

DOI: 10.7667/PSPC170167

需求侧响应下基于负荷特性的改进短期负荷预测方法

刘云¹, 张杭¹, 张爱民²

(1. 西安交通大学电气工程学院, 陕西 西安 710049; 2. 西安交通大学电子与信息工程学院, 陕西 西安 710049)

摘要: 为了提高需求侧电力负荷预测精度, 针对需求侧自身特点, 提出了基于负荷特性的改进短期负荷预测方法。依据需求侧负荷特性与属性聚类算法结合的方法完成两级需求侧负荷分类, 并使用优化改进粒子群优化径向基神经网络(MPSO-RBF)和最小二乘支持向量机回归模型(LS-SVM)等算法建立短期预测模型进行负荷预测。利用该方法对某工业园区用电负荷进行预测, 并与实际用电负荷数据和利用传统预测模型以及单一模型预测方法进行了比较分析。预测结果平均相对误差表明, 基于负荷特性的改进短期负荷预测方法是有效和实用的, 既能得到准确的负荷预测结果, 方便需求侧用户就地进行各类负荷针对性调控, 又方便管理者宏观掌控需求侧用户负荷情况, 有效推动能源互联网的发展。

关键词: 需求侧响应; 属性聚类; 改进粒子群优化径向基神经网络; 最小二乘支持向量机; 短期负荷预测

Improved load forecasting method based on load characteristics under demand-side response

LIU Yun¹, ZHANG Hang¹, ZHANG Aimin²

(1. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: In order to improve the accuracy of load forecasting for the demand side, this paper proposes an improved short-term load forecasting method based on demand-side load characteristics. It completes the two-segment classification for demand-side load according to the load characteristic and the attribute clustering algorithm, then establishes the forecasting model for load forecasting by using MPSO-RBF and LS-SVM. This method is used to forecast the power load of an industrial park, and is compared with the actual load data, the traditional forecasting model and the single model prediction method. It shows that the method is effective and practical, it can get accurate prediction results and control load for the users pertinently, and it is convenient to macroly control the load aggregation for manager. What's more, it can promote the development of the energy internet effectively.

Key words: demand side load; attribute cluster; MPSO-RBF; LS-SVM; short-term prediction

0 引言

在能源革命、“互联网+”和创新驱动等战略推动下, 传统电力行业正在掀起能源互联网发展的浪潮。能源互联网作为智能电网的核心和发展点, 增强了负荷的灵活性、可控性、可监测性, 促进了电网中各项元素智能化发展, 实现了多能源开放互联、能量自由多向传输以及“源荷网”的互动优化, 鼓励了需求侧用户积极参与能源管理, 保障了系统安全可靠运行^[1]。能源互联网包含互相耦合的多种设备元件, 通过使用互联网技术将设备数据化, 将所有主体自由联接, 实现不同类型能源和负荷协同优化管理。另一方面, 借鉴互联网的能源互联网实现

多种能源系统的开放互联, 并与信息通信技术融合转向与互联网融合, 利用互联网思维和技术, 依靠先进的数据分析及预测控制等手段, 有利促进电力能源行业进一步发展。

用电负荷的分析预测与控制管理是实现电力有序化管理的重要环节, 也是能源互联网系统中能源优化的组成部分^[2]。随着我国经济发展和用电结构的变化, 电力用户的负荷特性发生了很大变化。传统的电力负荷研究中主要以电力系统为研究单位, 其中负荷预测的研究目的在于发电计划和负荷需量分配方案。随着现代先进测量技术的发展, 以需求侧响应为导向的需求侧电力负荷分析成为研究的关注点。

随着现代技术理论不断提升, 负荷预测的方法从回归分析法、时间序列法、趋势外推法等发展到人工神经网络法^[3-5]、支持向量机法^[6]等。传统负荷预测方法将重点放在负荷数据序列本身, 应用于需求侧用户出现了收敛速度慢、预测精度低等问题^[7]。因此文献[8]提出了分段负荷预测方法, 文献[9]利用层次聚类分析对负荷曲线的标么值与基值分别预测, 而文献[10]根据各类负荷的特性, 提出各类针对性的负荷预测方法, 文献[11]提出针对配电网特性的分层预测模型, 取得较好的预测效果。

本文针对需求侧用户的负荷预测, 在分析已有方法的基础上, 从用户侧负荷特性入手, 采用负荷物理特性与属性聚类算法相结合的方法完成负荷二次细分, 使用精度较高的优化改进粒子群优化径向基神经网络(MPSO-RBF)和最小二乘支持向量机回归模型(LS-SVM)等算法建立负荷短期改进预测模型。预测模型适用于需求侧几百至几千千瓦的用户日负荷短期预测, 应用于涵盖多种类型负荷的工业园区, 能够得到更为准确的预测结果。

