

基于风电机组健康状态的风电场功率分配研究

刘 军, 汪继勇

(西安理工大学自动化与信息工程学院, 陕西 西安 710048)

摘要: 评价风电机组健康状态, 合理分配风电场中风电机组的功率, 对降低风电场的运维成本有着重要意义。首先, 利用风电机组监控与数据采集(supervisory control and data acquisition, SCADA)系统中的风电机组历史运行数据, 训练基于长短期记忆(long short-term memory, LSTM)网络的风电机组输出功率预测模型。然后, 根据预测功率和风电机组实测输出功率的偏差幅值将风电机组的健康状态分为良好、一般、较差等三个类别。最后, 综合考虑风电场中每台机组的健康状态、最大发电能力和电网调度部门对风电场下达的发电指令, 建立目标函数和约束条件, 采用遗传算法进行求解, 得到分配给每台机组的功率。仿真结果表明, 所提出的方法不仅能够根据风电机组的健康状态合理分配机组功率, 而且能够满足调度中心下达的风电场总的发电功率。

关键词: 风电机组; 风电场; 状态评估; 功率分配; LSTM网络

Research on power distribution of a wind farm based on the healthy state of wind turbines

LIU Jun, WANG Jiyong

(School of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China)

Abstract: Evaluating the health status of wind turbines and reasonably allocating their output power is of great significance in reducing the operational and maintenance costs of wind farms. First, an output power prediction model of wind turbines based on a Long Short-Term Memory (LSTM) network is trained using the historical operational data in the Supervisory Control and Data Acquisition (SCADA) system. Then, according to the deviation amplitude between measured output power of wind turbines and its predicted output power, the health status of wind turbines can be divided into three categories: good, average, and bad. Finally, for the health status of each wind turbine, the maximum generating capacity of each wind turbine and power generation directives from power grid dispatching departments to wind farms are established, along with the objective function and constraint formula. A genetic algorithm is used to solve the problem. Thus the output power allocated to each wind turbine is obtained. The simulation results show that the method proposed can not only distribute the power reasonably according to the health status of the wind turbine, but also meet the total power of the wind farm given by the dispatching center.

This work is supported by Shaanxi Provincial Key Research and Development Plan of China (No. 2017GY-061).

Key words: wind turbine; wind farm; health status evaluation; power allocation; LSTM network

0 引言

随着经济的快速发展, 人们对电能的需求不断增加, 能源短缺和环境污染问题日益突出。风能作为一种清洁、可再生能源, 得到广泛的开发和利用^[1-3]。风电机组一般工作在较为恶劣的环境中, 维护成本较高。风速的随机性和间歇性使风电场输出功率存在较大的波动, 大规模的风电输出功率波动导致电

网调节能力不足, 电网对风电的接纳能力受限, 因此风电机组多运行在限功率模式下^[4]。由于风电场中各风电机组运行条件不同, 风电机组的发电能力、运行状态也存在较大差异。因此, 研究风电机组的健康状态评价方法, 并根据风电机组的健康状态和风电场的目标发电量合理分配各台风电机组的功率, 对于降低风电场的运维成本、提高风电机组运行的可靠性、使风电场输出功率较准确地跟踪电网指令, 都具有重要的意义^[5]。

近年来, 风电机组健康状态评价方法的研究引

起了风电领域的广泛关注。风电机组功率曲线是衡量机组健康状态的重要标志, 通过研究功率曲线能识别风电机组的异常状态^[6-8]。现有文献多是使用基于数据驱动的方法估计风电机组的输出功率^[9-10]。文献[11]使用极限学习机模型预测风电机组的输出功率, 并引入误差校正模型, 降低预测误差。文献[12]使用风电机组输出功率的估计值和实测风速构建表示风电机组健康状态的 Copula 模型, 评价机组健康状态。但是上述文献仅使用了风电机组当前时刻的运行状态数据预测风电机组输出功率。考虑风电机组运行工况可以提高风电机组健康状态评价的准确性^[13-16], 然而这种方法受限于运行工况分类的准确性^[17]。文献[18]通过使用模糊 FMECA 方法对风电机组常见故障及其危害性进行分析, 有助于风电机组的健康状态评价研究, 但没有给出风电机组健康状态评价方法。文献[19-21]引入劣化度指标, 对风电机组某一时刻的健康状态进行评价, 但仅考虑机组某一时刻的运行状态数据可能会产生误差。文献[22]采用功率预测信息优化风电场有功指令分配方法, 使风电机组控制系统动作次数减少。文献[23]分析了风电机组的限功率运行特性, 并在风电场有功指令分配中考虑了机组限功率状态。但是, 文献[22-23]在分配风电场有功指令时, 都没有考虑风电场中风电机组的健康状态。文献[24-25]虽然在分配风电场有功指令时考虑了风电机组的健康状态, 但是在评价风电机组的健康状态时, 仅使用风电机组当前时刻的运行状态数据。

