

# 基于 DAG-SVMS 的非侵入式负荷识别方法\*

王 毅<sup>1,2</sup>, 徐元源<sup>1</sup>, 李松浓<sup>2</sup>

(1.重庆邮电大学 通信与信息工程学院,重庆 400065;2.国网重庆市电力公司电力科学研究院,重庆 404100)

**摘 要:** 在供电入口处嵌入非侵入式负荷识别技术,有利于推动建筑节能、实现电网负荷预测、开发智能楼宇、完善智能电网体系建设。据此,提出一种基于有向无环图支持向量机(Directed Acyclic Graph Support Vector Machines, DAG-SVMS)的负荷辨识方法。首先,对总线电流信号进行事件检测,检测到暂态事件后,分离目标负荷暂态电流波形,提取特征,然后,将特征输入预先训练好的 DAG-SVMS 模型进行分类识别。为提升分类器性能,使用粒子群优化 PSO(Particle Swarm Optimization)算法优化 DAG-SVMS 分类器的参数。为减小累积误差,提出 Gini 指数优化 DAG-SVMS 节点顺序的策略。实验结果表明,文中方法识别准确率高,识别速度快,具有可行性。

**关键词:** 非侵入式负荷识别;暂态事件;DAG-SVMS 模型;Gini 指数;PSO 算法

中图分类号: TN915

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.211451

中文引用格式: 王毅,徐元源,李松浓. 基于 DAG-SVMS 的非侵入式负荷识别方法[J]. 电子技术应用, 2021, 47(10): 107-112.

英文引用格式: Wang Yi, Xu Yuanyuan, Li Songnong. Non-intrusive load identification method based on improved directed acyclic graph support vector machines[J]. Application of Electronic Technique, 2021, 47(10): 107-112.

## Non-intrusive load identification method based on improved directed acyclic graph support vector machines

Wang Yi<sup>1</sup>, Xu Yuanyuan<sup>1</sup>, Li Songnong<sup>2</sup>

(1.School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2.Chongqing Electric Power Research Institute, Chongqing 404100, China)

**Abstract:** Embedding non-intrusive load identification technology in the power supply entrance is conducive to promote building energy saving, realize power grid load forecasting, develop intelligent buildings and improve the construction of smart grid system. Therefore, this paper proposes a non-intrusive power load identification method based on directed acyclic graph support vector machines (DAG-SVMS). Firstly, the event detection of power system bus current signal is carried out. After the transient event is detected, the transient current waveform of the target load is separated and the features are extracted. Then, the features are input into the pre trained DAG-SVMS model for classification and identification. In order to improve the performance of the classifier, particle swarm optimization(PSO) algorithm is used to optimize the parameters of the DAG-SVMS model. In order to reduce the cumulative error, Gini index is proposed to optimize the node order of DAG-SVMS. The experimental results show that the proposed method has high recognition accuracy, fast recognition speed and feasibility.

**Key words:** non-intrusive load identification; transient event; DAG-SVMS model; Gini index; PSO algorithm

### 0 引言

智能电网建设是以提高生态可持续性、供电安全性和经济竞争力为目标<sup>[1]</sup>,表现为提高负荷监测技术、提高终端用户响应速度、提高需求侧的节约能效、提供智能控制技术、分布式能源的自由接入<sup>[2]</sup>。非侵入式负荷识别作为非侵入式负荷监测的核心内容,在不改变用户电路结构的条件下,通过测量总负荷数据,即可获得系统内具体用电负荷的数量、类别、运行状态信息,安装和

维护成本低,易于推广。该技术的实现,可为用户、电力公司以及设备提供参考<sup>[3]</sup>。用户端,用户用电信息得到反馈,提升节能意识,规范用电行为。电力公司端,能提高负荷预测的精确度,实现有效的负荷规划、电能调度。对设备制造商来说,可据此识别出故障或低效设备,加快技术革新,推动高能效设备研发。

