

DOI: 10.19783/j.cnki.pspc.190723

基于 PSO-DBN 神经网络的光伏短期发电出力预测

李正明¹, 梁彩霞¹, 王满商²

(1. 江苏大学电气信息工程学院, 江苏 镇江 212013; 2. 国网江苏省电力有限公司镇江供电分公司, 江苏 镇江 212013)

摘要: 考虑到光伏输出功率的随机性和波动性, 提出一种基于粒子群算法(Particle Swarm Optimization, PSO)优化深度信念网络(Deep Belief Network, DBN)的光伏短期发电出力预测方法。首先利用改进粒子群算法确定 DBN 神经网络最优的初始权值, 建立初始 DBN 网络。其次, 确定预测日后, 利用灰色关联度法选出与预测日气象特征相似度高的日期。将这些日期的气象数据和历史发电数据作为训练集对初始 DBN 网络进行训练, 建立预测模型。最后仿真结果表明, 所用模型相比于传统的 DBN 神经网络具有更高的预测精度。

关键词: 短期功率预测; 相似日; 深度置信网络; 粒子群优化算法

Short-term power generation output prediction based on a PSO-DBN neural network

LI Zhengming¹, LIANG Caixia¹, WANG Manshang²

(1. School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China; 2. Zhenjiang Power Supply Branch, State Grid Jiangsu Electric Power Company, Zhenjiang 212013, China)

Abstract: Considering the randomness and volatility of photovoltaic output power, a short-term power generation output prediction method is proposed based on optimizing a Deep Belief Network (DBN) with Particle Swarm Optimization (PSO). First, the PSO algorithm is used to determine the optimal initial weight of the DBN neural network, and the initial DBN network is established. Second, after the prediction date is determined, the grey correlation degree method is used to select the date with high similarity to the predicted daily meteorological features. Meteorological data and historical power generation data are used as training sets to train the initial DBN network and establish a prediction model. Finally, the simulation results show that the model used in this paper has higher prediction accuracy than the traditional DBN neural network.

This work is supported by National Natural Science Foundation of China (No. 51477070).

Key words: short-term power prediction; similar day; deep confidence network; particle swarm optimization algorithm

0 引言

近年来, 太阳能作为一种清洁的可再生能源已成为全球能源转型的重要领域, 全球光伏装机总量逐年提高^[1-2]。光伏并网的稳定性和高效性与国民经济利益关系密切。光伏发电出力受光照、温度等外界环境因素影响较大, 具有较强的间歇性和随机性, 若大规模地直接进行光伏并网会给电力系统带来巨大的冲击^[3-5]。因而光伏短期发电出力的预测对于电网调度和规划、提高系统的可靠性以及光伏发电站运营的效率和经济性尤为重要^[6]。

目前, 对于光伏发电短期功率预测的方法主要有传统预测法和人工智能算法。其中, 传统预测法主要有时间序列法、回归分析法和趋势外推法等, 虽然其模型简单, 但对于光伏发电出力此类非线性系统的预测精确度有限。随着人工智能的研究发展, 智能算法突破了传统算法的局限性, 已逐步替代了传统的预测方法, 在短期光伏发电出力中得到广泛应用, 如人工神经网络^[7]、小波分析法^[8]和支持向量机^[9]等。深度信念网络是由 Hinton 于 2006 年提出的一种高效的神经网络学习算法^[10], 具有较强的数据分析和特征提取的能力。近年来, DBN 被广泛应用于各种非线性系统的预测中, 例如图像语音识别、交通流预测、汇率预测等^[11-12]。

传统人工神经网络一般存在易陷入局部最优

基金项目: 国家自然科学基金项目资助(51477070); 江苏高校优势学科建设工程资助项目 PAPD(20116)

