基于缺失数据重构的聚合温控负荷参与微电网优化调度

林 巧[1,2]，丁 李[2,1†]，余振威[1,2]，李 昕[1,2]

(1. 武汉大学 电气与自动化学院，湖北 武汉 430072；2. 武汉大学 机器人学院，湖北 武汉 430072)

摘 要: 温控负荷 (Thermostatically Controlled Loads, TCL) 作为典型柔性负荷资源, 可参与微电网需求响应并促进可再生能源消纳. 然而, 实际运行中受传感器故障、通信异常等因素影响, TCL 能耗数据存在缺失问题, 导致负荷特性辨识失准, 并进一步影响聚合建模及微电网优化调度的准确性. 针对上述问题, 提出一种基于多特征融合的改进复制粘贴法 (Improved Copy-Paste Imputation, ICPI), 综合周内特征、季节特征、极值特征及负荷曲线相关性构建复合相似性系数, 实现缺失 TCL 能耗数据的精准重构. 在此基础上, 建立聚合 TCL 虚拟电池模型, 并将重构数据引入微电网优化调度模型, 实现数据重构、负荷聚合建模与优化调度的协同分析. 仿真结果表明, 所提 ICPI 方法在平均绝对百分比误差和归一化均方根误差指标下均优于对比方法, 能够有效降低数据缺失对微电网调度结果的影响, 提高系统运行经济性与稳定性, 为不完整数据条件下柔性负荷参与微电网优化调度提供了一种有效方法.

关键词: 微电网优化调度；温控负荷；改进复制粘贴法；需求响应；数据重构；虚拟电池

中图分类号: TM715 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2026.0316

引用格式: 林巧, 丁李, 余振威, 等. 基于缺失数据重构的聚合温控负荷参与微电网优化调度 [J]. 控制与决策.

Optimal microgrid scheduling with aggregated thermostatically controlled loads based on missing data reconstruction

LIN Qiao[1,2]，*DING Li*[2,1†]，*YU Zhen-wei*[1,2]，*LI Xin*[1,2]

(1. School of Electrical Engineering and Automation，Wuhan University，Wuhan 430072，China；2. School of Robotics，Wuhan University，Wuhan 430072，China)

Abstract: Thermostatically Controlled Load (TCL) is an important flexible resource that can participate in microgrid demand response and facilitate renewable energy integration. However, missing TCL energy consumption data caused by sensor failures, communication interruptions, and other operational uncertainties may lead to inaccurate load characteristic identification, thereby reducing the accuracy of aggregated modeling and optimal microgrid scheduling. To address this issue, an Improved Copy-Paste Imputation (ICPI) method based on multi-feature fusion is proposed. The proposed method reconstructs missing TCL energy consumption data by establishing a composite similarity coefficient that integrates weekly characteristics, seasonal characteristics, extreme-value characteristics, and load profile correlation. Based on the reconstructed data, an aggregated TCL virtual battery model is developed and incorporated into a microgrid optimal scheduling framework, achieving coordinated data reconstruction, load aggregation modeling, and scheduling optimization. Simulation results demonstrate that the proposed ICPI method outperforms conventional imputation approaches in terms of both mean absolute percentage error and normalized root mean square error. Moreover, the reconstructed data effectively mitigate the adverse effects of missing data on microgrid scheduling, thereby improving the economic performance and operational stability of the system. The proposed framework provides an effective solution for integrating flexible loads into optimal microgrid scheduling under incomplete data conditions.

Keywords: microgrid optimal scheduling；thermostatically controlled load；improved copy-paste imputation；demand response；data reconstruction；virtual battery

收稿日期: 2026-04-11；**录用日期:** 2026-07-22.

基金项目: 国家自然科学基金项目 (62373290).

责任编委: 邢兰涛.

†通信作者. E-mail: liding@whu.edu.cn.

0 引 言

随着新型电力系统的加速发展, 以可再生能源为主体的分布式能源在电网中的渗透率持续提升, 推动了微电网 (Microgrid, MG) 在能源供应与管理中的广泛应用[1-3]. MG 通过集成光伏、风电等分布式能源及储能系统, 实现了多能互补与局部自治运行[4]. 然而, 可再生能源出力所固有的波动性与不确定性, 显著增加了系统在经济性与运行稳定性方面的调控难度[5]. 在此背景下, 需求响应 (Demand Response, DR) 作为提升系统灵活性的重要手段, 逐渐成为 MG 能量管理系统 (Energy Management System, EMS) 的关键组成部分[6-8].

温控负荷 (Thermostatically Controlled Loads, TCL) 作为典型的可调节负荷, 广泛存在于居民与商业用户中, 具有数量庞大、热惯性显著以及对用户舒适度影响可控等特点[9][10]. TCL 具有数量庞大、热惯性显著以及舒适度约束可控等特点, 研究中通常将其聚合建模为“虚拟电池”, 通过等效描述其充放电能力, 参与 MG 优化调度[11]. 已有研究表明, 引入聚合 TCL 参与 DR, 能够有效降低系统购电成本、缓解峰谷差并提升可再生能源消纳能力[12].

然而, 上述研究普遍基于一个理想假设, 即 TCL 能耗及运行数据是完整且准确可得的. 该假设在实际应用中往往难以满足[13]. 由于计量设备故障、通信中断以及数据采集机制不完善等因素, TCL 能耗数据普遍存在不同程度的缺失与异常[14]. 这类数据问题不仅影响负荷特性分析, 还会在建模与调度层面产生累积误差. 一方面, 缺失数据导致 TCL 功率基线估计偏差, 从而影响其可调节容量评估; 另一方面, 在虚拟电池建模过程中, 状态变量 (如等效电量状态) 将出现偏移, 降低调度模型的准确性与可行性[15].

针对缺失数据问题, 现有研究提出了多种数据重构方法, 包括线性插值、样条拟合等统计方法, 以及基于机器学习与深度学习的预测方法[17]. Chen 等[18] 针对电力系统中用电数据缺失问题, 通过迭代插值方法构建了最优复杂度模型, 以对缺失数据进行预测补全, 从而对电量分析与异常检测提供可靠支撑. Ren 等[19] 提出了一种结合卷积神经网络和残差神经网络的时空频谱预测模型, 实现高精度频谱预测. 尽管这些方法在一定程度上能够恢复缺失数据, 但统计方法难以刻画 TCL 能耗的非线性与时序相关特性, 而机器学习方法则通常依赖大规模训练数据, 在实际应用中存在泛化能力不足与计算复杂度较高等问题. 相比之下, 复制粘贴法[20](Copy-paste imputation, CPI) 通过挖掘历史数据中具有相似运行特征的参考日, 实现对缺失数据的重构, 在无需大量训练数据的情况下表现出良好的应用潜力. 然而, 传统 CPI 在选取参考日时考虑的相似性判据较为单一, 难以同时兼顾用电行为、气象因素及季节变化等多维特征, 从而限制了其重构精度.

另一方面, 已有研究在 MG 调度中引入 TCL 聚合模型, 并基于虚拟电池理论构建了优化调度框架. Lin 等[21] 将可调度温控负荷纳入需求侧管理并考虑设备老化与用户舒适度约束, 从而实现 MG 经济性与运行鲁棒性的协同提升. Ma 等[22] 提出一种基于分层优化的 TCL 灵活性调度方法, 通过将 TCL 在底层聚合为虚拟电池并在上层构建支持隐私保护的分布式交易型能源市场, 实现电力系统与设备层协同调度及灵活性资源的高效交易与利用. 然而, 相关研究普遍忽略了数据质量对调度模型的影响, 缺乏“数据层—建模层—调度层”的一体化分析. 特别是在存在数据缺失的实际场景中, 若直接基于不完整或低质量数据进行建模与调度, 可能导致系统运行成本增加甚至调度策略失效. 因此, 有必要构建一种兼顾数据重构与调度优化的统一方法框架, 从源头提升数据质量, 并将其有效传递至后续建模与优化决策过程.

基于上述分析, 本文提出一种考虑数据缺失的 TCL 聚合建模与 MG 优化调度方法. 首先, 针对 TCL 能耗数据缺失问题, 构建一种基于多特征融合的改进 CPI(Improved copy-paste imputation, ICPI) 算法, 实现对缺失数据的高精度重构; 其次, 基于重构后的高质量数据, 建立 TCL 聚合虚拟电池模型, 以准确刻画其群体调节能力; 最后, 在此基础上构建 MG 优化调度模型, 以最小化系统购电成本为目标, 实现可再生能源与 DR 资源的协同优化配置. 通过仿真分析验证所提方法在提升数据重构精度的同时, 能够显著改善 MG 的经济性与运行性能.