1 需求侧负荷特性分析与分类

日负荷曲线最直观展示了该负荷的特性, 其基本特征是波动性, 作为典型的时间序列, 其波动原因可概括归结为四种: 趋势变动、季节变动、循环变动和不规则变动^[12]。而对于需求侧的负荷短期分析, 较系统侧来说, 波动性更多表现为不规则变动, 即负荷与其众多的影响因素之间呈现复杂的非线性关系。传统负荷分析一般从电网负荷总量上分析负荷变化规律, 而忽略了用户用电规律本身, 因此分析结果会存在一定偏差。为了更准确地探求其不规则变动规律, 需要确定其变动的主要影响因素, 建立负荷有效分类, 这是实现准确预测的基础。

当前研究中分类方法主要分为两大类, 一种是依据用户行业特点或用电特点^[13], 结合实际生产生活经验来分析分类; 另一种是利用各种智能算法提取数据特点, 主要有小波聚类^[9]、K-means 聚类、模糊 C 均值聚类^[14]、密度聚类^[15]等, 并结合各类负荷指标^[16]综合衡量。前者依据主观经验将总负荷分类, 划分误差较大; 后者主要依靠数学算法寻找序列规律, 忽视了负荷自身变化的原因。依据分析, 本文采用负荷物理特性与聚类算法相结合的方法完成负荷分类。

1.1 需求侧用户负荷特性分析

需求侧电力负荷基数较小, 一些细微的负荷变动会对整个负荷曲线产生明显波动, 而天气、季节、生产计划和分时电价等负荷特性因素, 会对需求侧

用户的负荷产生较明显影响。电力负荷具有明显的周期性, 包括:

- 1) 不同日之间整体变化规律大致相同, 即日负荷高峰的峰值时间基本固定, 日负荷低谷的谷值时间也基本一致。
- 2) 每周同一周类型, 例如每周一的负荷曲线一般相似, 而每周日的负荷值也接近。
- 3) 工作日和休息日负荷具有自己的相似性。
- 4) 主要节假日负荷具有相似性。

用户电力负荷的不同时间尺度的负荷曲线可以展示负荷整体峰谷状态^[17], 如图 1 为典型用户一周的日负荷曲线, 周一至周五工作日曲线走势较为接近, 而周六周日由于作息时间不同有较大差异。

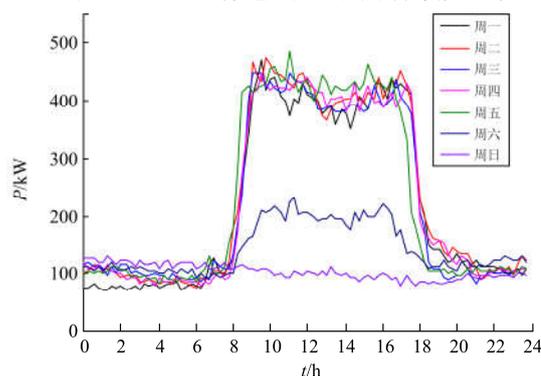


图 1 典型夏季一周日负荷曲线

Fig. 1 Daily load curve of typical summer week

需求侧响应下的用电负荷由各种用户聚合, 各个用户其作息时间和用电规律不同, 造成了日负荷曲线的差异。负荷变化又往往受到气温、湿度、风速、晴雨天气状况等多种气象因素影响^[18]。总负荷中各个分量受不同因素的影响程度不同。

1.2 需求侧负荷细分

用户需求侧响应针对用电用户端开展, 将每一个独立用户每一个端口采集的负荷数据作为分析对象计算量过大, 而整体配电网的尺度又过于宏观, 将负荷以合适的尺度分类更为合理。结合上述特征, 负荷的特征细分应当以用电类型为基础, 结合相关日期类型和气象等影响因素进行两级细分。

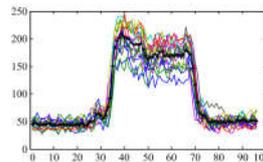
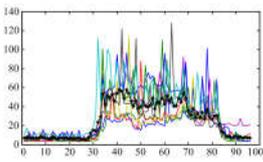
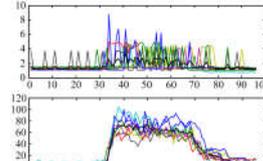
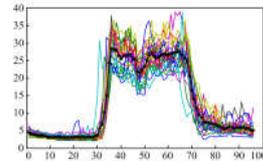
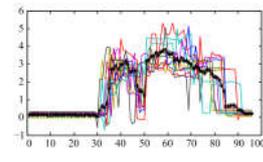
第一级细分是依据负荷的物理特性、用电习惯、影响因素等将负荷分为大类, 大类间的区分以负荷影响因素差异大而负荷分类复杂性低的原则进行。第二级细分是负荷预测的数据预处理阶段, 通过依据相关影响因素和特征量完成预测相似日集的选取。

常用的聚类方法有 K 均值(K-means)、模糊 C 均值(FCM)算法等, 但由于 K-means 容易陷入局部最优, 而 FCM 对噪声和野值较为敏感, 本文使用

文献[19]提出的稳健的属性聚类算法完成负荷细分。假设负荷数据集 X 有 N 个样本 x_n 和类数 K ，将其按照属性测度将 X 分为 K 类，即 K 个负荷数据相似日子集，类中心矢量 $M = (m_1, m_2, \dots, m_k)$ 。

