

基于 GCN-BiLSTM 的非侵入式负荷分解

徐健¹, 胡博^{1,2}, 邢作霞¹, 张鹏飞¹

(1. 沈阳工业大学电气工程学院, 沈阳 110870; 2. 国网辽宁省电力有限公司大连供电公司, 辽宁 大连 116000)

摘要: 近年来, 以深度学习为基础的负荷分解方法得到了广泛应用。但是, 目前的研究主要局限于传统欧氏空间序列的输入, 难以精确刻画电气设备工作过程中的时序相关性, 从而降低了对电气设备的解析精度。此外, 家电开关动作可能在时间序列数据中产生长距离影响, 但现有模型很少考虑负荷数据的长距离依赖问题。针对上述问题提出了一种基于图卷积网络(graph convolutional network, GCN)和双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)的非侵入式负荷分解模型。该方法基于图理论将总负荷序列转换为包含节点和边的图结构数据, 充分考虑节点之间的相关性特征, 并利用 GCN 进行特征提取。同时, 引入 BiLSTM 神经网络以处理长时间序列数据的局限性。通过算例分析验证了所提模型在分解精度和效果上显著优于传统方法。

关键词: 非侵入式负荷分解; 深度学习; 图卷积网络; BiLSTM

Non-Intrusive Load Disaggregation Based on GCN-BiLSTM

XU Jian¹, HU Bo^{1,2}, XING Zuoxia¹, ZHANG Pengfei¹

(1. Department of Electrical Engineering, Shenyang University of Technology, Shenyang 110870, China; 2. Dalian Power Supply Company, State Grid Liaoning Electric Power Co., Ltd., Dalian, Liaoning 116000, China)

Abstract: In recent years, load disaggregation methods based on deep learning have been widely applied. However, current researches mainly focus on inputs from traditional Euclidean space sequences, which struggle to accurately capture temporal correlations during the operation of electrical devices, thereby reducing the resolution accuracy of electrical equipment analysis. Furthermore, the switching actions of household appliances may have long-distance impacts in time series data, yet existing models often overlook the long-distance dependency issues in load data. To address these challenges, a non-intrusive load disaggregation model is proposed based on graph convolutional network (GCN) and bidirectional long short-term memory (BiLSTM). This method transforms the total load sequence into graph-structured data containing nodes and edges using graph theory, effectively considering inter-node correlation features and utilizing GCN for feature extraction. Additionally, BiLSTM neural networks are introduced to handle the limitations of long-term time series data. Case analysis demonstrates that the proposed model significantly outperforms traditional methods in terms of disaggregation accuracy and effectiveness.

Key words: non-intrusive load disaggregation; deep learning; graph convolutional network; BiLSTM

0 引言

根据是否需要在用户侧安装额外的传感器或仪表, 可将负荷分解分为侵入式负荷分解(intrusive load disaggregation, ILD)和非侵入式负荷分解(non-intrusive load disaggregation, NILD)。ILD 需要同样数量的传感器来采集各设备的基本参数来获

取用电信息。这种方法虽然精度较高, 但成本也高, 安装和维护复杂, 并可能影响用户隐私和安全。NILD 则只需在用户总回路处安装一个智能电表, 通过将采集到的总负荷信号输入到算法中来实现负荷分解, 获知用户各电气设备的负荷序列等信息, 这种方法的成本较低, 安装和维护较方便, 且对用户干扰较小, 具有较大的应用潜力和价值^[1-2]。

NILD 的难点是如何从用户的总负荷信号中提取出各个电气设备的负荷特征, 并根据这些特征来识别和分离各个电气设备的负荷。由于用户的总负

基金项目: 国家自然科学基金资助项目(U22B20115)。

Foundation item: Supported by the National Natural Science Foundation of China (U22B20115).

荷信号是由多个电气设备的负荷信号叠加而成的,而这些设备类型杂、模式多,且负荷特征随着时间、环境、用户习惯等因素而变化,因此用户的总负荷信号趋势极为复杂,没有规律,用传统的数学模型或统计方法进行负荷分解效果较差。为此,需要借助于机器学习等先进科技,通过大数据、深度学习等方法从用户的总负荷信号中自动学习和提取各个电气设备的负荷特征,最终实现负荷分解^[3]。

前馈神经网络(feedforward neural network, FFNN)是首个也是最简单的深度学习模型。模型由许多节点或单元组成,分层排列。关于 FENN 在 NILD 方面的应用, Jasiński 等^[4]提出了一种基于 FFNN 的负荷分解方法,旨在提取 3 种电气设备的功率消耗信号,研究证实了使用 FFNN 对电力负荷的分解进行建模的可能性。

卷积神经网络(convolutional neural network, CNN)在深度学习模型中备受关注,在多种任务中表现出色^[5-6]。文献[7]首次提出了基于 CNN 的序列到点的负荷分解方法,即模型分解输出的信号为序列的中点而非输出整段序列,这种形式对后续研究产生了较大影响。受上述序列到点模型的启发,文献[8]通过减少模型权重数量来降低模型规模与训练时占用的资源,形成了一种轻量级 NILD 算法。