1 微电网结构与温控负荷建模

1.1 微电网结构

MG 由分布式电源、储能系统、负荷单元及能量管理系统等构成, 通过电力与通信网络实现协调运行. 考虑聚合 TCL 的并网 MG 系统结构示意图如图 1 所示. 图中, 能量管理系统作为 MG 的核心控制单元, 通过综合考虑负荷需求、可再生能源出力及电价信息, 实现系统的优化调度与经济运行. 光伏 (Photovoltaic, PV) 和风机 (Wind turbine, WT) 等可再生能源接入交流母线, 为系统提供电能, 但其出力具有一定波动性. 在负荷侧, 电力负荷通常可分为刚性

负荷 (Rigid load, RL) 与柔性负荷. 其中, RL 主要指用电需求相对固定、难以参与调节的负荷类型, 如照明及基础用电等; 而柔性负荷则具备一定的可调节能力. TCL 作为典型的柔性负荷, 具有良好的调节潜力, 是实现需求侧响应的重要资源.

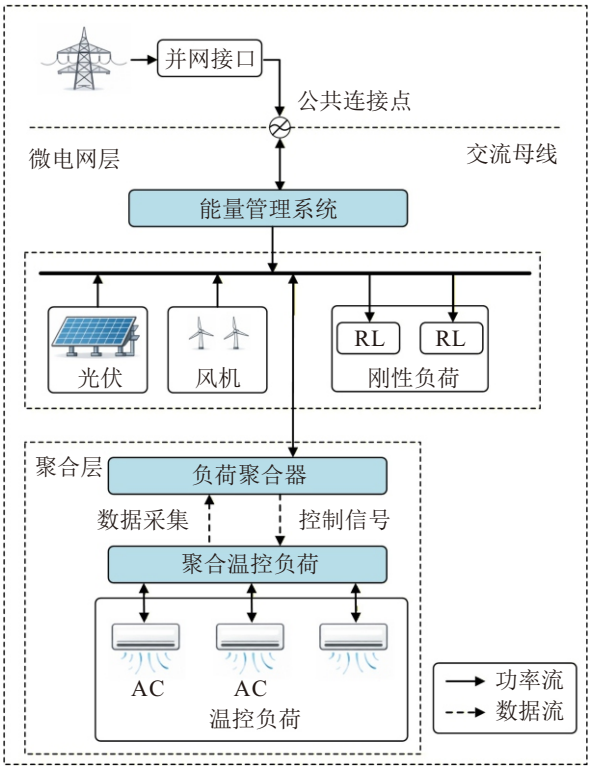

图 1　考虑聚合温控负荷的并网微电网系统结构示意图

1.2　温控负荷建模

1.2.1　单个温控负荷建模

TCL 通常采用一阶热动力学模型描述室内温度与外部环境及控制输入之间的关系. 在各类 TCL 中, 空调负荷因其在生产和生活中的广泛应用而具有代表性. 以空调在制冷模式下的运行为例, 其热力学过程可以通过以下线性微分方程进行描述:

$$C\frac{\mathrm{d}T_{in}(t)}{\mathrm{d}t}=\frac{1}{R}(T_{out}-T_{in}(t))-Q, \tag{1}$$

其中, $T_{in}(t)$表示时刻t的室内温度; T_{out}表示外部温度; R为等效热阻; C为等效热容; Q为制冷功率.

需要说明的是, 单个 TCL 的热力学模型包含热阻、热容及指数衰减项等非线性因素, 其连续时间模型可表示为建筑热平衡方程. 然而, 在聚合建模过程中, 本文首先对 TCL 热力学模型进行离散化处理, 并基于虚拟电池模型构建聚合状态方程.

对于变频型 TCL, 其电功率与制冷功率通常与压缩机运行频率呈线性关系, 可表示为:

$$P=a_1f+b_1, \tag{2}$$

$$Q=a_2f+b_2, \tag{3}$$

其中, P为 TCL 功率, a_1,b_1,a_2,b_2为线性模型固定参数.

基于 TCL 与储能设备在能量调节特性上的相似性, 研究中常将其等效为“虚拟电池”模型. 该模型通过引入基准功率与偏差功率, 刻画 TCL 在 DR 下的充放电行为, 其表达式为:

$$P_{cd}(k)=P(k)-P_{baseline}, \tag{4}$$

其中, $P_{baseline}$为设定温度下的基准功率, P_{cd}表示在调控信号作用下的等效充放电功率.

进一步地, 引入电量状态变量 (State of Charge, SOC) 描述虚拟电池的能量状态, 其动态方程为:

$$SOC(k+1)=\lambda_1SOC(k)+\lambda_2P_{cd}(k)+\lambda_3 \tag{5}$$

$$\lambda_1=e^{-\frac{\Delta t}{RC}} \tag{6}$$

$$\lambda_2=\frac{a_2R(1-\lambda_1)}{a_1(T_{\max}-T_{\min})} \tag{7}$$

$$\lambda_3=(1-\lambda_1)\cdot soc(0) \tag{8}$$

其中, λ_1、λ_2和λ_3为由热参数及采样时间确定的常数.

1.2.2　聚合温控负荷

由于单个 TCL 的调节能力有限, 难以直接参与系统级调度, 通常需要对大量 TCL 进行聚合建模. 设系统中共有n个 TCL, 其聚合虚拟电池模型可表示为:

$$SOC_{\mathrm{agg}}(k+1)=\lambda_{agg1}\cdot SOC_{agg}(k)+P_{agg}(k)+\lambda_{agg2} \tag{9}$$

$$P_{agg}(k)=\sum_{i=1}^{n}P_{cd,i}(k) \tag{10}$$

$$\lambda_{agg1}=\frac{\sum_{i=1}^{n}\lambda_{1i}}{n} \tag{11}$$

$$\lambda_{agg2}=\sum_{i=1}^{n}\frac{\lambda_{3i}}{\lambda_{2i}} \tag{12}$$

其中, P_{agg}、λ_{agg1}、λ_{agg2}为聚合虚拟电池的参数, n为聚合 TCL 数量, $P_{cd,i}$为虚拟电池的充放电功率.

上述模型将分散的 TCL 群体等效为一个统一的储能单元, 从而显著简化了建模复杂度, 并便于将其作为需求侧响应资源纳入 MG 优化调度框架. 此外, 聚合虚拟电池的运行需满足功率及能量约束, 即:

$$0\leqslant SOC_{\mathrm{agg}}(k+1)\leqslant SOC_{agg}^{\max} \tag{13}$$

$$SOC_{agg}^{\max}=n\cdot\min\{\frac{1}{\lambda_{2i}}\},\ 1\leqslant i\leqslant n \tag{14}$$

其中, $SOC_{agg}^{\max}$为聚合虚拟电池可达最大荷电状态.

2 基于多特征融合的改进 CPI 法

由公式 (1) 可知, 为保持室内温度在用户设定值附近, TCL 的功率与室外温度呈高度相关性. 具体而言, 由于制冷需求在夏季显著增加, TCL 的功率普遍高于春秋季节. 该特征表明, 在能耗数据重构过程中, 应充分考虑 TCL 对环境温度变化的敏感性, 特别是在处理缺失数据时, 环境因素对重构结果的准确性具有重要影响. 为进一步阐明所提出的 ICPI, 本节将通过数学表达形式对关键步骤与实现流程进行详细说明, 以提升方法描述的严谨性与可复现性.

2.1 线性插值

线性插值方法用于处理 TCL 能耗时间序列中的单个缺失值. 数学上, 若某一缺失值e_t位于相邻的两个已知值e_{t-1}与e_{t+1}之间, 则其计算公式可表示如下:

$$e_t = e_{t-1} + \frac{(e_{t+1} - e_{t-1})}{2} \tag{15}$$

其中, e_{t-1}和e_{t+1}分别表示在时刻$t-1$和$t+1$的能耗值, t表示当前的时间索引.

2.2 按比例分配

对于 TCL 能耗数据存在多日连续缺失时, 每日的缺失能耗根据其缺失时段的时间长度按比例进行分配. 每个目标日对应的缺失能耗可分别按如下公式确定:

$$E_k = \frac{\Delta T_k}{\Delta T_d} \cdot (e_{\mathrm{t}+d} - e_{t-1}) \tag{16}$$

其中, E_k表示第k日的总缺失能耗; ΔT_k表示第k个目标日的数据缺失时长, ΔT_d表示缺失数据的总缺失时长; $e_{t+d} - e_{t-1}$表示缺失时段的能耗差值.

