第40卷 第4期
2024年4月

电网与清洁能源
Power System and Clean Energy

Vol.40 No.4
Apr. 2024

文章编号:1674-3814(2024)04-0118-09 中图分类号:TM711 文献标志码:A

基于AP-WOA-GRU的分布式光伏集群电压越限动态预测

韩雨[1],郭成[2],方正云[3,4],陈凤仙[5]

(1. 昆明理工大学机电工程学院,云南 昆明 650500; 2. 昆明理工大学电力工程学院,云南 昆明 650500; 3. 昆明理工大学国土资源工程学院,云南 昆明 650000; 4. 云南电网有限责任公司,云南 昆明 650000; 5. 云南电网有限责任公司曲靖供电局,云南 曲靖 655000)

The Dynamic Prediction of Voltage Overrun of the Distributed Photovoltaic Cluster Based on AP-WOA-GRU

HAN Yu[1], GUO Cheng[2], FANG Zhengyun[3,4], CHEN Fengxian[5]

(1. School of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650500, Yunnan, China; 2. School of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, Yunnan, China; 3. School of Land and Resources Engineering, Kunming University of Science and Technology, Kunming 650000, Yunnan, China; 4. Yunnan Power Grid Co., Ltd., Kunming 650000, Yunnan, China; 5. Qujing Power Supply Bureau, Yunnan Power Grid Co., Ltd., Qujing 655000, Yunnan, China)

ABSTRACT: Focusing on the voltage fluctuation caused by large-scale distributed photovoltaic access to the distribution network under the background of photovoltaic in the entire Qujing county, a distributed photovoltaic cluster voltage overrun prediction method based on affinity propagation (AP) and Whale Optimization Algorithm (WOA) optimized gated recurrent unit (GRU) is proposed. Firstly, the geographical coordinates meteorological characteristics and the location characteristics are added based on the node density factors of the distribution network, and the distributed photovoltaic cluster with approximate meteorological characteristics and geographical characteristics is divided by the neighbor propagation clustering method to improve the model training effect and adaptability. Secondly, the whale optimization algorithm is used to search for the optimal training parameters of the GRU model globally to improve the training speed and prediction accuracy of the model. Finally, the WOA-GRU combination model is used to realize the correlation matching between the node voltage of the distribution network with the ambient temperature and light intensity, and thus realize the overall prediction of voltage fluctuation and voltage crossing in the regional distribution network. The experiments show that the proposed method can effectively improve the prediction accuracy and training speed, strengthen the adaptability of the prediction model, and have good economy and practicability.

KEY WORDS: voltage overrun; distributed photovoltaic; Whale Optimization Algorithm (WOA); gated recurrent unit (GRU); affinity propagation (AP)

摘要:针对整县光伏背景下规模化分布式光伏接入配电网导致的电压波动问题,提出了一种基于近邻传播聚类(affinity propagation, AP)与鲸鱼算法(whale optimization algorithm, WOA)优化门控循环单元(gated recurrent unit, GRU)的分布式光伏集群电压越限预测方法。首先,在考虑分布式光伏地理坐标气象特征的基础上,添加基于配电网节点负荷密度因素的位置特征,采用近邻传播聚类方法,在不指定聚类数目的情况下划分具有近似气象特征和地理位置特征的分布式光伏集群,提高模型训练效果及适应性;然后,采用鲸鱼优化算法全局搜索GRU模型的最优训练参数,进一步提高模型的训练速度和预测精度;最后,利用WOA-GRU组合模型实现配电网节点电压与环境温度、光照强度的关联匹配,进而实现区域配电网电压波动及电压越限情况的整体预测。实验证明:所提出的方法能够有效提高预测精度及训练速度,强

基金项目:云南省联合基金专项(202201BE070001-15);云南电网有限责任公司科技项目(YNKJXM20220074)。

Project Supported by Special Project of Yunnan Provincial Joint Fund (202201BE070001-15); Science and Technology Project of Yunnan Power Grid Co., Ltd. (YNKJXM20220074).

化预测模型的适应能力，具有较好的经济性和实用性。

关键词：电压越限；分布式光伏；鲸鱼优化算法；门控循环单元；近邻传播聚类

近年来，随着国家“双碳”战略目标的推进，以光伏为代表的清洁能源得到快速发展。各省各地积极响应国家号召，大力开展整县屋顶分布式光伏建设，配电网中分布式光伏规模持续增长，配电网的电压波动及越限问题突出[1-3]。我国部分区域中低压配电网网架较为薄弱，规模化光伏并网极有可能使现有的电压质量问题进一步恶化，导致电压合格率降低、线损增大、光伏发电单元损毁等事件的发生。对规模化分布式光伏并网导致的配电网电压越限情况开展准确预测评估，无论是对分布式光伏的并网规划，还是集群控制均具有重要研究意义。

针对分布式光伏引起的电压越限问题预测，现有方法主要包括数学统计和机器学习两大类。统计方法包括时间序列[4]、回归分析[5]等，虽然方法操作较为简单方便，但其相较于机器学习在预测准确率方面有待提高，且预测稳定性较差；机器学习方法包括随机森林[6]、深度神经网络[7]以及支持向量机[8]等，而结合各种不同预测方法的优势，弥补单一方法的不足也是近年来混合网络预测模型的一大趋势，如 CNN-GRU（convolutional neural networks-gated recurrent unit）[9-10]等组合网络也在预测精度和训练速度等方面有所提高。文献[11]利用 BP 神经网络进行台区低电压短期预测估算，在考虑了温度、天气、时段等多种影响因素共同作用的情况下进行电压问题的及时预测。然而考虑到分布式光伏规模较小且位置分散的特点，成体系的数据采集系统成本过高且难以实现。对此，文献[12]提出基于社团理论的虚拟集群动态划分方法，适用于多目标变化调控。文献[13]提出根据网架结构与负荷大小进行配电网集群划分的方法。

