Research on Non-Invasive State Recognition of Electrical Equipment Based on Deep Learning and Compressed Sensing*

ZHU Di*, LAI Yongzhan
(Foshan Power Supply Bureau, Guangdong Power Grid Limited Corporation, Foshan Guangdong 528000, China)

Abstract: In order to simplify the processing of non-invasive electrical equipment status signals, deep level state characteristics of electrical equipment are considered to achieve accurate recognition of equipment status. A non-invasive electrical equipment status recognition method based on deep learning and compressive sensing is studied. The collected non-invasive electrical equipment status signals are sparsely processed using compressive sensing technology to simplify the signal processing process, retain the key features of the original signal, and complete the reconstruction of the status signal. By optimizing the neural network through autoencoder, the deep learning based optimized neural network is fused with dictionary learning. Based on the reconstructed state signal, deep level feature extraction of non-invasive electrical equipment signals is achieved. Based on this feature, a KNN classifier is used to achieve non-invasive electrical equipment state recognition. Through experimental verification, the compressed sensing reconstructed device status signal used in this method can accurately express the operating characteristics of non-invasive electrical equipment. The equipment status recognition results are consistent with the actual results, and the monthly average maintenance time is reduced to within 40 minutes, the maintenance time reducing level is great.

Key words: deep learning; compression sensing; dictionary learning; autoencoder; non-invasive electrical equipment; state recognition
EEACC: 7220; 8140 **doi**: 10.3969/j.issn.1005-9490.2026.04.021

基于深度学习和压缩感知的非侵入式用电设备状态识别研究*

朱 迪*, 赖永湛
(广东电网有限责任公司佛山供电局, 广东 佛山 528000)

摘 要: 为实现非侵入式用电设备状态信号处理的简化, 考虑用电设备深层次状态特征, 实现设备状态的精确识别, 研究基于深度学习和压缩感知的非侵入式用电设备状态识别方法, 通过压缩感知技术对采集的非侵入式用电设备状态信号进行稀疏处理, 简化信号处理过程, 保留了原始信号的关键特征, 完成状态信号重构; 通过自编码器对神经网络进行优化, 将基于深度学习的优化神经网络与字典学习进行融合, 依据重构的状态信号, 实现非侵入式用电设备信号的深层次特征提取, 依据该特征, 采用 KNN 分类器, 实现非侵入式用电设备状态识别。通过实验验证, 该方法采用的压缩感知重构出的设备状态信号, 能够准确地表达非侵入式用电设备的运行特征, 设备状态识别结果同实际结果一致, 且将月平均检修时间减少至 40 min 之内, 极大缩短了检修时间。

关键词: 深度学习; 压缩感知; 字典学习; 自编码器; 非侵入式用电设备; 状态识别
中图分类号: TM74 **文献标识码**: A **文章编号**: 1005-9490(2026)04-0850-06

非侵入式用电设备作为现时代一种较为先进的技术, 能够实现优化能源管理, 提高能源利用效率, 在电力系统中具有重要作用[1]。实现非侵入式用电设备状态识别能够从供电侧和用电侧两方面共同实现优化, 能够对用户侧可靠用电和供电侧安全供电同时进行保障[2], 故对其进行状态识别具有重要意义。

杨秀等[3]设计了一种非侵入式用电设备状态识别方法, 该方法的基本思想结合了高斯混合模型聚类算法和深度神经网络, 通过基于高斯混合模型聚类算法的软分类对同一设备运行状态不一致的问题进行处理, 实现用电设备运行状态的分类, 生成用电设备运行特征库, 通过优化的卷积神经网络实现非侵入式用电设备状态识别。但该方法中采集的非侵入式用电设备数据可能存在噪声、异常值或缺失值, 影响状态识别的性能。赵成等[4]设计了一种非