循环神经网络(recurrent neural network, RNN)是一种专为序列数据设计的深度学习架构,其特点是能够将先前状态的信息用作当前状态的输入。RNN 有一定的局限性,即梯度消失和梯度爆炸的问题。为此,通常采用 RNN 的变体,即长短时记忆(long short term memory, LSTM)网络和门控循环单元(gated recurrent units, GRU)。在 NILD 领域,过去几年已经发表了许多使用 RNN 的方法。文献[9]分别将 3 种深度神经网络架构(长短期记忆神经网络、去噪自编码器以及一个回归网络)进行负荷分解,采用多指标评估这些算法在 5 个电气设备的真实总功率数据上的性能。结果显示 3 种神经网络的 F1 分数均优于组合优化算法和因子隐马尔可夫模型。文献[10]利用混合分解降低数据复杂度,将组合后的混合分量以双通道形式输入多分支 PCG-BiLSTM 模型,各分支通过 CNN 和 GRU 提取时空特征,并采用 BiLSTM 提取风速信号的双向波动规律,实现风速精准预测。文献[11]指出,与 LSTM 相比,GRU 网络更适合非侵入式负荷分解。

然而,上述建模方法均受到欧氏空间序列的限制,且各工况间的关联关系刻画不足,难以深入发掘其解析潜能,对非侵入式负荷进行分解时存在对不同电器负荷数据之间的关联性特征(指设备之间在时序行为、功率波动、运行规律等方面存在的隐性协同特征,如同步启停、模式重叠、趋势耦合等。这些特征通常以子序列形态分布在总负荷中,体现为特定的负荷模式组合)挖掘不充分的问题,从而限制了负荷分解效果的进一步提升,是非侵入式负荷分解中的难点之一。在实际应用中,上述建模方法缺乏对总负荷信息序列与各子负荷信息序列之间的映射关系进行有效构建。因此,传统模型由于缺乏结构建模能力、无法表达长序列依赖和非局部重复模式,难以深入挖掘这些关联性,导致分解性能受限。

随着图深度学习的提出,为多样化数据表达和特征提取提供了新的方法。这项技术专注于处理节点和边的非欧氏空间数据,强调挖掘数据的结构和关联特性。目前,这一技术已经在电网中得到了初步的运用,但在 NILD 方面的应用仍处于起步阶段。考虑到图神经网络可以解决传统负荷分解方法无法考虑不同电器运行状态下的关联性问题,本文提出了一种基于 GCN-BiLSTM 的 NILD 模型,通过引入图结构建模将滑动窗口子序列构造为节点,以相似性构造边,在图空间中充分表达负荷子序列之间的潜在组合关系,从而实现了不同电气负荷之间关联特征的有效挖掘与表达。与已有研究相比,本文创新点与贡献如下。

1)重新定义了总负荷序列的表达方式,以滑动窗口方式划分子序列,以每个窗口内功率数据作为节点特征,子序列之间潜在的相似度作为边的权重,实现了电力负荷序列的图结构数据构建。

2)首次将 GCN 与 BiLSTM 结合应用于 NILD,既考虑了负荷数据的图结构信息,又利用 BiLSTM 在时序上的优势捕捉时间序列的长期依赖关系。

1 非侵入式负荷分解框架流程

1.1 非侵入式负荷分解

非侵入式负荷分解的实现需要利用电气设备在运行过程中产生的用电状态信息,如有功功率、无功功率、电流波形、谐波特征等^[12]。这些信息被称为负荷特征。根据电气设备的运行条件,负荷特征

可分为暂态特征和稳态特征两种,对应的分解方法也可分为暂态分解法与稳态分解法。图1展示了常见的电气特征及其分类^[13]。




图1 电气特征

Fig. 1 Electrical characteristics

假设用户共有 M 个电气设备,则 t 时刻的分解结果如式(1)所示。

$$P(t) = \sum_{i=1}^M p_i(t) + p_{\text{noise}}(t) \quad (1)$$

式中: $P(t)$ 为 t 时刻智能电表获取的总功率; $p_i(t)$ 为 t 时刻用户设备 i 的功率; $p_{\text{noise}}(t)$ 为 t 时刻的噪声功率。

2 基于GCN-BiLSTM的NILD模型的设计

2.1 模型的输入

本模型的输入是一组总功率序列,用一维向量 $\mathbf{X}$ 表示,如式(2)所示。

$$\mathbf{X} = [x_1, x_2, \dots, x_t, \dots, x_T] \quad (2)$$

式中: x_t 为第 t 个时间点的总负荷的功率值; T 为序列长度。

在非侵入式负荷分解问题中,总负荷的每一时刻的功率值都与相近时刻的功率变化有关,因此,滑动窗口之间的时间间隔越短则特征关联性越强,滑动窗口之间的时间间隔越长则特征关联性越弱,这体现了不同电气设备的运行特性在总负荷上的叠加。导致传统建模方法难以对这种特性进行精确的数学描述。为此,本文重新定义输入序列的表达方式,构建了图结构输入数据,使用滑动窗口的数据信息作为节点特征的同时通过滑动窗口之间相似度来描述节点之间的权重,从而挖掘隐藏在总负荷数据中的各种关联性特征。因此,图结构数据构建方法如下。

