

基于GWO_SVM的非侵入式负荷识别研究

肖月¹, 杨超^{1*}, 王飘²

¹贵州大学电气工程学院, 贵州 贵阳

²多彩贵州航空有限公司, 贵州 贵阳

收稿日期: 2023年12月13日; 录用日期: 2023年12月28日; 发布日期: 2024年1月31日

摘要

随着全球能源需求的持续增长和资源的日益紧张, 非侵入式负荷监测(Non-Intrusive Load Monitoring, NILM)技术在实现资源节约和能源升级中扮演着至关重要的角色。本文针对NILM研究中存在的负荷特征较单一以及负荷识别准确率不高的问题, 通过将有功功率、无功功率与电流五次谐波引入作为识别特征, 提出了基于灰狼优化器算法(grey wolf optimizer, GWO)优化支持向量机(support vector machine, SVM)的模型, 经过在公开数据集REDD上进行实验验证, 该方法在负荷识别上具有98.96%的准确率, 通过与不同算法在同一数据集上进行负荷识别的准确率进行对比, 验证了该文算法在在准确率上有明显提升, 证明了该文算法对于提升负荷识别的准确率具有优越性。

关键词

非侵入式负荷监测, 灰狼优化器, 支持向量机, 负荷监测

Research on Non-Invasive Load Recognition Based on GWO_SVM

Yue Xiao¹, Chao Yang^{1*}, Piao Wang²

¹School of Electrical Engineering, Guizhou University, Guiyang Guizhou

²Colorful Guizhou Airlines, Guiyang Guizhou

Received: Dec. 13th, 2023; accepted: Dec. 28th, 2023; published: Jan. 31st, 2024

Abstract

With the continuous growth of global energy demand and the increasing scarcity of resources, Non-intrusive load monitoring (NILM) technology plays a crucial role in achieving resource conservation and energy upgrading. This article addresses the issues of single load characteristics

*通讯作者。

文章引用: 肖月, 杨超, 王飘. 基于 GWO_SVM 的非侵入式负荷识别研究[J]. 建模与仿真, 2024, 13(1): 932-940.

DOI: 10.12677/mos.2024.131090

and low accuracy in load recognition in NILM research. By introducing active power, reactive power, and fifth harmonic current as recognition features, a grey wolf optimizer (GWO) based model for optimizing support vector machine (SVM) is proposed. The model is validated through experiments on the public dataset REDD. This method has an accuracy of 98.96% in load identification. By comparing the accuracy of load identification with different algorithms on the same dataset, it was verified that the algorithm proposed in this paper has a significant improvement in accuracy, demonstrating its superiority in improving the accuracy of load identification.

Keywords

Non-Intrusive Load Monitoring, Grey Wolf Optimizer, Support Vector Machine, Load Identification

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着全球能源需求的持续增长和资源的日益紧张，能源的有效管理成为了当今世界面临的重大挑战之一。在此背景下，智能电网技术的发展和應用变得日益重要。智能电网的一个关键组成部分是对能源消费的精确监控和管理，而非侵入式负荷监测(Non-Intrusive Load Monitoring, NILM)技术在此方面扮演着至关重要的角色。

NILM 技术旨在从一个集中的点(如住宅或商业建筑的总电力线)中监测电能使用，通过分析电能表上的电压和电流信号变化，识别和追踪所用电器的能耗。这一技术最初由 Hart [1]于 1992 年提出，并自那时起经历了快速发展。它为能源监控提供了一种经济高效且对用户端也很友好的解决方案，与传统的侵入式监测方法相比，NILM 在安装和维护上更为简便。

