

基于盲信号分离原理的台区光伏实时出力感知算法

徐晓春¹, 李佑伟¹, 李彦伦², 戴欣¹, 窦晓波², 卜强生³, 张岩²

(1. 国网江苏省电力有限公司淮安供电分公司, 江苏 淮安 223002; 2. 东南大学电气工程学院, 南京 210096;
3. 国网江苏省电力有限公司电力科学研究院, 南京 211103)

摘要:随着整县分布式光伏项目的推进,分布式光伏的装机规模和范围逐渐扩大,台区内出现潮流反向现象,而现有的光伏电表无法完成发电数据的实时采集,这将导致调度侧负荷数据的失真和分布式新能源管理的缺失等问题。考虑到台区现有的一次设备量测与通信状况,提出了一种基于盲信号分离理论的台区内光伏实时出力估计方法。该方法基于变压器总表的电能数据与台区内光伏出力的轮廓数据,以最小互信息为标准进行光伏出力分解,并对结果进行卡尔曼滤波去噪。进一步基于分解得到的带标签的数据建立数据库,采用卷积神经网络进行训练,以得到优化的光伏出力估计结果。最后以扬中地区一含光伏台区实际数据进行验证,评估了算法的误差。

关键词:配电网;盲信号;光伏感知;互信息

Real-time Power Sensing Algorithm of Station Photovoltaic Based on Blind Signal Separation Principle

XU Xiaochun¹, LI Youwei¹, LI Yanlun², DAI Xin¹, DOU Xiaobo², BU Qiangsheng³, ZHANG Yan²
(1. Jiangsu Electric Power Company Huai'an Power Supply Company, Jiangsu Huaian 223002, China;
2. Electrical Engineering College of Southeast University, Nanjing 210096, China; 3. Electric Power Research Institute of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211103, China)

Abstract: With the promotion of the distributed photovoltaic project across the country, the installed scale and scope of the distributed photo-voltaic are gradually expanding, and the reverse trend of power flow occurs in the station area. However, the existing photo-voltaic meters have no way to complete the real-time collection of power generation data, which will lead to such problems as distortion of load data at the dispatching side and the lack of distributed new energy management. Considering the measurement and communication status of primary equipment in the station area, a kind of real-time photovoltaic output estimation method based on signal decomposition theory is proposed in this paper. Based on the electric energy data of the transformer meter and the contour data of photovoltaic output in the station area, the photovoltaic output is decomposed in accordance with the minimum mutual information, and the separation results are denoised by Kalman filter. Furthermore, the database is set up based on the labeled data obtained by decomposition, and the convolutional neural network is used for training to obtain the optimized photovoltaic output estimation results. Finally, the actual data of a photovoltaic neighborhood area in Yangzhong area is verified, and the error of the algorithm is assessed.

Keywords: distribution network; blind signal; photovoltaic perception; mutual information

0 引言

在国家“30·60”能源战略稳步推进与整县分布式光伏项目积极推动的背景下,台区内分布式光伏渗

透率逐渐上升,2021年度,我国新增分布式光伏容量2 928万千瓦,占全国总新增装机容量的16.6%^[1]。由于分布式光伏对电量平衡、配电网安全运行的影响,电网急需一种对分布式光伏进行实时监测的方

收稿日期:2023-04-17

基金项目:国网江苏省电力有限公司科技项目(J2021036)。

法^[2]。由于分布式光伏数量多、容量小、数据量大的特点,系统中一般不实时上传高分辨率的数据,仅使用定时冻结的方式上传低分辨率的数据以完成电费计量与上网补贴的工作,但数据精度无法满足分布式光伏的实时监控要求。考虑改造现有光伏电表完成监测的方案受台区水平制约,一方面台区内光伏信息标准缺失导致对信息采集与通信的成本敏感,另一方面由于量测缺失及较低的维护水平,分布式光伏的监测数据质量较差,光伏的实时监测无法满足^[3-4]。

盲信号分离,也称盲源信号分离,指只有观测信号已知,并且其中含有目标源信号和混合系统的未知信息的情况下,对源信号进行估计和分解,广泛应用于信号处理、语音处理、数字水印等诸多领域^[5-6]。盲信号分离从原理上可以分为两类,一类的特征是统计负熵、累计张量等参数作为分离标准^[7-8],另一类则针对复杂环境,基于深度学习和神经网络实现信号分离^[9-10]。在电力领域中,盲信号分离技术同样得到广泛应用,文献[11]通过局部分解的方法实现了欠定盲信号的分离,初步实现了家电负荷识别。文献[12]使用 SOBI 算法从变压器油箱表面振动分解出有载分接开关的振动信号,为变压器在线监测提供了一种手段。文献[13]采用快速独立分量分析算法分离在非同步采样情况下的谐波与间谐波,在较少的谱线数下保证了电力测量的精度。

目前,国内对于台区内光伏实时感知的相关研究较为匮乏,主要集中在研究分离光伏、负荷后进一步提高负荷预测的精度方面[14]。相比之下,国外已经开展相关研究,并提出了两种方案用于实现光伏感知,以满足能源聚合商对负荷监测与窃电检测的需求:

1)根据台区内负荷特性进行光伏出力分解。文献[15-17]基于台区内各用户负荷曲线特征的一致性,将整体负荷用部分有完全量测的负荷代替,并采用聚类等算法分离各用户。文献[18-19]需要安装额外的量测设备,采用非侵入式负荷监测,从而实现光伏出力的分解。文献[20]采用网格搜索方法进行相关性分析,但是仅适用于光伏规模较大的情况,无法有效应用于台区层面。

2)基于神经网络与深度学习实现光伏出力的分解。文献[21-23]基于数据驱动对台区光伏进行识别,但是本方法对量测数据规模有一定要求,难以进行实际应用。文献[24]将组合神经网络与聚类方法进行结合,但仍使用静态的方法对负荷进行分

析,无法处理台区负荷特性存在变化的情况。

在此背景下,本文基于现有的变压器总表量测与天气数据,采用盲信号分离领域中最小互信息的方式分解光伏与负荷处理,并采用卡尔曼滤波去除噪声对分离效果的影响,在积累的分解数据的基础上使用 CNN 网络的方式优化分解结果。最后以一高渗透率台区一年的数据验证了算法的有效性并与已有的算法进行了对比。

1 台区光伏实时出力感知框架

1.1 光伏负荷混合模型

根据是否存在光伏出力,台区内负荷可以分为光伏负荷与非光伏负荷两类,其自然混合过程可以用以下公式进行描述:

$$A_T(t) = A_L(t) + A_{pv}(t) \quad (1)$$

$$A_{pv}^{ref}(t) = \frac{1}{\lambda^*} A_{pv}(t) \quad (2)$$

式中: $A_T(t)$ 为台区变压器总表采集的负荷曲线; $A_L(t)$ 为非光伏用户的总负荷曲线; $A_{pv}(t)$ 为光伏用户的总负荷曲线; $A_{pv}^{ref}(t)$ 为可观测的光伏出力曲线轮廓; λ^* 是一个参数,用于表示实际光伏总出力与光伏曲线轮廓之间的倍率。

式中 $A_T(t)$ 与 $A_{pv}^{ref}(t)$ 为已知量。 $A_{pv}^{ref}(t)$ 可以根据当地的气象信息生成或通过当地可观测光伏节点出力生成。在精度允许范围内,本文使用光照强度轮廓曲线近似生成光伏曲线的形状^[25]。同时,针对某一时间段,对光照强度等参数进行间隔采样后取平均值,近似获得光伏电度曲线轮廓。由于假设了台区内光伏曲线轮廓的相似性,当台区内存在光伏的主动控制或配置有储能时,方法精度会受到一定程度的影响。

1.2 基于盲信号分离原理的光伏分解算法

根据配变总表的量测实现光伏与负荷出力的分离是一种盲信号分离问题。盲源信号分离技术是通过观测的混合信号去估计源信号的一类技术的总和,该技术可以在没有原始信号统计信息的情况下实现混合信号之间的分解,但是方法受噪声的影响较大。如果已知源信号的统计信息,采用神经网络的方式学习信号特征,能够更好的完成信号的分离。当台区内光伏为近期安装时,不存在历史运行信息。此外,营销与其他系统之间的数据融合与网络安全问题使得算法获取台区的历史数据困难。所以方案设计只根据实时获得的总表数据与气象数据建立算法,算法流程见图 1。




图1 光伏实时出力感知框架

Fig. 1 Photovoltaic real-time output sensing framework

算法的输入是配变总表数据与当时的气象数据,输出为台区内分布式光伏总的实时出力。方案在结构上可以分解为两个部分:

1)互信息分解算法。该算法是本方案的核心部分。首先根据气象数据生成光伏出力参照曲线,其次以光伏与负荷之间的互信息为评价函数得到光伏实际出力与光伏出力参照之间的倍率关系。考虑到存在模型、量测等误差,对分离出的光伏倍率进行卡尔曼滤波去噪。最后根据估计的倍率与光伏参照值即可获取实时的光伏总出力估计,并对结果进行定期记录。

2)网络算法(convolutional neural network,CNN)。该算法依赖于历史的数据集,在条件允许的情况下,数据集可以由营销系统直接获得。如果无法获得数据集的话,则由互信息算法逐渐积累历史数据。在获得了数据集的基础上,互信息算法仍在后台运行并定期更新训练数据集。CNN网络参数根据数据集进行训练,模型训练结束后,输入总表与气象数据即可直接输出当前的光伏总出力。

互信息分解算法不需要历史数据,能够直接输出结果,当算法运行时间少于60天时,由该部分算

法输出结果。互信息算法在运行的过程中会不断积累运行数据,并对CNN网络进行训练,当算法运行时间大于60天时,网络精度满足应用需求,此时由CNN网络算法输出光伏出力分解结果,互信息算法则在后台定期运行以定期更新CNN网络训练的历史数据库。

