

基于动态组合残差修正的预测方法

冯增喜, 任庆昌

(西安建筑科技大学 信息与控制工程学院, 西安 710055)

摘要 本文建立了一种基于残差修正的组合预测方法, 并基于该方法证明了针对多个单一的预测方法根据其在某个时间段的相对预测误差的大小选择组合选项可以进一步提高预测精度. 提出了针对不同时间段可根据各种单项预测模型的相对预测误差的大小动态选取相对预测误差最小的两种模型构成组合残差来修正基本方法的预测误差, 以提高预测精度. 最后通过实际空调负荷预测对其进行了验证, 结果表明这种动态组合残差修正的预测方法相对于基于多个固定单一预测方法的组合预测方法, 可以进一步改善预测效果.

关键词 预测; 组合残差; 精度

Forecasting model with dynamical combined residual error correction

FENG Zengxi, REN Qingchang

(School of Information and Control Engineering, Xi'an University of Architecture & Technology, Xi'an 710055, China)

Abstract In order to further improve the accuracy, a forecasting method with combined residual error correction is used in this paper. Based on the forecasting method, the residual error correction model and its combination ways are analyzed among some single forecasting methods, and the very high accuracy of the combination method with two minimum relative prediction errors is proven within a certain period. And then one forecasting method with dynamical combined residual error correction is proposed, based on choosing two minimum relative prediction errors to form the correction model during different periods. A study case indicates that the combination ways proposed in this paper can further improve the accuracy of combination forecast.

Keywords forecasting; combination residual error; accuracy

1 引言

如何提高预测精度一直是预测界的热点问题, 至今已有多篇文献报道了预测模型的研究成果. 其中, 自回归积分滑动平均模型 (autoregressive integrated moving average, ARIMA)、多元线性回归模型 (multiple linear regression, MLR)、灰色预测模型 (grey model, GM) 以及人工神经网络模型 (artificial neural network, ANN) 等几种模型是主要的模型. 利用灰色预测模型进行预测, 无需考虑系统结构, 直接利用原始数据的累加来寻找系统的规律并构建指数模型. 根据原始数据的特点, 可构造出不同的灰色预测模型, 灰色预测模型主要用于长期预测^[1-3]. 利用多元线性回归模型进行预测, 主要是借助于回归分析法找出预测对象及其影响因素之间的关系, 构建回归模型. 故该方法一般用于中期预测或仅用于趋势预测^[4,5]. 利用自回归积分滑动平

收稿日期: 2016-02-16

作者简介: 冯增喜 (1979-), 男, 汉, 陕西韩城人, 副教授, 博士研究生, 研究方向: 预测, 建筑智能化, E-mail: fengzengxi2000@163.com.

基金项目: 国家自然科学基金 (51508446); 陕西省教育厅专项科研项目 (15JK1389); 西安建筑科技大学基础基金 (JC1706)
Foundation item: National Natural Science Foundation of China (51508446); The Natural Science Fund of Shaanxi Province Education Office (15JK1389); The Basic Foundation of Xi'an University of Architecture and Technology (JC1706)

中文引用格式: 冯增喜, 任庆昌. 基于动态组合残差修正的预测方法 [J]. 系统工程理论与实践, 2017, 37(7): 1884-1891.

英文引用格式: Feng Z X, Ren Q C. Forecasting model with dynamical combined residual error correction[J]. Systems Engineering — Theory & Practice, 2017, 37(7): 1884-1891.

均模型进行预测, 方法简单、数据单一, 仅能预测出下一周期的值, 该方法适合短期预测^[6]. 利用神经网络预测, 主要有 RBF、BP、ELMAN 三种. 虽然神经网络的适应性和学习能力很强, 但由于其训练样本庞大、最优的网络结构难以寻找, 故其预测的准确性还有待提高. 神经网络较多地应用于短期预测^[7-11]. 实际中由于各种单项预测方法特点不同以及影响系统的部分因素具有随机性和不确定性, 导致单项预测方法表现出预测精度“时好时坏”的现象.

为提高预测精度, 组合预测被提出. 根据组合预测理论可知, 2 种或 2 种以上无偏的单项预测方法组合后预测结果优于每个单项的预测结果, 有效提高预测精度^[12,13]. 但对于同一对象进行组合预测, 若考虑角度不同、构成的单项预测方法有异, 则预测结果的准确程度也不尽相同^[14-17].