目前,非侵入式负荷识别技术在国内外均有研究。文献[4]利用稳态功率信息建立隐马尔科夫模型优化分解方法,对低频混合功率分解得到单个设备运行状态,但识别率不高,不能识别负荷投切时刻。文献[5]利用动

\* 基金项目:重庆市自然科学基金(csts2016cyjA0214)

态时间归整(Dynamic Time Warping, DTW)算法计算实测电流稳态波形和样本库稳态波形的相似度来识别家用负荷,但无法识别变频设备和且小功率设备容易误识。文献[6]提取负荷稳态电流谐波并结合 K-近邻(K-Nearest Neighbor, K-NN)算法进行负荷识别,为提高识别效果融入了核 Fisher 判别方法,综合了 K-NN 的简捷性和核 Fisher 的非线性识别能力,但谐波信息易受外界环境影响,且小功率设备谐波易被大功率设备湮没。文献[7]中提取负荷暂态电流波形特征后,根据分类与回归树(Classification and Regression Trees, CART)算法训练决策树算法进行负荷识别,但决策树结果不稳定,类别太多错误率增加会加快。文献[8]以负荷开关时的独特暂态功率波形为特征,计算测试暂态功率波形与样本库波形贴适度实现负荷识别。另外,神经网络<sup>[9-10]</sup>也是常用的负荷识别方法,但该类方法需要大量的训练样本,训练参数多,可解释性差,使用受到限制。由于稳态类方法对软硬件要求相对较低,目前大多非侵入式负荷识别方法仍然是基于稳态的,但该类方法难以有效识别变频设备等持续变化负荷,同时,小功率设备容易被大功率设备湮没,易受外界环境干扰。此外,无论是稳态类还是暂态类方法,大多研究仅对特征差异明显的设备识别效果好,一旦特征发生重叠便难以有效识别。

综上,文中对不同负荷投切时产生的暂态电流波形并提取合适的特征量进行负荷识别,为避免设备特征重叠造成负荷无法辨识的问题,提出 DAG-SVMS 负荷识别模型。为提高分类器识别准确率,采用 PSO 算法优化分类器参数,同时,提出基于 Gini 指数优化模型节点顺序的策略,以减少模型累积误差。最后,采用公开数据集 BLUED 进行试验验证,结果表明提出的方法识别准确率高,识别速度快,具有可行性。

## 1 暂态电流特征提取

### 1.1 暂态事件检测

将电力系统由一个稳定运行状态过渡到另一个稳定状态的过程定义为暂态事件<sup>[11]</sup>。不同的用电负荷投入、切除以及运行状态发生改变时,都会伴随暂态事件的发生。文中使用相邻周期电流强度变化量来检测负荷暂态事件,定义第  $T$  个周期的负荷的电流强度为:

$$I_{\text{intensity}}(T) = \sqrt{\frac{\sum_{k=1}^K i^2(k)}{K}} \quad (1)$$

式中,  $K$  为一个周期内电流的采样点总数;  $i(k)$  为第  $T$  个周期内第  $k$  个采样点的电流值。

当电力系统内部各用电负荷稳定运行时,总线处相邻周期的电流强度差值趋近于 0; 若某一时刻相邻周期电流强度差值超过  $\delta$ , 则判定系统内负荷发生了暂态事件, 记相邻周期中第二个周期电流起始时刻为暂态事件起始时刻。表示为:

$$\begin{cases} \Delta I_{\text{intensity}} = I_{\text{intensity}}(T+1) - I_{\text{intensity}}(T) \\ \Delta I_{\text{intensity}} > \delta \end{cases} \quad (2)$$

式中,  $\Delta I_{\text{intensity}}$  为第  $T$  个周期与  $T+1$  个周期电流强度的差值;  $\delta$  为暂态事件起始判定阈值。

检测到暂态事件的产生后,立即执行暂态事件结束算法,表示为:

$$\begin{cases} \Delta I_{\text{intensity}} < \varepsilon \\ T \geq \gamma \end{cases} \quad (3)$$

