

基于离散 Hopfield 模式识别样本的 GRNN 非线性组合短期风速预测模型

陈 烨,高亚静,张建成

(华北电力大学 新能源电力系统国家重点实验室,河北 保定 071003)

摘要: 利用实时风速数据,建立基于离散 Hopfield 模式识别样本的广义回归神经网络(GRNN)非线性组合预测模型。在风速数据样本集经二维小波阈值去噪处理后,基于离散 Hopfield 识别历史数据中与待预测样本最相似的数据,并作为训练样本;将支持向量机、BP 神经网络和 Elman 神经网络分别进行单项预测的结果作为输入向量,经 GRNN 进行非线性组合预测。采用某风电场的实际风速数据进行预测,结果验证了该预测模型的正确性和有效性。

关键词: 风电; 二维小波阈值去噪方法; 离散 Hopfield; 模式识别; 广义回归神经网络; 非线性组合预测; 模型; 去噪; 支持向量机; 神经网络; 预测

中图分类号: TM 73;TM 614

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2015.08.020

0 引言

近年来,风力发电已成为国际上公认的技术最成熟、开发成本最低、最具发展前景的可再生能源之一。许多国家把风电作为改善能源结构、应对气候变化的重要选择^[1-2]。随着风力发电技术的不断发展,风电在电力需求中所占比例越来越大。但由于风电出力的随机性、波动性和间歇性的影响,大量的风电接入电网,将对未来短期发电计划的制定及电力系统的安全、稳定运行产生影响^[3]。

风电场的有功出力主要由风速决定,由于风速受温度、气压等多种因素影响,具有很强的随机性^[4]。风速预测方法分为基于物理模型的方法和基于历史数据的方法两大类。基于物理模型的预测方法一般采用数值天气预报 NWP(Numerical Weather Prediction)数据进行风速预测^[5-6]。由于风速本身的不确定性和非周期性,以及受气候因素的影响,因此长远角度来看,NWP 对于风速预测效果的改善不可或缺,这也为学者们进一步研究提供了方向 and 平台。基于历史数据的风速预测方法包括持续法^[7]、卡尔曼滤波法^[8]、时间序列法^[9-11]、神经网络法^[12-16]、模糊逻辑法^[17]等。组合预测算法的研究也取得了一定突破,文献^[18]通过基于权重分配的组合方法将不同的网络模型或算法组合。文献^[19]提出一种新的组合预测模型,即采用影响风功率预测的多种因素作为各预测模型的输入变量来预测风电功率,再把各基础模型

的预测结果线性加权平均,该组合预测方法能够减小单一预测模型存在的较大误差,但只靠权重的分配并不能很好地减小整体误差。文献^[20]提出了在对风速数据做单项预测结果基础上,利用广义回归神经网络 GRNN(General Regression Neural Network)进行非线性组合预测。文献^[21]提出不能忽视样本数据之间存在的相似性,故采用模式识别技术筛选训练样本,不仅提高了预测精度,而且减少了样本数量,节省了计算时间。

本文在对风速数据中存在的异常数据给予修改或删除的基础上,基于二维小波阈值去噪的方法对风速样本集做数据平滑处理,然后基于离散 Hopfield 联想记忆功能识别出经去噪处理后的历史风速数据样本集中与待预测样本最相似数据,构成训练样本,最后提出一种基于 GRNN 的风速短期预测的非线性组合模型,以实现支持向量机 SVM(Support Vector Machine)、BP 神经网络和动态 Elman 神经网络 3 种方法进行风速短期预测的非线性组合。

1 基于二维小波阈值去噪方法

小波阈值收缩方法^[22-24]的基本思路是:首先对含噪信号 $f(k)$ 进行小波变换,将其分解为 M 层,得到一组小波系数 $\omega_{j,k}$, $\omega_{j,k}$ 为第 j 层分解后的第 k 个高频系数;然后根据信号和噪声的不同性质,对小波系数 $\omega_{j,k}$ 进行阈值处理,从而得到小波系数 $\hat{\omega}_{j,k}$, $\hat{\omega}_{j,k}$ 为第 j 层分解后的第 k 个高频系数的估计值;最后对 $\hat{\omega}_{j,k}$ 进行重构,由此得到的重构信号 $\hat{f}(k)$ 即为去噪信号。

