

# 开放售电环境下用户短期负荷预测方法

杨本臣, 张 军, 于坤鹏

(辽宁工程技术大学电气与控制工程学院, 辽宁 葫芦岛 125105)

**摘要:** 开放售电环境下用户负荷预测精度将直接影响售电公司的利益和电力系统的稳定性。提出了一种开放售电环境下的用户短期负荷预测方法,首先根据用户历史负荷数据计算用户的典型日(工作日,节假日)负荷曲线;然后,利用 Kohonen 神经网络挖掘用户用电行为之间的相似性,对用户用电负荷进行聚类,将用电行为相似的用户划分到同一个聚类中;最后在考虑电价和温度等影响因素下,利用在线顺序极限学习机(OS-ELM)负荷预测模型对已经聚类的用户分别进行负荷预测,并对负荷预测结果求和得到系统负荷。为了验证提出方法的可行性,采用某地区的智能电表数据进行试验,试验结果表明,该方法能够深入挖掘用户的用电行为,揭示了用户聚类数目与系统负荷预测精度的关系,能很好地满足系统短期负荷预测的精度要求。

**关键词:** 智能电表; Kohonen 神经网络; 用电行为; 电价; OS-ELM; 负荷预测

**DOI:** 10. 12067/ATEEE1807011      **文章编号:** 1003-3076(2020)01-0005-07      **中图分类号:** TM715

## 1 引言

开放售电环境下整个售电侧结构和运行方式变得复杂,不同售电主体间相互竞争与合作使电价和响应负荷的变化也更加明显,用户的用户负荷曲线、响应规律与力度都会发生很大的变化。引起变化的主要因素除行业类型、用户用电行为偏好、环境因素外,电价也成为主导因素之一。在开放售电环境下,供电企业期望增加与售电主体及用电客户的粘性,更加注重与用户的互动,对用户用电行为的分析和负荷的准确预测不仅是合理安排运行调度的基础,也是市场售电主体合理制定电价的前提,具有重要的意义<sup>[1,2]</sup>。

在开放售电环境下,通过对用户的用电行为进行数据化处理,可以对用户用电行为规律进行建模和挖掘,从而揭示与用户用电行为密切相关的属性,发现各类用户之间的隐含关系。用户的用电行为一般可由用户、时间、地点、用电量、用电负荷及类型、电价和环境等属性来描述,某个用户在特定时刻的用电行为可表示成一个向量,一个时期的用电行为可表示成一个用电行为序列。在用电行为序列的基

础上,可以构建出该用户相应的用电负荷曲线、用电价格曲线。此外考虑引起用户用电行为差异化的因素也对负荷预测精度的提高至关重要。传统的负荷预测方法一般只考虑天气、季节、日期和负荷性质<sup>[3-6]</sup>等因素,对负荷影响因素考虑不全面,自适应性不强。

近年来,研究者提出了一些基于用户用电行为的短期负荷预测方法。文献[7]结合大数据分析技术完成对用户的用电特征提取,通过动态聚类技术完成对用户的分类,然后采用用户用电行为分析方法实现电力用户的负荷预测;文献[8]将大数据处理技术应用于电力负荷预测中,首先使用聚类算法对行业进行细分,然后对不同的行业分别进行预测,大大提高了负荷预测的精度。文献[7,8]都只考虑了用户用电行为,不能体现出电价波动对负荷变化的影响。文献[9]提出售电市场下的电价对负荷变化的影响模型,不受电价影响的负荷用传统的方法进行预测,受到电价影响的负荷利用弹性矩阵来进行描述,然后用遗传算法对弹性矩阵进行优化,并验证了其方法的有效性;但是该方法不能体现出用户的用电行为,这将导致将来售电主体不能合理地针

**收稿日期:** 2018-07-04  
**基金项目:** 国家自然科学基金项目(61772249)  
**作者简介:** 杨本臣(1975-),男,辽宁籍,副教授,博士,研究方向为智能电网理论与技术;  
张 军(1995-),男,湖北籍,硕士研究生,研究方向为智能电网理论与技术。