2 基于最小互信息的光伏出力分解算法

2.1 基于最小互信息的光伏出力分解

由等式(1)–(2)可知,只要确定 λ^* 即可完成光伏与非光伏负荷两者之间的分解。设 λ 为待求解的逼近真值 λ^* 的变量,当 λ 不是最优时,由式(1)分解出的负荷曲线中会包含一定比例的光伏信息,当分离的效果越好时,负荷信息中就会包含越少的光伏信息,也就是说两者之间的互信息最少。在信号处理领域中常用互信息进行信号之间关联性的度量,针对应用的离散场景,公式有

$$H(X) = - \sum_{x \in \chi} p(x) \log_2 p(x) \quad (3)$$

$$H(X, Y) = - \sum_{x \in \chi} \sum_{y \in \psi} p(x, y) \log_2 p(x, y) \quad (4)$$

$$I(X, Y) = \frac{H(X) + H(Y) - H(X, Y)}{\sqrt{H(X)H(Y)}} \quad (5)$$

式中: $H(X)$ 为随机变量 X 的信息熵; $H(X, Y)$ 为随机变量 X, Y 之间的联合熵; $p(x)$ 为 X 的概率分布; $p(x, y)$ 表示 X, Y 之间的联合概率; χ 表示 x 的取值范围; ψ 为 y 的取值范围; $I(X, Y)$ 为随机变量 X, Y 之间的标准互信息。

评价分解效果的函数公式为

$$I(A_{pv}(t), A_L(t)) \approx \min I(A_{pv}^{ref}(t), A_T(t) - \lambda A_{pv}^{ref}(t)) \quad (6)$$

式中: λ 为待求解的最优光伏倍率,其取值范围为 $[0, S_T / \max(A_{pv}^{ref}(t))]$,最大值由实际物理意义决定,台区所装光伏容量不会超过变压器容量,所以光伏倍率不会超过变压器容量 S_T 与参考光伏曲线最大值之间的比值。实际的光伏出力曲线无法获得,所以采用参考光伏曲线进行近似替代。

对于该目标函数,在 λ 取值范围内存在先减小后增大的趋势,一般对 λ 采用梯度下降法进行迭代求解。但是根据一个时间窗口的数据对变压器总表 $A_T(t)$ 与光伏 $A_{pv}^{ref}(t)$ 的概率密度进行核密度估计本身就存在一定的误差,即使采用双曲正切或者sigmoid函数进行近似,在代入到互信息中计算也是对这些核函数或是近似函数的梯度,损失迭代效

率。本文中的互信息计算为离散场景,只需要各数据出现的频数,对于每一个 λ 值代入式(5)都能够直接计算出互信息值,不需要求解概率密度函数。所以本文采用粒子群算法求解最优 λ 。

2.2 基于卡尔曼滤波的出力估计

实际中为了考虑算法的可用性与对新装光伏的动态感知,算法使用的光伏与总表数据是采用时间窗扫描的形式,即每次送入的数据为当前时间点前一天同一时间点共 24 h 的数据。设当前时间为 T_N ,时间窗宽度为 w ,则曲线中时间变量 t 的取值范围为 $[T_N - w + 1, T_N - w + 2, \dots, T_N - 1, T_N]$ 。由于采用窗口扫描的方式,方法一次仅采用一天的数据量,结果受噪声的影响增大,使采用最小互信息的方式估计出的光伏倍率偏离真值。为了平抑分离的波动,采用卡尔曼滤波算法对光伏倍率进行滤波去噪。

本场景中采用一维卡尔曼滤波对光伏倍率进行状态估计。卡尔曼滤波分为预测与校正两个步骤,其中预测过程见式(7)–(8)

$$\lambda_t = \lambda_{t-1} \quad (7)$$

$$P_t = P_{t-1} + Q \quad (8)$$

式中: λ_{t-1} 为 $t-1$ 时刻卡尔曼滤波后的光伏倍率系数; λ_t 为对 t 时刻的倍率进行预测后得到的参数。在本文中,考虑无新装的光伏或光伏离退网的情况,此时的光伏倍率会趋向于常数。由于卡尔曼预测过程中没有控制变量的输入,因此在预测过程中输入控制矩阵为零,状态转移矩阵取单位矩阵,即 t 时刻的 λ 预测值等于 $t-1$ 时刻的 λ 滤波值。 P_{t-1} 为 $t-1$ 时刻的误差矩阵; Q 为预测过程的噪声方差; P_t 为对 t 时刻的误差矩阵的预测值。

预测过程得出的预测值还需要结合观测值进行误差修正,修正过程见式(9)–(11)。

$$K_t = \frac{P_t}{P_t + R} \quad (9)$$

$$\lambda_t = \lambda_t + K_t(\lambda - \lambda_t) \quad (10)$$

$$P_t = (1 - K_t)P_t \quad (11)$$

式中: R 为基于互信息分解得到的噪声方差,将其与预测误差进行加权得到 t 时刻的卡尔曼增益 K_t ; λ 为 t 时刻由互信息分解过程得到的光伏倍率,根据该测量值与预测值得到 t 时刻获得的光伏倍率滤波值 λ_t 。公式(11)表示根据校正后的卡尔曼增益更新预测的误差 P_t 。

经过以上的预测过程与校正过程即可完成卡尔曼滤波,方法总体运算量较小,适于实时计算, $t-1$ 时刻向 t 时刻传递的仅有误差 P_t 。方法需要给定观测误差的噪声方差 R 与预测的噪声误差 Q , R 可以通过对互信息方法进行实际验证得到普遍的通用值, Q 为卡尔曼模型的预测误差,其量级与 R 相同。

