

# 基于级联宽度学习与麻雀算法的非侵入式负荷分解方法

白星振<sup>1</sup>, 康家豪<sup>2</sup>, 尚继伟<sup>1</sup>, 郝春蕾<sup>1</sup>, 王雪梅<sup>3</sup>

(1. 山东科技大学 电气与自动化工程学院, 山东 青岛 266590;

2. 国网山东省电力公司 汶上县供电公司, 山东 济宁 272500;

3. 山东科技大学 工程实训中心, 山东 青岛 266590)

**摘要:**深度学习被广泛应用于非侵入式负荷分解中,其分解精度高但存在网络结构复杂、训练过程极度耗时等问题,并且对计算资源有一定要求,难以与嵌入式设备集成使用。对此,面向低频数据,提出一种基于级联宽度学习与麻雀算法的非侵入式负荷分解方法。首先,改进宽度学习特征节点的连接方式,构建各目标设备的级联宽度学习负荷分解网络。然后,通过麻雀搜索算法确定各目标设备分解网络的最优特征节点和增强节点数,实现负荷的高效分解。最后,基于实际数据集 UK-DALE 进行了仿真实验,通过与常用的非侵入式负荷分解方法进行比较,验证了所提方法的优越性。

**关键词:**非侵入式;负荷分解;宽度学习;麻雀算法;特征节点级联

中图分类号:TM721

文献标志码:A

## Non-intrusive load disaggregation method based on cascade broad learning and sparrow algorithm

BAI Xingzhen<sup>1</sup>, KANG Jiahao<sup>2</sup>, SHANG Jiwei<sup>1</sup>, HAO Chunlei<sup>1</sup>, WANG Xuemei<sup>3</sup>

(1. College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China;

2. Wenshang Power Supply Company, State Grid Shandong Electric Power Company, Jining 272500, China;

3. Engineering Training Center, Shandong University of Science and Technology, Qingdao 266590, China)

**Abstract:** Deep learning has been widely used in non-intrusive load disaggregation. Despite its high disaggregation accuracy, its problems such as complex network structure, extremely time-consuming training process, and some requirements for computational resources make it difficult to integrate with embedded equipment. To address these problems, a non-intrusive load disaggregation method based on cascaded broad learning and sparrow optimization was proposed for low-frequency data. Firstly, the connection method of the broad learning feature nodes was improved and the cascade broad learning load disaggregation network of each target device was constructed. Then, the optimal number of feature nodes and enhanced nodes of the disaggregation network of each target device was determined by the sparrow optimization algorithm to realize the efficient disaggregation of non-intrusive load. Finally, simulation experiments based on the real dataset UK-DALE were carried out, and the superiority of the proposed method was verified by comparing it with the commonly-used non-intrusive load disaggregation methods.

**Key words:** non-intrusive; load disaggregation; broad learning; sparrow algorithm; cascade of feature nodes

随着能源短缺和环境污染的不断加剧,能源节约问题受到了前所未有的关注。在终端能源消耗中,电能所占比重逐年增加,预计到 2035 年,我国电能占终端能源消耗的比重将提高至 38% 以上<sup>[1]</sup>。研究表明,用

收稿日期:2022-03-31

作者简介:白星振(1977—),男,山东临朐人,教授,博士,主要从事电力系统状态监测、估计方面的研究。

E-mail: xzbai@sdust.edu.cn.

王雪梅(1973—),女,山东肥城人,工程师,硕士,主要从事机器学习及优化算法的研究,本文通信作者。

E-mail: zpysd@163.com.

户在清楚家庭用电设备级粒度信息后,可以降低 13%左右的电能消耗<sup>[2]</sup>。随着电力物联网和智能电网的发展,电网与用户的双向互动更加友好紧密<sup>[3]</sup>。为了实现与电力用户的灵活互动,需要挖掘用户的用电行为及其规律,而这一切的基础是对用户内部设备使用信息的感知与获取<sup>[4]</sup>。非侵入式负荷监测(non-intrusive load monitoring, NILM),又称为非侵入式负荷分解,提供了一种仅通过用户总线处数据获取用户内部每个设备独立用电数据的方法<sup>[5]</sup>,从而帮助用户优化用电习惯、节约用电成本,同时辅助电网细致地掌握用户的用电行为模式,为双向互动提供数据基础。相比于传统的侵入式负荷监测方法, NILM 具有低成本、易于实施等优点,拥有广阔的发展空间。

