

面向云边协同的配变短期负荷集群预测

郭祥富¹, 刘昊², 毛万登², 范敏³, 胡雅倩³, 夏嘉璐³

(1. 国网河南省电力公司, 河南 郑州 450052; 2. 国网河南省电力公司电力科学研究院, 河南 郑州 450052;
3. 重庆大学自动化学院, 重庆 400044)

摘要: 配电变压器是配电网中连接用户的重要设备, 研究其负荷变化规律是十分重要的。随着物联网技术在电力系统中的推广, 配电网中监测的配电变压器将越来越多, 但对众多设备逐一分析建模会导致工作低效。因此, 提出面向云边协同的配变负荷预测框架, 并着重研究云端的集群预测模型。首先, 集群预测模型对配变进行日负荷曲线聚类, 提取日负荷模式, 并分析各配变日负荷模式变化规律, 采用聚类方法划分具有相似用电行为的配变。然后, 将同类别配变负荷数据整合训练, 利用 STL-LSTMs-XGBoost 预测模型实现配变的短期负荷集群预测。最后, 通过使用某市配变的负荷数据作为算例进行分析, 实验结果验证了所提方法的可行性和有效性。

关键词: 云边协同; 负荷曲线聚类; 短期负荷预测; 集群预测

Short-term load cluster forecast of distribution transformers for cloud edge collaboration

GUO Xiangfu¹, LIU Hao², MAO Wandeng², FAN Min³, HU Yaqian³, XIA Jialu³

(1. State Grid Henan Electric Power Company, Zhengzhou 450052, China; 2. State Grid Henan Electric Power Company Research Institute, Zhengzhou 450052, China; 3. College of Automation, Chongqing University, Chongqing 400044, China)

Abstract: The distribution transformer (DT) is an important piece of equipment connecting users in a distribution network, and it is very important to study the law of load changes. With the promotion of IoT technology applied in a power system, more and more DTs are monitored in the distribution network, but analyzing and modeling for many devices one by one will be inefficient. Therefore, this paper proposes a technical framework of distribution transformer load forecast for cloud edge collaboration, focusing on a cluster forecast model in the cloud. First, it performs daily load curve clustering on DTs, extracts daily load patterns, analyzes the changes in daily load patterns of DTs, and puts DTs with similar power consumption behavior into one category. Then, it integrates the same type of DT load data for training, and uses the STL-LSTMs-XGBoost forecasting model to realize short-term load cluster prediction of the DT. By using the load data of a city's DTs as an example for analysis, the experimental results verify the feasibility and effectiveness of the proposed method.

This work is supported by the National Key Research and Development Program of China (No. 2020YFB2009405).

Key words: cloud edge collaboration; load curve clustering; short-term load forecasting; cluster forecasting

0 引言

配电变压器是向用户分配电能和供给电能的重要配电设备。当配变负载率较高时, 其处于重过载状态, 容易导致内部结构损耗; 当配变负载率较低时, 其处于轻载状态, 容易增加系统的无功功率。因此分析配变的负荷变化规律, 构建相应的负荷预

基金项目: 国家重点研发计划项目资助(2020YFB2009405);
国家电网河南省电力公司科技项目资助(5217022000A6)

测模型, 对配变运行风险的智能管控发挥着重要的作用^[1-2]。目前, 物联网技术助推智能配电网的建设, 将全面支撑配电网运行性能的提升。配电物联网技术采用“云管边端”架构, 云中心负责数据汇集、深度挖掘和高级业务的处理, 边缘计算端负责数据采集和就地处理, 满足实时业务的研判要求, 达到数据交互、计算共享、业务切分的目的。因此, 利用云边协同^[3-5]模式构建负荷预测模型, 对于解决异常工况预测预警问题是一种新的有益探索。

为掌握多用电对象的负荷变化趋势, 常见的处

理方式为预测所有用电对象的负荷总量或者将用电对象进行集群预测。

负荷总量预测是将所有用电对象的负荷求和后进行分析。考虑到不同用电对象的用电行为不相同, 直接累加合并进行学习, 容易导致各对象用电特征被破坏, 从而降低了预测精度^[6]。因此, 文献[7-8]使用聚类算法将各用户按照用电特性分成不同的组, 然后将每个组的负荷求和学习, 最后将各组预测结果汇总得到负荷总量预测值。但是负荷总量预测无法掌握每台配变的负荷趋势。而负荷集群预测是将多个对象的负荷整合训练为一个预测模型, 可以预测每台配变的负荷变化趋势。考虑到用电行为相差较大的用电对象一起训练, 会对集群预测精度产生影响, 文献[9-10]利用用户的负荷数据进行聚类, 实现用户分类, 然后将每个类别的负荷数据整合建立预测模型。因此, 为提高短期负荷预测精度与效率, 本文先将用电对象分为多个集群, 然后使用性能较好的预测模型将同一集群的配变负荷数据整合训练, 实现多台配变的集群预测。

对于电力用户而言, 不同用户群体或地区用电习惯不同。目前我国按照用户的行业背景、电压等级与用电规模对用户进行分类电价设计^[11]。然而用户用电规律是动态变化的, 依照这些静态属性进行用户分类是不全面的^[12]。文献[6]选择用户的负荷、环境等统计特征对用户进行相似性聚类。文献[8]随机选取每个用户 10 天的日负荷数据进行 10 次聚类, 取实验的平均结果作为用户分类的结果。但这些方法仅仅使用了用户的部分负荷数据, 容易存在用电特性丢失。文献[8,10]直接利用用户一段时间的负荷数据进行聚类, 但当数据维度较大时, 用户特性区分不明显。文献[13]采用相似日法综合考虑用户的历史负荷及其影响因素对未来负荷进行预测。文献[14]考虑了用户模式的多样性, 将负荷模式相同的用户分为一类, 实现了用户分类。但是面对一个用户存在多种负荷模式时, 仅考虑负荷模式的相似性是不够完整的, 还应该考虑多种负荷模式的变化规律相似性。

