[文章编号] 1003－4684(2025)04-0043-07

基于 CPA-VMD 的短时电力负荷预测

汪繁荣[1,2]，乔一航[1]

(1 湖北工业大学电气与电子工程学院，湖北 武汉 430068;2 襄阳湖北工业大学产业研究院，湖北 襄阳 441100)

[摘 要] 针对目前电力负荷序列的非线性和波动性日益增强导致电力负荷预测难度越来越大的问题，引入了食肉植物算法，并将其应用于变分模态分解的参数选择问题，从而提高变分模态分解的精准度。选用某地区的日用电量负荷数据作为电力负荷数据集进行分解。首先使用食肉植物算法对变分模态分解中的序列分解个数 K 和二次惩罚因子 α 寻优，然后将原始负荷序列分解后的各本征模态分量使用 BP 神经网络和长短时记忆神经网络预测，验证食肉植物算法在负荷分解领域的适用性，最终食肉植物优化变分模态分解算法的分解损失为 1.086，BP 神经网络和 LSTM 神经网络的预测值准确率分别为 88.721％和 95.959％，实验表明该方法适用于短时电力负荷预测领域，而且其分解效率更好，预测精度更高。

[关键词] 负荷预测；食肉植物算法；变分模态分解；LSTM 神经网络；电网规划

[中图分类号] TM732 [文献标识码] A

1 研究背景

随着社会经济的发展，电网规模不断扩大，居民用电量越来越大，电力负荷数据相比以往数倍增长，电力数据越来越复杂，影响负荷的因素也越来越多，社会、政治、天气甚至经济因素都成为了电力负荷预测的背景，电力负荷预测的难度越来越大[1-4]。变分模态分解(variational mode decomposition，VMD)是电力负荷预测中常用的负荷序列分解方法，该方法得到的信号分量损失更小，负荷预测的结果更加准确，但是该方法经验选择的分解参数随机性很大，会对预测结果产生不利影响[5-8]。基于该原因，变分模态分解引入了智能算法用以寻优分解参数，从而减小经验选择的随机性，提高分解结果的精准度。但寻优算法普遍存在着收敛速度较慢、容易陷入局部最优的缺点，因此，搭建高预测精度、低分解误差和广泛外部性的分解模型是电力负荷预测领域的重中之重[9-11]。

为了解决以上问题，本文引入食肉植物算法(carnivorous plant algorithm，CPA)来优化 VMD 的分解参数。CPA-VMD 预测模型主要分为两个阶段，第一阶段利用 CPA 算法可以自适应全局寻优的特点，完成对 VMD 分解算法的参数寻优，避免因分解模态数过多和惩罚因子过大，对原始负荷序列过度惩罚，使分解信号失真，影响最终的预测结果；第二阶段将 CPA-VMD 算法分解产生的本征模态分量作为输入，分别使用 LSTM 神经网络和 BP 神经网络进行预测，在时间序列上预测出下一阶段的电力负荷并与实际值对比。实验结果表明，CPA-VMD 算法的收敛速度快，分解损失小，预测精准度高，在负荷预测领域具有强适用性，可以为电网发、供电动态平衡提供可靠依据。

2 研究方法

2.1 食肉植物算法(CPA)

食肉植物算法(CPA)是 2020 年由国外学者 Ong KokMeng 等人提出的一种基于种群的元启发式算法[12]，该算法的优化过程具体可分为以下几个阶段：

1)初始化 初始化的过程可由数学表达式(1)所示：

$$I_{i,j} = Lb_j + (Ub_j - Lb_j) \times rand \tag{1}$$

其中，Lb 和 Ub 表示目标参数的上下取值范围，$rand$ 是在(0,1)中随机选取的随机数。

2)分组分类 种群初始化后，通过预设的目标函数来计算种群中每个个体的适应度值，将适应度矩阵进行升序排序后，选择其中适应度最高的前 n 个解作为食肉植物，其余候选解作为猎物。

[收稿日期] 2023－03－18
[基金项目] 国家自然科学基金(61903129)
[第一作者] 汪繁荣(1979－)，男，湖北天门人，湖北工业大学副教授，研究方向为电网控制与智能制造、能耗管理、非侵入式负荷分解。
[通信作者] 乔一航(1998－)，女，河南平顶山人，湖北工业大学硕士研究生，研究方向为电力负荷预测。

