

文章编号:0254-0096(2019)08-2196-09

一种新型模块化风速预测方法

潘超¹, 秦本双¹, 蔡国伟¹, 袁翀²

(1. 东北电力大学电气工程学院, 吉林 132012; 2. 国网浙江淳安供电公司, 淳安 311700)

摘要: 针对风电场风速随机性强、波动性明显以及预测难度高等问题,提出一种新型模块化风速预测的方法。该方法主要包含3个模块:风速属性加权模块、智能优化聚类模块及极限学习机风速预测模块。首先考虑不同气象属性对风速的影响和风速的时间波动特性,计算风速属性矩阵元素的皮尔逊系数值并进行加权;然后采用遗传-模拟退火算法优化模糊 c 均值聚类方法,对加权风速属性矩阵矢量进行聚类;再通过极限学习机构建各类别的风速预测模型,进行短期风速预测。最后结合美国一风电场(N39.91°, W105.29°)的实测数据对风速进行预测,通过对比仿真结果与实测数据验证该文方法的正确性和有效性,结果表明该方法具有较高的预测精度。

关键词: 风速预测; 属性加权; 模糊聚类; 极限学习机

中图分类号: TM614

文献标识码: A

0 引言

风力发电作为一种重要的清洁能源利用方式,受到各国广泛重视^[1,2]。伴随着风力发电并网规模的不断加大,风速的随机性、波动性对电力系统的安全和稳定运行带来巨大挑战。大规模风力发电参与并网调度需要有效的风功率预测,准确有效的风速预测则是风电并网研究的一个关键环节^[3]。

针对风速时间序列随机性大、波动性强及准确预测难的特点,国内外学者对预测方法已进行大量研究,主要包括持续法、时间序列法、卡尔曼滤波法及神经网络法等^[4-7]。时间序列法原理简单,可常当作预测基准;时间序列法利用风速时间序列构建线性预测模型,而风速具有很强的非线性,其低阶模型预测精度不高,高阶模型参数不易确定;卡尔曼滤波法中风速噪声特性不易估计,难以构建特征方程和状态方程;神经网络法具有很强的非线性拟合能力,适用于开展短期风速预测研究,但传统神经网络(如BP)模型存在结构复杂、参数设置麻烦、迭代次数多等问题。极限学习机(extreme learning machine, ELM)结构简单,可随机确定输入权值和网

络偏置,仅需学习隐含层数输出权值参数,学习效率高、泛化能力强,并可根据风速预测需要确定隐含层数和激活函数,易收敛到最优解^[8]。因此相较于传统神经网络,ELM网络更适用于风电场风速短期预测。已有研究表明不同气象条件下的风速波动情况也具有一定规律性^[9,10],然而目前罕有研究考虑气象因素的影响。因此很有必要在深入挖掘风速、风向等因素与风速变化关联规则的基础上开展考虑温度、湿度等气象因素的大数据风速预测模型研究。针对风速属性数据多和信息冗余量大的特点,文献[11]从大量样本中提取出相似数据,进而构建预测模型,提高预测的精度,但在不同的气象条件下,样本数据分布不均,单一预测模型容易陷入过拟合现象。针对风速时间序列非线性和间歇性强的特点,文献[8]采用ELM对风速数据进行非线性拟合预测,得到很好的预测效果。

本文提出一种基于加权改进模糊 c 均值(weighted optimal fuzzy c -means, WOFM)聚类与模块化极限学习机(modular extremely learning machine, MELM)的风速预测新方法,通过采用遗传

收稿日期: 2017-03-07

基金项目: 国家高技术研究发展(863)计划(SS2014AA052502); 国家自然科学基金(51507027)

通信作者: 潘超(1981—)男, 博士、副教授, 主要从事研究新能源技术方面的研究。31563018@qq.com

算法(genetic algorithm, GA)与模拟退火(simulated annealing, SA)算法(在本文下列论述中将遗传模拟退火算法均用“GA+SA”表示)优化的FCM(fuzzy c-means)聚类算法,对风速属性因素进行聚类,针对不同类别分别构建MELM风速预测模型,并与实际风场量测数据进行比较,对本文方法进行验证。

1 风速气象属性数据预处理

1.1 属性分析

风速是由空气的相对运动产生的,在相似的天气情况下,风电场的风速变化会呈现出一定的相似性,其中大气的温度及湿度等因素能够间接影响风速的大小,通过分析多物理范畴的信息数据也能反映出未来风速的某种变化趋势^[12]。本文主要考虑风速、风向、温度及湿度等因素,由于这些物理变量在时间尺度上具有较强的自相关性,为降低信息处理冗余度,选取各因素自相关性最大的前4个时刻数据作为预测模型的输入。

$$\mathbf{S} = [s_1, \dots, s_i, \dots, s_m]^T$$

$$= \begin{bmatrix} s_{11} & \cdots & s_{1k} & \cdots & s_{1n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ s_{i1} & \cdots & s_{ik} & \cdots & s_{in} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ s_{m1} & \cdots & s_{mk} & \cdots & s_{mn} \end{bmatrix} \quad (1)$$