1) 将总功率序列按预设的滑动窗口长度 L 划分为子序列,每个子序列表示一个时间窗口内的总功率变化情况,滑动窗口的移动步长为1,滑动处理方式如图2所示。具体如式(3)所示。

$$\mathbf{X} = [x_1, x_2, \dots, x_T] \rightarrow [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_i, \dots, \mathbf{X}_N] \quad (3)$$




图2 滑动处理示意图

Fig. 2 Sketch diagram of sliding processing

式中: $\mathbf{X}_i = [x_i, x_{i+1}, \dots, x_{i+L}]$ 为第 i 个子序列,其中 L 为窗口的长度; N 为子序列的数量。

2) 以子序列作为图的节点,每个节点的特征是该子序列的元素,每个节点之间的边的权重是该子序列之间的相似度,构建方式如式(4)—(7)所示。

$$\mathbf{G} = (\mathbf{V}, \mathbf{E}) \quad (4)$$

$$\mathbf{V} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N\} \quad (5)$$

$$\mathbf{E} = \{e_{ij}\} \quad (6)$$

$$e_{ij} = \text{sim}(\mathbf{X}_i, \mathbf{X}_j) = \frac{\mathbf{X}_i \cdot \mathbf{X}_j}{\|\mathbf{X}_i\| \|\mathbf{X}_j\|} \quad (7)$$

式中: $\mathbf{G}$ 为图; $\mathbf{V}$ 为节点集合; $\mathbf{X}_j$ 为第 j 个子序列; $\mathbf{E}$ 为边集合; e_{ij} 为第 i 个节点和第 j 个节点之间的边的权重; $\text{sim}(\cdot)$ 为两两子序列之间的余弦相似度函数。

2.2 模型的输出

模型的输出为所选设备(分负荷)的功率序列,该序列 $\mathbf{Y}$ 用一个二维矩阵表示如下。

$$\mathbf{Y} = \begin{bmatrix} [y_{1,1}, y_{1,2}, \dots, y_{1,T}], [y_{2,1}, y_{2,2}, \dots, y_{2,T}], \\ \dots, [y_{1,1}, y_{1,2}, \dots, y_{m,T}], \dots, [y_{M,1}, y_{M,2}, \dots, y_{M,T}] \end{bmatrix} \quad (8)$$

式中: $y_{m,t}$ 为第 t 个时间点的第 m 个电气设备的功率值; M 为设备的数量; T 为负荷序列的长度。

2.3 模型的结构

所提模型的结构如图3所示,本模型的结构主要由以下几个部分组成。

1) 输入层: 输入层负责将输入的图数据转换为张量形式,以便后续的处理。输入层的输入是一个图,其节点的特征是一个长度为 L 的一维向量,边的权重是一个标量。输入层的输出是一个形状为 $(N, L, 1)$ 的三维张量,其中 N 为节点的数量, L 为窗口的长度, 1 为特征的维度。

2) 图卷积层: 负责对输入的张量进行图卷积操作,以更新节点的特征。图卷积层的输入是一个




图3 模型的结构

Fig. 3 Structure of the model

形状为 \$(N, L, 1)\$ 的三维张量, 输出为形状为 \$(N, L, F)\$ 的三维张量, 其中 \$F\$ 为图卷积层的输出特征的维度。图卷积层的具体实现方式是基于空域的图卷积层, 如式(9)所示。

$$H_C = \sigma(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} XW) \quad (9)$$

式中: \$H_C\$ 为图卷积层的输出张量, 其中下标 \$C\$ 为输出张量中的特征维度的索引; \$\sigma(\cdot)\$ 为激活函数; \$\tilde{A}\$ 为自循环邻接矩阵, 以保留节点自身的信息; \$\tilde{D}\$ 为 \$\tilde{A}\$ 的度矩阵; \$X\$ 为图卷积层的输入张量; \$W\$ 为图卷积层的权重矩阵, 用于节点特征的转换。

3) 图池化层: 用于对图卷积层的输出张量进行图池化操作, 来减少网络中的节点数量和特征维度。该层的输入和输出的形状分别为 \$(N, L, F)\$ 和 \$(N/K, L, F/K)\$ 的三维张量, 其中 \$K\$ 为图池化层的池化比例。图池化层是基于拓扑排序来实现, 如式(10)–(11)所示。

$$S = \text{topk}(H_C, N/K, 0) \quad (10)$$

$$H_p = S \odot H_C \quad (11)$$

式中: \$S\$ 为从 \$H_C\$ 中按照节点的特征的最大值进行拓扑排序后选取的前 \$N/K\$ 个节点的特征, 形状为 \$(N/K, L, F)\$ 的三维张量; \$\text{topk}\$ 为按照指定维度进行拓扑排序并选取前 \$k\$ 个元素的函数; \$H_p\$ 为图池化层的输出张量; \$\odot\$ 为 Hadamard 乘积。