3)生长 随机选择一组捕食关系,如果吸引率大于随机数,则食肉植物捕食成功,新食肉植物生长过程的数学表达式:

$$\begin{aligned} \mathrm{New}nP_{i,j} &= G \times nP_{i,j} + (1-G) \times nq_{v,j} \\ G &= g \times rand_{i,j} \end{aligned} \tag{2}$$

其中,$nP_{i,j}$ 是第 i 级食肉植物,$nq_{v,j}$ 是该组捕食者关系中随机选择的猎物,g 是预设的生长率的值。

如果吸引率小于随机数,则食肉植物捕食失败,猎物逃脱并继续生长,猎物生长过程的数学表达式:

$$\begin{aligned} \mathrm{New}nq_{i,j} &= G \times nq_{u,j} + (1-G) \times nq_{v,j} \\ G &= \begin{cases} g \times rand_{i,j}, f(nq_v) > f(nq_u) \\ 1 - g \times rand_{i,j}, f(nq_v) < f(nq_u) \end{cases} \end{aligned} \tag{3}$$

其中,$nq_{u,j}$ 是在该组捕食者关系中随机选择的另一个猎物。

4)繁殖 在食肉植物的捕食过程中,第一级食肉植物繁殖过程的数学表达式:

$$\begin{aligned} \mathrm{New}nP_{i,j} &= nP_{i,j} + \mathrm{Pr} \times rand_{i,j} \times m_{i,j} \\ m_{i,j} &= \begin{cases} nP_{v,j} - nP_{i,j}, f(nP_i) > f(nP_v) \\ nP_{i,j} - nP_{v,j}, f(nP_i) < f(nP_v) \end{cases}, i \neq v \neq 1 \end{aligned} \tag{4}$$

其中,$nP_{i,j}$ 为最优解,$nP_{v,j}$ 为随机选取的食肉植物,Pr 为预定义的繁殖率值。

5)重组 食肉植物和猎物进行自身的生长繁殖之后,与以前的种群矩阵相结合生成了新的种群,将新种群按照适应度值进行升值排序,则前 n 个个体即为目标函数的最优解。

2.2 变分模态分解(VMD)

VMD 分解算法具有良好的噪声鲁棒性,可以较好地保留原始负荷信号的信息,避免分解过程中信息损失过大而影响下一阶段的预测结果,从而保证预测过程的高精确度,其具体的分解过程数学表示如下:

$$\left[(\delta(\mathrm{t}) + \frac{j}{\pi \mathrm{t}}) * u_k(t) \right] e^{-j\omega k t} \tag{5}$$

$$\mathrm{s.t.} \sum_{k=1}^{K} u_k(t) = f(t) \tag{6}$$

$$\min_{\{u_k\}\{\omega_k\}} \left\{ \sum_{k=1}^{K} \left\| \partial_t \left[(\delta(\mathrm{t}) + \frac{j}{\pi \mathrm{t}}) * u_k(t) \right] e^{-j\omega k t} \right\|_2^2 \right\} \tag{7}$$

式中,K 为 IMF 信号序列的数量,$\{u_k\}$为 IMF 分量的集合,$\{\omega_k\}$为各 IMF 分量中心频率的集合。

为了消除变分过程中的约束问题,引入了惩罚因子 α 和乘子 λ,非约束变分问题的数学过程:

$$\begin{aligned} L(u_k, \omega_k, \lambda) = \alpha \sum_{k=1}^{K} \left\| \partial_t \left[(\delta(\mathrm{t}) + \frac{j}{\pi \mathrm{t}}) * u_k(t) \right] e^{-j\omega k t} \right\|_2^2 + \\ \left\| f(t) - \sum_{k=1}^{K} u_k(t) \right\|_2^2 + \langle \lambda(\mathrm{t}), f(t) - \sum_{k=1}^{K} u_k(t) \rangle \end{aligned} \tag{8}$$

在非约束变分问题求解过程中,本征模态分量和中心频率的迭代过程可以用数学表达式如式(9)和(10)所示:

$$u_k^{n+1} = \frac{f(\omega) - \sum_{i \neq k}^{K} u_i(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \tag{9}$$

$$\omega_k^{n+1} = \frac{\int_0^{\infty} \omega |u_k(\omega)| \mathrm{d}\omega}{\int_0^{\infty} |u_k(\omega)| \mathrm{d}\omega} \tag{10}$$

