

DOI: 10.19783/j.cnki.pspc.190485

考虑分时电价的居民用户短期用电量分类预测及修正方法

徐冰涵¹, 孙云莲¹, 易仕敏², 王华佑¹, 谢文旺¹

(1. 武汉大学电气与自动化学院, 湖北 武汉 430072; 2. 广东电网有限责任公司, 广东 广州 510620)

摘要: 为了更好地利用智能电网中的用户用电信息, 提高短期用电量预测精度, 针对居民用户提出一种考虑分时电价的分类短期用电量预测及修正方法。首先, 通过模糊聚类将用户按用电行为分类, 将电价、用电量和加权气象日期影响因素作为预测模型输入量。然后, 针对各类用户的用电特点, 经仿真对比选择相适应的 BP、Elman、LSTM 神经网络算法构建预测模型。最后, 运用修正算法对误差较大的峰谷值进行修正, 将修正后的分类预测结果相加以获得整体预测值。以广东省云浮市某小区为例对该方法进行仿真分析, 并与随机森林、CART 等算法进行对比。实验结果证明所提方法具有更高的预测精度。

关键词: 用电量预测; 分时电价; 模糊聚类; 神经网络; 修正

Classified short-term electricity consumption forecasting and correcting method for residential users considering time-of-use electricity price

XU Binghan¹, SUN Yunlian¹, YI Shimin², WANG Huayou¹, XIE Wenwang¹

(1. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China;

2. Guangdong Power Grid Co., Ltd., Guangzhou 510620, China)

Abstract: In order to make better use of the user's electricity consumption information in the smart grid and improve the forecasting accuracy, a classified short-term electricity consumption forecasting and correcting method for residential users considering time-of-use electricity price is proposed. Firstly, the fuzzy clustering is used to classify the users according to their electricity usage behavior, and the electricity price, electricity consumption and weighted weather and date influence factors are used as the predictive model input. Secondly, according to the simulation comparison, the BP, Elman and LSTM neural network algorithms are chosen for corresponding users to construct the prediction model. Finally, the modified algorithm is used to correct the peak-to-valley value with large error, and the corrected classification prediction results are added up to obtain the overall predicted value. Taking a certain community in Yunfu City, Guangdong Province as an example, the method is simulated and compared with random forest and CART algorithms. Experimental results show that the proposed method has higher prediction accuracy.

This work is supported by Science and Technology Project of China Southern Power Grid Company (No. 035300KK52150007 and No. 031800KK52170073).

Key words: electricity consumption forecasting; time-of-use electricity price; fuzzy clustering; neural networks; correction

0 引言

随着智能电网的飞速发展, 电网侧与用户侧的实时性关联互动日益增强, 用户对电网的作用日渐增大^[1]。为了更好地进行电力系统生产、调度和实现终端用户服务, 预测范围需从宏观向微观转移^[2]。

基金项目: 南方电网公司科技项目资助 (035300KK52150007, 031800KK52170073)

因此, 针对居民用户的短期负荷预测具有重要意义。

针对负荷预测问题, 现有的短期预测方法主要分为三类: 经典方法、传统方法和现代智能方法^[3]。经典方法主要有回归分析法和时间序列法, 传统方法有灰色预测法^[4]、相似日法^[5]等, 现代智能方法有小波分析法^[6]、支持向量机^[7]、神经网络^[8-12]、极限学习机^[13]、随机森林^[14]、组合模型预测法^[15]等。针对智能电网包含的海量数据, 经典方法和传统方法适用程度较低, 现代智能方法的提出, 为短期负

荷预测精度的提高提供了解决方案。其中, 神经网络因其非线性逼近映射的能力和 处理各影响因素便利的特点, 在短期负荷预测中广泛应用, 且效果良好。文献[8]提出一种基于 BP 的序贯混合神经网络; 文献[9]提出一种混合 GA-PSO-BPNN 算法; 文献[10]引入混沌时间序列和粗糙集理论改进 Elman 神经网络; 文献[11]将负荷数据经 EMD 算法分解后通过 SLSTM 网络进行家庭短期负荷预测; 文献[12]提出一种针对个体消费者的概率负荷预测方法, 通过 Pinball 损失函数训练 LSTM 网络参数来处理未来负荷分布的变化和不确定性。

在智能电网中, 用户的用电行为受电价的影响, 将电价作为影响因素, 有助于提高短期负荷预测的精度。文献[16]将实时电价作为输入量之一, 建立支持向量分位数回归与核密度估计相结合的预测模型; 文献[17-18]分析了负荷与实时电价的相关性, 采用 Adam-LSTM 模型和 Attention-LSTM 模型进行预测; 文献[19]建立了考虑需求侧响应的短期负荷预测模型。但以上方法面向的场景均为国外电网和电力市场, 鉴于国内电力市场暂未实行实时电价, 以上方法的适用性较低。