式中,  $\varepsilon$  为暂态过程结束的判定阈值;  $\gamma$  为电流强度变化小于  $\varepsilon$  的最小周期数;  $T$  为电流强度变化小于  $\varepsilon$  的周期数。

上式表达的具体含义为当  $\Delta I_{\text{intensity}}$  小于  $\varepsilon$  的周期个数大于  $\gamma$  时,则判定为负荷暂态事件结束。当前时刻减去  $\gamma$  个电流信号周期后得到暂态事件结束时刻。可见,负荷暂态过程持续时间(暂态事件结束时刻与起始时刻的差值)为工频周期的整数倍。

### 1.2 暂态过程波形分离

检测到暂态事件发生后,电流有效值增大的过程为负荷投入,表现为负荷的开启或升档等操作,电流有效值减小的暂态过程为负荷的切除,表现为负荷关闭或降档等操作。检测到暂态事件后,执行如下:

(1)根据暂态发生前后电流强度的变化,判定系统暂态事件为投入还是切除。若判定为负荷投入,执行步骤(2)。若判定为负荷切除,执行步骤(3)。

(2)暂态事件电流波形与相同周期数量的暂态前的稳态电流波形作差,去除背景波形。

(3)暂态事件电流波形与相同周期数量的暂态后的稳态电流波形作差,去除背景波形。

示例见图 1。

### 1.3 暂态波形特征提取

为尽可能详细地反映各类暂态过程的特性,选择多种特征表征暂态过程。

(1)暂态过程持续时间  $T$ : 暂态事件结束时刻与暂态事件起始时刻差值;

(2)暂态波形取绝对最大值  $I_p$ : 暂态波形取绝对值后的最大值;

(3)峰峰值  $I_{pp}$ : 暂态电流波形最大值与最小值之差;

(4)平均值  $I_{\text{mean}}$ : 暂态电流波形各采样点均值;


(5)绝对平均值  $I'_{\text{mean}}$ : 暂态电流波形取绝对值后的平均值;

(6)电流强度  $I_{\text{intensity}}$ : 将暂态电流波形按式(1)计算电流强度,采样点数为暂态事件电流采样点数;


(7)稳态波形有效值  $I_{\text{ms}}$ : 暂态事件前后稳态电流强度差值;

(8)峰均比  $R_{\text{pta}}$ : 峰峰值与电流强度比值( $I_{pp}/I_{\text{intensity}}$ );

(9)波形因数  $F_{\text{form}}$ : 电流强度与绝对平均值比值( $I_{\text{intensity}}/I'_{\text{mean}}$ );



(a) 系统总电流波形



(b) 目标负荷暂态电流波形

图1 暂态电流波形分离

(10) 波峰因数  $F_{crest}$ : 暂态波形取绝对最大值与电流强度比值 ( $I_p/I_{intensity}$ );

(11) 负荷标志位  $I_{flag}$ : 根据暂态事件前后电流强度变化判断负荷投切, 负荷投入时为 1, 负荷切除时为 0。

对负荷暂态电流波形提取 11 维特征, 构建样本数据库。图 1 特征提取如表 1 所示。

表 1 特征展示

$T$	$I_p$	$I_{pp}$	$I_{mean}$	$I'_{mean}$	$I_{intensity}$	$I_{rms}$	$R_{pla}$	$F_{form}$	$F_{crest}$	$I_{flag}$
0.07	4.16	6.20	0.06	0.81	1.17	0.59	5.30	1.44	3.56	1.00

获取到样本库后, 对样本特征空间进行归一化处理, 将负荷样本特征压缩至  $[0, 1]$  之间, 表示为:

$$x^* = \frac{x_{ij} - x_{jmin}}{x_{jmax} - x_{jmin}} \quad (4)$$

式中,  $i \in [-1, N]$ ;  $j \in [1, 11]$ ;  $N$  为样本个数;  $x_{ij}$  为第  $i$  个样本的第  $j$  个特征值;  $x_{jmax}$  为样本中第  $j$  个特征对应的最大值;  $x_{jmin}$  为样本中第  $j$  个特征对应的最小值。

