

DOI:10.3876/j.issn.1000-1980.2018.03.013

RBF-AR 模型在三峡水电站上网日电量预测中的应用

徐文权¹, 胡 慧², 卓张华³, 杨 伟¹

(1. 安庆师范大学物理与电气工程学院, 安徽 安庆 246001; 2. 安庆师范大学教育学院, 安徽 安庆 246001;
3. 中国长江电力股份有限公司三峡水利枢纽梯级调度通信中心, 湖北 宜昌 443002)

摘要: 针对水电站上网日电量数据的非线性特征, 采用状态相依自回归 (state-dependent auto-regressive, SD-AR) 模型对数据进行描述。用高斯径向基函数 (radial basis function, RBF) 神经网络来逼近 SD-AR 模型的函数型系数, 采用一种结构化非线性参数优化方法 (structured nonlinear parameter optimization method, SNPOM) 来离线辨识 RBF-AR 模型系数, 并利用此模型对数据进行预测。通过对三峡左岸和右岸水电站上网日电量真实数据进行训练和测试, 并与其他经典算法进行比较, 验证了 RBF-AR 模型在不确定条件下的预测准确性和可行性。

关键词: 状态相依模型; 上网电量预测; 非线性系统; RBF-AR 模型; 参数优化

中图分类号: TM612 **文献标志码:** A **文章编号:** 1000-1980(2018)03-0275-08

Application of RBF-AR model in the daily grid electricity forecasting of the Three Gorges hydropower station

XU Wenquan¹, HU Hui², ZHUO Zhanghua³, YANG Wei¹

(1. School of Physics and Electrical Engineering, Anqing Normal University, Anqing 246001, China;
2. School of Education, Anqing Normal University, Anqing 246001, China;
3. Cascade dispatching communication center of Three Gorges Project, China Yangtze Power Co., Ltd, Yichang 443002, China)

Abstract: According to the nonlinear characteristics of the daily grid electricity data of hydropower stations, the state-dependent auto-regressive (SD-AR) model is used to describe this data. In this study, the Gaussian radial basis function (RBF) networks are used to approximate the functional coefficients of SD-AR model, and the parameters of the RBF-AR model is estimated by an offline structured nonlinear parameter optimization method (SNPOM). After that, this model is applied to predict the data. Through the train and test for the real data of daily grid electricity of hydropower stations in the left bank and right bank of Three Gorges as well as comparison with other classical algorithms, the forecasting accuracy and feasibility of RBF-AR model are verified.

Key words: state dependent model; the grid electricity forecasting; nonlinear system; RBF-AR model; parameter optimization

发电量对一个国家未来经济发展具有举足轻重的作用, 电量预测有利于合理安排发电计划, 保障国家经济的正常发展。水电站上网日电量预测是根据上网日电量的历史值对未来值的预测, 水电站上网日电量在一定程度上能够反映出水电站供电区域的经济总体情况, 可以为该区域经济发展和相关政策制定提供有力

基金项目: 安徽省教育厅一般项目 (AQSK2014B002); 安庆师范大学校青年基金 (SK201208, KJ201315)
作者简介: 徐文权 (1983—), 男, 讲师, 博士研究生, 主要从事复杂系统建模与优化控制研究。E-mail: zyheijunma@163.com
引用本文: 徐文权, 胡慧, 卓张华, 等. RBF-AR 模型在三峡水电站上网日电量预测中的应用[J]. 河海大学学报(自然科学版), 2018, 46(3): 275-282.
XU Wenquan, HU Hui, ZHUO Zhanghua, et al. Application of RBF-AR model in the daily grid electricity forecasting of the Three Gorges hydropower station[J]. Journal of Hohai University(Natural Sciences), 2018, 46(3): 275-282.

