

[负荷预测]

基于相空间重构和EMD-ELM的短期电力负荷预测

文/广州汇电云联互联网科技有限公司 张睿 谭江浩 杨瑞 董海雷

为了提高短期电力负荷预测准确度，本文将相空间重构、经验模态分解和极限学习机等理论相结合，建立了基于相空间重构和EMD-ELM的短期电力负荷预测模型。预测结果表明，基于相空间重构和EMD-ELM的短期电力负荷预测模型的均方根误差、平均相对误差和全局最大相对误差分别为23.49（均方根误差没有单位）、4.24%和9.58%，远小于其他预测模型，验证了该短期负荷预测方法的正确性和有效性。

随着“碳中和”目标的提出，清洁能源所占比例越来越大，我国能源结构变得更加复杂，清洁能源的使用降低了碳排放，但也对电力系统的稳定性构成了一定威胁。精准的负荷预测能够使电力部门了解负荷需求，提前制订调度计划，因此，建立合适的负荷预测模型，提高短期负荷预测准确度具有重要意义。

目前，电力负荷预测已成为国内外专家学者研究的热点。张群洪考虑了日类型、温度和天气情况的影响，利用自组织和BP神经网络相结合，建立了基于集成智能方法的短期负荷预测模型，并用厦门市电力负荷数据验证了模型的正确性。张永信等采用核主成分分析法对负荷数据进行降维，降低了负荷数据的复杂度，采用支持向量机对负荷数据进行了回归。李杰等在粒子群优化算法中引入混沌自适应策略，对粒子群算法进行改进，利用改进粒子群算法对极限学习机（Extreme Learning Machine, ELM）进行优化，建立了基于改进粒子群优化极限学习机的短期负荷预测模型，并与其他负荷预测模型进行对比，验证了模型在负荷预测方面的优越性。孟凡煦等为了提高负荷预测准确度，采用变分模态分解对负荷数据进行处

理，得到一组模态分量，采用极限学习机对各模态分量分别进行预测，完成了短期电力负荷的预测。上述基于不同方法建立的短期负荷预测模型的预测准确度并不高，有待进一步改进。

针对上述情况，本文采用经验模态分解（Empirical Mode Decomposition, EMD）对负荷时间序列进行处理，得到一组模态分量，对各模态分量分别进行相空间重构，并采用ELM对各分量分别进行预测，建立基于相空间重构和EMD-ELM的短期电力负荷预测模型，并利用实际负荷数据对模型的正确性和实用性进行了验证。

算法原理

1. 相空间重构

研究表明，负荷时间序列具有混沌属性，可以进行相空间重构。根据Takens定理，令负荷时间序列为 $x(t)$ ，则相空间重构后的序列为

$$x(t) = \{y(t), y(t + \tau), \dots, y(t + (m - 1)\tau)\}, \quad (1)$$

$$t = 1, 2, \dots, M; M = N - (m - 1)\tau$$

式中， N 为序列长度； M 为相点数量； τ 为延迟时

基金项目：广州市黄埔区广州开发区创新创业领军人才项目“电力现货市场交易与辅助决策平台研发与应用”（项目编号：2020-L005）成果之一。

间； m 为嵌入维数。

本文延迟时间采用互信息法求取，互信息法认为，当时间序列的互信息值第一次经过极小值的位置时，对应的时间值即为延时时间。嵌入维数采用伪最邻近点法求取，伪最邻近点法认为，使时间序列的伪最邻近率低于1%的嵌入维数都是有效的。互信息法和伪最邻近点法的原理和步骤可参考李昕等相空间重构和支持向量机结合的电力负荷预测模型研究。

2. 经验模态分解

EMD原理简单、容易实现，常用于复杂信号分解处理。为了降低负荷时间序列的波动性，本文采用EMD对负荷时间序列 $x(t)$ 进行处理，具体步骤如下：

1) 找出负荷时间序列 $x(t)$ 中的所有极大值点和极小值点，其中所有极大值点和所有极小值点连接而成的曲线分别称为上包络线 $u(t)$ 和下包络线 $v(t)$ 。

2) 计算 $u(t)$ 、 $v(t)$ 的平均值 m_1 ，则有

$$m_1 = \frac{u(t) + v(t)}{2} \quad (2)$$

3) 计算 $x(t)$ 与 m_1 之间的差值函数 $h_1(t)$ ，则有

$$h_1(t) = x(t) - m_1 \quad (3)$$

4) 判定差值函数 $h_1(t)$ 是否为固有模态函数，若是，则称 $h_1(t)$ 为负荷时间序列 $x(t)$ 的第一个固有模态函数（也称IMF分量）；否则，采用相同的步骤对 $h_1(t)$ 进行分解，得到 m_{11} 和 $h_{11}(t)$ ，则有

$$h_{11}(t) = h_1(t) - m_{11} \quad (4)$$

判断 $h_{11}(t)$ 是否为固有模态函数，若仍不是固有模态函数，则一直重复分解步骤1)～步骤3)，直到 k 次分解后得到IMF分量 $h_{1k}(t)$ ，将其记为 $c_1(t)$ ，则 $c_1(t)$ 即为负荷时间序列 $x(t)$ 的第一个IMF分量。

