

基于改进的小波-BP神经网络的风速和风电功率预测

肖 迁, 李文华, 李志刚, 刘金龙, 刘会巧

(电磁场与电器可靠性省部共建重点实验室(河北工业大学), 天津 300130)

摘要: 为了提高超短期风电功率预测精度, 使用改进的小波-BP神经网络方法进行研究。针对预测模型普遍存在的延时问题, 先通过离散小波变换将信号分解为高低频段的信号, 再用遗传算法优化的BP神经网络分别进行建模, 最后求和各层预测信号。由于功率和风速具有混沌特性, 用C-C法联合优化重构相空间的参数, 以嵌入维数为神经网络输入层节点数。应用于山东某风电场, 仿真结果表明, 与BP神经网络模型相比, 该算法预测风速和功率精度较高, 但风速预测值经过实际功率曲线转换后, 功率预测精度变差。

关键词: 小波分析; 相空间重构; C-C法; 遗传算法; 神经网络; 功率曲线转换法

Wind speed and power prediction based on improved wavelet-BP neural network

XIAO Qian, LI Wen-hua, LI Zhi-gang, LIU Jin-long, LIU Hui-qiao

(Province-Ministry Joint Key Laboratory of Electromagnetic Field and Electrical Apparatus Reliability (Hebei University of Technology), Tianjin 300130, China)

Abstract: In order to improve the forecasting accuracy of ultra-short-term wind power, the improved wavelet-BP neural network method is applied. To solve the widespread delay problems of the prediction model, the original signal is decomposed into high and low frequency signal by the discrete wavelet transform. Moreover, genetic algorithm is used to optimize the BP neural network model separately. Finally, the summation of all the prediction results is gotten. As the wind speed and power series have chaos characteristics, the C-C method is used to optimize parameters of phase space reconstruction and the embedded dimension is taken as the input layer's node number of neural network. It is applied in a wind farm, in Shandong Province, and the simulation results show that it has higher prediction accuracy than BP neural network model in forecasting wind speed and power. With the conversion of wind speed prediction results by the measured power curve, the power prediction accuracy goes bad.

This work is supported by National Natural Science Foundation of China (No. 51377044).

Key words: wavelet analysis; phase-space reconstruction; C-C method; genetic algorithm; neural network; power curve conversion method

中图分类号: TM614 文献标识码: A 文章编号: 1674-3415(2014)15-0080-07

0 引言

由于风的波动性和间歇性, 大容量风电场的并网会对电网运行产生较大的冲击甚至危险。国标《风电场接入电力系统技术规定》明确要求风电场应配置风电功率预测系统, 滚动上报超短期15 min~4 h风电功率预测曲线。为了保障电网的安全稳定运行, 对风电功率进行预测是非常必要的^[1]。对风电功率超短期预测主要用于风力发电控制、电能质量评估及加强系统的经济运行等^[2-3]。

风电场风电功率预测可以分为两类, 一是直接预测法, 二是功率曲线转换法, 即先经过预测风速, 然后转换得到功率预测值^[4]。近年来, 许多学者对风电功率预测进行了研究, 并取得了一系列的成果。文献[5]用混沌DNA遗传算法确定脊波神经网络的隐层结构, 然后用粒子群算法优化, 得到分辨率为30 min的未来24 h的功率预测值。文献[6]基于ARIMA时间序列模型对超短期功率进行了预测研究, 功率预测每5 min自动预测一次, 自动滚动执行。文献[7]用数据挖掘和模糊聚类技术将东北某风电场50台风机机组进行分类, 应用于实时功率预测。文献[8]基于空间相关法与支持向量机方法, 建立了

基金项目: 国家自然科学基金项目(51377044)