1992年 Hart<sup>[6]</sup>首次提出 NILM 系统后,国内外学者对相关问题进行了大量研究,经过几十年的探索, NILM 已日趋成熟。在众多的 NILM 模型中,隐马尔可夫模型(hidden Markov model, HMM)得到了广泛关注。文献[7]改进了隐马尔可夫模型,通过人工免疫算法与增量学习对模型进行优化,提高了模型的分解精度。但 HMM 的计算复杂度随着设备数量的增加呈指数增长,因此有学者提出深度学习的 NILM 方法。Kelly 等<sup>[8]</sup>首次使用深度学习进行非侵入式负荷分解,构建了 3 种 NILM 深度神经网络架构,并证明了深度学习进行负荷分解的良好性能;文献[9]提出一种序列到点学习(seq2point)的 NILM 架构,输入为给定窗口长度的总功率序列,输出为窗口中点的分解值,与 Kelly 等提出的方法相比,两种标准误差指标分别提高了 84%和 92%;文献[10]提出一种基于序列到序列和注意力机制的深度学习框架,显著提升了深度神经网络对信息的提取与利用能力;文献[11]根据设备运行状态数量的差异,将设备运行状态分为简单和复杂两类,对两类状态分别使用多层感知网络和双向长短期记忆网络进行负荷分解,在一定程度上提高了分解精度。深度学习方法分解准确率高、泛化性能好,但深度学习涉及到大量的超参数,网络结构复杂使训练过程极度耗时。越来越多的学者研究嵌入式 NILM 方法<sup>[12-13]</sup>,期望将 NILM 算法与智能电表等嵌入式设备集成使用。然而深度学习算法结构复杂,受到存储空间和功耗的限制,深度学习模型在嵌入式设备上应用仍然是一个巨大的挑战。Chen 等<sup>[14]</sup>提出了宽度学习系统(broad learning system, BLS),相对于深度学习网络而言, BLS 是一种轻量算法,在训练时间上有明显优势,有学者将其应用于光伏发电功率超短期预测<sup>[15]</sup>和发电机旋转整流器的故障特征提取<sup>[16]</sup>中,在保证计算效率的同时取得了精度较高的计算结果。

为了解决非侵入式负荷分解网络结构复杂、训练极度耗时、对计算资源要求高等问题,本研究提出一种基于特征节点级联宽度学习系统(cascade of feature nodes broad learning system, CFBL)与麻雀搜索算法(sparrow search algorithm, SSA)的非侵入式负荷分解方法。首先,通过级联的特征节点提取输入数据特征,形成增强节点,构建级联宽度学习网络;然后,考虑到不同电器设备的分解网络具有不同的最优参数,利用麻雀算法全局搜索能力强、效率高的特点,对级联宽度学习负荷分解网络的参数进行优化,构建麻雀搜索算法优化的级联宽度学习网络(SSA-CFBL),提高非侵入式负荷分解的精度;最后,采用 UK-DALE<sup>[17]</sup>数据集进行仿真分析,验证本研究所提方法的优越性。

## 1 基于 SSA-CFBL 的非侵入式负荷分解方法

### 1.1 低频数据的非侵入式负荷分解

非侵入式负荷分解通过分析智能电表测量的总负荷电力数据,提取单个目标电器设备的电力信息,其本质是能源分解问题。目前,智能电表的采样频率较低,基于电压、谐波信号等高频特征的非侵入式负荷分解并不适用。考虑到市面上常用的智能电表只能达到 1 min 级别的召测能力<sup>[18]</sup>,本研究将采样间隔为 1 min 的有功功率作为输入,探究低功率数据下的非侵入式负荷分解方法。

设  $P(t)$  为总用电功率,非侵入式负荷分解的任务是将  $P(t)$  分解为目标设备功率信号  $p_j(t)$ 。在离散时间采样下,将  $P(t)$  简化为  $P(s)$ ,则非侵入式负荷分解函数模型为:

$$P(s) = \sum_{j=1}^M p_j(s) + e(s) \quad (1)$$

式中: $P(s)$ 为在采样点  $s$  时的总用电功率; $p_j(s)$ 为目标电器设备  $j$  在采样点  $s$  时的功率数据; $M$ 为电器设备的数量; $e(s)$ 为测量噪声。因此,可将非侵入式负荷分解看作时间序列回归问题,训练一个网络,使其由

$P(s)$ 得到目标设备功率的估计值。

### 1.2 CFBLS 负荷分解网络

本研究构建的 SSA-CFBLS 分解网络,是通过 CFBLS 学习总用电功率  $P(s)$ 与目标设备功率  $p_j(s)$ 的拟合关系,从而解决负荷分解问题。

CFBLS 是一种改进特征节点连接方式的 BLS 算法,结构如图 1 所示,将前一组特征节点和输入数据作为后一组特征节点的输入。相比于 BLS 直接将输入数据映射为特征节点,CFBLS 能够提取更多  $P(n)$ 的特征,从而提高非侵入式负荷分解网络的性能。




图 1 CFBLS 结构图

Fig. 1 Structure diagram of CFBLS

设图 1 中的 CFBLS 包括  $n$  组特征节点和  $m$  个增强节点。输入数据  $\mathbf{X}$  由历史总用电功率  $P(s)$  构成。首先通过特征映射得到一系列特征节点,第一组特征节点表示为  $\mathbf{Z}_1 = \phi(\mathbf{X}\mathbf{W}_{e1} + \boldsymbol{\beta}_{e1})$ ,第二组特征节点  $\mathbf{Z}_2$  由第一组特征节点和输入数据组成,表示为  $\mathbf{Z}_2 = \phi(\mathbf{Z}_1 \mathbf{W}_{z2} + \mathbf{X}\mathbf{W}_{e2} + \boldsymbol{\beta}_{e2})$ 。以此类推,第  $i$  组特征节点为:

$$\mathbf{Z}_i = \phi(\mathbf{Z}_{i-1} \mathbf{W}_{zi} + \mathbf{X}\mathbf{W}_{ei} + \boldsymbol{\beta}_{ei}), i = 2, 3, \dots, n. \quad (2)$$

式中:  $\phi$  为线性映射函数;  $\mathbf{W}_{zi}$ 、 $\mathbf{W}_{ei}$  和  $\boldsymbol{\beta}_{ei}$  分别为随机的特征节点权重和偏置。每组特征节点包含  $k$  个节点,共有  $nk$  个特征节点。