综上所述, 为实现物联网构架下有效的大规模配变短期负荷预测, 并解决以上集群预测中存在的问题, 提高短期负荷预测精度, 本文提出面向云边协同的配电变压器负荷预测框架, 着重研究云端的集群预测模型。集群模型构建主要有以下贡献: 1) 提出一种基于相似用电行为的配变划分方法, 该方法通过分析配变日负荷模式的规律, 将配变按照相似日负荷模式与相似日负荷模式变化规律进行划分, 从而为短期负荷集群预测提供支撑; 2) 为提高

短期负荷预测效率, 本文通过负荷曲线形态分析与幅值分析实现配变分类, 针对每一类配变实现短期负荷集群预测。通过对比实验, 验证了本文方法在提高工作效率的同时, 能达到与非集群预测精度相似的效果, 有助于下一步迁移至边端形成有效的就地研判模型。

1 面向云边协同的配变负荷预测框架

在配电物联网“云管边端”的建设体系下, 负荷预测模型通过云边协同机制进行云端与边端的部署。在云端, 大规模配电变压器的运行数据汇集, 可进行数据的深度挖掘^[15-17]。考虑到负荷预测与负荷运行规律密切相关, 因此负荷预测模型训练首先开展相似性聚类划分, 然后再进行针对性建模, 即集群建模思路。在边缘节点处, 台区智能融合终端根据配电变压器的划分类型, 从云端下载相应负荷预测模型, 并采用迁移学习方法进行模型的微调, 使之适应就地研判的需求, 发挥较好的负荷预测效果, 为配电变压器异常工况预警提供依据, 从而达到配电变压器精准运维目的。面向云边协同的配变负荷预测框架如图 1 所示。在本文中重点探讨云端集群预测模型的构建。

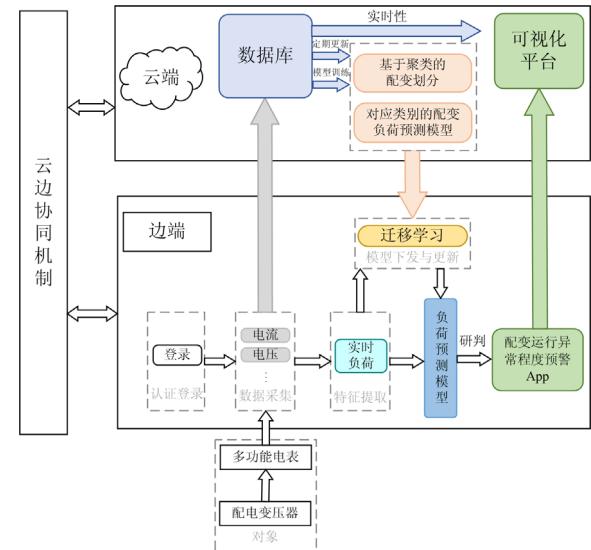


图 1 面向云边协同的配变负荷预测框架

Fig. 1 Technical framework of distribution transformer load forecast for cloud edge collaboration

2 基于相似用电行为的配变划分

为提高配变短期负荷集群预测精度, 文本先对配变进行负荷形态相似性分析^[18], 提出基于相似用电行为的配变划分方法。由于配变的负荷数据以天为单位, 周期性较强, 所以本文将负荷数据转换为

日负荷曲线，便于进行负荷形态相似性分析，其流程图如图 2 所示。

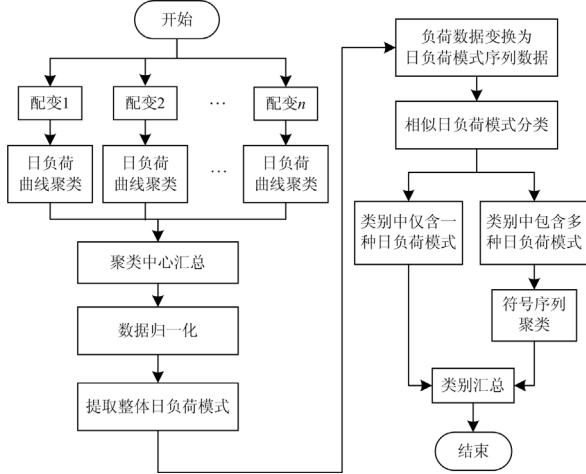


图 2 基于相似用电行为的配变划分流程图

Fig. 2 Flow chart of DT classification based on similar electricity consumption behavior

2.1 配变日负荷模式聚类

对配变的日负荷曲线聚类，可以有效归纳配变的日负荷模式，便于后期开展相似用电行为的配变分类建模与集群预测。考虑到直接对若干台配变负荷数据聚类时，由于数据规模大，可能导致在最优指标聚类结果的情况下聚类簇数过少、效果不理想，本文使用从个体到整体的分析方式。先依次对每台配变进行日负荷曲线聚类，发现每台配变的典型日负荷模式(即每台配变的日负荷曲线聚类中心)；然后将各聚类中心整合，形成新的负荷曲线数据集，再进行聚类后获得全局数据的聚类中心，即全局日负荷模式。由于不同配变所属的供电区域不同，负荷幅值可能差距较大，直接聚类容易忽略幅值较小的样本的负荷特性。所以整体分析时需对负荷序列数据 x 进行极值归一化，其计算方式如式(1)所示。

$$x_i = \frac{x_i}{\max(x)} \quad (1)$$

式中， x_i 为第 i 个时点的负荷值。

日负荷模式从个体到整体分析的聚类，都属于曲线聚类问题。针对该问题，本文提出基于奇异值的自适应负荷曲线聚类方法。方法先使用奇异值分解降低数据维度 $d(d \in D)$ ；再使用 k-means++ 算法聚类，并采用网格搜索确定模型参数 $k(k \in K)$ ，其中聚类评价指标选用轮廓系数(SHI)，其计算方式如式(2)所示。算法通过设置 D 与 K 的取值范围进行穷举搜索并计算 SHI 指标值，取最大 SHI 时刻的 d 与 k 作为最终参数。接着对聚类结果进行离群点检验，