为再进一步提高预测精度, 本文首先以径向基函数神经网络 (radical basis function neural networks, RBFNN) 作为基本预测方法, 利用 ARIMA 和 ELMAN 的预测残差构成组合残差, 并以此来修正基于 RBF 神经网络的预测误差, 有效提高了预测精度. 然后在其基础上利用数学工具推导证明了针对多个单一的预测方法根据其在某个时间段的相对预测误差的大小选择组合选项可以进一步提高预测精度, 最后提出了针对不同时间段, 根据各种单项预测模型的相对预测误差的大小, 动态选取相对预测误差最小的两种模型构成组合残差来修正基本方法的预测误差, 以进一步提高预测精度. 并将本文提出的动态组合残差修正的预测方法用于中央空调负荷预测, 结果表明动态组合残差修正的预测方法可进一步提高预测精度.

2 基于径向神经网络预测的组合模型

组合预测理论表明了对于同一预测问题, 多个不同预测模型的线性组合, 在一定条件下能有效地改善模型的预测精度^[16]. 基于此原理, 本文综合利用 ARIMA 模型和 ELMAN 模型的预测结果, 通过加权平均建立残差的组合预测模型, 修正预测残差来修正预测值, 以提高预测精度. 组合预测可利用多个单项模型来实现, 在此以 ARIMA 模型和 ELMAN 模型两种预测模型来进行组合修正残差, 故以此两种模型为例来推导残差的组合预测模型及其如何提高预测精度.

RBF 神经网络是一种多输入单输出的前馈神经网络, 如图 1 所示. 通常由输入层、隐含层和输出层 3 层构成, 各层之间全连接, 输入层和隐含层之间没有权值, 隐含层与输出层之间有权值连接. 在 RBF 神经网络中, 隐含层执行的是一种用于特征提取的非线性变换, 它将输入空间映射到一个新的空间, 输出层在该新的空间中实现线性组合. 整个网络中可调节的参数为针对输出层的线性组合的权值和控制基函数形状的参数. 关于 RBF 神经网络的逼近能力, 理论上已证明其可以提供一般 3 层网络的逼近能力^[16]. RBF 神经网络隐含层神经元非线性函数采用高斯函数:

$$G(\|X(t) - T_i\|) = \exp \left[-\frac{1}{2} \left(\frac{\|X(t) - T_i\|}{q} \right)^2 \right] \quad i = 1, 2, \dots, m \quad (1)$$

式 (1) 中, $X(t) = (x_{t1}, x_{t2}, \dots, x_{tn})$ 为训练样本集中第 t 条输入样本; $T_i = (t_1, t_2, \dots, t_n)$ 是第 i 条隐含层神经元的中心; q 为第 i 个隐层节点的归一化参数.

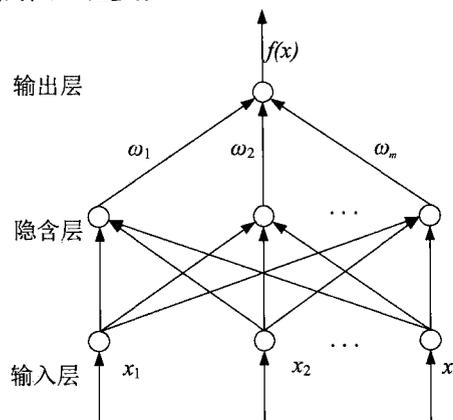


图 1 RBF 神经网络

RBFNN 输出为:

$$f(X(t), w_i, T_i) = \sum_{i=1}^m w_i G(\|X(t) - T_i\|) \quad (2)$$

式中, m 为隐层单元总数. $t = 1, 2, \dots, N$, N 为训练样本集中的样本总数. 定义误差为:

$$e(t) = y(t) - f(X(t), w_i, T_i) \quad (3)$$

式 (3) 中, $y(t)$ 为实际负荷值. RBFNN 的学习训练使样本集的总误差最小, 即:

$$\min E(W) = \frac{1}{2} \sum_{i=1}^n |e(t)|^2 \quad (4)$$

为提高 RBFNN 的预测精度, 有必要适当修正预测值. 令某时刻的实际值为 Q_{act} , 根据 RBFNN 预测模型得到的预测值为 Q_{RBF} , 则预测残差 Q_e 为:

$$Q_e = Q_{RBF} - Q_{act} \quad (5)$$

在实际预测中, 对残差 Q_e 进行预测建模主要是为了修正预测的最终结果, 以提高预测精度. 多元线性回归模型、自回归积分滑动平均模型、灰色预测模型和 ELMAN 模型均可用于残差 Q_e 的预测建模, 但由于不同的预测方法其特点不同以及实际情况的复杂性, 每种预测方法往往反映出“时好时坏性”^[18]. 为提高残差 Q_e 的预测精度, 在此根据残差 Q_e 的历史数据分别建立 ARIMA 和 ELMAN 两种预测模型, 然后综合利用 ARIMA 和 ELMAN 的预测结果, 用适当的权系数进行加权平均建立残差 Q_e 的组合预测模型.

