

DOI:10.12158/j.2096-3203.2021.01.012

基于极限学习机与负荷密度指标法的空间负荷预测

邵宇鹰¹, 彭鹏¹, 张秋桥², 王冰³

(1. 国网上海市电力公司, 上海 200122; 2. 南京宽塔信息技术有限公司, 江苏 南京 211100; 3. 河海大学能源与电气学院, 江苏 南京 211100)

摘要:空间负荷预测对有配电网的规划建设具有重要意义,为了提高配电网空间负荷预测的精度,文中提出基于极限学习机(ELM)的配电网空间负荷预测算法,采用粒子群优化(PSO)模型的参数。首先根据用地性质将负荷分类,再通过模糊C均值(FCM)算法对每一类负荷进行聚类分析,建立精细化的负荷密度指标体系。根据待预测地块的特性指标选取训练样本,代入ELM训练,提高预测精度。通过搜索的数据对实例进行仿真试验,通过对比未引入FCM算法的相对误差、未引入PSO算法的相对误差以及采用PSO-ELM算法的相对误差可得,文中提出的PSO-ELM算法具有较高精度,满足实际工程的要求。

关键词:空间负荷预测;负荷密度指标法;粒子群优化(PSO)算法;极限学习机(ELM);模糊C均值(FCM)算法
中图分类号:TM715 **文献标志码:**A **文章编号:**2096-3203(2021)01-0086-06

0 引言

空间负荷预测这一概念由 H. Lee Willis 于 20 世纪 80 年代初首次提出^[1],不仅要对其某一区域的负荷总量进行预测,同时还要预测这一区域负荷增长的位置。空间负荷预测是城市配电网规划中不可或缺的重要环节,其预测结果的精度对城市配电网规划的经济性^[2-6]以及可操作性有着重大影响。因此,随着城市负荷的增长以及智能电网建设需求的增加,空间负荷预测越来越受到重视。

目前,空间负荷预测的方法主要有趋势法^[7]、多元变量法^[8]、用地仿真法^[9]以及负荷密度指标法^[10-12]。用地仿真法是一种自上而下的预测方法,首先将规划区以网格的形式划分为面积相同的元胞,然后以土地利用性质为原则对负荷总量预测的结果进行空间位置上的分配^[13-14]。负荷密度指标法是一种自下而上的空间负荷预测方法,首先按照负荷类型划分功能小区,通过预测功能小区的负荷密度,然后结合小区的面积计算出各小区的负荷值,进而得出总量负荷值^[15]。这种预测方法适用于未来土地使用较为明确的情况,我国的土地使用方案已经被规划部门基本制定,因此负荷密度指标法在我国应用较多。

文献[16]为了解决数据匮乏且难以处理的问题,提出一种基于最小二乘支持向量机的新型配电网空间负荷密度预测算法,引用了灰色关联度算法来筛选样本数据,采用混沌粒子群算法优化最小二

乘支持向量机参数。文献[17—18]提出一种考虑了分布式能源以及电动汽车接入的配电网空间负荷预测算法,但是分布式能源与电动汽车是一种复杂的非线性变化,文中只依靠支持向量机算法难以保证预测的精度与准确性问题。

针对上述情况,文中提出基于极限学习机(extreme learning machine, ELM)和负荷密度指标法的空间负荷预测算法,通过划分小区元胞,对负荷进行详细划分,构造精细化的负荷密度指标。基于模糊C均值(fuzzy C-means, FCM)算法进行样本数据的筛选,利用粒子群优化(particle swarm optimization, PSO)算法优化 ELM 模型参数,通过实例验证了所提算法和模型的有效性。

1 ELM 算法

人工神经网络在电力负荷预测中应用较多,且模型的泛化能力以及训练速度较快,但存在易陷入过拟合以及预测精度不高的问题。针对这些问题,采用 ELM 算法建立空间负荷预测模型,与传统神经网络相比,ELM 的泛化性能好,训练速度更快。在进行空间负荷预测时,主要分为 2 个步骤:(1) 选取训练样本数据代入模型,确定模型的参数;(2) 将要预测的小区特征代入模型,进行预测。

ELM 算法是一种单隐含层前馈神经网络学习算法^[19-22],该算法随机产生输入层与隐含层间的连接权重及隐含层神经元的阈值。算法的原理为:假设共有 N 个训练样本 (x_i, y_i) ,隐含层有 L 个神经元,输入层与隐含层之间的连接权重为 W ,隐含层与输出层之间的连接权重为 β ,激励函数为 $g(x)$ 。

