

基于改进 GMDH 网络的风电场短期风速预测

吴栋梁¹, 王扬¹, 郭创新¹, 杨健²

(1. 浙江大学电气工程学院, 浙江 杭州 310027; 2. 上海市电力公司, 上海 200025)

摘要: 基于 GMDH 神经网络和模糊逻辑理论, 对风电场风速预测进行了深入研究, 提出了一种改进 GMDH 神经网络方法。该方法在传统网络的基础上将神经元模糊化并引入反馈环, 将 GMDH 网络的低维计算能力和模糊逻辑的高维推理能力结合起来用于预测。在进行网络训练时, 采用指数型能量函数作为目标误差函数, 提高了网络收敛速度。通过与 BP 神经网络及传统 GMDH 网络的预测结果相比较, 表明该改进方法能够有效地提高短期风速预测的精度。

关键词: GMDH 网络; 模糊逻辑; 反馈; 短期风速预测

Short-term wind speed forecasting in wind farm based on improved GMDH network

WU Dong-liang¹, WANG Yang¹, GUO Chuang-xin¹, YANG Jian²

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China;

2. Shanghai Municipal Electric Power Company, Shanghai 200025, China)

Abstract: Based on traditional GMDH network and fuzzy logic theory, the wind speed forecasting in wind farm is analyzed and an improved GMDH neural network is proposed. This method introduces feedback loop to the traditional network and makes the neuron fuzzified. The low-level computational ability of GMDH and the high-level reasoning ability of fuzzy logic are combined in the improved network for predicting. Besides, exponential energy function is taken into network training as the objective error function, which improves the speed of network convergence. Comparing the forecasting result by the proposed method with those from BP neural network and traditional GMDH network, the accuracy of the improved method in short-term wind speed forecasting is proved effectively.

Key words: GMDH network; fuzzy logic; feedback; short-term wind speed forecasting

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2011)02-0088-06

0 引言

近年来, 世界范围内掀起了一股智能电网的研究热潮, 作为智能电网的重要组成部分, 风力发电被认为是最有希望大规模应用的可再生能源技术, 国内外对风力发电的研究越来越深入, 相继制订出了很多风电并网导则。然而, 由于风电的随机性较强, 盲目的大规模上网必将导致系统稳定性、电能质量等一系列问题, 严重影响电力系统的正常运行。为了优化风电调度、同时便于风电竞价上网, 除了采用各种电力电子设备和储能设备进行软并网以外, 提高风速预测精度被认为是最为经济有效的方法之一。

目前的风速预测方法主要有时间序列法 (ARIMA)^[1-2]、卡尔曼滤波法^[3]、人工神经网络法 (ANN)^[4-6]、模糊逻辑法 (FL)^[7-8], 以及最新出现的支持向量机 (SVM)^[9]预测法。另外, 很多学

者提出了各种混合模型用于预测研究, 文献[10]将时间序列法与神经网络相结合, 提出了一种滚动式权值调整方法; 文献[11]将时间序列法与卡尔曼滤波算法相结合, 通过时间序列法建立模型进而推导出卡尔曼状态和预测方程; 文献[12]将人工神经网络与空间相关性法相结合用于爱琴海中南部岛屿的风速预测; 文献[13]将禁忌搜索法引入人工神经网络。这些方法都在一定程度上取得了较好的效果。本文将采用改进的模糊 GMDH 网络对浙江沿海某风电场风速进行预测。

GMDH 网络也称为多项式网络, 可通过多层神经元的取舍和权值调整拟合复杂的非线性规律, 由于网络结构能够在训练中不断调整, 该方法常用于各种预测; 而模糊网络能够有效地反映系统的不确定信息。本文将二者的优点结合起来, 采用带反馈的模糊 GMDH 网络对风速时间序列进行研究。

1 GMDH 网络预测

1.1 GMDH 网络结构

GMDH (Group Method of Data Handing) 网络最早由前苏联科学家 Ivakhnenko 提出, 该网络基于多层神经网络的自组织思想, 通过各层网络神经元之间不断二元组合来拟合非线性系统的 K-G 多项式:

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots \quad (1)$$

首先, 系统各输入单元通过交叉组合产生一层活动神经元, 从这些产生的神经元中选择与预测目标值最为接近的部分神经元作为下次网络的输入元, 如此强强结合, 不断竞争选择产生新层, 直到所有新产生的神经元都没有上代更优秀时, 进化过程结束。图 1 为一个训练好的典型 GMDH 网络。

