

考虑负荷功率特性与时序相关性的 非侵入式工业负荷监测

张逸¹, 陈锦涛¹, 李传栋^{2*}, 张良羽¹, 孙守铨¹

- 福州大学电气工程与自动化学院, 福建省福州市 350108;
- 福建农林大学机电工程学院, 福建省福州市 350100

Non-intrusive Industrial Load Monitoring Considering Load Power Characteristics and Timing Correlation

ZHANG Yi¹, CHEN Jintao¹, LI Chuandong^{2*}, ZHANG Liangyu¹, SUN Shouquan¹

- College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, Fujian Province, China; 2. College of Mechanical and Electrical Engineering, Fujian Agriculture and Forestry University, Fuzhou 350100, Fujian Province, China)

ABSTRACT: The implementation of non-intrusive load monitoring for industrial users contributes to power demand-side management and enhances energy utilization efficiency. To address the scarcity of sample data in industrial scenarios and the limitation of existing methods that don't account for industrial production process constraints, a non-intrusive industrial load decomposition method is proposed that considers the load power characteristics and timing correlation. Firstly, based on the time-varying characteristics of load operating power, the load is categorized into three types: switching load, multi-state load, and continuously varying load. Secondly, since the first two types of loads have stable power states, the integer programming method is used to establish the load power model by considering both active and reactive power characteristics. Thirdly, by extracting the actual production cycle of the enterprise and considering that the power of continuously varying loads has a continuous consumption range, the matrix factorization method is used to establish a load power model. Finally, considering the effects of base vector grouping and the constraints of load timing correlation under production process constraints, load decomposition is achieved by combining and solving the two models. The algorithm is validated using public datasets and measured private datasets, and the results indicate that the proposed method has higher accuracy and better engineering practicality compared to existing methods.

基金项目: 国家自然科学基金项目(51777035); 宁夏回族自治区自然科学基金项目(2023AAC03834)。

Project Supported by National Natural Science Foundation of China (51777035); Natural Science Foundation of Ningxia Hui Autonomous Region (2023AAC03834).

KEY WORDS: non-intrusive load monitoring; industrial loads; load power characteristics; timing correlation; integer programming; matrix factorization

摘要: 实施工业用户非侵入式负荷监测有助于电力需求侧管理与能源利用效率提高。针对工业场景下样本数据稀缺、现有方法未考虑工业生产流程约束等问题,提出一种考虑负荷功率特性与时序相关性的非侵入式工业负荷分解方法。首先,根据负荷运行功率的时变特性,并考虑实际工业信息的可获取性,将负荷分为开关型负荷、多状态型负荷与连续变化型负荷;其次,由于前2类负荷具有稳定的功率状态,同时考虑有功及无功功率特性,采用整数规划方法建立负荷功率模型;再次,提取企业实际生产周期,且由于连续变化型负荷的功率具有连续的功率消耗范围,采用矩阵分解方法建立负荷功率模型;最后,考虑基向量分组效应与生产流程约束下的负荷时序相关性约束,联合以上2个模型并求解,实现负荷分解。利用公开数据集及实测私有数据集对算法进行验证,结果表明所提方法较已有方法具有更高的精度和更好的工程实用性。

关键词: 非侵入式负荷监测; 工业负荷; 负荷功率特性; 时序相关性; 整数规划; 矩阵分解

0 引言

工业领域能源消费量占全国总体消费量 65% 左右^[1], 是节能降碳的主要领域之一。如何推动工业用户生产流程优化, 提高其电能利用效率, 是一个亟需解决的问题^[2]。

有研究表明, 通过监测负荷的用电数据, 每年可以帮助用户节省高达 20% 的能源消耗^[3-4]。当前,

常用的负荷监测方式有 2 种：侵入式负荷监测 (intrusive load monitoring, ILM) 与非侵入式负荷监测 (non-intrusive load monitoring, NILM)^[5]。侵入式负荷监测通过在每个负荷处安装量测装置获取用电数据。现有部分关注能耗的工业用户会对重要及能耗大的负荷安装量测装置，但对部分能耗小的负荷却并没有关注。同时，在工业用户内部，大量量测装置的安装以及后期维护不仅可能影响企业的正常生产^[6-7]，也会涉及相关隐私数据的收集^[8]，给企业造成了一定的困扰。而相比于侵入式负荷监测，非侵入式负荷监测更易于扩展到更多的负荷和更大的监测范围，而不会增加过多的复杂性以及量测装置。

NILM^[9]最早由 Hart 教授于 20 世纪 80 年代提出，其实质是分析用户总的用电信息，并将其分解为单个负荷的使用情况。随着智能家居与先进算法的普及，面向居民用户的 NILM 技术已经较为成熟，比较有代表性的方法有因子隐马尔可夫模型^[10-11]、卷积神经网络^[12-14]、图信号处理^[15-16]和图卷积网络^[17-18]等。家庭负荷往往采用几个稳定的功率状态进行建模，但许多工业负荷中存在功率连续变化的特点，导致过去的研究方法在工业用户上难以迁移，同时，工业用户数据因涉及商业机密，其保密性较强，造成样本数据较少，故工业环境下有关 NILM 的研究尚少^[8]。

当前，工业场景下的 NILM 方法主要分为模式识别与数学优化 2 类^[19]。基于模式识别的负荷分解，其实质是通过学习各用电负荷的特征模式，达到识别负荷的目标。文献[20]通过提取负荷稳态波形，采用随机森林的机器学习方法实现工业负荷辨识。与传统机器学习需人工提取特征相比，深度学习技术具有自动提取特征的优势^[21]。文献[22]建立了一个基于深度神经网络的分解模型。随后，序列翻译^[23]、物理先验知识嵌入^[24]、时序特征提取^[25]等方法也相继提出，在负荷分解性能上有了一定的提升。然而，模式识别方法需要大量精准的样本数据，这就需要安装大量监测装置，安装与维护成本较高。同时，不同工业企业因行业不同，其负荷与生产流程差异较大，在面对新的工业企业时，采用深度学习方法需要重新进行大量数据采集与训练^[8]。

相比模式识别，数学优化通过少量样本数据，建立完备的负荷特征库，将 NILM 问题转化为优化问题，通过加入不同约束项，实现负荷分解，其实

用性更好。文献[26]针对流程工业分别建立了不同负载特性的负荷模型，并采用混合整数规划的方法，实现负荷分解，但是对于相似有功功率特征的负荷难以区分，降低了解析准确度。同时，未考虑企业实际生产周期而采用固定时间对负荷特征矩阵中的基向量进行划分，会导致负荷分解精度低。文献[27]同时考虑了有功功率与无功功率 2 个特征，提出了一种基于负荷运行状态和改进灰狼算法的负荷分解方法，但未考虑功率为连续变化的负荷，导致了分解精度低的问题。同时，因生产流程的需要，工业负荷之间存在时序相关性，且存在超前、滞后等模式，而以上文献均未考虑这种时序相关性的约束条件，这将降低分解精度。同时，以上 2 类方法都需要一定的负荷样本数据进行训练，现有研究均未明确提出针对不同负荷类型的样本数据获取方法，在工业场景中，在全部负荷安装用电量测装置可能会影响正常生产^[6-7]，工程可行性低。

针对上述问题，本文提出一种考虑负荷功率特性与时序相关性的非侵入式工业负荷分解方法。首先，根据负荷运行功率数据的时变特性，并充分利用工业企业可调研或监测获取的信息，将负荷分为开关型负荷、多状态型负荷与连续变化型负荷，并明确了不同负荷类型的样本数据获取方法；其次，同时考虑有功及无功功率特征，针对开关型负荷与多状态型负荷具有稳定的运行状态，采用整数规划的方法实现负荷功率建模；再次，由于连续变化型负荷具有连续的功率消耗范围，且考虑企业实际生产周期各不相同，故将历史负荷的功率数据按所提取的实际生产周期进行切割构建基向量，并采用基向量的线性组合实现连续变化型负荷功率建模；最后，将已建立的 2 个模型进行联合，并计及不同工业负荷功率数值可能差距较大以及工业生产约束下的负荷相关性，建立优化模型并添加相关正则化项，求解优化模型实现最终的负荷分解。基于公开数据集及实测私有数据集的算例表明，对比现有方法，本文方法具有更高的精度和工程可行性。

1 非侵入式工业负荷分解框架

1.1 工业 NILM 问题概述

工业 NILM 技术通过分析工业用户电表采集的总功率 $P_{\text{sum}}(t)$ ，分离出目标负荷的功率 $P_o(t)$ ，估计出单个负荷的功率、使用状态等用电信息^[28]。对于某一工业用户，在 t 时刻工业总负荷功率序列 P_{sum}

