

11-6-2023

An evaluation method for the maximum distributed photovoltaic power capacity absorbed in the distribution networks considering multiple operation targets

Rui ZHANG

Dongguan Power Supply Bureau, Guangdong Power Grid Co., Ltd., Dongguan 523000, China

Huan RAO

Dongguan Power Supply Bureau, Guangdong Power Grid Co., Ltd., Dongguan 523000, China

Ruifeng XU

Dongguan Power Supply Bureau, Guangdong Power Grid Co., Ltd., Dongguan 523000, China

Aoqi MEI

Dongguan Power Supply Bureau, Guangdong Power Grid Co., Ltd., Dongguan 523000, China

Follow this and additional works at: <https://jepst.researchcommons.org/journal>

Recommended Citation

ZHANG, Rui; RAO, Huan; XU, Ruifeng; and MEI, Aoqi (2023) "An evaluation method for the maximum distributed photovoltaic power capacity absorbed in the distribution networks considering multiple operation targets," *Journal of Electric Power Science and Technology*: Vol. 38: Iss. 4, Article 15.

DOI: 10.19781/j.issn.1673-9140.2023.04.015

Available at: <https://jepst.researchcommons.org/journal/vol38/iss4/15>

This Scientific Research is brought to you for free and open access by Journal of Electric Power Science and Technology. It has been accepted for inclusion in Journal of Electric Power Science and Technology by an authorized editor of Journal of Electric Power Science and Technology. For more information, please contact dlxb04@163.com.

多运行目标下的分布式光伏接入配电网 极限容量多模型评估方法

张 锐, 饶 欢, 徐睿烽, 梅傲琪

(广东电网有限责任公司东莞供电局, 广东 东莞 523000)

摘 要:作为异构能源的重要组成部分之一,分布式光伏电源并网运行时由于其出力的随机性、波动性等特性,对传统配电网的安全稳定运行构成了较大程度的冲击和威胁;同时,随着发电容量的进一步提升,配网接纳分布式光伏电源的能力将成为主要制约因素。为此,在兼顾多运行目标的前提下,构建多模型学习方法,设计并整合光伏出力变化预测模型、负荷分布预测模型以及配网接纳分布式光伏极限容量评估模型,全过程分析光伏接入对配网运行产生的影响。构建 Elman 神经网络模型,确保光伏发电出力变化的预测精度;建立 BP 神经网络模型,在保障配网负荷时间、空间分布预测精度的同时,兼顾预测效率;在多约束条件下,基于 PSO 模型提出针对分布式光伏发电最大准入容量的优化模型,实现配网接纳分布式光伏发电极限的准确评估。实例结果表明,所提出方法可为配网安全稳定运行提供保障,并能够为配网接纳分布式光伏发电极限容量提供规划参考。

关 键 词:光伏;配电网;极限容量;多模型学习

DOI:10.19781/j.issn.1673-9140.2023.04.015

中图分类号:TM615

文章编号:1673-9140(2023)04-0143-08

An evaluation method for the maximum distributed photovoltaic power capacity absorbed in the distribution networks considering multiple operation targets

ZHANG Rui, RAO Huan, XU Ruifeng, MEI Aoqi

(Dongguan Power Supply Bureau, Guangdong Power Grid Co., Ltd., Dongguan 523000, China)

Abstract: As one of the important components of heterogeneous energy, the distributed photovoltaic power will affect the safety and stability of the traditional distribution network, due to the randomness and the fluctuation of its output. With the increase of power generation capacity, the ability of distribution network to incorporate the distributed photovoltaic power becomes the main constraint. Therefore, under the premise of considering multiple operation targets, a multi-model learning method is constructed in this paper, which consists of a PV force change prediction model, a load distribution prediction model, and a distributed PV maximum capacity evaluation model. The impacts of photovoltaic access on the distribution networks during the whole process can be analyzed by the proposed model. The Elman neural network model is proposed to ensure the prediction accuracy of the photovoltaic power generation variations. The BP neural network model is established to consider the prediction accuracy as well as the prediction efficiency. The PSO model for the maximum capacity of distributed photovoltaic power generation is built, so as to realize the accurate evaluation of the limit of distribution network acceptance of distributed photovoltaic power. The empirical results show that the proposed method can

收稿日期:2021-11-02;修回日期:2021-11-19

基金项目:广东电网公司重点科技项目(0319002021030103DK00003)

通信作者:张 锐(1988—),男,硕士,高级工程师,主要从事综合能源、调度自动化、智能电网方面的研究;E-mail:524595906@qq.com

ensure the safe and stable operation of the distribution network, and is also beneficial for the planning of the maximal capacity of distributed photovoltaic power generation in the distribution networks.

