

DOI: 10.7667/PSPC161584

基于多维特征分析的月用电量精准预测研究

唐静^{1,2,3}, 李瑞轩¹, 黄宇航⁴, 向万红⁵, 解来甲⁵, 彭一轩⁵, 宁立⁵

- (1. 华中科技大学计算机科学与技术学院, 湖北 武汉 430074; 2. 广东海洋大学数学与计算机学院, 广东 湛江 524025; 3. 广东省大数据分析处理重点实验室, 广东 广州 510006;
4. 国电江苏电力有限公司, 江苏 南京 210036; 5. 远光软件股份有限公司, 广东 珠海 519085)

摘要: 用户用电量的精准预测是智能配用电大数据应用和发展的关键之一。区别于传统的基于行业分类的预测办法, 提出基于大数据挖掘技术的用户用电多维度特征识别, 以及在此基础上的精准用电量预测方法。基于海量多用户用电特性, 建立多维度用电特征评价指标体系。对用户用电特性空间进行聚类和分析, 挖掘和识别用电模式。在不同的用电模式下, 分别建立用电量时间序列预测模型, 避免用电模式差异对预测算法准确性造成的不利影响。该方法适用于大数据平台的分析与处理, 算例分析结果表明其相比以往方法能显著提高预测精度和稳定性。

关键词: 配用电大数据; 用电量预测; 多维特征分析; 数据挖掘

Research on the accurate forecasting of monthly electricity demand based on the multi-feature analysis

TANG Jing^{1,2,3}, LI Ruixuan¹, HUANG Yuhang⁴, XIANG Wanhong⁵, XIE Laijia⁵, PENG Yixuan⁵, NING Li⁵

- (1. School of Computer Science & Technology, Huazhong University of Science and Technology, Wuhan 430074, China;
2. School of Mathematics and Computer, Guangdong Ocean University, Zhanjiang 524025, China;
3. Guangdong Key Laboratory of Big Data Analysis and Processing, Guangzhou 510006, China;
4. Guodian Jiangsu Power Generation Co., Ltd., Nanjing 210036, China; 5. YGsoft Inc., Zhuhai 519085, China)

Abstract: Nowadays, accurate forecasting of electricity demand has become one of the most important technologies in the development and application of big data in smart power distribution and consumption system. Be different from traditional forecasting methods based on the classification of eclectic power industry, a new monthly electricity demand forecasting method which can be applied on today's typical big data platform is presented mainly through recognizing and utilizing the multi-dimension features of big data produced in the electricity consumption. Indexes to evaluate and classify multi-dimension features of electricity consumption are established through mass data in electricity consumption. Typical electricity consumption patterns in the user space are identified and obtained by data mining. To avoid the adverse effects of the discrepancy in consumption patterns on the accuracy of the prediction, different time series prediction models for different consumption patterns are established. The proposed method makes for the analysis and processing of big data platform, and the results show that the method can significantly improve the prediction accuracy and stability compared to previous method.

Key words: big data in power distribution and consumption; electricity demand forecasting; multi-feature analysis; data mining

0 引言

随着电力大数据挖掘的深入研究和应用推广, 如何从海量的用户月用电量的数据中, 挖掘和识别有效信息, 实现精准预测并应用于电网各环节运营成为难点之一。近年来, 电力系统采集并积累的用电信息为用电量精细化预测提供了大数据基础, 而

近年来大数据相关平台的建设和应用研究, 为数据挖掘技术在用电量预测中的应用提供了硬件基础和应用环境^[1]。实现用户月用电量的精准预测, 对电网资金规划、财务预算管理决策和需求侧响应分析具有重要的指导意义。

月用电量预测属于中期时间序列预测, 研究模型主要有以下几种。

1) 宏观因素关联模型。文献[2]分析了影响用户用电行为的宏观因素, 如宏观经济、房地产和家电等; 文献[3]和文献[4]在分析的基础上, 建立影响因

基金项目: 广东省重大科技专项(2014B010117006); 广东省大数据分析处理重点实验室开放基金项目(2017005)

素和用电情况之间的影响关系，采用预测模型实现预测。该类模型注重分析宏观因素对用户用电的影响，其弊端在于，需要人工干预确定影响因素。

2) 时间序列分析模型。文献[5]通过灰色关联分析法分析序列的趋势相似性，然后采用多变量灰色模型(Multi-variable Grey Model, MGM) (1, n)实现用电量预测；文献[6]采用时间序列模型对7个不同的预测算法进行评估。该类方法中的算法预测以历史为导向，忽略用户自身用电特征对预测算法准确性的影响。

