

基于最优深度信念网络的高比例分布式光伏发电数据虚拟采集方法研究

张 华,李世龙,龙 呈,高艺文,苏学能,李明俊
(国网四川省电力公司电力科学研究院,四川 成都 610041)

摘要:为了解决配电站的高比例分布式光伏数据难以采集问题,提出了一种基于最优深度信念网络的分布式光伏数据虚拟采集方法。最优深度信念网络包括两部分,分别为基本深度信念网络与自适应萤火虫算法。其中,自适应萤火虫算法被用于估计深度信念网络的输出权重矩阵。首先,所提出的分布式光伏数据虚拟采集方法,可以实现同一光伏电站在仅1座分布式光伏设备具有完备数据采集装置情形下,完成区域范围内所有分布式光伏设备数据的虚拟采集;然后,以区域范围内100座分布式光伏设备对所提出的分布式光伏数据虚拟采集方法进行了验证。

关键词:分布式光伏;深度信念网络;萤火虫算法;虚拟采集

中图分类号:TM 73 **文献标志码:**A **文章编号:**1003-6954(2024)03-0006-07

DOI:10.16527/j.issn.1003-6954.20240302

Research on Virtual Collection Method for High Proportion of Distributed Photovoltaic Power Generation Data Based on Optimal Deep Belief Network

ZHANG Hua, LI Shilong, LONG Cheng, GAO Yiwen, SU Xueneng, LI Mingjun
(State Grid Sichuan Electric Power Research Institute, Chengdu 610041, Sichuan, China)

Abstract:In order to solve the difficulty of collecting high proportion of distributed photovoltaic (PV) data in distribution station, a virtual collection method for distributed PV data based on optimal deep belief network is proposed. The optimal deep belief network consists of two parts, namely basic deep belief network and adaptive firefly algorithm, in which the adaptive firefly algorithm is used to estimate the output weight matrix of deep belief networks. Firstly, the proposed virtual collection method for distributed PV data can realize the virtual data acquisition of all distributed PV equipment in the same PV power station under the condition that only one distributed PV equipment has a complete data acquisition device. And then, the proposed virtual collection method for distributed PV data is verified with 100 distributed PV devices in a region.

Key words:distributed photovoltaic; deep belief network; firefly algorithm; virtual collection

0 引言

由于传统化石能源逐渐消耗,节能减排和可持续发展的需求日益增强,可再生能源发电已成为世界众多国家共同发展的目标,也是能源变革以及电力行业发展的新方向^[1]。其中,光伏发电凭借其清洁性、安全性以及可持续能力强的特点在新能源发电队列占据重要位置。截至2021年年底,中国光伏发电累计并网容量为305.987 GW,分布式光伏电站

累计装机容量为107.508 GW。然而,分布式光伏电站具有布置范围广和排列无序等特点,通过增加传感器数量来获取分布式光伏设备运行数据又存在成本较高的问题,一定程度上制约了分布式光伏的发展^[2-3]。

虚拟采集技术是解决上述问题的可行方案之一^[4]。虚拟采集是通过同一区域内的已知数据来预测出未知数据,本质上是一种“实时+虚拟”的预测技术。在分布式光伏的数据监测中,同区域内分布式光伏设备的气候等外部条件相同,设备运行状

态数据和运行趋势相似,可以建立一个虚拟采集模型。其中,已知条件为同区域内已安装完整采集终端的光伏数据,通过虚拟采集模型可将区域内其余数据不完备的分布式光伏设备的数据补充完整,实现整个区域内分布式光伏发电数据的全面获取,体现出虚拟采集方法的经济性。

目前,虚拟采集技术在分布式光伏方面的相关研究较少。分布式光伏数据的虚拟采集主要涉及数据修复与功率预测等相关技术。在光伏数据修复方面,文献[5]首先选取与数据损坏电站有较高功率相似度的其余电站,考虑了天气情况以及地理位置等影响因素,根据相似日数据建立反向传播神经网络模型;最后采用自适应调节学习速率的方法修复不良数据。在光伏功率预测技术方面,根据预测方法的不同可分为物理法与统计法两种^[6]。物理法是基于天气信息与光伏电站出力数据建立一个光伏发电物理模型,进一步预测发电功率。统计法主要是利用人工智能方法建立输入和输出之间的映射模型,预测发电功率。文献[7]将天气分为阴、晴、雨等 5 种类型,考虑不同天气情况下功率波动不同,基于时空网络组合预测算法预测光伏功率。文献[8]提出一种双维度数据填补框架,能够将缺失数据按一定顺序补充完整,同时改进了 Kohonen 天气聚类的方法,更加精准地预测功率。文献[9]根据相似日理论确定相似日样本集,建立小波神经网络预测模型,在相似日和小波神经网络模型的基础上对光伏功率进行预测。文献[10]利用粒子群算法优化深度信念网络的权值,以近似日的气象和历史输出功率作为样本建立模型并预测功率。