若出现聚类簇中样本数量低于 β 的情况，则将该样本视为离群样本，并暂时移除重新聚类。算法流程图如图 3 所示。

$$SHI = \frac{1}{n} \sum_{i=1}^n \frac{d_a(i) - d_b(i)}{\max(d_a(i), d_b(i))} \quad (2)$$

式中： $d_a(i)$ 为样本 i 到其他簇所有样本的最小平均距离； $d_b(i)$ 为样本 i 与相同簇内其他样本的平均距离。

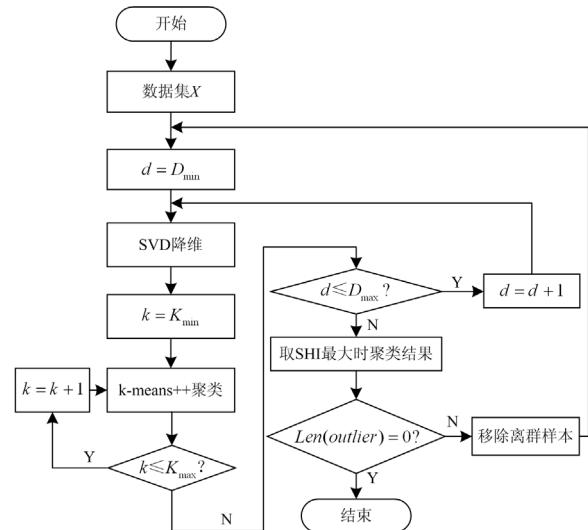


图 3 基于奇异值分解的自适应负荷曲线聚类方法流程

Fig. 3 Flow chart of adaptive load curve clustering method based on SVD

2.2 配变相似日负荷模式分类

根据聚类得到的全局日负荷模式，确定各配变日负荷数据的归属类别，并进一步将各配变的负荷曲线变化为带时序的日负荷模式符号序列，便于进一步进行配变的相似用电行为划分。

本文提出基于相似用电行为的配电变压器划分方法，同时考虑了各配变的日负荷模式类型与日负荷模式变化规律。该方法先将具有相同日负荷模式的配变分为一类，然后对具有多种日负荷模式的配变按照日负荷模式变化规律进行分类。

日负荷模式变化规律分类属于符号序列聚类问题。本文使用马尔可夫链转移分析对负荷序列进行特征提取，将转移概率矩阵作为其符号序列的描述特征。对于一个日负荷模式符号序列数据，其中包括 w 种状态，使用 f_{ij} 表示序列中从状态 i 经过一步转移到状态 j 的频次。因此可以得到转移频次矩阵 $F = [f_{ij}]_{w \times w}$ 。使用 P_{ij} 表示从状态 i 到状态 j 的转移概率，其计算公式为

$$P_{ij} = f_{ij} / \sum_{j=1}^w f_{ij} \quad (3)$$

因此可求得状态转移概率矩阵 $\mathbf{P} = [P_{ij}]_{w \times w}$ 。在使用马尔可夫模型对序列数据建模时, 需要检验是否具备“马氏性”。对于显著性水平 α , 若 $\chi^2 > \chi^2_\alpha((w-1)^2)$, 则认为序列根据马尔可夫建模符合马氏检验, 其中 χ^2 计算方式为

$$\left\{ \begin{array}{l} \chi^2 = 2 \sum_{i=1}^w \sum_{j=1}^w f_{ij} |\log \frac{p_{ij}}{p_{\bullet j}}| \\ p_{\bullet j} = \sum_{i=1}^w f_{ij} / \sum_{i=1}^w \sum_{j=1}^w f_{ij} \end{array} \right. \quad (4)$$

对于上述符号序列特征, 本文同样采用 k-means++ 进行聚类, 从而完成配变相似日负荷模式变化规律分类。

3 配变短期负荷集群预测

负荷预测的准确性对电力系统运行有很大影响, 因为预测误差的存在将直接增加电力系统运行的附加成本, 不利于经济性能的提高。通过研究现状分析, 配电变压器短期负荷预测建模中存在着以下三方面问题:

(1) 常见的短期负荷预测算法取得了不错的效果, 例如支持向量回归^[19]、BP 神经网络^[20]等, 但是这些算法存在对数据集的分布规律要求较高, 预测模型的稳定性不强等问题。

(2) 数据的分布、数据中噪点都有可能影响模型的预测精度, 将预测模型与数据分解模型^[21-22]结合, 获得规律性较强的子序列, 是解决问题的有效途径。

(3) 利用深度学习^[6,10]对短期负荷预测建模, 是目前短期负荷预测的趋势。但是预测模型中网络结构大多是单一的, 受参数调节的影响大, 在面对多类特性数据时适应性不强, 可采用集成学习^[23]思想对模型性能进行改进。

