

DOI: 10.19783/j.cnki.pspc.190561

结合图半监督与广义回归神经网络的非侵入式 海洋平台负荷监测

张安安¹, 庄景泰¹, 郭红鼎², 曲广龙¹, 周志通¹

(1. 西南石油大学, 四川 成都 610500; 2. 许继时代技术有限公司, 河南 许昌 461000)

摘要: 海洋平台微电网所处环境复杂, 对其自动化和智能化要求较高, 目前缺少对其负荷实时智能监测和管理的方法。从非侵入式负荷监测的角度, 考虑海洋平台的经济性要求和特殊的工业环境, 提出结合图半监督与广义回归神经网络的非侵入式海洋平台负荷监测方法。采用图半监督学习算法自动标记训练数据集, 减少了人工标记数据的工作量, 使系统能自动完成数据标记。并与半监督聚类算法对比分析, 表明图半监督学习算法对数据标记具有更高的正确率。再利用广义回归神经网络较强的非线性分类能力, 提升负荷识别的识别精度和减少计算复杂度。Matlab/Simulink 仿真结果表明, 所提出的负荷识别算法不仅减少了人工干预而且具有高精度的识别率。

关键词: 海洋平台; 数据标签; 非侵入式负荷监测; 图半监督学习; 广义回归神经网络

Non-intrusive offshore platform load monitoring based on graph-based semi-supervised learning and generalized regression neural networks

ZHANG An'an¹, ZHUANG Jingtai¹, GUO Hongding², QU Guanglong¹, ZHOU Zhitong¹

(1. Southwest Petroleum University, Chengdu 610500, China; 2. XJ Times Technology Company, Xuchang 461000, China)

Abstract: The offshore platform microgrid has a complex environment, it requires high automation and intelligence. At present, there is a lack of real-time intelligent monitoring and management methods for its load. From the perspective of Non-Intrusive Load Monitoring (NILM), considering the economic requirements and the special industrial environment of the offshore platform, this paper proposes a non-intrusive offshore platform load monitoring method based on Graph-Based Semi-Supervised Learning (GBSSL) algorithm and Generalized Regression Neural Networks (GRNN). GBSSL algorithm is used to automatically mark the training data set, which reduces the workload of manual labeling data and enables the system to automatically complete the data labeling. Compared with semi-supervised clustering algorithm, it shows that GBSSL has higher accuracy rate for labeling data. The strong nonlinear classification ability of generalized regressive neural networks is used to improve the recognition accuracy and reduce the computational complexity of load recognition. The simulation results of Matlab/Simulink show that the proposed load identification algorithm not only reduces manual intervention but also has high precision recognition rate.

This work is supported by National Key Research and Development Program of China (No. 2017YFE0112600), China Postdoctoral Fund (No. 2014M562335), and Research Program of Sichuan Scientific Research Team (No. 15TD0005).

Key words: offshore platform; data label; non-intrusive load monitoring; graph-based semi-supervised; generalized regression neural network

0 引言

海洋平台微电网的智能化是未来发展的必然趋

势。相比于陆地微网, 海洋平台微电网对集成度与运行稳定性要求更高, 更需要对负荷实时监测和管理^[1-2]。负荷监测能够及时检测和诊断用电负荷故障, 获得负荷用电信息, 掌握运行负荷工况^[3], 对海洋平台微电网的安稳运行至关重要。

负荷监测分为侵入式负荷监测和非侵入式负荷监测(Non-intrusive Load Monitoring, NILM)。传统的

基金项目: 国家重点研发计划项目资助(2017YFE0112600); 中国博士后基金项目资助(2014M562335); 四川省科研创新团队研究项目资助(15TD0005)

侵入式方法是在每个负荷内部安装采集传感装置，该方法虽然可以采集到不同负荷的电能数据，但存在安装和维护成本高，管理不方便等缺点^[4]。另外，采集装置本身存在能耗，会对电力系统产生影响，因此，对于海洋平台微电网而言，侵入式负荷监测系统难以应用。非侵入式负荷监测于二十世纪 80 年代由麻省理工大学(MIT)的 Hart 教授最先提出^[5]，其实质就是负荷分解，即将用户总负荷信息分解为各个用电设备的信息，进而获取用电设备能耗情况与用户用电规律等信息。非侵入式方法是将监测设备安装在电力入口处，通过负荷识别算法分析用电信息，获悉内部各设备的用电情况，可以大大简化硬件结构、降低成本。