3) 用户行为分析模型。文献[7]研究并提出大数据集的关联关系分析办法；文献[8]和文献[9]将用户用电量序列进行拆解分类为各种形态，分析出用户用电量与用电行为之间的关联关系。该类方法的预测精度主要依赖于分解用电行为的质量。

大数据平台的最新建设和研究成果使得各类智能算法与数据挖掘技术可以为复杂用电模式识别提供更多有力措施，结合用户端分析的时间序列预测方法，进一步提高用电量预测精准性和有效性成为可能。

由于需求侧用户用电多样化，细粒度月用电量的时间序列具有时变趋势复杂、多周期序列重叠和随机序列模式多样等特点^[10]。本文区别于传统的基于行业分类的预测办法，结合现有的时间序列预测算法，研究并提出了一种基于大数据挖掘技术的用户用电多维度特征识别和用电量预测方法。首先，对海量多用户历史用电数据进行统计计算，建立多维度的用户用电特征指标体系，依据计算出的用户用电特性矩阵进行聚类分析，挖掘和识别用电模式，获得不同用户用电模式集合。然后，针对不同的用电模式分别建立用电量预测模型进行预测。该方法能有效避免用电模式差异对预测算法准确性造成的不利影响，能为电力的规划和管理带来更有效的决策支持，有助于更深刻地认识用户及其群体效应，应对多样化发展的需求侧用电分析。以网省某区域23万用户为例，使用该方法开展用电量预测，计算和分析结果表明其科学性和有效性，且适用于现有大数据平台分析处理。

1 基于多维特征分析的用电预测模型

电力用户用电特征分析是配用电数据挖掘和大数据应用的基础，基于用户用电特征分析的预测流程如图1所示。模型的步骤主要是：首先针对 m 个用户用电大数据集进行有效数据预处理，生成目标分析数据集 V_d ，其中第 i 个用户的用电序列为 $V_i(x_{i1}, x_{i2}, \dots, x_{im})$, $i = 1, 2, \dots, m$ ；通过计算海量用户

用电多维评价指标，建立表征用户多维度用电特征的数据集 V_D ，其中第 i 个用户表征序列为 $V_i(x_{i1}, x_{i2}, \dots, x_{im}; \gamma_1, \gamma_2, \dots, \gamma_w)$, $i = 1, 2, \dots, m$ ；然后对用户多维度用电特征的数据集 V_D 进行聚类，挖掘和识别用电模式，得到 m 个用户的 k 个用户群体集合 G_k ；最后，根据用户群体特征，分别进行参数训练。在参数选优基础上建立算法预测模型 F_k ，求得各用户群体以及全体用户的用电量预测值，并进行预测评估。

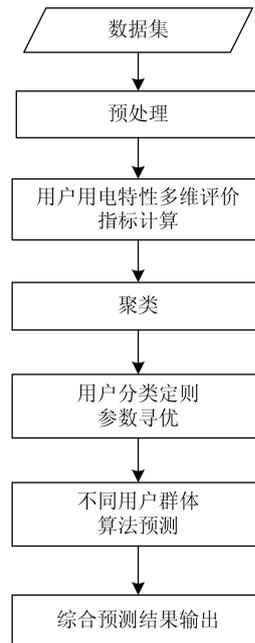


图1 预测流程

Fig. 1 Process of forecasting in the proposed method

2 用电的多维特征分析

2.1 数据预处理

用户的月用电量数据受到外部因素的干扰，不可避免有异常和缺失数据存在，不加处理就把异常值纳入数据的计算分析过程中，对结果会带来不良影响。对于异常的检测，本方案采用箱形图统计校验方法。箱形图利用中位数、25%分位数、75%分位数、上边界和下边界等统计量来描述数据的整体分布情况。本文统计这些参数计算生成箱体，箱体包含了大部分的正常数据，箱体外则判定为异常数据。上下边界的定义为

$$\begin{cases} \text{上边界} = 75\% \text{分位数} + (75\% \text{分位数} - 25\% \text{分位数}) \times 1.5 \\ \text{下边界} = 25\% \text{分位数} - (75\% \text{分位数} - 25\% \text{分位数}) \times 1.5 \end{cases} \quad (1)$$