然后,将  $n$  组特征节点组成  $\mathbf{Z}^n = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_n]$ ,由  $\mathbf{Z}^n$  通过非线性变换生成增强节点  $\mathbf{H}_j$ ,即:

$$\mathbf{H}_j = \xi(\mathbf{Z}^n \mathbf{W}_{hj} + \boldsymbol{\beta}_{hj}), j = 1, 2, \dots, m. \quad (3)$$

式中:  $\xi$  是非线性激活函数;  $\mathbf{W}_{hj}$  和  $\boldsymbol{\beta}_{hj}$  分别为随机的增强节点权重和偏置。

最后,CFBLS 网络模型可以表示为:

$$\mathbf{Y} = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_n \mid \mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_m] \mathbf{W}^m = [\mathbf{Z}^n \mid \mathbf{H}^m] \mathbf{W}^m = \mathbf{A}\mathbf{W}^m. \quad (4)$$

式中:  $\mathbf{W}^m$  为输入到输出的权重;  $\mathbf{Y}$  为 CFBLS 的输出,在非侵入式负荷分解模型中为各电器设备的功率  $p_j(s)$ 。

在训练过程中,权重  $\mathbf{W}_{zi}$ 、 $\mathbf{W}_{ei}$ 、 $\mathbf{W}_{hj}$  以及偏置  $\boldsymbol{\beta}_{ei}$ 、 $\boldsymbol{\beta}_{hj}$  均不再变化,网络仅学习权重  $\mathbf{W}^m$  即可。因此 CFBLS 训练时相当于求解:

$$\operatorname{argmin}_{\mathbf{W}^m} \|\mathbf{A}\mathbf{W}^m - \mathbf{Y}\|_2^2 + \lambda \|\mathbf{W}^m\|_2^2, \quad (5)$$

从而求得  $\mathbf{W}^m = \mathbf{A}^+ \mathbf{Y}$ 。其中,  $\mathbf{A}^+$  表示  $\mathbf{A}$  的伪逆矩阵,由式  $\mathbf{A}^+ = \lim_{\lambda \rightarrow 0} (\lambda \mathbf{I} + \mathbf{A}\mathbf{A}^T)^{-1} \mathbf{A}^T$  求得。可见 CFBLS 训练无需梯度下降进行权重更新,训练速度快。对于非侵入式负荷分解而言,训练数据规模较大,采用在单层结构上扩展节点数目的 CFBLS 作为负荷分解工具,计算效率的优势更加明显。

在 CFBLS 网络分解负荷的过程中,决定网络特征节点和增强节点数量的参数  $n$ 、 $k$  和  $m$ ,将直接影响分解的效果。因此,本研究通过 SSA 对 CFBLS 进行参数寻优,以提高 CFBLS 分解网络的精度。

### 1.3 麻雀优化算法

SSA 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)、蝙蝠算

法(bat algorithm,BA),具有较好的寻优能力<sup>[19]</sup>。故采用 SSA 对 CFBLS 负荷分解网络参数进行寻优,寻找一个较好的 CFBLS 特征节点和增强节点个数。

在 SSA 中,将种群中的  $N$  只麻雀分为发现者和加入者。发现者具有较高的适应度值,负责搜索最优觅食区域,为所有加入者提供觅食区域和方向;加入者如果察觉到发现者找到了更好的食物,会立刻去争夺食物<sup>[20]</sup>。发现者在迭代过程中的位置更新为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp(-\frac{i}{\alpha i_{\text{termax}}}), & R_2 < S_T; \\ X_{i,j}^t + QL, & R_2 \geq S_T. \end{cases} \quad (6)$$

式中: $X_{i,j}^t$  表示第  $t$  次迭代时第  $i$  个麻雀在第  $j$  维上的位置信息; $\alpha$  是  $[0,1]$  区间的随机数, $Q$  是标准正态分布的随机数; $i_{\text{termax}}$  为最大迭代次数; $L$  是元素都为 1 的矩阵; $R_2$  和  $S_T$  分别为预警值和安全值。

加入者的位置更新为:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp(\frac{X_{\text{worst}} - X_{i,j}^t}{i^2}), & i > N/2; \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot E^+ \cdot L, & i \leq N/2. \end{cases} \quad (7)$$

式中: $X_p^{t+1}$  和  $X_{\text{worst}}$  分别是目前加入者所处的最优位置和目前全局中的最差位置; $E^+$  是元素为 1 或 -1 的矩阵的伪逆矩阵。当  $i > N/2$  时,适应度值较低的加入者  $i$  没能获得食物,需要去其他地方寻找食物。

另外,部分麻雀察觉到危险时会进行反捕食行为,其数量占麻雀总数的 10%~20%,其位置更新为:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t|, & f_i > f_g; \\ X_{i,j}^t + K \cdot \frac{|X_{i,j}^t - X_{\text{best}}^t|}{(f_i - f_w) + \epsilon}, & f_i = f_g. \end{cases} \quad (8)$$

式中: $X_{\text{best}}^t$  为目前全局中的最优位置; $\beta$  为服从均值为 0、方差为 1 的正态分布的随机数; $K$  为  $[-1,1]$  区间的随机数; $\epsilon$  是为了保证分母不为 0 而设置的常数; $f_i$  是当前麻雀个体的适应度值, $f_g$  和  $f_w$  分别为目前全局中的最优和最差适应度值。