## 2 DAG-SVMS 负荷识别模型

非侵入式负荷识别可依据的特征多, 但在实际应用中能够获取的样本较少, 是典型的小样本高维数据问题, 且需要快速识别。SVM 是一种建立在统计学基础之上的分类器, 在小样本、非线性以及高维数据的模式识别中表现出十分突出的特性。传统的 SVM 是解决二分类问

题的, 但实际中大多是多分类问题, 因此, 需要将二分类扩展至多分类<sup>[12]</sup>。

### 2.1 SVM 基本原理

假设样本集合:

$$D = \{(x_i, y_i), x_i \in R^n, y_i \in \{-1, 1\}, i = 1, 2, 3, \dots, N\} \quad (5)$$

式中,  $x_i$  为样本数据;  $y_i$  为  $x_i$  类标签;  $N$  为样本个数;  $n$  为样本维数。

SVM 基本思想是构造最优超平面将不同类别的样本分开, 超平面构造原则为距离该平面最近的样本到该平面的间隔最大。得到优化问题如下:

$$\begin{aligned} \min \tau(W, \varepsilon) &= 1/2 \|W\|^2 + C \sum_{i=1}^m \varepsilon_i \\ \text{s.t. } y_i(W^T x_i + b) &\geq 1 - \varepsilon_i \\ \varepsilon_i &\geq 0, i = 1, 2, \dots, m \end{aligned} \quad (6)$$

式中,  $W$  为超平面法向量;  $b$  为超平面的偏移量;  $C$  为惩罚参数;  $\varepsilon_i$  为松弛变量。

构建拉格朗日函数:

$$\begin{aligned} L(W, \varepsilon, b, \alpha_i, \beta_i) &= 1/2 \|W\|^2 + C \sum_{i=1}^m \beta_i \varepsilon_i - \\ &\sum_{i=1}^m \alpha_i [y_i(W^T \psi(x_i) + b) - 1 + \varepsilon_i] + \sum_{i=1}^m \beta_i \varepsilon_i \end{aligned} \quad (7)$$

式中,  $\alpha_i$  和  $\beta_i$  为拉格朗日乘子。

对  $W$ 、 $b$  和  $\varepsilon_i$  求偏导为 0, 代入式(7), 得:

$$\begin{aligned} \max W(\alpha) &= \sum_{i=1}^m \alpha_i - 1/2 \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j \langle x_i \cdot x_j \rangle \\ \text{s.t. } 0 &\leq \alpha_i \leq C \\ \sum_{i=1}^m \alpha_i y_i &= 0, i = 1, 2, \dots, m \end{aligned} \quad (8)$$

求解式(8)得到分类决策面:

$$f(x) = \text{sgn}\{\langle W \cdot x \rangle + b\} = \text{sgn}\left\{\sum_{i=1}^m \alpha_i y_i \langle x \cdot x_i \rangle + b\right\} \quad (9)$$

称  $\alpha_i > 0$  对应的样本为支持向量。

数据样本在低维空间不可分时, 可通过核函数映射到高维空间  $\psi: x \rightarrow \psi(x)$ , 在高维空间中求解最优线性分类超平面, 将高维空间求解的线性分类超平面转为低维分类超曲面。SVM 通过核函数巧妙地避免了由低维映射至高维带来的维数灾难问题, 解决了样本的非线性可分问题。根据 Mercer 定理, 核函数要求满足:

$$K(x, x_i) = \psi(x) \cdot \psi(x_i) \quad (10)$$

大量文献与试验结果表明, 高斯核函数在模式识别问题中表现出优越性能, 因此, 选择高斯径向基核函数。

### 2.2 SVM 参数优化

#### 2.2.1 SVM 参数影响分析

SVM 分类性能主要受误差惩罚参数  $C$ 、核函数及其参数的影响<sup>[13]</sup>。文中 SVM 性能主要受误差惩罚参数  $C$  和高斯径向基核参数  $g$  影响。 $C$  越大表示越不能容忍误差, 分类器更加契合训练样本集, 易过拟合, 泛化性

