

DOI:10.19651/j.cnki.emt.2107628

# 基于改进 LSSVM 的短期电力负荷预测\*

杨 邓<sup>1</sup> 杨俊杰<sup>1,2</sup> 胡晨阳<sup>1</sup> 崔 丹<sup>1</sup> 陈照光<sup>1</sup>

(1. 上海电力大学 电子与信息工程学院 上海 200090; 2. 上海电机学院 上海 201306)

**摘要:** 针对电力负荷随机性、波动性以及非线性因素所导致预测精度不高等问题,提出了一种基于变分模态分解(VMD)与麻雀搜索算法(SSA)优化的最小二乘支持向量机(LSSVM)短期负荷预测模型。该方法首先借助 VMD 将原始负荷时间序列分解成不同频率的本征模态函数(IMF)和残差分量(Res),然后对各分量建立不同的 LSSVM 预测模型并利用 SSA 进行参数优化,最后将各分量预测值组合得到最终的预测结果。以比利时蒙斯大学和中国河南省某地区两组真实数据为例进行预测分析,将预测结果与 LSSVM、VMD-LSSVM、SSA-LSSVM 模型预测值对比,得出所提出方法的两组数据 MAPE 值分别为 1.501 6%、4.765%,远低于其他模型。结果表明该组合预测模型在预测精度上具有一定的优越性。

**关键词:** 负荷预测;变分模态分解;麻雀搜索算法;最小二乘支持向量机;预测模型;预测精度

**中图分类号:** TM715 **文献标识码:** A **国家标准学科分类代码:** 520.20

## Short-term power load forecasting based on improved LSSVM

Yang Deng<sup>1</sup> Yang Junjie<sup>1,2</sup> Hu Chenyang<sup>1</sup> Cui Dan<sup>1</sup> Chen Zhaoguang<sup>1</sup>

(1. College of Electronics and Information Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. Shanghai Dianji University, Shanghai 201306, China)

**Abstract:** Aiming at the problem of low prediction accuracy caused by randomness, fluctuation and nonlinear factors of power load, a short-term load prediction model based on least squares support vector machine (LSSVM) optimized by variational mode decomposition (VMD) and sparrow search algorithm (SSA) was proposed. In this method, the original load time series was decomposed into the intrinsic mode function (IMF) and residual component (Res) of different frequencies by VMD. Then, different LSSVM prediction models were established for each component and parameters were optimized by SSA. Finally, the final prediction results were obtained by combining the predicted values of each component. Taking two groups of real data from The University of Mons in Belgium and a certain area of Henan Province in China as examples, the prediction results were compared with the predicted values of LSSVM, VMD-LSSVM and SSA-LSSVM models, and the MAPE values of the two groups of data proposed were 1.501 6% and 4.765% respectively, far lower than those of other models. The results show that the combined prediction model has some advantages in prediction accuracy.

**Keywords:** load forecasting; variational modal decomposition; sparrow search algorithm; least squares support vector machine; prediction model; prediction accuracy

## 0 引 言

在电力系统运行、规划管理过程中,短期电力负荷预测是电网调度部门合理安排生产发电、输电以及配电的重要参考<sup>[1]</sup>,同时也是电力系统安全可靠运行的重要保障。因此,准确的负荷预测对于提高电力系统的经济效益、促进国民经济发展具有重要意义。

为了提高短期电力负荷预测的精度,近年来,国内外学者对负荷预测进行了大量的研究,主要包括两大类预测模型:时间序列预测模型和机器学习预测模型。时间序列预测模型是基于负荷数据的时间序列关系,从过去的负荷序列预测未来的负荷。如,指数平滑法<sup>[2]</sup>、多元线性回归<sup>[3-4]</sup>、回归分析法<sup>[5]</sup>等。这类方法的优点是模型简单、预测效率客观,但对于非线性较强的序列则预测效果不佳。针对时

收稿日期:2021-08-18

\* 基金项目:国家自然科学基金(61202369,61401269,61572311)、上海市科技创新行动计划地方院校能力建设(17020500900)、上海市教育发展基金会和上海市教育委员会“曙光计划”(17SG51)项目资助