依据上述原则，需求侧负荷按照大类特性分为基本保障负荷、生产计划负荷、气象敏感负荷、可控照明负荷和随机负荷五类，使用属性聚类算法聚类得到典型负荷分类曲线，其曲线特点及其需求侧响应措施如表 1 所示。

表 1 需求侧用户负荷典型分类
Table 1 Electrical load classification for typical distribution user side

负荷类型	负荷典型曲线	特点及典型需求侧响应措施
基本保障负荷		每日基本固定不变的基础电力负荷；重点保障，以维持正常工作生产
生产计划负荷		主要是生产类企业大负荷生产设备的运行产生的负荷；依据分时电价进行开机计划控制
气象敏感负荷		以空调等调温负荷为主，受到气象因素的影响；进行直接负荷控制，或进行柔性负荷控制
照明调控负荷		以照明负荷为主，负荷增减与日常作息和当日光照水平有关；通过调光照明或减少照明数量进行负荷控制
随机负荷		由使用规律性不强的小负荷组成，所占比例很小；对于过大尖峰可实施削峰控制

接着依据不同负荷大类的特征量进行负荷相似日的细分。以生产计划类负荷为例，典型生产工作计划一般分为正常上班、晚间加班、部分开机和停机休息。工厂生产计划具有阶段性，因此提出前一日负荷联合聚类的方法，即将每日负荷数据与上一日负荷数据合并联合分析连续两日数据。运用属性

聚类分类，将前一日的负荷作为特征量参数进行判别，计算特征量与数据中心矢量 M 的最短欧式距离，得到预测日相似输入数据集，作为预测模型的输入数据集进行预测。

其他类别负荷的细分方式如下所述。

1) 基本保障负荷

依据日期类型进行相似日细分，即分工作日、周六、周日与节假日三类，为基本相似日分类。

2) 气象敏感负荷

依据日期类型和气象因素完成聚类，即在基本日期相似日分类的基础上，将日最低气温、日最高气温、日相对湿度、日最大风速和日天气情况为特征量使用属性聚类，进而获得相似日集。

3) 可控照明负荷

依据日期类型和日天气情况完成聚类，即以阴晴雨等天气状况为特征量完成聚类。

4) 随机负荷

按照基本相似日完成分类获得相似日集。

通过对历史负荷数据进行不同维度的两级细分，将预测模型输入集误差影响因素大大减少，有利于下一阶段负荷预测。

2 改进短期负荷预测模型

采用基于负荷特性的改进负荷预测方法，步骤如图 2 所示。首先从 SCADA 数据库和气象数据库导入原始的用户负荷数据并预处理。先依据负荷特性细分为典型五类负荷，再使用属性聚类算法结合相关影响因素对每一类进行相似日细分。然后使用分布式预测模型对不同类别负荷分别预测，预测方法使用误差较小的优化改进粒子群优化径向基神经网络(MPSO-RBF)和最小二乘支持向量机回归模型(LS-SVM)算法。最后，通过耦合预测数据得到适用于需求侧响应的较准确短期负荷预测数据。

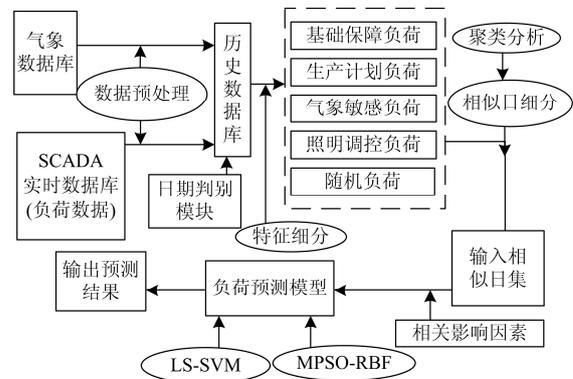


图 2 负荷预测方法流程图

Fig. 2 Flow chart of forecasting method

2.1 数据预处理

用户侧负荷预测历史数据由于系统不稳定等原因, 会有坏数据需要进行数据预处理。坏数据主要分为数据缺失和突变。

对于数据缺失, 较大缺失删除当日数据, 而较小缺失判断后使用相邻相似日数据补齐。

对于负荷数据突变, 若两点间的负荷值满足下述方程之一, 则存在突变。

$$\begin{cases} l(i) > (1 + \alpha_1) \times l(i-1) \\ l(i) < (1 + \alpha_2) \times l(i-1) \end{cases} \quad i = 2, 3, \dots, 96$$

式中: α_1 为负荷峰值的阈值; α_2 为负荷谷值的阈值。依据不同类型负荷分别取值。对于首端负荷, 使用右侧的级比生成进行修正, 而末端使用左侧数据修正, 中间段取其前后负荷加权平均。

