

•信息工程•

DOI:10.12454/j.jsuese.202201264



本刊网刊

## 基于在线自组织增量学习的非侵入式负荷识别方法

胡正伟, 王志红\*, 畅瑞鑫, 谢志远, 曹旺斌

(华北电力大学 电子与通信工程学院, 河北 保定 071003)

**摘要:** 随着电子技术智能化的发展, 对实现电器负荷使用情况的精准识别在智慧用电领域将有广泛的用户需求。为了实现对电器设备的实时在线精确监测, 本文提出了一种基于在线自组织增量学习(SOINN)的非侵入式负荷识别方法。该方法包含负荷特征提取、负荷特征分类及电器识别2个步骤。在负荷特征提取步骤中, 提出了包含奇次谐波、均值、方差、3阶矩、4阶矩、电流有效值、功率谱峰值、功率谱谷值在内的共12维特征的特征提取方案。在负荷特征分类及电器识别步骤中, 提出了结合SVM的SOINN的负荷特征分类及电器识别方法, 以克服传统的SOINN算法不能实现电器类型识别功能的缺陷。通过C++语言将所提方法中的功能算法编写成微处理器系统的可执行功能模块, 将功能模块移植部署在SoC FPGA的HPS端运行, 实现了FPGA和HPS之间的协同高速数据通信。选取了8种常规家用电器作为负荷识别对象, 搭建了基于SoC FPGA的硬件实验平台, 进行了最优负荷特征选取, 并采用本文方法对单电器与多电器的在线负荷进行了识别。实验结果: 选取12维特征为本文方法的最优特征组合; 本文方法的单电器与多电器的识别率均在95%以上。本文提出的负荷识别方法能够有效、准确地识别单电器与多电器; 系统可实施性强, 灵活性高, 具有在线学习的优越性与实际应用的切实可行性。

**关键词:** 增量学习; 负荷识别; 12维样本特征; FPGA

**中图分类号:** TN743

**文献标志码:** A

**文章编号:** 2096-3246(2024)04-0316-09

电器负荷智慧用电是实现电力需求侧管理的先决条件<sup>[1]</sup>, 监测用户内部每种电器的详细运行状况, 来获取每种家用电器负荷的用电行为及电量消耗情况等信息数据<sup>[2]</sup>, 以提升高效实时监测家用电器的工作状态数字化和信息化的程度<sup>[3]</sup>。以往家用电器负荷的监测主要是对总负荷数据进行采集, 如果对家用电器的每一种电器设备的运行状况均能实现在线监测与识别, 这对整个电网的经济、高效运行及未来社会的建设与规划都具有重要的现实意义, 如何实现灵活、交互的智慧用电是当前电力系统的一项重要研究方向。

近年来, 已有不少学者利用非侵入式负荷识别方法开展了研究。非侵入式负荷监测(non-intrusive load monitoring, NILM)技术能够对电力系统中的整体负荷数据进行分析与辨识<sup>[4]</sup>, 从而可以获得更精细

化的电器内部负荷使用状况和类型信息<sup>[5]</sup>, 在一定程度上降低了传统侵入式负荷监测设备安装复杂、管理与维护难等问题, 也降低了对用户生活和企业生产方面的干扰<sup>[6-7]</sup>。祁兵等<sup>[8]</sup>提出了一种利用动态时间弯曲(DTW)算法识别非侵入式负荷的辨识方法, 但是, 其在测量稳态波形时对电压有严格要求且对小电流设备的工作状态容易误判。Yang等<sup>[9]</sup>采用局部均值分解算法(LMD)对低维负荷特征进行分解, 利用KNN方法建立非侵入式负荷识别模型, 但是, KNN的 $k$ 值及LMD的分解维数都需要根据经验得到, 存在不确定性。陈张平等<sup>[10]</sup>结合高频电信号采集器、网络传输平台等硬件设备搭建了非侵入式电信号采集装置, 但是, 必须要依赖于高频的数据采集模块、高效率的数据传输模块才可以实现

非侵入式电器负荷识别是通过用电数据采集装

收稿日期:2022-11-18 修回日期:2023-05-10 网络出版日期:2024-07-10

基金项目:国家自然科学基金面上项目(52177083); 国家自然科学基金青年科学基金项目(62001166)

作者简介:胡正伟(1978—), 男, 副教授, 博士。研究方向:智能电网通信技术。E-mail: hzwward@hotmail.com

\*通信作者:王志红, E-mail: 1562197303@qq.com

置和通信网络进行特征提取<sup>[11-12]</sup>,采用神经网络算法进行负荷辨识,从而实现电器负荷的非侵入式识别与监测<sup>[13]</sup>。耿赫男等<sup>[14]</sup>提出一种基于人工神经网络的非侵入式负荷识别模型,用于判断家用电器的的工作状态,但是,难以形成具有处理复杂网络的判别函数和分类平台。朱昊等<sup>[15]</sup>设计了低复杂度的快速滤波算法和基于最小二乘的电器负荷状态监测方法,但是,其只用于单电器识别。裘星等<sup>[16]</sup>提出了一种基于V-I轨迹矩阵、高次谐波及功率等多特征融合的负荷辨识方法,但是,该方法的模型训练识别都在线下完成,缺少了在线的实时性。

针对实际应用的需求化和满足用户实际智能在线负荷的用电,本文提出了一种基于在线自组织增量学习神经网络(self-organizing incremental neural network, SOINN)的非侵入式电器负荷识别方法。本文方法主要包含负荷特征提取、负荷特征分类及电器识别2个步骤:

1)提出了基于包括5种奇次谐波、均值、方差、3阶矩、4阶矩、电流有效值、功率谱峰值、功率谱谷值在内的共12维特征作为在线自组织增量学习神经网络的学习样本,并选取最优特征组合,提高了负荷的识别效率,以及更精细化地实现提取电器负荷信息;

2)提出了结合SVM的SOINN的负荷特征分类及电器识别方法,可以自适应地建立网络的拓扑结构,并对源源不断到来的数据进行有效的信息提取和压缩。并且,可以在线快速动态更新同时,有助于发现新的电器类型,进一步结合SVM标签分类器,进行电器种类的识别,有效降低运算存储开销,使模型更加稳定。