随着模式识别算法的不断发展，国内外学者将其应用到负荷识别的领域，取得了较好的分类效果。模式识别方法一般可分为基于监督学习和非监督学习两类。基于监督学习的负荷识别算法众多，如：文献[6]将人工神经网络和 k 近邻算法应用到非侵入式负荷监测系统，再采用 Fisher 准则的人工免疫算法(AIA)调整特征参数，提高负荷识别率。文献[7]提出一种 AdaBoot 样本筛选算法以精简负荷特征库，利用 k 近邻算法的简捷性和核 Fisher 判别算法的非线性分类能力，提高了负荷识别的速度和精度。文献[8]以电器的平均功率作为负荷特征训练朴素贝叶斯，实现了负荷识别，并有一定的识别准确度。文献[9]提出将功率信息的模糊处理作为负荷特征量，使用混合支持向量机/高斯混合模型(SVM/GMM)分类模型对电器进行分类，对多器具和非线性负荷具有较高的识别率。基于监督学习的识别方法普遍都有较高的识别率，但需要人为收集训练数据和手动标记负荷^[2]。

为了减少人工干预，增强实用性，国外学者将无监督学习应用到非侵入负荷监测中。文献[10]采用无监督学习方法来对未标记的家庭数据汇总。文献[11]采用因子隐式 Markor 模型，简化了对负荷数据贴标签的繁琐过程，但无监督学习明显的缺陷是识别精度不高，且易陷入局部最优。

海洋平台微电网不仅需要高精度的负荷识别能力，而且应尽可能地减少人工干预。本文提出了一种图半监督学习(Graph-Based Semi-Supervised Learning, GBSSL)和广义回归神经网络(Generalized Regression Neural Network, GRNN)相结合的非侵入式负荷识别算法，通过利用自动采集的非监督信息数据和少量的监督信息数据，实现自动及高精度负荷识别。通过实验验证了图半监督算法和 GRNN 相结合的算法相比现有方法不仅可以减少人工干预，

而且具有高精度的识别率。

1 海洋平台的非侵入式负荷监测

NILM 系统通过在电力接入口安装电能数据采集装置(智能电表)来监测电压和电流的变化情况^[12]，本文将其应用于海洋平台。

如图 1 所示，该海洋工作平台负荷为 75 kW、15 kW 和 110 kW 的泵类电机负荷。75 kW 和 15 kW 负荷采用直接启动方式，而 110 kW 负荷采用软启动方式。这三类泵类负荷为该工作平台的主要负荷类别。

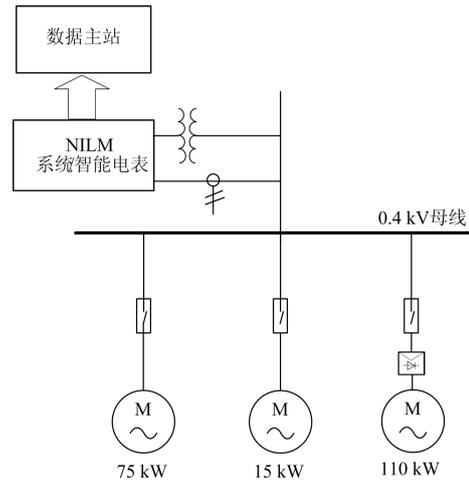


图 1 海洋平台非侵入式负荷监测系统

Fig. 1 NILM of offshore platform

本文根据典型的 NILM 框架构建海洋平台 NILM，并做了改进。在海洋平台 NILM 系统的典型框架中，包括了数据测量、数据处理、事件探测、特征提取、自动标记、负荷识别 6 个步骤。本文研究的主要内容为负荷识别。

第 1 步：数据测量，在平台的入口处获得总负荷的稳态和暂态信号，数据测量硬件必须满足对信号采样频率的要求。

第 2 步：数据处理，主要包括去噪及电气量的计算等。

第 3 步：事件探测，目的是获得用电设备的运行状态变化情况。

第 4 步：特征提取，在探测到的事件发生后，从数据中提取供负荷识别的一系列不同的负荷印记(Load Signatures, LS)^[2]特征。本文将负荷电流暂态作为 LS 特征。

第 5 步：自动标记，这一步由本文提出使用半监督算法自动给未标记的数据上标签，减少人工操作。

第6步: 负荷识别, 将数据提取的特征与已有特征库中的负荷特征进行比较, 当两者满足一定的相似度时, 即辨识出相应的用电设备。本文使用图半监督结合 GRNN 算法中的 GRNN 部分进行负荷识别。

