

基于改进 K-Means 聚类与 Elman 神经网络的 负荷集成预测

高彦超¹, 郭峰¹, 祝敬伟¹, 路昂¹, 顾舒(通讯作者)¹, 安琪儿¹, 张爱福¹, 乔善和¹, 燕蕾²

1. 北京华电天仁电力控制技术有限公司, 北京市海淀区西四环中路 16 号院 100039; 2. 华北电力大学, 北京市昌平区回龙观 102206

Load Integrated Forecasting Based on Improved K-means Clustering and Elman Neural Network

Gao Yanchao¹, Guofeng¹, Zhu Jingwei¹, Lu Ang¹, Gu Shu¹, An Qier¹, Zhang Aifu¹, Qiao Shanhe¹, Yan Lei²

1. Beijing Huadian Tianren Electric Power Control Technology Co., Ltd., Haidian District, Beijing, 100039; 2. North China Electric Power University, Changping District, Beijing, 102206;

摘要: 利用大规模负荷数据进行总量负荷预测, 预测全国或某地区的电力需求, 是负荷预测在中长期电力交易市场和现货电力交易市场中的重要应用。本文提出一种基于改进 K-Means 聚类与 Elman 神经网络的负荷集成预测, 首先提出对收集到的区域用户添加城市标签, 然后对同一城市的用户负荷进行聚类分析, 之后对同类用户建立考虑气象因素的神经网络预测模型进行预测, 最后将每类的预测结果汇总得到城市甚至地区的总量负荷。本文以某区域一个城市 182 个用户负荷为例进行算例仿真, 结果证明本文方法可大大提高负荷预测精度, 实现高质量的负荷集成预测。

关键词: 负荷预测; K-Means 聚类; Elman 神经网络

ABSTRACT: It is an important application of load forecasting to predict the power demand of the whole country or a certain region by using large scale load data. A load integrated forecasting method based on improved K-Means clustering and Elman neural network is proposed in this paper. Firstly, it is proposed to add city labels to the collected regional users, and then clustering analysis is carried out on the load of users in the same city, then, a neural network prediction model is established for the same users considering meteorological factors and finally the forecast results of each category are summarized to obtain the total load of the city or even region. In this paper, 182 sets of user load in a city in a certain region are taken as examples for numerical simulation. The results show that the method proposed in this paper can greatly improve the accuracy of load prediction and achieve high-quality load integrated prediction.

KEY WORD: load forecasting; K - Means clustering; Elman neural network

0 引言

电能是实时的、不能大量储存的, 在电力系统中, 发、输、配电与用电之间保持动态平衡, 才能确保电网的安全运行。随着经济的发展, 人们越来越依赖电力, 电力负荷的需求越来越高, 对电力供给提出了更高的要求^[1]。电力负荷预测是对将来一段时间的负荷进行预估, 根据负荷预测结果, 可以辅助中长期交易或现货交易中发售电两侧的各项切实业务环节, 为竞价辅助决策、

购售电交易决策与评估、售电运营与决策等提供数据处理分析与决策辅助支撑。随着大数据技术的快速发展和广泛运用, 用户负荷数据的采集、处理和特性分析越来越重要, 对于海量历史负荷数据, 如何对其负荷特性进行分析并合理的应用于负荷预测中是当前探讨的关键问题^[2-3]。

利用大规模负荷数据进行总量负荷预测, 预测全国或某地区未来某时段内的电力需求, 进而分析地区经济发展趋势, 是当前数据挖掘的重要

应用。一般有两种预测策略，第一种是在汇总某区域内所有用户的总量负荷的基础上进行预测；第二种是在预测某区域内每个用户负荷的基础上，汇总所有预测结果。前者在应用中较为广泛，但没有发挥大规模用户负荷数据的价值，后者的预测颗粒度虽然很细，但用户用电行为的随机性亦会导致过度拟合的情况，从而无法得到理想的结果。

因此有学者提出对大规模用户的负荷数据进行聚类分析后再预测。文献^[4]首次提出了面向居民用户的基于聚类算法的集成预测策略，并通过算例证明了该方法可以有效提高大规模居民用户的短期负荷预测精度；文献^[5]按照行业特性对用户进行聚类分析并以五金行业为例验证了该方法对工商业用户短期负荷预测精度的提高；文献^[6-8]着重于对相似日和训练、测试数据的处理，通过聚类提取用户负荷曲线特征，在此基础上对日期进行聚类。

