

适用于小样本的神经网络光伏预测方法

张程熠¹,唐雅洁¹,李永杰¹,高 强²,江全元¹

(1. 浙江大学 电气工程学院,浙江 杭州 310027;2. 国网浙江省电力公司电力调度控制中心,浙江 杭州 310007)

摘要: 基于神经网络的短期光伏预测方法通常需要大量训练样本,对于新投运的光伏电站,历史运行数据的不足使得常规短期光伏预测方法难以应用。针对该问题,提出一种适用于小样本的双层神经网络单步光伏预测方法。根据光伏发电各环节影响因素的解耦特性,将常规单层神经网络拆分为双层网络,使每层网络具有简化的结构;用单步预测代替多步预测,降低神经网络的输入输出维数;基于统计分析,将天气影响因素有效整合到预测模型中,简化输入输出之间的映射关系。使用实际数据对所提光伏预测模型进行训练和验证,结果表明,所提方法可有效减少对训练样本数量的需求,同时保证预测的准确度。

关键词: 光伏发电; 短期功率预测; 小样本; 神经网络; 单步预测

中图分类号: TM 615

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2017.01.016

0 引言

近年来,随着社会经济的发展,能源短缺和环境污染问题日益突出,开发与利用可再生能源成为解决能源和环境问题的有效途径。在新能源发电中,光伏发电由于具有安全可靠、地域限制少、建设周期短等优势而得到快速发展,目前已具备较大的产业规模。但由于天气等因素的影响,光伏输出功率在短时间尺度内存在较大的不确定性,准确有效的光伏预测技术对于系统的安全稳定运行和光伏能源的有效利用具有重要意义。

按照预测原理,光伏预测方法可分为物理方法和统计方法两大类。物理方法是利用物理模型进行预测,如文献[1]以数值天气预报为输入,利用太阳位置模型、光伏电池模型、逆变器效率模型,最终得到了光伏电站的输出功率。物理方法不需要历史运行数据,投产后即可预测,但是需要光伏电站详细的物理信息,预测精度受所建模型的影响很大,在实际工程中应用较少。统计方法是通过对历史运行数据进行统计分析,进而找出光伏输出功率与各影响因素的内在规律进行预测,如灰色预测、马尔科夫链、人工神经网络、支持向量机等。文献[2]以待预测日的历史相似日中有光照时段的每小时输出功率平均值,待预测日与历史相似日的气温信息、湿度信息、风速以及气溶胶数据为输入,以待预测日有光照时段每小时输出功率平均值为输出,用 BP 神经网络实现了未来 24 h 光伏输出功率的多步预测。文献[3]提出一种基于相似日和径向基函数神经网络的光伏发电预测方法。文献[4]通过灰色关联度分析选择

训练样本,利用最小二乘支持向量机预测未来 24 h 的光伏输出功率。文献[5]通过近邻传播算法对光伏出力进行分类,然后根据预测日所属类别建立回声网络状态方程用以预测光伏出力。上述方法在具备充足的样本数据时均具有较好的预测水平,但是由于实际系统所具备的预测条件差别很大,没有一种方法是普适的^[6]。目前,提前 1 d 的光伏短期预测方法一般都需要充足的历史数据支持,对数据积累时间的要求长达 3 个月至 1 a 不等^[2,5-6],若光伏电站处于投运初期,历史数据积累不足,常规预测方法在应用上会受到很大限制。因此,有必要针对小样本情境对常规方法进行改进,得到适用于投运初期光伏发电系统的功率预测方法。

为了充分利用神经网络方法对于解决非线性问题的优势,同时降低预测算法对历史数据的依赖程度、提高预测算法对小样本的适应性,本文提出了一种双层神经网络单步光伏预测方法。通过分析光伏输出功率的影响因素,明确了各影响因素的自然解耦特性,将单层神经网络拆分为双层神经网络,使各部分网络的结构得到简化;通过天气类型与云遮程度对应关系的统计分析,将云遮因素有效整合到模型输入量中,降低了输入、输出之间关系的复杂度;用单步预测代替多步预测,降低了网络的输入、输出维数,进一步简化了网络结构。最后基于实际系统的运行数据,验证了本文所提出的方法在小样本条件下,能够较准确地实现提前 1 d 的光伏发电功率预测。