收稿日期:2020-07-31;修回日期:2020-08-26

基金项目:国家自然科学基金资助项目(51777058)

故网络的输出 T 为:

$$T = (t_1, t_2, \dots, t_N) \quad (1)$$

$$t_j = \begin{pmatrix} t_{1j} \\ t_{2j} \\ \vdots \\ t_{mj} \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^L \beta_{i1} g(\mathbf{w}_i \mathbf{x}_j + b_i) \\ \sum_{i=1}^L \beta_{i2} g(\mathbf{w}_i \mathbf{x}_j + b_i) \\ \vdots \\ \sum_{i=1}^L \beta_{im} g(\mathbf{w}_i \mathbf{x}_j + b_i) \end{pmatrix} \quad j = 1, 2, \dots, N \quad (2)$$

式中: $\mathbf{w}_i = (w_{i1}, w_{i2}, \dots, w_{in})$ 为隐含层第 i 个神经元与各个输入层神经元间的连接权重; $\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{im})$ 为隐含层第 i 个神经元与各个输出层神经元间的连接权重; b_i 为隐含层第 i 个神经元的阈值。

根据式(1)和式(2)可得:

$$H\beta = T^T \quad (3)$$

式中: T^T 为矩阵 T 的转置; H 为神经网络的隐含层输出矩阵。 H 具体形式为:

$$H(\mathbf{w}_1, \dots, \mathbf{w}_L, b_1, \dots, b_L, \mathbf{x}_1, \dots, \mathbf{x}_N) = \begin{pmatrix} g(\mathbf{w}_1 \mathbf{x}_1 + b_1) & \dots & g(\mathbf{w}_L \mathbf{x}_1 + b_L) \\ \vdots & & \vdots \\ g(\mathbf{w}_1 \mathbf{x}_N + b_1) & \dots & g(\mathbf{w}_L \mathbf{x}_N + b_L) \end{pmatrix} \quad (4)$$

因此,整个神经网络的训练过程相当于寻找线性系统 $H\beta = T^T$ 的最小二乘解 $\hat{\beta}$:

$$\| \hat{H}\hat{\beta} - T^T \| = \min_{\beta} \| \hat{H}\beta - T^T \| \quad (5)$$

一般情况下,隐含层神经元要远远小于输入层神经元,故此时 H 是奇异的,可通过广义逆矩阵求解奇异矩阵的逆矩阵,即式(4)的解为:

$$\hat{\beta} = H^+ T^T \quad (6)$$

式中: H^+ 为隐含层输出矩阵 H 的 Moore-Penrose 广义逆矩阵。

2 FCM 算法

为了进一步提高空间负荷预测的精度,在进行仿真之前,需要对训练样本进行聚类分析。文中采用了使用较为广泛的 FCM 算法对训练样本进行聚类分析。FCM 算法是利用求解隶属度来确定每个样本所属程度的一种聚类算法,该算法具体求解步骤如下:

(1) 对于 N 个训练样本 $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, 将其划分为 C 类, $V = \{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_c\}$ 是 C 个聚类中心。实际问题中 C 一般是人为给定的,设定迭代停止条件 ε , 同时初始化聚类中心 $V = V_0$, 设置迭代计

数器 $t = 0$, 模糊权重指数 $m = 2$ 。

(2) 根据式(7)计算模糊隶属度矩阵 U 。

$$u_{ij} = 1 / \sum_{k=1}^c \left(\frac{d_{ij,t}}{d_{kj,t}} \right)^2 \quad (7)$$

$$\sum_{j=1}^c u_{ij} = 1 \quad (8)$$

式中: u_{ij} 为样本 \mathbf{x}_i 隶属于第 j 类的模糊隶属度, $0 \leq u_{ij} \leq 1$; d_{kj} 为样本 \mathbf{x}_i 到第 k 类聚类中心 \mathbf{v}_k 的欧式距离; d_{ij} 为样本 \mathbf{x}_i 到第 j 类聚类中心 \mathbf{v}_j 的欧式距离, 即:

$$d_{ij}^2 = \|\mathbf{x}_i - \mathbf{v}_j\|^2 = (\mathbf{x}_i - \mathbf{v}_j)^T (\mathbf{x}_i - \mathbf{v}_j) \quad (9)$$

