定的)参与组合预测模型个数; P 代表从模型库中选择的模型数; $\hat{x}_p(i)$ 表示第 p 个模型预测出的第 i 个点的数据; Δ_p^i 是第 p 个模型预测的第 i 个点的数据的相对误差; Δ_p 是第 p 个模型预测范围内的平均相对误差。

变权重 RBF 组合预测阶段的输入样本是被选定参与组合的各单项模型的预测输出,对应同一预测点的不同模型预测值构成组合预测训练的一个样本,该点的实测值作为训练的目标输出。

通过网络训练,对训练数据(输入数据)不断更替,进行模型更新,即使参与预测的各单项预测模型的权系数 ω_j 的大小不断变化,在网络训练中强调了预测精度高的那些单项预测方法对预测的贡献。

特别需要强调的是,在单项模型优选时,论文进行了组合模型训练数据重构,这一点非常重要,数据重构也是保证组合预测方法成功的重要手段。

4 组合预测在旋转机组烈度趋势预测中的应用

根据前面介绍的方法,对烟机烈度值进行组合建模预测。采用的各单项预测方法有:ARIMA 模型、RBF 神经网络预测,串联灰色 RBF 网络预测模型。以前 $n=25$ 点数据为建模数据,后18点为预报值进行预测方法检验。RBF 三层前向神经网络输入层采用10个点(10个神经元),输出层为一点,训练时采用10点预测下一点,如此循环递推预测,利用前25点作为训练数据。经训练得到3个单项预测模型:ARIMA($p=5, d=1, q=1$)模型、RBF 神经网络模型和灰色 RBF 网络模型。组合模型建模分为3步:

1) 数据重构 由于仅选用了3种模型,根据第2节给出的流程图,程序直接进入了根据3种单预测模型预测值求出的3个相对误差的大小,进行训练数据的重构。先用单项模型 ARIMA($p=5, d=1, q=1$)、RBF 神经网络和灰色 RBF 网络模型预测方

法进行一步预测,第 j 步预测值分别为 $\hat{x}_1(n+j)$ 、 $\hat{x}_2(n+j)$ 和 $\hat{x}_3(n+j)$,其中 $j=1, 2, \dots, 10$,各模型第 j 步预报误差分别为 $e_1(j) = |\hat{x}_1(n+j) - x(n+j)|$, $e_2(j) = |\hat{x}_2(n+j) - x(n+j)|$ 和 $e_3(j) = |\hat{x}_3(n+j) - x(n+j)|$ 。

分别计算第25~34点的各模型预测值的平均相对误差,对平均相对误差较大的模型预测值进行替换,替换数据取另2个模型同步预测值的平均值,经替换后得到模型的重构数据,依次记录每组的3个数据作为组合模型训练数据样本。

2) 组合模型 RBF 网络训练 利用重构后的数据样本进行组合模型的网络训练,取重构后各模型第25~34点的数据组成组合模型训练的输入,即输入层有3个神经元,共得到10个训练样本,对应样本的训练输出是该点的实测值。经过训练后得到组合预测模型。

3) 用前1~34个数据重新进行单项模型的模拟(训练)建模,得到新的单项预测模型,这样做是为了对单项模型与组合模型进行对比。

4) 用得到的组合预测模型进行预测 用组合预测模型预测第35~42点的输出,并将预测值与各参与组合的单项模型预测值进行比较。

为了对组合预测模型的预测效果进行评估,对取得的烟机振动烈度数据分别按上述的组合模型建模过程进行了单一模型建模,把单一模型的预测结果分别列于图4、5和6;对组合模型分别对本文给出的数据重构、数据加权与数据不重构、数据不加权的预测效果进行了比较验证,预测结果分别列于图7、8和9;3种参与组合的预测方法的预测结果详见表1所示;数据重构组合模型预测结果见表2;组合预测与各参与组合模型预测的对比结果见图10和表3。

从表3各种预测方法的预报误差可以看出,当简单根据3种单一模型的预测输出进行RBF权值训练组合建模时,组合模型并没有得到最佳的预测结果,而是介于3种单一模型预测结果的中间;而论文给出的组合模型建模方法,均好于各单一模型的预测结果。而且,变权重RBF组合模型的预测效果好于不变权的预测结果;数据重构的组合预测好于数据不重构的预测结果;而经过数据重构再进行变权重RBF组合模型建模的预测精度进一步得到提升,证明文中所给的方法的3个环节都对组合模型进行了改进,效果明显。

