

DOI:10.3876/j.issn.1000-1980.2020.03.012

基于神经网络的光伏电站气象-功率模型

鞠平¹,刘婧孜¹,秦川¹,李洪宇¹,杨宏宇²,封波³,屈卫锋²

(1. 河海大学能源与电气学院,江苏南京 210098; 2. 国网连云港供电公司,江苏连云港 222000;
3. 国网灌南县供电公司,江苏连云港 223500)

摘要: 基于双层前馈神经网络建立光伏电站输出功率与辐照等气象因素间的非机理模型。建立光伏电站输出功率与气象因素的神经网络模型;对功率模型的输入特征进行选择,分析不同气象因素的组合作为输入变量对模型准确度的影响,明确功率模型的输入变量;分析该模型网络的训练算法、隐含层神经元个数及训练次数对模型准确度的影响,据此确定功率模型的最优结构与参数;基于光伏电站的实际数据对功率模型进行验证。结果表明,基于双层前馈神经网络的光伏电站气象-功率模型具有较高的准确度。

关键词: 光伏电站;气象-功率模型;双层前馈神经网络;输入特征选择;网络结构优化

中图分类号: TM714 **文献标志码:** A **文章编号:** 1000-1980(2020)03-0268-08

Neural network based model of photovoltaic output power-weather information

JU Ping¹, LIU Jingzi¹, QIN Chuan¹, LI Hongyu¹, YANG Hongyu², FENG Bo³, QU Weifeng²

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 210098, China;
2. National Network Lianyungang Power Supply Company, Lianyungang 222000, China;
3. State Network Guannan Power Supply Company, Lianyungang 223500, China)

Abstract: In this study, a non-mechanism model for the output power of photovoltaic (PV) plant considering weather factors such as irradiance, etc. was established based on a two-layer feed-forward neural network. Firstly, a neural network-based model of output power of PV power plant was established by using weather factors as the inputs. Secondly, the combination of input features for the neural network model was selected. The impacts of different weather factors combinations to the model accuracy were compared to select the input combination of the power model. Then, the training algorithm, the number of hidden layer neurons, and the training times, were changed in the neural network to compare the estimation accuracy and simulation time, and thus the optimal network configuration and parameters of the power model were determined. Finally, the optimized power model of the PV power plant was validated based on the actual measured data. The result shows that the proposed power model has high accuracy.

Key words: PV power plant; weather-power model; two-layer feed-forward neural network; input feature selection; network configuration optimization

近年来,随着一次能源的大量消耗及环境污染等问题的出现,光伏发电等可再生能源发电得到了快速发展。据统计,截至2018年底,我国光伏发电装机达到1.74亿kW,2018年全年光伏发电量达1775亿kW·h^[1]。

基金项目: 国家自然科学基金重点项目(51837004); 111引智计划“新能源发电与智能电网学科创新引智基地”资助(B14022)

作者简介: 鞠平(1962—),男,教授,博士,主要从事电力系统建模与控制研究。E-mail:pju@hhu.edu.cn

通信作者: 秦川,副教授。E-mail:cqin@hhu.edu.cn

引用本文: 鞠平,刘婧孜,秦川,等.基于神经网络的光伏电站气象-功率模型[J].河海大学学报(自然科学版),2020,48(3):268-275.

JU Ping, LIU Jingzi, QIN Chuan, et al. Neural network based model of photovoltaic output power-weather information [J]. Journal of Hohai University (Natural Sciences), 2020, 48(3): 268-275.

光伏发电是一种典型的间歇式电源,其发电功率受气象、环境条件等的影响具有较强的随机性和波动性。光伏发电渗透率的不断提高对电网安全稳定运行的影响日益增强。建立准确的光伏发电功率模型并掌握其功率特性对电网和光伏电站自身的安全稳定运行具有重要意义^[2],常用的功率建模方法按模型描述方式分为机理和非机理^[3]。机理方法基于辐照传递方程、光伏组件运行方程等通过系统内部工作过程的物理关系建立数学模型,非机理模型基于模型输入、输出因素间的统计规律建模^[4-5]。常用的非机理模型包括传递函数(差分方程)模型、人工神经网络智能方法等^[3,6]。