4) 图嵌入层: 对图池化层的输出张量进行图嵌入操作以提取节点的低维向量。其输入和输出分别是形状为 \$(N/K, L, F/K)\$ 的三维张量和形状为 \$(N/K, D)\$ 的二维张量, \$D\$ 为图嵌入层输出向量的维度。该层是基于自编码器来实现图嵌入层, 如式(12)–(13)所示。

$$H_E = \sigma(W_e X_p + b_e) \quad (12)$$

$$\hat{X} = \sigma(W_d Z + b_d) \quad (13)$$

式中: \$H_E\$ 为图嵌入层的输出张量; \$W_e\$ 为编码器的权重矩阵; \$b_e\$ 为编码器的偏置向量; \$W_d\$ 为解码器的权重矩阵; \$b_d\$ 为解码器的偏置向量, \$\hat{X}\$ 为图嵌入层的重构张量, 用于计算重构误差。

5) BiLSTM层: 作用是对图嵌入层的输出进行建模, 捕捉负荷信号的长期依赖和双向上下文特征。BiLSTM层的输入是一个形状为 \$(N/K, D)\$ 的二维张量, 其输出是一个形状为 \$(N/K, 2U)\$ 的二维张量, 其中 \$U\$ 为 BiLSTM 层的隐藏单元的数量。BiLSTM层的具体实现方式是通过在每个时间步骤 \$t\$, 同时处理正向和反向的序列信息, 并将两个方向的隐藏状态合并, 如式(14)–(16)所示。

$$\vec{h}_t = \text{LSTM}(\vec{H}_{E_t}, \vec{h}_{t-1}) \quad (14)$$

$$\overleftarrow{h}_t = \text{LSTM}(\overleftarrow{H}_{E_t}, \overleftarrow{h}_{t+1}) \quad (15)$$

$$h_t = [\vec{h}_t; \overleftarrow{h}_t] \quad (16)$$

式中: \$\vec{h}_t\$ 和 \$\overleftarrow{h}_t\$ 分别为 \$t\$ 时刻的正向和反向 LSTM 的隐藏状态; \$h_t\$ 为合并后的隐藏状态; \$\text{LSTM}(\cdot)\$ 为 LSTM 模型; \$H_{E_t}\$ 为图嵌入层的输出在时间 \$t\$ 的切片; \$[\vec{h}_t; \overleftarrow{h}_t]\$ 为将正向和反向的隐藏状态在特征维度上进行拼接。

6) 输出层: 将 BiLSTM 层的输出张量 \$h_t\$ 转换为最终电气设备功率值矩阵 \$Y\$, 如式(17)所示。

$$Y = \sigma(W_o h_t + b_o) \quad (17)$$

式中: \$Y\$ 为最终的输出矩阵, 形状为 \$(M, T)\$, 包含了所选设备在所选时间段的分解功率值; \$\sigma\$ 为激活函数; \$W_o\$ 为输出层的权重矩阵; \$h_t\$ 为 BiLSTM 层的输出张量; \$b_o\$ 为偏置向量。

3 模型训练与评估

3.1 数据预处理

数据集的划分是模型训练与评估的关键步骤,直接影响其泛化能力和性能。根据数据的特点和模型的需求,对数据集进行了以下的处理。

1) 数据清洗:为了保证数据的完整性和准确性,对数据集进行必要的处理,包括补全缺失值和异常值等。

2) 数据对齐:对数据集进行必要的对齐,包括对数据进行重采样,保证数据采样频率一致;将不同的采样时间对齐为最短的负荷类型的时间,保证一致性和可比性。

3) 数据划分:对数据集进行必要的分割,可以按7:2:1比例分为训练集、验证集和测试集。

3.2 损失函数

为了评估模型的输出与真实数据的差异,需要选择一个合适的损失函数,而均方误差(mean squared error, MSE, 其值记作 E_{MSE})是一种常用的性能评估指标,用于量化预测值与实际值之间的差异。在统计学中MSE通常被用来评估回归模型的拟合程度。而在机器学习中, E_{MSE} 则被用来评估模型的预测能力^[14]。 E_{MSE} 的数学表达式如式(18)所示。

$$E_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (18)$$

式中: n 为样本数量; y_i 为真实值; $\hat{y}_i$ 为预测值。本文损失函数选择 E_{MSE} 。

3.3 优化器

为了优化模型的参数,需要选择一个合适的优化器。常用的优化器有Adam与Nadam等^[15-17]。因此本文采用统一的BiLSTM神经网络模型对比分析Adam和Nadam优化器的性能差异。

3.4 评价指标

为了评估所提模型的性能,本文采用了以下两种评价指标:平均绝对误差(mean absolute error, MAE)、平均相对误差(mean relative error, MRE)。