2 图半监督结合 GRNN 的负荷识别

2.1 半监督聚类算法原理

半监督聚类中的约束种子 k 均值(Constrained Seed k -means)算法由 Basu 等人^[13]提出。在 k -means 算法的基础上, 给定样本集 $X = \{x_1, x_2, \dots, x_m\}$, 含有少量的有标记样本为 $S = \bigcup_{j=1}^k S_j \subset X$, 其中 $S_j \neq \emptyset$ 为隶属于第 j 个聚类簇的样本。这类有标记的样本直接称为“种子”, 用它们初始化 k 均值算法的 k 个聚类中心, 并且在聚类簇迭代更新过程不改变种子样本的簇隶属关系, 最终达到给未标记数据上标签的目的。但半监督聚类容易陷入局部最优解, 图半监督学习算法可有效避免这个问题。

2.2 图半监督学习算法框架

给定 $X_l = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$, $l = u$, $l + u = m$, $X_u = \{x_{l+1}, x_{l+2}, \dots, x_{l+u}\}$, 有标签集合 $L = \{1, 2, \dots, c\}$, 其中 $y_i \in L$ 。基于 $X_l \cup X_u$ 构建图 $G = (V, E)$, 结点集 $V = \{x_1, \dots, x_l, x_{l+1}, \dots, x_{l+u}\}$, 边集 E 可表示为亲和矩阵(affinity matrix), 常基于高斯函数定义为

$$(W)_{ij} = \begin{cases} \exp\left(\frac{-\|x_i - x_j\|_2^2}{2\sigma^2}\right), & \text{if } i \neq j \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

式中: $i, j \in \{1, 2, \dots, m\}$; $\sigma > 0$, 表示用户指定的高斯函数带宽参数。

存在对角矩阵 $D = \text{diag}(d_1, d_2, d_3, \dots, d_{l+u})$, 其中对角元素 $d_i = \sum_{j=1}^{l+u} (W)_{ij}$ 。定义 $(l+u) \times c$ 的非负标记矩 $F = (F_1^T, F_2^T, \dots, F_{l+u}^T)^T$, 其第 i 行元素 $F_i = ((F)_{i1}, (F)_{i2}, \dots, (F)_{ic})$ 为示例 x_i 的标记向量, 分类规则为 $y_i = \text{argmax}_{j \leq c} F_{ij}$ 。

定义一个 $(l+u) \times n$ 的矩阵 $Y \in F$:

$$(Y)_{ij} = \begin{cases} 1, & \text{if } (1 \leq i \leq l) \wedge (y_i = j) \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

显然 Y 的前 1 行就是 1 个有标记样本的标记向量。

完整的标记传播算法流程如下。

步骤 1: 形成亲和矩阵 W 。

步骤 2: 基于 W 构造一个标记传播矩阵。

$$S = D^{-\frac{1}{2}} W D^{-\frac{1}{2}} \quad (3)$$

式中, $D^{-\frac{1}{2}} = \text{diag}\left(\frac{1}{\sqrt{d_1}}, \frac{1}{\sqrt{d_2}}, \dots, \frac{1}{\sqrt{d_{l+u}}}\right)$ 。

步骤 3: 形成迭代计算式。

$$F(t+1) = \alpha S F(t) + (1-\alpha) Y \quad (4)$$

式中, $\alpha \in (0, 1)$ 为用户指定的参数, 用于对标记传播项 $SF(t)$ 与初始化项 Y 的重要性进行折中。

步骤 4: 基于式(4)迭代至收敛可得

$$F^* = \lim_{t \rightarrow \infty} F(t) = (1-\alpha)(I - \alpha S)^{-1} Y \quad (5)$$

由 F^* 可获得 X_u 中样本的标记。作为分类, 式(5)可以等于 $F^* = (D - \alpha W)^{-1} Y$ ^[14]。这也证明了迭代结果完全不依赖于迭代的初始值。

2.3 图半监督学习算法结合 GRNN 的NILM算法原理

图半监督学习存在几点问题、一方面, 在存储开销上, 如样本数量为 $O(m)$, 则算法中所涉及的矩阵规模为 $O(m^2)$, 这使得很难直接处理大规模数据; 另一方面, 由于构图过程仅能考虑训练样本集, 难以判断新样本在图中的位置^[15-17]。

GRNN 具有所需训练样本少、结构简单的优点^[18-19]。要取得同样效果, GRNN 所需样本是 BP 神经网络的 1%^[20-22]。当接收到图半监督算法部分给出的少量训练集时, 仍然可以保持稳定的高精度识别能力。尽可能地减少了人工干预, 同时具有高精度的识别率。

