

# 基于灰狼算法优化支持向量机的电力设备绝缘故障气体监测技术研究

蔡志亮 陶柏洪 罗启维 罗婉儿 廖海君

中国南方电网有限责任公司东莞供电局

DOI:10.12238/pe.v3i5.16591

**[摘要]** 当变压器内部出现过热劣化时,会释放出具有特征性的气体,这些气体可作为故障的重要预警信号。然而,现有的分类算法在变压器故障诊断中的识别精度仍存在不足。本文旨在提升特征气体识别的准确性与可靠性,提出了一种基于灰狼优化的支持向量机分类方法(GWO-SVM)。通过设置多种性能指标,对GWO-SVM、标准SVM以及BP神经网络三种模型进行了对比实验,并在相同数据集上进行验证。结果表明,GWO-SVM在特征气体识别方面表现突出,分类精度更高,稳定性也优于其他模型。

**[关键词]** 电力变压器故障诊断; 溶解气体分析; 灰狼群智能优化; SVM模型

**中图分类号:** TF762+.6 **文献标识码:** A

## Study on Gas Monitoring Technology for Insulation Faults in Power Equipment Based on Gray Wolf Optimization Support Vector Machine

Zhiliang Cai Baihong Tao Qiwei Luo Waner Luo Haijun Liao

China Southern Power Grid, Dongguan Power Supply Bureau

**[Abstract]** When overheating degradation occurs in transformers, the release of characteristic gases becomes a crucial fault warning signal. However, the accuracy of existing classification algorithms in transformer fault diagnosis still has room for improvement. The aim of this study is to enhance the accuracy and reliability of transformer fault characteristic gas identification. A method based on a Gray Wolf Optimization Support Vector Machine (GWO-SVM) classification model is proposed. The performance of three models (GWO-SVM, standard SVM, and BP neural network) is compared using various performance metrics, and they are evaluated on the same dataset. Experimental results show that the GWO-SVM model significantly outperforms the others in identifying transformer fault characteristic gases, achieving higher classification accuracy and better stability.

**[Key words]** power transformer fault diagnosis; dissolved gas analysis; gray wolf optimization; SVM model

### 引言

随着城市化进程的不断推进以及农村电气化水平的提高,中国的电力网络不断扩展,覆盖范围逐渐增加。变压器作为关键的能源传输和转换设备,其运行对电网的安全和稳定至关重要。然而,由于变压器内部结构的复杂性,它在运行过程中可能受到多种因素的影响,导致绝缘老化、局部放电等故障的发生。这些故障往往会导致绝缘油的分解,并生成各种气体。研究表明,通过溶解气体分析(DGA)技术可以检测这些气体的成分和浓度,从而识别变压器故障类型<sup>[1]</sup>。

与此同时,智能算法在溶解气体分析中的应用逐渐增多,旨在提高故障诊断的准确性。文献<sup>[2]</sup>指出,支持向量机(SVM)和人工神经网络(ANN)等算法已成功应用于故障分类任务,并取得了

良好的效果。然而,传统的故障分类方法尽管在某些情况下有效,但在处理复杂数据时其性能可能会受到一定限制。文献<sup>[3]</sup>指出,BP神经网络容易陷入局部最优解,并可能由于过拟合现象导致分类准确率下降,而标准SVM在参数选择上缺乏有效优化,限制了模型的泛化能力。为了解决这些问题,本文引入了灰狼优化(GWO)算法对SVM的参数进行优化,形成了GWO-SVM模型,从而提高了分类准确性和收敛速度。

因此,GWO-SVM模型在变压器故障诊断中展现出了明显的优势,为准确快速的故障分类提供了可靠的技术支持。GWO算法凭借其出色的全局搜索能力,在优化SVM参数方面表现优异,使其在解决溶解气体分析数据的复杂分类问题时具有明显的优势。

### 1 理论基础与实现方法

### 1.1 灰狼优化算法原理

灰狼优化支持向量机 (GWO-SVM) 模型将灰狼优化算法 (GWO) 与支持向量机 (SVM) 相结合, 利用GWO强大的全局搜索能力来精细调整SVM的参数。此方法提高了分类的准确性, 同时增强了模型对新数据的泛化能力。

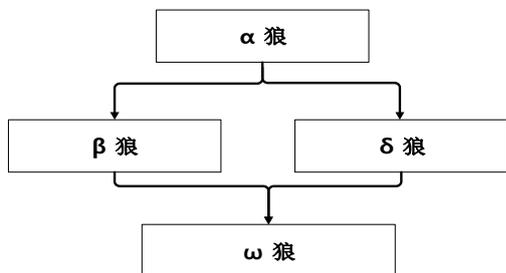


图1 灰狼优化狼群结构

如图1所示, 灰狼群体具有独特的社会结构, 成员被分为  $\alpha$ 、 $\beta$ 、 $\delta$  和  $\omega$  狼。GWO算法模拟了灰狼群体捕猎过程中的三个关键阶段: 包围、追踪和攻击。在该算法中, 每个阶段都通过不同的数学模型来平衡全局搜索与局部开发, 以实现高效的全局优化。

