

基于多源气象预报总辐照度修正的光伏功率短期预测

师浩琪,郭力,刘一欣,王成山

(天津大学 智能电网教育部重点实验室,天津 300072)

摘要:针对单一气象预报源可能存在的误报和偏差问题,提出一种基于多源气象预报总辐照度修正的光伏功率短期预测方法。根据功率序列特征,采用自组织映射神经网络聚类算法实现历史数据广义天气类型划分。按照晴朗程度实现广义天气类型与公共气象服务天气类型预报的匹配对应,并计算不同广义天气类型总辐照度各等级之间的折算系数。在计算各广义天气类型系统误差的基础上,如果预测日数值天气预报广义天气类型分类结果与公共气象服务天气类型预报的一致,则叠加修正总辐照度系统误差;否则,采用树扩展朴素贝叶斯算法计算2种广义天气类型的转移概率,在修正系统误差后利用折算系数计算公共气象服务天气类型预报对应广义天气类型的总辐照度序列,并根据转移概率设定权重系数进一步修正总辐照度序列。建立预测模型,基于遗传算法优化的反向传播神经网络获得光伏功率短期预测结果。利用某光伏电站的实际运行数据和气象预报数据验证了模型的有效性。

关键词:多源气象预报;转移概率;数值天气预报;功率预测;短期预测;光伏发电

中图分类号:TM 615

文献标志码:A

DOI:10.16081/j.epae.202201019

0 引言

近年来,为了缓解能源危机,以光伏发电为代表的可再生能源发展迅速,但其出力的不确定性和波动性给电网的安全稳定运行带来了巨大冲击^[1]。因此,准确预测光伏功率对电网制定更加精细的调度计划、提高电力系统可靠性有重要的现实意义^[2]。

目前已有许多学者围绕光伏电站日前24 h短期预测开展研究。在数据预处理方面,对预测模型的训练数据划分不同天气类型有助于建立更加精细的预测模型^[3],但在天气类型划分方面,目前还没有统一的标准。文献[4]根据温度、湿度、辐照度的特征,采用改进Kohonen神经网络进行天气聚类。文献[5]根据云量、辐照度、温度采用概率神经网络PNN(Probabilistic Neural Network)算法划分天气类型。上述历史数据分类模型未考虑各气象因素之间的相关关系,深层特征挖掘不足,存在数据冗余现象。在预测方法方面,随着大数据技术的发展,人工智能算法相较于统计方法和物理方法应用更加广泛^[6],主要包括人工神经网络^[7-8]、支持向量机^[9]以及多模型组合算法^[10]等。文献[7]以温度、湿度等气象数据和相似日功率数据为输入变量,采用反向传播BP(Back Propagation)神经网络预测光伏功率。文献[8]额外引入天气类型指数作为BP神经网络预测

模型的输入变量,预测不同天气类型下的光伏功率。文献[9]采用变分模态分解VMD(Variational Mode Decomposition)将历史光伏发电功率分解成多个子模态,用最小二乘支持向量机LSSVM(Least Square Support Vector Machine)分别预测光伏发电功率和误差。文献[10]针对各天气分型下的波动过程和类晴空过程,建立卷积神经网络CNN(Convolutional Neural Network)和长短期记忆LSTM(Long Short Term Memory)网络的组合预测模型。在预测数据源选择方面,短期预测算法多以数值天气预报NWP(Numerical Weather Prediction)为气象数值预报源^[11-12],以公共气象服务预报为天气状态预报源^[13]。文献[11]对高维NWP数据进行降维处理,在筛选相似日样本的基础上,通过LSTM网络预测模型建立气象因素与光伏功率之间的映射关系。文献[12]以数据采集与监视控制SCADA(Supervisory Control And Data Acquisition)系统的功率数据和NWP数据建立小波-粒子群-支持向量机预测模型。上述文献以NWP原始数据为输入,建立NWP-功率映射模型,但由于NWP存在误差,该模型不能准确描述气象-功率之间的关系。另外,由于NWP误差的不确定性,NWP-功率映射模型不能有效消除NWP误差对功率预测的影响。文献[13]对所划分的广义天气类型分别建立预测模型,并根据公共气象服务预报的预测日天气类型选择预测模型进行预测。由于公共气象服务预报的区域范围较大,与光伏发电预测要求的精细化气象预报场景存在较大差异,故须对公共气象服务预报的准确度进行评估。针对NWP预报偏差较大的问题,很多学者一直尝试解决,如采用模式后处理^[14-15]等方法进行修正,但效果不明显。

收稿日期:2021-04-22; **修回日期:**2021-11-23

基金项目:国家重点研发计划项目(2020YFB1506804);国家自然科学基金资助项目(51907140)

Project supported by the National Key R&D Program of China(2020YFB1506804) and the National Natural Science Foundation of China(51907140)

利用数据融合和数据同化技术综合多种来源的观测资料或者模拟数据,可获得高精度、高质量的多源数据融合气象预报产品^[16]。然而目前应用于光伏功率预测领域的气象数据融合研究还比较少。

针对上述问题,本文提出基于多源气象预报总辐照度修正的光伏功率短期预测方法。首先,根据功率序列特征采用自组织映射 SOM(Self Organizing Map)神经网络聚类算法划分广义天气类型,并与公共气象服务天气类型预报实现匹配对应,分类方法具有较高的准确度和较强的适应性;然后,通过融合预测日 NWP 和公共气象服务天气类型预报,基于树扩展朴素贝叶斯 TAN(Tree Augmented Naive Bayes)算法评估 2 种气象预报源的准确度,再结合实测总辐照度数据实现预测日 NWP 总辐照度修正;最后,以实测气象和功率为训练样本,得到准确反映气象与功率映射关系的预测模型,并以修正后的总辐照度为输入实现光伏功率短期预测。利用我国某光伏电站的实际运行数据和气象预报数据验证了模型的有效性。

1 基于总辐照度修正的光伏功率预测

光伏输出功率受多种外部气象因素和自身组件状态的影响,为构建高效、精确的预测模型,本节首先分析光伏发电影响因素,并筛选预测模型输入变量,然后介绍本文提出的基于多源气象预报总辐照度修正的光伏功率短期预测模型框架。

1.1 影响因素分析

光伏功率主要受两方面因素影响^[17]:一方面是光伏电站所处位置的辐照度、温度等气象因素;另一方面是光伏面板倾角、组件转换效率等自身因素。在不发生故障的情况下,光伏组件自身因素在短期内变化较小,研究预测问题时可以忽略其对光伏功率的影响。