在光伏发电数据虚拟采集方面,文献[11]基于相似日、蝙蝠算法和小波神经网络进行短期光伏功率预测,但小波神经网络拟合能力具有局限性,仍存在模型泛化能力弱、预测精度不佳的问题。而深度信念网络(deep belief network, DBN)具有较好的预测能力与建模能力,在电力系统中应用广泛,能够有效处理大量复杂数据。下面将电流数据作为输入,提出了一种基于最优 DBN(optimized DBN, O-DBN)的高比例分布式光伏发电的虚拟采集方法。为提高高比例分布式光伏数据的拟合精度,采用自适应萤火虫算法(adaptive firefly algorithm, AFA)对深度信念网络的权值进行不断调整优化,通过最优深度信念网络模型,实现对同一区域内分布式光伏设备出力数据进行虚拟采集的目的。

1 高比例分布式光伏发电数据的虚拟采集流程

分布式光伏易受光照、地域等因素影响,波动性大,不确定性高,难以较为准确地获取分布式光伏的各类数据,给运维监测等方面带来了挑战;同时,分布式光伏电站的数据监测类型繁多,数据容量庞大。在分布式光伏电站的数据监测过程中,通过增加传感器数量来感知有效数据信息的方法成本较高,在一定程度上制约了分布式光伏行业的发展。

这里提出一种基于深度信念网络与萤火虫算法相结合的高比例分布式光伏设备数据虚拟采集方法,利用自适应萤火虫算法对深度信念网络的输出权值进行估计,获得良好的预测模型;通过采集同一区域内 1 座分布式光伏设备的全部数据,对数据进行预处理后输入模型中,预测同一区域内剩余的高比例分布式光伏的功率。如图 1 所示,所提的高比例分布式光伏设备虚拟采集流程为:首先,将第 1 个光伏设备过去 M 天的 N 个电流数据采样点作为模型的训练输入数据,将过去 M 天的 N 个功率数据作为训练输出数据;然后,通过训练获得训练良好的预测模型;最后,利用其他光伏设备当前的 N 个电流数据采样点作为预测模型的输入,预测当前的 N 个功率数据。

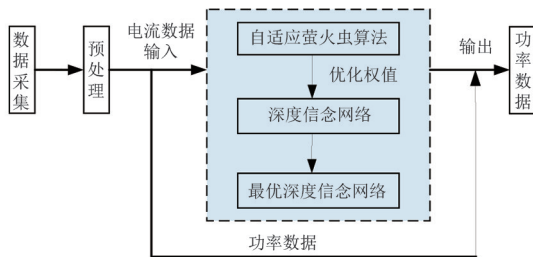


图 1 所提的高比例分布式光伏设备虚拟采集流程

2 相关理论

2.1 深度信念网络

深度信念网络是一种高效的深度学习算法,它由若干受限玻尔兹曼机(restricted Boltzmann machine, RBM)堆叠在一起组成^[12],能够提取数据的深层次特征。经典深度信念网络的结构模型如图 2 所示,它由 3 层 RBM 堆叠组成,单个 RBM 由一个可见层和一个隐藏层构成,层间神经元全连接,层

内神经元无连接。

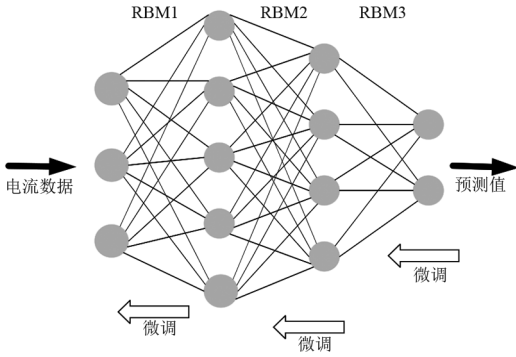


图2 深度信念网络结构模型

深度信念网络的训练过程可以分为两个阶段，即预训练和反向微调。预训练通过采用无监督贪婪学习算法对每个RBM进行逐层训练，因而数据信息可由此传递来初始化网络参数，确定初始的连接权重和神经元偏置^[13]。反向微调是通过对预训练的权重进行微调，使模型收敛到最优解，从而确定整个深度信念网络的结构。其中，深度信念网络的预训练过程如下：

设 n 和 m 分别为输入层 v 和隐藏层 h 的节点数； v_i 代表可见层的第 i 个节点状态； h_j 代表隐藏层的第 j 个节点状态。那么，RBM 的一个给定状态 (v, h) 的能量函数表达式为

$$E(v, h; \theta) = - \sum_{i=1}^n \sum_{j=1}^m W_{ij} v_i h_j - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n a_i v_i \quad (1)$$