本文提出一种基于风电机组健康状态的风电场机组功率分配方法。该方法能够根据风电机组的健康状态进行风电机组的有功指令分配, 对健康状态好的风电机组分配较大的功率给定, 对健康状态差的风电机组分配较小的功率给定, 并且使风电场整体输出功率达到电网调度中心下达的功率指令, 这样既可充分发挥健康状态好的风电机组的发电能力, 又能避免健康状态不佳的风电机组健康状态进一步恶化, 因此, 本文所提算法对于提高风电场机组运行可靠性、降低风电场的运维成本有着重要意义。

本文首先根据风速、风轮转速、齿轮箱高速轴转速和发电机转速, 使用 LSTM 网络预测风电机组的输出功率。然后根据预测的风电机组输出功率和实测的输出功率的偏差, 将风电机组的健康状态分为良好、一般和较差三种类型。在此基础上, 设置了健康状态越差的机组分配越小的功率给定以及风电场整体输出功率达到电网调度中心下达的功率给定指令的优化目标, 采用遗传算法优化分配给各个

风电机组功率给定。

本文的第一节详细描述了风电机组输出功率预测模型建立步骤和数学原理。第二节描述了如何在风电机组输出功率预测基础上, 评价风电机组的健康状态。第三节描述了基于风电机组健康状态的风电场机组功率分配的原理。第四节使用风电机组的 SCADA 数据验证了风电机组健康状态评价原理的正确性, 并通过仿真验证了本文所提出的基于风电机组健康状态的风电场机组功率分配方法的有效性, 该方法既能够避免健康状态不佳的风电机组运行状态进一步恶化, 又能使整个风电场输出功率达到电网调度中心下达的功率给定指令。第五节对基于风电机组健康状态的风电场机组功率分配方法研究进行了总结。

1 风电机组输出功率预测模型

以往文献在预测风电机组输出功率时, 使用的预测模型大多仅考虑到风电机组当前时刻的运行状态数据对输出功率的影响。然而, 风电机组作为一种大型旋转机械, 惯性较大, 其输出功率不仅与当前时刻风速、转速等有关, 而且与当前时刻之前的一段时间内的风速、转速等有关。因此, 本文使用一种带记忆的神经网络模型 LSTM 网络反映一段时间内风电机组风速、转速等特征数据与当前时刻风电机组输出功率之间的内在联系。

1.1 LSTM 网络模型

LSTM 网络是一种带记忆的神经网络模型, 其结构原理如图 1 所示, 可以用来表示风电机组输出功率与风速、转速等变量之间的关系。LSTM 网络可以由一个或多个 LSTM 单元组成, 分别表示数据在时间序列上相互独立和连续多个时刻的数据对当前时刻数据的影响。图 1 中, x_t 、 h_t 、 c_t 分别是 t 时刻 LSTM 单元的输入数据、隐藏状态和细胞状态。LSTM 单元由信息存储链、遗忘门、输入门和输出门等四个部分组成。信息存储链贯穿 LSTM 网络前后所有 LSTM 单元, 负责记忆信息的存储和传递, 在每个 LSTM 单元信息存储链上的信息都会被更新。遗忘门的输出为 f_t , 其值在 0 和 1 之间, 表示遗忘上一个单元细胞状态的概率, 遗忘门的数学表达式如式(1)所示。

$$f_t = \sigma(\omega_1 \cdot (h_{t-1}, x_t) + b_1) \quad (1)$$

式中: ω_1 、 b_1 分别是遗忘门的权重向量和偏值; σ 是 sigmoid 激活函数。输入门由两部分组成, 第一部分使用 sigmoid 激活函数, 记输出为 i_t ; 第二部分使用 tanh 激活函数, 记输出为 a_t 。