因此, 本文对具有相似用电行为的配变提出采用基于分解的集成预测模型(STL-LSTMs-XGBoost)进行集群学习与预测^[24], 图 4 为所提出的模型流程图。该模型首先将负荷序列数据进行 STL 分解, 得到趋势项(Trend)、周期项(Seasonal)和剩余项(Reminder); 然后, 采用 LSTM 神经网络建立预测模型, 同时考虑到单个 LSTM 神经网络受自身网络结构和训练数据类型的影响较大, 使用多种 LSTM 网络结构构造学习器, 且每一个学习器都包括趋势项与剩余项的预测模型; 最后, 采用 XGBoost 回归对各学习器预测结果进行非线性整合, 获得集成预测结果。该方法能够有效缓解数据分布与网络结构对预测模型精度的影响, 提高预测模型的稳定性和精度^[24]。

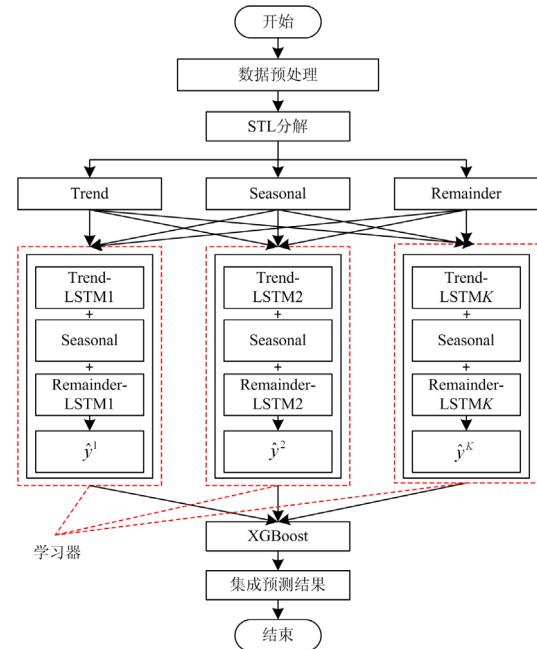


图 4 STL-LSTMs-XGBoost 模型流程图

Fig. 4 Flow chart of STL-LSTMs-XGBoost model

4 实验分析

本文使用的实验数据来自某市区从 2017/1/1 至 2017/4/20 的配变负荷数据, 包括 420 台配变, 采样频率为每小时一次。

4.1 配变负荷曲线规律分析

按照图 2 中的流程, 首先提取单台配变的日负荷模式。从数据集中选取某单台配电变压器的日负荷数据, 使用本文提出的方法进行聚类分析, 得到两个聚类中心, 即两种典型日负荷模式, 能够反映该配变的日负荷变化规律, 如图 5 所示。

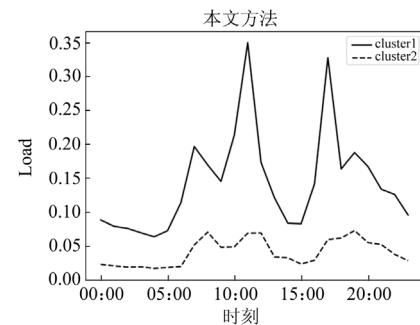


图 5 单台配变日负荷模式

Fig. 5 Daily load mode of single distribution transformer

实验中使用不同的特征提取方法对全部原始日负荷数据进行特征提取, 并对比其聚类效果。特征提取的方法包括 Analysis(提取统计特征, 包括负载率、日波峰波谷差率与用电高峰期、平缓期、低谷期负载率)、K-SVD(通过字典学习得到负荷数据

的稀疏编码, 将稀疏编码作为特征)、PCA(使用主成分分析方法对负荷数据提取特征)、Original(原始负荷数据作为特征)和本文提出的方法。

在表 1 中, 使用本文方法对 420 台配变进行单一对象日负荷曲线聚类时, 其平均 SHI 指标最高, 说明该方法聚类效果较好。

表 1 平均 SHI 评价指标

Table 1 Average SHI evaluation index

方法	Analysis	K-SVD	PCA	Original	本文方法
SHI	-0.028 9	0.203 1	0.293 3	0.298 8	0.300 2

然后, 提取数据集全局日负荷模式, 即将前述所有配电变压器聚类获得的日负荷模式整合, 通过聚类归纳出整体数据集的日负荷模式。根据本文提出的聚类算法搜索每种降维数 d 对应的最佳聚类数 k 值, 其中设置 $K \in [2,10]$ 、 $D \in [2,6]$ 。图 6 为数据维度 d 、聚类模型参数 k 与 SHI 指标的关系图。通过关系曲线可见, 当 $d=5$ 、 $k=5$ 时, SHI 指标到达最高值, 所以整体日负荷模式聚类中, 降维数 d 设置为 5, 聚类数 k 设置为 5。

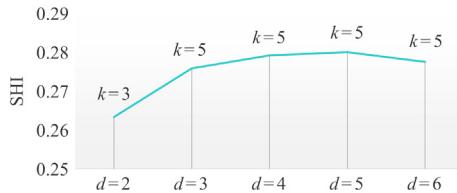
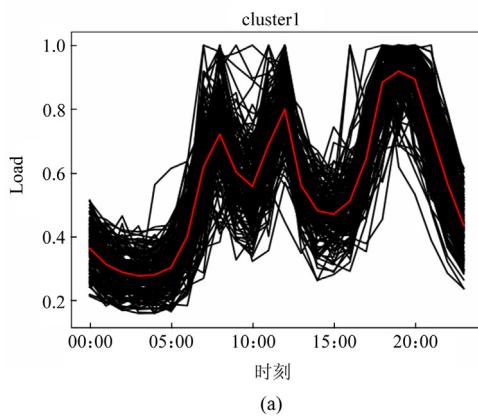