2.2 负荷预测算法

径向基函数(RBF)神经网络具有较好的非线性和自学习能力, 但存在对初始条件敏感、隐含层难以确定等缺点。改进粒子群优化(MPSO)算法用来训练神经网络的参数, 从而优化网络实现 RBF 神经网络参数自动优化^[20]。

算法流程如图 3 所示。

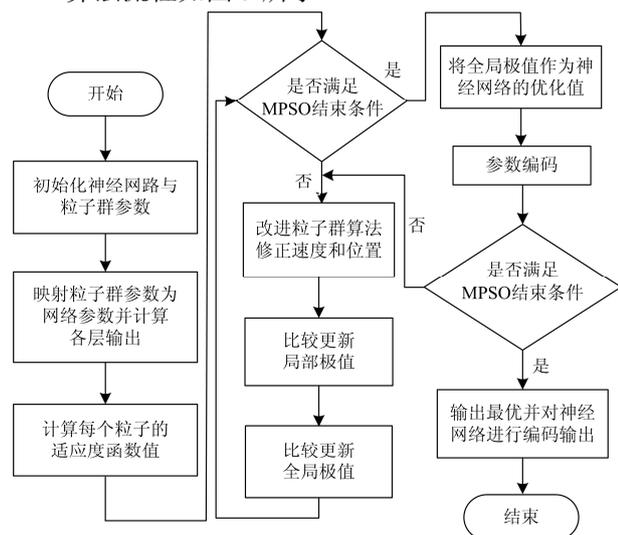


图 3 改进粒子群优化径向基神经网络预测流程

Fig. 3 MPSO-RBF neural network forecasting process

而最小二乘支持向量机(LS-SVM)采用最小二乘线性系统作为损失函数, 用等式约束代替支持向量机中的不等式约束条件, 将二次规划问题的求解转化为线性方程的求解, 简化了计算并提高了算法的收敛速度, 广泛应用于预测领域^[21-23]。

在已获得的研究成果中, 以上两种预测方法对于适用的负荷序列均有较好的预测准确性。综合使用两种模型并验证选取合适模型能进一步减少误差。

3 算例分析

本文以 2015 年 6 月至 2016 年 6 月某工业园区的各类用户电力负荷验证负荷预测方法。工业园区内含有的科研单位 A、行政单位 B、服务单位 C、设备工厂 D 和宾馆 D 共 5 个工业企业用户单位, 30 多个一级负载进线, 200 多个负载采集端口, 包含多种不同种类的负荷, 且负荷特性不尽相同。电力负荷数据来源为园区内 SCADA 系统, 数据采样间隔为 15 min, 每日数据由 96 点负荷数据组成。

首先获取数据并进行数据预处理, 将历史负荷数据按照上文所述特征细分方法分为五类, 现以气象敏感负荷为例详细阐述。

3.1 气象因素综合聚类修正的气象敏感负荷预测

本文使用该工业园区 2015 年全年历史数据预测当年冬季某日气象敏感类负荷。首先将历史负荷数据和对应历史气象数据进行数据预处理, 修正坏数据。将历史负荷数据完成[0,1]归一化处理^[24], 气象数据进行模糊化处理, 如表 2 所示。

表 2 气象因素特征量模糊化处理

Table 2 Fuzzy processing for meteorological factors

特性量	符号	模糊化方式
日最高气温, 日最低气温	T_{\max}, T_{\min}	在预测用历史数据集中作[0,1]归一化
最大风速	V	$V = \begin{cases} 0.25, V \leq 1.5 \text{ m/s} \\ 0.5, 1.6 < V \leq 5.4 \text{ m/s} \\ 0.75, 5.5 < V \leq 10 \text{ m/s} \\ 1, V > 10 \text{ m/s} \end{cases}$
相对湿度	H	$H = \begin{cases} 0.25, H \leq 30\% \\ 0.5, 30\% < H \leq 60\% \\ 0.75, 60\% < H \leq 80\% \\ 1, H > 80\% \end{cases}$
人体舒适度	C_{ssd}	$C_{\text{ssd}} = \begin{cases} 0.25, C_{\text{ssd}} \leq 25 \text{ 或 } C_{\text{ssd}} \geq 85 \\ 0.5, 25 < C_{\text{ssd}} \leq 38 \text{ 或 } 80 \leq C_{\text{ssd}} < 85 \\ 0.75, 38 < C_{\text{ssd}} \leq 58 \text{ 或 } 70 < C_{\text{ssd}} < 80 \\ 1, 59 \leq C_{\text{ssd}} \leq 70 \end{cases}$
天气状况	W	$W = \begin{cases} 0.25, \text{暴雨等恶劣天气} \\ 0.5, \text{雨雪} \\ 0.75, \text{阴, 多云} \\ 1, \text{晴} \end{cases}$

使用人体舒适度(C_{ssd})来衡量综合气象因素对人体感受的影响^[25-26]:

$$C_{\text{ssd}} = (1.818T + 18.18) \times (0.88 + 0.002H) + \frac{(T - 32)}{(45 - T)} - 3.2V + 18.2$$