Key words: photovoltaic power; distribution network; maximal capacity; multi-model learning method

“十四五”时期中国新能源发展内生动力强劲,新能源发电在全网总装机的占比将持续提高,新能源发展取得了重大成就^[1-2]。其中,分布式光伏由于具有投资小、清洁保护及供电可靠等优点,成为新能源配电网接入主体之一。但由于光伏出力受不同因素影响而存在较高的不确定性^[3],导致配网系统运行随机性上扬,继而产生线路过载、负荷短缺等风险问题。这无疑给现行分布式光伏接入配电网的控制及规划带来新的挑战。在满足多运行目标的前提下,亟待构筑配电网针对分布式光伏接纳能力的准确科学评估手段。

目前,为提升配网接纳分布式电源的能力,学者们已进行深入研究。文献[4]提出了针对一次设备的短路电流限制措施和改造方法;文献[5]在配网边际容量成本模型的计算过程中计及了无功影响;文献[6]提出了一种计及配电网原有三段式电流保护整定原则的分布式电源准入容量计算方法;文献[7]分析了交流配电网、交直流混合配电网的分布式电源最大准入容量以及相应的影响因素;文献[8]分析了网络重构、有载分接开关调节及无功功率补偿等因素对分布式电源最大准入容量的影响。以上研究针对配网分布式新能源的接纳取得了一定成果,但未充分考虑分布式光伏的随机性、波动性对于配网运行的影响,从而难以实施后续优化。

为此,学者们针对光伏的随机性、波动性开展了相关研究。文献[9]构建了一种计及振荡约束的准入功率极限模型;文献[10]设计了一种考虑网络传输约束的消纳分析模型;文献[11]利用动态规划法建立设备的动作时间表。以上方法深入分析了光伏的随机性,但未全方位考虑影响分布式光伏的因素以及负荷需求分布的影响。因此,学者们提出了计及多因素的光伏接纳优化方法。文献[12]通过模拟仿真技术验证模型的正确性,分析配电网接纳分布式电源能力;文献[13-14]利用数值分析的方法提出基于实际运行数据拟合的模型,从而得出接纳光伏的解析解。以上研究提出了针对光伏接纳

的优化途径,但未针对不同光伏需求匹配下的配网综合控制规划模型。

本文针对光伏接入过程中的出力变化、负荷分布以及极限评估三方面场景特点,设计相应最优匹配数据挖掘模型,整合建立多模型学习方法,在兼顾多运行目标的要求下,涵盖配网光伏接纳中的多因素、全流程。在光伏发电功率预测阶段,构建Elman神经网络模型,确保高随机、高不确定性的环境下发电出力的预测精度;在负荷分布预测阶段,考虑到日负荷分布强相似性的特征,建立BP神经网络模型,在保证预测精度的同时,力求降低运算复杂度从而提升预测效率;最后,在多约束条件下,建立粒子群优化(particle swarm optimization, PSO)模型,实现分布式光伏发电最大准入容量的持续优化。通过东北某地配网的实例结果表明,所提出多模型整合方法在预测性能上具有相应优势,能够为配网接纳分布式光伏极限提供规划参考。

1 基于Elman神经网络的光伏发电预测模型

为实现光伏发电输出功率的准确预测,需要计及光伏发电的影响因素。但如果将所有因素变量都作为模型输入,必然拉升模型的维数和计算负担;同时由于各因素相互之间对光伏出力的作用存在重叠,均衡考虑所有因素的影响难免降低预测效率。为此,在保证预测精度的基础上,构建Elman神经网络预测模型,筛选出原始数据中的有效关键信息。

