

考虑辨识结果连续性的 Type-III 型工商业负荷辨识方法

段 晶¹, 李 勇¹, 张振宇¹, 李巍巍², 蒋 林³, 李 磊⁴

(1. 湖南大学电气与信息工程学院, 湖南省长沙市 410082; 2. 长沙新奥长燃能源发展有限公司, 湖南省长沙市 410082; 3. 利物浦大学电气工程与电子系, 利物浦 L69 3BX, 英国; 4. 长沙新奥湘江新能源发展有限公司, 湖南省长沙市 410082)

摘要: 非侵入式负荷监测技术可以引导用户合理安排用电时间, 从而减少电量消耗。其中, 由于状态的连续可变性, 连续变化(Type-III)型负荷的辨识一直是非侵入式负荷监测中难以解决的问题之一。针对 Type-III 型负荷的辨识难题, 提出了基于深度卷积神经网络(CNN)和隐马尔可夫模型(HMM)的非侵入式负荷辨识算法。首先, 根据互信息理论进行负荷特征选择; 然后, 利用残差神经网络作为深度 CNN 的基本架构, 提取负荷多维特征并实现 Type-III 型负荷的初辨识; 最后, 为了解决 CNN 辨识结果中存在的状态断点问题, 采用 HMM 完成负荷辨识结果的连续性优化。在复杂的工商业运行环境中, 对具有代表性的 Type-III 型负荷数据进行了算法训练和验证, 结果表明所提算法能有效辨识 Type-III 型工商业负荷的运行状态。

关键词: 非侵入式负荷辨识; 互信息; 残差神经网络; 隐马尔可夫模型

0 引言

为提高电力用户终端负荷的能源利用效率、减少电量消耗、促进用户参与需求侧管理或实现远程优化控制, 电力负荷的在线监测必不可少^[1-2]。电力负荷的在线监测方法主要有侵入式负荷监测(ILM)和非侵入式负荷监测(NILM)两种。ILM 需要为每个监测设备配置一个或多个传感器, 虽然监测结果更为准确, 但成本高、配置复杂、维护困难。NILM 的概念最早由 Hart 于 1992 年提出^[3], 它只需在被监测系统的电力入口处安装一个电力信息采集装置, 再通过信号分析和处理实现负荷的分解与辨识, 虽然精度稍低, 但是硬件结构简单, 便于安装和维护, 更切合智能电网建设的实际需求^[4-5]。因此, 近年来 NILM 方法的研究备受国内外学者的关注。

负荷辨识是负荷监测的核心内容, 负荷辨识方法可分为三大类: 优化方法、监督学习方法和无监督学习方法。优化方法是负荷辨识最直接的方法, 将提取的负荷特征数据与模板库中的特征数据进行对比, 采用优化算法最小化误差, 找到匹配度最高的电

气设备状态组合, 包括动态时间弯曲(DTW)算法^[6]、遗传算法^[7]、粒子群优化算法^[8]等, 但优化方法进行负荷辨识普遍需要根据历史信息提前建立负荷特征模板库。监督学习方法需要已知电气设备的特定运行信息进行模型的初始训练, 且算法的性能很大程度上取决于模型学习的数据标签, 基本上是将负荷辨识问题转换为分类学习问题进行解决, 主要方法包括贝叶斯分类器^[9]、支持向量机(SVM)^[10]和人工神经网络(ANN)^[11-13]。无监督学习方法可以在没有任何先验信息的情况下运行, 相较于监督学习方法减少了训练步骤的干扰性, 主要算法包括隐马尔可夫模型(HMM)^[14]及其扩展, 如文献[15]中的因子隐马尔可夫模型(FHMM)和文献[16]中的隐式半马尔可夫模型(HSMM)均被应用到负荷辨识中。

不同类型的负荷具有不同的负荷特征, 按照其运行状态可大致分为 3 类^[17]。对于连续变化(Type-III)型的负荷, 由于其工作状态的功率值保持连续变化的特性, 导致其状态空间极其巨大。文献[18]指出, 对于常用的基于 HMM 的负荷辨识方法, 仅对 Type-I 型的开关负荷表现较好, 在面对状态更为复杂的其他类型负荷时效果将被极大的削弱。因此 Type-III 型负荷的辨识一直是 NILM 中研究的重点和难点之一。

为有效辨识 Type-III 型负荷, 满足负荷辨识算法对辨识准确率和算法鲁棒性的要求, 本文提出了

收稿日期: 2021-04-16; 修回日期: 2021-07-23。

上网日期: XXXX-XX-XX。

国家重点研发计划政府间国际科技创新合作重点专项资助项目(2018YFE0125300); 国家自然科学基金资助项目(52061130217); 湖湘高层次人才聚集工程资助项目(2019RS1016)。

一种基于深度卷积神经网络(CNN)和HMM的非侵入式负荷辨识算法。通过深度CNN提取负荷的多维特征,进行负荷的初次辨识,将连续变化的负荷状态辨识问题重构为二分类状态辨识;根据负荷状态的时间依赖性,利用HMM解决负荷的二分类状态再辨识,减少CNN辨识结果中出现的状态断点现象,提高辨识准确率。本文以工商业电力负荷为例,在具有代表性的Type-III型负荷数据上进行训练和测试,证明了本文算法的有效性,并且可达到97.9%的辨识准确率。

1 负荷数据处理与特征选择

附录A图A1展示了3种典型的负荷曲线,其中Type-III型负荷的状态连续可变性特点非常明显。工商业用电在总负荷中占有很大的比重,研究工商业用电特性,对电力系统安全经济运行和电力市场的发展有着重要的作用。对工商业电力负荷进行监测和辨识,可以帮助电力部门了解客户的用电行为,进而为不同的客户群制订相应的市场策略,使双方都受益。因此,本文使用Type-III型工商业负荷来验证非侵入式负荷辨识算法的性能。

1.1 数据处理

本文所用的数据集为实测电力数据。测量仪器为日置电能质量分析仪PQ3198,可完成无间隙的连续运算、事件检测、GPS时间同步等标准要求的测量,测量项目包括有功功率、无功功率、频率、电压、电流及其有效值、最值和高次谐波成分等多维负荷特征数据,并具备波形记录和存储功能。在电力入口处安装数据采集装备,采样频率为1 Hz,采样时长为7 d。为了验证辨识效果,在待辨识负荷处也安装采集设备以准确获取其运行状态,从而为辨识模型提供参考数据。