式中: T 为日平均气温; H 为相对湿度; V 为风速。

气象敏感负荷的相似日细分特征量由当日模糊化处理后的气象数据组成, 依据待预测日当日天气预报数据作为考察量, 与聚类气象数据中心矢量欧式距离匹配, 选出相似日集作为预测输入数据。

负荷预测方法为全日 96 点逐点预测, 即第 i 日每一时刻输入数据组成为

$$\{T_{\max_i}, T_{\min_i}, V_i, H_i, C_{\text{ssd}_i}, W_i, N_{i-1}, T_{\max_{i-1}}, T_{\min_{i-1}}, V_{i-1}, H_{i-1}, C_{\text{ssd}_{i-1}}, W_{i-1}, N_{i-7}, T_{\max_{i-7}}, T_{\min_{i-7}}, W_{\text{ssd}_{i-7}}\},$$

输出量为 N_i 。

其中: T_{\max} 为日最高气温; T_{\min} 为日最低气温; V 为日最大风速; H 为日相对湿度; W 为日天气状况; C_{ssd} 为日人体舒适度; 而 N_i 为第 i 日该时刻负荷值。

MPSO-RBF 神经网络系统采用三层结构, 其第一层输入为 17 个神经元, 第二层隐含神经元由 MPSO 优化得到, 第三层为输出层为 1 个, 对应于预测日某时刻负荷的预测值。MPSO-RBF 模型的初始参数分别为: 惯性因子 $\omega=0.6$, $c_1=2$, $c_2=2.2$, 基宽参数 σ_i 为 $[0.1, 3]$, C_{ij} 为 $[-3, 3]$, w_i 为 $[-1, +1]$, 粒子群 $M=80$, 最大进化代数为 1 000。其中神经网络的输出误差为 0.004 575 83, 而预测精度目标为 0.005。

通过相似日数据组成的输入集导入负荷预测模型中得到预测结果, 96 点预测值按时间序列排列即得到气象敏感负荷预测值。分别使用优化预测算法 MPSO-RBF 模型和 LS-SVM 模型预测当日负荷, 并与小波神经网络和 RBF 神经网络对比预测效果。

预测结果如图 4 所示。四种预测方法与实际当日负荷数据相对比, 由负荷曲线可以看出普通 RBF 神经网络预测有明显误差, 而使用 MPSO 优化后的 RBF 神经网络有效地减少了预测误差。

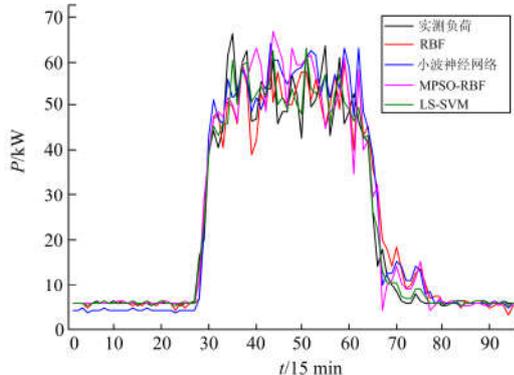


图 4 气象敏感负荷预测模型对比

Fig. 4 Comparison of weather-sensitive load forecasting models

使用平均绝对值误差 P_{MAPE} 来衡量各个模型精确度, 如表 3 所示。

$$P_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{p_i - r_i}{r_i} \right| \times 100\%$$

式中: N 为预测点数; p_i 为第 i 点的预测值; r_i 为第 i 点的实际值。

表 3 气象敏感负荷预测模型对比

Table 3 Comparison of weather-sensitive load forecasting models

预测模型	RBF	小波神经网络	MPSO-RBF	LS-SVM
P_{MAPE}	20.51%	24.08%	17.74%	6.41%

可以看出, 小波神经网络误差率较高, 改进粒子群优化后的径向基神经网络较之前有预测精度的提升, 而最小二乘支持向量机回归模型 LS-SVM 对于气象敏感负荷数据远小于其他方法的误差率。

3.2 负荷预测结果与误差分析

为了验证本文方法的有效性, 分别从负荷预测模型选取和负荷特性细分方法两方面来验证。

首先, 使用本文所述细分方法并分别使用 MPSO-RBF 模型和 LS-SVM 模型分别预测五类已细分负荷, 与基本的径向基神经网络 RBF 对比误差, 并选取预测模型和方法。预测结果的平均绝对值误差 P_{MAPE} 对比如表 4 所示。

表 4 分类负荷预测模型对比

Table 4 Comparison of classified load forecasting models

预测模型	RBF	MPSO-RBF	LS-SVM	选取模型
基本保障负荷	15.46%	13.25%	9.77%	LS-SVM
可控照明负荷	23.56%	17.48%	22.33%	MPSO-RBF
气象敏感负荷	20.51%	13.27%	6.41%	LS-SVM
生产计划负荷	29.66%	13.58%	32.09%	MPSO-RBF
随机负荷	37.87%	36.26%	41.79%	MPSO-RBF