在国外的研究中，文献[2]将总能耗分解为单个设备签名，并利用 K 近邻分类算法计算测试样本出最邻近的 5 个样本，但是该方法计算量大，在样本数量不足时分解精度较低。文献[3]将多标签分类问题转化为一组或多组单标签分类问题来构建分类模型，利用带有决策树的 RAKEL 作为多标签分类算法实现了高效分解，但是该方法在训练阶段需要大量的标记数据，数据集构建复杂，识别设备种类有限。文献[4]采用长短时记忆人工神经网络、去噪自动编码器以及自定义矩形网络三种算法实现非侵入式负荷识别，对比隐形马尔科夫链准确率都有较大提升。在国内，也在不同角度对非侵入式负荷监测开展研究。文献[5]基于支持向量机和 DS 证据理论，提出了一种基于分数相关的算法和基于 B 样条曲线拟合的算法。近年来随着各种事件检测算法的改进，传统负荷分解方法的精度逐步提高，但是针对低频采样数据效果有限。

2. 基于 GWO_SVM 的非侵入式负荷识别

2.1. 负荷特征选取

通过对相关文献进行研究分析，发现目前的负荷识别算法研究中仍存在负荷特征种类较少，监测场景较单一的问题。基于这种情况，通过分析数据集所采集的数据特性，本文在传统支持向量机算法的基础上，引入灰狼优化器(GWO)算法进行优化。

通过对数据集特点进行分析，本文采用有功功率、无功功率与电流五次谐波相结合作为特征进行识别。具体计算公式如下：

1) 有功功率

$$P = UI \cos \varphi \quad (1)$$

$$Q = UI \sin \varphi \quad (2)$$

式中: U 为用电设备电压的有效值, I 为用电设备电流的有效值, φ 为两者之间的相位差。

3) 电流谐波

大多数负荷运行时产生的偶次谐波幅值较小, 而奇次谐波的幅值较大[6], 傅里叶变换(fourier transform)可以将电流通过的时域信号转换为频域信号, 以便进行下一步的数值计算。本文在傅里叶变换的基础上, 选择对稳态电流进行快速傅里叶变换(fast fourier transform, FFT)获得电流谐波分量 I_k , 提升计算的速度:

$$I_k = \sum_{n=0}^{N-1} i(n) W_N^{kn} \quad k = 0, 1, 2, \dots, N-1 \quad (3)$$

$$W_N^{kn} = e^{-j(2\pi/N)kn} = \cos\left(\frac{2\pi}{N}kn\right) - j \sin\left(\frac{2\pi}{N}kn\right) \quad (4)$$

2.2. 传统 SVM 以及 GA-SVM 算法

2.2.1. 传统 SVM 模型

支持向量机(support vector machines, SVM)是一种二分类模型, 它将实例的特征向量映射为空间中的一些点, SVM 的目的就是想要画出一条线, 以“最好地”区分这两类点, 以至如果以后有了新的点, 这条线也能做出很好的分类。但支持向量机有一个很重要的性质, 即训练结束之后, 大部分的样本都不会出现在最终的模型之中, 最终的模型只和支持向量有关。且支持向量与训练样本有关, 即使是从同一样本中选取不同的子集, 训练出的支持向量也会有差别。

2.2.2. GA-SVM 算法

GA-SVM 它将“优胜劣汰, 适者生存”的生物进化原理引入待优化参数形成的编码串群体中, 按照一定的适配值函数及一系列遗传操作对各个体进行筛选, 从而使适配值高的个体被保留下来, 组成新的群体。新群体中各个体适应度不断提高, 直至满足一定的极限条件。

2.3. 灰狼优化器(GWO)算法

灰狼优化器算法(Grey Wolf Optimizer, GWO)是一种群体智能优化算法, 由 Mirjalili [7]等人于 2014 年提出。该算法受到了灰狼群体协作捕食猎物行为的启发, 模仿灰狼等级所搭建的数学模型。该算法与传统算法相比具有结构简单, 可调参数少, 收敛性强等优点。

GWO 将灰狼群体划分为 α 、 β 、 δ 和 ω 4 种等级。按适应度的大小排序金字塔如图 1 所示:




Figure 1. GWO fitness pyramid
图 1. GWO 适应度金字塔

将狼群中适应度最好的三匹灰狼依次标记为 α 、 β 、 δ ，其余的灰狼标记为 ω 。在狼群中，其他灰狼必须听从和执行 α 狼做出的决策， α 狼也被称为支配狼。 β 狼协助 α 狼做出正确的决策，并听从于 α 狼， δ 狼支配剩余层级的狼，并听从 α 和 β 狼。 ω 狼等级最低，服从于前 3 等级的狼，起到平衡狼群内部关系的作用， ω 狼跟随 α 、 β 、 δ 狼进行追踪和围捕。