2.3 神经网络预测模型

为了验证 CPA-VMD 算法在负荷预测领域的适用性,本文使用 LSTM 神经网络和 BP 神经网络作为预测模型。

2.3.1 长短时记忆神经网络(LSTM) LSTM 神经网络是在 RNN 的基础上添加了新的门控单元,以此来实现信息的传递,门控机制的加入可以调节信息流,精准抓取数据特征,有效排除序列分量集合中的干扰数据,增强 LSTM 神经网络的记忆功能,LSTM 神经网络的结构如图 1 所示。

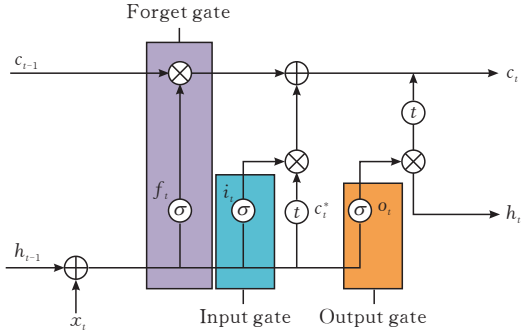

图 1 LSTM 神经网络结构

其中,f_t 是遗忘门,i_t 是输入门,o_t 是输出门;x_t 表示当前输入序列,h_t 和 h_{t-1} 表示当前输出和上一个输出,c_t 和 c_{t-1} 表示当前和前一时刻的记忆单元,h_{t-1} 和 c_{t-1} 都携带了以往的序列信息,c_t^* 表示当前输入状态;σ 表示 sigmoid 函数,t 表示 tanh 函数[13]。

遗忘门用于决定在长链数据传递中应丢弃或保留的信息,来自前一个隐藏状态的信息和当前输入的信息同时传递到 sigmoid 函数中去,函数值趋近 0 意味着该信息应该丢弃,趋近 1 意味着信息应该保留;输入门用于更新细胞状态,并将前一层隐藏状态的信息和当前输入的信息传递到 tanh 函数中;输出门用于确定下一个隐藏状态的值,并将隐藏状态作为当前输出,把新的序列状态和新的隐藏状态传递到下一个时间步长中去。LSTM 神经网络训练学习的过程可以由以下公式来表示:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{11}$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{12}$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{13}$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t \tag{14}$$

2.3.2　反向传播神经网络(BP)　BP 神经网络是一种多层的前馈神经网络,其过程主要分为两个阶段,第一阶段是序列的前向传播,从输入层经过隐含层,最后到达输出层;第二阶段是误差的反向传播,从输出层到隐含层,最后到输入层,在序列传递过程中需要依次调节隐含层到输出层的权重和偏置,输入层到隐含层的权重和偏置[14-15]。BP 神经网络的结构如图 2 所示。

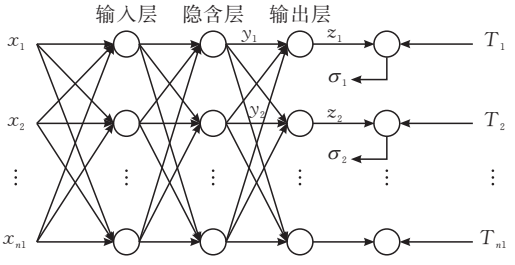

图 2　BP 神经网络结构

在神经结构中,假设输入层到隐含层的权重为 w_{ij},隐含层到输出层的权重为 w_{jk},输入层到隐含层的偏置为 a_j,隐含层到输出层的偏置为 b_k,则隐含层 H_j、输出层 O_k 可以由以下公式表示。

$$H_j = g\left(\sum_{i=1}^{n}\omega_{ij}x_i + a_j\right) \tag{15}$$

$$O_k = \sum_{j=1}^{l}H_j\omega_{jk} + b_k \tag{16}$$

权值 w_{ij}、w_{jk} 和偏置的更新过程如公式(17)(18)。

$$\begin{aligned}\omega_{ij} &= \omega_{ij} + \eta H_j(1-H_j)x_i\sum_{k=1}^{m}\omega_{ij}e_k\\ \omega_{jk} &= \omega_{jk} + \eta H_j e_k\end{aligned} \tag{17}$$

$$\begin{aligned}a_j &= a_j + \eta H_j(1-H_j)\sum_{k=1}^{m}\omega_{jk}e_k\\ b_k &= b_k + \eta e_k\end{aligned} \tag{18}$$