式中： $\theta = \{W_{ij}, a_i, b_j\}$ 为 RBM 的参数； W_{ij} 为节点 v_i 和 h_j 之间的链接权重； a_i 和 b_j 为它们的偏差^[14]。根据能量函数公式，隐藏层和可见层的联合概率分布 $P(v, h; \theta)$ 可以定义为

$$P(v, h; \theta) = \frac{1}{Z(\theta)} e^{-E(v, h; \theta)} \quad (2)$$

式中， Z 为归一化系数，其表达式为

$$Z(\theta) = \sum_{v, h} e^{-E(v, h; \theta)} \quad (3)$$

可见层和隐藏层的状态更新公式为：

$$P(h_j = 1 | v) = \frac{1}{1 + e^{-\sum_i W_{ij} v_i - a_j}} \quad (4)$$

$$P(v_i = 1 | h) = \frac{1}{1 + e^{-\sum_j W_{ij} h_j - b_i}} \quad (5)$$

在预训练期间，可见层 v_1 和隐藏层 h_1 被用来形成待训练的 RBM1。然后， h_1 被视为可见层 v_2 ，而隐藏层 h_2 和 v_2 组成 RBM2。RBM2 的隐藏层被视

为 RBM3 的可见层，以此类推，直到所有 RBM 训练结束。

在深度信念网络预训练过程中，对比发散算法被用于逐层训练。对比发散的过程可以分为 4 个步骤：1) 将训练数据作为可见神经元的状态变量；2) 根据式(4)计算隐藏层神经元的状态变量；3) 用式(5)得到可见层神经元的二进制概率，这样就可以计算出可见层的重构结果；4) 梯度下降算法被用来优化目标函数，以获得参数 ω_{ij} 、 a_i 和 b_j 的更新公式。

$$\Delta \omega_{ij} = \tau \{ (v_i h_j)_{P(h|v)} - (v_i h_j)_{\text{recon}} \} \quad (6)$$

$$\Delta a_i = \tau \{ (v_i)_{P(h|v)} - (v_i)_{\text{recon}} \} \quad (7)$$

$$\Delta b_j = \tau \{ (h_j)_{P(h|v)} - (h_j)_{\text{recon}} \} \quad (8)$$

式中， τ 为学习率； $(*)_{P(h|v)}$ 为样本数据分布 $P(h|v)$ 下的偏导数的期望值； $(*)_{\text{recon}}$ 为部分导数的期望值在重建模型分布下的偏导值。

2.2 自适应萤火虫算法

萤火虫算法是一种随机搜索算法，预测模型的求解及优化过程就是萤火虫之间移动位置、彼此吸引及优胜劣汰的过程。然而，萤火虫算法在运行时会出现优势不足的情况，即标准萤火虫算法在更新迭代萤火虫个体空间向量时，没有考虑到搜索的步长和精度^[15]。因此，利用二阶振荡替代惯性收敛，提出一种自适应萤火虫优化算法，提高萤火虫个体的搜索精度。

1) 自适应萤火虫算法

在萤火虫算法中，萤火虫依据式(9)更新萤火虫个体的空间矢量位置，即

$$x_i(t+1) = x_i(t) + \beta [x_j(t) - x_i(t)] + \alpha (r - \frac{1}{2}) \quad (9)$$

式中： $x_i(t+1)$ 为第 $t+1$ 次运动后的萤火虫 i 的位置； α 为预设的随机化参数， $\alpha \in [0, 1]$ ； r 为 0~1 之间的随机数； β 为吸引力系数，它的计算公式为

$$\beta = \beta_0 e^{-\gamma r_{ij}^2} \quad (10)$$

式中： β_0 为预设的最大吸引力系数； γ 为光吸收系数； r_{ij}^2 为第 i 只萤火虫与第 j 只萤火虫之间的欧几里得距离。

如果忽略式(9)的随机参数部分，式(9)可以改写为

$$x_i(t+1) - x_i(t) = \beta [x_j(t) - x_i(t)] \quad (11)$$

式(11)可以看作为 $x_i(t)$ 和 $x_j(t)$ 的差分公式。

因此，其微分公式为

$$\frac{dx_i(t)}{dt} = -\beta x_i(t) + \beta x_j(t) \quad (12)$$

因此,它可以用拉普拉斯变换来重写为 $sx_i(s) + \beta x_i(s) = \beta x_j(s)$,同时也可以这样解释为

$$\frac{x_i(s)}{x_j(s)} = \frac{\beta}{s + \beta} \quad (13)$$

因此,式(13)可以被看作为单阶惯性系统。随着迭代次数的增加, $x_i(s)$ 将收敛于到 $x_j(s)$, 表明传统的萤火虫算法在某种程度上有收敛性。然而,单阶惯性系统无法平衡搜索步骤和搜索精度,这可能导致萤火虫进入局部最优位置。因此,将惯性收敛的过程改进为二阶振荡收敛,提出的自适应萤火虫算法,即

$$x_i(t+1) = x_i(t) + \beta[x_j(t) - (1+\varphi)x_i(t) - \varphi x_i(t-1)] + \varepsilon \quad (14)$$

式中: $\varepsilon = \alpha(r-0.5)$; $x_i(t-1)$ 为第 i 个萤火虫在 $t-1$ 次迭代时的位置; φ 为平衡系数。在早期迭代阶段, φ 可以选择在 $(0, \frac{2\sqrt{\beta}-1}{\beta})$ 中进行大的搜索步骤,在

后面的迭代阶段可以设置为 $\left[\frac{2\sqrt{\beta}-1}{\beta}, \frac{3(2\sqrt{\beta}-1)}{2\beta} \right]$ 。