神经网络是20世纪80年代以来人工智能领域的研究热点^[9-11]。经典的反向传播神经网络(BPNN)在许多分类和回归问题中显示出优越性；Elman神经网络是神经网络的一种，在BP网络基本结构的基础上，Elman神经网络增加了一个递归层，使其具有记忆的功能，从而具有了适用时变特性的能力，适合于离散时间序列问题的预测^[12-14]。

综上，聚类分析和神经网络在负荷集成预测中的组合应用研究较少，而两种方法都是负荷预测中的研究重点，因此，本文提出一种基于改进K-Means聚类与Elman神经网络的负荷集成预测，首先提出对收集到的区域用户负荷添加城市标签，然后对同一城市的用户负荷进行聚类分析，挖掘不同用户数据之间的关联性，得到同类用户的负荷总量，之后考虑城市气象因素对同类用户建立神经网络预测模型进行预测，最后将每类的预测结果汇总得到城市甚至地区的总量负荷。

1 改进的 K-Means 聚类算法

K-Means 聚类算法（也可称为 k 均值聚类算法）是划分方法中的经典算法之一，该算法操作简单，运算速度快，在大规模数据聚类中广泛使

用，因此本文采用该算法进行聚类分析。

K-Means 聚类算法属于基于距离的聚类算法，采用距离作为相似性指标，从而将数据分为 k 类，各类的中心用聚类中心来描述。取欧几里得距离作为相似性指标进行度量，公式如下：

$$\sqrt{\sum_{i=1}^n (x_i - k_i)^2} \quad (1)$$

式中： x_i 和 k_i 是 n 维欧几里得空间中的任意两个点。

该算法的基本流程为：

- (1) 初始化，随机选择 k 个对象作为聚类中心；
- (2) 对剩余的对象，根据其与其初始类中心的距离，将其归于距离最近的类中；
- (3) 求解各类的平均向量，并作为新的聚类中心；
- (4) 聚类目标为各类的平方误差总和 (SSE) 最小，反复迭代第 2、3 步，直至 SSE 收敛或达到迭代上限。

K-Means 聚类算法需要事先指定聚类数 k ，本文对该算法的这一问题进行解决。一种方法是人工指定，而往往人工指定聚类数存在随机性和不稳定性，需要多次测试找到最优聚类；另一种思路是采用聚类有效性检验^[15]，利用聚类有效性指标确定合适的聚类数目，从而为大规模数据的聚类得到最佳聚类数。

聚类有效性的评价方法可分为三种：内部评价法、外部评价法和相对评价法。对于内部评价法，通常包括三类，即基于数据集模糊划分法、基于数据集样本几何结构法和基于数据集统计信息法。基于数据集样本几何结构法利用数据集本身和聚类结果的统计特征来评价一个聚类算法的结果，并选出最佳聚类数，指标包括 Calinski-Harabasz(CH) 指标，Davies-Bouldin(DB) 指标等。

本文采用 CH 指标确定最佳聚类数，对 K-Means 聚类算法进行改进。CH 指标通过类内协方差矩阵描述聚类紧密度，类间离差矩阵描述聚类分离度，指标定义为（ trW 表示矩阵 W 的迹）：