1 光伏输出功率影响因素

光伏发电是根据光生伏特效应,利用太阳能电池将太阳能直接转化为电能。光伏输出功率与地表太阳辐射强度以及光电转换效率紧密相关。在分析光伏输出功率影响因素时,可从影响地表太阳辐射的因

收稿日期:2016-07-29;修回日期:2016-11-09

基金项目:浙江省重大科技专项计划项目(2014C01006)

Project supported by Major Science and Technology Projects of Zhejiang Province(2014C01006)

素和影响光电转换环节的因素这两方面分别展开。

1.1 地表辐射强度的影响因素

太阳辐射在经过地球大气时,会受云量、气溶胶、水汽等因素的综合影响^[7]。

云量对太阳辐射的影响十分显著且复杂,但总体上,云量的增加会使到达地球表面的总辐射减少^[7-8]。在空气质量良好、空气湿度较小时,到达地表的太阳辐射主要受到云量的影响。为了表示太阳辐射穿透云层的能力,将第 j 天第 i 时段的平均太阳辐射强度 $R_{i,j}$ 与无云天气下对应时段的平均太阳辐射 R_{0i} 的比值定义为穿透率 $k_{i,j}$,即:

$$k_{i,j} = R_{i,j} / R_{0i} \quad (1)$$

R_{0i} 可由 n 个邻近日对应时段历史数据中的最大太阳辐射值近似表示,即:

$$R_{0i} \approx \max \{R_{i,1}, R_{i,2}, \dots, R_{i,j}, \dots, R_{i,n}\} \quad j=1, 2, \dots, n \quad (2)$$

其中, n 为所选择的邻近日数量。

作为太阳辐射最显著的影响因素,云量常被作为预测模型的输入量。目前,常规气象数据中还没有直接描述云量的值。由于天气类型能对云量进行模糊表示,在短期光伏预测中,普遍利用天气类型表征云量的情况。本文用到的天气类型数据主要来自公共气象数据网站 Weather Underground,包含晴天、多云时晴、多云、阴、雨这 5 类,数据间隔为 1 h。

气溶胶是大小为 $0.001 \sim 100 \mu\text{m}$ 的固体或液体小质点分散并悬浮在气体介质中形成的胶体分散体系,对太阳辐射也有着重要影响。它既可以直接反射、散射或吸收太阳辐射,又可以通过改变云的微物理性质而产生间接效应,但总体上,气溶胶的增加会使到达地面的太阳辐射减少^[8]。近年来,随着化石燃料的大量燃烧,人为气溶胶的排放大量增加,雾霾天气频繁出现,成为光伏预测中不可忽视的因素。环境监测中的空气质量指数 AQI (Air Quality Index) 作为空气质量状况的无量纲指标,是目前最常见的空气质量定量描述指标,故本文选用空气质量指数表示气溶胶的影响。文中用到的空气质量指数数据来自青悦空气质量历史数据库,数据间隔为 1 h。

水汽对太阳辐射也有较强的吸收作用,但相比云量和气溶胶的影响,这种作用小很多^[7]。一般情况下,只有在雾霾天气下,水汽才会对太阳辐射有比较明显的削弱作用。在训练样本有限时,为尽量简化输入、输出之间的映射关系,不再将水汽作为预测模型的输入量,仅在第 2.3 节进行统计样本的筛选时考虑水汽的影响。

1.2 光电转换环节的影响因素

到达地球表面的太阳辐射能够通过太阳能电池的光伏效应,完成光电转换过程,最终输出电功率。在这一过程中,地表辐射强度、逆变器转换效率、光

伏面板安装角度、光伏组件温度等因素都会影响输出功率。

由于绝大多数光伏并网逆变器都以相对稳定的功率转换率运行在最大功率点跟踪模式,对既定的光伏发电系统而言,其输出功率数据具有高度的自相关性,已包含了光伏阵列的系统信息,在短期预测中可以将逆变器转换效率、光伏面板安装角度等因素看作常数,而只需考虑地表太阳辐射强度和光伏组件的温度^[9]。

