

DOI: 10.19783/j.cnki.pspc.211526

基于 CEEMD-FE 和 AOA-LSSVM 的短期电力负荷预测

杨海柱¹, 田馥铭¹, 张鹏², 石剑¹

(1. 河南理工大学, 河南 焦作 454000; 2. 天津大学, 天津 300072)

摘要: 针对电力负荷预测精度不高、效率低的问题, 采用算术优化算法(AOA)和最小二乘支持向量机(LSSVM)的模型对经过互补集合经验模态分解(CEEMD)和模糊熵(FE)综合处理后的子序列进行预测, 构建了 CEEMD-FE-AOA-LSSVM 预测模型。首先, 利用 FE 算法对经过 CEEMD 处理后的各子序列进行熵值重组, 该过程提高了模型的抗干扰能力和运算效率。然后, 用 AOA-LSSVM 模型对处理后的子序列进行预测, 并将预测叠加输出。最后, 通过误差函数对模型进行横向对比和纵向对比, 利用两种对比结果来检验其性能。通过实验可知, 与 CEEMD-LSSVM、AOA-LSSVM、CEEMD-AOA-LSSVM 等其他模型相比, CEEMD-FE-AOA-LSSVM 组合模型能够兼顾到预测精度与预测效率两方面, 做到了综合性能的提升。同时也验证了经过 CEEMD 或 AOA 处理的模型能够有效地提升预测精度。

关键词: 算术优化算法; 最小二乘支持向量机; 组合模型; 短期负荷预测

Short-term load forecasting based on CEEMD-FE-AOA-LSSVM

YANG Haizhu¹, TIAN Fuming¹, ZHANG Peng², SHI Jian¹

(1. Henan Polytechnic University, Jiaozuo 454000, China; 2. Tianjin University, Tianjin 300072, China)

Abstract: In view of the low accuracy and low efficiency of load forecasting, sub-sequence undergoing processing of complementary ensemble empirical mode decomposition (CEEMD) and fuzzy entropy (FE) is predicted using a model of arithmetic optimization algorithm (AOA) and least squares support vector machines (LSSVM). The CEEMD-FE-AOA-LSSVM prediction model is then constructed. First, the FE algorithm is used to reconstruct the entropy value of each sub-sequence after CEEMD processing. This improves the anti-interference ability and computing efficiency of the model. Then, the AOA-LSSVM model is used to predict each sub-sequence after comprehensive treatment, and the prediction is superimposed on the output. Finally, the model is compared horizontally and longitudinally by the error function, and its performance is tested using the two comparison results. Through experiments, compared with CEEMD-LSSVM, AOA-LSSVM and CEEMD-AOA-LSSVM, CEEMD-FE-AOA-LSSVM combination model can take into account both prediction accuracy and efficiency, and improve the overall performance. At the same time, it is verified that the model processed by CEEMD or AOA can effectively improve prediction accuracy.

This work is supported by the National Natural Science Foundation of China (No. 51807133).

Key words: arithmetic optimization algorithm (AOA); LSSVM; combination model; short-term load forecasting

0 引言

电力负荷预测一直都是一个重要的研究课题, 它担负着电力系统规划和经济运行的重任^[1-4], 而该研究的关键是对短期电力负荷的预测。短期电力负荷预测既是电力部门调节发电计划的依据, 也是电

网高效经济运行的保障。为了提高社会效益, 准确地进行短期负荷预测至关重要。

多年来, 关于电力负荷预测的研究有很多, 有回归分析法^[5]、神经网络法^[6-8]、支持向量机^[9-10]等, 还有组合预测方法^[11-13]。传统预测方法具有运算量小、运算过程简单等优点, 但很难处理较为复杂多变的数据。智能预测方法可以对复杂的数据进行有效处理, 但面对庞大数据时, 预测不稳定, 易受外界干扰, 泛化能力差。这两种预测方法都避免不了

基金项目: 国家自然科学基金项目资助(51807133); 天津市自然科学基金项目资助(19JQNJC06100)

单一模型的局限性, 预测效果通常不理想, 不利于现代预测需求。组合预测模型可以通过信号分解和参数寻优等方式改善负荷预测性能。文献[14]利用分段粒子群对经过集合经验模态分解(EEMD)处理后的子序列进行优化, 从而达到组合预测效果, 避免了经验模态分解出现模态混叠现象, 但 EEMD 存在重构信号和残余辅助噪声等问题; 文献[15]利用粒子群算法(PSO)优化最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM), 提高了模型的预测精度, 但传统的 PSO 在寻优过程中易陷入早熟; 文献[16]采用门控循环单元神经网络和线性回归组合的预测方法, 对经过 EEMD 处理后的序列进行预测, 提高了负荷预测的精度, 但子序列较多、运行较慢, 不利于数据庞大的预测, 很难得到进一步推广; 文献[17]采用 EEMD 和样本熵对负荷序列进行分解再重构, 并利用 PSO 优化核极限学习机对负荷进行区间预测, 该方法通过重构序列分量提高了运算速度, 简化了预测复杂程度, 但样本熵对参数的选取比较严格, 鲁棒性较差。