$$CH(k) = \frac{trB(k)/(k-1)}{trW(k)/(n-k)} \quad (2)$$

式中： n 表示聚类的数目， k 表示当前类， tr 表示

矩阵的迹， $B^{(k)}$ 为类间的协方差矩阵， $W^{(k)}$ 表示类内的协方差矩阵。CH 指标值越大，则可认为聚类效果越好。

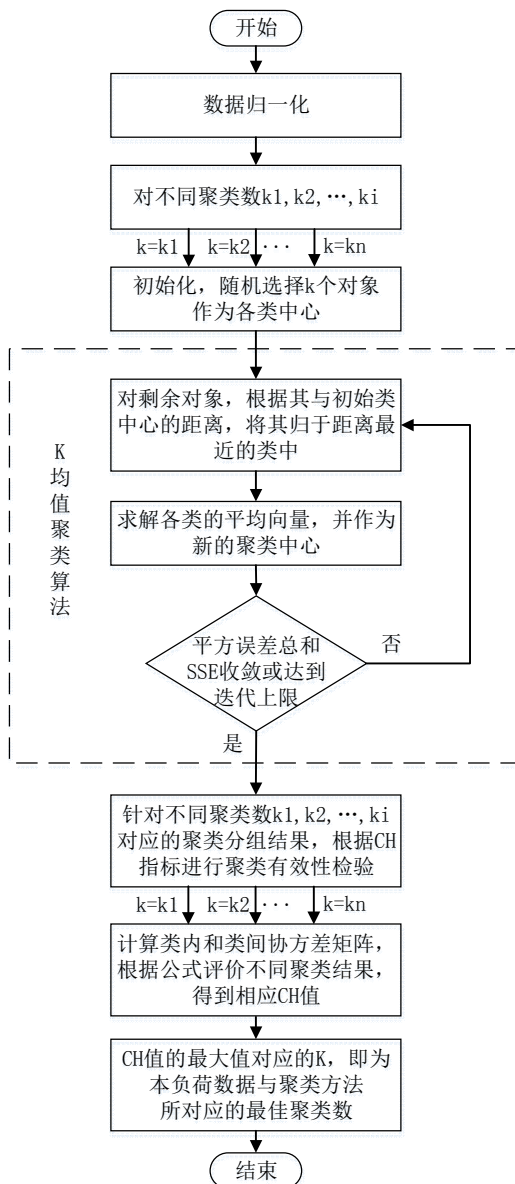


图 1 改进的 K-Means 聚类算法流程图

Fig. 1 Flow chart of improved K-Means clustering algorithm

2 考虑气象因素的 Elman 神经网络负荷集成预测模型

2.1 数据清洗

高质量的数据对于提高预测效果具有重要意义。目标用户的历史数据通常来自采集终端或系统，当出现电能表故障、终端故障、外部环境干扰或数据库故障等异常情况时，采集到的数据往往不完整，存在错误数据、重复数据、

空数据等，因此，首先应对历史数据进行数据清洗，剔除错误、不一致数据及修正数据，以确保数据的可信性、可用性^[16]。

针对每个用户的每条负荷数据，本文主要针对其存在的数据缺失进行数据补全。通常样本数据中缺失值不止一个，往往是多变量缺失，本文主要采用 EM 插补^[17]的方法，用数据的条件期望替代缺失值。

2.2 气象影响因素分析

为了充分建模，往往会考虑众多因素，这些涉及的因素称为变量。每个变量不同程度地反映了所研究问题的某些信息，且变量之间存在一定相关性。负荷预测模型中，过多的变量将导致计算复杂性的增加，而变量间的相关性也使得数据集规模过大，冗余度上升，因此，对变量进行分析并选择主要变量，可以简化预测模型，提高模型的计算速度和准确性。

历史数据的准确性和完整性都会对负荷预测产生较大影响，良好的历史数据往往会大幅度提高预测的精度，一般而言，历史数据量越大，预测过程完善程度越高，预测结果越精确。其次，电力系统中存在着多种多样的对气象因素敏感的负荷，如夏季的风扇、空调系统、用于灌溉的农用设备以及冬季的取暖设备等，因此，往往气象因素是需要考虑的影响因素，影响负荷预测的气象因素有气温、降水和风速等^[18]。

因此，本文通过主成分分析、相关分析方法^[19-20]，提取出主要气象影响因素，并加上历史负荷数据，构成神经网络模型的输入数据。

2.3 Elman 神经网络算法




图 2 Elman 神经网络架构图

Fig. 2 Elman neural network architecture diagram

Elman 神经网络，是一个具有动态学习特性的反馈网络，它在人工神经网络结构的基础上，增加了一个承接层，将前一时刻的隐含层

状态和当前时刻的输入共同作为隐含层输入，相当于一步延时算子，使整个网络具备动态记忆的能力，提高了网络稳定性和计算能力。与人工神经网络方法相比，该网络可以不仅减少了输入变量的数量，而且改进了预测的准确性。