上述方法在预测模型准确度方面都有明显提升，但预测模型对所需数据规模有较高要求，而整县光伏背景下单个分布式光伏所收集的数据体量较小，导致模型训练效果欠佳；且经由单个分布式光伏点的数据训练所得的预测模型难以适应其余分布式光伏的预测需要。因此，本文提出了一种基于近邻传播聚类（affinity propagation，AP）与鲸鱼算法（whale optimization algorithm，WOA）优化门控循环单元（gated recurrent unit，GRU）的分布式光伏集群电压越限动态预测模型。首先，以光伏出力和考虑节点负荷密度的光伏实际位置作为光伏集群划分的特征变量，利用 AP 聚类方法进行无指定聚类数目的自主聚类分群，形成若干具有近似气象特征和地理位置特征的分布式光伏集群，以扩大预测模型数据集规模，提高模型训练效果与适应性；其次，采用 WOA 优化算法搜索 GRU 模型最优训练参数，借以提高预测模型的预测精度；最后，以光伏集群为单位，收集电压、光伏阵列温度、光照强度等数据，利用 WOA 优化后的 GRU 模型进行训练，预测线路电压波动趋势以及电压越限情况。

1　基于气象-位置特征的AP划分

1.1　分布式光伏出力对配电网电压影响

假设配电网线路中存在 N 个节点，第 n 个节点的视在功率表示为 $P_n+\mathrm{j}Q_n(n=1,2,\cdots,N)$，节点电压为 $U_n(n=1,2,\cdots,N)$，第 n 个节点与前一个节点之间的线路阻抗为 $R_n+\mathrm{j}X_n=l_n(r+\mathrm{j}x)$，其中 l_n 为第 n 个节点与前一个节点之间的线路长度，r 和 x 分别为单位长度线路的电阻值和电抗值。节点 p 接入的光伏容量为 P_V，定义有功功率和无功功率以流出母线的方向为正值，分布式光伏群接入中压配电网的潮流分布如图 1 所示。

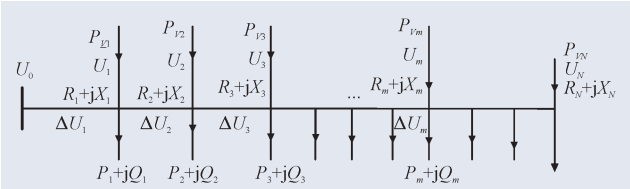

图1　负荷分布

Fig.1　Distribution of loads

分布式光伏集群接入前，相邻两个节点之间的电压降可表示为

$$\Delta U_m=U_m-U_{m-1}=-\frac{\sum_{m=n}^{N}P_nR_m+\sum_{m=n}^{N}Q_nX_m}{U_{m-1}}=-\frac{\sum_{m=n}^{N}P_nrl_m+\sum_{m=n}^{N}Q_nxl_m}{U_{m-1}}\quad(1)$$

因节点消耗的 P_n 和 Q_n 均为正值，故线路中电压降均大于 0，表明节点与初始节点之间的距离越大，线路电压降低越明显。节点 m 处的电压 U_m 为

$$U_m=U_0+\sum_{k=1}^{m}\Delta U_k=U_0-\sum_{k=1}^{m}\frac{\sum_{n=k}^{N}P_nrl_k+\sum_{n=k}^{N}Q_nxl_k}{U_{k-1}}\quad(2)$$

式中：U_0 为首端电压。

当分布式光伏集群接入配电网后，考虑到居民用电的影响，此时节点 m 处的电压 U'_m 为

$$U'_m = U_0 - \sum_{k=1}^{m} \frac{\sum_{n=k}^{N} P_n r l_k - \sum_{n=k}^{N} P_{Vn} r l_k}{U_{k-1}} \tag{3}$$

相邻两个节点之间的电压降可表示为

$$\Delta U'_m = U'_m - U'_{m-1} = \sum_{k=1}^{m-1} \frac{\sum_{n=k}^{N} P_n r l_k - P_{Vn} r l_k}{U_{k-1}} - \sum_{k=1}^{m} \frac{\sum_{n=k}^{N} P_n r l_k - P_{Vn} r l_k}{U_{k-1}} = -\frac{\sum_{n=m}^{N} P_n r l_m - P_{Vn} r l_m}{U_{m-1}} \tag{4}$$

式中：P_{Vn} 为第 n 个节点接入光伏发电的容量。

当 $\sum_{n=m}^{N} P_n > \sum_{n=m}^{N} P_{Vn}$ 时，表明从节点 m 往后所有负荷有功功率之和小于光伏集群发电功率之和，此时电压升高；当 $\sum_{n=m}^{N} P_n < \sum_{n=m}^{N} P_{Vn}$ 时，表明从节点 m 往后所有负荷有功功率之和大于光伏集群发电功率之和，此时电压降低。

