

DOI: 10.19783/j.cnki.pspc.210313

# 基于优化的 VMD-mRMR-LSTM 模型的短期负荷预测

胡威<sup>1,2</sup>, 张新燕<sup>1</sup>, 李振恩<sup>1</sup>, 李青<sup>1</sup>, 王衡<sup>1</sup>

(1. 新疆大学, 新疆 乌鲁木齐 830047; 2. 新疆理工学院, 新疆 阿克苏 843000)

**摘要:** 随着智能电网技术的发展和电力市场的推进, 用电模式的复杂性逐渐凸显, 对短期负荷预测的精度和稳定性提出了更高的要求。针对传统负荷预测方法缺少对时序数据相关性、特征值的全面考虑等问题, 提出一种基于优化的变分模态分解、最小冗余最大相关性 with 长短期记忆神经网络的组合预测模型。首先, 将波动性高的负荷序列分解为一组相对平稳的模态分量, 其中利用麻雀智能算法优化 VMD 的关键参量。其次, 利用 mRMR 方法分析各模态分量与预测模型输入特征元素间的相关性, 获取各预测模型的最优输入特征集, 并在分析负荷影响因子中考虑实时电价。最后, 采用不同结构参数的 LSTM 方法对各分量分别预测, 将预测结果叠加得到最终的预测值。以澳大利亚的实际运行数据做算例分析, 与常规负荷预测方法进行对比, 验证了该方法的有效性。

**关键词:** 负荷预测; 变分模态分解; 最小冗余最大相关性; 长短期记忆神经网络; 实时电价

## Short-term load forecasting based on an optimized VMD-mRMR-LSTM model

HU Wei<sup>1,2</sup>, ZHANG Xinyan<sup>1</sup>, LI Zhen'en<sup>1</sup>, LI Qing<sup>1</sup>, WANG Heng<sup>1</sup>

(1. Xinjiang University, Urumqi 830047, China; 2. Xinjiang Institute of Technology, Akesu 843000, China)

**Abstract:** With the development of smart grid technology and the advance of the power market, the complexity of power consumption patterns has gradually become prominent. This then makes higher demands on the accuracy and stability of short-term load forecasting. Given the lack of comprehensive consideration of time series data correlation and eigenvalues in traditional load forecasting methods, a combined forecasting model based on optimization of variational mode decomposition (OVMD), minimal redundancy maximal relevance (mRMR) and a long short-term memory neural network (LSTM) is proposed. First, the load sequence with high fluctuation is decomposed into a group of relatively stable modal components, in which the parameter of VMD is optimized by a sparrow intelligent algorithm. Secondly, the mRMR method is used to analyze the correlation between each modal component and the input feature set elements of the prediction model, obtain the optimal input feature set of each prediction model, and introduce the real-time electricity price into the load impact factor analysis. Finally, the LSTM method with different structural parameters is used to predict each component separately, and the predicted results are superimposed to obtain the final predicted value. An example is given to analyze the actual operational data of Australia, and compared with the conventional load forecasting method, the validity of the method is verified.

This work is supported by the National Natural Science Foundation of China (No. 51667018 and No. 52067020).

**Key words:** load forecasting; variational mode decomposition; minimal redundancy maximal relevance; long short-term memory; real-time electricity price

## 0 引言

短期电力负荷预测是电网运行调度、生产规划

的重要组成部分, 能够帮助电力系统维持供需平衡, 确保电网安全, 同时减少资源浪费和用电成本<sup>[1]</sup>。但随着可再生分布式电源、高铁、电动汽车、储能等的大规模接入电网<sup>[2]</sup>, 以及在电力市场改革背景下基于电价、激励等需求侧管理政策的逐步实施, 使得负荷数据非线性、不稳定性特征加剧, 加大了

**基金项目:** 国家自然科学基金项目资助 (51667018, 52067020); 新疆自然科学基金项目资助 (2021D01C044)

短期负荷预测的难度。因此有必要利用新的方法与技术来提高负荷预测的精度和可靠性,以满足工程技术要求。

统计与智能预测方法是常用的负荷预测方法。统计方法主要包括时间序列分析、回归模型等<sup>[3-4]</sup>,这类方法模型简单,但非线性拟合能力差。智能方法是把各种影响负荷的外界因素与历史负荷数据作为输入量,基于各种人工智能方法进行预测,其典型代表为 BP 神经网络、支持向量机(Support Vector Machine, SVM)等<sup>[5-7]</sup>。BP 神经网络具备可调参数多、操作性好的特点,但泛化能力有限,并且易陷入局部最优<sup>[7]</sup>。SVM 能较好地解决非线性和局部最小值等问题,但处理大规模数据时预测精度低<sup>[8]</sup>。深度学习算法是对传统人工智能算法的研究拓展,由于采用了多层非线性变换,能更有效地表征电力负荷数据中的复杂关系,目前在新能源出力以及负荷预测方面已成为一个研究热点<sup>[9-10]</sup>。文献[11]提出了基于改进的深度信念网络的预测方法,考虑了日期与峰谷分时电价等因素,提高了负荷的预测精度。文献[12]提出对温度进行模糊划分,结合多隐藏层的长短时记忆神经网络模型,提高了对夏季负荷预测的精度。文献[13]讨论了实时电价与负荷的相关性,提出了计及电价的长短期记忆神经网络(Long Short-Term Memory, LSTM)短期负荷预测模型,但忽略了温湿度等因素对负荷的影响。文献[14]利用经验模态分解(Empirical Mode Decomposition, EMD)对短期负荷序列做了分解处理,用最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)做预测,但忽视了 EMD 存在的模态混叠问题,以及 LSSVM 不能有效地提取时序数据间的关联特征。文献[15-16]采用变分模态分解(Variational Mode Decomposition, VMD)技术对负荷数据进行分解,VMD 方法能有效避免模态混叠现象的发生<sup>[17]</sup>,但 VMD 参数设置繁琐,忽视了电价等因素对负荷的积极影响。同时,文献[18-19]分析了气象因素对电力负荷的影响,指出湿度因素对负荷的变化不容忽视。

基于以上研究,本文综合考虑了实时电价与湿度等多种负荷影响因素,引入麻雀算法以及能量差追踪法自适应地优化 VMD 的关键参数,通过最小冗余最大相关性(minimum Redundancy Maximum Relevance, mRMR)方法从多元负荷特征集中筛选出各分量预测模型的最优特征输入集,选用对时序数据预测较为有效的 LSTM 方法,提出了一种 OVMD-mRMR-LSTM 预测模型,并验证了本方法的可行性。