1.1 光伏发电影响因素分析

影响光伏出力的最主要因素是太阳辐射强度和光伏电池板温。结合光伏I/V特性曲线随辐照强度、温度变化的趋势,容易确定光伏模块(阵列)的热电效应,继而有助于预测光伏输出功率。通常,光伏电池板的倾斜角度、所处的海拔高度、经纬度地理位置以及天气等众多因素都会影响太阳光照辐射强度、电池温度,从而加剧光伏出力的不确定

性和随机性。当针对某一特定地点的光伏电站发电量进行预测时,其地理位置、海拔因素都固定不变,并同时假定倾斜角始终处于最佳角度。因此,本文主要分析天气变量因素,包括:太阳辐射量、日平均温度、云团量、相对湿度、风向和风速、日降水量以及大气压强等。

1.2 Elman神经网络的构建

Elman神经网络一般由输入层、隐含层、承接层和输出层4层结构组成,其中输入层、隐含层和输出层的连接与BP(back propagation)神经网络类似,输入层有 n 个神经元,其作用仅将样本送入隐含层,不会参与任何实际运算;隐含层有 p 个神经元,采用S型传输函数tansig;输出层有 q 个神经元,采用线性组合函数purelin,这样的传输函数在2层神经网络的特殊组合中可以从任何精度来逼近任意的连续函数。与BP神经网络的区别是,还有一个局部反馈通道存在于隐含层与输入层的神经元之间,称之为承接层,其传输函数是在普通线性函数的基础上增加了一个延迟单元,用于存储过去的状态,并在 $t+1$ 时刻与网络的输入一起作为隐含层的输入变量,使得整个神经网络具有实时记忆功能,这个特点非常适用于时间序列的拟合预测。Elman神经网络结构如图1所示(D 代表神经元连接权矩阵),具体学习步骤如下。




图1 Elman神经网络结构

Figure 1 Structure of the typical Elman neural network

1) 初始化参数。将各连接权值和神经元阈值赋值在区间(1,1)内的一个随机数,设定样本数据容量为 m ,网络输出与期望输出的误差函数为 E ,预设精度设为 ϵ ,最大学习次数设为 $N_{\max}$ 。

2) 设第 $k(k=1, 2, \dots, m)$ 个输入样本 $X(k)$ 以及对应的期望输出 $Z(k)$ 为

$$\begin{cases} X(k)=[x_1(k), x_2(k), \dots, x_n(k)] \\ Z(k)=[z_1(k), z_2(k), \dots, z_q(k)] \end{cases} \quad (1)$$

3) 计算每层神经元真实输出(从输入层直到输出层):

$$\begin{cases} \alpha_h(k)=f\left(\sum_{i=1}^n w_{ih}^x x_i(k)+\sum_{j=1}^m w_{jh}^u y_j(k-1)-b_h^1\right), \\ h=1, 2, \dots, p \\ y_o(k)=f\left(\sum_{h=1}^p w_{ho}^y \alpha_h(k)-b_o^2\right), o=1, 2, \dots, q \end{cases} \quad (2)$$

式中, $\alpha_h(k)$ 为第 k 个样本在第 h 个隐含层输出; $y_o(k)$ 为第 k 个样本在第 o 个输出层输出; $W_x=[w_{ih}^x]_{n \times p}$ 为输入层与隐含层的前向连接权值,是一个 $n \times p$ 矩阵; $W_y=[w_{ho}^y]_{p \times q}$ 为隐含层与输出层的前向连接权值,是一个 $p \times q$ 矩阵; $W_u=[w_{jh}^u]_{m \times p}$ 为隐含层与输入层的反馈连接权值,是一个 $m \times p$ 矩阵; $b^1=[b_1^1, b_2^1, \dots, b_p^1]^T$ 为隐含层神经元的阈值; $b^2=[b_1^2, b_2^2, \dots, b_q^2]^T$ 为输出层神经元的阈值; $f(\cdot)$ 是激活函数(传递函数),一般隐含层的激活函数为双曲正切S型函数(tansig)或者对数S型函数(logsig),分别为

$$f(x)=\frac{1-e^{-x}}{1+e^{-x}}, \in(0, 1) \quad (3)$$

$$f(x)=\frac{1}{1+e^{-x}}, \in(0, 1) \quad (4)$$

输出层激活函数是线性函数,用purelin表示。

4) Elman网络的误差也采用BP算法修正,其真实输出与预期输出的误差函数 E 为

$$E=\frac{1}{2} \sum_{o=1}^q [z_o(k)-y_o(k)]^2 \quad (5)$$

5) 判断预测值与真实值之间的误差是否满足要求。当误差达到预设精度 ϵ 或者学习次数大于 $N_{\max}$ 时,则结束算法;否则,选取下一个样本及对应的期望输出,则进行新一轮的学习。