在灰狼算法中， α 狼代表着适应度最高的最优解，其余适应度较低三类狼群 β 、 δ 、 ω 服从 α 的管理，它们通过计算不断接近猎物直至成功捕捉到猎物的过程就是算法在寻找最优解的过程。灰狼的捕猎步骤分为如下步骤：

1) 包围猎物，灰狼群在头狼 α 的带领下包围猎物，其行为用数学模型定义为：

$$D = |C \cdot X_p(t) - X(t)| \quad (5)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (6)$$

式中： D 为狼群与猎物之间距离； $X_p(t)$ 是猎物当前的位置向量， $X(t)$ 是某灰狼当前的位置向量， A 、 C 为系数向量， t 为迭代次数。式(5)为灰狼与猎物的距离，式(6)为灰狼依据距离而发生的位置更新公式。系数向量 A 、 C 的计算公式如下：

$$A = 2a \cdot r_1 - a \quad (7)$$

$$C = 2 \cdot r_2 \quad (8)$$

式中： a 是收敛因子，随迭代次数的增加从 2 线性减小到 0， $|r_1|, |r_2|$ 是 $[0,1]$ 之间的随机数。

2) 狩猎，灰狼在包围猎物后对猎物进行抓捕，因为猎物的位置在不断变化，所以假设狼群 α 、 β 、 δ 能够获知猎物的位置坐标，并且狼群 ω 可以根据 α 、 β 、 δ 的指引更新它们的位置逐渐接近猎物。狼群位置更新的数学模型定义为：

$$\begin{cases} D_\alpha = |C_1 \cdot X_\alpha - X| \\ D_\beta = |C_2 \cdot X_\beta - X| \\ D_\delta = |C_3 \cdot X_\delta - X| \end{cases} \quad (9)$$

式中： D_α 、 D_β 、 D_δ 分别为 α 、 β 、 δ 与其他灰狼的距离； X_α 、 X_β 、 X_δ 分别为当前灰狼的位置； C_1 、 C_2 、 C_3 为随机向量。

$$\begin{cases} X_1 = X_\alpha - A_1 \cdot D_\alpha \\ X_2 = X_\beta - A_2 \cdot D_\beta \\ X_3 = X_\delta - A_3 \cdot D_\delta \end{cases} \quad (10)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (11)$$

式中： $X(t+1)$ 为更新后灰狼的位置向量； t 为迭代次数，根据以上公式得到 α 、 β 、 δ 的最优位置后，其他狼就可以据此进行位置更新。

3) 攻击猎物，狼群攻击猎物，算法得到最优解。在接近猎物的过程中，收敛因子 a 从 2 不断下降为 0，同时影响着 a 的模值变化。在式(7)中，收敛因子 a 的变化，会引起系数 A 的改变。通过 $|A|$ 的大小来确定是否找到猎物位置，当 $|A| \leq 1$ 时，算法收敛，狼群抓捕猎物。当 $|A| > 1$ 时，狼群散开，GWO 进行全局搜索。式(8)中的系数 C ，是在 $[0, 2]$ 上变化的随机数，作用是给灰狼搜索猎物提供随机权重，有助于优化算法避开局部最优。

2.4. 支持向量机(SVM)算法

支持向量机(supportvector machine, SVM) [8]是一种监督学习方法, 其输入是一个个代表样本特征的向量, 样本空间则是由输入的向量共同张成的空间。支持向量机算法通过在解空间中求解出一个最优超平面, 使得解空间的样本能够被此超平面正确分开。最优超平面的几何表示如图 2 所示, 图中实线即为最优的超平面。




Figure 2. Geometric representation of the optimal hyperplane of SVM
图 2. SVM 最优超平面的几何表示图