不同天气类型下光伏电站功率曲线特征具有明显差异。按照中国天气网对天气状态的预报形式,结合光伏电站所在地区的气候特点,以我国河南省某光伏电站为例,分析该地区天气类型占比较大的晴天(41.00%)、多云天(27.83%)、阴天(13.64%)和雨雪天(16.08%)4种典型天气类型下光伏电站功率曲线特征,功率曲线如图1所示。

由图1可知:晴天和多云天功率幅值较大,但晴天功率曲线较为平滑,多云天由于云层移动的影响其功率曲线呈现较强的波动性;阴天和雨雪天功率幅值较小并呈现出一定的波动性。通常而言,对于气象要素变化平缓的天气类型(如晴天),光伏预测精度较高,对于气象要素波动性强、变化规律不明显的天气类型(如多云天、阴天和雨雪天),由于气象要素预测的难度较大、精度较低,光伏功率预测偏差较




图1 不同天气类型下光伏电站功率曲线

Fig.1 Power curves of photovoltaic power plant under different weather types

大,因此有必要通过划分天气类型,采取针对性的预报方法或者修正方法来提高光伏功率预测精度。

到达地面的太阳辐射包括直射辐射和散射辐射,两者之和称为总辐射。直射辐射是指没有被任何物质所散射,直接到达地面的太阳辐射;散射辐射则是太阳辐射经过大气和云的散射后到达地面的太阳辐射。单位面积辐射量称为辐照度。总辐照度是光伏功率的直接影响因素,而气温、湿度、风速、气压等其他因素通过影响总辐照度的强弱间接影响光伏功率。随机选取连续3 d采样时间间隔为15 min的实测数据,采用皮尔森相似度分析法计算气象因素与光伏功率之间的相关性,不同气象因素与光伏功率间的皮尔森相关系数见表1。

表1 气象因素与光伏功率间的皮尔森相关系数

Table 1 Pearson relevant coefficient between meteorological factors and photovoltaic power

气象因素	皮尔森相关系数	气象因素	皮尔森相关系数
总辐照度	0.9927	风速	0.5301
气温	0.6980	气压	0.0806
湿度	-0.6456		

由表1可知:总辐照度与光伏功率呈现极强的正相关性;实际中,虽然气温升高导致光伏组件效率降低,但在该过程中往往天气越晴朗,太阳辐射越强,从而使光伏功率增大,综合效果来看,气温和光伏功率呈现较强的正相关性;湿度和风速也与光伏功率呈现出较强的相关性。因此本文以上述4种因素作为光伏功率预测模型的输入变量,并对最关键的总辐照度因素进行修正,以提高功率预测精度。

1.2 预测模型框架

单一气象预报源存在误报和偏差的问题,综合多种气象预报源可提升气象预报产品的精度,本文使用的多源气象预报包括2种气象源:一种是预测日的NWP数据,通常由NWP服务机构提供;另一种是预测日公共气象服务天气类型预报,通常来源于中央气象台、中国天气网等天气类型预报服务机构。在获取这2种信息的基础上,本文所提基于多源气象预报总辐照度修正的光伏功率短期预测模型框架见图2,主要包括光伏电站历史数据分类、NWP广义

天气类型分类、广义天气类型转移概率计算、NWP总辐照度修正和遗传算法GA(Genetic Algorithm)优化的BP(GA-BP)神经网络预测5个部分。目前关于GA-BP神经网络算法的研究较成熟,本文不再赘述。




图2 光伏功率短期预测模型框架

Fig.2 Framework of short-term photovoltaic power forecasting model

2 光伏电站历史数据分类

本节以光伏日功率序列为研究对象,提取光伏日功率序列特征,采用SOM神经网络聚类算法进行光伏电站历史数据广义天气类型划分,并对各广义天气类型的总辐照度划分不同等级。光伏电站历史数据分类模型框架见附录A图A1。

2.1 基于SOM神经网络聚类算法的光伏电站历史数据分类

光伏功率与多种气象因素密切相关,因此光伏功率可反映多种气象因素的综合变化。以光伏日功率序列特征构建特征向量进行聚类分析,综合了各气象要素场的关联关系,分类结果有较高的准确度。

2.1.1 光伏日功率序列特征

如图1所示,不同天气类型下光伏功率序列呈现出不同的幅值和波动情况,因此光伏日功率序列的幅值和波动特征反映了该日天气状态。本文对每日白昼时段的光伏日功率序列进行小波变换^[18],分解层数为4,得到反映光伏功率变化趋势的近似信号 A_4 和反映光伏功率随机波动的细节信号 D_1-D_4 ,将近似信号 A_4 作为该日晴空序列 u ,细节信号 D_1-D_4 之和作为该日波动序列 v ,基于晴空序列 u 和波动序列 v 构建的光伏日功率序列特征如下。

1) 幅值特征。

以晴空序列 u 的平均值 $\bar{u}$ 衡量光伏功率幅值大小,如式(1)所示。

$$\bar{u} = \frac{\sum_{i=n_1}^{n_2} u_i}{n_2 - n_1 + 1} \quad (1)$$

式中: u_i 为晴空序列 u 中第 i 个采样点的功率值; n_1 和 n_2 分别为采样起始位置和结束位置。

2) 波动特征。

(1) 波动幅值特征。

以波动序列 v 的一阶差分指标 Δ_f 衡量光伏功率波动幅值,如式(2)所示。

$$\Delta_f = \frac{\sum_{i=n_1}^{n_2-1} |v_{i+1} - v_i|}{n_2 - n_1} \quad (2)$$

式中: v_i 为波动序列 v 中第 i 个采样点的功率值。

(2) 波动频率特征。

将波动序列 v 进行快速傅里叶变换,确定其中心频率,以中心频率衡量光伏功率波动快慢。

2.1.2 SOM神经网络聚类

SOM神经网络根据人脑神经系统中兴奋和抑制的现象,采用“竞争学习”的方式,实现对不同特征样本的分类,其结构和算法步骤见附录B。

SOM神经网络聚类算法根据数据间的相似性,通过自组织、自适应改变网络的权值,可消除输入噪声的影响,但其聚类数需事先设定。本文借鉴层次聚类的思想,自顶向下利用SOM神经网络聚类算法,以2.1.1节中的光伏日功率序列特征为输入变量,采用逐步二分的方式将光伏电站历史数据划分为 N 类广义天气类型,分类过程见附录A图A2,然后如附录A图A3所示按晴朗程度实现广义天气类型与同时间范围内公共气象服务天气类型预报匹配对应。

2.2 实测总辐照度等级划分与折算

风速越大,对大气中云团和悬浮物的推动作用越大,天气越晴朗,总辐照度越大;湿度越大,大气中的水汽对总辐照度的阻挡作用越大。特定的广义天气类型对应多种公共气象服务天气类型预报,不同公共气象服务天气类型预报如阴、雾、扬沙、霾的总辐照度大小不同,因此,各广义天气类型下由于其他气象因素的影响或包含更精细的天气类型,总辐照度呈现出不同水平。为构建更精细的总辐照度修正模型,需对各广义天气类型的总辐照度等级进行划分,广义天气类型 c 总辐照度等级划分流程如下。