由于随机负荷不可控因素较大而误差略大, 而由于随机负荷的分离, 其他类型负荷的误差水平均较其他模型有较明显减少, 且处于需求侧负荷预测的较理想水平。说明 MPSO-RBF 模型或 LS-SVM 模型对于适合类型负荷数据, 较其他预测模型能够有效提升预测精度。

接着, 将本文提出的二次细分负荷的改进负荷预测模型与整体使用 MPSO-RBF 神经网络模型和最小二乘支持向量机回归 LS-SVM 模型对比, 预测工业园区日负荷曲线图对比如图 5, 其中 MPSO-RBF 神经网络模型的 P_{MAPE} 为 13.94%, LS-SVM 模型 P_{MAPE} 为 12.94%, 而本文的改进预测方法 P_{MAPE} 为 6.79%, 准确度有明显提升。

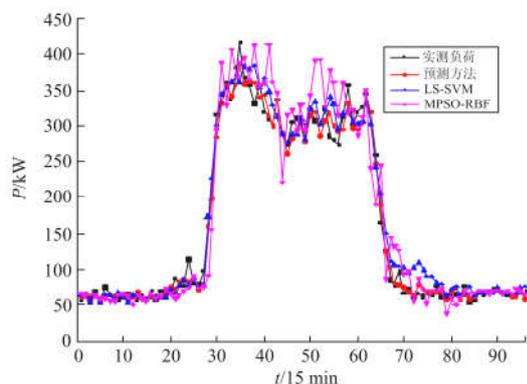


图5 短期负荷预测模型对比

Fig. 5 Comparison of short-term load forecasting models

3.3 改进负荷预测模型的应用

对于电力负荷连续预测工作, 使用本文基于负荷特性的改进负荷预测方法对工业园区连续30日负荷数据进行考察。使用本文上述细分方式, 对于某工业园区2016年6月整月电力负荷进行分析, 并使用改进预测方法进行短期日负荷预测, 并与现有负荷预测方法进行对比。如图6是2016年6月日负荷短期预测的平均绝对值误差, P_{MAPE} 最大值为12.90%, 说明本文的改进预测方法对于负荷基数小而负荷易波动的需求侧负荷, 有较为理想的预测结果。

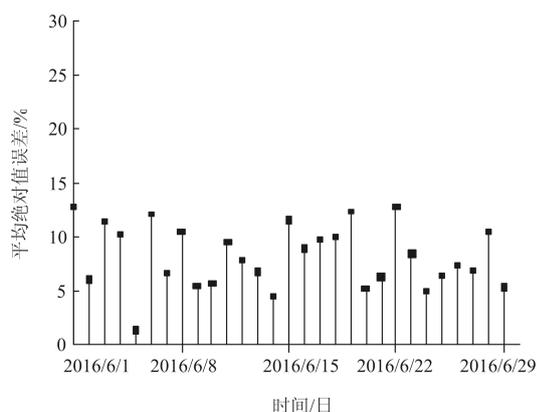


图6 2016年6月负荷预测数据平均绝对值误差

Fig. 6 MPAE of load forecasting data in June 2016

上文所述的改进负荷预测方法, 能够有效应用于需求侧电力负荷短期预测, 对于几百千瓦至几千千瓦需求侧短期日负荷, 使用负荷细分方法结合相关预测模型, 相比于其他方法能够得到较好的预测效果。除此以外, 还可以通过该负荷预测方法得到:

1) 需求侧用户的有效分类以及相关负荷管理控制, 如气象敏感负荷分类提取后, 可以使用相关空调控制策略完成需求侧响应。

2) 应用需求侧能源管理系统, 预测所监控负荷

变化趋势, 对管理者调控生产计划或部署节能减排工作提供有力支持。

3) 结合能源互联网技术, 将电力短期负荷预测结果应用于能量管理、调节和输配等环节, 将需求侧负荷与分布式发电和储能设备相结合, 实现电力能源互联互通。

4 结论与展望

本文通过分析需求用户侧负荷的特性和影响因素, 提出基于需求侧响应和负荷细分的负荷短期预测方法, 并得到较为理想的预测结果。

1) 不同于传统电力系统负荷预测方法, 从用户侧自身特点入手, 分析各类负荷特性, 提出负荷的整体周期性和负荷特异性, 依据负荷特性有效细分负荷并选用合适的预测方法, 提高了需求侧负荷预测精度, 同时为后续需求侧管理提供了有力依据。

2) 采用负荷物理特性与属性聚类算法相结合的方法完成负荷细分。按照负荷特征和需求侧响应机制将负荷分为五类, 并针对不同类负荷特点, 使用属性聚类算法两级细分为相似日集。

3) 分布式预测模型使用改进粒子群优化径向基神经网络(MPSO-RBF)和最小二乘支持向量机回归模型LS-SVM预测模型优化算法, 有效减少预测误差。使用优化后预测模型较优化前有明显准确度提升, 而使用分布式预测模型较整体直接预测, 平均绝对值误差 P_{MAPE} 明显减小。