人工神经网络因其具有高准确度和自学习的优势,所以在拟合系统的非线性输入输出关系特性时具有明显的优越性。Liu等^[7]以待预测日与历史相似日的气温、湿度、风速及气溶胶浓度为输入,以待预测日有光照时段每小时输出功率平均值为输出,基于BP神经网络实现了对未来24h光伏输出功率的多步预测。刘卫亮等^[8]以PM浓度、温度、空气相对湿度等气象数据为输入,分别利用BP神经网络与SVM方法建立大气气溶胶光学厚度估计模型,基于精细天气预报信息和PM浓度的预测,实现对光伏发电超短期功率的预测。同样,基于BP神经网络,由欧式距离法确定天气类型,再结合光伏电站的历史出力数据将影响因素映射为天气类型指数,从而建立了计及天气类型指数的光伏发电短期出力预测模型^[9]。张程熠等^[10]通过简化神经网络,降低输入输出维数,设计适用于小样本的双层神经网络单步光伏预测方法。可见,基于神经网络的光伏输出功率研究十分普遍^[11],大都集中于光伏输出功率的预测,但复现难度较大。而采用神经网络建立复杂气象因素与光伏输出功率间单纯关系的研究不多见,且对于建立的非机理模型精度的提升和神经网络结构参数设置的优化等问题,仍待进一步研究。

本文基于人工神经网络,以辐照、温度等气象因素为输入变量,光伏电站的输出功率为输出变量,建立光伏电站的气象-功率非机理模型。着重研究了神经网络结构、不同气象因素的组合作为输入对模型输出准确度的影响,明确了功率模型的理想网络结构与参数。最后基于实际光伏电站的量测数据,对提出的光伏电站气象-功率模型进行了对比验证。

1 数据采集

由于光伏电池的材质特性,光伏电池的输出特性受气象因素的影响较大,特别是太阳辐照度和电池温度^[12],因此对光伏发电输出功率进行建模时,作为输入的气象因素中必须含有辐照度和温度。本文研究采用的数据包括气象数据、光伏电站实测功率数据等。

1.1 气象数据

研究采用的气象信息来自SolarGIS高分辨率气候数据库。采样地点同下文光伏电站处,采样时期为2017年全年,采样的时间分辨率为10min。SolarGIS的数据为实地采样的平均值,并已成功应用于光伏发电的评估^[13],因此可以基于SolarGIS的气象数据对光伏电站输出功率建模。采集的数据包括水平面总辐照度(global horizontal irradiance, GHI, W/m^2)、散射水平辐照度(diffuse horizontal irradiance, DHI, W/m^2)、倾斜面总辐照度(global tilted irradiance, GTI, W/m^2 (倾角 31° ,方位角 180°))、温度(air temperature, TEMP, $^\circ C$)、风速(wind speed, WS, m/s)和风向(Wind direction, WD($^\circ$))。

辐照数据的采集方式有地面测量和卫星测量2种。目前,地面实测辐照度通常用于单一住宅光伏系统的研究,精确度较高,但测量成本也较高^[14]。Lave等^[15]指出地面实测辐照度只是点测量值,无法完全代表光伏的地域变化。Ruf等^[14]指出欧美的高光伏渗透率的电力系统数据采集更偏向采用卫星测量辐照度,采用卫星实测辐照度可以获得辐照度的空间变化信息。通过评估法国和比利时7000多个住宅光伏系统的性能,验证了卫星测量辐照度具有代表时空变化特点且更加精准的优势^[16-17]。因此,本文使用的辐照数据(GHI、DHI和GTI)是基于与地球自转同步的HIMAWARI气象卫星和全球气象模型计算生成,不确定度为 $\pm 4\% \sim \pm 8\%$,数据可以代表采集点地理区域内的辐照情况。

受地理位置的影响,不同经纬度下具有不同的最佳太阳入射角^[18],因此为得到最大的光伏输出功率,光伏面板需要呈现一定的倾斜角。在进行光伏输出特性的相关研究时,同一地区可以采用相同的光伏阵列倾斜角^[19]。

本文采用的其余气象数据(TEMP、WS和WD)由天气预报系统(climate forecast system reanalysis, CFSR)、第二版天气预报系统(climate forecast system Version 2, CFSv2)和美国气象服务系统(global forecast

system, GFS)数值天气模型生成,其精度略低于辐照数据,全年不确定度分别为温度 $\pm 1.3^\circ\text{C}$ 、风速 $\pm 1.7\text{ m/s}$,满足表征采集点地理区域内气象特点的精度要求。上述气象信息均得到 NOAA 综合地面数据库的验证。

1.2 光伏电站输出功率数据

研究采用的光伏功率数据为某实际光伏电站连接至上级变电站 35 kV 侧进线的有功功率 P_{real} ,数据时长为 2017 年全年,采样间隔为 5 min。功率数据取自某地调的 EMS 系统历史数据库,数据精度满足工程要求。

1.3 数据预处理

由上述可知,实测气象数据为平均采样值,实测光伏电站输出功率为 EMS 系统实际量测值。在建模前首先对光伏功率数据预处理,将光伏电站输出功率采样的时间分辨率由 5 min 变为 10 min,并对功率数据进行插值处理。预处理的步骤如下:

a. 将光伏电站输出功率数据与气象数据的采样时间点进行对应,确定预处理后将用于模型训练的数据采样时间点。

b. 选取该采样时间点及其前后各一个采样时间点的光伏电站输出功率数据,将 3 个采样数据加和并求均值。

任意选取某天 2 h(例如 8:05 ~ 10:05)内的倾斜面总辐照度与光伏电站输出功率数据,进行上述操作,得到预处理前后的数据结果如图 1 所示。由图 1 可以看出,对光伏电站输出功率的预处理可以描述光伏功率的总体变化特性。