可表示为

$$P_{\text{sum}}(t) = \sum_{o=1}^N P_o(t) + e(t) \quad (1)$$

式中： $P_{\text{sum}}(t)$ 为 t 时刻总负荷聚合功率； $P_o(t)$ 为第 o 个负荷的功率； N 为负荷的总数量； $e(t)$ 为聚合功率和各个负荷的测量误差。

1.2 考虑功率特性的工业负荷分类

本节通过工业负荷分类，充分利用工业企业可调研获取的信息建立开关型负荷和多状态型负荷特征库，仅需对连续变化型负荷安装量测装置以获取样本数据，减少了所需装置数量，提升方法在实际工程中的可行性，下文进行详细叙述。

在居民场景中，家庭负荷往往采用几个稳定的功率状态进行建模，而在工业场景中存在较多电动机等负荷，由于其变频调速特性，造成功率连续平滑地变化，故采用几个稳定的状态进行建模会导致精度较低。所以，本文根据负荷运行功率的时变特性，将工业负荷分为开关型负荷、多状态型负荷和连续变化型负荷^[29]。

1) 开关型负荷：如图 1 所示，开关型负荷是只有开启和关闭 2 种状态的负荷，且在这 2 种状态中，负荷的功率保持在某一数值附近，如具有启停状态的真空泵。对于开关型负荷，其运行状态稳定，且往往以额定功率状态运行，负荷的额定功率在负荷铭牌上有记录，因此，可通过调研负荷的铭牌构建开关型负荷特征库。

2) 多状态型负荷：如图 2 所示，多状态型负荷




图 1 典型开关型负荷有功功率时序图

Fig. 1 Typical active power timing diagram for switching loads




图 2 典型多状态型负荷有功功率时序图

Fig. 2 Typical active power timing diagrams for multi-state load

根据运行功率的数值大小可以分为有限个状态，在每一个状态功率数值大小不随时间变化，如具有多个工况的研磨机。在工业企业的生产管理中，为了保证生产正常运行，会记录负荷不同工况下的功率数据及相关运行参数^[30]，因此，可通过考察负荷工况及其所对应的功率信息建立多状态负荷特征库。

3) 连续变化型负荷：如图 3 所示，连续变化型负荷具有连续的功率范围 $[0, p_{\text{max}}]$ ，如变频调速的电机。对于连续变化型负荷，需要安装临时监测装置，获取负荷运行功率数据，以构建连续变化型负荷特征库。




图 3 典型连续变化型负荷有功功率时序图

Fig. 3 Typical active power timing diagram for continuously varying loads

1.3 生产流程约束下的时序相关性分析

在工业场景中，由于生产流程的约束，负荷的运行是需要相互配合的，在功率数据上就表现出负荷之间具有时序相关性^[31]，而部分负荷需要同时、延时或提前改变运行状态，这也对应着时序相关性中的时间超前、滞后等模式。如图 4 所示，负荷 1 为某工业用户油漆房中的压风机，负荷 2 为油漆房中的引风机，由于油漆房中产生的废气需实时排出，这就需要 2 个负荷同时运行，以将废气排到后续 UV 光氧设备进一步处理，故负荷 1 与负荷 2 会表现出时序相关性。相比之下，这种强的时序相关性在居民用户中并不常见，本文考虑工业生产的要求，引入负荷相关性以提高负荷分解的精度。




图 4 负荷相关性示意图

Fig. 4 Load correlation schematic

2 负荷建模方法

2.1 基于整数规划的开关型与多状态型负荷建模
相比于家庭场景，在工业场景中存在大量异步

电动机、感应电炉、交流电焊机等感性负载，它们将消耗大量无功功率，故在工业场景中负荷的无功功率特征会比家庭场景中更为明显^[32]。同时，随着负荷种类增多，仅考虑单一功率特征会造成特征重叠，进而导致分解准确度降低^[33]，故本文同时考虑有功功率与无功功率作为特征。通过加入无功功率对分解出的有功功率加以校正，以得到更好的分解效果。事实上，有功功率代表了系统实际使用的能量，本文的最终目标为分解出负荷的有功功率，是为了分析负荷的有功功率使用情况，而进一步降低企业的能耗，无功功率只是辅助特征，其目的是进一步提高分解有功功率的准确率。

对于开关型负荷和多状态型负荷，往往具有稳定的状态，可以采用整数规划的方法进行建模。只需要负荷的工况信息及其对应的功率即可实现开关型与多状态型负荷建模。对于单个负荷，其 t 时刻有功功率与无功功率可分别表示为：

$$\hat{X}_P(t) = \sum_{i=1}^{K_N} a_i(t) y_{P,i}, \quad \forall t \in [1, m] \quad (2)$$

$$\hat{X}_Q(t) = \sum_{i=1}^{K_N} a_i(t) y_{Q,i}, \quad \forall t \in [1, m] \quad (3)$$

式中： K_N 为负荷所拥有的状态数量； $y_{P,i}$ 、 $y_{Q,i}$ 分别为第 i 个稳定状态的有功和无功功率； $a_i(t)$ 表示每一个稳定状态是否开启， $a_i(t)=1$ 表示开启， $a_i(t)=0$ 表示关闭； m 为所选取负荷功率的数据长度。因为每个负荷在一个时刻只能处于 1 种状态，于是有如下约束：

$$a_i(t) \in \{0, 1\}, \quad \forall t \in [1, m] \quad (4)$$

$$\sum_{i=1}^{K_N} a_i(t) = 1, \quad \forall t \in [1, m] \quad (5)$$

进一步，对于 N 个负荷的有功和无功功率的总和可表示为：

$$X_P(t) = \sum_{n=1}^N \sum_{i=1}^{K_N} a_{n,i}(t) y_{P,n,i}, \quad \forall t \in [1, m] \quad (6)$$

$$X_Q(t) = \sum_{n=1}^N \sum_{i=1}^{K_N} a_{n,i}(t) y_{Q,n,i}, \quad \forall t \in [1, m] \quad (7)$$

式中 $y_{P,n,i}$ 、 $y_{Q,n,i}$ 分别为第 n 个负荷的第 i 个状态下的有功和无功功率。将式(6)、(7)在时间上展开，并以矩阵形式表示如下：

$$\mathbf{X}_P = \sum_{n=1}^N \mathbf{A}_n \mathbf{Y}_{P,n} \quad (8)$$

$$\mathbf{X}_Q = \sum_{n=1}^N \mathbf{A}_n \mathbf{Y}_{Q,n} \quad (9)$$

$$\mathbf{A}_n \mathbf{Y}_{P,n} = \begin{bmatrix} a_{n,1}(1) & a_{n,2}(1) & \dots & a_{n,K_n}(1) \\ a_{n,1}(2) & a_{n,2}(2) & \dots & a_{n,K_n}(2) \\ \vdots & \vdots & \dots & \vdots \\ a_{n,1}(m) & a_{n,2}(m) & \dots & a_{n,K_n}(m) \end{bmatrix} \begin{bmatrix} y_{P,n,1} \\ y_{P,n,2} \\ \vdots \\ y_{P,n,K_n} \end{bmatrix} \quad (10)$$

$$\mathbf{A}_n \mathbf{Y}_{Q,n} = \begin{bmatrix} a_{n,1}(1) & a_{n,2}(1) & \dots & a_{n,K_n}(1) \\ a_{n,1}(2) & a_{n,2}(2) & \dots & a_{n,K_n}(2) \\ \vdots & \vdots & \dots & \vdots \\ a_{n,1}(m) & a_{n,2}(m) & \dots & a_{n,K_n}(m) \end{bmatrix} \begin{bmatrix} y_{Q,n,1} \\ y_{Q,n,2} \\ \vdots \\ y_{Q,n,K_n} \end{bmatrix} \quad (11)$$

将式(8)、(9)进行改写并联立，对于多个开关型负荷与多状态型负荷的 NILM 问题，可以转化为如下优化问题：

$$\min_{\mathbf{A}_n} \left\| \mathbf{X}_P - \sum_{n=1}^N \mathbf{A}_n \mathbf{Y}_{P,n} \right\|_F^2 + \delta \left\| \mathbf{X}_Q - \sum_{n=1}^N \mathbf{A}_n \mathbf{Y}_{Q,n} \right\|_F^2 \quad (12)$$

式中： \mathbf{X}_P 、 \mathbf{X}_Q 分别为总负荷的聚合有功和无功功率； δ 为无功权重； F 为弗罗贝尼乌斯范数。

2.2 基于矩阵分解的连续变化型负荷建模

对于单个连续变化型负荷，采用稳定的几个状态进行建模将造成分解精度较低的问题。矩阵分解(matrix factorization, MF)实质是采用基向量的线性组合来估计原始矩阵^[34]。将历史负荷的功率数据按工业用户的生产周期进行切割形成基向量，并采用基向量的线性组合拟合负荷的功率曲线，实现连续变化型负荷建模。负荷基向量的大小受生产周期的影响，而企业实际生产周期并不相同，可为 8 h、1 天或 1 周等，而采用固定时间周期对功率数据进行划分，会造成负荷分解结果的精度下降。

