

DOI: 10.19783/j.cnki.pspc.210665

基于改进型自适应白噪声完备集成经验模态分解的 工业用户负荷预测方法

杨德州¹, 刘嘉明², 宋汶秦¹, 杨昌海¹, 妥建军¹, 王飞²

(1. 国网甘肃省电力公司经济技术研究院, 甘肃 兰州 730050; 2. 华北电力大学, 河北 保定 071003)

摘要: 工业用户的负荷通常由多种负荷类型共同组成, 结构较为复杂, 并且常常含有较大的冲击性负荷。传统的负荷预测方法难以准确预测负荷突变, 导致预测精度不高。将负荷分解成不同频率的分量再分别进行预测是较为可行的解决方式。提出了基于改进型自适应白噪声完备集成经验模态分解的工业用户负荷预测方法。首先, 采用ICEEMDAN算法将工业用户的负荷分解为高、低频模态分量。该算法利用局部均值来替换模态的估计, 避免了高斯噪声对模态分解的影响, 改善了传统模态分解方法中模态混叠的现象。其次, 采用长短期记忆神经网络、最小二乘支持向量回归算法分别建立高、低频分量的预测模型。最后, 将各分量的预测结果进行叠加重构, 得到了最终的预测结果。相比于单一预测方法、其他组合预测方法等多种预测方法, 所提方法的平均绝对百分比误差分别降低了26.35%, 12.75%, 具有最高的预测精度。

关键词: 工业用户; 负荷预测; ICEEMDAN算法; 模态分解

A load forecasting method for industrial customers based on the ICEEMDAN algorithm

YANG Dezhou¹, LIU Jiaming², SONG Wenqin¹, YANG Changhai¹, TUO Jianjun¹, WANG Fei²

(1. Economic and Technological Research Institute of Gansu Electric Power Company, Lanzhou 730050, China;
2. North China Electric Power University, Baoding 071003, China)

Abstract: The load of industrial customers usually contains various types. This leads to a complicated load structure and an inevitable composition of large impact loads. Traditional load forecasting methods find it difficult to accurately forecast these sudden changes in load patterns, resulting in low forecast accuracy. To improve load forecasting, an improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN) based method is proposed for industrial customers. It decomposes the load of industrial customers into different components in terms of frequencies and forecasts them separately. First, the ICEEMDAN algorithm decomposes the load into high and low-frequency modal components. The local mean is introduced to replace the modal estimation. This avoids the influence of Gaussian noise on modal decomposition, and improves on mode mixing in the traditional modal decomposition method. Secondly, long short-term memory (LSTM) and least squares support vector regression (LSSVR) algorithms are adopted to establish the forecasting models of high and low-frequency modes. Finally, the forecasting results of each component are superimposed and reconstructed to obtain the final load forecasting. Compared with multiple traditional methods such as the single forecasting and other combined forecasting methods, the mean absolute percentage error (MAPE) of the proposed method is decreased by 26.35% and 12.75% respectively, thus it has the highest forecast accuracy among them.

This work is supported by the Science and Technology Project of State Grid Corporation of China (No. 522730191002).

Key words: industrial customers; load forecasting; ICEEMDAN algorithm; modal decomposition

0 引言

工业用户作为城市用电的主体, 具有用电量、资源可调节空间大的特点^[1-4]。对工业用户的负荷进行准确的预测, 不仅可以优化自身的用电行为, 还

可以深度挖掘其内在的需求响应潜力, 以获得更多的可调节资源^[5-9]。精准的负荷预测作为工业用户能量管理系统的重要组成部分, 能够为工业用户的生产运行、优化管理、规划建设等各个环节提供重要的决策支撑。随着电力市场化改革的深入, 大型工业用户可参与电力市场交易, 精准的负荷预测将为工业用户在电力市场中的投标决策提供技术支撑,

基金项目: 国家电网公司科技项目资助(522730191002)