假设存在 m 个 n 维的样本 $\{x_k, y_k\}, y_k \in \{-1, 1\}, x_k \in R^n, k = 1, 2, \dots, m$, 则 SVM 算法的目标函数和不等式约束如下:

$$\begin{cases} \min_{W, b, \xi} J_p(W, \xi) = \frac{1}{2} W^T W + c \sum_{k=1}^m \xi_k \\ s.t. y_k \geq W^T \varphi(x_k) + b + \xi_k \end{cases} \quad (12)$$

式中: W 为超平面的法向量, ξ 为预测误差值, $\varphi(x_k)$ 为核函数, c 为惩罚因子, b 为常量。

针对惩罚因子 c 与 RBF 基函数的宽度参数 g 的取值对 SVM 分类结果影响的问题, 使用 GWO 算法进行参数的全局寻优。目标函数采用五折交叉验证的最佳准确率, 目标函数公式如下:

$$\text{Fitness} = \frac{n}{N} \times 100\% \quad (13)$$

式中: n 为识别准确的样本统计个数, N 为识别的样本总数。适应度越大, 说明优化模型的识别准确率越高。

2.5. GWO_SVM 算法

GWO_SVM 算法如下:

- 1) 首先提取负荷特征作为模型的输入。将样本分为训练集和测试集, 并对数据进行归一化处理。
- 2) 构建初始化模型。
- 3) 用灰狼算法对其进行初始化操作, 设置种群数量、最大迭代次数、交叉验证折数、SVM 的参数(C, g)的上下范围等算法参数。
- 4) 计算初始的种群适应度以及最优个体的位置, 利用公式(7)、(8)计算 A、C 的数值。
- 5) 根据公式(5)、(6)计算出灰狼与猎物之间的距离, 通过计算出的结果更新灰狼位置。计算出最佳适应度并更新头狼个体位置, 以 SVM (C, g)作为寻优目标, 获取最优参数。
- 6) 利用测试集数据对优化后的支持向量机进行测试。

