

DOI: 10.19783/j.cnki.pspc.180866

## 基于智能相似日识别及偏差校正的短期负荷预测方法

刘翊枫<sup>1</sup>, 周国鹏<sup>2</sup>, 刘昕<sup>1</sup>, 汪洋<sup>3</sup>, 郑宇鹏<sup>1</sup>, 邵立政<sup>1</sup>

(1. 国网湖北省电力有限公司, 湖北 武汉 430077; 2. 清华大学, 北京 100084;  
3. 北京清能互联科技有限公司, 北京 100080)

**摘要:** 在传统负荷预测理论的基础上, 提出了基于智能相似日识别及偏差校正的新型短期负荷预测方法。首先构建地市—相关因素特征矩阵, 通过判断矩阵相关性智能选取负荷相似日, 从而实现负荷曲线的一次预测。在此基础上, 建立了实时气象偏差校正策略, 采用 XGBoost 算法进行负荷曲线的二次偏差校正, 达到短期负荷预测的目标。算例研究表明, 该策略能够有效提升短期负荷预测精度, 而且具有较好的自适应特性, 可以应用于电力系统短期负荷预测实践。

**关键词:** 相关因素; 特征矩阵; 相似日; 偏差校正; 短期负荷预测

### A short-term load forecasting method based on intelligent similar day recognition and deviation correction

LIU Yifeng<sup>1</sup>, ZHOU Guopeng<sup>2</sup>, LIU Xin<sup>1</sup>, WANG Yang<sup>3</sup>, ZHENG Yupeng<sup>1</sup>, SHAO Lizheng<sup>1</sup>

(1. State Grid Hubei Electric Power Co., Ltd., Wuhan 430077, China; 2. Tsinghua University, Beijing 100084, China;  
3. Beijing Tsintergy Technology Co., Ltd., Beijing 100080, China)

**Abstract:** Based on the traditional load forecasting theory, this paper proposes a new short-term load forecasting method based on intelligent similar day recognition and deviation correction. Firstly, the characteristic matrix of prefecture-city and correlation factors is constructed to select the most similar day of load curve through calculating matrix correlation coefficient. On this basis, the real-time meteorological deviation correction strategy which adopts the XGBoost algorithm is established to carry out the secondary deviation correction of the load curve, so as to achieve the goal of short-term load prediction. An example study shows that this strategy can effectively improve accuracy of short-term load forecasting, and also has good adaptive characteristics. Therefore, this method can be applied to the short-term power load forecasting practice.

This work is supported by Science and Technology Project of State Grid Corporation of China (No. 52150016006B).

**Key words:** correlation factors; characteristic matrix; similar day; deviation correction; short-term load forecasting

## 0 引言

短期负荷预测是电力系统安全经济运行的基础, 随着新一轮电改以及我国电力市场的不断完善和发展, 短期负荷预测发挥的作用日趋重要<sup>[1-4]</sup>。目前, 国内外专家学者在短期负荷预测方面开展了大量研究, 并提出了一系列预测方法。这些预测方法大致可分为传统方法和新型智能方法两类<sup>[5-6]</sup>: 传统方法主要有回归分析法、时间序列法、相似日法、

指数平滑法、灰色预测法等<sup>[7-11]</sup>; 新型方法主要有神经网络法、支持向量机法、小波分析法、模糊预测法、随机森林法等<sup>[12-20]</sup>。在预测效果方面, 传统方法和新型方法均有其可取之处, 孰优孰劣难以一概而论。因此在实际应用中, 为了提高预测精度, 往往采取两者结合、优势互补的策略<sup>[21-23]</sup>。

基于相似日的短期负荷预测方法能够降低输入数据维度, 利用较少的训练数据达到较高的预测精度<sup>[24]</sup>, 因此在短期负荷预测中备受青睐。在此种方法中, 相似日的选取是关键, 其准确程度将直接影响到短期负荷预测算法的精度。文献<sup>[24]</sup>提出了一种基于动态权值优化的相似日选取算法和灰色

**基金项目:** 国家电网科技项目 (52150016006B) “基于分布式潮流控制的输电网柔性交流潮流控制技术的研究”

GRNN 串联组合模型的短期负荷预测方法。文献[25]采用人工神经网络选择相似日, 通过大量训练数据获取相似日。文献[26]利用改进的聚类分析方法得到历史标幺曲线的形状相似集与特征曲线, 取两者的交集作为相似日选择结果。诸如此类针对相似日选择算法的研究还有很多, 也都取得了一定的效果。但目前的大多数研究都是从数据处理的角度入手, 对相关因素的处理都不够精细化, 而气象因素(例如温度、湿度、风速等)是影响负荷的关键相关因素, 在采用基于相似日的地市加权方法预测省级负荷时应充分考虑不同地市的气象特征偏差。因此, 如何综合考虑各地市相关因素, 精确识别相似日, 是当前迫切需要解决的问题。此外, 如何综合考虑待预测日与相似日之间偏差变化规律, 从而在相似日负荷基础上补偿, 进一步提高预测精度也是需要解决的问题。