从而保障工业用户参与电力市场交易的经济性。然而由于冲击性负荷的存在, 常常会导致负荷曲线的突变, 直接对工业用户进行负荷预测难以获得较高的预测精度。目前国内外学者对于负荷预测的研究已经比较深入^[10-12], 当前的预测方法主要分为三类: 第一类是基于传统统计模型的预测方法, 例如时间序列法、线性回归法和指数平滑法等^[13]。该类预测方法原理简单, 模型搭建方便, 计算简洁, 具有较快的预测速度, 但由于该类统计模型考虑因素较少, 对于随机性较大和复杂的非线性系统, 难以获得较高的预测精度。第二类是基于机器学习的预测方法, 例如支持向量机、神经网络算法等^[14-15]。该类方法能够深度挖掘数据之间的相关关系, 对于一些复杂的系统也具有较强的鲁棒性, 但该方法对于数据的质量和数量的依赖程度较高。文献[2]提出了基于长短期记忆深度学习模型的工业负荷短期预测方法, 该方法原理简便, 所需计算时间短, 但该方法对于波动较大的负荷数据不具有适用性。在现实条件下由于干扰或其他因素, 往往会出现传输信号中断, 电气设备未校准等问题, 所以获得的数据质量较差, 对于第二类预测方法, 会产生收敛到局部最小点、超参数确定难、计算速度慢等问题, 导致难以获得较高的预测精度。由于上述两类方法存在的问题, 组合预测方法在近些年得到广泛关注^[16], 包括多种预测方法进行加权处理或通过数据处理再进行预测的组合方法。文献[17]利用聚类的方法将工业负荷数据进行聚类分析, 能够更好地对数据进行挖掘, 但对于负荷波动较为频繁的工业用户, 会产生多个聚类中心, 对于预测的精度影响较大。由于负荷的波动性对于负荷预测的结果有较大影响, “分解-预测-重构”的组合方法逐渐被应用了起来, 首先将负荷分解为多个波动较为平稳的模式分量, 即本征模式函数(Intrinsic Mode Function, IMF), 然后分别对多个模式分量进行预测, 最后将多个预测结果进行叠加重构, 得到最终的预测结果。常见的负荷模式分解方法包括经验模式分解(Empirical Mode Decomposition, EMD), 集合经验模式分解(Ensemble Empirical Mode Decomposition, EEMD), 添加互补白噪声的互补集合经验模式分解(Complementary Ensemble Empirical Mode Decomposition, CEEMD)和(Complete Ensemble Empirical Mode Decomposition With Adaptive Noise, CEEMDAN), 文献[18]利用EMD方法将电力负荷数据分解为有限个IMF和一个残余分量(Res), 然后建立不同分量的LSTM预测模型, 并利用层标准化(Layer Normalization, LN)对模型进行优化, 最后对各分量预测值进行叠加重构。

EMD方法解决了小波变换需要预先设定小波基和分解层数的问题, 根据数据本身自适应产生, 但在EMD分解的过程中会出现模式混叠现象, 对分量进行预测时, 由于分量中频率不一, 会影响模式分量的预测效果。EEMD在此基础上进行了改进, 通过添加辅助的白噪声消除了时间序列的间歇现象, 解决了模式混叠问题。但添加的白噪声难以完全消除, 对模式的分解有较大影响^[19]。在此方法基础上, CEEMDAN算法被提出。文献[20]首先利用CEEMDAN算法将负荷数据分解为不同频率的IMF分量和残余分量, 然后针对不同分量分别建立基于量子粒子群算法优化的支持向量机(Support Vector Machine, SVM)预测模型, 最后将各部分结果进行组合, 得到最终的预测结果。CEEMDAN方法通过添加自适应的高斯白噪声, 有效解决了分解效率较低的问题, 同时通过添加自适应的白噪声来提取模式分量, 减小了进行分解时噪声的影响。但白噪声仍然对模式分解有一定的影响。文献[21]提出了ICEEMDAN算法, 该算法用局部均值的估计替换模式的估计, 并且不直接使用白噪声, 而是使用信号的局部均值来提取 k 阶模式, 最大程度降低了白噪声对模式分解产生的影响。LSTM算法作为非线性模型, 可作为复杂的非线性单元用于构造更大型深度神经网络, 从而学习到更加深层的规律, 适用于高频分量预测。SVR算法适用于小样本数据集的训练和预测, LSSVR算法在此基础上进行了改进, 可以在小样本数据集下训练得到较小误差的回归模型, 适合低频分量的预测。

基于此, 本文提出了基于改进型自适应白噪声完备集成经验模式分解(ICEEMDAN)的工业用户负荷预测方法。首先采用ICEEMDAN算法对工业负荷数据进行分解, 将含有冲击性负荷的数据分解为不同的模式分量及残余分量, 根据过零率的大小, 将不同的分量分为高、低频分量。然后针对高、低频分别建立LSTM、LSSVR预测模型, 最后将各分量的预测结果进行叠加重构, 得到最终的工业用户负荷预测结果。

1 基于改进型自适应白噪声完备集成经验模式分解的工业用户负荷预测方法

1.1 ICEEMDAN算法

1) CEEMDAN算法

CEEMDAN算法以EMD算法为基础, 并进行了改进, 通过在每个阶段添加自适应高斯白噪声来抑制重构误差, 并且可以克服EMD算法存在的模

态混叠现象。

定义 IMF_k 和 IMF'_k 分别为使用 EMD 和 CEEMDAN 算法分解的第 k 个模态分量; $E_k(\cdot)$ 为使用 EMD 算法产生第 k 个模态分量的算子; $W_i(t)$ 为第 i 次加入的高斯白噪声, 均值为 0, 方差为 1; t 为时间变量; ε_{k-1} 为求解第 k 个模态分量 IMF'_k 时产生的自适应系数。则 CEEMDAN 算法具体的实现过程如下。

(1) 将噪声分量 $\varepsilon_{k-1}W_i(t), (i=1,2,\dots,n)$ 加入到原始信号 $X(t)$ 中, n 为加入高斯白噪声的次数。则经过 CEEMDAN 分解产生的一阶模态分量为

$$IMF'_1(t) = \frac{1}{n} \sum_{i=1}^n IMF_{i1}(t), \quad i=1,2,\dots,n \quad (1)$$