的支持。虽然电不能事先储存,但是发电企业可以根据对上网日电量的预测值,对要执行调度的发电量做出参考,并进行合理安排,这样有利于节约能源,避免不必要的经济损失和资源浪费。因此,怎样选用一种合适的函数逼近方法来分析上网日电量数据,并能够提取出有价值信息是一项很重要的研究课题。许多科研人员对电量预测做了大量的研究工作,并提出了一些预测分析方法。刘红岭等^[1]提出了一种基于不同场景构建方法的场景树模型,对水电站中长期合约电量进行随机规划,通过水电站实例验证了随机线性规划模型的有效性。卫志农等^[2]提出了将历史数据与其影响因素进行模式分类,使用样本数据对应模式进行预测的级联神经网络电量概率预测方法。Dedinec 等^[3]使用深度信念网络对马其顿电力负荷进行了预测,并与传统的神经网络相比获得了很小的平均绝对误差值。王娜等^[4]采用基于区域信息融合的方法用于风电场的平均年发电量预测,试验验证了提出的信息融合方法比采用单一气象站数据的预测误差降低了 11.32%。朱琳琳等^[5]采用粒子群优化(particle swarm optimization, PSO)算法与反向传播(back propagation, BP)算法相结合设计了一种光伏发电预测模型,并通过实例验证了模型的准确度。Zhang 等^[6]提出将小波变换,滑动自回归模型和极限学习模型相结合的混合模型用于电价的预测,并通过 3 个实例验证了模型精度。水电站上网日电量预测原理类似于电力负荷及电价的预测,虽然电力负荷及电价预测需要考虑电价波动对电力负荷产生的影响,但是可以借鉴电力负荷及电价预测方法和手段对水电站上网日电量进行预测。

本文针对三峡左岸和右岸水电站上网日电量时变,未来上网日电量未知的特点,采用状态相依自回归(state-dependent auto-regressive, SD-AR)模型来描述水电站上网日电量的非线性特征,使用高斯径向基函数(radial basis function, RBF)神经网络来逼近 SD-AR 模型的函数型系数,构建 RBF-AR 模型。采用 Peng 等^[7-8]提出的结构化非线性参数优化方法(structured nonlinear parameter optimization method, SNPOM)对 RBF-AR 模型参数进行离线辨识,根据辨识好的模型对未来的上网日电量进行预测。RBF-AR 模型参数估计方法自提出以来已成功用于时间序列的预测^[9],目前已将 RBF-AR 扩展成 RBF-ARX 模型,并对其进行了改进。RBF-AR(X)模型已经在磁悬浮球位置控制^[10-12]、四旋翼飞行器姿态控制^[13]、水箱液位控制系统^[14-15]以及日本东京海洋大学试验船舶的轨迹跟踪过程^[16]等非线性系统建模与优化控制领域取得了成功应用。本文首次将 RBF-AR 模型用于对三峡左岸和右岸水电站上网日电量的预测,也是首次对三峡水电站的上网日电量进行预测研究。通过试验结果得出,RBF-AR 模型与其他模型相比具有低的均方差值和归一化均方根误差值,提高了预测精度,对水电站的上网日电量预测研究提供参考。

1 状态相依 RBF-AR 模型

针对三峡水电站上网日电量的非线性特性,可以用式(1)所表示的非线性 AR 模型进行描述:

$$\begin{cases} y(t) = f(\mathbf{X}(t-1)) + e(t) \\ \mathbf{X}(t-1) = [y(t-1) \quad y(t-2) \quad \cdots \quad y(t-p)] \end{cases} \quad (1)$$

式中: $y(t) \in R$ ——预测输出值; $e(t)$ ——预测残差; $f(\cdot)$ ——非线性映射; $\mathbf{X}(t-1)$ —— t 时刻的状态向量,实时反映不同时刻的动态量; p ——模型输入阶次。在做实际控制时选择此固定向量作为系统的状态工作点,一般选择能表征系统非线性比较强的项作为固定向量;在实际的具体问题中也可以选择 $\{y(t-1), y(t-2), \cdots, y(t-p)\}$ 中的某几个值作为固定向量;根据文献[17]所述可得出状态相依 AR 模型具有以下结构特征:

$$y(t) = \phi_0(\mathbf{X}(t-1)) + \sum_{i=1}^p \phi_{y,i}(\mathbf{X}(t-1))y(t-i) + e(t) \quad (2)$$

式中: $\phi_0(\mathbf{X}(t-1))$ 和 $\{\phi_{y,i}(\mathbf{X}(t-1)), i=1, 2, \cdots, p\}$ ——状态相依函数型系数。式(2)是通过引入状态相依函数型系数来对式(1)进行局部线性化。