针对上述问题, 本文综合考虑地理位置、气象条件等负荷敏感因素, 研究不同类型日、不同气象因素条件下的负荷特征, 提出了基于地市—相关因素特征矩阵的智能相似日识别策略, 并结合实时气象对负荷偏差进行偏差校正, 提高短期负荷预测精度。

## 1 整体思路

负荷的变化主要取决于人们生产和生活的规律性, 同时受到一些相关因素(诸如日类型、温度、湿度)的影响。在实际负荷预测中, 历史数据一般是某个地市的负荷和气象信息。为了充分体现不同地市气象特点, 提高预测精度, 本文考虑采用智能选取相似日的方法, 综合考虑不同地市在不同类型日、不同气象因素(温度、湿度、风速等)条件下的负荷特征, 构建各地市相关因素特征矩阵, 通过计算特征矩阵距离, 智能判别、选取负荷相似日。

一次预测如果不考虑气象等相关因素的变化, 则只是历史负荷中规律性成分的外推。因此, 当气象等相关因素发生变化时, 必然造成一次预测结果的偏差, 而相关因素的变化量和一次预测偏差应该是强相关关系。在智能相似日选取的基础上, 将该相似日负荷曲线作为待预测日的基准负荷曲线, 然后采用 XGBoost 算法建立气象因素偏差与负荷偏差百分比之间的关联模型, 使用历史数据训练该学习模型, 进而对基准负荷曲线进行二次修正, 得到待预测日的负荷曲线。该策略的整体算法流程如图 1 所示。

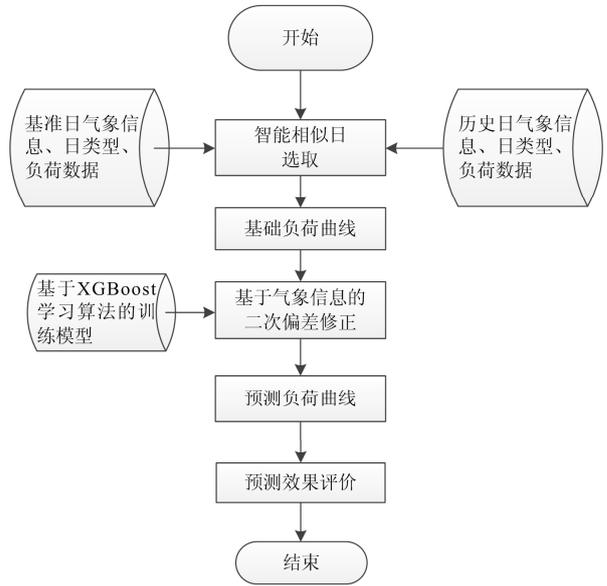


图 1 整体算法流程

Fig. 1 Global algorithm flow

## 2 智能相似日识别策略

### 2.1 相关因素特征矩阵构建

根据历史负荷数据、气象信息等, 构建短期负荷相关因素特征矩阵。其中, 行指标为相关地市, 列指标为相关因素(包括日类型、温度、湿度、降雨、风速等), 各列指标进行归一化处理, 形成能够描述全省某天各地市详细相关因素分布的特征矩阵。考虑到样本的复杂性以及所研究问题的目标, 为有效反映各种因素对负荷带来的影响, 构建特征矩阵时对原始数据进行了如下处理。

1) 日类型。日类型相同, 相似度为 1; 同为工作日/周末但日类型不同, 相似度为 0.7; 都不同为 0.4。即: 定义  $F(d_1, d_2)$ , 若  $d_1 = d_2$ , 则  $F = 1$ , 若  $d_1 \neq d_2$ , 但同为工作日或周末, 则  $F = 0.7$ , 若  $d_1$  和  $d_2$  其中一个为工作日一个为周末, 则  $F = 0.4$ 。