项目来源: 中国南方电网有限责任公司科技项目(GDKJXM20230486)
收稿日期: 2024-08-07 **修改日期**: 2024-10-08

侵入式用电设备状态识别方法,该方法通过先验知识和统计学习模型实现,通过对多种非侵入式用电设备进行细致区分研究,依据设备间的关联算法实现特征的区分,通过用电设备的反馈信息实现用电设备状态分类的模型训练。以此实现非侵入式用电设备状态识别。但该方法中若反馈信息不准确或存在偏差,可能会导致状态识别不准确。Luan 等[5]提出一种无监督识别的非侵入式用电设备状态识别方法,通过模拟用电设备正常运行状态和异常运行状态下的情况,通过信号变换、多重滤波和状态转移去除等预处理,并依据分段线性表示过程,得到非侵入式用电设备特征相关的信号子序列,通过深度学习实现非侵入式用电设备状态识别。但该方法涉及复杂的预处理和深度学习模型的计算,可能会导致状态识别实时性能不佳。Xu 等[6]提出了一种基于快速检测融合网络的非侵入式用电设备状态识别方法,通过在图像融合和目标检测中共享特征提取网络,实现计算复杂度的降低,依据该网络,能够实现特征提取,并实现非侵入式用电设备状态识别。但该方法中的共享特征提取网络可能影响到模型的状态识别性能。

压缩感知技术是一种简化信号处理过程的信号处理技术,能够提高信号重构质量,为非侵入式用电设备特征提取提供良好依据[7]。深度学习能够进行深层次非侵入式用电设备特征提取[8],是实现效果较好的非侵入式用电设备状态识别的前提,因此提出一种基于深度学习和压缩感知的非侵入式用电设备状态识别方法,通过实验验证,该方法能够实现一种较为精准的非侵入式用电设备状态识别,为电力管理系统提供了极大便利。

1　非侵入式用电设备状态识别

1.1　基于压缩感知的状态信号重构

对于采集的非侵入式用电设备状态信号 $m\times1$ 型矩阵 $\boldsymbol{a}$,在压缩感知理论体系中的稀疏域中稀疏表示为:

$$\boldsymbol{a}=\boldsymbol{\varphi\alpha} \tag{1}$$

式中:分别用 $n\times1$ 型矩阵 $\boldsymbol{\alpha}$ 表示非侵入式用电设备状态信号 $\boldsymbol{a}$ 在稀疏域上的映射,$m\times n$ 型矩阵 $\boldsymbol{\varphi}$ 表示稀疏字典。当 $n\times1$ 型矩阵 $\boldsymbol{\alpha}$ 中存在 $C(C\ll m)$ 个非零值,称 $\boldsymbol{\alpha}$ 由 C 进行稀疏。

通过对非侵入式用电设备状态信号与 1 个稀疏基的无关观测矩阵相乘,可以将非侵入式用电设备状态信号 $\boldsymbol{a}$ 映射到低维观测空间中[9],表示为:

$$\boldsymbol{b}=\boldsymbol{\beta a}=\boldsymbol{\beta\varphi\alpha}=\boldsymbol{\chi\alpha} \tag{2}$$

式中:分别将观测信号矩阵、观测矩阵、原始信号矩阵、感知矩阵表示为 $\boldsymbol{b}$、$\boldsymbol{\beta}$、$\boldsymbol{a}$、$\boldsymbol{\chi}$。其中,4 种矩阵的形式分别为:$l\times1$、$l\times m$、$m\times1$、$n\times1$。

通过构建矩阵 $\boldsymbol{\alpha}$ 的最优化问题并求解,表达式为:

$$\min\|\boldsymbol{\alpha}\|_0,\quad \text{s.t. } \boldsymbol{b}=\boldsymbol{\chi\alpha} \tag{3}$$

非侵入式用电设备状态信号在进行重构过程受到观测矩阵 $\boldsymbol{\beta}$ 的限制性等距条件的影响,即若存在 1 个 $\eta_c\in(0,1)$ 使所有向量 $\boldsymbol{a}$,$\|\boldsymbol{a}\|_0<C$ 满足:

$$(1-\eta_c)\|\boldsymbol{a}\|_2^2\leqslant\|\boldsymbol{\beta a}\|_2^2\leqslant(1+\eta_c)\|\boldsymbol{a}\|_2^2 \tag{4}$$