1.2 基于光伏出力的气象特征集

分布式光伏出力受多方面因素共同影响，但在实际工程应用中难以获得此类影响因素数据。数据短缺使研究者通常采用等效辐照度概念来描述分布式光伏的出力特性。由于光伏点的输出功率与等效辐照度存在近似线性关系[14]，可以采用光伏电站的输出功率变化来刻画光伏点的气象及环境因素。因此，将分布式光伏点的光伏输出功率作为AP聚类的气象特征集代表值，可以划分具有气象相似性的光伏点集群。

1.3 基于节点负荷密度的位置特征集

在进行线路电压走势预测时，线路损耗也是不能忽略的重要影响因素。在线路阻抗一定的情况下，电压传输路径过长，其电压损耗越大；同理，当分布式光伏所产生的不能就地消纳的能量传输上网时，其电压影响程度也与其接入点在线路当中的实际位置密切相关。与此同时，分布式光伏就地消纳能力不同，也可能造成盈余功率上网时对线路电压影响程度存在差异。

本文采用基于位置因素的节点负荷密度这一概念进行分布式光伏辐射范围内的线路阻抗与光伏就地消纳能力刻画。

$$\partial = \frac{\sum_{i=1}^{k=1} \bar{S}}{l} \tag{5}$$

式中：$\sum_{i=1}^{k=1} \bar{S}$ 为光伏辐射范围线路的各检测时刻正常运作的总负载容量的平均值；l 为目标分析线路光伏点与线路首端节点的距离。

将分布式光伏点的节点负荷密度作为AP聚类的实际位置特征集代表值，可以划分具有代表用电消纳能力特点的光伏点集群。

1.4 AP聚类划分光伏点集群

AP聚类算法规定数据集中所有数据点之间存在吸引度信息与归属度信息。通过两者的不断迭代传送，在不指定最终聚类个数的情况下，进行高效准确的聚类分组。与传统的聚类方法相比，AP算法多次独立运算的聚类结果可以保持一致，避免了重复聚类时结果的不同对后期进行电压越限预测可能带来的误差。

本文采用AP算法根据气象和位置的二维特征集对研究范围内的分布式光伏点进行聚类，将波动趋势较为一致的光伏点聚类为同一光伏集群。

在算法初始阶段，计算初始相似度 $S^{(0)} = (s_{ij})_{n\times n}$。

$$s_{ij} = s(i,j) = -d^2(x_i, x_j) = -\left\| x_i - x_j \right\|^2 \tag{6}$$

式中：x_i、x_j 为二维特征集的值；$-d^2(x_i, x_j)$ 为欧式距离。

设定初始参考度 $\boldsymbol{F}$ 和最大迭代次数 M。

$$\boldsymbol{F} = \boldsymbol{F}_{(n\times 1)} = (F_1, F_2, \cdots, F_n)^{\mathrm{T}} \tag{7}$$

式中：$F_i = F(i)$ 为 x_i 的参考度值，即 x_i 作为聚类中心的可靠程度，设置 $\boldsymbol{F}$ 为相似度 $\boldsymbol{S}$ 的中值。

计算样本间的吸引度值 r_{ij}。

$$r_{ij} = r(i,j) = s_{ij} - \max_{k\neq j}(s_{ik} + a_{ij}) \tag{8}$$

式中：r_{ij} 为 x_j 适合作为 x_i 聚类中心的程度，即从 i 到 j 的消息；a_{ij} 为 x_i 适合作为 x_j 聚类中心的程度，即从 j 到 i 的消息且初值为0。

计算样本点间的归属度值 a_{ij}。

$$a_{ij} = \min\left\{0, r_{ij} + \sum_{k\neq i,j} \max(0, r_{jk})\right\} \tag{9}$$

吸引度值 r_{ij} 与归属度值 a_{ij} 的更新。

$$r_{ij}^{(m+1)}=\lambda\cdot r_{ij}^{(m)}+(1-\lambda)\cdot r_{ij}^{(m+1),\mathrm{old}},\lambda\in[0.5,1) \quad (10)$$

$$a_{ij}^{(m+1)}=\lambda\cdot a_{ij}^{(m)}+(1-\lambda)\cdot a_{ij}^{(m+1),\mathrm{old}},\lambda\in[0.5,1) \quad (11)$$

式中：λ 为收敛系数，主要用于优化算法收敛速度和迭代稳定性；m 的最小值为 0 且 $m<M$；“old”表示原始值。

若聚类中心在多次迭代后不再变化，或 $m>M$，终止迭代，确定此时的聚类样本中心及样本点。聚类流程如图 2 所示。

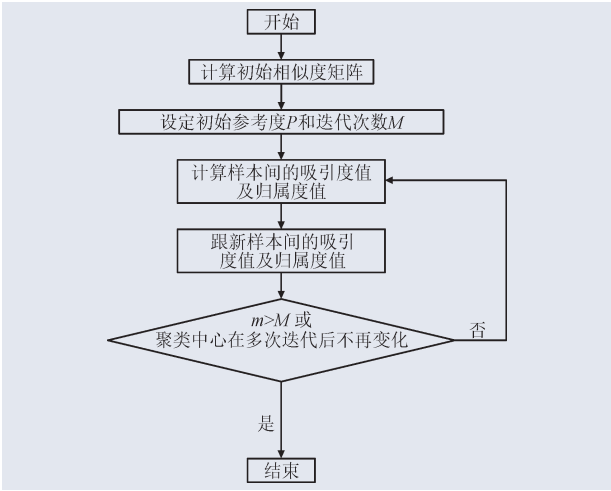

图2　AP聚类流程
Fig.2　AP clustering process

2　基于WOA-GRU的越限预测模型

2.1　基于WOA算法的参数优化模型

WOA 是一种元启发式优化算法，采用随机或最佳搜索代理来模拟座头鲸的捕猎行为，并使用螺旋来模拟其特有的泡泡网攻击机制。WOA 中每个座头鲸的位置代表一个潜在解，通过在解空间中不断更新座头鲸的位置进行全局最优解的搜索。