风速多步预测混合模型, 仿真图显示组合模型提高了预测精度。文献[9]考虑传统 BP 的固有缺陷, 将相似日数据输入到 Chebyshev 神经网络模型中, 从而得到预测功率值。文献[10]中取最近两天的同一时刻的数据和数值天气预报数据作为输入层, 使用小波-BP 神经网络模型得到未来 24 h 的功率值。文献[11]用风电功率的影响因素(风速、风向、气温、气压、湿度)作为输入因子, 建立 BP 神经网络, 进行了提前 30 min 和 1 h 的功率预测。由于目前很多风电场还没有数值天气预报系统, 且超短期预测功率点的间隔时间短, 气象变化不明显, 本文仅对自身的历史数据进行研究, 挖掘内在的规律性, 以提高超短期功率预测精度。考虑到 BP 网络具有良好的非线性逼近能力、结构较简单、操作性强等优点^[12], 本文基于 BP 网络来研究。但是 BP 网络输入层节点数的选取具有很大的盲目性和主观性, 如文献[13]中选取只是以提前 1h 的历史数据作为输入层, 本文用混沌相空间重构理论来给予理论指导。而 BP 神经网络存在收敛速度慢, 易陷入局部极小值点等缺陷, 故可以借助遗传算法的全局寻优特性来确定最优初始权值和阈值。针对预测模型普遍存在的延时问题, 可以使用小波分析法进行前处理, 即本文使用改进的小波-BP 神经网络用来进行风速和风电功率预测。再根据预测的风速值和实际运行的功率曲线, 也可以转换得到功率预测值。

1 算法介绍

1.1 小波分析

若信号 $s(t)$ 平方可积, 则其连续小波变换为

$$W_s(a, b) = \langle s, \Psi_{a,b} \rangle = |a|^{-\frac{1}{2}} \int_{-\infty}^{+\infty} s(t) \Psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

式中, $|a|^{-\frac{1}{2}} \Psi\left(\frac{t-b}{a}\right)$ 是由基小波 $\Psi(t)$ 经过平移和伸缩生成的连续小波, a 为伸缩因子, b 为平移因子。连续小波变换可以给出信号在时间-频率平面上一个矩形的时间-频率窗 (TFW):

$$[b+at^* - a\Delta\Psi, b+at^* + a\Delta\Psi] \left[\frac{\omega^*}{a} - \frac{1}{a} \Delta\Psi, \frac{\omega^*}{a} + \frac{1}{a} \Delta\Psi \right] \quad (2)$$

当检测高频信号 (a 较小) 时, TFW 自动变窄, 做细致观测; 当检测低频信号 (a 较大) 时, TFW 自动变宽, 做全局观测, 即在高频处时间细分, 低频处频率细分, 能自动适应时频信号分析的要求^[14]。

在实际应用中, 为方便使用, 可以使用离散小波变换, 将 a 和 b 离散化, 即

$$\Psi_{j,k}(t) = a_0^{-\frac{j}{2}} \Psi(a_0^{-j}t - kb_0)$$

常取 $a_0 = 2$, $b_0 = 1$ 。再用 Mallet 算法, 将信号 $s(t)$ 正交投影到空间 V_j 和 W_j , 得到分辨率 j 下的低频趋势信号 a_j 和 高频波动信号 d_j 。经过 n 层小波分解后, 如图 1 所示, 可知^[15]

$$s = \sum_{j=1}^n d_j + a_n \quad (3)$$

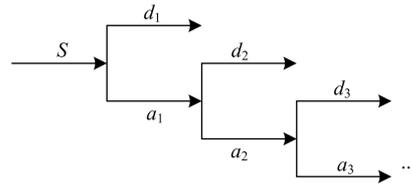


图 1 多层分解结构树

Fig. 1 Multi-decomposition tree

1.2 遗传算法及对 BP 神经网络的优化

遗传算法是模仿自然界生物进化机制发展起来的随机全局搜索和优化方法, 其本质是一种高效、并行、全局搜索方法, 它能够在搜索过程中自动获取和积累有关搜索空间的知识特征, 并自适应地控制搜索工程以求得最优解^[16]。把 BP 神经网络的初始权值和阈值看成种群中的个体(染色体), 并采用实数编码, 一组个体的集合称为种群。适应度函数的值表示个体对环境适应能力的评价, 适应值越大越好。基本遗传算法的三个基本算子是选择、交叉和变异, 将之称为遗传操作, 基本步骤: 1) 选定选择概率大的个体。选择概率是个体适应度占种群的适应值的比例。2) 对个体以交叉概率两两进行交叉操作, 若种群规模是偶数, 则配对成功; 若是奇数, 最后一个个体被直接复制到下一代。3) 对每一染色体以变异概率随机选取染色体中的某一基因进行变异操作, 产生新染色体。当新染色体的适应值增大时, 用新染色体替换原来的染色体。

