

文章编号: 2095-2163(2023)11-0135-07

中图分类号: TP183;TM715

文献标志码: A

# 基于 NGO-VMD-FCBF-Informer 的电力负荷组合预测模型

蒲 维<sup>1,2</sup>, 杨毅强<sup>1,2</sup>, 张渊博<sup>1,2</sup>, 付江涛<sup>1,2</sup>, 宋 弘<sup>2,3</sup>

(1 四川轻化工大学 自动化与信息工程学院, 四川 宜宾 644000; 2 人工智能四川省重点实验室, 四川 宜宾 644000; 3 阿坝师范学院, 四川 阿坝 623002)

**摘要:** 电力负荷预测对电力系统安全稳定运行至关重要, 现有的预测算法在精度及稳定性方面优化存在着欠缺, 在此提出一种基于 NGO-VMD-FCBF-Informer 电力负荷组合预测模型。为提高原始数据的平稳性, 使用 VMD 算法对原始数据进行分解, 同时利用 NGO 算法对 VMD 的 IMF 分量层数及惩罚因子两个参数进行寻优。针对电力负荷预测受温度、电价等众多不确定性因素影响的问题, 采用 FCBF 算法筛选出相关性程度高的特征变量作为输入变量。最后采用 Informer 网络对各个 IMF 分量进行单独预测, 并对每个 IMF 分量预测结果进行重构叠加得到最终预测结果。同时, 将该模型与其他预测模型进行对比实验分析, 实验结果表明, 该模型均值绝对误差、平均绝对百分比误差及均方根误差均低于列举的预测模型, 能够有效地提高电力负荷的精度。

**关键词:** 北方苍鹰优化算法; 变分模态分解; 特征选择; 电力负荷预测

## Powerload forecasting based on NGO-VMD-FCBF-Informer

PU Wei<sup>1,2</sup>, YANG Yiqiang<sup>1,2</sup>, ZHANG Yuanbo<sup>1,2</sup>, FU Jiangtao<sup>1,2</sup>, SONG Hong<sup>2,3</sup>

(1 School of Automation and Information Engineering, Sichuan University of Science &amp; Engineering, Yibin Sichuan 644000, China; 2 Artificial Intelligence Key Laboratory of Sichuan Province, Yibin Sichuan 644000, China; 3 Aba Teachers University, Aba Sichuan 623002, China)

**Abstract:** Power load forecasting is very important to the safe and stable operation of the power system. The existing forecasting algorithms are lacking in the optimization of accuracy and stability. Here, a power load forecasting model based on NGO-VMD-FCBF-Informer is proposed. In order to improve the stationarity of the original data, the VMD algorithm is used to decompose the original data, and the NGO algorithm is used to optimize the two parameters of the VMD's IMF components and penalty factor. Aiming at the problem that the power load forecast is affected by many uncertain factors such as temperature and electricity price, the FCBF algorithm is used to screen out the characteristic information with high correlation degree as the input information. Finally, the Informer network is used to predict each IMF component separately, and the prediction result of each IMF component is reconstructed and superimposed to obtain the final prediction result. At the same time, the model is compared with other prediction models. The experimental results show that the mean absolute error, mean absolute percentage error and root mean square error of the model are lower than the listed prediction models, which can effectively improve the accuracy of power load.

**Key words:** NGO; VMD; feature selection; power load forecast

## 0 引言

在国内发布“十四五”的规划中, 明确指出加快电网基础设施智能化改造和智能微电网建设, 提高电力系统互补互济和智能调节能力将成为未来的发展方向。电力资源作为一种二次能源, 是其他各行

业健康发展的基石, 高精度的电力负荷预测对整个电力系统经济有效、安全运行起着不容忽视的作用<sup>[1]</sup>。随着新能源汽车等用电设备的数量不断增长, 导致电网的随机性、不确定性、不稳定性进一步提高, 因此, 迫切需要一种稳定性好、预测精度高的电力负荷预测模型。

**基金项目:** 四川省科技厅项目(2022YFS0518, 2022ZHCG0035); 人工智能四川省重点实验室项目(2019RYY01); 企业信息化与物联网测控技术四川省高校重点实验室项目(2020WZY02); 四川理工学院四川省院士(专家)工作站项目(2018YSGZZ04)。