2.3 复合相似性系数的定义

为了准确识别用于 TCL 能耗数据重构的相似日, 有必要定义合理的相似性度量指标. 结合用户的用电模式以及 TCL 能耗数据的电气特性, 本文构建了四类相似性系数, 并进一步通过融合的方式构造复合相似性系数, 用以衡量目标日与历史完整日之间的相似程度[23].

相似性系数 1 用于衡量用户一周用电模式的相关性, 记为β_{i1}, 用于刻画目标日d_k与完整日d_i在每周用电行为模式上的相似程度. 具体而言, 若目标日与完整日处于一周中的相同位置, 则其相似性系数取值为 1; 若两者同为工作日或同为周末, 则相似性系数设为 0.5; 若一者为工作日、一者为周末, 则相似性系数为 0. 其计算公式如下所示:

$$\beta_{i1} = \begin{cases} 1,\ \text{if } w_k = w_i \\ 0.5,\ \text{if } w_k \neq w_i \\ w_k,\ w_i \in \{1, \cdots, 5\}\ or\ w_k, w_i \in \{6, 7\} \\ 0,\ \text{else} \end{cases} \tag{17}$$

其中, 数字 1 至 7 分别对应星期一至星期日; w_k与w_i分别表示目标日与完整日对应的星期编号, i表示具有完整能耗数据的完整日, 且该符号在下文中保持一致.

相似性系数 2 用于量化目标日与完整日能耗序列之间的差异性, 记为β_{i2}. 由于 TCL 在夏季与过渡季节 (春季和秋季) 存在显著的能耗模式差异, 本文引入相似性系数β_{i2}以体现并修正季节性因素的影响. 目标日与完整日之间的日期间隔越小, 其季节特征越接近, 相应的相似性系数也越高. 相似性系数 2 的计算可表示如下:

$$\beta_{i2} = \frac{\dfrac{Y}{2}}{\min(|y_k - y_i|, Y - |y_k - y_i|)} \tag{18}$$

其中, Y表示一年中的总天数. 鉴于年份可能为 365 天或 366 天, 本文采用长期平均的方法以确保不同年份间的一致性, 将Y的取值设定为 365.25. y_k与y_i分别表示目标日与完整日对应的日期索引, 即 1 表示第一天, 30 表示第 30 天.

相似性系数 3 用于比较目标日与完整日能耗数据的极值距离, 记为β_{i3}. 该系数定义为两日能耗极值之间欧氏距离的倒数, 用以衡量在能耗幅值上的接近程度. β_{i3}的数值越大, 说明目标日与完整日在能耗极值水平上越相似.

$$\beta_{i3} = \frac{1}{\sqrt{(e_{k,max} - e_{i,max})^2 + (e_{k,min} - e_{i,min})^2}} \tag{19}$$

其中, $e_{k,\max}$和$e_{k,\min}$分别表示目标日缺失时间序列中的最大与最小日能耗值; $e_{i,\max}$和$e_{i,\min}$分别表示完整日时间序列中的最大与最小日能耗值.

相似性系数 4 用于量化目标日与完整日能耗数据轮廓整体形状的相似程度, 记为β_{i4}. 该系数考察的是整日能耗曲线的匹配性. 常用的相似性度量方法之一为皮尔逊相关系数法, 可用于衡量两段时间序列之间的线性相关程度. β_{i4}值越高, 表明两日的能耗模式越相似. 其定义如下所示:

$$\beta_{i4} = \frac{\sum_{t=1}^{N} |e_{k,t} - \overline{e_k}||e_{i,t} - \overline{e_i}|}{\sqrt{\sum_{t=1}^{N} (e_{k,t} - \overline{e_t})^2} \sqrt{\sum_{t=1}^{N} (e_{i,t} - \overline{e_i})^2}} \tag{20}$$

其中, $e_{k,t}$和$e_{i,t}$分别表示目标日与完整日在时间步t处的能耗值; $\overline{e_k}$与$\overline{e_i}$分别表示目标日与完整日的日平均能耗; N表示缺失数据的数量.

为了将各个单项相似性度量整合为统一的评价指标, 本文采用几何平均的方法构建复合相似性系数, 相较于加权求和方法, 该构造方式能够避免人为权重设定带来的主观性, 并增强多特征之间的协同表达能力. 目标日与完整日的复合相似性系数记为$\beta_{k,i}$, 其数学表达式如下所示:

$$\beta_{k,i} = \sqrt[4]{\frac{\beta_{i1}}{\max(\beta_{i1})}\cdot\frac{\beta_{i2}}{\max(\beta_{i2})}\cdot\frac{\beta_{i3}}{\max(\beta_{i3})}\cdot\frac{\beta_{i4}}{\max(\beta_{i4})}} \tag{21}$$

其中, $\max(\beta_{i1})$、$\max(\beta_{i2})$、$\max(\beta_{i3})$和$\max(\beta_{i4})$分别表示所有完整日中对应相似性系数的最大值, 用于归一化处理, 以保证各指标在合成时具备可比性.

2.4　相似日匹配与数据重构

基于上述复合相似性系数的定义, 得到目标日与所有完整日的复合相似性系数, 其最小值所对应的完整日即为匹配日. 由于对比的是所有已获取数据的完整日, 匹配日也有可能是目标日之后的日期, 且每一个缺失数据的目标日均有其对应的匹配日.

根据匹配日的能耗时间序列数据, 得到对应的功率时间序列. 然后, 计算匹配日和目标日的总能耗比率, 并将此比率作为缩放系数, 应用于匹配日的功率序列, 从而生成目标日的缺失功率数据.

$$P_{k,t} = P_{i,t} \times \frac{E_i}{E_k} \tag{22}$$

其中, $P_{k,t}$为目标日重构后的功率, $P_{i,t}$为匹配日对应时刻功率, E_i为匹配日对应时间段总能耗, E_k为目标日的总缺失能耗.

最后, 通过对重构的功率时间序列进行累计, 得到完整的 TCL 能耗重构结果.

2.5　温控负荷能耗数据重构

采集 TCL 的能耗数据在实施需求侧响应和优化调度策略中具有重要意义. 然而, 在实际中, 由于电力设备运行环境复杂且工况多变, 传感器故障或通信网络不稳定等硬件问题常导致监测数据出现缺失[24]. 其中, 短时信号中断可能导致个别数据点的丢失, 而系统故障或传感器失效则可能造成长时间的数据缺失. 因此, 缺失数据的有效重构在提升数据完整性与保障数据准确性方面具有关键作用. 基于 ICPI 的 TCL 能耗数据重构方法的总体框架如图 2 所示.

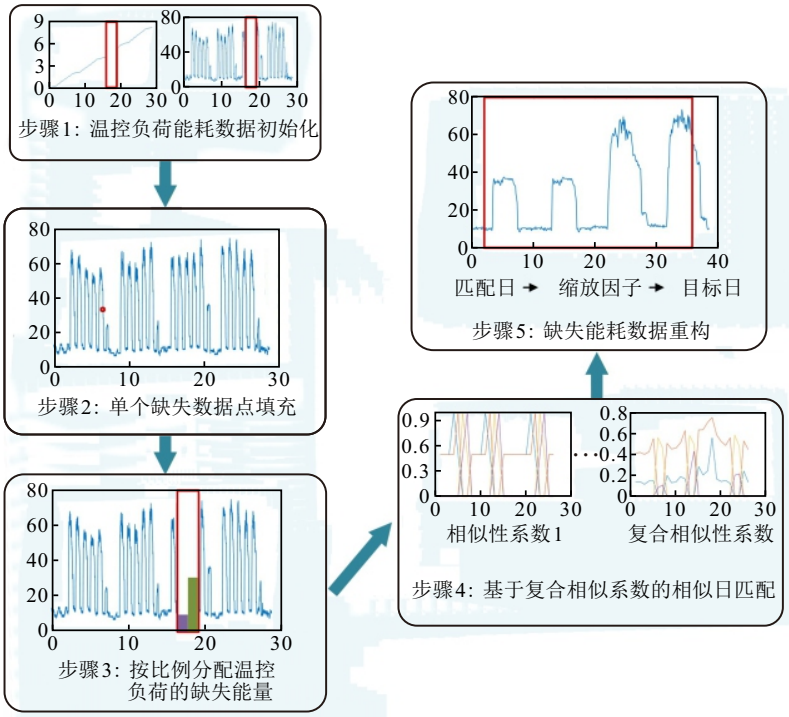

图 2　温控负荷能耗数据重构总体框架

相似日算法是一种被广泛应用于预测未来数据的方法. 该方法通过识别与目标日具有相似特征的数据完整日, 进而利用其数据作为参考, 以获得准确可靠的数据. 在此基础上, 本文提出了一种 ICPI 用于重构 TCL 能耗数据中的缺失部分. 该方法的核心思想是通过参考所有完整相似日的能耗数据, 包括历史数据完整相似日和未来数据完整相似日, 对目标日的能耗数据缺失区段进行重构. 其流程图如图 2

所示. 该方法的核心步骤

如下:

步骤 1: TCL 能耗数据初始化. 该过程首先对数据集按时间顺序进行结构化处理, 通常来源于用户智能电表所记录的电力消耗数据. 由于智能电表采集的数据通常为能耗的累积值, 因此需对其进行处理, 计算出每日的功率数据, 为后续的数据重构做好准备.