按下式迭代聚类中心矩阵 $\mathbf{v}_{j,t+1}$:

$$\mathbf{v}_{j,t+1} = \frac{\sum_{i=1}^N (u_{ij,t}^2 \mathbf{x}_i)}{\sum_{i=1}^N u_{ij,t}^2} \quad (10)$$

若 $\|\mathbf{V}_t - \mathbf{V}_{t+1}\| < \varepsilon$, 则停止, 输出 U 和聚类中心矩阵 \mathbf{V} ; 否则令 $h = h + 1$, 转至步骤(2)。

个体则是根据隶属度矩阵每列最大元素位置判断个体所属类别, 给定输入样本, 计算其与每一类聚类中心的欧式距离, 取最小欧式距离的那一类数据作为回归模型的训练样本, 从而极大地提高空间负荷预测精度。

3 基于 PSO-ELM 的建模

文中采用 ELM 建立空间负荷预测模型, 利用 PSO 模型的参数提高负荷预测的精度。PSO 的原理如下:

PSO 算法中每个粒子就是 d 搜索空间中的一个潜在解, 记为 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{id})$ 。将 \mathbf{X}_i 代入目标函数计算其适应度值, 则粒子的“好坏”可用适应度值来评判。第 i 个粒子的速度则是用一个 d 维向量表示, 记为 $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{id})$ 。在迭代的过程中, 第 i 个粒子搜索到的最佳位置记为 $\mathbf{P}_{id} = (p_{i1}, p_{i2}, \dots, p_{id})$, 所有粒子搜索到的最佳位置记为 $\mathbf{P}_{gd} = (p_{g1}, p_{g2}, \dots, p_{gd})$ 。粒子根据下式更新速度和位置:

$$\begin{cases} \mathbf{V}_{id,k+1} = \omega \mathbf{V}_{id,k} + c_1 r_1 (\mathbf{P}_{id,k} - \mathbf{X}_{id,k}) + \\ \quad c_2 r_2 (\mathbf{P}_{gd,k} - \mathbf{X}_{id,k}) \\ \mathbf{X}_{id,k+1} = \mathbf{X}_{id,k} + \mathbf{V}_{id,k+1} \end{cases} \quad (11)$$

式中: $i = 1, 2, \dots, m$; k 为迭代次数; ω 为惯性权重因子; 非负常数 c_1, c_2 为学习因子; r_1, r_2 为 $(0, 1)$ 间的随机数。

考虑到粒子在搜索的过程中是非线性变化的, 因此采用非线性凹函数递减惯性权重方式会获得更好的效果。

$$\omega = (\omega_{\max} - \omega_{\min}) \left(\frac{k}{T_{\max}} \right)^2 + (\omega_{\min} - \omega_{\max}) \frac{2k}{T_{\max}} + \omega_{\max} \quad (12)$$

式中: T_{\max} 为最大迭代次数; ω_{\max} , ω_{\min} 分别为惯性权重的最大、最小值,通常 ω_{\max} 取 0.9, ω_{\min} 取 0.4。

由上文对 ELM 的介绍可知,输入层神经元个数、隐含层神经元个数以及输出层神经元个数预先设定,模型未知的参数变量是输入层与隐含层之间的连接权重 W 和隐含层神经元阈值 b ,激励函数采用 Sigmoid 函数,目标函数是使式(5)最小。

因此,PSO 优化的过程,就是找到使得目标函数最小的 ELM 最优的输入层与隐含层之间的连接权重 W 和隐含层神经元阈值 b 的过程。通过粒子群的不断迭代,将模型的目标函数作为粒子群的评价指标,最终满足精度要求后输出模型的最优参数。

4 空间负荷预测步骤

采用负荷密度指标法进行空间负荷预测最重要的步骤是建立精细化的负荷密度指标体系,利用 FCM 算法对样本数据聚类分析;然后采用文中所提的 PSO-ELM 模型预测,将负荷密度作为模型的输出,结合小区的面积求出小区的负荷大小。空间负荷预测的具体步骤如下。

(1) 构建精细化的负荷密度指标体系。文中将电力负荷根据用电性质分为以下 10 类:工业负荷,居民住宅负荷,行政办公负荷,商业负荷,文化娱乐负荷,研发负荷,教育、医疗、体育等公共设施负荷,市政设施负荷,仓储物流负荷,绿化、广场及道路负荷。分析搜集到的数据可知,每一类负荷从最大值到最小值的跨度较大,有必要对每一类负荷再进行细分,见图 1。等级 1 到等级 T 表示将每一类负荷再细分为 T 类,通过上文提到的 FCM 算法实现。




