

基于 ELM 的非侵入式电力负荷识别算法^①

周 晓^② 李永清^③ 张有兵

(浙江工业大学信息工程学院 杭州 310023)

摘要 电力负荷识别是需求侧管理的重要环节,为解决传统侵入式负荷监测高成本、不易安装维护的问题,以非侵入式负荷监测为背景研究电力负荷识别算法。从负荷特性出发,针对各电力负荷的暂态及稳态电气特性,提取并建立负荷特征标签。然后,采用极限学习机(ELM)神经网络模型,将输入特征非线性地映射到输入层,实现快速收敛至全局最优点。采用基于累积和(CUSUM)的双边事件检测方法,实现快速准确地检测出负荷投切事件,实时触发负荷识别。最终,以 4 种常用电力负荷进行实验,结果表明,所提出的负荷识别算法可准确识别出负荷类型,运算效率高,且适用于组合负荷识别。

关键词 非侵入式; 负荷识别; 极限学习机(ELM)模型; 事件检测; 累积和(CUSUM)

0 引言

2019 年 7 月 22 日中电联行业发展与环境资源部发布了 2019 年 1~6 月全国电力工业统计数据一览表,表中显示城乡居民生活用电量累计 4 993 亿千瓦时,累计增长 9.6%,可见居民用户是微电网的重要需求端。在积极响应节能政策中电力需求侧管理显得至关重要,非侵入式负荷监测是需求侧管理的关键基础技术^[1]。通过对用户用电数据的采集实现各类电力负荷的在线监测,不仅有利于用户及时了解自身的用电情况,为用户节能提供数据支持,引导用户采取节能措施,还有助于电网在需求侧管理中,通过优化电网的供电策略来达到节能目的^[2]。

目前的负荷监测技术主要包括侵入式和非侵入式 2 类。侵入式方法需要在每个电力负荷内部安装传感器,此方法获得的数据准确,但会产生成本较大、维护不易等问题。非侵入式只需在电力入口端安装传感器来实时监测和采集用户负荷数据,通过负荷识别方法分析负荷的不同特征实现电力负荷的

识别,从而实现将用户的总用电信息细化到各类负荷上。非侵入式法成本低、安装维修简单,因此该方法将成为电力负荷识别的重要发展方向^[3]。

非侵入式负荷监测在 1992 年由 Hart^[4]提出,其通过监测电力入口端的总负荷稳态功率来实现负荷识别,从而实现总用电信息的细化。近些年随着人工智能技术的不断发展,越来越多的学者将智能算法应用到负荷识别中,并得到了较好的发展。文献[5]采用反向传播(back propagation, BP)神经网络对负荷进行识别,极大地降低了计算复杂度。文献[6]利用待识别负荷和模型库之间的贴近匹配度来进行负荷识别,在特征选择中进行预筛选和增加负荷局部特征来提高识别率。文献[7]以电流高次谐波和功率特征构建度量函数,采用粒子群算法对函数进行寻优求解,最终实现负荷识别。

上述研究大多选取稳态功率或高次谐波作为负荷识别的特征,不能准确地表征负荷特性,并且算法的运行速度不理想,不能做到实时地负荷识别。为此,本文提出一种基于极限学习机(extreme learning machine, ELM)的负荷识别方法。在特征选取上,统

① 国家自然科学基金(51777193)资助项目。

② 男,1971 年生,博士,副教授;研究方向:嵌入式系统, 电能检测等;E-mail: zx@zjut.edu.cn

③ 通信作者,E-mail: zjut_lyq@foxmail.com

(收稿日期:2019-09-02)

计分析了负荷所表现的特性,选取出能表征负荷暂态、稳态特性的特征;在负荷投切事件检测上,利用基于累积和(cumulative sum control chart, CUSUM)的事件检测方法检测出负荷投切事件;在负荷识别上,采用 ELM 模型,将特征参数作为输入层,并非线性地映射到输出层,得到合适的分类结果,从而有效地进行负荷识别。