**作者简介:** 蒲 维(1995-), 男, 硕士研究生, 主要研究方向: 电力负荷预测。

**通讯作者:** 杨毅强(1980-), 男, 博士, 讲师, 主要研究方向: 电力系统稳定与控制。Email: 9123915@qq.com

**收稿日期:** 2022-11-10

文献[2-3]分别采用了粒子群算法和遗传算法进行参数优化,虽然对预测精度有所提升,但这2种算法存在收敛速度缓慢,且复杂繁琐的问题。文献[4-5]采用了经验模态分解对原始数据进行分解,但在使用经验模态分解的过程中会伴随有端点效应、模态混叠等情况,而变分模态分解可以有效地避免经验模态分解存在的问题<sup>[6-9]</sup>。文献[10-12]中选用单一的电力负荷数据作为输入特征,未考虑到影响负荷数据的其他因素(如工作日、温度、电价),不能充分提取变量间的信息关系。文献[13-14]中采用循环神经网络(Recurrent Neural Network, RNN)进行预测,该网络能够很好地捕获数据的时序性,但经常伴随着梯度消失、爆炸的问题。文献[1, 3, 11, 15]中采用长短期记忆神经网络(Long Short-Term Memory, LSTM)。LSTM网络是在RNN基础上添加多个阈值门改进的,能够很好地解决RNN网络梯度消失、爆炸的问题,但当原始数据呈现高度线性,且含有噪声时,采用LSTM网络进行预测模型训练会导致过拟合的情况。文献[9, 16]中,采用了BP神经网络(Back propagation, BP)进行训练,其权值和阈值等参数在训练过程中是随机产生的,且BP网络存在学习率低,泛化能力弱,同时极易陷入局部最优的问题<sup>[17]</sup>。

基于已有的研究内容,本文提出了一种新型的预测模型—基于NGO-VMD-FCBF-Informer电力负荷组合预测模型,以解决现有电力负荷预测模型优化方法不够理想的问题,同时对该模型进行了有效性的论证。

## 1 算法原理

### 1.1 北方苍鹰优化算法

Dehghani等学者<sup>[18]</sup>在研究北方苍鹰捕食行为的过程中获得了灵感,由此提出了一种新的搜索算法,并将其命名为北方苍鹰优化算法(Northern Goshawk Optimization, NGO)。该优化算法主要是对北方苍鹰的捕食行为进行模拟,北方苍鹰种群作为NGO算法中的搜索者,种群中每只北方苍鹰需要对目标猎物的捕获问题提出解决方案,NGO算法的优化效果明显强于GWO算法、WOA算法及MPA算法<sup>[18]</sup>。

捕食过程由猎物识别和猎物捕获两个阶段组成。在猎物识别阶段中,北方苍鹰进行全局随机搜索,识别并选择最佳区域猎物,同时发动快速攻击。表达式如下:

$$P_i = X_k \quad (1)$$

$$x_{i,j}^{new,P1} = \begin{cases} x_{i,j} + r(p_{i,j} - Ix_{i,j}) & F_{P_i} < F_i \\ x_{i,j} + r(x_{i,j} - p_{i,j}) & F_{P_i} \geq F_i \end{cases} \quad (2)$$

$$X_i = \begin{cases} x_{i,j}^{new,P1} & F_i^{new,P1} < F_i \\ X_i & F_i^{new,P1} \geq F_i \end{cases} \quad (3)$$

其中, $P_i$ 为第*i*只北方苍鹰的目标猎物位置; $X_k$ 为*K*只北方苍鹰向量组成的矩阵; $x_{i,j}^{new,P1}$ 为新状态第一阶段下第*i*个提议的解决方案的第*j*个维度。 $F_i^{new,P1}$ 为第一阶段的目标函数值; $r$ 为 $[0, 1]$ 区间的随机数; $I$ 也是随机数,其值可以取1或2。

在猎物捕获阶段中,由于猎物试图逃跑,因此存在一个短暂的追逐过程——追尾,然后捕获猎物。这种行为的模拟增加了算法对搜索空间的局部搜索的利用能力。表达式如下:

$$x_{i,j}^{new,P2} = x_{i,j} + R(2r - 1)x_{i,j} \quad (4)$$

$$R = 0.02 \left( 1 - \frac{t}{T} \right) \quad (5)$$

$$X_i = \begin{cases} x_{i,j}^{new,P2}, & F_i^{new,P2} < F_i \\ X_i, & F_i^{new,P2} \geq F_i \end{cases} \quad (6)$$