式中, \mathbf{S} ——风速属性数据信息库; \mathbf{S}_i ——第 i 个风速属性矩阵; m ——风速属性数量; n ——训练样本维度; s_{ik} ——第 i 个属性在第 k 时刻的值。

1.2 皮尔逊系数属性权重的确定

对输入属性进行加权处理,基于皮尔逊相关系数(pearson correlation coefficient, PCC)法来衡量不同属性相对于风速序列的相关程度^[8,9],并确定输入属性数据的相关系数权重。

根据不同时刻数据信息库计算不同属性相对于风速序列的相关系数,设 \mathbf{S}_i 为风速属性时间序列, \mathbf{S}_o 为风速时间序列矩阵,其 PCC 值为:

$$\begin{cases} \mathbf{S}_i = [s_{i1}, \dots, s_{ik}, \dots, s_{in}] \\ \mathbf{S}_o = [s_{o1}, \dots, s_{ok}, \dots, s_{on}] \end{cases} \quad (2)$$

$$\rho_i = \frac{\sum_{k=1}^n (s_{ik} - \bar{s}_i)(s_{ok} - \bar{s}_o)}{\sqrt{\sum_{k=1}^n (s_{ik} - \bar{s}_i)^2 \sum_{k=1}^n (s_{ok} - \bar{s}_o)^2}} \quad (3)$$

根据 PCC 值可计算各输入属性的权值 σ_i :

$$\sigma_i = \frac{\rho_i}{\sum_{i=1}^m \rho_i} \quad (4)$$

式中, ρ_i ——第 i 类风速属性的 PCC 值; \bar{s}_i ——第 i 个变量序列的均值; s_{ok} ——在第 k 时刻的风速值; \bar{s}_o ——风速时间序列的均值, m ——风速样本属性数目。

2 优化的FCM聚类

2.1 FCM聚类

由于短时间内风速、风向、温度及湿度具有一定的连续性,同时相近的属性因素对风速的影响具有一定的相似性。

为提高风速预测精度,本文将对样本数据进行聚类分析,步骤为:

1) 选取风速的属性因素,并由式(4)得到加权风速属性样本集。

2) 将样本组分为 c 个簇。随机选取 c 个样本作为 c 个簇风速样本 v 的初始聚类中心,则样本点中心形式为:

$$v = \{v_1, \dots, v_k, \dots, v_c\}, 2 \leq c \leq n \quad (5)$$

式中, v_i ——第 i 类别的聚类中心; c ——聚类中心数量。

3) 计算任一样本点 x_i 到 c 个聚类中心的欧式距离:

$$D_{ik} = D(x_i - v_k) = \sqrt{\sum_{j=1}^m (x_{ij} - v_{kj})^2} \quad (6)$$

式中, D_{ik} ——欧氏距离,用于度量风速样本第 i 个样本 x_i 到第 k 个聚类中心的距离; x_{ij} ——风速样本第 i 个样本点的第 j 个属性; v_{kj} ——风速样本第 k 个聚类中心的第 j 个属性。

4) 求取任意一个样本点到 c 个聚类中心的隶属度:

$$A_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{q-1}}}, 1 \leq k \leq c \quad (7)$$

式中, d_{ik} 、 d_{jk} ——样本 x_i 、 x_j 到类别 v_k 的欧式距离; A_{ik} ——样本 x_i 对于类别 v_k 的隶属度; q ——加权参数。

5) 计算各簇(类别)与聚类中心的综合欧式距离及对应隶属度:

$$J_q(U, v) = \sum_{i=1}^n \sum_{k=1}^c (A_{ik})^q (D_{ik})^2 \quad (8)$$

$$\sum_{j=1}^c A_j(x_i) = 1 \quad (9)$$

式中, U ——相似分类矩阵。式(8)为聚类分析目标函数, 式(9)为约束条件。

6) 设 $I_k = \{i | 2 \leq i \leq n; D_{ik} = 0\}$, 则聚类中心为:

$$v_{ij} = \frac{\sum_{k=1}^n (A_{ik})^q x_{kj}}{\sum_{k=1}^n (A_{ik})^q} \quad (10)$$