针对以上问题, 本文提出了一种考虑分时电价的短期用电量分类预测及修正方法。首先通过模糊聚类将用户分类, 将电价、用电量和经判别加权的气象日期因素作为预测模型的多维输入量。然后对各类用户分别建立适应其特点的 BP、Elman 和 LSTM 神经网络预测模型。最后对预测结果的峰谷值进行修正, 将修正后各类预测结果相加以获得最终预测值。本文以广东省云浮市某小区为例进行仿真分析, 验证所提方法的预测性能。

1 用电量预测分析

1.1 用电量与分时电价相关性分析

智能电网环境下, 电价的波动会影响用电量的大小。为分析居民用电量与分时电价的关系, 将广东省云浮市某小区某日每 15 min 的实际用电量与该市实行的分时电价逐时段作图比较, 如图 1 所示。由图可看出用电量与电价有一定程度的负相关性。

为进一步检验二者的相关程度, 选取该小区整周用电量与分时电价进行皮尔逊(Pearson)和斯皮尔曼(Spearman)相关性分析^[18], 相关系数的绝对值如表 1 所示。由表中数据可知, 皮尔逊相关系数的平均绝对值为 0.582 8, 斯皮尔曼相关系数的平均绝对值为 0.670 2。上述结果证明二者有中等程度相关, 在短期用电量预测时, 应考虑分时电价的影响。

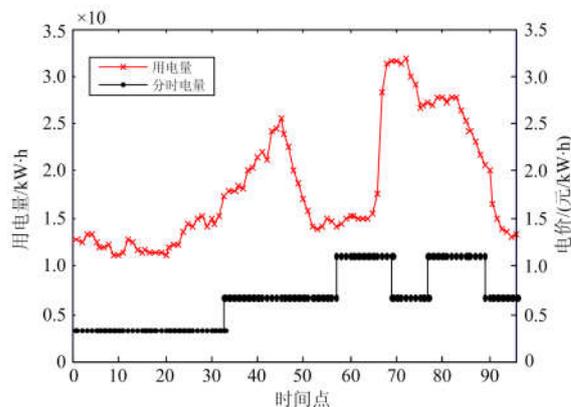


图 1 居民用电量与分时电价关系

Fig. 1 Relationship between residential electricity consumption and time-of-use electricity price

表 1 用电量与分时电价的相关系数绝对值

Table 1 Absolute value of correlation coefficient between electricity consumption and time-of-use electricity price

星期类型	相关性模型	
	Pearson	Spearman
1	0.546 6	0.648 9
2	0.569 2	0.661 8
3	0.642 0	0.730 0
4	0.574 8	0.655 7
5	0.570 0	0.627 9
6	0.616 6	0.680 9
7	0.560 2	0.686 2

1.2 输入量选择分析

为提高预测精度, 除用电量及电价外, 还应综合考虑日期类型和温度、天气情况等气象因素^[20]。

1) 影响因素选择及权重判别

本文将天气情况、风速、空气质量、最高温度、最低温度、最高湿度、最低湿度这七个气象因素和日期类型一起作为初始影响因素进行权重判别。

由于日期类型和天气情况不是定量指标, 需对二者进行量化处理。根据居民用户的用电习惯, 将工作日的日期类型量化值取为 0.5, 休息日取值为 1。对日间与夜间的天气情况分别取值, 日间的晴、多云取值为 0.1, 阴取值 0.2, 小雨、大雨等其他不适合出行的天气情况取值为 0.3; 夜间的晴、阴、多云取值为 0.1, 其他天气情况取值 0.2。当日的天气情况量化值为日间与夜间取值之和。

将其余六个定量的影响因素归一化到[0,1]。将处理后的各影响因素作为自变量, 用电量做为因变量, 计算各影响因素对用电量的直接通径系数及权重^[21]。

由实验可知, 影响因素并非越多越好。输入对用电量影响程度不高的因素不仅增加预测时间, 还可能降低预测精度。因此, 对于上述八个影响因素, 仅保留权重较高的四项作为输入量, 并根据通径分析的结果重新进行权重分配。用户类型 i 中影响因素 j 的实际权重为

$$k'_{ij} = k_{ij} / \sum_{n=1}^4 k_{in} \quad (1)$$

式中, k_{ij} 为该影响因素的初始权重。

为缩短模型的预测时间, 将保留的四项影响因素加权相加作为输入量:

$$M'_i = \sum_{j=1}^4 k'_{ij} M_{ij} \quad (2)$$

式中, M_{ij} 为影响因素归一或量化值。

2) 输入量选择

如表 2 所示, 预测模型共包含 14 个输入量。模型的输出量为预测日被预测时段用电量。针对神经网络的激活函数特性, 需对不同数量级和量纲的输入量进行归一化处理。