## 1 方法与理论

### 1.1 基于麻雀算法优化的变分模态分解

#### 1.1.1 变分模态分解

VMD 是一种完全非递归的模态变分方法,其将信号  $f$  分解为具有一定稀疏性质的多个模态函数  $u_k$ ,解决了 EMD 存在的模态混叠和高频信号丢失问题。 $u_k$  带宽的计算公式为

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|^2 \\ \text{s.t.} \sum_k u_k(t) = f(t) \end{cases} \quad (1)$$

式中:  $\{u_k\}$  为  $k$  个模态分量;  $\{\omega_k\}$  为各分量的频率中心。

用增广 Lagrange 函数求解式(1),得到式(2)。

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (2)$$

用交替方向乘子法(ADMM)求解式(2),可得:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)| d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

式中,  $\hat{u}_k^{n+1}(\omega)$ 、 $\omega_k^{n+1}$  分别为各分量的维纳滤波与频率中心。

#### 1.1.2 麻雀算法

麻雀搜索算法(Sparrow Search Algorithm, SSA)是薛建凯等人于 2020 年提出的仿生智能算法,它模拟了麻雀种群的觅食和反捕食行为。觅食时,整个麻雀种群划分为发现者和加入者两个比例固定的子种群。根据觅食规则,发现者通过位置更新,引导种群搜索和觅食。部分加入者选择跟随发现者获取食物,部分加入者为增加自身捕食率则选择不断监视发现者以及参与食物竞争。当麻雀种群意识到危险时,处于不同位置的麻雀会选择相应的逃避策略。SSA 算法在精度和稳定性方面的性能要优于常见的灰狼优化算法(Grey Wolf Optimization, GWO)、粒子群优化等算法(Particle Swarm Optimization, PSO)及飞蛾扑火优化算法(Moth-flame Optimization, MFO),具有较好的寻优能力<sup>[20-21]</sup>,故选用 SSA 优化 VMD。

### 1.1.3 基于 SSA 优化 VMD

采用 VMD 对信号进行分解, 需要预设模态分解数、惩罚因子、保真系数及收敛条件等参数。研究表明, VMD 的分解精度主要取决于分解数  $K$  和惩罚因子  $\alpha$ 。分解数  $K$  值设置过小, 会造成信息丢失;  $K$  值设置过大, 会导致分解过度。惩罚参数  $\alpha$  影响每个模态分量的带宽, 不同的带宽尺度影响信号的提取结果。由于实际待分解信号复杂多变, 人为设置分解数  $K$  和惩罚因子  $\alpha$  较为困难, 并且易导致分解结果的随机性<sup>[22]</sup>。为此, 本文提出利用 SSA 算法优化 VMD 的参数。

SSA 寻优 VMD 参数的适应度函数选用文献[23]提出的能量差追踪法。其基本思想是根据 VMD 方法将信号  $f(t)$  分解为  $K$  个有限带宽本征模态函数(Bandwidth Intrinsic Mode Function, BIMF)  $u_i$ , 见式(5)。

$$f(t) = u_1(t) + u_2(t) + \dots + u_k(t) = \sum_{i=1}^k u_i(t) \quad (5)$$

若 BIMF 满足正交性, 则原始信号  $f(t)$  的能量与  $K$  个分解信号的能量和(见式(6))相等。

$$E_{f1} = \int_{-\infty}^{+\infty} f^2(t) dt \quad (6)$$

$$E_{\text{BIMF}} = \int_{-\infty}^{+\infty} u_1(t) dt + \dots + \int_{-\infty}^{+\infty} u_k(t) dt \quad (7)$$

$$E_{f1} = E_{\text{BIMF}} \quad (8)$$

当信号实际分解分量不全部正交时, 则  $E_{f1}$  与  $E_{\text{BIMF}}$  之间存在能量误差  $E_{\text{err}}$ 。

$$E_{\text{err}} = |E_{f1} - E_{\text{BIMF}}| \quad (9)$$

$E_{\text{err}}$  越小, 则表明分解后的 BIMF 分量的正交性越好, 分解结果能更好地表征信号  $f(t)$  的特征。

VMD 算法的最佳参数组合  $[K, \alpha]$  的求解步骤如下:

1) 设置 SSA 算法的参数以及初始种群, 把能量误差  $E_{\text{err}}$  作为适应度函数;

2) 将信号进行 VMD 分解, 并通过式(8)可得到每只麻雀的适应度值;

3) 根据麻雀算法优化机制, 更新麻雀个体的位置, 比较各个位置对应的能量误差  $E_{\text{err}}$ , 不断更新最小适应度值;

4) 循环迭代 2)–4), 直至确定全局最小适应度值或达到最大迭代次数, 输出最佳麻雀个体  $[K, \alpha]$ ;

5) 利用最优参数  $[K, \alpha]$  对信号进行 VMD 分解。

### 1.1.4 OVMD

为验证 OVMD 分解信号的有效性, 构造了一个测试信号  $y(t)$ , 见式(10)。

$$\begin{cases} y(t) = y_1(t) + y_2(t) + y_3(t) + y_4(t) \\ y_1(t) = \cos(100\pi t) \\ y_2(t) = 1.2 \cos(200\pi t) \\ y_3(t) = 1.5 \sin(300\pi t) \end{cases} \quad (10)$$

式中:  $y_4$  为均值为 0、方差为 0.2 的 Gaussian 噪声。

SSA 种群数为 20, 迭代次数为 30, 设定  $K$  的寻优范围是 [2, 14],  $\alpha$  的搜索范围是 [0, 2 000], VMD 经过 SSA 算法寻优后的参数组合  $[K, \alpha]$  为 [4, 1243], 最小能量误差为 0.497。最优适应度值变化曲线见附图 1, SSA 算法对 VMD 参数寻优时与其他 3 种算法相比同样具有较好的寻优能力和适应性。 $y(t)$  在此参数下的 VMD 分解结果见附图 2, 用 EMD 方法与 SSA-VMD 方法对比分析, EMD 分解结果见附图 3。

由附图 2 可知, 含噪信号  $y(t)$  经 SSA-VMD 分解, 可分离出各频率信号以及噪声信号, 分量信号  $u_1$ 、 $u_2$  与  $u_3$  的幅值也与原始信号较为接近。从附图 4 可知, EMD 分解分量存在明显的频率混叠, 分解效果较差。因此本文利用 SSA-VMD 方法做后续负荷序列的分解。