使用最小互信息算法感知光伏实时出力的流程见图 2。




图2 互信息算法感知流程

Fig. 2 Mutual information algorithm sensing process

3 基于累计数据优化的CNN网络算法

神经网络算法能够根据历史数据进行学习,输出在当前情况下光伏总出力概率最大的结果,对噪声等误差的容忍度更高。所以利用互信息算法运行过程中积累的数据训练神经网络能够获得精度更高的结果。气象数据与配变总表数据是算法输入的两个特征,同时这两个数据相同位置的点代表的是同一个时间采集到的数据,可以理解为卷积神经网络中同一个数据的不同特征通道,所以算法适合采用针对特征进行学习的 CNN 神经网络。CNN 网络算法运行过程中,由互信息算法在后台进行数据集扩展,采用不同的原理生成训练数据的原因是避免网络出现过拟合。

3.1 基于卡尔曼平滑的出力修正

训练数据采用的是离线数据,对真实倍率的估计不仅可以用到 t 及 t 时刻之前的数据,还可以获得 $t+1$ 等目标时刻之后的数据,此时采用卡尔曼平滑能够获得更高的准确度。

卡尔曼平滑为预测与校正过程的前向迭代与反向迭代的结合。首先对离线的光伏倍率数据进行卡尔曼滤波的前向迭代过程,对滤波后的数据再进行反向迭代,如公式(12)–(13)。

$$\lambda_t = \lambda_{t+1} \quad (12)$$

$$P_t = P_{t+1} + Q \quad (13)$$

预测过程的公式与滤波相比从由前向后预测变为由后往前,误差修正同理,校正过程的公式与式(9)-(11)相同。

根据卡尔曼平滑后的光伏倍率将台区出力数据分解为光伏出力数据与纯负荷出力数据,将其存至数据库并定期更新。

3.2 数据预处理与模型建立

由实际数据积累的数据库无法直接进行神经网络训练,一方面实际倍率大部分偏向于一个常数,即使有新装光伏导致的变动也只是改变为另一个常数,数据集本身存在较大的不均衡性,会导致网络的过拟合。另一方面,实际的光伏参考曲线与总表曲线的波动范围不同,即使对于光伏曲线来说,天气的影响也会造成不同日期幅值的较大波动。所以数据集需要首先进行样本均衡的处理,之后对样本数据进行归一化处理。

对于样本不均衡问题,采用扩展样本的方式解决。经过光伏出力分解后可以得到独立的光伏出力曲线与纯负荷出力曲线。样本集的特征数据为光伏曲线与总表曲线,标签数据为光伏曲线倍率。所以扩展样本集的光伏参照曲线保持不变,总表曲线扩展为纯负荷曲线加以不同倍率的光伏曲线之和,如式(14)。

$$A_{T,exp}(t) = A_L(t) + \lambda' A_{pv}^{ref}(t) \quad (14)$$

式中: λ' 为扩展的光伏倍率,其取值范围为 $[0, S_T / \max(A_{pv}^{ref}(t))]$, 方法采用等间隔的取一定数量的 λ' ; $A_{T,exp}$ 为经过扩展后的台区总表数据。

经过样本扩展后,还需要进行样本数据的预处理。因为训练的过程是让神经网络进行互信息的拟合及预测,即分辨单位幅值的总表曲线中包含单位幅值的光伏曲线的倍率。所以对每一个样本的总表数据与光伏参照数据做 min-max 标准化与中心化处理。归一化后样本数据分布为 $[-0.5, 0.5]$ 。将光伏数据与总表数据归一化后,标签也就是光伏倍率同样需要换算,见式(15)。

$$\lambda'' = \lambda' \frac{A_{pv,max} - A_{pv,min}}{A_{T,exp,max} - A_{T,exp,min}} \quad (15)$$

λ'' 是与归一化后的光伏、总表数据相匹配的光伏倍率。需要注意的是,归一化是针对每一个样本单独归一化,而不是取所有样本的最大值、最小值

后归一化,由于总体负荷波动幅度较大,分别进行归一化会取得更好的训练样本。

由式(6)可得,光伏倍率 λ 和总表曲线、光伏参照曲线之间存在隐函数关系,且存在总表曲线、光伏参照曲线到 λ 的唯一映射,所以可以采用神经网络拟合学习这种映射关系。

光伏参考曲线与总表曲线是样本的两个主要特征,且两个特征有着相同的维度,序列在时间上存在一致性,适合于针对特征进行学习的 CNN 神经网络。网络输入通道为 2,之后采用一维卷积,多层卷积后经过全连接层即可构建初始网络结构。

模型输入的光伏与总表数据是按照一定的时间窗口进行的截取,在不同的时间截取数据时,获取的数据序列长度虽然相同,但是序列每个具体位置代表的时间断面不同,这增加了模型的复杂度与模型收敛的困难。所以对输入的数据进行切片调换处理,将每个序列的顺序按照采集的时间点进行重新排序。对于时间窗宽度为 w 的 x 序列,假设 w 表示一天的时间宽度,则序列 $x = \{x_1, x_2, \dots, x_{t_0}, \dots, x_w\}$, 假设 x_{t_0} 为采样时刻为 0:00 的数据,则重新排列过后的序列 x 为 $\{x_{t_0}, x_{t_0+1}, \dots, x_w, x_1, x_2, \dots, x_{t_0-1}\}$ 。