本文设计的图半监督学习与 GRNN 相结合的 NILM 算法, 先由图半监督学习对样本集中未标记负荷数据上标签, 再将新标记的数据和原少量带有标记的数据合并送入到 GRNN 中进行训练。最后用训练好的 GRNN 进行负荷识别。具体地, 图半监督和 GRNN 相结合的 NILM 算法原理如下。

输入: 未标记样本集 $X_u = \{x_{l+1}, x_{l+2}, \dots, x_{l+u}\}$;

有标记样本集 $X_l = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$ 。

1) 基于 $X_l \cup X_u$ 构建图 $G = (V, E)$, 结点集 $V = \{x_1, \dots, x_l, x_{l+1}, \dots, x_{l+u}\}$, 边集 E 被定义为径向基函数核(RBF kernel), 对角函数置 0。

2) 通过公式

$$F^* = (D - \alpha W)^{-1} Y \quad (6)$$

得到 X_u 中样本的标记。

3) 将 X_u 和 X_l 的数据合并成 X , 作为训练样本加入到 GRNN 输入层。每个输入神经元是简单的线性单元, 将输入变量传递给模式层。

4) 模式层神经元传递函数为

$$P_i = \exp\left(-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right) \quad (7)$$

式中： P_i 为模式层各神经元的输出； X_i 为第 i 个神经元对应的训练样本的自变量； $i=1,2,\dots,n$ ； σ 为光滑因子。

5) 加和层中分子单元和分母单元的传递函数分别为式(8)和式(9)所示。

$$S_{Nj} = \sum_{i=1}^n y_{ij} P_i = \sum_{i=1}^n \exp\left(-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right) \quad (8)$$

$$S_D = \sum_{i=1}^n P_i = \sum_{i=1}^n \exp\left(-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right) \quad (9)$$

6) 输出层节点个数等于标签向量的维度，每个节点的输出等于对应的加和层输出与求和层第一个节点输出相除，即可得出样本的类别。

本文提出的基于图半监督与 GRNN 结合的 NILM 方法实现过程如图 2 所示。首先分别采集少量带标签的电流数据和大量不带标签的电流数据，截取暂态电流，计算最大值、最小值、均方根及平均值作为特征值。再将数据集传入到图半监督算法中，给无标签数据上标签。然后将原有的少量带标签数据集和新上标签的数据集合并成训练集训练 GRNN 分类器。最后对多负荷数据和单负荷数据进行负荷识别。

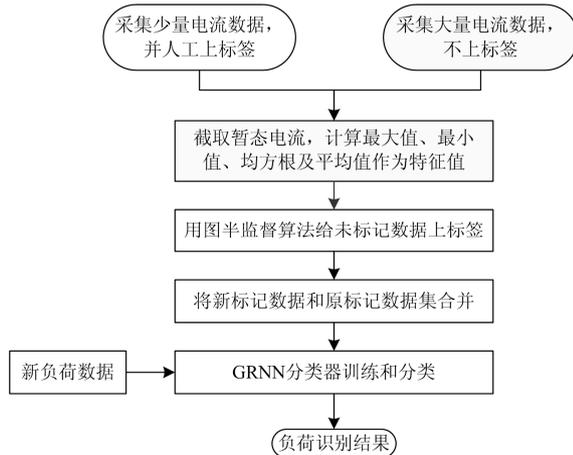


图 2 海洋平台的 NILM 流程

Fig. 2 Flow chart NILM of offshore platform

3 实验结果与分析

本文采用 Matlab 和 Simlink 仿真，通过对三种工业负荷的仿真模拟和测量并观察负载电流，实现两种半监督算法的对比分析和图半监督与 GRNN 结合算法的负荷识别仿真结果分析。

3.1 实验数据

本文通过控制所设计的控制电路来实现负载在不同的电压相位角下通电。在识别过程中，没有负载同时通电。此外，还假设平台工作负荷的配电系

统是稳定的。该实验执行 108 次单负载电流测量，三个负荷各测量 36 次。同时，42 个多负载电流测量数据用于验证。因为不同类型的设备具有不同的内部等效电路，在器具以不同的激励相位角通电时测量的负载电流波形不同，如图 3 所示。