2 光伏电站气象-功率模型的神经网络结构

2.1 双层前馈神经网络

本文采用的双层前馈神经网络是基于 sigmoid 隐含层神经元和线性输出神经元的网络^[20],由输入层和计算层构成,其中计算层包括隐含层和输出层。该神经网络在给定一致的数据和足够的隐含层神经元后经过反复训练,即可很好地拟合多维映射问题^[21]。

适用于双层前馈神经网络的训练算法很多,其中常见的如 Levenberg-Marquardt、Bayesian Regularization 和 Scaled Conjugate Gradient。限于篇幅,详细计算过程可参考文献[22-24]。

神经网络输入层和输出层节点数与网络的特征和目标的维度匹配,并影响隐含层神经元个数。一般而言,当输入层节点为 m 个且各输入变量不具有关联性时,隐含层节点为 $(2m+1)$ 个。但隐含层节点数也可由设计者设定。双层前馈神经网络的拟合原理在 2.2 节中结合实际数据详细说明。

神经网络的估算效果由网络的均方根误差 (root-mean-square error, E_{RMSE}) 和绝对值均值相对误差 (absolute mean relative error, E_{AMRE}) 体现,计算公式分别如式(1)和式(2)所示。2 种误差各自的数值越小,模型效果越好。

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{x}_i - x_i)^2} \quad (1)$$

$$E_{\text{AMRE}} = \frac{\left| \frac{1}{n} \sum_{i=1}^n |x_i| - \frac{1}{n} \sum_{i=1}^n |\bar{x}_i| \right|}{\frac{1}{n} \sum_{i=1}^n |x_i|} \times 100\% \quad (2)$$

式中: \bar{x}_i ——经过神经网络训练后的计算值; x_i ——与计算值对应的实际值; n ——输出计算值的总个数; i ——输出的计算值序列数。

2.2 功率模型的基本结构

研究借助 MATLAB,采用双层前馈神经网络建立光伏电站输出功率与多气象因素之间的非线性模型,该光伏电站气象-功率模型的神经网络基本结构如图 2 所示。模型的输入为各种气象因素,输出为光伏电站的输出功率,网络结构为包含一层隐含层的前馈神经网络。

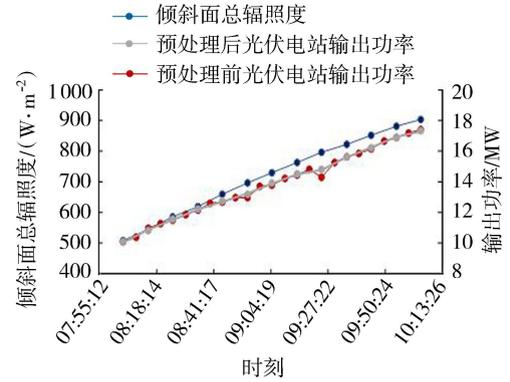


图1 光伏电站的输出功率预处理前后对比

Fig. 1 Comparison of output power of PV plant before and after pretreatment

网络的训练、验证和测试过程如下:

a. 训练:随机选取 70% 的样本集作为训练集训练网络。

b. 验证:在剩余的 30% 样本集中随机选取 1/2 的数据(总样本集的 15%)作为验证集验证网络,当验证集的误差收敛后停止训练,得到此时拟合效果突出的网络权重参数。

c. 测试:将剩余 15% 的样本集作为测试集,以该网络测试误差的形式表现上述确定的网络的性能。

在建模过程中,气象因素输入组合和网络结构的不同会对功率模型的精度产生较大的影响。为了得到准确的光伏电站气象-功率模型,下文将对功率模型的输入特征进行选择,得到效果理想的功率模型。

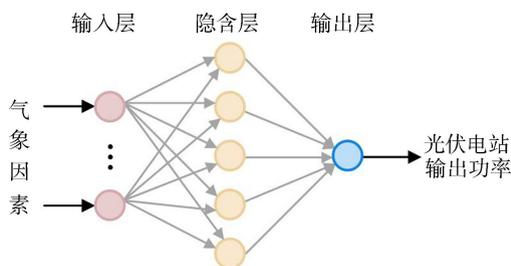


图 2 基于神经网络建模的结构

Fig. 2 Structure chart of model based on two-layer feed-forward neural network

3 光伏电站气象-功率模型的输入特征选择

实际环境中含有丰富的气象因素,不同气象因素间会相互作用并且均对光伏电站的输出功率产生影响。本节对功率模型的输入特征进行选择,明确该功率模型理想的输入变量。在进行特征选择时,网络的初始隐含层神经元为 5 个。