解、收敛速度慢和受初值选择影响较大等缺陷^[13]。为进一步提高神经网络模型的预测精度，许多学者提出了不同的对神经网络改进的方法。文献[14]提出了利用列文伯格-马夸尔特(LM)优化深度信念网络预训练之后得到的网络参数，以此加快网络的收敛速度。文献[15]建立了改进的神经网络的短期光伏发电功率预测模型，利用遗传算法逐步迭代选出BP神经网络的最优初始权值，提高了BP神经网络的收敛速度并改善了易陷入局部最优解的缺点。文献[16]提出了一种聚类分析和神经网络组合的预测模型，并进行负荷数据预测，结果表明该模型的预测精度相比之前有大幅度提高。

为精确预测光伏短期发电出力情况，本文提出了一种改进的DBN网络模型。由于DBN网络的神经元初始连接权重是通过随机赋值得到，这种做法可能会使得网络在求解过程中陷入局部极值^[17]。针对以上问题，本文提出利用粒子群优化算法迭代求解DBN网络的初始权值，建立PSO-DBN模型。首先，利用粒子群优化算法确定DBN神经网络最优的初始权值；之后，在确定预测日后，选取若干与预测日相似度高的日期，将这些日期的气象数据和历史输出功率作为训练样本对初始DBN网络进行训练，建立预测模型。

1 选取相似日

光伏发电出力受到众多因素的影响，例如光伏板的地理位置和安装角度、阵列的转换效率、天气类型、太阳辐射强度和大气压强等。对于某一确定的光伏电站来说，历史发电情况数据中已包含了例如光伏阵列的转换效率、光伏板的安装角度等系统因素。因而只需考虑外界环境因素的变化对光伏输出的影响。

太阳辐照强度与天气类型紧密相关，不同天气类型下光伏系统出力情况差异很大^[18]。一般光伏预测模型都会将天气类型作为模型的输入变量，常见的天气类型如晴、多云、阴、小雨、大雨等。这种模糊的类型描述无法直接作为预测模型的输入变量。根据日益完善的光伏监控数据系统，对大量光伏发电系统出力情况依照天气类型进行统计分析后，按照不同的天气类型对光伏出力情况的影响程度，将其映射为0~1之间的具体数值作为模型的一个输入量^[19]。

本文选取天气类型、日平均辐照度、气温和空气湿度作为影响光伏系统出力的因素。这些信息可以从当地气象部门获得。通过这些气象因素对历史

日进行搜索，选出的训练样本更具有针对性，在一定程度上可以提高预测精度。各影响因素构成的气象特征向量为

$$\mathbf{D}=[w, \bar{E}, T^h, T^l, H^h, H^l] \quad (1)$$

式中： w 代表量化后的天气类型； \bar{E} 代表日平均辐照度； T^h 和 T^l 分别指每日温度的最大值和最小值； H^h 和 H^l 分别指每日湿度的最大和最小值。

确定气象特征向量后，利用“极差法”对向量中各分量进行归一化，公式为

$$x_j(i) = \frac{d_j(i) - m(i)}{M(i) - m(i)} \quad (2)$$

式中： $d_j(i)$ 是第 j 个向量的第 i 个分量； $M(i)$ 、 $m(i)$ 分别指所有特征向量中第 i 个分量的最大值和最小值， $i \in [1, 6]$ 。归一化后预测日和第 j 日的特征向量分别为

$$\mathbf{x}_0 = [x_0(1), x_0(2), x_0(3), x_0(4), x_0(5), x_0(6)]^T \quad (3)$$

$$\mathbf{x}_j = [x_j(1), x_j(2), x_j(3), x_j(4), x_j(5), x_j(6)]^T \quad (4)$$

\mathbf{x}_0 和 \mathbf{x}_j 在第 k 个分量的关联系数为

$$\xi_j(k) = \frac{\min_j \min_k |\Delta_j(k)| + \rho \max_j \max_k |\Delta_j(k)|}{|\Delta_j(k)| + \rho \max_j \max_k |\Delta_j(k)|} \quad (5)$$