1) MAE:指真实功率和分解后的功率之间的绝对误差的平均值,反映了负荷分解的整体误差水平^[18], MAE的值记作 E_{MAE} , 其值越小表示负荷分解的准确度越高。如式(19)所示。

$$E_{\text{MAE}} = \frac{1}{T} \sum_{t=1}^T |\hat{x}_{m,t} - x_{m,t}| \quad (19)$$

式中: $\hat{x}_{m,t}$ 和 $x_{m,t}$ 分别为第 m 个电气设备 t 时刻功率的预测值和真实值; T 为采样点数量。

2) MRE:用于衡量预测或估计值与实际值之间相对差异大小的指标^[19]。MRE的值记作 E_{MRE} , 其值越小则模型在预测与实际观测值之间更好的一致性,显示出模型的优越性能。

$$E_{\text{MRE}} = \frac{1}{T} \sum_{t=1}^T \left| \frac{\hat{x}_{m,t} - x_{m,t}}{x_{m,t}} \right| \quad (20)$$

需特别指出的是,家用电器停用时功率为0,为避免计算 E_{MRE} 时产生除0错误,当设备真实功率值为0时,将对应采样点的相对误差设为0。该处理方法可能不是计算相对误差的最佳方式,但按最终的分解曲线来看,设备不工作时不同模型均能较好地拟合该段时间的趋势波动,因此将电气设备不工作时间的相对误差置0,对于最终对比结果来说影响不大。

4 算例与结果

本文采用公开的REFIT数据集的住宅1作为实验对象,因为其数据较为完整和平衡,选取的洗衣烘干机、洗衣机、计算机、电视机和电加热器各1台,作为训练以及测试对象,原因如下。

1) 表1为常用的电气设备,具有显著研究意义;

2) 数据集中大部分家庭几乎都存在,数据丰富;

3) 涵盖多种模式的电气设备:多状态设备、高能耗设备以及低能耗设备等。

表1为算例所涉及电气设备的各功率采样点数据。

4.1 超参数配置

为了获得最佳的MAE性能,本文采用网格搜索方法,对以下几个重要超参数进行了调整。

窗口长度 L :指输入层将图数据转换为张量时每个节点特征向量的长度。测试了从5开始,步长为5的窗口长度,发现 $L=15$ 时模型性能最佳。

图卷积层的输出特征维度 F :指图卷积操作后每个节点特征向量的维度。测试了 $F=2^n$, ($n=4, 5, \dots, 8$), 最终选取 $F=64$ 。

图池化层的池化比例 K :指图池化操作后节点

表 1 电气设备的各功率采样点数据

Tab. 1 Power measurement date of electrical devices sample

points						
采样点	总负荷	洗衣机	电加热器	电视机	计算机	洗衣烘干机
1	1 046.9	0	1 017.8	0	29.1	0
2	255.9	0	227.2	0	28.7	0
3	27.8	0	1.0	0	26.8	0
4	27.9	0	1.0	0	26.9	0
5	1 046.9	0	1 017.8	0	29.1	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
97	1 045.1	0	982.6	30.3	32.2	0
98	1 039.8	0	981.4	30.6	27.8	0
99	609.0	0	551.0	30.3	27.7	0
100	59.3	0	1.0	29.8	28.5	0

数量和特征维度的缩减比例, 最终选取 $K=4$ 。

图嵌入层的输出向量维度 D : 指图嵌入操作后每个节点的低维向量的维度。尝试了 $D=2^n$, ($n=3, 5, \dots, 7$), 最终取 $D=32$ 。

BiLSTM 层数 l : 层数设定为 2。

BiLSTM 层的丢弃率 d : 每层网络之间的丢弃率, 取为 0.5。

模型的最优参数组合, 通过调整这些超参数最终提升模型的性能, 如表 2 所示。

表 2 模型参数表

Tab. 2 Model parameters table

参数名称	最优值
窗口长度 L	15
图卷积层的输出维度 F	64
图池化层的池化比例 K	4
图嵌入层的输出维度 D	32
BiLSTM 层的层数 l	2
BiLSTM 层的丢弃率 d	0.5

4.2 优化器对模型影响

在训练过程中, 分别应用 Adam 与 Nadam 这两种优化器, 并通过比较实验结果来评估它们的效能。具体地, 在测试集上, 利用 BiLSTM 神经网络模型, 分别运用 Adam 和 Nadam 优化器进行测试, 并记录下 MAE 的数值, 如表 3 所示。

通常情况下, MAE 的数值越小, 模型的性能越高。从结果来看, 使用 Nadam 优化器的模型在性能上略胜一筹。

表 3 NILD MAE 结果对比

Tab. 3 Comparison table of NILD MAE results

电气设备	Adam 优化器	Nadam 优化器
洗衣烘干机	1.125 5	0.964 1
洗衣机	1.951 3	1.809 0
电视机	0.975 7	0.562 2
计算机	0.846 2	0.481 7