应用基于小波变换的阈值去噪方法有 2 个主要问题需要解决,即如何确定阈值和如何选取阈值函

收稿日期:2014-12-01;修回日期:2015-02-12

基金项目:国家自然科学基金资助项目(51177047);中央高校基本科研业务费专项资金资助项目(12MS107)

Project supported by the National Natural Science Foundation of China(51177047) and the Fundamental Research Funds for the Central Universities(12MS107)

数。本文采用固定阈值门限准则的 VisuShrink 方法^[23] (或称全局阈值去噪方法)来确定阈值门限 T :

$$T=\lambda \sqrt{2 \log _2 N} \quad (1)$$

其中, λ 为噪声标准; N 为信号的尺寸或长度。

选取半软阈值函数作为阈值函数,该阈值函数不但连续而且大于阈值门限的小波域内有连续的高阶导数,适用于处理具有一定变化特性的风速数据的去噪。

$$\hat{\omega}_{j,k}=\left\{\begin{array}{ll} (1-\mu) \omega_{j,k}+\mu \operatorname{sgn}\left(\omega_{j,k}\right)(\left|\omega_{j,k}\right|-T) & \left|\omega_{j,k}\right| \geq T \\ 0 & \left|\omega_{j,k}\right| < T \end{array}\right. \quad (2)$$

$$\mu=\frac{T}{\left|\omega_{j,k}\right|} \exp \left(-\frac{\left|\omega_{j,k}\right|-T}{\left|\omega_{j,k}\right|+T}\right) \quad (3)$$

其中, μ 为加权因子; $\operatorname{sgn}(\cdot)$ 为符号函数。

应用二维小波阈值去噪的步骤如下。

a. 考虑风速的横向连续性和纵向连续性,首先把前 n 天每天 96 点风速数据作为样本,按照日期排列成二维数据集,其在横向上表示同一天的风速数据,在纵向上则是相邻日期同一时间点的风速数据,然后对其进行归一化处理,得到二维灰度图像矩阵数据。

b. 对二维图像信号 $f(k)$ 进行小波分解。选取合适的小波基,进行 M 层小波分解,得到一组小波系数 $\omega_{j,k}$ 。

c. 对分解后的小波系数进行阈值处理。对于分解的每层小波,首先确定其阈值,然后对 $\omega_{j,k}$ 进行半软阈值函数处理,得到估计系数 $\hat{\omega}_{j,k}$ 。

d. 采用二维小波对图像信号进行重构,即利用 $\hat{\omega}_{j,k}$ 进行小波重构,得到重构信号 $\hat{f}(k)$ 并反归一化得到去噪后的风速数据。

2 基于离散 Hopfield 模式识别的相似样本获取

离散 Hopfield 网络^[25]是一种可以模拟生物神经元网络联想记忆功能的网络。它可分为记忆阶段和联想阶段。记忆阶段是通过某一确定的设计方法,确定权值矩阵,使网络记住期望的稳定平衡点;联想阶段就是网络的工作过程,是将新的模式输入网络,网络通过自身的动力学状态演化最终达到稳定平衡点。

采用离散 Hopfield 模式识别技术^[26]获取相似样本时,选取可由普通天气预报提供的日最大风力等级、日最小风力等级、日平均风速、日平均温度和日平均气压 5 个与风速有较大关系的因素构成模式识别矢量 $F^{[27]}$ 。并对日平均温度和日平均气压利用如下公式归一化处理:

$$W_i^0=\left(W_i-W_{\min }\right) /\left(W_{\max }-W_i\right) \quad (4)$$

其中, W_i^0 为样本 i 的温度及气压经归一化后的数值; W_i 为样本原值; $W_{\max }、W_{\min }$ 分别为样本集中最大、最小值。

基于上述 5 个因素构建风速评价标准如表 1 所示,表中日平均温度、日平均气压为归一化后数值。

表 1 风速数据评价标准

Table 1 Evaluation criteria of wind speed type					
风速类型	日最大 风力等级	日最小 风力等级	日平均 风速/(m·s ⁻¹)	日平均 温度	日平均 气压
I	≤2	≤1	≤2	≤0.1	≤0.1
II	≤4	≤2	≤4	≤0.3	≤0.3
III	≤6	≤4	≤7	≤0.5	≤0.5
IV	≤8	≤5	≤9	≤0.7	≤0.7
V	≤12	≤6	≤12	≤1.0	≤1.0