对于电力入口处采集的任一负荷特征数据,可用时间序列 $R = \{R_0, R_1, \dots, R_T\}$ 表示,其中 T 为负荷数据的时间长度。数据处理中可通过差分的方式来增强特征的表达能力,因此可以得到负荷的差值特征序列 $x = \{x_1, x_2, \dots, x_T\}$,其中任一元素 x_t 皆满足:

$$x_t = R_t - R_{t-1} \quad 1 \leq t \leq T \quad (1)$$

给定时间窗口长度 w ,并通过特征选择确定 n 种负荷特征,由此可生成CNN模型能学习的输入负荷数据 $\{H_1, H_2, \dots, H_L\}$,其中 L 为输入数据的总长度。

$$H_i = \{X_{i,1}, X_{i,2}, \dots, X_{i,n}\} \quad i = 1, 2, \dots, L \quad (2)$$

式中: $X_{i,j}$ 为第 j 种负荷特征的第 i 个窗口的差值时

间序列,如式(3)所示。

$$X_{i,j} = [x_{i,j} \ x_{i+1,j} \ \dots \ x_{i+w-1,j}]^T \quad (3)$$

式中: $i = 1, 2, \dots, T - w + 1, j = 1, 2, \dots, n$ 。

对于采集的待辨识负荷数据,以其电流有效值 $I_{i+w/2}$ 的大小为标准,生成设备的标签状态集 $\{y_1, y_2, \dots, y_L\}$,其中 y_i 为第 i 个时间窗口内的 $i + w/2$ 时刻点的负荷的运行状态, $i = 1, 2, \dots, L$ 。

$$y_i = \begin{cases} 1 & I_{i+w/2} > 1 \text{ A} \\ 0 & I_{i+w/2} \leq 1 \text{ A} \end{cases} \quad (4)$$

其中,将1 A作为状态标记的基准是根据待辨识负荷运行时的最小电流值所选择的。

1.2 特征选择

由电能质量分析仪采集的电力数据共包含3537种负荷特征,其中包括能反映待辨识负荷运行状态变化的相关特征和与待辨识负荷状态变化不相关的无关特征。除此之外,负荷特征中还包括一类冗余特征,即这类特征中所包含的信息可从其他特征中提取^[19]。冗余特征在负荷辨识模型学习中几乎不起作用,而无关特征反而会对模型学习造成干扰。因此,在进行模型训练之前要进行特征选择,去除无关特征和冗余特征,从而提高负荷辨识的准确率,并且特征选择可以在很大程度上降低维数,减少了模型的运算量。

时间窗口长度、特征维度与CNN的乘-加操作(multiply-accumulate operations, MACs)次数之间的关系如附录A图A2所示。随着特征数目的增加,神经网络的操作次数逐渐变得不可接受,另外,由于特征之间的组合状态爆炸增长,导致需要大量的数据才能对网络进行合适的训练。因此,为了降低网络运算复杂度、缩短模型训练时间,本文采用互信息算法进行特征选择。

在概率论和信息论中,2个随机变量的互信息是变量间相互依赖性的度量,互信息熵越大表明2个随机变量之间的相关性越强,反之互信息熵越小,2个随机变量之间的相关性就越弱^[20]。互信息值 $I(x, y)$ 的计算如下:

$$I(x, y) = \iint p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy \quad (5)$$

式中: $p(x)$ 和 $p(y)$ 分别为随机变量 x 和 y 的边缘概率密度函数; $p(x, y)$ 为 x 和 y 的联合概率密度函数。

本文采用互信息进行特征选择的具体步骤为:根据式(5)计算每个负荷特征与待辨识负荷运行状态之间的互信息值;按照互信息的大小对所有特征按从大到小进行排序;然后选择前 n 个互信息最大的特征,构成负荷辨识的初始特征集合

$\{f_1, f_2, \dots, f_n\}$; 计算 f_i 与 $f_j (i < j)$ 之间的互信息大小, 若 f_i 与某个特征 f_j 的互信息值大于阈值, 则将 f_j 移除特征子集, 并按照顺序添加新的特征; 重新计算新的特征子集中特征之间的互信息值, 重复筛选直到两两特征之间的互信息值皆小于阈值, 并构建新的特征集合。

附录 A 图 A3 以热图的形式展示了负荷特征之间的相关性。图 A3(a) 中互信息值很小, 不同特征之间的相关性很弱, 而图 A3(b) 则相反, 说明不同负荷特征之间存在冗余性, 特征提取时可从不同的特征中提取重叠的信息, 以致于增加了许多不必要的运算。因此去除冗余特征可使得模型在相同的运算维度内, 提取到更多的隐含特征。

2 深度 CNN-HMM 负荷辨识算法原理

对于 Type-III 型负荷, 本文引入了具备强特征提取能力的 CNN 模型, 用于提取连续的负荷功率变化中隐含的特征。但是, 纯 CNN 类的方法具有另一种弊端, 在本文中将其表述为辨识结果的非连续性问题, 如附录 A 图 A4 所示。由于 CNN 本身不具备时序建模能力, 所以其对时序数据的感知范围仅能停留在所选取的时间窗长度内, 这导致 CNN 的辨识结果中经常出现局部性的辨识错误。值得注意的是, 使用 CNN 重新提取负荷数据中的特征并将其重构为运行或非运行的二分类状态, 可以解决 HMM 面临的状态空间过大的问题, 使其重新适用于 HMM 对负荷状态的表达。因此, 本文最终确立了使用 CNN-HMM 架构的 Type-III 型负荷运行状态辨识的解决方案。

2.1 算法流程

基于深度 CNN-HMM 的非侵入式负荷辨识算法流程如图 1 所示。

第 1 阶段为数据处理: 采用互信息算法对电力入口处采集的高维负荷数据进行特征选择, 并采用差分处理的方式强化特征表达能力; 对于待辨识负荷数据, 根据电流有效值大小确定其运行状态, 生成设备的标签数据集。