地表太阳辐射强度是光电转换的直接影响因素,随着地表太阳辐射强度的增大,光伏电池的开路电压、短路电流会随之增大,从而引起输出功率的增大。

光伏电池对组件温度也具有一定的敏感性。随着温度的升高,短路电流有所增加,但开路电压却下降,且后者变化较大,总的输出功率将下降。这一情况在组件温度达到 20°C 以上时尤为显著^[10]。由于光伏组件的温度较难预测,在实际预测过程中常用环境温度进行代替。

1.3 影响因素的解耦

通过上述内容可以看出,从光伏发电物理机制的角度分析,可将影响光伏输出的因素分为 2 个部分:第一部分为太阳辐射从地外到达地球表面过程中的所有影响因素,包含大气中各要素对太阳辐射的削减,如云量、气溶胶等;第二部分为光电转换环节的影响因素,主要考虑地表太阳辐射和光伏组件温度。上述两部分影响因素具有如图 1 所示的天然解耦特性,在建立预测模型时,可将其分开考虑。




图 1 光伏输出功率影响因素解耦示意图

Fig.1 Schematic diagram of influencing factors decoupling for PV output

2 光伏发电预测模型

2.1 BP 神经网络

BP 神经网络是一种按误差反向传播算法训练的多层前馈网络,具有强大的非线性映射能力,它能够通过样本训练使网络学习大量的输入、输出映射关系,并且具有较好的泛化能力,在光伏预测中有着广泛的应用^[11]。

神经网络预测模型主要由输入层、隐含层、输出层组成。文献[12]在用 BP 神经网络进行提前 1 d 的光伏预测时,以前一天的发电量序列、天气类型、最高气温以及预测日的天气类型、最高气温为输入,以预测日的发电量序列为输出。这种利用邻近日

或相似日功率序列相似性而构建的预测模型在实际工程中有广泛的应用。目前,随着气象服务类信息的详细化,公共气象服务网站已经能够提供未来 1 d 中每小时的天气类型、温度等信息,可将这些信息加入到神经网络输入中,得到一个由天气类型、温度、空气质量确定的光伏输出功率预测模型 I;预测时段为 06:00—19:00,其他时段输出功率为 0,输入层变量为 06:00—19:00 每小时的天气类型、空气质量指数、温度,输出层变量为 06:00—19:00 每小时的光伏输出功率,如图 2 所示。




图 2 预测模型 I 神经网络结构图
Fig.2 Structure of neural network for forecast model I

为使预测模型适应小样本情境,提高在小样本条件下的泛化能力,本文对预测模型 I 进行了改进。一般而言,神经网络的泛化能力主要取决于 3 个因素,即问题本身的复杂程度、网络结构以及样本量的大小^[11]。在样本量一定且较小时,为保证网络的泛化水平,应尽可能简化输入和输出之间的关系以及网络结构。下文根据第 1.3 节中分析得到的光伏功率影响因素的自然解耦特性,将图 2 所示的预测网络拆分,使网络结构得到简化。此外,基于气象信息的统计分析对天气类型进行变换,并用单步预测代替多步预测,简化了输入和输出之间的关系。同时,用单步预测代替多步预测降低了输入、输出维数,进一步简化了网络结构。通过上述改进,初步得到了本文的预测模型 II。

2.2 神经网络结构拆分

根据第 1.3 节对光伏输出功率影响因素的分析,可将削弱辐射强度的主要影响因素云量、气溶胶,以及影响光电转换环节的温度这 3 个因素作为神经网络的输入。用天气类型表示云量情况,用空气质量指数表示气溶胶情况,即如图 2 所示的神经网络结构。

考虑到太阳辐射削弱环节与光电转换环节是 2 个较为独立的过程,为简化网络结构,可针对这 2 个过程进行解耦,从而把一个相对较大的网络拆分为 2 个较小的网络,得到如图 3 所示的输入、输出关系,通过这样的处理,网络结构能够得到初步简化,对小样本的适应性也会随之提高。