由于 RBF 网络存在结构简单以及具有很好的函数逼近能力,因此本文选用 RBF 网络来逼近式(2)中的函数型系数,由此得到状态相依 RBF-AR 模型结构为

$$\begin{cases} y(t) = \phi_0(\mathbf{X}(t-1)) + \sum_{i=1}^p \phi_{y,i}(\mathbf{X}(t-1))y(t-i) + e(t) \\ \phi_0(\mathbf{X}(t-1)) = c_0^0 + \sum_{k=1}^m c_k^0 \exp\{-\lambda_k^y \|\mathbf{X}(t-1) - \mathbf{Z}_k\|_2^2\} \\ \phi_{y,i}(\mathbf{X}(t-1)) = c_{i,0}^y + \sum_{k=1}^m c_{i,k}^y \exp\{-\lambda_k^y \|\mathbf{X}(t-1) - \mathbf{Z}_k\|_2^2\} \\ \mathbf{Z}_k = (z_{k,1} \quad z_{k,2} \quad \cdots \quad z_{k,d}) \end{cases} \quad (3)$$

式中: d ——模型的阶次; m ——RBF 网络隐含层的结点数; $\mathbf{Z}_k(k=1,2,\cdots,m)$ ——RBF 网络的中心值矩阵; $\lambda_k^y(k=1,2,\cdots,m)$ ——RBF 网络的比例缩放因子; $c_k^0(k=0,1,\cdots,m)$ 和 $c_{i,k}^y(i=1,2,\cdots,p;k=0,1,\cdots,m)$ ——RBF 网络线性权重; $\|\cdot\|_2$ ——向量的 2 范数。一般情况,式(3)中不同的回归部分具有不同 RBF 网络中心值。为了简化计算,可以取同一个中心值,因为即使中心值取值都相同,但是式(3)中的回归部分也会得出不同的回归值。

2 模型参数估计方法

RBF-AR 模型参数辨识包括对模型阶次以及 RBF 网络结构的中心值,线性权重和网络比例缩放因子的选择。如果不对待辨识的参数进行区别对待,仍然使用传统的最小二乘法 (least square method, LSM) 和 levenberg marquardt method (LMM) 对所有参数进行辨识,肯定会增加计算量,很难得到很好的解。文献[7]提出了一种 SNPOM 方法来辨识 RBF-AR 模型参数。SNPOM 方法将所有需要搜索的空间分为线性参数空间和非线性参数空间,使用 LSM 估计线性参数,使用 LMM 方法来估计非线性参数,在每次计算非线性参数时,线性参数已经被更新了很多次,此方法极大地提高了收敛速度和预测精度。对于上网日电量预测模型阶次的选择,使用 AIC(akaike information criterion, AIC)信息准则选择模型阶次。具体的 SNPOM 参数优化步骤如下:

2.1 参数分类

RBF-AR 模型的线性参数:

$$\theta_L = \left\{ c_0^0, c_1^0, \cdots, c_m^0 \right. \\ \left. c_{1,0}^y, c_{1,1}^y, \cdots, c_{1,m}^y, c_{2,0}^y, c_{2,1}^y, \cdots, c_{2,m}^y, \cdots, c_{p,0}^y, c_{p,1}^y, \cdots, c_{p,m}^y \right\} \in R^{(1+m)(1+p)}$$
 (4)

非线性参数为

$$\theta_N = \left\{ \lambda_1^y, \lambda_2^y, \cdots, \lambda_m^y \right. \\ \left. z_{1,1}, z_{1,2}, \cdots, z_{1,d}, z_{2,1}, z_{2,2}, \cdots, z_{2,d}, \cdots, z_{m,1}, z_{m,2}, \cdots, z_{m,d} \right\} \in R^{md+m}$$
 (5)

式中: θ_N ——待辨识的所有非线性参数; θ_L ——待辨识的所有线性参数。

为了将 SNPOM 方法能够更好地用于 RBF-AR 模型的参数估计,将模型构造成如下 2 种形式:

$$y(t) = f(\theta_L, \theta_N, \mathbf{X}(t-1)) + e(t)$$
 (6)

或者
$$y(t) = \Psi(\theta_N, \mathbf{X}(t-1))^T \theta_L + e(t)$$
 (7)

式(7)为式(6)的回归形式。

2.2 参数初始化

首先在向量空间 $\mathbf{X}(t-1)$ 中随机地选择一个子空间作为 $\mathbf{Z}_k^0(k=1,2,\cdots,m)$ 的初始值,接着根据式(8)计算缩放因子的初始值:

$$\lambda_k^0 = \frac{-\lg \varepsilon}{\max_{t=1} \{ \|\mathbf{X}(t-1) - \mathbf{Z}_k^0\|_2^2 \}} \quad 0.0001 \leq \varepsilon \leq 0.1$$
 (8)