第 2 阶段为模型训练: 将负荷特征数据和标签数据合成模型的训练数据集, 训练深度 CNN, 使其学习拟合特征数据与标签之间的非线性映射关系; 通过深度 CNN 得到负荷的初始辨识结果, 并将其作为 HMM 的已知观测序列, 训练 HMM 的参数。

第 3 阶段为模型评估: 将负荷特征数据和标签数据合成模型的测试数据集, 采用深度 CNN 模型提取负荷的隐含特征并进行初次辨识, 然后采用 HMM 优化 CNN 辨识结果中的状态断点问题, 由此

得到负荷的最终状态序列, 并根据负荷标签数据对 CNN-HMM 辨识结果的准确率进行评估。

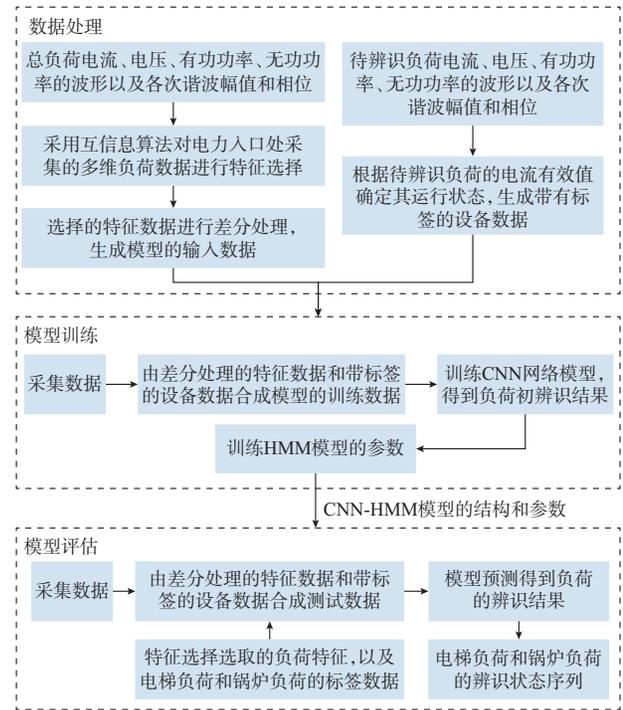


图 1 基于深度 CNN-HMM 的负荷辨识算法流程图
Fig. 1 Flow chart of load identification algorithm based on deep CNN-HMM

2.2 深度 CNN 结构

残差神经网络 (ResNet) 因其特殊的捷径连接结构, 不仅能通过增加网络的深度来提高准确率, 而且可缓解由深度增加所带来的梯度消失问题^[21-22]。因此, 本文采用 ResNet-50 网络作为深度 CNN 的基本架构, 通过 ResNet-50 的学习, 逐渐增加输入特征向量的深度, 减小其数据维度, 提取数据的深层隐含特征, 由此优化神经网络的学习性能。附录 A 表 A1 为 ResNet-50 网络结构的超参数。

2.3 HMM 参数计算

HMM 是关于时间序列的概率模型, 可用一个五元组参数 $\lambda = \{U, V, A, B, \pi\}$ 来表示, 其参数定义如下。

1) $U = \{u_1, u_2, \dots, u_N\}$ 是一组隐含状态的集合, 其中 N 为隐含状态数目, 系统在 t 时刻的隐含状态 $Q_t \in U$ 。本文采用 CNN 进行负荷特征提取, 并将其重构为二分类状态负荷辨识问题, 所以本文实验所选择的待辨识负荷的隐含状态数目 $N = 2$, 只有工作状态和非工作状态, 即 $U = \{0, 1\}$ 。

2) $V = \{v_1, v_2, \dots, v_M\}$ 是一组观测状态的集合, 其中 M 为每一个隐含状态可能输出的不同观测值的数目, 系统在 t 时刻的观测值 $S_t \in V$ 。对于待辨识

负荷,观测状态数目 $M = 2$, 即 $V = \{0, 1\}$ 。

3) 状态转移概率矩阵 $A = \{a_{ij}\}$, 其中 a_{ij} 为在 t 时刻状态为 u_i 的条件下, 在 $t + 1$ 时刻状态为 u_j 的概率, 计算公式如下。

$$a_{ij} = P(Q_{t+1} = u_j | Q_t = u_i) \quad (6)$$

式中: $1 \leq i, j \leq N, \sum_{j=1}^N a_{ij} = 1$ 。

4) 观测状态转移概率矩阵 $B = \{b_i(k)\}$, 其中 $b_i(k)$ 为在 t 时刻隐含状态为 u_i 的条件下, 观测状态为 v_k 的概率。

$$b_i(k) = P(S_t = v_k | Q_t = u_i) \quad (7)$$

式中: $1 \leq i \leq N, 1 \leq k \leq M, \sum_{k=1}^M b_i(k) = 1$ 。

5) 初始状态概率矩阵 $\pi = \{\pi_i\}$ 为 $t = 1$ 时刻初始状态的概率分布。

$$\pi_i = P(Q_1 = u_i) \quad (8)$$

式中: $1 \leq i \leq N, \sum_{i=1}^N \pi_i = 1$ 。

本文提出的非侵入式负荷辨识算法采用 ResNet-50 模型对负荷数据进行初辨识, 并将其重构为运行或非运行的二分类问题, 再采用 HMM 对初始辨识结果进行优化。HMM 算法的具体步骤为: ① 初始化 HMM 可更新参数 $\lambda'_0 = \{A, B, \pi\}$; ② 根据深度 CNN 的初辨识结果生成观测序列 $S = \{S_1, S_2, \dots, S_L\}$; ③ 迭代更新的参数 λ' , 直到观测序列出现的概率 $P(S|\lambda')$ 达最大值; ④ 通过最优参数 λ' 和观测序列 S , 采用维特比算法求使得可能性 $P(Q|S, \lambda')$ 最大的状态序列 $Q = \{Q_1, Q_2, \dots, Q_L\}$, 即为待辨识负荷的最终辨识结果。