近几年人们为了提高机器学习参数优化的能力, 提出了多种新型元启发式算法。文献[18]提出的算术优化算法(Arithmetic Optimization Algorithm, AOA)是一种元启发式优化算法, 相较于传统的优化算法寻优能力更强、迭代速度更快。因此, 引入 AOA-LSSVM 模型对经过互补集合经验模态分解(Complementary Ensemble Empirical Mode Decomposition, CEEMD)和模糊熵(Fuzzy Entropy, FE)综合处理后的子序列进行预测, 构建 CEEMD-FE-AOA-LSSVM 组合预测模型。通过 CEEMD 对历史负荷进行分解, 再用 FE 算法根据分解后各序列的熵值进行重组, 最后用 AOA-LSSVM 模型对处理后的子序列进行预测, 并叠加输出。

1 CEEMD-FE

1.1 CEEMD 原理

经验模态分解(EMD)能够将原序列分解为若干个频率不同且相互独立的本征模态函数(IMF)分量和 1 个残余分量(Re)^[19]。其分解后的序列为

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

式中: $x(t)$ 为原始一维信号; $C_i(t)$ 为 IMF 分量; $r_n(t)$ 为 Re 分量。

EEMD 是针对 EMD 存在模态混叠现象而做出的改进^[20], 在 EMD 分解前对原始序列多次添加高斯白噪声, 但 EEMD 会产生残余辅助噪声和重构误差, 而 CEEMD 通过添加成对高斯白噪声^[21], 减少

了残余辅助噪声, 且分解后的重构误差相对较小。

$$\begin{cases} x_i^+(t) = x(t) + \mu_i^+(t) \\ x_i^-(t) = x(t) + \mu_i^-(t) \end{cases} \quad (2)$$

式中, $x_i^+(t)$ 、 $x_i^-(t)$ 分别为添加随机高斯白噪声后的正负序列。

将每次正负序列经过 EMD 分解得到 IMF 分量和 Re 分量, CEEMD 的最终分解结果为

$$IMF_j = \frac{1}{2n} \sum_{i=1}^n (IMF_{ij} + IMF_{-ij}) \quad (3)$$

$$r = \frac{1}{2n} \sum_{i=1}^n (r_i + r_{-i}) \quad (4)$$

1.2 FE 的基本原理

FE 是在样本熵(Sample Entropy, SE)的基础上通过引入模糊隶属度函数所做出的改进, 它不仅保留了 SE 在测量时间序列复杂性方面好的特性, 还改善了 SE 对相关参数取值较为敏感的问题, 其鲁棒性更好^[22-23]。FE 基本流程如下所述。

1) 对序列 u 进行重构

$$s^m[i] = \{u(i), u(i+1), \dots, u(i+m-1)\} - u_0(i) \quad (5)$$

式中: m 为相空间维数; $i = 1, 2, \dots, N - m + 1$ 。

$$u_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} u(i+j) \quad (6)$$

2) 引入模糊隶属函数

$$A_{ij}^m = \exp(-\ln(2) \cdot (d_{ij}^m / r)^2) \quad (7)$$

式中, r 为相似容限度。

3) d_{ij}^m 为

$$d_{ij}^m = d[s^m[i], s^m[j]] = \max_{p=1, 2, \dots, m} (|u(i+p-1) - u_0(i)| - |u(j+p-1) - u_0(j)|) \quad (8)$$

4) 令 $C_i^m(r)$ 为

$$C_i^m(r) = (N - m)^{-1} \sum_{j=1, j \neq i}^{N-m+1} A_{ij}^m \quad (9)$$

式中, N 为时间序列长度。

5) 定义函数

$$\phi^m(r) = (N - m + 1)^{-1} \sum_{i=1}^{N-m+1} C_i^m(r) \quad (10)$$

6) 当 N 为有限值时, FE 计算值为

$$FE(m, r, N) = \ln \phi^m(r) - \ln \phi^{m+1}(r) \quad (11)$$

2 算术优化算法及算法性能

2.1 AOA 的基本原理

AOA 是 2021 年提出的元启发式优化算法, 它基于四则混合运算思想, 利用数学中的乘除运算提高位置更新的全局分散性, 利用加减运算提高位置

更新在局部区域的精确性。该算法主要分为三部分：
(1) 通过数学优化器加速函数选择优化策略；(2) 探索阶段，通过乘法和除法策略实现全局探索，增强全局寻优能力和克服早熟收敛能力；(3) 开发阶段，通过加法和减法策略实现局部探索，增强局部寻优能力。AOA 优化过程如下所述。