则矩阵 $\boldsymbol{\beta}$ 满足 C 阶限制性等距条件。

在压缩感知理论中,主要过程为:非侵入式用电设备状态信号稀疏表示、观测矩阵的建立、非侵入式用电设备状态信号重构[10]。非侵入式用电设备信号的稀疏表示过程即稀疏字典 $\boldsymbol{\varphi}$ 的建立过程,原始信号能够通过变换实现与多数时间点上的信号相关转化,且转化后的元素数值表示为 0。稀疏度为信号中数值非零的元素数量,非侵入式用电设备信号中的一种特征对应系数字典中的一个原子,即信号稀疏变换域中的一个基。实现非侵入式用电设备信号系数变换之后,能够获得最终的观测信号,该过程通过另一个与稀疏基互不相关的提供给信号稀疏采样方式的观测矩阵 $\boldsymbol{\beta}$ 得到,依据观测信号 $\boldsymbol{b}$ 和测量矩阵能够对非侵入式用电设备信号的原始信号进行重构,该问题本质上是对方程组进行最优问题求解。

1.2　字典学习方法

非侵入式用电设备信号稀疏过程中,字典学习中的稀疏字典具有重要作用,是该过程中的重要特征子空间[11]。通过基于聚类和向量量化的方式实现稀疏字典的生成。

非侵入式用电设备状态信号稀疏字典生成的过程主要通过 K 均值法和奇异值分解方法相结合(K-means Singular Value Decomposition,K-SVD)实现,具体的步骤如下:

①对稀疏字典和系数编码进行初始化,设初始化字典 $\boldsymbol{\varphi}$ 从非侵入式用电设备状态信号 $\boldsymbol{a}$ 中选取 k 个存入字典中,其中每一列作为一个 D 维特征向量,通过欧几里得归一化操作对特征进行处理,能够得到 $\boldsymbol{\varphi}^{D\times K}$,将系数编码矩阵 $\boldsymbol{\varepsilon}$ 初始化为 0。

②稀疏编码,稀疏字典为固定状态,通过追踪算法实现稀疏样本集中的样本稀疏编码,依据正交匹配追踪算法得到最简洁的稀疏表示系数。

③字典 $\boldsymbol{\varphi}$ 的更新,设需要对字典的第 g 列进行更新,则目标函数表示为:

$$\| \boldsymbol{b}-\boldsymbol{\varphi\varepsilon} \|_F^2 = \left\| \boldsymbol{b} - \sum_{i=1}^{K} \boldsymbol{\varphi}_i \boldsymbol{\varepsilon}_T^i \right\|_F^2 = \left\| \boldsymbol{b} - \sum_{i \neq g} \boldsymbol{\varphi}_i \boldsymbol{\varepsilon}_T^i - \boldsymbol{\varphi}_g \boldsymbol{\varepsilon}_T^g \right\|_F^2 = \| \boldsymbol{P}_g - \boldsymbol{\varphi}_g \boldsymbol{\varepsilon}_T^g \|_F^2 \quad (5)$$

则构建的目标函数可以表示为：

$$\min_{\boldsymbol{\varphi}_g, \boldsymbol{\varepsilon}_T^g} \| \boldsymbol{P}_g - \boldsymbol{\varphi}_g \boldsymbol{\varepsilon}_T^g \|_F^2 \quad (6)$$

计算过程选择 $\boldsymbol{P}_g$ 的非零项参与计算，能够保证系数表示矩阵 $\boldsymbol{\varepsilon}_T^g$ 稀疏性的完整，将行向量 $\boldsymbol{\varepsilon}_T^g$ 非零项的位置索引集合表示为 $\boldsymbol{R}_g = \{j \mid 1 \leqslant j \leqslant n, \boldsymbol{\varepsilon}_T^g(j) \neq 0\}$，将 $\boldsymbol{P}_g$ 中对应的 $\boldsymbol{R}_g$ 下标表示为 $\boldsymbol{P}'_g$，则对 $\boldsymbol{P}'_g$ 进行更新并不会影响到系数表示矩阵的稀疏性[12]。通过对 $\boldsymbol{P}'_g$ 实现奇异值分解过程，表示为：

$$\boldsymbol{P}'_g = \boldsymbol{X} \sum \boldsymbol{Y}^{\mathrm{T}} \quad (7)$$