式中： $\Delta_j(k) = x_0(k) - x_j(k)$ ； ρ 是分辨系数，此处取 $\rho = 0.5$ 。综合各分量的关联系数，将 \mathbf{x}_0 和 \mathbf{x}_j 的相似度定义为

$$F_j = \prod_{k=1}^6 \xi_j(k) \quad (6)$$

从最近的历史日开始算起，逐一计算与待预测日的相似度，选出达到要求的历史日的发电数据作为模型的训练样本。利用连乘法计算相似度可有效解决各分量权重的问题。

2 DBN神经网络

DBN网络由若干受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)堆叠而成^[20]，是一种深度高效学习算法，能够提取数据的深层次特征，常被用于非线性、高纬度的复杂数据问题的解决中。DBN的结构模型如图1所示，其中输入层包含气象数据和历史发电数据。图1中的DBN网络由三层RBM叠堆而成，单个RBM由一个可见层和一个隐含层构成，层间神经元全连接，层内神经元无连接。

DBN的训练过程可以分为两个阶段，即预训练和反向微调。首先利用无监督贪婪学习算法逐层训练网络中每个RBM，数据特征信息逐层传递，实现网络参数的初始化，确定初始的连接权重和神经元

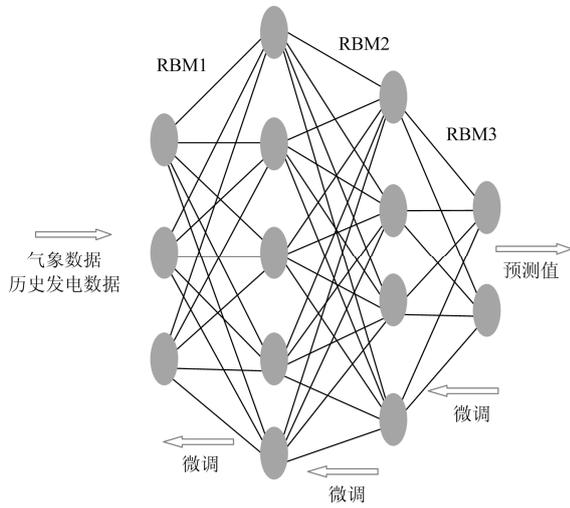


图 1 DBN 网络结构模型

Fig. 1 DBN network structure model

偏置^[21]。之后采用 BP(Back Propagation)算法对预训练得到的初始权重进行自上而下的微调, 该过程进行有监督的训练, 使模型收敛到最优解, 从而确定整个 DBN 网络的结构。DBN 网络的训练过程如下。

1) 设结点状态表示为 $\{S_i\}$, S_j 表示与结点 i 相连的结点 j 的状态, 权重矩阵为 W 。随机选取一个训练样本, 将其数据输入到第一个 RBM 的可见层, 依公式(7)更新第一层隐含层各结点的状态 S_j 。

$$S_j = \varphi_j \left(\sum_i \omega_{ij} S_i + \sigma \cdot N_j(0,1) \right) \quad (7)$$

式中: $\varphi_j(x)$ 为 s 型函数; $N_j(0,1)$ 是标准正态分布函数; $\sigma \in [0,1]$ 。

2) 利用上一步求出的隐含结点状态 S_j , 依据公式(8)更新第一个 RBM 可见结点状态, 记为 S'_i 。

$$S'_i = \varphi_i \left(\sum_j \omega_{ij} S_j + \sigma \cdot N_i(0,1) \right) \quad (8)$$

3) 利用上一步求得的可见结点状态 S'_i , 依据公式(9)再次更新第一个 RBM 的隐含结点状态, 记为 S'_j 。

$$S_j = \varphi_j \left(\sum_i \omega_{ij} S'_i + \sigma \cdot N_j(0,1) \right) \quad (9)$$

4) 将上一步求得的第一个 RBM 的隐含层结点状态 S'_j 作为第二个 RBM 的输入, 再按照上述步骤 1)~3)更新第二个 RBM 各个结点的状态。依据此过程, 逐层更新 DBN 网络的各结点状态, 直至将整个网络结点更新完毕。