其中, $R$ 为种群攻击范围半径; $t$ 为当前迭代次数; $T$ 为最大迭代次数; $F_i^{new,P2}$ 为第二阶段的目标函数值。

### 1.2 变分模态分解

变分模态分解(Variational Mode Decomposition, VMD)算法是由Dragomiretskiy等学者<sup>[19]</sup>在2014年提出了一种新型完全非递归的模态信号处理方法。该方法可以通过特定的方式将原始数据分解成若干个不同带宽及频率的本征模态函数(Intrinsic Mode Function, IMF)。

与经验模态分解相比,VMD分解可以有效的避免端点效应及模态混叠的情况,可以更好地提取负荷数据信息,并且,VMD分解的IMF分量层数*K*及惩罚因子 $\alpha$ 可以人为设置,其自适应性明显更强。针对电力负荷数据具有非线性、非平稳性等特点,VMD分解是一种非常适宜的分解方法。

### 1.3 快速相关性滤波算法

快速相关性滤波算法(Fast Correlation-Based Filter, FCBF)作为一种典型基于相关性分析的特征选择方法之一,能有效衡量2个特征变量之间相关性,其评判标准为对称不确定性(Symmetrical Uncertainty, SU),以此筛选出与目标特征变量相关性高的特征变量<sup>[20]</sup>。

在相关信息量中引入熵作为随机特征*X*与*Y*不

确定性的度量,通过熵的定义可以将特征  $X$  的熵进行表达,则可进一步表达出同时满足特征  $X$  与  $Y$  的条件熵。表达式如下:

$$H(X) = - \sum_i P(x_i) \log_2(P(x_i)) \quad (7)$$

$$H(X|Y) = - \sum_j P(y_j) \sum_i P(x_i|y_j) \log_2(P(x_i|y_j)) \quad (8)$$

其中,  $P(x_i)$ 、 $P(y_j)$  分别表示当随机特征  $X$  与  $Y$  取  $x_i$ 、 $y_j$  值的概率。

引入信息增益 (Information Gain,  $IG$ ) 来表达在特征  $X$  熵减 ( $Y$  提供的关于  $X$  的额外信息), 表达式如下:

$$IG(X|Y) = H(X) - H(X|Y) \quad (9)$$

可得出  $SU$  的表达式:

$$SU(X, Y) = 2 \frac{IG(X|Y)}{H(X) + H(Y)} \quad (10)$$

其中,  $SU$  的取值范围为  $(0, 1)$ , 且值越大表示 2 个特征变量之间相关性程度越高。

#### 1.4 Informer 模型

研究表明, Transformer 在提高预测精度方面具有潜力, 但 Transformer 存在二次时间复杂度、高内存使用量和编码器-解码器体系结构固有的局限性等问题。为了解决这些问题, Informer 模型应运而生<sup>[21]</sup>, 该模型对 Transformer 原有的自注意力机制进行了概率稀疏化, 降低了计算复杂度, 并有效提高了序列预测的准确度<sup>[22]</sup>。Informer 模型结构如图 1 所示。

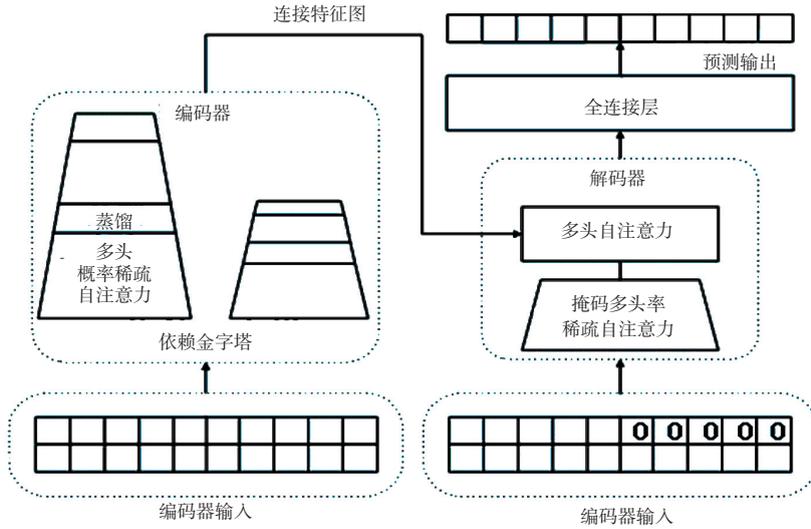


图 1 Informer 模型结构图

Fig. 1 Informer model structure diagram

##### 1.4.1 稀疏自注意力机制

与传统的自注意力机制相比, 稀疏自注意力机制在将传统的自注意力机制的  $Q$  (Query) 进行稀疏化操作得到新的  $\tilde{Q}$ 。稀疏自注意力机制的公式如下:

$$A(Q, K, V) = \text{softmax} \left( \frac{Q\tilde{K}^T}{\sqrt{d}} \right) V \quad (11)$$

其中,  $A$  表示 Attention 机制;  $Q, K, V$  表示由输入变量线性变换获得的相同行列的 3 个矩阵;  $T$  表示矩阵的转置;  $\text{softmax}$  表示激活函数;  $d$  表示变量输入维度。

##### 1.4.2 编码器

编码器 (Encoder) 由数量若干部的多头概率稀疏自注意力和“蒸馏” (Distilling) 共同构成, 是用来接

受输入端长时间序列数据输入, 同时从输入中获取数据的长期依赖性。自注意力蒸馏机制公式如下:

$$X_{j+1}^t = \text{MaxPool}(\text{ELU}(\text{Conv1d}([X_j^t]_{AB}))) \quad (12)$$

其中,  $X_j^t$  表示目标序列的占位符;  $\text{MaxPool}$  表示最大池化层;  $\text{ELU}$  表示激活函数;  $\text{Conv1d}()$  表示一维时间序列操作;  $[\cdot]_{AB}$  表示多头概率稀疏自注意力的基础运算。

##### 1.4.3 解码器

解码器 (Decoder) 由一个多头自注意力和一个掩码多头稀疏自注意力共同构成, 采用生成式预测方式来缓解长序列预测时的速度过慢的问题。公式如下:

$$X_{\text{feed\_de}}^t = \text{Concat}(X_{\text{token}}^t, X_0^t) \in R^{(L_{\text{token}} + L_y) \times d_{\text{model}}} \quad (13)$$

其中,  $X'_{token}$  表示 *start token*;  $L$  为时间序列的长度。

## 2 基于 NGO-VMD-FCBF-Informer 的电力负荷组合预测模型

### 2.1 实验数据

#### 2.1.1 数据选取

本文选取某地 2010 年 7 月至 9 月期间电力负荷数据集,其负荷数据信息采样间隔为 30 min,采集共计 4 415 组负荷数据。在此,选取 2010 年 7 月 1 日至 9 月 20 日,共计 3 936 组数据作为训练集,选取 2010 年 9 月 21 日至 30 日,共计 479 组数据作为测试集。

该数据集包含了 7 个实时特征变量及电力负荷信息,其中包括 2 个时间序列特征变量:时间点与星期变量;4 个气象特征变量:干球温度、露点温度、湿球温度及湿度变量;1 个市场特征变量:电价变量。

#### 2.1.2 数据预处理

由于原始数据的输入特征变量在数值上可能存在相差几个量级的问题,这将导致数量级大的特征变量在学习算法中占据主导地位,从而忽略了针对量级小的特征变量的学习。为了解决量纲上存在差距造成的影响,同时提高算法的收敛速度及预测精度的问题,本文选用 Min-Max 归一化对负荷数据进

行归一化处理。归一化公式如下:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (14)$$

其中,  $X_{\max}$  和  $X_{\min}$  分别为原始数据中的最大值及最小值;  $X'$  为归一化处理后的数据值。

#### 2.1.3 性能评价指标

本文选用了均值绝对误差 (*MAE*)、平均绝对百分比误差 (*MAPE*) 及均方根误差 (*RMSE*) 三个指标作为实验负荷预测结果精度的衡量标准。性能评价指标的数值越低,表明该模型的预测精度越精准。性能评价指标的公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |h_i - h_p| \quad (15)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{h_p - h_i}{h_i} \right| \quad (16)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (h_i - h_p)^2} \quad (17)$$

其中,  $h_p$ 、 $h_i$  分别表示  $t=i$  的预测值和实际值。

## 2.2 基于 NGO-VMD-FCBF-Informer 的电力负荷组合预测模型流程

基于 NGO-VMD-FCBF-Informer 的电力负荷组合预测模型流程如图 2 所示。整个预测流程由 2 个部分共同组成: NGO 算法优化 VMD 分解部分及 FCBF-Informer 电力负荷预测部分。