1) 通过数学优化器加速函数(Math Optimizer Accelerated, MOA)选择探索阶段，当 $r_1 > MOA$ 时，进行全局探索阶段，当 $r_1 < MOA$ 时，进行局部开发阶段。其中 r_1 是 0 到 1 之间的随机数。

$$MOA(t) = M_{\min} + t \cdot \frac{M_{\max} - M_{\min}}{T} \quad (12)$$

式中： M_{\max} 和 M_{\min} 分别代表 MOA 的最大值和最小值，本文选取为 1 和 0.2； t 为当前迭代次数； T 为总迭代次数。

2) 乘除算法全局探索过程，当 $r_2 < 0.5$ 时，执行除法探索策略，当 $r_2 \geq 0.5$ 时，执行乘法探索策略。

$$X(t+1) = \begin{cases} \frac{X_b(t)}{MOP + \xi} \cdot ((UB - LB) \cdot u + LB), r_2 < 0.5 \\ X_b(t) \cdot MOP \cdot ((UB - LB) \cdot u + LB), r_2 \geq 0.5 \end{cases} \quad (13)$$

式中： r_2 同 r_1 ； ξ 为极小值，防止分母为 0； u 是调整搜索过程的控制参数，取值为 0.499；数学优化器概率(Math Optimizer Probability, MOP)公式为

$$MOP(t+1) = 1 - \frac{t^\alpha}{T^\alpha} \quad (14)$$

式中， α 为敏感参数，代表了迭代过程中的局部开发精度，取值为 5。

3) 加减算法局部探索过程，当 $r_3 < 0.5$ 时，执行减法探索策略，当 $r_3 \geq 0.5$ 时，执行加法探索策略。

$$X(t+1) = \begin{cases} X_b(t) - MOP \cdot ((UB - LB) \cdot u + LB), r_3 < 0.5 \\ X_b(t) + MOP \cdot ((UB - LB) \cdot u + LB), r_3 \geq 0.5 \end{cases} \quad (15)$$

式中， r_3 是 0 到 1 之间的随机数。

2.2 AOA 函数性能测试

为了更加直观地表现出 AOA 的整体性能，分别选取 PSO 算法、遗传算法(GA)、蝗虫优化算法(GOA)同 AOA 算法进行函数比较实验。实验条件：种群数为 10，迭代次数为 300。函数如式(16)，其函数相关参数如表 1，算法平均最优适应度对比如表 2(数值为 30 次平均值)。

表 1 测试函数及其相关参数

	函数	范围	最小值
单模态函数	f_1	[-100,100]	0
	f_2	[-10,10]	0
多模态函数	f_3	[-5.12,5.12]	0
	f_4	[-32,32]	0
固定维数多模态函数	f_5	[-5,5]	-1.031 6

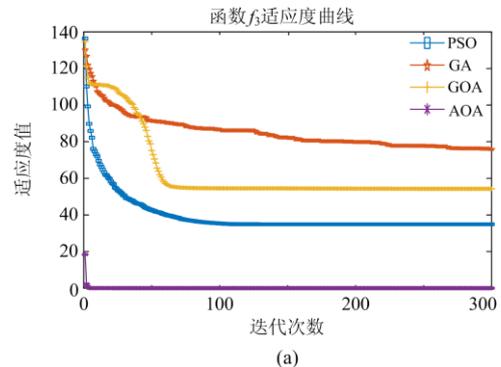
$$\begin{cases} f_1 = \sum_{i=1}^n x_i^2 \\ f_2 = \sum_{i=1}^n |x_i| + \prod_{i=1}^n |x_i| \\ f_3 = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10] \\ f_4 = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e \\ f_5 = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4 \end{cases} \quad (16)$$

表 2 各算法的数据对比

	AOA	GA	PSO	GOA
f_1	0	0.531 8	0.231 4	$2.308 4 \times 10^{-10}$
f_2	0	0.100 5	$1.599 5 \times 10^{-12}$	$1.411 7 \times 10^{-6}$
f_3	0	75.982 1	34.880 8	54.265 3
f_4	$8.881 8 \times 10^{-16}$	17.053 7	10.382 7	8.750 2
f_5	-1.031 6	-1.020 8	-1.031 6	-0.646 1

从表 2 可以看出，AOA 综合表现最优，其次是 PSO 与 GOA，而 GA 综合表现最差。如图 1 选取函数 f_3 和 f_4 下的收敛曲线进行观察。

评价算法优劣的标准可以归为以下两种：一种是在相同迭代次数下，最低的适应度值代表最优，但是这种条件下通常是局部最优；另一种是在最大迭代次数下，最先达到全局最优代表性能最好。由图 1 可知，AOA 在迭代开始就几乎达到全局最优，性能远超其他算法。