步骤 2: 单个缺失点的填补. 当由于信号中断或传感器故障导致出现单个数据点缺失时, 可采用线性插值法, 依据其前后相邻的有效数据点, 计算并补全该缺失点的能耗值.

步骤 3: TCL 多日缺失能耗的比例分配. 当 TCL 的缺失数据跨越多个连续日时, 先统计该时间段内的总缺失能耗值, 再依据各目标日的时间间隔长度按比例进行分配, 实现每日缺失数据的初步估算.

步骤 4: 基于复合相似性系数的相似日匹配. 提取目标日的关键特征, 包括能耗模式、气象因素以及用户行为等, 随后依据预设的相似性判据 (如欧几里得距离、相关系数等) 计算相似性系数. 将各类相似性度量结果融合形成复合相似性系数, 并选取与目标日最为相似的完整日作为匹配对象.

步骤 5: 缺失能耗数据重构. 首先由匹配的完整日提供参考数据; 然后将该完整日中与目标日缺失时段相对应的时间段进行对齐, 确保时间一致性; 最后根据设定的重构规则生成目标日的缺失能耗数据, 实现最终的重构.

为便于理解 ICPI 方法的数据重构过程, 以某 TCL 用户在目标日期发生能耗数据缺失为例进行说明. 首先, 根据目标日期的完整数据区间提取用电行为特征、季节特征以及负荷曲线特征, 并与候选参考日进行逐一比较. 通过计算各候选参考日的复合相似性系数, 选择相似性最高的日期作为参考日.

假设目标日期缺失时段为 12:00—15:00, 经计算得到参考日 A 的复合相似性系数最高, 因此选取参考日 A 作为重构依据. 由于目标日期与参考日在整体能耗水平上可能存在差异, 直接复制参考日对应时段数据可能导致重构结果出现系统性偏差. 因此, 引入缩放系数对参考日曲线进行修正, 其计算方式如下:

$$\lambda = \frac{\overline{P}_{target}}{\overline{P}_{ref}} \tag{23}$$

其中, $(\overline{P}_{target})$ 表示目标日期已知时段的平均功率, $(\overline{P}_{ref})$ 表示参考日期对应时段的平均功率.

例如, 当目标日期已知时段平均功率为 3.0 kW, 参考日期对应时段平均功率为 2.5 kW 时, 则缩放系数为$\lambda = \dfrac{3.0}{2.5} = 1.2$.

此时参考日缺失区间对应的功率值按照 1.2 倍进行缩放, 并作为最终重构结果. 通过该处理方式, 既能够保留参考日负荷曲线的变化趋势, 又能够反映目标日期实际能耗水平, 从而提高缺失数据重构的准确性.

为增强模型的实用性与调度结果的可靠性, 第 2 章所提出的数据重构方法主要用于恢复 TCL 缺失的能耗时间序列, 从而获得连续、完整且具有动态特征的负荷输入数据. 在此基础上, 重构后的 TCL 数据被进一步用于第 3 章的 MG 优化调度模型构建, 作为聚合 TCL 建模与可调度能力评估的重要基础变量, 从而实现从数据层到优化决策层的有效衔接.

3 聚合温控负荷参与的微电网优化调度方法

在完成基于 ICPI 方法的 TCL 能耗数据重构后, 可获得高完整性和高可信度的功率时间序列, 从而有效提升后续模型参数辨识与聚合建模的准确性. 在此基础上, 为充分挖掘 TCL 在 DR 中的调节潜力, 结合前文构建的聚合虚拟电池模型, 建立考虑聚合 TCL 参与的 MG 优化调度模型, 以实现多源协同条件下系统运行成本的最优控制.

3.1 优化调度模型

以调度周期内 MG 的购电成本最小为优化目标, 构建如下目标函数:

$$\min F = \sum_{k=1}^{T} P_{\text{grid}}(k)\lambda(k) \tag{24}$$

其中, $P_{\text{grid}}(k)$表示在时刻k时 MG 与主网的交互功率 (取正值表示购电, 负值表示售电), $\lambda(k)$为对应时段的电价.

根据系统功率平衡, 有如下公式:

$$P_{\text{grid}}(k) = P_{\text{RLs}}(k) - P_{PV}(k) - P_{\text{WT}}(k) - \text{P}_{\text{agg}}(k) \tag{25}$$

其中, $P_{\text{RLs}}(k)$为 RL 功率, $P_{\text{PV}}(k)$和$P_{\text{WT}}(k)$分别为光伏与风电出力, $P_{\text{agg}}(k)$为聚合 TCL 的功率.

3.2 约束条件

1) 功率平衡约束

为保证系统能量平衡, 需满足:

$$P_{\text{grid}}(k) + P_{\text{PV}}(k) + P_{\text{WT}}(k) + P_{\text{agg}}(k) = P_{RLs}(k) \tag{26}$$

2) 聚合 TCL 功率约束

聚合 TCL 作为虚拟储能资源, 其调节功率受上

下界限制:

$$P_{\text{agg}}^{\min} \leqslant P_{\text{agg}}(k) \leqslant P_{\text{agg}}^{\max} \tag{27}$$

其中, $P_{\text{agg}}^{\min}$和$P_{\text{agg}}^{\max}$分别为聚合虚拟电池的功率上下限.

3) SOC 动态约束

基于虚拟电池模型, 聚合 TCL 的状态演化可表示为:

$$SOC_{\text{agg}}(k+1) = \lambda_1 SOC_{\text{agg}}(k) + \lambda_2 P_{\text{agg}}(k) + \lambda_3 \tag{28}$$

其中, $SOC_{\text{agg}}(k)$表示聚合 TCL 在时刻k的等效状态量, λ_1、λ_2、λ_3为模型参数.

4) 状态范围约束

为保证用户舒适度及设备运行安全, 需对状态变量进行约束:

$$0 \leqslant SOC_{\text{agg}}(k) \leqslant SOC_{\text{agg}}^{\max} \tag{29}$$

5) 电网交互约束

考虑并网功率限制, MG 与主网的交互功率满足:

$$P_{\text{grid}}^{\min} \leqslant P_{\text{grid}}(k) \leqslant P_{\text{grid}}^{\max} \tag{30}$$

其中, $P_{\text{grid}}^{\max}$、$P_{\text{grid}}^{\min}$分别为主网允许交互功率上下限.

3.3　优化调度方法

为求解上述构建的 MG 优化调度模型, 本文设计了一种考虑聚合 TCL 参与的优化调度算法. 为提高模型输入数据的准确性与时序一致性, 本文在优化建模前引入 ICPI 数据重构步骤, 对原始负荷及可再生能源出力数据进行预处理, 从而增强优化调度结果的可靠性与鲁棒性. 该算法以预测刚性负荷、可再生能源出力及分时电价为输入, 在满足系统功率平衡及聚合 TCL 运行约束的前提下, 以购电成本最小为目标, 对调度周期内各时段的功率分配进行统一优化. 由于本文采用小时级优化调度框架, 而实际通信与计算过程通常处于秒级至分钟级时间尺度, 因此其影响相对有限.

所提出优化调度算法的伪代码如算法 1 所示. 具体而言, 基于 ICPI 重构后的负荷数据, 建立线性优化调度模型, 并通过 CPLEX 求解获得聚合 TCL、主网交互功率及 SOC 状态的最优结果.

