

基于NWP单点聚类分析与BP神经网络的短期风电功率预测

采用学习方法建模进行短期风电功率预测时，模型的输入数据一般为数值天气预报（NWP），输入数据的选取对模型的准确性起着很重要的作用。通过单点聚类对风电场的历史NWP数据进行聚类分析，从中寻找与预测日单点NWP最相近的样本，运用神经网络建模对预测日的短期风电功率进行预测并对某风电场发电功率预测进行仿真实验，与未对NWP数据进行聚类处理的预测对比，证明了该方法的可行性和有效性。

方市彬 厉虹 王丽婕/北京信息科技大学自动化学院

0 引言

风能固有的波动性和间歇性给电力系统的安全稳定运行和电能质量带来了严重威胁。随着大规模风电接入电力系统，为了保证电网安全、稳定运行，需要对风电场发电功率进行预测^[1]。国外对风力发电功率预测进行了大量研究，其中丹麦、德国、西班牙和美国等国家在风力发电系统中将风电功率预测作为电网调度的一个重要参考依据。在这些国家，风电功率预测已经成为大型并网风电场管理系统和控制的基本组成部分^[2]。我国于2012年1月1日强制风电场安装风电功率预测系统。如果能对风速和风电功率进行比较准确的预测，则有利于电力系统调度部门及时调整调度计划，合理制定风电场控制策略，使风电成为可调度的电源；同时可以减轻风电不稳定性对电网的影响，大幅降低电网旋转备用

容量，有效降低风力发电成本^[3]。所以风力发电功率预测理论和方法的研究在风力发电领域具有重要地位和意义。

成熟的风电预测系统多采用预测效果较好的组合预测模型，即将单一预测模型进行加权组合，由于依赖单一预测模型，所以对单一预测方法的研究仍是基础和重点。目前，单一预测方法大都集中在学习方法和统计方法上。统计方法的实质是在系统的输入（NWP、历史统计数据及实测数据）和风电功率之间建立一个映射关系（通常为线性关系），并以解析法的形式描述出来^[4]。与统计方法不同，学习方法是基于人工智能策略，在输入与输出之间进行非线性建模，主要有神经网络法^[5]、小波分析法^[6-7]和支持向量机法^[8]等。

风电功率预测用学习方法建模时，训练样本的选取对模型的准确度有很大影响。为了提高预测的准确度，在前端数据处理上，很多预测模型都加入了聚类分析。文献[9]在分析风电场不同机组出力特性的基础上，利用数据挖掘和模糊聚类对机组进行分类，提高了实时预测的准确度。文献[10-11]运用相似日聚类分析分别建立了径向基神经网络的风速预测模型和时间序列法的风速预测模型。

上述聚类方法通常是先将历史数据分到每一天，然后运用一天内各项数据的平均向量来进行聚类。这就需要至少一天的连续数值天气预报（CNWP）数据，如果数据被打乱，则对风电功率



方市彬/硕士研究生

关键词/Keywords

风电功率预测·
聚类分析·
数值天气预报·

国家自然科学基金项目（11472058），北京市教委科技计划面上项目（KM201511232007）。

预测将有很大影响,由于这种方法采用的是平均向量,可能会使气象信息波动较大的一天与变化平稳的一天聚类在一起,易使不应聚到一类的个体聚到一类,影响最终预测的准确度。本文提出一种基于单点数值天气预报(SNWP)聚类的BP神经网络风电功率预测方法。将一段时间的历史NWP数据按分辨率点进行聚类分析,再将各类数据作为神经网络的输入,实验表明SNWP方法能够较好地提高预测的准确性。

1 聚类分析的原理

聚类分析就是一个在数据集中寻找相似元素集合的无监督学习过程^[12],是一种多元统计分析方法。聚类分析的基本思想是将没有类别标记的样本或数据按照某种标准或准则划分成若干类,使相似的样本尽可能在一类中,而不相似的样本尽量划分到不同的类中。本文主要运用了模糊C均值聚类算法与模糊减法聚类。其中模糊C均值聚类对样本的不确定性描述能较客观地反映真实情况,但运用这种方法对数据聚类时需要预先知道聚类的种数。采用模糊减法聚类,其特点是可以对没有先验信息的数据确定相应的分类数。

模糊C均值聚类算法(Fuzzy C-Means, FCM)是硬C均值聚类的推广,在硬划分中,要么属于指定的类,要么不属于该类,二者必占其一。而模糊聚类则是样品以一定的概率属于指定的类。算法通过最小化基于某种范数和聚类原型的目标函数将没有标签的数据进行分类。