图 1 负荷密度指标体系

Fig.1 Load density index system

(2) 确定训练样本。利用 FCM 聚类算法,将每类负荷再细分为几个类型。以居民住宅为例,将这一类负荷分为再 5 种类型,求出每一类的聚类中心矩阵。对于给定的待预测地的特性指标,求出与 5 个聚类中心的欧式距离,取距离最小的那一类样本

作为训练样本。

(3) 建立回归模型。文中采用的回归模型是基于 PSO 的 ELM 算法,将选好的训练样本代入模型,影响因素作为模型的输入,负荷密度作为模型的输出。训练好模型后,代入待预测地的特性指标,即可得出待预测地未来年的负荷密度。

(4) 进行空间负荷预测。将求出的各类负荷密度 ρ_i 乘以小区的面积 S_i 即可得每个小区的负荷值 W_i ,将小区负荷相加并进行修正即可得到规划区的总量负荷。

$$W = p_i \sum_{i=1}^N \rho_i S_i \quad (13)$$

式中: p_i 为小区的同时系数; N 为小区个数; W 为预测的空间负荷值。

根据以上 4 个步骤,基于 ELM 和负荷密度指标法的空间负荷预测流程如图 2 所示。

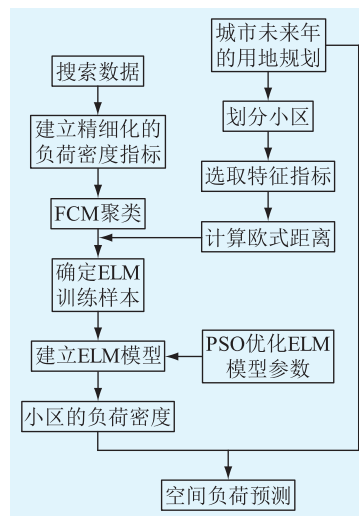


图 2 空间负荷预测总流程

Fig.2 General flow chart of space load prediction

5 算例分析

以居民住宅负荷为例,搜集上海市某规划地小区居民负荷数据样本,参考负荷密度指标体系可知,影响居民住宅负荷的主要因素为:人口密度 A_1 ,人均收入 A_2 ,人均用电量 A_3 ,煤电价格比增长率 A_4 及回归模型的输出负荷密度 C 。搜集到的 128 个居民住宅样本数据如表 1 所示。

考虑到居民住宅负荷密度大小跨度较大,因此将其再细分为 5 类,使用 FCM 算法将其聚类,每一类的聚类中心以及样本数如表 2 所示。

已知预测小区影响因素的数值为: $A_1 = 26\ 431$, $A_2 = 1\ 576.3$, $A_3 = 751$, $A_4 = 1.379$,对数据进行归一化处理,计算该样本与上述 5 类样本距离中心矩阵的

表1 样本数据
Table 1 Sample data

序号	$A_1 /$ (人·km ⁻²)	$A_2 /$ 元	$A_3 /$ (kW·h)	A_4	$C /$ (MW·km ⁻²)
1	25 701	1 000.3	834	1.313	20.2
2	16 600	1 222.7	1 019	2.263	2.54
3	17 649	843.8	620	1.483	5.138
4	23 189	1 643.8	513	1.424	11.246
5	21 579	3 138.5	1203	0.792	21.456
6	30 189	1 643.9	679	1.249	14.167
7	28 569	1 356.5	439	1.432	8.936
8	24 916	1 976.5	694	1.249	9.186
⋮	⋮	⋮	⋮	⋮	⋮
128	20 349	3 648.9	1 234	1.034	16.792

表2 各类负荷的聚类中心矩阵和样本数目

Table 2 Cluster center matrix and sample number of each load

序号	样本 个数	$A_1 /$ (人·km ⁻²)	$A_2 /$ 元	$A_3 /$ (kW·h)	A_4
1	28	25 872	1 728.1	756	1.342
2	23	17 994	869.3	693	2.525
3	27	21 130	1 769.9	666	1.543
4	21	21 982	3 593.7	1 144	1.010
5	29	26 767	1 458.8	531	1.412