3 算例分析

3.1 评价指标

负荷辨识算法的性能可用准确率 A_{cc} 、精确度 P 、召回率 R 以及调和平均评价指标 F_{score} 进行评估。准确率 A_{cc} 的计算如下:

$$A_{cc} = \frac{m}{L} \quad (9)$$

式中: m 为经过算法辨识预测正确的数量。

精确度 P 用来表示算法抗误检的能力, 召回率 R 用来表示算法抗漏检的能力。

$$P = \frac{T_p}{T_p + F_p} \quad (10)$$

$$R = \frac{T_p}{T_p + F_n} \quad (11)$$

式中: T_p 为被辨识为正样本、实际为正样本的数量; F_p 为被辨识为正样本、实际为负样本的数量; F_n 为

被辨识为负样本、实际为正样本的数量。

F_{score} 是用来平衡精确度和召回率的评价指标。

$$F_{score} = \frac{2PR}{P + R} \quad (12)$$

此外, 本文采用 Wasserstein 距离衡量负荷辨识结果的运行时间概率分布与实际负荷运行时间概率分布之间的差异^[23], 距离可表征算法解决识别错误断点的能力, 该值越小表明 2 个概率分布之间的拟合程度越好。Wasserstein 距离的计算公式如下。

$$d = \inf_{\gamma \in \Pi(p_r, p_g)} E_{(x,y) \sim \gamma} (\|x - y\|) \quad (13)$$

式中: p_r 和 p_g 为需要计算二者之间距离的 2 个概率分布; $\inf(\cdot)$ 表示取最小值; $\Pi(p_r, p_g)$ 为以 p_r 和 p_g 为边缘分布的所有可能的联合概率分布 γ 的集合。从 γ 中采样 $(x, y) \sim \gamma$, 计算其范数距离 $\|x - y\|$, 由此计算该联合分布下的距离期望值 $E_{(x,y) \sim \gamma} (\|x - y\|)$, 所有可能的联合分布中取该期望值的下确界为 Wasserstein 距离。

3.2 算例数据集介绍

本文实验所用数据集为实测电力数据, 数据采集地点分别为湖南大学研究生教学楼和湘江欢乐城能源站。其中, 教学楼背景负荷较为简单, 主要用能设备包括电梯与中央空调。而能源站用能结构较为复杂, 它是一个冷热电综合能源站, 包括溴化锂机组、蒸汽锅炉、燃气热水锅炉、热水锅炉循环泵等多种用能设备以及内燃发电机等发电设备。除去大型设备外, 也存在数量众多的中小型负荷, 由于供能覆盖范围较大, 难以穷举。为满足 2 所酒店与冰雪世界的用能需求, 设备机组经常处于复杂的动态调控过程中, 用电情况多变、辨识难度较高, 是一个典型的工商业复杂负荷。

附录 A 图 A5 为实验数据采集地点的电网拓扑结构图, 数据采集装置的安装位置已在图中标记。图 A5(a) 为教学楼低压侧的拓扑, 包括相互独立的 1 号与 2 号电梯、中央空调、照明设备等, 本文选择 1 号电梯负荷为待辨识负荷, 采集的部分电梯负荷数据见附录 B。图 A5(b) 为能源站低压侧的拓扑与其部分负荷, 为保障能源站供电的安全可靠性, 其中包含两支独立的进线, 电源进线为消防负荷供电, 非消防负荷进线为其他电力负荷供电, 本文选择锅炉负荷作为待辨识负荷。

图 2 为待辨识负荷的有功功率 P 和无功功率 Q 的联合分布图。可以看出, 电梯负荷和锅炉负荷的有功和无功功率变化范围都非常广泛, 并且分布较随机, 不能简单地将其聚类处理划分为有限个状态, 且其有功功率并非维持在一个或多个稳定值附近。

电梯负荷和锅炉负荷的状态多变复杂,是典型的 Type-III 型负荷,因此可以作为验证本文算法有效性的待辨识负荷。

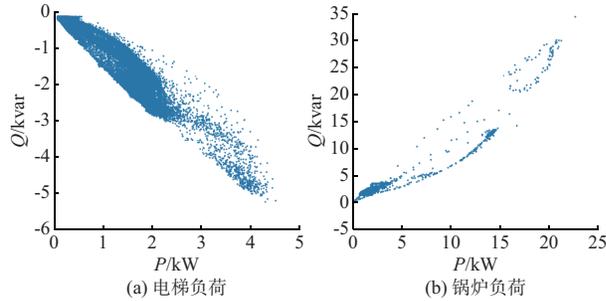


图2 待辨识负荷的有功、无功功率联合分布图
Fig. 2 Diagram of active and reactive power joint distribution for load to be identified

3.3 时间窗口长度和特征数目对负荷辨识的影响

对采集的数据集进行预处理和特征选择时,选择不同的时间窗口长度 w 和特征数量 n 会产生不同的辨识结果。表1为固定 $w = 50$ s时,不同的特征数目对 ResNet-50 网络每轮训练时间的影响。由表1可知,随着特征数目的增加,输入数据维度变大,网络的训练时间也会随之变长,因此采用互信息进行特征选择可以缩短模型的训练时间,从而提高模型运算效率。

表1 ResNet-50 网络每轮的训练时间
Table 1 Training time of each epoch in ResNet-50 network

特征数目	训练时间/min
30	2.95
40	3.20
50	3.55
60	3.83
70	4.40

图3展示了算法辨识准确率与时间长度和特征数目的关系。由图可见,随着 n 的增加,负荷辨识模型可从输入数据中提取更多的隐含特征,但当 n 达到某一数值后,选择的负荷特征中开始出现重叠信息或是无关信息,反而会对模型辨识产生干扰,降低辨识的准确率;随着 w 的增加,模型可从一个时间窗口内学习待辨识负荷状态之间的时间连续性,从而减少辨识结果非连续性的现象,但当 w 覆盖负荷的最大运行周期值时,模型逐渐达到饱和,负荷辨识准确率便不会随着 w 的增大而增大。综合考虑算法的运算量和准确率,本文选择时间窗口长度 $w = 60$ s、特征数量 $n = 40$ 进行特征选择和模型训练。