在电路中，有功功率代表了系统实际使用的能量，通过分解出每个负荷的有功功率可以帮助分析负荷的能耗。同时，有功功率能很好地反映企业的生产周期。所以，本文仅使用有功功率进行周期提取。工业用户生产周期的提取方法如下：设企业的总负荷有功功率数据序列为 Y ，对 Y 进行傅里叶变换，分解出频率为 k/M 的幅值为

$$Y[k] = \sum_{v=0}^{M-1} Y[v] e^{-j(2\pi/M)kv} \quad (13)$$

分别求解所有幅值，对幅值进行降序排列。取幅值最大的 3 个进行自相关系数计算。周期为 M/k 时，其自相关系数(autocorrelation coefficient, AC)计算公式为

$$A_C(k) = \left[\frac{1}{M - M/k} \sum_{t=M/k+1}^M (Y_t - \bar{Y})(Y_{t-M/k} - \bar{Y}) \right] / \left[\frac{1}{M} \sum_{t=1}^M (Y_t - \bar{Y})^2 \right] \quad (14)$$

式中： Y_t 为 t 时刻负荷的功率； $X_{t-M/k}$ 为 $t-M/k$ 时刻功率； \bar{Y} 为平均功率。选取AC指标最大的周期作为企业的生产周期。

$$\bar{Y} = \sum_{t=1}^M Y_t / M \quad (15)$$

具体单个负荷建模举例如下：假设有一个7天的负荷功率数据训练集与1天的测试集 $\{V\}$ ，采样间隔为1min，且该用户的生产周期为1天，选择1天的数据形成一个基向量，则向量的大小为 1440×1 ，可以建立7个向量集合，并横向拼接即可得到特征矩阵 W ，则测试集 $\{V\}$ 可以由矩阵 W 中的每一个列向量的线性组合进行表示，可以表述为如下优化问题：

$$\min_{L>0} \|V - WL\|_F^2 \quad (16)$$

式中 L 为激活矩阵，其中每一个元素代表矩阵 W 中每一个列向量的激活系数。在矩阵分解中，为了避免过拟合问题，通常加入正则化项来增强对噪声的鲁棒性，将式(16)改写为

$$\min_{L>0} \|V - WL\|_F^2 + \alpha \|L\|_F^2 \quad (17)$$

式中 α 为防止过拟合的正则化参数。进一步，对于多个连续变化型负荷的聚合功率，可以采用多个负荷的特征矩阵进行线性加权组合，实现负荷分解。则对于多个连续变化型负荷的NILM可以转化为如下优化问题：

$$\min_{B>0} \|X_P - D_P B\|_F^2 + \delta \|X_Q - D_Q B\|_F^2 + \alpha \|B\|_F^2 \quad (18)$$

式中： $X_P, X_Q \in \mathbf{R}^{m \times 1}$ 分别为总负荷的聚合有功和无功功率向量； $D_P, D_Q \in \mathbf{R}^{m \times T}$ 分别为有功特征矩阵与无功特征矩阵，每一列代表一个负荷的基向量， T 为基向量的总数； $B \in \mathbf{R}^{T \times 1}$ 为激活矩阵，其中，每个元素代表每一个基向量的激活系数。

3 构建考虑负荷特性的正则化项

3.1 基向量分组效应

在工业场景下，不同负荷的功率数值可能相差较大，小功率负荷容易淹没于大功率负荷的噪声中。基向量分组效应对每个负荷的基向量具有分组效应，使模型倾向于使用同一个负荷的基向量作为

特征进行功率分解^[35]。它强制每个负荷基向量的激活系数的和为1，这样就保证了对于单个负荷的功率曲线是由该负荷的基向量线性组合而成，而避免了其他负荷的基向量对其产生的影响。通过对目标函数添加正则化项以实现基向量分组效应，具体举例如下：

假设企业的生产周期为1天，且有2个连续变化型负荷，负荷1和2均有3天的历史功率数据，则总的特征矩阵为 $D=[D_1, D_2]=[d_{1,1}, d_{2,1}, d_{3,1}, d_{1,2}, d_{2,2}, d_{3,2}]$ 。其中： $D_1=[d_{1,1}, d_{2,1}, d_{3,1}]$ 为负荷1的特征矩阵； $D_2=[d_{1,2}, d_{2,2}, d_{3,2}]$ 为负荷2的特征矩阵； $d_{1,1}$ 与 $d_{1,2}$ 为第1天的功率数据；类似地，使用相同的结构对激活矩阵进行分组，即有激活矩阵 $B=[B_1, B_2]^T=[b_{1,1}, b_{2,1}, b_{3,1}, b_{1,2}, b_{2,2}, b_{3,2}]^T$ 。其中： $B_1=[b_{1,1}, b_{2,1}, b_{3,1}]^T$ 为负荷1的激活矩阵； $B_2=[b_{1,2}, b_{2,2}, b_{3,2}]^T$ 为负荷2的激活矩阵。则所添加的约束项如下：

$$\beta \left\| \begin{bmatrix} 1 \\ 1 \end{bmatrix} - \begin{bmatrix} 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 1 \end{bmatrix} B \right\|_F^2 \quad (19)$$

式中 β 为基向量分组效应的正则化系数。对于负荷1的功率曲线，倾向于仅使用基向量 $d_{1,1}$ 、 $d_{2,1}$ 和 $d_{3,1}$ 的线性组合进行拟合，原因是该正则化项使 $b_{1,1}+b_{2,1}+b_{3,1}=1$ ， $b_{1,2}=b_{2,2}=b_{3,2}=0$ 。同理，对于负荷2的功率曲线，倾向于仅使用基向量 $d_{1,2}$ 、 $d_{2,2}$ 和 $d_{3,2}$ 的线性组合进行拟合，则式(19)可以通用地表示为如下形式：

$$\beta \|U - QB\|_F^2 \quad (20)$$

式中： U 为全为1的向量； Q 为只由0和1元素构成的矩阵，其大小形式由具体的负荷数量与负荷所对应的基向量数量确定。

3.2 负荷相关性约束

在工业场景中，由于生产流程的约束，负荷的运行是需要相互配合的，部分负荷需要同时、延时或提前改变运行状态，这也对应着时序相关性中的时间超前、滞后等模式，这在1.3节中已详细叙述。本文首先通过斯皮尔曼(Spearman)相关系数检测哪些负荷之间具有时序相关性，再通过引入互相关(cross-correlation)函数检测时序相关性中的时间超前、滞后等模式，最后，引入正则化项对负荷的功率进行约束。

Spearman系数是常见的衡量2个向量相关联程度的一种方法，它是利用变量的秩次大小做线性相关分析，相关系数越大，2个变量的相关性越强，

反之相关性越弱^[36]。具体举例如下:

在3.1的例子基础上,负荷1与2具有时序相关性,负荷1的历史3天功率序列为 $\mathbf{G}=[G_1, G_2, \dots, G_n]$,负荷2的历史3天功率序列为 $\mathbf{H}=[H_1, H_2, \dots, H_n]$,对 \mathbf{G} 和 \mathbf{H} 进行降序或升序排列,得到 $\mathbf{g}=[g_1, g_2, \dots, g_n]$, $\mathbf{h}=[h_1, h_2, \dots, h_n]$,Spearman相关系数具体计算公式如下:

$$\rho = \frac{\sum_{i=1}^n (g_i - \mu_g)(h_i - \mu_h)}{\sqrt{\sum_{i=1}^n (g_i - \mu_g)^2} \sqrt{\sum_{i=1}^n (h_i - \mu_h)^2}} \quad (21)$$

式中: μ_g 为序列 g 的平均值; μ_h 为序列 h 的平均值。只有当2个负荷的历史功率序列的Spearman系数大于0.7时,视为2个负荷具有强相关性。

对于负荷1的功率序列 \mathbf{G} 和负荷2的功率序列 \mathbf{H} ,其互相关函数为

$$R(\tau) = \sum_{i=0}^n G_i H_{i-\tau} \quad (22)$$

式中 τ 为时序数据的偏移量,表示序列 \mathbf{H} 与 \mathbf{G} 之间的超前、滞后模式。当 $i < \tau$ 时,采用周期延拓的方式对序列 \mathbf{H} 进行补充。采用该函数对具有时序相关性负荷的功率数据进行检测,得到函数值最大时,二者的时序相关性最高,将此时的 τ 记为 τ_{\max} ,此时序列 \mathbf{H} 超前序列 \mathbf{G} ,且超前 τ_{\max} 个时间单位,换言之,即序列 \mathbf{H} 滞后序列 \mathbf{G} ,且滞后 $n - \tau_{\max}$ 个时间单位。