选择好缩放因子的初始值后再选择非线性参数的初始值 θ_N^0 ,并将其固定,再使用 LSM 计算线性参数初始值 θ_L^0 。

$$\theta_L^0 = \left[\sum_{t=\tau+1}^M \bar{\boldsymbol{\psi}}_{t,0} \bar{\boldsymbol{\psi}}_{t,0}^T \right]^{-1} \sum_{t=\tau+1}^M \bar{\boldsymbol{\psi}}_{t,0} \bar{x}(t)$$
 (9)

其中
$$\bar{\boldsymbol{\psi}}_{t,0} = \boldsymbol{\psi}(\theta_N^0, \bar{\mathbf{X}}(t-1))$$

式中: $\bar{x}(t)$ 、 $\bar{\mathbf{X}}(t-1)$ ——待观测的数据集; τ ——延迟时间; M ——待辨识的数据长度。

2.3 参数优化

使用残差的平方和作为目标函数:

$$V(\theta_L, \theta_N) = \frac{1}{2} \|\mathbf{F}(\theta_L, \theta_N)\|_2^2$$
 (10)

$$\boldsymbol{F}(\theta_L, \theta_N) = \begin{bmatrix} f(\theta_L, \theta_N, \bar{\boldsymbol{X}}(\tau)) - \bar{x}(\tau + 1) \\ f(\theta_L, \theta_N, \bar{\boldsymbol{X}}(\tau + 1)) - \bar{x}(\tau + 2) \\ \vdots \\ f(\theta_L, \theta_N, \bar{\boldsymbol{X}}(M - 1)) - \bar{x}(M) \end{bmatrix} \tag{11}$$

参数优化问题即为

$$(\hat{\theta}_L, \hat{\theta}_N) = \arg \min V(\theta_L, \theta_N) \tag{12}$$

式中: $\hat{\theta}_N$ ——最终辨识出的所有非线性参数; $\hat{\theta}_L$ ——最终辨识出的所有线性参数。

使用相互交叉迭代过程来对要估计的参数进行优化,非线性参数的更新公式为

$$\theta_N^{k+1} = \theta_N^k + \beta_k d_k \tag{13}$$

式中: d_k ——搜索方向; β_k ——代表到最小值之间距离的步长; k ——迭代的步数。对于线性参数,使用 LSM 计算得出:

$$\begin{cases} \theta_L^{k+1} = \left[\left(\sum_{t=\tau+1}^M \bar{\boldsymbol{\psi}}_{t,k+1} \bar{\boldsymbol{\psi}}_{t,k+1}^T \right)^{-1} \sum_{t=\tau+1}^M \bar{\boldsymbol{\psi}}_{t,k+1} \bar{x}(t) \right] \\ \bar{\boldsymbol{\psi}}_{t,k+1} = \boldsymbol{\psi}(\theta_N^{k+1}, \bar{\boldsymbol{X}}(t - 1)) \end{cases} \tag{14}$$

搜索方向 d_k 值可由下式计算得出:

$$\begin{cases} \boldsymbol{J}(\theta_N^k) = \left[\frac{\partial \boldsymbol{F}(\theta_L^k, \theta_N^k)}{\partial \theta_N^k} \right]^T \\ [\boldsymbol{J}(\theta_N^k)^T \boldsymbol{J}(\theta_N^k) + \gamma_k \boldsymbol{I}] d_k = -\boldsymbol{J}(\theta_N^k)^T \boldsymbol{F}(\theta_L^k, \theta_N^k) \end{cases} \tag{15}$$

式中: $\boldsymbol{J}(\theta_N^k)$ ——Jacobian 矩阵; γ_k ——用来控制 d_k 的幅度和方向的量, $\boldsymbol{I}$ ——单位向量。

当 γ_k 趋近于 0 的时候, d_k 将沿着高斯-牛顿方向;当 γ_k 趋近无穷大的时候, d_k 将沿着最速下降方向。当 d_k 求出后,式(13)中的 β_k 由类似于混合二次、三次多项式内插,外插法的线搜索过程得出。应当注意的是所有线性参数(非线性参数)的更新都是紧随着非线性参数(线性参数)的更新得出的^[9-10]。