2) 温度。选取每日最大值、最小值、平均值。

每日最高温度:  $\text{Max Temp}_i (i=1, 2, \dots, 96)$

每日最低温度:  $\text{Min Temp}_i (i=1, 2, \dots, 96)$

每日平均温度:  $\text{Average} \sum_{i=1}^{96} \text{Temp}_i$

3) 平均湿度:  $\text{Average} \sum_{i=1}^{96} \text{Hum}_i$

4) 累计降雨量:  $\sum_{i=1}^{96} \text{Rain}_i$

5) 平均风速:  $\text{Average} \sum_{i=1}^{96} \text{Wind}_i$

## 2.2 智能相似日判别方法及实现流程

在构建了上述特征矩阵的基础上, 根据特征矩阵之间的距离判断不同日期负荷相关因素之间的相似程度。在本文中, 采用相关系数(Correlation Coefficient)计算特征矩阵的相关关系。基于地市-相关因素特征矩阵的智能相似日识别策略实现流程如图 2 所示。

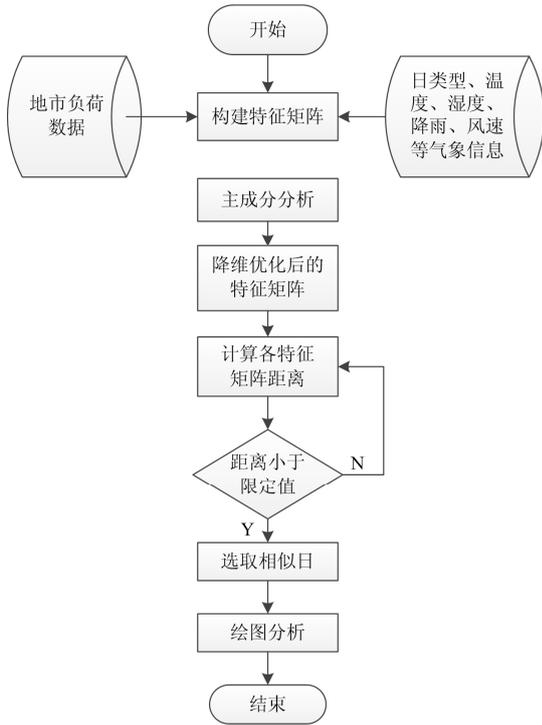


图 2 智能相似日识别算法流程

Fig. 2 Intelligent similar day recognition algorithm

## 3 负荷预测偏差校正策略

### 3.1 XGBoost 算法原理

XGBoost(全称 eXtremeGradient Boosting)是华盛顿大学陈天奇博士在 2014 年 2 月提出的一种专注于梯度提升算法的机器学习函数库。XGBoost 算法采用正则项限制了模型计算复杂度, 通过二阶泰勒展开、并行计算特征分裂增益。在算法实现上, XGBoost 基于 C++ 通过多线程实现了回归树的并行构建, 并在原有 Gradient Boosting 算法基础上加以改进, 从而极大地提升了模型训练速度和预测精度。随着智能电网的发展, 电网运行的数据量激增, 负荷预测需要考虑的数据规模也日益增长, 传统的计算方法在处理海量数据时效率问题日益凸显, 考虑到 XGBoost 算法并行处理、学习速度快等特征, 可研究将其用于短期负荷预测中。

XGBoost 的建模思路就是在每轮迭代中生成一棵新的回归树, 并综合所有回归树的结果, 使预测

值越来越逼近真实值。其计算过程如下。

#### 1) 定义目标函数

XGBoost 在目标函数中加上了正则化项, 正则化项与树的叶子节点的数量  $T$  和叶子节点的值有关。

$$Obj(t) = \sum_{i=1}^n L(y_i, \hat{y}^{t-1} + f_i(x_i)) + \Omega(f_i) + C \quad (1)$$

式中:  $C$  为常数项;  $\Omega(f_i)$  为正则项, 定义如式(2)。

$$\Omega(f_i) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (2)$$

式中,  $\omega_j$  表示第  $j$  个叶子节点的权重。

#### 2) 二阶泰勒展开

利用泰勒展开式:

$$f(x + \Delta x) \approx f(x) + f'(x)\Delta x + \frac{1}{2} f''(x)\Delta x^2 \quad (3)$$

对式(3)进行展开, 可以得到式(4)。

$$Obj(t) \approx \sum_{i=1}^n [L(y_i, \hat{y}^{t-1}) + g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i)] + \Omega(f_i) + C \quad (4)$$

式中:  $g_i$  表示  $L(y_i, \hat{y}^{t-1})$  对  $\hat{y}^{t-1}$  的一阶导数;  $h_i$  表示  $L(y_i, \hat{y}^{t-1})$  对  $\hat{y}^{t-1}$  的二阶导数。