在得出负荷功率之间的偏移量后,对模型添加约束,保证时序相关性。假设负荷1和2的功率数据之间具有时序相关性,负荷2的功率数据超前负荷1的功率数据 τ_{\max} 个时间单位,负荷1有3天的历史功率数据,长度为 $1440 \times 3 = 4320$ 。 $\mathbf{D}_1=[\mathbf{d}_{1,1}, \mathbf{d}_{2,1}, \mathbf{d}_{3,1}]$ 为负荷1的特征矩阵, $\mathbf{D}_2=[\mathbf{d}_{1,2}, \mathbf{d}_{2,2}, \mathbf{d}_{3,2}]$ 为负荷2的特征矩阵,则 \mathbf{D}_1 和 \mathbf{D}_2 的大小为 1440×3 。相对应有 $\mathbf{B}_1=[b_{1,1}, b_{2,1}, b_{3,1}]^T$ 为负荷1的激活矩阵, $\mathbf{B}_2=[b_{1,2}, b_{2,2}, b_{3,2}]^T$ 为负荷2的激活矩阵, \mathbf{B}_1 和 \mathbf{B}_2 的大小为 3×1 。所以, $\mathbf{D}_1 \mathbf{B}_1$ 为分解出的负荷1的功率, $\mathbf{D}_2 \mathbf{B}_2$ 为分解出的负荷2的功率,大小都为 1440×1 。为了保证分解出的功率具有时序相关性,要保证在相关性最强下的偏移量时,2个负荷的功率数据的欧式距离最小,则有如下约束:

$$\gamma \|\mathbf{D}_1 \mathbf{B}_1(\tau_{\max} : 1440) - \mathbf{D}_2 \mathbf{B}_2(0 : 1440 - \tau_{\max})\|_2^2 \quad (23)$$

式中: γ 为正则化系数; $\mathbf{D}_1 \mathbf{B}_1(\tau_{\max} : 1440)$ 代表 $\mathbf{D}_1 \mathbf{B}_1$

中第 $\tau_{\max} \sim 1440$ 个元素。将其转为通用地转化为以下形式:

$$\gamma f(\mathbf{D}, \mathbf{B} | \tau_{\max}, \psi) = \gamma \|\mathbf{D}_1 \mathbf{B}_1(\tau_{\max} : n) - \psi \mathbf{D}_2 \mathbf{B}_2(0 : m - \tau_{\max})\|_2^2 \quad (24)$$

式中 ψ 为避免不同负荷之间的特征矩阵数值差距过大而设置的参数。

4 负荷分解方法的流程

将式(12)与(18)进行联立,并引入考虑负荷特性的正则化项,本文提出的工业NILM问题可以转化为以下最优化问题:

$$\begin{aligned} \min Z(\mathbf{A}_n, \mathbf{B}) = & \min_{\mathbf{A}_n, \mathbf{B} > 0} \|\mathbf{X}_P - \mathbf{D}_P \mathbf{B} - \sum_{n=1}^N \mathbf{A}_n \mathbf{Y}_{P,n}\|_F^2 + \\ & \delta \|\mathbf{X}_Q - \mathbf{D}_Q \mathbf{B} - \sum_{n=1}^N \mathbf{A}_n \mathbf{Y}_{Q,n}\|_F^2 + \alpha \|\mathbf{U} - \mathbf{Q} \mathbf{B}\|_F^2 + \\ & \gamma f(\mathbf{D}, \mathbf{B} | \tau_{\max}, \psi) + \beta \|\mathbf{U} - \mathbf{Q} \mathbf{B}\|_F^2 \end{aligned} \quad (25)$$

其中,约束项为式(4)、(5)。本文负荷分解方法具体流程见附图A1。

本模型实质上是一个混合整数非线性规划问题,随着负荷数量的增加以及求解的数据规模增长,整数变量会随之变多,计算复杂度也将急剧增加,模型将变得求解困难。所以,为了减小求解问题的规模,本文引入了时间窗口,时间窗口的大小可以根据数据量大小进行调整。在后续算例分析中,当数据的采样时间间隔为1min时,为了增加求解效率,时间窗口设置为60min,即每次只求解60min的数据,实时地对负荷进行分解;当数据根据目前用电信息采集系统的采样时间间隔为15min时,时间窗口设置为12h。

5 算例分析

5.1 算例设置

5.1.1 硬件环境及软件平台

本文硬件环境为Intel(R) Core™ i7-12700H CPU @2.3 GHz 16G DDR5内存的64位个人计算机。软件平台为WINDOWS-11操作系统及Python 3.9。本文方法实际为混合整数非线性规划问题,采用Gurobipy中的分支切割(branch-and-cut)算法框架进行求解。在后续的所有算例分析中,求解器参数设置见附表A1。由于添加了基向量分组效应,并对不同负荷分别设置了不同建模方法,使得模型对参数并不敏感,无需对不同算例设置不同参数。

5.1.2 数据集选取

本文选取 IMDELD 公开数据集^[22]及现场实测私有数据集作为本文算例的数据源。IMDELD 数据集是在一家家禽饲料厂收集的，由于峰谷电价，工厂每天从 22:00 工作到第 2 天 17:00。该工厂中，造粒机、双极接触器、排气扇与研磨机为主要生产负荷，故本文选取造粒机，双极接触器所带负荷(后简称双极接触器)、2 台排气扇与研磨机作为待分解的负荷，其他办公及照明等负荷不作考虑。原始数据集为每 1 s 采样 1 次。为了降低计算成本，同时方便与其他文献^[26,35]进行比较，本文将数据降采样至 1 min 采样 1 次。实测私有数据集 1 和 2 均利用智能电表监测获取，数据时间间隔均为 15 min，前者取自中国中部某城市的食品生产厂，工厂工作时间为 08:00—22:00，所选取的待分解的负荷包括 1 台提升泵、2 台加氧风机；后者取自中国中部某城市的药品生产厂，工厂的工作时间为 08:00—21:00，所选取的待分解的负荷包括 2 台引风机、1 台曝气泵。参考文献[26-27]，3 个数据集中的总负荷聚合功率为所选负荷的功率之和。

在后续算例分析中，本文将采用 IMDELD 数据集进行负荷分解，与现有方法进行对比分析，并进行数据敏感性分析、噪声鲁棒性测试及消融实验，以验证本文方法的先进性以及各模块的有效性。最后，利用 2 个实测私有数据集验证了本文方法的工程实用性与泛化性。

5.1.3 评价指标

为了评估负荷分解的性能，本文选取了标准分解误差(normalized disaggregation error, NDE)、功率分解准确率(PACC)、平均分解误差(mean absolute error, MAE)和总能量误差(sum of absolute error, SAE)作为评价指标。

$$N_{DE} = \left\{ \sum_{t=1}^m [p_{gr}(t) - p_{disa}(t)]^2 \right\} / \left[\sum_{t=1}^T p_{gr}^2(t) \right] \quad (26)$$

$$P_{ACC} = 1 - \left[\sum_{t=1}^m |p_{gr}(t) - p_{disa}(t)| \right] / \left[2 \sum_{t=1}^T p_{gr}(t) \right] \quad (27)$$

$$M_{AE} = \frac{1}{m} \sum_{t=1}^m |p_{gr}(t) - p_{disa}(t)| \quad (28)$$

$$S_{AE} = |\hat{E} - E| / E \quad (29)$$

式中： $p_{gr}(t)$ 为 t 时刻真实功率值； $p_{disa}(t)$ 为 t 时刻分解功率值； $\hat{E} = \sum_{t=1}^T p_{disa}(t)$ 和 $E = \sum_{t=1}^T p_{gr}(t)$ 分别为负荷在一段时间内的能量损耗预测值和真实值；NDE

作为模型误差的评价指标，其反映了模型分解值与真实值的差距，其数值越小，代表分解的效果越好；PACC 作为模型精度的评价指标，可以说明模型分解的准确程度，其数值越大，表示分解的精度越高；MAE 属于回归任务中常见的指标之一，能够反映实际分解误差的大小，其数值越小，代表分解的效果越好；SAE 为 NILM 领域常用的指标之一，它可以用于衡量在一段时间内模型分解的总能量误差，有助于用户了解设备的能量损耗情况^[37]。