式中, $IMF_{i1}(t)$ 为加入第 i 次高斯白噪声后经过 EMD 算法分解产生的一阶模态分量。

(2) 经过 CEEMDAN 分解产生的第一个余量信号 $r_1(t)$ 为

$$r_1(t) = X(t) - IMF'_1(t) \quad (2)$$

(3) 向余量信号 $r_1(t)$ 中加入高斯噪声分量 $\varepsilon_1 E_1 W_i(t)$, 然后通过 EMD 算法进行二阶模态分量的求解, 如式(3)。

$$IMF'_2(t) = \frac{1}{n} \sum_{i=1}^n E_1(r_1(t) + \varepsilon_1 E_1 W_i(t)) \quad (3)$$

(4) 重复上述步骤(2)和(3), 则第 j 个余量信号和第 $j+1$ 阶模态分量可以分别表示为

$$r_j(t) = r_{j-1}(t) - IMF'_j(t) \quad (4)$$

$$IMF'_{j+1}(t) = \frac{1}{n} \sum_{i=1}^n E_j(r_j(t) + \varepsilon_j E_j W_i(t)) \quad (5)$$

(5) CEEMDAN 算法的结束条件为求解出的余量信号 $r_j(t)$ 无法再进行 EMD 分解。假设原始信号 $X(t)$ 共分解出 J 阶模态分量, 则最终余量信号 $R(t)$ 可以表示为

$$R(t) = X(t) - \sum_{j=1}^J IMF'_j(t) \quad (6)$$

2) ICEEMDAN 算法

CEEMDAN 算法通过添加自适应高斯白噪声的方式来降低噪声的影响, 但各分量中仍有部分噪声, 并且各分量中会存在伪模式。所以在此基础上, ICEEMDAN 算法不直接使用高斯噪声, 而是使用信号的均值来提取 k 阶模态, 最大程度降低了白噪声对模态分解产生的影响。

定义操作符 $M(\cdot)$ 表示信号的局部均值; $\langle \cdot \rangle$ 表示取均值。

(1) 构造 $X_i(t) = X(t) + \varepsilon_0 E_1(W_i(t))$, 通过 EMD 算法计算第一余量信号为

$$r_1(t) = \langle MX_i(t) \rangle \quad (7)$$

(2) 计算一阶模态分量, 可以表示为

$$IMF''_1(t) = X(t) - r_1(t) \quad (8)$$

(3) 将第二余量信号估计为一系列 $r_1(t) + \varepsilon_1 E_2 W_i(t)$ 的均值, 所以二阶模态分量可以表示为

$$IMF''_2(t) = r_1(t) - r_2(t) = r_1(t) - \langle M(r_1(t) + \varepsilon_1 E_2 W_i(t)) \rangle \quad (9)$$

(4) 重复上述步骤(2)和(3), 则第 j 个余量信号和第 j 阶模态分量可以分别表示为

$$r_j(t) = \langle M(r_{j-1}(t) + \varepsilon_{j-1} E_j W_i(t)) \rangle \quad (10)$$

$$IMF''_j(t) = r_{j-1}(t) - r_j(t) \quad (11)$$

针对某地区的工业负荷数据, 采用 ICEEMDAN 算法进行模态分解, 如图 1 所示。

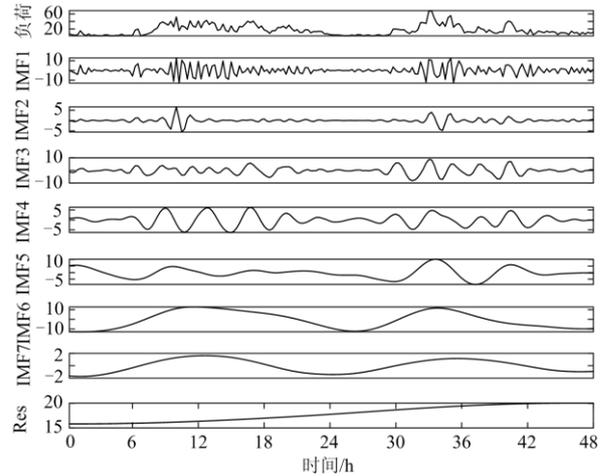


图 1 ICEEMDAN 分解结果

Fig. 1 Decomposition results of ICEEMDAN

本文根据过零率的大小区分高、低频分量, 过零率的计算公式如式(12)所示。

$$P_{\text{zero}} = \frac{Z_{\text{zero}}}{Z_{\text{all}}} \quad (12)$$

式中: Z_{zero} 为序列中过零点的个数; Z_{all} 为序列的长度; P_{zero} 为过零点的概率, P_{zero} 的值越大, 表示频率越高, 反之表示频率越低。

将不同的分量分为高、低频分量后, 分别对高频分量建立 LSTM 预测模型, 对低频分量建立 LSSVR 预测模型, 来获得不同分量的预测结果。

1.2 LSTM 算法

LSTM 算法改善了传统 RNN 中存在的长期依

赖问题, 并且作为非线性模型, LSTM 可作为复杂的非线性单元用于构造更大型深度神经网络, 对处理模式分解后的高频分量具有较好的适用性^[22-23]。LSTM 神经网络的基本结构如图 2 所示。