2 基于BP神经网络的负荷分布预测模型

2.1 BP神经网络的建立

BP神经网络通常由输入层、隐含层和输出层组成,一般输入层和输出层只有一层,而隐含层由一层或多层组成。BP神经网络的每一层都是由多个

并行计算的神经元组成,输入层和输出层神经元的个数由实际需求而定,隐含层的神经元个数可由公式近似选取或者试探选择最优数量,一般采用经验公式确定范围再用试探法确定最优个数。

首先确定激活函数。激活函数主要负责将神经元的输入映射到输出端。常见的激活函数有linear、sigmoid、Tanh及ReLU函数等。由于本文采用的神经网络层数相对较少,并且为保证网络学习过程不会出现过度学习的问题,激活函数选择了sigmoid函数。

然后确定训练函数与学习函数。两者均用于调整权重和阈值,其中,训练函数面向整体误差的全局调整,学习函数面向单个神经元的误差局部调整。从训练函数中得到整体的权重和阈值后由学习函数进行调整更新,之后再由训练函数得出新的权重和阈值,反复继续调整直至误差小于设定值为止。主流训练/学习函数包括:自适应学习速率法、共轭梯度法、拟牛顿法、LM(levenberg-marquardt)算法等。为避免神经网络学习率过大而出现不能收敛或是学习率较小出现训率速度慢而陷入局部收敛的问题,本文采用自适应学习速率法提高神经网络训练过程的收敛速度,并且避免陷入过训练而造成局部收敛的情况,提高神经网络输出的精确度。

BP神经网络的学习过程存在2个阶段:①前向传播,计算神经元的输出值和误差值;②反向优化,利用误差反向传播优化神经网络的权重和阈值。

1)前向传播过程。

输入层的输入矩阵为 $[x_1, x_2, \dots, x_j, \dots, x_m]$;隐含层第 i 个神经元的输入为

$$I_{\text{net}_i} = \sum_{j=1}^m w_{ij} x_j + b_i \quad (6)$$

经过激活函数作用,隐含层第 i 个神经元的输出为

$$h_o = \Phi(I_{\text{net}_i}) = \Phi\left(\sum_{j=1}^m w_{ij} x_j + b_i\right) \quad (7)$$

输出层第 k 个神经元的输入为

$$I_{\text{NET}_k} = \sum_{i=1}^n w_{ki} \Phi\left(\sum_{j=1}^m w_{ij} x_j + b_i\right) + a_k \quad (8)$$

再经过激活函数 $\phi(\cdot)$ 的作用,输出层第 k 个神经元

的输出为

$$O_k = \phi(I_{\text{NET}_k}) = \phi\left(\sum_{i=1}^n w_{ki} \Phi\left(\sum_{j=1}^m w_{ij} x_j + b_i\right) + a_k\right) \quad (9)$$

2)反向优化过程。通过计算输出层的输出值与目标值之间的总误差,再通过误差的反向传播对神经网络的权重和阈值进行优化,从而降低误差。

设某一样本为 p , T_k 为目标值,则系统输入 s 个训练样时的总二次型误差准则函数的表达式为

$$e_s = \frac{1}{2} \sum_{d=1}^s \sum_{k=1}^q (T_k^d - O_k^d)^2 \quad (10)$$

式中, T_k^d 为第 d 个样本的目标值; O_k^d 为第 d 个样本下输出层第 k 个神经元的输出;