围捕行为通过动态调整每只灰狼的位置来实现。GWO算法的核心在于通过控制参数实现不同的搜索策略, 以平衡全局搜索与局部搜索之间的关系。灰狼的位置更新过程如公式(1-3)所示。

$$\vec{x}(t+1) = \vec{x}_a(t) - A \cdot [C \cdot \vec{x}_a(t) - \vec{x}(t)] \quad (1)$$

$$\vec{x}(t+1) = \vec{x}_b(t) - A \cdot [C \cdot \vec{x}_b(t) - \vec{x}(t)] \quad (2)$$

$$\vec{x}(t+1) = \vec{x}_d(t) - A \cdot [C \cdot \vec{x}_d(t) - \vec{x}(t)] \quad (3)$$

其中,  $\vec{x}_a$ 、 $\vec{x}_b(t)$  和  $\vec{x}_d(t)$  分别表示领导者、副领导者和和其他灰狼的位置。  $\vec{x}(t)$  是当前候选解的位置。A和C是控制搜索行为的参数。

A和C的计算过程如公式(4-5)所示。

$$A = 2 \cdot r_1 - 1 \quad (4)$$

$$C = 2 \cdot r_2 \quad (5)$$

其中,  $r_1$ 和 $r_2$ 是在区间[0, 1]内随机生成的值, 用于控制算法的探索与开发行为。通过不断更新灰狼的目标位置, 算法能够进行全局搜索以寻找最优解。

### 1.2 支持向量机分类原理

支持向量机 (SVM) 是一种监督学习算法, 广泛应用于分类和回归任务。在实际应用中, SVM通常用于二分类问题, 但它也可以扩展来处理多分类问题。假设我们的数据集包含N个样本点  $(x_i, y_i)$ , 其中每个  $x_i$  均为d维的特征向量。我们的目标是找到一个超平面, 将这些数据点进行划分, 使得每个样本点满足以下条件:

$$y_i(w \cdot x_i + b) \geq 1, \forall i \quad (6)$$

其中w是超平面的法向量, b是偏置项,  $x_i$ 是数据点,  $y_i$ 是数据点的类别标签, 取值为+1或-1。对于超平面与支持向量之间的“间隔”, 超平面  $w \cdot x_i + b = 0$  到任意支持向量  $x_i$  的距离为:

$$\frac{w \cdot x_i + b}{\|w\|} \quad (7)$$

为了确保数据点能够被正确分类并且具有最大的间隔, 我们希望所有的数据点都能满足以下约束条件:

$$y_i(w \cdot x_i + b) \geq 1 \quad (8)$$

最大化间隔等同于最小化  $\|w\|$ , 因为间隔与w成正比。因此, 支持向量机 (SVM) 的目标是最大化间隔, 并最小化  $\|w\|^2$ 。之所以选择  $\|w\|^2$  作为优化目标, 是因为常数项通常在计算中被去除, 从而简化了推导过程。

总而言之, SVM通过寻找一个最大化分类间隔的最优超平面来完成分类任务。通过引入拉格朗日乘子法和核技巧, 借助这些数学推导, SVM不仅能够处理线性问题, 还能应对复杂的非线性分类问题。

### 1.3 灰狼优化支持向量机方法

灰狼优化支持向量机 (GWO-SVM) 是一种结合了灰狼优化 (GWO) 算法与支持向量机 (SVM) 的混合方法。GWO算法模拟灰狼的社会结构和领导层次, 指导搜索最优解。其目标是通过精细调整SVM的超参数来提高分类性能。

如图2所示, GWO-SVM首先随机初始化多个灰狼个体, 每个个体代表一个潜在的SVM解。然后评估每个个体的适应度, 并根据灰狼的社会行为规则更新它们的位置, 以逐步收敛到最佳的SVM超参数集。在每次迭代中, 选择表现最好的灰狼作为当前最优解, 并不断重复这一过程, 直到达到最大迭代次数或满足终止准则为止。