2.4 模型阶次选择

待辨识模型阶次的选择由 AIC 信息准则确定,根据选择不同的 RBF-AR 模型阶次或者隐含层神经元个数,重复使用 SNPOM 优化方法,选择 AIC 值最小时的阶次作为最终阶次和隐含层神经元个数。对于 RBF-AR 模型,AIC 值计算公式如下:

$$Q_{\text{AIC}} = M \lg e^2(t) + 2(s + 1) \qquad M > p \tag{16}$$

式中: s ——所有待辨识的参数个数。

3 性能评价指标

为了更好地对上网日电量数据进行预测,笔者采用均方差(mean square error, MSE),均根方差(root mean square error, RMSE)和归一化均方根误差(normalized root mean squared error, NMSE)等指标对上网日电量的预测结果进行评价。

$$Q_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N e^2(t) \tag{17}$$

$$Q_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N e^2(t)} \tag{18}$$

$$Q_{\text{NMSE}} = \sqrt{\frac{\sum_{i=1}^N e^2(t)}{\sum_{i=1}^N (x(t) - \bar{x}(t))^2}} \tag{19}$$

其中

$$e(t) = x(t) - \hat{x}(t)$$

式中: $x(t)$ ——真实值; $\hat{x}(t)$ ——预测值; $\bar{x}(t)$ ——数据 $\{x(1), x(2), \dots, x(N)\}$ 的平均值; N ——测试数据的个数。

RMSE、MSE 和 NMSE 常用来衡量 RBF-AR 模型的预测精度,得出的数值越接近于 0,代表预测模型具有更高的精度,除此之外,这 3 个指标也用于对不同模型精度的比较。

4 三峡水电站上网日电量的建模与预测结果分析

三峡水电站位于湖北省宜昌市,是世界上已建规模最大的水电站,包括左岸、右岸、地下电站和电源电站。三峡工程在防洪、发电、航运、补水等方面发挥着巨大的综合效益。笔者通过对左岸和右岸水电站上网日电量的预测来验证 RBF-AR 模型的有效性。基于数据的变化区间比较大,笔者对原始数据都进行了归一化处理,文中所有图形都是在经归一化处理后的数据,所有参数指标都是在对原始数据归一化处理基础上计算得到的。

4.1 三峡左岸水电站上网日电量预测

试验数据采用三峡左岸电站 2006 年 2 月 20 日至 2007 年 5 月 6 日共 440 d 的上网日电量作为数据集。经归一化处理的上网日电量数据如图 1 所示。

将源数据前 400 d 的上网日电量用来训练模型,后 40 d 的上网日电量数据作为测试模型来验证 RBF-AR 模型性能。根据式(1)可知,用固定的向量 $\{y(t-1),y(t-2),\cdots,y(t-5)\}$ 来预测 $y(t)$,使用如下的 RBF-AR 模型来对上网日电量数据进行建模:

$$\begin{cases} y(t) = \phi_0(X(t-1)) + \sum_{i=1}^5 \phi_{y,i}(X(t-1))y(t-i) + e(t) \\ \phi_0(X(t-1)) = c_0^0 + \sum_{k=1}^m c_k^0 \exp\{-\lambda_k^y \|X(t-1) - Z_k\|_2^2\} \\ \phi_{y,i}(X(t-1)) = c_{i,0}^y + \sum_{k=1}^m c_{i,k}^y \exp\{-\lambda_k^y \|X(t-1) - Z_k\|_2^2\} \\ X(t-1) = [y(t-1), y(t-2), \cdots, y(t-5)]^T \end{cases} \quad (20)$$

使用 RBF-AR(p,m,d)来表示预测模型,其中 $d=\dim\{X(t-1)\}$ 。根据 AIC 准则选择模型参数建立 RBF-AR 模型,分别调节结点数目 m ,对 $m=3,4,6,8,10,12,14,16,18$ 这些情况采用 SNPOM 优化方法进行试验比较。试验在 Matlab2010,处理器为 Intel(R) Core(TM)2 Duo CPU, 2.53GHz, RAM 为 4GB 的 Windows10 系统中完成。分别得出在不同隐含层结点数情况模型的一些性能指标,试验结果见表 1。

表 1 不同结点数目的 RBF-AR 模型对上网日电量的测试数据预测结果

Table 1 Prediction results of RBF-AR model on daily electricity with different number of nodes