5) 随机在训练集中选取下一个训练样本作为 DBN 网络的输入, 跳转到步骤 1), 直至所有训练样

本都被输入过, 结束第一轮训练。根据公式(10)计算网络权重值的变化量, 更新网络中的权重矩阵。

$$\Delta \omega_{ij} = \eta_{\omega} (\langle S_i S_j \rangle - \langle S'_i S'_j \rangle) \quad (10)$$

6) 跳转到步骤 1), 开始下一轮训练, 直到网络的权重矩阵的变化量足够小或达到设定的最高训练次数, 即当 $\|\Delta W(i)\| < \varepsilon$ 时, 结束 DBN 训练, DBN 网络建模完成。

3 粒子群算法优化 DBN 网络

3.1 粒子群优化算法

在建立 DBN 预测模型时, DBN 网络结构的初始权重是随机赋值得到的, 如若选择不当可能使训练过程陷入局部最优解或使收敛时间变长。因而本文采用改进粒子群算法优化 DBN 网络的初始权重。Kennedy 和 Eberhart 于 1995 年提出粒子群算法, 该算法来源于鸟类的捕食运动规律。PSO 算法是一种群体智能模型优化算法, 在模型中, 每个粒子都代表优化问题的解。粒子的速度决定它们运动的距离和方向, 并且通过不断迭代跟踪个体极值 P_{best} 和群体极值 G_{best} , 更新自身位置, 从而得到问题的全局最优解^[22]。

设种群规模为 N 的粒子群在 D 维空间构成的种群为 $X = [X_1, X_2, X_3, \dots, X_n]$, 第 j 个粒子在空间中的位置可表示为 $X_j = [X_{j1}, X_{j2}, X_{j3}, \dots, X_{jD}]$, 速度表示为 $V_j = [V_{j1}, V_{j2}, V_{j3}, \dots, V_{jD}]$ 。将第 j 个粒子的个体最优位置即个体极值表示为 $P_j = [P_{j1}, P_{j2}, P_{j3}, \dots, P_{jD}]$ 。群体极值表示为 $P_g = [P_{g1}, P_{g2}, P_{g3}, \dots, P_{gD}]$, 则速度和位置的更新公式为

$$V_{jd}^{t+1} = \omega V_{jd}^t + c_1 r_1 (P_{jd}^t - X_{jd}^t) + c_2 r_2 (P_{gd}^t - X_{jd}^t) \quad (11)$$

$$X_{id}^{t+1} = X_{id}^t + V_{id}^{t+1} \quad (12)$$

式中: $d = 1, 2, 3, \dots, D$; ω 表示该粒子对原来运动速度的保持程度即惯性权重; c_1 和 c_2 为加速因子, 其中 c_1 表示该粒子保持自身个体极值的程度, c_2 表示该粒子对全局的群体极值学习程度的系数; r_1 和 r_2 是 0~1 之间的随机数。

3.2 改进粒子群优化算法

基于 PSO 算法易陷入局部最优解, 目前对其改进的研究也很多。权重调整、引入遗传算法的变异和限制学习因子是目前常用的改进方法。其中, 权重调整可以通过随机调整、线性递减和非线性递减三种方法来实现^[23]。随着迭代次数的不断增加, 粒子距离全局最优解越来越远, 此时需要缩小搜索区域, 粒子的速度不宜过大, 因而惯性权重 ω 的值随着迭代次数的增加应该不断增加。这里采用权重线

性递减的方法, 公式为

$$\omega = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{T} \times k \quad (13)$$

式中, ω_{\min} 和 ω_{\max} 分别为初始惯性权重的最小值和最大值; T 为最高迭代次数; k 为当前的迭代次数。

学习因子也对 PSO 算法寻优能力有直接的影响, c_1 和 c_2 分别反映了粒子对个体极值和群体极值的学习程度。在算法迭代前期, 粒子受个体极值的搜索经验影响程度较大, 后期则是受群体极值影较大。学习因子的调整一般采用自适应时变策略调整其取值, 公式为

$$\begin{cases} c_1 = c_{\max} - \frac{c_{\max} - c_{\min}}{T} \times k \\ c_2 = c_{\max} + \frac{c_{\max} - c_{\min}}{T} \times k \end{cases} \quad (14)$$