#### 3) 简化目标函数

$L(y_i, \hat{y}^{t-1})$  为真实值与前一个函数计算所得残差, 是已知的。同时, 在同一个叶子节点上的数的函数值是相同的, 可以做合并, 进而目标函数可以简化为

$$Obj(t) = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T + C \quad (5)$$

目标函数简化后, 可以看到 XGBoost 的目标函数是可以自定义的, 计算时只是用到了它的一阶导和二阶导。得到简化公式后, 下一步针对选择的特征计算其所带来的增益, 从而选取合适的分裂特征

$$gain(\phi) = \frac{1}{2} \left[ \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (6)$$

可见, XGBoost 采用了贪心算法, 尝试去对已有的叶子加入一个分割, 计算分割所能带来的增益, 然后选择那个带来最多增益的分割。

### 3.2 基于 XGBoost 算法的二次负荷预测偏差校正

定义第  $n$  日  $t$  时刻实际负荷为  $P_{n,t}$ , 根据相似日选取方法, 一次预测方法的预测结果为  $P_{n,t}^{(1)}$ , 则  $\Delta P_{n,t} = P_{n,t} - P_{n,t}^{(1)}$  为一次预测偏差;

定义  $X_{n,t}$  为第  $n$  日  $t$  时刻要考虑该区域负荷的相关因素向量(日类型、温度、湿度、降雨等相关因素), 用一次预测方法得到的该时刻  $X_{n,t}$  的一次估计值为  $X_{n,t}^{(1)}$ ;

由上所述, 可将负荷的一次预测结果(相似日负荷)作为基础预测值, 记为

$$P_{n,t}^{(\text{base})} = P_{n,t}^{(1)} = g(P_{n-1,t}, P_{n-2,t}, \dots, P_{n-k,t}) \quad (7)$$

式中:  $g(\cdot)$  表示负荷的一次预测方法;  $k$  是用于预测的历史天数。则一次预测偏差可以记作  $\Delta P_{n,t} = P_{n,t} - P_{n,t}^{(\text{base})}$ , 然后采用 3.1 节中介绍的 XGBoost 算法对负荷偏差与相关因素偏差进行建模, 得到

$$\Delta P_{n,t} = f((\Delta x_{n,t})_1, (\Delta x_{n,t})_2, \dots, (\Delta x_{n,t})_m) = f(\Delta X_{n,t}) \quad (8)$$

式中,  $m$  为相关因素数目。

最后, 对一次预测结果进行二次偏差校正, 得到负荷预测结果为

$$P_{n,t}^{(2)} = P_{n,t}^{(1)} + \Delta P_{n,t} \quad (9)$$

上述偏差建模的过程可以由图 3 来表示。

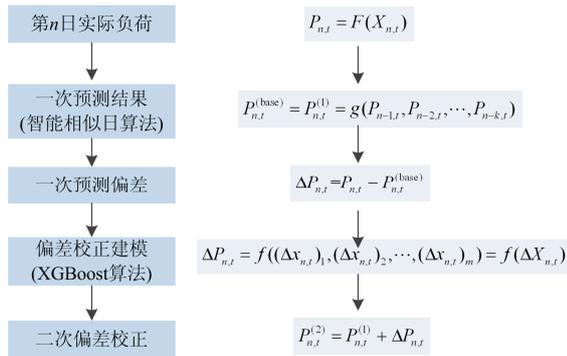


图 3 二次偏差校正建模流程

Fig. 3 Secondary deviation correction modeling

## 4 实证分析

### 4.1 算例设计

以湖北省全网负荷为研究对象, 收集 2016 年至 2017 年两年的历史负荷数据及下辖 13 个地市(武汉、孝感、十堰、恩施、鄂州等)的历史气象数据, 数据采样时间间隔为 15 min(每日 96 个点), 设计算例验证上述负荷预测方法的有效性。

### 4.2 参数选取及计算

(1) 各地市在省总负荷中占据的权重系数

根据湖北省统调数据以及 13 个地市的历史负荷数据, 综合考虑各地市的负荷水平, 计算中采用 2016 年全年各地市平均负荷, 确定各地市公司在省网负荷中占据的权重系数为

$$w_i = \frac{P_{i,\text{avg}}}{\sum_{i=1}^n P_{i,\text{sum}}} \times 100\% \quad (10)$$

(2) 地市-相关因素特征矩阵相关系数

假设第  $i$  个地市第  $j$  日的特征矩阵与基准日特征矩阵相关系数为  $c_{i,j}$ , 第  $i$  个地市的负荷权重系数为  $w_i$ , 则全省第  $j$  日与基准日的特征矩阵综合相关系数为

$$C_j = \sum_{i=1}^{13} w_i c_{i,j} \quad (j=1, 2, \dots, N) \quad (11)$$

### 4.3 结果分析

选取 2017 年 7 月 13 日作为基准日, 分别选取基准日前 30 天(2017 年 6 月 12 日至 2017 年 7 月 12 日)、前一年同季节时期(2016 年 5 月 13 日至 2016 年 8 月 13 日)的历史气象信息数据为样本数据范围, 按照上述思路构建了特征矩阵并进行相关系数的计算, 得到相似日排序结果(详见附表 1)。