模型	结点数/个	运行时间/s	Q_{AIC}	$Q_{MSE} \times 10^{-3}$	$Q_{RMSE} \times 10^{-2}$	Q_{NMSE}
RBF-AR(5,3,5)	3	8	-110.0	4.48	6.69	0.360
RBF-AR(5,4,5)	4	20	-84.4	5.03	7.09	0.382
RBF-AR(5,6,5)	6	73	-27.4	7.25	8.52	0.459
RBF-AR(5,8,5)	8	144	79.6	45.90	21.40	1.150
RBF-AR(5,10,5)	10	115	93.9	18.80	13.70	0.739
RBF-AR(5,12,5)	12	448	151.0	28.10	16.80	0.903
RBF-AR(5,14,5)	14	231	191.0	24.10	15.50	0.836
RBF-AR(5,16,5)	16	498	345.0	562.00	75.00	4.040
RBF-AR(5,18,5)	18	363	392.0	631.00	79.50	4.280

从表 1 可以看出,预测模型参数的选择要根据预测性能指标最小值情况下获得。选择表 1 中性能指标为最小值情况下的模型作为本文最终预测模型。本文预测模型选为 RBF-AR(5,3,5),由于 RBF 网络的结点数目比较少,所以预测模型在很短的时间内就能完成。根据表 1 进一步验证了在 AIC 值最小的情况下,MSE, RMSE 和 NMSE 的数值也最小。使用 SNPOM 优化方法得出的训练模型实际值与预测值见图 2。图 3 为将训练模型辨识出的参数固定后测试模型的实际值与预测值相比较的图形。从图 3 可以很明显地看出测试数据的预测值能够准确跟踪实际数据变化趋势。




图 1 经归一化处理左岸水电站上网日电量
Fig. 1 Daily electricity on the left bank hydropower station after normalized




图2 训练数据的实际值与预测值比较

Fig.2 Comparison between actual values and training data

为了公平比较以及说明 RBF-AR 模型的预测精度,分别使用最小二乘法和反向传播(back propagation, BP)神经网络两种经典算法对上网日电量数据进行测试。LSM 与 BP 的阶次都取 5。BP 模型的结构为 5-7-1,学习率为 0.1,迭代次数为 10000。为了验证 3 种算法的稳健性,分别对 3 种算法进行了 100 次运算,得出 MSE、RMSE 和 NMSE 值的平均值分别如表 2 所示。

从表 2 可以看出,RBF-AR 模型的预测结果优于传统 LSM 和 BP 算法,由于 SNPOM 使用 LSM 对线性部分进行优化,所以在运行时间比单独的 LSM 要长点,但少于 BP 算法。通过分析进一步验证了 SNPOM 优化方法在日上网电量预测中的可行性。

4.2 三峡右岸水电站上网日电量预测

为了进一步验证 RBF-AR 模型的有效性,使用三峡右岸水电站 2008 年 1 月 1 日至 2009 年 12 月 31 日的上网日电量共 731 个数据作为数据集。将前面的 670 个数据用来训练模型,最后 2 个月的 61 个数据用作测试。经归一化处理的上网日电量数据见图 4。

根据式(1),在 AIC 值最小情况下的阶次作为最终模型阶次,最终阶次取 13,即用 $\{y(t-1), y(t-2), \dots, y(t-13)\}$ 来预测 $y(t)$,构建的 RBF-AR 模型结构如下:

$$\begin{cases} y(t) = \phi_0(\mathbf{X}(t-1)) + \sum_{i=1}^{13} \phi_{y,i}(\mathbf{X}(t-1))y(t-i) + e(t) \\ \phi_0(\mathbf{X}(t-1)) = c_0^0 + \sum_{k=1}^m c_k^0 \exp\{-\lambda_k^y \|\mathbf{X}(t-1) - \mathbf{Z}_k\|_2^2\} \\ \phi_{y,i}(\mathbf{X}(t-1)) = c_{i,0}^y + \sum_{k=1}^m c_{i,k}^y \exp\{-\lambda_k^y \|\mathbf{X}(t-1) - \mathbf{Z}_k\|_2^2\} \\ \mathbf{X}(t-1) = [y(t-1), y(t-2), \dots, y(t-13)]^T \end{cases} \quad (21)$$

得出测试模型的预测值与实际值如图 5 所示,从图 5 可以看出,预测值能准确跟踪实际值的变化趋势。表 3 给出了 RBF-AR(13,3,5)模型与 LSM 及 BP 算法对比的预测结果。LSM 的阶次为 13。BP 结构是 13-25-1,迭代 60000 次。从表 3 中可以看出 RBF-AR 模型的预测结果优于其他 2 种算法。