3　模型搭建

3.1　食肉植物算法适应度函数

CPA 算法在初始化结束后生成适应度值矩阵进行后续的分组生长,因此需要引入一个合理的适应度函数——分解损失 *Loss* 来解决参数选择问题。该函数适用于电力负荷预测领域,相比经验选择更加严谨且有效,分解损失的数学表达式如公式(19)所示[16]:

$$\mathrm{Loss} = \frac{\sum_{t=1}^{T}|f(t)-f'(t)|}{T} \tag{19}$$

在以上公式中,$f(t)$ 表示原始负荷序列,T 表示该序列在时域上的长度,$f'(t)$ 表示各本征模态分量之和,$f'(t)$ 的构造过程可由公式表示:

$$f'(t) = \sum_{k=1}^{K}u_k(t) \tag{20}$$

在无分解损失的理想情况下,$f'(t)$ 与原始负荷序列 $f(t)$ 相等,但在实际过程中,负荷序列往往会由于噪声信号以及分解产生的残余信号发生分解损失。分解损失 Loss 函数的实质就是 VMD 分解后的本征模态分量之和构造的负荷序列与原始负荷序列的平均绝对误差,绝对误差越小,说明在分解过程中产生的损失越小,分解信号所包含的数据特征就越多,负荷序列就越准确,为下一步的预测过程提供了良好的前提。

3.2　基于 CPA-VMD 预测模型实现

在 CPA 算法寻优 VMD 分解参数的过程中,K 表示分解产生的本征模态分量个数,K 的取值很大程度决定 VMD 算法的精准度,合理的 K 值可以使原始负荷序列完全分离,避免分解过程中出现模态重叠,同时又最大程度地保留数据特征;惩罚因子 α 的合理取值可避免 VMD 在分解过程中因为过度惩罚使分解信号严重失真,影响后续的负荷预测过程。基于 CPA-VMD 的预测模型具体过程如下:

1)输入负荷序列,并设置食肉植物算法参数:迭代数、吸引率、生长率和繁殖率,将寻优维度设置为 2,代表 VMD 的分解参数 K 和 α;

2)根据种群初始化规则生成初始种群,Loss 函数被用作目标函数,依次计算种群中个体的适应度,并选择适应度最高的前 2 个个体作为捕食者,其他个体为猎物。在分组过程中将猎物按照等级原则分配给食肉植物;

3)随机生成一个随机数,若随机数小于吸引率,则猎物逃脱继续生长生成新猎物,否则食肉植物捕食成功,获得养分继续生长;

4)适应度排名第一的食肉植物根据繁殖率进行繁殖产生新个体,并且重新随机选择猎物,生长繁殖后的个体产生新种群;

5)计算新种群每个个体的适应度值,并排序更新种群;

6)判断是否完成迭代次数,若没有完成则重复步骤 3)至 5);若迭代完成,输出适应度值最高的前 2 名食肉植物。这 2 个个体即为全局最优个体,也就是 VMD 的最优分解参数 K 和 α。

7)根据寻优得出的最优分解个数 K 和惩罚因子 α 进行 VMD 分解,得到本征模态分量 IMF_1,IMF_2,…,IMF_k。

8)搭建神经网络预测模型,将本征模态分量作为数据样本分别输入预测模型进行训练,得到各个分量的预测结果 IMF_1',IMF_2',…,IMF_k'。

9)各分量预测结果 IMF_1',IMF_2',…,IMF_k',求和得到最终负荷预测序列。基于 CPA-VMD 预测模型的完整过程由图 3 所示。

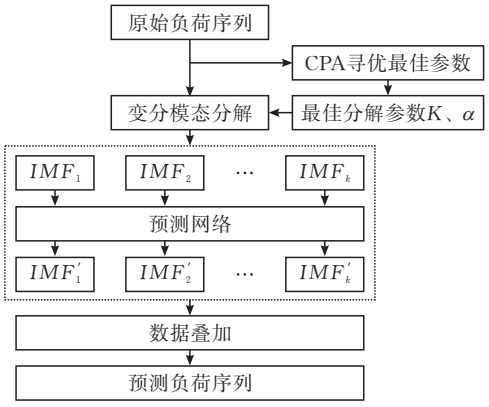

图 3 基于 CPA-VMD 的预测模型流程

4 仿真试验及分析

4.1 数据来源及评价标准

4.1.1 数据预处理 为了验证 CPA-VMD 算法在负荷预测领域的精准度以及可应用性，本文使用某地区 2021 年 3—7 月的日电力负荷数据作为数据集来进行网络模型训练。为保证数据集的周期性与连续性，选择以 30 天为周期对数据集进行清洗，最后得出 150 个数据点作为有效值，其中 80%作为训练集训练模型，20%作为测试集验证模型精准度。原始数据列表如表 1 所示。