(1) 相似日选取结果分析

根据基准日与历史相似日的负荷数据, 分别绘制排名靠前的前三个相似日与基准日的负荷曲线, 如图 4 所示, 基准日与最佳相似日的负荷曲线如图 5 所示。

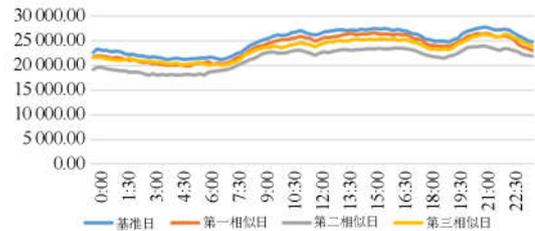


图 4 基准日与前三相似日负荷曲线(有名值, MW)

Fig. 4 Load curves of the base day and front three similar days



图 5 基准日与最佳相似日负荷曲线(标么值)

Fig. 5 Load curves of the base day and first similar day

从图 4 和图 5 可以看出, 前三个历史相似日的负荷曲线均匀基准日负荷曲线走势比较相近, 特别是相关系数最大的第一相似日(2017 年 7 月 12 日), 其日负荷标么曲线变化趋势与基准日负荷标么曲线

基本吻合。

根据预测误差评价指标 MAPE(Mean Absolute Percentage Error)定义

$$MAPE = \frac{1}{N} \sum_{t=1}^N \frac{|A_t - F_t|}{A_t} \quad (12)$$

式中:  $N = 96$ ;  $A_t$  为基准日  $t$  时刻负荷标么值;  $F_t$  为相似日  $t$  时刻负荷标么值。分别计算前三相似日与基准日的 MAPE, 可以得到表 1。

表 1 前三相似日与基准日的 MAPE 统计

相似日	第一相似日	第二相似日	第三相似日
MAPE	0.99%	1.58%	1.80%

(2) 二次偏差校正后的负荷预测结果分析

在智能识别相似日的基础上, 将第一相似日负荷曲线作为一次预测结果, 利用训练好的模型进行负荷偏差校正, 得到待预测日 2017.7.13 对应的 96 个时刻的负荷预测值, 对比实际负荷曲线, 如图 6 所示。



图 6 偏差校正后的负荷预测曲线

Fig. 6 Prediction load curves after deviation correction

从图 6 可以看出, 利用智能相似日识别加负荷偏差修正算法得到的预测曲线与实际负荷曲线非常接近, 可以达到较好的预测效果。为进一步说明本文所采取负荷预测方法的效果, 分别选取一次预测传统方法 ARMA、二次偏差校正常用的 SVM 算法与本文采用的智能相似日加 XGBoost 的算法进行比较, 统计不同组合方法下的负荷预测结果, 得到表 2。

表 2 不同方法下预测结果对比

预测方法	智能相似日+ XGBoost 偏差校正	智能相似日+ SVM 偏差校正	ARMA+XGBoost 偏差校正
MAPE	0.64%	1.76%	3.16%

由表 2 可见, 相比于传统的预测方法及 SVM 偏差校正方法, 本文采取的智能相似日加 XGBoost

偏差校正策略具有更高的预测精度, 从而进一步验证了智能相似日识别及偏差校正策略在短期负荷预测方面的效果。

## 5 结论

本文设计了基于智能相似日选取及实时气象偏差校正的负荷预测方法, 通过构建地市-相关因素特征矩阵智能识别相似日, 在此基础上训练 XGBoost 模型进行负荷偏差的二次修正, 得到待预测日的负荷曲线。研究表明, 此种算法可以有效提高相似日识别效率, 提高负荷预测精度, 在电力系统短期负荷预测中具有一定的应用价值。