算法1　基于ICPI的聚合TCL参与的MG优化调度

输入:

原始负荷数据$P_{RLs}^{ori}(k)$

原始光伏出力$P_{PV}^{ori}(k)$

原始风电出力$P_{WT}^{ori}(k)$

电价$\lambda(k)$

虚拟电池参数$(\lambda_1, \lambda_2, \lambda_3)$

功率约束$P_{agg}^{\min}, P_{agg}^{\max}$

SOC约束$SOC_{agg}^{\max}$

初始状态$SOC_{agg}(0)$

输出:

最优调度结果$P_{agg}^{*}(k), P_{grid}^{*}(k), SOC_{agg}^{*}(k)$

步骤:

1. 数据重构处理

对原始数据进行预处理与重构, 得到平滑且一致的输入序列: $P_{\text{RLs}}(k), P_{\text{PV}}(k), P_{\text{WT}}(k)$

2. 初始化

设定$k=1$, 并初始化聚合TCL状态:

$$SOC_{agg}(1) = SOC_{agg}(0)$$

3. 构建优化模型

目标函数: 最小化调度周期内购电成本:

$$\min F = \sum_{k=1}^{T} P_{\text{grid}}(k)\lambda(k)$$

约束条件:

(1) 功率平衡约束

(2) 聚合TCL功率约束

(3) SOC动态约束

(4) SOC范围约束

4. 模型转化

将上述优化问题转化为标准线性规划问题

5. 模型求解

调用优化求解器(如CPLEX)进行求解

6. 输出结果

4　仿真分析

4.1　数据来源及初始化

本节对上述 ICPI 进行测试, 以验证其在 TCL 实际能耗时间序列数据重构中的应用效果. 所采用的数据集涵盖了 2012 年 1 月至 2014 年 1 月期间, 以 15 分钟为间隔记录的电表数据[25]. 为验证所提出算法的有效性与泛化能力, 本文选用的原始数据为完整的能耗时间序列, 无缺失值. 为更贴近 TCL 能耗数据的实际缺失特点, 本研究在模拟数据缺失时遵循典型故障模式, 综合考虑随机干扰与系统性故障的影响, 分别引入了孤立缺失点和连续缺失区段, 并采用完全随机缺失机制构造缺失数据. 即在原始完整数据中按照预设缺失比例随机选取数据点或连续时间段进行删除, 以模拟传感器故障、通信中断等实际运行过程中产生的数据缺失现象.

此外, 为与 MG 调度场景保持一致, 相关外部数据 (包括光伏出力、风电出力及电价信号) 选自典型运行日数据, 其中可再生能源出力采用典型晴天的

表 1 TCL 相关参数

参数	数值	参数	数值
R	[1.5, 2.5] °C/kW	$P_{\min}$	0.5 kW
C	[1.5, 2.5] kWh/°C	$P_{\max}$	5 kW
T_{set}	[22, 24] °C	a_1	0.03 kW/Hz
$T_{\min}$	22 °C	b_1	−0.4 kW
$T_{\max}$	24 °C	a_2	0.06 kW/Hz
		b_2	−0.3 kW

预测曲线, 电价、环境参数及 TCL 相关参数来源于文献 [26]. 选取 1 000 台 TCL 为研究对象, 具体参数如表 1 所示.

为验证所提算法的有效性与泛化能力, 本文选取了三组具有不同用电特性的 TCL 功率时间序列, 并在人为构建的随机数据缺失场景下进行实验, 以真实模拟实际应用中数据缺失的随机性. 具体地, 缺失数据的设置包括两种情形, 第一种是单点缺失, 第二种是区段缺失, 缺失的数据是全年数据总量的 10%. 图 3 (a) - (c) 展示了用于测试的 TCL 功率时间序列.

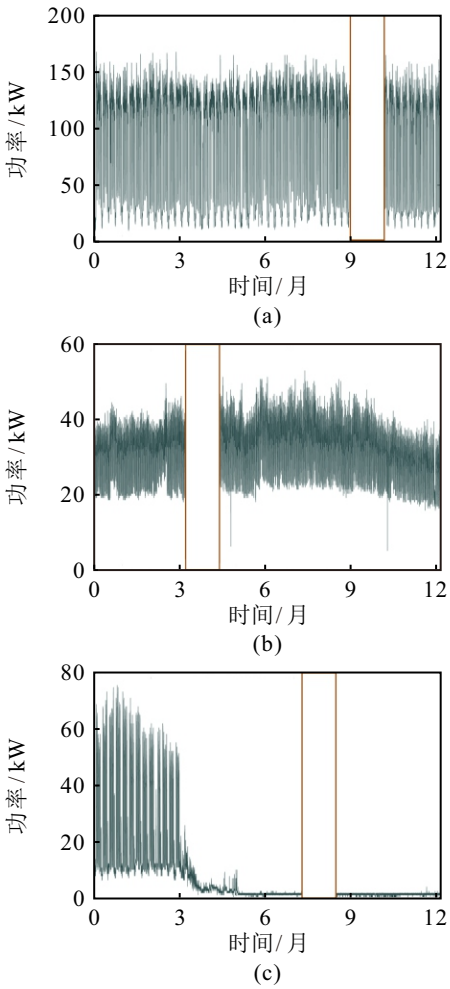

图 3 存在缺失数据的不同 TCL 功率时间序列

4.2 重构精度评价指标

为全面评估所提算法在缺失能耗数据重构中的有效性, 本文采用两种常用误差评价指标: 平均绝对百分比误差 (Mean Absolute Relative Error, MARE) 与归一化均方根误差 (Normalized Root Mean Square Error, NRMSE). 这两种指标均为无量纲误差度量, 能够在不同数据尺度下评估重构结果的准确性. 两项指标的计算公式如下所示:

$$\mathrm{MARE} = \frac{1}{N}\sum_{k=1}^{N}\left|\frac{p_{t,k}-\hat{p}_{t,k}}{p_{t,k}}\right| \tag{31}$$

$$\mathrm{NRMSE} = \frac{\sqrt{\dfrac{1}{N}\displaystyle\sum_{k=1}^{N}\left(p_{t,k}-\hat{p}_{t,k}\right)^2}}{p_{t,k,max}-p_{t,k,min}} \tag{32}$$

其中, $e_{t,k}$表示目标日第k个时间步的实际功率值, $\hat{e}_{t,k}$表示对应时间步的重构值. 分母$e_{t,k,\max}-e_{t,k,\min}$表示该目标日实际数据的取值范围, 用于归一化处理, 从而确保误差度量的尺度无关性.

4.3 数据重构结果分析

4.3.1 重构曲线

图 4 为上述三组具有不同用电特性的 TCL 功

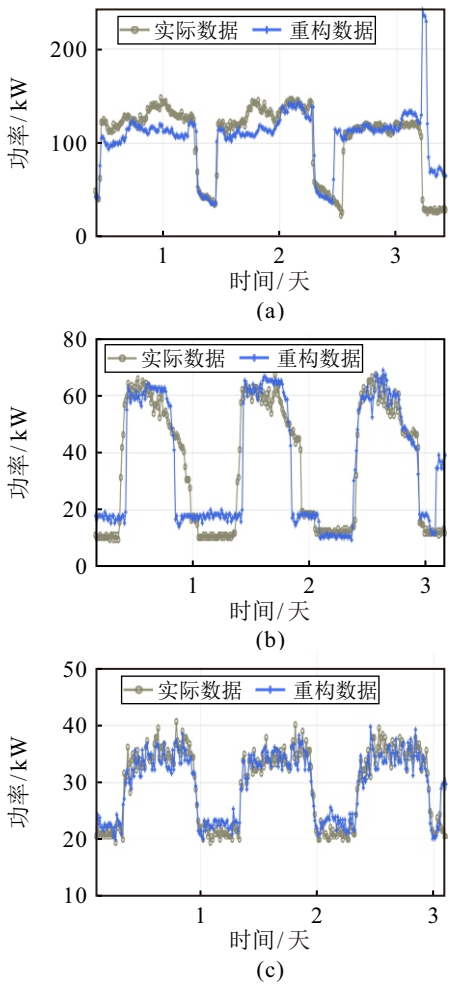

图 4 TCL 数据重构功率时间序列

率时间序列在缺失数据场景下的重构曲线. 图中, 灰色曲线为缺失片段的实际功率曲线, 蓝色曲线为采用所提 ICPI 方法重构得到的功率曲线. 如图 4 (a) - (c) 所示, 尽管在个别剧烈变化点 (例如图 4 (a) 中第四个目标日) 存在一定的重构误差, 但对于功率波动相对平稳的场景, 所提方法表现出较高的重构精度, 例如在图 4 (c) 中, 重构曲线与实际曲线高度一致, 几乎无明显偏差. 整体来看, 重构结果在整体趋势变化、峰谷时序及局部波动特性方面与真实值较为一致. 结果表明, ICPI 能够较好地适应不同运行状态下的 TCL 数据缺失场景, 并具有一定的鲁棒性. 综上, ICPI 方法能够较好地重构不同类型 TCL 的缺失功率数据, 在保持整体趋势和局部波动特征方面具有较好的适应性, 为后续聚合建模与优化调度提供了可靠的数据基础.