2.3 输入量变换

在神经网络输入量中,空气质量指数和温度均




图 3 分层后的输入、输出关系示意图
Fig.3 Schematic diagram of relationship between input and output after layering

为具有实际物理意义的数值,但天气类型仅对晴天、多云时晴、多云、阴、雨这 5 种情况进行区分,一般用整数对其进行标识,记为 w ,如表 1 所示。

表 1 天气类型标识码对照表
Table 1 Identification codes of weather type

天气类型	w	天气类型	w
晴天	1	阴天	4
多云时晴	2	雨	5
多云	3		

w 只能对 5 种天气类型进行区分标识,并不能表示其云遮程度,加大了输入和输出之间关系的复杂度。为尽可能减少这一影响,本文充分利用待预测时段邻近时段的天气类型预报信息和邻近日的历史太阳辐射数据,统计得到各天气类型所对应的穿透率期望,用穿透率期望代替天气类型,简化输入、输出之间的映射关系。具体处理过程如下所述。

a. 在历史样本中除去空气质量不佳、空气湿度大的部分,得到地表太阳辐射强度主要受云量影响的样本。由式(2)计算得到邻近日第 i 时段最大太阳辐射,用于近似表示第 i 时段无云天气下的太阳辐射 R_{0i} ,再由式(1)计算第 j 天第 i 时段的实际穿透率 $k_{i,j}$ 。结合第 j 天第 i 时段实际天气类型与实际穿透率,统计得到天气类型 w 所对应的穿透率的分布,并计算其期望值。利用浙江南都电源光储一体化电站 2015 年 4 月至 6 月的历史数据,得到的统计结果如表 2 所示。相比 w 所标识的天气类型,穿透率期望值能够更直接地体现出当前云量对太阳辐射的削减程度,从而简化神经网络的映射关系。

表 2 天气类型与穿透率期望对应关系
Table 2 Weather type and corresponding penetration rate expectation

w	穿透率期望	w	穿透率期望
1	0.864	4	0.373
2	0.727	5	0.185
3	0.548		

b. 步骤 a 中 5 种天气类型的表示比较模糊,每一种天气类型统计得到的穿透率较为分散。为细化步骤 a 中穿透率的统计分析过程,将前后时段的天气类型也考虑其中,得到了考虑前后时段天气情况的穿透率分布。由实际数据得到统计结果,部分结果如表 3 所示。表中天气类型转换 1-2-1 表示当前时段天气类型为 2,前一时段天气类型为 1,后一时

表 3 考虑前后时段天气类型的穿透率期望对照
Table 3 Penetration rate expectation considering previous and succeeding weather types

天气类型	穿透率期望	天气类型	穿透率期望
1-2-1	0.746	1-3-1	0.584
2-2-2	0.731	2-3-2	0.569
3-2-3	0.712	3-3-3	0.549
4-2-4	0.706	4-3-4	0.527
5-2-5	0.696	5-3-5	0.528

段天气类型为 1。相比表 2,表 3 对天气类型有了更细致的划分,同时计及了天气的变化信息。

c. 由步骤 a、b 分别得到了 2 种穿透率的统计结果。在进行预测时,首先根据待预测时段及其前后时段的天气类型,在表 3 中查找对应的穿透率期望,若该考虑时变的天气类型在有限的统计样本中未曾出现,则只考虑当前时段的天气类型,并在表 2 中查找对应的穿透率期望,得到代表云量的穿透率期望作为输入值,用于模型的训练和预测。