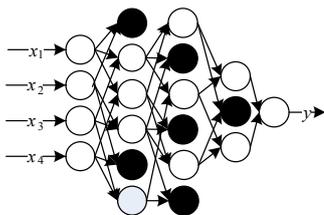


图 1 典型 GMDH 网络

Fig.1 Traditional GMDH network

从图中可以看出, 任一神经元都以上层网络中的两个神经元输出作为其输入, 首先从系统输入变量 $[x_1, x_2, x_3, x_4]$ 开始, 对每一对输入量 $[x_i, x_j]$ 按式(2)进行非线性拟合:

$$\begin{aligned} \mathbf{w}_k &= [w_0, w_1, w_2, w_3, w_4, w_5] \\ \mathbf{x}_k &= [1, x_i, x_i^2, x_i x_j, x_j, x_j^2] \\ y &= \mathbf{w}_k \cdot \mathbf{x}_k^T \end{aligned} \quad (2)$$

其中: \mathbf{w}_k 为各层权系数; \mathbf{x}_k 为输入向量; y 为神经元输出。显然, 四个系统输入两两组合将产生六个新的神经元, 根据 RRMSE 准则, 选择其中拟合效果较好的四个替代系统输入元作为下层网络输入, 删除拟合效果不好的部分 (黑色神经元), 不断重复这一过程, 得到如图 1 的典型 GMDH 网络, 反向回推即可得到复杂的 K-G 多项式, 具体构建过程如图 2 所示。

1.2 网络权值调整

采用 Widrow-Hoff 学习规则

$$\mathbf{w}_{k+1}^T = \mathbf{w}_k^T + \lambda \frac{\mathbf{x}_k}{|\mathbf{x}_k|^2} (\hat{y} - \mathbf{w}_k \cdot \mathbf{x}_k^T) \quad (3)$$

对 GMDH 网络权系数 \mathbf{w}_k 进行调整, 其中 λ 为学习速率, 取值一般在 (0.1, 1) 之间, \hat{y} 为某时刻的实际输出。将数据分为训练样本、测试样本和预测样本, 以历史风速值作为网络输入, 下一时刻风速值作为网络输出, 将训练数据作用于网络, 第一层神经元的均方差之和不再减小时, 停止训练; 再将测试样本作用于网络, 以相对均方误差的均值作为阈值, 大于阈值的神经元被删除^[14], 不再参与第二层网络的生成。

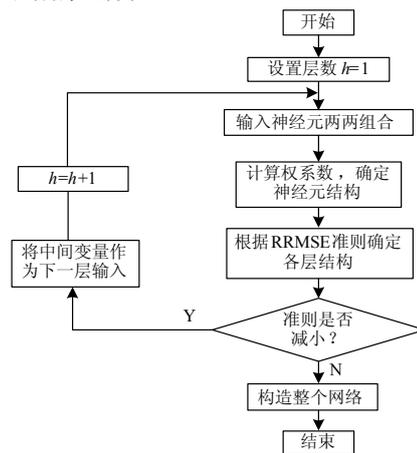


图 2 GMDH 网络构造流程

Fig.2 Flowchart of the GMDH neural network

2 改进的模糊 GMDH 网络预测

2.1 模糊逻辑

模糊逻辑可以通过 IF-THEN 语言规则, 以接近人类思维的方式获取系统的不确定信息, 这些语言规则能够不断地修改更正从而拟合系统的内在规律性。以下 Gauss 函数被选择为隶属函数:

$$\mu_j(x_i) = \exp \left[-\frac{(x_i - c_j)^2}{\sigma_j^2} \right] \quad i = 1, 2, \dots, r, \quad j = 1, 2, \dots, u \quad (4)$$

其中: x_i 为输入变量; c_j 和 σ_j 分别为第 i 个输入元第 j 个隶属函数的中心和宽度; r 为输入变量总数; u 为每个变量对应隶属函数的数量。

T-范数层采用乘积算子, 每个节点代表一个模糊规则的 IF 部分, 该层节点数即为模糊规则数, 第 j 个节点的输出为:

$$v_j = \exp \left[-\sum_{i=1}^r \frac{(x_i - c_j)^2}{\sigma_j^2} \right] \quad j = 1, 2, \dots, u \quad (5)$$

输出层采用上述 TSK 模型, 得到最后的输出为:

$$y = \frac{\sum_{j=1}^u [(a_{j0} + a_{j1}x_1 + \dots + a_{jr}x_r)v_j]}{\sum_{j=1}^u v_j} \quad (6)$$