## 2 负荷分解流程

本研究所提方法的分解过程如图 2 所示,图中实线代表 SSA-CFBLS 分解网络建立的过程,虚线代表应用训练好的网络进行负荷分解的过程,具体步骤如下。

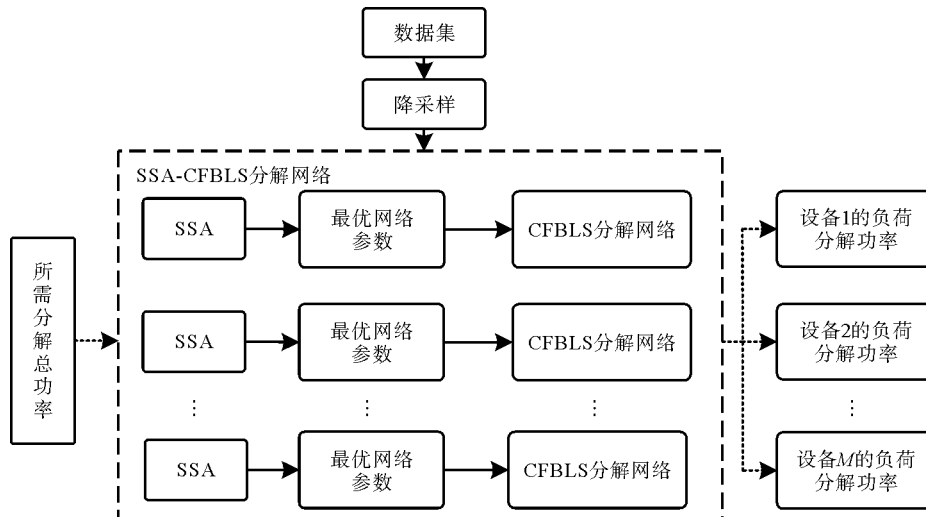


图 2 分解过程示意图

Fig. 2 Process diagram of disaggregation

1) 训练数据的构建。UK-DALE 数据集是目前广泛应用的非侵入式负荷分解数据集,是负荷分解的测试基准数据集之一。该数据集记录了 5 个家庭 10 多种类型电器设备的真实用电数据,采样频率为 1/6 Hz。本研究选择冰箱、洗碗机、水壶、微波炉作为目标电器设备,这 4 种电器设备消耗功率占比较高,而且可以涵盖数据集中绝大多数电器设备的工作状态,如水壶等简单的开/关状态设备和洗衣机等复杂的多状态设备。将数据降采样到 1/60 Hz,使用低频功率数据作为训练集。

2) 训练分解网络。在网络训练阶段,总用电功率作为特征数据,目标设备功率作为标签,对于不同的用电设备,分别构建 CFBLs 网络进行训练。不同电器设备的特征不同,对应的分解网络最优参数不同。将 CFBLs 负荷分解的误差作为适应度函数,对每个 CFBLs 分解网络的  $N_n$ 、 $N_f$  和  $N_m$  3 个参数进行寻优,得到 SSA-CFBLs 非侵入式负荷分解网络。

3) 应用 SSA-CFBLs 网络进行负荷分解。将待分解的总用电功率经同样的降采样后送入训练好的网络并输出分解值,从而得到目标设备的功率序列。

### 3 算例分析

本研究以 UK-DALE 数据集 2 号房间 60 天的数据作为训练集,以 1 天的数据作为测试集,验证本研究方法的有效性。

#### 3.1 评价指标

本研究采用平均绝对误差( $M_{AE}$ )、均方根误差( $R_{MSE}$ )、召回率( $R_{ecall}$ )、准确率( $P_{recision}$ )和 F1 分数( $F_1$ )作为算法评价指标,用平均绝对误差与均方根误差评估分解值和实际值的误差,用召回率、准确率与 F1 分数评估电器是否处于工作状态的准确度。计算式分别为:

$$M_{AE} = \frac{1}{n_{um}} \sum_{i=1}^{n_{um}} |y_i - \hat{y}_i|, \quad (9)$$

$$R_{MSE} = \sqrt{\frac{1}{n_{um}} \sum_{i=1}^{n_{um}} (y_i - \hat{y}_i)^2}, \quad (10)$$

$$R_{ecall} = \frac{T_p}{T_p + F_N}, \quad (11)$$

$$P_{recision} = \frac{T_p}{T_p + F_P}, \quad (12)$$

$$F_1 = \frac{2 \times R_{ecall} \times P_{recision}}{R_{ecall} + P_{recision}}. \quad (13)$$

式中: $n_{um}$  为样本数量; $y_i$  为目标设备功率的真实值; $\hat{y}_i$  为目标设备功率的分解估计值; $T_p$  表示分解的电器状态和实际状态均为开的数量; $F_N$  表示分解的电器状态为开,实际状态为关闭的数量; $F_P$  表示分解的电器状态为关,实际状态为开的数量。

#### 3.2 SSA 参数优化结果

如果特征节点和增强节点的数量太多会造成提取特征的冗余,也会增加网络复杂度;如果特征节点和增强节点的数量过少又难以提取完整的数据特征<sup>[16]</sup>。因此,参考文献[21]中参数设置的范围,将待寻优参数  $n$ 、 $k$  和  $m$  的搜索范围分别设置为[1, 50]、[1, 50]、[1, 200],麻雀数量设置为 50,迭代次数为 100。为了验证 SSA 的优越性,将其与 GWo、BA 进行比较。其中 SSA、GWo 和 BA 参数设置分别为:麻雀数量为 50,发现者的比例为 20%,警戒者的比例为 10%,安全值  $S_T=0.8$ ;灰狼数量为 50;蝙蝠数量为 50,脉冲频率为 0.5,响度为 0.5。各目标设备负荷分解网络参数寻优的过程如图 3 所示。由图 3 可知,对于冰箱、洗碗机、水壶和微波炉的负荷分解网络,3 种优化算法在参数寻优迭代过程中适应度不断下降,但相比于 BA 与 GWo,SSA 得到的优化结果适应度最低,分别为 18.16、64.79、82.06 和 66.97,说明 SSA 搜索能力更强。适应度不断下降,代表 CFBLs 网络负荷分解的误差不断减小,证明优化 CFBLs 网络的参数可以提高分解精度。SSA 参数寻优结果如表 1 所示。