1 负荷特征分析及提取

1.1 负荷特性分析

负荷特性是指负荷在耗电时所携带的电气特性^[8]。为选取能表征负荷的特征,本文对瞬时负荷特性进行分析,瞬时负荷特性包括投切瞬时负荷特性和稳态瞬时负荷特性,投切瞬时负荷特性指负荷在开启和关闭瞬间所表现的电气特性,稳态瞬时特性指负荷开启进入稳定工作后所表现的电气特性^[9]。本文选取 4 种常见的实验室电力负荷,分别是功率为 7 W 的 LED 灯、功率为 32 W 的电风扇、功率为 1800 W 的电热水壶、功率为 23 W 的液晶显示器,在 Matlab 平台上对测量到的负荷数据进行特性分析,每种负荷瞬时电流如图 1 所示,每种负荷瞬时有功功率如图 2 所示,每种负荷瞬时无功功率如图 3 所示。

从图 1 可知,4 种负荷的瞬时电流差别较大,负荷间电流稳态瞬时值不同,负荷从开启到进入稳态的时间不同,负荷间电流暂态瞬时波形平缓度不同。

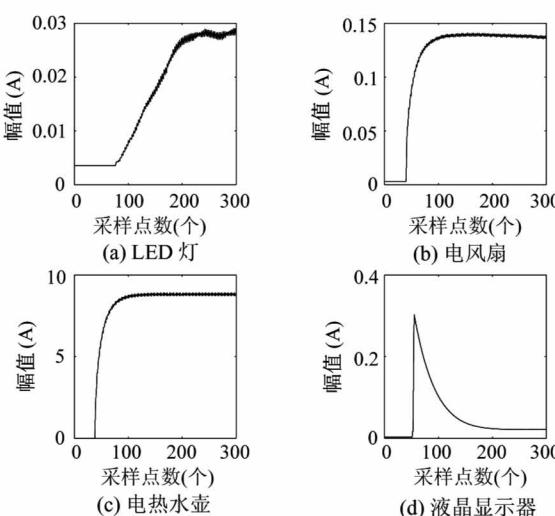


图 1 负荷瞬时电流

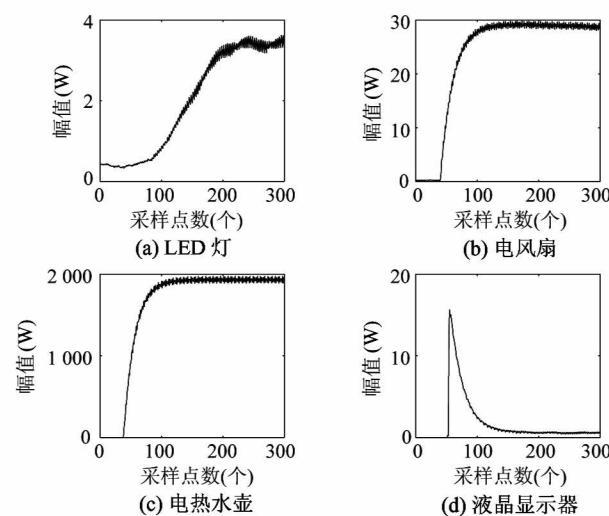


图 2 负荷瞬时有功功率

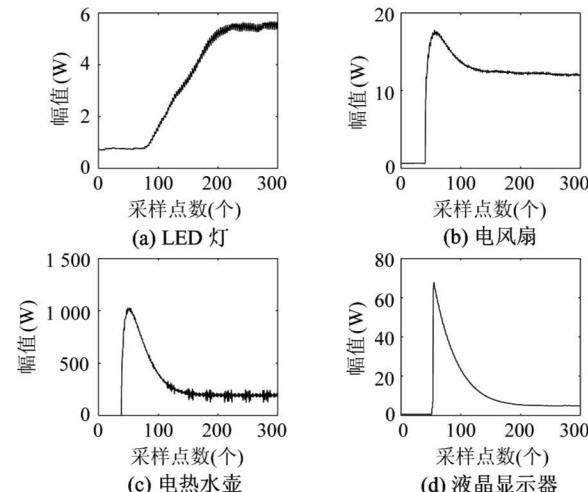


图 3 负荷瞬时无功功率

从图 2 可知,4 种负荷的瞬时有功功率和瞬时电流波形基本一致,但是负荷间瞬时有功功率最大值互不相同。从图 3 可知,4 种负荷间瞬时无功功率脉冲值和瞬时无功功率最大值不同。由于不同负荷之间的物理性质、内部器件结构不同,其负荷在投切时所表现的负荷特性一定存在差异,因此可以选取合适的特征来进行负荷识别。

1.2 负荷特征提取

由上述 4 种负荷的特性分析,提取以下 6 个电气特征为不同负荷的识别指标。

(1) 电流最大值 I_{Max}

$$I_{\text{Max}} = \max(i(k)), 0 \leq k < N \quad (1)$$

式中, k 为数据采样点数, $i(k)$ 为瞬时电流值(本文

的瞬时电流值都指瞬时电流有效值)。

(2) 有功功率最大值 P_{Max}

$$P_{\text{Max}} = \max(p(k)), 0 \leq k < N \quad (2)$$

式中, k 为数据采样点数, $p(k)$ 为瞬时有功功率值。

(3) 无功功率最大值 Q_{Max}

$$Q_{\text{Max}} = \max(q(k)), 0 \leq k < N \quad (3)$$