对不同的用户提供不同的增值化服务。

本文提出了一种考虑电价因素的基于用户用电行为的短期负荷预测方法,该方法利用用户的用电曲线之间的差异性将用户进行聚类,在考虑电价和温度等影响因素的情况下,利用在线顺序极限学习机(Online Sequential Extreme Learning Machine, OS-ELM)学习速度快、泛化能力强的优点对不同用户进行预测,并对模型中影响负荷预测精度的参数进行了研究。仿真结果表明,本文算法能很好地满足短期负荷预测的要求。

## 2 基于用电行为的短期负荷预测思路

本文的用户用电负荷预测的研究原理的流程图如图 1 所示。该预测模型采用用户行为序列中的用电负荷曲线。首先排除掉节假日因素,将用户工作日一天的典型负荷曲线和节假日一天的典型负荷曲线级联成一个典型曲线,利用这一典型曲线来代表这个用户的相似日特征行为。由于在挖掘电力用户的行为时,考虑的是其负荷曲线的相似性,与具体电力消耗无关,因此在进行聚类之前,需要将典型曲线进行归一化处理,归一化采用负载聚类过程中最常用的 min-max 标准化算法。然后利用 Kohonen 神经网络挖掘所有用户的典型曲线的相似性,将用户分成具有相同的用电行为的几类用户,每一类都取其类中的归一化平均用电负荷曲线作为预测曲线,最后利用 OS-ELM 算法在考虑电价和温度的情况下对每一类分别进行学习得到相应的参数,进行预测,反归一化求和得到系统负荷。

## 3 基于用户用电行为的聚类

### 3.1 坏数据的辨识与处理

负荷预测的准确性需要数据的可靠性和预测算法的适用性两方面的保证<sup>[10]</sup>,因此在预测之前纠正以及填补历史数据至关重要。负荷的缺失值很容易辨认和识别,对于缺失值,使用传统的人工填写法,采用缺失值两侧数据的平均值进行替代即可。对于异常值的辨识和处理,文献[11]提出了一种改进的模糊 c-均值聚类方法,该方法首先利用减法聚类算法得到 c-均值的聚类中心和聚类数目,然后以此作为 c-均值的起点,通过横向比较负荷曲线,找到并修正负荷曲线的不良数据,最后验证了该方法的有效性。本文采用文献[11]的思想对异常数据点进行识别和处理。

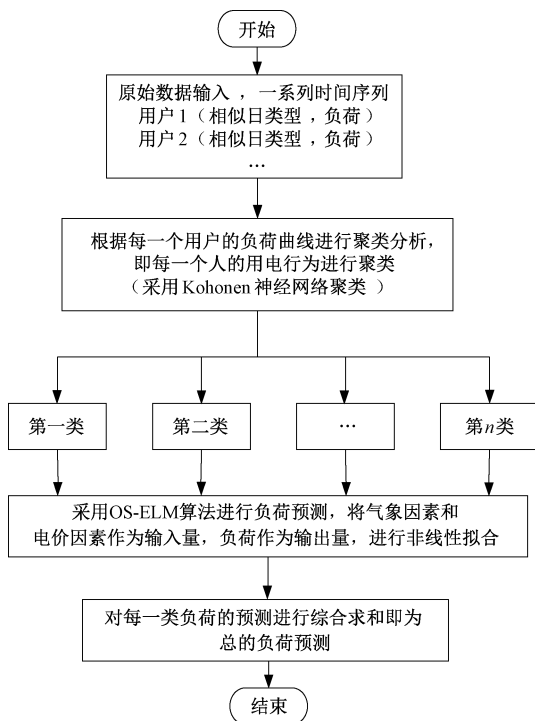


图 1 用户用电负荷预测流程图

Fig.1 User power load forecasting flow chart

### 3.2 用户典型负荷曲线的提取方法

本文对用户典型负荷曲线的提取采用平均值法。在一个用户用电行为序列中,取其中的用电负荷曲线,以天为单位将其分成节假日与工作日两类负荷曲线,分别计算其平均值以及其与平均值的距离,舍去其中偏离平均值较大的负荷,再次求其平均值,循环直至所有负荷值均在平均负荷周围波动,记录节假日与工作日的用户典型负荷曲线。流程图如图 2 所示。