当检测失真数据点后，采用连续5个数据的平均值填充，形成平滑时间序列。即

$$x'_{ii} = \frac{1}{5} \sum_{j=-2}^2 x_{ii+j} \quad (2)$$

为去除负荷数量级对模式分析的影响,本模型通过极值法归一化,以提取负荷形态^[7],即

$$x'_{ii} = (x_{ii} - x_{ii\min}) / (x_{ii\max} - x_{ii\min}) \quad (3)$$

式中: x'_{ii} 为采用极值法归一化后的第*i*点数据; $x_{ii\max}$ 和 $x_{ii\min}$ 分别为数据序列的最大值和最小值。归一化是指将用户用电数据压缩在区间[0, 1]中,若是对某些特性指标进行类别分析,则无需进行归一化。

2.2 用户用电特性多维评价指标的选取

根据用电特性的差异,基于不同用电模式对用户进行分类,研究各类用户的用电量变化规律,这是配用电大数据分析和应用的关键。用电模式的判别方法和结果与用电特性指标的选取密切相关,因此,需要定义合理的用电特性评价指标以辅助用电模式识别和用户分类。本文在综合现有评价指标的基础上,针对不同用户提出了包含时序与非时序数据的用户用电特性多维评价指标。从时域内提取时间序列的多个静态特征 $\gamma_1, \gamma_2, \dots, \gamma_w$ 。这些特征指标可以刻画出用电模式和辅助用户分类。例如:极值、均值和变异系数可以体现序列的离散程度;单位根检验值可以反映序列的平稳性;偏度刻画了时间序列相对于均值的不对称程度;峰度则描述了时间序列分布的波动是陡峭还是平缓。利用这些静态特征可以获得时间序列有用的信息。多维特征分析的数据集模型可以表示为

$$V_i(x_{i1}, x_{i2}, \dots, x_{im}; \gamma_1, \gamma_2, \dots, \gamma_w) \in V_D, \quad i = 1, 2, \dots, m \quad (4)$$

式中: $x_{i1}, x_{i2}, \dots, x_{im}$ 是月用电量时间序列向量; $\gamma_1, \gamma_2, \dots, \gamma_w$ 是非时序多维的特征向量。

3 聚类分析算法

不同用电类别的电力用户的用电行为特征不同,即使同一用电类别的用户,也会因一些因素影响而有所差别。一方面,居民用户月用电量数据集具有密度分布不均的特点,中、低月用电量用户占绝大多数,且分布密集;少部分用户集中在月高用电量区域,且分布较离散;另一方面,商业用户和工业用户的月用电量随季节和节假日变化明显,高峰期月用电量较大。因此,根据各个电价类别的用户的特点选取合适的密度邻域参数,对于月用电量分布密集的用户,密度参数取值较小,而月用电量数据集分布相对分散的用户,密度参数取值较大。

聚类(Clustering)是指将物理或抽象对象的集合分为相似的对象类的过程,属于无监督式学习范畴。

本文利用用户多维度用电特征的数据集 V_D ,寻找最高密度分布中心,再以多维密度聚类算法获得用户群体集合。其核心思路如下。

步骤 1、特征聚类。以每个特征维度 $\gamma_1, \gamma_2, \dots, \gamma_w$,用 K-means 进行聚类,利用特征聚类获得用电特征的分布。

步骤 2、寻找高密度中心。按照数理统计的方法,空间 S 中任意一个点 P 密度是指给定半径 ε ,点 P 的 ε 邻域内所包含的点的个数,记为 $D(P, \varepsilon) = |N(P, \varepsilon)|$,式中: $N(P, \varepsilon)$ 为 ε 邻域内点的集合; $|\cdot|$ 表示点的个数。

步骤 3、密度聚类。以高密度中心 P 为簇的初始中心位置,进行用户分类的聚类计算,划分簇。

4 分类算法预测

对于月度用电时间序列分析具有以下三种变化分解形式:1)趋势变动,指用电随时间变化呈现出持续稳定地上升、下降或平稳的趋势;2)周期变动,指用户用电受季节性影响,以固定周期呈现出的周期性变化;3)非平稳随机变动,指用户类受一些外部因素影响而呈现出的不规则波动,用电时间序列不平稳。