通过搭建基于FPGA的负荷识别系统,实现了本文方法对家用电器设备运行状况进行在线增量式监测。本文方法可以识别单电器和多电器类型,并且识别准确率高,能够高效实时监测与智能管控家用电器。

## 1 方法

本文提出基于在线自组织增量学习的非侵入负荷识别方法,首先,通过电流互感器采集实时电流数据;然后,基于电流采样数据,完成负荷特征提取;最后,基于改进的在线自组织增量学习算法完成负荷的分类和识别。

按照数据的处理流程,本文方法可以划分为2个主要步骤:1)负荷特征提取,选取最优特征组合;2)基于SOINN+SVM的在线电器负荷类型识别分类和识别:利用SOINN算法具有既能从新数据中学习新知识又能够保留旧知识的特性,使得本文方法具有在线负荷识别及动态更新的能力,可以在线实时

实现负荷分类及发现新的电器设备,但是,SOINN算法只能实现负荷的分类,无法实现每类负荷情况下电器类型的识别,因此,本文加入了SVM标签分类器,可以成功识别当前负荷下工作的电器的类型。

### 1.1 负荷特征提取

非侵入式负荷识别与侵入式负荷识别的区别在于不能直接测量电压电流计算功率,因此,需要先采用电流互感器分别采集每种电器的电流数据信息,再对电流数据信息进行时频域特性分析,选取具有代表性的特征参量作为电器负荷识别的特征数据。

本文选取电流参数的12维度特征量作为用电器负荷识别特征,并进行编号,便于进行最优特征组合时的研究,如表1所示。

表1 12维样本特征

| 特征编号           | 12维样本特征      |
|----------------|--------------|
| $Q_1 \sim Q_5$ | 1、3、5、7、9次谐波 |
| $Q_6$          | 均值           |
| $Q_7$          | 方差           |
| $Q_8$          | 3阶中心矩阵       |
| $Q_9$          | 4阶中心矩阵       |
| $Q_{10}$       | 电流有效值        |
| $Q_{11}$       | 功率谱峰值        |
| $Q_{12}$       | 功率谱谷值        |

表1中,12维特征可以分为奇次谐波特征、统计量特征、电流有效值特征、功率谱特征4类,具体如下。

1)奇次谐波分量特征。在平衡的三相电力系统中,由于对称关系,偶次谐波被消除,以奇次谐波为主,所以取1、3、5、7、9奇次谐波作为特征量。式(1)为谐波分量的计算表达式,对应编号为 $Q_1 \sim Q_5$ 的特征。

$$Q_{(k+1)/2} = x_k \sin(k\omega t + \theta_k); k \in [1, 3, 5, 7, 9] \quad (1)$$

式中, $x_k$ 为电流 $k$ 次谐波幅值, $\theta_k$ 为电流 $k$ 次谐波相角, $\omega$ 为频率。

2)统计量特征。引入统计量提取每一个采样点负荷的统计量特征,作为负荷特征提取之一,来反映负荷特征的本质统计特性参数。

通过均值 $E(x)$ 、方差 $V(x)$ 、3阶中心矩 $S(x)$ 、4阶中心矩 $K(x)$ 来描述电流信号的重心程度、离散程度、非对称程度、陡峭程度<sup>[17]</sup>。 $E(x)$ 、 $V(x)$ 、 $S(x)$ 、 $K(x)$ 的计算式分别如式(2)~(5)所示,分别对应编号为 $Q_6 \sim Q_9$ 的特征。

$$Q_6 = E(x) = \int_{-\infty}^{+\infty} xf(x)dx = \frac{\sum_{t=1}^N x_t}{N} \quad (2)$$

$$Q_7 = V(x) = \int_{-\infty}^{+\infty} |x - E(x)|^2 dx = \frac{\sum_{t=1}^N (x_t - E(x))^2}{N} \quad (3)$$

$$Q_8 = S(x) = \int_{-\infty}^{+\infty} |x - E(x)|^3 dx = \frac{\sum_{t=1}^N (x_t - E(x))^3}{N} \quad (4)$$

$$Q_9 = K(x) = \int_{-\infty}^{+\infty} |x - E(x)|^4 dx = \frac{\sum_{t=1}^N (x_t - E(x))^4}{N} \quad (5)$$

式(2)~(5)中,  $x_t$ 为电流在第 $t$ 时刻测定的电流瞬时值,  $N$ 为第 $t$ 时刻内的采样点总数量。

3) 电流有效值特征。电流有效值的定义为交流电流瞬时值的平方和在周期中均方根值, 如式(6)所示, 对应编号为 $Q_{10}$ 的特征。

$$Q_{10} = I = \sqrt{\frac{1}{T} \int_0^T x_t^2 dt} \quad (6)$$

式中,  $T$ 为交流电流周期。

4) 功率谱密度特征。功率谱密度可以在频域内提取被淹没在噪声中的有用信息。通过电流数据 $x_t$ 可估计出自相关函数 $R(n)$ , 如式(7)所示。

$$R(n) = \frac{1}{t} \sum_{t=0}^{t-1-|n|} x_t x(t+n) \quad (7)$$

对 $R(n)$ 进行傅里叶变换, 便获得 $x_t$ 的功率谱估计 $P(e^{j\omega})$ , 其中,  $P(e^{j\omega})_{\max}$ 为功率谱峰值,  $P(e^{j\omega})_{\min}$ 为功率谱谷值, 如式(8)所示, 对应编号为 $Q_{11}$ 、 $Q_{12}$ 的特征。

$$\begin{cases} Q_{11} = P(e^{j\omega})_{\max} = \sum_{n=-\infty}^{+\infty} R(n) e^{-j\omega n}, \\ Q_{12} = P(e^{j\omega})_{\min} = \sum_{n=-\infty}^{+\infty} R(n) e^{-j\omega n} \end{cases} \quad (8)$$