运用离散 Hopfield 网络进行模式识别的步骤如下。

a. 设定网络的记忆模式,即将预存储的模式进行编码,得到取值为 1 和 -1 的记忆模式。由于风速的分级标准为 5 级,且采用了 5 项指标进行评价,所以记忆模式 $U_k=\left[u_1^k, u_2^k, \cdots, u_n^k\right](k=1,2,3,4,5 ; n=25)$ 。记忆模式如图 1 所示,表示基于上述 5 个因素构建的风速评价标准。




图 1 网络记忆模式

Fig.1 Network memory patterns

b. 建立网络,即运用 MATLAB 工具箱提供的 newhop 函数建立 Hopfield 网络,参数为 U_k 且可得到设计权值矩阵及阈值向量。

c. 将风速的实测指标值转化为网络的欲识别模式,即转化为二值型模式,将其设为网络的初始状态,运用 MATLAB 提供的 sim 函数进行多次迭代使其收敛。选取某 5 天样本 1、2、3、4、5 的网络输入模式为例,如图 2 所示,其余样本的输入模式依此类推。

d. 输出网络的稳定状态,根据各样本风速的综合评价结果,找到与预测样本最相似的样本数据,以此作为预测的训练样本。

3 基于 GRNN 的非线性组合风速预测模型

组合预测^[28]的基本思想是将不同的预测模型和方法结合起来,综合利用各种预测方法所提供的信息,以适当的加权平均方式得到组合预测模型。因为




图 2 测点输入模式
Fig.2 Measuring point input patterns

每种预测模型和方法利用的数据不完全相同,组合预测方法能够最大限度地利用各种单一预测方法的有用信息,因此组合预测方法一般均能够增加系统的预测准确性。

目前组合预测领域重点研究的是如何用线性组合方法结合各单项预测^[29],如权重平均法、协方差优选组合法和时变权系数组合系数法。由文献^[29]可以看出,组合预测模型能有效减少各预测点较大误差的出现,有利于提高预测精度,但同时运用线性组合方法的模型预测效果仍然具有更进一步提升的可能性。本文提出基于 GRNN^[30-31]的非线性组合预测方法。GRNN 在逼近能力、分类能力和学习速度方面具有较强优势,同时具有很强的非线性映射能力和柔性网络结构以及高度的容错性和鲁棒性。

GRNN 的理论基础是非线性回归分析,非独立变量 Y 相对于独立变量 x 的回归分析实际上是计算具有最大概率值的 y 。设随机变量 x 和随机变量 y 的联合概率密度函数为 $f(x,y)$,已知 x 的观测值为 X ,则 y 相对于 X 的回归,即条件均值 $E(y|X)$ 为:

$$\hat{Y}=E(y|X)=\frac{\int_{-\infty}^{\infty}yf(X,y)dy}{\int_{-\infty}^{\infty}f(X,y)dy}$$

(5)

其中, $\hat{Y}$ 为在输入为 X 的条件下 Y 的预测输出。

应用 Parzen 非参数估计,可以由样本数据集 $\{x_i,y_i\}_{i=1}^n$ 估算密度函数 $\hat{f}(X,y)$ 。

$$\hat{f}(X,y)=\frac{1}{n(2\pi)^{\frac{p+1}{2}}\sigma^{p+1}}\times\sum_{i=1}^n\exp\left[-\frac{(X-X_i)^T(X-X_i)}{2\sigma^2}\right]\exp\left[-\frac{(X-Y_i)^2}{2\sigma^2}\right]$$

(6)

其中, X_i,Y_i 分别为随机变量 x 和 y 的样本观测值; n 为样本容量; p 为随机变量 x 的维数; σ 为高斯函数的宽度系数,在此称为光滑因子。

基于 SVM、BP 神经网络和 Elman 神经网络可分别作为风速预测模型,这 3 个单项预测结果与实际值较为贴近,同时考虑到 GRNN 在分类和学习速度

方面的优势,将单项预测结果作为 GRNN 的输入向量,建立组合预测模型如图 3 所示。



图 3 GRNN 非线性组合模型
Fig.3 GRNN nonlinear combination model

基于 GRNN 的非线性组合预测法步骤如下:

- a. 将风速样本数据经二维阈值去噪方法进行预处理,得到更为平滑的风速样本集;
- b. 经步骤 a 预处理后,基于离散 Hopfield 神经网络联想记忆待预测样本数据和所有历史数据的 5 个识别矢量,模式识别出在历史数据中与待预测样本最相似的样本,作为训练样本;
- c. 利用 SVM、BP 神经网络和 Elman 神经网络分别基于训练样本对风速进行预测,然后将这 3 项预测结果作为输入向量经 GRNN 进行非线性组合预测,得到最终的风速预测值。

4 算例

4.1 预测结果分析

选取国内某风电场 2013 年 4 月 1 日至 5 月 30 日共 60 天每天 96 点风速数据,共 5760 个数据点作为训练样本集,排成 60 行 96 列矩阵,采用 db4 小波,分解层数 M 取 3。采用二维小波阈值去噪方法进行数据平滑处理。以天为单位,根据表 1 的风速数据评价标准,创建出 60 d 数据共 60 个输入模式,将此模式进行二数值编码,黑体部分编码为 1,空白部分编码为 -1,例如图 2 的测点 1,编码后得到的数据点阵 Y_1 为:

$$Y_1=\begin{bmatrix} 1 & 1 & 1 & 1 & -1 \\ 1 & 1 & 1 & -1 & -1 \\ 1 & 1 & 1 & -1 & -1 \\ 1 & 1 & -1 & -1 & -1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}$$

利用离散 Hopfield 神经网络对编码得到的 60 个数据点阵进行模式识别后具体分类,如表 2 所示。


表 2 样本分类结果

Table 2 Results of sample classification

分类级别	天数	分类级别	天数
I	6	IV	11
II	14	V	7
III	22		

基于普通天气预报提供的预测日相关气象预报信息,包括风速、空气温度、湿度以及大气压强,利用离散 Hopfield 模式识别技术,将预测日数据根据表 1 评价标准列出当天的输入模式,如图 4 所示。

将此输入模式进行二数值编码。黑体部分编码



预测日

图 4 预测日 Hopfield 输入模式

Fig.4 Input pattern of day to be forecasted

为 1,空白部分编码为-1,即可得到预测日的数据点阵 Y_0 为:

$$Y_0 = \begin{bmatrix} 1 & 1 & 1 & 1 & -1 \\ 1 & 1 & -1 & -1 & -1 \\ 1 & 1 & 1 & -1 & -1 \\ 1 & 1 & -1 & -1 & -1 \\ 1 & 1 & 1 & -1 & -1 \end{bmatrix}$$

经过离散 Hopfield 模式识别,最终分类结果为Ⅲ类,故将在训练样本集分类寻找到的Ⅲ类 22 d 数据作为最终的训练样本。


利用 SVM、BP 神经网络和 Elman 神经网络分别基于训练样本预测风速。对于 SVM^[32]预测,采用径向基函数 RBF(Radical Basis Function)核函数,利用交叉验证方法寻找最佳的参数 c (惩罚因子)和参数 g (RBF 核函数中的方差),然后利用最佳的参数训练模型;对于 BP 神经网络预测,设定迭代次数为 1000,学习率为 0.1,目标为 0.001,采用 newff 函数构建网络模型以及 train 函数对构建的 BP 网络进行训练;用 sim 预测函数对训练好的 BP 神经网络进行预测;对于 Elman 神经网络预测,设定隐藏层神经元层数为 11,默认隐藏层函数为 tansig,输出层函数为 purelin,网络训练次数为 1000,用 newelm 函数建立网络训练模型。基于这 3 个单项预测模型对 6 月 1 日风速进行预测,预测效果如图 5 所示。

将得到的 3 个单项预测结果作为三维输入向量经 GRNN 进行非线性组合预测,预测 6 月 1 日的风速数据。对于 GRNN,采用交叉验证方法训练,并用循环方法找出最佳参数。最终得到的预测效果如图 6 所示。


由图 5、6 可以看出:风电场风速具有强烈的波动性和无序性;BP 神经网络、Elman 神经网络和 SVM 都可用于风速预测,其中 SVM 整体预测效果最好,说明 SVM 的非线性映射能力很强;Elman 神经网络预测效果好于 BP 神经网络;基于 GRNN 的非线性组合预测法的效果较 3 个单项预测更好。