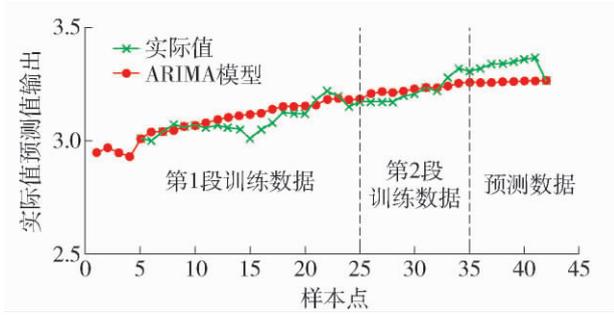


图 4 ARIMA 模型预测曲线

Fig. 4 Prediction curve of ARIMA model



图 5 RBF 模型预测曲线

Fig. 5 Prediction curve of RBF model

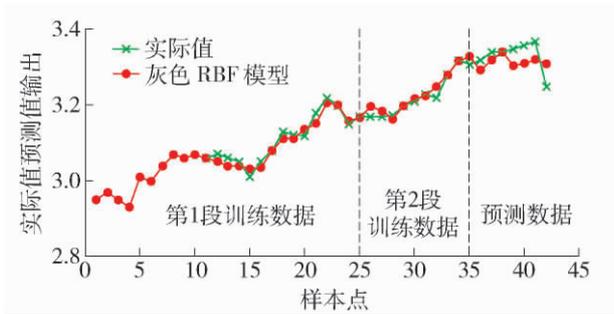


图 6 串联灰色 RBF 复合模型预测曲线

Fig. 6 Prediction curve of composite model of grey RBF Neural network in-line model

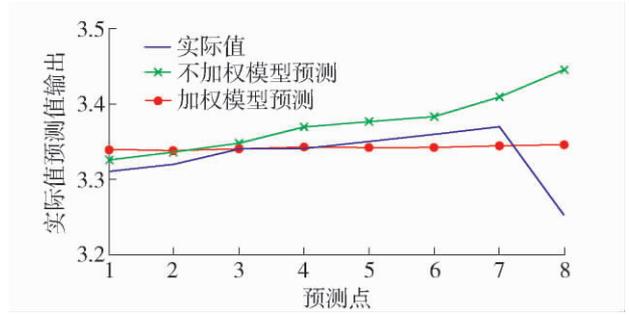


图 7 数据不重构时组合模型预测曲线

Fig. 7 Combined model prediction curves with data non-reconstruction

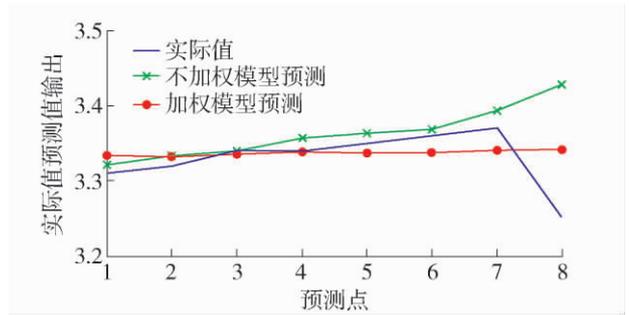


图 8 组合模型数据重构预测曲线

Fig. 8 Combination model data reconstruction forecast curves

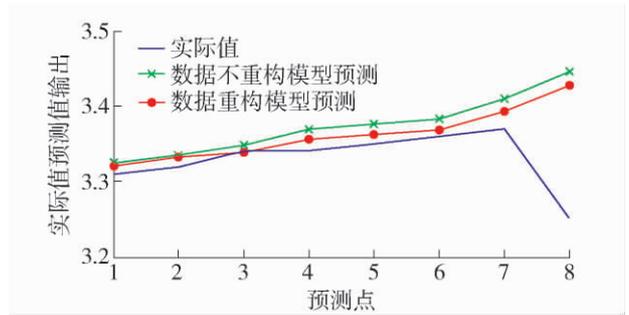


图 9 组合模型不加权预测曲线

Fig. 9 Combination model prediction curves of unweighted

表 1 烟机振动烈度数据 3 种模型预测结果

Table 1 Three models prediction results of tobacco machinery vibration intensity data