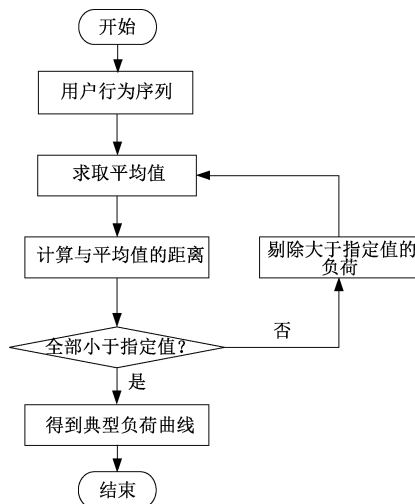


图 2 用户典型负荷曲线提取流程图

Fig.2 User typical load curve extraction flow chart

### 3.3 基于 Kohonen 的负荷特性聚类

在以往的文献中,大多通过自适应的 K-means 聚类方法从大量用户和大范围数据中寻找不同用户的用电规律<sup>[12-14]</sup>。与以往文献不同的是本文采用 Kohonen 方法进行聚类,Kohonen 神经网络是自组织竞争性神经网络的一种,能够识别环境特征并自动聚类,其包括输入层和竞争层两层前馈神经网络,输入层神经元个数同输入样本维数一致,竞争层节点呈二维阵列分布,输入节点和输出节点之间以可变权值全连接。其工作原理为当样本输入网络时,竞争层上的神经元计算输入神经元与竞争层神经元权值之间的欧几里得距离,距离最小的神经元为获胜神经元。调整获胜神经元和相邻神经元权值,使其周边权值靠近该样本,通过反复训练,使同类神经元具有相近的权系数,不同类的神经元权系数差别明显。以下为实现 Kohonen 方法的具体步骤:

(1) 网络初始化。初始化权值网络  $\omega_{ij}$ 。

(2) 距离计算。计算输入向量  $\mathbf{X} = (x_1, x_2, \dots, x_m)$  与竞争层神经元  $j$  之间的距离  $d_j$ , 其表达式为:

$$d_j = \left| \sum_{i=1}^m (x_i - \omega_{ij})^2 \right| \quad j = 1, 2, \dots, n \quad (1)$$

(3) 神经元选择。将与输入向量  $\mathbf{X}$  距离最小的竞争层神经元  $c$  作为最优匹配输出神经元。

(4) 权值调整。调整节点  $c$  和在其领域内  $N_c(t)$  包含的节点权系数,即

$$N_c(t) = (t \mid \text{find}(\text{norm}(\text{pos}_t, \text{pos}_c) < r)) \quad t = 1, 2, \dots, n \quad (2)$$

$$\omega_{ij} = \omega_{ij} + \eta(x_i - \omega_{ij}) \quad (3)$$

式中,  $\text{pos}_t, \text{pos}_c$  分别为神经元  $c$  和  $t$  的位置;  $\text{norm}$  表示计算两神经元之间的欧几里得距离;  $r$  为领域半径;  $\eta$  为学习效率。

(5) 判断算法是否结束,若没有结束,返回步骤(2)。

其流程图如图 3 所示。

### 4 基于 OS-ELM 的短期负荷预测

OS-ELM 是一种新型的学习算法,该算法使用单隐层前馈神经网络,可以应用于分类和回归问题<sup>[15]</sup>。OS-ELM 算法对于单隐层神经网络的输出权重的学习过程主要分为两部分:第一部分是初始阶段,即通过少量样本得到单隐层前馈神经网络的输出权值  $\beta$ ;第二部分是在线学习部分,利用单个样本或者样本数据块更新在初始阶段学习到的单隐层前