设 $X = \{x_1, x_2, \dots, x_n\}$ 为样品集, n 为样品容量, C 为聚类数, u_{ij} 为第 j 个样本属于第 i 个中心的隶属度,且其隶属度矩阵为

$$\sum_{i=1}^C u_{ij} = 1 \quad (u_{ij} \geq 0) \quad (1)$$

模糊C均值聚类是求解式(2)的优化问题,即

$$\text{Minimize } J_m(U, V) = \sum_{j=1}^n \sum_{i=1}^C u_{ij}^m (x_j - v_i)^2 \quad (2)$$

具体步骤为:

1) 给定聚类类别数 C , $2 \leq C \leq n$, 其中 n 是数据个数,设定加权指数 m ,初始化隶属度矩阵 $U =$

(u_{ij}) , 使得 $\sum_{i=1}^C u_{ij} = 1$ 。

2) 根据式(3)

$$v_i = \frac{\sum_{j=1}^n (u_{ij})^m x_j}{\sum_{j=1}^n (u_{ij})^m} \quad 1 \leq i \leq C \quad (3)$$

计算聚类中心 v_i , $i = 1, 2, \dots, C$ 。

3) 根据式(4)

$$u_{ij} = \left[\sum_{k=1}^C \left(\frac{(x_j - v_i)^2}{(x_j - v_k)^2} \right)^{1/(m-1)} \right]^{-1} \quad 1 \leq i \leq C, 1 \leq j \leq n \quad (4)$$

计算新的隶属度矩阵。

4) 若 $J_m(U, V)$ 小于预先给定的正数 ε ,则聚类过程结束,否则转到步骤2)。

2 预测模型

在建立模型前,需要对训练数据进行聚类预处理。采用模糊C均值聚类时,需要知道分类数,考虑对于数据的分类数没有先验信息,所以采用模糊减法聚类来确定相应的分类数。

风电功率预测对NWP原始样本数据具有敏感依赖性,要提高预测准确度就应选取合适的样本作为模型的输入数据。NWP数据的时间间隔为15 min,每组信息中包含风速、风向、温度和气压。由于历史数据量很大,为了获得对预测准确度影响最大的数据,首先对历史数据进行聚类分析,得到各类的聚类中心,运用欧氏距离法查找与预测日各点数据最相似的点作为训练样本;再利用各类中的数据点训练对应的BP神经网络,并保存各个网络权值。单层BP神经网络能够以任意准确度逼近任何非线性映射,可以学习和适应未知信息,三层网络理论上就可以逼近任何非线性函数^[13]。因此预测模型采用单隐含层的BP神经网络。隐含层节点数采用逐渐递增使误差最小的方法得到,经过逐一筛选后得到隐含层节点数为10,隐含层节点数过多或过少都会使误差变大。模型结构如图1所示。

随后计算预测日各个数据点与聚类中心的欧氏




图1 BP神经网络模型结构

距离并归类。最后依据各点的归属类选择相应的网络进行预测。模型建立的具体过程如图2所示。




图2 基于单点聚类风电功率预测框图

3 实际风力发电功率预测

对我国某风电场2012年1~2月的NWP数据和实测功率数据进行分析、建模和预测。NWP数据的时间间隔为15 min。以2012年2月4日作为预测日，预测步长为一天（96个点）。NWP数据提供了风电场单位位置的风速、风向、气温和气压四个信息。

3.1 聚类分析结果

为方便处理，每个点的数据对象用五维向量表示为 $X=[V, D_{\cos}, D_{\sin}, T, P]$ ，其中的变量依次为分辨率点的风速、风向余弦值、风向正弦值、气温和气压值。

由于NWP向量中各分量的量纲不同，需要对其进行归一化处理，风速、气压分别除以各自的历史最大值，风向正弦和余弦值均为归一化数值不需要再作处理。

预测各点与聚类中心的距离用欧式距离来进行计算，计算公式如下

$$d_i = \left\{ \sum_{k=1}^5 [x_m(k) - v_i(k)]^2 \right\}^{1/2} \quad (5)$$

式中， d_i 为预测点与聚类中心的欧氏距离； x_m 为预测点的NWP向量； v_i 为历史数据的聚类中心的NWP向量， $i=1, 2, \dots, C$ ，其中 C 为聚类数。