式中, c_{\max} 和 c_{\min} 分别为初始加速因子的最大值和最小值。

3.3 PSO 优化 DBN 网络的实现

PSO 优化 DBN 神经网络的流程如图 2 所示, 具体步骤如下:

(1) 首先初始化 DBN 神经网络, 即确定网络中神经元的层数和每层的个数。以此确定粒子的维度。进行数据预处理, 将原始数据分为训练集和测试集, 并将数据进行归一化。

(2) 初始化粒子群各参数, 包括学习因子 c_{\max} 和 c_{\min} 、最大迭代次数 T 、惯性权重 ω_{\min} 和 ω_{\max} , 并且规定粒子速度和位置的范围。在该范围内随机初始化种群中粒子的速度向量和位置向量。将 DBN 网络的各层间的连接权重映射到粒子的各维度。

(3) 确定适应度函数如下, 利用公式(15)计算各个粒子的适应度函数值, 求出个体极值 P_{best} 和群体极值 G_{best} 。

$$F_{\text{fitness}} = \frac{\sum_{i=1}^N \sum_{j=1}^m (p_{ij} - t_{ij})^2}{N} \quad (15)$$

式中: N 为样本总数目; m 为粒子的维数; p_{ij} 、 t_{ij} 分别为第 i 个样本的第 j 维数据的重构值和实际值。

(4) 比较各粒子的适应度值与自身个体极值 P_{best} 的大小。若粒子当前的适应度大于个体极值 P_{best} , 则将其赋给个体极值 P_{best} , 反之保持 P_{best} 不变。

(5) 比较粒子群中所有粒子的个体极值与群体极值 G_{best} , 若存在个体极值优于群体极值 G_{best} , 则将其赋给群体极值 G_{best} , 反之保持 G_{best} 不变。

(6) 根据式(11)、(12)更新各粒子的速度和位置。

(7) 判断迭代是否终止。当达到设定的最高迭代次数或群体极值的变化量足够小时, 迭代终止。否则, 返回第(3)步。

(8) 将 PSO 优化后最终取得的群体极值的各维数值设为 DBN 网络的连接权值。之后进行 DBN 网络的预训练和反向微调, 直至达到 DBN 结束训练的要求, DBN 网络建模完成。

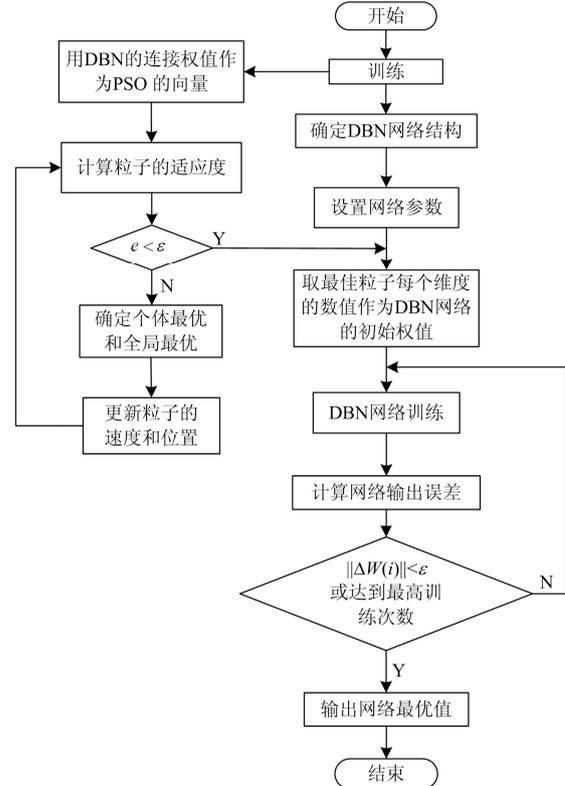


图 2 PSO-DBN 神经网络算法流程图

Fig. 2 Flow chart of PSO-DBN neural network algorithm

4 算例分析

4.1 实验数据和输入变量的选取

实验所用数据来自浙江龙游光伏电站 (119.17° E, 29.03° N), 该站共有 17 个逆变器, 光伏装机容量为 10 MW, 是一座分布式屋顶光伏电站。所获取数据的时间区间为 2015 年 6 月 30 日至 2016 年 4 月 30 日, 功率实测值每隔 10 min 采集一次。根据光伏发电特性, 确定预测模型输入变量为相似日历史发电量、天气类型、日平均辐照度、气温和空气湿度。