图 3 Kohonen 神经网络流程图

Fig.3 Kohonen neural network flowchart

馈神经网络的输出权值  $\beta$ 。在初始阶段,假设隐藏层神经元个数为  $l$ , 有  $N_0$  个任意训练样本  $(\mathbf{x}_j, \mathbf{t}_j)$ , 其中  $\mathbf{x}_j = [x_{1j}, x_{2j}, \dots, x_{mj}]^T$ ,  $\mathbf{t}_j = [t_{1j}, t_{2j}, \dots, t_{mj}]^T$ ,  $\omega_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{in}]$ ,  $\mathbf{T}_0 = [t_1, t_2, \dots, t_{N_0}]$ 。利用基本的极限学习计算法思想,希望求得使满足  $\|H_0\beta - T_0^T\|$  最小的  $\beta$ , 其中  $H_0$  的表达式为:

$$H_0 = \begin{bmatrix} g(\omega_1 \mathbf{x}_1 + b_1) & g(\omega_2 \mathbf{x}_1 + b_2) & \cdots & g(\omega_l \mathbf{x}_1 + b_l) \\ g(\omega_1 \mathbf{x}_2 + b_1) & g(\omega_2 \mathbf{x}_2 + b_2) & \cdots & g(\omega_l \mathbf{x}_2 + b_l) \\ \vdots & \vdots & & \vdots \\ g(\omega_1 \mathbf{x}_{N_0} + b_1) & g(\omega_2 \mathbf{x}_{N_0} + b_2) & \cdots & g(\omega_l \mathbf{x}_{N_0} + b_l) \end{bmatrix} \quad (4)$$

式中,  $b_i (i = 1, 2, \dots, l)$  为隐含层第  $i$  个神经元的偏置。

设隐含层与输出层间的连接权值为:

$$\beta = \begin{bmatrix} \beta_{11} & \beta_{12} & \cdots & \beta_{1m} \\ \beta_{21} & \beta_{22} & \cdots & \beta_{2m} \\ \vdots & \vdots & & \vdots \\ \beta_{l1} & \beta_{l2} & \cdots & \beta_{lm} \end{bmatrix} \quad (5)$$

式(5)解为  $\beta = K_0^{-1} H_0^T T_0^T$ ,  $K_0 = H_0^T H_0$ , 当有新的单个样本进入模型时,其训练公式为:

$$\begin{cases} \mathbf{P}_{k+1} = \mathbf{P}_k - \frac{\mathbf{P}_k \mathbf{h}_{k+1} \mathbf{h}_{k+1}^T \mathbf{P}_k}{1 + \mathbf{h}_{k+1}^T \mathbf{P}_k \mathbf{h}_{k+1}} \\ \beta^{(k+1)} = \beta^{(k)} + \mathbf{P}_{k+1} \mathbf{h}_{k+1} (t_{k+1}^T - \mathbf{h}_{k+1}^T \beta^{(k)}) \end{cases} \quad (6)$$

式中,  $\mathbf{K}_{k+1} = \mathbf{K}_k + \mathbf{H}_{k+1}^T \mathbf{H}_{k+1}$ ;  $\mathbf{P}_k = \mathbf{K}_k^{-1}$ ;  $\mathbf{h}_{k+1} = \mathbf{H}_{k+1}^T \circ$

OS-ELM 算法的具体实现过程如下:

(1)确定隐含层神经元个数,随机设定输入层与隐含层间的连接权值  $\omega$  和隐含层神经元的偏置  $b$ 。

(2)选择一个无限可微的函数作为隐含层神经元的激活函数,进而计算隐含层输出矩阵  $H_0$ 。

(3)计算输出层权值  $\beta$ 。

(4)在线学习,假设一批样本的个数为  $N_i$ , 计算隐含层的输出矩阵  $H_i$ 。

(5)计算输出权重,采用如下公式:


当只有一个样本时,采用式(6)中的公式来迭代计算输出层权值。

当为多个样本时,公式为:

$$\begin{cases} P_{k+1} = P_k - P_k H_{k+1}^T (1 + H_{k+1} P_k)^{-1} H_{k+1} P_k \\ \beta^{(k+1)} = \beta^{(k)} + P_{k+1} H_{k+1}^T (T_{k+1}^T - H_{k+1} \beta^{(k)}) \end{cases} \quad (7)$$

(6)返回输出权重  $\beta$ 。

最后训练完毕后需要对 OS-ELM 进行性能评价,本文采用算法预测值和真实值之间的误差对模型的泛化能力进行评价。其流程图如图 4 所示。



5 算例分析


本文主要采用某一地区的智能电表数据,这些数据记录了用户每隔 1h 从 2017 年 6 月 1 日~2017 年 11 月 31 日的用电量,本文从中随机抽取 400 户用户的智能电表数据作为实验样本,其中前 4 个月的数据作为 OS-ELM 预测的训练样本,后 2 个月的数据作为其测试样本。首先利用实验样本提取典型负荷曲线,然后用这些典型负荷曲线作为 Kohonen 网络的输入来进行用户行为挖掘,其中 Kohonen 网络的参数设置为:最大学习率 0.2,最小学习率

0.05,最大学习半径 1.2,最小学习半径 0.8。接着利用其相应的实时电价和每天的最高温度、最低温度数据对未来一天的负荷进行预测,OS-ELM 隐藏层神经元个数设为 12,激活函数为 sig 函数,OS-ELM 预测的输入参数如表 1 所示,其中用户实时电价在图 5 实时电价基础上加上一个市场影响的随机变量,使不同日的实时电价具有一定波动性。

表 1 OS-ELM 输入数据

Tab.1 OS-ELM input data

所需数据	变量	描述
$x_1 \sim x_4$	历史负荷	前 4h 的负荷
$x_5 \sim x_8$	历史负荷	前 4 天同时刻负荷
$x_9 \sim x_{10}$	温度	最高和最低气温
$x_{11}$	电价	实时电价



5.1 负荷预测评价函数

本文负荷预测误差评价函数采用  $MAPE$ ,其表达式为:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| \times 100\% \quad (8)$$

式中,  $y_i$  为第  $i$  个群体的负荷实际值;  $y'_i$  为第  $i$  个群体的负荷预测值;  $n$  为样本数量。

5.2 实验结果分析

利用本文所提出的预测模型对算例进行负荷预测,考虑电价因素条件下不同分类情况的负荷预测值如表 2 所示。在不计电价的情况下考虑分类的误差曲线如图 6 所示,其分类误差结果如表 3 所示。

表 2 电价因素下不同分类情况的负荷预测值

Tab.2 Load forecasting under different classification conditions of electricity price factor

时间	实际 负荷/MW	不计电价负荷预测值/MW					计电价负荷预测值/MW				
		$k=1$	$k=2$	$k=3$	$k=4$	$k=5$	$k=1$	$k=2$	$k=3$	$k=4$	$k=5$
0:00	1536.62	1485.29	1648.47	1634.07	1482.47	1565.04	1494.90	1559.74	1562.20	1591.88	1541.67
1:00	1382.86	1416.29	1457.77	1395.04	1420.59	1425.58	1363.84	1365.49	1386.88	1447.95	1405.50
2:00	1426.40	1319.27	1410.18	1471.87	1338.85	1488.83	1407.41	1379.48	1400.43	1483.10	1410.76
3:00	1336.10	1465.68	1469.91	1392.88	1450.08	1487.78	1473.67	1416.13	1350.09	1412.52	1409.89