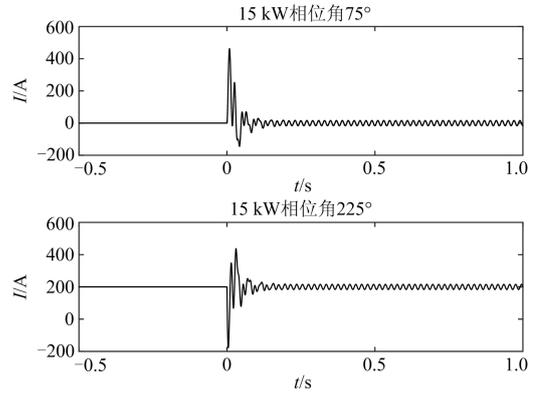


图 3 相位角为 75° 度和 225° 的电流波形

Fig. 3 Current waveforms of 75 degrees and 225 degrees

多负载运行情况下的激励电流波形如图 4 所示。在多负载操作方案中，未识别设备外的所有设备都预先通电。

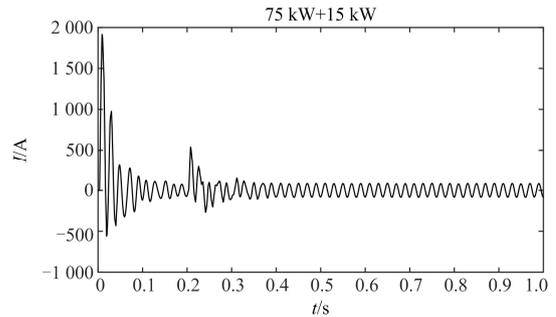


图 4 多负载电流波形

Fig. 4 Current waveforms of multiple-load

3.2 负荷特征提取

本文首先截取单负荷和多负荷暂态电流，如图 5 所示，再用负荷暂态电流计算得到特征值，包括最大值、均方根值及平均值，这些特征值都可以作为 LS，为负荷识别提供重要的依据。

图 6 显示了特征空间中不同类型负荷特征数据的总体分布。在该图中，负荷通过仿真电路来控制不同激励相位角通电时，进而获得空间中的每个数据。

3.3 负荷标记结果

本实验中，样本集为随机选择，并且每一类负荷在样本集中至少有一个标记点，形成带有标签的样本集，剩下的数据作为没有标签的样本集。本实验中的错误率由 100 次试验求平均值得到。负荷标记结果如图 7 所示。

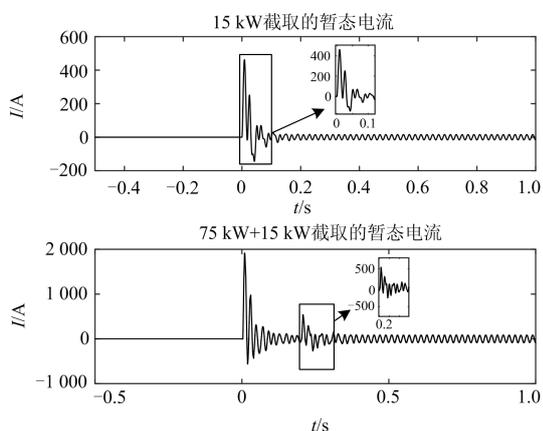


图 5 单负荷和多负荷截取的暂态电流

Fig. 5 Transient current of single-load and multiple-load

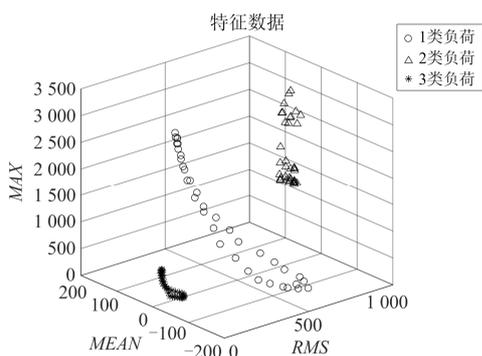


图 6 特征数据

Fig. 6 Feature data

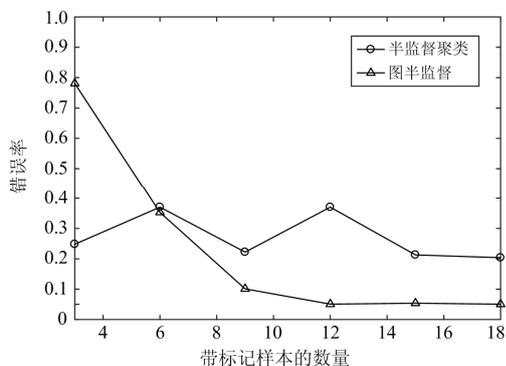


图 7 负荷标记结果

Fig. 7 Result of labeled load

由图 7 可知, 半监督聚类的准确率不再随着带标记样本集数量的增加而发生大幅度变化。因为半监督聚类是由聚类算法加少量标记样本改进而来, 对初始选取的聚类中心点是敏感的, 不同簇中心的聚类结果完全不同。半监督聚类用标记样本来初始化簇中心, 所以标记的准确率比较依靠样本集的选