对比短期的负荷预测(96点/天),月度的用电量预测(12点/年)粒度较粗,时间序列的变化受到的影响复杂且难以挖掘,各种预测算法的敏感度都受到变化因素的影响。因此,用电量预测不适合研究一种算法来达到预测精度,然而,不同的时间序列采用不同的算法,所能达到的精度也是不一样的。文献[11-13]都利用标准数据集对多种预测算法进行了对比和分析。针对时间序列的分解,预测模型也可以分为线性周期性预测模型、线性非周期性预测模型和非线性预测模型。其中线性周期性预测模型有自回归积分移动平均(ARIMA)和三次指数平滑法(Holt-Winters);线性非周期性预测模型有回归算法和灰色(GM);非线性预测模型有支持向量机(SVM)和人工神经网络(ANN)^[14]。

各种算法模型都有各自的适用范围和优缺点,我们对比分析了大数据平台可调用的 R 语言各个算法包中的算法模型,见表 1。

5 算例分析

依据前文所述,本文构建了基于电力用户用电多维特征分析的月用电量预测模型,该模型由预处理、特征提取、多维聚类和算法预测组成。所有数据分析与算法预测均在大数据平台支持的开源 R 语言环境下实现。

表 1 算法对比

Table 1 A comparison of several algorithms

	优点	缺点
回归	回归模型参数估计技术成熟，过程简单，预测速度快，外推性好。	对原始时间序列平稳性要求高，当数据存在较大波动或缺陷，模型预测精度将大大降低。
ARIMA	所需的数据少，工作量小，计算速度快。	适用变化平稳的周期可拆解预测，专家系统过程复杂。
GM	不考虑数据变化趋势，数据需求少，计算简单，检验方便。	数据离散程度越大，灰度越大，预测精度越低。
ANN	具有较强的自学习、自组织和自适应能力，适应并行式分布处理。	算法上存在一些缺陷，收敛速度慢，容易导致局部最优。
SVM	能够很好地解决高维数、非线性、小样本和存在局部极值点等实际问题，具有全局最优、拟合精度高等优点。	存在训练时间长等缺点。在实际应用中，还没有建立选择模型参数的具体规范。

5.1 数据来源

本文的数据来源于电网某网省公司财务管控系统，从集成数据库中提取某区域 23 万用户的月度用电量数据，时间跨度为 2011 年 1 月至 2015 年 6 月。经有效性分析后，完整有效地分析用户数达到 16 万左右。将 2011 年 1 月至 2014 年 12 月的月用电量形成的表作为模型的建模训练数据集，2015 年 1 月至 2015 年 6 月的月用电量作为模型测试数据集进行数据分析和挖掘的计算。对数据集按照 2.1 节中介绍的方法进行数据预处理。然后，从用电训练数据集时域内提取时间序列的静态特征：最大值(max)、最小值(min)、均值(mean)、变异系数、单位根检验值(ADF)、偏度(SK)、峰度(KU)，7 个指标作为特征向量，计算方式如表 2 所示。

表 2 特征指标

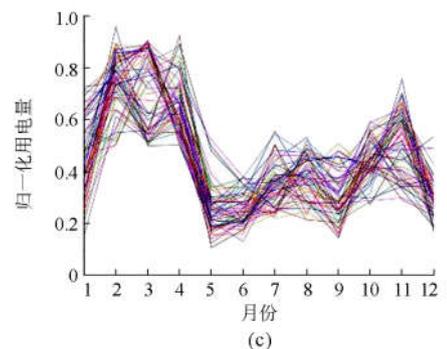
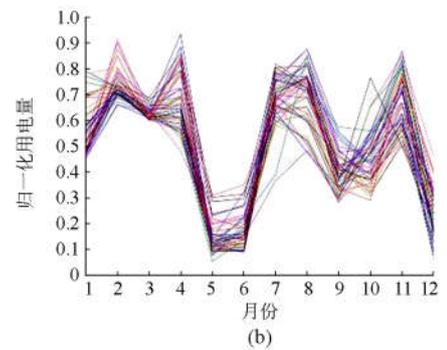
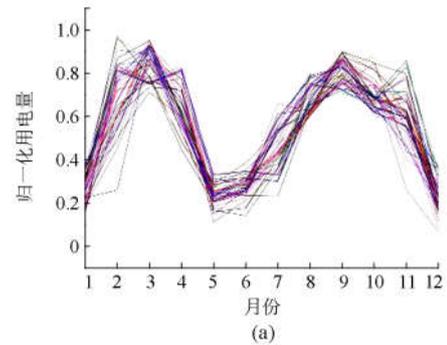
Table 2 Indexes of characteristics