$$i_t = \sigma(\omega_2 \cdot (h_{t-1}, x_t) + b_2) \quad (2)$$

$$a_t = \tanh(\omega_3 \cdot (h_{t-1}, x_t) + b_3) \quad (3)$$

式中, ω_2 、 b_2 和 ω_3 、 b_3 分别是第一部分和第二部分的权重向量和偏移值。输出门的输出为 o_t , 如式(4)所示。

$$o_t = \sigma(\omega_4 \cdot (h_{t-1}, x_t) + b_4) \quad (4)$$

细胞状态 c_t 和隐藏状态 h_t 的更新公式分别如式(5)和式(6)所示。

$$c_t = (c_{t-1} \otimes f_t) \oplus (i_t \otimes a_t) \quad (5)$$

$$h_t = \tanh(\omega_5 \cdot c_t + b_5) \otimes o_t \quad (6)$$

式中, ω_5 、 b_5 分别是权重向量和偏移值。




图 1 LSTM 结构原理图

Fig. 1 LSTM structure schematic diagram

1.2 数据处理

为了降低样本在不同特征上的幅值偏差对模型精确度的影响, 在训练 LSTM 网络模型前, 需要对样本数据进行标准化处理, 如式(7)所示。

$$\bar{x}_i = \frac{\bar{x}_i - \frac{1}{N} \sum_{j=1}^N \bar{x}_j}{\sqrt{\frac{1}{N} \sum_{j=1}^N (\bar{x}_j - \frac{1}{N} \sum_{j=1}^N \bar{x}_j)^2}} \quad (7)$$

式中: $\bar{x}_i = [x_{i1}, x_{i2}, x_{i3}, x_{i4}]$ 是第 i 个标准化后的样本特征向量; $\frac{1}{N} \sum_{j=1}^N \bar{x}_j$ 是均值向量; $\bar{x}_i$ 是第 i 个原始特征向量; N 是样本个数。

相比于回归问题, LSTM 网络模型在分类问题上效果更好^[26]。为了将回归问题转化为分类问题, 以 m 为间隔, 将风电机组的输出功率分为 p 类。再将类别进行独热编码, 类别与独热编码向量之间的关系如表 1 所示。本文中 m 是 50 kW, p 是 31。

表 1 类别编码表

Table 1 Category code table

类别	编码
1	[1,0,0,L,0]
2	[0,1,0,L,0]
L	L
n	[0,0,0,L,1]

表 1 中每个类别的编码长度都为 p 。

为了增加模型的精度, 本文在构建基于 LSTM 网络的风电机组输出功率预测模型时, 在 LSTM 层的输出后加了两层神经网络, 最后一层神经网络是模型的输出层, 有 p 个神经元。为了提高模型的泛化能力, 随机断开一定比例的 LSTM 层网络与其后第一层神经网络之间的连接。模型的激活函数为 softmax 函数, 选择 Adam 优化算法, 通过最小化交叉熵损失函数最优化模型中的各个参数。

对于待预测的样本数据, 将最大概率值所对应的类作为样本所属的类别。由于控制误差、风速突变等干扰因素的存在, 为了提升模型预测精度和泛化能力, 在 0 至 m 之间随机生成一个值加在样本所属类别的起始值上, 作为样本在风电机组输出功率预测模型中的预测值。

2 风电机组健康状态评价

风电场多分布于偏远地区, 并且风电机组运行的环境有时还十分恶劣, 研究风电机组健康状态评价方法, 优化风电机组功率分配, 对减小风电机组故障率, 降低风电场运维成本有着重要意义。图 2 所示为本文风电机组健康状态评价原理流程图。首先选用处于良好运行状态的风电机组运行数据, 构建基于 LSTM 网络风电机组输出功率预测模型。然后根据待评估风电机组运行数据预测得到的输出功率与实测的输出功率的偏差来评价风电机组健康状态。




图 2 风电机组健康状态评价原理图

Fig. 2 Schematic diagram of wind turbine health status evaluation

当机组的预测输出功率与其实测输出功率的偏差较小时, 风电机组处于良好的健康状态, 当偏差的较大时, 风电机组健康状态较差^[15]。根据预测输出功率与实测输出功率的偏差幅值, 将风电机组的