续表

时间	实际 负荷/MW	不计电价负荷预测值/MW					计电价负荷预测值/MW				
		$k=1$	$k=2$	$k=3$	$k=4$	$k=5$	$k=1$	$k=2$	$k=3$	$k=4$	$k=5$
4:00	1358.58	1384.95	1427.48	1424.81	1372.26	1472.15	1377.49	1377.49	1390.04	1440.97	1371.10
5:00	1440.36	1526.15	1605.22	1496.44	1546.75	1580.09	1440.90	1525.76	1460.90	1481.78	1494.45
6:00	1575.00	1607.82	1685.51	1626.15	1672.87	1666.08	1686.26	1639.94	1611.98	1715.74	1595.41
7:00	1827.28	1841.06	1818.05	1807.85	1902.06	1945.67	1955.64	1909.50	1842.27	1873.17	1781.64
8:00	2190.54	1851.64	1997.25	1980.26	1962.23	2089.08	2000.01	2143.8	2127.46	2124.55	2024.31
9:00	2661.00	2385.49	2721.01	2715.35	2631.85	2743.78	2834.54	2660.23	2710.59	2801.85	2697.77
10:00	2975.96	2645.56	2923.13	2928.76	2840.87	2918.73	2946.40	2868.17	3011.35	2993.08	2784.32
11:00	2752.12	2412.56	2601.52	2867.38	2603.14	2732.96	2585.05	2661.01	2748.54	2810.13	2751.58
12:00	2538.84	2462.51	2464.66	2418.53	2582.02	2616.40	2309.03	2482.91	2454.41	2598.15	2572.18
13:00	2630.60	2353.49	2352.54	2755.03	2650.77	2643.99	2695.56	2645.67	2530.72	2665.74	2682.36
14:00	2606.40	2714.28	2576.17	2832.66	2865.35	2853.92	2610.67	2795.25	2612.93	2663.79	2798.86
15:00	2698.06	2633.52	2565.10	2767.32	2635.36	2717.74	2741.41	2663.13	2572.66	2590.34	2723.55
16:00	2646.68	2626.5	2601.26	2619.38	2751.50	2674.03	2632.97	2632.76	2534.87	2657.02	2676.41
17:00	2331.00	2103.77	2054.48	2259.93	2225.27	2129.19	2135.33	2086.25	2255.80	2230.90	2178.54
18:00	2258.30	2241.06	2214.17	2201.27	2298.34	2325.05	2312.25	2281.88	2249.53	2198.84	2414.4
19:00	2243.90	2092.38	2166.54	2299.38	2192.42	2267.44	2208.15	2225.19	2187.71	2194.67	2261.57
20:00	1940.66	1866.37	1646.78	1842.75	1899.94	1696.85	1790.06	1800.00	1906.45	1919.39	1770.49
21:00	1867.02	1844.19	1658.82	1802.12	1826.47	1714.26	1838.69	1781.07	1843.96	1735.04	1721.12
22:00	1816.50	1811.73	1638.52	1740.17	1748.31	1698.92	1781.14	1718.99	1791.65	1790.24	1762.18
23:00	1632.28	1708.77	1463.62	1542.89	1628.34	1536.02	1588.20	1536.25	1595.53	1569.35	1560.44




图6 不计电价不同分类条件下的误差曲线  
Fig.6 MAPE of load forecasting under different clustering without considering electricity price

表3 不计电价不同分类情况下的最大误差和平均误差  
Tab.3 Maximum and average MAPE of load forecasting under different clustering without considering electricity price

分类数目 $k$	MAPE(%)	
	最大值	平均值
1	15.4712	5.4610
2	15.1435	6.300
3	9.5993	3.8813
4	10.4224	4.0270
5	12.5633	5.0814

从图6和表3中可以看出,在不考虑电价情况下对用户进行合适的用电行为挖掘可以提高负荷预测的精度,当分为3类时,其平均误差最低可达3.8813%,最大误差为9.5993%。

计及电价考虑分类的误差曲线如图7所示,其分类误差结果如表4所示。从图7和表4可以看出,在考虑电价的情况下,整体预测水平较不考虑电价精确度提高,当分为3类时,其平均误差最低可达1.9490%,最大误差为4.6479%。因此在负荷预测时同时考虑电价和分类数的影响对预测精度的提高起着至关重要的作用。