4.3 实验结果

本文以 REFIT 数据集为算例展示了以滑动窗口划分子序列的具体实例, 并可视化了该节点特征的权重。如图 4 所示, 本文通过滑动窗口机制将总负荷序列划分为多个子序列节点, 并引入余弦相似度函数构建节点间边的权重, 形成图结构输入。在此基础上, 利用 GCN 对节点间结构信息进行聚合与编码, 从而有效捕捉子序列之间的潜在关联性特征。相比传统仅基于时间维度建模的方式, 本文方法能够增强模型对负荷序列内在结构与动态变化的感知能力, 从而提升了分解的准确性和稳定性。




图 4 以滑动窗口划分子序列

Fig. 4 Dividing subsequences with sliding windows

本节还展示了所提模型的实验结果, 并与其他几种方法进行了比较和评估。方法包括: 1) 基于 BiLSTM 的负荷分解方法; 2) 基于 GRU 的负荷分解方法。使用上述方法对所选设备的功率序列进行了负荷分解, 比较本模型与其他模型的表现, 展示了模型局部分解效果, 具体如图 5—9 所示。

图 5 为不同模型下的洗衣烘干机负荷分解效果对比图, 图 5 中显示 3 种分解模型分解的功率均有




图5 洗衣烘干机分解对比图

Fig. 5 Comparison diagram of disassembly of washing and drying machines

一定滞后性,但整体来看,所提出的模型在趋势拟合效果方面更好,峰值处相较于另外两种模型更大。




图6 计算机分解效果对比图

Fig. 6 Comparison diagram of computer decomposition effects

图6展示了计算机在不同模型下的分解效果,从图6可以看出模型在功率波动峰值处的分解效果略差,但趋势拟合度方面仍优于另外两种方法,且分解后的功率时间滞后现象好于洗衣烘干机。

图7则展示了电视机在不同模型下的分解效果,该模型在峰、谷处的拟合效果较好,趋势基本与真实负荷一致,能较好反应电气设备的工作模式。

图8为洗衣机的分解效果,其在一段时间内连续工作,且工作状态多,负荷波动较大。可以看出,模型BiLSTM与GRU分解效果一般,对于峰值与低谷段负荷往往不能很好地拟合,且有较明显




图7 电视机分解效果对比图

Fig. 7 Comparison of TV decomposition effects




图8 洗衣机分解效果对比图

Fig. 8 Comparison diagram of disassembly effects of washing machine

的滞后性,效果相较于本文模型略差,所提模型更优。图9则展示了不同模型下电加热器的负荷分解效果。

3个模型在该设备的分解性能差异较为明显,首先对于峰值部分的分解结果,所提模型与真实值的差值较小,趋势与真实功率波动相比,较为吻合。而另外两种模型不论在差值方面还是在拟合趋势方面均表现较差,而在谷值方面,BiLSTM模型则出现较大误差,有预测出负值的情况发生,而GRU也有小部分类似情况。

图10展示了部分总负荷功率曲线与分解出的电气设备负荷功率曲线的对比图。可以看出,本文方法不仅成功识别了电器间复杂的运行模式与交叠关系,还通过图结构建模实现了对总负荷中不同电




图9 不同模型下电加热器分解效果对比图

Fig. 9 Comparison of decomposition effects of electric heaters under different models

器负荷成分的高精度还原。在图 10 中, 多个分解曲线叠加后, 与总负荷曲线整体轮廓基本一致, 这表明本文模型在还原电器总功率构成方面具有良好的整体准确性。各设备负荷曲线在峰值出现时段与总负荷的波峰位置匹配较好, 尤其是洗衣烘干机与电加热器在高峰时段的功率响应, 体现了本文模型对峰值负荷的准确识别能力。对于电视机、计算机等低功率设备, 其分解曲线平稳, 能较好跟踪其工作/待机状态的切换, 反映了本文模型对微弱负荷变化的感知能力。其次, 各电器分解曲线之间相互独立、无过多重叠现象, 说明本文模型成功地从总负荷中分解出不同电器的独立运行特征。此外, 各设备功率变化点与总负荷变化点时间匹配较好, 滞后较小, 反映 BiLSTM 结构在时序依赖建模上的优势。可见, 本文提出的基于 GCN-BiLSTM 模型在结构信息建模与时序特征提取方面可以协同增

强, 显著提升了负荷分解的细节精度。

图 11 显示了模型在训练过程中的损失变化曲线, 可以看出训练、验证和测试的 MSE 值从相似的值开始, 不断下降并直至稳定。综上可知, 本文模型可以较好地分解所选设备的功率序列, 与真实序列的波形和峰值较为一致, 而其他模型则有一定的偏差和延迟。如表 4 显示, 该模型在所选电气设备的负荷分解任务中 MAE 值和 MRE 值优于其他模型, 说明该模型在负荷分解上具有较高的准确率。