健康状态分为良好、一般和较差。为了量化风电机组健康状态类别与偏差幅值的关系, 本文使用正态分布拟合偏差信号的分布函数。通过式(8), 可以知道偏差信号的上 α 分位点。

$$v_\alpha = \bar{v} + \sigma v_\alpha^* \quad (8)$$

式中: $\bar{v}$ 为偏差的均值; σ 为偏差的标准差; v_α^* 是标准正态分布的上 α 分位点, 其值可以通过查标准正态分布表得到; v_α 是偏差分布的上 α 分位点。当 α 确定后, 通过式(8)可以得到对应 v_α 值。 α 表示偏差大于某一点的概率, 其值越小表示被考虑的偏差值越大。当偏差绝对值在偏差幅值的前 1% 时, 风电机组健康状态很差; 当偏差绝对值在偏差幅值的前 25% 到 1% 之间时, 风电机组的健康状态一般^[5]。因此可得风电机组健康状态与偏差值的关系如表 2 所示。

表 2 健康状态与偏差范围关系表

Table 2 Relation table between health status and deviation range

健康状态	偏差范围/kW
良好	$v_{0.875} < v \leq v_{0.125}$
一般	$v_{0.125} < v \leq v_{0.005}$ 或 $v_{0.995} < v \leq v_{0.875}$
差	$v \leq v_{0.995}$ 或 $v > v_{0.005}$

3 风电场功率优化分配

由于风的随机性和间歇性, 并网的风电场多处于限功率运行状态。受风速等因素的影响, 风电场中每台机组的最大发电能力不同, 且每台风电机组的健康状态也存在差异。风电场在接到电网调度中心发出的指令后, 如何根据每台风电机组的最大发电能力和健康状态合理分配每台机组的发电任务是本节的主要研究问题。

基于风电机组健康状态的风电场功率分配流程如图 3 所示, 在新的调度指令下达前, 通过使用 1、2 节所描述的方法评价每台机组健康状态, 综合考虑电网调度中心下达的发电指令和每台风电机组的最大可发电能力及其健康状态, 分配发电指令。在分配风电场功率时, 为了使风电场的总发电功率满足电网调度中心下达的发电要求, 且降低健康状态差的风电机组的功率给定, 建立两个优化目标如下。

1) 风电场的总发电量等于电网调度中心下达的发电指令, 如式(9)所示。

$$\sum_{i=1}^n p_{\text{ref}}^i = p_{\text{total}} \quad (9)$$

式中: n 是风电场中风电机组台数; p_{ref}^i 是分配到第 i 台机组的功率给定; p_{total} 是该调度周期电网调度中

心对风电场下达的功率给定指令。

2) 风电场的总健康衰退度最低。某个调度周期风电场的总健康衰退度为

$$S = \sum_{i=1}^n \frac{p_{\text{ref}}^i}{p_{\text{max}}^i} S_i \quad (10)$$

式中: S 是风电场的总健康衰退度; n 是风电场风电机组台数; p_{max}^i 和 p_{ref}^i 分别是第 i 台机组可输出的最大功率和被分配的功率指令; S_i 是第 i 台机组的健康衰退度。风电机组的健康状态越差, 机组的健康衰退度越大, 当风电机组的健康状态为良好、一般和较差时, 机组的健康衰退度分别取 0、3 和 6。




图 3 风电场功率分配原理图

Fig. 3 Power distribution schematic diagram of wind farm

为了提高控制精度, 应当设置风电机组的最低输出功率为风电机组额定功率的 20%^[23]。因此, 在每个调度周期, 可以得到目标函数和约束条件分别如式(11)、式(12)所示。

$$\min \left\{ a \cdot \left| \sum_{i=1}^n p_{\text{ref}}^i - p_{\text{total}} \right| + b \cdot \sum_{i=1}^n \frac{p_{\text{ref}}^i}{p_{\text{max}}^i} S_i \right\} \quad (11)$$

$$p_{\min} \leq p_{\text{ref}}^i \leq p_{\text{max}}^i \quad (12)$$

式中: a 、 b 分别为两个优化子目标的权重系数; $p_{\min}$ 为单台风电机组的最低输出功率。通过求目标函数在约束公式下的解, 可以得到风电场对每台机组下达的发电指令。

4 算法验证

4.1 参数选取

实验数据来自额定功率为 1.5 MW 的风电机组 SCADA 系统, 数据每隔 30 s 采样一次。SCADA 系统记录了风电机组 25 个参数的运行数据, 包括风速、风向、风轮转速和输出功率等参数。风电机组在实际运行中, 运行工况复杂, 导致风电机组在风速很高时输出功率很低的原因既可能是风电机组发生故障, 也可能是风电机组处于限功率运行状态。