式(7)、(8)中,  $R(n) e^{-j\omega n}$ 为电流在第 $n$ 个采样点计算的功率。

## 1.2 基于SOINN+SVM的在线负荷分类及电器负荷类型识别算法

SOINN是一种基于竞争学习的两层神经网络, 用于在没有先验知识的情况下对动态输入数据进行在线聚类 and 拓扑表示<sup>[18]</sup>, 能够实现模拟人类大脑的智能信息处理系统<sup>[19]</sup>。原始的SOINN算法只能实现负荷的分类, 但无法实现每类负荷情况下电器类型的识别。因此, 本文在SOINN的基础上加入了SVM<sup>[20]</sup>标签分类器, 用于识别当前负荷下工作的电器类型, 由此本文提出了SOINN+SVM电器负荷识别算法, 不仅保留了传统SOINN算法的优点, 而且克服了其不

能实现电器设备类型识别的缺陷。SOINN+SVM电器负荷识别算法流程如图1所示。

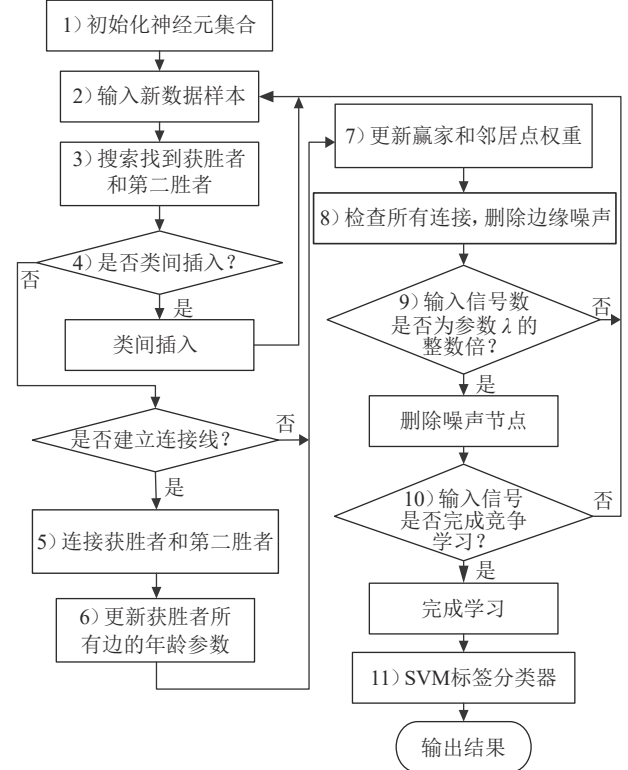


图 1 基于SOINN+SVM电器负荷识别算法步骤流程图  
Fig. 1 SOINN+SVM electrical load identification algorithm step flow chart

SOINN+SVM电器负荷识别算法的具体算法步骤如下:

1) 初始化神经元集合 $N = \{c_1, c_2\}$ , 其中,  $c_1$ 、 $c_2$ 为随机的两个初始数据样本节点, 初始化神经元连接关系集合 $c \in N \times N$ 。

2) 根据本文采集的数据样本特点, 修改输入方式后将其作为一个新的数据样本 $\xi$ 。

3) 搜索找到获胜者和第二胜者, 基于欧氏距离查找 $N$ 中与 $\xi$ 最近的2个神经元 $S_1$  (获胜者)和 $S_2$  (第二获胜者)如式(9)、(10)所示。

$$S_1 = \operatorname{argmin} \|\xi - W_c\|, c \in N \quad (9)$$

$$S_2 = \operatorname{argmin} \|\xi - W_c\|, c \in N \setminus \{S_1\} \quad (10)$$

式中,  $W_c$ 为神经元 $c$ 的权重,  $\setminus$ 表示差集。

4) 判断是否进行类间插入, 计算神经元 $S_1$ 和 $S_2$ 的相似度阈值 $T_{S_1}$ 和 $T_{S_2}$ , 对任意神经元 $c$ , 将 $c$ 的邻居神经元集合记为 $N_c$ ,  $T_c$ 的计算方法如式(11)所示。

$$T_c = \begin{cases} \max_{j \in N_c} \|W_c - W_j\|, N_c \neq \emptyset; \\ \min_{j \in N_c \setminus \{c\}} \|W_c - W_j\|, N_c = \emptyset \end{cases} \quad (11)$$

式中,  $T_c$ 实际上是当前最大类内距离和最小类间距

离的估计值。

5) 连接获胜者和第二胜者,若 $S_1$ 和 $S_2$ 不存在连接关系,则为其建立边的连接关系,即 $c = c \cup \{(S_1, S_2)\}$ ,并将 $S_1$ (获胜者)和 $S_2$ (第二获胜者)连接的年龄设置为0,即 $A_{(S_1, S_2)} = 0$ ,从而刷新边 $\{S_1, S_2\}$ 的年龄参数,其中, $A_{(S_1, S_2)}$ 为 $S_1$ 和 $S_2$ 间的年龄参数。

6) 更新 $S_1$ (获胜者)所有边的年龄参数,即 $A_{(S_1, i)} = A_{(S_1, i)} + 1, \forall i \in N_{S_1}$ ,其中, $N_{S_1}$ 为 $S_1$ 的所有邻居神经元,也就是说, $S_1$ 与相连的所有边的年龄都增加1。

7) 更新获胜神经元权重和其邻居点的权重如式(12)、(13)所示。

$$W_{S_1} = W_{S_1} + \varepsilon(t)(\xi - W_{S_1}) \quad (12)$$

$$W_i = W_i + \varepsilon'(t)(\xi - W_i) \quad (13)$$

式(12)、(13)中: $\varepsilon(t)$ 为赢家的学习率, $\varepsilon(t) = 1/t$ ; $\varepsilon'(t)$ 为邻居的学习率, $\varepsilon'(t) = 1/(100t)$ ; $t$ 为神经元从训练开始截至目前的获胜次数。

8) 检查所有连接 $(i, j) \in c$ 当前年龄参数 $A_{(i, j)}$ ,如果神经元的年龄参数大于预定值,即 $A_{(i, j)} > A_{\max}$ ,

$c = c \setminus \{(i, j)\}$ ,其中, $A_{\max}$ 为预定义参数,则执行删除边缘噪声操作,从 $c$ 移除该连接。

9) 如果当前输入的数据样本总数是参数 $\lambda$ 的整数倍,对于 $N$ 中的所有节点,查找没有邻居或只有一个邻居的节点,删除这部分节点。并根据本文实际数据特征不断调整 $\lambda$ ,找到最佳参数 $\lambda$ 数值。