表 2 预测模型输入量

Table 2 Input of predictive model

输入类型	描述
历史用电量	相似日 $d-1$ 、 $d-2$ 、 $d-7$ 的 $t-1$ 、 t 、 $t+1$ 时刻用电量
气象日期因素	预测日影响因素加权值
实时用电量	预测日 $t-1$ 、 $t-2$ 时刻的用电量
实时影响因素	预测日被预测时刻 t 预报温度、电价

2 分类预测修正模型

2.1 模糊聚类算法

电力用户用电特性分析是数据挖掘和大数据应用的基础。在建立预测模型前, 以各用户相似日的用电量均值曲线作为输入量, 通过模糊 c 均值聚类算法将用户按用电特性进行分类。

模糊 c 均值聚类算法用隶属度表示样本对各聚类簇的隶属关系。算法流程为: 先随机选择一个聚类中心, 然后对目标函数最小点进行搜索, 在达到终止条件前, 不断采用迭代方程和隶属度更新公式进行迭代, 更新聚类中心和样本隶属度, 最终将样本划分到对应类别。算法可用下式描述^[22-23]。

$$\text{Min } J_{fcm}(\mathbf{U}, \mathbf{V}) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^M d_{ij}^2 \quad (3)$$

式中: \mathbf{U} 是模糊划分矩阵; \mathbf{V} 是由 C 个聚类中心构成的矩阵; M 是模糊系数; u 是隶属度; d 是样本点到中心的距离。

2.2 分类预测模型

通过聚类算法将用户分类后, 分析用户用电特性, 协调考虑预测时间和精度, 为每类用户选择最合适的神经网络算法建立短期用电量预测模型。

1) BP 神经网络

BP 神经网络是由输入层, 隐含层及输出层构成的多层前馈网络, 其特点是误差反向传播, 结构如图 2 所示, 映射关系如式(4)、式(5)所示。

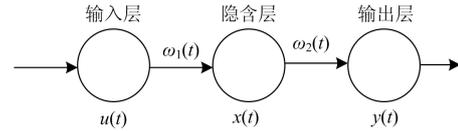


图 2 BP 神经网络单元结构

Fig. 2 Unit structure of BP neural network

$$x(t) = f(\omega_1(u(t)) + b_1) \quad (4)$$

$$y(t) = g(\omega_2(x(t)) + b_2) \quad (5)$$

式中: $f(x)$ 为隐含层传递函数; $g(x)$ 为输出层传递函数; b_1 、 b_2 为隐含层、输出层神经元阈值。

BP 神经网络结构简单, 预测时间短, 在用电量波动较小时有良好的预测效果。但因其无法处理前后数据间的关联信息, 当用电量发生突变时, 其预测误差较大。

2) Elman 神经网络

Elman 神经网络在传统的 BP 网络的三层结构之外, 新增了一个承接层, 用以实现层内、层间的反馈联结, 网络结构如图 3 所示, 映射关系如式(6)、式(7)所示。隐含层的输出通过承接层的延迟和存储自联回输入, 实现了二者在时间上的延迟。这种自联方式提高了网络对历史状态数据的敏感度, 使其拥有动态记忆功能^[10]。

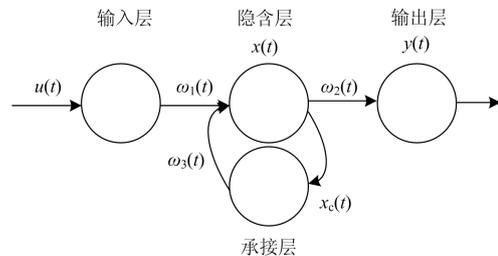


图 3 Elman 神经网络单元结构

Fig. 3 Unit structure of Elman neural network

$$x(t) = f(\omega_3(x_c(t)) + \omega_1(u(t)) + b_1) \quad (6)$$

$$x_c(t) = a \cdot x_c(t-1) + x(t-1) \quad (7)$$

式中, a 为自连接反馈因子。

Elman 神经网络相比 BP 神经网络, 预测时间

增加,但在用电量存在突变的情况下预测精度明显提高。对于用电量波动较大的用户类型,Elman神经网络的预测效果优于BP。

3) LSTM 神经网络

LSTM神经网络的单元结构如图4所示。由于其隐含层内部增加了遗忘门、输入门和输出门,并增加了一条代表长期记忆的信息流,LSTM可实现良好的长短期记忆功能^[17]。