风速和风轮转速之间的关系，可以反映风电机组是否处于限功率运行状态。齿轮箱高速轴转速和发电机转速也是反映风电机组健康状态的重要参数，因此，本文使用风速、风轮转速、齿轮箱高速轴转速和发电机转速作为输入参数，构建风电机组输出功率预测模型。

选择风电机组处于健康状态的历史运行数据，按照本文第一节所描述的方法训练风电机组的输出功率预测模型，模型中 LSTM 层网络参数如表 3 所示。

在风电机组处于健康状态时，风电机组的实测输出功率与其预测输出功率如图 4 所示。从图 4 可知，本文所提出的风电机组输出功率预测模型可以准确地预测风电机组输出功率。

表 3 模型部分参数表

Table 3 Partial parameter of model table

参数	数值
LSTM 状态数	15
LSTM 隐藏层数	62
LSTM 神经元个数	930

预测模型得到的 1.5 MW 的风电机组的输出功率与该机组在发生故障前的一段时间的实际输出功率的偏差如图 5 所示。功率偏差的 $V_{0.005}$ 、 $V_{0.125}$ 、 $V_{0.875}$ 和 $V_{0.995}$ 分别是 224.89 kW、91.28 kW、-53.67 kW 和 -187.28 kW。从图 5 可知，在故障发生前的 6 个小时左右，机组输出功率预测值和实测值的偏差幅值明显增大。这说明风电机组的健康状态随着风电机组的实测值和预测值的偏差幅值增大而衰退。




图 4 预测输出功率和实测输出功率图

Fig. 4 Predicted output power and measured output power diagram




图 5 待评估风电机组的实测输出功率与预测值输出功率偏差

Fig. 5 Deviation between predicted output power and measured output power of wind turbines

4.2 仿真分析

为了验证本文所提的基于风电机组健康状态的风电场功率分配优化算法能够使风电场在满足电网

调度中心下达的发电指令要求的基础上，降低健康状态差的风电机组的发电任务，以 10 台额定功率为 1.5 MW 的风电机组、5 个调度周期为例对算法进行

仿真。在 5 个调度周期中, 风电场得到的调度指令分别为 7 MW、8 MW、8 MW、7 MW、8 MW。10 台风电机组的健康衰退度分别为 0、0、0、3、3、3、3、6、6、6, 并保持不变。10 台风电机组的最大可输出功率(单位: MW)及其所对应的风速(单位: m/s)如表 4 所示。

表 4 单台风电机组可输出最大功率及其所对应的风速表

Table 4 Maximum output power and wind speed table for each wind turbine

周期	WT1	WT2	WT3	WT4	WT5	WT6	WT7	WT8	WT9	WT10
1	1.1 11.67	1.3 12.39	1.2 12.03	1.1 11.67	1.1 11.67	1.0 11.31	1.2 12.03	1.0 11.31	1.1 11.67	1.1 11.67
2	1.0 11.31	1.5 13.14	1.0 11.31	1.3 12.39	1.0 11.31	1.2 12.03	1.0 11.31	0.9 10.92	1.0 11.31	1.2 12.09
3	1.2 12.03	1.2 12.03	1.1 11.67	1.2 12.03	1.2 12.03	1.0 11.31	1.2 12.09	1.2 12.09	1.0 11.31	1.2 12.09
4	1.1 11.67	1.0 11.31	1.1 11.67	1.3 12.39	1.1 11.67	1.2 12.03	1.1 11.67	1.0 11.31	1.1 11.67	1.0 11.31
5	1.3 12.39	1.1 11.67	1.2 12.03	1.1 11.67	1.0 11.31	1.1 11.67	1.3 12.39	1.1 11.67	1.2 12.09	1.1 11.67

本文所提出的风电场功率分配优化算法中有两个优化目标, 为了得到合适的权重系数比值, 在权重系数取不同的比值时, 使用遗传算法对目标函数进行求解。然后计算风电场的总发电量与电网调度中心下达的发电指令的偏差绝对值和风电场的总健康衰退度在 5 个调度周期中的均值, 其结果如表 5 所示。由表 5 可知, 随着优化子目标权重系数 a 与 b 的比值减小, 风电场健康衰退度逐渐减小至 0; 当权重系数比值减小到 1:3 时, 风电场发电量偏差开始从 1:1.5 时刻的 0 增加到 1.62 MW。因此, 选择两个优化子目标的权重系数比为 1:1.5 比较合适。