间序列预测算法鲁棒性较差的缺点,机器学习预测模型可以有效地解决负荷非线性问题,它是根据神经网络强大的多元映射能力,实现对负荷时间序列的深度挖掘,达到较高的预测精度。如王克杰等<sup>[6]</sup>使用猫群算法对 BP 神经网络的参数进行优化,建立最优短期预测模型,降低了模型的预测误差,提高了预测精度。杨捷等<sup>[7]</sup>考虑日特征相关因素结合相空间重建建立相应的支持向量回归机短期预测模型,相比较于未考虑日特征相关因素的预测精度更高。蔡秋娜等<sup>[8]</sup>将熵诱导度量引入人工神经网络当中,并建立起新的鲁棒性人工神经网络,提高了预测性能。虽然机器学习预测方法相对于时间序列法有更好的预测效果,但随着负荷数据量的指数式增加,数据中有效信息不能够准确地表达,并且存在参数难以确定、预测效率慢等缺点<sup>[9]</sup>,导致该方法往往难以达到预期的预测效果。

鉴于上述两种方法的局限性,有学者提出组合预测模型在负荷预测领域得到了不错的进展。姚程文等<sup>[10]</sup>针对传统 LSTM 网络参数多、模型收敛速度慢等缺点,利用卷积神经网络强大的数据挖掘能力提取出高维空间特征向量的重要信息输入到 GRU 循环神经网络中训练,提高了预测精度。赵兵等<sup>[11]</sup>为解决深度学习中循环神经网络难以提取有效历史序列中高维特征等问题,将注意力机制应用于 CNN-GRU 预测模型当中,通过注意力机制映射加权配置 GRU 不同的权重,最终取得较高的预测精度。孔祥玉等<sup>[12]</sup>提出基于 EMD 特征相关性分析的短期负荷预测模型。该模型首先使用 EMD 将原始载荷序列分解为一定数量的 IMF 和残差分量,然后用差分序列寻找具有最小冗余最大相关的最佳输入集,最后由 LSSVM 预测。但是 EMD 易造成模式混叠和模式虚幻现象<sup>[13]</sup>,这会对预测精度产生一定程度的干扰,影响最终的预测效果。针对此问题,Duan 等<sup>[14]</sup>提出一种新型的组预测算法,利用 VMD 将原始负荷序列分解为不同带宽的 IMF,同时提取自身特征信息,这样有效地解决了 EMD 所存在的问题,最终达到了较高的预测精度。

在上述背景下,本文提出一种基于变分模态分解与麻雀搜索算法优化的最小二乘支持向量机短期负荷预测模型。首先通过 VMD 将原始负荷序列分解成不同频率的模态分量 IMF 和残差 Res,以此降低原负荷序列的波动性和非平稳性,然后采用 SSA-LSSVM 预测模型分别对不同频率的分量进行训练和预测,将各个分量预测值整合得出最终的预测结果。最后以比利时蒙斯大学和中国河南省某地区采集的真实数据为例,将算例结果与其他算法对比,验证了本文方法的有效性。

## 1 算法原理

### 1.1 VMD 变分模态分解

电力部门在负荷数据采集过程中,会受到各种电磁波噪声的干扰,严重影响数据的质量,导致预测精度不高等问

题,因此有必要对数据降噪处理。VMD 是一种非平稳信号的自适应分解方法<sup>[15]</sup>,可以根据序列实际情况确定模态分解个数,并在求解过程中可以自适应地匹配到每类模态最佳中心频率带宽,最终得到问题的最优解。

VMD 可以将原始高频信号  $f$  分解成  $K$  个不同中心频率带宽的模态分量  $u_k$ ,且使所有模态估计带宽之和取得最小,即满足下列约束条件:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t.} \quad \sum_{k=1}^K u_k = f(t) \end{cases} \quad (1)$$

式中:  $u_k$  表示分解后的第  $k$  个模态分量;  $\omega_k$  为第  $k$  个模态分量的中心;  $\delta(t)$  为狄拉克分布;  $f(t)$  为输入序列。

为了方便求解,引入二次惩罚因子  $\alpha$  和拉格朗日乘子  $\lambda$ ,消除约束变分模型的约束性,将式(1)约束问题转化为下式非约束问题,即:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \quad (2)$$

利用交替方向乘子算法交替更新  $u_k^{n+1}$ 、 $\omega_k^{n+1}$  和  $\lambda^{n+1}$  求得拉式方程的鞍点,如式(3)、(4)所示。

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

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

式中:  $\hat{u}_k^{n+1}$  为模态分量的维纳滤波,  $\omega_k^{n+1}$  为对应的模态分量的频率中心,  $\omega$  为频率。利用傅里叶反变换将  $\hat{u}_k(\omega)$  变换至  $u_k(t)$ , 那么式(1)中的约束方程便可求解。

### 1.2 LSSVM 最小二乘支持向量机

LSSVM 是在 SVM 基础上的改进,它采用最小二乘线性方程作为其损失函数,用等式约束代替了标准支持向量机中的不等式约束。这样,将二次规划问题转化为求解线性方程组,简化了计算复杂程度,提高了算法的收敛速度,有助于对具有非线性特性短期电力负荷的有效拟合<sup>[16-17]</sup>。具体步骤如下。