10) 若竞争学习未结束,则返回步骤2);若竞争学习结束,进入步骤11)。

11) 训练SVM模型,调整参数,找到一个最优的超平面,将不同类别的数据分开,输出分类结果。

## 2 系统实现

### 2.1 系统硬件构架

基于SoC FPGA电器负荷在线识别平台的硬件构架如图2所示。硬件使用Terasic的DE10-Nano SoC FPGA开发板, Cyclone V SE5CSEB-A6U2317NDK芯片,结合了高性能的双核ARM Cortex-A9 CPU。选定ZMCT103C电流互感器模块作为交流电流数据采集设备。

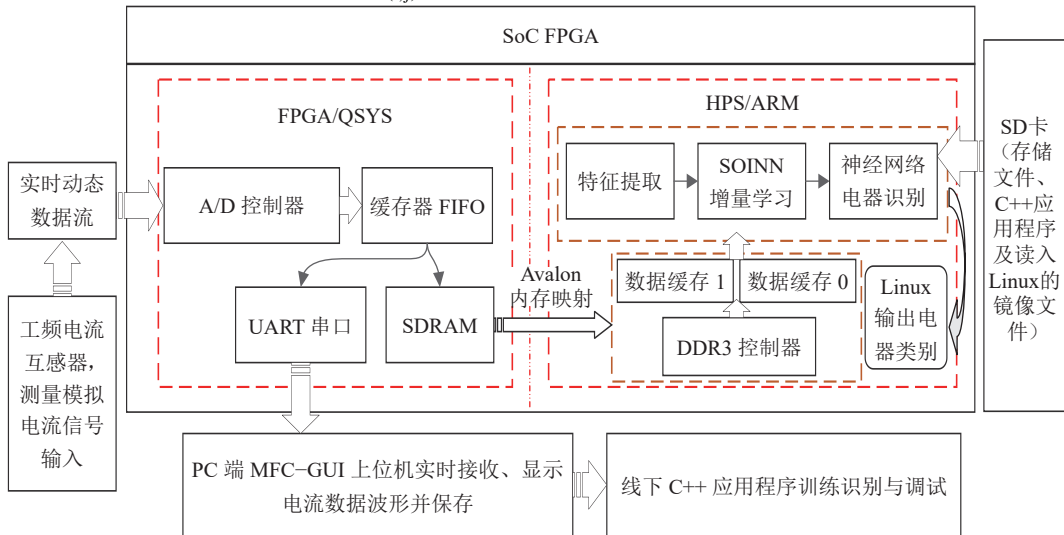


图2 系统的硬件框架

Fig. 2 Hardware architecture of System

首先,先运行硬核处理器系统(HPS),并启动Linux操作系统,HPS支持从microSD卡存储器启动。然后,在Quartus Prime18.1软件平台上,搭建Avalon总线来控制各模块,主要模块为:A/D转换模块、FIFO缓存模块、UART发送模块、SDRAM与DDR3读写控制通信模块,以及数据接口协议模块等。之后,采用PingPong数据流处理方式实现数据在Linux操作系统中的读取。最后,设计HPS系统程序的功能模块,实现非侵入式用电器负荷类别的在线增量学习识别系统。

### 2.2 系统的软件设计

首先,按照Avalon总线协议将采集的代表负荷状

态的电流数据传输到Linux接口端。然后,通过VS2019软件平台使用C++语言编写Linux的可执行功能模块,包括:1)提取代表性的负荷样本特征量模块;2)采用SOINN在线增量式学习电荷特征数据模块;3)通过SOINN+SVM在线识别电器类型模块。相较于传统方法,应用在线增量学习机制,可以动态更新检测模型,在自适应获取新知识的同时,保留旧知识,调整和强化算法模型自身参数。训练好的SOINN可以在线识别分类,但是,不能识别出设备的具体类型,所以,本文提出SOINN+SVM识别算法,以实现自组织增量神经网络模型的在线电器负荷识别。系统的软件设计

流程如图3所示。

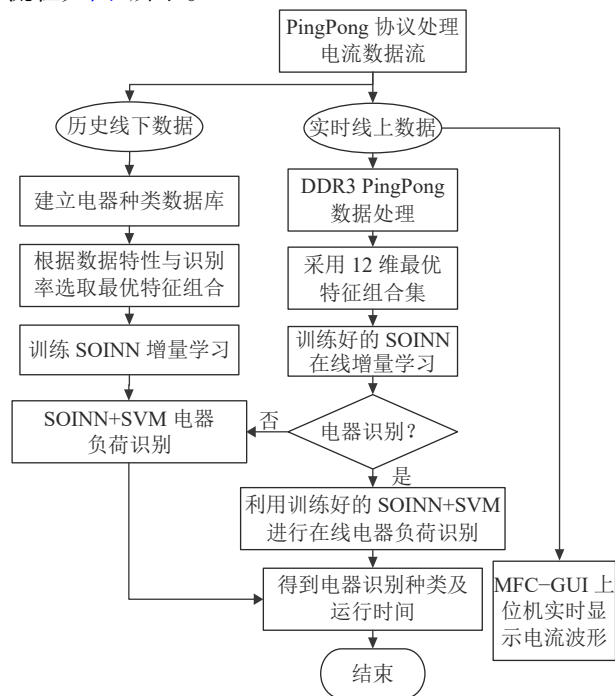


图 3 软件设计流程图

Fig. 3 Software flow chart

### 3 实验及结果分析

#### 3.1 搭建识别平台

基于本文设计的负荷特征提取和SOINN+SVM电器负荷识别算法,搭建了不同电器在线识别平台环境,连接电流互感器、DE10-Nano开发板、电器设备和计算机。电器负荷在线识别平台实物如图4所示。