选择2012年1月1~30日30天的历史数据共2 880个点做聚类分析，由于对分类数没有先验信息，先采用模糊减法聚类确定其聚类数，后用模糊C均值聚类确定其聚类中心。

由模糊减法聚类确定其聚类数 $K=4$ ，其中有451个点属于第1类，有1 005个点属于第2类，有517个点属于第3类，有907个点属于第4类。由式（3）计算出这4类的归一化后的聚类中心为

第1类：[0.369 4 -0.060 4 0.085 0 0.764 4 0.993 1]

第2类：[0.381 9 -0.016 1 -0.023 1 1.110 5 0.990 7]

第3类：[0.382 8 0.020 2 0.138 9 1.312 3 0.990 0]

第4类：[0.338 9 -0.037 7 0.000 9 0.946 0 0.992 1]

由式（5）分别计算出预测日2012年2月4日与这4个聚类中心的欧氏距离，并取最小值，得到96个点所属的类别如表1所示。

表1 预测日各点所在聚类情况

样本点	1	2	3	4	5	6	7	8	9	10
所属类	4	4	4	4	4	4	4	4	2	2
样本点	11	12	13	14	15	16	17	18	19	20
所属类	2	2	2	2	2	2	2	2	2	2
样本点	21	22	23	24	25	26	27	28	29	30
所属类	2	2	2	2	2	2	2	2	2	2
样本点	31	32	33	34	35	36	37	38	39	40
所属类	2	2	2	2	2	2	4	4	4	4
样本点	41	42	43	44	45	46	47	48	49	50
所属类	4	4	4	4	4	4	1	1	1	1
样本点	51	52	53	54	55	56	57	58	59	60
所属类	1	1	1	1	1	1	1	1	1	1
样本点	61	62	63	64	65	66	67	68	69	70
所属类	1	1	1	1	1	1	1	1	1	1
样本点	71	72	73	74	75	76	77	78	79	80
所属类	1	1	1	1	1	1	1	1	1	1
样本点	81	82	83	84	85	86	87	88	89	90
所属类	1	1	1	1	1	1	1	1	1	1

(续)

样本点	91	92	93	94	95	96
所属类	1	1	1	11	1	1

3.2 实验结果

模型的输入向量为五维归一化处理 and 聚类处理后的NWP数据, 隐含层个数为10, 输出层为对应时刻的风电功率预测值。分别用聚类后的各类历史NWP数据对BP神经网络进行训练, 保存各类对应的权值和阈值, 运用距聚类中心的欧氏距离最小对预测日各点数据进行分类, 使用具有不同权值和阈值的BP神经网络对2012年2月4日各类NWP点进行功率预测。

图3为单纯运用BP神经网络和加入聚类分析的BP神经网络各自的预测功率曲线。从图中可以看出, 采用单点NWP聚类分析后的BP神经网络模型所得的预测值更接近实际值。表2列出了两种模型的平均绝对误差(NMAE)和均方根误差(NRMSE)。由表2可知, 采用单点NWP聚类的BP神经网络模型的平均绝对误差和均方根误差相较于单纯采用BP神经网络预测时的误差和均方根误差数据都有所下降, 预测效果比较理想。可将平均绝对误差降低1.50%, 均方根误差降低3.80%。说明基于单点NWP聚类分析可以对预测时间段附近分散的历史NWP数据进行聚类, 克服了




图3 模型预测结果对比

表2 各预测模型的误差对比

预测模型	NMAE(%)	NRMSE(%)
BP神经网络	18.80	22.85
单点NWP聚类的神经网络	17.30	19.05

历史数据必须连续的缺点。

4 结束语

数值天气预报对于风电功率预测的准确性影响很大。如果单纯运用神经网络对风电功率预测需要大量连续的历史NWP数据, 并且预测曲线和各种误差并不理想。如果对NWP数据进行单点聚类处理, 则不需要大量连续的历史NWP数据, 克服了必须使用连续时间NWP数据的缺点, 而且聚类分析后所选用的训练样本与预测时刻的情况更接近, 使预测准确性有所提高。