7) 输出 GWO-SVM 的测试集分类结果。
算法流程图如图 3 所示。

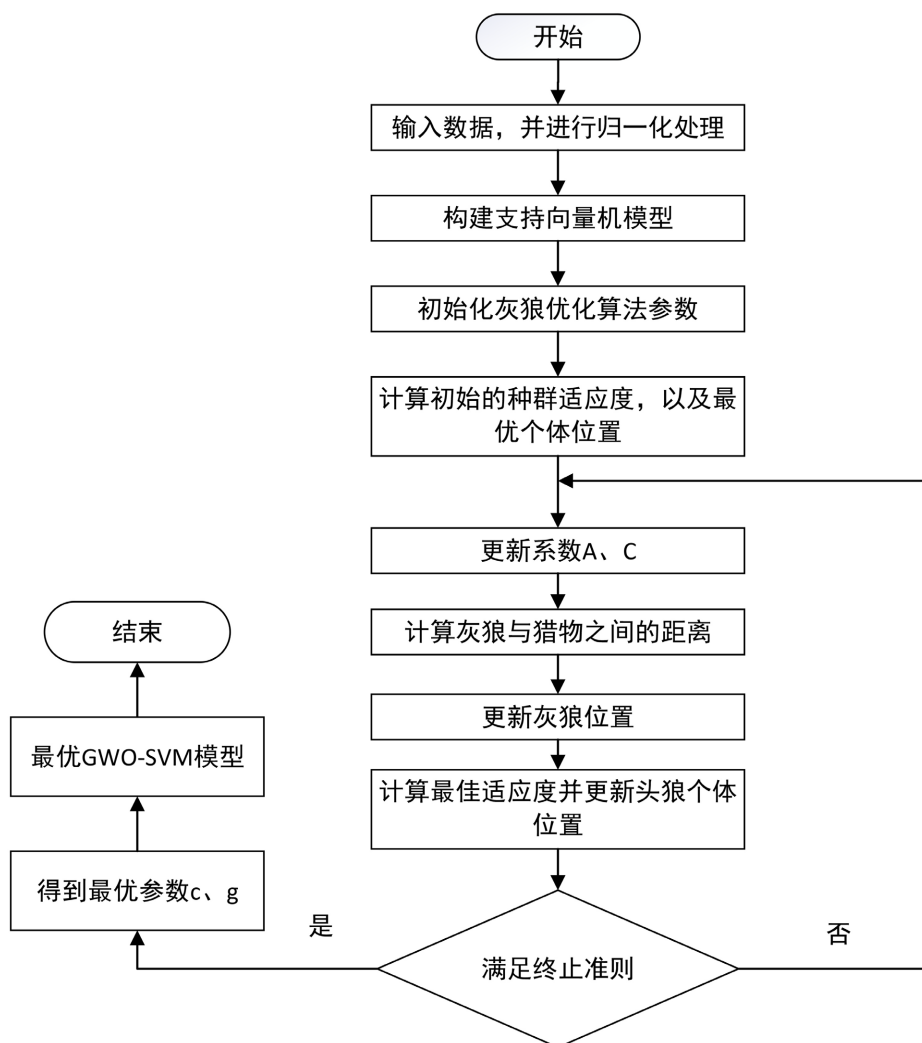


Figure 3. GWO_SVM flow chart
图 3. GWO_SVM 流程图

3. 实验分析

本文采用了 REDD 数据集的 House1 作为实验数据, REDD 数据集是由国外研究机构 MIT 创立的数据集, 其中 House1 收集了部分常用电器用电数据, 本文选取具有代表性的 5 种数据作为验证, 实验标签分别记为 1, 2, 3, 4, 5。

对数据集采用 FFT 分解, 通过分析实验结果可知: GWO_SVM 算法的训练集和测试集包含 3 个负荷特征, 分别是有功功率、无功功率和五次谐波电流幅值, 形成特征向量:

$$F = [E_1, E_2, E_3]$$

其中随机选取 80% 的样本数据作为训练集, 20% 的样本数据作为测试集。GWO_SVM 算法参数设定: 种群大小为 20, 最大迭代次数为 100。SVM 参数(C, g)的范围设置为 $[10^{-5}, 1000]$ 。GWO 优化 SVM 后的分类效果及适应度曲线如图 4 所示。

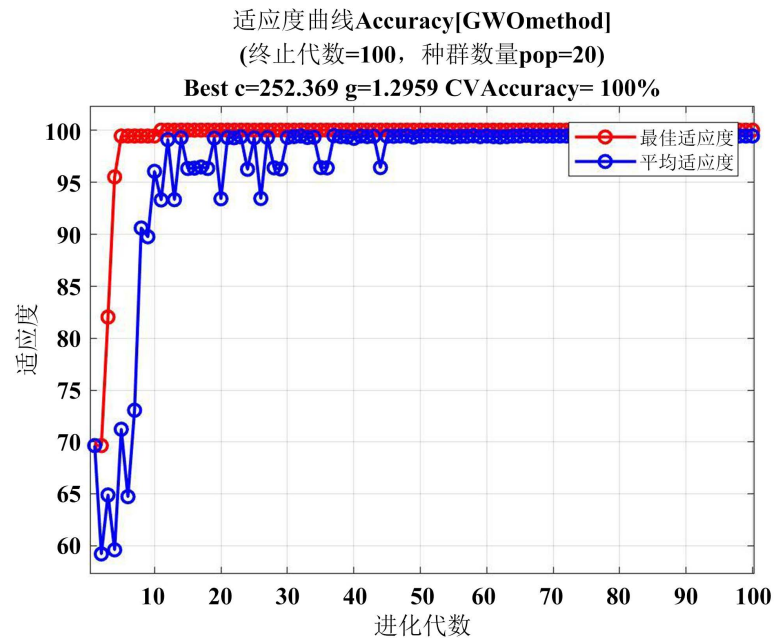


Figure 4. GWO_SVM fitness curve
图 4. GWO_SVM 适应度曲线

使用 MATLAB 软件对本文所提出 GWO_SVM 负荷识别模型进行测试，经 GWO 优化后得到的最优参数 $C = 252.369$ ， $g = 1.2959$ 。得到最优的分类模型后，用测试集样本进行验证，结果如图 5 所示。