低。 $C$  偏小易出现欠拟合,训练误差大,对新样本分类变差。 $g$  决定数据映射到高维空间的新分布, $g$  过大则支持向量过于紧密,支持向量少,分类器难以获得优质分类性能, $g$  过小则支持向量关系过于松弛,支持向量多,难以保证分类器泛化性能。支持向量的数量决定了分类器复杂度。

### 2.2.2 SVM 参数优化

PSO 算法是依据鸟群觅食行为所研究的群体协作优化算法<sup>[14]</sup>。首先,随机初始化  $M$  个粒子,然后,通过迭代的方式获得最优解,每次迭代粒子通过跟随个体极值  $p_{id}$  和全局极值  $p_{gl}$  更新速度,根据速度进一步更新粒子下一次位置,并进行适应度评价,以此迭代循环,直至找到最优解。粒子速度与位置更新公式如下:

$$\begin{cases} v_{id}(t+1) = w * v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gl} - x_{id}(t)) \\ x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \end{cases} \quad (11)$$

式中, $v_{id}$  为粒子的速度; $x_{id}$  为粒子的位置; $w$  为惯性权重; $c_1$ 、 $c_2$  为学习因子; $r_1$ 、 $r_2$  为均匀分布在  $[0, 1]$  范围内的随机数。

SVM 参数优化框图见图 2。

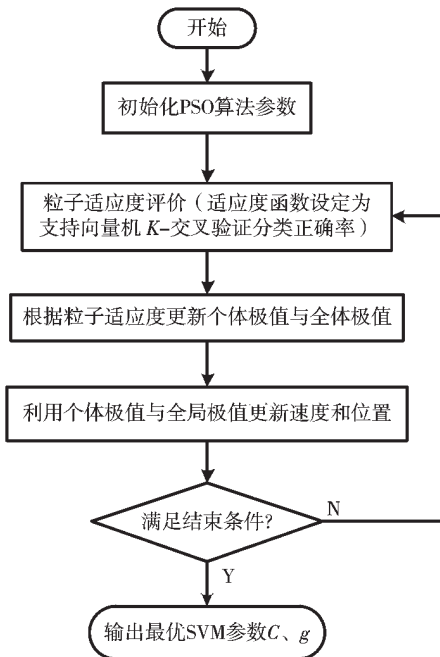


图 2 PSO 算法优化 SVM 参数

### 2.3 DAG-SVMS 算法

假设一个含有  $N$  个类别的数据集合,将其中任意两类样本构建一个分类器得到  $C_N^2$  个分类器,将这些分类器搭建为 DAG 图,将得到  $N(N-1)/2$  分支节点和  $N$  个叶节点。DAG-SVMS 采用“排除”的思想,样本将随着根节点从上到下流动直至叶节点,分支节点决定样本具体被分类到左分支还是右分支,最终叶节点的类别就是该样本所属类别,完成一次分类需  $N-1$  个节点。示例见图 3。

相对于常用的 1-V-1 SVM 多分类算法,DAG-




图 3 三分类 DAG-SVMS 算法

SVMS 识别速度更快;相对于 1-V-R SVMS 多分类算法,DAG-SVMS 训练时间短。同时 DAG-SVMS 不存在误分、拒分区域,分类精度也有所提高。由于 DAG-SVM 采取层次结构,误差累计是层次结构不可避免的弊端,即高层节点对整体样本的分类准确率影响更大。鉴于此,文中首先根据负荷标志位,将样本数据分为负荷的投入和切除两部分,分别训练 DAG-SVMS 模型,以减少 DAG-SVMS 层数,当系统采集到样本后根据标志位判断样本属于投入还是切除,然后将样本数据送入对应 DAG-SVMS 进行识别。下面提出基于 Gini 指数的节点顺序优化策略。