图7 计电价不同分类条件下的误差曲线  
Fig.7 MAPE of load forecasting under different clustering when considering electricity price

表 4 计电价不同分类情况下的最大误差和平均误差

Tab.4 Maximum and average *MAPE* of load forecasting under different clustering when considering electricity price

分类数目 <i>k</i>	<i>MAPE</i> (%)	
	最大值	平均值
1	10.2960	3.9013
2	10.4999	3.5167
3	4.6479	1.9490
4	8.9360	3.4257
5	8.7687	3.4764

根据上述研究,对于所选数据集所提出的样本聚类方法和预测模型,当用户被分为三个群组时,预测精度最高。其工作日与节假日共两天级联而成的标准化用户负载曲线的聚类结果如图 8 所示。




图 8 聚类效果图(三类)

Fig.8 Effect pictures when number of clusters is three

图 8 中曲线是不同用户的归一化典型负荷曲线。对上述曲线取平均值,可得其平均负荷曲线,可以看出,来自同一群组用户的用电负荷曲线非常相似,来自不同群组用户的用电负荷曲线差异很大;除此之外,还可以从图 8 的用户用电行为来大致判断用户的类型,从而为供电公司的调度和个性化服务提供理论支撑。

从图 8(a)中可以看出,用电高峰主要集中在白天,是典型的商业用电模式;从图 8(b)中可以看出,用电高峰主要在 11:00 附近和 18:00 附近,是典型的上班族用电模式;同理从图 8(c)中可以看出,这是一个重要的用电客户,全天不间断用电,很可能是医院等重要用电场所。

6 结论

为适应售电侧的开放,智能电表数据的精细化发展,本文提出了一种基于用户用电行为的短期负荷预测模型。通过数据化用户用电行为,将大量用户进行精细化分类,使预测更加合理,在此基础上对不同类用户考虑电价的影响因素下分别进行负荷预测,最终对所有不同类用户的预测结果求和得到系统负荷,并对影响精确度的因素分类数目做出了研究。实际算例表明,本文提出的方法不仅能很好地解决未来电力市场下供电公司的负荷预测精度问题,还能深度挖掘用户用电行为的相关性,可以作为供电公司为用户提供个性化、增值化服务的基础。

参考文献 (References):

[ 1 ] 胡时雨, 罗滇生, 阳霜, 等 (Hu Shiyu, Luo Diansheng, Yang Shuang, et al.). 基于多变量 LS-SVM 和模糊循环推理系统的负荷预测 (Load forecasting based on multi-variable LS-SVM and fuzzy recursive inference system) [J]. 计算机应用 (Journal of Computer Applications), 2015, 35 (2): 595-600.

[ 2 ] 于道林, 张智晟, 韩少晓, 等 (Yu Daolin, Zhang Zhisheng, Han Shaoxiao, et al.). 计及需求响应的 Elman-NN 短期负荷预测模型研究 (Study of short-term load forecasting model based on Elman-NN considering demand response) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2017, 36 (4): 59-65.

[ 3 ] 彭堃, 陈星莺, 李斌, 等 (Peng Kun, Chen Xingying, Li Bin, et al.). 气象环境对电网负荷的影响因素分析 (Analysis of the impact factors of meteorological environment on power load) [J]. 电力需求侧管理 (Power Demand Side Management), 2016, 18 (1): 8-13.

[ 4 ] 邹红波, 伏春林, 喻圣 (Zou Hongbo, Fu Chunlin, Yu Sheng). 基于 Akima-LMD 和 GRNN 的短期负荷预测 (Short-term load forecasting based on Akima-LMD and GRNN) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2018, 37 (1): 51-56.

[ 5 ] 曲正伟, 张坤, 王云静, 等 (Qu Zhengwei, Zhang Kun, Wang Yunjing, et al.). 基于 PSO-OMP 优化的

WD-ASD 超短期负荷预测 (Short-term load forecasting based on WD-ASD optimized by PSO-OMP) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2017, 36 (12): 39-45.

[ 6 ] 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.