Elman 神经网络的架构如上图所示：

图 1 中，假设该网络包含一个 n 维输入层，输入向量表示为 $\mu(t) = \{\mu(1), \dots, \mu(n)\}$ ； r 维隐含层，隐含层向量表示为 $x(t) = \{x(1), \dots, x(r)\}$ ； m 维输出层，输出向量表示为 $y(t) = \{y(1), \dots, y(m)\}$ ； r 维反馈状态向量，表示为 $x'(t) = \{x'(1), \dots, x'(r)\}$ ； ω_1 、 ω_2 、 ω_3 分别表示输入层到隐藏层、隐含层到输出层、承接层到隐藏层的连接权值， $f^{(\cdot)}$ 表示隐含层神经元的传递函数，常采用 S 函数； $g^{(\cdot)}$ 表示输出层神经元的传递函数。

则该网络的数学表达式表示如下：

隐含层输出为：

$$x(t) = f(\omega_3 x'(t) + \omega_1 \mu(t)) \quad (3)$$

式中： $x'(t) = x(t-1)$ ，表示承接层对前一时刻的隐含层状态的记忆。

输出层的输出为：

$$y(t) = g(\omega_2 x(t)) \quad (4)$$

本文首先对负荷数据进行数据清洗，得到完整数据样本集，然后以历史负荷数据和主要气象因素构建神经网络输入矩阵，利用 Elman 神经网络预测模型对负荷进行预测。

2.4 预测评价指标

对预测结果进行误差分析，是评价预测效果的主要手段，也是必不可少的环节，预测误差评价指标主要包括均方误差（Mean Squared Error, MSE）、平均绝对误差（Mean Absolute Error）和平均相对误差（Mean Absolute Percentage Error, MAPE）等。本文采用 MSE 和 MAPE 作为预测评价指标，分别表示为：

$$MSE = \frac{1}{N} \sum_{t=1}^N (L_{t\text{预}} - L_{t\text{实}})^2 \quad (5)$$

$$MAPE = \frac{100}{N} \sum_{t=1}^N \left| \frac{L_{t\text{预}} - L_{t\text{实}}}{L_{t\text{实}}} \right| \times 100\% \quad (6)$$

式中： N 为测试集的样本个数， $L_{t\text{预}}$ 为 t 时刻的负荷预测值， $L_{t\text{实}}$ 为 t 时刻的负荷实际值。

本文负荷集成预测的流程如下图所示：

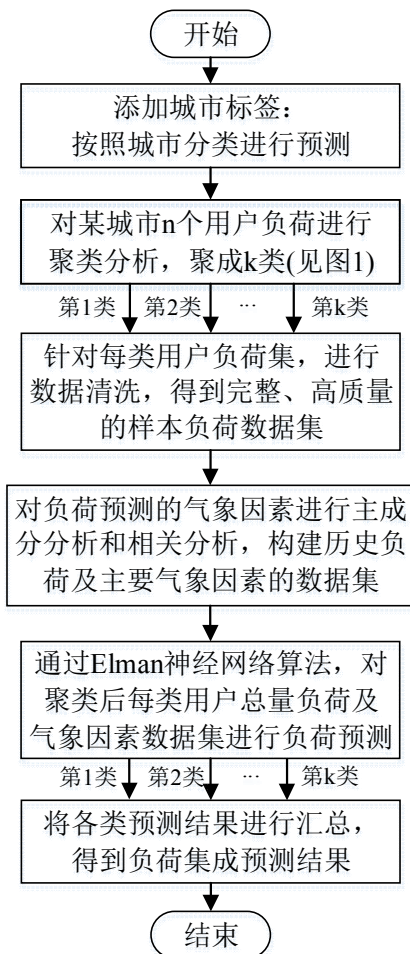


图 3 负荷集成预测流程图

Fig. 3 Flow chart of load integrated forecasting

3 算例分析

3.1 数据介绍

本文以收集到的某区域 583 个用户的负荷数据为例进行算例仿真与分析，该数据包含了 2019 年 1 月 1 日至 5 月 16 日共 136 天内的完整用电数据，采样频率为一小时，原始数据为 583×136 的矩阵。首先，按照城市标签，对收集到的不同电力用户的负荷数据进行分类；然后，以某城市 182 个用户为例，对该城市用户负荷进行聚类分析，依据负荷曲线特征，将用户分为 k 类；其次，对得到的 k 类用户负荷分别进行负荷量汇总，进行数据清洗后，以城市用户历史负荷和主要气象影响因素构建 Elman 神经网络的输入数据集，分别进行预测，然后将 k 类预测结果汇总得到负荷集成预测结果，并与总量集成预测的效果进行对比。本文采用 MATLAB 进行编程实现负荷集成预测，Elman 神经网络函数中，隐含层和输出层的传递