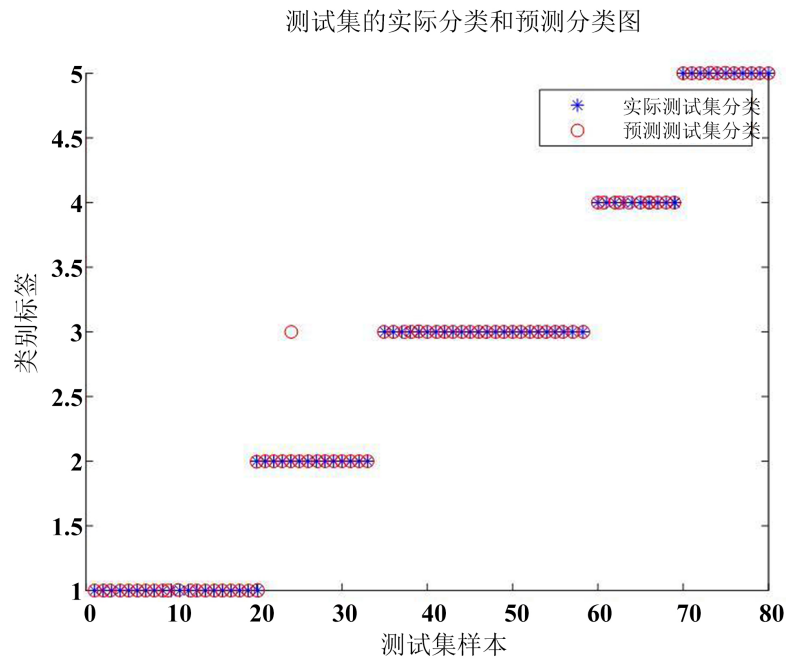


Figure 5. GWO_SVM classification results
图 5. GWO_SVM 分类结果

使用传统 SVM 分类结果如图 6 所示，使用 GA-SVM 分类结果如图 7 所示。三种算法的识别准确率对比如表 1 所示。

Table 1. Data characteristics
表 1. 数据特征

序号	名称	P/W
1	卧室灯	21
2	洗衣机	100~500
3	干衣机	250~5000
4	冰箱	100~150
5	热泵	1200~2000

测试集的实际分类和预测分类图

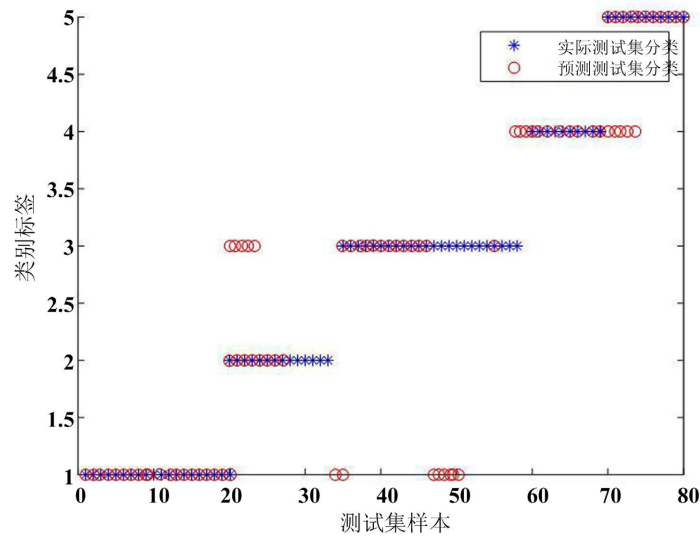


Figure 6. Traditional SVM classification results
图 6. 传统 SVM 分类结果

测试集的实际分类和预测分类图

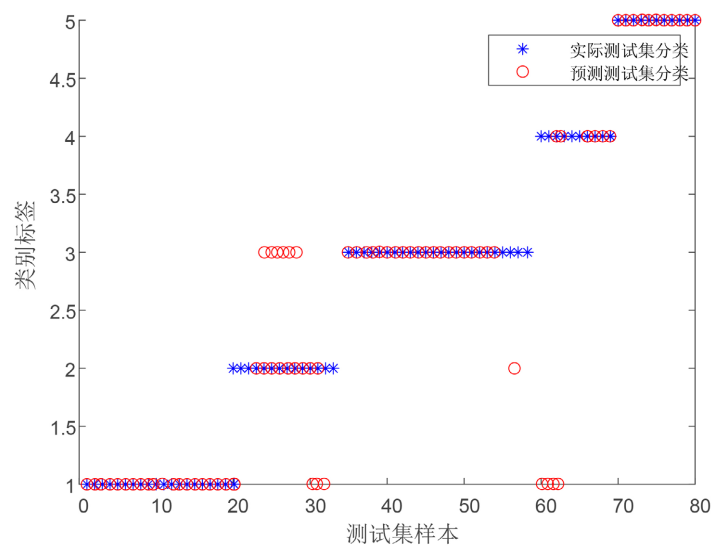


Figure 7. GA-SVM classification results
图 7. GA-SVM 分类结果

由表 2 可以看出, 相较于传统 SVM 以及 GA-SVM 分类算法, GWO_SVM 在负荷识别上具有更高的准确率, 所选取的负荷特征也能较好进行分类识别。

Table 2. Comparison of recognition accuracy of three algorithms (%)
表 2. 三种算法的识别准确率对比(%)

标签	传统 SVM	GA-SVM	GWO_SVM
1	100	100	100
2	57.4	73.8	100
3	45.2	81.3	97.1
4	73.6	65.7	96.6
5	100	100	100
总准确率	77.53	84.16	98.96

4. 结论

本文通过对 REDD 数据集的数据进行分析以及预处理, 引入有功功率、无功功率和五次谐波电流幅值作为特征进行识别, 并使用灰狼优化器算法对 SVM 中的核心参数开展寻优, 得到最优参数并进行分类。通过与传统 SVM 和 GA-SVM 进行对比, 验证了有效性, 解决了目前研究中存在的负荷特征较少、监测场景较单一问题的结论。

参考文献

- [1] Hart, G.W. (1992) Nonintrusive Appliance Load Monitoring. *Proceedings of the IEEE*, **80**, 1870-1891. <https://doi.org/10.1109/5.192069>