3层神经网络结构如图2所示。




图2 BP神经网络结构

Figure 2 Structure of the typical BP neural network

沿误差函数对权重或阈值偏导数的负方向进行修正,可得到输入层与隐含层、隐含层与输出层之间的权重和阈值的修正公式,分别为

$$\Delta w_{ki} = \eta \sum_{d=1}^s \sum_{k=1}^q (T_k^d - O_k^d) \phi'(I_{\text{NET}_k}) h_i \quad (11)$$

$$\Delta b_i = \eta \sum_{d=1}^s \sum_{k=1}^q (T_k^d - O_k^d) \cdot \phi'(I_{\text{NET}_k}) w_{ki} \Phi'(I_{\text{net}_i}) \quad (12)$$

$$\Delta w_{ij} = \eta \sum_{d=1}^s \sum_{k=1}^q (T_k^d - O_k^d) \cdot \phi'(I_{\text{NET}_k}) w_{ki} \Phi'(I_{\text{net}_i}) x_j \quad (13)$$

$$\Delta a_k = \eta \sum_{d=1}^s \sum_{k=1}^q (T_k^d - O_k^d) \phi'(I_{\text{NET}_k}) \quad (14)$$

式(11)~(14)中, η 为算法学习率; x_j 为输入层第 j 个神经元的输入; $\Phi(\cdot)$ 为隐含层的激活函数; $\phi(\cdot)$ 为输出层的激活函数; w_{ki} 为隐含层第 i 个神经元到输出层第 k 个神经元之间的权重; b_i 为隐含层第 i 个神经元的阈值; w_{ij} 为输入层第 j 个神经元到隐含层第 i 个神经元之间的权重; a_k 为输出层第 k 个神经元的阈值。

2.2 负荷分布预测主要步骤

基于BP神经网络的短期负荷分布预测主要步骤如下:

- 1) 历史数据预处理, 主要包括对电力负荷的预处理和影响因素(气象因素、时间因素)的归一化处理, 经过预处理得到训练模型的样本数据;
- 2) 确定BP神经网络的拓扑结构, 即确定拓扑结构的输入层、隐含层和输出层各1层;
- 3) BP神经网络结构的权重和阈值的初始化;
- 4) 输入训练集、验证集得到训练好的模型, 通过测试集的评估得到预测值和误差;
- 5) 比较在不同训练算法的情况下的误差, 进行结果分析。

3 基于PSO的配电网接纳分布式光伏极限容量评估

3.1 PSO模型的搭建

在PSO算法中, 首先随机产生一群粒子, 每一个粒子都是搜索空间的潜在解, 然后通过迭代寻找最优解。每一个的粒子都有一个适应于种群的适应值(fitness), 决定粒子运动的位置和速度。每次迭代后可以通过2个“极值”更新粒子下一时刻的速度和位置, 第1个极值是迭代后粒子本身的最优解, 称为局部最优解; 第2个极值是整个种群的最优解, 称为全局最优解。假设在一个 D 维的目标搜索空间中, 有 m 个粒子组成一个群落, 其中第 i 个粒子的位置表示为 $x = (x_{i1}, x_{i2}, \dots, x_{iD})$, 速度表示为 $v = (v_{i1}, v_{i2}, \dots, v_{iD})$, 第 i 各粒子目前搜索到的最优位置为 $p_i = (p_{i1}, p_{i2}, \dots, p_{iD})$, 整个粒子群的最优位置为 $p_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 。

PSO对粒子操作时所采用公式为

$$v_{id}^{n+1} = v_{id}^n + c_1 r_1^n (p_{id}^n - x_{id}^n) + c_2 r_2^n (g_{id}^n - x_{id}^n) \quad (15)$$

$$x_{id}^{n+1} = x_{id}^n + v_{id}^{n+1} \quad (16)$$

其中, $i = 1, 2, \dots, m, d = 1, 2, \dots, D$, 加速因子 c_1, c_2 均是非负常数。分别调节个体最优粒子和全局最优粒子飞行的最大步长, 若最大步长太小, 则粒子可能远离目标区域, 太大则会导致粒子突然向目标区域飞去或飞过目标区域。合适的 c_1, c_2 可以加快收敛且不易陷入局部最优, 通常令 $c_1 = c_2 = 2$, r_1, r_2 是介于 $[0, 1]$ 之间的随机数。粒子在每一维飞行的速度不超过算法设定的最大速度 $v_{\max}$ 。