### 1.2 最小冗余最大相关性

多个特征间的相关性和冗余性会降低预测的准确率, 因此需要筛选和优化特征集合。mRMR 是一种依靠互信息反映特征间相关性和冗余性的方法。

将  $x$ 、 $y$  的概率密度与联合概率密度分别定义为  $p(x)$ 、 $p(y)$ 、 $p(x, y)$ , 则  $x$  与  $y$  的互信息定义为

$$I(x, y) = \iint p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy \quad (11)$$

利用互信息可得到 mRMR 准则:

$$\max D(S, c), D = \frac{1}{|S|} \sum_{x_i \in S} I(x_i, c) \quad (12)$$

$$\min R(S), R = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i, x_j) \quad (13)$$

式中:  $S$  是特征集合;  $|S|$  是维数;  $I(x_i, c)$  是特征  $x_i$  与目标  $c$  间的互信息;  $I(x_i, x_j)$  是  $x_i$  与  $x_j$  的互信息;  $D$  与  $R$  分别为相关性与冗余性。

mRMR 算法综合考虑上述两个准则, 即

$$\max \Phi(D, R), \Phi = D - R \quad (14)$$

对于上式的求解, 采用增量搜索算法实现。从选出的  $m-1$  集合中增加第  $m$  个特征, 应满足:

$$\max_{x_j \in X - S_{m-1}} \left[ I(x_j, c) - \frac{1}{m-1} \sum_{x_i \in S_{m-1}} I(x_j, x_i) \right] \quad (15)$$

分析影响  $k$  个模态分量预测的特征因素, 初步从原始特征集  $X$  中设置特征数  $M$ , 针对每个 IMF 分量可根据式(13)依次从  $X$  中择取  $M$  个特征子  $J$ 。  $J$  中每个特征  $x_i$  的 mRMR 值不同, 若选取不同的特征组合作为预测模型输入参量, 易出现特征冗余或特征信息不足的问题, 需要进一步从  $J$  中选出最佳特征集。为了减少计算量, 本文选取各预测分量的均方根误差  $R$  作为评价各分量预测模型的输入特征数影响预测效果优劣的指标, 见式(16)所示。

$$R = \sqrt{\frac{1}{n} \sum_{i=1}^n (\alpha'_{\text{IMF}_i} - \alpha_{\text{IMF}_i})^2} \quad (16)$$

式中,  $\alpha_{\text{IMF}_i}$  与  $\alpha'_{\text{IMF}_i}$  分别为 IMF 的实际值和预测值。

### 1.3 长短期记忆神经网络

循环神经网络(Recurrent Neural Network, RNN)是一种与先前时刻输入相关联的网络<sup>[24]</sup>。

传统的 RNN 增强了对时序数据特征的提取能力, 但处理长序列数据时易出现梯度消失和爆炸的问题, 并且很难保持长时间的记忆。LSTM 基于 RNN 做了改进, 其在隐藏层设置了三个门结构与一个 cell 状态, 使得网络模型能够较长时间保存并传递信息, 因此在处理序列数据时 LSTM 表现出巨大优势。LSTM 的内部单元结构见文献[19]。

在  $t$  时刻, LSTM 的输入为  $x_t$ 、 $h_{t-1}$  与  $c_{t-1}$ , LSTM 输出为  $h_t$  与  $c_t$ ,  $f_t$ 、 $i_t$ 、 $o_t$  分别表征遗忘门、输入门和输出门的状态值。在 LSTM 中, 遗忘门决定保留历史信息量, 输入门决定新信息输入, 输出门决定最终的输出结果。LSTM 计算公式为

$$\begin{cases} i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \\ f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \\ c_t = f_t h_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \\ o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_{t-1} + b_o) \\ h_t = o_t \tanh(c_t) \end{cases} \quad (17)$$

式中:  $W_x$ 、 $W_h$ 、 $W_c$  代表不同的权重矩阵;  $b_i$ 、 $b_c$ 、 $b_f$ 、 $b_o$  为偏置向量;  $\sigma$ 、 $\tanh$  为激活函数。

LSTM 与 BP 神经网络类似, 同样采用梯度优化算法更新权重。Adam 优化算法是一种用于随机目标函数的一阶梯度优化算法, 文献[25]指出 Adam 算法结合了 AdaGrad 和 RMSProp 算法的优势, 能够对不同参数计算适应性学习率, 占用内存小且适合于数据、参数维度较大的问题, 因此本文选用 Adam 算法作为 LSTM 的训练优化算法。

## 2 OVMD-mRMR-LSTM 组合预测模型

### 2.1 预测模型输入信息设置

将影响负荷变化的各因素(历史负荷、实时电价、星期、时刻值以及温湿度等, 构成预测模型的输入变量特征集合  $X$ )。  $y$  为收集的历史负荷数据经变分模态分解后的各 IMF 分量,  $x$  表示影响各 IMF 分量的特征。为方便处理数据, 对日期与时刻类型进行量值处理, 周一至周日分别用 1~7 表示, 00:00—23:00 依次表示一天中的所有整点时刻(整点间的采样点间隔 30 min 用 0.5 表示), 由于通过气象台可提前获知待预测时刻对应的气象情况, 故温度、湿度取实时值, 考虑到负荷曲线具有一定的日周期性, 输入变量选取了负荷与电价的前 1 天至 7 天的历史数据, 考虑到负荷曲线具备连续性特点, 故在每一天的同一个时刻点  $t$  往前顺延了 3 h 的数据点。输入变量设置参见表 1 所示。

表 1 输入变量的特征集

Table 1 Feature set of the input variable

$x$	特征描述	取值
Lt-n	日前负荷	各序列负荷值 $y$
Hour	一天中时刻	00:00—23:00 (0.5)
Wdt	所属星期类型	1~7
Tt	温度	实时温度值
Humt	湿度	实时湿度值
Pt-n	日前实时电价	实时电价值