式中, k 为数据采样点数, $q(k)$ 为瞬时无功功率值。

(4) 无功功率脉冲含量 MC

$$MC = \frac{Q_{\text{Max}} - Q_{\text{start}}}{Q_{\text{steady}} - Q_{\text{start}}} \quad (4)$$

式中, Q_{Max} 为无功功率最大值, Q_{start} 为负荷开启前的无功功率值, Q_{steady} 为负荷开启结束的无功功率稳态值。

(5) 启动时间 T

$$T = T_{\text{steady}} - T_{\text{start}} \quad (5)$$

式中, T_{steady} 为负荷开启结束后进入稳态的第一个采样点, T_{start} 为负荷开启前的最后一个采样点, 利用第 2 节的负荷投切事件检测算法检测出负荷暂态过程, 并提取出 T_{steady} 和 T_{start} 。 T 只是为负荷开启前后的采样点数差值, 具有物理意义的采样时间则需乘以采样周期。

(6) 电流波形平缓度 BD

$$BD = \frac{\sum_{k=1}^{n-1} i(k+1) - i(k)}{n - 1} \quad (6)$$

式中, n 为负荷开启到稳态工作的暂态过程采样点数, $i(k+1) - i(k)$ 为相邻采样点数的电流瞬时值的差值, BD 越小电流波形越平缓。

经过实验提取, 4 种电力负荷对应的 6 个特征参数值如表 1 所示。

表 1 4 种负荷 6 个特征参数值

特征 类型	I_{Max} (A)	P_{Max} (W)	Q_{Max} (Var)	MC	T	BD
LED 灯	0.029	3.7	5.8	1.086	364	0.00003
电风扇	0.141	29.8	17.8	1.693	114	0.0012
电热水壶	8.884	1954.4	1023.7	8.321	208	0.0427
液晶显示器	0.303	15.6	67.8	16.18	4	0.07496

从表 1 可看出, LED、电风扇、电热水壶和液晶屏幕 4 种不同负荷的特征值差别较大, 这 6 种负荷特征表征了负荷的暂态和稳态特性, 为 ELM 模型进行负荷识别提高了识别率。

2 负荷投切事件检测

当负荷投切引起电气特性变化, 快速准确地检测出投切事件是实现负荷识别的基础。本文采用基于工业检测 CUSUM 算法, 能准确发现负荷投切时刻, 以此分离出负荷投切暂态过程。