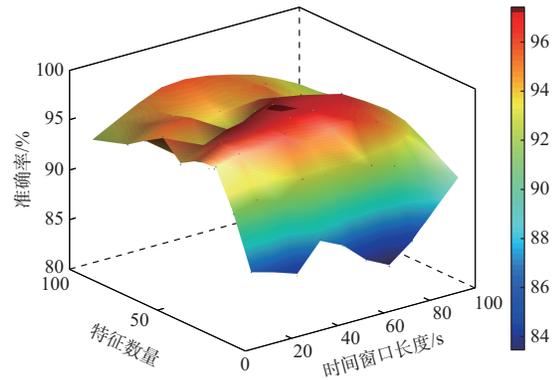


图3 时间长度和特征数量与辨识准确率的关系
Fig. 3 Relationship of time length, number of characteristics and identification accuracy

3.4 ResNet-50 网络训练过程

从实验数据集中选择周六的数据作为网络的训练数据,选择周一的数据作为测试数据,并且在训练数据中将 80% 用于训练,其余 20% 用于模型的评估,从而选择出效果最佳的模型。在训练过程中,采用 Adam 优化器,设置初始学习率为 0.001,并使用线性整流函数(ReLU)以加快模型的收敛速度,用交叉熵函数计算分类误差。附录 A 图 A6 为损失函数值随训练过程迭代次数的变化曲线图。可以看出,在迭代次数达到 30 左右时,无论是训练误差还是评估误差,模型的损失值都趋于平缓,达到收敛状态。

3.5 与其他辨识算法的对比

本文将几种常用的非侵入式负荷辨识算法作为对比算法进行测试,包括 k 最近邻(KNN)^[24]、随机森林(RF)^[25]、HMM^[14]、长短期记忆(LSTM)网络^[12]、CNN^[11]以及 CNN-LSTM 模型。其中,选择 HMM 和 CNN 算法是为了对比本文算法相较于单独模型的优化效果。KNN 和 RF 算法是经典的分类识别算法,而 LSTM 网络模型是处理时间序列的神经网络,这 3 种算法均被普遍应用于非侵入式负荷辨识领域中。

待辨识负荷的辨识结果如表 2 所示,图 4 展示了几种负荷辨识算法在相同时间内的辨识结果。由图 4 可见,LSTM 和 CNN 算法的辨识结果中都存在一定的状态断点问题,导致负荷辨识的准确率降低;而两层模型 CNN-LSTM 和 CNN-HMM 相较于单独模型在一定程度上优化了辨识结果的非连续性,提高了负荷辨识的准确率,且 HMM 比 LSTM 的优化效果更为显著,本文提出的 CNN-HMM 算法具有更高的精度。结合表 2 中的评价指标对比,可在数据上证实这一观点。虽然在精确度 P 和召回率 R 上,本文算法并非是最优的,即本文算法在所有对比算法中并不具有最强的抗误检和抗漏检的能力,但

是对于能综合反映辨识结果的可靠程度指标 F_{score} , 提出的算法取得了 0.987 9 的最高值; 对于反映负荷辨识结果与实际运行状态之间差异的 Wasserstein 距离, 提出的算法取得了最小值, 而 d 值越小表明算

法解决识别错误断点的能力越强。综上所述, 本文算法对于 Type-III 型工商业负荷的辨识效果优于其他对比算法, 并且具有最高的辨识准确率, 能达到 97.9%。

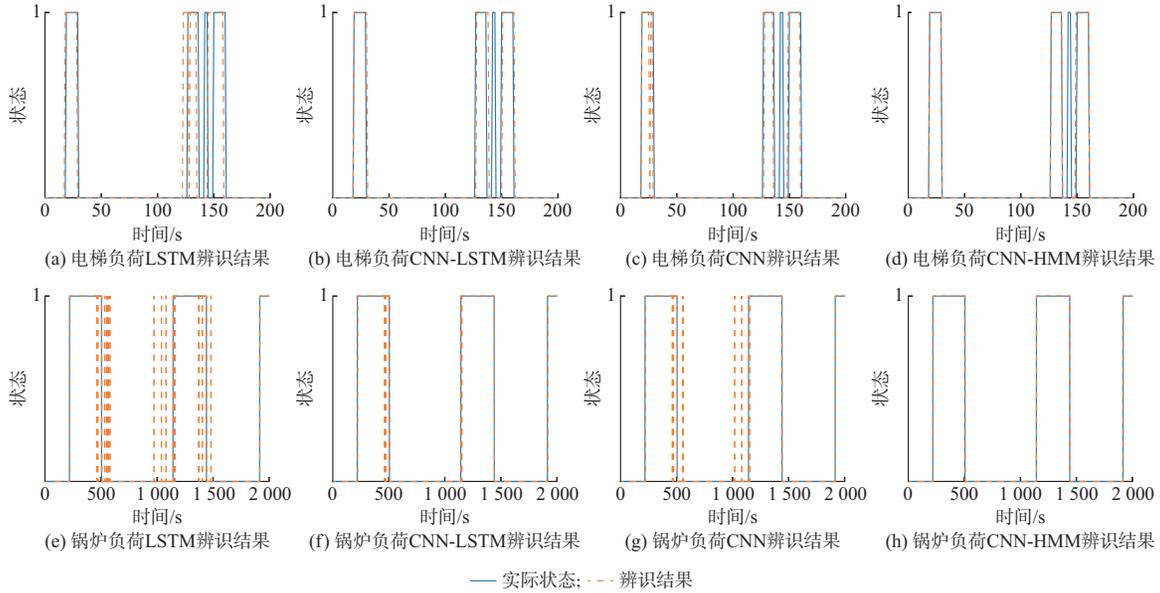


图 4 算法辨识结果对比

Fig. 4 Comparison of algorithm identification results

表 2 待辨识负荷的辨识结果
Table 2 Identification results of load to be identified

算法	电梯负荷					锅炉负荷				
	$P/\%$	$R/\%$	F_{score}	$A_{cc}/\%$	d	$P/\%$	$R/\%$	F_{score}	$A_{cc}/\%$	d
KNN ^[24]	93.41	91.60	0.924 9	86.33	0.062 00	69.72	93.63	0.799 3	91.25	0.040 91
RF ^[25]	91.35	98.36	0.947 3	90.75	0.034 50	78.97	98.50	0.876 6	92.79	0.039 69
HMM ^[14]	93.73	93.76	0.937 5	88.23	0.049 33	89.69	73.66	0.808 9	86.38	0.065 88
LSTM ^[12]	96.98	96.88	0.969 3	94.00	0.033 27	97.52	66.29	0.789 3	93.70	0.035 48
CNN ^[11]	100.00	95.43	0.976 6	95.60	0.030 64	96.71	76.46	0.854 0	95.39	0.029 18
CNN-LSTM	96.94	99.22	0.980 6	96.50	0.022 31	98.55	77.71	0.869 0	95.90	0.028 07
CNN-HMM	98.50	99.07	0.987 9	97.90	0.017 59	97.06	81.48	0.885 9	96.60	0.021 98