2) 收敛性分析

类似地,式(10)可以被改写为

$$x_i(t+1) - x_i(t) - [x_i(t) - x_i(t-1)] = \beta[x_j(t) - (1+\varphi)x_i(t) - \varphi x_i(t-1)] - [x_i(t) - x_i(t-1)] \quad (15)$$

所以,

$$\begin{aligned} x_i(t+1) - 2x_i(t) + x_i(t-1) &= -\beta(\varphi+1)x_i(t) - \\ x_i(t) + \varphi\beta x_i(t-1) + x_i(t-1) + \varphi x_j(t) &= \\ -\beta\varphi[x_i(t) - x_i(t-1)] - [x_i(t) - & \\ x_i(t-1)] - \beta x_i(t) + \beta x_j(t) & \end{aligned} \quad (16)$$

因此,其微分公式为

$$\frac{d^2 x_i(t)}{dt^2} = -(\beta\varphi+1) \frac{dx_i(t)}{dt} - \beta x_i(t) + \beta x_j(t) \quad (17)$$

经过拉普拉斯变换为

$$s^2 x_i(s) + (\beta\varphi+1)sx_i(s) + \beta x_i(s) = \beta x_j(s) \quad (18)$$

即为

$$\frac{x_i(t)}{x_j(t)} = \frac{\beta}{s^2 + (\beta\varphi+1)s + \beta} \quad (19)$$

式(19)可被视为一个二阶的振荡系统。

所以,当 $s^2 + (\beta\varphi+1)s + \beta = 0$ 时,两个根极点为

$$A_{1,2} = \frac{-(\beta\varphi+1) \pm \sqrt{(\beta\varphi+1)^2 - 4\beta}}{2} \quad (20)$$

对于大的搜索步长和快的收敛速度,系统可能处于欠阻尼状态,并且能够收敛: $(\beta\varphi+1)^2 - 4\beta < 0$ 和 $-(\beta\varphi+1) < 0$, 即为可以在 $(0, \frac{2\sqrt{\beta}-1}{\beta})$ 的前一段时间的迭代中选择平衡系数。在后期,该系统应处于超阻尼状态,以实现小的搜索步长和高精确度: $(\beta\varphi+1)^2 - 4\beta > 0$ 和 $-(\beta\varphi+1) < 0$ 。经过不断的测试,它可以被设定为 $\left[\frac{2\sqrt{\beta}-1}{\beta}, \frac{3(2\sqrt{\beta}-1)}{2\beta} \right]$ 。

2.3 基于最优 DBN 的高比例分布式光伏数据学习模型

自适应萤火虫算法具有较好的收敛性和全局搜索能力,并且具有模型简单、参数少、通用性强等特点。利用自适应萤火虫算法估计深度信念网络中的输出权值,提高深度信念网络的拟合性能,解决高比例分布式光伏数据学习与预测的问题。所建立的基于 O-DBN 的分布式光伏发电数据虚拟采集模型如图 3 所示。

首先,获取完整光伏设备在过去 M 天采集得到的 N 个电流数据和 N 个功率数据,构成训练阶段的输入数据矩阵 $X \in \mathbf{R}^{M \times N}$ 和输出数据矩阵 $Y \in \mathbf{R}^{M \times N}$ 。

其次,初始化深度信念网络的相关参数设置,包括隐含层数目 N ; 每个隐含层神经元个数 $K_l, l=1, 2, 3, \dots, N$; 学习率 τ 。初始化 RBM 的相关参数,包括输入权重矩阵 $\mathbf{W}^{K_l \times K_{l-1}}$ 、可视化层的偏置 $a^{1 \times K_{l-1}}$ 、隐含层的偏置 $b^{1 \times K_l}$ 和最大训练迭代次数 N_{RBM} 。

然后,通过以下算法流程对深度信念网络进行预先训练,即

1) 通过式(4)计算第 l 个隐含层中第 j 个神经元的条件分布 $P(h_j = 1 | v)$, 进一步获得 Gibbs 采样点 $h_j, j=1, 2, 3, \dots, K_l$ 。

2) 通过式(4)计算第 $l-1$ 个隐含层中第 i 个神经元的重构条件分布 $P([v_i]_{\text{recon}} = 1 | h)$, 进一步获得 Gibbs 采样点 $v_{i_{\text{re}}}, i=1, 2, 3, \dots, K_{l-1}$ 。当 $l-1=0$ 时,第 $l-1$ 个隐含层表示输入层。

3) 通过式(4)计算第 l 个隐含层中第 j 个神经元的重构 Gibbs 采样点 $[h_j]_{\text{recon}}, j=1, 2, 3, \dots, K_l$ 。