令 ARIMA 和 ELMAN 两种预测方法对 t 时段残差 $Q_{e,t}$ 的预测值分别为 $Q_{e,ARIMA}$ 、 $Q_{e,ELMAN}$, 则依组合预测原理可得残差 $Q_{e,t}$ 的组合预测模型:

$$Q_{e,t,combine} = \omega_{ARIMA} Q_{e,ARIMA} + \omega_{ELMAN} Q_{e,ELMAN} \quad (6)$$

式中, ω_{ARIMA} 、 ω_{ELMAN} 分别为 ARIMA 和 ELMAN 两种预测方法的权重, 且其满足:

$$\omega_{ARIMA} + \omega_{ELMAN} = 1.0, \quad \omega_{ARIMA} \geq 0, \quad \omega_{ELMAN} \geq 0.$$

组合方法中确定权值的方法有多种, 在此采用最小二乘法确定各预测方法的权重. 考虑到残差历史数据 $Q_{e,t}$ 与组合残差模型 $Q_{e,t,combine}$ 的最小二乘意义上的拟合, 等价于下式所描述的条件极值问题:

$$\begin{cases} \min Z = \sum_{i=1}^m (Q_{e,t,combine}(i) - Q_{e,t}(i))^2 \\ \text{s.t.} \\ \omega_{ARIMA} + \omega_{ELMAN} = 1.0 \\ \omega_{ARIMA} \geq 0, \omega_{ELMAN} \geq 0 \end{cases} \quad (7)$$

假设 ARIMA 和 ELMAN 两种残差预测模型的实际偏差分别为 ε_{ARIMA} 、 ε_{ELMAN} :

$$\varepsilon_{ARIMA} = Q_{e,ARIMA} - Q_{e,t} \quad (8)$$

$$\varepsilon_{ELMAN} = Q_{e,ELMAN} - Q_{e,t} \quad (9)$$

则组合预测模型的实际偏差 $\varepsilon_{combine}$ 为:

$$\varepsilon_{combine} = Q_{e,t,combine} - Q_{e,t} = \varepsilon_{ARIMA} \omega_{ARIMA} + \varepsilon_{ELMAN} \omega_{ELMAN} \quad (10)$$

依据式 (7), 则式 (10) 可写成式 (11) 的形式:

$$\begin{cases} \min Z = W^T H W \\ \text{s.t.} \\ e^T W = 1.0 \\ W^T \geq 0 \end{cases} \quad (11)$$

式 (11) 中, $W = [\omega_{ARIMA}, \omega_{ELMAN}]^T$; $e = [1, 1]^T$;

$$H = \begin{bmatrix} \varepsilon_{ARIMA}^2 & \varepsilon_{ARIMA} \varepsilon_{ELMAN} \\ \varepsilon_{ARIMA} \varepsilon_{ELMAN} & \varepsilon_{ELMAN}^2 \end{bmatrix}.$$

对于残差预测模型 $Q_{e,ARIMA}$ 和 $Q_{e,ELMAN}$, 其预测偏差序列分别为:

$$\varepsilon_{ARIMA} = (\varepsilon_{ARIMA,1}, \varepsilon_{ARIMA,2}, \dots, \varepsilon_{ARIMA,n}) \quad (12)$$

$$\varepsilon_{ELMAN} = (\varepsilon_{ELMAN,1}, \varepsilon_{ELMAN,2}, \dots, \varepsilon_{ELMAN,n}) \quad (13)$$

根据统计学理论可知, 因为 $Q_{e,ARIMA}$ 和 $Q_{e,ELMAN}$ 是相互独立的, 所以两种模型偏差序列的协方差为零, 即:

$$Cov(\varepsilon_{ELMAN}, \varepsilon_{ARIMA}) = E\{[\varepsilon_{ELMAN} - E(\varepsilon_{ELMAN})][\varepsilon_{ARIMA} - E(\varepsilon_{ARIMA})]\} = 0 \quad (14)$$