4) 对于由空调负荷构成的气象敏感负荷, 使用气象因素模糊化处理后聚类分析, 得到优化相似日数据集, 使用LS-SVM预测, 得到较为准确的预测值; 而生产计划负荷, 依据实际生产计划选择相似日, 提出前一日为特征量的聚类方法, 使用MPSO-RBF模型预测误差较小。

依据负荷特性的改进负荷短期预测可以便利地成为需求侧调控的重要依据, 精确度高的预测结果既能方便需求侧用户就地进行各类负荷针对性调控, 又方便管理者宏观掌控负荷聚合端负荷情况, 更能有效推动能源互联网的发展。

参考文献

- [1] 李倩玉. 智能电网下负荷特性分析和负荷预测新技术[D]. 南京: 东南大学, 2014.
LI Qianyu. New technologies of load characteristic analysis and load forecasting under the smart grid[D]. Nanjing: Southeast University, 2014.
- [2] 王蓓蓓, 李扬, 高赐威. 智能电网框架下的需求侧管理展望与思考[J]. 电力系统自动化, 2009, 33(20): 17-22.

- WANG Beibei, LI Yang, GAO Ciwei. Demand side management outlook under smart grid infrastructure[J]. Automation of Electric Power Systems, 2009, 33(20): 17-22.
- [3] HIPPERT H S, PEDREIRA C E, SOUZA R C. Neural networks for short-term load forecasting: a review and evaluation[J]. IEEE Transactions on Power Systems, 2001, 16(1): 44-55.
- [4] FAN S, CHEN L. Short-term load forecasting based on an adaptive hybrid method[J]. IEEE Transactions on Power Systems, 2006, 21(1): 392-401.
- [5] 李龙, 魏靖, 黎灿兵, 等. 基于人工神经网络的负荷模型预测[J]. 电工技术学报, 2015, 30(8): 225-230.
- LI Long, WEI Jing, LI Canbing, et al. Prediction of load model based on artificial neural network[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 225-230.
- [6] 张劲帆. 配电网分布式负荷预测方法[D]. 长沙: 湖南大学, 2013.
- ZHANG Jinfan. Distributed load forecasting method for distribution network[D]. Changsha: Hunan University, 2013.
- [7] 杨浩, 何茜, 殷家敏. 基于改进熵值法和限幅小波的大波动地区短期负荷预测[J]. 电力系统保护与控制, 2012, 40(11): 70-75.
- YANG Hao, HE Qian, YIN Jiamin. Short load forecasting in heavy wave areas based on improved entropy method and limited wavelet analysis[J]. Power System Protection and Control, 2012, 40(11): 70-75.
- [8] 沈沉, 秦建, 盛万兴, 等. 基于小波聚类的配变短期负荷预测方法研究[J]. 电网技术, 2016, 40(2): 521-526.
- SHEN Chen, QIN Jian, SHENG Wanxing, et al. Study on short-term forecasting of distribution transformer load using wavelet and clustering method[J]. Power System Technology, 2016, 40(2): 521-526.
- [9] 董聪. 智能配电网馈线负荷预测系统研究[D]. 哈尔滨: 哈尔滨工业大学, 2014.
- DONG Cong. Study of feeder load forecasting system for smart distribution grid[D]. Harbin: Harbin Institute of Technology, 2014.
- [10] SUN X, LUH P B, CHEUNG K W, et al. An efficient approach to short-term load forecasting at the distribution level[J]. IEEE Transactions on Power Systems, 2015, 31(4): 2526-2537.
- [11] 董继征, 何怡刚, 王薇, 等. 基于电力细分市场的负荷分解预测方法[J]. 电网技术, 2005, 29(17): 40-43.
- DONG Jizheng, HE Yigang, WANG Wei, et al. Load decomposition forecasting method based on electricity segment market[J]. Power System Technology, 2005, 29(17): 40-43.
- [12] 陈昊. 基于广义自回归条件异方差模型的负荷预测新方法[J]. 电力系统自动化, 2007, 31(15): 51-54.
- CHEN Hao. A new method of load forecasting based on generalized autoregressive conditional heteroscedasticity model[J]. Automation of Electric Power Systems, 2007, 31(15): 51-54.
- [13] 张铁峰, 顾明迪. 电力用户负荷模式提取技术及应用综述[J]. 电网技术, 2016, 40(3): 804-811.
- ZHANG Tiefeng, GU Mingdi. Overview of electricity customer load pattern extraction technology and its application[J]. Power System Technology, 2016, 40(3): 804-811.
- [14] 黄宇腾, 侯芳, 周勤, 等. 一种面向需求侧管理的用户负荷形态组合分析方法[J]. 电力系统保护与控制, 2013, 41(13): 20-25.
- HUANG Yuteng, HOU Fang, ZHOU Qin, et al. A new combinational electrical load analysis method for demand side management[J]. Power System Protection and Control, 2013, 41(13): 20-25.
- [15] 廖峰, 张泽良, 徐聪颖, 等. 基于 FCM 与影响因子的母线负荷特性分析[J]. 陕西电力, 2014, 42(8): 40-45.
- LIAO Feng, ZHANG Zeliang, XU Congying, et al. Bus load characteristics analysis based on FCM and impact factors[J]. Shaanxi Electric Power, 2014, 42(8): 40-45.
- [16] 陈明辉, 王珂, 蔡莹, 等. 基于数据驱动的母线负荷特性分析[J]. 南方电网技术, 2016, 10(2): 70-76.
- CHEN Minghui, WANG Ke, CAI Ying, et al. Bus load characteristics analysis based on data-driven method[J]. Southern Power System Technology, 2016, 10(2): 70-76.
- [17] 刘思, 李林芝, 吴浩, 等. 基于特性指标降维的日负荷曲线聚类分析[J]. 电网技术, 2016, 40(3): 797-803.
- LIU Si, LI Linzhi, WU Hao, et al. Cluster analysis of daily load curves using load pattern indexes to reduce dimensions[J]. Power System Technology, 2016, 40(3): 797-803.
- [18] 褚燕, 张征, 黄兴德, 等. 国外空调负荷需求侧响应综述及启示[J]. 华东电力, 2014, 42(4): 639-644.
- CHU Yan, ZHANG Zheng, HUANG Xingde, et al. Review and enlightenment of foreign air conditioning load demand side response[J]. East China Electric Power, 2014, 42(4): 639-644.
- [19] 张媛祥. 一种稳健的聚类方法[J]. 数学的实践与认识, 2003, 33(8): 8-10.
- ZHANG Yuanxiang. A kind of robust clustering method[J]. Mathematics in Practice and Theory, 2003, 33(8): 8-10.
- [20] 师彪, 李郁侠, 于新花, 等. 基于改进粒子群-径向基