5.2 公开数据集负荷分解结果分析

5.2.1 负荷分解结果及不同算法对比

由于本节采用公开数据集作为数据源，故根据负荷的历史运行功率数据分析，将造粒机、双极接触器、2 台排气扇划分为连续变化型负荷；将研磨机划分为多状态型负荷，研磨机被建立为具有 4 个稳定状态的负荷，每个状态的有功和无功功率数值见附表 A1。而在实际工程应用中，可通过现场调研与企业台账信息将企业中的负荷类型进行具体划分。

本文选取历史 15 天的历史负荷功率数据作为训练集形成连续变化型负荷的特征矩阵，选取 2 天的数据作为测试集进行负荷分解。经过对 15 天的总负荷功率数据进行傅里叶变换与 AC 指标计算，得到该工业用户的生产周期为 1 天，与企业实际生产情况相符。

本文方法模型的相关参数采用网格搜索法进行确定，以负荷分解误差最小为目标。对于正则化系数 β 与 γ ，采用的网格值为 $\{10^9, 10^{10}, 10^{11}, 10^{12}, 10^{13}, 10^{14}, 10^{15}, 10^{16}, 10^{17}\}$ ；对于正则化项 α ，测试中采用的网格值为 $\{10^7, 10^8, 10^9, 10^{10}, 10^{11}, 10^{12}, 10^{13}\}$ ；对于参数 δ ，测试中采用的网格值为 $\{0.5, 1, 10, 20, 30, 40, 50, 60\}$ 。最终得到正则化系数 β 为 10^{13} ，正则化系数 γ 为 10^{13} 、正则化系数 α 为 10^{10} 、参数 δ 为 30。如附图 A2 所示，计算历史 15 天各个连续变化型负荷有功功率数据之间的 Spearman 相关系数，造粒机与双极接触器的功率数据的 Spearman 相关系数 ρ 为 0.71，显示出较强的时序相关性。

采用互相关函数对 15 天的造粒机与双极接触器的功率进行检测，得到的互相关函数见附图 A3。当 $\tau=2$ 时，取得最大值，即 $\tau_{max}=2$ ，故双极接触器的负荷功率数据超前造粒机的功率数据 2 min。如附图 A4 所示，造粒机与双极接触器在相近时刻都

展现了功率波动。所以，本文所提的方法不仅能较好地得到负荷之间的相关性，并且能进一步考虑到时序相关性中的超前、滞后关系，这也与实际工业生产场景中的负荷需要同时、延时或提前改变运行状态相适应。为了避免造粒机与双极接触器的功率数值差距过大，根据它们的负荷功率特性，确定参数 ψ 为70。

为了验证本文方法在负荷分解性能上的优越性，将本文方法与文献[26]所提方法、文献[35]所提方法、文献[38]中的因子隐马可夫(factorial hidden Markov model, FHMM)及文献[9]中的组合优化(combinatorial optimization, CO)进行了对比实验。在FHMM及CO方法中，对于造粒机、双极接触器、研磨机采用3个状态对负荷进行建模。对排气扇1和2采用2个状态对负荷进行建模。5个负荷的各项性能指标的对比结果如表1所示，选取1天的负荷分解结果数据进行可视化分析，图5为5个负荷有功功率的分解值与真实值对比。其中：图5(a)~(e)为每个负荷的有功功率的分解值与真实值对比图；图5(f)为研磨机的功率曲线细节放大图。由图5和表1可知，本文方法能较好地分解各个负荷的功率。其中，造粒机与研磨机呈现出较好的分解效果，而双极接触器与2个排气扇由于功率较小，容易淹没于大功率负荷的波动噪声中，其分解效果

表1 IMDELD数据集负荷分解误差对比

Table 1 Comparison of load decomposition errors for the IMDELD dataset

负荷	评价指标	结果				
		本文方法	文献[26]方法	文献[35]方法	FHMM ^[38] 方法	CO ^[9] 方法
造粒机	$N_{DE}/\%$	4.12	3.98	4.81	4.87	56.54
	$P_{ACC}/\%$	93.58	93.43	93.29	93.5	68.77
	M_{AE}	7 699.30	7 880.52	8 048.34	7 801.31	37 489.58
	S_{AE}	0.033	0.018	0.03	0.072	0.687
双极接触器	$N_{DE}/\%$	8.38	14.58	20.28	12.72	67.77
	$P_{ACC}/\%$	91.06	85.68	83.68	90.16	64.24
	M_{AE}	128.98	206.56	235.43	141.91	515.79
	S_{AE}	0.111	0.121	0.022	0.09	0.659
排气扇1	$N_{DE}/\%$	2.45	7.03	6.86	8.28	81.46
	$P_{ACC}/\%$	94.01	92.19	93.4	93.5	58.21
	M_{AE}	302.41	394.03	333.01	377.38	2 109.01
	S_{AE}	0.054	0.024	0.023	0.09	0.81
排气扇2	$N_{DE}/\%$	2.47	9.62	8.98	11.26	85.11
	$P_{ACC}/\%$	96.01	91.06	92.56	93.09	57.14
	M_{AE}	341.77	764.34	636.67	590.96	3 668.02
	S_{AE}	0.022	0.091	0.057	0.064	0.853
研磨机	$N_{DE}/\%$	5.11	12.57	52.15	12.51	164.76
	$P_{ACC}/\%$	94.15	91.15	58.43	83.47	21.12
	M_{AE}	2 918.36	5 931.97	14 315.12	5 688.08	27 143.84
	S_{AE}	0.012	0.103	0.1123	0.103	0.035