WOA 将全局解空间作为其搜索范围，在实行围捕时需要确定目标猎物的具体位置。WOA 一般将目标猎物或接近最优解假定为当前的最佳候选解，其余搜索代理向最佳搜索代理跟新其位置。此阶段行为的模型函数为

$$\boldsymbol{G}=\left|\boldsymbol{C}\cdot\boldsymbol{Y}^{*}(t)-\boldsymbol{Y}(t)\right| \quad (12)$$

$$\boldsymbol{Y}(t+1)=\boldsymbol{Y}^{*}(t)-\boldsymbol{A}\cdot\boldsymbol{G} \quad (13)$$

式中：$\boldsymbol{A}$ 和 $\boldsymbol{C}$ 为系数向量；t 为当前迭代次数；$\boldsymbol{Y}^{*}(t)$ 为当前最优解的位置向量；$\boldsymbol{Y}(t)$ 为当前位置向量。

当出现更好的解决方案时，进行 $\boldsymbol{Y}^{*}(t)$ 的更新。

其中系数向量的计算方式为

$$\boldsymbol{A}=2\boldsymbol{a}\times\boldsymbol{r}_1-\boldsymbol{a} \quad (14)$$

$$\boldsymbol{C}=2\times\boldsymbol{r}_2 \quad (15)$$

式中：$\boldsymbol{a}$ 为模型收敛因子，实行 2~0 线性递减；$\boldsymbol{r}_1$ 与 $\boldsymbol{r}_2$ 为向量形式，表示(0,1)的随机数[15-16]。

2.2　GRU模型

门控循环单元 GRU 是传统循环神经网络模型(recurrent netural networks，RNN)的变体，相较于 RNN，GRU 能够规避在时间序列处理过程中可能出现的梯度爆炸或梯度消失等问题，又在长短期记忆(long short term memory，LSTM)的基础上将遗忘门与输入门结合形成了一个更新门，在保留过去信息影响的同时提高了训练速度。其中更新门决定了模型向后传递信息的数量，而重置门决定了需要丢弃的信息数量[17-18]。

因此，考虑到温度、光照强度等预测数据具有较强的时序性特征，采用 GRU 进行时序性预测。门控循环单元 GRU 原理如图 3 所示。

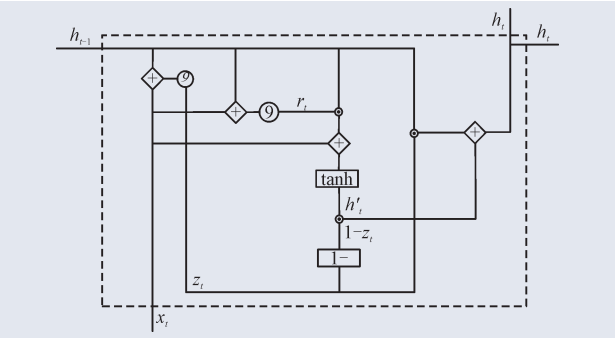

图3　门控循环单元(GRU)原理
Fig.3　The principle of the gate recurrent unit

GRU 在进行模型训练时，权重修正利用 Adam 算法进行循环迭代修正权重，从而逐渐逼近具有较强随机性的数据。

2.3　WOA-GRU混合模型

WOA-GRU 混合模型首先利用鲸鱼优化算法对 GRU 的初始训练参数进行优化配置，对 GRU 模型第一和第二隐藏层的节点数、最大训练代数以及初始学习率进行全局搜索，得到最优值；基于最优参数对 GRU 模型重新赋值并进行再训练，学习数据间的时间依从关系[19-20]，再通过全连接层输出一维结构的最终结果。WOA-GRU 混合模型如图 4 所示。

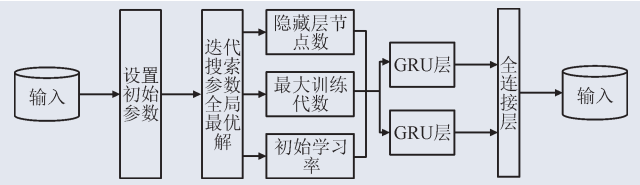

图4 WOA-GRU混合模型
Fig.4 WOA-GRU hybrid model

本文所提出的预测算法流程如图5所示：首先收集区域内分布式光伏点的温度、光照强度和电压值等实测数据，利用光伏输出功率以及节点负荷密度指标建立气象—位置特征集，采用AP聚类划分具有特征相似性的分布式光伏集群，筛选合并聚类结果所示的光伏集群的实测数据，划分训练集和测试集；再利用WOA优化算法模拟鲸鱼捕食，全局搜索GRU模型的最优节点数、训练代数和学习率等模型参数；运用优化后的GRU模型进行模型训练，更新权重和偏置，最终输出电压走势及电压越限预测结果。