4.3.2　不同连续缺失程度下的重构性能分析

为进一步验证所提方法对长时间连续缺失数据的重构能力, 本文设置不同连续缺失比例场景进行测试. 保持其余实验条件不变, 在原始完整数据中随机选取连续时间区段进行删除, 分别设置 5%、10%、20% 和 30% 四种连续缺失比例, 以模拟不同程度的通信中断或传感器故障导致的数据缺失情况. 不同连续缺失场景下的重构结果如表 2 所示.

表 2　不同连续缺失场景下的重构结果

场景	缺失率/%	MARE	NRMSE
M1	5	0.30	0.14
M2	10	0.68	0.23
M3	20	0.73	0.22
M4	30	0.76	0.25

表 2 结果表明, 随着连续缺失比例由 5% 增加至 30%, MARE 与 NRMSE 整体上升, 说明缺失程度加剧会降低重构精度. 其中, 5% 至 10% 区间误差增长最为显著, MARE 由 0.30 升至 0.68, NRMSE 由 0.14 增至 0.23, 表明模型对局部时间依赖结构较为敏感, 信息连续性破坏会显著影响重构效果. 而在 20% 与 30% 缺失场景下, 误差增长趋于平缓, MARE 稳定在 0.73–0.76, NRMSE 维持在 0.22–0.25, 说明模型在高缺失条件下仍具有一定稳定性. 总体而言, 所提方法在 30% 连续缺失下仍保持可接受误差水平, 具有较好的鲁棒性. 需要指出的是, 数据重构误差可能通过虚拟电池参数辨识过程影

响基准功率和 SOC 状态估计, 并进一步传递至优化调度层; 由于所提方法具有较高的数据重构精度, 因此能够有效降低误差传播对调度结果的影响.

4.3.3　基准算法与 ICPI 的效果比较

为全面评估所提 ICPI 方法在 TCL 能耗数据重构中的性能, 本文选取三种具有代表性的传统数据填补方法作为对比基线, 包括线性插值法 (基准 1)、前向填充法 (基准 2) 以及均值填补法 (基准 3). 其中, 线性插值法利用相邻已知数据点对缺失值进行时间连续性估计, 能够反映基于局部趋势的重构能力; 前向填充法采用最近的有效观测值对缺失数据进行替代, 属于最简单的时序延续型填补策略; 均值填补法则利用历史观测数据的统计均值对缺失值进行替代, 反映基于全局统计特性的重构方式.

ICPI 与三种基准方法在两项评价指标 (MARE 与 NRMSE) 下的对比结果如表 3 所示. 在 TCL1–TCL3 三类场景下, ICPI 在 MARE 与 NRMSE 两项指标上整体优于三种基准方法. 在 TCL1 中, ICPI 的 MARE 与 NRMSE 分别为 0.33 和 0.24, 其中 MARE 明显优于基准 1(0.54)、基准 2(0.55) 及基准 3(0.54), NRMSE 与基准 1 持平或更优; 在 TCL2 中, ICPI 取得 0.30 和 0.17, 显著优于基准 1(1.04, 0.32)、基准 2(0.52, 0.93) 及基准 3(0.81, 0.65); 在 TCL3 中, ICPI 进一步达到最优水平 (0.06, 0.11), 相较各基准方法均表现出更低误差. 总体而言, ICPI 在不同负荷特性条件下均表现出稳定且优越的重构性能.

表 3　ICPI 与基准方法的评价指标

评价指标	TCL类型	MARE	NRMSE
ICPI	TCL1	0.33	0.24
	TCL2	0.30	0.17
	TCL3	0.06	0.11
基准1	TCL1	0.54	0.24
	TCL2	1.04	0.32
	TCL3	0.23	0.26
基准2	TCL1	0.55	0.66
	TCL2	0.52	0.93
	TCL3	0.27	0.38
基准3	TCL1	0.54	0.38
	TCL2	0.81	0.65
	TCL3	0.23	0.23

4.3.4　重构参考天数的影响

为研究重构参考天数对 TCL 能耗时间序列重构精度的影响, 本节设计分组对比实验, 固定缺失数据段的长度, 通过调整参与重构过程的参考天数进行重构精度分析. 具体地, 参考天数分别设置为 14 天 (1 344 个采样点)、30 天 (2 880 个采样点)、90 天 (8 640 个采样点)、180 天 (17 280 个采样点) 和 365 天 (35 040 个采样点), 以评估不同参考天数下 ICPI 缺失片段长度为总天数 10% 时的重构效果.

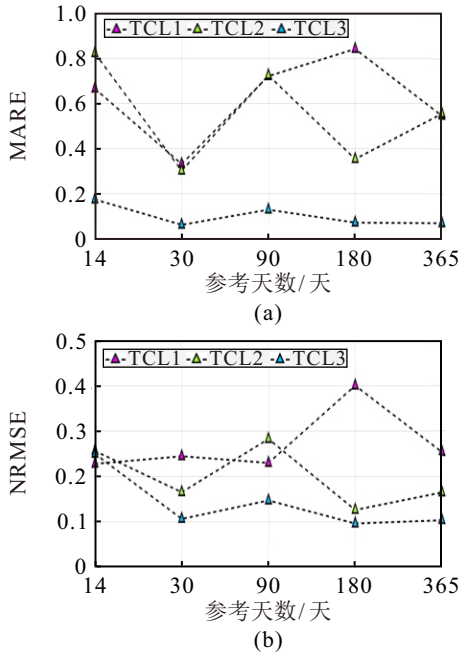

图 5 不同参考天数下 ICPI 重构精度

表 4 不同参考天数下 ICPI 重构误差

参考天数	MARE	NRMSE
14	0.66	0.23
30	0.33	0.25
90	0.72	0.23
180	0.84	0.4
365	0.55	0.25

ICPI 在不同参考天数下的重构精度如图 5 所示, 数据重构的误差指标如表 4 所示.

由图 5 和表 4 可知, 三个 TCL 样本在 MARE 与 NRMSE 指标上的变化趋势基本一致, 且均在参考天数为 30 天时误差较低. 综合分析可知, 参考天数的选取对数据重构性能具有显著影响. 当参考天数过少时, 相似特征提取不足; 参考天数过多时, 则可能引入冗余信息. 实验结果表明, 30 天参考窗口能够在特征代表性与数据相关性之间取得较好的平衡.

4.3.5 复合相似性系数的影响

为进一步评估复合相似性系数对 TCL 能耗数据重构精度的影响, 本节考察了两种相似日选取标准, 分别是采用所提复合相似性系数和无复合相似性系数的加和总系数. 表 5 展示了在有无复合相似性系数参与下, 所提出的 ICPI 方法的重构性能评价指标.

表 5 复合相似性系数的影响

评价指标	MARE	NRMSE
有复合相似性系数	0.10	0.09
无复合相似性系数	0.19	0.14

结果表明, 复合相似性系数的引入提升了重构精度. 具体而言, MARE 由 0.19 降至 0.10, NRMSE 由 0.14 降至 0.09. 该结果表明, 复合相似性系数在数据重构过程中发挥了关键作用, 有效提高了相似日的匹配精度, 从而实现了更准确的数据重构, 并更好地保持了 TCL 时间序列中的时序相关性. 综上, 引入复合相似性系数能够综合考虑多维特征信息, 提高相似日识别的准确性, 是提升 ICPI 重构性能的重要因素.

4.3.6 数据重构对微电网优化调度性能的影响分析

为验证所提数据重构方法在 MG 优化调度中的有效性, 将重构后的负荷功率时间序列引入 MG 能量管理系统, 并与未进行数据重构的情形进行对比分析. 在可再生能源出力预测、电价信号及调度模型约束条件一致的前提下, 分别构建“无数据重构”和“ICPI 数据重构”两种调度场景, 以评估数据完整性对调度结果的影响, 仿真结果如图 6 所示.