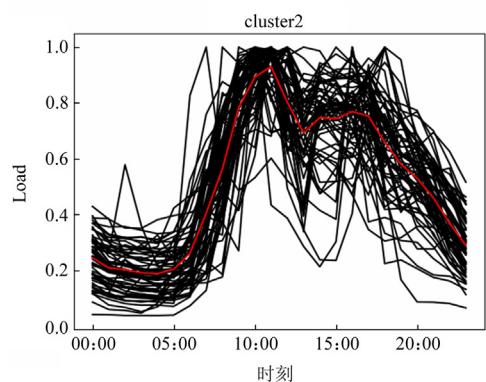
图 6 数据维度 d 、聚类数 k 与 SHI 关系图

Fig. 6 Relationship between data dimension d , cluster number k and SHI

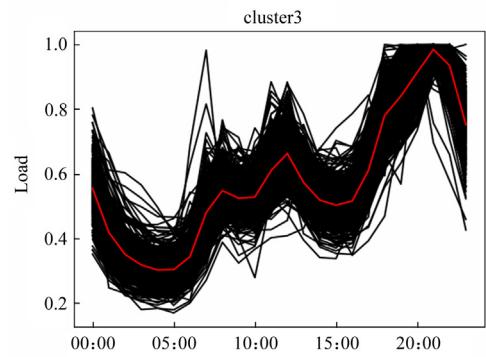
数据集整体聚类结果如图 7 所示, 共获得 5 种典型日负荷模式, 分别记为 a、b、c、d、e 模式。从图中可以发现, a 模式为三峰型, b 模式与 d 模式为双峰型, c 模式和 e 模式的负荷模式比较相似, 但是 e 模式的波峰与波谷的差值小于 c 模式(模式与分图对应)。



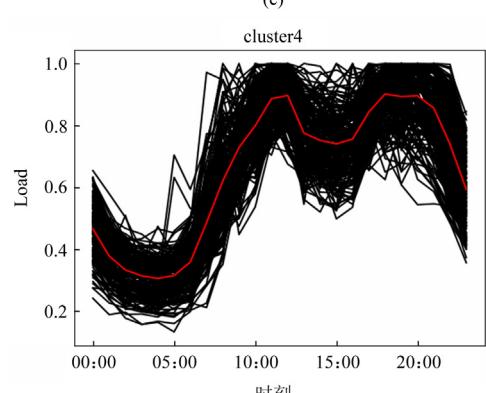
(a)



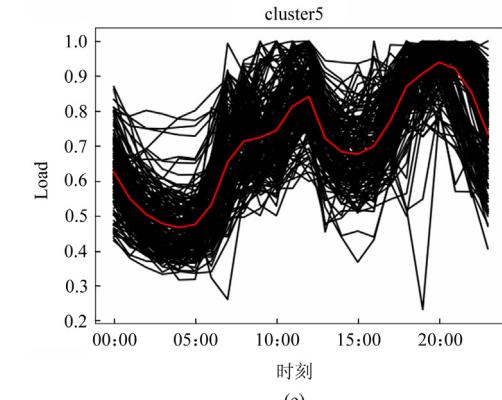
(b)



(c)



(d)



(e)

图 7 整体日负荷模式聚类结果
Fig. 7 Clustering results of the overall daily load patterns

最后, 按照整体数据的日负荷模式, 将每台配变的负荷数据变化为日负荷模式序列, 统计各配变的日负荷模式类别。表 2 为各日负荷模式的配变数量, 由此将 420 台配变划分到不同的日负荷模式类别。对于具有多种日负荷模式的配变将进一步开展日负荷模式变化规律分类, 具体实验见后文。

表 2 各日负荷模式配变数量

Table 2 Number of DTs in each daily load mode

模式	数量	模式	数量	模式	数量
c	154	ad	13	be	5
d	59	b	12	ab	5
e	50	ce	11	bde	1
a	46	ac	10	ade	1
de	22	ae	9	abd	1
bd	15	cd	6	—	—

4.2 配变短期负荷预测实验

本文选择各配变 2017/1/1 到 2017/4/17 的负荷数据整合为训练集, 2017/4/18 到 2017/4/20 的负荷数据整合为测试集。实验中使用平均绝对百分比误差(MAPE)指标评估预测模型的精度, 其计算方式为

$$E_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \text{pred}_i}{y_i} \right| \cdot 100\% \quad (5)$$

式中: y_i 为负荷数据真实值; pred_i 为负荷数据预测值; N 为样本数量。当 E_{MAPE} 值越小, 精度越高。

在实验中, 预测模型将 STL 的分解频率设置为 12, 集成预测的学习器数量设置为 4, LSTM 神经网络的输入序列长度设置为 12。经实验得到的各学习器网络结构的参数设置如表 3 所示。

表 3 各学习器网络结构参数

Table 3 Network structure parameters of each learner

模型名称	参数 1	参数 2
STL-LSTM1	(1, 10)	(1, 20)
STL-LSTM2	(2, 10)	(2, 20)
STL-LSTM3	(1, 20)	(1, 30)
STL-LSTM4	(2, 20)	(2, 30)

1) 实验 1

将本文提出的集群预测方法与非集群(单独对每台配变建立预测模型)预测方法的精度进行对比。选取模式 c 中平均赋值范围在 0.1~0.2 MW 的配变负荷数据作为实验数据, 总计 79 台配变。将同一集群的配变负荷数据进行整合建模, 模型中参数设置见表 3 中的参数 2。非集群预测方法中每个模型的参数设置见表 3 中的参数 1。表 4 为集群预测与非集群预测精度评价结果。