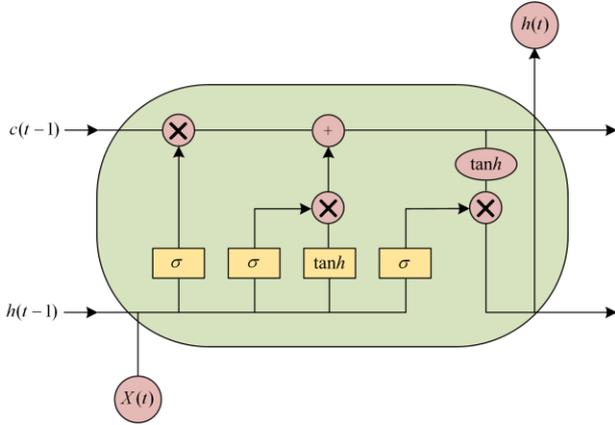


图 2 LSTM 示意图

Fig. 2 Schematic diagram of the LSTM method

LSTM 神经网络的显著特点是使用了输入门 i 、遗忘门 f 和输出门 o 来构成控制模式, 该模式有利于对高维序列上的信息适当遗弃, 进行选择性的记忆, 满足了预测过程的计算速度, 同时保证了预测的精度。

1.3 LSSVR 算法

LSSVR 算法将二次规划问题转变为线性方程组的求解问题, 大大改善了计算的复杂性。并且 LSSVR 算法可以在有限的数据集下进行训练, 并可以得到较小的训练误差^[24-25]。对于给定一组样本集 $\{x_i, y_i\}_{i=1}^m$, 其中: x_i 为输入向量, $x_i \in R^n$; y_i 为输出, $y_i \in R$; m 为样本容量。LSSVR 通过一个非线性函数 ϕ 将样本数据从原始特征空间映射到高维的特征空间, 此时回归函数可以表示为

$$f(x) = w \cdot \phi(x) + b \quad (13)$$

式中: w 为权重矩阵; b 为偏差值。

根据风险最小化原则, LSSVR 算法的优化目标函数可以表示为

$$\begin{cases} \min J(w, e) = \frac{1}{2} \|w\|^2 + \frac{1}{2} C \sum_{i=1}^m e_i^2 \\ \text{s.t. } y_i = w \cdot \phi(x) + b + e_i, i = 1, 2, \dots, m \end{cases} \quad (14)$$

式中: e_i 为样本误差; C 为惩罚函数, $C > 0$ 。定义 α 为拉格朗日乘子, 构造拉格朗日函数, 并利用 KKT 条件进行求解, 即可求出相关参数, 则 LSSVR 的回归函数为

$$\begin{cases} f(x) = \sum_{i=1}^m \alpha_i K(x_i, y_j) + b \\ K(x, x_i) = \exp\left\{-\frac{\|x - x_i\|^2}{2\sigma^2}\right\} \end{cases} \quad (15)$$

式中: K 为核函数; σ 为核函数宽度。本文采用径向基函数(RBF)作为核函数。

1.4 本文流程图

本文所研究方法的流程图如图 3 所示。

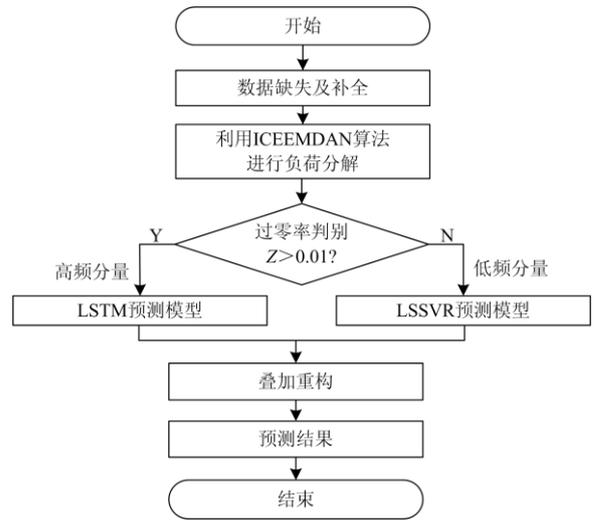


图 3 本文流程图

Fig. 3 Flow chart of this paper

2 算例分析

2.1 数据来源

本文针对西北地区某药厂的负荷数据进行实测分析, 采集时间为 2019 年 12 月 27 日—2020 年 1 月 19 日, 采样间隔为 15 min, 共 2 270 个有功功率数据。在进行仿真前, 本文已经对该组数据进行了处理, 去除了偏差较大的数据并对缺失值进行了补全。该药厂的负荷曲线如图 4 所示。

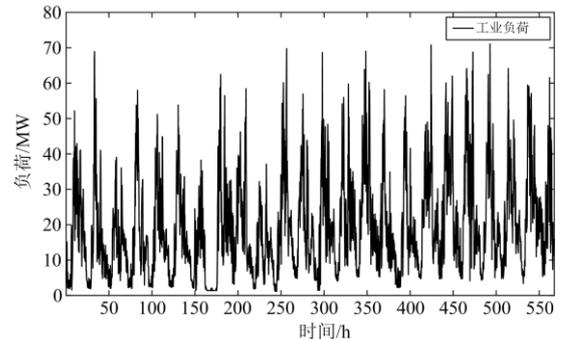


图 4 某工业用户的负荷曲线

Fig. 4 Load curve of an industrial customer

由图 4 可以看出, 该工业负荷数据中含有较多的冲击性负荷, 并且峰谷差较大、波动较为剧烈, 如果对该负荷进行直接预测, 会导致预测效果不佳, 所以应采用分解-预测-重构的方式对该工业负荷进行预测。