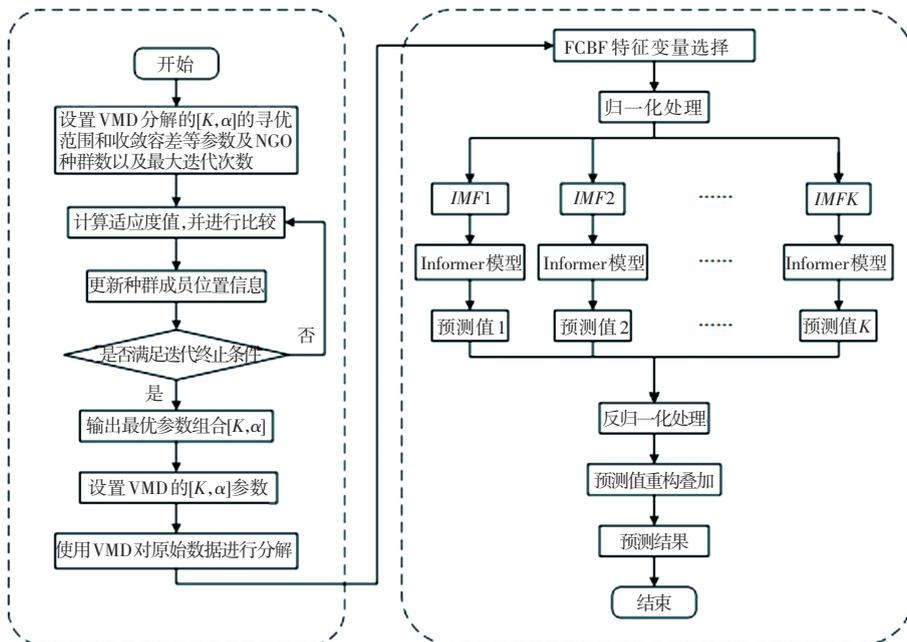


图 2 NGO-VMD-FCBF-Informer 组合预测模型流程图

Fig. 2 Flow chart of NGO-VMD-FCBF-Informer combination prediction model

### 2.2.1 NGO-VMD(OVMD)

在使用 VMD 分解对原始数据进行处理前,需要手动设置  $IMF$  分量层数  $K$  及惩罚因子  $\alpha$ 。由于这 2 个参数在 VMD 分解中占据着主导地位,对分解的结果起着决定性的作用,如若参数设置不当将导致后续步骤难以进行<sup>[22]</sup>。纵然研究人员可以凭借经验对 2 个参数进行预先设置,但人为设置参数会存在主观性、随机性等问题。且参数往往需要多次设置、直至较优,该过程繁琐且费时费力,并且人为确定的最终参数极大可能会逊于 NGO 算法寻优确定的参数,这将导致 VMD 分解不充分,原始数据的非线性、非平稳性不能得到最大程度的缓解。因此,本文选用 NGO 算法对 VMD 分解的  $IMF$  分量层数  $K$  及惩罚因子  $\alpha$  进行寻优,OVMD 部分的主要工作是对原始数据进行分解处理。采用 NGO 算法优化 VMD 分解的  $[K, \alpha]$  参数组合具体步骤如下。

(1) 设置 VMD 分解的收敛容差等基本参数。

(2) 设置 NGO 算法的种群数及最大迭代次数;选用样本熵局部最小值作为 NGO 算法适应度函数。

(3) 设置 VMD 分解的  $[K, \alpha]$  参数组合寻优范围。

(4) 利用 VMD 对原始信号进行分解处理,同时计算出寻优范围内不同  $[K, \alpha]$  参数组合的适应度值。

(5) 随着迭代的进行,利用 NGO 算法的优化机制不断更新出种群个体的位置信息。

(6) 循环(4)~(5)的步骤,直至获得了最优  $[K, \alpha]$  参数组合或者迭代次数达到预设最大迭代次数。

(7) 输出当前最优  $[K, \alpha]$  参数组合。

本文设置  $IMF$  分量个数  $k$  及惩罚因子  $\alpha$  的寻优范围分别为  $[2, 20]$  与  $[200, 4\ 000]$ ,  $[k, \alpha]$  参数组合经过 NGO 算法寻优,最终本文确定的最优  $[k, \alpha]$  参数组合为  $[18, 3\ 400]$ , 利用 VMD 算法对原始数据进行分解。根据分解的结果可知,  $IMF1$  分量至  $IMF18$  分量的分量频率依次增大,数值量级依次减小。在这 18 个  $IMF$  分量中,  $IMF1$  所占数量级最大、且与原始数据最为接近,  $IMF2$  分量与  $IMF3$  分量的数值量级属于同级,  $IMF4$  分量至  $IMF18$  分量的数值量级较一致。