3.1 辐照作为神经网络输入

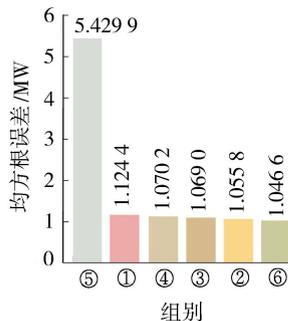
通常意义下,辐照是影响光伏电池输出功率的主要因素,而实际环境中存在多种类的辐照,因此首先设置不同类型的辐照组合作为神经网络的输入,对比各组网络的准确度。设置 5 组不同类型的辐照作为输入的对照组分别为:倾斜面总辐照度;水平面总辐照度;散射水平辐照度;水平面总辐照度+散射水平辐照度;倾斜面总辐照度+水平面总辐照度+散射水平辐照度。将 5 个对照组依次进行训练,得到对应神经网络的均方根误差分别为 1.178 6 MW、1.462 7 MW、2.857 6 MW、1.403 7 MW、1.124 4 MW。由此可知:(a)将 3 种辐照度组合作为神经网络输入时,网络误差最小;(b)以倾斜面总辐照度作为输入时的误差略大于 3 种辐照度组合,但明显小于其他 2 种辐照度的组合。可见,由于光伏面板呈现倾斜状态,其吸收最充分的辐照是倾斜面总辐照度,所以倾斜面总辐照度为影响光伏电站输出功率的最主要气象因素。

3.2 温度和风况作为神经网络输入

对比神经网络输入中加入温度和风况气象因素的影响。设置 6 组不同输入的对照组,并依次进行训练,得到每组对应的神经网络的均方根误差,如图 3 所示。

从图 3 中可以看出:(a)仅以温度和风况作为输入(组⑤)的误差最大;(b)由于光伏面板为光敏温敏材料,而经过其表面的风况又能影响温度和辐照。因此,将所有的气象因素作为功率模型的输入(组⑥),误差最小。

综上,后续对光伏电站功率建模研究中,输入因素设定为全气象因素。而如果实际情况下部分气象因素未知,可以考虑倾斜面总辐照度与已知气象因素的组合。



- ①—倾斜面总辐照度+水平面总辐照度+散射水平辐照度;
- ②—倾斜面总辐照度+水平面总辐照度+散射水平辐照度+温度;
- ③—倾斜面总辐照度+水平面总辐照度+散射水平辐照度+风速;
- ④—倾斜面总辐照度+水平面总辐照度+散射水平辐照度+风速+风向;
- ⑤—温度+风速+风向;
- ⑥—倾斜面总辐照度+水平面总辐照度+散射水平辐照度+温度+风速+风向

图 3 功率模型在 6 组不同网络输入特征下的均方根误差

Fig. 3 RMSE of power models with 6 different input features

4 光伏电站气象-功率模型的结构优化

4.1 神经网络的理想训练算法及训练次数的选择

不同的网络训练算法对功率模型的训练和应用也会有影响。双层前馈神经网络常见训练算法如 Levenberg-Marquardt、Bayesian Regularization 和 Scaled Conjugate Gradient 算法。按照上文选定的神经网络输入输出变量,依次在 3 种训练算法下进行 1~40 次独立训练,统计每种训练算法在完成 1~40 次训练后的网