CUSUM 算法是序贯分析原理中的序贯概率比检验方法, 通过累积时间过程中样本数据信息的小偏移, 将小偏移放大达到临界值时判定为发生变点事件^[10,11]。本文中电力负荷投切类型是未知的, 通过图 1 可以看出负荷瞬时电流存在周期波动, 这使

得获取负荷瞬时电流信号的概率分布时变得较困难。为解决此问题, 本文采用一种基于非参数化的双边 CUSUM 投切事件检测算法, 当负荷投切引起瞬时电流变化时, 通过统计瞬时电流变化值 G_n , 实现负荷投切的暂态过程检测。

定义投切事件检测算法:

$$G_n = \begin{cases} G_n^+ = \max(0, G_{n-1}^+ + i_n - (\bar{i}_n + \beta)), G_0^+ = 0 \\ G_n^- = \max(0, G_{n-1}^- - i_n + (\bar{i}_n - \beta)), G_0^- = 0 \end{cases} \quad (7)$$

式中, i_n 为负荷瞬时电流值, \bar{i}_n 为变点发生前的负荷电流平均值, β 为噪声, G_n^+ 、 G_n^- 分别为正累积量和负累积量, 其代表负荷开启和关闭事件。统计量 $G_n = G_n^+ = G_n^- = 0$, 当 $G_n > H$ 时, 则可认为检测到负荷发生了投切事件, H 为投切事件变点阈值。

本文投切事件检测算法如下。

(1) 当负荷监测装置开始工作, G_n 初始化为 0,

依次记录负荷瞬时电流值,电力负荷在投切前和投切完毕后都处于稳态,统计量 G_n 的值在 0 附近无规律波动。

(2) 当负荷投切引起负荷特性发生改变,即瞬时电流序列发生变化。若负荷开启,则序列的电流值变大,导致统计量 G_n^+ 的值不断变大。若负荷关闭,则序列的电流值变小,导致统计量 G_n^- 的值不断变小。

(3) 当统计量 $G_n^+ > H$ 时记录此时序列的采样点数,该点为负荷开启时刻,继续检测 G_n 的值,直到 G_n 的值在 0 附近波动,记录此时序列的采样点数,该点为负荷开启完毕进入稳态的时刻,两点的采样点数差值为负荷开启时间。负荷关闭过程和开启相似,因此不再阐述。

3 负荷识别方法

3.1 ELM 基本原理

ELM 是由 Huang 等人^[12,13]提出的一种人工神经网络模型,该模型是一种基于单隐层前馈神经网络(single hidden layer feedforward networks, SLFNs)的随机化学习算法。相比传统的前馈神经网络学习算法,ELM 学习过程可不需要调整隐藏层节点,即 ELM 隐藏层偏置和网络输出权重是随机生成的,ELM 网络学习开始前仅需要设置一个隐藏层神经元节点数,因此,相比其他需在学习中设置很多网络参数的学习算法(如 BP 神经网络、SVM),ELM 训练、分类和回归速度要快得多且具有较强的泛化能力^[14,15]。

假设由 N 个任意的训练样本 (x_i, t_i) , $i = 1, \dots, N$, 其中 $x_i = [x_{i1}, \dots, x_{in}]^T \in R^n$, $t_i = [t_{i1}, \dots, t_{in}]^T \in R^m$, n 和 m 分别是网络输入层和输出层神经元节点数。对于一个由 L 层隐藏神经元组成的单隐层神经网络模型可用下面的公式表示。

$$\sum_{i=1}^L \beta_i g(w_i x_j + b_i) = o_j, j = 1, 2, \dots, N \quad (8)$$

式中 $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 为随机生成的第 i 个隐藏层和输入层间的权值向量, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$ 为随机生成的第 i 个隐藏层和输出层间的权值