根据互信息算法积累的历史数据,进一步采用 CNN 网络算法进行光伏出力感知的流程见图 3。




图3 CNN网络算法感知流程
Fig. 3 CNN algorithm sensing process

4 算例分析

为了验证本文算法的有效性,以扬中一实际台区的数据进行验证,并与文献[26]的方法进行了对比。该台区共有用户 71 户,其中 9 户安装有分布式光伏(其中一户光伏为 9 月新安装)。选取该台区 2021 年度一年 365 日的的数据,删除其中存在量测缺失的日期后剩余 219 日。台区总表采集频率

为一日 96 点,台区下光伏电表、用户电表的采集频率为每日 24 点,处理后统一采用每日 24 点。由于方法使用的是电度值,为电表码值之差,所以每日 24 点处理后为每日 23 点。将上述数据拼接后获得连续的 219×23 点的数据,包括三条曲线,1)变压器总表曲线;2)光伏参照出力曲线(选取一台光伏电表的出力作为参照);3)台区光伏总出力曲线。

方法以一台用户的光伏电表作为分离光伏曲线的参照,首先验证一台用户的光伏出力曲线形状与台区光伏总出力形状的相似性,各用户的光伏曲线与台区光伏总出力曲线之间相关系数最小为 0.915,也就是线性相关程度极高,将一个用户的光伏电表作为台区光伏总出力的参照是有效的。

分析参考光伏曲线与实际总光伏出力曲线之间形状的误差带来的算法性能影响。分离算法的原理是最小互信息,所以当波形失真所叠加的信号为高斯信号时,对算法的性能影响最大。计算典型日光伏总出力与光伏总出力叠加 $N(0, \delta^2)$ 信号之间皮尔逊相关系数的变化,结合光伏最小相关系数为 0.915,此时噪声 $\delta = 4.74$ 。在该情况下,仍考虑分解的最差情况,为高斯信号全部分解至光伏出力侧,则此时产生的绝对误差为 $E(|N(0, 4.74^2)|) = 4.74 \times \sqrt{2/\pi} \approx 3.78$,产生的相对误差约为 13%。

4.1 基于最小互信息的光伏出力分解

在上述台区中,验证采用互信息分解原理的光伏出力辨识算法。算法输入为 24 h 的一台光伏表的数据、配变总表数据,将算法分解出的光伏出力与实际光伏出力进行对比。算法设置式(12)中动态变量 $a=0.2$,卡尔曼滤波参数 $Q=1 \times 10^{-4}$, $R=0.1$ 。分解结果见图 4-5。




图4 光伏倍率分解效果

Fig. 4 Photovoltaic magnification decomposition effect




图5 光伏出力分解效果

Fig. 5 Photovoltaic output decomposition effect

由图 4 可以看出,单纯以最小互信息为标准进行光伏分离,其效果受噪声影响较大,经过卡尔曼滤波之后的光伏倍率围绕实际的光伏倍率小范围波动。在长时间尺度下仍存在一定的类似周期性误差,可能是存在一个周期更长的干扰噪声,或者是存在模型外参数导致的系统误差。图 5 为截取的连续十五日的光伏出力分解结果,经过滤波后的分解光伏出力与实际光伏总出力基本重合。

为了验证方法的动态性能,台区在 9 月有一户新安装的光伏用户,选取该日的前后两天共五日的数据进行验证。发现不经过滤波的算法性能有轻微改善,但是误差和方差都高于经过滤波的算法。优化了动态性能的算法误差最小,仅为 14.59%,要优于不考虑动态性能与滤波的情况。可见无论是从全局稳态的角度还是从存在光伏容量变动的角度,方法都能够较好适应现实情况,完成台区光伏出力的实时估计。

4.2 基于累计数据优化的 CNN 网络估计效果

在互信息分解的基础上,进一步评估采用 CNN 网络方式优化估计光伏实时出力算法的性能。首先,对算法分解的光伏标签数据进行卡尔曼平滑。平滑后平均绝对误差为 1.112 kWh,平均相对误差为 11.05%,比仅经过滤波的数据提升了一个百分点的精度。

训练数据集的扩展方式 λ' 取值为 $\{0.5, 0.75, 1, 1.25, 1.5, 1.75, 2\} \times \lambda$,将训练集扩展 6 倍。训练过程采用 python3.8,pytorch1.10.2 环境,训练网络由一层卷积核为 2×2 的卷积层与两层全连接层构成。训练的训练集与测试集比例为 3:1,损失函数为均方差,采用 adadelta 算法进行网络参数寻优,训练一

共对训练集数据迭代 100 轮。

方案模拟真实的逐渐积累数据的情况,逐渐向训练数据库中增加数据。从 219 天的数据中随机抽取 19 天作为数据库容量不同时训练出的模型效果的验证,这 19 日由于拥有所有光伏与负荷的量测数据,所以将光伏的容量同样做相同的扩展以增加验证集的多样性。根据不同时间长度构建的数据集并训练神经网络,在这 19 日的测试集上测试分离误差,并与文献[26]中采用线性相关系数的方法进行了对比,分离效果见图 6。