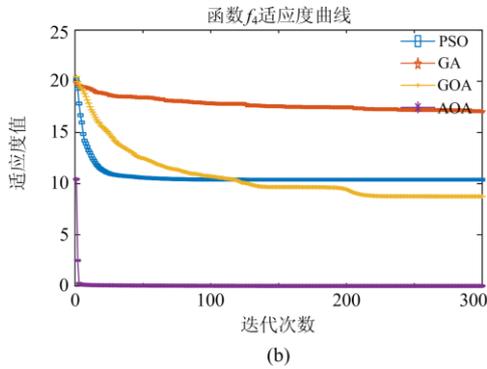


图 1 两种函数的适应度曲线

Fig. 1 Fitness curves for the two functions

3 基于 CEEMD-FE-AOA-LSSVM 的预测模型

3.1 最小二乘支持向量机模型

LSSVM 是在支持向量机(SVM)的基础上做出的一种改进^[24], 其回归函数为

$$f(x) = \omega^T \cdot x + b \quad (17)$$

式中, ω 是权值向量。目标函数及约束条件为

$$\min J(\omega, e) = \frac{1}{2} \omega^T \omega + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2 \quad (18)$$

$$y_i = \omega^T \cdot x_i + b + e_i \quad (19)$$

式中, γ 为正则化参数。

拉格朗日函数为

$$L(\omega, b, e, \alpha) = J(\omega, e) - \sum_{i=1}^n \alpha_i (\omega^T \cdot x_i + b + e_i - y_i) \quad (20)$$

L 经过偏微分处理, 其回归函数为

$$y = \sum_{i=1}^n \alpha_i \cdot x_i + b = \sum_{i=1}^n \alpha_i K(x, x_i) + b \quad (21)$$

$K(x, x_i)$ 为核函数, 公式如式(22)所示。

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (22)$$

式中, σ 为核参数。

σ 和 γ 都是 LSSVM 的重要控制参数, 本文通过 AOA 来优化这两个参数, 从而提高 LSSVM 算法的抗干扰能力和泛化能力。

3.2 基于 AOA 优化 LSSVM 参数的模型

为了减少数值差距带来的影响, 对原始电力负荷进行归一化处理, 如式(23)所示。

$$y_i = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (23)$$

式中, y_{\max} 和 y_{\min} 分别为原始数据集的最大负荷值和最小负荷值。

处理后的数据分为训练集和测试集, 在迭代次数和种群数选取后由训练集学习, 测试集进行预测。下面采用平均绝对误差(MAE)、均方根误差(RMSE)和平均绝对百分比误差(MAPE)进行评价^[25], 如式(24)所示。

$$\begin{cases} MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \\ RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \\ MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \end{cases} \quad (24)$$

3 个评价标准中 MAPE 作为主要评价标准, 其余两个作为辅助评价标准。根据评价标准, 构造 AOA 优化 LSSVM 参数模型, 流程图如图 2 所示。

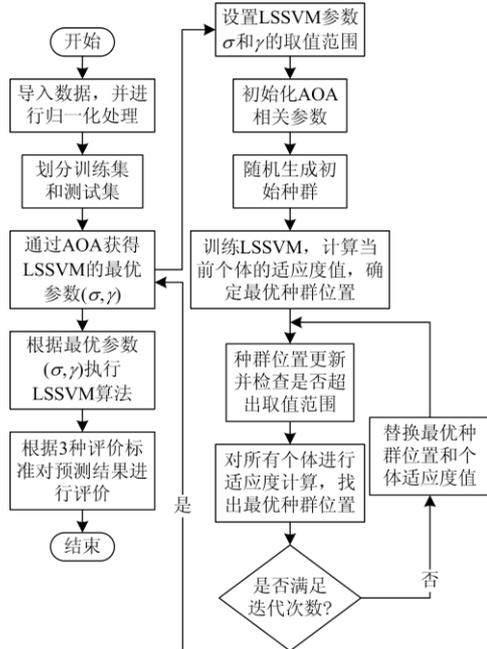


图 2 基于 AOA-LSSVM 组合模型的流程图

Fig. 2 Flow chart based on AOA-LSSVM combined model

基于 AOA 优化 LSSVM 参数 σ 和 γ 具体操作步骤如下。

- 1) 设置目标参数 σ 和 γ 的取值范围。
- 2) 初始化 AOA 优化变量的维度、种群数、加速函数的最大值和最小值、最大迭代次数、局部开发精度以及调整搜索过程的控制参数。
- 3) 随机生成种群, 其初始位置代表参数 (γ, σ) 初始值, 并根据式(24)求解初始个体适应度值, 通过比较各适应度值得出当前最佳种群位置 X_{fit} 。
- 4) 通过式(12)来判断初始种群是进行探索阶段还是开发阶段, 并根据式(13)一式(15)对初始种群位置更新。

步骤五：对更新后的种群进行比较，适应度最低的作为最优种群位置，并判断是否满足迭代条件。

步骤六：将迭代结束产生的最优值作为 LSSVM 的参数 (γ, σ) 进行模型预测。

3.3 组合预测模型

直接利用 AOA 优化 LSSVM 模型进行负荷预测，波动性通常很大，很大一部分原因是负荷数据易受到外界干扰。本文通过 CEEMD 将原始负荷数据分解为多个 IMF 分量和 Re 分量，提高了预测模型的抗干扰性，同时也改善了 EMD 和 EEMD 算法存在的不足，很好地解决了上述问题。但对原始负荷分解，一般 IMF 分量很多，运行时间很长。因此，为了解决这一新的问题，本文引入模糊熵来对分解出来的 IMF 分量和 Re 分量进行熵值计算，对计算结果相近的 IMF 进行重构。这样处理既解决了运算时间太长的问题也保证了预测模型的精确度。基于 CEEMD-FE-AOA-LSSVM 的短期电力负荷预测模型具体步骤如下：