络均方根误差,如图 4 中的散点所示。

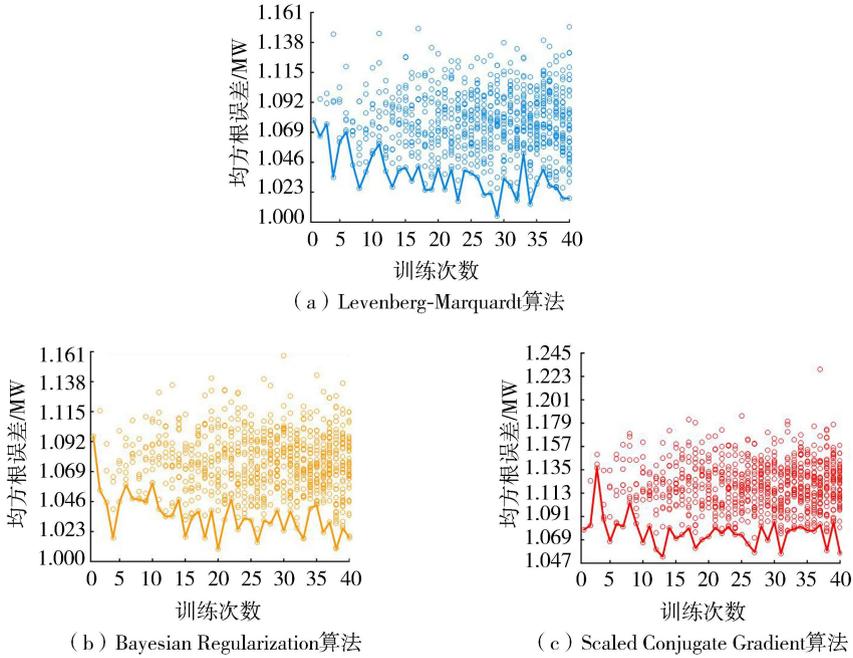


图 4 功率模型在不同算法和训练次数下的均方根误差分布

Fig. 4 Scatterplot of RMSE of power model with different training algorithms and training times

由图 4 可以看出输入输出一致的神经网络进行多次训练时结果误差存在明显差异,模型估算结果的误差呈现波动状态,这是因为神经网络的初始权重为随机设置,导致优化的网络权重存在随机性。标记多次独立训练后均方根误差最小值,如图 4 中的实线所示。

将图 4 中 3 条实线进行对比,如图 5 所示。可以看出整体上基于 Scaled Conjugate Gradient 算法的均方根误差最大,Levenberg-Marquardt 算法的误差和 Bayesian Regularization 算法的误差接近,但 Levenberg-Marquardt 算法的误差波动相对大一点。此外训练过程中发现 Bayesian Regularization 算法的训练时间最长,Scaled Conjugate Gradient 算法所需的训练时间次之,Levenberg-Marquardt 算法的最短。虽然 Levenberg-Marquardt 算法在经过 29 次训练后可以得到误差最小的网络,对该误差相比 Bayesian Regularization 算法 20 次训练后得到的网络误差(图 5 中黑色圆圈处)没有明显的提高。同时,基于 Bayesian Regularization 算法的网络在训练次数达 10 次后,波动趋势趋于稳定。

综上,采用 Bayesian Regularization 训练算法进行 20 次训练,随后选择其中均方根误差值最小的网络可相对理想地拟合该光伏电站输出功率与气象因素的关系模型。

4.2 神经网络的理想隐含层节点数的选择

隐含层节点数设定过少时,神经网络不能充分发挥学习能力和拟合能力;隐含层节点数设定过多时,增加网络结构的复杂性,导致网络学习训练过程耗时,学习过程中容易陷入局部最优解。基于上述确定的双层前馈神经网络的输入变量、训练算法和训练次数,依次设置隐含层神经元为 1 ~ 20 个训练神经网络,统计各组的均方根误差最小值,如图 6 所示。各组进行 20 轮训练的耗时如下:隐含层节点 2 个,总耗时 80 s;

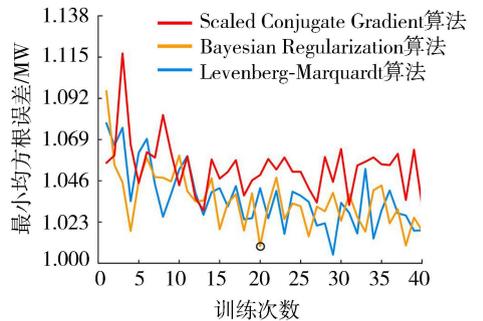


图 5 3 种训练算法在不同训练次数下的最小均方根误差曲线

Fig. 5 Curve of minimum RMSE with 3 training algorithms under different training times

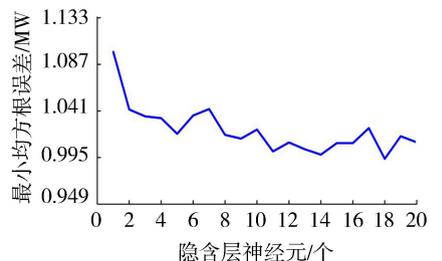


图 6 不同隐含层神经元的 最小均方根误差分布

Fig. 6 Scatterplot of minimum RMSE with different hidden layer neurons number

隐含层节点 4 个,总耗时 198 s;隐含层节点 6 个,总耗时 475 s;隐含层节点 8 个,总耗时 670 s;隐含层节点 10 个,总耗时 986 s;隐含层节点 12 个,总耗时 1302 s;隐含层节点 14 个,总耗时 1885 s;隐含层节点 16 个,总耗时 2 195 s;隐含层节点 18 个,总耗时 3 194 s;隐含层节点 20 个,总耗时 3 239 s。

由图 6 可以看出,神经网络的均方根误差随隐含层节点数的增加而呈现减小的趋势,10 个隐含层节点后,波动趋势趋于稳定;神经网络的总耗时与隐含层节点数之间呈现正相关的关系;隐含层神经元为 14 个和 18 个时的神经网络均方根误差明显较小,对比耗时,确定隐含层神经元为 14 个。