遗传算法的流程图, 如图 2 所示, 最终把最优个体作为 BP 网络的初始权值和阈值。染色体长度为

$$S = R \cdot S_1 + S_1 \cdot S_2 + S_1 + S_2 \quad (4)$$

式中, R, S_1, S_2 分别为 BP 神经网络输入层、隐含层和输出层的节点数。

个体的适应度函数为

$$F = \frac{1}{\sum_{i=1}^n |y_i - \bar{y}_i|} \quad (5)$$

式中： n 为训练样本数； y_t 和 \bar{y}_t ($t=1,2,\dots,n$) 分别是 BP 神经网络第 t 个训练样本的期望输出值、预测输出值。

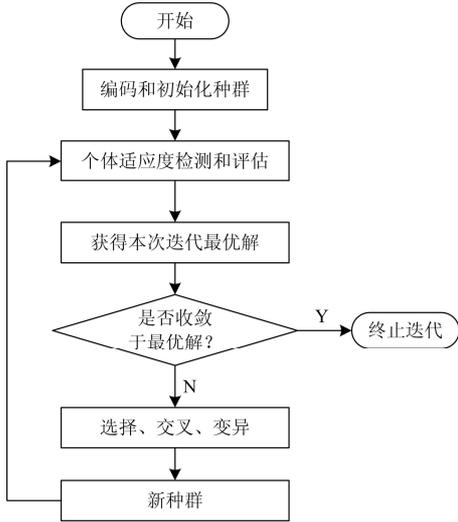


图 2 遗传算法流程图

Fig. 2 Flowchart of genetic algorithm

1.3 混沌相空间重构理论

通过计算风速和功率时间序列的 Laypunov 指数和分数维，判断其是否具有混沌特性。利用混沌相空间重构理论，可还原风电功率时间序列的非线性动力特性。用重构相空间来恢复吸引子的特性，从而把时间序列中蕴藏的信息充分地显露出来^[17]。

对于信号 $\{s_t\}(t=1,2,\dots,n)$ ，进行相空间重构，嵌入维数为 m ，时间延迟为 τ ，则相空间中相点个数 $N=n-(m-1)\tau$ ，重构后的相空间向量 $X_i(i=1,2,\dots,N)$ ，即

$$X_i = [x_i, x_{i+\tau}, x_{i+2\tau}, \dots, x_{i+(m-1)\tau}] \quad (6)$$

为方便操作，减少计算量，可以利用 C-C 方法，其联合考虑了延迟时间和嵌入维数，可同时计算出延迟时间和嵌入时间窗。基本步骤：

1) 对于时间序列 $\{x_i\}, i=1,2,\dots,N$ ，将其分成 t 个不相交的时间子序列，子序列长度 $l=N/t$ 。对于一般的自然数 t ，有

$$\begin{cases} \{x(1), x(t+1), x(2t+1), \dots\} \\ \{x(2), x(t+2), x(2t+2), \dots\} \\ \vdots \\ \{x(t), x(t+t), x(2t+t), \dots\} \end{cases} \quad (7)$$

2) 定义每个子序列的统计量。

$$S(m, N, r, \tau) = \frac{1}{t} \sum_{s=1}^t \{C_s(m, N/t, r, \tau) - C_s(1, N/t, r, \tau)\} \quad (8)$$

式中， C_s 是第 s 个子序列的关联积分。

3) 定义 r 的最大偏差。

$$\Delta S(m, t) = \max\{S(m, r_j, t)\} - \min\{S(m, r_j, t)\} \quad (9)$$

4) 取 $r_i = i\sigma/2, i=1,2,3,4$ ， σ 是时间序列的均方差， $\mathcal{J} \ll \mathcal{M} \ll \mathcal{Z}$ ，计算 3 个统计量。

$$\bar{S}(t) = \frac{1}{16} \sum_{j=1}^4 \sum_{m=2}^5 S(m, r_j, t) \quad (10)$$

$$\Delta \bar{S}(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, t) \quad (11)$$

$$S_{\text{cor}}(t) = \Delta \bar{S}(t) + |\bar{S}(t)| \quad (12)$$

式中： $\Delta \bar{S}(t)$ 的第一个极小值对应最佳延迟时间； $S_{\text{cor}}(t)$ 的最小值对应的时间为最佳嵌入窗宽 τ_w ，且 $\tau_w = (m-1) \cdot \tau$ 。