参考文献

- [1] 张文秀, 武新芳, 陆豪乾. 风电功率预测技术综述与改进建议 [J]. 电力与能源, 2014, 35 (4): 436-441.
- [2] Watson S J, Landberg L, Halliday J A. Application of wind speed forecasting to the integration of wind energy into a large scale power system [J]. IEEE Proceedings of Generation Transmission & Distribution, 1994, 141 (4): 357-362.
- [3] Kurt Rohrig, Bernhard Lange. Application of wind power prediction tools for power system operations [C]. IEEE Power Engineering Society General Meeting, 2006.
- [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]. 电力系统保护与保护, 2009, 37 (4): 118-121.
- [5] Li S. Wind power prediction using recurrent multilayer perceptron neural networks [C]. Power Engineering Society General Meeting, IEEE, 2003: 2325-2330.
- [6] 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, 36 (16): 44-48.
- [7] 王晓兰, 王明伟. 基于小波分解和最小二乘支持向量机的短期风速预测 [J]. 电网技术, 2010, 34 (1): 179-184.

(下转第72页)

- applications [J]. IEEE Transactions on Industrial Electronics, 2006, 53 (2) : 486-494.
- [3] Moor G D, Beukes H J. Maximum power point trackers for wind turbines [C]. IEEE 35th Annual Power Electronics Specialists Conference, 2004 : 2044-2049.
- [4] 宋卓彦, 王锡凡, 滕予非, 等. 变速恒频风力发电机组控制技术综述 [J]. 电力系统自动化, 2010, 34 (10) : 8-17.
- [5] 吴政球, 干磊, 曾议, 等. 风力发电最大风能追踪综述 [J]. 电力系统及其自动化学报, 2009, 21 (4) : 88-93.
- [6] 朱翔, 高强, 李征, 等. 基于自建永磁直驱风电机组数学模型的三种MPPT控制模式的比较研究 [J]. 华东电力, 2013, 41 (2) : 341-346.
- [7] Younsi R, Eibatany I, Tritsch J B, et al. Dynamic study of a turbine blade with horizontal axis [J]. European Journal of Mechanics A/Solids, 2001, 20 (2) : 241-252.
- [8] Nicholas W M, Juan J S-G, William W P. Dynamic modeling of GE 1.5 and 3.6 MW wind turbine generators for stability simulation [R]. USA: GE Power Systems Energy Consulting, 2003.
- [9] 周志超, 王成山, 郭力, 等. 变速变桨距风电机组的全风速限功率优化控制 [J]. 中国电机工程学报, 2015, 35 (8) : 1737-1844.
- [10] 杨晓萍, 郭鑫. 直驱式永磁风力发电机组并网控制 [J]. 电力系统及其自动化学报, 2010, 22 (1) : 65-70.
- [11] 赵仁德, 王永军, 张加胜. 直驱式永磁同步风力发电机组最大功率追踪控制 [J]. 中国电机工程学报, 2009, 29 (27) : 106-111.
- [12] 尹明, 李庚银, 张建成, 等. 直驱式永磁同步风力发电机组建模及其控制策略 [J]. 电网技术, 2007, 31 (15) : 61-65.
- [13] 何仰赞, 温增银. 电力系统分析 [M]. 武汉: 华中科技大学出版社, 2010.
- [14] 管维亚, 吴峰, 鞠平. 直驱永磁风力发电系统仿真与优化控制 [J]. 电力系统保护与控制, 2014, 42 (9) : 54-60.
- [15] Omid A, Amirnaser Y. A strategy for real power control in a direct-drive PMSG-based wind energy conversion system [J]. IEEE Transactions on Power Delivery, 2013, 28 (3) : 1297-1305.
- (收稿日期: 2016-11-17) **EA**

(上接第65页)

- [8] 丁志勇. 基于相似日聚类的支持向量风电功率预测方法 [J]. 电气应用, 2013, 32 (19) : 25-28.
- [9] 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.
- [10] 朱峰, 孙辉, 周玮. 基于相似日聚类的神经网络风速预测 [C]. 中国高等学校电力系统及其自动化专业第二十四届学术年会议论文集 (下册), 2008.
- [11] 方江晓, 周晖, 黄梅, 等. 基于统计聚类分析的短期风电功率预测 [J]. 电力系统保护与控制, 2011, 39 (11) : 67-74.
- [12] 王骏, 王士同, 邓赵红. 聚类分析中的若干问题 [J]. 控制与决策, 2012, 27 (3) : 321-32.
- [13] 范高峰, 王伟胜, 刘纯. 基于人工神经网络的风电功率短期预测系统 [J]. 电网技术, 2008, 32 (22) : 72-76.
- (收稿日期: 2016-12-13) **EA**