综上,本研究中功率模型的理想网络结构为:隐含层神经元为 14 个、采用 Bayesian Regularization 训练算法进行 20 次训练,随后选择其中均方根误差值最小的神经网络。

5 模型验证

根据上文的分析,建立光伏电站气象-功率模型的理想结构和参数,下文基于实际数据对该模型进行验证。功率模型的平均误差如表 1 所示。可以看出,由于训练集、验证集和测试集的样本数不同,三者误差也略有不同,但均小于 1%,可见该光伏电站气象-功率模型具有良好的精度。

进一步在 2017 全年 4 个季节中分别随机选取晴天、阴天和多云的一天反映功率模型的估算效果,功率对比曲线如图 7 所示,选取的各随机天的估算结果误差如表 2 所示。

表 1 功率模型的神经网络误差

Table 1 Errors of power model based on neural network

样本集	E_{RMSE}/MW	$E_{AMRE}/\%$
训练集	1.0554	0.22
验证集	1.0551	0.59
测试集	1.0218	0.14

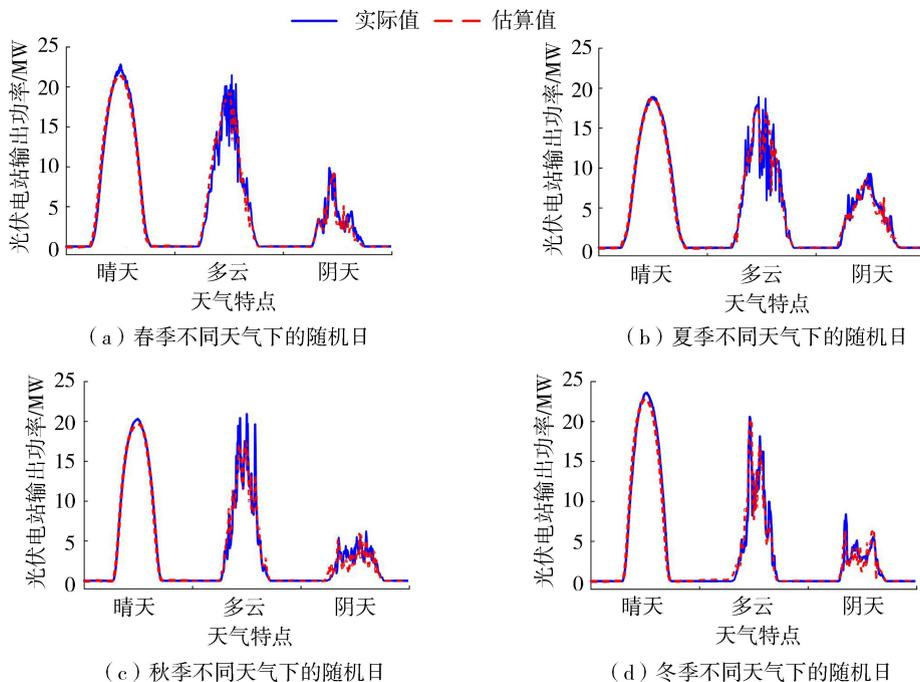


图 7 基于光伏电站气象-功率估算模型的仿真结果对比

Fig. 7 Comparison of simulation results based on weather-power estimation model of PV plant

表 2 基于光伏电站气象-功率模型的随机天误差

Table 2 Errors of testing day based on weather-power estimation model of PV plant

天气	E_{RMSE}/MW				$E_{AMRE}/\%$			
	春	夏	秋	冬	春	夏	秋	冬
晴天	0.3289	0.1886	0.2382	0.4548	0.50	1.08	1.32	2.76
多云	1.0062	1.8165	1.0552	1.3667	4.19	5.07	2.14	3.72
阴天	0.7648	0.6376	0.9945	0.7098	9.93	5.48	7.85	6.50

由图7和表2可以看出:(a)该光伏电站气象-功率模型的计算结果与实际的功率曲线趋势一致;(b)晴天日的误差值很小,多云和阴天的估算结果略差于晴天,但除了春季阴天日误差达到9%以外,其余误差均小于6%。可见,本文所建立的基于双层前馈神经网络的光伏电站气象-功率估算模型可以理想地实现气象因素对光伏电站输出功率的估算。

6 结 语

基于双层前馈神经网络,建立了光伏电站气象-功率模型并进一步改进提高了模型的精确度。首先,对功率模型的输入特征进行选择,明确了对光伏功率影响最大的气象因素是倾斜面总辐照度;其次为水平面总辐照度,尽管温度和风况对功率估算的影响较小,但较全面的气象因素输入可以使神经网络模型达到较好的估算效果;再次,通过神经网络的不同的训练算法、训练次数及隐含层节点数对比,确定了功率模型的网络结构和参数;最后,通过实际光伏电站的量测数据,对建立的功率模型进行了验证。结果表明,该光伏电站气象-功率模型具有良好的精度。