设给定一组训练样本集:

$$S = \{(x_i, y_i), x_i \in \mathbf{R}^n, y_i \in \mathbf{R}\}, i = 1, 2, \dots, N \quad (5)$$

式中:  $x_i$  为第  $i$  个输入向量,  $y_i$  为第  $i$  个输出向量;  $n$  为输入向量的维数,  $N$  为训练样本的大小。

LSSVM 的核心原理是将训练样本通过非线性映射映射到高维特征空间,然后在高维空间进行线性回归。回归

函数可以描述如下:

$$f(x) = \omega \cdot \varphi(x) + b \quad (6)$$

式中:  $\omega$  为权重向量;  $\varphi(x)$  是 LSSVM 的核函数, 表示为低维特征空间到高维特征空间的映射关系;  $b$  为偏差量。按结构风险最小化原则, LSSVM 的优化问题可以转化为:

$$\begin{cases} \min J(\omega, b, e) = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2 \\ \text{s. t. } y_i = \omega^\top \varphi(x_i) + b + e_i \end{cases} \quad (7)$$

式中:  $e_i$  为拟合误差;  $\gamma$  为惩罚因子, 控制误差的惩罚程度。引入拉格朗日乘子  $\lambda_i$  对上述优化问题求解:

$$L(\omega, b, e, \lambda) = J(\omega, b, e) - \sum_{i=1}^n \lambda_i [\omega^\top \varphi(x_i) + b + e_i - y_i] \quad (8)$$

根据 KKT 条件, 对式(8)求解推导:

$$\begin{cases} \frac{\partial J}{\partial \omega} = 0 \rightarrow \sum_{i=1}^n \lambda_i \varphi(x_i) \\ \frac{\partial J}{\partial b} = 0 \rightarrow \sum_{i=1}^n \lambda_i = 0 \\ \frac{\partial J}{\partial e} = 0 \rightarrow \lambda_i = \gamma e_i \\ \frac{\partial J}{\partial \omega} = 0 \rightarrow \omega^\top \varphi(x_i) + B + e_i - y_i = 0 \end{cases} \quad (9)$$

通过求解, 消除上述方程  $\omega$  和  $e$ , 最终得到预测模型函数<sup>[17]</sup>:

$$f(x) = \sum_{i=1}^n \lambda_i K(x_i, x_j) + b \quad (10)$$

式中:  $K(x_i, x_j)$  为核函数, 表示输入空间到高维特征空间的非线性映射。常见的核函数有傅里叶核函数、径向基核函数。由于径向基核函数具有径向对称, 泛化能力强的特点, 因此可以作为本文预测模型的核函数, 如式(11)所示。

$$K(x_i, x_j) = \exp\left[-\frac{\|x - x_i\|^2}{2\sigma^2}\right] \quad (11)$$

式中:  $\sigma$  为核函数的宽度因子。

在 LSSVM 预测模型当中,  $\gamma$  反映误差大小以及模型的泛化能力,  $\sigma$  反映训练数据样本的分布特性, 这两个参数直接影响了预测效果。因此, 在预测之前, 有必要选取智能优化算法对 2 个超参数进行寻优。

### 1.3 SSA 麻雀优化算法

麻雀搜索算法是 Xue 等<sup>[18]</sup>在 2020 年提出的一种新型的群智能优化算法。它是一种模仿麻雀种群捕食过程中的群体合作行为而形成的启发式算法, 这种行为策略在一定程度上提高了最优搜索空间的探索与开发。详细步骤如下。

初始化种群位置用如下矩阵表示:

$$\mathbf{X} = \begin{bmatrix} X_1^1 & X_1^2 & \cdots & X_1^d \\ X_2^1 & X_2^2 & \cdots & X_2^d \\ \cdots & \cdots & \ddots & \cdots \\ X_n^1 & X_n^2 & \cdots & X_n^d \end{bmatrix} \quad (12)$$

式中:  $d$  表示待优化的维度,  $n$  表示麻雀种群的数量。

在麻雀搜索算法中, 发现者具有良好的适应度值, 负责寻找食物并为种群提供觅食方向, 发现者在搜索食物过程中, 位置更新如下<sup>[19-20]</sup>:

$$X_{ij}^{t+1} = \begin{cases} X_{ij}^t \cdot \exp\left(-\frac{i}{\alpha \cdot t_{\max}}\right), & R_2 < ST \\ X_{ij}^t + \mathbf{QL}, & R_2 \geq ST \end{cases} \quad (13)$$