2.2 带反馈的模糊 GMDH 网络

在传统 GMDH 网络基础上将中间层神经元模糊化, 同时引入反馈环, 就形成了带反馈的模糊 GMDH 网络 (NF-GMDH-FL) [15], 如图 3 所示, 该网络只有三层, 模糊神经元及输出层的参数通过不断循环迭代得到。第一次循环训练中, 将预测点前一时刻的实际值作为反馈输入; 第二次及其之后的循环训练中, 则以上次网络循环的网络输出作为反馈输入, 该反馈的引入能够反映网络预测误差趋势的相关信息, 使得网络参数向着减少误差的方向进行调整, 不断提高预测精度。

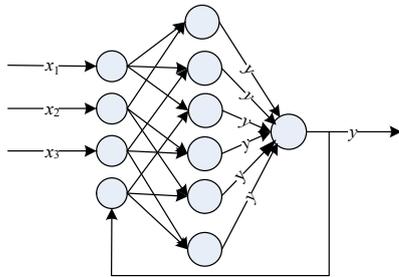


图 3 典型 NF-GMDH-FL 网络
Fig.3 Traditional NF-GMDH-FL network

2.3 网络训练

对于输出层, 采用上述 Widrow-Hoff 学习规则进行权值调整。对于模糊层, 为提高初始阶段收敛速度, 本文在传统的最大梯度法基础上采用了如式 (7) 指数型能量函数 [6] 作为目标误差函数。

$$J = \exp(\beta E) \quad (7)$$

其中: $E = \frac{1}{2} \left(\hat{y} - y \right)^2$, $\beta > 1$ 为参数, 根据 TSK 模型式 (6), 参数 a_{ji} 可按式 (8) 修正。

$$a_{ji}(t+1) = a_{ji}(t) + \begin{cases} \eta_1 \zeta \delta \frac{v_j}{\sum_{j=1}^u v_j}, i = 0 \\ \eta_1 \zeta \delta \frac{x_i v_j}{\sum_{j=1}^u v_j}, i \neq 0 \end{cases} \quad (8)$$

其中: η_1 为学习率; $\delta = -\frac{\partial E}{\partial y} = \hat{y} - y$; $\zeta = \beta \exp(\beta E)$ 。

根据隶属度式 (5), 参数 c_{ij} 和 σ_{ij} 可按式 (9) 和式 (10) 修正:

$$c_{ij}(t+1) = c_{ij}(t) - \eta_2 \zeta \frac{\partial E}{\partial \mu_{ij}} \mu_{ij} \frac{2(x_i - c_{ij})}{\sigma_{ij}^2} \quad (9)$$

$$\sigma_{ij}(t+1) = \sigma_{ij}(t) - \eta_3 \zeta \frac{\partial E}{\partial \mu_{ij}} \mu_{ij} \frac{2(x_i - c_{ij})^2}{\sigma_{ij}^3} \quad (10)$$

$$\text{其中, } \frac{\partial E}{\partial \mu_{ij}} = \frac{\partial E}{\partial v_j} \cdot \frac{\partial v_j}{\partial \mu_{ij}} = \frac{\partial E}{\partial y} \cdot \frac{\partial y}{\partial v_j} \cdot \frac{\partial v_j}{\partial \mu_{ij}} =$$

$$-\delta \cdot \left[(a_{j0} + a_{j1}x_1 + a_{j2}x_2) - \frac{\sum_{j=1}^u [(a_{j0} + a_{j1}x_1 + a_{j2}x_2)v_j]}{\left(\sum_{j=1}^u v_j\right)^2} \right] \cdot \prod_{i \neq j} \mu_{ij}$$

采用 NF-GMDH-FL 进行预测时, 需将样本分为训练样本和预测样本, 训练样本用作参数调整和测试, 相对均方根误差 *RRMSE* 为:

$$RRMSE = \left(\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n \hat{y}_i^2} \right)^{\frac{1}{2}} \quad (11)$$

其中: \hat{y}_i 和 y_i 分别为第 i 个实测值和预测值; n 为预测点个数。当 *RRMSE* 变小时, 记录下各个权值, 变大时不做改变, 达到设定迭代次数时停止训练。

3 算例分析

3.1 原始数据分析

本文以浙江沿海某风电场 2007 年 9 月 1 日至 2007 年 11 月 29 日的风速数据对上述方法进行仿真研究。该风电场的风速变化存在明显的非线性, 该时段内最大最小风速分别为 48.4 m/s、0.4 m/s。以下分别进行半小时和 1 小时风速预测, 半小时预测中, 以 9 月 1 日至 21 日风速 (共 1 008 组) 作为训练数据, 对 9 月 22 日至 25 日共 192 个风速点进行预测; 1 小时预测中, 以 9 月 1 日至 11 月 25 日风速 (共 2 064 组) 作为训练数据, 对 11 月 26 日至 29 日共 96 个风速点进行预测。