向量, b_i 为第 i 个隐藏单元的偏置, $g(x)$ 为激活函数,本文选取的是非线性的 Sigmoid 函数,它的数学形式如下:

$$g(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

ELM 模型学习的目的是使得输出以最小误差逼近 N 个训练样本,可以表示为

$$\sum_{j=1}^N \|o_j - t_j\| = 0, j = 1, 2, \dots, N \quad (10)$$

即存在 w_i , β_i 和 b_i , 使得

$$\sum_{i=1}^L \beta_i g(w_i x_j + b_i) = t_j, j = 1, \dots, N \quad (11)$$

式(11)用矩阵简化为

$$H\beta = T \quad (12)$$

式中, H 为隐藏层节点的输出矩阵, β 为隐藏层和输出层间的权值矩阵, T 为期望输出矩阵。

式(12)的具体形式如式(13)、(14)所示。

$$H(w_1, \dots, w_L, b_1, \dots, b_L, x_1, \dots, x_L) = \begin{bmatrix} g(w_1 x_1 + b_1) & \cdots & g(w_L x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1 x_N + b_1) & \cdots & g(w_L x_N + b_L) \end{bmatrix}_{N \times L} \quad (13)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_L^T \end{bmatrix}_{N \times m} \quad (14)$$

为训练 ELM 模型,希望得到 \hat{w}_i , $\hat{\beta}_i$ 和 \hat{b}_i , 使得:

$$\|H(\hat{w}_i, \hat{b}_i)\hat{\beta}_i - T\| = \min_{w, b, \beta} \|H(w_i, b_i)\beta_i - T\| \quad (15)$$

式(15)中 $i = 1, 2, \dots, L$, 这等价于最小化损失函数

$$E = \sum_{j=1}^N (\sum_{i=1}^L \beta_i g(w_i x_j + b_i) - t_j)^2 \quad (16)$$

在 ELM 算法中,随机生成输入权重 w_i 和隐藏层偏置 b_i 后隐藏层的输出矩阵 H 就被唯一确定。因此 ELM 的训练可以转化为求解一个线性系统 $H\beta = T$, 且可以求得输出权重 β 为

$$\hat{\beta} = H^\dagger T \quad (17)$$

式中 H^\dagger 为矩阵 H 的 Moore-Penrose 广义逆矩阵,且 $\hat{\beta}$ 的范数是唯一最小的。

3.2 ELM 在负荷识别中的应用

在利用 ELM 进行电力负荷识别时,主要是建立

从电力负荷样本数据到电力负荷类型的映射关系,即建立第 1 节提取的 6 个负荷特征到 4 种电力负荷类型的函数映射。假设电力负荷特征样本数的数据集为 $X = \{x_i | x_i \in R, i = 1, 2, \dots, Q\}$, 其对应的电力负荷类型向量集为 $T = \{t_i | t_i \in R, i = 1, 2, \dots, Q\}$, 由此可构建包含特征数据和负荷类型的数据集 Ω , 且 $\Omega = \{X, T\} = \{x_i, t_i\}$, 在零误差的情况下, 根据 ELM 模型建立的电力负荷识别模型为

$$F: X \rightarrow T, T = F(X) \quad (18)$$

在电力负荷识别的实际应用中, 假设经过训练后模型输出的负荷类型的状态向量为 Y , 那么在基于数据集 X 的基础上, 应用 ELM 建立的识别模型的映射关系为

$$F': X \rightarrow Y, Y = F'(X) \quad (19)$$

假设基于 ELM 的电力负荷识别误差为 ε , 那么对于任意 $\{x_i \in X, i = 1, 2, \dots, Q\}$ 的负荷类型 $t_i = F(x_i)$ 和 $y_i = F'(x_i)$ 能满足:

$$\|t_i - y_i\| \leq \varepsilon \quad (20)$$

上式中, 状态向量 T 为识别模型的期望输出结果, 状态向量 Y 为识别模型的实际输出结果。如果 ε 设置成允许的误差, 那么在实际的电力负荷识别中所得到测试结果的误差满足要求。

根据上述对负荷特征和负荷类型间映射关系的分析, 在建立基于 ELM 的电力负荷识别模型中, 本文将 4 种电力负荷的标签和 6 个特征组合成模型的输入样本, 并将 4 种电力负荷的标签作为模型的输出结果。