对于平稳的历史序列, 其偏差序列为白噪声, 数学期望值为零, 所以:

$$E(\varepsilon_{ELMAN}) - E(\varepsilon_{ARIMA}) = 0 \quad (15)$$

根据 (14) 式和 (15) 式可得:

$$E(\varepsilon_{ELMAN}\varepsilon_{ARIMA}) = Cov(\varepsilon_{ELMAN}, \varepsilon_{ARIMA}) = \left(\sum_{i=1}^n \varepsilon_{ELMAN,i}\varepsilon_{ARIMA,i}\right) / n = 0 \quad (16)$$

即:

$$\sum_{i=1}^n \varepsilon_{ELMAN,i}\varepsilon_{ARIMA,i} = 0 \quad (17)$$

依式 (17) 可知, 对于平稳历史序列, 可将矩阵 H 作为一对角阵. 基于式 (11) 求解最优组合权重, 则需先建立拉格朗日函数:

$$L = W^T H W + \lambda (e^T W - 1) \quad (18)$$

再由 Kuhn-Tucker 条件得:

$$\begin{cases} \frac{\partial L}{\partial W} = 2HW + \lambda e = 0 \\ \frac{\partial L}{\partial \lambda} = e^T W - 1 = 0 \end{cases} \quad (19)$$

求解式 (19) 即可得到权重向量:

$$W = [\omega_{ARIMA}, \omega_{ELMAN}]^T = (H^{-1}e) / (e^T H^{-1}e) \quad (20)$$

根据式 (5) 与式 (20) 即可建立以 ARIMA 和 ELMAN 两种模型为基础的残差组合预测模型, 以此对 RBF 神经网络预测结果进行修正.

假设 RBFNN、ARIMA、ELMAN 模型的预测相对误差分别为 δE_{RBFNN} 、 δE_{ARIMA} 、 δE_{ELMAN} . 依据组合预测原理, ARIMA 模型和 ELMAN 模型两模型的组合预测相对误差 δE_Z 可用式 (21) 表示:

$$\delta E_Z = \omega_{ARIMA}\delta E_{ARIMA} + \omega_{ELMAN}\delta E_{ELMAN} \quad (21)$$

令某时刻 RBFNN 的实际值为 Q_{act} , 预测值为 $Q_{RBFNN,f}$, 则:

$$\delta E_{RBFNN} = \frac{|\Delta E_{RBFNN,act}|}{Q_{act}} \quad (22)$$

式 (22) 中, $\Delta E_{RBFNN,act} = Q_{RBFNN,f} - Q_{act}$ 为 RBFNN 预测模型的实际残差. 利用 ARIMA 和 ELMAN 两种模型构成的组合预测法对实际残差 $\Delta E_{RBFNN,act}$ 进行预测修正, 则有:

$$\delta E_Z = \frac{|\Delta E_Z - \Delta E_{RBFNN,act}|}{|\Delta E_{RBFNN,act}|} \quad (23)$$

其中, ΔE_Z 为组合预测模型对 RBFNN 实际残差的预测值.

利用 ΔE_Z 对 RBF 神经网络的预测值进行修正, 则可得最终预测结果的残差:

$$\Delta E_{cor} = \Delta E_{RBFNN,act} - \Delta E_Z \quad (24)$$

此时, 经残差组合预测修正后的 RBFNN 相对预测误差 δE_{RBFNN}^* 为

$$\delta E_{RBFNN}^* = \frac{|\Delta E_{RBFNN,act} - \Delta E_Z|}{Q_{act}} \quad (25)$$

将式 (22)、(23) 代入式 (25) 中, 得:

$$\delta E_{RBFNN}^* = \frac{\delta E_Z |\Delta E_{RBFNN,act}|}{Q_{act}} = \delta E_Z \delta E_{RBFNN} \quad (26)$$

由于,

$$\max(\delta E_{ARIMA}, \delta E_{ELMAN}) \geq \delta E_Z \geq \min(\delta E_{ARIMA}, \delta E_{ELMAN}) \quad (27)$$

所以, 经残差组合预测修正后的 RBFNN 相对预测误差 δE_{RBFNN}^* 的区间为

$$\max(\delta E_{ARIMA}, \delta E_{ELMAN})\delta E_{RBFNN} \geq \delta E_{RBFNN}^* \geq \min(\delta E_{ARIMA}, \delta E_{ELMAN})\delta E_{RBFNN} \quad (28)$$

根据式 (26) (27) 可知, 只要满足 $\delta E_{ARIMA} < 1$ 和 $\delta E_{ELMAN} < 1$, 则

$$\delta E_{RBFNN}^* < \delta E_{RBFNN} \quad (29)$$

式 (29) 表明: 经残差预测修正后, RBFNN 的预测精度可得到一定程度的改善^[17-19].