### 2.2 预测模型输入信息设置

本文提出的 OVMD-mRMR-LSTM 预测模型, 建模流程如图 1 所示, 具体步骤如下所述。

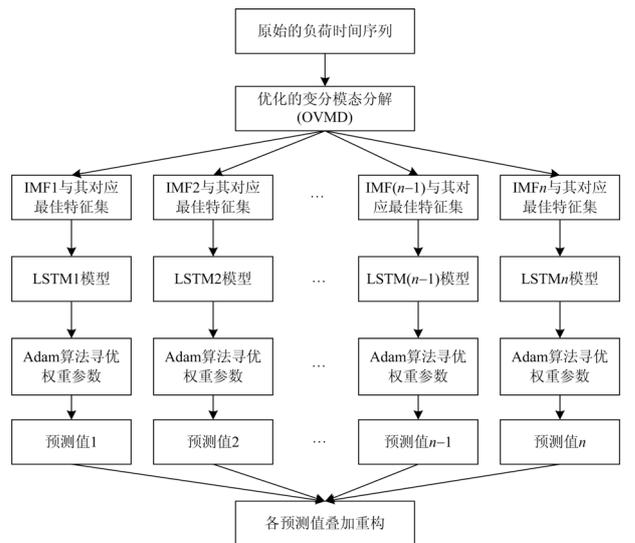


图 1 OVMD-mRMR-LSTM 组合预测模型

Fig. 1 OVMD-mRMR-LSTM combined prediction model

1) 收集待预测日的前期历史负荷数据, 采用 OVMD 方法对该负荷数据做分解处理, 得到若干个模态分量 IMF。

2) 利用 mRMR 从单一负荷模态分量和表 1 的负荷影响因素数据中提取该 IMF 分量预测模型的较佳输入特征集, 接着根据 1.2 节式(16)进一步筛选出该模型的最佳特征集。逐个对各 IMF 分量施加此方法可获取与每个 IMF 分量相对应的最佳特征集, 即作为每个分量预测模型的输入变量。

3) 对各 IMF 分量分别构建 LSTM 神经网络预测模型, 初始化 LSTM 模型的参数, 并采用 Adam 算法不断优化、调整预测模型的权重参数, 以提高对各分量预测的准确度。

4) 运用训练好的模型做多步滚动预测, 叠加各分量预测值, 得到预测结果。

### 2.3 评价指标

选用均方根误差(RMSE)、平均相对误差均值(MAPE)指标评估预测模型性能。

$$E_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i - s'_i)^2} \quad (18)$$

$$E_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \frac{s_i - s'_i}{s_i} \times 100\% \quad (19)$$

式中:  $N$  为样本数量;  $s_i$  为第  $i$  个样本真实值;  $s'_i$  为第  $i$  个样本预测值。

## 3 算例分析

本文将研究对象选为澳大利亚某地 2008 年 5 月 6 日至 5 月 26 日的实际负荷数据(包括当日实时采集的温度、实时电价等数据), 数据点间隔为 30 min。将 5 月 6 日至 25 日的共 960 个数据作为训练样本, 将 5 月 26 日的 48 个数据作为测试样本。

### 3.1 负荷序列分解

对样本序列分解时, 采用 1.1 节的方法设置 OVMD 参数: 惩罚参数  $\alpha$  为 1 937; 模态函数个数取  $K=4$ ; 其余参数均取默认值。分解结果见图 2 所示, 由图可知, IMF<sub>1</sub> 在 4 种分量中占比最大, IMF<sub>2</sub> 与 IMF<sub>3</sub> 占比居中, IMF<sub>4</sub> 占比最小, 且 IMF<sub>1</sub>-IMF<sub>4</sub> 频率依次递增, 针对不同特征的分量, 需要选择相应预测模型的最佳输入特征集。

### 3.2 各 IMF 分量输入变量选择

采用 1.2 节 mRMR 方法, 从特征集合  $X$  中提取满足式(13)的特征子集  $J$ ,  $J$  中的每个特征的 mRMR 值大小是按照降序排列的, 应用式(14)进一步筛选各个 IMF 分量的最佳输入特征集合, 输入特征数量和误差的关系见附图 5, 从图中可以看出影响 4 种

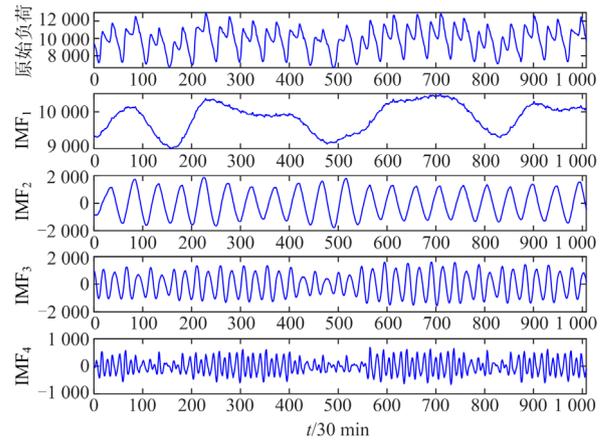


图 2 OVMD 分解结果

Fig. 2 OVMD decomposition results

分量的因素不同, 在满足每个分量的最佳特征输入数的情况下, 此时的预测误差  $R$  最小, 输入特征数不足或增大时误差也会增大, 在负荷中占比最大的 IMF<sub>1</sub> 分量输入特征数也是最大的。IMF<sub>1</sub>-IMF<sub>4</sub> 分量选取的最佳特征集合见附表 1, 从附表中可得出, IMF<sub>1</sub> 分量受到历史负荷、日前实时电价、实时温度值与实时湿度值等多种因素的影响; IMF<sub>2</sub> 主要受历史负荷以及时刻因素的影响; 预测日前一天以及前一周  $t$  时刻负荷值是影响 IMF<sub>3</sub> 与 IMF<sub>4</sub> 的主要因素。

### 3.3 数据预处理

为消除变量间的量纲差异, 需对样本数据归一化, 公式为

$$M_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (20)$$

式中:  $x_i$  为输入数据;  $M_i$  为所得结果;  $x_{\min}$ 、 $x_{\max}$  分别为变量的最小与最大值。

### 3.4 LSTM 预测模型参数选择

构建 LSTM 预测模型, 需要确定模型中的多个超参数。输入层时间步数(TL)表示进行短期负荷预测的历史数据序列长度, 其数值的确定需要考虑模型训练的有效性以及历史信息的完备性; 输入层维数则是各个 IMF 分量的输入变量, 根据附表 1 获得; 隐藏层数目(HD)即是 LSTM 层的个数, 在训练样本充足条件下, 隐藏层的增多, 可提高模型的非线性拟合能力, 但同时增加了模型的复杂度, 耗费时间成本, 甚至引发过拟合问题, 因此本文将隐藏层数选择的范围控制在两层内; 隐藏层维数(HF)的确定需综合考虑模型的学习能力和训练复杂度; LSTM 输出为负荷值, 故输出变量维数为 1。学习率初始值(LR)影响到模型的迭代速度以及预测精度。经过多次试探, 各参数选值见表 2。另外, 为防止梯度