聚类优化原则为: 通过聚类步骤 1)~步骤 5) 计算各簇目标函数, 若其目标函数值为最小值, 则算法结束, 完成模糊聚类的划分; 若各簇目标函数非最小值, 则进入步骤 6) 更新聚类中心, 并重复步骤 3)~步骤 5) 直至寻优结束。

考虑到风速波动存在不确定性, FCM 的初始聚类中心具有随机性, 若初始聚类中心选取不当, 聚类过程易出现局部寻优的问题, 从而影响聚类边界划分和聚类结果的准确性^[13]。因此需对 FCM 聚类算法的初始聚类中心进行优化。

2.2 基于 GA+SA 优化的 FCM 聚类分析

GA(遗传算法)是一种基于自然进化系统的计算模型, 结合生物进化和随机交换理论适应性搜索最优解。SA(模拟退火算法)把某类优化问题的求解过程与统计热力学平衡问题进行对比, 采用 Metropolis 接受准则使算法跳离局部最优的陷阱, 而得到全局最优解。采用 GA+SA 相结合的优化算法可互相取长补短, 既有效克服传统 GA 的早熟现象, 又可避免 SA 计算时间长的缺陷, 使该算法更有效、更迅速地收敛到全局最优解。相关计算原理已较为成熟, 本文不做赘述。

结合加权风速属性数据, 采用 GA+SA 优化的 FCM 进行聚类分析: 首先初始化控制参数, 结合文献[14]确定出降温速率 α 、起始温度 T_0 、温度冷却系数 r 、终止温度 T_{end} 以及 Metropolis 链长 L 等控制参数, 流程如图 1 所示。图中 T_i 、 T_{i+1} 分别为进行第 i 和 $i+1$ 次冷却后的温度, gen 为迭代次数, $MAXGEN$ 为最大迭代次数。

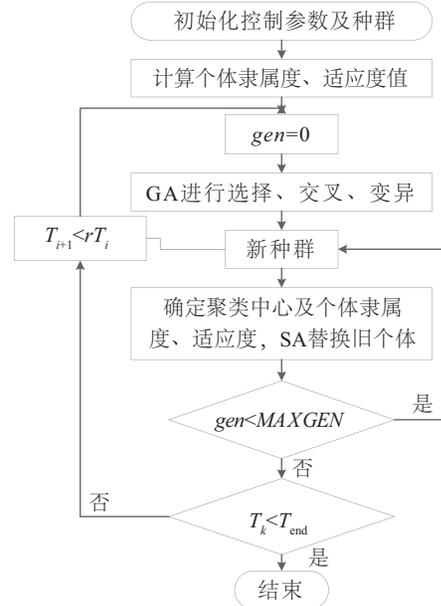


图1 基于 GA+SA 算法的 FCM 聚类流程图
Fig. 1 Flow chart of FCM clustering based on GA+SA algorithm

3 ELM 风速预测

3.1 ELM 基本原理

ELM^[11,15]是在单隐含层前馈神经网络的基础上提出的。设 ELM 的激活函数为 $F(x)$, 当训练样本足够大时 ELM 能以零误差逼近训练样本:

$$\begin{cases} \lambda_j = [\lambda_{1j}, \lambda_{2j}, \dots, \lambda_{mj}] \\ \delta_j = [\delta_{1j}, \delta_{2j}, \dots, \delta_{lj}] \end{cases} \quad j = 1, 2, \dots, M \quad (11)$$

$$F(\lambda_j, b_j, x_j) = F(\lambda_j x_j + b_j) \quad (12)$$

式中, λ_j ——第 j 个隐含层神经元与输入层神经元之间的连接权值向量; b_j ——第 j 个隐含层神经元的偏置; δ_j ——第 j 个输出层神经元与隐含层输出神经元之间的连接权值向量; $F(\lambda_j, b_j, x_j)$ ——第 j 个隐含层神经元的输出; M ——隐含层神经元数量; p ——输入神经元数量; L ——输出神经元个数。

在该预测方法中, 激活函数采用拟合性能良好的 Sig 函数^[11], 将式(12)写为矩阵形式:

$$H\delta = Z \quad (13)$$

式中, H ——隐含层输出矩阵; δ ——隐含层神经

元与输出层神经元之间的连接权值矩阵; Z ——输出向量矩阵。

权值矩阵 λ 以及偏置 b 初始化时,均由系统随机给定,故隐含层输出矩阵 H 为确定矩阵。由此将 ELM 网络的训练变为求解输出权值矩阵最小二乘解 δ 的问题:

$$\|H\hat{\delta} - Z\| = \min_{\delta} \|H\delta - Z\| \quad (14)$$

由式(14)可求出输出权值矩阵 $\hat{\delta}$:

$$\hat{\delta} = H^{-}G \quad (15)$$

式中, G ——ELM 网络的输出函数; H^{-} ——隐含层输出矩阵 H 的 M-P(Moore-Penrose)广义逆。然后利用 M-P 广义逆求得该方程组的最小二乘解作为 ELM 网络的权值参数。