式中:  $t$  为当前迭代次数;  $j$  为当前维度,  $j = 1, 2, 3, \dots, d$ ;  $X_{ij}^t$  为第  $t$  次迭代第  $i$  只麻雀在第  $j$  维的位置信息;  $\alpha \in [0, 1]$  为一个随机数;  $R_2$  ( $R_2 \in [0, 1]$ ) 和  $ST$  ( $ST \in [0.5, 1]$ ) 分别表示预警值与安全阈值, 当  $R_2 < ST$  时, 说明周围无捕食者, 发现者进入食物搜寻模式, 反之, 麻雀放弃搜索捕食行为, 迅速飞往完全区域;  $\mathbf{Q}$  为一个服从正态分布的随机数;  $\mathbf{L}$  为  $1 \times d$  的单位矩阵。

在算法中, 追随者的适应度值较差, 他们会根据发现者的位置来寻找食物。当他们监视到发现者找到食物时, 会改变当前位置参与食物竞争, 若竞争失败, 便到其他地方继续搜寻, 位置更新过程如下所示:

$$X_{ij}^{t+1} = \begin{cases} \mathbf{Q} \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{ij}^t}{i^2}\right), & i > \frac{n}{2} \\ X_{ij}^{t+1} + |X_{ij}^t - X_p^{t+1}| \cdot \mathbf{A}^* \cdot \mathbf{L}, & i \leq \frac{n}{2} \end{cases} \quad (14)$$

式中:  $X_{\text{worst}}^t$  为当前全局最差位置;  $X_p^{t+1}$  为第  $t+1$  次迭代发现者的最优位置;  $\mathbf{A}$  为元素随机分配为 1 或 -1 的  $1 \times d$  维矩阵, 且满足  $\mathbf{A}^* = \mathbf{A}^\top (\mathbf{A}\mathbf{A}^\top)^{-1}$ ,  $n$  为麻雀总数。

当一只麻雀意识到危险时, 它会主动靠近圈内或周围伙伴, 以增加自身安全, 该过程位置更新方式如下所示:

$$X_{ij}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{ij}^t - X_{\text{best}}^t|, & f_i > f_g \\ X_{ij}^t + K \cdot \frac{|X_{ij}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \epsilon}, & f_i = f_g \end{cases} \quad (15)$$

式中:  $X_{\text{best}}^t$  为第  $t$  次迭代全局最佳位置;  $\beta$  为迭代步长, 服从标准正态分布;  $f_i$  为当前麻雀的适应度值,  $f_g$  与  $f_w$  分别为全局最佳和最差适应度值;  $K$  为  $[-1, 1]$  之间的随机数;  $\epsilon$  为最小常数, 防止分母为 0。

## 2 模型搭建

### 2.1 SSA 优化 LSSVM 模型

由 1.2 节中 LSSVM 模型可知, 在短期负荷预测中, 参数的选择会直接影响到负荷预测的精度。因此本文选择 1.3 节中 SSA 算法优化 LSSVM 的两个参数。图 1 为优化流程, 具体步骤如下。

步骤 1: 初始化 SSA 参数, 包括种群数量、迭代次数; LSSVM 初始参数  $\gamma$  和  $\sigma$ 。

步骤 2: 计算每只麻雀的适应度值  $f_i$ , 并根据  $f_i$  选出最佳和最差个体和其对应的位置  $X_{\text{best}}$  与  $X_{\text{worst}}$ 。

步骤 3: 计算警报值, 根据式(13)与(14)更新发现者与追随者位置。

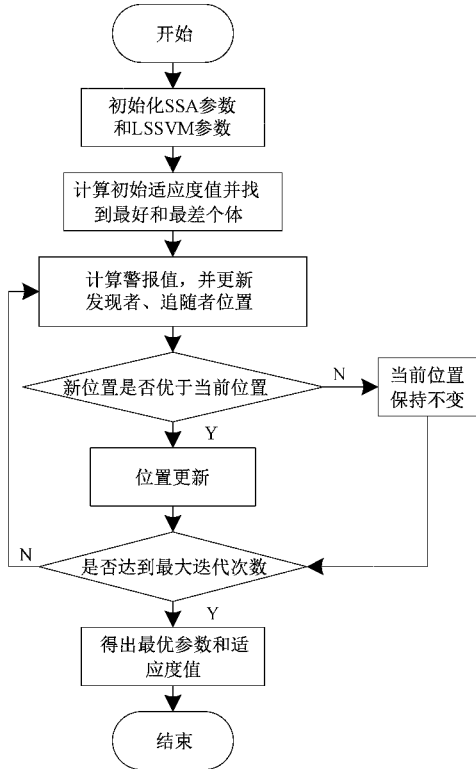


图 1 SSA 优化 LSSVM 流程

步骤 4: 计算麻雀新位置的适应度值, 并与原始值进行比较。

步骤 5: 根据步骤 4 的比较值更新所有麻雀适应度值  $f_i$ , 重新选取全局最优  $f_g$  和最差  $f_w$ , 分别对应位置  $X_{best}$ 、 $X_{worst}$ 。