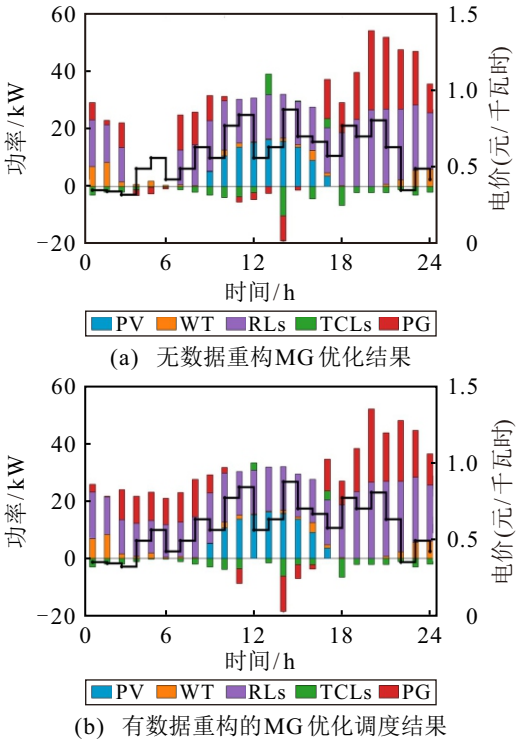

图 6 有无数据重构下的 MG 优化调度结果

由图 6(a) 与 (b) 的对比结果可以看出, 在未进行数据重构的情况下, RLs 数据存在明显的缺失与不连续现象, 部分时段负荷功率异常偏低甚至接近为零, 导致系统负荷水平被严重低估. 在此基础上进行优化调度时, 模型对负荷需求的判断偏小, 从而减少主网购电功率并改变聚合 TCL 的出力分配, 造成调度结果偏离实际运行状态. 同时, 负荷数据的不完整性削弱了聚合 TCL 的调节有效性, 使其聚合 SOC 演化与电价信号之间的协同关系减弱, 削峰填谷能力受到限制. 此外, 在部分时段甚至出现不合理的功

率波动 (如时刻 4、5 和 6), 加剧了系统运行的不稳定性. 相比之下, 采用 ICPI 方法进行数据重构后, 负荷曲线更加平滑连续, 能够较为准确地反映系统负荷需求特性, 从而使优化调度在主网购电决策与 TCL 调节分配上更加合理, 系统运行运行状态得到改善.

为进一步量化数据重构对 MG 系统调度的影响, 对系统层面运行指标进行对比分析, 结果如表 6 所示. 在未进行数据重构的情况下, 系统总购电成本为 18976 元; 采用 ICPI 方法进行数据重构后, 该指标降低至 18378 元. 相比之下, 数据重构使系统购电成本下降约 3.15%. 同时, 系统峰谷差由 8641.1 kW 降低至 7407.4 kW, 降幅达到 14.28%, 说明重构后的负荷数据能够更准确地反映负荷响应特性, 从而提升优化调度的削峰填谷效果. 此外, 负荷波动率由 526.6 kW 下降至 400.8 kW, 降幅约为 23.89%, 表明经数据重构后得到的调度方案具有更好的平滑性和运行稳定性. 综合来看, 所提数据重构方法不仅能够降低系统运行成本, 还能够改善负荷曲线形态, 增强系统调度的稳定性, 为后续虚拟电池建模与优化调度提供更加可靠的数据基础.

表 6　系统层面运行指标对比

指标	无数据重构	有数据重构	变化率
成本/元	18976	18378	3.15%
峰谷差/千瓦	8641.1	7407.4	14.28%
负荷波动/千瓦	526.6	400.8	23.89%

4.3.7　计算复杂度与求解效率分析

为评估所提方法的工程可实施性, 本文对数据重构与优化调度过程的计算效率进行了分析. 对于

ICPI 数据重构过程, 其主要计算量来源于参考日搜索与相似性匹配过程. 由于该方法不涉及复杂迭代训练过程, 因此无需额外的模型训练过程, 计算复杂度相对较低. 对于优化调度部分, 由于目标函数及约束条件均为线性形式, 所建立模型属于标准线性规划问题, 并采用 CPLEX 求解器进行求解. 在 MATLAB R2021a 环境下 (Intel Core i7 处理器, 32 GB 内存), 本文测试案例中 ICPI 数据重构耗时约为 2.78 s, 优化调度求解耗时约为 2.90 s, 总计算时间约为 5.68 s. 考虑到本文采用小时级优化调度框架, 该计算时间远小于调度周期, 能够满足实际 MG 能量管理系统的在线应用需求, 表明所提方法能够满足小时级 MG 优化调度的计算需求, 具备实际工程应用潜力.

4.3.8　不同运行场景下的适应性分析

为进一步验证所提方法在不同运行条件下的适用性和鲁棒性, 在基准场景基础上构建 4 种典型运行场景进行测试. 其中, 基准场景 (S0) 采用原始负荷数据和光伏出力数据, 不对其进行额外调整. 各场景均保持系统结构参数、电价机制及数据缺失率不变, 仅调整负荷水平或光伏出力水平. 其中, 案例 1(S1) 为低负荷场景, 负荷水平设置为基准场景的 80%; 案例 2(S2) 为高负荷场景, 负荷水平设置为基准场景的 120%; 案例 3(S3) 为低光伏出力场景, 光伏出力设置为基准场景的 70%; 案例 4(S4) 为高光伏出力场景, 光伏出力设置为基准场景的 130%. 各场景的具体设置如表 7 所示.

表 7　不同运行场景设置

场景	负荷水平	光伏出力
S0	100%	100%
S1	80%	100%
S2	120%	100%
S3	100%	70%
S4	100%	130%

针对上述场景, 分别比较“无数据重构”和“基于 ICPI 数据重构”两种优化调度方案下的运行结果, 并统计系统运行成本和成本变化率, 结果如表 8 所示. 从负荷水平场景来看, 随着负荷水平由 80% 提高至 120%, 系统购电成本明显增加. 在无数据重构条件下, 低负荷场景 (S1) 和高负荷场景 (S2) 的购电成本分别为 19258 元和 40560 元; 采用 ICPI 数据重构后, 购电成本分别降低至 12766 元和 34414 元, 对应降幅达到 33.71% 和 15.15%. 结果表明, 所提方法在不同负荷水平条件下均能够有效改善调度结果, 但随着系统负荷水平提高, 由于购电需求增加, 数据重构带来的相对经济收益有所减弱.

表 8　不同运行场景下优化调度结果

场景	调度方案	购电成本/元	成本变化率/%
S0	无重构	30585	-
S0	ICPI重构	24230	20.78
S1	无重构	19258	-
S1	ICPI重构	12766	33.71
S2	无重构	40560	-
S2	ICPI重构	34414	15.15
S3	无重构	35092	-
S3	ICPI重构	28844	17.80
S4	无重构	24965	-
S4	ICPI重构	18551	25.69

从光伏出力场景来看, 光伏出力变化对系统购电成本具有显著影响. 当光伏出力降低至基准场景的 70% 时 (S3), 系统需要从主电网购入更多电能以

满足负荷需求, 购电成本达到 35 092 元; 当采用 ICPI 数据重构后, 购电成本下降至 28 844 元, 降幅为 17.80%. 当光伏出力提高至基准场景的 130% 时 (S4), 系统可利用更多本地可再生能源, 购电成本降低至 24 965 元; 采用 ICPI 数据重构后, 购电成本进一步下降至 18 551 元, 降幅达到 25.69%. 这说明在不同可再生能源出力条件下, 所提方法均能够有效提高调度决策的准确性, 从而降低系统运行成本.

综合比较各场景结果可以发现, 采用 ICPI 数据重构后, 所有场景的购电成本均得到不同程度降低, 成本降幅介于 15.15%～33.71% 之间. 其中, 低负荷场景和高光伏出力场景的经济性改善效果较为明显, 而高负荷场景下的降幅相对较小. 总体而言, 所提方法在不同负荷水平及光伏出力条件下均能够保持良好的应用效果, 表明其具有较好的场景适应能力和运行鲁棒性.

5 结 论

针对 TCL 能耗数据缺失问题, 本文提出了一种基于多特征融合的 ICPI 数据重构方法, 并构建了考虑聚合 TCL 参与的 MG 优化调度模型, 实现了从数据重构、负荷建模到调度优化的统一分析框架. 仿真结果表明, 该方法能够有效提升数据质量并增强调度决策的准确性.

在数据重构性能方面, ICPI 方法融合用电行为、季节性及能耗曲线等多维特征, 相较传统方法显著降低重构误差, 在不同 TCL 样本中 MARE 最低可达 0.06, NRMSE 最低为 0.11. 该方法在 5%–30% 数据连续缺失场景下仍保持稳定性能, 且在所有基准对比方法中表现最优或接近最优, 体现出较好的鲁棒性与泛化能力.