4) 通过式(6)、式(7)和式(8)更新第 l 个隐含

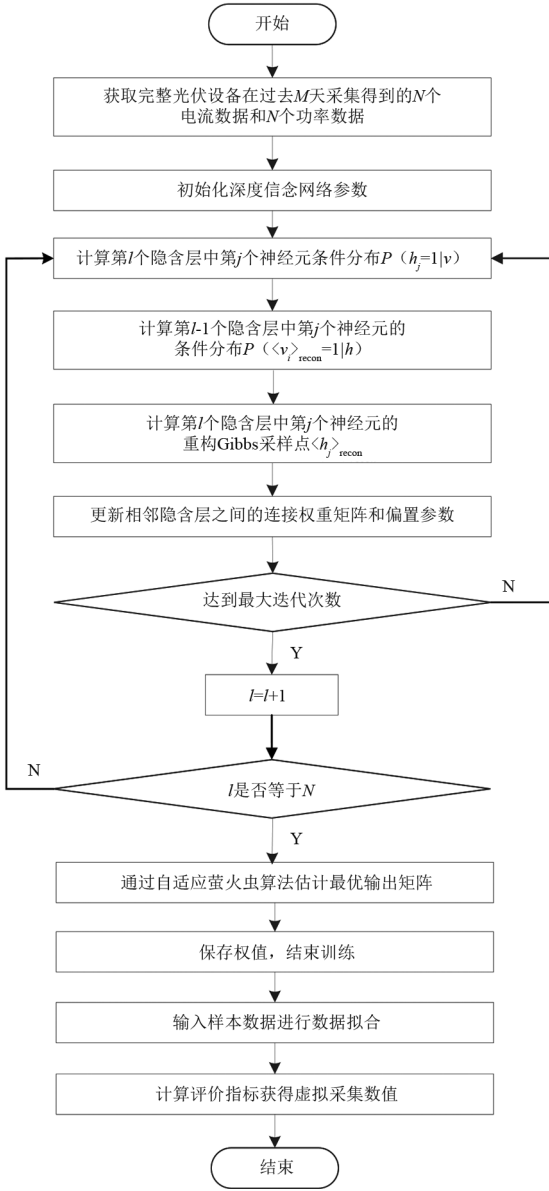


图 3 基于最优 DBN 的分布式光伏发电数据虚拟采集模型

层与第 $l-1$ 个隐含层之间的连接权重矩阵和偏置参数。

5) 判断是否达到最大迭代次数。如果否,那么迭代次数加 1, 返回到步骤 1。如果是,那么 $l+1$, 返回到步骤 1。

6) 判断 l 是否等于 N ; 如果否, 那么返回到步骤 1。

接着, 通过自适应萤火虫算法估计 DBN 的输出矩阵 \mathbf{W}_{out} , 如图 4 所示。具体步骤为:

1) 初始化自适应萤火虫算法的相关参数, 包括萤火虫个体数目 Q 、预设的最大吸引力系数 β_0 、光吸收系数 γ 和最大迭代次数 n_{ite} 。

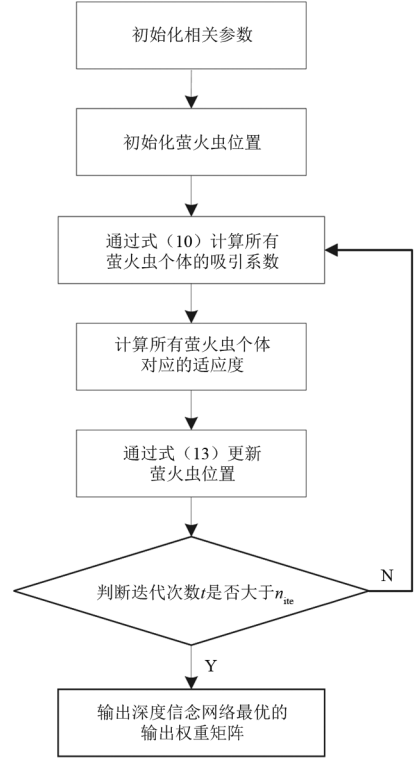


图 4 自适应萤火虫算法流程

2) 初始化所有萤火虫个体的空间矢量, 第 i 只萤火虫个体在 t 次迭代的空间矢量为 $x_i(t) \in \mathbf{R}^{K \times N}$, $i=1, 2, 3, \dots, Q$ 。

3) 通过式 (10) 计算所有萤火虫个体的吸引力系数。

4) 计算所有萤火虫个体对应的适应度。这里第 i 只萤火虫个体在 t 次迭代的适应度定义为

$$f_i(t) = \frac{1}{MN} \sqrt{\sum_{p=1}^M \sum_{q=1}^N (Y_{pq} - \hat{Y}_{pq})^2} \quad (21)$$

式中, Y_{pq} 和 \hat{Y}_{pq} 分别为训练阶段真实输出矩阵 \mathbf{Y} 和拟合输出矩阵 $\hat{\mathbf{Y}}$ 的第 p 行第 q 列的元素值。

通过式 (14) 更新第 i 只萤火虫个体在 t 次迭代的空间矢量。

5) 判断当前迭代次数 t 是否大于 n_{ite} 。如果否, 那么迭代次数加 1, 返回步骤 3。

6) 输出深度信念网络最优的输出权重矩阵。

最后, 保存通过自适应萤火虫算法估计得到的输出矩阵权值, 将样本数据输入进行数据拟合, 得到虚拟采样数据。

通过 AFA 估计 DBN 的输出权重, 提高 DBN 拟合分布式光伏电流与功率数据的拟合能力, 进一步利用训练良好的 DBN 预测其他分布式光伏设备的输出功率。所提出的数据虚拟采集方法通过实时采