预测点 序号	实测值	ARIMA 模型 5-1-1			RBF 模型			灰色 RBF 复合		
		预测值	绝对 误差	相对 误差 /%	预测值	绝对 误差	相对 误差 /%	预测值	绝对 误差	相对 误差 /%
35	3.31	3.258 5	0.051 5	1.555 9	3.320 9	0.010 9	0.329 3	3.333 0	0.023 0	0.694 9
36	3.32	3.258 3	0.061 7	1.858 4	3.336 3	0.016 3	0.491 0	3.293 4	0.026 6	0.801 2
37	3.34	3.258 6	0.081 4	2.437 1	3.368 9	0.028 9	0.865 3	3.320 4	0.019 6	0.586 8
38	3.34	3.261 9	0.078 1	2.338 3	3.401 7	0.061 7	1.847 3	3.340 7	0.000 7	0.021 0
39	3.35	3.263 2	0.086 8	2.591 0	3.407 3	0.057 3	1.710 4	3.306 6	0.043 4	1.295 5
40	3.36	3.264 5	0.095 5	2.842 3	3.416 7	0.056 7	1.687 5	3.312 0	0.048 0	1.428 6
41	3.37	3.265 8	0.104 2	3.092 0	3.447 3	0.077 3	2.293 8	3.323 7	0.046 3	1.373 9
42	3.25	3.267 0	0.017 0	0.523 1	3.481 4	0.231 4	7.120 0	3.312 4	0.062 4	1.920 0
平均相对误差				2.154 8			2.043 1			1.015 2

表2 数据重构组合模型预测结果

Table 2 Data reconstruction model prediction results

原数据	不加权			加权		
	预测值	绝对误差	相对误差/%	预测值	绝对误差	相对误差/%
3.31	3.321 3	0.011 3	0.341 4	3.333 5	0.023 5	0.710 0
3.32	3.333 5	0.013 5	0.406 6	3.332 0	0.012 0	0.361 4
3.34	3.338 9	0.001 1	0.032 9	3.335 6	0.004 4	0.131 7
3.34	3.356 5	0.016 5	0.494 0	3.338 8	0.001 2	0.035 9
3.35	3.362 8	0.012 8	0.382 1	3.337 0	0.013 0	0.388 1
3.36	3.368 6	0.008 6	0.256 0	3.337 9	0.022 1	0.657 7
3.37	3.393 0	0.023 0	0.682 5	3.340 5	0.029 5	0.875 4
3.25	3.428 0	0.178 0	5.476 9	3.341 9	0.091 9	2.827 7
平均相对误差			1.009 1	0.748 5		

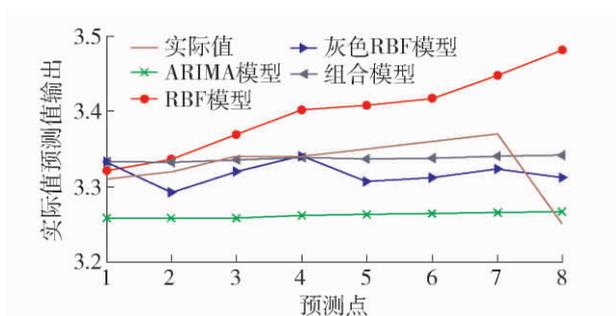


图10 4种模型预测曲线

Fig. 10 Prediction curves of four models

表3 预报误差比较表

Table 3 Prediction error comparison table

预报模型	平均相对误差 MAPE
ARIMA(5,1,1)模型	2.154 8
RBF神经网络	2.043 1
灰色RBF复合	1.015 2
数据不重构不变权组合预测模型	1.339 4
数据不重构变权重组合预测模型	0.750 6
数据重构不变权组合预测模型	1.009 1
数据重构变权重组合预测模型	0.748 5