在调度性能方面, 引入重构数据后系统经济性与运行稳定性均得到改善, 总购电成本由 18 976 元降低至 18 378 元 (约 3.15%), 峰谷差与负荷波动率分别降低约 14.28% 与 23.89%. 在不同负荷与光伏出力场景下, 购电成本降幅介于 15.15%–33.71% 之间, 表明该方法具有良好的场景适应性. 在计算性能方面, ICPI 无需训练过程, 总计算时间约 5.68s, 能够满足小时级调度需求, 具有良好的工程可实现性. 未来研究重点可进一步拓展至多类型柔性负荷协同调度, 以提升系统整体灵活性与调度性能.

参考文献 (References)

[1] 杨婕, 王伟强, 马锴, 等. 考虑共享电池站和温控负荷响应的综合能源系统优化调度[J]. 控制与决策, 2022, 37(2): 370-378.
(Yang J, Wang W Q, Ma K, et al. Optimal scheduling of integrated energy system considering response of shared battery station and thermostatically controlled loads[J]. Control and Decision, 2022, 37(2): 370-378.)

[2] 李忠文, 张玉成, 程志平. 光伏发电参与直流微电网多时间尺度电压支撑的分布式分层控制[J]. 中国电机工程学报, 2025, 45(12): 4707-4717.
(Li Z W, Zhang Y C, Cheng Z P. Distributed hierarchical control of PV system to provide multiple-time scale voltage support for DC microgrid[J]. Proceedings of the Chinese Society for Electrical Engineering, 2025, 45(12): 4707-4717.)

[3] 王丹璐, 孙秋野, 苏涵光. 多微网系统端网协同分布式实时智能优化[J]. 控制与决策, 2024, 39(11): 3801-3809.
(Wang D L, Sun Q Y, Su H G. Collaborative distributed real-time intelligent optimization of multi-microgrid system[J]. Control and Decision, 2024, 39(11): 3801-3809.)

[4] 李鹏, 习伟, 蔡田田, 等. 数字电网的理念、架构与关键技术[J]. 中国电机工程学报, 2022, 42(14): 5002-5016.
(Li P, Xi W, Cai T T, et al. Concept, architecture and key technologies of digital power grids[J]. Proceedings of the Chinese Society for Electrical Engineering, 2022, 42(14): 5002-5016.)

[5] Hosseini S M, Carli R, Dotoli M. Robust optimal energy management of a residential microgrid under uncertainties on demand and renewable power generation[J]. IEEE Transactions on Automation Science and Engineering, 2021, 18(2): 618-637.

[6] Dey B, Misra S, Garcia Marquez F P. Microgrid system energy management with demand response program for clean and economical operation[J]. Applied Energy, 2023, 334: 120717.

[7] Nawaz A, Zhou M, Wu J, et al. A comprehensive review on energy management, demand response, and coordination schemes utilization in multi-microgrids network[J]. Applied Energy, 2022, 323: 119596.

[8] 王俐英, 林嘉琳, 宋美琴, 等. 考虑需求响应激励机制的园区综合能源系统博弈优化调度[J]. 控制与决策, 2023, 38(11): 3192-3200.
(Wang L Y, Lin J L, Song M Q, et al. Optimal dispatch of park integrated energy system considering demand response incentive mechanism[J]. Control and Decision, 2023, 38(11): 3192-3200.)

[9] Li D, Zhou Y X, Hu G Q, et al. Handling incomplete sensor measurements in fault detection and diagnosis for building HVAC systems[J]. IEEE Transactions on Automation Science and Engineering, 2020, 17(2): 833-846.

[10] 魏传锋, 洪春森, 何鹏, 等. 面向建筑节能热舒适控制的增强人工智能方法[J]. 控制与决策, 2025, 40(12): 3551-3564.
(Wei C F, Hong C S, He P, et al. Energy efficient and thermal comfort control in buildings *via* augmented

AI[J]. Control and Decision, 2025, 40(12): 3551-3564.)

[11] Zhao L, Zhang W. A geometric approach to virtual battery modeling of thermostatically controlled loads[C]. 2016 American Control Conference. Boston, Piscataway: IEEE, 2016: 1452-1457.

[12] Song M, Deng R N, Yan X Y, et al. Two-stage decision-dependent demand response driven by TCLs for distribution system resilience enhancement[J]. Applied Energy, 2024, 361: 122894.

[13] Borges C E, Kamara-Esteban O, Castillo-Calzadilla T, et al. Enhancing the missing data imputation of primary substation load demand records[J]. Sustainable Energy, Grids and Networks, 2020, 23: 100369.

[14] 徐焕增, 孔政敏, 王帅, 等. 基于动态线损及 FMRLS 算法的智能电表误差在线评估模型[J]. 中国电机工程学报, 2021, 41(24): 8349-8357.
(Xu H Z, Kong Z M, Wang S, et al. Online error evaluation model of smart meter based on dynamic line loss and FMRLS algorithm[J]. Proceedings of the CSEE, 2021, 41(24): 8349-8357.)

[15] 姚邹静, 赵春晖, 李元龙, 等. 面向工业软测量应用的定制化生成对抗数据填补模型[J]. 控制与决策, 2021, 36(12): 2929-2936.
(Yao Z J, Zhao C H, Li Y L, et al. Customized generative adversarial data imputation model for industrial soft sensing[J]. Control and Decision, 2021, 36(12): 2929-2936.)

[16] 李富盛, 陈伟松, 钱斌, 等. 面向低压配电网智能电表误差监测的 LightGBM-EM-EC 多变量缺失数据高效重建[J]. 中国电机工程学报, 2022, 42(S1): 95-105.
(Li F S, Chen W S, Qian B, et al. Efficient reconstruction of multivariate missing data for smart meter error monitoring in low voltage distribution network based on LightGBM-EM-EC[J]. Proceedings of the CSEE, 2022, 42(S1): 95-105.)

[17] Li Y Y, Song L D, Hu Y, et al. Load profile inpainting for missing load data restoration and baseline estimation[J]. IEEE Transactions on Smart Grid, 2024, 15(2): 2251-2260.

[18] Chen J D, Yuan J J, Chen W R, et al. Research on interpolation method for missing electricity consumption data[J]. Computers, Materials & Continua, 2024, 78(2): 2575-2591.

[19] Ren X Y, Mosavat-Jahromi H, Cai L, et al. Spatio-temporal spectrum load prediction using convolutional neural network and ResNet[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(2): 502-513.

[20] Weber M, Turowski M, Çakmak H K, et al. Data-driven copy-paste imputation for energy time series[J]. IEEE Transactions on Smart Grid, 2021, 12(6): 5409-5419.

[21] Lin Q, Ding L, Kong Z M, et al. Multi-time scale model predictive control-based demand side management for a microgrid[J]. IEEE Transactions on Smart Grid, 2025, 16(2): 1181-1193.

[22] Song M, Sun W, Wang Y F, et al. Hierarchical scheduling of aggregated TCL flexibility for transactive energy in power systems[J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2452-2463.

[23] Ma M F, Zhu A Q, Guo S T, et al. Intelligent network selection algorithm for multiservice users in 5G heterogeneous network system: Nash Q-learning method[J]. IEEE Internet of Things Journal, 2021, 8(15): 11877-11890.

[24] 张迪. 多源数据驱动的电力设备状态预估与电网弹性提升研究[D]. 长沙: 湖南大学, 2022.
(Zhang D. Research on Multi-source Data-driven Methods for Power Equipments Condition Prediction and Power Grid Resilience Enhancement [D]. Changsha: Hunan University, 2022.)

[25] Rhodes J D, Upshaw C R, Harris C B, et al. Experimental and data collection methods for a large-scale smart grid deployment: Methods and first results[J]. Energy, 2014, 65: 462-471.

[26] Song M, Gao C W, Yan H G, et al. Thermal battery modeling of inverter air conditioning for demand response[J]. IEEE Transactions on Smart Grid, 2018, 9(6): 5522-5534.

作者简介

林巧 (1996−), 女, 博士生, 主要研究方向为需求响应、柔性负荷建模与优化调度、微电网优化调度, E-mail: linqiao@whu.edu.cn;

丁李 (1979−), 男, 教授, 博士, 博士生导师, 主要研究方向为智能用电技术. E-mail: liding@whu.edu.cn;

余振威 (2000−), 男, 博士生, 主要研究方向为需求响应, 柔性负荷建模与优化调度, 微电网优化调度. E-mail: zhenweiyu@whu.edu.cn;

李昕 (1999−), 女, 博士生, 主要研究方向为需求响应、分布式优化、强化学习. E-mail: lixin9905@whu.edu.cn.