3.2 GMDH 网络输入变量选择

为了运用上述改进的 GMDH 网络对风电场风速建模, 首先需要选择合适的历史数据点作为输入变量, 可利用 ARIMA 模型对原始数据进行分析, 选择相关性最大的历史点, ARIMA(p, d, q) 模型可表示为:

$$\varphi(B)(1-B)^d x_t = \theta(B)a_t$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

式中: a_t 为正态白噪声; B 为移位算子。以半小时预测为例, 前 1 008 个点的风速序列 x_0 和前 20 个自相关函数值如图 4 所示, 可见, 自相关系数不能快速衰减到零, 第 20 位的自相关系数仍达到 0.811 6, 原始风速序列非平稳, 需进行平稳化处理。

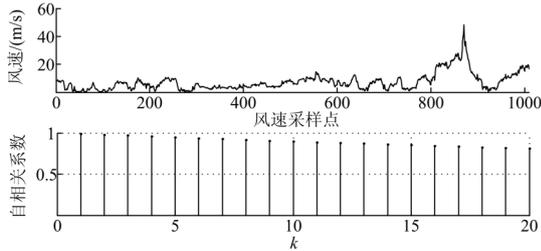


图 4 x_0 序列及其前 20 个自相关系数

Fig.4 The first twenty self-correlation coefficients for x_0 series

经过对原始风速序列 x_0 进行二阶差分变换, 得到差分后序列 x_2 及其前 20 个自相关系数如图 5 所示, 由图可知, 经过二阶差分后数据不断振荡, 自相关系数能够较快衰减到零, 说明序列已经平稳。

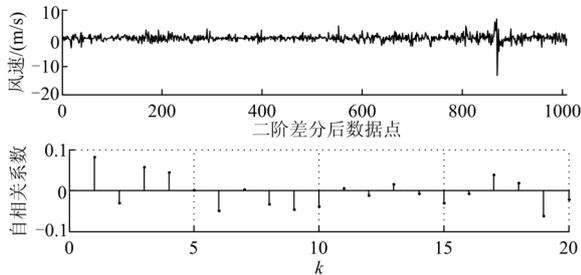


图 5 x_2 序列及其前 20 个自相关系数

Fig.5 The first twenty self-correlation coefficients for x_2 series

根据以上分析可将模型识别为 ARIMA($p, 2, q$), 进一步对 $p=0, 1, 2, 3; q=0, 1, 2, 3$ 的多组可能的阶数进行参数估计和模型检验, 考虑到平稳性和可逆性条件, 运用 SPSS 统计软件, 根据 AIC 准则将模型确定为 ARIMA(2, 2, 1)。

由于风速与气象因素相关性较大, 因此, 将温度也作为输入变量, 提高预测精度。整个时段的温度变化趋势如图 6 所示, 可以看到温度随时间存在明显的线性和周期变化趋势。

综上, GMDH 网络的输入量可确定为最近 4 个历史值、温度值、最近一个残差值及预测值 (反馈输入), 将下一时刻的风速作为其输出。

3.3 训练和预测结果

将输入历史风速数据模糊化, 经过多次试验, 将最佳模糊规则数选为 3, 初始隶属函数如图 7 所示, 当风速大于和小于均值时, 每一个隶属函数都采用了不同的方差, 相应地, 在进行网络权值训练时, 需要分别加以调整。

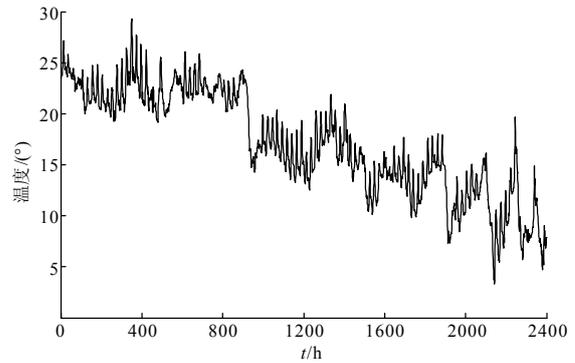


图 6 温度变化曲线

Fig.6 Curve of the changing temperature

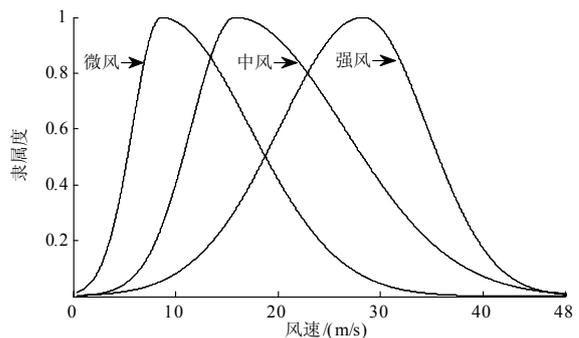


图 7 风速的隶属函数

Fig.7 The membership function of wind speed

将风速数据按照式 (12) 进行归一化处理。

$$x_{\text{norm}} = 0.1 + 0.9 \times (x_0 - x_{0\text{min}}) / (x_{0\text{max}} - x_{0\text{min}}) \quad (12)$$