4.2 误差分析


选用合理的误差指标对评判预测效果有着重要意义。本文采用绝对平均误差 MAPE(Mean Absolute Percentage Error)的改进指标均值绝对平均误差 MMAPE(Mean-Mean Absolute Percentage Error)及方均根误差 RMSE(Root Mean Square Error)2 项作为风电预测指标,其定义为:



(a) SVM



(b) Elman 神经网络



(c) BP 神经网络

图 5 3 个单项风速预测

Fig.5 Wind speed forecasted by three particular methods




图 6 GRNN 风速预测

Fig.6 Wind speed forecasted by GRNN

$$MMAPE = \frac{1}{N_0} \sum_{k=1}^{N_0} \frac{|y(k) - y_d(k)|}{y_{ave}} \times 100\% \quad (7)$$

$$y_{ave} = \frac{1}{N_0} \sum_{k=1}^{N_0} y(k) \times 100\% \quad (8)$$

$$RMSE = \frac{1}{y_{ave}} \sqrt{\frac{\sum_{k=1}^{N_0} (y(k) - y_d(k))^2}{N_0}} \quad (9)$$

其中, $y(k)$ 为第 k 个样本的实测值; $y_d(k)$ 为第 k 个样本的预测值; N_0 为样本容量; y_{ave} 为实测值的平均值。利用误差指标 MMAPE 和 RMSE 对 3 个单项预测模型及 GRNN 非线性组合预测模型进行评定,结果如表 3 所示。

表 3 预测模型误差
Table 3 Errors of different forecasting models

模型	经二维小波阈值 处理预测模型误差		未经二维小波阈值 处理预测模型误差	
	MMAPE	RMSE	MMAPE	RMSE
SVM	0.1047	0.1321	0.1568	0.1719
BP 神经网络	0.1737	0.2049	0.2352	0.2517
Elman 神经网络	0.1184	0.1492	0.1729	0.1992
GRNN 非线性组合	0.0927	0.1169	0.1283	0.1548

由表 3 可知,经二维小波阈值处理数据后 4 种预测模型的预测精度均有明显提高;基于 GRNN 非线性组合预测模型预测精度比 3 个单项预测精度都要高,可以说明该非线性组合预测方法可更有效地预测风速。

5 结论

本文重点研究了风电场风速预测,提出了一种基于离散 Hopfield 模式识别样本的 GRNN 非线性组合预测方法,应用国内某地区的实测风速对本文提出的风速预测方法进行验证分析,结果表明本文提出的风速预测模型的正确性。同时对比未经二维小波阈值处理模型,经阈值处理后的模型预测精度有明显提高。在离散 Hopfield 识别出风速最相似样本后,经 SVM、BP 神经网络和 Elman 神经网络进行单项预测,以 3 个单项预测结果作为输入向量经 GRNN 进行非线性组合预测,结果表明此非线性组合预测模型具有准确性。

参考文献:

[1] 泽尔沃斯·阿瑟劳斯,王艳. 全球风电发展现状 & 展望[J]. 中国能源,2008,30(4):23-28.
ARTHOUROS Z,WANG Yan. The present situation and prospects of global wind power development[J]. Energy of China,2008,30(4):23-28.

[2] 李俊峰,高虎,董路影,等. 2008 中国风电发展报告[M]. 北京: 中国环境科学出版社,2008:23-75.

[3] FOLEY A M,LEAHY P G. Current methods and advances in forecasting of wind power generation[J]. Renewable Energy, 2012,37:1-8.

[4] BOSSANYI E. A short-term wind prediction using kalman filters [J]. Wind Engineering,1985,9(1):1-8.

[5] 冯双磊,王伟胜,刘纯,等. 风电场功率预测方法研究[J]. 中国电机工程学报,2010,30(2):1-6.
FENG Shuanglei,WANG Weisheng,LIU Chun,et al. Study on the physical approach to wind power prediction[J]. Proceedings of the CSEE,2010,30(2):1-6.

[6] PELIKAN E,EBEN K,RESLER J,et al. Wind power forecasting

by an empirical model using NWP outputs[C] //International Conference on Environment and Electrical Engineering. Prague, Czech Republic:[s.n.],2010:45-48.