### 2.4 Gini 指数

Gini 指数用于度量样本数据的不纯度和不确定性,表示为:

$$Gini(D) = 1 - \sum_{i=1}^n p_i^2 \quad (12)$$

式中, $p_i$  为  $D$  中样本属于第  $i$  类的概率; $D$  表示样本数据集。

假设样本集被节点划分为两个子集合  $D_1$ 、 $D_2$ ,则经过该划分后样本的 Gini 指数降低为:

$$Gini_{xy}(D) = \frac{D_1}{D} Gini(D_1) + \frac{D_2}{D} Gini(D_2) \quad (13)$$

经过该划分,产生的 Gini 指数差为:

$$\Delta Gini(SVM_{xy}) = Gini(D) - Gini_{xy}(D) \quad (14)$$

由于 Gini 指数越小样本越有序,将划分后的样本 Gini 指数最小化,即保证划分前后数据的 Gini 指数差值最大,使划分结果更加有序。文中对节点顺序的优化为:首先使用各个分类器对样本训练集进行划分,选择 Gini 指数差值最大的节点作为根节点,然后将划分后的样本集  $D_1$ 、 $D_2$  分别视为独立集,在下一层中选择 Gini 指数差值最大的分类器作为当前节点,以此类推,搭建 DAG-SVMS 结构。

### 2.5 算法框图

文中算法框图如图 4 所示,包括:数据采集、事件监测、特征提取、负荷辨识,分为辨识模型训练阶段和在线识别两个阶段。考虑到实际用户家庭负荷用电习惯,暂态事件过程持续时间极短,文中假设各负荷独立,不存在多种负荷同时投切这一特殊情况。



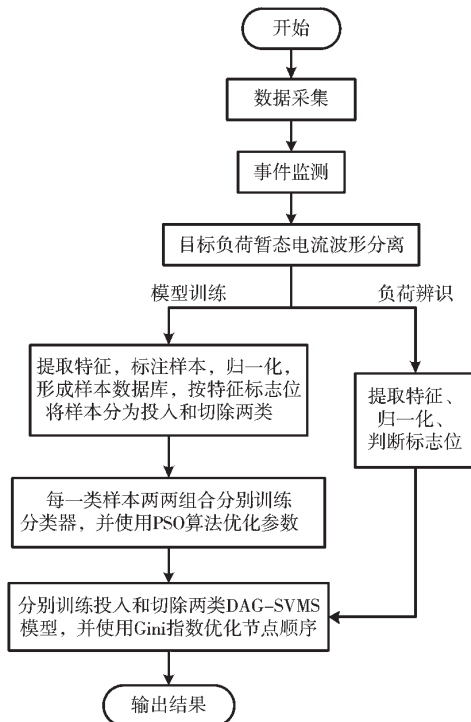


图4 算法流程

### 3 实验验证

采用 BLUED<sup>[15]</sup>数据集进行仿真验证分析,数据来源于某家庭电力总线端口处,共采集了8天,采样频率为12 kHz,包括电压、电流数据,并配备各用电设备的暂态事件投切时刻表。软件平台使用 MATLAB2018a,辅助工具箱 Libsvm3.24,硬件平台使用 Intel Core i5-4210U 2.40 GHz,4 GB RAM 电脑。从数据集中选取5种投切次数较多的用电设备用于实验验证,暂态事件起始判定阈值设定为功率最小负荷浴室顶灯电流强度的1/2,暂态过程结束的判定阈值设定为浴室顶灯电流强度1/5,提取11维特征向量形成样本数据空间。共5种用电设备的投切,10类暂态过程,详见表2。

表2 样本数据组成

电器类型	投入样本数	切除样本数	总样本数
冰箱	71	71	142
楼上浴室灯	68	68	136
卧室灯	9	9	18
空气压缩机	12	12	24
后院灯	9	9	18