式中: x_0 为实际负荷数据值; $x_{0\text{max}}$ 为历史负荷数据的最大值; $x_{0\text{min}}$ 为历史负荷数据的最小值; x_{norm} 为经过归一化处理的负荷数据。经过归一化处理, 能够有效地避免网络训练中出现过拟合。

训练过程中, 参数 β 取 1.8, λ 取 0.01, η_1, η_2, η_3 取 0.001, 进行 200 次迭代, 相对均方差能保持基本稳定。分别以 E 和 J 作为误差目标函数时, $RRMSE$ 的变化趋势如图 8 所示, 可见, 后者能够在初始阶段明显地提高网络收敛速度。 $RRMSE$ 最小值出现在第 95 次迭代处, 记录此时的网络参数, 对后 4 天风速进行预测。

为了验证方法的有效性, 分别采用 BP 神经网络以及传统 GMDH 网络进行预测, 不断进行实验

得到最佳的网络结构和训练参数,对相同时间段进行预测,三种方法以及实测风速曲线如图 9 所示。可见改进的模糊 GMDH 网络能够明显提高预测精度。

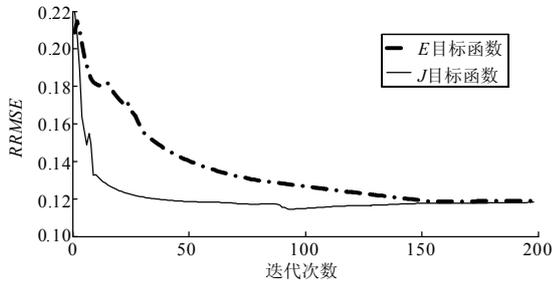


图 8 不同目标函数下 RRMSE 收敛曲线

Fig.8 The convergence curves of using two different objective functions

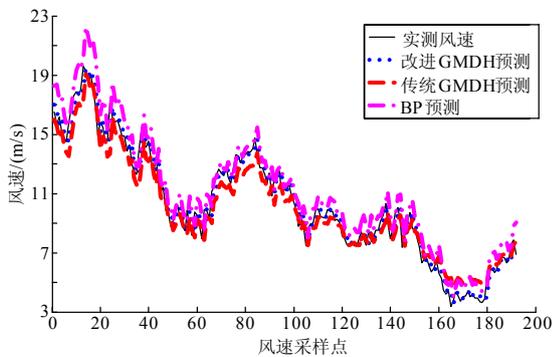


图 9 半小时风速预测结果

Fig.9 The results of half-hour wind speed forecasting

为方便理解起见,假设某日的半小时风速预测结果为 y_1, y_2, \dots, y_{48} , 则按照式 (11) 便可以求出该日预测结果的相对均方差 RRMSE, 此时, $n=48$ 。表 1 列出了该风电场 2007 年 9 月 22 日至 25 日风速预测 RRMSE 的详细比较结果。从表中可以看出, BP 算法对后 4 天风速预测的相对均方误差为 11.40%, 采用 GMDH 算法提高了大约 2.6% 左右, 采用本文提出的改进模糊 GMDH 算法, 预测结果进一步提高了 2%, 可达到 6.82%。

表 1 半小时风速预测误差比较

Tab.1 Comparison of the half-hour wind speed forecasting errors

日期	RRMSE / %					
	BP 网络		传统 GMDH		改进 GMDH	
2007	风速	风电	风速	风电	风速	风电
9.22	11.47	8.10	7.89	8.47	6.14	6.27
9.23	8.65	11.58	9.09	12.25	6.76	9.09
9.24	11.21	16.70	7.10	10.58	6.79	10.09
9.25	18.17	33.63	14.90	27.58	10.33	19.13
均值	11.40	12.63	8.82	11.33	6.82	8.61