ELM 网络的训练过程就是寻找一个最优的 $\hat{\delta}$ 使得训练样本的真实值和预测值之间误差最小:

$$Opt(\hat{\delta}) = \min_{\delta} \|F - Z\| \quad (16)$$

当 ELM 的输入为风速属性,输出为该时刻风速时,可构建 ELM 的风速预测模型。

3.2 构建 MELM 风速预测模型

针对风电场实测风速及气象属性数据,为避免较小的属性值在模型训练中贡献值小的现象,首先采用式(17)对原始数据进行规范化和归一化处理,将所有属性数据映射到 $[0, 1]$ 之间,得到初始数据集:

$$\begin{cases} x_i = \frac{x_i' - \min\{x_i'\}}{\max\{x_i'\} - \min\{x_i'\}} \\ i = 1, 2, \dots, N \end{cases} \quad (17)$$

式中, x_i' ——第 i 时刻的原始风速数据, x_i'' ——归一后的风速数据; N ——风速预测样本数。

再采用式(3)分别计算风电场的 16 维实测属性数据相对于风速序列的 PCC 值,基于式(4)对相应的属性进行加权处理,得到加权数据集;采用 GA+SA 算法对 FCM 聚类方法的初始聚类中心进行优化,对加权数据集采用 WOFCM 聚类处理,得到不同类别的数据集,针对每一类数据集分别构建 ELM 预测模型;最后,利用已构建的预测模型对风速数据进行预测。其具体流程如图 2 所示。

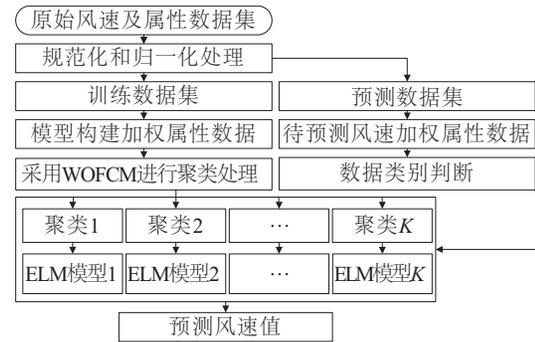


图2 风速预测流程图

Fig. 2 Flow chart of wind speed forecasting

将预测输出按式(18)进行反归一化处理:

$$\begin{cases} y_j' = y_j \times (\max\{x_i''\} - \min\{x_i''\}) + \min\{x_i''\} \\ i = 1, 2, \dots, N \end{cases} \quad (18)$$

式中, y_j ——第 j 个时刻的预测数据; y_j' ——第 j 个时刻反归一化后的预测数据。

为衡量预测结果的准确性,选用平均绝对百分比误差 (MAPE) 和均方根误差 (RMSE) 作为评价指标:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|f_i - y_i'|}{f_i} \quad (19)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_i - y_i')^2} \quad (20)$$

式中, f_i ——实际风速值。

4 仿真分析

结合美国风能数据中心北纬 39.91° 西经 105.29° 的一个风电场实测风速以及气象属性数据开展研究。采用实测数据的时间间隔为 30 min, 对应预测模型每次输出 1 个风速值。

算例分析的思路: 1) 采用平均插值法和持续法对原始异常和缺失数据进行筛选修正; 2) 以 2014 年全年的相关数据为训练样本, 构建预测模型; 3) 采用 2015 年的数据作为测试样本, 检验该模型的预测效果。风速属性的具体类别如表 1 所示。

根据式(3)计算出 16 维风速属性相对于风速序列的 PCC 值, 将其归一化处理, 结果如表 2 所示。并利用该系数值对相应的属性值进行加权处理, 得到加权数据矩阵。

表1 风速属性类别及元素

Table 1 Attribute categories and elements of wind speed

| 类别 | 风速属性 | 类别 | 风速属性 |
|------|--------|------|--------|
| S(1) | 风速前一时刻 | H(4) | 湿度前四时刻 |
| S(2) | 风速前二时刻 | H(3) | 湿度前三时刻 |
| S(3) | 风速前三时刻 | H(2) | 湿度前二时刻 |
| S(4) | 风速前四时刻 | H(1) | 湿度前一时刻 |
| D(1) | 风向前一时刻 | T(4) | 温度前四时刻 |
| D(2) | 风向前二时刻 | T(3) | 温度前三时刻 |
| D(3) | 风向前三时刻 | T(2) | 温度前二时刻 |
| D(4) | 风向前四时刻 | T(1) | 温度前一时刻 |