函数分别采取 tansig 和 logsig 函数, 网络训练次数设置为 50000 次, 训练目标设置为 0.00001, 学习率设置为 0.1。

3.2 聚类分析

以某城市 182 个用户为例, 对该城市用户负荷进行 K-means 聚类分析。本文选取 2019 年 4 月 16 日为典型日, 并考虑到月负荷水平对本次预测的影响, 以 24 个分时负荷数据和月负荷均值、月负荷标准差、月负荷中位数作为负荷特征, 构建 182×27 的矩阵。由于负荷水平不一致, 首先对负荷进行标准化处理。依据负荷曲线特征和 CH 指标评价, 得到这些用户的最佳聚类数为 4, 如下图 4 所示。




图 4 最佳聚类数的确定

Fig. 4 Determination of the optimal number of clusters




图 5 聚类后的典型负荷特征曲线

Fig.5 Typical load characteristic curve after clustering

因此本文将该城市内 182 个用户聚为 4 类, 聚类后的典型负荷特征曲线如图 5 所示。第一类用户用电高峰期在上午 8-11 点和下午 1-5 点, 其他时间段用电较少, 属于白天用电类型; 第二类用户用电特性与第一类相反, 在晚上 10 点-早上

7 点用电水平高于白天用电, 用电高峰期在电价低谷时段, 属于夜间用电类型; 第三类用户用电水平远高于前两类, 用电峰谷大, 属于夜间用电类型, 且晚间负荷水平比起白天明显降低, 避开了晚上的用电高峰期; 第四类用户全天用电水平平稳, 变化较小, 只有白天的用电水平稍微起伏。

3.3 负荷集成预测分析

3.3.1 主要气象影响因素分析

气象因素对负荷的影响已随着用电量的增加而越来越显著, 主要包括温度、相对湿度、降水量、风级等。本文根据收集到的用户所在城市的气象数据, 进行主成分分析和相关性分析, 由下表 1 所示, 该数据集的 $KMO=0.565$, 大于阈值 0.5, 且显著性 $\text{Sig.} < 0.05$, 说明各变量间具有相关性, 主成分分析和相关性分析是有效的。

表 1 KMO 和巴特利特检验表

Table 1 KMO and Bartlett checklist	
KMO 和巴特利特检验	
KMO 取样适切性量数	0.565
巴特利特球形度检验: 显著性	0.000

表 2 相关性矩阵

Table 2 Correlation matrix					
	温度	相对湿度	降水量	风级	负荷
温度	1.000	0.386	0.699	0.358	0.788
相对湿度	0.386	1.000	0.021	0.223	0.577
降水量	0.699	0.021	1.000	0.231	0.526
风级	0.358	0.223	0.231	1.000	0.151
负荷	0.788	0.577	0.526	0.151	1.000

由表 2 相关性矩阵可看出, 影响负荷的气象因素中, 风级的相关性只有 0.151, 说明风力对负荷预测的影响很低, 可以忽略。温度与降水量的相关系数为 0.699, 相关性较高, 但是若仅用一个变量代替两个变量, 则信息量损失较大, 因此将温度和降水量都保留, 并与相对湿度共同作为负荷预测的气象影响因素。因此, 除历史负荷外, 本文提取的影响负荷预测的主要气象因子, 分别为温度、相对湿度、降水量。

3.3.2 负荷集成预测结果分析

以用户的 136 天的分时负荷数据和气象因子构建网络输入数据矩阵, 则每个用户包含分时负荷数据量为 136×24 , 即 3264 个。则针对四类用

户, 分别将四类用户的负荷数据进行汇总, 再加上气象数据, 得到的输入矩阵为 3264×4 。按照时间长度, 将最后一天 24 个分时数据作为测试集, 其他数据分为训练集和验证集, 比例为 7:3。得到的负荷集成预测结果如图 6 所示, 并将预测结果与不进行聚类分析的总量负荷预测 (图 7) 进行对比。