3 基于动态组合残差修正的预测方法的提出

经过前面的推导可知, 经残差组合预测修正后, 预测精度可进一步提高. 但如前所述, 不同的预测方法适用范围有所不同. GM 模型主要用于长期预测. MLR 模型一般用于中期预测或仅用于趋势预测. ARIMA 模型预测适合短期预测. BP、ELMAN 等人工神经网络预测适合短期预测. 且由于各种单项预测方法特点不同以及影响系统的部分因素具有随机性和不确定性, 导致单项预测方法表现出预测精度“时好时坏”的现象. 因此, 若用于组合预测的单项预测方法项数多少相同, 那么如何选取不同的单项预测方法再进一步提高预测精度? 本文以两项单项预测方法组合为例, 研究如何选取不同的单项预测方法来进一步提高预测精度.

假定在某一时段内存在 4 种预测方法, 分别用 1、2、3、4 表示. 其预测相对误差分别为 $\delta E_1, \delta E_2, \delta E_3, \delta E_4$. 且其满足以下条件:

$$\delta E_1 \leq \delta E_3 \quad (30)$$

$$\delta E_1 \leq \delta E_4 \quad (31)$$

$$\delta E_2 \leq \delta E_3 \quad (32)$$

$$\delta E_2 \leq \delta E_4 \quad (33)$$

假设:

$$\omega_1 + \omega_2 = 1 \quad (34)$$

其中, $0 \leq \omega_1 \leq 1, 0 \leq \omega_2 \leq 1$.

$$\omega_3 + \omega_4 = 1 \quad (35)$$

其中, $0 \leq \omega_3 \leq 1, 0 \leq \omega_4 \leq 1$.

联合式 (30)、(31)、(32)、(33)、(34)、(35), 并假设 $\delta E_1 \leq \delta E_2, \delta E_3 \leq \delta E_4$, 即在 $\delta E_1, \delta E_2$ 中取其大者, 在 $\delta E_3, \delta E_4$ 中取其小者, 则有:

$$\omega_1\delta E_1 + \omega_2\delta E_2 \leq \omega_1\delta E_2 + \omega_2\delta E_2 = \delta E_2 \leq \delta E_3 = \omega_3\delta E_3 + \omega_4\delta E_3 \leq \omega_3\delta E_3 + \omega_4\delta E_4 \quad (36)$$

即:

$$\omega_1\delta E_1 + \omega_2\delta E_2 \leq \omega_3\delta E_3 + \omega_4\delta E_4 \quad (37)$$

则根据公式 (21) 得:

$$\delta E_{Z,12} = \omega_1\delta E_1 + \omega_2\delta E_2 \quad (38)$$

$$\delta E_{Z,34} = \omega_3\delta E_3 + \omega_4\delta E_4 \quad (39)$$

则由 (37)、(38)、(39) 可得:

$$\delta E_{Z,12} = \omega_1\delta E_1 + \omega_2\delta E_2 \leq \omega_3\delta E_3 + \omega_4\delta E_4 = \delta E_{Z,34} \quad (40)$$

式中, $\delta E_{Z,12}$ 为基于方法 1 和 2 的组合预测相对误差, $\delta E_{Z,34}$ 为方法 3 和 4 的组合预测相对误差.

由 (26) 可得:

$$\delta E_{RBFNN,12}^* = \frac{\delta E_{Z,12} |\Delta E_{RBFNN,act}|}{Q_{act}} = \delta E_{Z,12} \delta E_{RBFNN} \quad (41)$$

$$\delta E_{RBFNN,34}^* = \frac{\delta E_{Z,34} |\Delta E_{RBFNN,act}|}{Q_{act}} = \delta E_{Z,34} \delta E_{RBFNN} \quad (42)$$

由 (40)、(41)、(42) 可得:

$$\delta E_{RBFNN,12}^* \leq \delta E_{RBFNN,34}^* \tag{43}$$

依两种不同组合方法修正后, RBFNN 相对预测误差 δE_{RBFNN}^* 经残差组合预测修正后的区间为:

$$\min(\delta E_1, \delta E_2) \delta E_{RBFNN} \leq \delta E_{RBFNN,12}^* \leq \max(\delta E_1, \delta E_2) \delta E_{RBFNN} \tag{44}$$

$$\min(\delta E_3, \delta E_4) \delta E_{RBFNN} \leq \delta E_{RBFNN,34}^* \leq \max(\delta E_3, \delta E_4) \delta E_{RBFNN} \tag{45}$$