- 1) 对经过 CEEMD 处理后的负荷子序列，利用 FE 算法对各分量进行熵值评价，重新组合成新的 IMF 分量集。
- 2) 将新的各 IMF 分量通过优化模型 AOA-LSSVM 进行预测，得到多个预测分量。
- 3) 对 2) 中的结果进行叠加输出最终值。
- 4) 对最终预测值和真实值代入式(24)进行误差分析。

本文所采用的组合方法流程图如图 3 所示。

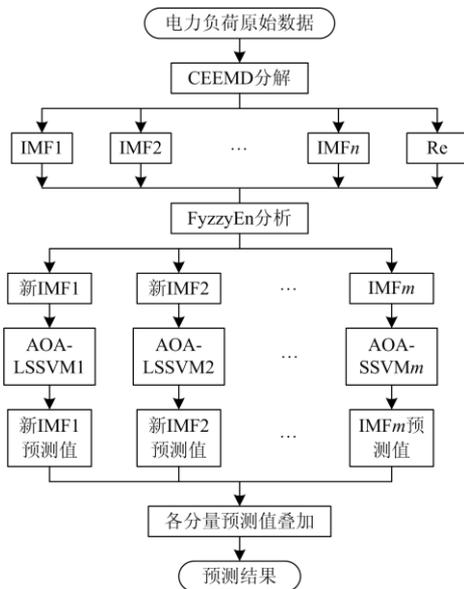


图 3 基于 CEEMD-FE-AOA-LSSVM 组合方法的流程图

Fig. 3 Flow chart based on CEEMD-FE-AOA-LSSVM combination method

4 实例仿真

以河南省焦作市某县 2019 年 1 月份电力负荷数据为例，如图 4 所示，采样时间段为：1 月 1 日—1 月 15 日，采样间隔 15 min，前 1 344 个数据为训练集，后 96 个数据为测试集。