1.4 改进的小波-BP 神经网络

BP 网络能将系统输入输出问题转化为非线性优化问题，采用梯度下降法，通过反向传播来不断调整网络的权值和阈值，最终使网络的误差平方和最小。根据 Kolmogorov 定理，三层 BP 网络能够以任意精度逼近任意复杂的非线性函数。但是，其训练算法是一个局部寻优算法，它可以保证网络权值可以收敛到一个最终值，但不能保证该值是全局最优解，即该最终值可能是误差超平面上一个局部极小值。对于 BP 自身的缺陷，故可以用遗传算法全局寻优初始权值和阈值，然后再建立 BP 模型。基于混沌相空间重构理论，用 C-C 法联合优化重构相空间的参数，选取嵌入维数为神经网络输入层节点数。

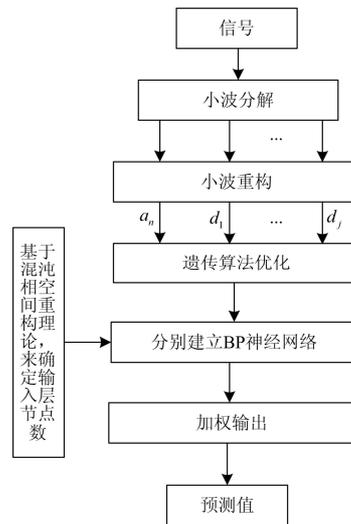


图 3 改进的小波-BP 神经网络流程图

Fig. 3 Flowchart of improved wavelet-BP neural network

由于实测信号的非平稳性, 先用小波分析法进行多尺度分解, 从而获得高低频段的信号, 然后用遗传算法优化的 BP 神经网络对其分别建模预测, 最后加权各层预测数据, 流程图如图 3 所示。

2 算例分析

山东某风电场的单台风机容量为 1 500 kW, 每 10 min 采样 1 次, 使用 5 月 1 日 0 时 6 分到 5 月 26 日 3 时 56 分共 3 624 个样本的风速和功率数据, 用前 3 600 个样本作为训练数据, 后 24 个样本作为测试数据, 来进行未来 4 h 的预测研究。为衡量预测结果, 使用百分比误差 δ 和平均百分比误差 δ' 。

$$\delta = \frac{\hat{y}_t - y_t}{y_t} \quad (13)$$

$$\delta' = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (14)$$

式中: $y_t (t=1, 2, \dots, n)$ 是实际测量值; 而 $\hat{y}_t (t=1, 2, \dots, n)$ 为建立模型的预测值。

2.1 改进的小波-BP 神经网络预测

2.1.1 小波分解和重构

选用 db5 小波对风电场实测的功率信号进行 5 层分解, 用 Mallat 算法对分解后的信号在不同尺度上进行信号重构, 如图 4 所示。

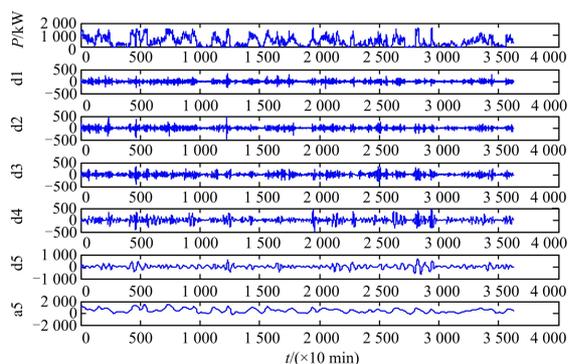


图 4 小波分解结果

Fig. 4 Result of wavelet decomposition

2.1.2 网络结构和参数的确定

功率时间序列 $N=3\ 600$, $t=20$, 计算三个统计量, 如图 5 所示。 $\Delta \bar{S}(t)$ 的第一个极小值时, $t=6$, 则最佳时间延迟 τ 为 6; $S_{\text{cor}}(t)$ 的最小值对应的的时间 $t=19$, 则最佳嵌入窗宽 τ_{ω} 为 19; 由 $\tau_{\omega} = (m-1) \cdot \tau$, 可以取嵌入维数 m 为 5。并用小数据量法计算得到最大 Lyapunov 指数为 0.045 8, 则功率时间序列具有混沌特性^[17]。BP 神经网络输入层节点数确定为 5, 选取对应的前 5 个小波重构的信号作为输入层, 分