1) 根据2.1节中的光伏电站历史功率数据广义天气类型划分结果,绘制广义天气类型 c 总辐照度散点图。

2) 计算广义天气类型 c 各时刻总辐照度序列不同分位数值,构建分位数值时间序列。广义天

气类型 c 第 i 个采样点的总辐照度序列 $R_{c,i}=[R_{c,1,i}, R_{c,2,i}, \dots, R_{c,K_c,i}]$, 其中 $R_{c,j,i}$ ($j=1, 2, \dots, K_c$) 为广义天气类型 c 第 j 个样本中第 i 个采样点的总辐照度值, K_c 为广义天气类型 c 所包含的样本数。若 $R_{c,i}$ 的 α 分位数值 $R'_{c,i,\alpha}$ 满足 $P(R_{c,j,i} \leq R'_{c,i,\alpha}) = \alpha$, 则广义天气类型 c 的 α 分位数值时间序列 $R'_{c,\alpha}=[R'_{c,1,\alpha}, R'_{c,2,\alpha}, \dots, R'_{c,h,\alpha}]$, 其中 $P(A)$ 表示事件 A 成立的概率, h 为采样点数。

3) 利用高斯滤波法对广义天气类型 c 总辐照度分位数值时间序列进行平滑处理。

4) 定义广义天气类型 c 相邻分位数值时间序列之间的总辐照度散点带, 将其按照从高到低分别分为等级 $1-M$ 。

将各广义天气类型总辐照度均按上述方法划分为多个等级后, 将上下界分位数值时间序列的平均值作为该等级的代表序列。根据不同广义天气类型同一等级的代表序列计算不同广义天气类型间的总辐照度折算系数序列。广义天气类型 c_1 和 c_2 间总辐照度等级 i 的折算系数序列 $\lambda_{c_1 \rightarrow c_2, i}$ 按式(3)进行计算。

$$\lambda_{c_1 \rightarrow c_2, i} = R_{c_2, i}^{\text{re}} / R_{c_1, i}^{\text{re}} \quad (3)$$

式中: $R_{c_1, i}^{\text{re}}$ 和 $R_{c_2, i}^{\text{re}}$ 分别为广义天气类型 c_1 和 c_2 总辐照度等级 i 的代表序列。

3 基于TAN的广义天气类型转移概率计算

天气状态变化具有连续性, 本文天气类型转移概率定义为在预测日前几日天气类型一定的情况下, 预测日各天气类型发生的概率。某日邻近前几日的天气状态与该日天气状态具有相关性, 不满足传统朴素贝叶斯算法各属性变量之间相互独立的假设。本文使用TAN算法计算预测日各广义天气类型的转移概率, 该算法在朴素贝叶斯算法的基础上, 假设每个条件属性在类别属性之外最多依赖于1个其他条件属性。根据该思想, 本文将预测日的广义天气类型作为类别属性, 将预测日前 D 天的广义天气类型作为条件属性, 计算预测日各广义天气类型的转移概率, 以此评估各气象预报源的准确性。广义天气类型转移概率计算模型框架见附录A图A4。TAN算法步骤见附录C。

广义天气类型转移概率的大小对总辐照度修正值的精度有很大影响, 为确定转移概率计算模型的最适条件属性数, 本文提出转移概率有效率 I_e 来评估转移概率的有效性, 计算公式为:

$$\begin{cases} I_e = \frac{1}{d} \sum_{i=1}^d B_i \times 100\% \\ B_i = \begin{cases} 1 & \arg\max_{c_k} (p_i(c_k)) = c_{\text{real}, i} \\ 0 & \arg\max_{c_k} (p_i(c_k)) \neq c_{\text{real}, i} \end{cases} \end{cases} \quad (4)$$

式中: d 为预测日天数; B_i 为引入的二进制变量, 用

于判断类变量转移概率最大值对应的广义天气类型是否为实际广义天气类型, $B_i=1$ 表示第 i 个预测日类变量转移概率最大值对应的广义天气类型与实际广义天气类型一致, $B_i=0$ 表示不一致; $p_i(c_k)$ 为第 i 个预测日第 k 种广义天气类型的转移概率中间值; $\arg\max_{c_k} (p_i(c_k))$ 表示 $p_i(c_k)$ 最大时 c_k 的取值; $c_{\text{real}, i}$ 为第 i 个预测日的实际广义天气类型。

4 基于NWP广义天气类型分类的总辐照度修正

以反映云量多少的日均直总辐照度比作为NWP广义天气类型分类的标准, 通过分析NWP广义天气类型分类正确的样本计算NWP总辐照度系统误差, 引入公共气象服务天气类型预报源, 并结合广义天气类型转移概率修正NWP总辐照度。NWP总辐照度修正模型框架见附录A图A5。

4.1 NWP广义天气类型分类

有关研究结果表明, 在云量较少、大气透明度较高的时段, 总辐照度中直射辐照度占比较大, 因此直射辐照度和总辐照度的比值反映了云量的多少。根据2.1节中的各广义天气类型所占比例, 对同一时间范围内NWP日均直总辐照度比进行排序, 按比例求取各广义天气类型日均直总辐照度比阈值, 即可根据预测日NWP数据确定预报的广义天气类型。日均直总辐照度比 η 按式(5)进行计算。

$$\eta = \frac{\sum_{i=n_1}^{n_2} \frac{R_i^{\text{di}}}{R_i^{\text{ti}}}}{n_2 - n_1 + 1} \quad (5)$$

式中: R_i^{di} 为日直射辐照度序列第 i 个采样值; R_i^{ti} 为日总辐照度序列第 i 个采样值。

4.2 NWP总辐照度系统误差计算

本文将NWP总辐照度系统误差定义为预报场的长时间平均和实测场的长时间平均之差。总辐照度实测场的长时间平均 $\bar{R}_t$ 和总辐照度预报场的长时间平均 $\bar{R}_f$ 可分别表示为:

$$\bar{R}_t = [\bar{R}_t^1, \bar{R}_t^2, \dots, \bar{R}_t^h] \quad (6)$$

$$\bar{R}_f = [\bar{R}_f^1, \bar{R}_f^2, \dots, \bar{R}_f^h] \quad (7)$$

式中: $\bar{R}_t^i, \bar{R}_f^i$ ($i=1, 2, \dots, h$) 分别为所有样本实测、预报总辐照度序列第 i 个采样点的平均值, 分别按式(8)、(9)进行计算。

$$\bar{R}_t^i = \sum_{j=1}^g R_{j,i}^t / g \quad (8)$$

$$\bar{R}_f^i = \sum_{j=1}^g R_{j,i}^f / g \quad (9)$$

式中: $R_{j,i}^t, R_{j,i}^f$ ($j=1, 2, \dots, g$) 分别为第 j 个样本实测、预报总辐照度序列的第 i 个采样值, g 为样本数。