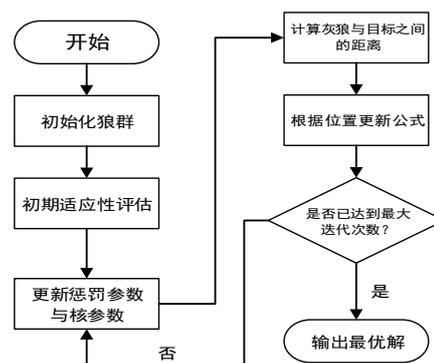


图2 GWO-SVM混合模型技术流程图

在实际应用中, 通过优化SVM的参数, GWO算法有效提高了模型分类的准确性, 并减少了过拟合的风险, 这为变压器故障的准确诊断提供了技术支持。

## 2 变压器故障气体数据处理

本研究的数据来自某电力变压器油中的溶解气体测量数据集。该数据集包含了五种常见气体(氢气、甲烷、乙烷、乙烯和乙炔)的浓度值, 并包括对应的故障类型标签。

根据IEC 60599标准中对电力变压器或油浸式电气设备故

障类型的专门分类,根据温度范围或放电能量的分类,低温对应T1范围;中温对应T2范围;中低温对应T2范围。一些文献或厂商分析软件会在T1和T2之间细分一个“中低温”区间(也可视为T1/T2过渡区),这是实际诊断中常见的定制分类;高温对应T3范围;低能量放电故障对应D1,通常指低能量电弧或火花放电、局部放电等;高能量放电故障对应D2。不同阶段释放的气体类型如表1所示。

表1 不同故障类别情况下部分气体浓度

气体种类	不同故障类别情况下部分气体浓度						
	Normal	D1	D2	T1/T2	T3	T2	T1
H <sub>2</sub>	189	4892	5423	8456	4563	879	2135
CH <sub>4</sub>	365	3210	2896	7569	14321	4563	1563
C <sub>2</sub> H <sub>6</sub>	184	1998	765	29872	7893	1586	1289
C <sub>3</sub> H <sub>8</sub>	420	5568	5879	13564	20186	3256	3014
C <sub>4</sub> H <sub>10</sub>	18.6	2156	56237	189	468	9.84	12.8

文献<sup>[4]</sup>指出,溶解气体分析通过检测变压器油中气体浓度的变化,能够有效识别不同类型的故障。

### 3 仿真结果与分析

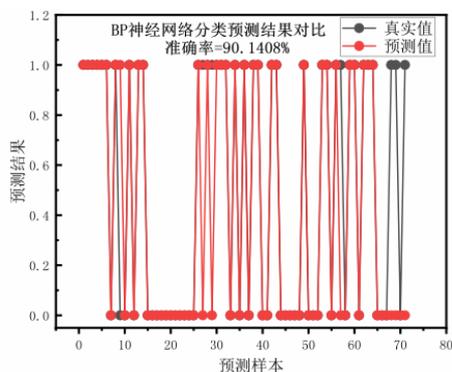
#### 3.1 气体分类结果

本研究中,使用MATLAB对SVM、BP神经网络和GWO-SVM模型在气体数据上的分类性能进行了分析,并将结果导入Origin进行可视化处理。

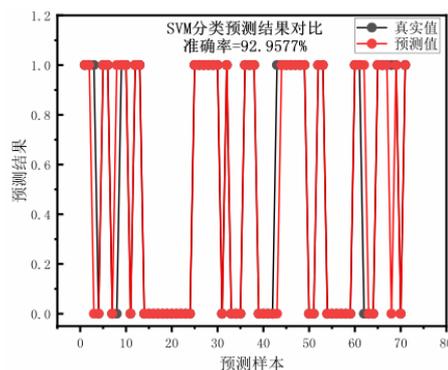
不同算法的分类准确率结果如表2所示。

表2 各分类算法准确度对比

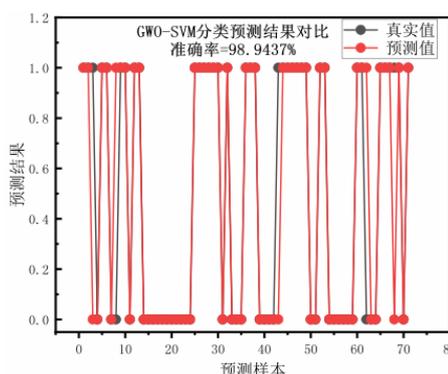
分类算法	分类准确率
GWO-SVM	98.94%
SVM	92.96%
BP神经网络	90.14%