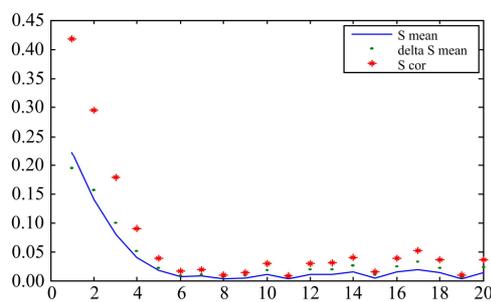


图 5 功率时间序列重构参数

Fig. 5 Power time series reconstruction parameters

别建立 BP 神经网络。

而隐含层节点个数选用试验法, 即取不同节点个数进行预测结果比较, 发现隐含层节点数为 11 时最佳, 即 BP 模型选用 5-11-1 结构。并用遗传算法来优化 BP 神经网络, 染色体长度 $S=78$, 采用实数编码, 初始种群个体取 30, 交叉概率取 0.25, 变异率取 0.1, 最大遗传代数取 100, 最后把最优个体作为 BP 神经网络的初始权值和阈值。BP 模型训练采用梯度下降法, 误差精度为 10^{-6} , 学习率为 0.03。最后对各个加权系数取 1, 即各个序列预测值相加求和就是预测功率值。遗传算法优化后, 模型具有全局学习能力, 效果对比如图 6 和图 7 所示。未来 4 h 的功率预测结果及 δ 误差曲线如图 8 和图 9 所示, 改进方法的 δ' 为 3.51%, 而 BP 的为 13.54%。针对 BP 神经网络的延时和缺陷问题, 改进的小波-BP 神经网络模型基本上解决, 明显优于单纯的 BP 神经网络。同样使用该改进的小波-BP 神经网络法预测风速, 未来 4 h 的风速预测结果及 δ 误差曲线如图 10 和图 11 所示, 改进的方法的 δ' 为 2.53%, 而 BP 的为 12.14%, 进一步验证此算法的有效性。