爆炸, 将梯度阈值设置为 1。

表 2 IMF<sub>1</sub>—IMF<sub>4</sub> 预测模型超参数

Table 2 IMF<sub>1</sub>—IMF<sub>4</sub> prediction model super parameter

IMF	TL	HD	HF	LR
IMF <sub>1</sub>	240	1	120	0.01
IMF <sub>2</sub>	480	2	{10、50}	0.005
IMF <sub>3</sub>	336	2	{100、60}	0.01
IMF <sub>4</sub>	672	2	{20、70}	0.04

### 3.5 预测结果

#### 3.5.1 基于 OVMD-mRMR-LSTM 的预测

OVMD-mRMR-LSTM 模型各部分参量确定后, 首先用该模型预测各 IMF 分量, 然后叠加各分量的预测结果作为短期负荷预测的最终结果, 并与 mRMR-LSTM、VMD-LSTM、LSTM 等方法做对比, 其中 LSTM 与 VMD-LSTM 模型的输入是 2.1 节表 1 中的全部特征集(共 102 个输入特征), mRMR-LSTM 模型的输入是表 1 中的全部特征集经过 mRMR 方法筛选后的特征。为避免某一预测模型的每次预测结果可能存在波动性较大的问题, 以下预测结果均为各自执行 20 次的预测结果均值, 预测结果如图 3、图 4 与表 3 所示。

本文方法相较于 mRMR-LSTM、OVMD-LSTM 与 LSTM 方法, 其 RMSE 分别下降了 138.24 MW、250.36 MW、522.23 MW, 其 MAPE 分别下降了 0.93%、1.28%、3.26%, 结果表明 OVMD-mRMR-LSTM 的预测效果要优于 OVMD-LSTM、mRMR-LSTM, 单一的 LSTM 模型的预测效果最差。当忽略电价、湿度等因素时, 本文方法预测精度下降, RMSE 和 MAPE 指标分别上升了 66.09 MW 和 0.69%。

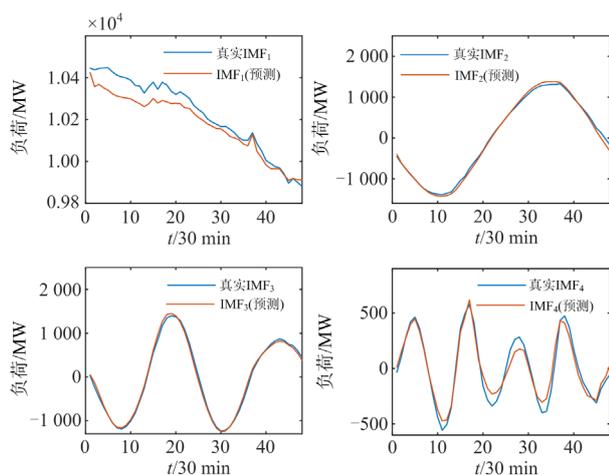


图 3 各分量预测结果

Fig. 3 Prediction results of each component

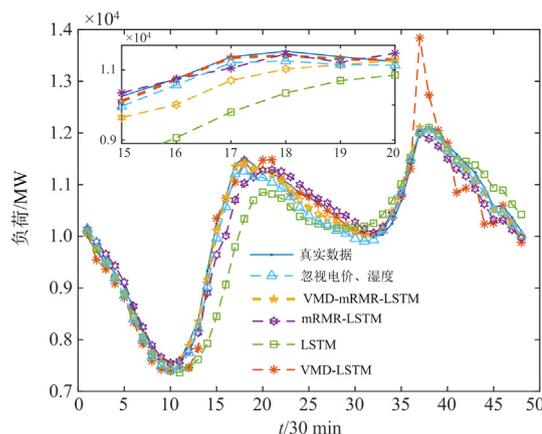


图 4 不同组合方法预测结果

Fig. 4 Prediction results of different combination methods

这是因为负荷预测结果是各个 IMF 分量预测结果的叠加, 从 3.2 节得知 IMF<sub>1</sub> 分量的预测结果与电价、湿度因素关联度大, 因而在预测模型的输入参量中引入电价、湿度因素, 能提高负荷的预测精度。

表 3 不同组合方法的误差指标

Table 3 Error index of different combination methods

预测方法	$E_{RMSE}/MW$	$E_{MAPE}/\%$
本文方法	116.88	0.95
mRMR-LSTM	255.09	1.88
OVMD-LSTM	367.31	2.15
LSTM	576.04	3.75
忽略电价、湿度	182.97	1.64

#### 3.5.2 与其他方法对比

为证明本文方法的可行性, 选择负荷预测的常规方法包括 SVM、BP 神经网络、Elman 神经网络和 ELM 方法及其组合模型与本文方法做比较。为保证客观性, 各预测模型的参数均通过多次尝试实验选取最佳值。

SVM 选用 RBF 核函数, 通过网格搜索法确定惩罚因子和 RBF 核参数。ELM 的结构参数设置为 102-35-1, 最大迭代次数为 500, 激活函数为 sig。BP 用单隐层, 结构参数为 102-55-1, 学习率为 0.01, 最大迭代次数为 500。Elman 的结构参数为 102-20-1, 最大迭代次数为 500。由 OVMD 直接和预测模型构成的组合预测模型的输入是表 1 中的全部特征集(共 102 个输入特征)。由 OVMD-mRMR 和预测模型构成的组合预测模型的输入特征值均按照附表 1 中的输入值。为方便讨论, 实验结果为各方法独立运行 20 次的均值, 忽略各方法在每次预测结果中随机出现的优劣差异, 如图 5 与表 4 所示。

由各方法的误差指标比较可知,组合预测方法的预测结果更接近实际值,预测效果要优于单一的 SVM、ELM、Elman 与 BP 方法,这是因为组合预测方法让整个预测过程变得更加精细化。在组合预测法中引入 mRMR 方法的预测模型与 OVMD 方法直接组合预测方法相比较,预测精度更高,可得出用 mRMR 方法寻找最优特征集,避免了预测模型输入量的不足与冗余干扰问题,因而提升了预测效果。与相同预测类型的 OVMD-mRMR-SVM、OVMD-mRMR-ELM 模型相比,本文方法的误差指标 RMSE 分别降低了 207.05 MW、83.26 MW; MAPE 指标分别降低了 1.66%、0.58%。LSTM 方法的预测效果优于 SVM、ELM 方法,这是因为 LSTM 方法能很好地提取与保留各时序数据间的特征。