分别从10类暂态过程中随机选择60%的数据样本用于训练,剩余40%样本用于测试,执行10次。评价指标选用准确率:

$$\text{Acc} = \frac{\text{识别正确样本数}}{\text{样本总数}} \times 100\%$$

PSO 算法最大迭代次数设置为100,搜索空间维数  $d=2$ ,初始化个体数目  $N=30$ ,学习因子  $c_1=2$ 、 $c_2=2$ ,惯

性权重  $w=0.65$ ,粒子位置值范围 $[-10,10]$ ,折叠交叉数  $K=5$ ,实验结果如表3所示。

表3 负荷识别正确率

电器类型	负荷投入 Acc/%	负荷切除 Acc/%
冰箱	100.00	98.62
浴室顶灯	100.00	92.08
卧室灯	100.00	100.00
空气压缩机	100.00	92.00
后院灯	100.00	100.00

从表3可以看出,文中方法对各负荷投入识别率均为100%,负荷切除识别率相对偏低,这是因为负荷切除时的暂态过程持续时间偏短,外加电力线中噪声干扰,导致暂态特征区分度减弱。算法平均识别率为97.69%。

分别使用1-V-1 SVMS、1-V-R SVMS、传统 DAG-SVMS 以及文中优化改进的 DAG-SVMS 算法进行识别性能对比分析。分类器参数优化前,使用平台默认参数结果如图5所示。从图5中可以看到,PSO 算法优化后,各多分类 SVM 算法识别准确率均大大提高,文中 DAG-SVMS 优化前后识别准确率均优于传统 SVMS,且波动较小,识别结果稳定。

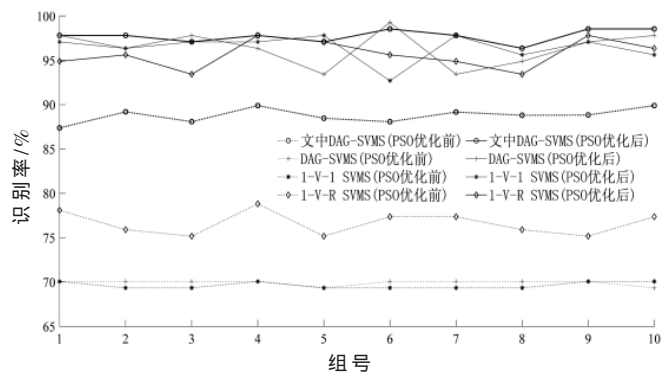


图5 多分类 SVM 算法测试结果

多分类 SVM 算法训练、测试结果如表4所示,表4中,各项指标由10次实验结果平均得到。可以看到,文中算法平均训练时间最短,为20.35 s,单样本平均识别时间最快,为1.53  $\mu\text{s}$ ,平均识别率最高,为97.69%,均为最优。由于文中算法在训练模型前,根据负荷标志位对模型进行了简化处理,模型结构简单,训练时间减少。同时,分类识别时所需分类器判决次数少,识别时间更快。

表4 多分类 SVM 算法训练、测试结果

识别方法	训练时间/s	单样本识别时间/ $\mu\text{s}$	PSO 优化前 Acc/%	PSO 优化后 Acc/%
1-V-1 SVMS	29.26	17.20	69.34	96.42
1-V-R SVMS	51.87	53.03	76.64	95.69
DAG-SVMS	43.54	3.44	69.92	96.42
文中 DAG-SVMS	20.35	1.53	88.78	97.69

使用目前负荷识别领域常用的 BP 神经网络、K-NN 算法、CART 算法与文中优化改进 DAG-SVMS 算法进行性能对比结果如图 6 所示。




图 6 不同算法的识别结果

从图 6 中可以看出，文中 DAG-SVMS 算法 10 次实验结果识别准确率均高于其他几种常用算法，均保持在 95% 以上。进一步整理实验结果，如表 5 所示。

表 5 不同算法实验结果

识别算法	算法训练时间/s	单样本识别时间/ $\mu$ s	Acc/%
BP 神经网络	10.25	689.83	85.69
K-NN	0	586.97	92.12
CART	0.74	67.38	95.33
文中 DAG-SVMS	20.35	1.53	97.69