4 实验结果及分析

实验所用的电脑配置是: 处理器为 Intel (R) Core i5-8250U@1.6 GHz, 内存为 12 GB DDR4, Windows 10 操作系统, 平台为 Matlab R2017a。实验所用的数据集来自实验室自主设计的非侵入式负荷监测装置, 装置的数据采样频率为 900 Hz, 该数据集包含每种负荷 6 个特征。

4.1 投切事件检测及负荷识别结果

为验证本文事件检测算法的有效性, 实验中依次打开 LED 灯和电风扇。由于本文的事件检测算

法是利用负荷瞬时电流进行判别的, 所以本文提取负荷监测装置的瞬时电流数据进行分析。实验负荷投切事件检测结果如图 4 所示。

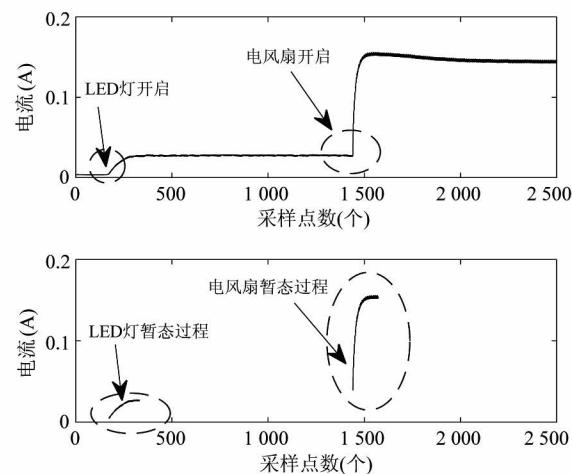


图 4 负荷投切事件检测

在图 4 中, 上图为 LED 灯和电风扇叠加运行的瞬时电流波形, 下图为上图的同一叠加波形经过事件检测算法提取出的 2 个负荷暂态过程。从图中可以看出, 本文的负荷投切事件检测算法不仅适合单负荷投切检测, 还适合多负荷投切检测。通过事件检测算法检测出负荷投切时刻, 提取出负荷暂态过程, 为负荷识别提供数据支持。

为验证本文负荷识别算法的有效性, 本文对 LED 灯、电风扇、电热水壶和液晶显示器这 4 种电力负荷进行识别。在对 ELM 模型的训练样本数据选择中, 本文用负荷监测装置采集得到 800 组样本数据(每种负荷样本各 200 组数据), 其中, 每组样本数据均由本文 1.2 节分析提取的 6 个特征参数组成, 将这 800 组样本数据随机分成 2 组, 其中 760 组样本数据作为训练样本集, 40 组样本数据作为测试集样本, 并设置 ELM 模型的隐藏层节点数为 40。40 组单负荷识别结果如图 5 所示。

由图 5 可以看出, 将 ELM 模型应用于电力负荷识别效果非常好, 在隐藏层为 40 的情况下, 40 组测试集样本的真实值与模型的输出值完全拟合, 单个负荷识别率达到 100%。

为分析不同隐藏层节点数时训练集和测试集识别率, 本文用不同的节点数进行实验, 测试单负荷投

切识别率,从而选取最优的隐藏层节点数,实验结果如表 2 所示。

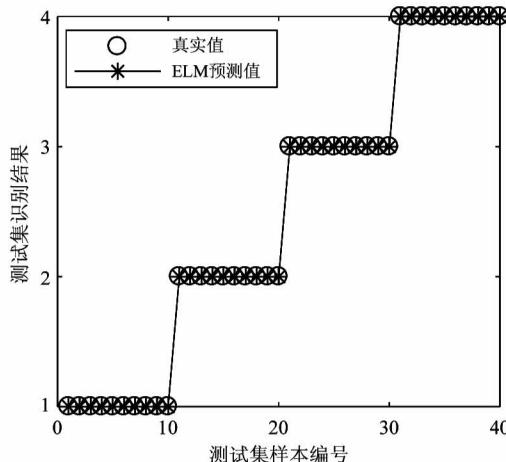


图 5 40 隐藏层节点数的单负荷识别结果

表 2 不同隐藏层节点数的单负荷识别率对比

隐藏层节点数	训练集识别率(%)	测试集识别率(%)
5	75.83	73.33
10	85.67	83.33
15	90.83	90.33
20	98.33	93.33
40	100.00	100.00
70	100.00	98.67
100	100.00	99.83
150	100.00	100.00