为了平衡进化过程中粒子的全局和局部搜索性能, 采用自适应PSO(adaptive PSO, APSO)进行求解。对惯性权重进行线性调整, 目的是为了先采用全局搜索, 使搜索空间快速收敛于某一区间, 然后采用局部精细搜索以获得高精度的解。调整公式为

$$\omega = \omega_{\max} - \frac{(\omega_{\max} - \omega_{\min})}{N_{\text{iter}, \max}} \cdot N_{\text{iter}} \quad (17)$$

式中, $\omega_{\min}, \omega_{\max}$ 分别为惯性权重最小、最大值; N_{iter} 为当前迭代次数; $N_{\text{iter}, \max}$ 为最大迭代次数。

3.2 极限评估模型的设计

通常配电网能够消纳的光伏发电容量既与具体的网络拓扑结构相关, 也与配电网的运行调度方式相关。评估过程中需考虑因素: ①选择冬季最大运行方式对电网进行稳态分析, 因为冬季电网的运行状况最为恶劣; ②并网逆变器输出功率因数通常控制为单位功率因数, 故光伏电站可看作无功出力为零的节点; ③在调压方法上尽可能采取使用投切无功补偿装置和变压器分接头等调压措施, 使光伏电站容量逐步增加时满足配电网的稳态运行要求, 从而确定并网光伏电站的最大并网容量。

基于上述条件, 本文建立以光伏发电最大接入量为目标的优化模型。优化目标为配电网可接纳光伏电总容量的最大值, 约束条件为系统潮流方程及电网安全约束条件。

1) 提出目标函数。

模型以配电网可接纳分布式光伏发电总容量的最大值为目标, 其表达式为

$$\max F(x) = \sum_{i=1}^n x_i \quad (18)$$

式中, $F(x)$ 为配电网可接纳分布式光伏发电的总容量; x_i 为决策变量, 即单个地区光伏发电的接入容量; n 为接入的光伏电站数量。

2) 确定约束条件。

等式约束为系统潮流方程, 可写为

$$\begin{cases} P_{gi} + P_{pi} - P_{Li} - \\ U_i \sum_{j \in i} U_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) = 0 \\ Q_{gi} + Q_{pi} - Q_{Li} - \\ U_i \sum_{j \in i} U_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) = 0 \end{cases} \quad (19)$$

式中, P_{gi} 、 Q_{gi} 分别为系统节点 i 处常规机组的有功、无功出力; P_{Li} 、 Q_{Li} 分别为系统节点处有功、无功负荷; P_{pi} 、 Q_{pi} 分别为系统节点处光伏电站的有功、无功出力; U_i 、 U_j 、 θ_{ij} 分别为系统节点 i 和 j 的电压幅值、相角差; G_{ij} 、 B_{ij} 分别为导纳矩阵所对应的元素。

3) 设立不等式约束条件。

本文选取电压偏差、电压波动以及谐波约束, 分别为

$$U_N(1 - \theta) \leq U_i \leq U_N(1 + \theta) \quad (20)$$

$$\phi_i \leq \phi_{\max} \quad (21)$$

$$\frac{S_{PV}}{\sqrt{3} U_N} \cdot \varphi_k \leq I_k \quad (22)$$

式(20)~(22)中, U_N 为标称电压; U_i 为第 i 个节点电压; θ 为确定电压等级的电压偏差率限定值; ϕ_i 为光伏发电接入引起的电压波动值; $\phi_{\max}$ 为国标约定的电压波动最大值; S_{PV} 为光伏接入的容量; φ_k 为国标约定的光伏系统输出的谐波含有率的限定值; I_k 为国标约定的允许接入电网的谐波电流, k 为谐波次数。

4) 模型求解。

基于 PSO 算法进行配电网接纳分布式光伏发电极限容量计算, 具体步骤如下:

① 输入配电网原始参数, 设置 PSO 算法计算参数;

② 粒子初始化, 每个粒子代表光伏发电设备待选安装节点的光伏发电容量;

③ 设置约束条件, 包括等式和不等式约束;

④ 计算适应度值, 以式(18)为目标函数, 对每个粒子进行潮流计算, 对于违反约束条件的个体降低其适应度值, 根据适应度值记录各粒子最优位置和全局最优位置;


⑤ 由式(15)、(16)更新粒子的速度和位置, 对越限变量进行限制, 重复步骤④, 迭代更新;