3.6 用户用电行为分析

用户的用电行为是指在什么时间用了什么电器产生了多大的负荷, 通过 NILM 技术可以方便地获得各电器的使用情况, 进而可以对各电器的用电信息如启停时间、持续时间及用电量等进行统计, 以得到用户准确的用电行为, 从而帮助电网公司制定供需互动策略。

附录 A 图 A7 为根据负荷辨识结果得到的电梯负荷和锅炉负荷一天的用能统计。由图 A7(a) 可知, 电梯负荷的运行具有明显的时间特性, 主要用电行为集中在 09:00—23:00, 而在 00:00—06:00 时段内几乎没有运作, 且工作日的运行时长较周末的略长, 这与电梯负荷所处的学校环境有关, 电梯的运行

时段与学生上下课时段重合。由图 A7(b) 可知, 锅炉负荷的运行几乎与时间无关, 因其处于供能站内, 要满足站内所有的供热需求, 所以锅炉负荷每天的工作时间都很长, 用能量很大, 且工作日与周末的用能并没有很大区别。

4 结语

为有效辨识 Type-III 型负荷, 本文提出了基于深度 CNN-HMM 的非侵入式负荷辨识算法。首先, 根据互信息原理进行特征选择并去除冗余特征, 采用参数搜索确定最优时间窗口长度和特征数目; 由于 ResNet-50 网络可有效解决深度网络训练过程中梯度消失的问题, 将其作为深度 CNN 模型的架构,

提取负荷的多维特征,并完成初次辨识;根据初次辨识结果,计算HMM的参数,并完成负荷的二次辨识,从而优化CNN模型辨识中存在的辨识结果非连续性问题;最后,与其他负荷辨识算法的对比测试结果表明,本文算法能有效辨识Type-III型工商业电力负荷,具有更好的准确率和辨识精度。

下一步的工作重点是研究Type-III型负荷运行时的典型状态辨识问题。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

参 考 文 献

- [1] LIN Y H, TSAI M S. An advanced home energy management system facilitated by nonintrusive load monitoring with automated multiobjective power scheduling [J]. *IEEE Transactions on Smart Grid*, 2015, 6(4): 1839-1851.
- [2] 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.
- [3] HART G W. Nonintrusive appliance load monitoring [J]. *Proceedings of the IEEE*, 1993, 80(12): 1870-1891.
- [4] YANG Dongsheng, GAO Xiaoting, KONG Liang, et al. An event-driven convolutional neural architecture for non-intrusive load monitoring of residential appliance[J]. *IEEE Transactions on Consumer Electronics*, 2020, 66(2): 173-182.
- [5] CHRYSOPOULOS A, DIOU C, SYMEONIDIS A L, et al. Bottom-up modeling of small-scale energy consumers for effective demand response applications [J]. *Engineering Applications of Artificial Intelligence*, 2014, 35: 299-315.
- [6] GYUBAEK K, SANGHYUN P. A study on data requirements for power disaggregation [C]// *International Conference on Power and Energy Applications*, October 9-11, 2020, Busan, Korea: 141-144.
- [7] 雷怡琴,孙兆龙,叶志浩,等.电力系统负荷非侵入式监测方法研究[J].*电工技术学报*,2021,36(11):2288-2297.
LEI Yiqin, SUN Zhaolong, YE Zhihao, et al. Research on non-invasive load monitoring method in power system [J]. *Transactions of China Electrotechnical Society*, 2021, 36(11): 2288-2297.
- [8] HSUEH H C, MENG C L, WEI J L, et al. Feature extraction-based Hellinger distance algorithm for nonintrusive aging load identification in residential buildings[J]. *IEEE Transactions on Industry Applications*, 2016, 52(3): 2031-2039.
- [9] FANG Zhaoyuan, ZHAO Dongbo, CHEN Chen, et al. Nonintrusive appliance identification with appliance-specific networks [J]. *IEEE Transactions on Industry Applications*, 2020, 56(4): 3443-3452.
- [10] WENNINGER M, STECHER D, SCHMIDT J. SVM-based segmentation of home appliance energy measurements [C]// *IEEE International Conference on Machine Learning and Applications*, December 16-19, 2019, Boca Raton, USA: 1666-1670.
- [11] 王守相,郭陆阳,陈海文,等.基于特征融合与深度学习的非侵入式负荷辨识算法[J].*电力系统自动化*,2020,44(9):103-110.
WANG Shouxiang, GUO Luyang, CHEN Haiwen, et al. Non-intrusive load identification algorithm based on feature fusion and deep learning [J]. *Automation of Electric Power Systems*, 2020, 44(9): 103-110.
- [12] KASELIMI M, DOULAMIS N, VOULODIMOS A, et al. Context aware energy disaggregation using adaptive bidirectional LSTM models [J]. *IEEE Transactions on Smart Grid*, 2020, 11(4): 3054-3067.
- [13] 罗平,樊星驰,章坚民,等.基于电器运行状态和深度学习的非侵入式负荷分解[J].*电力系统自动化*,2021,45(12):49-56.
LUO Ping, FAN Xingchi, ZHANG Jianmin, et al. Non-intrusive load decomposition based on operation state of electrical appliances and deep learning [J]. *Automation of Electric Power Systems*, 2021, 45(12): 49-56.
- [14] MAKONIN S, POPOWICH F, BAJIĆ I V, et al. Exploiting HMM sparsity to perform online real-time nonintrusive load monitoring [J]. *IEEE Transactions on Smart Grid*, 2016, 7(6): 2575-2585.
- [15] DOMINIK E, VENKATA P B, WILFRIED E. PALDi: online load disaggregation via particle filtering [J]. *IEEE Transactions on Instrumentation and Measurement*, 2015, 64(2): 467-477.
- [16] ANDREOLI J. Learning energy consumption profiles from data [C]// *IEEE Symposium on Computational Intelligence and Data Mining*, December 9-12, 2014, Orlando, USA: 463-470.
- [17] LI D, SAWYER K, DICK S. Disaggregating household loads via semi-supervised multi-label classification [C]// *Annual Conference of the North American Fuzzy Information Processing Society Held Jointly with 5th World Conference on Soft Computing*, August 17-19, 2015, Redmond, USA: 1-5.
- [18] KONG Weicong, DONG Zhaoyang, WANG Bo, et al. A practical solution for non-intrusive Type II load monitoring based on deep learning and post-processing [J]. *IEEE Transactions on Smart Grid*, 2020, 11(1): 148-160.
- [19] 刘旭东.互信息去冗余与多种分类模型结合的癌症分类问题研究[D].长沙:湖南大学,2018.
LIU Xudong. Research on cancer classification problem based on mutual information redundancy and multiple classification models[D]. Changsha: Hunan University, 2018.
- [20] ALEXANDER K, HARALD S, PETER G. Estimating mutual information[J]. *Physical Review*, 2004, 69: 066138.
- [21] ŞAFAK K, İMAN A, YILMAZ K. Using ResNet transfer deep learning methods in person identification according to physical actions[J]. *IEEE Access*, 2020, 8: 220364-220373.
- [22] LI Baoqi, HE Yuyao. An improved ResNet based on the adjustable shortcut connections [J]. *IEEE Access*, 2018, 6: 18967-18974.