参考文献:

- [1] 国家能源局. 2018年全国光伏发电统计信息[J]. 太阳能, 2019(3):76-77. (National Energy Administration. 2018 Statistical information for PV generation capacity in China[J]. Solar Energy, 2019(3):76-77. (in Chinese))
- [2] 刘东冉, 陈树勇, 马敏, 等. 光伏发电系统模型综述[J]. 电网技术, 2011, 35(8): 47-52. (LIU Dongran, CHEN Shuyong, MA Min, et al. A review on models for photovoltaic generation system[J]. Power System Technology, 2011, 35(8): 47-52. (in Chinese))
- [3] 李培强, 李欣然, 林舜江. 电力负荷建模研究述评[J]. 电力系统及其自动化学报, 2008, 20(5): 56-64. (LI Peiqiang, LI Xinran, LIN Shunjiang. Critical review on synthesis load modeling[J]. Proceedings of the CSU-EPSA, 2008, 20(5): 56-64. (in Chinese))
- [4] 龚莺飞, 鲁宗相, 乔颖, 等. 光伏功率预测技术[J]. 电力系统自动化, 2016, 40(4): 140-151. (GONG Yingfei, LU Zongxiang, QIAO Ying, et al. An overview of photovoltaic energy system output forecasting technology[J]. Automation of Electric Power Systems, 2016, 40(4): 140-151. (in Chinese))
- [5] 张瑞祥. 生物质发电电气化过程机理分析与建模研究[D]. 保定: 华北电力大学, 2008.
- [6] 刘畅. 基于实测数据的电力负荷建模研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.
- [7] LIU Jun, FANG Wanliang, ZHANG Xudong, et al. An improved photovoltaic power forecasting model with the assistance of aerosol index data[J]. IEEE Transactions on Sustainable Energy, 2015, 6(2): 434-442.
- [8] 刘卫亮, 刘长良, 林永君, 等. 计及雾霾影响因素的光伏发电超短期功率预测[J]. 中国电机工程学报, 2018, 38(14): 4086-4095. (LIU Weiliang, LIU Changliang, LIN Yongjun, et al. Super short-term photovoltaic power forecasting considering influence factor of smog[J]. Proceedings of the CSEE, 2018, 38(14): 4086-4095. (in Chinese))
- [9] 袁晓玲, 施俊华, 徐杰彦. 计及天气类型指数的光伏发电短期出力预测[J]. 中国电机工程学报, 2013, 33(34): 57-64. (YUAN Xiaoling, SHI Junhua, XU Jieyan. Short-term power forecasting for photovoltaic generation considering weather type index [J]. Proceedings of the CSEE, 2013, 33(34): 57-64. (in Chinese))
- [10] 张程熠, 唐雅洁, 李永杰, 等. 适用于小样本的神经网络光伏预测方法[J]. 电力自动化设备, 2017, 37(1): 101-106. (ZHANG Chengyi, TANG Yajie, LI Yongjie, et al. Photovoltaic power forecast based on neural network with a small number of samples[J]. Electric Power Automation Equipment, 2017, 37(1): 101-106. (in Chinese))
- [11] 程泽, 韩丽洁, 李思宇, 等. 光伏发电功率的智能预测算法[J]. 电力建设, 2014, 35(7): 34-39. (CHENG Ze, HAN Lijie, LI Siyu, et al. Intelligent forecasting algorithm for photovoltaic power generation[J]. Electric Power Construction, 2014, 35(7): 34-39. (in Chinese))
- [12] 丁坤, 翟泉新, 张经纬, 等. 一种光伏组件输出功率的估算模型[J]. 可再生能源, 2014, 32(3): 275-278. (DING Kun, ZHAI Quanxin, ZHANG Jingwei, et al. An estimation model for PV module output power[J]. Renewable Energy Resources, 2014, 32(3): 275-278. (in Chinese))
- [13] TARIGAN E, DJUWAR I, PURBA L. Assessment of PV power generation for household in surabaya using SolarGIS-pvPlanner Simulation[J]. Energy Procedia, 2014, 47:85-93.
- [14] RUF H, SCHROEDTER-HOMSCHIEDT M, HEILSCHER G, et al. Quantifying residential PV feed-in power in low voltage grids based on satellite-derived irradiance data with application to power flow calculations[J]. Solar Energy, 2016, 135: 692-702.