2.2 模态分解

该负荷曲线经 ICEEMDAN 算法分解后的模态分量(IMF)和残余分量(Res)如图 5 所示, 其中负荷为预处理后的负荷曲线, IMF1—IMF9 为分解的模态分量, Res 为该负荷的残余分量。

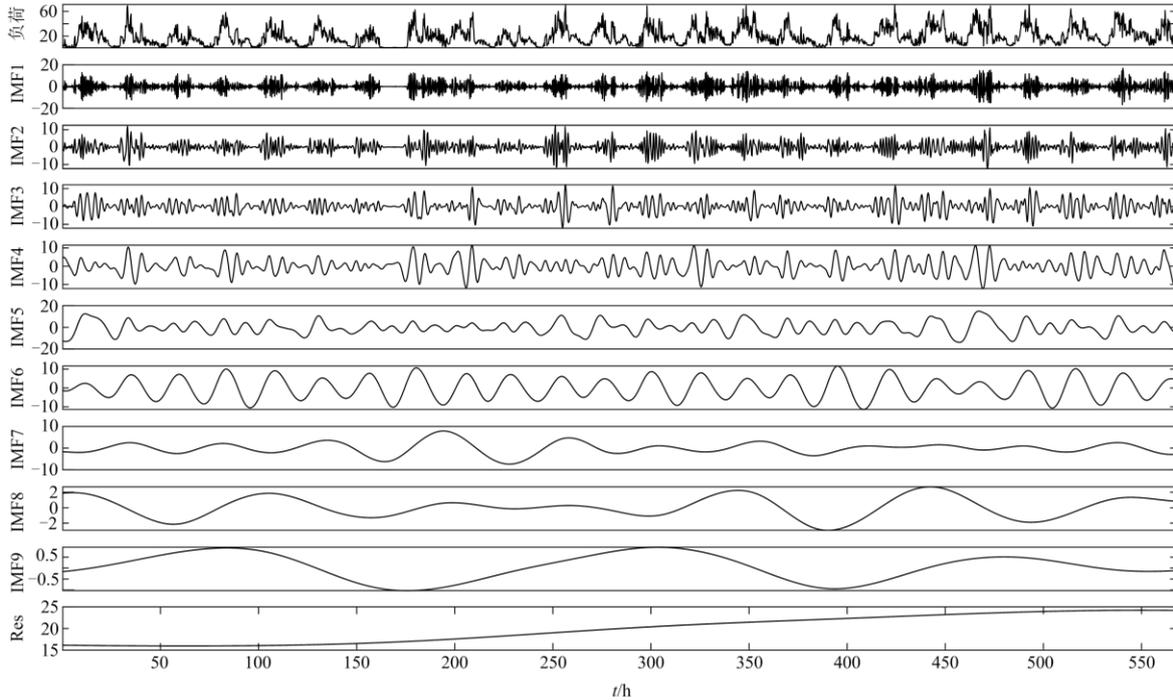


图 5 经过模态分解后得到的分量

Fig. 5 Decomposition results of industrial load using ICEEMDAN

由图 5 可以看出, 经过 ICEEMDAN 算法分解后的分量中, 并没有明显的模态混叠现象, 同一分量的频率相对稳定。对各分量进行过零率的计算, 将不同分量的过零率用柱状图表示, 如图 6 所示。

量^[13]。所以由图 6 可以看出, 在该负荷曲线进行分解时, 产生的 IMF1—IMF6 为高频分量, IMF7—IMF9 及 Res 为低频分量。

2.3 分量预测

根据高、低频分量分别建立 LSTM、LSSVR 预测模型, 进行各分量的预测, 通过叠加重构的方式获得最终的预测结果。为进一步验证本文所提方法的有效性, 将本文所提方法仿真结果与其他预测模型的预测结果进行对比。在进行仿真实验时, 本文对所有模型都进行了调参。图 7 和图 8 分别展示了部分高、低频分量的预测结果, 由于高频分量波动较大, 无法直观展示预测效果的好坏, 故图 7 采用整体与局部相结合的展示方法。

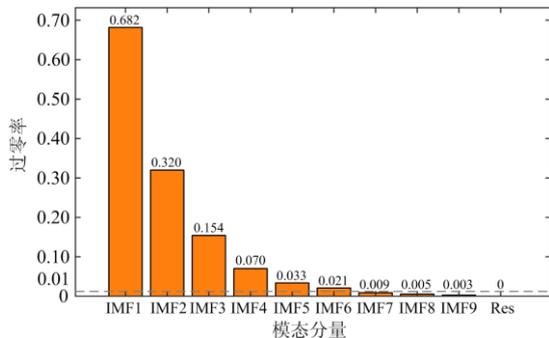


图 6 不同分量的过零率

Fig. 6 Zero crossing rate of different components

本文根据不同分量过零率的大小, 来区分高、低频分量。设定阈值 0.01, 若过零率大于 0.01, 则认为该分量为高频分量, 否则认为该分量为低频分

由图 7、图 8 可以看出, 针对高、低频分量, 本文采用的 LSTM、LSSVR 预测方法分别在高、低频分量下具有较高的预测精度。本文利用 MAE、RMSE 和 MAPE 误差评价指标对预测精度进行评价, IMF3 与 IMF7 模态分量的误差情况如表 1 所示。