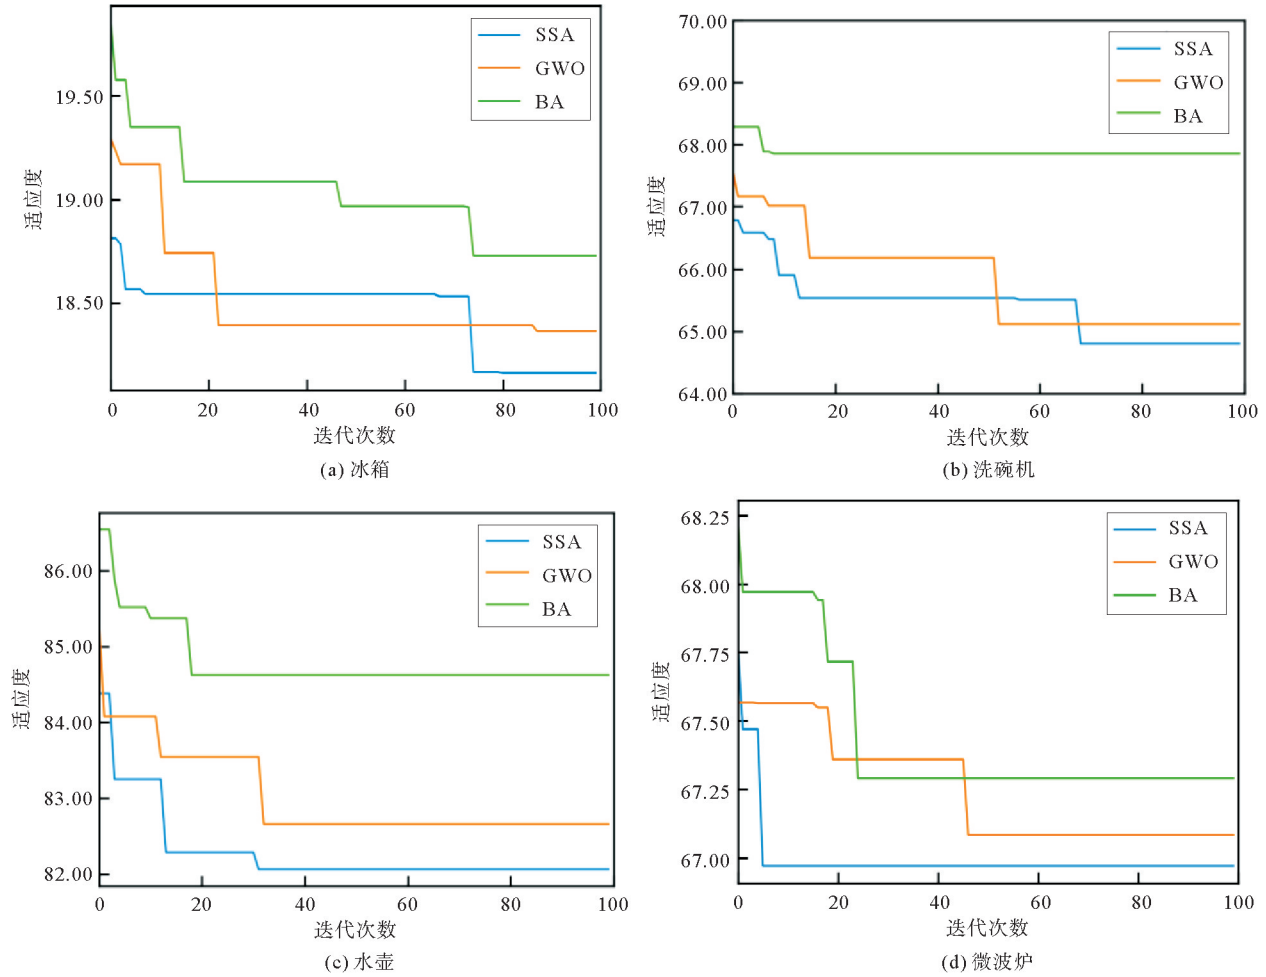


图 3 负荷分解网络参数优化过程图

Fig. 3 Process diagram of load disaggregation network parameter optimization

### 3.3 SSA-CFBLs 负荷分解结果分析

将组合优化 (combinatorial optimization, CO)、因子隐马尔可夫模型 (factorial hidden Markov model, FHMM)、长短时记忆网络 (long short-term memory, LSTM)、BLS 和 CFBLs 进行对比,以验证本研究所提方法的效果。为了比较 BLS 与 CFBLs 的性能,将 BLS 和 CFBLs 的特征节点和增强节点数量都设定为表 1 中的数量, LSTM 深度神经网络的迭代次数为 50, batchsize 设置为 128。