步骤 6: 判断是否达到最大迭代次数, 若是, 则输出最优参数, 反之重复步骤 2。

### 2.2 基于 VMD-LSSVM 的预测模型

本模型的预测流程如图 2 所示。考虑到原始数据的非平稳性, 所以首先将原始负荷序列通过 VMD 进行分解, 然后将分解后的各个模态分量归一化处理, 接着对各分量构建不同核函数特征的 LSSVM 预测模型并进行训练, 同时采用 SSA 算法找到各个分量 LSSVM 模型的最佳参数, 最后将各个 LSSVM 预测分量组合得出最终的预测值。

### 3 算例分析

采用 2 个实际负荷数据集对本文模型进行验证, 分别为比利时蒙斯大学采集当地某用户真实数据<sup>[21]</sup>以及中国河南省某地区实际电力负荷数据为例。蒙斯大学所采集的数据规模为 2016 年 1 月 11 日~2016 年 5 月 27 日, 采样时间间隔为 10 min, 如图 3 所示。中国河南省某地区数据集选取为 2008 年 6 月 1 日~2018 年 8 月 29 日, 每天采集 24 个时间点, 采样时间间隔为 1 h。以 LSSVM、VMD-LSSVM、SSA-LSSVM 预测模型作为本文的对比方法, 将

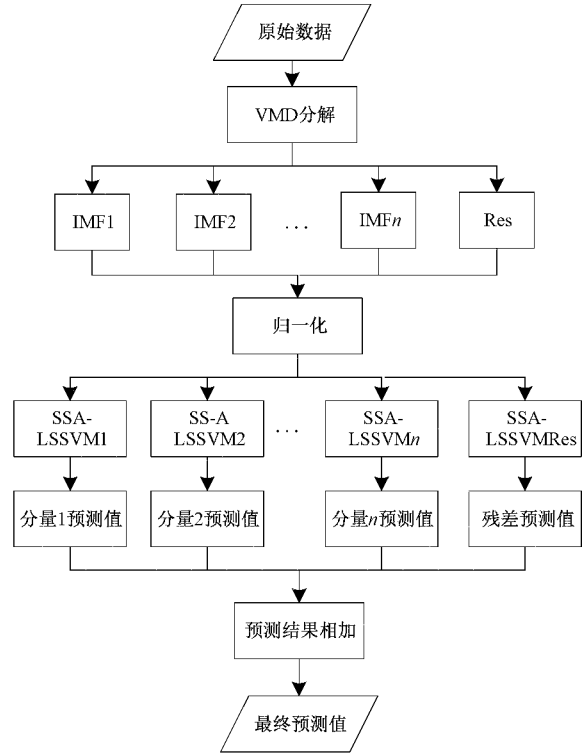


图 2 VMD-SSA-LSSVM 预测模型流程

预测结果真实值对比, 最后采用 MAPE、MAE 和 RMSE 3 个评价指标对各模型预测结果综合评价。




图 3 历史负荷数据

### 3.1 数据预处理与评价指标

因采集到的数据特征量纲不同, 为提高模型的鲁棒性, 需对 VMD 分解后的序列归一化处理<sup>[22]</sup>, 使用线性化映射归算到  $[0, 1]$  之间, 归一化公式如下:

$$\tilde{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (16)$$

式中:  $\tilde{x}$  为归一化后的数据,  $x$  为分解后的序列数据,  $x_{\max}$  和  $x_{\min}$  分别代表负荷最大值和最小值。

为评估模型的精度, 本文选取均方根误差 (RMSE)、平均绝对误差 (MAE) 和平均绝对百分比误差 (MAPE) 作为预测精度的测试标准<sup>[23 24]</sup>, RMSE、MAE、MAPE 越小, 模

型预测精度越高。以 MSE 作为模型的适应度函数。表达式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \tilde{y}_i)^2} \quad (17)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \tilde{y}_i| \quad (18)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \tilde{y}_i}{y_i} \right| \times 100\% \quad (19)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \tilde{y}_i)^2 \quad (20)$$