通过 $\boldsymbol{X}$ 的第一列对字典的第 g 列进行更新，在系数矩阵表示为：

$$\boldsymbol{\varepsilon}'^g_T = \sum (1,1) Y(\cdot,1)^{\mathrm{T}} \quad (8)$$

反复进行上述过程，直至将字典 $\boldsymbol{\varphi}$ 中所有原子和 $\boldsymbol{\varepsilon}$ 中所有非零项更新完毕，若迭代更新字典和稀疏表示矩阵满足收敛条件，即达到指定误差，则停止更新。

字典学习算法能够从非侵入式用电设备信号中获得稀疏字典及其稀疏表示系数矩阵，即特征集合。在字典中包含了非侵入式用电设备信号的本质特征，故其中的正常信号可以通过字典中的原子较为简洁地线性表示，而非侵入式用电设备异常信号不能通过字典中的原子进行线性表示，且表示较为繁琐[13]。二者之间的较大差异性为深度学习的分类检测提供了便利。

1.3 基于神经网络的非侵入式用电设备状态特征提取

深度学习的本质内容是神经网络，以三层神经网络为例，结构如图 1 所示。

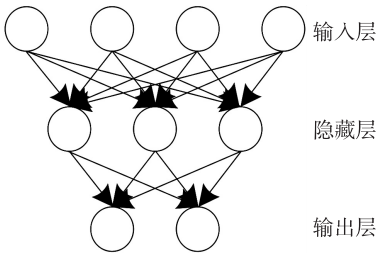

图 1 神经网络结构图

如图 1 所示，神经网络结构一般由输入层、隐藏层、输出层组成[14]，通过该结构能够实现非侵入式用电设备信号状态的分类和检测。

设输入到神经网络中重构的非侵入式用电设备状态信号为 $\boldsymbol{x} = [x_1, x_2, x_3]^{\mathrm{T}}$，则神经网络隐藏层信号表示为：

$$\boldsymbol{q}_1 = u(\boldsymbol{\omega}_1 \boldsymbol{x} + \boldsymbol{\delta}_1) \quad (9)$$

式中：将神经网络第一层的权重矩阵表示为 $\boldsymbol{\omega}_1$，$\boldsymbol{\omega}_\mu = [V]$ 作为其中的任意一行，表示第 μ 个隐藏信号对应的各个输入的权重参数，能够实现控制各个信号的重要程度，其中 $0<\mu<U$，分别将权重矩阵的行数、输入层和隐藏层之间的偏置表示为 U、$\boldsymbol{\delta}_1$。非线性激活函数 $u(\ )$ 实现神经网络表达能力的增强，通过将输入信号与权重的乘积传输到下一神经元，能够得到隐藏层的各节点信号值和输入信号的加权。

1.4 基于自动编码器的神经网络优化

自动编码器包括编码和解码两部分[15]，图 2 为单层自动编码器结构。

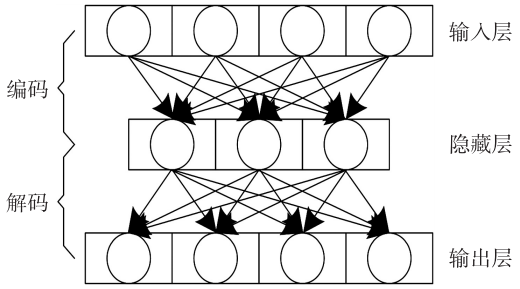

图 2 单层自动编码器结构

若输入向量和偏置已知，则：

$$\boldsymbol{q} = \boldsymbol{\omega x} + \boldsymbol{\delta} \quad (10)$$

式中：分别将权重矩阵和偏置表示为 $\boldsymbol{\omega}$、$\boldsymbol{\delta}$。

通过非线性激活函数表示隐藏层内的信号输出，则式(10)可以表示为：

$$\boldsymbol{q} = u_1(\boldsymbol{\omega x} + \boldsymbol{\delta}) \quad (11)$$

式中：将激活函数表示为 $u_1(\ )$，主要包括 Sigmoid 函数、tanh 函数等，在获得隐藏层信号之后，解码过程表示为：

$$\boldsymbol{x} = \boldsymbol{\omega}' u_1(\boldsymbol{\omega x} + \boldsymbol{\delta}) \quad (12)$$