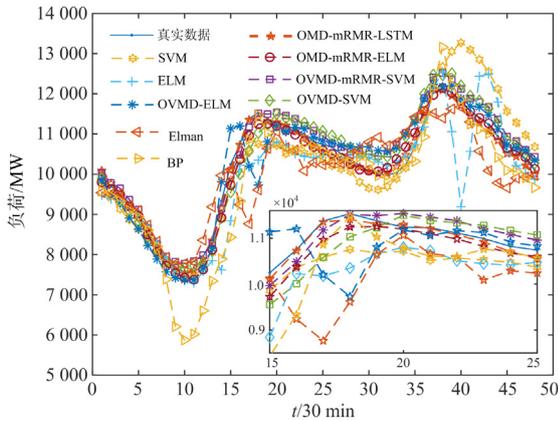


图 5 不同方法的预测结果

Fig. 5 Prediction results of different methods

表 4 不同预测方法的误差指标

Table 4 Error index of different prediction methods

预测方法	$E_{RMSE}/MW$	$E_{MAPE}/\%$
本文方法	116.88	0.95
SVM	631.38	4.74
OVMD-mRMR-SVM	323.93	2.61
OVMD-SVM	380.9	3.12
ELM	706.45	4.7
OVMD-mRMR-ELM	200.14	1.53
OVMD-ELM	472.27	3.46
Elman	748.26	5.34
BP	685.89	5.03

为充分验证本文方法的适应性,将所提模型与其他 8 种模型对 2008 年 7 月 9 日至 15 日共计 7 天负荷进行预测效果比较。为方便图中标识,分别将方法 OVMD-mRMR-LSTM、SVM、OVMD-mRMR-

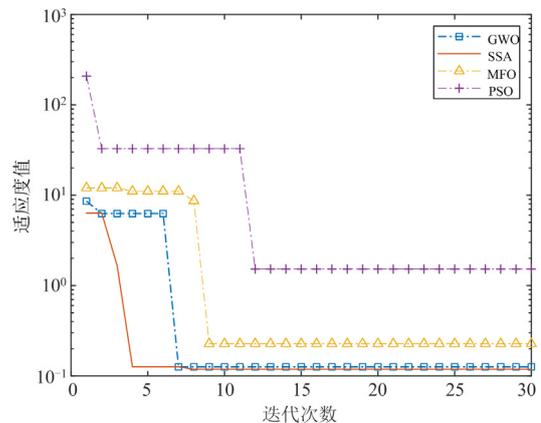
SVM、OVMD-SVM、ELM、OVMD-mRMR-ELM、OVMD-ELM、Elman 与 BP 命名为方法 1—方法 8。预测结果与误差指标分别见附图 6 与附图 7。可以看出,OVMD-mRMR-LSTM 模型预测效果较好,本文方法的 RMSE 总均值为 255.79 MW, MAPE 总均值为 2.04%。

#### 4 结论

本文为提高电力负荷预测的精度,提出了 OVMD-mRMR-LSTM 组合预测模型,综合考虑了实时电价、湿度等多种负荷影响因素,以实际负荷数据做算例分析,得出以下结论。

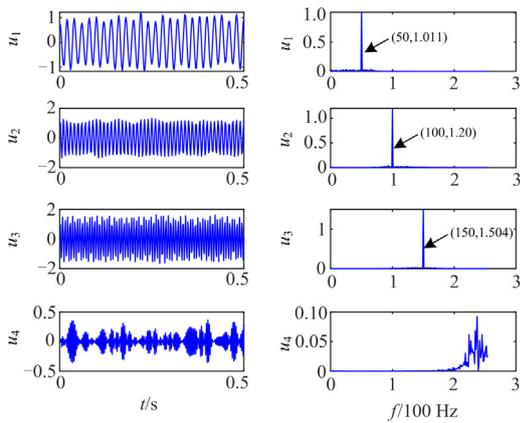
- 1) SSA 算法在求解精度和稳定性方面优于 GWO、PSO 与 MFO 等算法,能用于优化 VMD 的分解数  $K$  和惩罚因子  $\alpha$  等主要参数,且 OVMD 方法比 EMD 方法对原始信号具有更好的分解效果。
- 2) 分析得出 OVMD-mRMR-LSTM 组合模型的预测效果要优于 mRMR-LSTM、OVMD-LSTM 两种组合预测方法,且它们均优于单一的 LSTM 方法。
- 3) 针对时序数据预测,OVMD-mRMR-LSTM 模型的预测效果要优于 OVMD-mRMR-SVM 与 OVMD-mRMR-ELM 方法,并且 SVM、ELM 等方法的预测效果比单一的 LSTM 方法要差。同时,预测模型的输入参量会对预测结果产生重要影响,在电力负荷预测时需要把电价与湿度等因素考虑在内。
- 4) 本文所提组合方法对低频分量预测效果有待改善,未来可研究低频分量预测模型的改进及参数优化,以进一步提升短期负荷的预测精度。