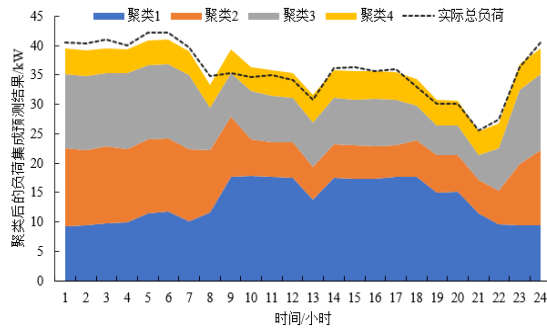


图 6 聚类后的负荷集成预测结果示意图

Fig.6 Results of the load integrated forecasting after clustering




图 7 总量负荷预测结果示意图

Fig.7 Results of total load forecasting

图 6 中, 四类用户的集成预测负荷与用户用电特性 (图 5) 大致符合, 由于聚类将用电特性类似的用户聚集到一类, 在后续的预测过程中, 不同类别分别进行负荷集成预测, 从而使得预测精度有所提高。总量负荷预测 (图 7) 中, 将该城市所有用户的 136 天的分时负荷数据和气象因子构建网络输入数据矩阵, 输入到 Elman 神经网络中进行预测, 由于不同用户数据特征各异, 而汇总后的总量负荷数据特性不够明显, 预测精度下降。

表 3 本文方法与总量负荷预测结果对比

Table 3 Comparison between the results of the method in this paper and total load forecasting

评价指标	总量负荷预测	聚类后的 负荷集成预测	集成预测 改进效果
MSE	7.227	1.584	5.643
MAPE	6.86%	2.74%	4.12%

采用 MSE 和 MAPE 评价指标对结果进行对比展示, 如表 3 所示。可以看出, 经过聚类分析后的负荷集成预测, 预测精度大大提升, 在大规模负荷预测中有实际价值。

4 结论

本文提出一种基于改进 K-Means 聚类与 Elman 神经网络的负荷集成预测方法, 主要优势有:

(1) 考虑到气象因素对负荷预测的影响, 本文提出对收集到的用户负荷按照城市进行分类, 在区域负荷集成预测中添加城市标签, 从而建立了更为精确的考虑气象因素的负荷集成预测模型。

(2) 通过挖掘不同用户数据之间的关联性, 预测前对负荷数据进行聚类分类, 减少用户群数量的同时, 突出了不同类型用户的特征, 大大提高了负荷集成预测精度。

(3) 算例中利用改进 K-Means 聚类和 Elman 神经网络算法, 以收集到的用户负荷和城市气象数据开展聚类分析和集成预测, 对结果进行分析和评价, 并与总量负荷预测进行对比, 证明了本文方法的有效性和优越性。

参 考 文 献

- [1] 肖欣,周渝慧,张宁等. 城镇化进程与电力需求增长的关系研究[J]. 中国电力, 2015, 48(2): 145-149.
- XIAO Xin,ZHOU Yuhui,ZHANG Ning, et al. Study on the Relationship Between Urbanization Process and Electricity Demand Growth[J]. Electric Power, 2015, 48(2): 145-149.
- [2] 朱斌,姜宁,霍雪松等. 南京城市电网核心区短期负荷特性分析及预测[J]. 中国电力, 2016, 49(2): 67-72.
- ZHU Bin,JIANG Ning,HUO Xuesong , et al. Forecasting and Studies on Load Characteristics of Nanjing Center Area Power Network[J]. Electric Power, 2016, 49(2): 67-72.
- [3] 石玉恒,赵娜,王凌等. 北京地区日最大电力负荷预测模型初探[J]. 中国电力, 2019, 52(8): 157-163.
- SHI Yuheng,ZHAO Na,WANG Ling , et al. Study on Forecasting Model of Maximum Daily Power Load in Beijing Area[J]. Electric Power, 2019, 52(8): 157-163.
- [4] WIJAYA T K, VASIRANI M, HUMEAU S, et al. Cluster-based aggregate forecasting for residential electricity demand using smart meter data [C]//2015 IEEE International Conference on Big Data (Big Data). Santa Clara, CA: IEEE, 2015: 879-887.
- [5] 毕圣. 基于数据挖掘技术的短期负荷预测[D]. 北京: 北京交通大学, 2016.
- BI Sheng. Short-term load forecasting based on data mining