NWP总辐照度系统误差 $\bar{R}_e$ 可表示为:

$$\bar{R}_e = \bar{R}_f - \bar{R}_r \quad (10)$$

NWP总辐照度系统误差计算步骤如下:

1) 根据2.1节中的历史功率数据分类模型确定样本集的广义天气类型;

2) 根据4.1节中的日均直总辐照度比确定样本集NWP广义天气类型;

3) 从样本集筛选NWP广义天气类型分类正确的样本,本文NWP广义天气类型分类正确的样本定义为与NWP广义天气类型与功率分类确定的广义天气类型相同的样本;

4) 在NWP广义天气类型分类正确的样本中分别计算各广义天气类型下NWP总辐照度系统误差。

4.3 NWP总辐照度修正

在预测日前一天从不同的气象服务机构获取预测日的NWP数据和公共气象服务天气类型预报,判断预测日NWP广义天气类型 c_{NWP} 与公共气象服务预报的广义天气类型 c_{WTF} 是否一致:若一致,则仅修正总辐照度系统误差即可得到用于功率预测的总辐照度序列,即广义天气类型 c_{NWP} 的总辐照度序列 $R_{c_{NWP}}$;若不一致,则根据辐照度较高时段11:00—13:00的总辐照度平均值判断广义天气类型 c_{NWP} 总辐照度等级 i ,根据广义天气类型 c_{NWP} 和 c_{WTF} 之间总辐照度等级 i 的折算系数序列 $\lambda_{c_{NWP} \rightarrow c_{WTF}, i}$ 得到广义天气类型 c_{WTF} 的总辐照度序列 $R_{c_{WTF}}$ 。由预测日广义天气类型转移概率模型分别计算NWP广义天气类型 c_{NWP} 和公共气象服务预报的广义天气类型 c_{WTF} 的转移概率 $P(c_{NWP})$ 和 $P(c_{WTF})$,并以转移概率为权重对2种广义天气类型下的总辐照度序列进行求和,得到用于功率预测的总辐照度序列 R^* 。NWP总辐照度2步修正示意图见附录A图A6。用于功率预测的总辐照度序列 R^* 按式(11)进行计算。

$$R^* = \begin{cases} R_{c_{NWP}} & c_{NWP} = c_{WTF} \\ R_{c_{NWP}} P(c_{NWP}) + R_{c_{WTF}} P(c_{WTF}) & c_{NWP} \neq c_{WTF} \end{cases} \quad (11)$$

式(11)中公共气象服务预报的广义天气类型 c_{WTF} 对应的总辐照度序列 $R_{c_{WTF}}$ 按照式(12)进行计算。

$$R_{c_{WTF}} = R_{c_{NWP}} \lambda_{c_{NWP} \rightarrow c_{WTF}, i} \quad (12)$$

5 算例分析

以我国某装机容量为20 MW的光伏电站2018年6月1日至2019年5月31日的实测数据和相关气象预报数据为样本。NWP数据来源于德国天气在线数值预报数据中心,该中心基于WRF(Weather Research and Forecasting)模式对全球预报系统GFS(Global Forecast System)背景场数据进行计算模拟;公共气象服务天气类型预报数据来源于中国天气网。以2018年6月1日至2019年4月30日的样本作为训练样本,2019年5月1日至2019年5月31日

的样本作为测试样本,对本文所建立的光伏功率短期预测模型进行验证。根据测试样本所在季节的日出日落时间,选取06:30—18:30时段的功率作为功率预测的对象。另外,根据2017—2019年的公共气象服务天气类型预报数据建立和验证广义天气类型转移概率计算模型。

5.1 光伏电站历史数据分类

提取日功率序列特征并采用SOM神经网络聚类算法进行逐步分类,由戴维森堡丁指数DBI^[19](Davies Bouldin Index)确定分类数 N ,DBI越小,分类效果越好。不同分类数 N 对应的DBI变化见图3。




图3 不同分类数下的DBI

Fig.3 DBI under different classification numbers

理论上,广义天气类型种类越多,分类模型越精细,但预测模型的复杂度越高。由图3可知,当 $N=4$ 时,DBI出现明显拐点,因此本文将历史数据划分为4种广义天气类型。通过比较聚类中心发现:广义天气类型1和2的日功率幅值较大,但广义天气类型1的日功率波动性较小,广义天气类型2的日功率波动性较大;广义天气类型3和4的日功率都呈现出一定的波动性,但广义天气类型4的日功率幅值更低。

样本时间范围内光伏电站所在地区公共气象服务天气类型预报包括晴、多云、阴、小雨、中雨、大雨、暴雨、阵雨、雷阵雨、雾、霾、扬沙、小雪、大雪、雨夹雪共15种天气类型。将这15种天气类型按照晴朗度排序,并与本文划分的4种广义天气类型进行匹配,匹配结果及各天气类型占比见表2。

表2 广义天气类型与公共气象服务天气类型预报匹配

Table 2 Matching between generalized weather types and weather type forecast by public weather service

广义天气类型	公共气象服务天气类型预报	广义天气类型占比/%	公共气象服务天气类型预报占比/%
1	晴	41.38	41.00
2	多云	27.25	27.83
3	阴、雾、霾、扬沙	15.02	15.09
4	小雨、阵雨、雷阵雨、中雨、大雨、暴雨、小雪、大雪、雨夹雪	16.35	16.08

由表2可以看出,在一定误差范围内,公共气象服务天气类型预报与本文所划分的4种广义天气类型具有较高的匹配度,验证了本文提出的基于功率特征的历史数据分类方法的有效性。

在总辐照度等级划分上,针对难以细化的广义天气类型1和2,由于风速、湿度等其他因素的影响,总辐照度呈现出不同的水平。针对包含多种精细天气状态的广义天气类型3和4,不同的精细天气状态对应不同的总辐照度水平,兼顾典型性和代表性,本文将各广义天气类型总辐照度划分为10%、30%、50%、70%、90%这5个分位数序列,共4个等级。各广义天气类型总辐照度等级及分位数界见表3。