集与离线训练的方式,解决其他分布式光伏设备发电数据的虚拟采集问题。

3 算例分析

3.1 基础数据

为验证所提虚拟采集方法的有效性与可行性,利用仿真得到的100座分布式光伏设备的数据进行验证。其中,1号设备为具有完整数据采集系统的标杆设备,2~100号设备为待进行虚拟采集数据补充的设备。为实现数据的统一性,每日的功率实测值经过规整后为20 min采集一次,时间区间为05:00~20:00。同时,选取过去1000天的历史数据作为训练集,利用1号分布式光伏设备的部分数据与2~100号设备的电流数据,实现区域范围内分布式光伏设备的数据虚拟采集。

分别在两种不同天气情况下进行验证实验,即平稳天气与突变天气,利用同一区域的电流数据作为最优DBN的输入训练样本,将数据归一化后分别对稳定天气与突变天气进行模型训练。最优DBN相关参数设置为:DBN采用4层结构,神经元数据分别设置为45、50、50和45,学习率设置为0.01,最高迭代次数设为100次。萤火虫算法相关参数设置为:萤火虫的个体数量为50,最大迭代次数100次,最大吸引力系数为1,光吸收系数为0.5。在100座分布式光伏设备中选取10号、20号、30号、40号、50号、60号光伏设备作为参考。

本章研究内容共分为两部分:1)利用1号分布式光伏设备的部分数据与2~100号设备的电流数据,完成区域范围内所有分布式光伏设备数据的虚拟采集,并以部分光伏设备采集结果作为参考;2)将所提方法与多种虚拟采集方法进行对比。

3.2 部分虚拟采集结果

在平稳天气及突变天气下的虚拟采集结果分别如图5与图6所示。可以看出,虚拟采集值和实际值整体趋势一致,预测误差较小。为了评估预测模型的性能,以均方根误差 E_{RMSE} 与平均绝对误差 E_{MAE} 评价虚拟采集结果。不同天气条件下所提方法的误差指标结果如表1所示。

3.3 不同方法对比

为进一步说明所提方法的高效性,将所提方法与小波神经网络、BP神经网络、蝙蝠小波神经网络

(bat algorithm and wavelet neural network, BA-WNN)进行比较,比较结果如图7所示。

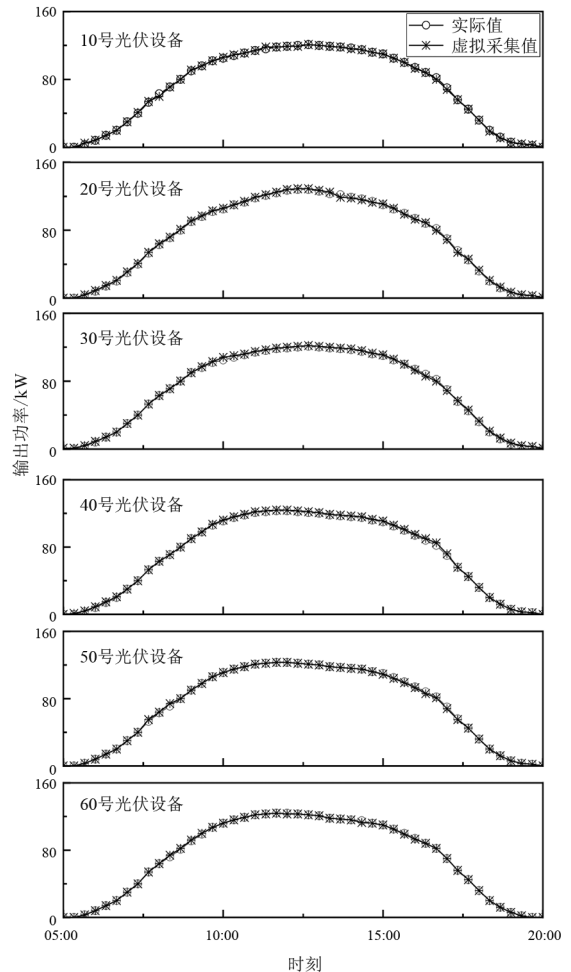


图5 平稳天气各设备虚拟采集数据

表1 不同天气条件下所提方法的误差指标

光伏设备编号	平稳天气		突变天气	
	E_{RMSE}/kW	E_{MAE}/kW	E_{RMSE}/kW	E_{MAE}/kW
10	0.153 8	0.123 6	0.138 9	0.108 5
20	0.132 5	0.115 3	0.143 2	0.115 6
30	0.179 8	0.142 7	0.189 1	0.143 9
40	0.156 7	0.133 6	0.165 4	0.120 4
50	0.237 5	0.204 8	0.132 5	0.096 3
60	0.216 9	0.173 4	0.119 4	0.078 4