欧式距离,采用标量值表示,记为 $d = \{0.048\ 7, 0.657\ 3, 0.313\ 2, 0.685\ 4, 0.238\ 6\}$ 。计算结果表明,预测小区与第一类负荷的欧式距离最小,故选取第一类负荷的28个样本数据作为训练样本训练极限学习机回归模型。文中使用 Matlab 建立 ELM 模型,利用 PSO 算法来对 ELM 的参数进行优化。

采用绝对误差 E_{AE} 和相对误差 E_{RE} 作为评价指标:

$$E_{AE} = |C - C'| \quad (14)$$

$$E_{RE} = \frac{|C - C'|}{C} \times 100\% \quad (15)$$

为了验证文中所提算法的有效性,分别对未采用 FCM 算法、未采用 PSO 算法与文中所提算法进行比较,预测结果如表 3 所示。

表3 3种算法的预测结果比较
Table 3 Comparison of prediction results of three algorithms

算法	$E_{AE} /$ (MW·km ⁻²)	$E_{RE} /$ %
未采用 FCM	0.717	8.79
未采用 PSO	0.494	6.06
PSO-ELM	0.089	1.09

由表 3 可知,PSO-ELM 算法精度最高,且误差满足实际的工程要求。FCM 聚类算法只是对数据

进行处理,没有改变模型本身的复杂性。PSO 算法优化耗时较短,因此引入 PSO 算法并不会影响模型的计算速度。

对于上述小区的负荷大小,可通过负荷密度乘以小区面积获得,对于规划地的空间负荷总量的预测则需要预测出每个小区的负荷密度大小,然后求取每个小区的负荷大小。表 4 给出了另外 3 个小区的特性指标,采用上述的 PSO-ELM 算法预测负荷密度大小。

表4 预测结果分析

Table 4 Analysis of prediction results

序号	$A_1 /$ (人·km ⁻²)	$A_2 /$ 元	$A_3 /$ (kW·h)	A_4	实际值	预测值
1	21 687	1 643.9	649	1.219	12.649	12.755
2	23 153	1 956.1	618	1.467	15.146	15.036
3	13 486	894.6	513	-1.039	21.139	21.024

按照此方法,求出规划区内所有的小区负荷密度,即可得到居民区空间负荷分布规律。文中在求取总负荷时,参考统计数据,设置同时系数为 0.9,将每个小区负荷叠加修正即可得到总的空间负荷大小。

6 结语

文中所采用的空间负荷预测的算法是基于我国土地开发的实际情况提出的,我国土地的规划主要由政府决定,土地的使用性质明确,故可采用负荷密度指标法。文中采用的回归模型是 ELM,该算法属于神经网络范畴,具有运行速度快、自学习能力强等优点。但是该算法也容易陷入过拟合状态,因此采用了改进的 PSO 算法来对其参数进行寻优处理。文中提出的负荷密度指标法意在建立精细化的负荷密度指标体系,采用 FCM 算法对每一类负荷进行再细化的聚类,为 ELM 提供训练样本,提高预测的精度。仿真试验证明,该算法具有很强的实用性。

本文得到国网上海市电力公司“基于智能算法的配电网空间负荷聚类及预测研究”(5209701800-0G)资助,谨此致谢!

参考文献:

- [1] WILLIS H L, NORTH COTE-GREE J E D. Spatial electric load forecasting: a tutorial review [J]. Proceedings of the IEEE, 1983, 71(2): 232-253.
- [2] 周潮,邢文洋,李宇龙. 电力系统负荷预测方法综述[J]. 电源学报, 2012, 10(6): 32-39.
ZHOU Chao, XING Wenyang, LI Yulong. Summarization on load forecasting method of electrical power system [J]. Journal of