[7] 韩爽,杨勇平,刘永前. 三种方法在风速预测中的应用研究[J]. 华北电力大学学报,2008,35(3):57-61.
HAN Shuang,YANG Yongping,LIU Yongqian. Application study of three methods in wind speed prediction[J]. Journal of North China Electric Power University,2008,35(3):57-61.

[8] 王耀南,孙春顺,李欣然. 用实测风速校正的短期风速仿真研究 [J]. 中国电机工程学报,2008,28(11):94-100.
WANG Yaonan,SUN Chunshun,LI Xinran. Short-term wind speed simulation corrected with field measured wind speed[J]. Proceedings of the CSEE,2008,28(11):94-100.

[9] 邵璠,孙育河,梁岚珍. 基于时间序列法的风电场风速预测研究 [J]. 电力环境保护,2008,24(4):1-5.
SHAO Fan,SUN Yuhe,LIANG Lanzhen. Study on the time-series wind speed forecasting of the wind farm based on time series[J]. Electric Power Environmental Protection,2008,24(4): 1-5.

[10] BILLINTON R,GUANG Bai. Generating capacity adequacy associated with wind energy[J]. IEEE Trans on Energy Conversion,2004,19(3):641-646.

[11] 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 Xiuyuan,XIAO Yang,CHEN Shuyong. Wind speed and generated power forecasting in wind farm[J]. Proceedings of the CSEE,2005,25(11):1-5.

[12] ERNST B,OAKLEAF B,AHLSTROM M L,et al. Predicting the Wind[J]. IEEE Power and Energy Magazine,2007,5(6):78-89.

[13] CHANG Pengfei,LI Li. Ocean surface wind speed and direction retrievals from the SSM/I[J]. IEEE Transactions on Power Systems,1998,36(6):1866-1871.

[14] BARBOUNIS T G,THEOCHARIS J B,ALEXIADIS M C,et al. Long-term wind speed and power forecasting using local recurrent neural network models[J]. IEEE Transactions on Energy Conversion,2006,21(1):273-284.

[15] GHANBARZADEH A,NOGHREHABADI A R,BEHRANG M A,et al. Wind speed prediction based on simple meteorological data using artificial neural network [C] //IEEE International Conference on Industrial Informatics. Ahwaz,Iran:IEEE,2009: 664-667.

[16] 洪翠,温步瀛,林维明,等. 基于改进 OLS-RBF 神经网络模型的短期风电场出力预测[J]. 电力自动化设备,2012,32(9):40-45.
HONG Cui,WEN Buying,LIN Weiming,et al. Short-term forecasting of wind power output based on improved OLS-RBF ANN model [J]. Electric Power Automation Equipment,2012,32(9):40-45.

[17] ALEXIADIS M,DOKOPOULOS P,SAHSAMANOGLU H,et al. Short term forecasting of wind speed and related electrical power[J]. Solar Energy,1998,63(1):61-68.

[18] 陈聪聪. 基于组合模型的风功率预测[D]. 乌鲁木齐:新疆大学,2012.
CHEN Congcong. The combination model of wind power prediction[D]. Urumqi:Xinjiang University,2012.

[19] 刘纯,范高锋,王伟胜,等. 风电场输出功率的组合预测模型[J]. 电网技术,2009,33(13):74-79.