表2 风速属性的PCC值

Table 2 PCC values of wind speed attributes

| 类别 | PCC值 | 类别 | PCC值 |
|------|--------|------|--------|
| S(1) | 1.0000 | H(4) | 0.1845 |
| S(2) | 0.8909 | H(3) | 0.1810 |
| S(3) | 0.8136 | H(2) | 0.1777 |
| S(4) | 0.7555 | H(1) | 0.1744 |
| D(1) | 0.3006 | T(4) | 0.0427 |
| D(2) | 0.2787 | T(3) | 0.0462 |
| D(3) | 0.2575 | T(2) | 0.0478 |
| D(4) | 0.2381 | T(1) | 0.0483 |

由表2可知,历史风速与预测风速的PCC相关系数为(0.75,1.00),二者属于强相关关系,对风速预测起决定性作用;历史风向和历史湿度与预测风速属于弱相关;历史温度与预测风速的相关性最低。结果表明,对风速属性进行加权处理可突出相关性较强的属性元素,以此为基础开展的风速预测结果更为准确。

采用BP神经网络、传统ELM方法和加权ELM网络进行风速预测,依据该风电场2015年4个季节典型日的实测数据进行对比,结果如图3所示。由图3可知各典型日在09:00~18:00内风速变化较缓慢,3种方法的预测结果均与实际风速的变化相符;但在风速波动较为明显的时间段内(18:00~24:00),BP神经网络和传统ELM方法的预测结果出现较大偏差,而加权ELM方法则取得了良好的预测效果;在00:00~09:00内风速变化剧烈,上述方法的预测效果差异更为显著,加权ELM预测结果更接近真实风速。3种风速预测模型的误差对比结果如表3所示。