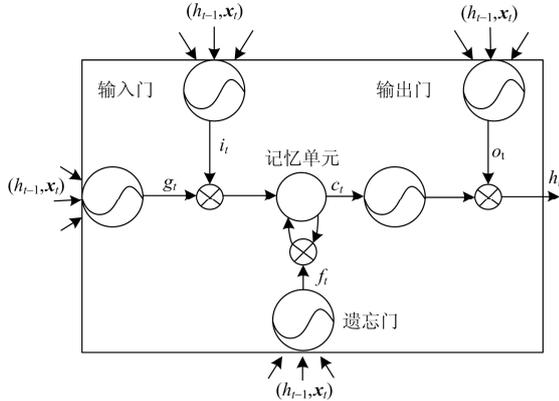


图4 LSTM单元结构

Fig. 4 LSTM unit structure

图4中, x_t 为输入向量, h_t 为隐含层状态值, y_t 为输出向量。记忆单元记录当前时刻状态,输入门、输出门实现参数的读取、输出和修正。遗忘门对上一时刻的单元状态进行选择遗忘^[18]。

LSTM神经网络的预测时间和精度均高于Elman。对于用电量存在突变且对精度要求高的用户类型,LSTM的预测效果最好。

2.3 峰谷值修正算法

使用神经网络对非线性函数进行逼近时,两侧斜率变化过大的点易存在较大误差。居民用户的用电量易波动且具有较高的随机性,故使用神经网络进行预测时,针对预测曲线中可能存在较大误差的峰谷值点,运用修正算法进行修正,以进一步提高预测精度。修正步骤如下:

1) 取峰谷值范围及其前、后一小时作为修正时段 T_i 。

2) 对预测日该时段进行用电量预测,得该时段预测用电量 \dot{Q}_{T_i} 。

3) 对于峰谷值范围内的各测量时段,计算其在相似日 l 的时段占比 $P_{la} = Q_{la} / Q_{lT_i}$, 其中 Q_{la} 为相似日 l 中峰谷值范围内测量时段 a 的用电量, Q_{lT_i} 为相似日 l 中修正时段的用电量。

4) 计算时段 a 在相似日中的时段平均占比

$\bar{P}_a = \sum_{l=1}^N P_{la} / N$ 。 N 为相似日天数,本文中 $N = 3$ 。

5) 修正值 $Q_a^* = \dot{Q}_{T_i} \times \bar{P}_a$, 用修正值代替预测日时段 a 的预测值,修正完成。

2.4 整体预测模型

本文所提分类预测模型具体步骤如下:

1) 数据预处理,对智能电表上传的原始用电量数据中的异常和缺失部分进行修正和补充。

2) 根据历史用电量数据,通过模糊聚类将用户按用电行为进行分类。

3) 对各类用户的八种气象日期影响因素进行关联程度判别,选择关联程度较强的四种影响因素重新进行权重分配,加权后和用电量、电价一起作为输入量。

4) 对输入量进行归一化处理。

5) 为各类用户选择最合适的神经网络建立预测模型,进行短期用电量预测。

6) 对预测曲线中的峰谷值点进行修正。

7) 将各类用户的最终预测结果相加以获得整体预测值。

3 算例分析

本文使用广东省云浮市某小区数百用户2017年7月至11月的用电量和相关气象、电价数据进行仿真分析。通过建模及网络训练,使用文章所提分类预测及修正算法对该小区2017年11月10日的用电量进行预测。预测前已对所有用电量数据进行预处理。

3.1 预测性能指标

误差指标采用平均绝对百分比误差MAPE^[24]和均方根误差RMSE^[25],计算公式如式(8)、式(9)所示。

$$e_{\text{MAPE}} = \frac{1}{T} \sum_{i=1}^T \frac{|l_i - l'_i|}{l} \times 100\% \quad (8)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{T} \sum_{i=1}^T (l_i - l'_i)^2} \quad (9)$$