如图7所示,小波神经网络虚拟采集的数值与真实值相差较大,最大误差达到67.4%,BP神经网络和BA-WNN方法虽优于小波神经网络,但不及所提方法高效。所提方法在平稳天气和突变天气中,都能较合理地预测出分布式光伏设备的输出功率,与真实值相较最大误差为2.9%。不同天气条件下各方法的误差指标如表2所示。

由表2可知,由小波神经网络所得出的数据误




图 6 突变天气各设备虚拟采集数据

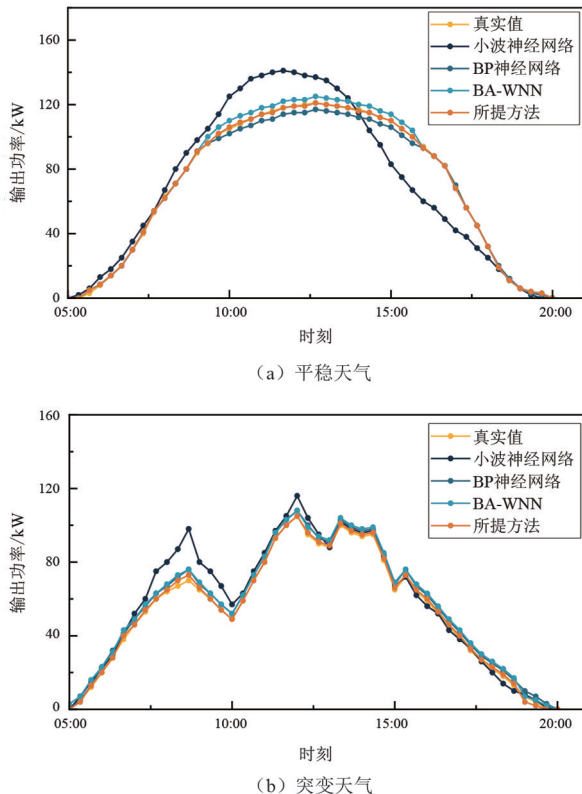


图 7 不同天气条件下各方法的虚拟采集结果对比

表 2 不同天气条件下各方法的误差指标

方法	平稳天气		突变天气	
	E_{RMSE}/kW	E_{MAE}/kW	E_{RMSE}/kW	E_{MAE}/kW
小波神经网络	2.275 8	1.648 2	2.461 1	1.879 5
BA-WNN	0.734 7	0.618 2	0.563 7	0.342 3
BP 神经网络	0.312 6	0.259 3	0.284 6	0.198 3
所提方法	0.153 8	0.123 6	0.138 9	0.108 5

差较大,拟合能力不足以完善所需预测的数据。相较于小波神经网络、BA-WNN 和 BP 神经网络,所提方法在平稳天气下的均方误差指标分别提升了 93.2%、79.1%和 50.1%,有效地将采集数据与实际值误差控制在 0.153 8 kW 以内且误差最小;在突变天气下的均方误差指标分别提升了 94.4%、75.4%和 51.2%,能够更好地反映出高比例分布式光伏输出功率的情况,自适应萤火虫算法对深度信念网络的优化在一定程度上降低了随机权重矩阵对学习模型的影响,降低了模型的预测误差。仿真结果验证了所提方法的可行性、有效性和准确性。

4 结 论

上面提出了一种基于最优深度信念网络的高比例分布式光伏发电数据虚拟采集方法,并通过算例分析验证了该方法的有效性。通过分析,得出结论:1)自适应萤火虫算法估计深度信念网络的输出权重权值,提高了深度信念网络对虚拟采集数据的拟合精度,为分布式光伏虚拟采集的研究提供了支撑;2)与小波神经网络、BA-WNN 和 BP 神经网络对比,所提方法能够极好地将采集数据与实际值误差控制在 0.153 8 kW 以内,误差相对较小。因此,所提方法在不同的天气条件下能够更加准确地预测高比例分布式光伏输出功率,具有更好的预测能力。

参考文献

- [1] 黎静华,骆怡辰,杨舒惠,等.可再生能源电力不确定性预测方法综述[J].高电压技术,2021,47(4):1144-1157.
- [2] 赵洪山,孙承妍,温开云,等.无气象信息条件下基于AGCRN的分布式光伏出力超短期预测方法[J].高电压技术,2024,50(1):65-73.