## 附表

表 1 相似日计算结果排序

Table 1 Sort the results of similar days

日期排序 (相似度由高到低)	日类型 (星期)	特征矩阵 综合相关系数
20170712	星期三	0.999 2
20160622	星期三	0.998 6
20160722	星期五	0.998 6
20160723	星期六	0.997 9
20170621	星期三	0.997 6
20170627	星期二	0.997 2
20160724	星期日	0.997 1
20160721	星期四	0.997 1
20160613	星期一	0.997 0
20160711	星期一	0.996 9
20160712	星期二	0.996 7
20160618	星期六	0.996 7
20160812	星期五	0.996 6
20160810	星期三	0.996 2
20170619	星期一	0.996 1
20160709	星期六	0.996 1
20160610	星期五	0.996 1
20170711	星期二	0.996 1
20160710	星期日	0.995 9
20170618	星期日	0.995 8
20160513	星期五	0.995 7
20170617	星期六	0.995 4
20170705	星期三	0.995 3
20160609	星期四	0.995 3
20160813	星期六	0.995 3
20170622	星期四	0.995 2
20170704	星期二	0.995 2
20170625	星期日	0.995 1
20160529	星期日	0.995 1
20170620	星期二	0.994 6
20160608	星期三	0.994 5
20160809	星期二	0.994 4

续表 1

日期排序 (相似度由高到低)	日类型 (星期)	特征矩阵 综合相关系数
20160811	星期四	0.994 4
20160725	星期一	0.994 2
20160606	星期一	0.994 2
20160605	星期日	0.994 0
20160621	星期二	0.993 6
20170703	星期一	0.993 6
20170702	星期日	0.993 5
20160530	星期一	0.993 5
20170710	星期一	0.993 3
20160708	星期五	0.993 2
20170626	星期一	0.993 0
20170624	星期六	0.992 7
20160716	星期六	0.992 7
20160617	星期五	0.992 6
20160707	星期四	0.992 3
20170706	星期四	0.992 2
20170614	星期三	0.991 8
20170629	星期四	0.991 7
20170616	星期五	0.991 5
20160524	星期二	0.991 4
20160517	星期二	0.990 8
20160726	星期二	0.990 7
20160518	星期三	0.990 7
20160629	星期三	0.990 7
20160604	星期六	0.990 4
20160727	星期三	0.989 1
20160614	星期二	0.988 5
20160801	星期一	0.988 2
20170628	星期三	0.987 9
20160806	星期六	0.987 4
20160728	星期四	0.986 9
20160525	星期三	0.985 1
20160516	星期一	0.985 1
20160611	星期六	0.984 9
20160612	星期日	0.984 7
20160729	星期五	0.984 3
20160523	星期一	0.983 9
20160805	星期五	0.983 9
20160731	星期日	0.981 8
20170623	星期五	0.981 2
20160528	星期六	0.979 3
20160603	星期五	0.979 1
20160705	星期二	0.978 5
20160808	星期一	0.977 6
20160730	星期六	0.977 5
20160522	星期日	0.977 3
20160615	星期三	0.977 2
20170612	星期一	0.973 4

续表 1

日期排序 (相似度由高到低)	日类型 (星期)	特征矩阵 综合相关系数
20160626	星期日	0.972 3
20160521	星期六	0.971 9
20170615	星期四	0.971 3
20160531	星期二	0.970 9
20170707	星期五	0.970 2
20160802	星期二	0.967 8
20160515	星期日	0.963 7
20160607	星期二	0.958 3
20160715	星期五	0.957 1
20160616	星期四	0.953 7
20160807	星期日	0.927 8
20160630	星期四	0.922 4
20160627	星期一	0.921 6
20160519	星期四	0.920 7
20170613	星期二	0.909 4
20160623	星期四	0.907 8
20170709	星期日	0.904 5
20160718	星期一	0.897 2
20160628	星期二	0.895 6
20160526	星期四	0.894 1
20160717	星期日	0.893 4
20160804	星期四	0.888 5
20160714	星期四	0.885 2
20160602	星期四	0.864 8
20160803	星期三	0.863 8
20160520	星期五	0.856 7
20170708	星期六	0.841 2
20160527	星期五	0.840 7
20160719	星期二	0.837 5
20160625	星期六	0.835 2
20160720	星期三	0.833 1
20170701	星期六	0.803 5
20160514	星期六	0.792 0
20160713	星期三	0.790 3
20160703	星期日	0.784 2
20160706	星期三	0.782 8
20170630	星期五	0.778 4
20160704	星期一	0.774 5
20160702	星期六	0.651 9
20160624	星期五	0.623 0
20160601	星期三	0.599 6
20160619	星期日	0.577 8
20160620	星期一	0.385 3
20160701	星期五	0.241 4

## 参考文献

- [1] 康重庆, 夏清, 张伯明. 电力系统负荷预测研究综述与发展方向的探讨[J]. 电力系统自动化, 2004, 28(17): 1-11.