图3 测试数据的实际值与预测值比较

Fig.3 Comparison between actual values and predicted values of testing data

表 2 测试数据使用不同算法计算出的性能指标

Table 2 Performance metrics of different algorithms for the testing data

模型	运行时间/s	$Q_{MSE} \times 10^{-3}$	$Q_{RMSE} \times 10^{-2}$	Q_{NMSE}
RBF-AR(5,3,5)	8	4.48	6.69	0.360
LSM	2	4.59	6.77	0.365
BP	75	5.40	7.22	0.572




图4 经归一化处理后右岸水电站上网日电量

Fig.4 Daily electricity on the right bank hydropower station after normalized




图 5 测试数据的实际值与预测值比较

表 3 右岸水电站上网日电量预测结果
Table 3 Predicted results of daily electricity data of the right bank Hydropower Station

模型	运行时间/s	$Q_{MSE} \times 10^{-4}$	$Q_{RMSE} \times 10^{-2}$	Q_{NMSE}
RBF-AR(13,3,5)	154	2.95	1.72	0.551
LSM	5	3.29	1.81	0.581
BP	856	3.91	1.98	0.633

5 结 语

状态相依 RBF-AR 模型可以准确地描述工作点时变的非线性系统动态特性。采用 SNPOM 优化方法的 RBF-AR 模型,通过对 RBF 神经网络不同隐含层个数及输入阶次的情况下的预测指标值进行比较,最终选择出合适的 RBF-AR 预测模型。采用 RBF-AR 模型对三峡左岸和右岸水电站的上网日电量进行预测,并将 RBF-AR 模型预测结果与其他经典算法进行比较。通过试验验证得出 RBF-AR 模型在均方差等性能指标上具有一定的优势。论文所采用的预测方法对企业上网日电量进行合理调度具有一定的参考价值。

参考文献:

[1] 刘红岭, 蒋传文, 张焰. 基于随机规划的水电站中长期合约电量优化策略[J]. 中国电机工程学报, 2010, 30(13):101-108. (LIU Hongling, JIANG Chuanwen, ZHANG Yan. Optimal determination of long-term and mid-term contracts for a hydropower producer based on stochastic programming[J]. Proceedings of the CSEE,2010,30(13):101-108. (in Chinese))

[2] 卫志农, 王丹, 孙国强,等. 基于级联神经网络的短期负荷概率预测新方法[J]. 电工技术学报, 2005, 20(1):95-98. (WEI Zhinong, WANG Dan, SUN Guoqiang, et al. A novel method of short time load probability forecasting based on cascaded neural network[J]. Transactions of China Electrotechnical Society,2005,20(1):95-98. (in Chinese))

[3] DEDINEC A, FILIPOSKA S, DEDINEC A, et al. Deep belief network based electricity load forecasting: an analysis of Macedonian case[J]. Energy, 2016, 115:1688-1700.

[4] 王娜, 邵霞, 高云鹏,等. 基于区域信息融合的风电场平均年发电量预测[J]. 湖南大学学报(自然科学版), 2015(8):81-85. (WANG Na, SHAO Xia, GAO Yunpeng, et. al. Average annual energy output prediction based on regional information fusion [J]. Journal of Hunan University (Natural Sciences), 2015(8):81-85. (in Chinese))

[5] 朱琳琳, 钟志峰, 严海,等. 一种新的光伏发电预测模型设计[J]. 太阳能学报, 2016, 37(1):63-68. (ZHU Linlin, ZHONG Zhifeng, YAN Hai, et al. A new design of photovoltaic power generation forecasting model[J]. Acta Energiæ Solaris Sinica,2016,37(1):63-68. (in Chinese))

[6] ZHANG Y, LI C, LI L, et al. Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods [J]. Applied Energy, 2017, 190:291-305.

[7] PENG H, OZAKI T, TOYODA Y, et al. RBF-ARX model-based nonlinear system modeling and predictive control with application to a NO x, decomposition process [J]. Control Engineering Practice, 2004, 12(2):191-203.

[8] PENG H, WU J, INOUSSA G, et al. Nonlinear system modeling and predictive control using the RBF nets-based quasi-linear ARX model [J]. Control Engineering Practice, 2009, 17(1):59-66.

[9] 甘敏, 彭辉. 基于带回归权重 RBF-AR 模型的混沌时间序列预测[J]. 系统工程与电子技术, 2010, 32(4):820-824. (GAN Min, PENG Hui. Predicting chaotic time series using RBF-AR model with regression weight[J]. Systems Engineering and Electronics,2010,32(4):820-824. (in Chinese))

[10] QIN Y, PENG H, ZHOU F, et al. Nonlinear modeling and control approach to magnetic levitation ball system using functional weight rbf network-based state-dependent arx model [J]. Journal of the Franklin Institute, 2015, 352(10):4309-4338.