对于 1 小时预测, 网络的建模、训练和预测过程与半小时预测相同, 只是样本数据量不同, 为节约篇幅, 只给出预测曲线和误差比较, 如图 10 和表 2 所示。

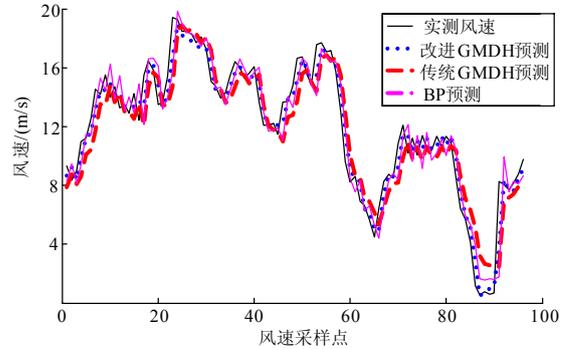


图 10 1 小时风速预测结果

Fig.10 The results of one-hour wind speed forecasting

从图 10 中可看出, 改进 GMDH 网络的预测精度相对较高, 在 11 月 29 日的风速低谷突变时段, 改进网络的预测效果明显好于其他两种方法, 说明该网络能够较好地处理风速的强波动性, 有效提高了预测的精度。对比表 1 和表 2 可以看出, 在半小时预测中, GMDH 预测误差小于 BP 网络; 而在 1 小时预测中, GMDH 预测误差却大于 BP 网络。这可能是由于随着预测时段和系统复杂度的增加, 传统 GMDH 网络在构建过程中删除了对预测效果影响较大的神经元, 导致预测效果没有 BP 网络平稳, 泛化能力下降较快, 而改进的 GMDH 网络则克服了该缺陷, 通过增加反馈输入和模糊化处理提高了网络本身的复杂度, 预测精度较为稳定准确。

表 2 1 小时风速预测误差比较

Tab.2 Comparison of one-hour wind speed forecasting errors

日期	RRMSE / %					
	BP 网络		传统 GMDH		改进 GMDH	
2007	风速	风电	风速	风电	风速	风电
11.26	11.75	13.41	12.95	14.38	7.63	8.39
11.27	6.63	7.71	7.49	8.71	4.20	4.93
11.28	11.43	13.35	13.73	16.45	8.30	9.62
11.29	21.95	26.47	23.98	27.81	14.40	19.93
均值	11.78	13.44	13.25	14.92	7.68	9.34

由于风电的并网调度需要预测风电出力, 本文对此做了进一步研究, 该风电场的切入、切出以及额定风速分别为 3 m/s、25 m/s 和 16 m/s。根据风速预测数据和风电机组概率特性曲线, 得到风电出力的预测结果, 三种方法的预测误差结果也同时列于表 1 和表 2 中, 可见, 改进 GMDH 网络的预测精

度更高, 但风电预测误差总是大于相应的风速预测误差, 这是由于风速和风电之间存在着非线性的对应关系, 使得风电的规律性比风速更差, 因而预测精度相对较低。

4 结论

(1) 本文在传统 GMDH 网络基础上引入模糊逻辑和反馈环, 将数据信息和语义信息相结合, 该混合算法用于浙江沿海某风电场风速预测, 通过与传统 GMDH 网络及 BP 神经网络进行比较, 表明通过较小的改进能够明显提高风速预测的精度。

(2) 通过引入指数型能量函数作为目标函数, 在网络训练之初, 误差 E 较大, 误差下降速度较快, 且容易跳出局部最优; 当训练一定次数之后, 误差减小, 此时误差下降速度也变小, 收敛过程平稳。试验证明, 该方法能够有效地提高收敛速度。

(3) 任何预测方法都可能突破预测对象本身的规律性所限定的预测精度极限^[16]。由于风速的本身规律性较弱, 大幅度提高风速预测精度较为困难, 但是目前的预测精度尚未达到极限, 通过深入研究, 预测精度尚可进一步提高。