权重矩阵在编码解码过程中具有重要作用，在整个训练学习过程中，可以优化表示为：

$$\min_{\boldsymbol{\omega}, \boldsymbol{\omega}'} \| \boldsymbol{x} - u_2(\boldsymbol{\omega}' u_1(\boldsymbol{\omega x} + \boldsymbol{\delta})) \|_2^2 \quad (13)$$

式中：分别将训练样本矩阵、训练样本数量表示为 $\boldsymbol{X}$、x_n，$\boldsymbol{x} \in \boldsymbol{X} = [x_1, x_2, \cdots, x_n]$，$u_2(\boldsymbol{\omega}' u_1(\boldsymbol{\omega x} + \boldsymbol{\delta}))$ 表示映射回到数据空间的非侵入式用电设备信号，通过梯度下降法求解该二者之间的最小距离。

图 3 所示为含有多隐藏层的自动编码器。

对于图 3 所示自动编码器结构，进行多层编码后再进行解码过程，优化方程表示为：

$$\min_{\boldsymbol{\omega}_1, \cdots, \boldsymbol{\omega}_L, \boldsymbol{\omega}'_1, \cdots, \boldsymbol{\omega}'_L} \| \boldsymbol{x} - u_2(\boldsymbol{\omega}'_L u_1(\boldsymbol{\omega}_L, x, \boldsymbol{\delta}_L) + \boldsymbol{\delta}'_1) \|_2^2 \quad (14)$$

通过三层深度字典学习方法[16-17]，将融合的非

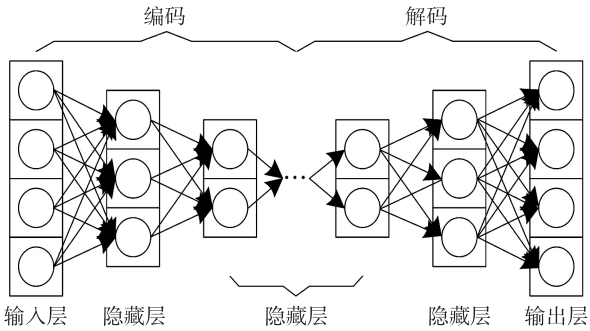

图 3　多隐藏层自动编码器结构

侵入式用电设备信号作为深度字典学习模型的输入,将上层输出作为下层的输入,在最后一层进行稀疏特征的学习。

在第一层中,对字典矩阵 $\boldsymbol{\varphi}_1$ 和编码矩阵 $\boldsymbol{S}_1$ 进行训练以表示数据 $\boldsymbol{X}$:

$$\boldsymbol{X}=\boldsymbol{\varphi}_1\boldsymbol{S}_1 \tag{15}$$

将第一层中学习的编码矩阵作为下层字典学习的下一阶段,表示为:

$$\boldsymbol{S}_1=\boldsymbol{\varphi}_2\boldsymbol{S}_2 \tag{16}$$

$$\boldsymbol{X}=\boldsymbol{\varphi}_1\boldsymbol{S}_1=\boldsymbol{\varphi}_1\boldsymbol{\varphi}_2\boldsymbol{S}_2 \tag{17}$$

式中:分别将第一层字典学习到的编码矩阵、对应的字典矩阵和编码矩阵表示为 $\boldsymbol{S}_1$、$\boldsymbol{\varphi}_2$、$\boldsymbol{S}_2$。则第三层表示为:

$$\boldsymbol{S}_2=\boldsymbol{\varphi}_3\boldsymbol{S}_3 \tag{18}$$

$$\boldsymbol{X}=\boldsymbol{\varphi}_1\boldsymbol{S}_1=\boldsymbol{\varphi}_1\boldsymbol{\varphi}_2\boldsymbol{S}_2=\boldsymbol{\varphi}_1\boldsymbol{\varphi}_2\boldsymbol{\varphi}_3\boldsymbol{S}_3 \tag{19}$$