(a) BP神经网络



(b) SVM



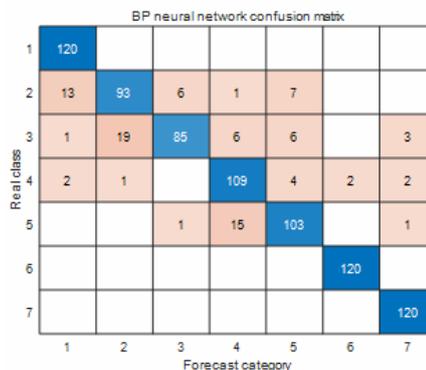
(a) GWO-SVM

图3 各分类算法的分类结果

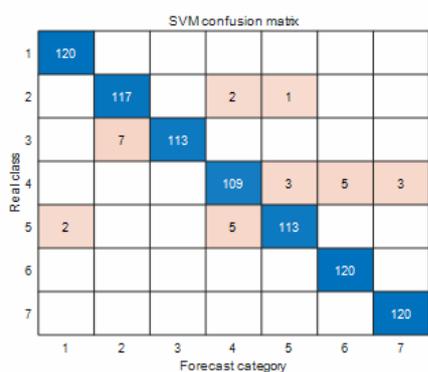
BP神经网络的准确率为90.14%,明显低于SVM和GWO-SVM的表现。由于其训练过程依赖于反向传播算法,BP神经网络对初始权重和学习率等因素较为敏感,容易陷入局部最优解,从而导致准确率下降。在SVM中,其交叉验证的准确率为92.96%。然而,与GWO-SVM的表现相比,SVM的准确率明显较低,模型优化效果也更为有限。GWO-SVM分类算法在准确性方面具有显著优势,且其最佳准确率稳定在98.94%,有效避免了过拟合。

#### 3.2 分类结果混淆矩阵分析

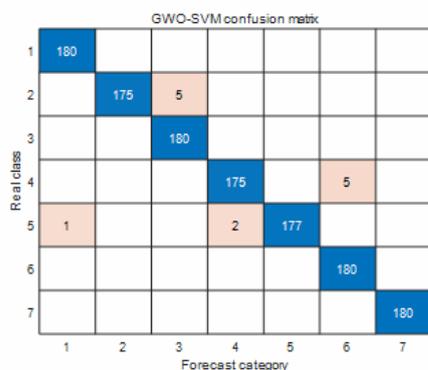
本文将混淆矩阵作为评估指标之一。每个模型的混淆矩阵展示了不同类别之间的预测结果,包括正确分类样本的数量和误分类样本的数量。各模型的混淆矩阵如图4所示。



(a) BP神经网络



(b) SVM



(a) GWO-SVM

图4 各分类算法混淆矩阵

混淆矩阵分析结果表明, GWO-SVM模型在分类准确性方面优于神经网络和SVM模型。将灰狼优化算法与SVM结合, 显著提高了模型的参数优化能力, 从而减少了误分类的发生。具体而言, GWO-SVM模型在所有类别上均表现出显著的错误率减少。这些结果凸显了将GWO与SVM结合使用的优势, 能够有效提升分类性能, 与近年来优化技术在提高预测准确性方面的趋势相一致<sup>[5]</sup>。

## 4 结论与展望

本文通过对三种常见分类算法——GWO-SVM、SVM和BP神经网络——进行系统评估, 深入分析并比较它们在多类别分类任务中的应用。总体来看, GWO-SVM展示了显著的优势, 尤其是在处理多类别和复杂数据集时, 能够有效提升分类准确性, 避免过拟合, 并更好地处理类别之间的细微差异。通过将灰狼优化算法与SVM参数调优相结合, GWO-SVM在处理复杂数据集时展现了更高的准确性和适应性。在准确性方面, GWO-SVM实现了98.94%的分类准确率, 显著优于SVM(92.96%)和BP神经网络(90.14%)。因此, GWO-SVM不仅在本研究中表现优异, 而且为实际应用中的分类任务提供了可靠且高效的解决方案。

### [基金项目]

南方电网科技项目“储能电站多参数协同极早期火灾探测预警技术研究”(031900KC23070050)。

### [参考文献]

- [1]陈图南,马凤翔,王刘芳,等.高分子渗透膜在变压器油中溶解气体分析中的应用[J].电工技术学报,2022,37(03):750-66.
- [2]KOK Z H,MOHAMED SHARIFF A R,ALFATNI M S M,et al.Support Vector Machine in Precision Agriculture: A review[J].Computers and Electronics in Agriculture,2021,191:106546.
- [3]赵明星.考虑运行损耗的变电站主变压器局部放电故障诊断[J].自动化仪表,2024,45(12):24-8.
- [4]李长海.基于支持向量机的油浸式电力变压器故障诊断方法研究[J].电气应用,2019,38(05):67-72.
- [5]张腾跃.电气设备状态监测与故障诊断方法研究[C]//2025工程技术应用与管理交流会论文集,2025:1-3.

### 作者简介:

蔡志亮(1981--),男,汉族,广东东莞人,硕士,高级工程师,研究方向为储能电池故障分析。