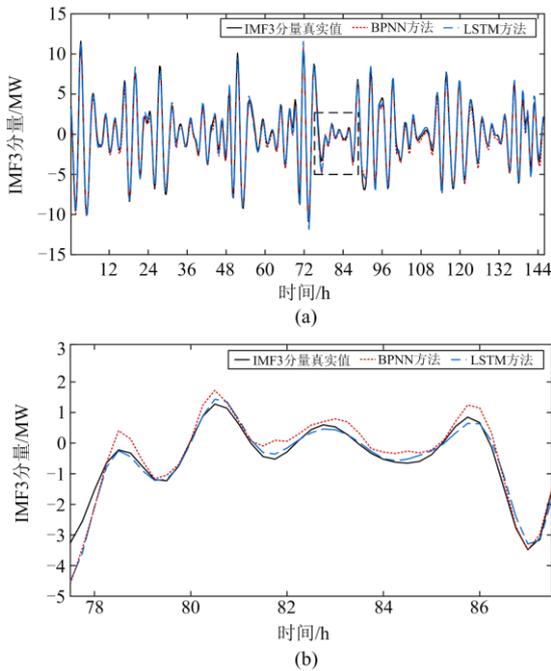


图 7 高频 IMF 分量的预测结果

Fig. 7 Forecast results of high frequency IMF component

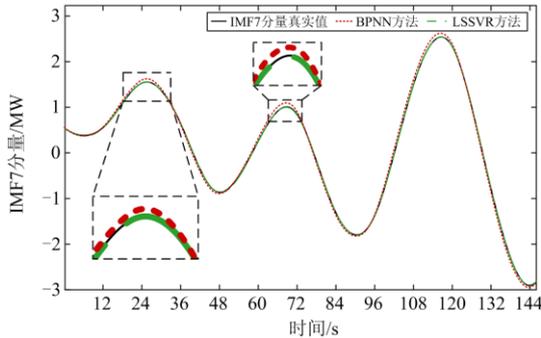


图 8 低频 IMF 分量的预测结果

Fig. 8 Forecast results of low frequency IMF component

表 1 高、低 IMF 分量预测结果对比

Table 1 Comparison of high and low IMF component forecast results

分量	IMF3		IMF7	
	BPNN	LSTM	BPNN	LSSVR
MAE/MW	0.373 1	0.354 2	0.013 4	0.007 0
RMSE/MW	0.498 6	0.470 4	0.018 5	0.008 9
MAPE/%	139.858 8	79.590 1	3.601 6	1.784 4

2.4 叠加重构

通过对高、低频分量的预测并进行叠加重构,可以得到最终工业用户的负荷预测结果,将本文所提方法的预测结果与其他预测方法进行对比,如图 9 和图 10 所示。

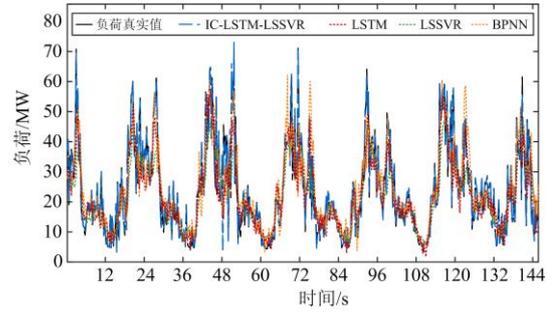


图 9 单一预测模型结果对比

Fig. 9 Comparison of single forecasting model results

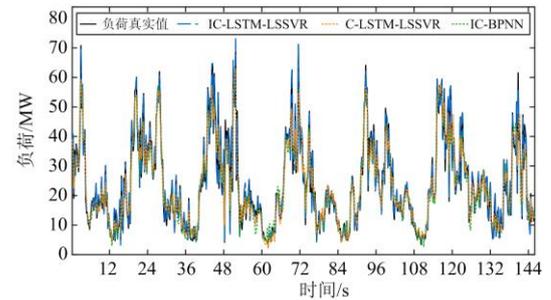


图 10 组合预测模型结果对比

Fig. 10 Comparison of combined forecasting model results

其中 LSTM、LSSVR 和 BPNN 分别表示单独使用 LSTM、LSSVR 和 BPNN 方法得到的预测结果; C- LSTM-LSSVR 表示使用 CEEMDAN 算法进行模式分解,利用 LSTM、LSSVR 算法分别对高、低频模态分量进行预测并进行重构后得到的预测结果。IC-BPNN 表示使用 ICEEMDAN 算法进行模式分解,再利用 BPNN 预测算法对模态分量进行预测并进行重构后得到的预测结果; IC-LSTM-LSSVR 表示使用模式分解算法,利用 LSTM、LSSVR 预测算法分别对高、低频模态分量进行预测并进行重构后得到的预测结果,此方法即为本文所提方法。