表 1 原始数据

训练集					测试集
1	2	3	4	5	
111 943	107 899	105 059	104 100	105 349	117 278
108 773	111 216	115 164	111 995	116 817	108 613
157 302	159 139	162 318	167 790	171 351	157 384
168 105	170 999	173 719	179 902	182 710	167 393
136 010	136 102	137 227	140 901	141 558	138 455
103 016	101 349	101 004	101 955	104 649	106 773
83 279	81 938	82 158	84 374	88 845	85 923
75 291	75 350	76 091	78 984	80 263	77 281
71 709	70 737	71 262	73 960	76 400	74 146
86 106	87 834	90 768	89 711	91 045	85 517
89 890	87 479	86 189	87 693	91 763	93 758
79 879	79 455	80 479	83 874	85 387	82 093
96 792	97 068	98 657	102 282	102 670	98 373
88 612	88 926	90 190	91 130	92 206	89 942
116 911	118 799	121 794	120 140	120 795	117 816
131 066	131 611	133 035	137 521	139 067	132 027
125 452	126 160	127 239	130 351	132 588	127 001
102 980	102 795	104 032	108 496	109 613	105 695
110 457	109 979	110 589	113 190	115 062	113 146

考虑到模型的收敛性，将数据进行归一化处理后进行训练，模型仿真过程使用 MATLAB 2021a，编程语言为 Java，实验所使用的计算机型号为联想 Think book 15 G3 ITL，CPU 型号为 i7-1195G7。

4.1.2 评价标准 本次实验引入的评价指标为平均绝对误差(mean absolute error，MAE)和均方根误差(root mean square error，RMSE)，其数学表示如表 2 所示。

表 2 评价标准数学表示

	公式
平均绝对误差	$MAE=\frac{1}{m}\sum_{i=1}^{m}\lvert\hat{y}_i-y_i\rvert$
均方根误差	$RMSE=\sqrt{\frac{\sum_{i=1}^{m}(\hat{y}_i-y_i)^2}{m}}$

4.2 实验结果分析

4.2.1 CPA 算法优化结果分析 CPA 算法优化 VMD 的过程中，将迭代次数设置为 100，吸引率设置为 0.8，生长率设置为 2，繁殖率设置为 1.8，食肉植物个数选取为 2，种群的其余个体为猎物，分解损失 Loss 作为适应度目标函数进行迭代寻优。同时分别使用 MATLAB 软件中默认的 VMD 参数和 PSO 算法寻优 VMD 参数的两种分解算法作为对照，经过相同迭代次数之后，得出 3 种方法的分解损失迭代过程如图 4 所示，分解参数和分解损失数值如表 3 所示。

表 3 分解参数设置及分解结果

	分解个数	惩罚因子	分解损失
VMD	5	1000	18.75
PSO-VMD	27	10452	6.36
CPA-VMD	7	249	1.08

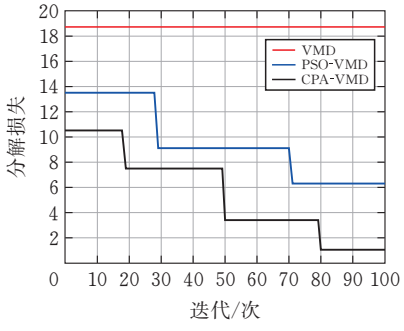

图 4 分解损失对比

由表 3 和图 4 可以看出，经验设置 VMD 的分解参数得出的分解结果会产生较大的误差，PSO-VMD 分解和 CPA-VMD 分解相比于单一 VMD 算法的分解损失分别下降了 66.08%和 94.24%，说明了寻优算法引入 VMD 分解的必要性，利用算法参数寻优的过程相比于传统经验设置方法更加严谨，而且分解结果更加精准。

对比 PSO 算法和 CPA 算法优化过程可以看出，CPA-VMD 算法相比于 PSO-VMD 算法的分解损失下降了 83.01%，且 CPA 的收敛性快于 PSO，

说明了 CPA-VMD 算法的分解效率快，分解损失小，进一步表明了 CPA 算法在负荷分解领域具有优越性和可应用性。

4.2.2　预测效果分析　CPA-VMD 分解过程结束后，以 LSTM 神经网络为例，将其分解得到的每个本征模态分量进行预测，分量预测结果相加之后即最终预测序列，各本征模态分量的预测结果如图 5 所示。