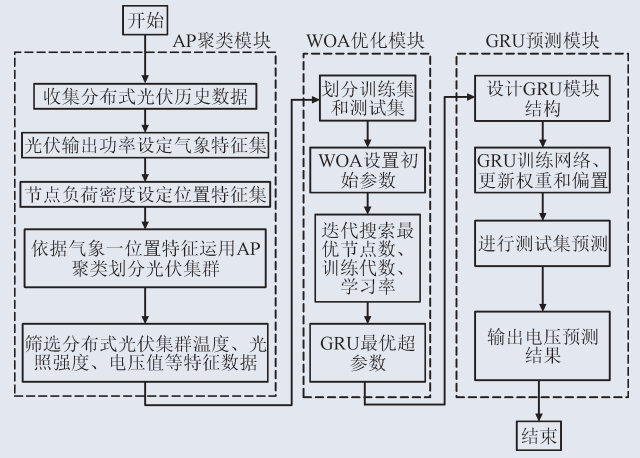

图5 预测流程
Fig.5 Forecast processes

3 算例分析

本文选取澳大利亚DKASC数据集中Yulara Solar System光伏电站的光伏功率与气象数据进行实验，包括60个分布式光伏点一天中06:00—18:00的电压(V)、光照强度(lm/m²)、温度(℃)和光伏阵列输出功率(MW)等。

3.1 数据预处理

1）剔除异常值

光伏点数据因数据采集设备误差等不可控因素，存在部分缺失值和异常数据，因此对原始数据进行数据清洗，去除信息不全和偏差过大的数据。

2）数据归一化

$$q'_{ij}=\frac{q_{ij}-\min\left(q_{ij}\right)}{\max\left(q_{ij}\right)-\min\left(q_{ij}\right)} \tag{16}$$

式中：q_{ij}为对应的原始数据值。

3.2 分布式光伏集群划分

研究分布式光伏对于配电网电压影响需要大量光伏相关数据的支持，光伏数据的采集就显得尤为重要。但完备且成体系的数据采集设备费用高，加之整县光伏的推进使分布式光伏数量增加，想要准确获取各分布式光伏点的相关数据需要大量的经济成本。因此，为制定更加经济有效的电压越限预测方法，根据各光伏点的具体特征利用AP聚类方法进行光伏集群的划分，采用光伏集群代表中心的采集数据进行电压越限预测。

以预处理后的数据由式(5)计算气象-位置特征集数据，如表1所示。

表1 气象-位置二维特征集
Table 1 Meteorology-location two-dimensional feature

光伏点编号	气象值	位置值
1	1	0.377 4
2	0	0.361 9
3	0.997 3	0.711 8
⋮	⋮	⋮
59	0.901 2	0.317 7
60	0.898 9	0.345 7

基于AP聚类进行光伏集群划分。AP聚类最大迭代次数M为500，迭代不变次数m为50，阻尼系数R为0.5，以矩阵S中第三列的中间值即所有相似度的中位数作为参考初始值。各分布式光伏点的聚类情况如图6所示。

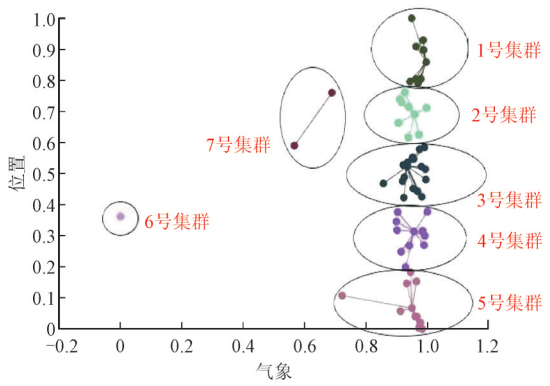

图6 AP聚类划分结果
Fig.6 Segmentation results of AP

3.3　电压越限预测结果

3.3.1　模型评价指标

为更加直观地观察组合模型的准确率及其鲁棒性，采用平均绝对误差 MAE 、均方根误差 RMSE 以及拟合度 RS 进行模型有效性验证。

$$\mathrm{MAE}=\frac{1}{n}\sum_{i=1}^{n}\left|\hat{y}_i-y_i\right| \tag{17}$$

式中：MAE 范围为 $[0,+\infty)$ ，MAE 越小，说明模型误差越小，精度越高；$\hat{y}_i$ 为样本 n 的预测值；y_i 为样本 n 的实际值，同下。

$$\mathrm{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2} \tag{18}$$

式中：RMSE 为回归效果与真实值差值的平均值，该值越小，说明模型质量越高。

$$\mathrm{RS}=1-\frac{\sum_i(\hat{y}_i-y_i)^2}{\sum_i(\bar{y}_i-y_i)^2} \tag{19}$$

式中：RS 范围为 [0,1] ，表示模型拟合度，该值越接近 1，说明模型拟合效果越好；$\bar{y}$ 表示均值。

3.3.2　实验设置

本实验的硬件配置为 intel CORE i7-11800H CPU，16 GB 内存；基于 MatLab 框架实现。

参照 WOA 原理，种群数量设置为 10，最大迭代次数为 200，优化自变量个数为 3；将最终优化参数赋值给 GRU 模型后，训练集与测试集的划分比例为 0.83∶0.17。

3.3.3　WOA-GRU 预测结果分析

以 AP 聚类划分结果中的 4 号光伏集群作为研究对象，输入为温度和光照强度，输出为电压值；预测结果显示，MAE=0.206 7，RMSE=0.267 1，RS=0.984 3；其 WOA-GRU 模型的预测结果如图(7)、图(8)所示。