由图 9 和图 10 可以看出,本文所提方法与真实值更为接近,并且采用 ICEEMDAN 算法分解相比采用其他分解算法的预测效果更好,从而也印证了 ICEEMDAN 算法对于工业用户负荷分解的有效性。表 2 反映了各预测方法在不同指标下的预测精度。

由表 2 可以看出:对于工业负荷而言,由于其负荷模式波动较为剧烈,并且存在较多的冲击性负荷,使用单一预测模型的精度较低,预测误差较大,三种单一方法最小的平均绝对百分误差(MAPE)为 31.73%;对于一些冲击性负荷不能很好地预测。使用 CEEMDAN 算法进行模式分解后的预测模型相比单一模型的预测精度有所提升,MAPE 的值为

表 2 不同方法的预测结果

Table 2 Forecasting results of different methods

预测方法	BPNN	LSSVR	LSTM	C-LSTM-LSSVR	IC-BPNN	IC-LSTM-LSSVR
MAE/MW	6.253 9	6.305 5	6.181 2	3.613 7	3.011 9	1.012 8
RMSE/MW	8.582 3	8.931 5	8.567 2	4.842 8	4.254 8	1.420 1
MAPE/%	32.561 5	31.734 0	31.978 4	18.127 0	14.867 8	5.380 4

18.13%；采用本文所提出的改进型自适应白噪声完备集成经验模态分解(ICEEMDAN)的组合预测模型对于工业用户的负荷预测具有最高的预测精度，MAPE 的值为 5.38%，预测误差下降较为明显，与原负荷数据较为接近，对于由于冲击性负荷导致的负荷突变也有较好的跟随效果；不同误差指标大小情况也验证了本文所提方法的有效性。

3 结论

鉴于工业用户负荷预测的重要性，本文提出了基于改进型自适应白噪声完备集成经验模态分解(ICEEMDAN)的工业用户负荷预测方法。首先利用 ICEEMDAN 算法对负荷数据进行模态分解，该方法克服了传统模态分解算法的模态混叠现象和白噪声对模态分解的影响。其次结合 LSTM 和 LSSVR 算法对高、低频分量预测的优势，对 ICEEMDAN 算法分解产生的高、低频分量进行预测，获得不同分量的预测结果。最后将各分量的预测结果进行叠加重构，得到最终的工业用户的负荷预测结果。仿真结果表明，本文所提出的方法在对工业负荷进行预测时，具有较高的预测精度，同时对于含有冲击性负荷的预测也具有较强的鲁棒性。

参考文献

- [1] WANG Y Y, KONG Y, TANG X F, et al. Short-term industrial load forecasting based on ensemble hidden Markov model[J]. IEEE Access, 2020, 8: 160858-160870.
- [2] 杨甲甲, 刘国龙, 赵俊华, 等. 采用长短期记忆深度学习模型的工业负荷短期预测方法[J]. 电力建设, 2018, 39(10): 20-27.
YANG Jiajia, LIU Guolong, ZHAO Junhua, et al. A long short term memory based deep learning method for industrial load forecasting[J]. Electric Power Construction, 2018, 39(10): 20-27.
- [3] LI K P, CAO X, GE X X, et al. Meta-heuristic optimization based two-stage residential load pattern clustering approach considering intra-cluster compactness and inter-cluster separation[J]. IEEE Transactions on Industry Applications, 2020, 56(4): 3375-3384.
- [4] WANG Y Y, SUN S F, CHEN X Q, et al. Short-term load forecasting of industrial customers based on SVM and XGBoost[J]. International Journal of Electrical Power & Energy Systems, 2021, 129.
- [5] WANG F, XIANG B, LI K P, et al. Smart households' aggregated capacity forecasting for load aggregators under incentive-based demand response programs[J]. IEEE Transactions on Industry Applications, 2020, 56(2): 1086-1097.
- [6] LI K P, WANG F, MI Z Q, et al. Capacity and output power estimation approach of individual behind-the-meter distributed photovoltaic system for demand response baseline estimation[J]. Applied Energy, 2019, 253.
- [7] LU X X, LI K P, XU H C, et al. Fundamentals and business model for resource aggregator of demand response in electricity markets[J]. Energy, 2020, 204.
- [8] 黄剑平, 陈皓勇, 林镇佳, 等. 需求侧响应背景下分时电价研究与实践综述[J]. 电力系统保护与控制, 2021, 49(9): 178-187.
HUANG Jianping, CHEN Haoyong, LIN Zhenjia, et al. A summary of time-of-use research and practice in a demand response environment[J]. Power System Protection and Control, 2021, 49(9): 178-187.
- [9] 薛风华, 冯小宇, 仲寅峰, 等. 增量配电网多主体投资收益分配 Shapley 模型研究[J]. 智慧电力, 2020, 48(1): 80-84, 96.
XUE Fenghua, FENG Xiaoyu, ZHONG Yinfeng, et al. Research on Shapley model of multi-agent investment income distribution in incremental distribution network[J]. Smart Power, 2020, 48(1): 80-84, 96.
- [10] 康重庆, 夏清, 张伯明. 电力系统负荷预测研究综述与发展方向的探讨[J]. 电力系统自动化, 2004, 28(17): 1-11.
KANG Chongqing, XIA Qing, ZHANG Boming. Review of power system load forecasting and its development[J]. Automation of Electric Power Systems, 2004, 28(17): 1-11.
- [11] TAN M, YUAN S P, LI S H, et al. Ultra-short-term industrial power demand forecasting using LSTM based hybrid ensemble learning[J]. IEEE Transactions on Power Systems, 2020, 35(4): 2937-2948.