取。半监督聚类和聚类算法一样, 采用了贪心策略, 通过迭代优化来求解, 所以容易陷入局部最优解。本文实验中半监督聚类的标记效果如图 8 所示。

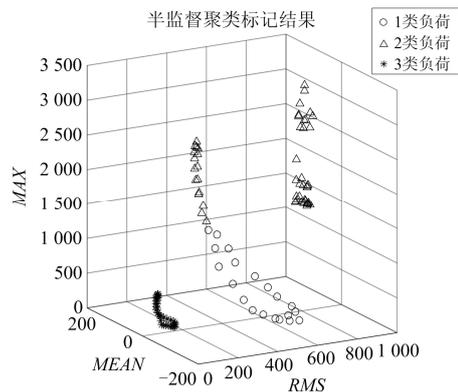


图 8 半监督聚类标记结果

Fig. 8 Labeled result of semi-supervised clustering methods

由图 8 可知, 1 类负荷上半部分数据被错误标记为 2 类负荷, 2 类负荷的簇中心落在了 1 类负荷上半部分和 2 类负荷之间。簇中心陷入了局部最优解。并且随着带标记样本的增多, 并没有得到改善。

而图半监督算法的错误率随着带标记样本的数量逐渐降低, 由图 7 可以看到错误率在 0.05 左右。图半监督算法在本实验中相对于半监督聚类算法, 精度较高、性能更加稳定, 最大程度发挥了监督信息的作用。图半监督算法认为在相同结构中的点有可能有相同的标签, 所以图半监督算法是从数据的全局结构来标记未带标签样本。图半监督算法的结果如图 9 所示。

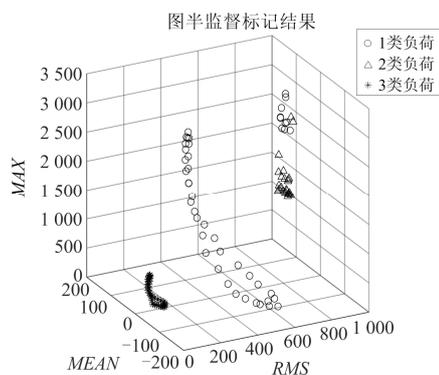


图 9 图半监督标记结果

Fig. 9 Labeled result of GBSSL

可以看到 2 类负荷的上半部分少量数据被错误分类为 1 类负荷。但本文实验中随着带标记样本的数量增多, 2 类负荷被错误标记样本的数量逐渐减少。

3.4 图半监督与 GRNN 结合算法的负荷识别仿真结果分析

将图半监督算法所标记好的单负荷启动样本集加入到 GRNN 中进行负荷识别训练。将图半监督分别标记好的 108 次单负荷数据集、69 样本集用于培训，其余 39 个测量用于验证。此外，还有 42 个多负载电流测量用于验证。单负荷和多负荷识别率随带标记样本的数量变化如图 10 所示。

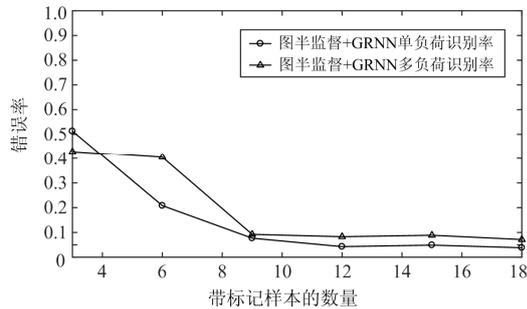


图 10 图半监督+GRNN 负荷识别结果

Fig. 10 Load identification results of GBSSL+GRNN

由图 10 可以看到，本文所提出的负荷识别算法随着带标记样本数量的增加，错误率不断减小。该算法对单负荷启动的识别率高于多负荷启动。单负荷的识别率随着带标记样本的数量增加，错误率稳定在 0.05 左右，而多负荷的识别错误率稳定在 0.08 左右。本文还分别采用图半监督算法、图半监督与 GRNN 结合算法对测试集样本进行识别测试，总体准确率如图 11 所示。