3.3.4　预测模型性能评估及误差分析

1）单点预测与光伏集群预测对比分析

为验证 AP 聚类对于光伏集群的划分对电压越限预测模型的有效性，本文分别建立了 11 个单点 WOA-GRU 预测模型与光伏集群 WOA-GRU 预测模型。11 个单一光伏点 WOA-GRU 预测模型以 4 号光伏集群内 11 个分布式光伏点的温度和光照强度分别作为输入，各光伏点的电压分别作为其输出；光伏集群 WOA-GRU 预测模型以 4 号光伏集群内所有温度和光照强度数据作为输入，输出为其电压值。两类预测模型的预测结果的评价指标值对比如表 2 所示。

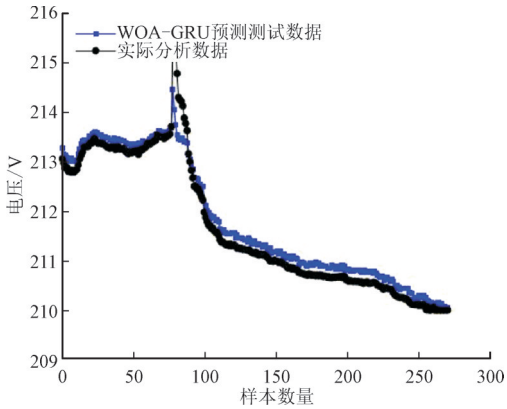

图7　WOA-GRU 预测结果

Fig.7　WOA-GRU prediction results

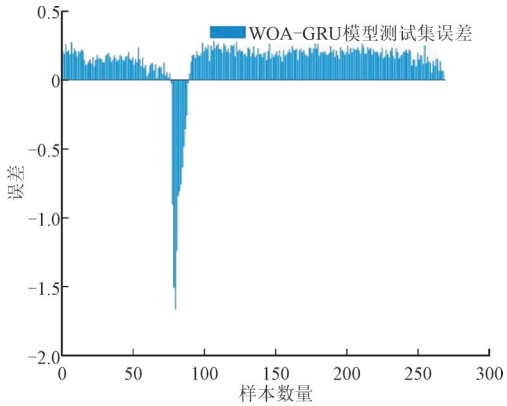

图8　WOA-GRU 测试集误差

Fig.8　The error of the WOA-GRU test set

表2　单点预测与光伏集群预测对比

Table 2　Single-point forecasts versus PV cluster forecasts

预测模型	MAE											训练时间/s
	1	2	3	4	5	6	7	8	9	10	11	
WOA-GRU	1.32	1.66	2.13	1.69	3.09	2.77	2.54	2.31	3.25	3.07	1.17	473
AP-WOA-GRU	1.07	1.48	2.00	1.62	2.76	2.56	2.33	2.04	3.11	2.99	0.99	292

由表 2 可得，以光伏集群为单位进行 WOA-GRU 预测拥有更低的平均绝对误差值 MAE ，说明以光伏集群为单位的预测效果更好，误差更小，精度更高，同时拥有更快的训练速度。

2）不同预测模型对比分析

为验证 WOA-GRU 模型的有效性，本文将 4 号光伏集群相关数据通过 AP-WOA-GRU 模型与

AP-LSTM 模型、AP-GRU 模型和 AP-CNN-GRU 模型进行对比分析,以 MAE 、RMSE 以及 RS 等指标对模型有效性与准确性进行刻画。不同预测模型的对比曲线如图 9 所示,预测结果对比如表 3 所示。

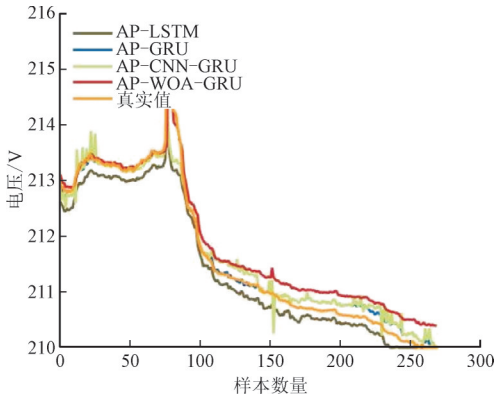

图9 不同预测模型与真实值的对比曲线

Fig. 9 Curves of different predictive models versus true values

表3 不同预测模型预测结果

Table 3 Prediction results for different predictive models

模型	MAE	RMSE	RS
AP-LSTM	1.32	2.10	0.94
AP-GRU	1.31	2.00	0.97
AP-CNN-GRU	1.34	2.18	0.96
AP-WOA-GRU	1.19	1.97	0.98

从模型对比结果可以看出,AP-WOA-GRU 模型较其他预测模型拥有更低的 MAE 和 RMSE ,且 RS 更高,说明 AP-WOA-GRU 模型在预测误差、模型精度以及拟合效果方面均优于其他对比模型。