表 2 为 4 种分解算法 MAE 与 RMSE 的计算结果。可以看出, CO 和 FHMM 算法负荷分解误差较大, 基于深度学习和宽度学习的负荷分解误差显著下降。对于冰箱和洗碗机, LSTM 的两种误差指标值优于 SSA-BLS, 说明 SSA-BLS 的分解能力未优于 LSTM。改进后的 SSA-CFBLs 通过特征节点级联, 增强了输入数据的特征提取能力, 各电器设备的分解误差均小于 LSTM, 提高了分解的准确率。

图 4 为负荷分解结果对比, 展示了 2 号家庭 1 天中 4 种目标设备的真实功率 (real power) 和 5 种方法分解得到的功率序列。由图 4 可知, FHMM 与 CO 算法分解得到的功率序列与真实功率序列有较大差距, 这是因为 FHMM 与 CO 只能对电器设备的状态进行预测, 难以反映电器设备的详细功率信息。相反, LSTM、SSA-BLS、SSA-CFBLs 的分解结果都能较好地与真实功率吻合, 侧面说明了宽度学习具有与 LSTM 深度神

表 1 目标设备最优节点数量

Table 1 Optimal number of nodes for the target device

参数	冰箱	洗碗机	水壶	微波炉
$n$	4	6	9	19
$k$	46	37	37	18
$m$	186	181	161	192

经网络同样优秀的分解能力。

表 2 不同算法分解误差对比

Table 2 Comparison of disaggregation errors of different algorithms

W

指标	方法	冰箱	洗碗机	水壶	微波炉
$M_{AE}$	CO	64.64	187.79	97.47	69.60
	FHMM	45.09	75.68	61.37	185.08
	LSTM	21.02	11.64	20.08	19.34
	SSA-BLS	21.86	13.31	12.95	9.98
	SSA-CFBLs	14.32	10.35	8.09	8.97
$R_{MSE}$	CO	54.15	389.45	426.67	166.00
	FHMM	30.98	350.06	320.37	248.46
	LSTM	24.51	68.03	91.02	79.84
	SSA-BLS	25.51	73.22	92.74	69.83
	SSA-CFBLs	18.16	64.79	82.06	66.93

为了更好地体现 CFBLs 的优越性,着重对 LSTM 与 CFBLs 进行比较。将 4 种电器设备在某个工作期间的真实功率与分解功率进行对比,结果如图 5 所示。当设备开始工作时,两种算法都能准确识别,并且能够较好地跟踪功率序列的变化,但本研究提出的 CFBLs 算法更接近设备的实际运行效果。