从表 4 可以看出, 除电加热器外, 本模型对于其他电气设备的分解 MAE 值、MRE 值均处于较低水平, 且均小于另外两种模型。相对来说, 模型对于电加热器等高功率电气设备的分解效果较差。此外, 就 MRE 指标而言, 洗衣烘干机的 MRE 指标水平最低, 但这并不代表模型对于洗衣烘干机的分解性能最好, 而是因为洗衣烘干机停机时间占比高, MRE 指标无法精准反应模型对于该机器的分解效果。

总体来看, 本文提出的模型在评价指标上优于其他的方法, 具有较好的负荷分解性能。在非侵入式负荷分解问题中, 总负荷是多种电器负荷的叠加结果, 而不同电器之间往往存在协同运行的时段和组合模式。通过构建滑动窗口并基于相似度将负荷序列转化为图结构, 本文模型得以在图层面捕捉数据子序列之间的潜在关联性。这种子序列的相似性实质上反映了电器组合使用的模式重叠, 因此在 GCN 的学习过程中, 模型能够自动学习到不同电器之间的负荷特征交互关系, 从而实现更精细、更准确的电器负荷数据分解。




图 10 总负荷功率曲线与分解出的电气设备负荷功率曲线

Fig. 10 Total load power curve and decomposed electrical equipment load power curves




图 11 LOSS 曲线

Fig. 11 LOSS curves

表 4 家电设备负荷分解指标对比表

Tab. 4 Comparison table of load disaggregation indicators for household appliances

电气设备	模型	MAE 值	MRE 值
洗衣烘干机	本文模型	0.201 7	0.000 164 8
	BiLSTM	0.964 1	0.000 160 0
	GRU	0.982 4	0.000 128 0
洗衣机	本文模型	1.100 2	0.053 282 1
	BiLSTM	1.809 0	0.090 518 1
	GRU	1.532 8	0.077 749 9
计算机	本文模型	0.377 3	0.035 868 5
	BiLSTM	0.481 7	0.036 279 1
	GRU	0.559 9	0.060 897 8
电视机	本文模型	0.481 0	0.034 544 5
	BiLSTM	0.562 2	0.045 447 1
	GRU	0.567 9	0.051 271 0
电加热器	本文模型	14.625 0	3.205 446 4
	BiLSTM	21.596 2	10.793 010 5
	GRU	18.810 5	7.481 132 3

5 结论

在建设电力市场和新型电力系统的背景下,提升非侵入式负荷分解的精度是助力电力系统智能化、参与电网调度的必要手段。针对传统方法对非侵入式负荷进行分解时,存在对不同电器负荷数据之间的关联性特征挖掘不充分从而限制负荷分解效果进一步提升的问题。本文提出了一种基于 GCN-BiLSTM 的非侵入式负荷分解方法,首次将负荷序列通过滑动窗口机制重构为多个子序列,并以子序列为节点构建图结构数据。通过计算节点间的余弦相似度建立边的权重,形成具有结构语义的“总负

荷-图-子负荷”映射关系。利用图卷积网络在图结构中完成对节点特征的聚合与传递,并对“子序列之间的模式共性”进行编码,实现了对总负荷与子负荷间隐式组合模式的结构化建模,从而构建了总负荷与子负荷的映射通道,为负荷分解提供了高质量的特征表示。然后,通过 BiLSTM 挖掘其长时序依赖,从结构维度与时序维度双重增强了对关联性特征的感知能力,进而全面提升模型的综合性能,有效提升通用家用电器的分解精度。通过理论分析和仿真验证得出以下结论。

1) 将总功率序列数据重构为图结构数据, GCN-BiLSTM 模型能够充分利用节点和边的特征,捕捉数据子序列之间的关联性。该方法在图层面进行特征提取,显著提升了数据内部关联关系的表达效果,有助于挖掘潜在特征,提高了负荷分解的精度。

2) GCN-BiLSTM 模型在 REFIT 数据集上的实验结果表明,该方法在负荷分解精度和整体性能均优于传统的 BiLSTM 和 GRU 模型,表现更好的 MAE 和 MRE 指标能够有效拟合功率波动并准确反映设备的工作模式,证明了将总负荷序列转换为图数据的优势,为 NILD 提供了一种新的有效途径。

本文所提 GCN-BiLSTM 方法尽管在非侵入式负荷分解中表现出色,但未考虑所有家用电器,设备种类有限。未来研究应扩展设备种类与数据集,增强相似设备的识别能力,以提升其在实际应用中的适用性和性能。

参考文献

[1] 刘航, 刘春阳, 赵浩然, 等. 基于深度学习的公共楼宇电-气负荷非侵入式分解[J]. 电网技术, 2023, 47(3): 1188 – 1197. LIU Hang, LIU Chunyang, ZHAO Haoran, et al. Non-intrusive disaggregation of electricity and gas load in public buildings based on deep learning [J]. Power System Technology, 2023, 47(3): 1188 – 1197.

[2] 徐利美, 赵金, 李裕民, 等. 考虑多变量建模的中期负荷预测模型[J]. 南方电网技术, 2024, 18(11): 79 – 87. XU Limei, ZHAO Jin, LI Yumin, et al. Medium-term load forecasting model considering multivariate modeling [J]. Southern Power System Technology, 2024, 18(11): 79 – 87.