名称	计算公式
最大/小值(max/min)	$\max/\min = \max/\min_{j=1, \dots, N} n_j$
均值(mean)	$u = \frac{1}{N} \sum_{j=1}^N n_j$
变异系数(CV)	$(\sqrt{\frac{1}{N-1} \sum_{j=1}^N (n_j - u)^2} / u) \times 100\%$
单位根检验值(ADF)	调用函数 <code>adf.test()</code>
偏度(skew)	$SK = \frac{\sum_{j=1}^N (n_j - u)^3}{(N-1)\sigma^3}$
峰度(kurt)	$KU = \frac{\sum_{j=1}^N (n_j - u)^4}{(N-1)\sigma^4}$

5.2 聚类分析

经多维特征计算后，用于聚类的用户用电特性数据集 V_D 包括 2011 年 1 月至 2014 年 12 月用户每月的用电量数据和 $\gamma_1, \gamma_2, \dots, \gamma_7$ 特征指标数据。依据本文第 3 节描述的聚类算法，初始化聚类数目为 4，在多维特征实现聚类。考虑图表显示效果，本节随机选取 500 个用户的聚类结果进行展示。

图 2 中，用户一年的月用电量曲线分别表示为 4 类曲线簇。图 2(a)是典型的双峰型用户，用电呈现周期性规律，同时，某些月份之间受到周期规律因素的影响，波动很大，例如 1 到 2 月；图 2(b)是多峰型，周期性特征不明显，波动也极大，需要算法能对周期和季节因素进行拆解；图 2(c)是单峰，序列受到的影响因素多样，极难拆解和提取，且峰的位置并不稳定，同时整个序列波动大、不平稳；图 2(d)是较为稳定且趋势增长型用户，该类用户用电平稳，波动不大。



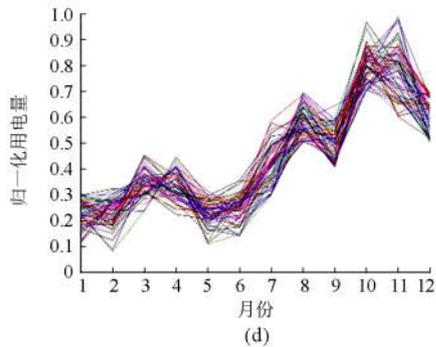


图2 月用电量聚类簇

Fig. 2 Clusters of monthly power consumption

基于聚类结果, 针对不同特征指标下的数据区间进行统计分析, 如表3所示。表3中, 加粗数据区间表示该指标在类中的用户数最多, 是训练的聚类高密度中心。从最大值(max)、最小值(min)、均值(mean)和峰度(KU)这4个特征指标看, 图2(a)展示的第一类用户簇和图2(c)展示的第三类用户簇中密度分布较高, 这4个特征主要描述了序列的离散程度。从变异系数、单位根检验值(ADF)看, 图2(b)展示的第二类用户簇密度分布较高, 这两个显示了序列的分散程度; 图2(d)展示的第四类用户簇密度分布较高的是偏度特征。从表3中可以分析出, 统计特征能够很好地展示序列的走势和状态。在这样的分类基础上, 能够更好地实现训练预测算法。

表3 不同特征指标的聚类统计

Table 3 Clustering results of different characteristic indexes

特征指标	数据区间			
	第一类	第二类	第三类	第四类
γ_1	[0.84,0.90]	[0.63,0.76]	[0.90,0.98]	[0.77,0.84]
γ_2	[0.05,0.12]	[0.22,0.31]	[0.17,0.22]	[0.13,0.17]
γ_3	[0.37,0.43]	[0.48,0.53]	[0.43,0.47]	[0.53,0.60]
γ_4	[0.46,0.52]	[0.41,0.46]	[0.52,0.60]	[0.33,0.40]
γ_5	[0.01,0.22]	[0.52,0.72]	[0.73,0.99]	[0.25,0.51]
γ_6	[-0.81,-0.24]	[0.62,1.22]	[-0.22,0.20]	[0.23,0.61]
γ_7	[2.55,3.30]	[1.10,1.60]	[1.60,1.99]	[2.02,2.51]