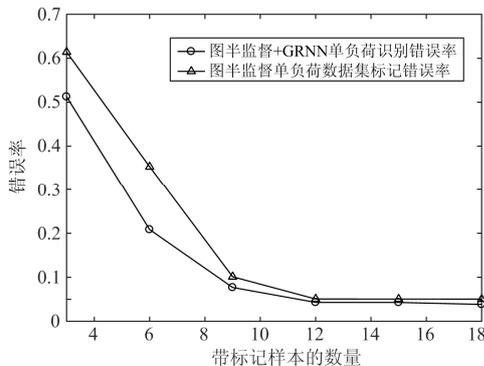


图 11 两种方法单负荷识别结果

Fig. 11 Load identification results of two algorithms

随着带标记样本数量的增加，图半监督算法、图半监督与 GRNN 结合算法对单负荷的识别错误率呈下降趋势。当带标记样本数量大于 12 时，错误率均趋于平稳，但图半监督与 GRNN 结合算法的准确率略高于图半监督算法。单纯的图半监督判别新样本时，需要对图进行重构。而结合算法的 GRNN

部分训练完成后，不需要调整网络中各项参数，可以直接对未知数据进行分类，不增加存储开销，可处理大规模数据。上述实验结果表明，图半监督算法的缺陷较为明显，一方面，存储开销较大，很难直接处理大规模数据。另一方面，其构图过程仅能考虑训练样本集，难以判断新样本在图中的位置。而本文所提出的图半监督与 GRNN 结合算法较好地解决了以上图半监督算法存在的问题。

4 结论

本文针对海洋平台缺少负荷实时智能管理和监测的问题，提出结合图半监督学习与 GRNN 的工业负荷识别算法，不仅减少了人工干预，还保证了较高精度的识别率。通过仿真获取到海洋平台负荷的暂态电流数据，提取负荷特征，并将所提算法的图半监督学习部分与半监督聚类算法进行分析比较，结果表明图半监督学习精度更高，性能更加稳定。将图半监督学习与 GRNN 相结合用于海洋平台负荷识别，既可以减少人工干预，又比单纯的图半监督学习算法具有更低的错误率，同时也避免了图半监督算法难以处理大规模数据和不能直接判断新样本类别的问题。研究成果为 NILM 在工业负荷识别提供了一种新的识别方法，为进一步分析工业负荷用电提出智能用电策略。

参考文献

- [1] 林湘宁, 陈冲, 周旋, 等. 远洋海岛群综合能量供给系统[J]. 中国电机工程学报, 2017, 37(1): 98-110.
LIN Xiangning, CHEN Chong, ZHOU Xuan, et al. Integrated energy supply system of pelagic clustering islands[J]. Proceedings of the CSEE, 2017, 37(1): 98-110.
- [2] 张安安, 黄维维, 杜振华, 等. 海洋平台微电网电压稳定性评估[J]. 中国海上油气, 2016, 28(4): 143-148.
ZHANG An'an, HUANG Weiwei, DU Zhenhua, et al. Assessment of voltage stability for offshore platform micro-grids[J]. China Offshore Oil and Gas, 2016, 28(4): 143-148.
- [3] 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述[J]. 电网技术, 2016, 40(10): 3108-3117.
CHENG Xiang, LI Linzhi, WU Hao, et al. A survey of the research on non-intrusive load monitoring and disaggregation[J]. Power System Technology, 2016, 40(10): 3108-3117.
- [4] 肖江, AUGER F, 荆朝霞, 等. 基于贝叶斯信息准则的非侵入式负荷事件检测算法[J]. 电力系统保护与控制, 2018, 46(22): 8-14.
XIAO Jiang, AUGER F, JING Zhaoxia, et al. Non-intrusive load event detection algorithm based on Bayesian information criterion[J]. Power System Protection and