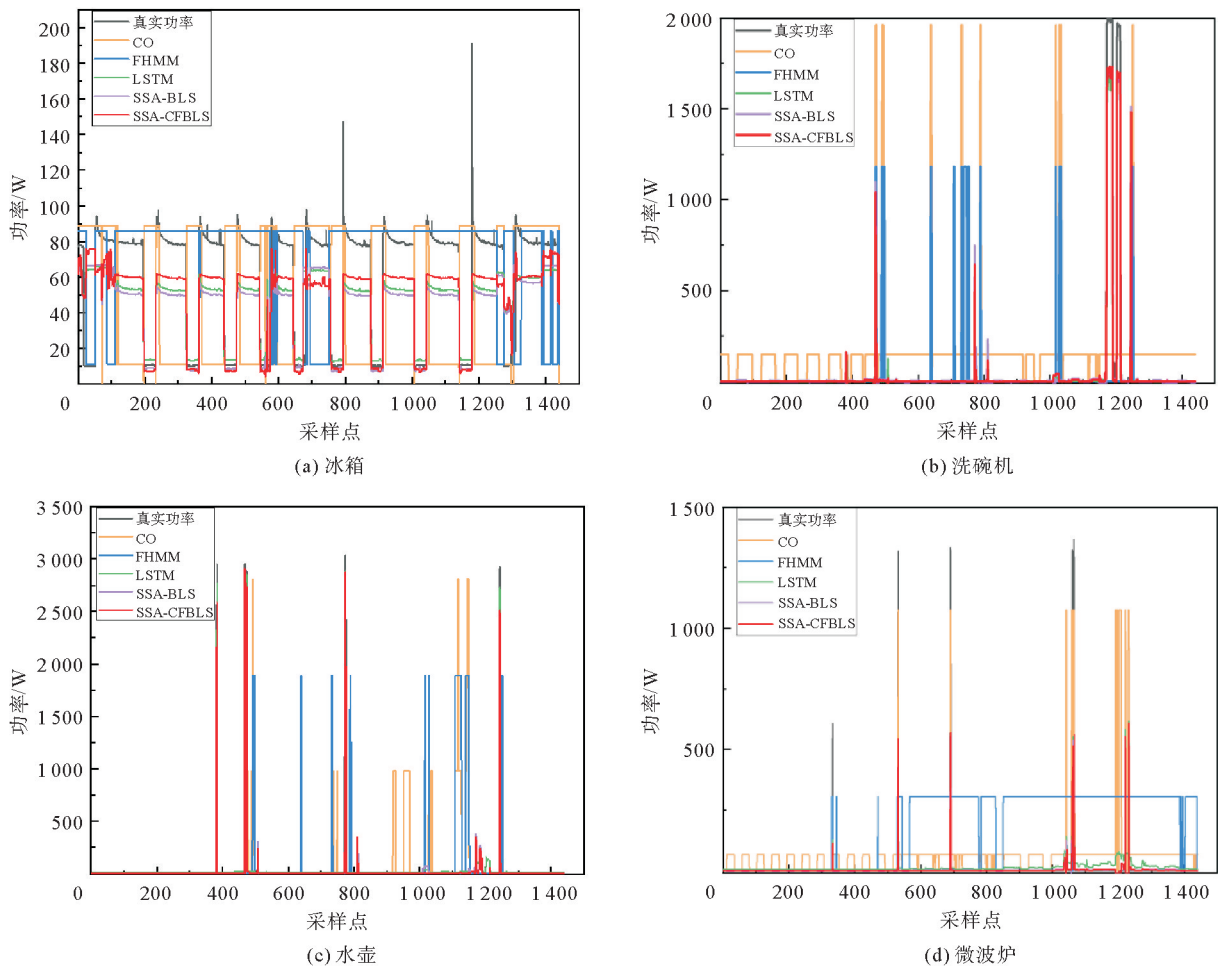


图 4 整体负荷分解对比

Fig. 4 Comparison of overall load disaggregation




图 5 LSTM 与 SSA-CFBLs 局部负荷分解对比

Fig. 5 Comparison of local load disaggregation between LSTM and SSA-CFBLs

为了定量分析 CFBLs 对开/关状态的识别能力,将召回率、准确率和 F1 分数作为开/关评估指标,开/关评估指标数值越大,识别准确度越高。图 6 为 SSA-CFBLs 与 LSTM 的开/关评估指标对比。由图 6 可以看出,CFBLs 的开/关评估指标均优于 LSTM。相比于 LSTM,CFBLs 的召回率、准确率和 F1 分数平均分别提高了 10.45%、2.03%和 6.58%。




图 6 开/关状态测试结果

Fig. 6 On/off status test results

### 3.4 应用可行性分析

目前,非侵入式负荷分解应用有两种方式:一种是通过边缘计算和云计算协同完成非侵入式负荷分解<sup>[12]</sup>;另一种是直接通过智能电表等嵌入式设备完成分解。边缘计算和云计算协同的方式是在云端进行训练,然后将训练好的模型下载到嵌入式设备中,这种方式对嵌入式设备的计算能力要求低,而直接通过智能电表等嵌入式设备完成分解的方式,对设备的计算能力要求高。本书根据非侵入式负荷分解的两种方式分



析 CFBLs 算法应用的可行性。

时间复杂度会影响算法的训练时间,CFBLs 算法的时间复杂度  $O$  与节点数量、数据规模有关,

$$O = n_{\text{um}} \times d \times [(m + n) \times k]^{[22]}。 \quad (14)$$

式中, $d$  为数据维数。若以分解冰箱数据为例,训练数据规模为 86 400 个采样点, $n$ 、 $k$  和  $m$  分别为 4、46 和 180,CFBLs 算法的时间复杂度为  $86\,400 \times 50 \times 180$ ,而深度学习算法参数多达百万,复杂度远大于 CFBLs。

云端计算机计算能力强,当在配置为 Intel(R) Core(TM) i5-9300H CPU @ 2.40 GHz 的计算机上训练时,LSTM 平均训练时间为 891.15 s,而本研究提出的 CFBLs 平均耗时仅为 2.24 s,远少于深度学习算法的训练耗时。

重点关注直接在嵌入式设备上完成分解的可行性。文献[23]设计出一种多芯智能电表,可以实现非侵入式负荷分解,但依赖于高 CPU 与大容量储存。市场上已有的非侵入式负荷分解设备数据处理模块采用 STM32F746ARM 芯片,搭载了 64 M 数据内存,处理速度最高可到 220 MHz,但此设备的计算能力低于计算机,并且高 CPU 与大容量储存的非侵入式负荷分解设备的价格较贵,在实际应用中受到经济性的限制。相较于深度学习,CFBLs 算法对 CPU 性能和储存容量的要求小,更适合于直接通过嵌入式设备进行分解的场景。

#### 4 结论

本研究提出一种基于级联宽度学习与麻雀算法的非侵入式负荷分解方法。首先,利用轻量的 BLS 构建非侵入式负荷分解网络,并改进特征节点的连接方式形成 CFBLs 算法。然后,通过 SSA 确定分解网络的最优特征节点和增强节点数量,提高了负荷分解网络的性能。算例分析表明,相比于 CO、FHMM 和 LSTM 算法,本研究所提方法分解精度更高,并且网络结构简单、训练过程耗时少,对计算资源要求不高,为非侵入式负荷分解与智能电表等嵌入式平台的集成使用提供了算法支持。