式中: T 为预测时段数; l_i 为第 i 个时段的实际用电量; l'_i 为第 i 个时段的预测用电量。时间指标采用各时段的平均预测耗时。

3.2 预测仿真

1) 聚类分类

将小区内各用户在11月9日、11月8日及11月3日的用电量均值曲线作为用电特征,通过聚类算法对用户进行分类。如图5所示,用户被分为四种类型。

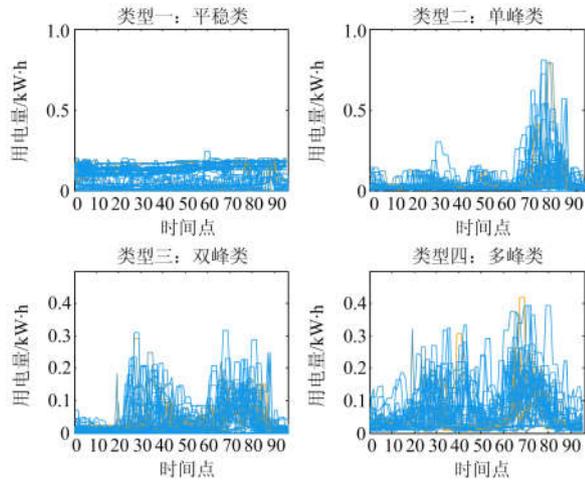


图 5 用户聚类分类结果

Fig. 5 Clustering results of users

2) 影响因素选择及权重判别

对各类用户分别进行天气情况、风速、空气质量、最高温度、最低温度、最高湿度、最低湿度、日期类型这八个气象日期因素的权重判别，结果如表 3 所示。

由表中数据可知，四类用户中权重较高的前四项气象日期因素均为日期类型、天气情况、最高及最低温度。在各类用户中对这四个因素重新进行权重分配，加权后作为预测模型输入量之一。

表 3 各类型影响因素权重

Table 3 Weight of various types of influencing factors

	平稳类	单峰类	双峰类	多峰类
日期类型	0.107 2	0.113 5	0.123 7	0.162 1
天气情况	0.119 4	0.179 0	0.162 8	0.173 0
最高温度	0.341 7	0.225 1	0.173 9	0.180 2
最低温度	0.286 9	0.205 4	0.152 1	0.176 0
最高湿度	0.019 1	0.088 4	0.100 7	0.083 7
最低湿度	0.007 8	0.077 5	0.108 4	0.063 4
风力	0.079 5	0.085 2	0.094 5	0.105 9
空气质量	0.038 4	0.025 9	0.083 9	0.055 7

表 4 各模型分类预测的效果对比

Table 4 Prediction effects comparison of each model classification prediction

预测模型	平稳类			单峰类			双峰类			多峰类		
	MAPE/%	RMSE/%	t/s	MAPE/%	RMSE/%	t/s	MAPE/% 误差/%	RMSE/%	t/s	MAPE/% 误差/%	RMSE/%	t/s
BP	1.30	1.26	0.69	10.85	9.86	0.65	13.95	3.15	0.64	16.88	5.12	0.68
ELMAN	2.28	1.68	1.67	5.85	4.97	1.70	5.87	1.42	1.71	8.79	2.65	1.77
LSTM	2.01	1.59	2.89	3.46	3.25	2.80	4.64	1.40	2.92	5.29	1.76	2.95

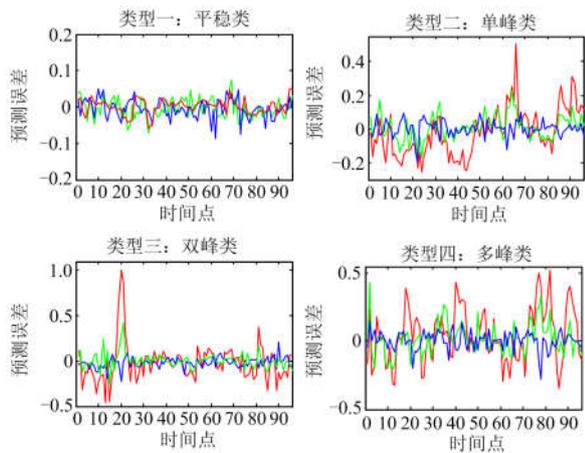


图 6 各模型分类预测误差对比效果

Fig. 6 Comparison of prediction errors of each model

图 6 中，红、绿、蓝三种颜色的曲线分别代表 BP、Elman、LSTM 神经网络模型的预测误差。由图 6 及表 4 中数据可知，平稳类用户使用 BP 神经

3) 用电量预测

对各类用户分别使用 BP、Elman、LSTM 神经网络进行预测仿真，各模型预测值与实际值的逐时段预测误差对比如图 6 所示，预测性能指标对比如表 4 所示。

网络时预测误差最小且耗时最短，其他三类用户在使用 LSTM 神经网络时误差最小，但耗时最长。将单峰、双峰及多峰类预测模型分别由 Elman 替换为 LSTM，计算整体预测结果的 MAPE。通过仿真可知，单峰类模型替换后整体预测结果的 MAPE 减少 0.47%，而双峰及多峰类用户因数量较少，模型替换后整体预测结果的 MAPE 分别减少只了 0.02%和 0.07%。综合考虑模型的预测时间和预测精度后，平稳类用户选择 BP 神经网络，单峰类用户选择 LSTM 神经网络，双峰及多峰类用户选择 Elman 神经网络进行预测建模。该分类模型预测的 MAPE 为 1.91%，RMSE 为 5.08%，时段平均预测耗时为 6.98 s。