- Control, 2018, 46(22): 8-14.
- [5] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [6] TSAI M, LIN Y. Modern development of an adaptive non-intrusive appliance load monitoring system in electricity energy conservation[J]. Applied Energy, 2012, 96: 55-73.
- [7] 宋旭帆, 周明, 涂京, 等. 基于 k-NN 结合核 Fisher 判别的非侵入式负荷监测方法[J]. 电力自动化设备, 2018, 42(6): 73-80.
SONG Xufan, ZHOU Ming, TU Jing, et al. Application of demand side management in smart grid[J]. Electric Power Automation Equipment, 2018, 42(6): 73-80.
- [8] YANG C C, SOH C S, YAP V V. A non-intrusive appliance load monitoring for efficient energy consumption based on Naive Bayes classifier[J]. Sustainable Computing: Informatics and Systems, 2017, 14: 34-42.
- [9] LAI Y, LAI C, HUANG Y, et al. Multi-appliance recognition system with hybrid SVM/GMM classifier in ubiquitous smart home[J]. Information Sciences, 2013, 230: 39-55.
- [10] PARSON O, GHOSH S, WEAL M, et al. An unsupervised training method for non-intrusive appliance load monitoring[J]. Artificial Intelligence, 2014, 217: 1-19.
- [11] ZOHA A, GLUHAK A, IMRAN M A, et al. Non-intrusive load monitoring approaches for disaggregated energy sensing: a survey[J]. Sensors, 2012, 12(12): 16838-16866.
- [12] 祁兵, 程媛, 武昕. 基于 Fisher 有监督判别的非侵入式居民负荷辨识方法[J]. 电网技术, 2016, 40(8): 2484-2491.
QI Bing, CHENG Yuan, WU Xin. Non-intrusive household appliance load identification method based on fisher supervised discriminant[J]. Power System Technology, 2016, 40(8): 2484-2491.
- [13] BASU S, BANERJEE A, MOONEY R. Semi-supervised clustering by seeding[C] // Proceedings of the 19th International Conference on Machine Learning, 2002: 19-26.
- [14] ZHOU D Y, BOUSQUET O, LAL T N, et al. Learning with local and global consistency[C] // Proceeding of Advances in Neural Information Processing Systems, Cambridge: MIT Press, 2003: 321-328.
- [15] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
- [16] 吴梦麟, 陈强, 孙权森. 基于图半监督学习的医学图像检索[J]. 计算机辅助设计与图形学学报, 2013, 9: 1354-1360.
WU Menglin, CHEN Qiang, SUN Quansen. Medical image retrieval by graph-based semi-supervised learning[J]. Journal of Computer-Aided Design and Computer Graphics, 2013, 9: 1354-1360.
- [17] 毛盾, 邢昌凤, 黎铁冰, 等. 基于图的半监督目标跟踪[J]. 系统工程与电子技术, 2016, 38(2): 450-456.
MAO Dun, XING Changfeng, LI Tiebing, et al. Graph-based semi-supervised learning for object tracking[J]. Systems Engineering and Electronics, 2016, 38(2): 450-456.
- [18] 张旭博, 徐颖, 张婷颖, 等. 基于 GRNN 建立开孔型多孔玻璃吸声性能模型[J]. 西北工业大学学报, 2019, 37(1): 57-62.
ZHANG Xubo, XU Ying, ZHANG Tingying, et al. Building sound absorption performance model of Porous glass based on GRNN[J]. Journal of Northwestern Polytechnical University, 2019, 37(1): 57-62.
- [19] 喻华, 卢继平, 曾燕婷, 等. 基于不同优化准则和广义回归神经网络的风电功率非线性组合预测[J]. 高电压技术, 2019, 45(3): 1002-1008.
YU Hua, LU Jiping, ZENG Yanting, et al. Nonlinear combined model for wind power forecasting based on different optimization criteria and generalized regression neural network[J]. High Voltage Engineering, 2019, 45(3): 1002-1008.
- [20] 周润景. 模式识别与人工智能[M]. 北京: 清华大学出版社, 2018.
- [21] 谢文旺, 孙云莲, 易仕敏, 等. 一种基于改进 VPGA 优化 Elman 神经网络的电力线通信数据处理算法[J]. 电力系统保护与控制, 2019, 47(6): 58-65.
XIE Wenwang, SUN Yunlian, YI Shimin, et al. A data processing algorithm for power line communication based on Elman neural network optimized by improved VPGA[J]. Power System Protection and Control, 2019, 47(6): 58-65.
- [22] 李鑫, 孟亨, 杨楨, 等. 基于 BP 神经网络递推积分 PI-重复控制在微电网 APF 中的研究[J]. 电力系统保护与控制, 2019, 47(6): 132-140.
LI Xin, MENG Heng, YANG Zhen, et al. Research on recursive integral PI-repetitive control based on BP neural network in micro-grid APF[J]. Power System Protection and Control, 2019, 47(6): 132-140.

收稿日期: 2019-05-19; 修回日期: 2019-08-22

作者简介:

张安安(1977—), 男, 博士, 教授, IEEE 会员, 青年专家, 研究方向为电压无功优化, 海上电气系统控制; E-mail: ananzhang@swpu.edu.cn

庄景泰(1993—), 男, 硕士研究生, 研究方向为非侵入式负荷监测技术;

郭红鼎(1977—), 男, 高级工程师, 研究方向为智能电网控制。

(编辑 许威)