5.3 用户用电量预测

利用R语言, 实现前文介绍的6种可选用的预测模型: 自回归积分移动平均(ARIMA)、三次指数平滑法(Holt-Winters)、回归算法、灰色(GM)、支持向量机(SVM)和人工神经网络(ANN)。基于5.2节多维特征聚类训练的4类用户簇作为基本输入, 训练结合预测算法, 最终优选结果为: 第一类采用ARIMA; 第二类采用灰色; 第三类采用支持向量机; 第四类采用神经网络。本文预测了2014年1月至2014年6月的用户用电量, 并与实际值进行对比,

计算出预测的绝对百分误差($APE = |\text{预测值} - \text{真实值}| / \text{真实值} \times 100\%$), 结果如表4所示。

表4 新方法预测结果

Table 4 Forecasting results of the new model

月份	实际用电量 (10^8 kWh)	预测用电量 (10^8 kWh)	APE/%
2015.1	1 158 980 987	1 176 780 700	1.54
2015.2	830 762 230	859 838 908	3.50
2015.3	1 053 002 410	1 027 098 550	2.46
2015.4	1 154 609 366	1 156 735 690	0.18
2015.5	1 125 497 264	1 144 968 366	1.73
2015.6	1 138 760 608	1 161 036 563	1.96

以此, 我们进行对比实验, 不采用用户特征多维分析, 直接对序列进行灰色、ARIMA专家法和人工神经网络3种方法的预测, 预测结果的APE对比如图3所示。表5展示了连续6个月预测的平均绝对误差($MAPE = \sum APE / n$)。从图中和表中的结

果可以看出, 本文方法的预测值和真实值之间的误差较小, 而且6个月的预测差波动较低, 连续6个月的平均绝对误差仅为1.89。因此, 本文提出的基于电力用户用电多维特征分析的月用电量预测方法, 不仅实现了预测精度的提高, 而且精准预测的稳定性也有很大的提升。

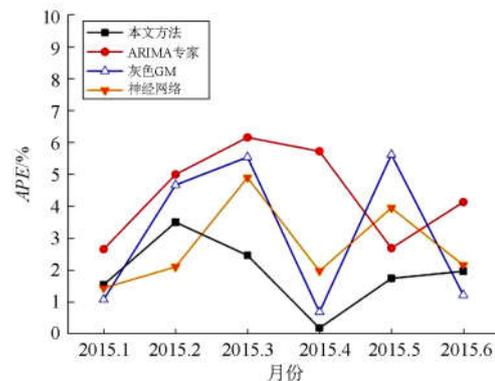


图3 不同方法预测结果

Fig. 3 Forecasting results by different methods

表5 不同方法预测结果对比

Table 5 Comparison of prediction results of different methods

	本文方法	ARIMA	灰色	神经网络
MAPE	1.89	4.39	3.13	2.75

6 结论

智能配用电大数据的快速发展和应用, 用电量的精准预测是基础之一。

1) 海量多用户用电特性研究, 建立多维度用电

特征评价指标体系, 快速有效地对海量用电数据进行特征分析识别, 能帮助电网公司获取用户用电的主体信息特征, 给智能用电管理和需求侧分析提供有效的决策支持。

2) 本文基于数据挖掘方法, 对用户多维度用电特征的数据集进行聚类, 挖掘用户群体信息, 有助于更深刻地认识用户及其群体特征。

3) 本文针对不同的用电模式, 采用多种预测算法对用户用电量进行建模, 该方法有效地避免了用电模式差异对预测算法准确性造成的不利影响。从文中的预测结果看, 不仅实现了预测精度的提高, 而且精准预测的稳定性也有很大的提升。

4) 本文提出的细粒度用户口径的月用电量预测方法, 采用 R 语言实现。不仅可以用于大数据平台上的配用电分析应用, 而且还可以在财务管控中协助财务人员实现月度购售电预算和控制, 降低年底损益预算的误差。

5) 如何在电网运营各环节中进一步合理利用数据挖掘方法, 建立用电量特性指标集、优化模型结构与参数、实现对用户聚类数目参数进行训练和优化、提高预测能力等是下一步的研究重点。

参考文献

[1] ALFARES H K, NAZEERUDDIN M. Electric load forecasting: literature survey and classification of methods[J]. International Journal of Systems Science, 2002, 33: 23-34.