以下将利用模型该光伏发电厂 2015 年 2 月 6 日及 7 日光伏发电出力情况进行预测。每个预测日的相似日个数定为 5, 出力状况 10 min 采集一次,

即每一天有 144 个数据点。DBN 网络采用四层结构, 第一、二层隐含层神经元数目分别设为 15、10。RBM 学习率设置为 0.01, 最高迭代次数设为 1 000 次。粒子群优化算法初始参数设置如下: $\omega_{\max} = 0.9$ 、 $\omega_{\min} = 0.5$ 、 $c_{\max} = 2.6$ 、 $c_{\min} = 0.6$ 、 $T = 1000$ 。

4.2 模型评价指标

本文采用平均绝对百分比误差 δ_{MAPE} 作为模型预测效果的评价标准, δ_{MAPE} 的表达式为

$$\delta_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n |(y_i - y'_i) / y_i| \cdot 100\% \quad (16)$$

式中: y_i 为第 i 个预测点的实际功率输出; y'_i 为模型的预测输出功率; n 为预测点总数。

4.3 结果分析

为了充分验证本文模型的预测精确性, 选择与传统 DBN 方法、BP 网络进行对比, 对比的 DBN 网络和本文所用模型的参数设置和网络结构相同。为避免偶然性, 实验结果均为执行十次实验结果得到的平均值。图 3 给出了三种模型的预测结果和真实输出功率的对比图。从图中可以看出, 本文预测模型更接近真实值, 拟合程度更好。图 4 为三种模型各数据点 MAPE 值的对比图, 求得 BP 神经网络的 MAPE 值为 10.45%, DBN 网络模型的 MAPE 值为 7.31%, 本文提出的 PSO-DBN 模型 MAPE 值为 3.45%。从图 4 中可以看出在日出和日落时, 三种模型预测误差都比较大, 这主要是因为在此时太阳辐照度波动比较大。同时可以看出 DBN 网络的预测精度优于 BP 网络, 并且通过引入粒子群优化算法, 一定程度上提高了 DBN 网络的预测精

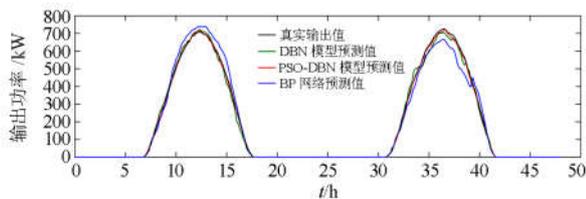


图 3 模型预测结果对比图

Fig. 3 Comparison of model prediction results

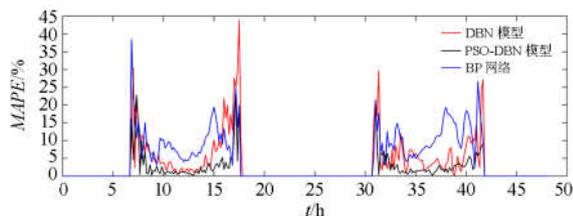


图 4 模型预测误差对比图

Fig. 4 Comparison chart of model prediction error

度, 同时 PSO-DBN 模型的误差波动相比于 DBN 网络有一定的减少。

5 结论

光伏发电短期预测对电网安全稳定运行具有重大意义。基于此, 本文提出利用 PSO 算法优化 DBN 神经网络, 即利用粒子群优化算法为 DBN 网络选取最优的初始权值, 并利用灰色关联度法选择与预测日相似度高的若干日期的历史数据作为训练样本。通过仿真实验, 得出以下结论:

1) 利用灰色关联度法选取训练样本, 更加符合实际需求, 建立的预测模型更加具有针对性, 从而提高了 DBN 网络的预测精度。

2) 本文将 PSO 算法与 DBN 网络相结合, 利用 PSO 算法为 DBN 网络选择最优的初始权值, 可以有效避免因初值选择不当导致算法陷入局部最优解和收敛速度慢的缺点。

参考文献

- [1] 张雨金, 杨凌帆, 葛双冶, 等. 基于 Kmeans-SVM 的短期光伏发电功率预测[J]. 电力系统保护与控制, 2018, 46(21): 124-130.
ZHANG Yujin, YANG Lingfan, GE Shuangye, et al. Short-term photovoltaic power generation prediction based on Kmeans-SVM[J]. Power System Protection and Control, 2018, 46(21): 124-130.
- [2] 贾科, 宣振文, 林瑶琦, 等. 基于 Adaboost 算法的并网光伏发电系统的孤岛检测法[J]. 电工技术学报, 2018, 33(5): 1106-1113.
JIA Ke, XUAN Zhenwen, LIN Yaoqi, et al. Islanding detection method for grid-connected photovoltaic power generation system based on Adaboost algorithm[J]. Transactions of China Electrotechnical Society, 2018, 33(5): 1106-1113.
- [3] 单英浩, 付青, 耿炫, 等. 基于改进 BP-SVM-ELM 与粒子化 SOM-LSF 的微电网光伏发电组合预测方法[J]. 中国电机工程学报, 2016, 36(12): 3334-3343.
SHAN Yinghao, FU Qing, GENG Xuan, et al. Combined forecasting method of microgrid photovoltaic power generation based on improved BP-SVM-ELM and particleized SOM-LSF[J]. Proceedings of the CSEE, 2016, 36(12): 3334-3343.
- [4] 王磊, 武小龙, 侯俊贤, 等. 光伏经多端柔性直流输电并网的控制研究[J]. 电力系统保护与控制, 2019, 47(4): 71-78.
WANG Lei, WU Xiaolong, HOU Junxian, et al. Control of photovoltaic multi-terminal flexible DC transmission grid-connected[J]. Power System Protection and Control, 2019, 47(4): 71-78.
- [5] 田春光, 田利, 李德鑫, 等. 基于混合储能系统跟踪光伏发电输出功率的控制策略[J]. 电工技术学报, 2016,