图 4 电器负荷在线识别平台

Fig. 4 Platform for online load identification

选取了8种常用家用电器并编号,如表2所示。采用电流互感器分别采集每种电器的电流信息数据。

依次将电器单独使用和多个电器设备同时组合使用,便可进行一边在线实时显示电流波形,一边显示此时波形的电器负荷在线识别测试。

表 2 电器种类

Tab. 2 Types of electrical appliances

| 电器编号 | 电器名称 | 额定电压/V | 额定功率/W |
|------|------|--------|--------|
| 1    | 台灯   | 220    | 20     |
| 2    | 暖手宝  | 220    | 700    |
| 3    | 电风扇  | 220    | 30     |
| 4    | 热水壶  | 220    | 800    |
| 5    | 电饭锅  | 220    | 1000   |
| 6    | 电脑   | 220    | 200    |
| 7    | 吹风机  | 220    | 1200   |
| 8    | 加湿器  | 220    | 40     |

#### 3.2 最优负荷特征选取

为了对电器负荷特征集进行寻优搜索,获得识别率最优的电器负荷特征集,进行了最优负荷特征选取实验。采用SOINN+SVM的特征选择算法,每种电器组合实验100次。本文方法随机选取的部分不同特征组合如表3所示,表3中不同特征组合的单电器与多电器的识别率如图5所示。图5中,电器设备识别率为识别分类正确的结果占测试总数的比值。

表 3 随机选取不同特征组合

Tab. 3 Random selection of different feature combinations

| 特征组合编号 | 特征组合  |
|--------|---|
| 1      | $Q_1, Q_2, Q_3, Q_4, Q_5$   |
| 2      | $Q_6, Q_7, Q_8, Q_9$  |
| 3      | $Q_{10}, Q_{11}, Q_{12}$  |
| 4      | $Q_1, Q_2, Q_3, Q_6, Q_7, Q_8, Q_9$                                   |
| 5      | $Q_6, Q_7, Q_8, Q_9, Q_{10}, Q_{11}, Q_{12}$                          |
| 6      | $Q_1, Q_2, Q_3, Q_4, Q_5, Q_{10}, Q_{11}, Q_{12}$                     |
| 7      | $Q_1, Q_2, Q_3, Q_4, Q_5, Q_6, Q_7, Q_8, Q_9$                         |
| 8      | $Q_1, Q_2, Q_3, Q_4, Q_6, Q_7, Q_8, Q_9, Q_{10}$                      |
| 9      | $Q_1, Q_2, Q_6, Q_7, Q_8, Q_9, Q_{10}, Q_{11}, Q_{12}$                |
| 10     | $Q_1, Q_2, Q_3, Q_4, Q_6, Q_7, Q_8, Q_9, Q_{10}, Q_{11}, Q_{12}$      |
| 11     | $Q_1, Q_2, Q_3, Q_6, Q_7, Q_8, Q_9, Q_{10}, Q_{11}, Q_{12}$           |
| 12     | $Q_1, Q_2, Q_3, Q_4, Q_5, Q_6, Q_7, Q_8, Q_9, Q_{10}, Q_{11}, Q_{12}$ |

由图5可知:不同的特征组合的识别效果不同。由于多电器的使用情况种类比单电器更加复杂,所以选择不同的特征组合的多电器的总识别率比选择不同特征组合的单电器的总识别率差异更大。不同特征组合的单电器识别中,当特征组合为 $Q_1 \sim Q_9$ (编号7)时,单电器的总识别率最高为98.750%;当特征选择为 $Q_1 \sim Q_{12}$ (编号12)时,单电器的总识别率为97.875%,其总识别率差异较小。不同特征组合的多电器识别中,当特征选择维度为 $Q_1 \sim Q_{12}$ (编号12)时,在图5中多电器的总识别率最高为97.933%;当特征选择为 $Q_{10} \sim Q_{12}$ (编号3)时,多电器进行特征选择

后总识别率最高可以为42.496%,其差异性较大;最终选取上述12维特征样本组合 $Q_1 \sim Q_{12}$ (编号12)进行用电器负荷识别时,单电器和多电器的总识别率均能达到97%及以上,所以选取上述12维特征样本组合(编号12)是最优特征组合。




图5 选取的不同特征组合的识别率

Fig. 5 Recognition rate of different feature combinations

### 3.3 单电器负荷识别

采用表2的8种电器设备, A/D采样频率为10 kHz, 每次读取1 024个数据流, 每种电器设备单独接入并记录识别成功次数, 测量200次。随机选取台灯为示例, 采用本文方法的单电器负荷实时在线识别如图6所示。

```
COM3 - PuTTY
all time = 0.067496 s
Feature extraction time = 0.06531 s
identification results: 1 class
soinn time = 0.00052 s
all time = 0.067489 s
Feature extraction time = 0.065215 s
identification results: 1 class
soinn time = 0.000469 s
all time = 0.067429 s
Feature extraction time = 0.065302 s
identification results: 1 class
soinn time = 0.000517 s
all time = 0.067554 s
Feature extraction time = 0.06529 s
identification results: 1 class
soinn time = 0.000501 s
all time = 0.067554 s
Feature extraction time = 0.065294 s
identification results: 1 class
soinn time = 0.000504 s
all time = 0.067452 s
Feature extraction time = 0.065393 s
identification results: 1 class
soinn time = 0.000516 s
all time = 0.067602 s
Feature extraction time = 0.065266 s
identification results: 1 class
soinn time = 0.000491 s
all time = 0.067422 s
Feature extraction time = 0.065321 s
identification results: 1 class
soinn time = 0.00052 s
all time = 0.067551 s
```

图6 单电器负荷在线识别示例

Fig. 6 Example of single appliance load online identification

由图6可知, 本文方法实现了不间断实时数据流形式的在线单电器负荷识别分类, 耗时约为0.065 s。

采用SOINN结合不同标签分类器, 验证本文提出的SOINN+SVM电器负荷识别算法是否为最优算法。除了本文的SOINN+SVM标签分类器外, 随机选择SOINN+BP<sup>[21]</sup>、SOINN+GA-BP<sup>[22]</sup>、SOINN+PSO-BP<sup>[23]</sup>、SOINN+GA-SVM<sup>[24]</sup>、SOINN+PSO-SVM<sup>[25]</sup>这5种标签分类器。采用不同标签分类器识别表2的8种电器设备的对比测试结果如图7所示。绘制不同分类器的耗时如表4所示。