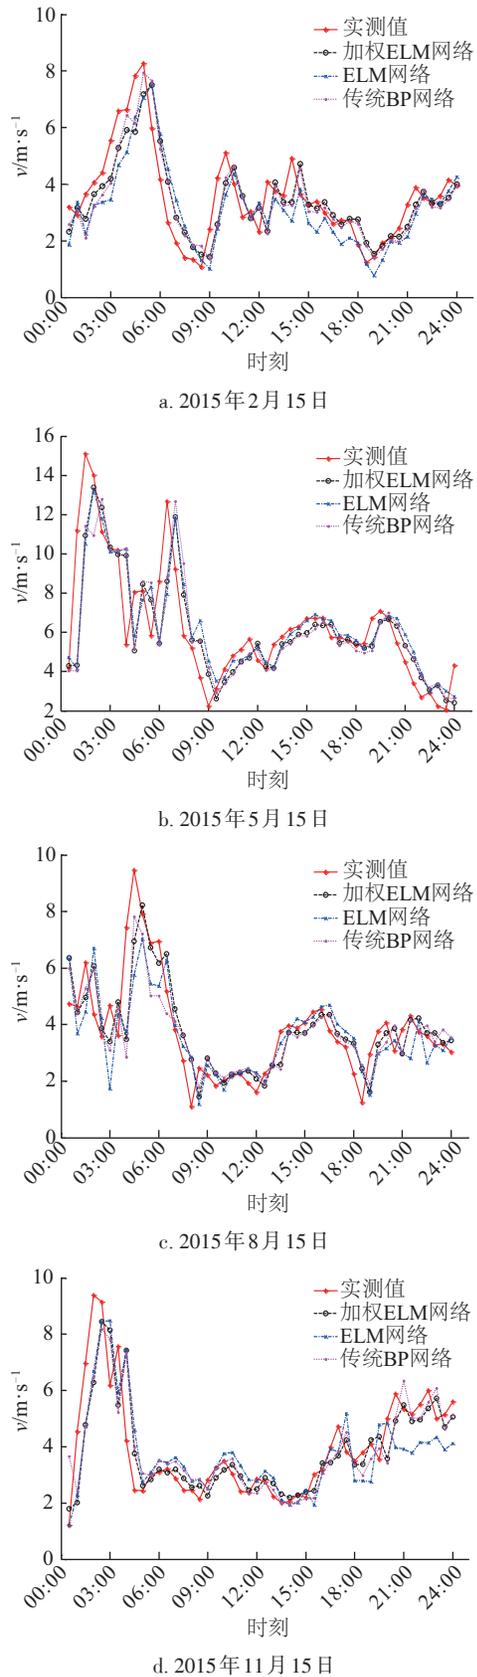


图3 不同预测方法结果对比

Fig. 3 Results comparison of different forecasting methods

从表3中的误差结果对比可知,传统ELM风速预测模型误差最大,BP网络误差次之,而加权ELM模型预测误差最优,说明加权处理能在一定程度

上提高ELM的预测精度,这是由于加权方法在一定程度上降低了与风速弱相关的属性因素的影响。

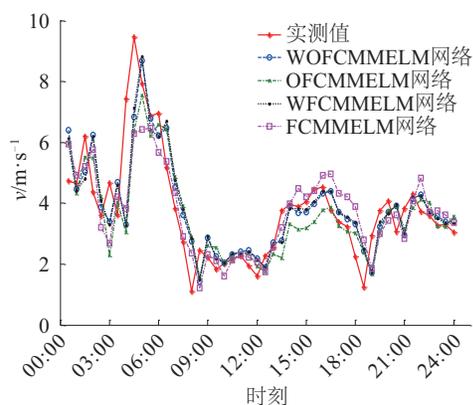
表3 不同预测模型结果对比

Table 3 Results comparison of different forecasting models

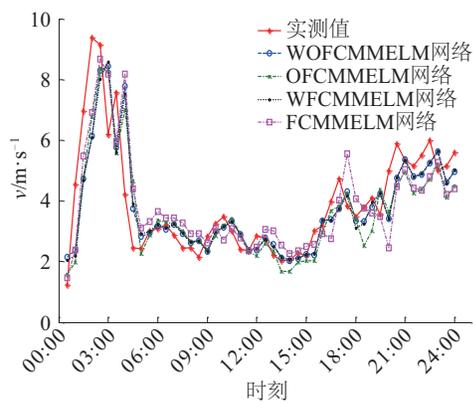
| 预测模型 | 2月15 | | 5月15 | | 8月15 | | 11月15 | |
|-------|---------|---------|---------|--------|---------|--------|---------|--------|
| | MAPE | RMSE | MAPE | RMSE | MAPE | RMSE | MAPE | RMSE |
| BP网络 | 12.2470 | 0.4578 | 13.1282 | 0.5014 | 10.7226 | 0.4889 | 13.0919 | 0.5813 |
| ELM | 18.3365 | 0.6843 | 18.6318 | 0.7766 | 18.0735 | 0.9132 | 20.1317 | 0.8930 |
| 加权ELM | 11.6442 | 0.43362 | 12.2892 | 0.4739 | 10.3151 | 0.4874 | 11.9617 | 0.5138 |

分别采用模糊c均值模块化极限学学习机(FCMMELM)、加权模糊c均值模块化极限学学习机(WFCMMELM)、优化模糊c均值模块化极限学学习机(OFCMMELM)及加权优化模糊c均值模块化极限学学习机(WOFCMMELM)进行风速预测,并进行逐一对比,以验证该方法的准确性,对比结果如图4所示。

从图4可知,各典型日在风速变化缓慢的时间段(09:00~18:00)内,4种方法均能很好地预测



c. 2015年8月15日



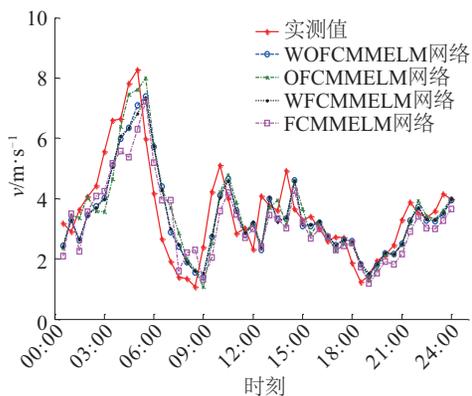
d. 2015年11月15日

图4 不同方法的预测结果对比

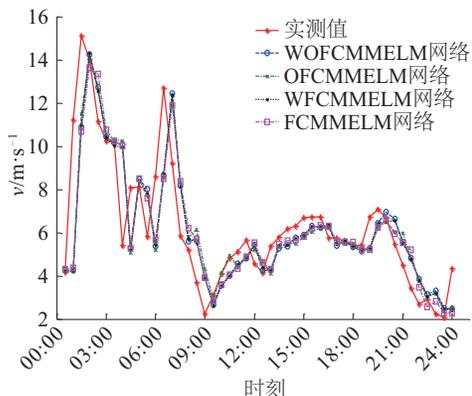
Fig. 4 Results comparison of different forecasting methods