表 4 集群预测与非集群预测平均 MAPE 评价结果

Table 4 Average MAPE evaluation results of cluster prediction and non-cluster prediction

平均负荷值 范围/MW	配变数量	集群预测/%	非集群预测/%
[0.1, 0.2)	79	14.74	14.27

表 4 中集群预测的平均 MAPE 略高于非集群预测。利用相似用电行为对配变进行分类, 保证了同类别配变的负荷模式大致相似。由于配变的负荷扰动比较随机, 导致各配变自身的扰动影响了集群的预测精度, 但使用集群预测与非集群预测的 MAPE 总体平均值差距较小, 说明本文提出的短期负荷集群预测方案可以代替对单一配变逐个建模的繁琐工作, 且效果是可行有效的。

2) 实验 2

为了说明本文所提分类算法在集群预测中的优势, 实验 2 将对比不同集群预测策略的预测精度。从模式 c、模式 d 与模式 e 中各选择 10 台配变的负荷数据进行实验。为了避免由于数据集负荷幅值差距影响带来的对比误差, 配变的平均负荷范围均分布在 0.2~0.3 MW。

本文提出的集群预测策略: 由于实验数据集包含 3 种日负荷模式的配变, 所以数据集分为 3 个集群, 记为类别 1(模式 c)、类别 2(模式 d)和类别 3(模式 e)。分别将 3 个集群中负荷数据整合, 训练 3 个预测模型, 其中模型参数设置见表 3 中的参数 2。对比策略: 不考虑用电相似性, 将 30 台配变的负荷数据整合, 训练一个预测模型, 预测模型参数设置见表 3 中的参数 2。

表 5 为实验 2 的平均 MAPE 评价结果。由表 5 中可见, 本文提出的方法在每个数据集上精度都较高, 且汇总的平均精度相比于对比策略提高 19.19%, 从而说明本文所提的短期负荷集群预测方法有助于提高预测精度。

表 5 实验 2 平均 MAPE 评价结果

Table 5 Average MAPE evaluation results in Case2

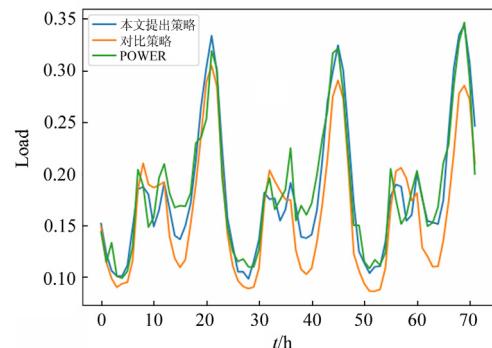
数据集	对比策略/%	本文提出的策略/%
类别 1	16.35	10.79
类别 2	16.39	14.06
类别 3	16.03	14.57
汇总	16.26	13.14

从三种模式中各选择一台配变进行精度对比, 分别为配变 A(类别 1)、配变 B(类别 2)和配变 C(类别 3)。表 6 为 3 台配变的 MAPE 预测精度评价结果, 图 8 为 3 台配变预测结果图。

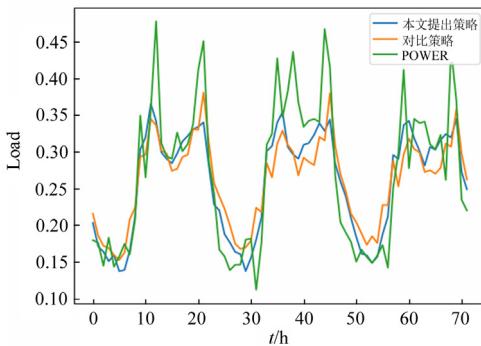
表 6 实验 2 中配变 A、B、C 的 MAPE 评价结果

Table 6 MAPE evaluation results of DTs A, B, and C in Case2

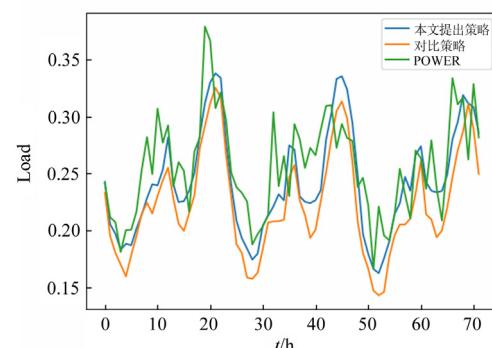
配变	对比策略/%	本文提出的策略/%
配变 A	16.86	8.99
配变 B	18.32	13.68
配变 C	14.42	9.50
平均值	16.53	10.72



(a) 配变 A



(b) 配变 B



(c) 配变 C

图 8 实验 2 中配变 A、B、C 预测结果

Fig. 8 Prediction results of DTs A, B and C in Case2

从 3 台配变的预测曲线对比图可见，本文提出的方法与真实负荷跟随的更加紧密，MAPE 预测评价指标值更小。

3) 实验 3

为说明在相似用电行为分析中加入日负荷模式变化规律相似性对集群预测的作用，本实验选取日负荷模式为 bd 的配变进行实验。该数据集中包含 15 台配变的负荷数据，每台配变包含 b、d 两种日负荷模式。