[3] GEORGIOS-FOTIOS A, CHRISTOS T, STELIOS K, et al. NILM applications: literature review of learning approaches, recent developments and challenges [J]. Energy & Buildings, 2022(261): 111951.1 – 111951.10.

[4] JASINSKI T. Modelling the disaggregated demand for electricity at the level of residential buildings with the use of artificial neural networks (deep learning approach) [C]// the 4th Central

- European Symposium on Building Physics, September 14 – 16, 2019, Prague, Czech Republic. Prague: CESBP, 2019: 110 – 121.
- [5] 奚鑫泽, 邢超, 覃日升, 等. 基于深度卷积去噪网络的电能质量扰动识别方法[J]. 南方电网技术, 2022, 16(12): 118 – 125.
- XI Xinze, XING Chao, QIN Risheng, et al. Power quality disturbance identification method based on deep convolutional denoising network [J]. Southern Power System Technology, 2022, 16(12): 118 – 125.
- [6] 覃日升, 况华, 于辉, 等. 自适应VMD与新型K-M互卷积窗的非稳态谐波参数检测方法[J]. 南方电网技术, 2024, 18(8): 70 – 79.
- QIN Risheng, KUANG Hua, YU Hui, et al. Non-stationary harmonic parameter detection method based on adaptive VMD and novel K-M convolution window [J]. Southern Power System Technology, 2024, 18(8): 70 – 79.
- [7] YANG M, LI X, LIU Y. Sequence to point learning based on an attention neural network for nonintrusive load decomposition [J]. Electronics, 2021, 10(14): 1657 – 1670.
- [8] BARBER J, HERIBERTO C, ZHONG M, et al. Lightweight non-intrusive load monitoring employing pruned sequence-to-point learning [C]// the 7th ACM International Conference on Systems for Energy-Efficient Buildings, Cities, and Transportation, October 10 – 12, 2020, New York, USA. New York: ACM, 2020: 145 – 158.
- [9] 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): 150007.1 – 150007.11.
- [10] 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.
- [11] 汪繁荣, 向堃, 吴铁洲. 基于聚类特征及seq2seq深度CNN的家电负荷识别方法研究[J]. 电测与仪表, 2023, 60(10): 79 – 86.
- WANG Fanrong, XIANG Kun, WU Tiezhou. Research on household appliance load identification method based on clustering features and seq2seq depth CNN [J]. Electrical Measurement & Instrumentation, 2023, 60(10): 79 – 86.
- [12] 杨秀, 吴吉海, 孙改平, 等. 基于深度学习和迁移学习的公共楼宇非侵入式负荷分解[J]. 电网技术, 2022, 46(3): 1160 – 1169.
- YANG Xiu, WU Jihai, SUN Gaiping, et al. Non-intrusive load decomposition of public buildings based on deep learning and transfer learning [J]. Power System Technology, 2022, 46(3): 1160 – 1169.
- [13] 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.
- [14] 潘立群, 吴中华, 洪标. 基于核技巧改进的Informer模型的长序列时间序列预测方法[J]. 计算机科学, 2023, 50(S2): 678 – 683.
- PAN Liqun, WU Zhonghua, HONG Biao. Prediction method of long series time series based on improved informer model with kernel technique [J]. Computer Science, 2023, 50(S2): 678 – 683.
- [15] KINGMA P D, BA J. Adam: a method for stochastic optimization [C]// 2015 International Conference on Learning Representations, May 7 – 9, 2015, San Diego, CA, USA. San Diego: ICLR, 2015: 112 – 124.
- [16] GAVIRAGHI B, SCHINDELE A, ANNUNZIATO M, et al. On optimal sparse-control problems governed by jump-diffusion processes [J]. Applied Mathematics, 2016, 16(7): 1978 – 2004.
- [17] XU B, WANG N, CHEN T, et al. Empirical evaluation of rectified activations in convolutional network [J]. Computer Science, 2015(5): 853 – 864.
- [18] WILLMOTT C, MATSUURA K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance [J]. Climate Research, 2005(30): 79 – 82.
- [19] JADON A, PATIL A, JADON S. A comprehensive survey of regression based loss functions for time series forecasting [C]// 2024 International Conference on Data Management, Analytics & Innovation, December 20 – 22, 2024, Singapore, Singapore. Singapore: ICDMAI, 2024: 77 – 84.

收稿日期: 2024-12-18; 网络首发日期: 2025-06-09

作者简介:

徐健(1983), 男, 高级工程师, 博士研究生, 研究方向为虚拟电厂优化运行、新能源控制与并网技术, xujian@smail.sut.edu.cn;

胡博(1972), 男, 高级工程师(教授级), 博士, 研究方向为电力系统分析运行和电力系统智能技术, dianli-hubo@sina.com;

邢作霞(1976), 女, 通信作者, 教授, 博士, 研究方向为电力系统自动化、智能电网优化调度、新能源控制与并网技术, xingzuox@163.com。