⑥ 判断是否满足算法终止条件, 满足条件则输出结果, 否则转步骤④。


4 算例分析

本文基于东北某地配电网进行实例仿真。


1) 针对光伏发电预测模型, 本算例依据该配网6月份某天的数据实施动态模拟, 并选用支持向量回归(support vector regression, SVR)、随机森林(random forest, RF)、线性加权矩阵(weighted linear matrix, WLM)作为对比模型, 如图3所示, 可知基于 Elman 神经网络模型的光伏出力预测效果相较于其他模型在准确性和不确定度上均有一定优势。



(a) 输出功率



(b) 残差



(c) 相对误差

图3 光伏发电预测结果对比

Figure 3 Comparison between models for photovoltaic output predictions

从图3中可以看出,在输出功率曲线上,Elman神经网络得到的预测值相比于其他模型更接近实际值;在残差值的对比上,Elman神经网络预测结果的残差绝对值相比于其他模型更小;在相对误差上,Elman神经网络的相对误差最小,且误差在允许范围内。总体来说,Elman神经网络预测模型的预测精度最高,满足工程要求,具有较大的实际意义。

2) 针对负荷分布预测模型,本算例针对该配网6月7—10号这4天的输入参数实施预测。将预测结果对比这4天的实际负荷分布,如图4所示,可得BP神经网络模型的性能已能够满足日负荷分布的预测需求,无需进一步舍弃运算效率、速度以换取更高的精度。

3) 针对配电网接纳分布式光伏极限容量评估模型,以该配网某节点为例实施仿真。在此节点上,估算光伏极限接入容量为2 MW,设置节点电压的上、下限分别为1.05、0.95 p.u.,在接入前、后网损变化不大时,通过计算得出此节点接入的光伏极限容量为1.086 6 MW。光伏接入前、后系统电压的变化曲线如图5所示。




图4 日负荷分布预测结果

Figure 4 Prediction of daily distribution of loads




图5 光伏接入前、后系统电压变化

Figure 5 Voltage variation before and after the photovoltaic access is available

系统节点电压变化如表1所示,可以看出该节点接入最大极限容量后其他各节点的电压变化。光伏发电接入后该线路电压最大、最小值分别为1.002 40、0.995 65 p.u.,表明影响光伏接入的原因是网损约束或单个节点接入光伏极限容量约束。

表1 系统节点电压变化

Table 1 Voltage variation of other nodes in this system

节点	电压/p.u.		节点	电压/p.u.	
	接入前	接入后		接入前	接入后
1	1.000 00	1.000 00	7	0.992 49	0.998 97
2	0.999 28	0.999 90	8	0.997 40	0.998 03
3	0.997 21	1.001 20	9	0.996 01	0.996 64
4	0.995 93	1.002 40	10	0.995 09	0.995 72
5	0.994 98	1.001 50	11	0.995 02	0.995 65
6	0.993 11	0.999 59			

5 结语

本文针对多运行目标约束下的分布式光伏接入配电网极限容量,提出了一种基于多模型学习方法的评估模型,在预测过程中能够计及应用场景下多因素的不同影响以及全流程的不同特性。

1) 构建基于Elman神经网络的光伏出力变化预测模型,实现了高随机、高不确定性的环境下光伏发电功率的准确预测;

2) 考虑到日负荷分布的强相似性,建立了基于BP神经网络的负荷分布预测模型,力求兼顾预测精度以及预测效率;

3) 结合光伏出力以及负荷分布预测结果,设计多约束条件下的PSO优化模型,实现了针对分布式光伏发电最大准入容量的综合评估。

参考文献:

- [1] SHAHIN S, HADI K, SEYED ALI AGHA M, et al. Performance analysis of finned photovoltaic/thermal solar air dryer with using a compound parabolic concentrator[J]. Applied Energy, 2021, 304(1): 117-128.
- [2] ZHAO Y, LI D, LU T, et al. Collaborative fault detection for large-scale photovoltaic systems[J]. IEEE Transactions on Sustainable Energy, 2020, 11(4): 2745-2754.