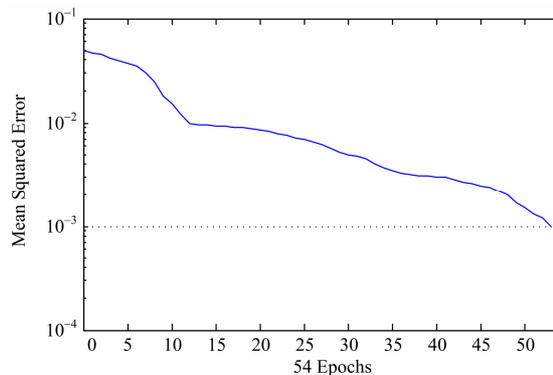


图 6 遗传算法优化的神经网络训练结果

Fig. 6 Training result of neural network optimized by genetic algorithm

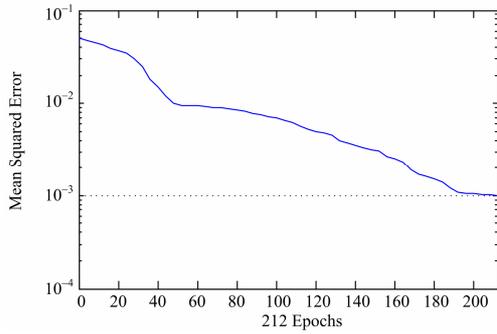


图 7 传统神经网络训练结果

Fig. 7 Training result of traditional neural network

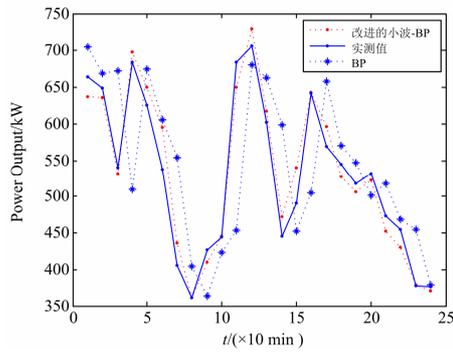


图 8 风电功率预测结果

Fig. 8 Wind power prediction results

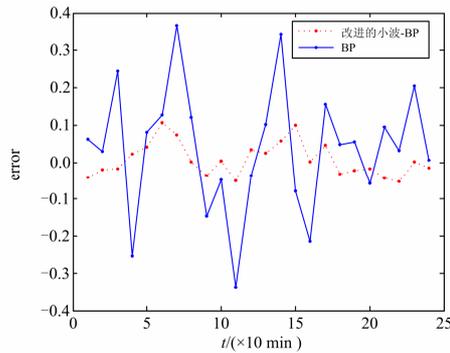


图 9 风电功率预测误差曲线

Fig. 9 Error curves of wind power prediction

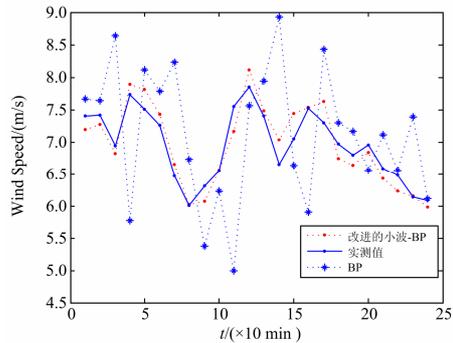


图 10 风速预测结果

Fig. 10 Wind speed prediction results

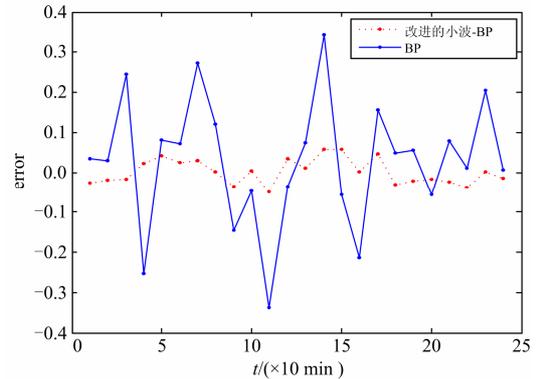


图 11 风速预测误差曲线

Fig. 11 Error curves of wind speed prediction

2.2 由预测的风速转换得到功率

功率曲线形状受空气密度、实际利用率等很多因素的影响，有必要用风机的实际运行功率曲线来进行更准确的功率预测。此风机额定功率 1 500 kW，切入、切出风速和额定风速分别为 3、25、15 m/s。拟合的实际运行曲线如图 12 所示，方程为

$$P(v) = \begin{cases} 0 & v \leq 3 \text{ 或 } v \geq 25 \\ f(v) & 3 < v \leq 15 \\ 1559 & 15 < v < 25 \end{cases} \quad (15)$$

式中， $f(v) = -4.315890455665682 \cdot 10^{-7} \cdot v^{12} + 4.680259123533799 \cdot 10^{-5} \cdot v^{11} - 0.002241194081238 \cdot v^{10} + 0.06240516619975 \cdot v^9 - 1.119904739264209 \cdot v^8 + 13.568919155890569 \cdot v^7 - 113.0597029987166 \cdot v^6 + 647.5493783691807 \cdot v^5 - 2505.882187179473 \cdot v^4 + 6316.34355518394 \cdot v^3 - 9699.733935248032 \cdot v^2 + 8056.852300706899 \cdot v - 2726.92216659118$

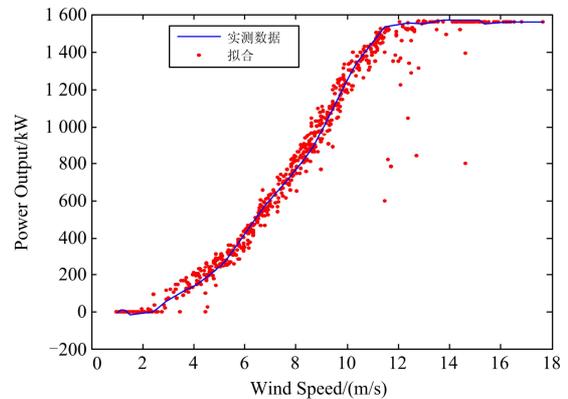


图 12 实际的功率拟合曲线

Fig. 12 Fitting curve of real wind power

将风速预测值代入到此拟合曲线上，通过功率曲线转换间接得到功率值，未来 4 h 的功率预测结果及 δ' 误差曲线如图 13 和图 14 所示， δ' 为 11.61%，

预测精度变差。由于预测的风速值在切入风速和额定风速区间时, 斜率比较大, 较小的风速变化值将导致较大的功率变化值, 这样就使得本来规律性不是很强的风速序列在经过转换后, 功率序列规律性变差, 同时拟合曲线也会有一定的误差, 都将使最终功率预测误差变大。