- LIU Chun,FAN Gaofeng,WANG Weisheng,et al. A combination forecasting model for wind farm output power[J]. Power System Technology,2009,33(13): 74-79.
- [20] 杨江平. 基于神经网络组合预测的风电场风速及发电功率短期预测[D]. 重庆:重庆大学,2012.
- YANG Jiangping. Short-term wind speed and power forecasting in wind farm based on ANN combination forecasting [D]. Chongqing:Chongqing University,2012.
- [21] 吴兴华,周晖,黄梅. 基于模式识别的风电场风速和发电功率预测[J]. 继电器,2008,36(1):27-32.
- WU Xinghua,ZHOU Hui,HUANG Mei. Wind speed and generated power forecasting based on pattern recognition in wind farm[J]. Relay,2008,36(1):27-32.
- [22] 李光珍,刘文颖,云会周,等. 母线负荷预测中样本数据预处理的新方法[J]. 电网技术,2010,34(2):149-154.
- LI Guangzhen,LIU Wenying,YUN Huizhou,et al. A new data preprocessing method for bus load forecasting[J]. Power System Technology,2010,34(2):149-154.
- [23] DONOHO D L,JOHNSTONE I M. Ideal spatial adaptation by wavelet shrinkage[J]. Biometrika,1994,81(3):425-45.
- [24] 张德丰. Matlab 小波分析[M]. 北京:机械工业出版社,2009:106-152.
- [25] HOPFIELD J J. Neural networks and physical systems with emergent collective computational abilities[J]. Proceedings of the National Academy of Sciences of the USA,1982,79(8):2554-2558.
- [26] 都晨. 基于模糊聚类的 GA-BP 风电场短期风速及功率预测的研究[D]. 南京:南京理工大学,2013.
- DU Chen. Short-term prediction research of wind power based on fuzzy clustering algorithm and GA-BP[D]. Nanjing:Nanjing University of Science and Technology,2013.
- [27] FAN S,LIAO J R,YOKOYAMA R,et al. Forecasting the wind generation using a two-stage network based on meteorological information[J]. IEEE Trans on Energy Conversion,2009,24(2):474-482.
- [28] BATES J M,GRANGER C W J. The combination of forecasts [J]. Operational Research Quarterly,1969,20(4):451-468.
- [29] 刘纯,范高峰,王伟胜,等. 风电场输出功率的组合预测模型[J]. 电网技术,2009,33(13):74-79.
- LIU Chun,FAN Gaofeng,WANG Weisheng,et al. A combination forecasting model for wind farm output power[J]. Power System Technology,2009,33(13):74-79.
- [30] 刘亚南,卫志农,朱艳,等. 基于 D-S 证据理论的短期风速预测模型[J]. 电力自动化设备,2013,33(8):131-136.
- LIU Yanan,WEI Zhinong,ZHU Yan,et al. Short-term wind speed forecasting model based on D-S evidence theory [J]. Electric Power Automation Equipment,2013,33(8):131-136.
- [31] 韩冬梅,牛文清,杨荣. 线性与非线性最优组合预测方法的比较研究[J]. 情报科学,2007,25(11):1672-1679.
- HAN Dongmei,NIU Wenqing,YANG Rong. The comparative study on linear and nonlinear optimal forecast-combination methods[J]. Information science,2007,25(11):1672-1679.
- [32] 李慧杰,刘亚南,卫志农,等. 基于相关向量机的短期风速预测模型[J]. 电力自动化设备,2013,33(10):28-32.
- LI Huijie,LIU Yanan,WEI Zhinong,et al. Short-term wind speed forecasting model based on relevance vector machine[J]. Electric Power Automation Equipment,2013,33(10):28-32.

作者简介:



陈 烨

陈 烨(1994—),男,安徽马鞍山人,研究方向为新能源发电出力预测(E-mail: chenye19941002@163.com);

高亚静(1980—),女,河北衡水人,讲师,博士,研究方向为电网调度自动化、电力经济(E-mail: commoncat@163.com);

张建成(1965—),男,河北衡水人,教授,博士研究生导师,博士,研究方向为新型储能技术、电能质量控制技术和可再生能源发电控制技术(E-mail: zhangjiancheng@126.com)。

GRNN nonlinear combination model for short-term wind speed forecasting based on discrete Hopfield pattern recognition

CHEN Ye,GAO Yajing,ZHANG Jiancheng

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Baoding 071003, China)

Abstract: With the real-time wind speed data, a GRNN (General Regression Neural Network) nonlinear combination model based on discrete Hopfield pattern recognition is built for short-term wind speed forecasting. After the wind speed data sample set is processed by the two-dimension wavelet threshold de-noising method, the historic data most similar to the sample to be forecasted are picked out by the discrete Hopfield identification and taken as the training sample. The forecasting results obtained respectively by the support vector machine, BP neural network and Elman neural network are taken as the input vectors of GRNN for the nonlinear combination forecasting. The forecasting results based on the real wind speed data of a wind farm verify the correctness and effectiveness of the proposed forecasting model.

Key words: wind power; two-dimension wavelet threshold de-noising method; discrete Hopfield; pattern recognition; general regression neural network; nonlinear combination forecasting; models; de-noising; support vector machines; neural networks; forecasting