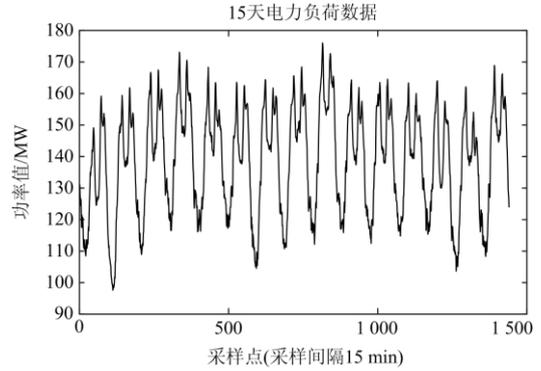


图 4 某县 2019 年 1 月份电力负荷数据

Fig. 4 Power load data of a county in January 2019

4.1 原始数据的 CEEMD-FE 分解实验

如图 5 所示为原始负荷数据经过 CEEMD 处理后的子序列。

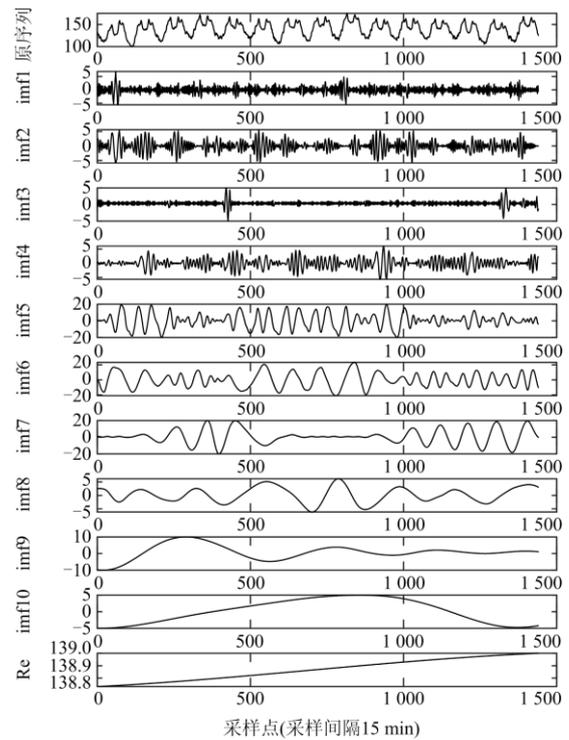


图 5 CEEMD 电力负荷的分解结果

Fig. 5 CEEMD decomposition results of power load

求解 CEEMD 分解出的各分量的模糊熵值，如图 6 所示。

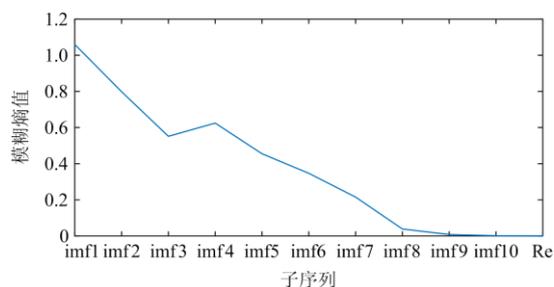


图 6 各子序列分量模糊熵值

Fig. 6 Fuzzy entropy of each subsequence component

由图 6 可知, imf8—Re 模糊熵值非常接近, 故组合成新的序列分量。各序列分量组合如表 3。

表 3 各序列的重新组合

Table 3 Recombination of sequences

IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
Imf1	Imf2	Imf3	Imf4	Imf5	Imf6	Imf7	Imf8+imf9+imf10+Re

重新组合后的分解结果如图 7 所示。

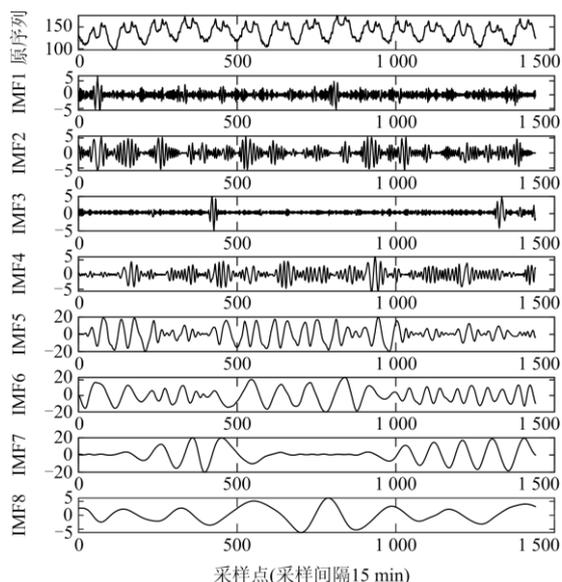


图 7 CEEMD-FE 电力负荷的分解结果

Fig. 7 CEEMD-FE decomposition results of power load

4.2 基于 CEEMD-FE-AOA-LSSVM 的短期负荷预测实验

以下用两种组合搭配来验证本文组合模型的有效性。第一种组合搭配是横向对比, 分别建立 LSSVM、CEEMD-LSSVM、CEEMD-FE-LSSVM、AOA-LSSVM、CEEMD-AOA-LSSVM、CEEMD-FE-AOA-LSSVM 6 种模型并通过式(24)进行误差评价。如图 8 为 6 种模型对比, 如表 4 是对 6 种模型的误差评价。

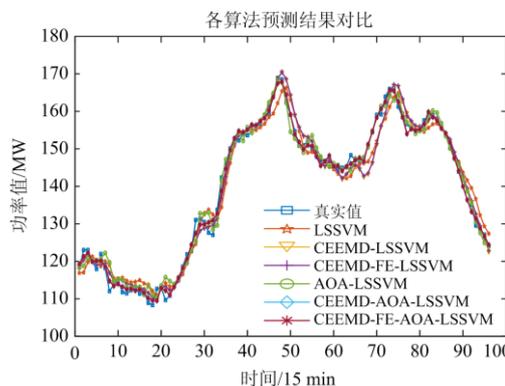


图 8 横向预测结果对比

Fig. 8 Comparison of horizontal prediction results

由表 4 可以看出, 单一模型 LSSVM 预测效果最差, 经过 CEEMD 的序列分解或引入 AOA 参数寻优对预测结果的精度都有明显的提高。但是不加入 AOA 优化的 CEEMD-LSSVM 模型和未经过 CEEMD 处理的 AOA-LSSVM 模型在预测精度上都不如 CEEMD-AOA-LSSVM。为了做进一步优化, 本文模型加入 FE 算法进行对比。无论是 CEEMD-LSSVM 和 CEEMD-FE-LSSVM 对比还是 CEEMD-AOA-LSSVM 和 CEEMD-FE-AOA-LSSVM 对比, 3 种误差评价相差都很小, 甚至 CEEMD-FE-LSSVM 的预测误差要比 CEEMD-LSSVM 的预测误差小 0.006 3%, 而且 CEEMD-FE-AOA-LSSVM 的预测误差仅仅比 CEEMD-AOA-LSSVM 的预测误差高 0.000 17%, 几乎可以忽略不计。但是在时间上, 本文的组合模型 30 次运行时间的平均值为 104.307 37 s, 远远小于 CEEMD-AOA-LSSVM 组合模型 30 次运行时间平均值的 141.039 02 s, 节省了大量时间。由此证明组合模型 CEEMD-FE-AOA-LSSVM 的有效性。