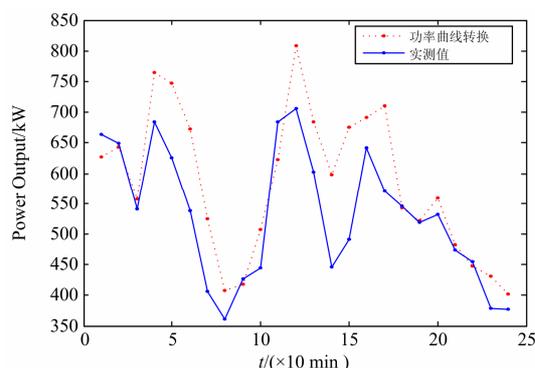


图 13 风电功率预测结果

Fig. 13 Wind power prediction results

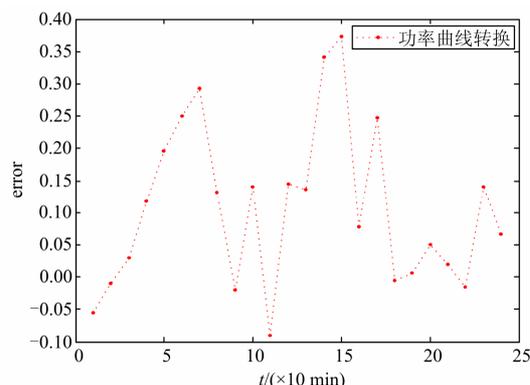


图 14 风电功率预测误差曲线

Fig. 14 Error curves of wind power prediction

3 结论

使用改进的小波-BP 神经网络对山东某风电场进行了未来 4 h 的超短期预测研究, 得出:

1) 基于混沌相空间重构理论, 用 C-C 法联合优化重构相空间的参数, 选取嵌入维数为神经网络输入层节点数, 可以为神经网络输入层节点数的选取提供理论指导。

2) 改进的小波-BP 神经网络, 由于结合遗传算法的全局优化搜索能力、小波分析法的良好时频局部性质和 BP 网络强大的非线性映射能力, 同时基于混沌相空间重构理论来确定输入层节点数, 故模型延时和 BP 缺陷问题等得到改善, 风速和功率的平均百分比误差分别为 2.53%和 3.51%, 预测精度较高, 可以为功率预测系统提供理论基础。

3) 超短期功率预测时, 建议采取直接法预测。由于间接法加入了风速突变的预测误差和功率曲线转换带来的误差, 使得预测精度变差。

参考文献

- [1] FOLEY A M, LEAHY P G Current methods and advances in forecasting of wind power generation[J]. Renewable Energy, 2012, 37: 1-8.
- [2] ERNST B, OAKLEAF B, AHLSTROM M L, et al. Predicting the wind[J]. IEEE Power & Energy Magazine, 2007(11): 79-89.
- [3] POTTER C W, NEGNEVITSKY M. Very short-term wind forecasting for Tasmanian power generation[J]. IEEE Trans on Power Systems, 2006, 21(2): 965-972.
- [4] 王丽婕, 廖晓钟, 高阳, 等. 风电场发电功率的建模和预测研究综述[J]. 电力系统保护与控制, 2009, 37(13): 118-121.
- WANG Li-jie, LIAO Xiao-zhong, GAO Yang, et al. Summarization of modeling and prediction of wind power generation[J]. Power System Protection and Control, 2009, 37(13): 118-121.
- [5] 周洪煜, 曾济贫, 王照阳, 等. 基于混沌 DNA 遗传算法与 PSO 组合优化的 RNN 短期风电功率预测[J]. 电力系统保护与控制, 2013, 41(2): 144-149.
- ZHOU Hong-yu, ZENG Ji-pin, WANG Zhao-yang, et al. Ridgelet neural network model for short-term wind power forecasting based on the combination of chaos DNA genetic and particle swarm optimization algorithm[J]. Power System Protection and Control, 2013, 41(2): 144-149.
- [6] 常康, 丁茂生, 薛峰, 等. 超短期风电功率预测及其在安全稳定预警系统中的应用[J]. 电力系统保护与控制, 2012, 40(12): 19-24.
- CHANG Kang, DING Mao-sheng, XUE Feng, et al. Ultra-short-term wind power prediction and its application in early-warning system of power systems security and stability[J]. Power System Protection and Control, 2012, 40(12): 19-24.
- [7] 杨茂, 熊昊, 严干贵, 等. 基于数据挖掘和模糊聚类的风电功率实时预测研究[J]. 电力系统保护与控制, 2013, 41(1): 1-6.
- YANG Mao, XIONG Hao, YAN Gan-gui, et al. Real-time prediction of wind power based on data mining and fuzzy clustering[J]. Power System Protection and Control, 2013,