2.4 用单步预测代替多步预测

在对天气类型进行变换后,双层神经网络中体现光伏输出功率影响因素的变量包含穿透率期望 $\bar{k}_{i,j}$ 、空气质量指数 $A_{i,j}$ 以及环境温度 $T_{i,j}$,用向量 $\mathbf{x}_{i,j}$ 表示第 j 天第 i 时段的影响因素,即:

$$\mathbf{x}_{i,j} = [\bar{k}_{i,j}, A_{i,j}, T_{i,j}] \tag{3}$$

由于夜间光伏输出功率为 0,式(3)中预测时段 i 的取值区间为 06:00—19:00,则第 j 天的影响因素 $\mathbf{x}_j$ 为:

$$\mathbf{x}_j = [\mathbf{x}_{6,j}, \mathbf{x}_{7,j}, \cdots, \mathbf{x}_{19,j}] \tag{4}$$

定义第 j 天第 i 时段的光伏输出功率为 $y_{i,j}$,则第 j 天的光伏输出功率 $\mathbf{y}_j$ 为:

$$\mathbf{y}_j = [y_{6,j}, y_{7,j}, \cdots, y_{19,j}] \tag{5}$$

根据预测模型输出向量的维数,分别定义单步预测和多步预测。输出向量只有一维的为单步预测,输出向量有多维的为多步预测。即单次预测中,若以 $y_{i,j}$ 为输出,则称为单步预测,若以 $\mathbf{y}_j$ 为输出,则称为多步预测。一般情况下,多步预测模型的各输入因素也需是多维的,而相比多步预测,单步预测各输入因素的维数大幅降低。以本文模型 I 的输入、输出关系为例,多步预测的输入量是 06:00—19:00 时间范围内每个时段的天气类型、空气质量指数和温度;单步预测的输入量可以简化为 06:00—19:00 时间范围内某一个待预测时段的天气类型、空气质量指数和温度。目前在短期光伏预测中,一般采用多步预测方法,输入、输出维数较高,需要较多的隐含层节点,网络结构趋于复杂化,对训练样本数量有较高要求。考虑到地表太阳辐射强度主要受当前时段的天气类型、空气质量等因素的影响,在光电转换环节中,光伏输出功率也主要受当前时段光照强度、

温度的影响,并且现有气象服务网站可以提供时间间隔为 1 h 的气象数据,因此可以用单步预测代替多步预测,用单个时段的数据代替连续一天各时段的数据序列,从而构建各影响因素单时段输入、预测结果单时段输出的单步预测模型。

在单步预测中,若以 $\mathbf{x}_{i,j}$ 为输入、以 $y_{i,j}$ 为输出,则输入量中的时段信息会缺失。一种处理方法是在输入量中加入时刻 t_i ,得到新的输入变量 $\mathbf{x}'_{i,j}$:

$$\mathbf{x}'_{i,j} = [\bar{k}_{i,j}, A_{i,j}, T_{i,j}, t_i] \tag{6}$$

另一种处理方法是将穿透率期望 $\bar{k}_{i,j}$ 与第 i 时段无云天气下的太阳辐射 R_{0i} 相乘,得到第 i 时段受云量影响后的太阳辐射强度 $\tilde{R}_{i,j}$,即:

$$\tilde{R}_{i,j} = \bar{k}_{i,j} \times R_{0i} \tag{7}$$

通过这样的改变,可以得到新的输入变量 $\mathbf{x}''_{i,j}$:

$$\mathbf{x}''_{i,j} = [\tilde{R}_{i,j}, A_{i,j}, T_{i,j}] \tag{8}$$

这 2 种方式均能将时刻信息添加到输入量中,但是由于第一种方式增加了新的输入量,网络结构不如第二种方式简洁,所以在预测模型中采用 $\mathbf{x}''_{i,j}$ 作为输入变量。具体预测流程如图 4 所示,将该预测方法对应的模型记作模型 II。




图 4 模型 II 预测流程示意图

Fig.4 Schematic diagram of forecast model II

3 预测结果与分析

上文提及了常规的预测模型 I 以及适用于小样本的预测模型 II,预测模型 II 相比预测模型 I 的改进主要体现在以下 3 个方面:

- a. 将单层神经网络拆分为双层神经网络;
- b. 用单步预测代替多步预测;
- c. 用云遮后辐射强度代替天气类型标识码。

为验证预测模型 II 的有效性,分别构建预测模型 I 与预测模型 II 的网络结构,并实现 BP 神经网络的学习训练与仿真预测。神经网络输入、输出层节点个数与预测模型输入、输出个数一致。通过试算,预测模型 I 的隐含层选择为 2 层,2 层隐含层节点数均为 5 个;预测模型 II 中第一个神经网络的隐含层为 1 层,节点数为 3 个,第二个神经网络的隐含层为 1 层,节点数为 2 个。在 2 种预测模型中,隐含层激励函数类型均为 Logsig 函数,输出层激励函数为线性函数,使用梯度下降法进行网络训练。算例中所采用的辐射强度数据、光伏输出功率数据来自浙江南都

电源光储一体化电站 57 kW 光伏发电系统 2015 年 4 月 20 日至 6 月 17 日的运行数据,共包含 50 d 有效数据。天气类型、温度等气象数据来自公共气象数据网站,数据间隔均为 1 h。

选择 6 月 8 日至 6 月 17 日这 10 d 的数据作为预测样本,分别将 6 月 8 日之前的 10 d、20 d、30 d、40 d 数据作为训练样本,对预测模型 I 与预测模型 II 进行检验。

以 6 月 12 日(晴天)与 6 月 16 日(阴雨天)为例,将 2 种预测模型在不同数量的训练样本下的预测结果绘制在图 5 与图 6 中。图 5 是天气类型为晴天的预测结果,图 6 是天气类型为阴雨天时的预测结果。




图 5 晴天预测结果
Fig.5 Predictive results for sunny day




图 6 阴雨天预测结果
Fig.6 Predictive results for overcast and rainy day

从图 5 和图 6 中可以看出,预测模型 I 与预测模型 II 在晴天的预测效果较好,在阴雨天的预测效果较差。模型 II 的预测效果在小样本情况下优于模型 I,随着样本数量的增加,模型 I 的预测效果逐渐提升,两者的预测效果趋近。

为了进一步分析预测效果,本文以均方根误差 RMSE(Root Mean Square Error)、平均绝对值百分比误差 MAPE(Mean Absolute Percentage Error)和希尔不等系数 TIC(Theil Inequality Coefficient)为评价指标,对模型进行评估。RMSE、MAPE 与 TIC 的计算式分别如下^[13]:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - P_{ti})^2} \quad (9)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_i - P_{ti}}{P_i} \right| \times 100\% \quad (10)$$

$$TIC = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - P_{ti})^2}}{\sqrt{\frac{1}{N} \sum_{i=1}^N P_i^2} + \sqrt{\frac{1}{N} \sum_{i=1}^N P_{ti}^2}} \times 100\% \quad (11)$$

其中, P_i 为光伏输出功率实测值,单位为 kW; P_{ti} 为光伏输出功率预测值,单位为 kW; N 为预测日所预测的时段总数。

图 7 对比了 2 种预测模型在不同训练样本下所有预测日的预测误差指标均值。需要说明的是,由于日出日落时段的光伏出力实际值很小,较小的预测偏差就可能会导致很大的相对绝对值误差值。因此,为了合理地展示不同模型的预测效果,在图 7 所示的 MAPE 指标结果中,没有考虑日出日落时段(早晨或傍晚光伏出力小于 0.5 kW 的时段)的预测误差。







图 7 不同数量训练样本的预测误差指标均值
Fig.7 Means of forecast error indexes for different training sample sizes

由于 3 种误差评价指标变化趋势相似,因此在图 8 中以 RMSE 指标为例,分别呈现了在不同数量的训练样本下,预测模型 I 与预测模型 II 的预测误差。日期编号 1—10 分别对应 6 月 8 日至 6 月 17 日。





(c) 采用 30 d 数据作为训练样本



(d) 采用 40 d 数据作为训练样本

■ 模型 I, ■ 模型 II

图 8 分别采用 10、20、30、40 d 数据作为训练样本的误差对比

Fig.8 Comparison of forecast error between two models, based on 10-,20-,30-,40-day training sample