表 4 横向仿真结果

Table 4 Horizontal simulation results

模型	RMSE/MW	MAE/MW	MAPE/%
LSSVM	3.350 0	2.736 8	1.990 90
CEEMD-LSSVM	2.755 9	2.067 2	1.477 40
CEEMD-FE-LSSVM	2.744 8	2.062	1.471 10
AOA-LSSVM	2.234 7	1.620 3	1.217 80
CEEMD-AOA-LSSVM	1.379 4	1.068 4	0.791 70
CEEMD-FE-AOA-LSSVM	1.379 5	1.068 6	0.791 87

第二种组合搭配是纵向对比, 分别建立 CEEMD-FE-PSO-LSSVM、CEEMD-FE-GA-LSSVM 和 CEEMD-FE-GOA-LSSVM 这 3 种组合模型同本文模型对比。如图 9 为 4 种模型对比, 如表 5 是对

4 种模型的误差评价。

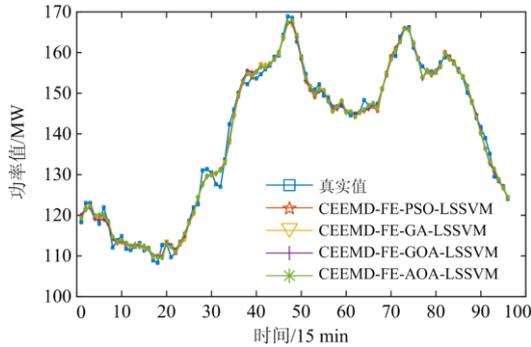


图 9 纵向预测结果对比

Fig. 9 Comparison of longitudinal prediction results

表 5 纵向仿真结果

Table 5 Longitudinal simulation results

模型	RMSE/MW	MAE/MW	MAPE/%
CEEMD-FE-GA-LSSVM	1.440 0	1.116 2	0.821 66
CEEMD-FE-GOA-LSSVM	1.432 3	1.108 3	0.819 74
CEEMD-FE-PSO-LSSVM	1.451 5	1.108 4	0.812 09
CEEMD-FE-AOA-LSSVM	1.379 5	1.068 6	0.791 87

由表 5 可知, CEEMD-FE-AOA-LSSVM 模型的 RMSE、MAE 和 MAPE 均最低, 其中 MAPE 比 CEEMD-FE-PSO-LSSVM 低了 0.020 22%, 比 CEEMD-FE-GOA-LSSVM 低了 0.027 87%, 比 CEEMD-FE-GA-LSSVM 低了 0.029 79%。由此可知, 经过 AOA 优化的模型预测效果最好。

5 结论

本文针对电力负荷变化的周期性和波动性提出了一种基于 CEEMD-FE-AOA-LSSVM 的短期电力负荷预测方法, 结论如下:

1) 在 CEEMD 的优势基础上增加模糊熵值评价, 将复杂度相近的归为一类, 即保证了预测精度也兼顾了预测速率。但仍会有少量的噪声信号, 需要进一步改进。

2) 本文通过采用寻优能力强, 收敛速度快的 AOA 对 LSSVM 模型的两个参数进行优化, 解决了 LSSVM 参数较难确定的问题, 同时在寻优性能方面也比以往的优化算法更好, 能够较大地提升预测的精确度。

3) 组合模型 CEEMD-FE-AOA-LSSVM 在预测精度方面要比一般的单一模型或没有深度处理的组合模型更高, 适合在电网运行中进一步推广。但目前该模型的应用场景较少, 不具有权威性, 需要更多应用场景进行验证。

参考文献

- [1] 周潮, 邢文洋, 李宇龙. 电力系统负荷预测方法综述[J]. 电源学报, 2012(6): 32-39.
ZHOU Chao, XING Wenyang, LI Yulong. Summarization on load forecasting method of electrical power system[J]. Journal of Power Supply, 2012(6): 32-39.
- [2] 廖旋煊, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152.
LIAO Nihuan, HU Zhihong, MA Yingying, et al. Review of the short-term load forecasting methods of electric power system[J]. Power System Protection and Control, 2011, 39(1): 147-152.
- [3] 朱文广, 李映雪, 杨为群, 等. 基于 K 折交叉验证和 Stacking 融合的短期负荷预测[J]. 电力科学与技术学报, 2021, 36(1): 87-95.
ZHU Wenguang, LI Yingxue, YANG Weiqun, et al. Short-term load forecasting based on the K fold cross validation and stacking ensemble[J]. Journal of Electric Power Science and Technology, 2021, 36(1): 87-95.
- [4] 龚雪娇, 朱瑞金, 唐波. 基于贝叶斯优化 XGBoost 的短期峰值负荷预测[J]. 电力工程技术, 2020, 39(6): 76-81.
GONG Xuejiao, ZHU Ruijin, TANG Bo. Short-term peak load forecasting based on Bayesian optimization XGBoost[J]. Electric Power Engineering Technology, 2020, 39(6): 76-81.
- [5] ZHAO Jing, LIU Xiaojuan. A hybrid method of dynamic cooling and heating load forecasting for office buildings based on artificial intelligence and regression analysis[J]. Energy & Buildings, 2018, 174: 293-308.
- [6] 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.
- [7] QUAN Hao, SRINIVASAN D, KHOSRAVI A. Short-term load and wind power forecasting using neural network-based prediction intervals[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(2): 303-315.
- [8] 李啸骢, 李春涛, 从兰美, 等. 基于动态权值相似日选取算法的短期负荷预测[J]. 电力系统保护与控制, 2017, 45(6): 1-8.
LI Xiacong, LI Chuntao, CONG Lanmei, et al. Short-term load forecasting based on dynamic weight similar day selection algorithm[J]. Power System Protection and Control, 2017, 45(6): 1-8.
- [9] 谢敏, 邓佳梁, 吉祥, 等. 基于信息熵和变精度粗糙集