- 神经网络模型的短期电力负荷预测[J]. 电网技术, 2009, 33(17): 180-184.
- SHI Biao, LI Yuxia, YU Xinhua, et al. Short-term load forecasting based on modified particle swarm optimization and radial basis function neural network model[J]. Power System Technology, 2009, 33(17): 180-184.
- [21] 王宁, 谢敏, 邓佳梁, 等. 基于支持向量机回归组合模型的中长期降温负荷预测[J]. 电力系统保护与控制, 2016, 44(3): 92-97.
- WANG Ning, XIE Min, DENG Jialiang, et al. Mid-long term temperature-lowering load forecasting based on combination of support vector machine and multiple regression[J]. Power System Protection and Control, 2016, 44(3): 92-97.
- [22] 李霄, 王昕, 郑益慧, 等. 基于改进最小二乘支持向量机和预测误差校正的短期风电负荷预测[J]. 电力系统保护与控制, 2015, 43(11): 63-69.
- LI Xiao, WANG Xin, ZHENG Yihui, et al. Short-term wind load forecasting based on improved LSSVM and error forecasting correction[J]. Power System Protection and Control, 2015, 43(11): 63-69.
- [23] 林顺富, 郝朝, 汤晓栋, 等. 基于数据挖掘的楼宇短期负荷预测方法研究[J]. 电力系统保护与控制, 2016, 44(7): 83-89.
- LIN Shunfu, HAO Chao, TANG Xiaodong, et al. Study of short-term load forecasting method based on data mining for buildings[J]. Power System Protection and Control, 2016, 44(7): 83-89.
- [24] LI Zhi, YE Lin, ZHAO Yongning, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 9-16. DOI: 10.1186/s41601-016-0016-y.
- [25] 高赐威, 李倩玉, 苏卫华, 等. 短期负荷预测中考虑积温效应的温度修正模型研究[J]. 电工技术学报, 2015, 30(4): 242-248.
- GAO Ciwei, LI Qianyu, SU Weihua, et al. Temperature correction model research considering temperature cumulative effect in short-term load forecasting[J]. Transactions of China Electrotechnical Society, 2015, 30(4): 242-248.
- [26] 樊唯钦, 张伟, 李勇钢, 等. 基于改进人体舒适指数的微电网超短期负荷预测[J]. 广东电力, 2017, 30(4): 137-142.
- FAN Weiqin, ZHANG Wei, LI Yonggang, et al. Ultra short-term load forecasting for micro-grid based on improved human comfort index[J]. Guangdong Electric Power, 2017, 30(4): 137-142.
- [27] 谷云东, 张素杰, 冯君淑, 等. 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, et al. Multi-model fuzzy synthesis forecasting of electric power loads for larger consumers[J]. Transactions of China Electrotechnical Society, 2015, 30(23): 110-115.

收稿日期: 2017-02-10; 修回日期: 2017-11-02

作者简介:

刘云(1992—), 女, 硕士研究生, 研究方向为电力需求侧负荷预测和控制; E-mail: liuyunxjtu@163.com

张抗(1962—), 男, 硕士, 副教授, 研究方向为智能电器与智能控制技术; E-mail: zhangh@mail.xjtu.edu.cn

张爱民(1962—), 女, 博士, 教授, 博士生导师, 研究方向为新能源控制技术。E-mail: zhangam@mail.xjtu.edu.cn

(编辑 张爱琴)