- [23] LU Mengtao, YIN Jianfei. A feature metric algorithm combining the Wasserstein distance and mutual information [C]// IEEE International Conference on Progress in Informatics and Computing, December 14-16, 2018, Suzhou, China: 154-157.
- [24] 徐伟枫, 华锦修, 余涛, 等. 计及电器状态关联规则的非侵入式负荷分解[J]. 电力自动化设备, 2020, 40(4): 197-203.
XU Weifeng, HUA Jinxiu, YU Tao, et al. Non-intrusive load decomposition considering association rules of appliances' state [J]. Electric Power Automation Equipment, 2020, 40 (4) : 197-203.
- [25] WU Xin, GAO Yuchen, JIAO Dian. Multi-label classification based on random forest algorithm for non-intrusive load

monitoring system[J]. Processes, 2019, 7(6): 337-351.

段 晶(1996—),女,硕士,主要研究方向:非侵入式负荷监测。E-mail:duanjing@hnu.edu.cn

李 勇(1982—),男,通信作者,教授,博士生导师,主要研究方向:电力系统运行与控制、电力电子系统与控制。E-mail:yongli@hnu.edu.cn

张振宇(1994—),男,博士,主要研究方向:中压配电网的拓扑识别、非侵入式负荷监测。E-mail:zhenyuzhang@hnu.edu.cn

(编辑 王梦岩)

Identification Method for Type-III Industrial and Commercial Load Considering Identification Result Continuity

DUAN Jing¹, LI Yong¹, ZHANG Zhenyu¹, LI Weiwei², JIANG Lin³, LI Lei⁴

(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China;

2. Changsha Xinao Changran Energy Development Co., Ltd., Changsha 410082, China;

3. Department of Electrical Engineering and Electronics, University of Liverpool, Liverpool L69 3BX, UK;

4. Changsha Xinao Xiangjiang New Energy Development Co., Ltd., Changsha 410082, China)

Abstract: Non-intrusive load monitoring technology can guide users to arrange power consumption time reasonably, thereby reducing power consumption. Among them, due to the continuous variability of the state, the identification of continuously varying (Type-III) load has always been one of the difficult problems in non-intrusive load monitoring. Aiming at the problem of Type-III load identification, a non-intrusive load identification algorithm based on deep convolutional neural network (CNN) and hidden Markov model (HMM) is proposed. Firstly, the load characteristics are selected according to the mutual information theory. Then, the residual neural network is used as the basic structure of deep CNN to extract multi-dimensional features of the load and realize the initial identification of Type-III loads. Finally, in order to solve the problem of state breakpoint in CNN identification results, the HMM is used to complete the continuous optimization of load identification results. In the complex industrial and commercial operation environment, the algorithm is trained and verified on the representative Type-III load data. The results show that the proposed algorithm can effectively identify the operation state of Type-III industrial and commercial load.

This work is supported by International Science and Technology Cooperation Program of China (No. 2018YFE0125300), National Natural Science Foundation of China (No. 52061130217) and Huxiang Youth Talent Program of Hunan Province (No. 2019RS1016).

Key words: non-intrusive load identification; mutual information; residual neural network; hidden Markov model



附录 A

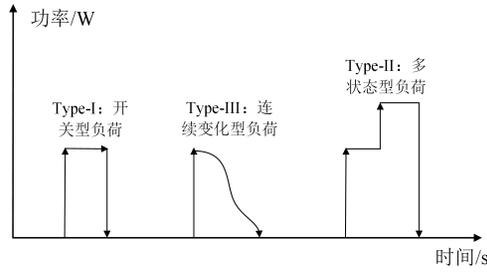


图 A1 负荷分类
Fig. A1 Load classification

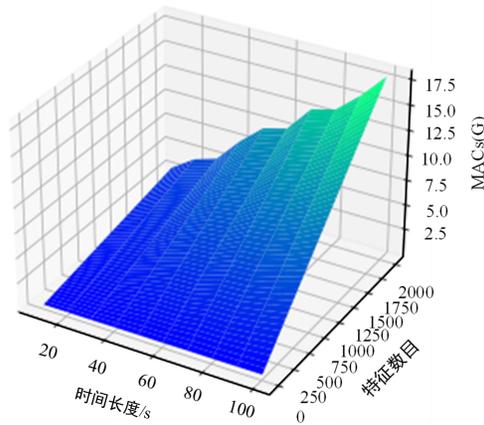


图 A2 ResNet-50 的运算量
Fig. A2 Computation burden of ResNet-50

图 A3(a)为根据互信息去冗余之后所选择的前 10 个负荷特征之间的互信息值,图 A3(b)为未去除冗余特征的互信息,对角线表示负荷特征的自相关性,其互信息值最大,颜色也最深;而除对角线之外的则代表不同负荷特征之间的相关性,图 A3(a)中除对角线外方格颜色都很浅,表明其互信息值很小,不同特征之间的相关性很弱,而图 A3(b)则相反,说明不同负荷特征之间存在冗余性,特征提取时可从不同的特征中提取重叠的信息,以致于增加了许多不必要的运算。因此去除冗余特征可使得模型在相同的运算维度内,提取到更多的隐含特征。