- 优化的支持向量机降温负荷预测方法[J]. 电网技术, 2017, 41(1): 210-214.
- XIE Min, DENG Jialiang, JI Xiang, et al. Cooling load forecasting method based on support vector machine optimized with entropy and variable accuracy roughness set[J]. Power System Technology, 2017, 41(1): 210-214.
- [10] 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.
- [11] 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.
- [12] 王凌云, 林跃涵, 童华敏, 等. 基于改进 Apriori 关联分析及 MFOLSTM 算法的短期负荷预测[J]. 电力系统保护与控制, 2021, 49(20): 74-81.
- WANG Lingyun, LIN Yuehan, TONG Huamin, et al. Short-term load forecasting based on improved Apriori correlation analysis and an MFOLSTM algorithm[J]. Power System Protection and Control, 2021, 49(20): 74-81.
- [13] ZHENG Dehua, ESEYE A T, ZHANG Jianhua, et al. Short-term wind power forecasting using a double-stage hierarchical ANFIS approach for energy management in microgrids[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 136-145.
- [14] LIU Zhigang, SUN Wanlu, ZENG Jiajun. A new short-term load forecasting method of power system based on EEMD and SS-PSO[J]. Neural Computing and Applications, 2014, 24(3-4): 973-983.
- [15] 朱霄珣, 韩中合. 基于 PSO 参数优化的 LS-SVM 风速预测方法研究[J]. 中国电机工程学报, 2016, 36(23): 6337-6342, 6598.
- ZHU Xiaoxun, HAN Zhonghe. Research on LS-SVM wind speed prediction method based on PSO[J]. Proceedings of the CSEE, 2016, 36(23): 6337-6342, 6598.
- [16] 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.
- [17] 张林, 刘继春. 基于 EEMD-SE 和 PSO-KELM 的短期负荷区间预测方法[J]. 中国电力, 2021, 54(3): 132-140.
- ZHANG Lin, LIU Jichun. A short-term load interval forecasting method based on EEMD-SE and PSO-KELM[J]. Electric Power, 2021, 54(3): 132-140.
- [18] ABUALIGAH L, DIABAT A, MIRJALILI S, et al. The arithmetic optimization algorithm[J]. Computer Methods in Applied Mechanics and Engineering, 2021, 376: 1-38.
- [19] 周小麟, 童晓阳. 基于 CEEMD-SBO-LSSVR 的超短期风电功率组合预测[J]. 电网技术, 2021, 45(3): 855-864.
- ZHOU Xiaolin, TONG Xiaoyang. Ultra-short-term wind power combined prediction based on CEEMD-SBO-LSSVR[J]. Power System Technology, 2021, 45(3): 855-864.
- [20] WU Zhaohua, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [21] YEH J R, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method[J]. Advances in Adaptive Data Analysis, 2010, 2(2): 135-156.
- [22] CHEN Weiting, WANG Zhizhong, XIE Hongbo, et al. Characterization of surface EMG signal based on fuzzy entropy[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2007, 15(2): 266-272.
- [23] 孙克辉, 贺少波, 尹林子, 等. 模糊熵算法在混沌序列复杂度分析中的应用[J]. 物理学报, 2012, 61(13): 71-77.
- SUN Kehui, HE Shaobo, YIN Linzi, et al. Application of fuzzy entropy algorithm to the analysis of complexity of chaotic sequence[J]. Acta Physica Sinica, 2012, 61(13): 71-77.
- [24] SUYKENS J A K, VANDEWALLE J. Least squares support vector machine classifiers[J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [25] 李辰颖. 基于 CEEMD-SVM 组合模型的快递业务量预测[J]. 统计与决策, 2019, 35(12): 83-85.
- LI Chenying. Prediction of express business volume based on CEEMD-SVM combined model[J]. Statistics & Decision, 2019, 35(12): 83-85.

收稿日期: 2021-11-14; 修回日期: 2022-01-08

作者简介:

杨海柱(1975—), 男, 博士, 副教授, 主要研究方向为电能质量分析和控制以及电力电子学和电力传输; E-mail: 35948436@qq.com

田馥铭(1996—), 男, 通信作者, 硕士研究生, 主要研究方向为电力系统运行与控制和信息处理。E-mail: 634213975@qq.com

(编辑 葛艳娜)