表 5 权重系数比 $a:b$ 对优化结果的影响

Table 5 Influence of weight coefficient ratio $a:b$ on optimization results

权重系数比	风电场发电量偏差/MW	风电场健康衰退度
4:1	0	17.30
3:1	0	15.95
1.5:1	0	14.58
1:1	0	14.69
1:1.5	0	13.86
1:3	1.62	10.30
1:4	7.60	0.00

变比例分配算法是一种常用的风电场功率分配算法, 根据风电机组最大输出功率, 按照最大输出功率越大分配越多的发电任务的原则, 为每台风电机组分配发电任务^[22]。图 6 为使用变比例分配算法时, 在每个调度周期, 每台风电机组的输出功率曲线。使用本文所提出的基于风电机组健康状态的风电场发电功率分配算法时, 在每个调度周期, 每台机组的输出功率如图 7 所示。在 5 个调度周期内, 健康状态比较差的 8 号、9 号、10 号机组在本文所提出功率分配算法下的输出功率与变比例分配算法

在每个调度周期, 通过控制风电机组的发电机转速和桨距角, 使风电机组的输出功率满足风电场下达的发电指令要求。不失一般性, 在 Simulink 平台上搭建风电机组输出功率控制模型, 每个调度周期时长为 100 s, 使用文献[27]中输出功率控制方法, 控制风电机组的输出功率。

相比, 分别降低了 54%、56%和 55%。通过分析图 6 和图 7 可知, 两种风电场功率分配算法在每个调度周期都能使风电场的总发电功率满足上级电网调度中心下达的发电指令要求。但变比例分配算法只考虑风电场中每台机组的最大可发电能力, 忽视了风电机组健康状态, 使健康状态差的风电机组在风电场限功率运行下仍然承担着较大的发电任务, 可能导致健康状态较差的机组进一步恶化。本文所提出的风电场功率分配算法充分考虑了风电场中每台机组的最大可发电能力和其健康状态, 按照健康状态好的风电机组承担较大发电任务的原则, 合理分配发电指令, 从而降低了健康状态差的风电机组在风电场限功率运行下的输出功率。




图 6 基于变比例分配的风电机组输出功率

Fig. 6 Wind turbine output power based on variable proportional distribution




图 7 基于机组健康状态分配的机组输出功率

Fig. 7 Wind turbines output power based on wind turbines health status

5 结论

考虑风电场中各台风电机组的健康状态存在较大差异, 本文提出了一种基于风电机组健康状态的风电场功率分配方法。构建了 LSTM 风电机组输出功率预测模型, 用风速、风轮转速、齿轮箱高速轴转速和发电机转速作为模型的输入特征, 机组的输出功率作为模型的输出, 训练 LSTM 模型。通过机组实际输出功率与预测功率的偏差大小, 将机组的健康状态分为良好、一般和差三类。在每个调度周期, 按照风电场总的输出功率等于电网调度中心下达的输出功率指令, 以及风电场的总健康衰退度最低两个优化目标, 采用遗传算法对风电机组功率分配进行优化。仿真结果表明, 本文所提出的基于风电机组健康状态的风电场功率分配算法不仅能使风电场发电功率达到电网调度中心下达的输出功率指令, 而且能根据每台风电机组的健康状态合理地分配功率给定, 对于提高风电场运行的可靠性, 降低风电场运维成本有着重要意义。