[ 7 ] 梁伟 (Liang Wei). 基于用户用电行为正向分析负荷预测方法的研究 (Study on load forecasting technology based on user behavior pattern with forward analysis) [D]. 广州: 华南理工大学 (Guangzhou: South China University of Technology), 2015.

[ 8 ] 邵冬冬 (Shao Dongdong). 基于大数据分析的电力短期负荷预测研究与开发 (The power short-term load forecasting based on large data analysis of the research and development) [D]. 北京: 华北电力大学 (Beijing: North China Electric Power University), 2016.

[ 9 ] 刘孝杰, 苏小林, 阎晓霞, 等 (Liu Xiaojie, Su Xiaolin, Yan Xiaoxia, et al.). 面向主动响应和售电市场的主动配电系统负荷预测 (Load forecast of active distribution system based on active response and electricity market) [J]. 电力系统及其自动化学报 (Proceedings of the CSU-EPSA), 2017, 29 (2): 121-128.

[10] 沈沉, 秦建, 盛万兴, 等 (Shen Chen, Qin Jian, Sheng Wanxing, et al.). 基于小波聚类的配变短期负荷预测方法研究 (Study on short-term forecasting of distribution transformer load using wavelet and clustering method) [J]. 电网技术 (Power System Technology), 2016, 40 (2): 521-526.

[11] 苏舟, 李灿, 姚李孝, 等 (Su Zhou, Li Can, Yao Lixiao, et al.). 电力负荷数据预处理研究及应用 (Research and application of pretreatment of electrical load data) [J]. 电网与清洁能源 (Power System and Clean Energy), 2017, 33 (5): 40-43, 50.

[12] 张承畅, 张华誉, 罗建昌, 等 (Zhang Chengchang, Zhang Huayu, Luo Jianchang, et al.). 基于云计算和改进 K-means 算法的海量用电数据分析方法 (Massive data analysis of power utilization based on improved K-means algorithm and cloud computing) [J]. 计算机应用 (Journal of Computer Applications), 2018, 38 (1): 159-164.

[13] 肖琪 (Xiao Qi). 基于优化 K-means 算法的电力负荷分类研究 (Research on power load classification based on optimized K-means algorithm) [D]. 大连: 大连理工大学 (Dalian: Dalian University of Technology), 2015.

[14] 赵莉, 候兴哲, 胡君, 等 (Zhao Li, Hou Xingzhe, Hu Jun, et al.). 基于改进 k-means 算法的海量智能用电数据分析 (Improved k-means algorithm based analysis on massive data of intelligent power utilization) [J]. 电网技术 (Power System Technology), 2014, 38 (10): 2715-2720.

[15] Li Y, Guo P, Li X. Short-term load forecasting based on the analysis of user electricity behavior [J]. Algorithms, 2016, 9 (4): 80.

# User short-term load forecasting method under open sales environment

YANG Ben-chen, ZHANG Jun, YU Kun-peng

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

**Abstract:** The accuracy of user load forecasting under the open sales environment will directly affect the interests of the power selling company and the stability of the power system. A user short-term load forecasting method under open sales environment is proposed. First, the typical daily (working day, holiday) load curve of the user is calculated based on the user historical load data recorded by the smart meter; then, by using Kohonen neural network, the similarity between user electricity behaviors is collected and the user electricity loads are clustered to classify the users with similar behaviors into the same cluster. Finally, under the condition of considering the price of electricity and temperature, the load forecasting model based on the Online Sequential Extreme Learning Machine (OS-ELM) is applied to different clusters to conduct load forecasting, and the load forecast is summed to obtain the system load. In order to prove the validity of the proposed method, the data of smart meter in a certain area was used to test. The experimental results show that this method can deeply investigate the user electricity behaviors, and reveals the relationship between forecasting accuracy and cluster numbers. It can well meet the accuracy requirements of short-term load forecasting of the system.

**Key words:** smart meter; Kohonen neural network; electricity behavior; electricity price; OS-ELM; load forecasting