- technology [D]. Beijing: Beijing Jiaotong University, 2016.
- [6] Sun Q, Yao J, Jiang W, et al. Application of improved fuzzy C means algorithm on bad-data identification and adjustment in short-term load forecasting[C]//2011 International Conference on Advanced Power System Automation and Protection. Beijing: IEEE, 2011: 568-571.
- [7] Fahiman F, Erfani S M, Rajasegarar S, et al. Improving load forecasting based on deep learning and K-shape clustering[C]//2017 International Joint Conference on Neural Networks (IJCNN). Anchorage, AK: International Neural Network Society, 2017: 4134-4141.
- [8] Zhang P, Wu X, Wang X, et al. Short-term load forecasting based on big data technologies[J]. CSEE Journal of Power and Energy Systems, 2015, 1(3): 59-67.
- [9] 李宝玉. 基于神经网络的电力负荷预测[D]. 湖南大学, 2013.
Li Baoyu. Electric load forecast based on neural network [D]. Hunan University, 2013.
- [10] 黄湘君. 基于主成分分析的BP神经网络在电力系统负荷预测中的应用[J]. 科技信息(科学教研), 2008(16): 313-314.
Huang Xiangjun. Application of BP neural network based on principal component analysis in power system load forecasting [J]. Science and Technology Information (Science and Technology Research), 2008(16): 313-314.
- [11] 赵会茹, 赵一航, 郭森. 基于互补集合经验模态分解和长短期记忆神经网络的短期电力负荷预测[J]. 中国电力, 2020, 53(6): 48-55.
ZHAO Huiru, ZHAO Yihang, GUO Sen Short-Term Load Forecasting Based on Complementary Ensemble Empirical Mode Decomposition and Long Short-Term Memory[J]. Electric Power, 2020, 53(6): 48-55.
- [12] 张德丰. MATLAB神经网络仿真与应用[M]. 北京: 电子工业出版社, 2009.
Zhang Defeng. MATLAB neural network simulation and application [M]. Beijing: Electronic Industry Press, 2009.
- [13] Siddarameshwara N., Anup Yelamali, Kshitiz Byahatti, et al. Electricity Short Term Load Forecasting Using Elman Recurrent Neural Network[C]//2010 International Conference on Advances in Recent Technologies in Communication and Computing. Kottayam: IEEE, 2010: 351-354.
- [14] Di Pengyu, Dong Kai, Du Jiang, Dong Chao, et al. Ultra-Short Term Load Forecasting Based on Elman Neural Network[C]//2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia). Chengdu: IEEE, 2019: 911-915.
- [15] 杨燕, 靳蕃, KAMEL Mohamed. 聚类有效性评价综述[J]. 计算机应用研究, 2008(06): 1630-1632+1638.
Yang Yan, Jin Fan, KAMEL Mohamed. Review of clustering effectiveness evaluation [J]. Computer Application Research, 2008(06): 1630-1632+1638.
- [16] 王曰芬, 章成志, 张蓓蓓, 吴婷婷. 数据清洗研究综述[J]. 现代图书情报技术, 2007(12): 50-56.
Wang Yuefen, Zhang Chengzhi, Zhang Beibei, Wu Tingting. A review of data cleaning research [J]. Modern Library and Information Technology, 2007(12): 50-56.
- [17] 杨晓倩. 缺失数据插补方法的选择研究[D]. 兰州财经大学, 2016.
Yang Xiaolian. Research on the selection of missing data interpolation method [D]. Lanzhou University of Finance and Economics, 2016.
- [18] 赵娜, 石玉恒, 李乃杰等. 温湿变化对北京城区气象敏感电力负荷的影响分析[J]. 中国电力, 2017, 50(2): 175-180.
ZHAO Na, SHI Yuheng, LI Naijie, et al. The Relationship of Temperature Humidity Index and Meteorology Sensitive Power Load in Beijing [J]. Electric Power, 2017, 50(2): 175-180.
- [19] Wold S, Esbensen K, Geladi P. Principal component analysis [J]. Chemometrics and Intelligent Laboratory Systems, 1987, 2(1): 37-52.
- [20] 周松林, 茆美琴, 苏建徽. 基于主成分分析与神经网络的风电功率预测[J]. 电网技术, 2011, 35(9): 128-132.
Zhou Songlin, Mao Meiqin, Su Jianhui. Wind power prediction based on principal component analysis and artificial neural network [J]. Power Grid Technology, 2011, 35(9): 128-132.