在第三层中通过稀疏正则化项对非侵入式用电设备信号中的冗余特征进行消除,通过第三层得到的稀疏特征作为分类器输入。

1.5　基于 KNN 分类器的非侵入式用电设备状态识别

通过上述过程能够得到字典矩阵最优解 $\boldsymbol{\varphi}_{\text{best}}$ 和稀疏编码矩阵最优解 $\boldsymbol{S}_{\text{best}}$,分类器基于 KNN 思想,输入的非侵入式用电设备信号样本对应的编码向量表示为:

$$\boldsymbol{s}_{\text{best}}=\min_{\boldsymbol{s}}\|\boldsymbol{x}-\boldsymbol{\varphi}_{\text{best}}\boldsymbol{s}\|_2^2 \tag{20}$$

$$\boldsymbol{s}_{\text{best}}=\min_{\boldsymbol{s}}\|\boldsymbol{x}-\boldsymbol{\varphi}_{\text{best}}\boldsymbol{s}\|_2^2+\zeta\|\boldsymbol{s}\|_1 \tag{21}$$

式中:$\|\ \|_2^2$ 表示范数,ζ 表示正则化参数。

对非侵入式用电设备信号样本的状态标签进行求解,表示为:

$$\boldsymbol{w}=1-\underset{w\in\{0,1,\cdots,n\}}{\operatorname{argmin}}\left[(\boldsymbol{S}_{w_{\text{best}}}\boldsymbol{s}_{\text{best}})/(\|\boldsymbol{S}_{w_{\text{best}}}\|_2\|\boldsymbol{s}_{\text{best}}\|_2)\right] \tag{22}$$

式中:分别将稀疏编码矩阵最优解的子向量、非侵入式用电设备信号状态标签表示为 $\boldsymbol{S}_{w_{\text{best}}}$、$w$。将 argmin( ) 表示为在定义域 $\{0,1,\cdots,n\}$ 中取最小值的参数值。

2　实验

智能电表是目前常用的一种非侵入式用电设备,因此本文以某小区为例,对该小区内的智能电表进行状态识别,图 4 为该智能电表实物图。

图 4　智能电表实物图

通过本文方法主要能够实现的智能电表状态识别主要包括:

①正常状态:智能电表处于正常运行状态,电表读数准确,显示正常。

②电表显示异常:智能电表显示非正常读数,可能由电表内部组件故障或者线路松动造成。

③电表读数不准确:智能电表显示的读数异常,与实际不符,可能由内部计量模块故障或电表配置参数错误造成。

④通信故障:智能电表与电力公司之间的数据无法正常传输,可能由线路故障导致。

通过对实验小区内智能电表进行研究,能够实现智能电表状态识别,如图 5 所示。

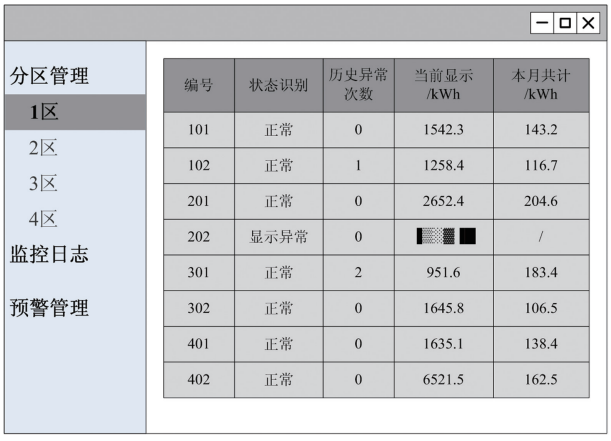

图 5　智能电表状态监控页面

由图 5 可知,本文提出的非侵入式用电设备状态识别方法,能够有效识别出实验小区内智能电表的状态,如正常状态、显示异常等情况,并能够提供历史异常情况,以供相关人员进行查看,考虑异常次数频繁可以进行更换,通过监控页面可以实现智能