图6 分离精度与数据集大小的关系
Fig. 6 Relationship between separation accuracy and data set size

由图中可以看出,采用 CNN 网络进行光伏实时出力分解的方式受数据集的增大影响,其分解精度逐渐增高,当数据集容量大于 60 天时,分解的相对误差低于采用互信息方法进行分解。当数据集容量大于 90 天时,分解的均方差低于互信息算法。当数据集容量为 200 天时,测试精度最优,误差降低到了 4.2%。文献[26]方法是采用神经网络进行优化,使得分离的负荷与光伏功率之间的皮尔逊相关系数最低,由于皮尔逊相关系数是一种衡量两组数据之间的线性关系,实际的光伏与负荷存在一定的相关性,所以方法分离的相对误差与均方差均高于互信息方法,CNN 网络方法在拥有 30 天以上的训练数据时,精度也优于文献[26]方法。

由上述两部分算例可见,针对无先验量测数据的含光伏台区,采用本方法能够实现 11.72% 以内误差的光伏实时出力估计,并随着时间的推移,方法的估计精度能够进一步减少至 4.2%,甚至更低,能够完成正常的台区光伏感知、监控功能。

5 结语

针对调度侧对台区内光伏实时出力不可见的

问题,本文综合考虑台区内复杂的设备状况与维护水平的局限性,提出了一种基于盲信号分离的台区光伏出力估计方法,通过实测数据分析并与其他文献的方法对比,能够得出以下结论;

1) 无需安装额外量测,仅需要台区总表的量测数据与光伏出力曲线轮廓,算法易于推广;

2) 使用互信息与神经网络等非线性度量方法。基于负荷与光伏的物理特性进行判别,在负荷与光伏之间功率的线性相关性假设较弱或负荷特性发生变化的情况下仍有较高精度;

3) 算法随着数据积累会逐渐增加求解精度;

4) 当台区内存在光伏主动控制、光储一体化时,会对算法性能造成一定的影响。

算法的上限受到光伏轮廓曲线精度的约束,另一方面,当台区新增光伏装机时,算法需要 1-2 天的时间甄别是否为噪声。因此,如何更好的适应台区内光伏容量的投切以均衡算法的快速性与稳定性,有待于未来进一步研究。

参考文献

- [1] 方磊,张玮亚,姜小涛,等. 面向分布式光伏智慧运维的虚拟采集关键技术[J]. 电力电容器与无功补偿,2022,43(3):153-164.
FANG Lei, ZHANG Weiya, JIANG Xiaotao, et al. Key technology of virtual acquisition for PV intelligent operation and maintenance[J]. Power Capacitor & Reactive Power Compensation, 2022, 43(3): 153-164.
- [2] 郑伟烁,郑文悦,李志伟,等. 光伏电站在线监测技术现状与进步趋势展望[J]. 电测与仪表,2021,58(9):1-7.
ZHENG Weishuo, ZHENG Wenyue, LI Zhiwei, et al. Status and outlook of online monitoring technologies for photovoltaic power stations[J]. Electrical Measurement & Instrumentation, 2021, 58(9): 1-7.
- [3] 刘岩,李文文,周丽霞,等. 基于高斯混合模型的光伏发电出力中高比例异常数据检测方法研究[J]. 电测与仪表,2021,58(9):14-21.
LIU Yan, LI Wenwen, ZHOU Lixia, et al. Research of high proportion of outliers detection method in photovoltaic power output data based on Gaussian mixture model[J]. Electrical Measurement & Instrumentation, 2021, 58(9): 14-21.
- [4] 王华昕,刘美娜,褚启迪. 计及长线路参数扰动的新能源黑启动工程分析[J]. 高压电器,2023,59(3):99-107.
WANG Huaxin, LIU Meina, CHU Qidi. Analysis of new energy black start-up engineering considering parameter perturbation of long line [J]. High Voltage Apparatus, 2023, 59(3): 99-107.
- [5] 周治宇,陈豪. 盲信号分离技术与算法综述[J]. 计算机科学,2009,36(10):16-20.