上述图形表明:

a. 预测模型 I 对训练样本的依赖较大,随着样本数量的增加,预测误差逐渐减小;

b. 预测模型 II 对小样本的适应性较好,在样本数量从 10 d 增加到 40 d 的过程中,预测误差变化不大,且均保持在较低水平;

c. 随着预测样本数量的增加,预测模型 I 的预测水平逐渐接近预测模型 II,当训练样本数量达到 40 d 时,预测模型 I 在第 5 个预测样本中的预测结果甚至优于预测模型 II。

可以看出,本文所提出的预测模型 II 对小样本情境有较好的适应性,适合应用于投运初期、历史累积数据较少的光伏电站。

4 结论

本文提出了一种改进的双层神经网络单步光伏短期预测方法。该方法通过将单层神经网络拆分为双层神经网络、用单步预测代替多步预测、用穿透率期望代替天气类型标识码,实现了网络结构和输入输出之间关系的简化。算例结果表明,该方法在小样本条件下,有较好的预测结果。

参考文献:

- [1] 卢静,翟海清,冯双磊,等. 光伏发电功率预测方法的探索[J]. 华东电力,2013,41(2):380-384.
- LU Jing,ZHAI Haiqing,FENG Shuanglei,et al. Physical method for photovoltaic power prediction[J]. East China Electric Power, 2013,41(2):380-384.
- [2] LIU J,FANG W,ZHANG X,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.

- [3] 王晓兰,葛鹏江. 基于相似日和径向基函数神经网络的光伏阵列输出功率预测[J]. 电力自动化设备,2013,33(1):100-109.
- WANG Xiaolan,GE Pengjiang. PV array output forecasting based on similar day and RBFNN[J]. Electric Power Automation Equipment,2013,33(1):100-109.
- [4] 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.
- [5] 李乐,刘天琪. 基于近邻传播聚类 and 回声状态网络的光伏预测[J]. 电力自动化设备,2016,36(7):41-46.
- LI Le,LIU Tianqi. PV power forecasting based on AP-ESN[J]. Electric Power Automation Equipment,2016,36(7):41-46.
- [6] 钱振,蔡世波,顾宇庆,等. 光伏发电功率预测方法研究综述[J]. 机电工程,2015,32(5):651-659.
- QIAN Zhen,CAI Shibo,GU Yuqing,et al. Review of PV power generation prediction[J]. Journal of Mechanical & Electrical Engineering,2015,32(5):651-659.
- [7] 尹青,张华,何金海. 近 48 年华东地区地面太阳总辐射变化特征和影响因子分析[J]. 大气与环境光学学报,2011,6(1):37-46.
- YIN Qing,ZHANG Hua,HE Jinhai. Long term change of surface total solar radiation and influencing factors over East China in recent 48 years[J]. Journal of Atmospheric and Environmental Optics,2011,6(1):37-46.
- [8] 申彦波,赵宗慈,石广玉. 地面太阳辐射的变化、影响因子及其可能的气候效应最新研究进展[J]. 地球科学进展,2008,23(9): 915-924.
- SHEN Yanbo,ZHAO Zongci,SHI Guangyu. The progress in variation of surface solar radiation,factors and probable climatic effects[J]. Advances in Earth Science,2008,23(9):915-924.
- [9] 丁明,王磊,毕锐. 基于改进 BP 神经网络的光伏发电系统输出功率短期预测模型[J]. 电力系统保护与控制,2012,40(11):93-99.
- DING Ming,WANG Lei,BI Rui. A short-term prediction model to forecast output power of photovoltaic system based on improved BP neural network[J]. Power System Protection and Control, 2012,40(11):93-99.
- [10] 邓雅,胡书举,孟岩峰,等. 光伏发电系统功率预测研究方法综述[J]. 电气制造,2013(6):18.
- DENG Ya,HU Shuju,MENG Yanfeng,et al. Overview of research methods for power prediction of photovoltaic power generation system[J]. Journal of Electrical Engineering,2013 (6):18.
- [11] 阎平凡,张长水. 人工神经网络与模拟进化计算[M]. 北京:清华大学出版社,2005:79-82.
- [12] 陈昌松. 光伏微网的发电预测与能量管理技术研究[D]. 武汉:华中科技大学,2011.
- CHEN Changsong. Research on power forecasting and energy management for photovoltaic microgrid [D]. Wuhan:Huazhong University of Science & Technology,2011.
- [13] 高阳,张碧玲,毛京丽,等. 基于机器学习的自适应光伏超短期出力预测模型[J]. 电网技术,2015,39(2):307-311.
- GAO Yang,ZHANG Biling,MAO Jingli,et al. Machine learning-based adaptive very-short-term forecast model for photovoltaic power[J]. Power System Technology,2015,39(2):307-311.