由图 5 可以看出，在原始序列分解过程中，大量数据特征被保留在 IMF_1 中，因此 IMF_1 的预测结果与本身曲线的重合度较大，说明其分解精度高，随着本征模态分量数的增多，预测的精准度有所降低但负荷趋势依然较为准确，这是由于本征模态分量数的增多，原始负荷信号的残余量越来越少，可以被抓取的数据特征也逐渐减少，而且受到天气、社会等外来因素的影响，其预测精度有所降低。

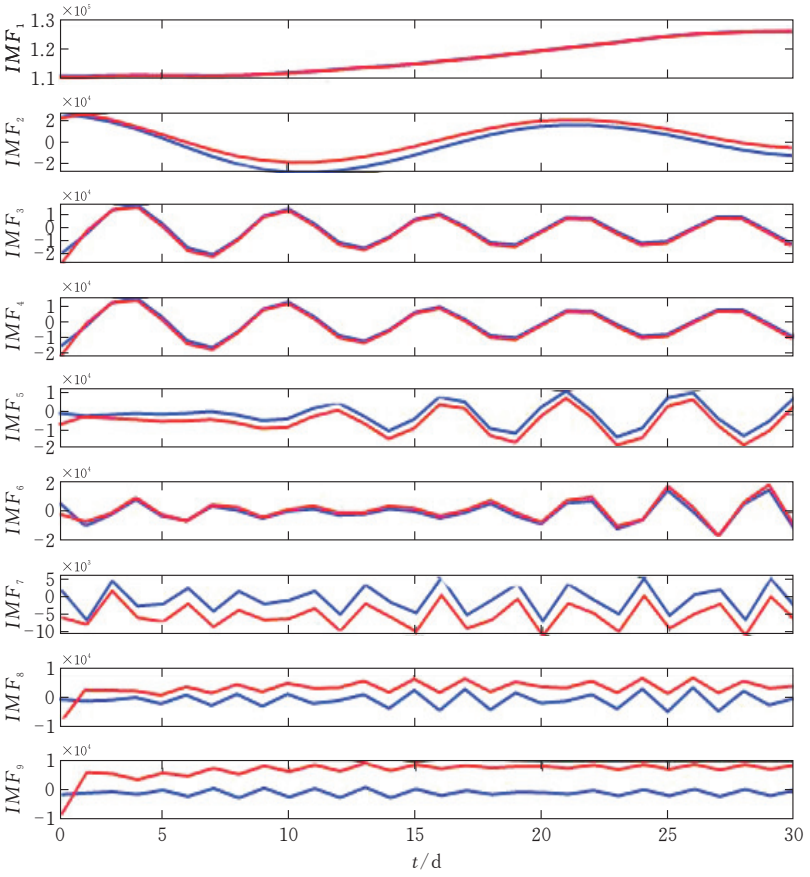

图 5　本征模态分量预测结果对比

为了验证 CPA-VMD 分解方法在负荷预测领域的适用性，分别使用 LSTM 神经网络和 BP 神经网络进行预测，最终预测结果与实际值的对比如图 6 所示，两种预测模型的准确率如表 4 所示。

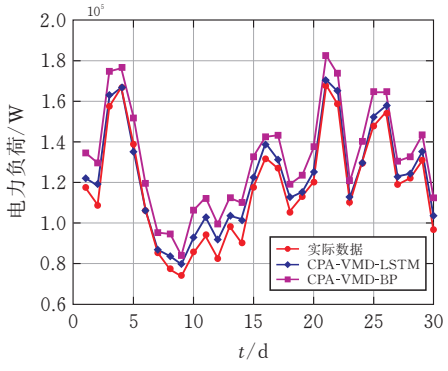

图 6　负荷预测结果对比

由图 6 和表 4 可以看出，与 LSTM 神经网络相比，虽然 BP 神经网络的预测效果的准确率相对较差，但是负荷序列的趋势基本与实际负荷序列一致，可以准确反映数据走向，说明了 CPA-VMD 算法在负荷预测领域具有适用性。

表 4　预测结果准确率

预测模型	预测结果准确率/%
BP 神经网络	88.721
LSTM 神经网络	95.959

结合本征模态分量预测结果和整体预测结果来看，分解信号在预测过程中，虽然残余信号的预测精度降低，但是本征模态分量的预测结果叠加之后得到的最终负荷预测结果与实际数据依然比较贴合，说明在信号分解的过程中，决定预测精准度的是含有大量数据特征的前 n 个本征模态分量，而残余信号的预测效果对最终负荷预测结果的影响不会