- [3] LÓPEZ LORENTE J, LIU X, MORROW D J. Spatial aggregation of small-scale photovoltaic generation using voronoi decomposition[J]. IEEE Transactions on Sustainable Energy, 2020, 11(4): 2677-2686.
- [4] 刘松喜, 杨智奇, 黄伟达, 等. 基于分布式测量的低压主动配电网中性线断线识别与定位方法[J]. 供用电, 2022, 39(4): 68-76.
- LIU Songxi, YANG Zhiqi, HUANG Weida, et al. Identification and location of neutral line broken in low voltage active distribution network based on distributed measurement[J]. Distribution & Utilization, 2022, 39(4): 68-76.
- [5] 曲正伟, 张嘉曦, 王云静, 等. 考虑分布式电源不确定性的配电网改进仿射状态估计[J]. 电力系统自动化, 2021, 45(23): 104-112.
- QU Zhengwei, ZHANG Jiayi, WANG Yunjing, et al. Improved affine state estimation for distribution network considering uncertainty of distributed generator[J]. Automation of Electric Power Systems, 2021, 45(23): 104-112.
- [6] 邓成江, 李海峰, 曾德辉, 等. 含逆变型分布式电源的不平衡配电网短路电流计算方法研究[J]. 智慧电力, 2021, 49(2): 39-46.
- DENG Chengjiang, LI Haifeng, ZENG Dehui, et al. Calculation method of short-circuit current in unbalanced distribution network with inverter-based distributed generation[J]. Smart Power, 2021, 49(2): 39-46.
- [7] 马睿, 顾洁, 彭虹桥. SNOP优化配置的多维效用并合模型[J]. 电力科学与技术学报, 2020, 35(1): 75-82.
- MA Rui, GU Jie, PENG Hongqiao, et al. Multi-attribute utility merge model of SNOP optimal allocation[J]. Journal of Electric Power Science and Technology, 2020, 35(1): 75-82.
- [8] 马兵. 智能静态切换开关控制器相关关键技术研究[D]. 南京: 东南大学, 2016.
- MA Bing. The research of related key technologies about intelligent static switch controller[D]. Nanjing: Southeast University, 2016.
- [9] 郭立东, 雷鸣宇, 杨子龙, 等. 光储微网系统多目标协调控制策略[J]. 电工技术学报, 2021, 36(19): 4121-4131.
- GUO Lidong, LEI Mingyu, YANG Zilong, et al. Multi objective coordinated control strategy for optical storage microgrid systems[J]. Transactions of China Electrotechnical Society, 2021, 36(19): 4121-4131.
- [10] 刘轶, 王景钢. 大型光伏电站并网暂态特性研究[J]. 电力系统保护与控制, 2021, 49(7): 182-187.
- LIU Yi, WANG Jinggang. Study on transient characteristics of large photovoltaic power stations connected to the grid[J]. Power System Protection and Control, 2021, 49(7): 182-187.
- [11] 卞海红, 孙健硕. 基于典型气象周的GRNN光伏发电量预测模型[J]. 电力工程技术, 2021, 40(5): 94-99.
- BIAN Haihong, SUN Jianshuo. Photovoltaic power generation prediction model based on optimized TMY Method-GRNN[J]. Electric Power Engineering Technology, 2021, 40(5): 94-99.
- [12] 张长春, 赵尚, 杨弘诚, 等. 光伏并网逆变器内部短路故障耐受性能试验研究[J]. 高压电器, 2022, 58(7): 28-33.
- ZHANG Changchun, ZHAO Shang, YANG Hongcheng, et al. Research on withstand performance test of internal short circuit fault of photovoltaic grid connected inverter[J]. High Voltage Apparatus, 2022, 58(7): 28-33.
- [13] 耿龙海, 李朝霞, 权学政. 基于PSASP的含大规模光伏发电系统暂态稳定仿真分析[J]. 电网与清洁能源, 2021, 37(2): 124-131.
- GENG Longhai, LI Zhaoxia, QUAN Xuezheng. Transient stability simulation analysis of the power generation system containing large-scaled photovoltaic based on PSASP[J]. Power System and Clean Energy, 2021, 37(2): 124-131.
- [14] SHABANI A, MAZLUMI K. Evaluation of a communication-assisted overcurrent protection scheme for photovoltaic-based DC microgrid[J]. IEEE Transactions on Smart Grid, 2020, 11(1): 429-439.