相较于前两者较差。

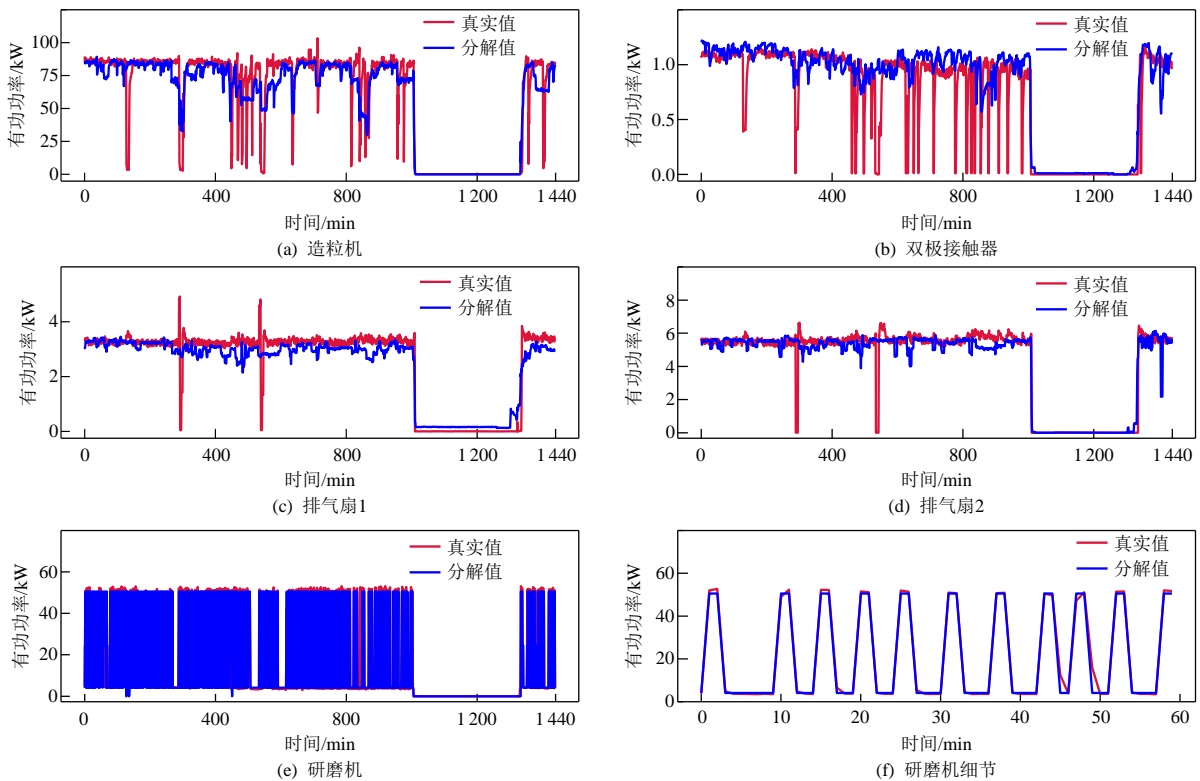


图5 本文方法负荷分解结果

Fig. 5 Load decomposition results of the proposed method

由表1可知,除了造粒机,本文方法性能指标略低于文献[26]所提方法以外,在其他负荷上,本文方法的性能指标皆优于其他方法。对于造粒机,所有方法都能得到比较好的分解结果,这是由于造粒机在所有负荷中的功率占比最大,负荷特征最为明显。对于双极接触器,本文方法考虑生产约束下的负荷相关性并引入相关约束,负荷分解性能较其他2种方法都有较大地提升。对于2个排气扇,本文同时考虑有功和无功功率2个特征,较好地避免了功率特征重叠与有功功率数值差距过大的问题。对于研磨机,在文献[35]所提方法中,将研磨机作为连续变化型负荷进行分解,由图5(e)可知,工作时,研磨机的功率会在3个状态下快速切换,这并不符合连续变化型负荷的功率特性,导致矩阵分解方法难以拟合多个状态下快速切换的特性,故分解结果较差;而本文方法将研磨机视为多状态型负荷,NDE性能指标提升47.04%;在文献[26]所提方法中,研磨机的其中1种工况与排气扇1存在有功功率特征重叠的情况,本文方法同时考虑有功功率与无功功率的特征,避免了特征重叠的情况,NDE性能指标提升了7.40%。FHMM方法在双极接触器上的SAE指标展现了较好的效果,这是由于SAE关注的是负荷在一段时间内的能量消耗,它忽略了实时的功率分解的情况,所以即使在功率未能很好地分解情况下,也可能展现较小的误差。在其他负荷分解结果中,本文方法相对FHMM方法和CO方法都表现出了更好的性能。这是因为FHMM方法和CO方法往往应用于家庭场景,它们采用几个有限的状态对负荷进行功率建模,忽略了负荷功率的时变特性,这在工业场景下并不适用。工业场景中存在较多电动机等负荷,由于其变频调速特性,造成功率连续平滑地变化,采用几个稳定的状态进行建模会导致精度较低。所以,FHMM和CO方法相比于本文方法的分解性能较差。另外,值得注意的是,CO方法展现了更差的性能,这是由于不同负荷的功率数值可能相差较大,小功率负荷容易淹没于大功率负荷的噪声中。而本文对功率连续变化的负荷引入了矩阵分解方法及基向量分组效应,有效提升了模型的分解精度。综上,本文方法对比现有文献及传统方法都表现了优越的性能。

5.2.2 数据敏感性分析与噪声鲁棒性测试

为了进一步验证本文方法的先进性及在实际工程中的实用性,本节采用IMDELD数据集对模型

的数据敏感性与噪声鲁棒性进行分析与测试。对于工作模式有限的开关型负荷与多状态型负荷,所建立的负荷状态矩阵已经包含负荷所有的工况,故模型能有较好的分解效果。因此,为了测试模型对选取的训练集大小的敏感性,选取能耗占比最大的连续变化型负荷造粒机与多状态型负荷研磨机进行分析,在不同训练集大小的情况下进行对比测试,其学习曲线如图6所示。




图6 不同训练集天数情况下的负荷分解误差对比

Fig. 6 Comparison of load decomposition errors for different training set days scenarios

结果表明:在仅使用4~15天的训练数据时,造粒机与研磨机都有很好的分解效果;在使用8~15天的训练数据时,负荷的分解指标趋于稳定,造粒机与研磨机的分解误差分别在4.5%与5.5%左右。这是因为在本文方法中,对于连续变化型负荷,即使在测试数据没有完全匹配训练数据中的某一个基向量,模型也可以通过基向量分组效应约束,采用基向量的线性组合进行估计分解功率。因此训练数据集中不必包含连续变化型负荷的所有工作模式,即模型在数据较少的情况下也能拥有较好的分解效果,这在工业数据样本较少的情况下具有一定的工程实际价值。

在实际应用中,采集数据会存在一定的噪声及测量误差,为验证模型对抗噪声的鲁棒性,对负荷聚合功率数据分别加入均值为0、标准差分别为50和100的噪声,其对比结果如图7所示。结果表明,模型在噪声干扰下负荷分解依然有较高的精度。对于连续变化型负荷,加入了正则化项来增强对噪声的鲁棒性,使得连续变化型负荷在面对噪声时,也能拥有较好的分解效果。例如,对于造粒机负荷,其NDE指标只出现略微上升。对于双极接触器,由于引入了负荷相关性约束,其指标在不同噪声干扰下仅分别上升了0.35%和0.44%。以上说明,模型在各种噪声干扰下,具有很好的鲁棒性。




图7 不同噪声情况下的负荷分解误差对比

Fig. 7 Comparison of load decomposition errors for different noise cases

5.2.3 消融实验

1) 无功功率特征对分解结果的影响。

为了验证本文同时考虑有功、无功功率特征的必要性，本节采用 IMDELD 数据集对同时考虑有功、无功功率特征与只考虑有功功率特征的模型进行了对比，如表 2 所示。其中，每个负荷的最佳性能指标采用粗体表示。表 3 为各个负荷的满载有功及无功功率。

表 2 考虑无功功率特征对于负荷分解的影响

Table 2 Impact of considering reactive power characteristics on load decomposition

负荷	同时考虑有功与无功功率特征		只考虑有功功率特征	
	$N_{DE}/\%$	$P_{ACC}/\%$	$N_{DE}/\%$	$P_{ACC}/\%$
造粒机	4.12	93.58	3.95	93.85
双极接触器	8.38	91.06	9.38	89.74
排气扇 1	2.45	94.01	7.64	92.77
排气扇 2	2.47	96.01	8.00	92.48
研磨机	5.11	94.15	11.40	91.18

表 3 负荷的满载有功及无功功率

Table 3 Full load active and reactive power of loads

负荷	满载有功功率/kW	满载无功功率/kvar
造粒机	85.0	53.0
双极接触器	1.2	3.3
排气扇 1	3.7	1.6
排气扇 2	5.5	6.9
研磨机	50.0	38.0

由表 2 可知，在同时考虑有功与无功功率特征的情况下，双极接触器、2 台排气扇与研磨机的分解效果有较高的提升。其原因主要有：1) 由表 3 可知，双极接触器、排风扇 1 与排风扇 2 的满载运行的有功功率与研磨机与造粒机相比数值较小，若单纯以有功功率作为特征进行分解，小功率负荷容易淹没于大功率负荷的噪声波动中；而以上负荷的满载无功功率数值差距有所减小，有较好的分解效

果，所以，本文考虑无功功率特征，对各个负荷的基向量对应的激活系数加以修正，双极接触器、排气扇 1 与排气扇 2 的分解性能提升较为明显。2) 研磨机存在有功功率为 4.105 kW 的工况，而排气扇 1 的满载有功功率为 3.7 kW，数值较为接近，造成了有功功率特征重叠的问题，使负荷分解准确度降低，本文引入无功功率，避免了有功功率特征重叠的影响，故研磨机的分解性能有较大的提升。而对于造粒机，在同时考虑有功与无功功率特征的情况下，其性能指标虽略微下降，但并不明显，原因为造粒机的有功功率波动较大，其有功功率特征较无功功率更为明显，故对于造粒机仅采用有功功率特征分解效果更好。总之，同时考虑有功与无功功率特征，对于大多数负荷都具有较好的分解效果。

2) 负荷时序相关性约束对分解结果的影响。

为了验证本文引入负荷相关性的必要性，本节采用 IMDELD 数据集，分别对不考虑负荷相关性与考虑负荷相关性的模型进行了对比。由于只有造粒机与双极接触器的 Spearman 系数超过了 0.7，为强相关性，故只对这 2 个负荷引入负荷相关性约束。各个模型的性能对比如表 4 所示，其中，每个负荷的最佳性能指标采用粗体表示。

表 4 考虑负荷时序相关性对于负荷分解的影响

Table 4 Impact of considering load timing correlation on load decomposition

模型	评价指标	结果	
		造粒机	双极接触器
不考虑 负荷相关性	$N_{DE}/\%$	4.33	11.66
	$P_{ACC}/\%$	93.51	87.05
	M_{AE}	7806.67	169.49
考虑 负荷相关性	$N_{DE}/\%$	4.12	8.38
	$P_{ACC}/\%$	93.58	91.06
	M_{AE}	7699.30	128.98

由表 4 可知，在考虑负荷相关性的情况下，模型的分解性能最好，2 个负荷的 N_{DE} 指标分别降低了 0.16% 与 3.28%。这是因为在引入负荷相关性约束后，通过互相关函数测试了 2 个负荷的时延特性，并约束 2 个负荷的功率数据的欧式距离，保证了造粒机与双极接触器的功率波动的相似性，提升了负荷的分解性能。

5.3 实测私有数据集负荷分解结果分析

本节采用 2 个实测私有数据集作为数据源，限于篇幅，仅展示其中 8 天的负荷功率数据，见附图 A5、A6。实测私有数据集 1 用于验证本文方法

的工程实用性，利用实测私有数据集 2 验证本文方法针对不同类型负荷组合的泛化性。

通过实地分析企业的生产过程及台账数据，将提升泵划分为连续变化型负荷，将 2 台加氧风机划分为开关型负荷。通过调研 2 台加氧风机的铭牌得到其额定的有功和无功功率的数值，见附表 A4。