太大。

为了验证 CPA-VMD 分解算法在预测领域的有效性，以预测精度更高的 LSTM 神经网络为例，分别使用单一 VMD 和 PSO-VMD 分解算法对同一原始序列进行分解预测，两者的预测过程参数与 CPA-VMD 保持一致，3 种算法的预测结果误差对比如图 7 所示。

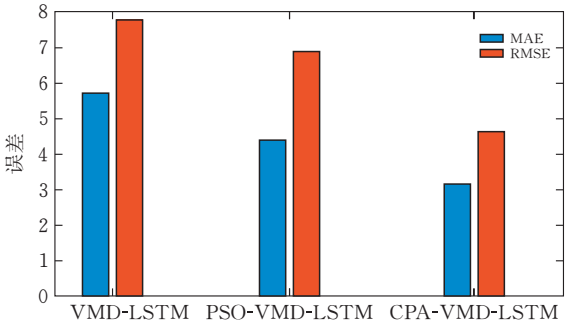

图 7 模型误差对比

由图 7 可知，CPA-VMD-LSTM 模型预测结果相对于 VMD-LSTM 模型和 PSO-VMD-LSTM 模型的平均绝对误差分别降低了 45.2%和 28.8%，均方根误差分别降低了 40.7%和 32.9%，说明了 CPA-VMD-LSTM 模型的预测结果与实际值的误差更小，再次表明了 CPA 优化算法应用于负荷分解预测的有效性，其寻优效果使 VMD 分解算法的精准度和分解效率得到了进一步提升，结合 LSTM 神经网络所建立的模型预测精度更高，再一次验证了其应用于短期负荷预测的适用性。

综上所述，CPA 优化算法在负荷分解参数寻优中具有高优越性和适用性，其寻优效率及其优化搜索效果能够进一步提高 VMD 分解算法的准确性，为后续的预测过程提供更加精准的数据基础。

5 结论

电力系统中的短期负荷预测在经济调度、电厂维护和机组启动关闭中发挥着重要作用，因此要求短期负荷预测有较高的预测精度。本文提出的基于 CPA-VMD 的短期电力负荷预测模型，通过对某地区数据集的实际预测实验进行分析，得出以下结论：

1)与单一 VMD 分解模型相比，经过优化算法寻优分解参数的复合型分解模型具有更高的精准度，说明了 CPA 算法应用于负荷分解参数寻优可以有效减小经验设置带来的随机性，通过准确抓取数据特征，减少分解过程中的分解损失，提高了分解效果。

2)基于 CPA-VMD 负荷预测模型的高准确度说明了 CPA-VMD 分解方法在负荷预测领域的适用性；而基于 CPA-VMD 的负荷预测方法相比于基于 PSO-VMD 和单一 VMD 的预测方法结果更精准，说明该算法可以有效降低误差，提高预测效果的精准度，能够为电网规划提供可靠的依据，具有合理性以及可应用性。

随着电力负荷数据越来越复杂，波动性和过零率越来越高，电力负荷预测也存在一定的难题，比如节假日和天气因素等外界影响都会使神经网络的预测结果产生一定偏差，因此在后续的研究过程中，应结合大数据处理技术，将影响负荷预测效果的多重影响因素转化成单一影响因素，在此基础上进行多步性负荷预测，从而进一步提高负荷预测的准确度。

[参 考 文 献]

[1] 赵洋，王瀚墨，康丽，等. 基于时间卷积网络的短期电力负荷预测[J]. 电工技术学报，2022，37(05)：1242-1251.

[2] 张新阳，李辉，保富，等. 智能配电网环境下负荷预测研究[J]. 电子测量技术，2019，42(09)：121-124.

[3] 李文武，石强，李丹，等. 基于 VMD 和 PSO-SVR 的短期电力负荷多阶段优化预测[J]. 中国电力，2022，55(08)：171-177.

[4] 史加荣，赵丹梦，王琳华，等. 基于 RR-VMD-LSTM 的短期风电功率预测[J]. 电力系统保护与控制，2021，49(21)：63-70.

[5] 赵冬梅，杜刚，刘鑫，等. 基于时序分解及机器学习的风电功率组合预测模型[J]. 现代电力，2022，39(01)：9-I0001.