表3 总辐照度等级及分位数界

Table 3 Total irradiance levels and quantile boundaries

总辐照度等级	上界分位数 / %	下界分位数 / %
1	90	70
2	70	50
3	50	30
4	30	10

此外,位于10%分位数序列以下和90%分位数序列之上的总辐照度序列出现的概率较低,分别将其归为等级4和等级1。广义天气类型1所有样本总辐照度散点图及等级划分如图4所示。其他广义天气类型所有样本总辐照度散点图及等级划分见附录D图D1—D3。图5为广义天气类型3总辐照度等级及其对应的精细天气状态示意图,图中阴、雾、扬沙、霾4种天气类型分别对应总辐照度等级1—4。另外,经统计验证可知:广义天气类型4中小雨、




图4 广义天气类型1总辐照度散点图及等级划分
Fig.4 Scatter diagram and classification of total irradiance for Generalized Weather Type 1




图5 广义天气类型3总辐照度等级及精细天气状态
Fig.5 Total irradiance levels and fine weather condition for Generalized Weather Type 3

阵雨、雷阵雨天气下的辐照度水平较高,属于等级1;中雨、大雨天气下的辐照度水平属于等级2;暴雨、小雪天气下的辐照度水平属于等级3;大雪、雨夹雪天气下的辐照度水平属于等级4。

5.2 广义天气类型转移概率有效性评估

为确定基于TAN的广义天气类型转移概率模型的最适条件属性数,考虑到与预测日间隔天数越多,天气状态间的相关性越弱,本文分别以预测日前1—6 d作为预测日转移概率计算的属性变量,并通过转移概率有效率 I_e 评估不同属性变量数下的转移概率有效性。

由于光伏电站历史数据时间范围较小,不适用于建立和验证广义天气类型转移概率计算模型,且虽然较长时间范围内公共气象服务预报的广义天气类型存在一定误差,但当样本集足够大时,以公共气象服务预报结果建立的广义天气类型转移概率模型与以实际广义天气类型建立的转移概率模型趋于一致,因此本文以2017年1月1日至2019年4月30日公共气象服务预报的广义天气类型作为训练样本,2019年5月1日至2019年12月31日公共气象服务预报的广义天气类型作为测试样本,分别建立不同属性变量数的转移概率计算模型,对应的转移概率有效率如表4所示。

表4 不同属性变量数下的转移概率有效率

Table 4 Transfer probability efficiency under different numbers of attribute variables

属性变量数	转移概率有效率 / %	属性变量数	转移概率有效率 / %
1	65.31	4	84.90
2	86.94	5	83.67
3	91.84	6	81.63

由表4可知:仅用预测日前1 d的广义天气类型作为属性变量计算预测日广义天气类型转移概率具有较大的偶然性,转移概率有效率较低;当用预测日前3 d的广义天气类型作为属性变量时,既保证了预测日前3 d的广义天气类型与预测日广义天气类型具有较强的相关性,又避免了属性变量较少时转移概率偶然性较大造成转移概率有效率较低的问题;当属性变量继续增加时,距离预测日时间较长的属性变量的广义天气类型与预测日广义天气类型的相关性较小,对预测日广义天气类型的判定造成干扰,导致转移概率有效率降低。因此,本文选择预测日前3 d的广义天气类型作为预测日广义天气类型转移概率计算的属性变量。

5.3 功率预测结果分析

本文将总辐照度、温度、湿度、风速作为GA-BP神经网络的输入变量,功率作为输出变量,使用五折交叉验证进行模型参数寻优,将训练样本平均划分

为5个互斥子集,其中4个子集作为训练集,另外1个子集作为验证集,每组模型参数循环验证5次,将5次预测结果的平均误差作为最终误差,选取误差较小时的模型参数作为最终GA-BP预测模型参数。模型参数见附录D表D1。

本文选取平均绝对误差MAE(Mean Absolute Error)和均方根误差RMSE(Root Mean Square Error)^[20]作为光伏电站功率预测误差的评价指标。

在测试集中根据NWP广义天气类型和公共气象服务预报的广义天气类型对总辐照度进行修正,共分为附录D表D2所示的7种情况。表中:“一步修正”表示修正系统误差,“两步修正”表示修正系统误差后进一步按照转移概率进行修正;仅情况5—7需要计算广义天气类型的转移概率和总辐照度等级,进行两步修正;情况1—4中NWP广义天气类型与公共气象服务预报的广义天气类型相同,只需根据对应的广义天气类型修正总辐照度系统误差;每种情况分别选取1d作为典型日。图6为广义天气类型1典型日总辐照度修正及功率预测结果,其他广义天气类型典型日总辐照度修正及功率预测结果见附录D图D4—D6。表5为不同广义天气类型下的功率预测误差。

由表5可以看出,所有广义天气类型下以NWP修正系统误差后的总辐照度作为功率预测的数据源,预测准确度大幅提升,验证了本文所提的NWP总辐照度系统误差计算方法的有效性。

情况5—7中NWP划分的广义天气类型与公共气象服务预报的广义天气类型不同,需要在修正系统误差的基础上进一步依据预测日不同广义天气类型的转移概率修正NWP总辐照度值。图7为情况5





图6 广义天气类型1总辐照度修正及功率预测结果


Fig.6 Total irradiance correction and power forecasting results for Generalized Weather Type 1

表5 不同广义天气类型下的功率预测误差
Table 5 Power forecasting errors under different generalized weather types

情况	广义天气类型	输入数据源	MAE / %	RMSE / %
1	1	未修正	9.35	10.08
		一步修正	3.53	4.73
2	2	未修正	15.05	18.12
		一步修正	8.14	11.26
3	3	未修正	13.46	15.29
		一步修正	5.68	7.37
4	4	未修正	14.38	16.11
		一步修正	4.89	6.00



(a) 总辐照度修正结果



(b) 功率预测结果

— 未修正, 一步修正, - - 两步修正, ---- 实测

图7 2019年5月5日总辐照度修正及功率预测结果

Fig.7 Total irradiance correction and power forecasting results on May 5, 2019

对应的总辐照度修正及功率预测结果。情况6和情况7对应的总辐照度修正及功率预测结果分别见附录D图D7和图D8。

针对情况7对应的2019年5月4日进行分析说明。该日NWP广义天气类型为广义天气类型4,公共气象服务预报的广义天气类型为广义天气类型2。按照广义天气类型4修正总辐照度系统误差后得到的功率预测结果与实测功率相差较大,这是由NWP广义天气类型预报错误,对总辐照度修正过度导致的。通过广义天气类型2与4之间的折算系数和2种广义天气类型转移概率计算融合2种气象预报进行修正后的总辐照度序列,拉升了按广义天气类型4进行系统误差修正后的总辐照度曲线,按该总辐照度曲线得到的功率预测结果与实测功率的误差相比仅进行系统误差修正大幅减小。附录D表D3为情况5—7典型日预测误差。由表可知,当预测日NWP划分的广义天气类型与公共气象服务预报的广义天气类型不一致时,按照本文提出的两步修正方法修正NWP总辐照度,并将其作为预测模型的输入