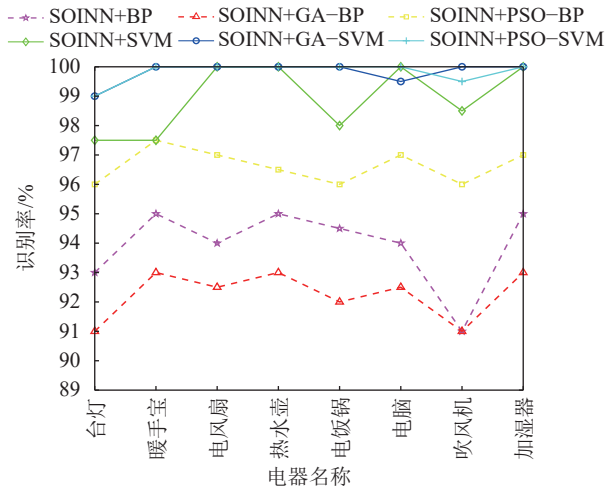


图7 不同标签分类器的单电器识别测试结果

Fig. 7 Test results of single appliance recognition for different label classifiers

表4 不同分类器的耗时

Tab. 4 Time consuming for different classifiers

| 标签分类器         | 耗时/s  |
|---------------|-------|
| SOINN+BP      | 0.069 |
| SOINN+GA-BP   | 1.899 |
| SOINN+PSO-BP  | 2.884 |
| 本文的SOINN+SVM  | 6.294 |
| SOINN+GA-SVM  | 8.603 |
| SOINN+PSO-SVM | 9.054 |

由图7、表4可知: 所有方法的识别率在90%以上。虽然, SOINN+BP、SOINN+GA-BP、SOINN+PSO-BP的耗时低于SOINN+SVM、SOINN+GA-SVM、SOINN+PSO-SVM, 但是, SOINN+SVM、SOINN+GA-SVM、SOINN+PSO-SVM的识别率高于SOINN+BP、SOINN+GA-BP、SOINN+PSO-BP的识别率且相对稳定, SOINN+SVM的识别率为96%以上, 且SOINN+SVM比SOINN+GA-SVM、SOINN+PSO-SVM的运算复杂度较小, 运行速度相对较快。所以, 本文提出的SOINN+SVM电器负荷识别算法为最优算法。本文方法的单电器识别效果较好, 运行速度较快, 满足设计使用需求。

### 3.4 多电器负荷识别

不同种类的电器设备电流波形各有特点,在多个用电设备同时使用时,用电设备各周期的波形基本相同,使用本文方法进一步实现对同时使用的多个用电设备识别。采用训练好的SOINN+SVM电器负荷识别算法,采样频率为10 kHz,每次读取1024个数据,测量100次,分别测试表2中各电器组合运行。随机选取台灯、暖手宝、电饭锅、电脑、加湿器组合示例,采用本文方法的多电器负荷实时在线识别如图8所示。随机选取表2中部分电器组合的识别结果如表5所示。

```

COM3 - PuTTY
soinn time = 0.000491 s
all time = 7.3171 s
identification results: 1,2,5,6,8 class
Feature extraction time = 0.065397 s
soinn time = 0.000482 s
all time = 7.28298 s
identification results: 1,2,5,6,8 class
Feature extraction time = 0.065421 s
soinn time = 0.00047 s
all time = 7.27729 s
identification results: 1,2,5,6,8 class
Feature extraction time = 0.065481 s
soinn time = 0.000494 s
all time = 7.26322 s
identification results: 1,2,5,6,8 class
Feature extraction time = 0.065476 s
soinn time = 0.000476 s
all time = 7.28867 s
identification results: 1,2,5,6,8 class
Feature extraction time = 0.06543 s
soinn time = 0.000481 s
all time = 7.26244 s
identification results: 1,2,5,6,8 class
Feature extraction time = 0.065418 s
soinn time = 0.000489 s
all time = 7.25493 s
identification results: 1,2,5,6,8 class
Feature extraction time = 0.065422 s
soinn time = 0.000475 s
all time = 7.2671 s
identification results: 1,2,5,6,8 class
Feature extraction time = 0.065463 s
soinn time = 0.000478 s
all time = 7.27559 s
identification results: 1,2,5,6,8 class
Feature extraction time = 0.065419 s

```

图 8 多电器负荷在线识别示例

Fig. 8 Example of multi-appliance load online identification

表 5 多电器识别测试结果

Tab. 5 Multi-appliance identification test results

| 电器设备编号组合        | 总识别率/% | 耗时/s |
|-----------------|--------|------|
| 2,3,4           | 100    | 7.26 |
| 1,3,5,7         | 96     | 7.27 |
| 2,3,5,6         | 100    | 7.31 |
| 4,5,6,7,8       | 99     | 7.28 |
| 1,2,5,6,8       | 97     | 7.25 |
| 3,4,5,7,8       | 98     | 7.27 |
| 2,4,5,6,7,8     | 95     | 7.28 |
| 1,2,3,4,5,6     | 97     | 7.29 |
| 1,2,3,4,5,6,8   | 97     | 7.28 |
| 1,2,3,4,5,6,7,8 | 95     | 7.30 |

由图8与表5可知,本文方法实现了不间断实时数据流形式的在线多电器负荷识别分类,耗时约为7.286 s,识别率在95%以上。

为了进一步分析本文所提方法的识别性能,采用准确率(accuracy,记为 $A$ )、误差(error,记为 $E_r$ )、灵敏度(sensitivity,记为 $S_e$ )、精准率(precision,记为 $P_r$ )、假正率(false positive rate,记为 $F$ )、 $F_1$ 指数( $F_1\_score$ ,记为 $F_1$ )6种评价指标和混淆矩阵进行算法性能的评估,各项评价指标的数学表达式如式(14)~(19)所示。

$$A = \frac{\sum_{i=1}^N \frac{P_i + T_i}{P_i + T_i + F_i + H_i}}{N} \quad (14)$$

$$E_r = \frac{\sum_{i=1}^N \frac{H_i + F_i}{P_i + T_i + F_i + H_i}}{N} \quad (15)$$

$$S_e = \frac{\sum_{i=1}^N \frac{P_i}{P_i + H_i}}{N} \quad (16)$$

$$P_r = \frac{\sum_{i=1}^N \frac{P_i}{P_i + F_i}}{N} \quad (17)$$

$$F = \frac{\sum_{i=1}^N \frac{F_i}{F_i + T_i}}{N} \quad (18)$$

$$F_1 = \frac{\sum_{i=1}^N \frac{2P_i^2}{2P_i + F_i + F_i}}{N} \quad (19)$$

式中, $i$ 为表2中1~8类相应电器种类, $N$ 为种类数目, $P_i$ 为*i*类真正例, $T_i$ 为*i*类真负例, $F_i$ 为*i*类假正例, $H_i$ 为*i*类假负例。采用上述6种评价指标综合评估表5的分类结果,如表6所示。