#### 附录



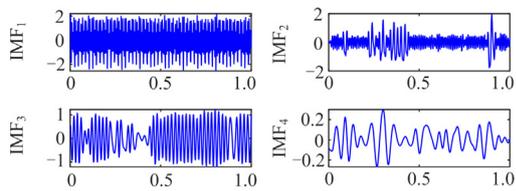
附图 1 适应度变化曲线

Attached Fig. 1 Fitness change curves



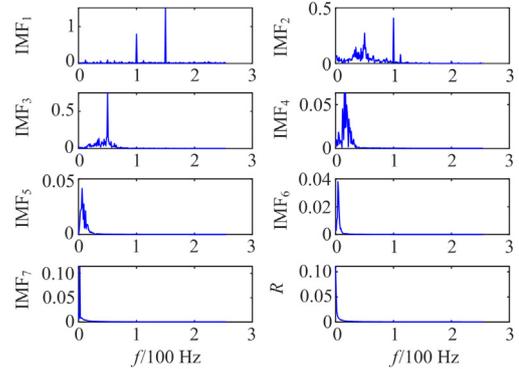
附图 2 OVMD 分解结果

Attached Fig. 2 OVMD decomposition results



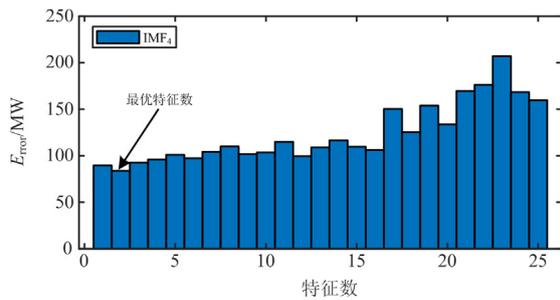
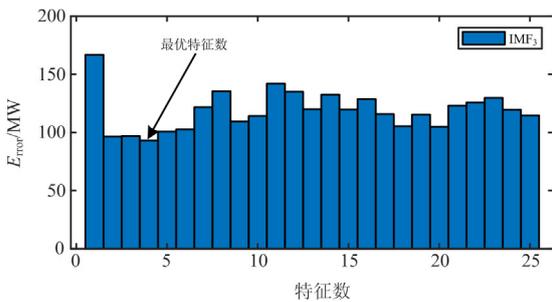
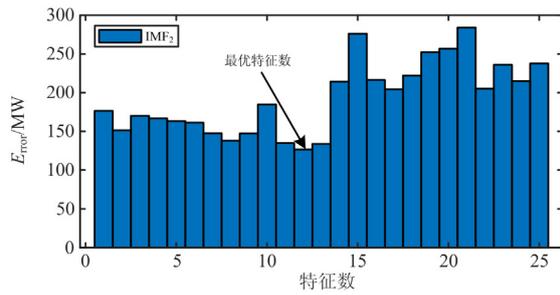
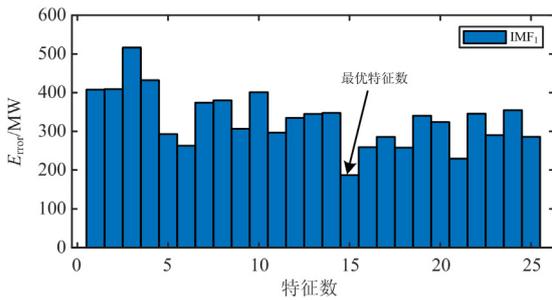
附图 3 EMD 分解结果

Attached Fig. 3 EMD decomposition results



附图 4 EMD 各分解分量频谱

Attached Fig. 4 Spectrum of the decomposed components of EMD



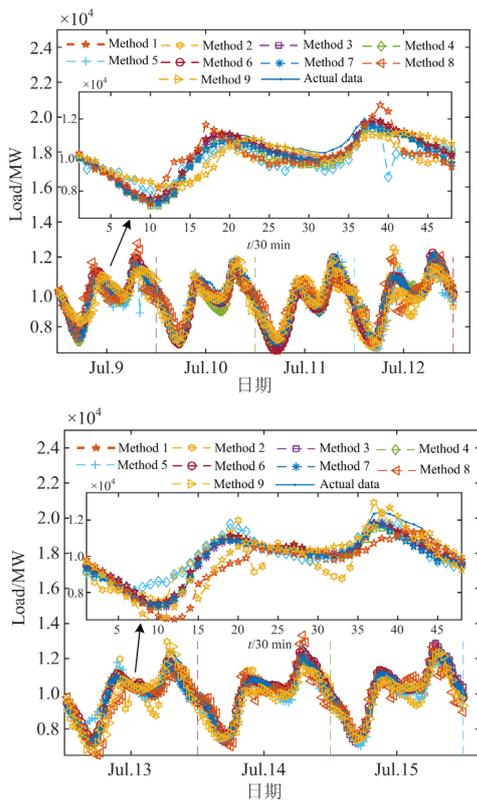
附图 5 输入特征数量和误差的关系图

Attached Fig. 5 Relationship between the number of input features and the error

附表 1 IMF<sub>1</sub>—IMF<sub>4</sub> 分量的最佳输入特征集

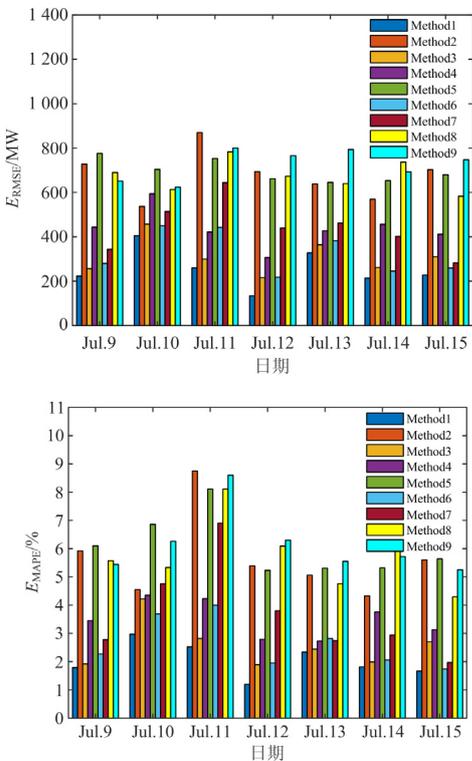
Attached Table 1 Best input feature set of IMF1-IMF4 components

模态分量	特征描述	个数
IMF <sub>1</sub>	Lt-342, Lt-48, Lt-124, Tt, Lt-337, Pt-336, Humt, Lt-301, Lt-150, Pt-342, Lt-97, Lt-336, Pt-74, Pt-77, Lt-340	15
IMF <sub>2</sub>	Lt-48, Lt-336, Lt-168, Lt-342, Lt-49, Hourt, Lt-337, Lt-71, Lt-120, Lt-73, Lt-144, Lt-72	12
IMF <sub>3</sub>	Lt-336, Lt-48, Lt-144, Lt-337	4
IMF <sub>4</sub>	Lt-48, Lt-336	2



附图 6 周负荷预测结果

Attached Fig. 6 Results of weekly load prediction



附图 7 周负荷预测误差指标对比

Attached Fig. 7 Comparison of weekly load forecasting error index

参考文献

[1] 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.

[2] 李军徽, 冯喜超, 严干贵, 等. 高风电渗透率下的电力系统调频研究综述[J]. 电力系统保护与控制, 2018, 46(2): 163-170.  
LI Junhui, FENG Xichao, YAN Gangui, et al. Survey on frequency regulation technology in high wind penetration power system[J]. Power System Protection and Control, 2018, 46(2): 163-170.

[3] 李冬辉, 尹海燕, 郑博文. 基于 MFOA-GRNN 模型的年电力负荷预测[J]. 电网技术, 2018, 42(2): 585-590.  
LI Donghui, YIN Haiyan, ZHENG Bowen. An annual load forecasting model based on generalized regression neural network with multi-swarm fruit fly optimization algorithm[J]. Power System Technology, 2018, 42(2): 585-590.

[4] HU R, WEN S, ZENG Z, et al. A short-term power load forecasting model based on the generalized regression neural network with decreasing step fruit fly optimization algorithm[J]. Neurocomputing, 2017, 221: 24-31.