本文选取历史 15 天的历史负荷功率数据作为训练集形成提升泵的特征矩阵，选取 4 天的数据作为测试集进行负荷分解。经过对 15 天的总负荷功率数据进行傅里叶变换与 AC 指标计算，得到该工厂的生产周期为 1 天，与企业实际生产情况相符。

由于所选取负荷只包括了 1 台连续变化型负荷，同时，经过调研，该工厂的负荷之间不存在相互配合的情况，无需考虑负荷相关性。通过网络搜索法，确定正则化系数 β 为 10^{10} ，正则化系数 α 为 0.01，参数 δ 为 10。3 个负荷的分解的各项性能指标如表 5 所示，并选取其中 1 天进行可视化分析，见附图 A7。

表 5 实测私有数据集 1 负荷分解误差对比

Table 5 Comparison of load decomposition errors for measured private dataset 1

模型	提升泵		加氧风机 1		加氧风机 2	
	N _{DE} /%	P _{ACC} /%	N _{DE} /%	P _{ACC} /%	N _{DE} /%	P _{ACC} /%
本文方法	2.41	97.10	5.51	96.86	2.23	97.45
文献[26]	5.58	92.28	16.41	91.34	6.28	95.44
文献[35]	5.95	93.92	41.94	60.87	23.36	75.62

由表 5 可知，本文方法对于 3 个负荷的分解性能皆优于现有方法，平均 NDE 指标分别提升了 6.04% 与 20.36%，表明本文所提针对不同类型负荷建立样本库的方法能很好地在实际工程中应用，负荷分解精度也有所提升。同时，实测私有数据集利用智能电表采集，数据间隔为 15 min^[39]，故本文即使在较低的采样频率下，也能拥有较好的分解效果。通常，数据在降采样后难以保留负荷的瞬态特征，本文针对连续变化型负荷采用负荷的原始数据形成负荷特征库，能够尽量保留负荷的特征，使连续变化型负荷在较低采样频率下也能有较好的分解效果；针对多状态型负荷与开关型负荷，采用多个负荷状态能较好地描述负荷的功率曲线，使 2 个加氧风机在较低采样频率下仍有较高的分解精度。因此，本文方法所需的总负荷数据对数据的采样频率要求不高，减小了数据在传输、存储的压力，可以从电力公司现有用采系统直接获得，表明所提方法在实际工业场景中具有实用性。

在实测私有数据集 2 中，2 台引风机被划分为开关型负荷，曝气泵被划分为多状态型负荷，参数 δ 设置为 10。3 个负荷分解的各项性能指标如表 6 所示，选取其中 1 天的分解结果进行展示，见附图 A8。

表 6 实测私有数据集 2 负荷分解误差对比

Table 6 Comparison of load decomposition errors for measured private dataset 2

负荷	N _{DE} /%	P _{ACC} /%	M _{AE}
引风机 1	0.012	99.55	0.028
引风机 2	0.016	99.51	0.029
曝气泵	0.12	98.42	0.046

由结果可知，3 个负荷均表现出了较好的分解性能。IMDELD 公开数据集包含 4 个连续变化型负荷和 1 个多状态型负荷；实测私有数据集 1 中包含 1 个连续变化型负荷和 2 个开关型负荷；实测私有数据集 2 中包含 2 个开关型负荷和 1 个多状态型负荷。由上述分析可知，对于各种包含不同类型负荷的数据集，本文方法都有较好的分解效果，这是因为本文针对不同负荷类型，分别提出了整数规划与矩阵分解的负荷建模方法，能有效地面对不同负荷的工业场景，具有较好的泛化性能。

6 结论

本文针对当前工业场景样本数据稀缺、未考虑工业生产流程约束等问题，提出一种非侵入式工业负荷监测方法，得出结论如下：

1) 本文同时考虑有功与无功功率特征，并考虑工业场景下因生产流程约束而存在超前、滞后等时序相关性的负荷特性，提升了负荷分解的准确度与精度。

2) 通过企业实际生产周期提取，不仅辅助了负荷时序相关性分析，而且保证了连续变化型负荷的特征矩阵构建更符合不同企业实际生产情况，使本文方法的适用性更为广泛。

3) 本文面向工业生产实际能获取的数据进行方法设计，只需要较低的数据采样频率与少量样本数据便能拥有较好的分解效果，并具有一定的抗噪声能力和针对不同类型负荷组合的泛化能力，这对解决工业场景下的 NILM 问题具有一定实际意义。

针对有功与无功功率数值相近的不同负荷，下一步可考虑引入谐波等电能质量特征指标，以提高模型分解的准确度。

参考文献

- [1] 张永生, 董舵, 肖逸, 等. 我国能源生产、消费、储能现状及碳中和条件下变化趋势[J]. 科学通报, 2021, 66(34): 4466-4476.
ZHANG Yongsheng, DONG Duo, XIAO Yi, et al. Current status and trends in energy production, consumption, and storage under carbon neutrality conditions in China[J]. Chinese Science Bulletin, 2021, 66(34): 4466-4476.
- [2] 舒印彪, 赵勇, 赵良, 等. “双碳”目标下我国能源电力低碳转型路径[J]. 中国电机工程学报, 2023, 43(5): 1663-1671.
SHU Yinbiao, ZHAO Yong, ZHAO Liang, et al. Study on low carbon energy transition path toward carbon peak and carbon neutrality[J]. Proceedings of the CSEE, 2023, 43(5): 1663-1671(in Chinese).
- [3] LUAN Wenpeng, YANG Fan, ZHAO Bochao, et al. Industrial load disaggregation based on Hidden Markov models[J]. Electric Power Systems Research, 2022, 210: 108086.
- [4] AYDIN E, BROUNEN D, KOK N. Information provision and energy consumption: evidence from a field experiment[J]. Energy Economics, 2018, 71: 403-410.
- [5] SCHIRMER P A, MPORAS I. Non-intrusive load monitoring: a review[J]. IEEE Transactions on Smart Grid, 2023, 14(1): 769-784.
- [6] 武昕, 于金莹, 彭林, 等. 基于用户边缘侧事件解析的工业电力负荷非侵入式感知辨识[J]. 电力系统自动化, 2021, 45(4): 29-37.
WU Xin, YU Jinying, PENG Lin, et al. Non-intrusive perception and identification of industrial power load based on analysis of event on user edge[J]. Automation of Electric Power Systems, 2021, 45(4): 29-37(in Chinese).
- [7] 张逸, 姚文旭, 邵振国, 等. 基于电能质量监测数据的企业环保异常工况识别[J]. 电力系统自动化, 2023, 47(5): 180-189.
ZHANG Yi, YAO Wenxu, SHAO Zhenguo, et al. Identification of abnormal operation condition for environmental protection in enterprises based on power quality monitoring data[J]. Automation of Electric Power Systems, 2023, 47(5): 180-189(in Chinese).
- [8] ADABI A, MANTEY P, HOLMEGAARD E, et al. Status and challenges of residential and industrial non-intrusive load monitoring[C]//2015 IEEE Conference on Technologies for Sustainability (SusTech). Ogden: IEEE, 2015: 181-188.
- [9] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [10] 于超, 覃智君, 阳育德. 基于启停状态识别改进因子隐马尔可夫模型的非侵入式负荷分解[J]. 电网技术, 2021, 45(11): 4540-4550.
YU Chao, QIN Zhijun, YANG Yude. Non-intrusive load disaggregation with improved factorial hidden Markov model considering ON-OFF status recognition[J]. Power System Technology, 2021, 45(11): 4540-4550(in Chinese).
- [11] KUMAR P, ABHYANKAR A R. A time efficient factorial hidden Markov model-based approach for non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2023, 14(5): 3627-3639.
- [12] 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(in Chinese).
- [13] KELLY J, KNOTTENBELT W. Neural NILM: deep neural networks applied to energy disaggregation[C]//2nd ACM International Conference on Embedded Systems For Energy-Efficient Built Environments. Seoul: Springer International Publishing, 2015.
- [14] ZHANG Chaoyun, ZHONG Mingjun, WANG Zongzuo, et al. Sequence-to-point learning with neural networks for non-intrusive load monitoring[C]//Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence (AAAI-18). New Orleans: AAAI, 2018, 32(1): 2604-2611.
- [15] HE Kanghang, STANKOVIC L, LIAO Jing, et al. Non-intrusive load disaggregation using graph signal processing[J]. IEEE Transactions on Smart Grid, 2018, 9(3): 1739-1747.
- [16] 冯人海, 袁万琦, 葛磊蛟. 基于图信号交替优化的居民用户非侵入式负荷监测方法[J]. 中国电机工程学报, 2022, 42(4): 1355-1364.
FENG Renhai, YUAN Wanqi, GE Leijiao. Non-intrusive load monitoring method for resident users based on alternating optimization in graph signal[J]. Proceedings of the CSEE, 2022, 42(4): 1355-1364(in Chinese).
- [17] 彭秉刚, 潘振宁, 余涛, 等. 图数据建模与图表示学习方法及其非侵入式负荷监测问题的应用[J]. 中国电机工程学报, 2022, 42(17): 6260-6273.
PENG Binggang, PAN Zhenning, YU Tao, et al. Graph data modeling and graph representation learning methods and their application in non-intrusive load monitoring problem[J]. Proceedings of the CSEE, 2022, 42(17): 6260-6273(in Chinese).
- [18] 陈鑫沛, 余涛, 杨家俊, 等. 基于设备行为关联图的非侵入式多标签负荷分解改进方法[J]. 中国电机工程学报, 2024, 44(1): 95-104.
CHEN Xinpei, YU Tao, YANG Jiajun, et al. An improved