- KANG Chongqing, XIA Qing, ZHANG Boming. Review of power system load forecasting and its development[J]. Automation of Electric Power Systems, 2004, 28(17): 1-11.
- [2] 廖旋焕, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152.
- LIAO Nihuan, HU Zhihong, MA Yingying, et al. Review of the short-term load forecasting methods of electric power system[J]. Power System Protection and Control, 2011, 39(1): 147-152.
- [3] 黎灿兵, 李晓辉, 赵瑞, 等. 电力短期负荷预测相似日选取算法[J]. 电力系统自动化, 2008, 32(9): 69-73.
- LI Canbing, LI Xiaohui, ZHAO Rui, et al. A novel algorithm of selecting similar days for short-term power load forecasting[J]. Automation of Electric Power Systems, 2008, 32(9): 69-73.
- [4] 郭华安, 加玛力汗·库马什, 常喜强, 等. 电力系统短期负荷预测方法与预测精度综述[J]. 电气技术, 2011(10): 20-23.
- GUO Huaan, Jamalihan·Kumashi, CHANG Xiqiang, et al. Review of the short-term load forecasting methods and the accurate prediction of power system[J]. Electric Technologies, 2011(10): 20-23.
- [5] 王惠中, 周佳, 刘轲. 电力系统短期负荷预测方法研究综述[J]. 电气自动化, 2015, 37(1): 1-3.
- WANG Huizhong, ZHOU Jia, LIU Ke. Summary of research on the short-term load forecasting method of the electric power system[J]. Electrical Automation, 2015, 37(1): 1-3.
- [6] 康重庆, 夏清, 刘梅. 电力系统负荷预测[M]. 北京: 中国电力出版社, 2007.
- [7] 黄元生, 邓佳佳, 苑珍珍. 基于 ARMA 误差修正和自适应粒子群优化的 SVM 短期负荷预测[J]. 电力系统保护与控制, 2011, 39(14): 26-32.
- HUANG Yuansheng, DENG Jiajia, YUAN Zhenzhen. SVM short-term load forecasting based on ARMA error calibration and the adaptive particle swarm optimization[J]. Power System Protection and Control, 2011, 39(14): 26-32.
- [8] 李军, 於阳. 基于稀疏编码的短期风电功率时间序列预测[J]. 电力系统保护与控制, 2018, 46(12): 16-23.
- LI Jun, YU Yang. Short-term wind power time series prediction based on sparse coding method[J]. Power System Protection and Control, 2018, 46(12): 16-23.
- [9] 张振高, 杨正瓴. 短期负荷预测中的负荷求导法及天因素的使用[J]. 电力系统及其自动化学报, 2006, 18(5): 79-83.
- ZHANG Zhengao, YANG Zhengling. Load derivation in short term forecasting using weather factor[J]. Proceedings of the CSU-EPSC, 2006, 18(5): 79-83.
- [10] 靳春旭, 董福贵. 长期风电负荷预测方法比较[J]. 广东电力, 2018, 31(9): 70-76.
- JIN Chunxu, DONG Fugui. Comparison of prediction methods for long-term wind power load[J]. Guangdong Electric Power, 2018, 31(9): 70-76.
- [11] 李辉. 改进残差 GM(1,1)模型在中长期负荷预测中的应用[J]. 广东电力, 2017, 30(9): 81-85.
- LI Hui. Application of improved residual error GM (1, 1) model in medium and long term load forecasting[J]. Guangdong Electric Power, 2017, 30(9): 81-85.
- [12] ZHENG Dehua, ESEYE A T, ZHANG Jianhua, et al. Short-term wind power forecasting using a double-stage hierarchical ANFIS approach for energy management in microgrids[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 136-145. DOI: 10.1186/s41601-017-0041-5.
- [13] 谷云东, 张素杰, 冯君淑. 大用户电力负荷的多模型模糊综合预测[J]. 电工技术学报, 2015, 30(23): 110-115.
- GU Yundong, ZHANG Sujie, FENG Junshu. Multi-model fuzzy synthesis forecasting of electric power loads for larger consumers[J]. Transactions of China Electrotechnical Society, 2015, 30(23): 110-115.
- [14] 张平, 潘学萍, 薛文超. 基于小波分解模糊灰色聚类和 BP 神经网络的短期负荷预测[J]. 电力自动化设备, 2012, 32(11): 121-125.
- ZHANG Ping, PAN Xueping, XUE Wenchao. Short-term load forecasting based on wavelet decomposition, fuzzy gray correlation clustering and BP neural network[J]. Electric Power Automation Equipment, 2012, 32(11): 121-125.
- [15] 刘会家, 管鑫, 陈波, 等. 考虑主动需求的主动配电网负荷预测[J]. 电力系统保护与控制, 2018, 46(10): 68-74.
- LIU Huijia, GUAN Xin, CHEN Bo, et al. Load forecasting for active distribution network in the presence of active demand[J]. Power System Protection and Control, 2018, 46(10): 68-74.
- [16] 黄晗, 孙堃, 刘达. 基于随机森林的电力系统小时负荷预测研究[J]. 智慧电力, 2018, 46(5): 8-14.
- HUANG Han, SUN Kun, LIU Da. Hourly load forecasting of power system based on random forest[J]. Smart Power, 2018, 46(5): 8-14.
- [17] 王志勇, 郭创新, 曹一家. 基于模糊粗糙集和神经网络的短期负荷预测方法[J]. 中国电机工程学报, 2005, 25(19): 7-11.