式中:  $N$  为预测样本个数,  $\tilde{y}_i$  和  $y_i$  分别为测试集中的预测值与真实值。

### 3.2 比利时数据集预测分析

本文对比利时蒙斯大学所采集的负荷数据训练预测, 将 2016 年 5 月 26 日 18 时之前的数据作为训练集, 对最后 24 h 共计 144 个数据作为测试集。

由图 3 可知历史负荷数据具有较强的波动性和非线性特征。因此有必要用 VMD 对负荷数据进行分解, 设置 VMD 的参数: 惩罚因子  $\alpha = 2000$ ; 初始中心频率  $\omega = 0$ ; 收敛因子为  $10^{-7}$ 。负荷数据经分解后得到本征模态分量和残差, 如图 4 所示, 可以看出分解后的序列较为规律, 具有一定的周期性, 频率相对稳定, 没有明显的频谱混叠现象。

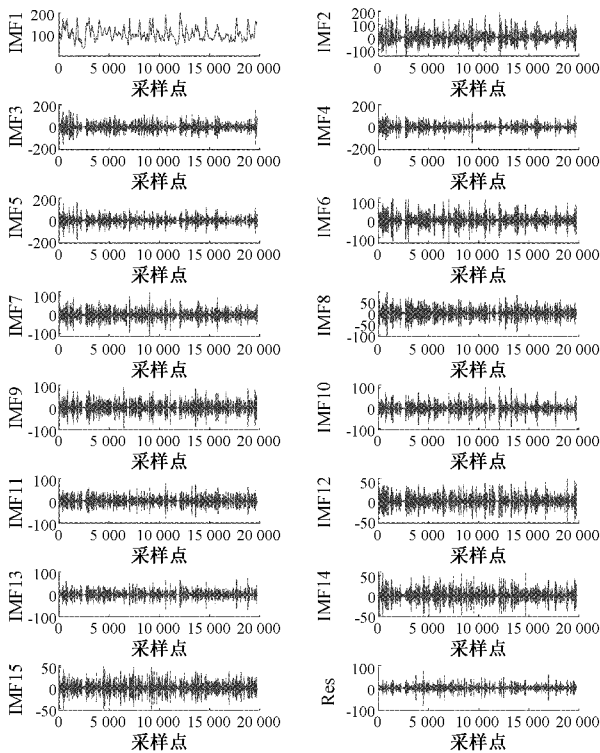


图 4 VMD 分解后各序列

将 VMD 分解后的各分量序列的训练集经归一化后输入到本文的预测模型当中, 以均方误差 MSE 作为模型的适应度值, MSE 是真实值和预测值之差的平方期望值, MSE

值越小, 说明预测模型精度越高。当 SSA 优化模型迭代次数达到最大值后, 得出最终的 SSA-LSSVM 预测模型。将 2016 年 5 月 26 日 18 时后的测试集代入模型当中, 预测结果如图 5 所示, 实线为真实值, 虚线为预测值, 很显然预测值与真实值之间吻合度较高。根据图 6 适应值随迭代次数变化曲线可以看出, 在 10 次迭代过程中, 本模型在迭代初期就达到了较高的精度, 平均适应值在迭代第 5 次时就已达到收敛。




图 5 VMD 本文算法预测结果




图 6 适应值曲线

为了验证本文所提组合预测模型的优越性, 将其与单一 LSSVM 模型以及 VMD-LSSVM 模型、SSA-LSSVM 模型进行对比, 预测结果比较如图 7 所示。粗实线为负荷真实值, 点划线为本文预测结果, 细实线为 VMD-LSSVM 预测结果, 双划线为 SSA-LSSVM 预测结果, 虚线为 LSSVM 预测结果。不难发现, 本文所提模型预测结果更接近于真实值, 具有较高的预测精度。并且, 在负荷波动比较大的波峰时段预测结果相对于其他算法更加精准。分析其原因, 由于负荷较强的波动性以及非线性因素, 导致 LSSVM、SSA-LSSVM 预测值与真实值在波峰时段存在较大误差; 而 VMD-LSSVM 预测结果相对平稳, 得益于 VMD 分解降低了负荷的非平稳性, 提高了预测精度; 本文方法预测精度相对更高, 验证了 SSA 对 LSSVM 关键参数优化的有效性。