5 结论

1) 本文优化组合方法可以根据预测任务不同,方便地实现预测模型的自适应选择,帮助非专业人员完成预测任务。

2) 实例验证了所给出的组合预测方法能弥补

单一模型的不足,充分利用了已有模型的有效信息,获得比参与组合的各单项模型精度更高的预测结果。

3) 提出的以样本距预测时点的远近对样本进行加权处理后,再进行基于变权重RBF组合预测方法,比不变权重的RBF组合模型预测效果好。

4) 本文提出的经过数据重构再进行变权重RBF组合模型建模方法,与不进行数据重构的变权重RBF组合模型相比,预测精度得到进一步提升。

参考文献:

- [1] BATES J M, GRANGER C W J. The combination of forecasts [J]. Journal of Operational Research Quarterly, 1969, 20(4): 451-468.
- [2] 陈华友. 组合预测权系数确定的一种合作对策方法 [J]. 预测, 2003, 22(1): 75-77.
CHEN Hua-you. A kind of cooperative games method determining weights of combination forecasting [J]. Forecasting, 2003, 22(1): 75-77. (in Chinese)
- [3] 许丽佳, 王厚军, 龙兵. 故障组合预测模型研究 [J]. 电子测量与仪器学报, 2007, 21(5): 6-10.
XU Li-jia, WANG Hou-jun, LONG Bing. Study of fault integrated forecasting model [J]. Journal of Electronic Measurement and Instrument, 2007, 21(5): 6-10. (in Chinese)
- [4] HANSEN B E. Least-squares forecast averaging [J]. Journal of Econometrics, 2008, 146(2): 342-350.
- [5] 韩东, 许葆华, 马献果. 基于绝对误差的线性组合预测研究 [J]. 河北科技大学学报, 2010, 31(6): 497-500, 522.

- HAN Dong, XU Bao-hua, MA Xian-guo. Research on linear combination forecasting based on absolute error [J]. Journal of Hebei University of Science and Technology, 2010, 31(6): 497-500, 522. (in Chinese)
- [6] 唐小我, 曹长修. 组合预测方法研究的若干新结果 [J]. 预测, 1992, 11(5): 39-46.
TAGN Xiao-wo, CAO Chang-xiu. Some new results of combination forecasting study [J]. Forecasting, 1992, 11(5): 39-46. (in Chinese)
- [7] 徐小力, 徐洪安, 曹爱东. 旋转机组的基于变权重神经网络组合预测模型 [J]. 中国机械工程, 2003, 14(4): 68-71.
XU Xiao-li, XU Hong-an, CAO Ai-dong. A combined predicting model based on neural network of variable weighting modulus to rotary sets [J]. China Mechanical Engineering, 2003, 14(4): 68-71. (in Chinese)
- [8] 臧淑英, 梁欣, 冯仲科. 变权组合预测模型的建立及其在区域生态风险预测中的应用 [J]. 北京林业大学学报, 2007, 29(增刊2): 203-208.
ZAGN Shu-ying, LIANG Xin, FENG Zhong-ke. Establishment of the changeable weight combination forecasting model and its application in regional ecological risk forecasting [J]. Journal of Beijing Forestry University, 2007, 29(Suppl 2): 203-208. (in Chinese)
- [9] 刘志杰, 季令, 叶玉玲, 等. 基于径向神经网络的集装箱吞吐量组合预测 [J]. 同济大学学报: 自然科学版, 2007, 35(6): 739-744.
LIU Zhi-jie, JI Ling, YE Yu-ling, et al. Combined forecast method of port container throughput based on RBF neural network [J]. Journal of Tongji University: Natural Science, 2007, 35(6): 739-744. (in Chinese)
- [10] 唐纪, 王景. 组合预测方法评述 [J]. 预测, 1999, 18(2): 42-43.
TAGN Ji, WAGN Jing. Recite on combination forecasting method [J]. Forecasting, 1999, 18(2): 42-43. (in Chinese)
- [11] 王吉芳, 徐小力, 费仁元, 等. 基于径向神经网络的设备运行状态新信息加权预测模型研究 [J]. 制造业自动化, 2011, 33(4): 76-80.
WANG Ji-fang, XU Xiao-li, FEI Ren-yuan, et al. Reseaching on prediction model of the new information weighted for mechanical equipment running-state based on RBF neural network [J]. Manufacturing Automation, 2011, 33(4): 76-80. (in Chinese)

(责任编辑 张 蕾)