- 41(1): 1-6.
- [8] 陈妮亚, 钱政, 孟晓风, 等. 基于空间相关法的风电场风速多步预测模型[J]. 电工技术学报, 2013, 28(5): 15-21.
CHEN Ni-ya, QIAN Zheng, MENG Xiao-feng, et al. Multi-step ahead wind speed forecasting model based on spatial correlation and support vector machine[J]. Transactions of China Electrotechnical Society, 2013, 28(5): 15-21.
- [9] 孟洋洋, 卢继平, 孙华利, 等. 基于相似日和人工神经网络的风电功率短期预测[J]. 电网技术, 2010, 34(12): 163-167.
MENG Yang-yang, LU Ji-ping, SUN Hua-li, et al. Short-term wind power forecasting based on similar days and artificial neural network[J]. Power System Technology, 2010, 34(12): 163-167.
- [10] 师洪涛, 杨静玲, 丁茂生, 等. 基于小波-BP 神经网络的短期风电功率预测方法[J]. 电力系统自动化, 2011, 35(16): 44-48.
SHI Hong-tao, YANG Jing-ling, DING Mao-sheng, et al. A short-term wind power prediction method based on wavelet decomposition and BP neural network[J]. Automation of Electric Power Systems, 2011, 35(16): 44-48.
- [11] 范高锋, 王伟胜, 刘纯, 等. 基于人工神经网络的风电功率预测[J]. 中国电机工程学报, 2008, 28(34): 118-123.
FAN Gao-feng, WANG Wei-sheng, LIU Chun, et al. Wind power prediction based on artificial neural network[J]. Proceedings of the CSEE, 2008, 28(34): 118-123.
- [12] 袁铁江, 晁勤, 李义岩, 等. 大规模风电并网电力系统经济调度中风电场出力的短期预测模型[J]. 中国电机工程学报, 2010, 30(13): 23-27.
YUAN Tie-jiang, CHAO Qin, LI Yi-yan, et al. Short-term wind power output forecasting model for economic dispatch of power system incorporating large-scale wind farm[J]. Proceedings of the CSEE, 2010, 30(13): 23-27.
- [13] 陶玉飞, 李伟宏, 杨喜峰. 风电场风速预测模型研究[J]. 电网与清洁能源, 2009, 25(3): 53-56.
TAO Yu-fei, LI Wei-hong, YANG Xi-feng. Wind speed forecast model for wind farms[J]. Power System and Clean Energy, 2009, 25(3): 53-56.
- [14] 孙延奎. 小波分析及其应用[M]. 北京: 机械工业出版社, 2005.
SUN Yan-kui. Wavelet analysis and its application[M]. Beijing: China Machine Press, 2005.
- [15] 温锦斌, 王昕, 李立学, 等. 基于频域分解的短期风电负荷预测[J]. 电工技术学报, 2013, 28(5): 66-72.
WEN Jin-bin, WANG Xin, LI Li-xue, et al. Short-term wind power load forecasting based on frequency domain decomposition[J]. Transactions of China Electrotechnical Society, 2013, 28(5): 66-72.
- [16] 罗文, 王莉娜. 风场短期风速预测研究[J]. 电工技术学报, 2011, 26(7): 68-74.
LUO Wen, WANG Li-na. Short-term wind speed forecasting for wind farm[J]. Transactions of China Electrotechnical Society, 2011, 26(7): 68-74.
- [17] 吕金虎, 陆君安, 陈士华. 混沌时间序列分析及其应用[M]. 武汉: 武汉大学出版社, 2002.
Lü Jin-hu, LU Jun-an, CHEN Shi-hua. Chaotic time series analysis and its application[M]. Wuhan: Wuhan University Press, 2002.

收稿日期: 2013-10-15; 修回日期: 2013-12-16

作者简介:

肖 迁 (1988-), 男, 硕士研究生, 主要研究方向为风力发电预测, 电器可靠性及检测技术; E-mail: 15822884679@163.com

李文华 (1973-), 男, 通讯作者, 博士, 教授, 硕士生导师, 主要研究方向为风力发电预测, 电器可靠性及检测技术; E-mail: liwenhua@hebut.edu.cn

李志刚 (1958-), 男, 博士, 教授, 博士生导师, 主要研究方向为电器可靠性及检测技术。