源,得到的预测结果误差更小,验证了本文所提出的依据转移概率对总辐照度进行进一步修正的有效性。

在测试集31 d中:NWP广义天气类型与公共气象服务预报的广义天气类型一致的共有17 d,对于该类预测日的NWP总辐照度,只需修正系统误差;NWP广义天气类型与公共气象服务预报的广义天气类型不一致的共有14 d,对于该类预测日的NWP总辐照度,在修正系统误差之后,以各广义天气类型的转移概率为权重计算修正后的总辐照度。附录D表D4为测试集平均误差统计表。由表可知,从长时间范围看:NWP总辐照度修正系统误差后比修正前预测结果的MAE减小了6.48%,RMSE减小了6.19%;NWP总辐照度两步修正后比修正前预测结果的MAE减小了7.65%,RMSE减小了7.66%;本文提出的NWP总辐照度两步修正算法比仅修正NWP总辐照度系统误差预测结果的MAE减小了1.17%,RMSE减小了1.47%。测试集31 d预测结果的月RMSE为9.91%,完全满足我国现行标准NB/T 32011—2013《光伏电站功率预测系统技术要求》中规定的短期预测月RMSE小于15%的要求。

因此,本文提出的结合公共气象服务天气类型预报分步修正NWP总辐照度可以显著提高功率预测的准确度,并具有较高的工程应用价值。

6 结论

本文基于NWP和公共气象服务天气类型预报2种气象预报数据源,建立总辐照度修正的光伏功率短期预测模型,该模型由光伏电站历史数据分类模型、NWP广义天气类型分类模型、广义天气类型转移概率计算模型、NWP总辐照度修正模型和GA-BP神经网络预测模型组成。从测试集31 d的预测结果来看,相较于传统以未处理的NWP数据和仅修正NWP系统误差后的数据进行功率预测的方法,本文所建立的预测模型MAE分别减小了7.65%和1.17%,RMSE分别减小了7.66%和1.47%,且月RMSE为9.91%,满足我国现行标准的要求,验证了所建立的光伏功率短期预测模型的有效性,为使用NWP进行功率预测提供了一种新思路。

本文建立的总辐照度修正模型以d为单位,以修正后的总辐照度预测光伏功率,在一定程度上提高了功率预测的精度。但在长时间尺度上总辐照度修正标准单一,未来可将研究重点转向将预测日全天划分为不同时段分别进行修正,以进一步提升预测精度。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

[1] 陈炜,艾欣,吴涛,等. 光伏并网发电系统对电网的影响研究综

述[J]. 电力自动化设备,2013,33(2):26-32,39.

CHEN Wei, AI Xin, WU Tao, et al. Influence of grid-connected photovoltaic system on power network[J]. Electric Power Automation Equipment, 2013, 33(2): 26-32, 39.

[2] 杨国清,张凯,王德意,等. 基于包络线聚类的多模融合超短期光伏功率预测算法[J]. 电力自动化设备,2021,41(2):39-46.

YANG Guoqing, ZHANG Kai, WANG Deyi, et al. Multi-mode fusion ultra-short-term photovoltaic power prediction algorithm based on envelope clustering[J]. Electric Power Automation Equipment, 2021, 41(2): 39-46.

[3] 杨国华,张鸿皓,郑豪丰,等. 基于相似日聚类 and IHGWO-WNN-AdaBoost模型的短期光伏功率预测[J]. 高电压技术,2021,47(4):1185-1194.

YANG Guohua, ZHANG Honghao, ZHENG Haofeng, et al. Short-term photovoltaic power forecasting based on similar weather clustering and IHGWO-WNN-AdaBoost model[J]. High Voltage Engineering, 2021, 47(4): 1185-1194.

[4] 李燕青,杜莹莹. 基于双维度顺序填补框架与改进Kohonen天气聚类的光伏发电短期预测[J]. 电力自动化设备,2019,39(1):60-65.

LI Yanqing, DU Yingying. Short-term photovoltaic power forecasting based on double-dimensional sequential imputation framework and improved Kohonen clustering[J]. Electric Power Automation Equipment, 2019, 39(1): 60-65.

[5] 王昕,黄柯,郑益慧,等. 基于PNN/PCA/SS-SVR的光伏发电功率短期预测方法[J]. 电力系统自动化,2016,40(17):156-162.

WANG Xin, HUANG Ke, ZHENG Yihui, et al. Short-term forecasting method of photovoltaic output power based on PNN/PCA/SS-SVR[J]. Automation of Electric Power Systems, 2016, 40(17): 156-162.

[6] 舒胜,谢应明,杨文字,等. 光伏发电预测方法研究进展[J]. 热能动力工程,2020,35(11):1-11.

SHU Sheng, XIE Yingming, YANG Wenyu, et al. A review of photovoltaic power generation forecasting methods[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(11): 1-11.

[7] LIU J, FANG W L, ZHANG X D, 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] 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):57-64,12.

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, 12.

[9] 余向阳,赵怡茗,杨宁宁,等. 基于VMD-SE-LSSVM和迭代误差修正的光伏发电功率预测[J]. 太阳能学报,2020,41(2):310-318.

YU Xiangyang, ZHAO Yiming, YANG Ningning, et al. Photovoltaic power generation forecasting based on VMD-SE-LSSVM and iterative error correction[J]. Acta Energiae Solaris Sinica, 2020, 41(2): 310-318.

[10] 叶林,裴铭,路朋,等. 基于天气分型的短期光伏功率组合预测方法[J]. 电力系统自动化,2021,45(1):44-54.


YE Lin, PEI Ming, LU Peng, et al. Combination forecasting method of short-term photovoltaic power based on weather classification[J]. Automation of Electric Power Systems, 2021, 45(1): 44-54.

[11] 吉梓铭,李慧,刘思嘉,等. 基于MIE-LSTM的短期光伏功率预测[J]. 电力系统保护与控制,2020,48(7):50-57.

JI Xingge, LI Hui, LIU Sijia, et al. Short-term photovoltaic power forecasting based on MIE-LSTM[J]. Power System Protection and Control, 2020, 48(7): 50-57.