本文提出的策略：对于含有多种日负荷模式的类别，需要进行日负荷模式变化相似性分析。按照式(3)计算该数据集中各序列的马尔可夫转移概率矩阵，并进行马氏检验。在显著水平 $\alpha = 0.05$ 时， $\chi^2_{0.05}(1) = 3.84$ 。实验数据集得到最小 $\chi^2 = 12.19$ ，则满足显著水平 $\alpha = 0.05$ 的马氏检验。将得到的日负荷序列状态转移概率矩阵作为特征进行聚类，设置 $K \in [2, 4]$ ， $\beta = 2$ 。在聚类过程中，存在一个聚类簇只有一个样本，不满足离群点检验，则移除该样本后进行第二次聚类。图 9 为第二次聚类结果热力图，聚类为 3 个簇，子图 cluster1、cluster2 与 cluster3 分别代表一种类别的日负荷模式变化规律。子图中横轴为时间(以天为单位)，纵轴为样本标号；图中对应每个样本标号的每条数据代表一台配电变压器一段时间的日负荷模式序列，不同色块代表不同日负荷模式，其中红色块为模式 b，黄色块为模式 d。

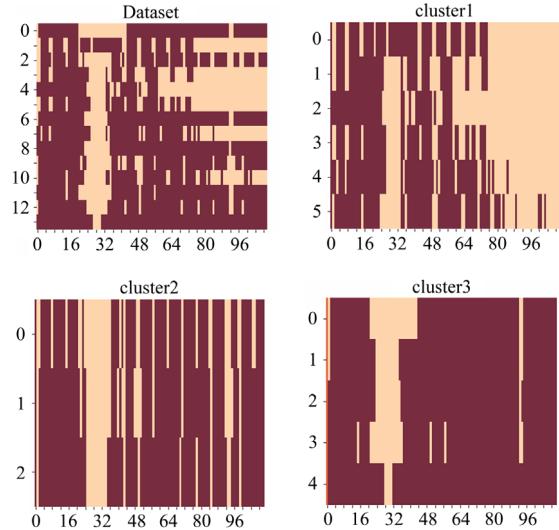


图 9 剔除离群点后聚类结果热力图

Fig. 9 Heat map of clustering results after excluding outliers

从图 9 中可见，相比于 cluster3、cluster1，cluster2 中存在两种模式交替频繁出现。将配变按照基于相似用电行为的配变分类方法进行分类后，各类别配变的数量分别为 6、3、5。在每个类别中，由于样本量较少，幅值差距较大，为避免幅值相差太大对集群预测的影响，选取平均负荷粒度为 0.2 MW，对各类进一步划分成多个集群。将每个集群数据整

合分别建模, 参数设置如表 3 参数 1 所示。

对比策略: 该策略按照相同日负荷模式对配变进行分类。为了避免由于数据集幅值差距影响预测精度, 从而影响对比实验的科学性, 将数据集中配变按照 0.2 MW 平均负荷粒度对配变进行划分。对每个集群数据整合建模, 参数设置见表 3 中的参数 1。

表 7 为实验 3 中对比实验的平均 MAPE 评价结果, 从中可见本文提出的集群预测策略的预测精度与非集群预测精度相似, 且高于仅考虑日负荷模式相似性的对比策略, 从而说明加入日负荷模式变化相似性能有助于提高配变的集群预测精度。

表 7 实验 3 平均 MAPE 评价结果

Table 7 Average MAPE evaluation results in Case3

方法	$E_{MAPE}/\%$
本文提出的策略	25.04
非集群预测	25.55
对比策略	27.44

从以上实验结果可以看出, 本文提出的集群预测模型作用于单个配电变压器的效果与单独逐一建模的效果是相似的, 并且优于对比的集群预测模型。因此其在云端建模的工作效率较高, 并且部署在智能融合终端发挥效果的作用也是明显的, 可以实现配电物联网体系下的数据协同和业务协同。

5 总结

在配电物联网“云管边端”架构下, 本文以配电变压器为研究对象, 针对其短期负荷预测问题提出了面向云边协同的配电变压器负荷预测框架, 并着重研究了云端的集群预测模型。该方法将具有相似负荷形态与变化规律的配变负荷数据整合在一起进行训练, 在不降低预测模型精度的条件下, 提高了短期负荷预测模型建模与推广的工作效率, 为大规模配电变压器集群的精细化运维管理提供了新思路。本文下一步将研究短期负荷预测模型的迁移学习机制, 构建智能融合终端(边缘节点)的专属预测模型, 为更准确地开展预测性维护提供决策支持。

参考文献

- [1] 沈建新. 基于智能优化的电力负荷预测方法研究[D]. 合肥: 合肥工业大学, 2015.
SHEN Jianxin. Research on intelligent optimization based power load forecasting methods[D]. Hefei: Hefei University of Technology, 2015.
- [2] 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.
- [3] 李彬, 贾滨诚, 曹望璋, 等. 边缘计算在电力需求响应业务中的应用展望[J]. 电网技术, 2018, 42(1): 79-87.
LI Bin, JIA Bincheng, CAO Wangzhang, et al. Application prospect of edge computing in power demand response business[J]. Power System Technology, 2018, 42(1): 79-87.
- [4] 王永福, 张方正, 王亚飞, 等. 采用虚拟化技术的智能变电站间隔层集群测控装置研制[J]. 电力系统自动化, 2019, 43(13): 169-176, 190.
WANG Yongfu, ZHANG Fangzheng, WANG Yafei, et al. Development of virtualization-technology-based cluster measurement and control device at bay level in smart substation[J]. Automation of Electric Power Systems, 2019, 43(13): 169-176, 190.
- [5] LI L, OTA K, DONG M. When weather matters: IoT-based electrical load forecasting for smart grid[J]. IEEE Communications Magazine, 2017, 55(10): 46-51.
- [6] 沈兆轩, 袁三男. 利用卷积神经网络支持向量回归机的地区负荷聚类集成预测[J]. 电网技术, 2020, 44(6): 2237-2244.
SHEN Zhaoxuan, YUAN Sannan. Regional load clustering integration forecasting based on convolutional neural network support vector regression machine[J]. Power System Technology, 2020, 44(6): 2237-2244.
- [7] WANG Yi, CHEN Qixin, SUN Mingyang, et al. An ensemble forecasting method for the aggregated load with subprofiles[J]. IEEE Transactions on Smart Grid, 2018, 9(4): 3906-3908.
- [8] 杨德昌, 赵肖余, 何绍文, 等. 面向海量用户用电数据的集成负荷预测[J]. 电网技术, 2018, 42(9): 2923-2929.
YANG Dechang, ZHAO Xiaoyu, HE Shaowen, et al. Aggregated load forecasting based on massive household smart meter data[J]. Power System Technology, 2018, 42(9): 2923-2929.
- [9] 王毅星. 基于深度学习和迁移学习的电力数据挖掘技术研究[D]. 杭州: 浙江大学, 2019.
WANG Yixing. Power data mining technology based on deep learning and transfer learning[D]. Hangzhou: Zhejiang University, 2019.
- [10] 王振宇. 智能电网中基于深度学习的用户短期负荷预测研究[D]. 南京: 南京邮电大学, 2019.
WANG Zhenyu. Short-term load forecasting of users based on deep learning in the smart grid[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2019.
- [11] 吴敬慧, 张杰, 潘舒妍, 等. 电力现货市场中标准零售