联立 (43)、(44)、(45) 可得:

$$\min(\delta E_1, \delta E_2) \delta E_{RBFNN} \leq \delta E_{RBFNN,12}^* \leq \max(\delta E_1, \delta E_2) \delta E_{RBFNN} \leq \tag{46}$$

$$\min(\delta E_3, \delta E_4) \delta E_{RBFNN} \leq \delta E_{RBFNN,34}^* \leq \max(\delta E_3, \delta E_4) \delta E_{RBFNN}$$

4 实验验证 —— 基于动态组合残差修正的空调负荷预测

该实验基于西安建筑科技大学变风量中央空调系统实验平台. 在此平台上, RBFNN 作为基本方法被用来预测空调负荷. 为比较不同组合方式的预测效果, 采用了三种组合方式进行空调负荷预测, 一种是自回归积分滑动平均模型 (ARIMA) 和 ELMAN 组合, 第二种是多元线性回归模型 (MLR) 和 GM 组合, 第三种是本文提到的方法, 即根据 4 种单项预测方法的在某个时段里相对预测误差的大小, 动态选取相对预测误差相对较小的两种方法组合.

在 RBF 神经网络预测模型中, 网络训练样本参数即输入层节点包括 τ 时刻的室外空气温度、室外空气湿度、太阳辐射强度和前一天 τ 时刻的室外空气温度、室外空气湿度、太阳辐射强度及空调负荷等. 输出层节点为预测空调负荷. 隐含层节点数根据经验公式 $m = \sqrt{nl}$ 计算可得, 式中 $n = 8$ 为网络输入节点数, $l = 1$ 为网络输出节点数, m 为隐含层节点数. 网络的基本结构如图 2 所示.

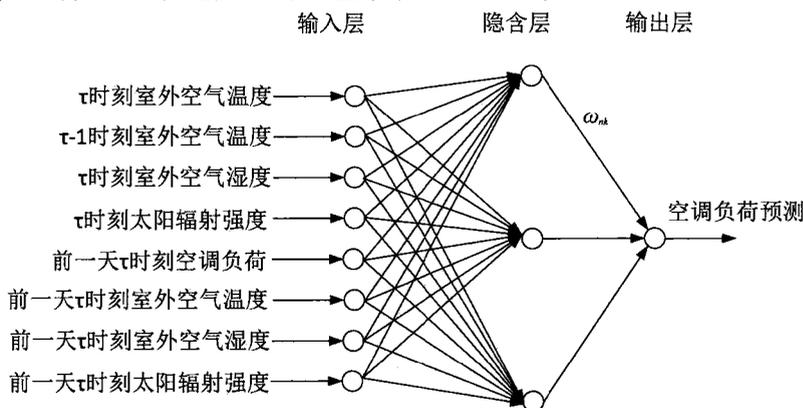


图 2 RBFNN 空调负荷预测模型的网络结构

基于动态组合残差模型修正的 RBFNN 空调负荷预测模型工作流程如图 3 所示.

在模型的建立过程中, 一万四千余组数据作为训练数据集被用来训练单项空调负荷预测模型, 七千余组数据被用来测试模型. 根据建立好的 RBF 模型和组合残差修正模型分别对夏季某一日中白天的 12 个小时的空调负荷进行预测. 各种方法预测的实际值、绝对误差和平均相对误差如图 4、图 5、图 6 所示.

针对不同方法对空调负荷预测仿真结果, 利用负荷预测中常用的平均相对误差、均方根误差和平均绝对误差等 3 个参数进行分析, 计算结果如表 1 所示.

表 1 不同方法的空调负荷预测结果

	RBF	GM 和 MLR 残差修正	ELMAN 和 ARIMA 残差修正	动态残差修正
平均相对误差 (%)	7.64	4.07	1.40	1.22
均方根误差	1.3865	0.7581	0.3024	0.2591
平均绝对误差 (kW)	1.3335	0.6771	0.2502	0.2175

预测结果表明: 通过组合残差修正可提高单项预测方法 RBF 的预测精度, 且组成组合残差的单项预测模型的预测精度越高, 则修正后的预测精度越高. 例如经适合中、长期负荷预测的 GM 和 MLR 残差组合

对 RBF 修正后的预测精度的平均相对误差由 7.64% 改善至 4.07%，而经适合短期负荷预测的 ELMAN 和 ARIMA 残差组合对 RBF 修正后的预测精度的平均相对误差由 7.64% 改善至 1.40%。预测结果还表明：经过动态残差组合修正，RBF 的预测精度还可进一步提高，如本例中 RBF 的预测精度的平均相对误差被进一步改善至 1.22%。