- [2] Khan, M.M.R., Siddique, M.A.B. and Sakib, S. (2019) Non-Intrusive Electrical Appliances Monitoring and Classification Using K-Nearest Neighbors. 2019 *2nd International Conference on Innovation in Engineering and Technology (ICIET)*, Dhaka, 23-24 December 2019, 1-5. <https://doi.org/10.1109/ICIET48527.2019.9290671>
- [3] Buddhahai, B., Wongseree, W. and Rakkwamsuk, P. (2018) A Non-Intrusive Load Monitoring System Using Multi-Label Classification Approach. *Sustainable Cities and Society*, **39**, 621-630. <https://doi.org/10.1016/j.scs.2018.02.002>
- [4] Srinivasan, D., Ng, W.S. and Liew, A.C. (2006) Neural-Network-Based Signature Recognition for Harmonic Source Identification. *IEEE Transactions on Power Delivery*, **21**, 398-405. <https://doi.org/10.1109/TPWRD.2005.852370>
- [5] Le, T., Kim, J. and Kim, H. (2016) Classification Performance Using Gated Recurrent Unit Recurrent Neural Network on Energy Disaggregation. 2016 *International Conference on Machine Learning and Cybernetics (ICMLC)*, Jeju, 10-13 July 2016, 105-110. <https://doi.org/10.1109/ICMLC.2016.7860885>
- [6] 吕志宁, 赵少东, 饶竹一, 等. 非侵入负荷辨识的谐波特征量提取改进方法研究[J]. 电子测量技术, 2019, 42(7): 29-34.
- [7] Mirjalili, S., Mirjalili, S.M. and Lewis, A. (2014) Grey Wolf Optimizer. *Advances in Engineering Software*, **69**, 46-61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- [8] 丁世飞, 齐丙娟, 谭红艳. 支持向量机理论与算法研究综述[J]. 电子科技大学学报, 2011, 40(1): 2-10.