### 2.2.2 FCBF-Informer

FCBF-Informer 的作用是筛选出与电力负荷高度相关的特征变量作为输入变量后进行负荷预测,采用 FCBF-Informer 进行负荷预测的具体步骤

如下:

(1) 在经过 NGO 算法对 VMD 分解的  $IMF$  分量层数  $K$  及惩罚因子  $\alpha$  的优化步骤后,采用 FCBF 算法对多维特征变量进行筛选,筛选出与电力负荷高度相关的特征变量作为输入变量。

(2) 将确定作为输入变量的特征变量与各个  $IMF$  分量同时作为 Informer 模型的输入,对输入变量进行归一化处理,再进行训练和预测,得到各个  $IMF$  分量对应的预测值。

(3) 对各个  $IMF$  分量的预测值进行反归一化操作,将反归一化操作后各个  $IMF$  分量预测值进行重构叠加得到最终的预测值,并将该值与原始数据进行对比分析。

经过 FCBF 算法的处理,可以获知,本文选用数据集的原始输入特征变量与电力负荷相关程度由高到低依次为电价、露点温度、干球温度、湿球温度、湿度以及星期(未计入时间点特征变量),并且星期特征变量相关性较小,所以本文选择除去星期特征变量剩余的 5 个特征变量作为 Informer 模型的输入变量。

## 3 算例分析

### 3.1 Informer 模型超参数确定

在 Informer 模型中,不同的超参数会对负荷预测的精度产生重大的影响。经过多次实验本文最终确定 Informer 模型的编码器、解码器的输入步长及层数等基本超参数设置,见表 1。

表 1 Informer 模型超参数设置

Tab. 1 Setting of Informer model hyperparameters

Informer 模型超参数设置	参数值
编码器输入步长	10
解码器输入步长	10
编码器层数	2
解码器层数	1
“多头”数	10
优化器	Adam
批量大小	32
丢弃率	0.3
初始学习率	0.01
激活函数	sigmoid

### 3.2 实验结果

#### 3.2.1 组合模型实验结果

为论证 OVMD 及 FCBF 算法引入到 Informer 模型的可行性和有效性,在此将 OVMD、FCBF 与

Informer 进行了组合,构成不同组合预测模型进行预测。性能指标见表2,实验结果如图3所示。

表2 不同组合模型的性能评价指标

Tab. 2 Performance evaluation indexes of different combination models

模型	MAE	MAPE/%	RMSE
Informer	72.78	0.87	86.96
FCBF-Informer	59.82	0.78	76.96
OVMD-Informer	65.04	0.79	77.99
本文模型	48.21	0.58	59.48

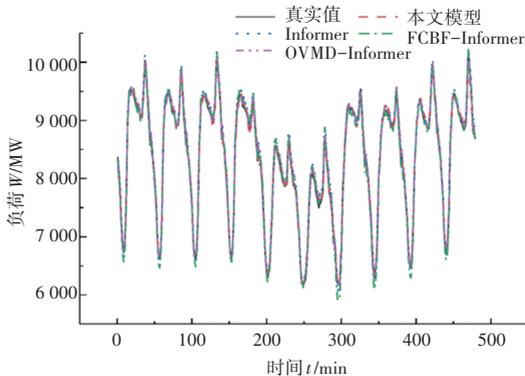


图3 不同组合预测模型结果

Fig. 3 Results of different combination prediction models

FCBF-Informer 及 OVMD-Informer 两种模型在3个性能评价指标上均有不同程度上的降低。在Informer模型中引入FCBF算法,FCBF算法可以在众多特征变量中筛选出与预测变量相关性较大的特征变量,研究人员可以自主地选择输入特征变量,避免了特征变量间的冗余,在降低计算时间的同时,提高了收敛速度。Informer模型中引入OVMD分解,OVMD分解可以降低原始数据的非线性、非平稳性,减少了波峰和波谷的出现次数,提高原始数据的质量。