4) 预测修正

平稳类用户的用电量无突变且预测模型效果较好，故不对其预测结果进行修正。观察其他三类用户预测日前一周的日用电量趋势，找出两侧斜率变化大的峰谷值范围。单峰类用户满足条件的峰值主

要出现在 46~50 这个时间段; 双峰类用户的峰、谷值主要出现在 42~44、69~71、74~76、83~85 这四个时间段; 多峰类用户的峰值主要出现在 43~45、68~70、83~86 这三各时间段。对这三类用户预测日对应峰谷值范围内的预测结果进行修正, 修正前后整体预测值与实际值的预测误差对比如图 7 所示。

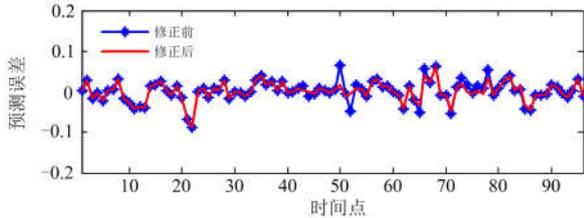


图 7 修正前后预测误差对比

Fig. 7 Comparison of prediction errors before and after correction

由仿真结果可知, 修正后整体预测的 MAPE 为 1.69%, RMSE 为 4.31%, 二者相比修正前分别减少 0.22% 和 0.77%。结果证明, 修正算法进一步提高了

表 5 改进前后模型预测效果对比

Table 5 Comparison of prediction effects before and after improvement

预测模型	原始输入量						改进输入量					
	直接预测			分类预测			直接预测			分类预测		
	MAPE/%	RMSE/%	t/s									
BP	8.03	18.65	0.41	4.51	12.44	2.35	6.08	15.11	0.72	3.93	8.98	2.65
ELMAN	6.31	14.28	1.06	3.21	7.00	5.76	4.47	10.44	1.69	2.50	5.12	6.86
LSTM	5.03	10.82	2.48	2.11	5.49	9.56	3.27	8.63	3.01	1.78	4.49	11.57
分类 ANN	—	—	—	2.30	6.36	6.28	—	—	—	1.91	5.08	6.98

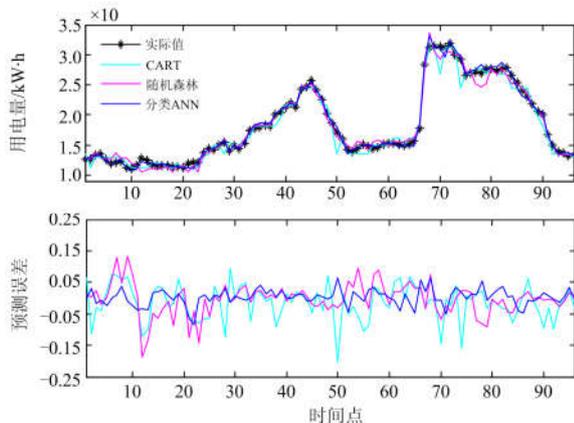


图 8 整体预测结果对比

Fig. 8 Comparison of overall prediction results

表 6 模型预测效果对比

Table 6 Comparison of each model's prediction effects

预测模型	MAPE/%	RMSE/%	t/s
CART	4.43	11.10	1.08
随机森林	3.53	8.52	2.07
分类 ANN 及修正	1.69	4.31	7.23

模型的预测精度。

3.3 不同预测模型效果对比

使用 BP、Elman、LSTM 和本文所提分类 ANN 预测算法, 在使用未考虑分时电价和预测日实时上传的用电量的原始输入量和改进输入量的情况下, 分别进行直接预测和分类预测, 各模型预测性能指标如表 5 所示。

将表 5 中性能指标进行横向比较, 可证明改进输入量后模型的预测精度高于原始输入, 分类预测的精度相比直接预测也有明显提高。将性能指标纵向比较可证明, 本文所提分类 ANN 算法的预测精确度优于 BP、Elman 分类预测, 而时段平均预测耗时相比 Elman 分类预测仅增加 0.12 s。

在采用改进输入量的情况下, 将使用修正算法后的分类 ANN 算法与随机森林、CART 算法进行预测效果对比, 各模型性能指标如表 6 所示, 预测结果与预测误差如图 8 所示。