5) 计算 $c_1(t)$ 与 $x(t)$ 的差值，获得待处理信号 $r_1(t)$ ，则有

$$r_1(t) = x(t) - c_1(t) \quad (5)$$

6) 对待处理信号 $r_1(t)$ 重复上述分解步骤，即可获得负荷时间序列 $x(t)$ 的所有IMF分量，即

$$\begin{cases} r_1(t) = x(t) - c_1(t) \\ \vdots \\ r_n(t) = r_{n-1}(t) - c_n(t) \end{cases} \quad (6)$$

7) 为了防止信号被过度分解，需要设置分解终止条件，通常根据两个连续分量的标准差 SD 进行判断，计算公式为

$$SD = \sum_{i=0}^r \frac{h_{k+1}(t) - h_k(t)}{h_{k+1}^2(t)} \quad (7)$$

通常 $SD \in [0.2, 0.3]$ ，当 SD 满足条件时即停止分解，则负荷时间序列 $x(t)$ 最终表达式为

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (8)$$

式中， $r_n(t)$ 为剩余分量。

3. 极限学习机

ELM原理如下：设训练样本为 $\{x_i, t_i | x_i \in R^n, t_i \in R^n, i=1, 2, \dots, N\}$ ，激励函数为 $g(x)$ ，则有

$$H\beta = T \quad (9)$$

$$H = \begin{bmatrix} g(w_1 x_1 + b_1) & \cdots & g(w_l x_1 + b_l) \\ \vdots & & \vdots \\ g(w_1 x_n + b_1) & \cdots & g(w_l x_n + b_l) \end{bmatrix}_{n \times l}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_l^T \end{bmatrix}_{l \times m}, T = \begin{bmatrix} t_1^T \\ t_2^T \\ \vdots \\ t_n^T \end{bmatrix}_{n \times m} \quad (10)$$

式中， n 为输入层节点数； l 为隐含层节点数； m 为输出层节点数； H 为隐含层矩阵。

由于 H 中的激励函数可以无限次微分，因此ELM的权值和偏置量无须调整，对式(9)的最小二乘范数解 $\tilde{\beta}$ 进行求解，可得

$$\|H\tilde{\beta} - T\| = \min_{\beta} \|H\beta - T\| \quad (11)$$

此时，有

$$\tilde{\beta} = H^+ T \quad (12)$$

式中， H^+ 为 H 的 Moore-Penrose 广义逆。

由ELM的学习原理可知，ELM回归就是寻找合适的 β ，从而使样本数据的预测值与实际值的误差最小。研究表明，ELM原理简单、参数少，学习过程中不易陷入局部最优，因此本文采用ELM对短期电力负荷进行预测。

相空间重构与EMD-ELM的短期电力负荷预测模型

短期电力负荷变化具有较大的随机性和波动性。为了降低负荷时间序列的波动性，采用EMD对负荷时间序列进行分解，得到若干个不同频率的IMF分量和一个剩余分量。考虑到负荷时间序列的混沌属性，对各分量分别进行相空间重构，并利用ELM对重构后的分量分别进行预测，通过累加获得负荷预测的最终结果。模型的建模步骤如

图1所示。




图1 预测模型建模步骤

1) 对负荷时间序列 $x(t)$ 进行EMD分解，得到若干个不同频率的IMF分量和一个剩余分量。

2) 对各分量分别进行相空间重构，分别采用互信息法和伪最邻近点法求取各分量相空间重构的延迟时间和嵌入维数。

3) 对相空间重构后的各分量建立ELM预测模型，其输入层神经元个数由嵌入维数确定，如某分量进行相空间重构的嵌入维数为 m ，则 t 时刻负荷 P_t 与前 m 个时刻负荷关系如下

$$P_t = f(P_{t-m}, P_{t-m+1}, \dots, P_{t-1}) \quad (13)$$

式中， $\{P_1, P_2, \dots, P_t\}$ 为某一子序列。

4) 根据各分量预测最小误差分别确定各ELM分量预测模型隐含层神经元个数，本文采用均方根误差进行判断，其计算公式为

$$\varepsilon_{\text{RMSE}} = \sqrt{\frac{1}{M} \sum_{i=1}^M (y_i - y_i^*)^2} \quad (14)$$

式中， M 为样本容量； y_i 为第 i 时刻电力负荷实际

值； y_i^* 为第 i 时刻电力负荷预测值。

5) 采用ELM模型对各分量进行预测。

6) 将各负荷分量预测值进行累加，获得负荷预测的最终结果。

算例分析

以华南某市2019年6月的负荷数据进行算例分析，具体如图2所示。负荷记录时间为30 min/次，共记录1 440个负荷数据。根据建模需要，将1 440个负荷数据分为两组：前1 392个数据作为训练集，用于模型的训练；后48个数据作为测试集，用于检验模型的预测准确度。短期负荷预测的单位是天，超短期负荷预测以小时为单位，作者建模思路为：用前29天数据训练，对第30天数据进行预测，符合短期负荷的要求。另外，目前这些数据是30 min/次的实际负荷数据。