- ZHOU Zhiyu, CHEN Hao. Research and survey on algorithms of blind signal separation technology[J]. Computer Science, 2009, 36(10): 16-20.
- [6] WILDEBOER R R, SAMMALI F, VAN SLOUN R J G, et al. Blind source separation for clutter and noise suppression in ultrasound imaging: review for different applications[J]. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 2020, 67(8): 1497-1512.
- [7] HYVÄRINEN A. Fast and robust fixed-point algorithms for Independent component analysis[J]. IEEE Transactions on Neural Networks, 1999, 10(3): 626-634.
- [8] CARDOSO J F. Source separation using higher order moments[J]. Acoustics, Speech, and Signal Processing, 1988. ICASSP-88. 1988 International Conference on, 1989, 4.
- [9] XU Yong, DU Jun, DAI Lirong, et al. An experimental study on speech enhancement based on deep neural networks[J]. IEEE Signal Processing Letters, 2014, 21(1): 65-68.
- [10] 杨帆, 李雅海, 卢文斌, 等. 高压电气设备局部放电过程超高频信号监测方法[J]. 电网与清洁能源, 2022, 38(11): 55-60.
- YANG Fan, LI Yahai, LU Wenbin, et al. Ultra-high frequency signal monitoring method for partial discharge process of high-voltage electrical equipment[J]. Power System and Clean Energy, 2022, 38(11): 55-60.
- [11] 高贺, 杨朋威, 石海鹏, 等. 一起光伏电站电压振荡事故分析和解决措施[J]. 东北电力技术, 2021, 42(2): 39-43.
- GAO He, YANG Pengwei, SHI Haipeng, et al. Analysis and solution of voltage oscillation accident in PV power station[J]. Northeast Electric Power Technology, 2021, 42(2): 39-43.
- [12] 郑婧, 何婷婷, 郭洁, 等. 基于独立成分分析和端点检测的变压器有载分接开关振动信号自适应分离[J]. 电网技术, 2010, 34(11): 208-213.
- ZHENG Jing, HE Tingting, GUO Jie, et al. Adaptive separation of vibration signal of on-load tap changer based on independent component analysis and endpoint detection [J]. Power System Technology, 2010, 34(11): 208-213.
- [13] 杜文龙, 杨洪耕, 马晓阳. 基于快速独立分量分析的谐波/间谐波频谱分离算法[J]. 电力系统自动化, 2020, 44(13): 115-122.
- DU Wenlong, YANG Honggeng, MA Xiaoyang. Harmonic/interharmonic spectrum separation algorithm based on fast Independent component analysis[J]. Automation of Electric Power Systems, 2020, 44(13): 115-122.
- [14] 李康平. 高渗透率分布式光伏下需求响应基线负荷估计方法研究[D]. 北京: 华北电力大学, 2020.
- [15] YAN Jichuan, GE Xinxin, LU Xiaoxing, et al. Joint energy disaggregation of behind-the-meter PV and battery storage: a contextually supervised source separation approach[C]// 2021 IEEE/IAS 57th Industrial and Commercial Power Systems Technical Conference (I&CPS). [S.l.]: IEEE, 2021: 1-9.
- [16] BU FANKUN, DEHGHANPOUR K, YUAN Yuxuan, et al. A data-driven game-theoretic approach for behind-the-meter PV generation disaggregation[J]. IEEE Transactions on Power Systems, 2020, 35(4): 3133-3144.
- [17] SAEEDI R, SADANANDAN S K, SRIVASTAVA A K, et al. An adaptive machine learning framework for behind-the-meter load/PV disaggregation[J]. IEEE Transactions on Industrial Informatics, 2021, 17(10): 7060-7069.
- [18] ECK A, CMR B, MT D, et al. Disaggregating solar generation from feeder-level measurements-science direct[J]. Sustainable Energy, Grids and Networks, 2018(13): 112-121.
- [19] DINESH C, WELIKALA S, LIYANAGE Y, et al. Non-intrusive load monitoring under residential solar power influx[J]. Applied Energy, 2017, 205: 1068-1080.
- [20] WANG Yi, ZHANG Ning, CHEN Qixin, et al. Data-Driven probabilistic net load forecasting with high penetration of Behind-the-Meter PV[J]. IEEE Transactions on Power Systems, 2018, 33(3): 3255-3264.
- [21] ZHANG Xiaochen, GRIJALVA S. A data-driven approach for detection and estimation of residential PV installations[J]. IEEE Transactions on Smart Grid, 2016, 7(5): 2477-2485.
- [22] SHAKER H, ZAREIPOUR H, WOOD D. A data-driven approach for estimating the power generation of invisible solar sites[J]. IEEE Transactions on Smart Grid, 2016, 7(5): 2466-2476.
- [23] LIN Jun, MA Jin, ZHU Jianguo. A privacy-preserving federated learning method for probabilistic community-level behind-the-meter solar generation disaggregation[J]. IEEE Transactions on Smart Grid, 2022, 13(1): 268-279.
- [24] LI Kangping, YAN Jichuan, HU Lin, et al. Two-stage decoupled estimation approach of aggregated baseline load under high penetration of behind-the-meter PV system[J]. IEEE Transactions on Smart Grid, 2021, 12(6): 4876-4885.
- [25] 张曦, 康重庆, 张宁, 等. 太阳能光伏发电的中长期随机特性分析[J]. 电力系统自动化, 2014, 38(6): 6-13.
- ZHANG Xi, KANG Chongqing, ZHANG Ning, et al. Analysis of mid/long term random characteristics of photovoltaic power generation[J]. Automation of Electric Power Systems, 2014, 38(6): 6-13.
- [26] 刘博, 柯德平, 李鹏, 等. 低压配电台区分布式光伏发电功率辨识方法[J]. 电力系统自动化, 2019, 43(19): 111-116.
- LIU Bo, KE Deping, LI Peng, et al. Identification method of distributed photovoltaic power in low-voltage distribution networks[J]. Automation of Electric Power Systems, 2019, 43(19): 111-116.