参考文献

- [1] 丁明, 张立军, 吴义纯. 基于时间序列分析的风电场风速预测模型[J]. 电力自动化设备, 2005, 25 (8): 32-34.
DING Ming, ZHANG Li-jun, WU Yi-chun. Wind speed forecast model for wind farms based on time series analysis[J]. Electric Power Automation Equipment, 2005, 25 (8): 32-34.
- [2] 陈友, 王晔, 李渝曾. 一种用于短期电价预测的分时段时间序列传递函数模型[J]. 电力系统保护与控制, 2008, 36 (16): 1-4.
CHEN You, WANG Xian, LI Yu-zeng. Electricity price forecasting based on transfer function models for period-decoupled time series[J]. Power System Protection and Control, 2008, 36 (16): 1-4.
- [3] Anders Malmberg, Ulla Holst, Jan Holst. Forecasting near-surface ocean winds with Kalaman filter techniques[J]. 2005, 32 (3): 273-291.
- [4] 郭伟伟, 刘家学, 马云龙, 等. 基于改进 RBF 网络算法的电力系统短期负荷预测[J]. 电力系统保护与控制, 2008, 36 (23): 45-48.
GUO Wei-wei, LIU Jia-xue, MA Yun-long, et al. Optimal algorithm of electric power system's short-term load forecasting based on radial function neural network[J]. Power System Protection and Control, 2008, 36 (23): 45-48.
- [5] 懂安正, 赵国藩. 人工神经网络在短期资料风速估计方面的应用[J]. 工程力学, 2003, 20 (5): 10-13.
DONG An-zheng, ZHAO Guo-fan. Application of artificial neural networks in wind speed estimation from short-term records[J]. Engineering Mechanics, 2003, 20 (5): 10-13.
- [6] 何述东, 瞿坦, 黄心汉. 电力负荷短期预测的改进神经网络方法[J]. 电力系统自动化, 1997, 21(11): 13-15.
HE Shu-dong, QU Tan, HUANG Xin-han. Using improved neural network for short-term load forecasting[J]. Automation of Electric Power Systems, 1997, 21 (11): 13-15.
- [7] Mohammad Monfared, Hasan Rastegar, Hossein Madadi Kojabadi. A new strategy for wind speed forecasting using artificial intelligent methods[J]. Renewable Energy, 2009, 34 (3): 845-848.
- [8] Johnson P L, Negnevitsky Michael, Muttaqi K M. Short term wind power forecasting using adaptive neuro-fuzzy inference system[C]. //Australasian Universities Power Engineering Conference. Perth(Australia): 2007.
- [9] 刘庆彪, 张步涵, 王凯, 等. 电价预测的自适应支持向量机方法研究[J]. 电力系统保护与控制, 2008, 36(22): 34-39.
LIU Qing-biao, ZHANG Bu-han, WANG Kai, et al. Short-term load forecasting based on chaotic characteristic of loads and least squares support vector machines[J]. Power System Protection and Control, 2008, 36(22): 34-39.
- [10] 杨秀媛, 肖洋, 陈树勇. 风电场风速和发电功率预测研究[J]. 中国电机工程学报, 2005, 25 (11): 1-5.
YANG Xiu-yuan, XIAO Yang, CHEN Shu-yong. Wind speed and generated power forecasting in wind farm[J]. Proceedings of the CSEE, 2005, 25 (11): 1-5.
- [11] 潘迪夫, 刘辉, 李燕飞. 基于时间序列分析和卡尔曼滤波算法的风电场风速预测优化模型[J]. 电网技术, 2008, 32 (7): 82-86.
PAN Di-fu, LIU Hui, LI Yan-fei. A wind speed forecasting optimization model for wind farms based on time series analysis and kalman filter algorithm[J]. Power System Technology, 2008, 32 (7): 82-86.
- [12] Alexiadis M C, Dokopoulos P S, Sahsamanoglou H S, et al. Short-term forecasting of wind speed and related electrical power[J]. Solar Energy, 1998, 63 (1): 61-68.
- [13] HAN Shuang, LIU Yong-qian, YANG Yong-ping. Taboo search algorithm based ANN Model for wind speed prediction[C]. // Proceedings of 2007 IEEE Conference on Industrial Electronics and Applications. Piscataway (United States): 2007: 2599-2602.
- [14] 赵小梅, 宋执环, 李平. 改进的 GMDH 型神经网络及其在混沌预测中的应用[J]. 电路与系统学报, 2002, 7 (1): 13-17.
ZHAO Xiao-mei, SONG Zhi-huan, LI Ping. The improved GMDH-type neural network and its application to forecasting chaotic time series[J]. Journal of Circuits and System, 2002, 7 (1): 13-17.

(下转第 111 页 continued on page 111)

网电能质量监控系统实现了电能质量的自动实时监控。系统不同地点多个装置同时触发、同步监控,能够对谐波的出现实现实时录入加以分析,对改善局部电网的电能质量起到技术支撑作用。