对比表 6 及表 5 中的指标数据可知, 使用修正算法后, 分类 ANN 算法的预测精度略高于 LSTM 分类算法, 而预测耗时明显减少, 性能更优。由图 8 及表 6 中数据可知, 本文所提分类 ANN 及修正算法预测精度最高, 但时段平均预测耗时明显高于 CART 及随机森林算法, 故本文所提算法适用于预测精度要求高, 而预测速度要求较低的情况。

4 结语

本文基于智能电表每 15 min 上传的用户用电信息数据, 对居民用户进行短期用电量预测, 通过以下改进提高预测精度:

- 1) 改进输入量, 将分时电价和被预测时刻的前一时刻、前两时刻的用电量添加到输入量中。
- 2) 通过聚类算法将用户按用电行为分类, 根据每类用户的用电特点选择合适的预测算法。
- 3) 对于存在用电峰值的用户类型, 在获得预测值后, 对两侧斜率变化过大的峰、谷值点进行预测修正。

通过对比分析可知, 本文所提分类预测及修正算法的预测性能良好, 适用于预测精度要求高而速度要求相对较低的情况。

后续研究将综合考虑除电价政策外的需求侧响应机制, 建立需求响应机理模型, 更全面地体现智能电网和用户之间的关联互动, 进一步完善针对居民用户的短期用电量预测模型。

参考文献

- [1] 张智晟, 于道林. 考虑需求响应综合影响因素的 RBF-NN 短期负荷预测模型[J]. 中国电机工程学报, 2018, 38(6): 1631-1638, 1899.
ZHANG Zhisheng, YU Daolin. RBF-NN based short-term load forecasting model considering comprehensive factors affecting demand response[J]. Proceedings of the CSEE, 2018, 38(6): 1631-1638, 1899.
- [2] RYU S, NOH J, KIM H. Deep neural network based demand side short term load forecasting[C] // IEEE International Conference on Smart Grid Communications, November 6-9, 2016, Sydney, Australia, 10(1): 3.
- [3] 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.
- [4] 杨楠, 李宏圣, 袁景颜, 等. 计及灰色关联度分析的中长期负荷灰色预测方法[J]. 电力系统及其自动化学报, 2018, 30(6): 108-114.
YANG Nan, LI Hongsheng, YUAN Jingyan, et al. Medium-and long-term load forecasting method considering grey correlation degree analysis[J]. Proceedings of the CSU-EPSA, 2018, 30(6): 108-114.
- [5] 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 Xiacong, 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.
- [6] RANA M, KOPRINSKA I. Forecasting electricity load with advanced wavelet neural networks[J]. Neurocomputing, 2016, 182: 118-132.
- [7] 张冠英, 羨一鸣, 葛磊蛟, 等. 经济新常态下基于 Verhulst-SVM 的中长期负荷预测模型[J]. 电测与仪表, 2019, 56(1): 102-107.
ZHANG Guanying, XIAN Yiming, GE Leijiao, et al. Medium and long-term load forecasting model based on Verhulst-SVM under new normal economy[J]. Electrical Measurement & Instrumentation, 2019, 56(1): 102-107.
- [8] EAPEN R R, SIMON S P. Performance analysis of combined similar day and day ahead short term electrical load forecasting using sequential hybrid neural networks[J]. IETE Journal of Research, 2019, 65(2): 216-226.
- [9] HU Yusha, LI Jigeng, HONG Mengna, et al. Short term electric load forecasting model and its verification for process industrial enterprises based on hybrid GA-PSO-BPNN algorithm—a case study of papermaking process[J]. Energy, 2019, 170.
- [10] 吴佳懋, 李艳, 符一健. 基于粗糙集-混沌时间序列 Elman 神经网络的短期用电量预测[J]. 电力系统保护与控制, 2019, 47(3): 23-30.
WU Jiamao, LI Yan, FU Yijian. Short-term power consumption prediction based on rough set chaotic time series Elman neural network[J]. Power System Protection and Control, 2019, 47(3): 23-30.
- [11] 刘建华, 李锦程, 杨龙月, 等. 基于 EMD-SLSTM 的家庭短期负荷预测[J]. 电力系统保护与控制, 2019, 47(6): 40-47.
LIU Jianhua, LI Jincheng, YANG Longyue, et al. Short-term household load forecasting based on EMD-SLSTM[J]. Power System Protection and Control, 2019, 47(6): 40-47.
- [12] WANG Yi, GAN Dahua, SUN Mingyang, et al. Probabilistic individual load forecasting using pinball loss guided LSTM[J]. Applied Energy, 2019, 235.
- [13] 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.
- [14] LAHOUAR A, BEN H S J. Day-ahead load forecast using random forest and expert input selection[J]. Energy Conversion and Management, 2015, 103: 1040-1051.
- [15] CHEN Xi, QIU Jing, DONG Zhaoyang. An improved load forecast model using factor analysis: An Australian case study[C] // IEEE International Conference on Information and Automation, July 18-20, 2017, Macau SAR, China: 903-908.
- [16] 何耀耀, 刘瑞, 撒奥洋. 基于实时电价与支持向量分位数回归的短期电力负荷概率密度预测方法[J]. 中国电机工程学报, 2017, 37(3): 768-776.
HE Yaoyao, LIU Rui, HAN Aoyang. Short-term power load probability density forecasting method based on real