#### 参考文献:

- [1] 胡鞍钢. 中国实现 2030 年前碳达峰目标及主要途径[J]. 北京工业大学学报(社会科学版),2021,21(3):1-15.  
HU Angang. China's goal of achieving carbon peak by 2030 and its main approaches[J]. Journal of Beijing University of Technology (Social Sciences Edition),2021,21(3):1-15.
- [2] ZEIFMAN M,ROTH K. Nonintrusive appliance load monitoring:Review and outlook[J]. IEEE Transactions on Consumer Electronics,2011,57(1):76-84.
- [3] 王守相,葛磊蛟,王凯. 智能配电系统的内涵及其关键技术[J]. 电力自动化设备,2016,36(6):1-6.  
WANG Shouxiang,GE Leijiao,WANG Kai. Main contents and key technologies of smart distribution system[J]. Electric Power Automation Equipment,2016,36(6):1-6.
- [4] 陈中,方国权,赵奇,等. 面向区域级用户的非侵入式负荷监测技术应用方法[J]. 电力自动化设备,2020,40(8):126-132.  
CHEN Zhong,FANG Guoquan,ZHAO Qi,et al. Application method of non-intrusive load monitoring technology for region-level users[J]. Electric Power Automation Equipment,2020,40(8):126-132.
- [5] 程祥,李林芝,吴浩,等. 非侵入式负荷监测与分解研究综述[J]. 电网技术,2016,40(10):3108-3117.  
CHENG Xiang,LI Linzhi,WU Hao,et al. A survey of the research on non-intrusive load monitoring and disaggregation[J]. Power System Technology,2016,40(10):3108-3117.
- [6] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE,1992,80(12):1870-1891.
- [7] 孙毅,李昊洋,刘耀先,等. 基于改进隐马尔科夫模型的非侵入式家居负荷识别[J]. 电力建设,2020,41(4):73-80.  
SUN Yi,LI Haoyang,LIU Yaoxian,et al. Non-intrusive home-load identification based on improved hidden Markov model [J]. Electric Power Construction,2020,41(4):73-80.
- [8] KELLY J,KNOTTENBELT W. Neural NILM:Deep neural networks applied to energy disaggregation[C]//Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-efficient Built Environments. Seoul,2015:55-64.
- [9] ZHANG C Y,ZHONG M J,WANG Z Z,et al. Sequence-to-point learning with neural networks for non-intrusive load monitoring[C]//Proceedings of the 32nd AAAI Conference on Artificial Intelligence. New Orleans,2018,32(1):73-80.

- [10] 王轲,钟海旺,余南鹏,等.基于 seq2seq 和 Attention 机制的居民用户非侵入式负荷分解[J].中国电机工程学报,2019,39(1):75-83.  
WANG Ke,ZHONG Haiwang,YU Nanpeng,et al. Nonintrusive load monitoring based on sequence-to-sequence model with attention mechanism[J]. Proceedings of the CSEE,2019,39(1):75-83.
- [11] 罗平,樊星驰,章坚民,等.基于电器运行状态和深度学习的非侵入式负荷分解[J].电力系统自动化,2021,45(12):49-56.  
LUO Ping,FAN Xingchi,ZHANG Jianmin,et al. Non-intrusive load decomposition based on operation state of electrical appliances and deep learning[J]. Automation of Electric Power Systems,2021,45(12):49-56.
- [12] 刘耀先,孙毅,李彬,等.基于边缘嵌入深度学习的非侵入式负荷分解方法[J].电网技术,2019,43(12):4329-4337.  
LIU Yaoxian,SUN Yi,LI Bin,et al. Non-intrusive load disaggregation method based on edge embedded deep learning[J]. Power System Technology,2019,43(12):4329-4337.
- [13] BIANSONGNERN S,PLANGKLANG B. An alternative low-cost embedded NILM system for household energy conservation with a low sampling rate[J]. Symmetry,2022,14(2):279-300.
- [14] CHEN C L P,LIU Z L. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture[J]. IEEE transactions on Neural Networks and Learning Systems,2017,29(1):10-24.
- [15] 周楠,徐潇源,严正,等.基于宽度学习系统的光伏发电功率超短期预测[J].电力系统自动化,2021,45(1):55-64.  
ZHOU Nan,XU Xiaoyuan,YAN Zheng,et al. Ultra-short-term forecasting of photovoltaic power generation based on broad learning system[J]. Automation of Electric Power Systems,2021,45(1):55-64.
- [16] 崔江,冯赛,张卓然,等.基于 BLS 的无刷发电机旋转整流器特征提取技术研究[J].中国电机工程学报,2020,40(12):4004-4013.  
CUI Jiang,FENG Sai,ZHANG Zhuoran,et al. Research on feature extraction technology of brushless generator rotating rectifier based on BLS[J]. Proceedings of the CSEE,2020,40(12):4004-4013.
- [17] KELLY J,KNOTTENBELT W. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes[J]. Scientific Data,2015,2(1):1-14.
- [18] 崔亮节,孙毅,刘耀先,等.考虑分时段状态行为的非侵入式负荷分解方法[J].电力系统自动化,2020,44(5):215-222.  
CUI Liangjie,SUN Yi,LIU Yaoxian,et al. Non-intrusive load disaggregation method considering time-phased state behavior[J]. Automation of Electric Power Systems,2020,44(5):215-222.
- [19] 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.
- [20] XUE J K,SHEN B. A novel swarm intelligence optimization approach:Sparrow search algorithm[J]. Systems Science & Control Engineering,2020,8(1):22-34.
- [21] 郭威,徐涛.基于 M-estimator 的鲁棒宽度学习系统[J].控制与决策,2023,38(4):1039-1046.  
GUO Wei,XU Tao. M-estimator-based robust broad learning system[J]. Control and Decision,2023,38(4):1039-1046.
- [22] 夏恒,汤健,崔璨麟,等.基于宽度混合森林回归的城市固废焚烧过程二噁英排放软测量[J].自动化学报,2023,49(2):343-365.  
XIA Heng,TANG Jian,CUI Canlin,et al. Soft sensing method of dioxin emission in municipal solid waste incineration process based on broad hybrid forest regression[J]. Acta Automatica Sinica,2023,49(2):343-365.
- [23] 孙毅,王永生,顾博川,等.具备边缘计算能力的多芯智能电表设计[J].电子测量技术,2019,42(23):194-199.  
SUN Yi,WANG Yongsheng,GU Bochuan,et al. Design of multi-core smart meter with edge computing capability[J]. Electronic Measurement Technology,2019,42(23):194-199.

(责任编辑:齐敏华)