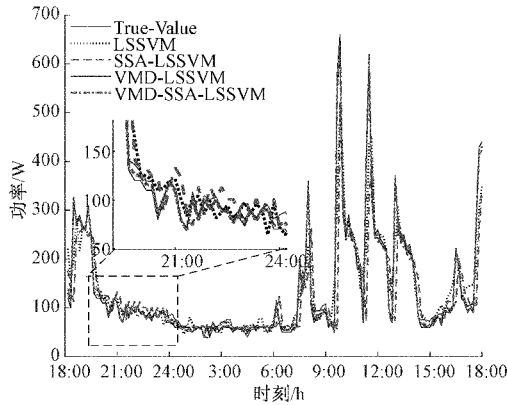


图 7 本文算法与其他算法对比图

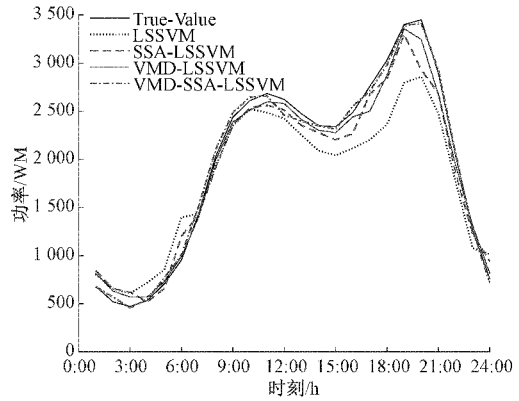


图 8 预测结果对比图

为进一步验证本文方法的优越性,将本文方法与其他预测模型对比,得出在此数据集上的综合评价指标如表 1 所示。从均方根误差角度分析,本文所提模型相比于 LSSVM、SSA-LSSVM 与 VMD-LSSVM, RMSE 分别下降了 75.185 7、48.547 7、5.259 4;从平均绝对误差角度分析, MAE 相对于其他 3 种算法分别降低了 34.003 6、26.931 8、4.13;从平均百分比误差角度分析, MAPE 相对于其他 3 种算法分别降低了 31.377 6%、21.893 1%、2.141 4%。结果表明,本文所提 VMD-SSA-LSSVM 短期负荷预测模型相比较于其他模型具有较高的预测精度,算法可靠性高。

表 1 不同模型预测精度比较

算法模型	RMSE	MAE	MAPE/%
LSSVM	78.535 7	36.669 0	32.880 2
SSA-LSSVM	51.897 7	29.597 2	23.395 7
VMD-LSSVM	8.609 4	6.795 4	3.644 0
本文方法	3.350 0	2.665 4	1.501 6

### 3.3 国内数据集预测分析

为验证本文方法的实用性,将此方法应用于国内数据集中。本文将中国河南省某地区的电力负荷数据集划分为两部分,其中将 2018 年 6 月 1 日~2018 年 8 月 28 日的的数据作为训练集,2018 年 8 月 29 日的数据作为测试集,对测试集的负荷值进行预测。

图 8 为本文方法与 LSSVM、SSA-LSSVM、VMD-LSSVM 的预测结果对比图。粗实线为负荷真实值,点划线为本文预测结果,细实线为 VMD-LSSVM 预测结果,双划线为 SSA-LSSVM 预测结果,虚线为 LSSVM 预测结果。由图 8 可以看出本文预测模型预测结果更贴近于真实值,相比较于其他方法,本文方法在负荷变动较大的波峰时段预测更加精准,能够较为准确地预测出负荷的变化规律。

为了验证本文模型的科学性,将各模型最终预测结果综合评价。如表 2 所示,可知本文模型的预测精度最高,其

中 RMSE 相对于其他 3 种方法分别降低了 97.989、36.119、14.703; MAE 相对于其他 3 种方法分别降低了 53.199、31.507、12.15; MAPE 相对于其他 3 种方法降低了 42.874%、19.762%、6.765%。综合分析上述结果,可以得出本文方法相对于其他 3 种方法的评价指标都有明显地提升,达到了较高的预测精度,表明本文方法预测效果更好。

表 2 预测精度比较

算法模型	RMSE	MAE	MAPE/%
LSSVM	107.632	58.981	47.639
SSA-LSSVM	45.762	37.289	24.527
VMD-LSSVM	24.346	17.932	11.530
本文方法	9.643	5.782	4.765

## 4 结 论

电力负荷的精准预测是电网可靠运行的重要前提,针对负荷侧波动性、非线性因素导致预测难度大,预测精度不高等问题,本文提出了基于 VMD-SSA-LSSVM 的负荷预测模型。首先利用 VMD 分解序列的优势,降低了电力负荷序列的非平稳性,提高了模型的预测精度,然后采用 SSA 优化 LSSVM 模型参数,这样可以有效降低预测误差,提高预测精度。最后以国外比利时以及国内真实数据为例,通过与其他模型预测结果对比,得出本文方法预测精度更高,充分验证了本文模型的优越性。另外,本文在下一步的研究中,会着重考虑对短期负荷预测影响较大的因素:气象、日期类型等,进一步提高预测精度。