- Power Supply, 2012, 10(6): 32-39.
- [3] 丁晓, 孙虹, 郑海雁, 等. 基于配用电大数据的短期负荷预测[J]. 电力工程技术, 2018, 37(3): 21-27.
DING Xiao, SUN Hong, ZHENG Haiyan, et al. Distribution and consumption big data based short-term load forecasting[J]. Electric Power Engineering Technology, 2018, 37(3): 21-27.
- [4] 马梦冬, 彭道刚, 王丹豪. 基于EEMD-LSTM的区域能源短期负荷预测[J]. 浙江电力, 2020, 39(4): 29-35.
MA Mengdong, PENG Daogang, WANG Danhao. Short-term load forecasting based on EEMD-LSTM for regional energy[J]. Zhejiang Electric Power, 2020, 39(4): 29-35.
- [5] 王啸峰, 苏慧玲, 宋天立, 等. 基于负荷细分的差异化用户基线负荷预测[J]. 电力工程技术, 2018, 37(6): 33-38.
WANG Xiaofeng, SU Huilin, SONG Tianli, et al. Differential customer baseline load forecasting based on load subdivision[J]. Electric Power Engineering Technology, 2018, 37(6): 33-38.
- [6] 刘伟, 张锐锋, 彭道刚. 基于K-Adaboost数据挖掘的配电网负荷预测[J]. 浙江电力, 2019, 38(1): 104-110.
LIU Wei, ZHANG Ruifeng, PENG Daogang. Load forecasting of distribution network based on K-Adaboost data mining[J]. Zhejiang Electric Power, 2019, 38(1): 104-110.
- [7] 胡怡霜, 夏翔, 丁一, 等. 基于因子和趋势分析反馈的多元回归负荷预测[J]. 电力需求侧管理, 2018, 20(6): 22-25, 35.
HU Yishuang, XIA Xiang, DING Yi, et al. A multivariate regression load forecasting algorithm based on factor and tendency analysis feedback[J]. Power Demand Side Management, 2018, 20(6): 22-25, 35.
- [8] 肖白, 周潮, 穆钢. 空间电力负荷预测方法综述与展望[J]. 中国电机工程学报, 2013, 33(25): 78-92, 14.
XIAO Bai, ZHOU Chao, MU Gang. Review and prospect of the spatial load forecasting methods[J]. Proceedings of the CSEE, 2013, 33(25): 78-92, 14.
- [9] 马星河, 娄晨阳, 赵军营, 等. 基于人工蜂群算法的空间负荷预测[J]. 电力系统及其自动化学报, 2018, 30(8): 102-107.
MA Xinghe, LOU Chenyang, ZHAO Junying, et al. Spatial load forecasting based on artificial bee colony algorithm[J]. Proceedings of the CSU-EPSSA, 2018, 30(8): 102-107.
- [10] 杨军胜, 彭石, 王承民, 等. 基于城市用地性质的配网空间负荷预测研究[J]. 电测与仪表, 2018, 55(11): 30-34.
YANG Junsheng, PENG Shi, WANG Chengmin, et al. Research of spatial load forecasting in distribution network based on grid partition of urban land-use property[J]. Electrical Measurement & Instrumentation, 2018, 55(11): 30-34.
- [11] 肖白, 杨欣桐, 田莉, 等. 计及元胞发展程度的空间负荷预测方法[J]. 电力系统自动化, 2018, 42(1): 61-67.
XIAO Bai, YANG Xintong, TIAN Li, et al. Spatial load forecasting method based on development degree of cell[J]. Automation of Electric Power Systems, 2018, 42(1): 61-67.
- [12] 李勤超, 周立中, 赵艳龙, 等. 基于分布式光伏典型日曲线的统调负荷预测方法[J]. 浙江电力, 2019, 38(6): 113-117.
LI Qinchao, ZHOU Lizhong, ZHAO Yanlong, et al. A unified dispatch load forecasting method based on the typical daily load curve of distributed PV power[J]. Zhejiang Electric Power, 2019, 38(6): 113-117.
- [13] 曹敏, 李文云, 钱详华, 等. 基于分类识别深度置信网络的电力负荷预测算法[J]. 电力需求侧管理, 2020, 22(2): 44-49.
CAO Min, LI Wenyun, QIAN Xianghua, et al. Power load forecasting algorithm based on classified identification deep belief network[J]. Power Demand Side Management, 2020, 22(2): 44-49.
- [14] 雷绍兰, 孙才新, 周淦, 等. 模糊粗糙集理论在空间电力负荷预测中的应用[J]. 电网技术, 2005, 29(9): 26-30.
LEI Shaolan, SUN Caixin, ZHOU Quan, et al. Application of fuzzy rough set theory in spatial load forecasting[J]. Power System Technology, 2005, 29(9): 26-30.
- [15] 周淦, 孙威, 任海军, 等. 基于最小二乘向量机和负荷密度指标法的配电网空间负荷预测[J]. 电网技术, 2011, 35(1): 66-71.
ZHOU Quan, SUN Wei, REN Haijun, et al. Spatial load forecasting of distribution network based on least squares support vector machine and load density index system[J]. Power System Technology, 2011, 35(1): 66-71.
- [16] 唐玮, 钟士元, 舒娇, 等. 基于GRA-LSSVM的配电网空间负荷预测方法研究[J]. 电力系统保护与控制, 2018, 46(24): 76-82.
TANG Wei, ZHONG Shiyuan, SHU Jiao, et al. Research on spatial load forecasting of distribution network based on GRA-LSSVM method[J]. Power System Protection and Control, 2018, 46(24): 76-82.
- [17] 蒯圣宇, 田佳, 台德群, 等. 计及分布式能源与电动汽车接入的空间负荷预测[J]. 电力需求侧管理, 2019, 21(1): 47-51.
KUAI Shengyu, TIAN Jia, TAI Dequn, et al. Space load forecasting considering distributed energy and electric vehicles[J]. Power Demand Side Management, 2019, 21(1): 47-51.
- [18] 刘志凯, 郑文悦, 李海弘, 等. 多接入电动汽车充电桩对电网谐波的影响研究[J]. 浙江电力, 2020, 39(2): 77-82.
LIU Zhikai, ZHENG Wenyue, LI Haihong, et al. Study on the impact of electric vehicle charging pole with multiple access points on power grid harmonic[J]. Zhejiang Electric Power, 2020, 39(2): 77-82.
- [19] 张小斐, 耿俊成, 万迪明, 等. 基于大数据平台的配电网负荷预测关键技术[J]. 电力需求侧管理, 2020, 22(4): 25-30.
ZHANG Xiaofei, GENG Juncheng, WAN Diming, et al. Key technologies of load forecasting in distribution network based on big data platform[J]. Power Demand Side Management, 2020, 22(4): 25-30.
- [20] 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): 154-157.
LI Jie, JIN Mengyu, MA Shihao. Short-term power load prediction with extreme learning machine based on particle swarm algorithm[J]. Manufacturing Automation, 2019, 41(1): 154-