其中，K-NN 算法 K 值为样本识别准确率最高情况下的对应值，该算法直接计算样本类别，因此，无训练时间。可以看到，文中方法单样本识别时间仍为最短，仅为 BP 神经网络的 0.22%、K-NN 算法的 0.26%、CART 算法的 2.27%。识别准确率上，平均识别率均高于其他几种算法。从训练时间角度看，文中算法平均离线训练时间最长，为 20.35 s，但实际应用中，考虑到系统通信模块、人机交互等，文中算法负荷在线识别速度快，识别准确率高，故适合在线识别。

最后，从表 6 中可以看出，文中 DAG-SVMS 算法在节点顺序优化后，平均识别准确率提高 1.04% 百分点，反映了节点顺序优化方法的有效性。

表 6 节点顺序优化前后对比

	Acc/%
节点顺序优化前	96.65
节点顺序优化后	97.69

4 结论

针对稳态类方法识别负荷的不足，文中以暂态电流为特征，提出了一种基于改进 DAG-SVMS 的非侵入式负荷识别方法。包括事件检测、暂态波形分离、特征提取，为解决特征类似负荷的识别问题，以 SVM 为分类器，搭建 DAG-SVMS 负荷识别模型，同时，优化模型中的分类器参数和节点顺序，以进一步提高识别准确率。实验结果表明文中算法识别准确率高，识别速度最快，实用性强，适合在线识别。

参考文献

[1] 余贻鑫,刘艳丽.智能电网的挑战性问题[J].电力系统自动化,2015,39(2):1-5.

[2] 梁甜甜,高赐威,王蓓蓓.智能电网下电力需求侧管理应用[J].电力自动化设备,2012,32(5):81-85.

[3] 邓晓平,张桂青,魏庆来,等.非侵入式负荷监测综述[J/OL].自动化学报:1-21[2021-03-04].https://doi.org/10.16383/j.aas.c200270.

[4] 孙毅,李昊洋,刘耀先,等.基于改进隐马尔科夫模型的非侵入式家居负荷识别[J].电力建设,2020,41(4):73-80.

[5] 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.

[6] 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].电力系统自动化,2018,42(6):73-80.

[7] 曹敏,魏龄,邹京希,等.基于暂态过程的非侵入式负荷监测研究[J].水电能源科学,2018,36(8):177-180.

[8] 高云,杨洪耕.基于暂态特征贴度匹配的家用负荷识别[J].电力系统自动化,2013,37(9):54-59.

[9] CHANG H, LIAN K, SU Y, et al. Power-spectrum-based wavelet transform for nonintrusive demand monitoring and load identification[J]. IEEE Transactions on Industry Applications, 2014, 50(3): 2081-2089.

[10] LIN Y H, HU Y C. Electrical energy management based on a hybrid artificial neural network-particle swarm optimization-integrated two-stage non-intrusive load monitoring process in smart homes[J]. Processes, 2018, 6(12): 236.

[11] 曲禾笛.基于暂态特征的负荷非侵入式辨识方法研究与实现[D].成都:电子科技大学,2018.

[12] 侯小丽,王建国,王佳丽.基于支持向量机的多目标分类和识别[J].火力与指挥控制,2016,41(9):189-192.

[13] 王霞,董永权,于巧,等.结构化支持向量机研究综述[J].计算机工程与应用,2020,56(17):24-32.

[14] KENNEDY J, EBERHART R. Particle swarm optimization[C]// Icn95-international Conference on Neural Networks, Perth: IEEE, 1995: 1942-1948.

[15] ANDERSON K D, OCNEANU A, BENITEZ D, et al. Blued: a fully labeled public dataset for eventbased non-intrusive load monitoring research[C]// 2nd KDD Workshop on Data Mining Applications in Sustainability, Beijing: ACM, 2012: 12-16.

(收稿日期:2021-03-04)

作者简介:

王毅(1981-),男,博士后,副教授,主要研究方向:电路与系统。

徐元源(1994-),男,硕士研究生,主要研究方向:负荷识别、信息与通信工程。

李松浓(1980-),男,博士,主要研究方向:智能信息处理研究。



扫码下载电子文档

## 版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所