参考文献

- [1] 丁显, 徐进, 滕伟, 等. 风电机组状态检测技术研究现状及发展趋势[J]. 可再生能源, 2017, 35(10): 1551-1557.
DING Xian, XU Jin, TENG Wei, et al. Research status and development trend of wind turbine condition detection technology[J]. Renewable Energy Resource, 2017, 35(10): 1551-1557.
- [2] 金尚婷, 吴杰康, 覃炜梅, 等. 考虑风电消纳的配电网多目标无功协同优化[J]. 广东电力, 2019, 32(1): 52-59.
JIN Shangting, WU Jiekang, QIN Weimei, et al. Multi-objective collaborative reactive power optimization for distribution network considering wind power accommodation[J]. Guangdong Electric Power, 2019, 32(1): 52-59.
- [3] 饶日晟, 张亚丽, 叶林. 直驱式永磁同步风电机组的风电场降阶等值模型[J]. 广东电力, 2019, 32(6): 9-17.
RAO Risheng, ZHANG Yali, YE Lin. Equivalent model of order reduction of wind power plant with DD-PMSG[J]. Guangdong Electric Power, 2019, 32(6): 9-17.
- [4] 刘军, 张彬彬, 赵婷. 基于模糊评价的风电场有功功率分配算法[J]. 电工技术学报, 2019, 34(4): 786-794.
LIU Jun, ZHANG Binbin, ZHAO Ting. Research on wind farm active power dispatching algorithm based on fuzzy evaluation[J]. Transactions of China Electrotechnical Society, 2019, 34(4): 786-794.
- [5] QIAN Peng, MA Xiandong, ZHANG Dahai, et al. Data-driven condition monitoring approaches to improving power output of wind turbines[J]. IEEE Transactions on Industrial Electronics, 2019, 66(8): 6012-6020.
- [6] LONG Huan, WANG Long, ZHANG Zijun, et al. Data-driven wind turbine power generation performance monitoring[J]. IEEE Transactions on Industrial Electronics, 2015, 62(10): 6627-6635.
- [7] PANDIT R K, INFELD D. SCADA-based wind turbine anomaly detection using Gaussian process models for wind turbine condition monitoring purposes[J]. IET Renewable Power Generation, 2018, 12(11): 1249-1255.
- [8] GILL S, STEPHEN B, GALLOWAY S. Wind turbine condition assessment through power curve Copula modeling[J]. IEEE Transactions on Sustainable Energy, 2012, 3(1): 94-101.
- [9] 杨茂, 张罗宾. 基于数据驱动的超短期风电功率预测综述[J]. 电力系统保护与控制, 2019, 47(13): 171-186.
YANG Mao, ZHANG Luobin. Review on ultra-short term wind power forecasting based on data-driven approach[J]. Power System Protection and Control, 2019, 47(13): 171-186.
- [10] 杨杰, 霍志红, 何永生, 等. 基于小波与最小资源分配网络的超短期风电功率预测研究[J]. 电力系统保护与控制, 2018, 46(9): 55-61.
YANG Jie, HUO Zhihong, HE Yongsheng, et al. Ultra-short-term wind power prediction based on wavelet and minimum resource allocation network[J]. Power System Protection and Control, 2018, 46(9): 55-61.
- [11] LI Zhi, YE Lin, ZHAO Yongning, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 9-16. DOI: 10.1186/s41601-016-0016-y.
- [12] HE Yusen, KUSIAK A. Performance assessment of wind turbines: data-derived quantitative metrics[J]. IEEE Transactions on Sustainable Energy, 2018, 9(1): 65-73.
- [13] 董玉亮, 顾煜炯. 基于保局投影与自组织映射的风电机组故障预警方法[J]. 太阳能学报, 2015, 36(5): 1123-1129.
DONG Yuliang, GU Yujiong. Wind turbine fault prognostics based on locality preserving and self-organizing maps[J]. Acta Energetica Solaris Sinica, 2015, 36(5): 1123-1129.
- [14] 董玉亮, 李亚琼, 曹海斌, 等. 基于运行工况辨识的风电机组健康状态实时评价方法[J]. 中国电机工程学报, 2013, 33(11): 88-95.
DONG Yuliang, LI Yaqiong, CAO Haibin, et al. Real-time health condition evaluation on wind turbines based on operational condition recognition[J]. Proceedings of the