(下转第148页)

- [22] OUYANG Jinxin, ZHENG Di, XIONG Xiaofu, et al. Short-circuit current of doubly fed induction generator under partial and asymmetrical voltage drop[J]. Renewable Energy, 2016, 88: 1-11.
- [23] 欧阳金鑫, 熊小伏. 计及转子励磁控制的双馈感应发电机短路电流研究[J]. 中国电机工程学报, 2014, 34(34): 6083-6092.
OUYANG Jinxin, XIONG Xiaofu. Research on short-circuit current of doubly-fed induction generators under rotor excitation control[J]. Proceedings of the CSEE, 2014, 34(34): 6083-6092.
- [24] 孔祥平, 张哲, 尹项根, 等. 计及撬棒保护影响的双馈风力发电机组故障电流特性研究[J]. 电工技术学报, 2015, 30(8): 1-10.
KONG Xiangping, ZHANG Zhe, YIN Xianggen, et al. Study of fault current characteristics of DFIG considering impact of crowbar protection[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 1-10.
- [25] 尹俊, 毕天姝, 薛安成, 等. 计及低电压穿越控制的双馈风力发电机组短路电流特性与故障分析方法研究[J]. 电工技术学报, 2015, 30(23): 116-125.
YIN Jun, BI Tianshu, XUE Ancheng, et al. Study on short circuit current and fault analysis method of double fed induction generator with low voltage ride-through control strategy[J]. Transactions of China Electrotechnical Society, 2015, 30(23): 116-125.
- [26] 甘俊文, 邵能灵. 基于机端电压跌落深度的双馈风机自适应短路电流计算方法[J]. 电力科学与技术学报, 2018, 33(3): 3-9.
GAN Junwen, TAI Nengling. Research on adaptive short circuit current calculation of DFIG considering the terminal voltage dip[J]. Electric Power Science and Technology, 2018, 33(3): 3-9.
- [27] MA Jing, KANG Shengyang, THORP J S. Research on transient characteristics of doubly fed wind power generator under symmetrical short-circuit fault considering grid-side converter control[J]. Electric Power Components and Systems, 2016, 11(15): 1-12.
- [28] 陈鹏, 张哲, 尹项根, 等. 计及GSC电流和控制策略的DFIG稳态故障电流计算模型[J]. 电力系统自动化, 2016, 40(16): 8-16.
CHEN Peng, ZHANG Zhe, YIN Xianggen, et al. Steady fault calculation model of doubly-fed induction generator considering grid-side converter current and different control strategies[J]. Automation of Electric Power Systems, 2016, 40(16): 8-16.
- [29] 靳现林, 蔡晓宇, 刘其辉, 等. 一种考虑RSC和GSC的双馈风机短路电流实用计算方法[J]. 电力系统保护与控制, 2019, 47(24): 23-30.
JIN Xianlin, CAI Xiaoyu, LIU Qihui, et al. A practical calculation method for short-circuit current of DFIG considering RSC and GSC[J]. Power System Protection and Control, 2019, 47(24): 23-30.
- [30] 范小红, 孙士云, 孙德娟, 等. 双馈风机三相短路电流特性分析[J]. 电力系统保护与控制, 2019, 47(18): 38-48.
FAN Xiaohong, SUN Shiyun, SUN Dejuan, et al. Analysis of three-phase short-circuit current characteristics of doubly fed induction generator[J]. Power System Protection and Control, 2019, 47(18): 38-48.
- [31] 杨淑英. 双馈型风力发电变流器及其控制[D]. 合肥: 合肥工业大学, 2007.
- [32] ABAD GONZALO, JESUS LOPEZ, RODRIGUEZ M A, 等. 双馈感应电机在风力发电中的建模与控制[M]. 北京: 机械工业出版社, 2014.
- [33] 王增平, 李菁, 郑涛, 等. 考虑变流器限流与GSC电流的双馈风力发电机暂态全电流计算与分析[J]. 电工技术学报, 2018, 33(17): 4123-4135.
WANG Zengping, LI Jing, ZHENG Tao, et al. Calculation and analysis of transient short circuit current of doubly-fed induction generator considering converter current limitation and GSC current[J]. Transactions of China Electrotechnical Society, 2018, 33(17): 4123-4135.

作者简介:

任蔷(1996—), 女, 助理工程师, 主要研究方向为新能源涉网保护与控制策略。E-mail: 179510125@qq.com。

陈洁羽(1986—), 女, 高级工程师, 主要研究方向为新型电力系统继电保护技术。

邓俊(1985—), 男, 高级工程师, 主要研究方向为新型电力系统分析计算。

段建东(1973—), 男, 教授, 主要研究方向为综合能源系统、电力系统继电保护等。

(上接第140页)

作者简介:

徐晓春(1970—), 女, 高级工程师, 从事电力系统自动化工作。

李佑伟(1981—), 男, 高级工程师, 从事电力系统调度自动化工作。

李彦伦(2000—), 男, 硕士研究生, 从事配电网数据挖掘

研究。E-mail: 18952731328@qq.com。

窦晓波(1979—), 男, 教授, 从事分布式电源高渗透率配电网研究。

张岩(1998—), 男, 硕士研究生, 从事配电网光伏感知研究。