[11] 覃业梅, 彭辉, 阮文杰. 基于线性函数型权重的 RBF-ARX 模型的磁悬浮球系统预测控制[J]. 中南大学学报(自然科学版), 2016, 47(8):2676-2684. (TAN Yemei, PENG Hui, RUAN Wenjie. Modeling and predictive control of magnetic levitation ball system based on RBF-ARX model with linear functional weights[J]. Journal of Central South University, 2016, 47(8):2676-2684. (in Chinese))

[12] QIN Y, PENG H, RUAN W, et al. A modeling and control approach to magnetic levitation system based on state-dependent ARX model[J]. Journal of Process Control, 2014, 24(1):93-112.

[13] 曾小勇, 彭辉, 魏吉敏. 基于状态相依 RBF-ARX 模型的非线性预测控制及应用[J]. 系统工程与电子技术, 2012, 34(10):2110-2116. (ZENG Xiaoyong, PENG Hui, WEI Jimin. State-dependent RBF-ARX model based nonlinear predictive control and application [J]. Systems Engineering and Electronics, 2012, 34(10):2110-2116. (in Chinese))

[14] ZHOU F, PENG H, QIN Y, et al. RBF-ARX model-based MPC strategies with application to a water tank system[J]. Journal of Process Control, 2015, 34:97-116.

[15] ZHOU F, PENG H, ZENG X Y, et al. Modeling and control approach to coupled tanks liquid level system based on function-type weight RBF-ARX model[J]. Asian Journal of Control, 2017, 19(2):692-707.


[16] WU J, PENG H, CHEN Q. RBF-ARX model-based modeling and control of quadrotor[J]. IEEE International Conference on Control Applications, 2010, 58:1731-1736.

[17] PENG H, OZAKI T, HAGGAN-OZAKI V, et al. A parameter optimization method for radial basis function type models[J]. IEEE Transactions on Neural Networks, 2003, 14(2):432.

[18] PRIESTLEY M B. State-dependent models: a general approach to non-linear time series analysis[J]. Journal of Time, 1980, 1(1):47-71.

[19] GAN M, LI H, PENG H. A variable projection approach for efficient estimation of RBF-ARX model[J]. IEEE Transactions on Cybernetics, 2015, 45(3):476-482.

(收稿日期:2017-07-30 编辑:张志琴)



· 简讯 ·

江苏省特种机器人技术重点实验室召开第一届学术委员会第一次会议

2017年5月16日,江苏省特种机器人技术重点实验室第一届学术委员会第一次会议在河海大学常州校区召开。学术委员会主任、中国工程院谭建荣院士,副主任、德国汉堡科学院院士张建伟以及梅涛研究员等7名委员出席会议。副校长郑金海教授为学术委员会专家颁发聘书并致辞。会议由学术委员会主任谭建荣院士主持。

河海大学副校长郑金海对出席会议的领导和专家表示欢迎,对他们长期以来给予重点实验室的关心和支持表示感谢。他指出,实验室建设一年多来,研究方向进一步凝练,在人才培养、科学研究、成果转化等方面都取得了一些进展,希望实验室以国家战略和地方经济发展需求为导向,继续发挥河海大学与共建单位的优势,重视学科交叉融合和产业化导向,着力提升自主创新能力,力争在某些关键技术上有所突破,同时进一步加大成果转化力度,扩大在行业的影响力和竞争力,早日建设成为行业一流的技术创新基地、新产品研发基地和高层次人才培养基地,为推动江苏省特种机器人研究和产业发展做出应有的贡献。

与会专家听取了重点实验室主任骆敏舟教授所作的实验室建设工作报告及五年发展规划。专家们充分肯定了重点实验室一年多来取得的成果,认为实验室通过一年多的建设,基础条件得到改善,团队建设成效明显,研究成果初步显现,校企协同扎实推进,社会交流不断扩大。学术委员会希望实验室在下一步建设中要对标建设要求,结合河海大学的学科优势和江苏地方产业,进一步汇聚研究方向,集中团队力量开展优势与特色研究,在水环境、水利、水电等方面加强机器人技术的应用研究,力争产出一些标志性成果;进一步加强人才队伍建设,提升原始创新能力;推进实验室内涵建设,促进科技成果转化,更好地服务于国家战略需求和经济社会发展。

(本刊编辑部供稿)