- WANG Zhiyong, GUO Chuangxin, CAO Yijia. A method for short term load forecasting integrating fuzzy-rough set with artificial neural network[J]. Proceedings of the CSEE, 2005, 25(19): 7-11.
- [18] 吴潇雨, 和敬涵, 张沛, 等. 基于灰色投影改进随机森林算法的电力系统短期负荷预测[J]. 电力系统自动化, 2015, 39(12): 50-55.
- WU Xiaoyu, HE Jinghan, ZHANG Pei, et al. Power system short-term load forecasting based on improved random forest with gray relation projection[J]. Automation of Electric Power Systems, 2015, 39(12): 50-55.
- [19] 林芳, 林焱, 吕宪龙, 等. 基于均衡 KNN 算法的电力负荷短期并行预测[J]. 中国电力, 2018, 51(10): 88-94.
- LIN Fang, LIN Yan, LÜ Xianlong, et al. Short-term parallel power load forecasting based on balanced KNN[J]. Electric Power, 2018, 51(10): 88-94.
- [20] 赵芝璞, 高超, 沈艳霞, 等. 基于关联模糊神经网络和改进型蜂群算法的负荷预测方法[J]. 中国电力, 2018, 51(2): 54-60.
- ZHAO Zhipu, GAO Chao, SHEN Yanxia, et al. A method for load forecasting based on correlated fuzzy neural network and improved artificial bee colony algorithm[J]. Electric Power, 2018, 51(2): 54-60.
- [21] 张炀, 汪洋, 祝宇翔, 等. 基于 PAM 和 ELM 的电力短期负荷预测相似日选取算法[J]. 电力大数据, 2017, 20(12): 84-87.
- ZHANG Yang, WANG Yang, ZHU Yuxiang, et al. Similarity day selection algorithm for power short-term load forecasting[J]. Power Systems and Big Data, 2017, 20(12): 84-87.
- [22] 张冰玉. 基于数据挖掘技术的短期电力负荷预测[J]. 电力大数据, 2017, 20(10): 18-21.
- ZHANG Bingyu. Prediction of short-term power load based on data mining technology[J]. Power Systems and Big Data, 2017, 20(10): 18-21.
- [23] 曲正伟, 张坤, 王云静, 等. 基于 PSO-OMP 优化的 WD-ASD 超短期负荷预测[J]. 电工电能新技术, 2017, 36(12): 39-45.
- QU Zhengwei, ZHANG Kun, WANG Yunjing, et al. Short-term load forecasting based on WD-ASD optimized by PSO-OMP[J]. Advanced Technology of Electrical Engineering and Energy, 2017, 36(12): 39-45.
- [24] 李啸骢, 李春涛, 从兰美, 等. 基于动态权值相似日选取算法的短期负荷预测[J]. 电力系统保护与控制, 2017, 45(6): 1-8.
- LI Xiaocong, LI Chuntao, CONG Lanmei, et al. Short-term load forecasting based on dynamic weight similar day selection algorithm[J]. Power System Protection and Control, 2017, 45(6): 1-8.
- [25] SENJYU T, TAKARA H, UEZATO K, et al. One-hour-ahead load forecasting using neural network[J]. IEEE Transactions on Power Systems, 2002, 17(1): 113-118.
- [26] 孙谦, 姚建刚, 赵俊, 等. 基于最优交集相似日选取的短期母线负荷综合预测[J]. 中国电机工程学报, 2013, 33(4): 126-134.
- SUN Qian, YAO Jiangang, ZHAO Jun, et al. Short-term bus load integrated forecasting based on selecting optimal intersection similar days[J]. Proceedings of the CSEE, 2013, 33(4): 126-134.

收稿日期: 2018-07-13; 修回日期: 2018-10-12

作者简介:

刘翊枫(1988—), 男, 通信作者, 硕士, 工程师, 研究方向为电力系统自动化、电力市场; E-mail: 843837395@qq.com

周国鹏(1988—), 男, 硕士, 工程师, 研究方向为电力系统运行与控制、电力市场与电力经济等。

(编辑 魏小丽)