### 参考文献

[1] GUAN T, XU Z, LIN L, et al. Maximum incremental load recursive model based on LSSVM considering accumulated temperature effect [C]. 2018 IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData), IEEE, 2018;

- 716-719.
- [2] DUDEK G, PELKA P, SMYL S. A hybrid residual dilated LSTM and exponential smoothing model for midterm electric load forecasting [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, DOI: 10.1109/TNNLS.2020.3046629.
- [3] 陈锦鹏, 胡志坚, 陈纬楠, 等. 二次模态分解组合 DBiLSTM-MLR 的综合能源系统负荷预测[J]. 电力系统自动化, 2021, 45(13): 85-94.
- [4] 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.
- [5] 王雁凌, 吴梦凯. 经济新常态下基于偏最小二乘回归的中长期负荷预测模型[J]. 电力自动化设备, 2018, 38(3): 133-139.
- [6] 王克杰, 张瑞. 基于改进 BP 神经网络的短期电力负荷预测方法研究[J]. 电测与仪表, 2019, 56(24): 115-121.
- [7] 杨捷, 罗成臣, 张思路, 等. 相空间重构和 SVR 耦合的短期电力负荷预测[J]. 电测与仪表, 2020, 57(16): 96-100.
- [8] 蔡秋娜, 潮铸, 苏炳洪, 等. 基于一种新型鲁棒损失的神经网络短期负荷预测方法[J]. 电网技术, 2020, 44(11): 4132-4139.
- [9] ZHENG J, XU C, ZHANG Z, et al. Electric load forecasting in smart grids using long-short-term-memory based recurrent neural network[C]. 2017 51st Annual Conference on Information Sciences and Systems(CISS), IEEE, 2017: 1-6.
- [10] 姚程文, 杨苹, 刘泽健. 基于 CNN-GRU 混合神经网络的负荷预测方法[J]. 电网技术, 2020, 44(9): 3416-3424.
- [11] 赵兵, 王增平, 纪维佳, 等. 基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J]. 电网技术, 2019, 43(12): 4370-4376.
- [12] 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.
- [13] 阳曾, 丁施尹, 叶萌, 等. 基于变分模态分解和深度学习的短期电力负荷预测模型[J/OL]. 电测与仪表, 2020: 1-8.
- [14] DUAN J, WANG P, MA W, et al. Daily electricity consumption combined forecast based on variational mode decomposition and sample entropy[C]. 2019 IEEE Sustainable Power and Energy Conference (iSPEC), IEEE, 2019: 762-767.
- [15] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [16] 张鑫, 赖伟坚, 林泽宏, 等. 基于最小二乘支持向量机和裸骨烟花算法的电力负荷短期预测[J]. 新型工业化, 2019, 9(6): 1-5, 22.
- [17] 付乐天, 李鹏, 高莲. 考虑样本异常值的改进最小二乘支持向量机算法[J]. 仪器仪表学报, 2021, 42(6): 179-190.
- [18] XUE J K, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [19] 赵普凡, 王伟. 基于动态路径规划的车载自组织网络贪婪路由协议[J]. 国外电子测量技术, 2020, 39(11): 46-51.
- [20] 陈颖, 刘峥莹, 肖春艳, 等. 基于麻雀搜索算法的土壤重金属 X 射线荧光光谱重叠峰解析[J]. 光谱学与光谱分析, 2021, 41(7): 2175-2180.
- [21] CANDANEDO L. Appliances energy prediction Data Set[DB/OL]. (2017-02-15)[2021-07-12]. <http://archive.ics.uci.edu/ml/datasets/Appliances+energy+prediction>.
- [22] 姚栋方, 吴瀛, 罗磊, 等. 基于深度学习的短期电力负荷预测[J]. 国外电子测量技术, 2020, 39(1): 44-48.
- [23] 夏飞, 张洁, 张浩, 等. 基于 BIC 准则和加权皮尔逊距离的居民负荷模式精细识别及预测[J]. 电子测量与仪器学报, 2020, 34(11): 33-42.
- [24] 刘士进, 孙立华, 郭鹏. 基于 EEDM-Arima 算法的某地区电力系统负荷预测及算例分析[J]. 电子测量技术, 2020, 43(7): 185-188.

### 作者简介

杨邓, 硕士研究生, 主要研究方向为智能电网、负荷预测等。

E-mail: 1051011670@qq.com