风速的变化趋势;而在风速变化较为剧烈的时间段(00:00~09:00)内,WOFCMMELM网络相比其他3种方法可呈现出更好的风速预测性能。

FCMMELM、WFCMMELM、OFCMMELM、WOFCMMELM这4种方法的预测结果误差对比如表4所示。



a. 2015年2月15日



b. 2015年5月15日

表4 风速预测结果对比

Table 4 Results comparison of wind speed forecasting

| 预测模型 | 2月15 | | 5月15 | | 8月15 | | 11月15 | |
|----------|---------|--------|---------|--------|---------|--------|---------|--------|
| | MAPE | RMSE | MAPE | RMSE | MAPE | RMSE | MAPE | RMSE |
| FCMMELM | 18.5540 | 0.6977 | 21.1963 | 0.8313 | 15.3143 | 0.6677 | 14.8788 | 0.7132 |
| WFCMMELM | 11.8771 | 0.4507 | 12.7268 | 0.5038 | 10.3122 | 0.4742 | 11.6532 | 0.5281 |
| OFCMMELM | 15.7436 | 0.5978 | 17.0196 | 0.6730 | 11.0982 | 0.5002 | 14.8882 | 0.6821 |
| WOFMMELM | 11.6122 | 0.4298 | 12.2590 | 0.4657 | 10.1919 | 0.4652 | 11.6334 | 0.4273 |

深入分析4种方法的预测结果可知,与FCMMELM预测模型相比,OFCMMELM预测模型通过优化FCM聚类算法的初始聚类中心,使算法更易搜索到全局最优解,且可在一定程度上提高计算速度;WFCMMELM预测模型可增加高关联度属性的权重,降低若关联度属性,从而提高了预测模型的精度;WOFMMELM预测模型集中了前2种方法的优点,预测模型误差最小,精度最高。

基于WOFMMELM方法,对该风电场2015年5月份风速进行预测,并与实测数据对比,结果如图5和表5所示。从图5及表5可知,采用WOFMMELM模型进行风速预测,仿真值与实测值基本一致且能较好地反映风速的变化趋势,验证了本文方法的正确性。

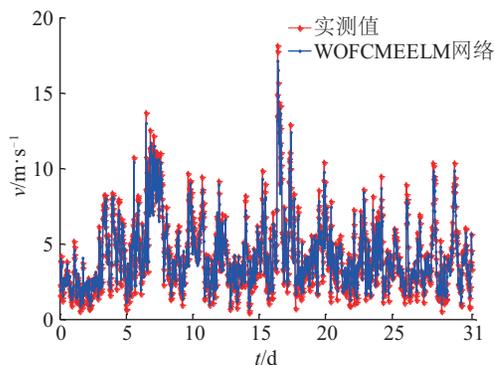


图5 5月份风速预测与实测结果对比

Fig. 5 Prediction results of wind speed in May

表5 5月份风速预测指标

Table 5 Forecasting index of wind speed in May

| 指标量 | WOFMMELM |
|------|----------|
| MAPE | 12.6173 |
| RMSE | 0.4972 |

5 结 论

本文结合实测数据提出一种基于属性加权FCM聚类的模块化ELM风速预测方法,结合实际风电场数据进行风速预测,得出以下结论:

1)对风速属性进行加权,可提高关联度高的属性因素在风速预测中的比重,降低与风速弱相关的属性因素的影响,从而有效提高预测精度。

2)采用GA+SA对FCM聚类算法的初始聚类中心进行优化,使结果易搜索到全局最优解,有利于提高风速预测模型的精度,仿真结果与实测数据对比验证了本文方法的准确性和可行性。

[参考文献]

- [1] 刘兴杰,郑文书.基于STCP-BP的风速实时预测方法研究[J].太阳能学报,2015,36(8):1799—1805.
- [1] Liu Xingjie, Zheng Wenshu. Study on real-time forecasting method of wind speed based on STCP-BP[J]. Acta Energetica Solaris Sinica, 2015, 36(8): 1799—1805.
- [2] 薛禹胜,郁琛,赵俊华,等.关于短期及超短期风电功率预测的评述[J].电力系统自动化,2015,39(6):141—151.
- [2] Xue Yusheng, Yu Chen, Zhao Junhua, et al. A review on short-term and ultra-short-term wind power prediction [J]. Automation Electric Power Systems, 2015, 39(6): 141—151.
- [3] 吴息,许婷婷,余江,等.风功率预测中的场风速指标的应用[J].太阳能学报,2016,37(2):310—315.
- [3] Wu Xi, Xu Tingting, Yu Jiang, et al. Application of wind speed indexes in field for wind power prediction