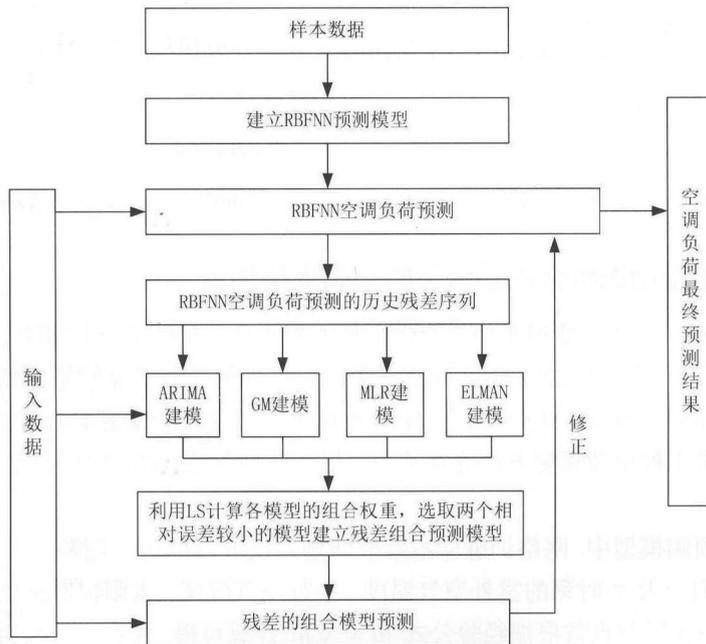


图 3 基于动态组合残差模型修正的 RBFNN 空调负荷预测模型工作流程

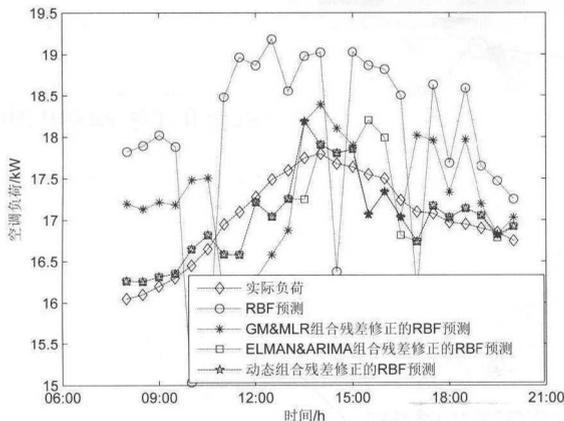


图 4 不同方法的空调负荷预测

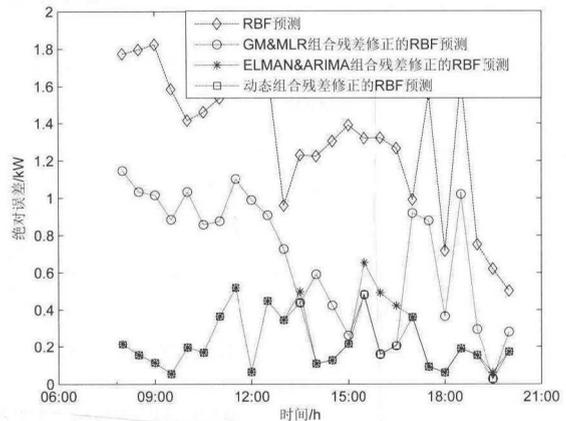


图 5 不同组合方法的空调负荷预测的绝对误差

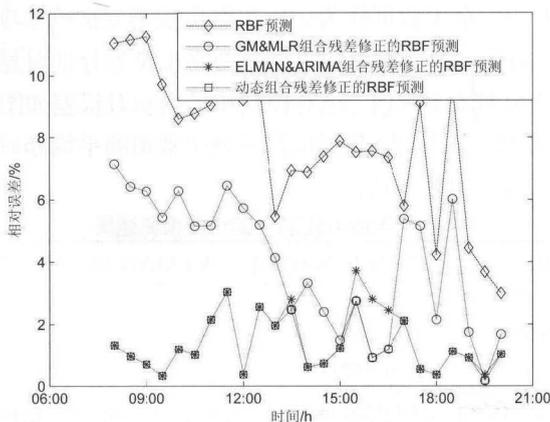


图 6 不同组合方法的空调负荷预测的相对误差

5 总结

本文建立了一种基于 RBFNN 模型, 并依据组合残差来修正 RBFNN 预测误差的方法, 此种方法可大大提高空调负荷的预测精度. 并证明了当采用相同数量的预测方法构成组合残差进行负荷预测时, 利用单项相对误差小的预测方法组合后, 预测精度还可进一步提高. 还在其基础上提出了在不同的时段, 放弃利用固定不变的单项预测方法来形成组合残差, 而是根据各个单项方法预测误差的大小, 动态的选取两种单项预测方法来构成组合残差, 可以进一步提高负荷预测的精度.