同时,相比于Informer、FCBF-Informer及OVMD-Informer三种模型,本文模型进一步降代了3个性能评价指标,本文模型预测结果的性能评价指标MAE为48.21,MAPE为0.58%,RMSE为59.48。该模型预测曲线拟合程度在一定程度上得到加强,尤其是在预测波峰和波谷到来的时间点,其预测结果与真实值更为接近。充分论证了在Informer模型基础上引入OVMD分解及FCBF算法的可行性和有效性。

### 3.2.2 不同模型实验结果

为了进一步论证本文模型的可行性和有效性,在此选用了BP、LSTM、CNN-LSTM、CNN-BiLSTM等模型与本文模型进行了对比实验。为了保障实验

的客观性,对比实验模型中超参数的设置尽量与本文模型保持相同或者一致(如输入步长、丢弃率、批量大小等),若对比模型中存在本文模型没有的超参数,而其他模型拥有同类超参数也应该相同或者一致(如隐藏层的层数、神经元个数等)。性能指标见表3,实验结果如图4所示。

表3 不同模型的性能评价指标

Tab. 3 Performance evaluation indexes of different models

模型	MAE	MAPE/%	RMSE
本文模型	48.21	0.58	59.48
BP	464.49	5.41	523.33
LSTM	174.94	2.13	231.18
CNN-LSTM	169.03	2.07	238.39
OVMD-CNN-LSTM	160.26	1.95	232.32
CNN-BiLSTM	162.54	1.99	233.51
OVMD-FBCF-CNN-BiLSTM	153.05	1.85	229.22

由所列不同模型的性能评价指标可知,与BP、LSTM、CNN-LSTM、CNN-BiLSTM这类单一预测模型相比,Informer模型有着不错的预测效果,这是因其在时域上对非平稳性、非线性负荷数据拥有更为敏感的感知能力,同时在捕捉历史负荷数据输入特征变量及特征变量间的潜在信息更为充分,能够对输入输出之间进行更为高效的拟合,因而该模型的预测性能更为优异。不过,单一的预测模型对历史负荷数据集质量要求苛刻,在对非平稳性、非线性的历史负荷数据进行预测时得到的结果精度较差。

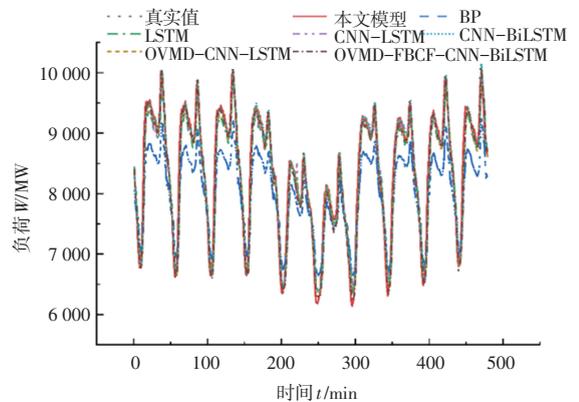


图4 不同模型预测结果

Fig. 4 Different models predict results

组合模型可以在保障历史负荷数据的时序性基础上提高其平稳性,同时对输入特征变量进行筛选,进行多变量对单变量的负荷预测。由此可见,组合模型预测相比单一预测模型有着更为满意的结果。

## 4 结束语

为了解决现有预测模型优化方法不够理想、预测精度不高的问题,本文提出了一种基于 NGO-VMD-FCBF-Informer 的电力负荷组合预测模型,经过仿真对比实验论证,得出了如下结论:

(1)文中利用 NGO 算法对 VMD 分解的 IMF 分量层数  $K$  及惩罚因子  $\alpha$  寻优,经过 OVMD 处理后的数据相较于原始数据,在很大程度上其非线性、非平稳性得以降低,有利于 Informer 模型更好地进行训练。

(2)文中考虑了气象条件等影响因素,同时采用 FCBF 算法对影响负荷的特征变量进行筛选作为预测模型输入,不仅可以减少部分工作量,加快算法的计算速度,同时对预测模型的精度有一定的改善。

(3)根据实验结果显示,本文提出的预测模型克服了单一模型的局限性,有效地解决了现有方法预测结果精度不高的问题,可以为电力系统的日常工作、安排提供有益的理论指导参考,具有极其重要的意义。

## 参考文献

[1] 赵婧宇,池越,周亚同. 基于 SSA-LSTM 模型的短期电力负荷预测[J]. 电工电能新技术,2022,41(6):71-79.