表 6 多电器识别综合评价指标结果

Tab. 6 Electrical identify evaluation index results

| 评价指标      | 指标结果  |
|-----------|-------|
| 准确率 $A$   | 0.974 |
| 误差 $E_r$  | 0.026 |
| 灵敏度 $S_e$ | 0.975 |
| 精准率 $P_r$ | 0.974 |
| 假正率 $F$   | 0.029 |
| $F_1$ 指数  | 0.974 |

由表6可知:多电器识别的准确率、灵敏度、精准率及 $F_1$ 指数均较高,识别分类的误差较小,假正率较

低。通过6种评价指标进一步验证了本文模型的准确率、有效性能较好,误判率较低。因此,本文提出的方法实现了高效识别电器组合中存在的电器种类,识别正确率、有效性及实时性效果均良好,有利于用电器的智能化发展。

## 4 结 论

本文提出了一种基于在线自组织增量学习的非侵入式负荷识别方法,并基于SoC FPGA完成了算法的实现,搭建了测试平台,验证了本文方法的有效性,并兼顾了实际应用的可实施性,为非侵入式负荷的在线识别提供了一种工程实现参考方案。但是,本文方法的电器类型适用范围还具有一定的局限性,后续研究中将对本文方法的适用电器类型和应用领域进行拓展,并将进一步优化SOINN+SVM算法的通用性及神经网络架构,以便更适合于边缘计算设备进行部署,提高方法的实用性。

### 参考文献:

- [1] Cooperman A, Martinez M. Load monitoring for active control of wind turbines[J]. *Renewable and Sustainable Energy Reviews*, 2015, 41: 189–201.
- [2] Yassine A. Implementation challenges of automatic demand response for households in smart grids[C]// *Proceedings of the 2016 3rd International Conference on Renewable Energies for Developing Countries (REDEC)*. Zouk Mosbeh: IEEE, 2016: 1–6.
- [3] Miao Weiwei, Zeng Zeng, Teng Changzhi, et al. Non-invasive load identification method based on the characteristics of residential electrical appliances[C]// *Proceedings of the 2022 5th International Conference on Energy, Electrical and Power Engineering (CEEPE)*. Chongqing: IEEE, 2022: 827–832.
- [4] Cui Can. Study on key technologies in non-intrusive residential load monitoring for intelligent power utilization[D]. Beijing: North China Electric Power University, 2017. [崔灿. 面向智能用电的非侵入式居民负荷监测关键技术研究[D]. 北京: 华北电力大学, 2017.]
- [5] Liu Zheng, Tian Guiyun, Cao Wenping, et al. Non-invasive load monitoring of induction motor drives using magnetic flux sensors[J]. *IET Power Electronics*, 2017, 10(2): 189–195.
- [6] Gang Yining, Liu Xuesong, Tong Donghui, et al. Non-invasive power load monitoring method based on cloud edge collaboration[J]. *IOP Conference Series (Earth and Environmental Science)*, 2020, 512(1): 012115.
- [7] Angelis G F, Timplalexis C, Krinidis S, et al. NILM applications: Literature review of learning approaches, recent developments and challenges[J]. *Energy and Buildings*, 2022, 261: 111951.
- [8] Qi Bing, Dong Chao, Wu Xin, et al. Non-intrusive load identification method based on DTW algorithm and steady-state current waveform[J]. *Automation of Electric Power Systems*, 2018, 42(3): 70–76. [祁兵, 董超, 武昕, 等. 基于DTW算法与稳态电流波形的非侵入式负荷辨识方法[J]. *电力系统自动化*, 2018, 42(3): 70–76.]
- [9] Yang Pengfei, Sun Xianbo, Zhu Li, et al. Non-intrusive load monitoring method based on LMD and KNN algorithm[C]// *Proceedings of the 2021 IEEE International Conference on Electrical Engineering and Mechatronics Technology (ICEEMT)*. Qingdao: IEEE, 2021: 692–698.
- [10] Chen Zhangping, Li Zhen, Shi Yongtao, et al. Design of non-intrusive online load monitoring system[J]. *Research and Exploration in Laboratory*, 2022, 41(2): 50–54. [陈张平, 李真, 施永涛, 等. 非侵入式负荷在线监测系统的设计[J]. *实验室研究与探索*, 2022, 41(2): 50–54.]
- [11] Xia Min, Liu Wanan, Wang Ke, et al. Non-intrusive load disaggregation based on composite deep long short-term memory network[J]. *Expert Systems with Applications*, 2020, 160: 113669.
- [12] Zhou Yajun, Sun Mingyang, Li Pengyun, et al. Research on non-invasive load monitoring based on convolutional neural network[C]// *Proceedings of the 2022 4th International Conference on Communications, Information System and Computer Engineering (CISCE)*. Shenzhen: IEEE, 2022: 472–477.
- [13] Zhang Ruoyuan, Ma Ruoling. Non-invasive load identification method based on ABC-SVM algorithm and transient feature[J]. *Energy Reports*, 2022, 8: 63–72.
- [14] Geng Henan, Liu Li, Pang Xinfu. Non-intrusive residential electric load identification method based on artificial neural network[J]. *Journal of Shenyang Institute of Engineering (Natural Science)*, 2019, 15(3): 236–240. [耿赫男, 刘莉, 庞新富. 基于人工神经网络的非侵入式居民用电负荷识别方法[J]. *沈阳工程学院学报(自然科学版)*, 2019, 15(3): 236–240.]
- [15] Zhu Hao, Yang Huijun, Guo Lihong, et al. Design of embedded NILM power load acquisition and feature database construction system[J]. *Chinese Journal of Electron Devices*, 2021, 44(6): 1421–1428. [朱昊, 杨会军, 郭丽红, 等. 嵌入式NILM电力负荷识别及特征库构建系统设计[J]. *电子器件*, 2021, 44(6): 1421–1428.]
- [16] Qiu Xing, Yin Shihong, Zhang Zhihan, et al. Non-intrusive load identification method based on V-I trajectory and high-order harmonic feature[J]. *Electric Power Engineering Technology*, 2021, 40(6): 34–42. [裘星, 尹仕红, 张之涵, 等. 基于V-I轨迹与高次谐波特征的非侵入式负荷识别方法[J]. *电力工程技术*, 2021, 40(6): 34–42.]
- [17] Shi Fangning, Jing Xiaojun, He Yuan, et al. Classification model of wireless signals based on higher-order statistics[C]// *Proceedings of the 2020 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB)*. Paris: IEEE, 2020: 1–5.
- [18] Lentaris G, Stratakos I, Stamoulias I, et al. High-performance vision-based navigation on SoC FPGA for spacecraft prox-