本监控系统加强对谐波源的监控;对数据做进一步挖掘分析处理,实现构建层次分明、拓展性强的电能质量监测系统,为电网决策人员提供数据。

参考文献

- [1] 程浩忠, 艾芊. 电能质量[M]. 北京:清华大学出版社, 2006.
CHEN Hao-zhong, AI Yu. Power quality[M]. Beijing: Tsinghua University Press, 2006.
- [2] 林海雪. 现代电能质量的基本问题[J]. 电网技术, 2001, 25(10): 5-12.
LIN Hai-xue. The basic problem of modern power quality[J]. Network Technology, 2001, 25(10): 5-12.
- [3] 裴林, 郑建辉, 孙怡. 电能质量综合监测管理系统的研究[J]. 电力系统保护与控制, 2008, 36(23): 49-53.
PEI Lin, ZHENG Jian-hui, SUN Yi. Study on power quality comprehensive monitoring and management system[J]. Power System Protection and Control, 2008, 36(23): 49-53.
- [4] 王东滨, 方滨兴, 云晓春. 基于 Web 管理的网络监测技术的设计与实现[J]. 计算机, 2005(10): 4-9.
WANG Dong-bin, FANG Bin-xing, YUN Xiao-chun. Based on the management of network monitoring technology Web design and implementation[J]. Computer, 2005 (10): 4-9.
- [5] 孙毅, 龚钢军. 电能质量在线监测系统的设计和实现[J]. 继电器, 2004, 32(17): 60-63.
SUN Yi, GONG Gang-jun. Design and realization of on line monitoring system of power quality[J]. Relay, 2004, 32(17): 60-63.
- [6] IEEE Std 519-1992. IEEE recommended practices and requirements for harmonic control in electrical power systems[S]. 1993.
- [7] 冯红岩, 赵双喜, 张建成, 等. 基于双 CPU 的电能质量监测系统设计与实现[J]. 继电器, 2006, 34(7): 61-64.
FENG Hong-yan, ZHAO Shuang-xi, ZHANG Jian-cheng,

- et al. Design and implementation of a power quality monitoring system based on dual CPUs[J]. Relay, 2006, 34(7): 61-64.
- [8] 邹宏亮, 周晨, 郑远德. 基于嵌入式 internet 技术的变电站监控系统[C]. //2008 年电力系统保护与控制学术研讨会.
ZOU Hong-liang, ZHOU Chen, ZHENG Yuan-de. Based on embedded Internet technology of substation system[C]. // Power System Protection and Control Aeminar. 2008
- [9] 卢海南, 董超, 赵录怀. 电能质量监测的发展趋势与新型电能质量监测仪的研制[J]. 2004.
LU Hai-nan, DONG Chao, ZHAO Lu-huai. The development trend of electric power quality monitoring and new power quality monitor[J]. 2004.
- [10] 陈巨涛. ARM+DSP 嵌入式仿真平台的开发及其在实时仿真中的应用[D]. 上海: 上海海事大学, 2004.
CHEN Yi-tao. ARM + DSP embedded simulation platform development and its application in real-time simulation[D]. Shanghai: Shanghai Maritime University, 2004.
- [11] 刘敦敏, 孙云痊. B/S 模式的电力技术监督管理系统权限管理的实现[J]. 计算机应用工程, 2002, 28(10): 203-204, 279.
LIU Dun-min, SUN Yun-shuan. B/S model of electric power system of technological supervision and administration implementation[J]. The Computer Application, 2002, 28(10): 203-204, 279.
- [12] 马冲, 江贺, 冯静芳. 软件体系结构理论与实践[M]. 北京: 人民邮电出版社, 2004.
MA Chong, JIANG He, FENG Jing-fang. Software architecture theory and practice[M]. Beijing: The People's Posts and Telecommunications Press, 2004.

收稿日期: 2009-08-03; 修回日期: 2010-09-18

作者简介:

王 玲(1983-), 女, 助理工程师, 工学硕士, 从事互感器技术研究; E-mail: wl00532@tom.com

康 健(1982-), 男, 助理馆员, 工学学士, 从事数据挖掘研究;

邹宏亮(1982-), 男, 工学硕士, 从事电力系统研究。

(上接第 93 页 continued from page 93)

- [15] 楼玉, 赵小梅, 刘国华. 具有改进反馈环的 NF-GMDH 网络及其在混沌预测中的应用[J]. 电路与系统学报, 2004, 9(5): 86-90.
LOU Yu, ZHAO Xiao-mei, LIU Guo-hua. The NF-GMDH with improved feedback loop network and its application to the prediction of chaotic time series[J]. Journal of Circuits and System, 2004, 9(5): 96-90.
- [16] 于尔铿, 刘广义, 周京阳, 等. 能量管理系统[M]. 北京: 科技出版社, 1998.

作者简介:

吴栋梁(1987-), 男, 硕士研究生, 主要研究方向为分布式发电, 电力系统风险评估; E-mail: wudonglianghd@126.com

王 扬(1983-), 男, 博士研究生, 主要研究方向为分布式发电, 数据挖掘技术及其在电力系统中的应用, 电力系统信息化;

郭创新(1969-), 男, 教授, 博士生导师, 主要研究方向为智能信息处理技术及其在电力系统中的应用。

收稿日期: 2010-01-27; 修回日期: 2010-03-12