电表的实时显示及当月统计,便于管理。由此验证,本文方法是一种有效的非侵入式用电设备状态识别方法,能够有效识别出设备的状态,为相关人员的管理过程提供了便利。

通过将本文使用的压缩感知技术方法与降采样方法对采集的非侵入式用电设备状态信号进行处理,并对效果进行对比,得到非侵入式用电设备状态信号最大值曲线,如图 6 所示。

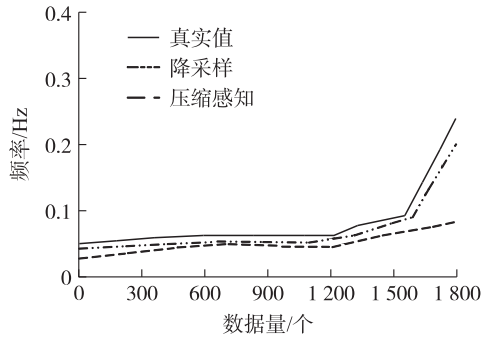

图 6 非侵入式用电设备状态信号最大值曲线

由图 6 可知,降采样方法与本文使用的压缩感知技术存在较大差距,通过降采样方法的处理,原始非侵入式用电设备状态信号中的高频部分被去除,因此得到的特征失效,无法代表原始信号中的特征,而通过本文压缩感知技术进行处理后,得到的特征与原始非侵入式用电设备状态信号基本吻合,因此证明了该方法能够准确地表达非侵入式用电设备的运行特征,为深度学习的深层次特征提取提供了良好依据。

从实验小区内随机抽取 15 个智能电表,通过本文方法进行状态识别,由专业检修人员进行智能电能表的检查,将本文方法得到的结果与专业人员检查的结果进行对比,以此对本文方法实现的非侵入式用电设备状态识别效果进行验证,得到的对比结果如表 1 所示。

由表 1 可知,通过本文方法实现的非侵入式用电设备状态识别结果与实际的相关检修人员进行检查的结果基本一致,且实际异常原因与通过本文方法实现识别的异常状态的相关故障原因情况吻合,证明了本文方法进行状态识别的有效性,验证了本文方法是一种识别较为准确的非入侵式用电设备状态识别的方法。

为进一步验证本文方法实现非入侵式用电设备状态识别的有效性,对该实验小区进行 12 个月内的平均检修时间情况统计,将本文方法与降采样方法进行对比,得到 12 个月内的平均检修时间统计情况,如图 7 所示。

表 1 状态识别结果对比情况

编号	户号	状态	实际状态	实际故障原因	识别是否正确
1	2#102	正常	正常	/	是
2	2#101	显示异常	异常	电表线路松动	是
3	4#101	正常	正常	/	是
4	1#402	正常	正常	/	是
5	3#102	读数不准确	异常	内部计量模块故障	是
6	2#301	正常	正常	/	是
7	4#502	正常	正常	/	是
8	1#602	正常	正常	/	是
9	3#502	正常	正常	/	是
10	2#501	正常	正常	/	是
11	4#401	正常	正常	/	是
12	3#402	通信故障	异常	电表线路断开	是
13	1#102	正常	正常	/	是
14	4#102	正常	正常	/	是
15	3#302	正常	正常	/	是

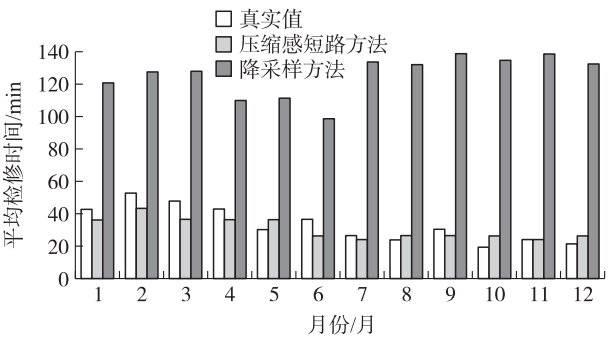

图 7 12 个月内平均检修时间统计情况

由图 7 可知,使用本文方法对非侵入式用电设备状态进行识别,与真实值较为接近,平均检修时间的差异很小,使用降采样方法与真实值差异较大,本文方法能够及时发现设备异常状态且提供了较为准确的故障原因,因此在检修时无需进行判断,极大缩短了检修时间,能够控制在 60 min 以内,证明了本文方法的有效性,能够为故障之后的检修过程提供良好依据,极大地缩短检修时间。