从表 2 可以看出,在隐藏层节点数达到 40 前,训练集识别率和测试集识别率随着隐藏层节点数的增加而提高;当隐藏层节点数为 40 时训练集和测试集的识别率达到 100%;当隐藏层节点数为 40~150 时,训练集识别率一直维持在 100%,而测试集识别率则在 100% 下波动。即隐藏层节点数为 40 后,增加隐藏层节点数对单负荷识别率影响不大,反而会产生节点数的增多使 ELM 模型复杂化的问题,增加运算量,ELM 模型学习时间变长。所以最优隐藏层节点数选为 40。

4.2 算法对比

为进一步验证本文识别算法的性能,选取文献[6]中贴进度匹配算法与文献[5]中的 BP 神经网络算法和本文的算法进行对比。在同一实验环境中,使用上述 3 种方法对单负荷识别、2 种负荷叠加、3 种负荷叠加及 4 种负荷叠加的情况进行识别,叠加工作是指一个负荷在开启的基础上再开启另一个负荷。为了对比不同算法的负荷识别性能,利用负荷识别率和负荷识别速度作为算法性能指标,其中,由于叠加负荷识别实质是将叠加负荷分解为多个单负荷识别,所以在各算法识别速度对比上只分析单负荷识别速度。3 种算法的识别结果如表 3 所示。

表 3 不同算法识别结果对比

算法类型	识别率(%)					识别速度(s)
	1 种负荷	2 种负荷	3 种负荷	4 种负荷	单负荷	
贴进度匹配	100	97.5	95.8	92.1	2.632	
BP 算法	100	95.2	90.5	88.6	0.157	
本文方法	100	94.1	91.3	89.4	0.066	

由表 3 可知,贴进度匹配算法的负荷识别率相比于 BP 算法和本文方法要高一些,然而贴进度匹配算法的负荷识别速度要远低于后两者算法,这是由于贴进度匹配方法需要将待检测负荷的瞬时电流数据与模型库里面的数据逐一进行贴近度比对;BP 算法和本文算法的识别率相差不大,但本文算法的负荷识别速度比 BP 算法快 1 倍多;与贴进度匹配算法相比,本文算法的识别率略微低一点,但本文算法的识别速度远胜于贴进度匹配算法。针对本文负