图2 2019年6月负荷数据

从图2可以看出，负荷时间序列波动性较大，为了降低负荷时间序列的波动性，采用EMD进行分解，分解结果如图3所示。由图3可知，经过EMD分解，负荷时间序列分解得到7个不同频率的IMF分量和1个剩余分量，其中，前3个IMF分量波动较明显，可见负荷时间序列的波动主要是由前3个分量引起的。

对EMD分解得到的8个分量分别进行相空间重构，图4给出了IMF分量的互信息函数随嵌入维数的变化情况。由图4可知，IMF分量的互信息函数在延时时间为11时首次达到极小值，因此IMF分量进行相空间重构的延迟时间为11。图5给出了IMF分量的伪近邻率随嵌入维数的变化情况。由图5可知，当嵌入维数 $m \geq 5$ 时，伪近邻率小于1%，因此，IMF分量进行相空间重构的嵌入维数为5。




图3 EMD分解结果




图4 互信息函数变化图




图5 伪近邻率变化图

依照IMF分量延迟时间和嵌入维数的求解过程，采用互信息法和伪最邻近点法分别求取其他分量相空间重构的延迟时间和嵌入维数，结果见表1。

表1 各子序列相空间重构参数

分量	延迟时间/min	嵌入维数
IMF ₁	11	5
IMF ₂	16	6
IMF ₃	9	5
IMF ₄	21	7
IMF ₅	14	4
IMF ₆	18	5
IMF ₇	26	4
R ₇	6	3

根据表1中各分量嵌入维数的计算结果，可以确定8个分量进行相空间重构的嵌入维数分别为5、6、5、7、4、5、4和3，以IMF₁分量ELM预测模型为例，其输入层节点个数为5，输出层节点个数为1，采用交叉验证法确定隐含层节点个数，采用训练集数据进行训练，IMF₁分量预测模型训练集误差随隐含层节点个数的变化曲线如图6所示。从图6可以看出，隐含层节点个数为12时，训练误差最小，因此，IMF₁分量ELM预测模型各层节点组合为5-12-1。




图6 IMF1分量预测模型误差变化情况

利用同样的方法即可确定其他7个分量ELM预测模型各层节点组合。建立好所有分量预测模型后,采用各分量预测模型对测试集进行预测,然后将各分量预测结果进行累加,得到最终负荷预测值,如图7所示。由图7可知,基于相空间重构和EMD-ELM的短期电力负荷预测模型预测值与负荷实际变化情况基本一致。图8给出了本次预测的相对误差变化情况。从图8可以看出,模型预测误差波动较小,误差控制较好。




图7 最终负荷预测值




图8 预测结果的相对误差

为了对模型的预测准确度进行进一步评价,本文采用均方根误差、平均相对误差和全局最大相对误差进行综合评价,平均相对误差和全局最大相对

误差计算公式如下

$$\varepsilon_{\text{MAPE}} = \frac{1}{M} \sum_{i=1}^M \frac{|y_i - y_i^*|}{y_i} \times 100\% \quad (15)$$

$$\varepsilon_{\text{max}} = \max \left| \frac{y_i - y_i^*}{y_i} \right| \times 100\% \quad (16)$$

根据三种误差的计算公式,对测试集预测误差进行计算,具体见表2。表2中同时给出了BP神经网络和ELM对测试集数据的预测误差,对比表2中的数据可知,基于相空间重构和EMD-ELM的短期电力负荷预测模型的均方根误差、平均相对误差和全局最大相对误差分别为23.49、4.24%和9.58%,远小于BP神经网络预测模型,相比于ELM模型,均方根误差、平均相对误差和全局最大相对误差分别下降48.91%、41.4%和40.6%,误差明显下降,由此可见,基于相空间重构和EMD-ELM的短期电力负荷预测模型能够减小误差波动,提高计算准确度。

表2 不同模型预测误差对比

模型	$\varepsilon_{\text{RMSE}}$	$\varepsilon_{\text{MAPE}} (\%)$	$\varepsilon_{\text{max}} (\%)$
EMD-ELM	23.49	4.24	9.58
BP神经网络	84.38	10.25	21.24
ELM	45.98	7.24	16.13

结束语

本文以电力负荷为研究对象,采用EMD对负荷时间序列进行分解,以降低负荷时间序列的波动性,得到相对平稳且频率不同的分量,利用互信息法和伪最邻近点法分别求取各分量的延迟时间和嵌入维数,对各分量分别进行相空间重构,并采用ELM对各分量分别进行预测,建立了基于相空间重构和EMD-ELM的短期电力负荷预测模型,采用实际负荷数据验证了模型的正确性和实用性。EA

(收稿日期: 2021-10-09)

声明

《电气时代》杂志唯一投稿渠道

登录电气时代官网 www.eage.com.cn, 点击“我要投稿”

咨询电话: 010 - 68993981