- time price and support vector quantile regression[J]. Proceedings of the CSEE, 2017, 37(3): 768-776.
- [17] 李鹏, 何帅, 韩鹏飞, 等. 基于长短期记忆的实时电价条件下智能电网短期负荷预测[J]. 电网技术, 2018, 42(12): 4045-4052.
- LI Peng, HE Shuai, HAN Pengfei, et al. Short term load forecasting of smart grid based on long-short-term memory recurrent neural networks in condition of real-time electricity price[J]. Power System Technology, 2018, 42(12): 4045-4052.
- [18] 彭文, 王金睿, 尹山青. 电力市场中基于 Attention-LSTM 的短期负荷预测模型[J]. 电网技术, 2019, 43(5): 1745-1751.
- PENG Wen, WANG Jinrui, YIN Shanqing. Short-term load forecasting model based on attention-LSTM in electricity market[J]. Power System Technology, 2019, 43(5): 1745-1751.
- [19] 陈丽娜, 张智晟, 于道林. 基于广义需求侧资源聚合的电力系统短期负荷预测模型[J]. 电力系统保护与控制, 2018, 46(15): 45-51.
- CHEN Lina, ZHANG Zhisheng, YU Daolin. Short-term load forecasting model of power system based on generalized demand side resources aggregation[J]. Power System Protection and Control, 2018, 46(15): 45-51.
- [20] GARULLI A, PAOLETTI S, VICINO A. Models and techniques for electric load forecasting in the presence of demand response[J]. IEEE Transactions on Control Systems Technology, 2015, 23(3): 1087-1097.
- [21] 郑国和, 贺民, 郑瑞云, 等. 基于多表融合数据的用户短期用电量预测[J]. 电力系统及其自动化学报, 2019, 31(3): 146-150.
- ZHENG Guohe, HE Min, ZHENG Ruiyun, et al. Short-term electricity consumption forecasting based on multi-meter data fusion[J]. Proceedings of the CSU-EPSA, 2019, 31(3): 146-150.
- [22] 孔祥玉, 胡启安, 董旭柱, 等. 引入改进模糊 C 均值聚类的负荷数据辨识及修复方法[J]. 电力系统自动化, 2017, 41(9): 90-95.
- KONG Xiangyu, HU Qi'an, DONG Xuzhu, et al. Load data identification and correction method with improved fuzzy C-means clustering algorithm[J]. Automation of Electric Power Systems, 2017, 41(9): 90-95.
- [23] 李恩文, 王力农, 宋斌, 等. 基于改进模糊聚类算法的变压器油色谱分析[J]. 电工技术学报, 2018, 33(19): 4594-4602.
- LI Enwen, WANG Linong, SONG Bin, et al. Analysis of transformer oil chromatography based on improved fuzzy clustering algorithm[J]. Transactions of China Electrotechnical Society, 2018, 33(19): 4594-4602.
- [24] 杨智宇, 刘俊勇, 刘友波, 等. 基于自适应深度信念网络的变电站负荷预测[J]. 中国电机工程学报, 2019, 39(14): 4049-4061.
- YANG Zhiyu, LIU Junyong, LIU Youbo, et al. Transformer load forecasting based on adaptive deep belief network[J]. Proceedings of the CSEE, 2019, 39(14): 4049-4061.
- [25] 吴润泽, 包正睿, 王文韬, 等. Hadoop 架构下基于模式匹配的短期电力负荷预测方法[J]. 电工技术学报, 2018, 33(7): 1542-1551.
- WU Runze, BAO Zhengrui, WANG Wentao, et al. Short-term power load forecasting method based on pattern matching in Hadoop framework[J]. Transactions of China Electrotechnical Society, 2018, 33(7): 1542-1551.

收稿日期: 2019-04-30; 修回日期: 2019-08-25

作者简介:

徐冰涵(1995—), 女, 硕士研究生, 研究方向为电力线通信技术、电力数据分析应用; E-mail: binghan_xu@foxmail.com

孙云莲(1962—), 女, 教授, 博士生导师, 研究方向为电力信息技术、智能电网。E-mail: ylsun@whu.edu.cn

(编辑 姜新丽)