- 套餐设计——基于用户分群的分析[J]. 价格理论与实践, 2019(12): 132-136.
- WU Jinghui, ZHANG Jie, PAN Shuyan, et al. Standard retail tariff design based on customer clustering in electricity spot market[J]. Price: Theory & Practice, 2019(12): 132-136.
- [12] 李焱, 贾雅君, 李磊, 等. 基于随机森林算法的短期电力负荷预测[J]. 电力系统保护与控制, 2020, 48(21): 117-124.
- LI Yan, JIA Yajun, LI Lei, et al. Short term power load forecasting based on a stochastic forest algorithm[J]. Power System Protection and Control, 2020, 48(21): 117-124.
- [13] 陈弘川, 蔡旭, 孙国歧, 等. 基于智能优化方法的相似日短期负荷预测[J]. 电力系统保护与控制, 2021, 49(13): 121-127.
- CHEN Hongchuan, CAI Xu, SUN Guoqi, et al. Similar day short-term load forecasting based on intelligent optimization method[J]. Power System Protection and Control, 2021, 49(13): 121-127.
- [14] 蒋子规. 面向电力大数据的用户用电行为挖掘方法[D]. 北京: 北京邮电大学, 2019.
- JIANG Zigui. Electricity consumption behavior mining methods based on big data in smart grid[D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [15] 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.
- [16] WANG Yi, CHEN Qixin, KANG Chongqing, et al. Clustering of electricity consumption behavior dynamics toward big data applications[J]. IEEE Transactions on Smart Grid, 2016, 7(5): 2437-2447.
- [17] CHARWAND M, GITIZADEH M, SIANO P, et al. Clustering of electrical load patterns and time periods using uncertainty-based multi-level amplitude thresholding[J]. International Journal of Electrical Power & Energy Systems, 2020, 117(5): 1-15.
- [18] TEERARATKUL T, O'NEILL D, LALL S. Shape-based approach to household electric load curve clustering and prediction[J]. IEEE Transactions on Smart Grid, 2018, 9(5): 5196-5206.
- [19] XING Z. Short-term load forecasting for electric bus charging stations based on fuzzy clustering and least squares support vector machine optimized by wolf pack algorithm[J]. Energies, 2018, 11(6).
- [20] YU Feng, XU Xiaozhong. A short-term load forecasting model of natural gas based on optimized genetic algorithm and improved BP neural network[J]. Applied Energy, 2014, 134(12): 102-113.
- [21] 严通煜, 杨迪珊, 项康利, 等. 基于时间分解技术的中远期逐时负荷预测模型[J]. 电力系统保护与控制, 2019, 47(6): 110-117.
- YAN Tongyu, YANG Dishan, XIANG Kangli, et al. Mid-long term hourly load forecasting model based on time decomposition[J]. Power System Protection and Control, 2019, 47(6): 110-117.
- [22] XIONG Tao, LI Chongguang, BAO Yukun. Seasonal forecasting of agricultural commodity price using a hybrid STL and ELM method: evidence from the vegetable market in China[J]. Neurocomputing, 2018, 275: 2831-2844.
- [23] 姜建, 刘海琼, 李衡, 等. 基于XGBoost的配电网线路峰值负荷预测方法[J]. 电力系统保护与控制, 2021, 49(16): 119-127.
- JIANG Jian, LIU Haiqiong, LI Heng, et al. Peak load forecasting method of distribution network lines based on XGBoost[J]. Power System Protection and Control, 2021, 49(16): 119-127.
- [24] FAN Min, HU Yaqian, ZHANG Xi, et al. Short-term load forecasting for distribution network using decomposition with ensemble prediction[C] // 2019 Chinese Automation Congress (CAC), November 22-24, 2019, Hangzhou, China.

收稿日期: 2021-07-16; 修回日期: 2021-09-22

作者简介:

郭祥富(1983—), 男, 硕士, 教授级高工, 主要研究方向为配电物联网、电力信息化; E-mail: 27667767@qq.com

刘昊(1979—), 男, 博士, 高工, 主要研究方向为配电物联网、分布式电源、电力信息化; E-mail: liuhaoepri@139.com

范敏(1975—), 女, 通信作者, 博士, 副教授, 研究方向为机器学习与数据挖掘, 电力大数据分析。E-mail: fanmin@cqu.edu.cn

(编辑 姜新丽)