- [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] 邓带雨, 李坚, 张真源, 等. 基于 EEMD-GRU-MLR 的短期电力负荷预测[J]. 电网技术, 2020, 44(2): 593-602.
DENG Daiyu, LI Jian, ZHANG Zhenyuan, et al. Short-term electric load forecasting based on EEMD-GRU-MLR[J]. Power System Technology, 2020, 44(2): 593-602.
- [14] 祝学昌. 基于 IFOA-GRNN 的短期电力负荷预测方法研究[J]. 电力系统保护与控制, 2020, 48(9): 121-127.
ZHU Xuechang. Research on short-term power load forecasting method based on IFOA-GRNN[J]. Power System Protection and Control, 2020, 48(9): 121-127.
- [15] 宋建, 束洪春, 董俊, 等. 基于 GM(1,1) 与 BP 神经网络的综合负荷预测[J]. 电力建设, 2020, 41(5): 75-80.
SONG Jian, SHU Hongchun, DONG Jun, et al. Comprehensive load forecast based on GM(1,1) and BP neural network[J]. Electric Power Construction, 2020, 41(5): 75-80.
- [16] 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.
- [17] 李钢, 杜欣慧, 裴玥瑶, 等. 基于改进密度峰值聚类的超短期工业负荷预测[J]. 电测与仪表, 2021, 58(5): 159-163.
LI Gang, DU Xinhui, PEI Yueyao, et al. Ultra-short term industrial load prediction based on improved density peak clustering[J]. Electrical Measurement & Instrumentation, 2021, 58(5): 159-163.
- [18] 魏鹭, 茅大钧, 韩万里, 等. 基于 EMD 和长短期记忆网络的短期电力负荷预测研究[J]. 热能动力工程, 2020, 35(4): 203-209.
WEI Ao, MAO Dajun, HAN Wanli, et al. Short-term load forecasting based on EMD and long short-term memory neural networks[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(4): 203-209.
- [19] 王新, 孟玲玲. 基于 EEMD-LSSVM 的超短期负荷预测[J]. 电力系统保护与控制, 2015, 43(1): 61-66.
WANG Xin, MENG Lingling. Ultra-short-term load forecasting based on EEMD-LSSVM[J]. Power System Protection and Control, 2015, 43(1): 61-66.
- [20] 贾逸伦, 龚庆武, 李俊雄, 等. 基于 CEEMDAN 与量子粒子支持向量机的电力负荷组合预测[J]. 电测与仪表, 2017, 54(1): 16-21.
JIA Yilun, GONG Qingwu, LI Junxiong, et al. The power load combined forecasting based on CEEMDAN and QPSO-SVM[J]. Electrical Measurement & Instrumentation, 2017, 54(1): 16-21.
- [21] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E. Improved complete ensemble EMD: a suitable tool for biomedical signal processing[J]. Biomed Signal Process Control, 2014, 14(1): 19-29.
- [22] 王飞, 李正辉, 李渝, 等. 基于数据序列分辨率压缩尺度优化的月度电量预测方法[J]. 电力系统保护与控制, 2020, 48(11): 62-68.
WANG Fei, LI Zhenghui, LI Yu, et al. Data series resolution compression scale optimization based monthly electricity consumption forecasting[J]. Power System Protection and Control, 2020, 48(11): 62-68.
- [23] ZHEN Z, LIU J M, ZHANG Z Y, et al. Deep learning based surface irradiance mapping model for solar PV power forecasting using sky image[J]. IEEE Transactions on Industry Applications, 2020, 56(4): 3385-3396.
- [24] 唐杰明, 刘俊勇, 杨可, 等. 基于灰色模型和最小二乘支持向量机的电力短期负荷组合预测[J]. 电网技术, 2009, 33(3): 63-68.
TANG Jieming, LIU Junyong, YANG Ke, et al. Short-term load combination forecasting by grey model and least square support vector machine[J]. Power System Technology, 2009, 33(3): 63-68.
- [25] 刘小雍, 方华京, 张南庆, 等. 泛化性能的最优上边界回归模型辨识[J]. 信阳师范学院学报(自然科学版), 2020, 33(3): 454-461.
LIU Xiaoyong, FANG Huajing, ZHANG Nanqing, et al. Optimal upper boundary regression model identification with generalization performance-guaranteed[J]. Journal of Xinyang Normal University (Natural Science Edition), 2020, 33(3): 454-461.

收稿日期: 2021-06-04; 修回日期: 2021-08-26

作者简介:

杨德州(1968—), 男, 高级工程师, 主要研究方向为电网规划技术; E-mail: 807095067@qq.com

王飞(1973—), 男, 通信作者, 工学博士, 教授, 博导, 主要研究方向为新能源功率预测、综合能源与能源互联网、电力市场与需求响应。E-mail: feiwang@ncepu.edu.cn

(编辑 周金梅)