[5] 朱清智, 董泽, 马宁. 基于即时学习算法的短期负荷预测方法[J]. 电力系统保护与控制, 2020, 48(7): 92-98.  
ZHU Qingzhi, DONG Ze, MA Ning. Forecasting of short-term power based on just-in-time learning[J]. Power System Protection and Control, 2020, 48(7): 92-98.

[6] YANG A, LI W, YANG X. Short-term electricity load forecasting based on feature selection and least squares support vector machines[J]. Knowledge-Based Systems, 2019, 163: 159-173.

[7] DOU C, ZHENG Y, YUE D, et al. Hybrid model for renewable energy and loads prediction based on data mining and variational mode decomposition[J]. IET Generation, Transmission & Distribution, 2018, 12(11): 2642-2649.

[8] 王增平, 赵兵, 纪维佳, 等. 基于 GRU-NN 模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(5): 53-58.  
WANG Zengping, ZHAO Bing, JI Weijia, et al. Short-term load forecasting method based on GRU-NN model[J]. Automation of Electric Power Systems, 2019, 43(5): 53-58.

[9] 彭曙蓉, 黄士峻, 李彬, 等. 基于深度学习分位数回归模型的充电桩负荷预测[J]. 电力系统保护与控制, 2020, 48(2): 44-50.  
PENG Shurong, HUANG Shijun, LI Bin, et al. Charging pile load prediction based on deep learning quantile regression model[J]. Power System Protection and Control, 2020, 48(2): 44-50.

[10] ZANG H, CHENG L, DING T, et al. Hybrid method for

- short-term photovoltaic power forecasting based on deep convolutional neural network[J]. IET Generation, Transmission & Distribution, 2018, 12(20): 4557-4567.
- [11] 孔祥玉, 郑锋, 鄂志君, 等. 基于深度信念网络的短期负荷预测方法[J]. 电力系统自动化, 2018, 42(5): 133-139.  
KONG Xiangyu, ZHENG Feng, E Zhijun, et al. Short-term load forecasting based on deep belief network[J]. Automation of Electric Power Systems, 2018, 42(5): 133-139.
- [12] 郑瑞骁, 张姝, 肖先勇, 等. 考虑温度模糊化的多层长短时记忆神经网络短期负荷预测[J]. 电力自动化设备, 2020, 40(10): 181-186.  
ZHENG Ruixiao, ZHANG Shu, XIAO Xianyong, et al. Short-term load forecasting of multi-layer long short-term memory neural network considering temperature fuzziness[J]. Electric Power Automation Equipment, 2020, 40(10): 181-186.
- [13] 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.
- [14] 孔祥玉, 李闯, 郑锋, 等. 基于经验模态分解与特征相关分析的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(5): 46-52.  
KONG Xiangyu, LI Chuang, ZHENG Feng, et al. Short-term load forecasting method based on empirical mode decomposition and feature correlation analysis[J]. Automation of Electric Power Systems, 2019, 43(5): 46-52.
- [15] 张淑清, 宿新爽, 陈荣飞, 等. 基于变分模态分解和 FABP 的短期电力负荷预测[J]. 仪器仪表学报, 2018, 39(4): 67-73.  
ZHANG Shuqing, SU Xinshuang, CHEN Rongfei, et al. Short-term load forecasting based on the VMD and FABP[J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 67-73.
- [16] 梁智, 孙国强, 李虎成, 等. 基于 VMD 与 PSO 优化深度信念网络的短期负荷预测[J]. 电网技术, 2018, 42(2): 598-606.  
LIANG Zhi, SUN Guojiang, LI Hucheng, et al. Short-term load forecasting based on VMD and PSO optimized deep belief network[J]. Power System Technology, 2018, 42(2): 598-606.
- [17] HE Feifei, ZHOU Jianzhong, FENG Zhongkai, et al. A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm[J]. Applied Energy, 2019, 237: 103-116.
- [18] 熊明明, 李明财, 任雨, 等. 天津电力负荷特性及其与气象因子的关系[J]. 气象科技, 2013, 41(3): 577-582.  
XIONG Mingming, LI Mingcai, REN Yu, et al. Characteristics of electrical load and its relationship to meteorological factors in Tianjin[J]. Meteorological Science and Technology, 2013, 41(3): 577-582.
- [19] 杨秀, 陈斌超, 朱兰, 等. 基于相关性分析和长短期记忆网络分位数回归的短期公共楼宇负荷概率密度预测[J]. 电网技术, 2019, 43(9): 3061-3071.  
YANG Xiu, CHEN Binchao, ZHU Lan, et al. A short-term public building load probability density prediction based on correlation analysis and long- and short-term memory network quantile regression[J]. Power System Technology, 2019, 43(9): 3061-3071.
- [20] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [21] 李雅丽, 王淑琴, 陈倩茹, 等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用, 2020, 56(22): 1-12.  
LI Yali, WANG Shuqin, CHEN Qianru, et al. Comparative study of several new swarm intelligence optimization algorithms[J]. Computer Engineering and Applications, 2020, 56(22): 1-12.
- [22] GAI J, SHEN J, HU Y, et al. An integrated method based on hybrid grey wolf optimizer improved variational mode decomposition and deep neural network for fault diagnosis of rolling bearing[J]. Measurement 2020, 162.
- [23] CHENG Junsheng, YU Dejie, YANG Yu. Research on the intrinsic mode function (IMF) criterion in EMD method[J]. Mechanical Systems and Signal Processing, 2006, 20: 817-824.
- [24] 张旭. 基于循环神经网络的时间序列预测方法研究[D]. 南京: 南京大学, 2019.  
ZHANG Xu. Time series forecasting based on recurrent neural networks[D]. Nanjing: Nanjing University, 2019.
- [25] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报, 2018, 44(4): 772-784.  
WANG Xin, WU Ji, LIU Chao, et al. Exploring LSTM based recurrent neural network for failure time series prediction[J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(4): 772-784.

收稿日期: 2021-03-04; 修回日期: 2021-07-08

作者简介:

胡威(1987—), 男, 博士研究生, 研究方向为新能源功率预测与优化调度; E-mail: 434870858@qq.com

张新燕(1964—), 女, 通信作者, 教授, 博士生导师, 研究方向为新能源发电与并网控制技术; E-mail: xjcxzy@126.com

李振恩(1986—), 男, 硕士, 讲师, 研究方向为风电场机组故障诊断与科学维护。E-mail: 1377223559@qq.com

(编辑 姜新丽)