- [J]. *Acta Energiae Solaris Sinica*, 2016, 37(2): 310—315.
- [4] 杨锡运, 孙翰墨. 基于趋势项分析的时间序列风速多点预测研究[J]. *太阳能学报*, 2012, 33(10): 1697—1701.
- [4] Yang Xiyun, Sun Hanmo. Model based on time series prediction of wind speed [J]. *Acta Energiae Solaris Sinica*, 2012, 33(10): 1697—1701.
- [5] 柏丹丹, 和敬涵, 王小君, 等. 自适应粒子群支持向量机风速组合预测模型[J]. *太阳能学报*, 2015, 36(4): 792—797.
- [5] Bai Dandan, He Jinghan, Wang Xiaojun, et al. Combination model for forecasting wind speed based on adaptive PSO-SVM [J]. *Acta Energiae Solaris Sinica*, 2015, 36(4): 792—797.
- [6] 黄小华, 李德源, 吕文阁, 等. 基于人工神经网络模型的风速预测[J]. *太阳能学报*, 2011, 32(2): 193—197.
- [6] Huang Xiaohua, Li Deyuan, Lyu Wenge, et al. Wind speed prediction based on artificial neural network model [J]. *Acta Energiae Solaris Sinica*, 2011, 32(2): 193—197.
- [7] 刘进宝, 丁涛. 基于径向基函数神经网络的风速预测[J]. *太阳能学报*, 2012, 33(7): 1131—1135.
- [7] Liu Jinbao, Ding Tao. Wind speed prediction model based on radial basis functional neural network [J]. *Acta Energiae Solaris Sinica*, 2012, 33(7): 1131—1135.
- [8] 王辉, 刘达, 王继龙. 基于谱聚类和优化极端学习机的超短期风速预测[J]. *电网技术*, 2015, 39(5): 1307—1314.
- [8] Wang Hui, Liu Da, Wang Jilong. Ultra-short-term wind speed prediction based on spectral clustering and optimized extreme learning machine [J]. *Power System Technology*, 2015, 39(5): 1307—1314.
- [9] Zjavka L. Wind speed forecast correction models using polynomial neural networks [J]. *Renewable Energy*, 2015, 83: 998—1006.
- [10] Wang Jianzhou, Hu Jianming, Ma Kailiang, et al. A self-adaptive hybrid approach for wind speed forecasting [J]. *Renewable Energy*, 2015, 78: 374—385.
- [11] 杨锡运, 孙宝君, 张新房, 等. 基于相似数据的支持向量机短期风速预测仿真研究[J]. *中国电机工程学报*, 2012, 32(04): 35—41.
- [11] Yang Xiyun, Sun Baojun, Zhang Xinfang, et al. Short-term wind speed forecasting based on support vector machine with similar data [J]. *Proceedings of the CSEE*, 2012, 32(4): 35—41.
- [12] Wang Jianzhou, Wang Yun, Jiang Ping. The study and application of a novel hybrid forecasting model—A case study of wind speed forecasting in China [J]. *Applied Energy*, 2015, 143: 472—488.
- [13] Mishra N S, Ghosh S, Ghosh A. Fuzzy clustering algorithms incorporating local information for change detection in remotely sensed images [J]. *Applied Soft Computing*, 2012, 12(8): 2683—2692.
- [14] Yu Wenkai, Yao Xuri, Liu Xuefeng, et al. Ghost imaging based on Pearson correlation coefficients [J]. *Chinese Physics B*, 2015, 24(5): 344—349.
- [15] Huang Guangbin, Zhu Qinyu, Siew C K. Extreme learning machine: Theory and applications [J]. *Neurocomputing*, 2006, 70(1): 489—501.

A NEW MODULAR FORECASTING METHOD OF WIND SPEED

Pan Chao¹, Qin Benshuang¹, Cai Guowei¹, Yuan Chong²

(1. *School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China;*

2. *State Grid Zhejiang Chunan Power Supply Company, Chun'an 311700, China*)

Abstract: Aiming to the characteristic of the wind power plant having obviously strong randomness, volatility and the wind speed predicting difficult, a new modularization wind speed forecasting method was put forward in this paper. This method mainly includes three modules which is attribute weighting module, intelligent optimization clustering module and wind speed prediction module with extreme learning machine (ELM). First of all, considering the different weather attributes influencing on the wind speed and time fluctuation characteristics, the Pearson coefficient values of the attribute matrix elements were calculated and weighted. The fuzzy *c*-means clustering method optimized by genetic algorithm – simulated annealing algorithm was carried out on the weighted attribute matrix to cluster. Then the all kinds of wind speed forecasting models are built by using the extreme learning machine. Finally, the wind speed forecasting by this module is verified by the measurement data of America wind farm (N39.91°, W105.29°). The experimental results show that the method has very good prediction accuracy.

Keywords: wind speed forecasting; attributes weighted; fuzzy *c*-means clustering; extreme learning machine