在验证了本文所提组合模型的有效性后,采用组合模型对线路整体电压走势进行预测,预测结果如图 10 所示。

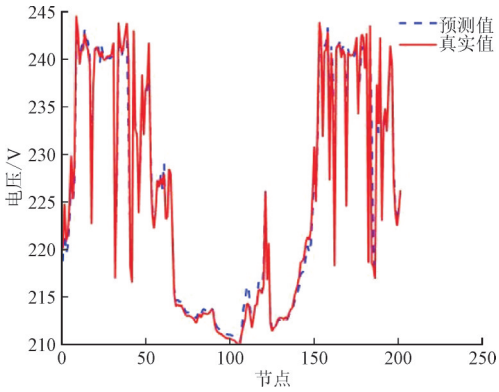

图10 线路整体预测结果

Fig. 10 Overall forecast results of lines

从预测结果来看,采用本文所述组合模型能够对接入分布式光伏的配电台区整体电压走势进行较为准确的预测,从而有效预判可能出现的电压越限问题。

4 结论

本文针对分布式光伏接入配电网导致的电压越限问题,提出了一种基于 AP-WOA-GRU 的分布式光伏集群电压越限预测方法。主要研究结论如下:

1) 采用纳入节点负荷密度特征的气象-位置特征集,借助 AP 聚类方法对目标范围内的分布式光伏点进行有效分类,形成具有气象相似性与位置相似性的光伏集群,能够降低分布式光伏群的气象数据采集成本。

2) 利用 WOA 鲸鱼算法进行 GRU 模型参数优化,避免人为设置训练参数的可能误差,提高了预测模型的训练精度和迭代速度。

3) 利用 AP-WOA-GRU 组合模型进行分布式光伏规模化并网情况下的配电网电压越限预测具有可行性。

参考文献

[1] 王晓霞,俞敏,霍泽健,等.基于近邻传播聚类与LSTNet的分布式光伏电站群短期功率预测[J]. 电力系统自动化,2023,47(6): 133-141.
WANG Xiaoxia, YU Min, HUO Zejian, et al. Short-term power forecasting of distributed photovoltaic station clusters based on affinity propagation clustering and long short-term time-series network[J]. Automation of Electric Power Systems,2023,47(6): 133-141.

[2] 余昆,唐修明,陈星莺,等.高比例分布式光伏接入的配电网过电压责任分摊方法[J/OL].中国电机工程学报,2023:1- 12[2023- 10- 30].http://kns.cnki.net/kcms/detail/11.2107.TM.20230616.1549.021.html.
YU Kun,TANG Xiuming,CHEN Xingying,et al. Distribution network overvoltage responsibility allocation method for high proportion distributed photovoltaic access[J/OL]. Proceedings of the CSEE, 2023:1- 12[2023- 10- 30].http://kns.cnki.net/kcms/detail/11.2107.TM.20230616.1549.021.html.

[3] 江晶晶,黄潇贻,陈婧.含风电场电力系统的静态电压稳定性预警系统[J].电网与清洁能源,2022,38(7):92-97,106.

JIANG Jingjing, HUANG Xiaoyi, CHEN Jing. Quiescent voltage stability early warning system for power system with wind farm[J].Power System and Clean Energy, 2022, 38(7):92-97, 106.

[4] 田书娅,贾清泉,林丽娟,等.面向谐波和电压综合治理的电压检测型APF与SVG协同配置[J]. 电力系统自动化,2021,45(24): 149-157.
TIAN Shuya, JIA Qingquan, LIN Lijuan, et al. Collaborative allocation of voltage detection active power filter and static var generator for harmonic and voltage comprehensive mitigation[J]. Automation of Electric Power Systems, 2021, 45(24): 149-157.

[5] 丁长新,张沛,孟祥飞,等.基于分类回归树算法的在线静态电压稳定裕度评估[J]. 电力系统及其自动化学报,2020,32(1): 93-100.
DING Changxin, ZHANG Pei, MENG Xiangfei, et al. Online evaluation on static voltage stability margin based on classification and regression tree algorithm[J]. Proceedings of the CSU-EPSA, 2020, 32(1): 93-100.

[6] 杜晓东,王立斌,刘科研,等.基于随机森林的配电网故障分布特征预测方法[J].电网与清洁能源,2023,39(1): 70-77.
DU Xiaodong, WANG Libin, LIU Keyan, et al. Fault distribution characteristic prediction method of distribution network based on random forest[J].Power System and Clean Energy, 2023, 39(1):70-77.

[7] 张宇精,乔颖,鲁宗相,等.含高比例分布式电源接入的低感知度配电网电压控制方法[J]. 电网技术,2019,43(5): 1528-1535.
ZHANG Yujing, QIAO Ying, LU Zongxiang, et al. Voltage control for partially visible distribution networks with high DG penetration[J]. Power System Technology, 2019, 43(5): 1528-1535.

[8] 许可. 基于大数据与机器学习的配电网电压质量异常预测技术研究[D]. 扬州:扬州大学,2021.

[9] 冯裕祺,李辉,李利娟,等.基于CNN-GRU的光伏电站电压轨迹预测[J]. 中国电力,2022,55(7): 163-171.
FENG Yuqi, LI Hui, LI Lijuan, et al. Voltage trajectory prediction of photovoltaic power station based on CNN-GRU[J]. Electric Power, 2022, 55(7): 163-171.

[10] 张哲,秦博宇,高鑫,等.基于CNN-LSTM网络的电网电压稳定紧急控制策略[J]. 电力系统自动化,2023,47(11): 60-68.
ZHANG Zhe, QIN Boyu, GAO Xin, et al. Emergency control strategy of power grid voltage stability based on convolutional neural network and long short-term memory network[J]. Automation of Electric Power Systems, 2023, 47(11): 60-68.

[11] 魏振,江智军,杨晓辉,等.基于BP神经网络的低电压短期预测的估算[J]. 现代电子技术,2019,42(23): 62-66.
WEI Zhen, JIANG Zhijun, YANG Xiaohui, et al. Estimation of short-term prediction of low voltage based on BP neural network[J]. Modern Electronic Technique, 2019, 42(23): 62-66.