- [12] ESEYE A T, ZHANG J H, ZHENG D H. Short-term photovoltaic solar power forecasting using a hybrid Wavelet-PSO-SVM model based on SCADA and meteorological information [J]. *Renewable Energy*, 2018, 118: 357-367.
- [13] 王飞, 米增强, 甄钊, 等. 基于天气状态模式识别的光伏电站发电功率分类预测方法[J]. *中国电机工程学报*, 2013, 33(34): 75-82, 14.
WANG Fei, MI Zengqiang, ZHEN Zhao, et al. A classified forecasting approach of power generation for photovoltaic plants based on weather condition pattern recognition[J]. *Proceedings of the CSEE*, 2013, 33(34): 75-82, 14.
- [14] VERBOIS H, RUSYDI A, THIERY A. Probabilistic forecasting of day-ahead solar irradiance using quantile gradient boosting[J]. *Solar Energy*, 2018, 173: 313-327.
- [15] RINCÓN A, JORBA O, FRUTOS M, et al. Bias correction of global irradiance modelled with weather and research forecasting model over Paraguay[J]. *Solar Energy*, 2018, 170: 201-211.
- [16] 师春香, 潘昶, 谷军霞, 等. 多源气象数据融合格点实况产品研发进展[J]. *气象学报*, 2019, 77(4): 774-783.
SHI Chunxiang, PAN Yang, GU Junxia, et al. A review of multi-source meteorological data fusion products[J]. *Acta Meteorologica Sinica*, 2019, 77(4): 774-783.
- [17] 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.
- [18] 杨丽薇, 高晓清, 蒋俊霞, 等. 基于小波变换与神经网络的光伏电站短期功率预测[J]. *太阳能学报*, 2020, 41(7): 152-157.
YANG Liwei, GAO Xiaoqing, JIANG Junxia, et al. Short-term photovoltaic output power prediction based on wavelet transform and neural network[J]. *Acta Energetica Sinica*, 2020, 41(7): 152-157.
- [19] 黄越辉, 曲凯, 李驰, 等. 基于K-means MCMC算法的中长期风电时间序列建模方法研究[J]. *电网技术*, 2019, 43(7): 2469-2476.
HUANG Yuehui, QU Kai, LI Chi, et al. Research on modeling method of medium- and long-term wind power time series based on K-means MCMC algorithm[J]. *Power System Technology*, 2019, 43(7): 2469-2476.
- [20] YIN W S, HAN Y T, ZHOU H, et al. A novel non-iterative correction method for short-term photovoltaic power forecasting [J]. *Renewable Energy*, 2020, 159: 23-32.

作者简介:



师浩琪

师浩琪(1998—),男,河北石家庄人,硕士研究生,主要研究方向为新能源发电功率预测及应用(E-mail: hqshi@tju.edu.cn);
郭力(1981—),男,山东济宁人,教授,博士,主要研究方向为分布式发电接入配电网、交直流微电网的规划和运行控制(E-mail: liguo@tju.edu.cn)。

(编辑 王锦秀)

Short-term forecasting of photovoltaic power based on total irradiance correction of multi-source meteorological forecast

SHI Haoqi, GUO Li, LIU Yixin, WANG Chengshan

(Key Laboratory of Smart Grid of Ministry of Education, Tianjin University, Tianjin 300072, China)

Abstract: Aiming at possible misstatement and deviation problems of a single weather forecast source, a short-term forecasting method of photovoltaic power based on total irradiance correction of multi-source meteorological forecast is proposed. According to the characteristics of power series, the self-organizing map neural network clustering algorithm is adopted to divide the generalized weather types of historical data. The matching correspondence between generalized weather types and weather type forecast from public weather service is realized according to the degree of sunshine, and the conversion coefficient between each level of total irradiance of different generalized weather types is calculated. On the basis of calculating system error of each generalized weather type, if the generalized weather type classification result of numerical weather prediction is consistent with that of weather type forecast from public weather service on the forecast day, the system error of total irradiance is corrected by superposition, otherwise the tree augmented naive Bayes algorithm is adopted to calculate the transfer probability of two generalized weather types, the conversion coefficient is used to calculate the total irradiance sequence of generalized weather type corresponding to the weather type forecast from public weather service after the correction of system error, and the weighting coefficient is set by transfer probability to further modify the total irradiance sequence. The forecasting model is built, and the short-term photovoltaic power forecasting results are obtained based on back propagation neural network optimized by genetic algorithm. The validity of the model is verified by the actual operation data of a photovoltaic power plant and the weather forecast data.

Key words: multi-source meteorological forecast; transfer probability; numerical weather prediction; power forecasting; short-term forecasting; photovoltaic power generation

附录 A:




图 A1 光伏电站历史数据分类模型框架

Fig.A1 Framework of classification model for historical data of photovoltaic plant




图 A2 光伏电站历史数据分类过程

Fig.A2 Classification process for historical data of photovoltaic plant




图 A3 广义天气类型与公共气象服务天气类型预报匹配对应

Fig.A3 Matching correspondence between generalized weather types and weather type forecast by public weather service




图 A4 广义天气类型转移概率计算模型框架

Fig.A4 Framework of calculation model for transition probability of generalized weather types




图 A5 NWP 总辐照度修正模型框架

Fig.A5 Framework of correction model for NWP total irradiance




图 A6 总辐照度两步修正示意图

Fig.A6 Schematic diagram of two-step correction for total irradiance

附录 B:

SOM 神经网络输入层有 s 个神经元，竞争层由 t 个神经元组成一维或二维神经元阵列。竞争层的各神经元之间相互竞争以求被激活，最终在每个样本输入时仅有 1 个神经元被激活，称为获胜神经元，该神经元表示对输入样本的分类结果。




图 B1 SOM 神经网络结构

Fig.B1 Structure of SOM neural network

SOM 算法步骤如下。

1)网络初始化。随机初始化输入层与竞争层之间的连接权值向量 $\mathbf{w}_i \in \mathbf{R}^s (i=1,2,\dots,t)$ ，令迭代次数 $k=1$ ，设定最大迭代次数 K 。

2)输入向量归一化。对新的输入样本 $\mathbf{I}=[I_1, I_2, \dots, I_s] \in \mathbf{R}^s$ ，进行归一化处理。

3)求取获胜神经元。计算竞争层各个神经元的权值向量与输入向量之间的距离，将距离最小的竞争层神经元作为获胜神经元，获胜神经元的权值记为 $\mathbf{w}_v$ 。

$$\mathbf{w}_v = \arg \min_{\mathbf{w}_i} \|\mathbf{I} - \mathbf{w}_i\|_2 \quad (\text{B1})$$

式中： $\|\cdot\|_2$ 表示 L2 范数。

4)修正网络权值。修正获胜神经元邻近区域的神经元权值。

$$\mathbf{w}_i^{(k+1)} = \mathbf{w}_i^{(k)} + \mathbf{h}_v^{(k)} (\mathbf{x} - \mathbf{w}_i^{(k)}) \quad (\text{B2})$$

式中： $\mathbf{w}_i^{(k)}$ 为第 k 次迭代时 $\mathbf{w}_i$ 的值； $\mathbf{h}_v^{(k)}$ 为第 k 次迭代中获胜神经元的邻域函数，随两神经元间距离增加而减小。