[2] JONES R V, FUERTES A, LOMAS K J. The socio-economic, dwelling and appliance related factors affecting electricity consumption in domestic buildings[J]. Renewable and Sustainable Energy Reviews, 2015, 43: 901-917.

[3] HAN Y, SHA X, GROVER-SILVA E, et al. On the impact of socio-economic factors on power load forecasting[C] // Big Data (Big Data), 2014 IEEE International Conference on: IEEE, 2014: 742-747.

[4] 赵腾, 王林童, 张焰, 等. 采用互信息与随机森林算法的用户用电关联因素辨识及用电量预测方法[J]. 中国电机工程学报, 2016, 36(3): 604-614.

ZHAO Teng, WANG Lintong, ZHANG Yan, et al. Relation factor identification of electricity consumption behavior of users and electricity demand forecasting based on mutual information and random forests[J]. Proceedings of the CSEE, 2016, 36(3): 604-614.

[5] 王允平, 黄殿勋, 熊浩清, 等. 智能电网环境下采用关联分析和多变量灰色模型的用电量预测[J]. 电力系统保护与控制, 2012, 40(1): 96-100.

WANG Yuning, HUANG Dianxun, XIONG Haoqing, et al. Using relational analysis and multi-variable grey model for electricity demand forecasting in smart grid environment[J]. Power System Protection and Control, 2012, 40(1): 96-100.

[6] EDWARDS R E, NEW J, PARKER L E. Predicting future hourly residential electrical consumption: a machine

learning case study[J]. Energy and Buildings, 2012, 49: 591-603.

[7] RESHEF D N, RESHEF Y A, FINUCANE H K, et al. Detecting novel associations in large data sets[J]. Science, 2011, 334(6062): 1518-1524.

[8] KOLTER J Z, FERREIRA JR J. A large-scale study on predicting and contextualizing building energy usage[J]. 2011.

[9] 雷正新, 韩蓓, 聂萌, 等. 配电网大数据环境下的多点负荷预测算法与应用研究[J]. 电力系统保护与控制, 2016, 44(23): 68-78.

LEI Zhengxin, HAN Bei, NIE Meng, et al. Research and application of multi-node load forecasting algorithm under the environment of distribution network's big data[J]. Power System Protection and Control, 2016, 44(23): 68-78.

[10] ALMESHAI EI E, SOLTAN H. A methodology for electric power load forecasting[J]. Alexandria Engineering Journal, 2011, 50: 137-144.

[11] 鲁宝春, 赵深, 田盈, 等. 优化系数的 NGM(1,1,k)模型在中长期电量预测中的应用[J]. 电力系统保护与控制, 2015, 43(12): 98-103.

LU Baochun, ZHAO Shen, TIAN Ying, et al. Mid-long term electricity consumption forecasting based on improved NGM (1,1,k) gray model[J]. Power System Protection and Control, 2015, 43(12): 98-103.

[12] 孙伟, 常虹, 赵巧芝. 基于量子声优化的改进 DMSFE 组合模型及在中长期电量预测中的应用[J]. 电力系统保护与控制, 2014, 42(21): 66-73.

SUN Wei, CHANG Hong, ZHAO Qiaozhi. Forecasting mid-long term electricity consumption using a quantum harmony search based improved DMSFE combination model[J]. Power System Protection and Control, 2014, 42(21): 66-73.

[13] HE Jinghan, LIU Lin, LI Wenli, et al. Development and research on integrated protection system based on redundant information analysis[J]. Protection and Control of Modern Power Systems, 2016, 1: 13pp.

DOI 10.1186/s41601-016-0024-y

[14] 田野. 基于动量因子的神经网络群电流负荷预测模型[J]. 电力系统保护与控制, 2016, 44(17): 31-38.

TIAN Ye. A forecasting model for current load of neural network group based upon momentum factor[J]. Power System Protection and Control, 2016, 44(17): 31-38.

收稿日期: 2016-09-22; 修回日期: 2017-04-10

作者简介:

唐静(1984—), 女, 博士后, 研究方向为电力大数据与数据挖掘应用研究; E-mail: tangjing1205@gmail.com

李瑞轩(1974—), 男, 教授, 博士生导师, 研究方向为系统安全、云计算、大数据管理与分析; E-mail: rxli@hust.edu.cn

黄宇航(1972—), 男, 硕士, 工程师, 研究方向为电力系统分析、电力用电管理、电力大数据应用。E-mail: wudeming92692@126.com

(编辑 魏小丽)