- 157.
- [21] 殷豪,董朕,孟安波. 基于结合混沌纵横交叉的粒子群算法优化极限学习机的短期负荷预测[J]. 计算机应用研究, 2018,35(7):2088-2091.
- YIN Hao,DONG Zhen,MENG Anbo. Short-term load forecasting based on extreme learning machine optimized by particle swarm optimization integrated with chaotic crisscross optimization[J]. Application Research of Computers, 2018, 35 (7) : 2088-2091.
- [22] 符杨,朱兰,曹家麟. 基于模糊贴近度理论的负荷密度指标求取新方法[J]. 电力系统自动化,2007(19):46-49,90.
- FU Yang,ZHU Lan,CAO Jialin. A new method to obtain load

density according to the theory of fuzzy approach degree[J]. Automation of Electric Power Systems,2007(19):46-49,90.

作者简介:



邵宇鹰

邵宇鹰(1977),男,博士,高级工程师,从事新能源、状态监测相关工作(E-mail:329409-599@qq.com);

彭鹏(1987),女,博士,工程师,从事电力系统相关工作;

张秋桥(1995),男,硕士,工程师,从事基于人工智能算法的空间负荷预测相关工作。

Spatial load forecasting based on ELM and clustering algorithm

SHAO Yuying¹, PENG Peng¹, ZHANG Qiuqiao², WANG Bing²

(1. State Grid Shanghai Electric Power Company, Shanghai 200122, China;

2. Nanjing Kunta Information Technology Co., Ltd., Nanjing 211100, China;

3. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: Spatial load forecasting is of great significance to the planning and construction of distribution network. In order to improve the accuracy of spatial load forecasting of distribution network, based on extreme learning machine, a spatial load forecasting algorithm is put forward in this paper. The parameters of the particle swarm optimization mode are adopted. Firstly, the load is classified according to the property of land use. Then, the FCM algorithm is used to carry out cluster analysis for each type of load and a refined load density index system is established. Next, the training samples are carried out with the extreme learning machine to improve the accuracy of prediction, which selected according to the characteristic indexes of the plots to be predicted. The example is simulated by the search data. By comparing with the relative error without the introduction of FCM algorithm, the relative error without the introduction of PSO optimization algorithm and the relative error with the adoption of PSO-ELM algorithm, it can be obtained that the PSO-ELM algorithm proposed in this paper has a high accuracy and meets the requirements of practical engineering.

Keywords: spatial load forecasting; load density index method; particle swarm optimization (PSO) algorithm; extreme learning machine (ELM); fuzzy C-means (FCM) algorithm

(编辑 钱悦)