(下转第 30 页)

- 应用成效分析[J]. 电力系统自动化, 2012, 36(18): 27-32.
- [2] 沈郑毅, 刘天琪, 洪行旅, 等. 中心城市大型配电自动化设计方案与应用[J]. 电力系统自动化, 2012, 36(18): 49-53.
- [3] 彭晖, 任远, 宋鑫, 等. 基于双核架构的分布式地县配一体化技术支持系统设计[J]. 电力系统自动化, 2013, 37(12): 75-80.
- [4] 寇凌峰, 梁英, 王金丽, 等. 计及负荷增长风险的配电变压器选型方法[J]. 电网技术, 2015, 39(5): 1384-1389.
- [5] 杨楠, 李宏圣, 袁景颜, 等. 计及不确定性和全寿命周期成本的配电变压器规划方法[J]. 电力系统自动化, 2017, 41(21): 94-104.
- [6] 欧阳森, 陈欣晖. 考虑基态-差异化特征的台区无功优化配置策略[J]. 电网技术, 2015, 39(12): 3513-3519.
- [7] 王鹏, 林佳颖, 郭岫, 等. 配用电数据分析及应用[J]. 电网技术, 2017, 41(10): 3333-3340.
- [8] 欧阳森, 杨家豪, 耿红杰, 等. 面向台区管理的台区状态综合评价方法及其应用[J]. 电力系统自动化, 2015, 39(11): 187-192.
- [9] 汤毅, 程乐峰, 李正佳, 等. 基于智能台区的配电网经济运行及优化高级分析系统设计[J]. 电力系统保护与控制, 2016, 44(15): 150-158.
- [10] 耿俊成, 马文栋, 郭志民, 等. 基于智能电表大数据分析的台区变压器三相不平衡治理[J]. 智慧电力, 2018, 46(9): 103-108.
- [11] 段祥骏, 王金丽, 冯德志, 等. 配电台区建设与改造智能决策系统设计和实现[J]. 电网技术, 2017, 41(8): 2709-2715.
- [12] 朱文俊, 王毅, 罗敏, 等. 面向海量用户用电特性感知的分布式聚类算法[J]. 电力系统自动化, 2016, 40(12): 21-27.
- [13] 武东升. 家庭能量管理系统用电与电能调度优化策略研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
- [14] 张新昌, 周逢权. 智能电网引领智能家居及能源消费革新[J]. 电力系统保护与控制, 2014, 42(5): 59-67.
- [15] 高慧, 黄春艳, 周鑫, 等. 基于紧迫度的城中村台区改造优先级评估方法[J]. 电力科学与技术学报, 2019, 34(4): 158-165.
- [16] 秦博雅, 刘东. 电网信息物理系统分析与控制的研究进展与展望[J]. 中国电机工程学报, 2020, 40(18): 5816-5827.

作者简介:

刘国伟(1978), 男, 高级工程师, 从事配电网管理和智能配电网研究工作。

(收稿日期: 2023-08-09)

(上接第 12 页)

- [3] 苗长越, 王维庆, 王海云, 等. 光伏接入对系统小干扰稳定的影响研究[J]. 高压电器, 2019, 55(7): 211-215.
- [4] 张凌浩, 张明, 嵇文路, 等. 基于灰色关联理论和 BP 神经网络的分布式光伏电站运维数据虚拟采集方法[J]. 电力建设, 2021, 42(1): 125-131.
- [5] 郭辉, 杨国清, 姚李孝, 等. 基于综合相似日和功率相关性的光伏电站预测功率修正[J]. 电网与清洁能源, 2018, 34(9): 52-58.
- [6] ALMONACID F, PEREZ-HIGUERAS P J, PERNANDEZ E F, et al. A methodology based on dynamic artificial neural network for short-term forecasting of the power output of a PV generator[J]. Energy Conversion and Management, 2014, 85(9): 389-398.
- [7] 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.
- [8] 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.
- [9] 祝喧懿, 姚李孝. 基于相似日和小波神经网络的光伏短期功率预测[J]. 电网与清洁能源, 2019, 35(3): 75-78.
- [10] 李正明, 梁彩霞, 王满商. 基于 PSO-DBN 神经网络的光伏短期发电出力预测[J]. 电力系统保护与控制, 2020, 48(8): 149-154.
- [11] 葛磊蛟, 秦羽飞, 刘嘉恒, 等. 基于相似日与 BA-WNN 的分布式光伏数据虚拟采集方法[J]. 电力自动化设备, 2021, 41(6): 8-16.
- [12] KUREMOTO T, KIMURA S, KOBAYASHI K, et al. Time series forecasting using a deep belief network with restricted Boltzmann machines [J]. Neurocomputing, 2014, 137(15): 47-56.
- [13] NAIR V, HINTON G E. Rectified linear units Improve restricted Boltzmann machines [C] // Proceedings of the 27th International Conference on International Conference on Machine Learning (ICML-10), June 21-24, 2010. Haifa, Israel.
- [14] AMINI M H, MOGHADDAM M P, KARABASOGLU O. Simultaneous allocation of electric vehicles' parking lots and distributed renewable resources in smart power distribution network[J]. Sustainable Cities and Society, 2017, 28: 332-342.
- [15] 阮仁俊, 陈焯, 刘天琪. 基于混沌理论和排序选择的蚁群无功优化算法[J]. 电网技术, 2009, 33(11): 49-54.

作者简介:

张 华(1985), 男, 硕士, 高级工程师, 研究方向为配电网物联网、电力系统分析等;

李世龙(1989), 男, 博士, 高级工程师, 研究方向为数字化配电网与配电网运行控制;

龙 呈(1987), 男, 博士, 高级工程师, 研究方向为配电网运行及自动化。

(收稿日期: 2023-06-09)