- CSEE, 2013, 33(11): 88-95.
- [15] LAPIRA E, BRISSET D, ARDAKANI H D, et al. Wind turbine performance assessment using multi-regime modeling approach[J]. *Renewable Energy*, 2012(45): 86-95.
- [16] 马然, 栗文义, 齐咏生. 基于风功率数据的风电机组性能预测与健康状态评估[J]. *可再生能源*, 2019, 37(8): 1252-1259.
- MA Ran, LI Wenyi, QI Yongsheng. Performance degradation prognostic and health assessment using wind power data for wind turbine generation unit[J]. *Renewable Energy Resources*, 2019, 37(8): 1252-1259.
- [17] 郑小霞, 李美娜, 王靖, 等. 基于 PSO 优化核主元分析的海上风电机组运行工况分类[J]. *电力系统保护与控制*, 2016, 44(16): 28-35.
- ZHENG Xiaoxia, LI Meina, WANG Jing, et al. Operational conditions classification of offshore wind turbines based on kernel principal analysis optimized by PSO[J]. *Power System Protection and Control*, 2016, 44(16): 28-35.
- [18] 王宇晨, 成斌. 基于风电机组常见故障的模糊 FMECA 评价研究[J]. *电力系统保护与控制*, 2018, 46(1): 143-149.
- WANG Yuchen, CHENG Bin. Fuzzy FMECA based on common faults of wind turbine generator[J]. *Power System Protection and Control*, 2018, 46(1): 143-149.
- [19] 李辉, 胡姚刚, 唐显虎, 等. 并网风电机组在线运行状态评估方法[J]. *中国电机工程学报*, 2010, 30(33): 103-109.
- LI Hui, HU Yaogang, TANG Xianhu, et al. Method for on-line operating conditions assessment for a grid-connected wind turbine generator system[J]. *Proceedings of the CSEE*, 2010, 30(33): 103-109.
- [20] 王志国, 马一太, 杨昭, 等. 风力发电机组性能分析的模糊综合评判方法[J]. *太阳能学报*, 2004, 25(2): 177-181.
- WANG Zhiguo, MA Yitai, YANG Zhao, et al. Fuzzy comprehensive evaluation method of wind power generation unit[J]. *Acta Energaie Solaris Sinica*, 2004, 25(2): 177-181.
- [21] 胡姚刚, 李辉, 刘海涛, 等. 基于多类证据体方法的风电机组健康状态评估[J]. *太阳能学报*, 2018, 39(2): 331-341.
- HU Yaogang, LI Hui, LIU Haitao, et al. Evaluation of health status of wind turbine based on multiple evidence method[J]. *Acta Energaie Solaris Sinica*, 2018, 39(2): 331-341.
- [22] 汤奕, 王琦, 陈宁, 等. 采用功率预测信息的风电场有功优化控制方法[J]. *中国电机工程学报*, 2012, 32(34): 1-7.
- TANG Yi, WANG Qi, CHEN Ning, et al. An optimal active power control method of wind farm based on wind power forecasting information[J]. *Proceedings of the CSEE*, 2012, 32(34): 1-7.
- [23] 肖运启, 贺贯举. 大型风电机组限功率运行特性分析及其优化调度[J]. *电力系统自动化*, 2014, 38(20): 18-25.
- XIAO Yunqi, HE Guanju. Power-limited operation characteristic analysis and optimal scheduling for large scale wind turbines[J]. *Automation of Electric Power Systems*, 2014, 38(20): 18-25.
- [24] 肖运启. 基于风电机组健康状态优化的风电场功率调度控制[J]. *太阳能学报*, 2017, 38(7): 1935-1942.
- XIAO Yunqi. Wind farm power control strategy based on operating wind turbines health condition optimization[J]. *Acta Energaie Solaris Sinica*, 2017, 38(7): 1935-1942.
- [25] 童纪新, 王琳, 冯浩. 考虑风电机组运行健康状态的风电场优化调度方法[J]. *水电能源科学*, 2016, 34(1): 198-202.
- TONG Jixin, WANG Lin, FENG Hao. Optimal scheduling method of wind farm considering operation health status of wind turbine[J]. *Water Resources and Power*, 2016, 34(1): 198-202.
- [26] LIU Yu, DONG Shuting, LU Mingming, et al. LSTM based reserve prediction for bank outlets[J]. *Tsinghua Science and Technology*, 2019, 24(1): 77-85.
- [27] 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): 1837-1844.
- ZHOU Zhichao, WANG Chengshan, GUO Li, et al. Output power curtailment control of variable-speed variable-pitch wind turbine generator at all wind speed regions[J]. *Proceedings of the CSEE*, 2015, 35(8): 1837-1844.

收稿日期: 2019-11-29; 修回日期: 2020-02-21

作者简介:

刘 军(1963—), 男, 教授, 博士生导师, 研究方向为风力发电、智能控制与电力拖动等; E-mail: liujun0310@sina.com

汪继勇(1994—), 男, 通信作者, 硕士研究生, 研究方向为基于风电机组健康状态的风电场功率分配方法。E-mail: 869073430@qq.com

(编辑 魏小丽)