5)更新输入样本，返回步骤 3)，直到输入样本全部提供给网络。

6)令 $k = k + 1$ ，返回步骤 3)，直到 k 达到最大迭代次数。

附录 C:

TAN 算法包括以下 3 个步骤。

1) 计算各属性节点之间的条件互信息。

计算预测日前 D 天广义天气类型两两之间的条件互信息，按照各属性之间互信息的大小确定相互依赖关系。预测日前 i 天广义天气类型节点 X_i 与前 j 天广义天气类型节点 X_j 之间的条件互信息按下式计算：

$$I_{ij}(X_i, X_j | C) = \sum_{k=1}^N \left(P(c_k) \sum_{m=1}^N \sum_{n=1}^N P(x_{m,i}, x_{n,j} | c_k) \cdot \ln \frac{P(x_{m,i}, x_{n,j} | c_k)}{P(x_{m,i} | c_k) \cdot P(x_{n,j} | c_k)} \right) \quad (C1)$$

式中： C 为预测日广义天气类型节点； c_k 为预测日第 k 种广义天气类型； $x_{m,i}$ 为预测日前 i 天的第 m 种广义天气类型； $x_{n,j}$ 为预测日前 j 天的第 n 种广义天气类型； N 为广义天气类型种类数。

2) 构建贝叶斯网络。

以节点 X_i 和 X_j 的条件互信息作为树中边 (X_i, X_j) 的权值，建立最大权重跨度树，增加类节点到所有属性节点的有向边，构建贝叶斯网络。

3) 各节点局部条件概率计算和类变量概率推理。

各节点的局部条件概率为 $P(X_i | \bar{X}_{i,C}, C)$ ， $\bar{X}_{i,C}$ 为贝叶斯网络中除去类变量节点 C 之外，节点 X_i 的父节点集合。给定一组未知类别的实例 $(x_1, x_2, \dots, x_D)$ ，类变量概率推理如下式：

$$p(c_k) = P(c_k) \prod_{i=1}^D P(x_i | \bar{x}_{i,C}, c_k) \quad (C2)$$

式中： $x_i (i=1, 2, \dots, D)$ 为节点 X_i 的广义天气类型， $\bar{x}_{i,C}$ 为节点集合 $\bar{X}_{i,C}$ 对应的广义天气类型。

通过局部条件概率推算得到 NWP 广义天气类型 c_{NWP} 和公共气象服务预报的广义天气类型 c_{WTF} 对应的转移概率中间值 $p(c_{NWP})$ 和 $p(c_{WTF})$ ，由于 $p(c_{NWP}) + p(c_{WTF}) \neq 1$ ，因此预测日各类广义天气类型的概率需要经过下式进行转换计算：

$$P(c_{NWP}) = \frac{p(c_{NWP})}{p(c_{NWP}) + p(c_{WTF})} \quad (C3)$$

$$P(c_{WTF}) = \frac{p(c_{WTF})}{p(c_{NWP}) + p(c_{WTF})} \quad (C4)$$

附录 D:




图 D1 广义天气类型 2 总辐照度散点图及等级划分

Fig.D1 Scatter diagram and classification of total irradiance for Generalized Weather Type 2




图 D2 广义天气类型 3 总辐照度散点图及等级划分

Fig.D2 Scatter diagram and classification of total irradiance for Generalized Weather Type 3




图 D3 广义天气类型 4 总辐照度散点图及等级划分

Fig.D3 Scatter diagram and classification of total irradiance for Generalized Weather Type 4

表 D1 模型参数


Table D1 Model parameters

算法	参数	参数值
BP	输入层节点数	4
	隐含层节点数	12
	输出层节点数	1
	迭代次数	2 000
	学习率	0.1
	最小误差	0.003
GA	编码方式	实数编码
	种群规模	50
	进化代数	100


表 D2 测试集总辐照度修正情况种类

Table D2 Cases of total irradiance correction for test set

情况	NWP 广义天气类型/转移概 率	公共气象服务广义天气类 型/转移概率	修正步骤	总辐照度等级	典型日日期
1	1	1	一步修正	—	5 月 2 日
2	2	2	一步修正	—	5 月 11 日
3	3	3	一步修正	—	5 月 28 日
4	4	4	一步修正	—	5 月 8 日
5	2/0.56	3/0.44	一步修正	2	5 月 5 日
			两步修正		
6	3/0.63	4/0.37	一步修正	1	5 月 24 日
			两步修正		
7	4/0.43	2/0.57	一步修正	3	5 月 4 日
			两步修正		




(a)总辐照度修正结果




(b)功率预测结果

图 D4 广义天气类型 2 总辐照度修正及功率预测结果

Fig.D4 Total irradiance correction and power forecasting results for Generalized Weather Type 2




(a)总辐照度修正结果




(b)功率预测结果

图 D5 广义天气类型 3 总辐照度修正及功率预测结果

Fig.D5 Total irradiance correction and power forecasting results for Generalized Weather Type 3




(a)总辐照度修正结果




(b)功率预测结果

图 D6 广义天气类型 4 总辐照度修正及功率预测结果

Fig.D6 Total irradiance correction and power forecasting results for Generalized Weather Type 4




(a)总辐照度修正结果



(b)功率预测结果

图 D7 2019 年 5 月 24 日总辐照度修正及功率预测结果

Fig.D7 Total irradiance correction and power forecasting results on May 24, 2019



(a)总辐照度修正结果




图 D8 2019 年 5 月 4 日总辐照度修正及功率预测结果

Fig.D8 Total irradiance correction and power forecasting results on May 4, 2019

表 D3 情况 5—7 功率预测误差

Table D3 Power forecasting errors of Case 5-7

情况	NWP/公共气象服务 广义天气类型	输入数据源	MAE/%	RMSE/%
5	2/3	未修正	23.24	26.34
		一步修正	12.18	16.26
		两步修正	7.18	9.97
6	3/4	未修正	24.53	27.19
		一步修正	13.87	16.75
		两步修正	8.43	10.16
7	4/2	未修正	15.95	20.91
		一步修正	23.51	31.98
		两步修正	8.58	10.62

表 D4 测试集平均误差统计

Table D4 Mean error statistics of test set

样本范围	天数	输入数据源	MAE/%	RMSE/%
广义天气类型一致的样本	17	未修正	14.08	16.15
		一步修正	7.31	9.48
		未修正	16.91	19.29
广义天气类型不一致的样本	14	一步修正	10.75	13.67
		两步修正	8.17	10.44
		未修正	15.35	17.57
全体样本	31	一步修正	8.87	11.38
		两步修正	7.70	9.91