- 31(14): 75-83.
TIAN Chunguang, TIAN Li, LI Dexin, et al. Control strategy for tracking photovoltaic output power based on hybrid energy storage system[J]. Transactions of China Electrotechnical Society, 2016, 31(14): 75-83.
- [6] 王新普, 周想凌, 邢杰, 等. 一种基于改进灰色 BP 神经网络组合的光伏出力预测方法[J]. 电力系统保护与控制, 2016, 44(18): 81-87.
WANG Xinpu, ZHOU Xiangling, XING Jie, et al. A photovoltaic output prediction method based on improved gray BP neural network combination[J]. Power System Protection and Control, 2016, 44(18): 81-87.
- [7] NIE P L, FEI D, WANG H J, et al. Short-term power load forecasting based on EMD-BP neural network[J]. Control & Instruments in Chemical Industry, 2016.
- [8] KAWASAKI N, OOEKI T, OTANI K, et al. An evaluation method of the fluctuation characteristics of photovoltaic systems by using frequency analysis[J]. Solar Energy Materials and Solar Cells, 2006, 90(18-19): 3356-3363.
- [9] 吴坚, 郑照红, 薛家祥. 深度置信网络光伏发电短时功率预测研究[J]. 中国测试, 2018(5): 6-11.
WU Jian, ZHENG Zhaohong, XUE Jiayang. Research on short-term power prediction of deep-trust network photovoltaic power generation[J]. China Test, 2018(5): 6-11.
- [10] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [11] HUANG G B. Learning hierarchical representations for face verification with convolutional deep belief networks[C] // 2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 16-21, 2012, Providence, RI, USA.
- [12] 晁静. 基于 DBN 的汇率预测研究[D]. 南京: 南京大学, 2012.
CHAO Jing. Research on exchange rate forecast based on DBN[D]. Nanjing: Nanjing University, 2012.
- [13] 李杰, 靳孟宇, 马士豪. 基于粒子群算法的极限学习机短期电力负荷预测[J]. 制造业自动化, 2019, 41(1): 160-163.
LI Jie, JIN Mengyu, MA Shihao. Short-term electric load forecasting of extreme learning machine based on particle swarm optimization[J]. Manufacturing Automation, 2019, 41(1): 160-163.
- [14] 孔祥玉, 郑锋, 鄂志君, 等. 基于深度信念网络的短期负荷预测方法[J]. 电力系统自动化, 2018, 42(5): 133-139.
KONG Xiangyu, ZHENG Feng, E Zhijun, et al. Short-term load forecasting method based on deep belief network[J]. Automation of Electric Power Systems, 2018, 42(5): 133-139.
- [15] 张颖超, 王雅晨, 邓华, 等. 基于 IAFSA-BPNN 的短期风电功率预测[J]. 电力系统保护与控制, 2017, 45(7): 58-63.
ZHANG Yingchao, WANG Yachen, DENG Hua, et al. Short-term wind power prediction based on IAFSA-BPNN[J]. Power System Protection and Control, 2017, 45(7): 58-63.
- [16] JETCHEVA J G, MAJIDPOUR M, CHEN W P. Neural network model ensembles for building-level electricity load forecasts[J]. Energy and Buildings, 2014, 84: 214-223.
- [17] 梁智, 孙国强, 李虎成, 等. 基于 VMD 与 PSO 优化深度信念网络的短期负荷预测[J]. 电网技术, 2011, 25(增刊): 9-14.
LIANG Zhi, SUN Guoqiang, LI Hucheng, et al. Short-term load forecasting based on VMD and PSO optimized deep belief network[J]. Power System Technology, 2011, 25(S): 9-14.
- [18] 梁彩霞, 高赵亮. 基于相似日和 GA-DBN 神经网络的光伏发电短期功率预测[J]. 电气应用, 2019(3): 97-102.
LIANG Caixia, GAO Zhaoliang. Short-term power prediction of photovoltaic power generation based on similar day and GA-DBN neural network[J]. Electrical Application, 2019(3): 97-102.
- [19] 倪春花, 陈国恩, 朱伟, 等. 基于相似日理论和 BP 神经网络的光伏发电功率预测[J]. 电气应用, 2016(1): 42-48.
NI Chunhua, CHEN Guo'en, ZHU Wei, et al. Photovoltaic power generation prediction based on similarity theory and BP neural network[J]. Electrical Applications, 2016(1): 42-48.
- [20] 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.
- [21] HINTON G E. Rectified linear units improve restricted boltzmann machines Vinod Nair[C] // Proceedings of the 27th International Conference on Machine Learning (ICML-10), June 21-24, 2010, Haifa, Israel.
- [22] CHENG R, JIN Y. A social learning particle swarm optimization algorithm for scalable optimization[J]. Information Sciences, 2015, 291: 43-60.
- [23] 陈周林, 李明辉. 改进 PSO-BP 网络预测模型在造纸能耗预测中的应用[J]. 轻工科技, 2018(11): 91-94.
CHEN Zhoulin, LI Minghui. Application of improved PSO-BP network prediction model in paper energy consumption prediction[J]. Light Industry & Technology, 2018(11): 91-94.

收稿日期: 2019-06-24; 修回日期: 2019-09-04

作者简介:

李正明(1958—), 男, 教授, 主要从事微电网电能质量分析与控制的研究工作; E-mail: lzming@ujjs.edu.cn

梁彩霞(1994—), 女, 硕士研究生, 主要从事光伏并网方面的研究工作;

王满商(1986—), 男, 博士研究生, 研究方向为分布式发电运行控制和微电网电能质量分析与控制。

(编辑 姜新丽)