(下转第 111 页 continued on page 111)

Design of VSG testbed for LVRT of renewable energy

ZHOU Wen¹,BI Daqiang²,DAI Yuxing¹,CHENG Linyu¹,XIONG Shuhua¹

(1. Zhejiang Province Engineering Laboratory of Electrical Digital Design Technology,Wenzhou University,
Wenzhou 325035,China;2. State Key Lab of Power Systems,Department of Electrical Engineering,
Tsinghua University,Beijing 100084,China)

Abstract: A method of transformer-type VSG(Voltage Sag Generator) design based on the LabVIEW control system is proposed for the LVRT(Low Voltage Ride Through) test and the design principle of the VSG testbed is analyzed. The control of communication between the supervisory computer and the local VSG controller is designed by LabVIEW and the VSG control system adopts STM32F103 as its master control chip. The main structure of VSG includes tapped transformer,relay and current-limiting resistor. In order to meet the requirements of LVRT test,the developed testbed operates the VSG safely and reliably via the supervisory computer,sets the voltage sag duration accurately,and simulates the grid fault voltage with different drop depths. The experimental results validate the effectiveness and reliability of the designed VSG testbed.

Key words: voltage sag generator; communication; control; LabVIEW; low voltage ride through; renewable energy resources

(上接第 106 页 continued from page 106)

作者简介:



张程熠

张程熠(1991—),女,浙江宁波人,硕士研究生,主要研究方向为新能源发电预测与微电网能量管理(**E-mail**:zcyee@zju.edu.cn);
唐雅洁(1993—),女,湖南长沙人,硕士研究生,主要研究方向为微电网能量管理(**E-mail**:tyj@zju.edu.cn);
李永杰(1989—),男,山东东营人,博

士研究生,主要研究方向为电力系统小干扰稳定分析与控制(**E-mail**:yongjieee@zju.edu.cn);
高 强(1985—),男,山西稷山人,高级工程师,硕士,主要研究方向为电力系统调控运行(**E-mail**:gaoqiang242@163.com);
江全元(1975—),男,湖北黄冈人,教授,博士,主要研究方向为电力系统稳定与控制、电力系统高性能计算、电力系统最优化(**E-mail**:jqy@zju.edu.cn)。

Photovoltaic power forecast based on neural network with a small number of samples

ZHANG Chengyi¹,TANG Yajie¹,LI Yongjie¹,GAO Qiang²,JIANG Quanyuan¹

(1. College of Electrical Engineering,Zhejiang University,Hangzhou 310027,China;
2. Power Dispatch and Control Center of State Grid Zhejiang Electric Power Company,Hangzhou 310007,China)

Abstract: Since the conventional short-term PV(PhotoVoltaic) power forecast based on neural network normally needs a large number of samples for training,it is not suitable for the newly-built PV station with insufficient historical data,for which,a method of PV power forecast based on dual-layer neural network is proposed for a small number of samples. The conventional single-layer neural network is divided into two layers according to the decoupling characteristics of different influencing factors of PV generation and each layer has a simplified structure. Instead of multi-step forecasting,single-step forecasting is adopted to lower the input and output dimensions of neural network. Based on the statistical analysis,the weather factors are effectively integrated into the forecast model to simplify the mapping between input and output. Practical data are applied to train and verify the proposed model and results show that,the proposed method can effectively reduce the demand of training samples while guarantee the forecast accuracy.

Key words: photovoltaic generation; short-term power forecast; a small number of samples; neural networks; single-step prediction