- [15] LAVE M, KLEISSI J, STEIN J S. A wavelet-based variability model (WVM) for solar PV power plants[J]. IEEE Transactions on Sustainable Energy, 2013, 4(2): 501-509.
- [16] LELOUX J, NARVARTE L, TREBOSC D. Review of the performance of residential PV systems in Belgium[J]. Renewable and Sustainable Energy Reviews, 2012, 16(1): 178-184.
- [17] LELOUX J, NARVARTE L, TREBOSC D. Review of the performance of residential PV systems in France[J]. Renewable and Sustainable Energy Reviews, 2012, 16(2), 1369-1376.
- [18] 凤江涛. 光伏示范校园中的关键问题研究[D]. 北京: 北方工业大学, 2012.
- [19] 成驰, 陈正洪, 孙朋杰. 光伏阵列最佳倾角计算方法的进展[J]. 气象科技进展, 2017, 7(4): 60-65. (CHENG Chi, CHEN Zhenghong, SUN Pengjie. Advances in calculation method of the optimal tilted angle for PV array in solar resource assessment[J]. Advances in Meteorological Science and Technology, 2017, 7(4): 60-65. (in Chinese))
- [20] 孙喜波. BP神经网络算法与其它算法的融合研究及应用[D]. 重庆: 重庆大学, 2011.
- [21] 成晓鹏, 侯道琪. 基于前馈神经网络的模式识别效率分析[J]. 现代计算机, 2015(9): 21-26. (CHENG Xiaopeng, HOU Daoqi. Research on the network training of the feed-forward neural networks algorithm[J]. Modern Computer, 2015(9): 21-26. (in Chinese))
- [22] 刘旭. 基于改进型BP神经网络的风电功率预测研究[D]. 北京: 华北电力大学, 2013.
- [23] 杨春生, 牛红涛, 隋良红, 等. 基于贝叶斯正则化算法BP神经网络锂电池SOC预测[J]. 现代电子技术, 2016, 39(8): 158-161. (YANG Chunsheng, NIU Hongtao, SUI Lianghong, et al. Application of BP neural network improved by Bayesian regularization algorithm in VRB SOC prediction[J]. Modern Electronics Technique, 2016, 39(8): 158-161. (in Chinese))
- [24] 史春玉, 李田泽, 仝其丰, 等. 基于改进共轭梯度算法的二维PSD非线性修正[J]. 山东理工大学学报(自然科学版), 2017, 31(2): 27-30. (SHI Chunyu, LI Tianze, TONG Qifeng, et al. Two dimensional non-correction PSD based on improved conjugate gradient algorithm[J]. Journal of Shandong University Technology(Natural Science Edition), 2017, 31(2): 27-30. (in Chinese))

(收稿日期: 2019-05-11 编辑: 张志琴)

· 简讯 ·

水利部部署取用水管理专项整治行动

中国水利网站 2020 年 5 月 15 日讯,为认真贯彻党中央、国务院有关决策部署,深入贯彻落实“水利工程补短板、水利行业强监管”水利改革发展总基调,全面摸清取水口及取水监测计量现状,依法整治取用水突出问题,近日,水利部印发《取用水管理专项整治行动方案》(以下简称《行动方案》),对取用水管理专项整治工作作出部署。

《行动方案》提出,要通过全面开展取水口核查登记,摸清全国取水口现状,掌握取水口的监测计量和合规性情况,依法整治存在的问题,规范取用水行为,健全取水口监管机制,为管住用水奠定坚实的基础,促进水资源节约保护和合理开发利用。

《行动方案》明确,纳入专项整治行动的范围涵盖全国 31 个省(自治区、直辖市)和新疆生产建设兵团。核查登记对象为利用取水工程或者设施直接从江河、湖泊(含水库)或者地下取水,依法应纳入取水许可管理的各类河道外用水的取水口。

《行动方案》确定了整治行动 4 项任务:一是核查登记。要按照属地登记的原则,以县级行政区为单元,逐级审核上报取水口信息,并登记入库。二是整改提升。按照取水许可管理权限,各流域管理机构和地方各级水行政主管部门对取水口核查登记发现的问题进行认定,建立台账,逐级审核,整改销号。三是监督检查。水利部开展取用水管理专项整治行动监督检查,对问题严重的单位进行约谈或通报。各流域管理机构和地方各级水行政主管部门对本流域、本区域专项整治行动情况进行监督检查。四是建章立制。针对专项整治行动反映的问题,及时出台相关政策措施,建立取水口动态更新机制和取用水监管机制,切实加强取用水管理。

《行动方案》要求,各流域管理机构和地方各级水行政主管部门要高度重视本次专项整治行动,加强组织领导,抓好工作部署,压实工作责任,强化工作保障,确保如期完成各项任务。长江流域、太湖流域及相关省(区、市)在前期工作完成的基础上,着力抓好整改提升工作,并与本次专项整治行动做好衔接。

(本刊编辑部供稿)