荷监测装置获取的数据,综合对比分析,本文方法兼顾了识别率和识别速度,在单负荷和多负荷情况下均能更好地实现实时负荷识别。

5 结 论

本文在分析电力负荷瞬时电流、瞬时有功功率和瞬时无功功率的基础上,提取出能表征负荷暂态和稳态特性的 6 个电气特征;并利用负荷瞬时电流,

采用基于 CUSUM 的事件检测算法对负荷投切事件进行检测;最后构建 ELM 模型对负荷进行识别。经实验测试与结果分析,可得出如下结论。

(1) 本文提出的事件检测方法能准确检测负荷投切事件,根据检测出的投切时刻能有效地分离出负荷暂态和稳态过程。

(2) 对常见电力负荷具有较高的识别率和识别速度,且适合于多负荷叠加工作的情况,具有良好的工程应用价值。

(3) 本文方法对于多负荷同时投切的情况不能较好地识别,多负荷同时投切引起负荷波形完全重叠,无法精确地提取负荷特征,导致负荷识别率低,今后将对此问题进一步研究。

参考文献

- [1] Javaid N, Hafeez G, Iqbal S, et al. Energy efficient integration of renewable energy sources in the smart grid for demand side management [J]. *IEEE Access*, 2018, 6 (99): 77077-77096
- [2] Tabatabaei S M, Dick S, Xu W. Toward non-intrusive load monitoring via multi-label classification [J]. *IEEE Transactions on Smart Grid*, 2017, 8(1): 26-40
- [3] Chang H H, Chen K L, Tsai Y P, et al. A new measurement method for power signatures of nonintrusive demand monitoring and load identification[J]. *IEEE Transactions on Industry Applications*, 2012, 48(2): 764-771
- [4] Hart G W. Nonintrusive appliance load monitoring[J]. *Proceedings of the IEEE*, 1992, 80(12): 1870-1891
- [5] Lin Y H, Tsai M S. Development of a non-intrusive monitoring technique for appliance identification in electricity energy management [C] // 2011 International Conference on Advanced Power System Automation and Protection, Beijing, China, 2011: 108-113
- [6] 高云, 杨洪耕. 基于暂态特征贴近度匹配的家用负荷识别[J]. 电力系统自动化, 2013, 37(9): 54-59
- [7] Sun Y, Zhang L, Zhao H, et al. A non-intrusive household load monitoring method based on dynamic adaptive particle swarm optimization algorithm [J]. *Power System Technology*, 2018, 42(6): 1819-1826
- [8] Huang T D, Wang W S, Lian K L. A new power signature for nonintrusive appliance load monitoring[J]. *IEEE Transactions on Smart Grid*, 2015, 6(4): 1994-1995
- [9] 曲朝阳, 于华涛, 郭晓利. 基于开启瞬时负荷特征的家电负荷识别[J]. 电工技术学报, 2015, 30 (S1): 358-364
- [10] Amirach N, Xerri B, Borloz B, et al. A new approach for event detection and feature extraction for NILM [C] // IEEE International Conference on Electronics, Marseille, France, 2014: 287-290
- [11] Sibai R E, Chabchoub Y, Chiky R, et al. An in-depth analysis of CUSUM algorithm for the detection of mean and variability deviation in time series[C] // The 16th International Symposium on Web and Wireless Geographical Information Systems (W2GIS), Berlin, Germany, 2018: 25-40
- [12] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications [J]. *Neurocomputing*, 2006, 70(1-3): 489-501
- [13] Huang G B, Zhou H, Ding X, et al. Extreme learning machine for regression and multiclass classification [J]. *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*, 2012, 42(2): 513-529
- [14] Xu Y, Wang Q W. Traffic sign recognition algorithm combining weighted ELM and Adaboost [J]. *Journal of Chinese Computer Systems*, 2017, 38(9): 2028-2032
- [15] 王金甲, 田佩佩. 半监督极限学习机用于 Android 手机活动识别的研究[J]. 高技术通讯, 2017, 27(3): 228-236

Identification algorithm for non-intrusive power load based on ELM

Zhou Xiao, Li Yongqing, Zhang Youbing

(Department of Information Engineering, Zhejiang University of Technology, Hangzhou 310023)

Abstract

Power load identification is an important part of demand-side management. In order to solve the problems of high cost, difficult installation and maintenance of traditional intrusive load monitoring, the non-intrusive load monitoring is used as the background to study the power load identification algorithm. Based on the load characteristics, this paper extracts and establishes the characteristic labels of the loads according to the transient and steady-state electrical characteristics of each power load. Then, the extreme learning machine (ELM) neural network model is used to non-linearly map the input features to the input layer, and the model quickly converges to the global best. The cumulative sum control chart (CUSUM)-based bilateral event detection method is used to quickly and accurately detect load switching events and trigger load identification in real time. Finally, experiments are performed using 4 kinds of commonly used power loads. The results show that the proposed load identification algorithm can accurately identify the type of load. It has high computing efficiency and is suitable for the identification of combined loads.

Key words: non-intrusive, load identification, extreme learning machine (ELM) model, event detection, cumulative sum control chart (CUSUM)