[12] 窦晓波,常莉敏,倪春花,等.面向分布式光伏虚拟集群的有源配电网多级调控[J]. 电力系统自动化,2018,42(3): 21-31.
DOU Xiaobo, CHANG Limin, NI Chunhua, et al. Multi-level dispatching and control of active distribution network for virtual cluster of distributed photovoltaic[J]. Automation of Electric Power Systems, 2018, 42(3): 21-31.

[13] 丁明,方慧,毕锐,等.基于集群划分的配电网分布式光伏与储能选址定容规划[J]. 中国电机工程学报,2019,39(8): 2187-2201.
DING Ming, FANG Hui, BI Rui, et al. Optimal siting and sizing of distributed PV-storage in distribution network based on cluster partition[J]. Proceedings of the CSEE, 2019, 39(8): 2187-2201.

[14] 冷亚军,吴宗育,赵文会,等.基于近邻传播聚类权重的黑启动方案评估方法[J]. 电力系统自动化,2020,44(13): 73-80.
LENG Yajun, WU Zongyu, ZHAO Wenhui, et al. Assessment method of black-start scheme based on affinity propagation clustering weight[J]. Automation of Electric Power Systems, 2020, 44(13): 73-80.

[15] SUN L, GUO C, LIU C, et al. Fast affinity propagation clustering based on incomplete similarity matrix[J]. Knowledge and Information Systems, 2017, 51(3):941-963.

[16] 刘威,郭直清,王东,等.改进鲸鱼算法及其在浅层神经网络搜索中的权值阈值优化[J]. 控制与决策,2023,38(4): 1144-1152.
LIU Wei, GUO Zhiqing, WANG Dong, et al. Improved whale optimization algorithm and its weights and thresholds optimization in shallow neural architecture search[J]. Control and Decision, 2023, 38(4): 1144-1152.

[17] 张国治,陈康,方荣行,等.基于DGA与鲸鱼算法优化Logit Boost-决策树的变压器故障诊断方法[J]. 电力系统保护与控制,2023,51(7): 63-72.
ZHANG Guozhi, CHEN Kang, FANG Rongxing, et al. Transformer fault diagnosis based on DGA and a whale algorithm optimizing a Logit Boost-decision tree[J]. Power System Protection and Control, 2023, 51(7): 63-72.

[18] 乔石,王磊,张鹏超,等.基于时间模式注意力机制的GRU短期负荷预测[J].电力系统及其自动化学报,2023,35(10):49-58.
QIAO Shi, WANG Lei, ZHANG Pengchao, et al. GRU short-term load prediction based on time pattern attention mechanism[J].Journal of Electric Power System and Automatics,2023,35(10):49-58.
[19] 马燕峰,骆泽榕,赵书强,等.基于改进蒙特卡洛混合抽样的含风光电力系统风险评估[J]. 电力系统保护与控制,2022,50(9): 76-83.
MA Yanfeng, LUO Zerong, ZHAO Shuqiang, et al. Risk assessment of a power system containing wind power and photovoltaic based on improved Monte Carlo mixed sampling[J]. Power System Protection and Control,2022,50(9): 76-83.
[20] 王永辉,何帅彪,冯瑾涛,等.考虑中点电压平衡的三相四开关变换器模型预测电压控制[J]. 电力系统保护与控制,2019,47(12): 31-39.
WANG Yonghui, HE Shuaibiao, FENG Jintao, et al. Model predictive voltage control of three- phase four- switch converter in island mode considering capacitor voltage balancing control[J]. Power System Protection and Control, 2019,47(12): 31-39.

收稿日期:2023-10-08。

作者简介:
韩 雨(1998—),女,硕士研究生,研究方向为电压越限预测与无功电压协调控制;
郭 成(1978—),男,通信作者,博士,教授级高工,研究方向为电能质量分析与控制、电力系统性稳定分析;
方正云(1979—),男,博士研究生,高级工程师,研究方向为电气工程、数字电网;
陈凤仙(1977—),女,本科,工程师,研究方向为电力系统配网运行管理。

(编辑 冯露)

(上接第117页)

[20] 张雅美,郝涛,尹四倍,等. 具有时延和随机扰动的未知C-G神经网络的有限时间函数投影同步及其在保密通信中的应用[J]. 应用数学和力学,2020,41(12):1405-1416.
ZHANG Yamei, HAO Tao, YIN Sibei, et al. Finite-time function projective synchronization of unknown cohen-grossberg neural networks with time delays and stochastic disturbances and its application in secure communication [J]. Applied Mathematics and Mechanics, 2020, 41(12): 1405-1416.

收稿日期:2022-02-22。

作者简介:
马智强(1989—),男,硕士,工程师,研究方向为电力系统分析运行和电力系统智能技术;
马胜国(1985—),男,硕士,工程师,研究方向为电力系统分析运行和电力系统智能技术;
陈 亮(1984—),男,本科,工程师,研究方向为用电信息采集系统建设和智能运维技术;
刘德志(1988—),男,本科,工程师,研究方向为用电信息采集系统建设和智能运维技术;
董 婧(1989—),女,本科,工程师,研究方向为用电信息采集系统建设和智能运维技术;
马 丽(1992—),女,本科,工程师,研究方向为用电信息采集系统建设和智能运维技术。

(编辑 卢秀)