[2] WANG Wenchuan, XU Dongmei, CHAU K W, et al. Improved annual rainfall-runoff forecasting using PSO-SVM model based on EEMD[J]. Journal of Hydroinformatics, 2013, 15(4): 1377-1390.

[3] 赵明伟,张文胜,王克文,等. 基于 EMD-PSO-LSTM 组合模型的城市轨道交通短时客流预测[J]. 铁道运输与经济,2022,44(7):110-118.

[4] MA Dongliang, ZHOU Tao, CHEN Jie, et al. Supercritical water heat transfer coefficient prediction analysis based on BP neural network [J]. Nuclear Engineering and Design, 2017(320): 400-408.

[5] 张睿,谭江浩,杨瑞,等. 基于相空间重构和 EMD-ELM 的短期电力负荷预测[J]. 电气时代,2022(1):103-107.

[6] 段雪滢,李小腾,陈文洁. 基于改进粒子群优化算法的 VMD-GRU 短期电力负荷预测[J]. 电工电能新技术,2022,41(5):

8-17.

[7] 赵海洋,黄俊,王金东,等. 改进 SSA-VMD 算法及其在往复压缩机故障诊断中的应用[J]. 润滑与密封,2022,47(7): 147-152.

[8] 张璐,刘真,李磊,等. 基于 VMD-PSR-BNN 模型的月径流预测方法研究[J]. 中国农村水利水电,2023(4):105-113

[9] 于喜金,于晓光,杨同光,等. 基于优化 VMD 和 BP 神经网络液压管路故障诊断研究[J]. 机床与液压,2022,50(9):215-220.

[10] 徐武,汤弘毅,杨吴东,等. 基于 ISSA 优化的 Elman 神经网络短期电力负荷预测[J]. 扬州大学学报(自然科学版),2022,25(1):37-42.

[11] 张震,李孟洲,李浩方,等. 基于 VMD-LSTM-MLR 的短期电力负荷预测[J]. 水电能源科学,2021,39(10):208-212.

[12] 钟劲松,王少林,冉懿,等. 基于互信息和 LSTM 的用户负荷短期预测[J]. 电力建设,2022,43(7):96-102.

[13] ZHU Hailong, XIE Yawen, HE Wei, et al. A novel traffic flow forecasting method based on RNN-GCN and BRB [J]. Journal of Advanced Transportation, 2020(24): 1-11.

[14] 吴章玉,朱成杰,王鸣雁. 基于 RNN 的锂电池健康预测[J]. 绿色科技,2021,23(18):201-203.

[15] WANG Yuanyuan, ZHOU Jian, CHEN Kejia, et al. Water quality prediction method based on LSTM neural network [C]// Proceedings of 2017 12<sup>th</sup> International Conference on Intelligent Systems and Knowledge Engineering (ISKE). Nanjing, China: IEEE, 2017:1-5.

[16] MA Dongliang, ZHOU Tao, CHEN Jie, et al. Supercritical water heat transfer coefficient prediction analysis based on BP neural network [J]. Nuclear Engineering and Design, 2017, 320:400-408.

[17] 余本国. BP 神经网络局限性及其改进的研究[J]. 山西农业大学学报(自然科学版),2009,29(1):89-93.

[18] DEGHANI M, HUBÁLOVSKÝ Š, TROJOVSKÝ P. Northern goshawk optimization: a new swarm-based algorithm for solving optimization problems [J]. IEEE Access, 2021, 9:162059-162080.

[19] DRAGOMIRE SKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.

[20] 董治强. 基于 DTW-FCBF-LSTM 模型的超短期风速预测[J]. 电测与仪表,2020,57(4):93-98.

[21] ZHOU Haoyi, ZHANG Shanghang, PENG Jieqi, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting [C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2021, 35(12):11106-11115.

[22] 董浩,孙琳,欧阳峰. 基于 Informer 的 PM<sub>2.5</sub> 浓度预测[J]. 环境工程,2022,40(6):48-54,62.