3 结论

非侵入式用电设备状态识别技术能够实时监控各电器运行状态,不仅能够保证用户侧稳定可靠的用电,还能保证供电侧的安全供电,提高收益。通过本文方法,能够实现一种较为准确可靠的非侵入式用电设备状态识别,为供电公司相关管理人员提供

一种良好的管理模式,为检修过程提供了一种良好的判断依据,极大缩短了检修时间。

参考文献:

[1] 薛博水,陈杰,赵四洪,等. 基于谐波特征和 BSA 优化的非侵入式负荷识别算法研究[J]. 昆明理工大学学报(自然科学版),2022,47(5):113-120,152.

[2] 王传君,缪巍巍,曾锃,等. 基于复合特征的非侵入式电力负荷识别方法研究[J]. 电子器件,2023,46(1):218-222.

[3] 杨秀,李安,孙改平,等. 基于改进 GMM-CNN-GRU 混合的非侵入式负荷监测方法研究[J]. 电力系统保护与控制,2022,50(14):65-75.

[4] 赵成,宋彦辛,周赣,等. 基于先验统计模型的非侵入负荷辨识算法[J]. 电力工程技术,2024,43(1):165-173,211.

[5] Luan W P,Ma C W,Liu B,et al. Unsupervised Identification and Status Assessment for Electric Bicycle Charging Load[J]. Electric Power Systems Research,2022,210:108130.

[6] Xu X,Liu G,Bavirisetti D P,et al. Fast Detection Fusion Network(FDFnet):An End to End Object Detection Framework Based on Heterogeneous Image Fusion for Power Facility Inspection[J]. IEEE Transactions on Power Delivery,2022,37(6):4496-4505.

[7] 郑娟毅,慕金玉,邢丽荣,等. 基于深度压缩感知的波束空间信道估计算法[J]. 华南理工大学学报(自然科学版),2022,50(12):101-108.

[8] 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.

[9] 魏志超,杨春玲. 时域注意力特征对齐的视频压缩感知重构网络[J]. 电子学报,2022,50(11):2584-2592.

[10] 李彤,肖锋,张文娟,等. 基于深度学习的压缩感知图像重构算法综述[J]. 微电子学与计算机,2022,39(12):1-12.

[11] 张宇博,郝治国,林泽暄,等. 基于深度字典学习的输电线路故障分类方法[J]. 电力自动化设备,2022,42(11):159-166.

[12] 迟钰坤,焦之明,纪洪伟,等. 基于图像相似度与深度学习的变电站刀闸状态识别算法的对比研究[J]. 电力大数据,2023,26(4):1-10.

[13] 秦利娟,冯乃勤. 基于深度学习反向传播的稀疏数据特征提取[J]. 计算机仿真,2022,39(5):333-336,469.

[14] 刘诗仪,刘改,吴峰. 基于深度神经网络的字典学习[J]. 计算机系统应用,2022,31(8):292-297.

[15] 孙小双,王宇. 基于自动编码器的内部威胁检测技术[J]. 计算机工程与设计,2022,43(10):2725-2730.

[16] 赵瑜,方亮,周云,等. 基于深度学习理论和压缩感知技术的车辆识别与跟踪研究[J]. 地震工程与工程振动,2021,41(5):206-214.

[17] 杨春玲,梁梓文. 特征域近端高维梯度下降图像压缩感知重构网络[J]. 华南理工大学学报(自然科学版),2024,52(3):119-130.

朱　迪(1988—),女,汉族,湖北广水人,本科,高级工程师,主要研究方向:市场营销,zhudi_1988@163.com。