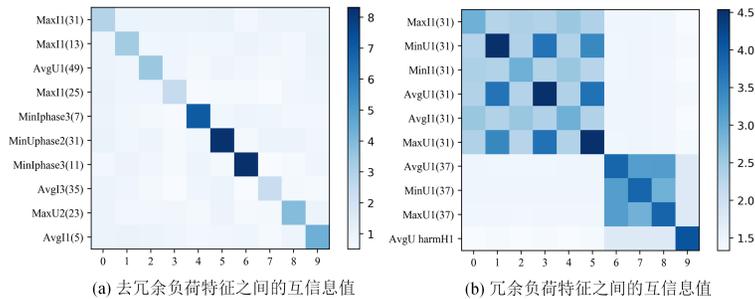


图 A3 负荷特征之间互信息热图
Fig. A3 Heat map of mutual information between load characteristics

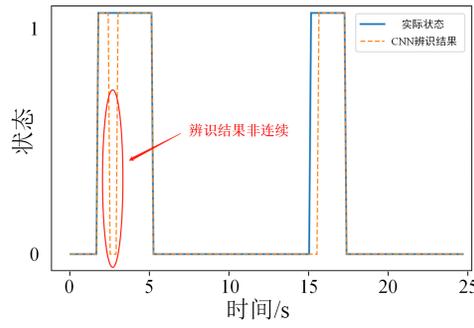


图 A4 CNN 辨识结果的非连续性
Fig. A4 Discontinuity of CNN identification results

表 A1 为 ResNet-50 网络结构的超参数。其中,Conv(·)表示卷积层,该层参数依次为卷积核个数、卷积核大小和激活函数,选择线性整流函数(ReLU)的目的是为了加快模型的收敛速度;Max-pool 和 Avg-pool 分别为最大池化和平均池化层;Dense(·)表示全连接层,采用隐藏节点数和激活函数的参数,Softmax 作为输出层的激活函数将输出映射到(0,1)区间内,可以表示当前输出属于各个类别的概率。

表 A1 ResNet-50 网络结构超参数
Table A1 Hyperparameters of ResNet-50 network structure

层数	参数	层数	参数
1	Conv(64, 7, ReLu)	5	$\begin{bmatrix} \text{Conv}_1(256, 1, \text{ReLu}) \\ \text{Conv}_2(256, 3, \text{ReLu}) \\ \text{Conv}_3(1024, 1, \text{ReLu}) \end{bmatrix} \times 6$
2	Max-pool		
3	$\begin{bmatrix} \text{Conv}_1(64, 1, \text{ReLu}) \\ \text{Conv}_2(64, 3, \text{ReLu}) \\ \text{Conv}_3(256, 1, \text{ReLu}) \end{bmatrix} \times 3$		
4	$\begin{bmatrix} \text{Conv}_1(128, 1, \text{ReLu}) \\ \text{Conv}_2(128, 3, \text{ReLu}) \\ \text{Conv}_3(512, 1, \text{ReLu}) \end{bmatrix} \times 4$	6	$\begin{bmatrix} \text{Conv}_1(512, 1, \text{ReLu}) \\ \text{Conv}_2(512, 3, \text{ReLu}) \\ \text{Conv}_3(2048, 1, \text{ReLu}) \end{bmatrix} \times 3$
		7	Avg-pool
		8	Dense(2, Softmax)

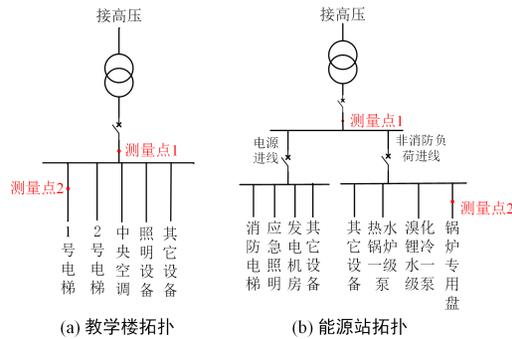


图 A5 数据采集地电网拓扑
Fig. A5 Topology of power grid in data acquisition area

图 A7 中,颜色越深表示用能时间越短,颜色越浅表示用能时间越长。

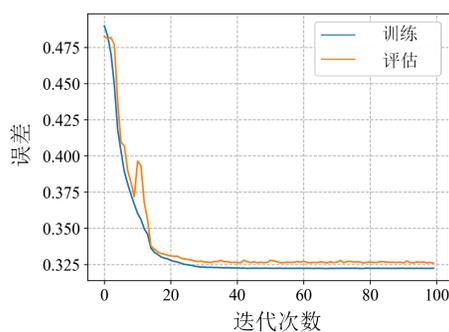


图 A6 ResNet-50 训练损失函数曲线
Fig. A6 Loss function curve of ResNet-50 training

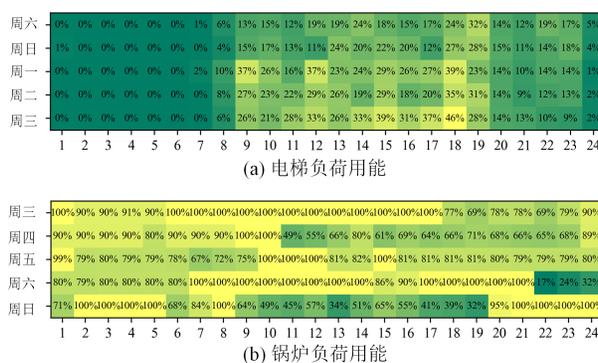


图 A7 负荷用能统计
Fig. A7 Statistics of load energy consumption

附录 B

本文实验所用的电梯负荷数据集以百度网盘文件的方式公开, 以下为部分数据的获取链接: <https://pan.baidu.com/s/1bjeZjd1XAYRVLenEqY3iw>, 提取码为: fhsj。