参考文献

- [1] Tsai S B. Using grey models for forecasting China's growth trends in renewable energy consumption[J]. *Clean Technologies and Environmental Policy*, 2016, 18(2): 563-571.
- [2] Feng S J, Ma Y D, Song Z L, et al. Forecasting the energy consumption of China by the grey prediction model[J]. *Energy Sources, Part B: Economics, Planning and Policy*, 2012, 7(4): 376-389.
- [3] Lee Y C, Wu C H, Tsai S B. Grey system theory and fuzzy time series forecasting for the growth of green electronic materials[J]. *International Journal of Production Research*, 2014, 52(10): 2931-2945.
- [4] Mokarram M. Modeling of multiple regression and multiple linear regressions for prediction of groundwater quality (case study: north of Shiraz)[J]. *Modeling Earth Systems and Environment*, 2016, 2(3): 1-7.
- [5] Keshavarzi A, Sarmadian F. Comparison of artificial neural network and multivariate regression methods in prediction of soil cation exchange capacity (case study: Ziara region)[J]. *Desert*, 2010, 15: 167-174.
- [6] Paulo C, Miguel R, José N. Evolving time series forecasting ARMA models[J]. *Journal of Heuristics*, 2004, 10: 415-429.
- [7] Abner C R N, Cícero A M, Mauro R. Comparative study on local and global strategies for confidence estimation in neural networks and extensions to improve their predictive power[J]. *Neural Computing and Applications*, 2013, 22(7): 1519-1530.
- [8] Khosravi A, Nahavandi S, Creighton D. Comprehensive review of neural network-based prediction intervals and new advances[J]. *IEEE Transactions on Neural Networks*, 2011, 22(9): 1341-1356.
- [9] Khosravi A, Nahavandi S, Creighton D. Lower upper bound estimation method for construction of neural network-based prediction intervals[J]. *IEEE Transactions on Neural Networks*, 2011, 22(3): 337-346.
- [10] Amrita K, Suchandan K D, Prem K S. Estimation of scale deposition in the water walls of an operating indian coal fired boiler: Predictive modeling approach using artificial neural networks[J]. *Journal of the Institution of Engineers (India): Series D*, 2016, 97(1): 39-46.
- [11] Lu T, Viljanen M. Prediction of indoor temperature and relative humidity using neural network models: Model comparison[J]. *Neural Computing & Applications*, 2009, 18: 345-357.
- [12] Rapach D E, Strauss J K. Forecasting U.S. employment growth using forecast combining methods[J]. *J Forecast*, 2008, 27: 75-93.
- [13] 朱大奇, 史慧. 神经网络原理及应用 [M]. 北京: 科学出版社, 2013.
Zhu D Q, Shi H. The theory and application of neural network[M]. Beijing: Science Press, 2013.
- [14] 唐小我. 组合预测方法研究的若干新成果 [J]. 预测, 1992, 11(5): 39-46.
Tang X W. Some new results of combination forecasting study[J]. *Forecasting*, 1992, 11(5): 39-46.
- [15] 王景, 刘良栋, 王作义. 组合预测方法的现状和发展 [J]. 预测, 1997, 16(6): 37-38.
Wang J, Liu L D, Wang Z Y. The status and development of combination forecasting study[J]. *Forecasting*, 1997, 16(6): 37-38.
- [16] Chert G J, Li K K, Chung T S. Application of all innovative combined forecasting method in power system load forecasting[J]. *Electric Power Systems Research*, 2001, 59(2): 131-137.
- [17] Shen J C, Chang C H, Wu S J. Real-time correction of water stage forecast using combination of forecasted errors by time series models and Kalman filter method[J]. *Stochastic Environmental Research and Risk Assessment*, 2015, 29(7): 1903-1920.
- [18] 姚晔. 集中空调系统状态空间建模及稳态优化节能控制研究 [D]. 上海: 上海交通大学, 2005.
Yao Y. State-space models of central air-conditioning system and stably optimal control for energy saving[D]. Shanghai: Shanghai Jiongtong University, 2005.
- [19] Yao Y, Lian Z W. An innovative air-conditioning load forecasting model based on RBF neural network and combined residual error correction [J]. *International Journal of Refrigeration*, 2006, 29: 528-538.