- non-invasive multi-label load disaggregation method based on appliance behavior correlation graph[J]. Proceedings of the CSEE, 2024, 44(1): 95-104(in Chinese).
- [19] 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(in Chinese).
- [20] 王健, 易姝慧, 刘俊杰, 等. 基于随机森林算法和稳态波形的非介入式工业负荷辨识[J]. 中国电力, 2022, 55(2): 82-89. WANG Jian, YI Shuhui, LIU Junjie, et al. Non-intrusive industrial load identification based on random forest algorithm and steady-state waveform[J]. Electric Power, 2022, 55(2): 82-89(in Chinese).
- [21] 周念成, 廖建权, 王强钢, 等. 深度学习在智能电网中的应用现状分析与展望[J]. 电力系统自动化, 2019, 43(4): 180-191. ZHOU Niancheng, LIAO Jianquan, WANG Qianggang, et al. Analysis and prospect of deep learning application in smart grid[J]. Automation of Electric Power Systems, 2019, 43(4): 180-191(in Chinese).
- [22] MARTINS P B M, GOMES J G R C, NASCIMENTO V B, et al. Application of a deep learning generative model to load disaggregation for industrial machinery power consumption monitoring[C]//2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (Smart Grid Comm). Aalborg: IEEE, 2018: 1-6.
- [23] WEI Jun, LI Ce, YANG Rong, et al. Application of attention mechanism enhanced neural network in non-invasive load monitoring of industrial power data[J]. Measurement and Control, 2023, 56(9-10): 1780-1787.
- [24] HUANG Gang, ZHOU Zhou, WU Fei, et al. Physics-informed time-aware neural networks for industrial nonintrusive load monitoring[J]. IEEE Transactions on Industrial Informatics, 2023, 19(6): 7312-7322.
- [25] ANGELIS G F, TIMPLALEXIS C, SALAMANIS A I, et al. Energformer: a new transformer model for energy disaggregation[J]. IEEE Transactions on Consumer Electronics, 2023, 69(3): 308-320.
- [26] LI Chuyi, ZHENG Kedi, GUO Hongye, et al. A mixed-integer programming approach for industrial non-intrusive load monitoring[J]. Applied Energy, 2023, 330: 120295.
- [27] WANG Zhongrui, XU Yonghai, HE Sheng, et al. A non-intrusive method of industrial load disaggregation based on load operating states and improved grey wolf algorithm[J]. Applied Energy, 2023, 351: 121934.
- [28] 邓晓平, 张桂青, 魏庆来, 等. 非侵入式负荷监测综述[J]. 自动化学报, 2022, 48(3): 644-663. DENG Xiaoping, ZHANG Guiqing, WEI Qinglai, et al. A survey on the non-intrusive load monitoring[J]. Acta Automatica Sinica, 2022, 48(3): 644-663(in Chinese).
- [29] 王谱宇, 丁一帆, 陈鉴祥, 等. 基于动态谐波导纳参数的非侵入式负荷监测数据模拟生成方法[J]. 中国电机工程学报, 2025, 45(3): 923-935. WANG Puyu, DING Yifan, CHEN Jianxiang, et al. Non-invasive load monitoring data simulation generation method based on dynamic harmonic admittance parameters[J]. Proceedings of the CSEE, 2025, 45(3): 923-935(in Chinese).
- [30] 吴龙飞, 刘浩. 电力企业生产数据分析及预警模型的开发与应用[J]. 能源工程, 2023, 43(4): 62-67. WU Longfei, LIU Hao. Development and application of production data analysis and early warning model for power enterprises[J]. Energy Engineering, 2023, 43(4): 62-67(in Chinese).
- [31] KALINKE F, BIELSKI P, SINGH S, et al. An evaluation of NILM approaches on industrial energy-consumption data[C]//Proceedings of the Twelfth ACM International Conference on Future Energy Systems. New York: Association for Computing Machinery, 2021: 239-243.
- [32] TANONI G, PRINCIPI E, SQUARTINI S. Non-intrusive load monitoring in industrial settings: a systematic review [J]. Renewable and Sustainable Energy Reviews, 2024, 202, 114703.
- [33] 孙毅, 崔灿, 陆俊, 等. 基于遗传优化的非侵入式家居负荷分解方法[J]. 电网技术, 2016, 40(12): 3912-3917. SUN Yi, CUI Can, LU Jun, et al. A non-intrusive household load monitoring method based on genetic optimization[J]. Power System Technology, 2016, 40(12): 3912-3917(in Chinese).
- [34] 黄帅栋, 卫志农, 高宗和, 等. 基于非负矩阵分解的相关向量机短期负荷预测模型[J]. 电力系统自动化, 2012, 36(11): 62-66. HUANG Shuaidong, WEI Zhinong, GAO Zonghe, et al. A short-term load forecasting model based on relevance vector machine with nonnegative matrix factorization[J]. Automation of Electric Power Systems, 2012, 36(11): 62-66(in Chinese).
- [35] RAHIMPOUR A, QI Hairong, FUGATE D, et al. Non-intrusive energy disaggregation using non-negative matrix factorization with sum-to-k constraint[J]. IEEE Transactions on Power Systems, 2017, 32(6): 4430-4441.
- [36] 吴珺玥, 赵二刚, 郭增良, 等. 基于 Spearman 系数和 TCN 的光伏出力超短期多步预测[J]. 太阳能学报,

2023, 44(9): 180-186.

WU Junyue, ZHAO Ergang, GUO Zengliang, et al. Ultra-short-term photovoltaic power multi-step prediction based on Spearman coefficient and TCN[J]. Acta Energiæ Solaris Sinica, 2023, 44(9): 180-186(in Chinese).

- [37] 陈嘉伟, 季天瑶, 梅广, 等. 基于多尺度特征融合与多任务学习框架的非侵入式负荷监测方法[J]. 电网技术, 2024, 48(5): 2074-2083.

CHEN Jiawei, JI Tianyao, MEI Guang, et al. Multi-scale feature fusion and multi-task learning architecture for non-intrusive load monitoring[J]. Power System Technology, 2024, 48(5): 2074-2083(in Chinese).

- [38] YANG Fan, LIU Bo, LUAN Wenpeng, et al. FHMM based industrial load disaggregation[C]//2021 6th Asia Conference on Power and Electrical Engineering (ACPEE). Chongqing: IEEE, 2021.

- [39] 张逸, 王攸然, 刘航, 等. 基于监测数据相关性分析的用户谐波责任划分方法[J]. 电力系统自动化, 2020, 44(2): 189-197.

ZHANG Yi, WANG Youran, LIU Hang, et al. Determination method of user harmonic responsibility based on correlation analysis of monitoring data[J]. Automation of Electric Power Systems, 2020, 44(2): 189-197(in Chinese).

附录

<http://ntps.epri.sgcc.com.cn/djgxcb/CN/10.13334/j.0258-8013.pcsee.242006>



张逸

在线出版日期: 2025-03-24。

收稿日期: 2024-08-19。

作者简介:

张逸(1984), 男, 博士, 副教授, 研究方向为电能质量、主动配电网及电力数据分析等, zhangyi@fzu.cn;

陈锦涛(2000), 男, 硕士研究生, 研究方向为电力数据分析, 1749211300@qq.com;

*通信作者: 李传栋(1979), 男, 博士, 副教授, 主要研究方向为电网分析、电网规划等, lichuandong@126.com;

张良羽(1999), 女, 硕士研究生, 研究方向为电力数据分析, 905567116@qq.com;

孙守铨(1999), 男, 硕士研究生, 研究方向为电力数据分析, ssq_zb@163.com。

(责任编辑 李泽荣)