[6] 顾能华，侯银银，韩雪龙. 基于 EEMD 分解与 PCA-FCM 聚类的岸桥减速箱故障诊断方法[J]. 电子技术应用，2021，47(04)：101-111.

[7] 赵倩，陈芳芳，甘露，等. 基于 EEMDPSOSVM 的短期风电功率预测[J]. 现代电子技术，2021，44(15)：89-93.

[8] 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，2020，435(02)：227-236.

[9] 王增平，赵兵，贾欣，等. 基于差分分解和误差补偿的短期电力负荷预测方法[J]. 电网技术，2021，45(07)：2560-2568.

[10] 吴松梅，蒋建东，燕跃豪，等. 基于 VMD-PSO-多核极限学习机的短期负荷预测[J]. 电力系统及其自动化学报，2022，34(05)：18-25.

[11] 廖庆陵，窦震海，孙锴，等. 基于自适应粒子群算法优化支持向量机的负荷预测[J]. 现代电子技术，2022，45(03)：125-129.

[12] ONG K M，ONG P，SIA C K. A carnivorous plant algorithm for solving global optimization problems[J]. Applied soft computing，2021，98(4)：106833-106842.

[13] 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

(06):40-47.
[14] 黄孝斌,沈军,李国新,等. 遗传算法优化确定 BP 神经网络的遥感图像分类[J]. 现代电子技术,2020,43(12):4-12.
[15] 徐先峰,赵依,刘状壮,等. 用于短期电力负荷预测的日负荷特性分类及特征集重构策略[J]. 电网技术,2022,46(04):1548-1556.
[16] 张淑清,李君,姜安琦,等. 基于 FPA-VMD 和 BiLSTM 神经网络的新型两阶段短期电力负荷预测[J]. 电网技术,2021,08(46):1-12.

Short-term Power Load Forecasting Based on CPA-VMD

WANG Fanrong[1,2], QIAO Yihang[1]
(1 *School of Electrical and Electronic Engineering, Hubei Univ. of Tech., Wuhan* 430068, *China*;
2 *Xiangyang Industrial Institute of Hubei Univ. of Tech., Xiangyang* 441100, *China*)

Abstract: The Carnivorous plant algorithm(CPA)was introduced to solve the difficulty of power load prediction due to the increasing nonlinearity and volatility of current power load series.It has been applied to the parameter selection of Variational mode decomposition(VMD),so as to improve the accuracy of VMD. The daily electricity consumption load data of a region is selected as the power load data set to decompose. First,Carnivorous plant algorithm was used to optimize the sequence decomposition number K and quadratic penalty factor α in the variational mode decomposition.Then,BP neural network and Short and long time memory neural network (Short and long time memory neural network,short and long time memory neural network, short and long time memory neural network,Finally,the decomposition loss of CPA-VMD algorithm is 1.086,and the prediction accuracy of BP neural network and LSTM neural network is 88.721% and 95.959%,respectively.Experiments show that this method is suitable for short-time power load prediction. Moreover,the decomposition efficiency is better and the prediction accuracy is higher.

Keywords: load forecasting; carnivorous plant algorithm; variational mode decomposition; LSTM neural network; power grid planning

[责任编校:闫　品]

(上接第 15 页)

Solving the Flexible Job Shop Scheduling Problem with an Improved GWO Algorithm

GONG Lixiong, XIAO Miaoling, WANG Yuanyuan, LIANG Jiale, FAN Yanmiao
(*School of Mechanical Engineering, Hubei Univ. of Tech., Wuhan* 430068, *China*)

Abstract: Aiming at minimizing the maximum completion time, this study proposes an Improved Grey Wolf Optimization (IGWO) algorithm for solving the flexible job shop scheduling problem. First, a separated encoding strategy is adopted to decouple machine selection and operation sequencing. Second, the GLR initialization method is employed to enhance solution quality and ensure population diversity. Subsequently, crossover and mutation operators are integrated to effectively suppress premature convergence. Finally, an enhanced variable neighborhood search strategy is introduced to strengthen the algorithm's local search capability. Experimental evaluations on MK benchmark instances and comparative analyses with other algorithms demonstrate that the proposed IGWO algorithm exhibits significant advantages in addressing flexible job shop scheduling problems.

Keywords: flexible job shop scheduling; makespan; Grey Wolf Optimization Algorithm; improved variable neighborhood search

[责任编校:张　众]