- imity operations[J].*IEEE Transactions on Circuits and Systems for Video Technology*,2020,30(4):1188–1202.
- [19] Qiu Tianyu, Shen Fura, Zhao Jinxi. Review of self-organizing incremental neural network[J].*Journal of Software*,2016,27(9):2230–2247.[邱天宇,申富饶,赵金熙.自组织增量学习神经网络综述[J].*软件学报*,2016,27(9):2230–2247.]
- [20] Hu Wei, Zhang Weiling, Min Yong, et al. Real-time emergency control decision in power system based on support vector machines[J].*Proceedings of the CSEE*,2017,37(16):4567–4576.[胡伟,张玮灵,闵勇,等.基于支持向量机的电力系统紧急控制实时决策方法[J].*中国电机工程学报*,2017,37(16):4567–4576.]
- [21] He Yuesheng, Ye Chun, Yang Bo, et al. Application research of BP algorithm in fault diagnosis system of power plant[J].*Electric Power Automation Equipment*,2002,22(5):7–9.[何悦盛,叶春,杨波,等.BP网络在电站故障诊断系统中的应用研究[J].*电力自动化设备*,2002,22(5):7–9.]
- [22] Wei Ying, Gao Xuelian. Transmission line galloping prediction based on GA-BP-SVM combined method[J].*IEEE Access*,2021,9:107680–107687.
- [23] Wei Xing, Shu Naiqiu, Zhang Lin, et al. Power transformer fault diagnosis based on improved PSO-BP hybrid algorithm[J].*Electric Power Automation Equipment*,2006,26(5):35–38.[魏星,舒乃秋,张霖,等.基于改进PSO-BP混合算法的电力变压器故障诊断[J].*电力自动化设备*,2006,26(5):35–38.]
- [24] Xiao Bai, Xing Shiheng, Wang Maochun, et al. Prediction method of output power long-term fluctuation characteristic for multiple wind farms after aggregation based on improved KDE method and GA-SVM[J].*Electric Power Automation Equipment*,2022,42(2):77–84.[肖白,邢世亨,王茂春,等.基于改进KDE法和GA-SVM的多风电场聚合后输出功率率长期波动特性预测方法[J].*电力自动化设备*,2022,42(2):77–84.]
- [25] Xu Changlu, Li Linsheng, Li Jiwei, et al. Surface defects detection and identification of lithium battery pole piece based on multi-feature fusion and PSO-SVM[J].*IEEE Access*,2021,9:85232–85239.

## Non-intrusive Load Identification Method Based on the Online Self-organizing Incremental Neural Network

HU Zhengwei, WANG Zhihong\*, CHANG Ruixin, XIE Zhiyuan, CAO Wangbin

(School of Electrical & Electronic Eng., North China Electric Power Univ., Baoding 071003, China)

**Abstract:** With the development of intelligent electronic technology, the accurate identification of electrical load usage will have extensive user demands in the field of smart electricity. In order to achieve the online real-time accurate monitoring of the electrical equipment, this paper proposed a non-intrusive load identification method based on the online self-organizing incremental neural network (SOINN). This method included two steps, which are the load feature extraction and the load feature classification with the equipment identification. In the process of load feature extraction, a 12-dimensional feature extraction scheme was proposed, which includes the odd harmonics, the mean value, the variance value, the third-order moment, the fourth-order moment, the root mean square current, the peak value of power spectrum, and the trough value of power spectrum. In the second step, a method combining SVM and SOINN for the load feature classification and the electrical equipment identification was proposed to overcome the limitation of the traditional SOINN algorithm in appliance type recognition. The functional algorithms in the proposed method are implemented as executable functional modules for the microprocessor system using C++ programming language. The functional modules were then ported and deployed on the HPS side of the SoC FPGA, achieving collaborative high-speed data communication between FPGA and HPS. Eight types of conventional household appliances were selected as the load identification objects. A hardware experimental platform based on SoC FPGA was built to select the optimal load characteristics. The proposed method was validated for identifying online loads of both single and multiple appliances. Experimental results showed that the above 12-dimensional features were selected as the optimal feature combination for the method proposed in this paper. The recognition rates of both single and multiple appliances using the proposed method were above 95%. The proposed load identification method can effectively and accurately identify both single and multiple electrical appliances. The system has strong implementability, high flexibility, the advantages of online learning, and practical feasibility for practical applications.

**Key words:** incremental learning; load identification; 12-dimensional sample characteristics; FPGA

(编辑 赵婧)

引用格式: Hu Zhengwei, Wang Zhihong, Chang Ruixin, et al. Non-intrusive load identification method based on the online self-organizing incremental neural network[J]. *Advanced Engineering Sciences*, 2024, 56(4): 316–324. [胡正伟, 王志红, 畅瑞鑫, 等. 基于在线自组织增量学习的非侵入式负荷识别方法[J]. *工程科学与技术*, 2024, 56(4): 316–324.]