

# 基于 IPSO 优化 SVM 的变压器故障诊断

邵黎\*, 杨建民

内蒙古电力(集团)有限责任公司呼和浩特供电公司, 内蒙古呼和浩特, 中国

\*通讯作者

**【摘要】**为有效解决变压器故障诊断准确率低的问题, 本文提出一种基于改进粒子群算法(Improved Particle swarm optimization, IPSO)优化支持向量机(Support Vector Machine, SVM)的变压器故障诊断新方法, 旨在提升变压器故障识别的准确性与鲁棒性。具体而言, 首先利用主成分分析(Principal Component Analysis, PCA)对高维故障特征进行降维处理, 保留关键判别信息并削弱冗余与噪声干扰; 其次, 引入一种 IPSO 策略, 自动寻优 SVM 的关键超参数, 最终构建参数自适应、泛化能力强的 SVM 分类器完成故障类型判别。在内蒙古某电力公司变压器故障样本数据上的实验验证表明, 该集成方法具备良好的实用性与诊断可靠性, 综合故障诊断准确率为 99.67%。与 SVM 模型和 PSO-SVM 模型相比分别提升了 7.34% 和 2.67%, 验证了所提方法对变压器故障诊断的有效性和先进性。

**【关键词】**IPSO; SVM; PCA; 变压器; 故障诊断

## 1. 引言

当前, 人工智能、传感监测与大数据分析等前沿技术正广泛应用于电力设备状态感知领域, 海量在役设备持续产生的运行数据, 为构建具备自感知、自诊断与自决策能力的新型智能电网提供了坚实的数据基础[1]。作为智能电网的关键枢纽, 电力变压器不仅造价高昂, 更承担着电能变压、分配与长距离输送的核心功能。其长期运行中易受绝缘老化、局部放电等因素影响, 诱发多种典型故障。此类故障会显著改变设备的多维特征响应, 包括油中溶解气体组分(如  $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$  等)[2]。其中, 溶解气体分析(dissolved gas analysis, DGA)因其非侵入性与高灵敏度, 已成为现场最主流的故障预警手段[3]。现有的特征气体处理方法主要包括: 特征气体识别法、三比值法、罗杰斯比值法、杜瓦尔三角图法等[4]。但受限于故障机理的强非线性、气体生成路径的耦合性以及设备个体差异性, 传统基于经验阈值与固定比值的诊断方法普遍存在判据僵化、边界模糊、容错性差等问题, 难以精准刻画故障演化的过渡态与交叉态[5]。

为提升变压器故障诊断的判别精度与鲁棒性, 研究者陆续将多种智能计算方法引入该领域, 典型代表包括模糊逻辑系统、人工神经网络、卷积神经网络以及支持向量机(SVM)[6]。上述方法通过不同建模机制挖掘故障特征与类别间的映射关系, 有力推动

了智能化诊断技术的发展。然而, 各类方法在实际应用中仍面临固有局限: 模糊系统依赖专家经验设定隶属函数与规则, 参数整定主观性强; 神经网络虽具备强非线性拟合能力, 但易受初始权值影响而收敛至次优解; 卷积神经网络对超参数高度敏感, 缺乏自适应调优机制[7]。SVM 作为一种强泛化能力的监督学习模型, 已被广泛应用于模式分类任务, 其最初面向二分类问题设计, 后经扩展形成多种多类划分策略, 显著增强了在变压器故障诊断中对多重故障类型的区分能力[8]。值得注意的是, 多类 SVM 的分类性能高度依赖于核函数类型及其对应参数的协同配置。为缓解高维故障特征带来的计算负担并提升建模效率, 本文首先采用 PCA 对原始输入数据进行降维压缩, 在保留主要故障判别信息的同时剔除冗余与噪声成分。进一步地, 针对传统人工试凑法在参数寻优中主观性强、效率低、易陷入次优解等问题, 本研究引入 IPSO 算法对 SVM 的关键参数进行优化。最终, 在经 PCA 预处理的特征子空间内, IPSO 驱动的 SVM 可自适应锁定最优超参数配置, 从而构建出兼顾精度与鲁棒性的故障识别模型。该 PCA-IPSO-SVM 融合框架不仅加快了训练与推理速度, 更显著提升了诊断准确率与稳定性。

## 2. 理论基础

### 2.1 PCA

为缓解高维故障特征对 SVM 建模效率

与泛化性能的不利影响,数据预处理成为构建高性能诊断模型的关键前置环节。本文采用PCA作为降维手段,其核心思想是通过正交变换将原始高维故障特征空间映射至一组彼此线性无关、互不冗余的新坐标轴—即主成分[9]。这些主成分按方差贡献度由大到小排序,累计贡献率可定量表征所保留信息的完整性;实践中,通常依据设定阈值选取前 $k$ 个主成分,以在显著压缩维度的同时最大限度维持原始数据的判别结构与统计特性。

设原始故障数据集由 $n$ 个独立样本构成,每个样本包含 $p$ 个表征变压器运行状态的特征变量,则该数据可形式化表示为一个 $n \times p$ 维的观测矩阵。

$$X_{n \times p} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} \quad (1)$$

为求解主成分,需找出 $i(i \leq p)$ 个线性函数:  $y_{ji} = A_i^T X_j$ , 设  $Y_{ji} = (y_{1i}, y_{2i}, \dots, y_{ni})^T$ , 为得到最大方差, 可得:

$$\begin{cases} \max \text{var}(Y_{ji}) = \max A_i^T \sum A_i \\ A_i^T A_i = 1 \end{cases} \quad (2)$$

其中,  $\sum$ 为协方差矩阵。

本文采用拉格朗日乘子法对式(2)所示的约束优化问题进行求解。相应地,构造其拉格朗日函数如下:

$$Q(A_i) = A_i^T \sum A_i - \lambda_j (A_i^T \sum A_i - 1) \quad (3)$$

其中,  $\lambda_j$ 为特征值,  $A_i$ 为对应的特征向量。由于 $A_i$ 的值不为0,  $A_i^T \sum^* A_i = \text{var}(A_i^T X_j) > 0$ , 所以 $\sum$ 为正定矩阵。设:

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0 \quad (4)$$

本文选择 $p$ 个主成分的累计贡献率大于90%时的成分构建新的故障特征向量。

## 2.2 SVM

SVM是一种以结构风险最小化为理论基础的监督式学习算法,其本质在于通过在映射后的高维特征空间中寻求一个最优分离超平面,同步实现分类准确性与模型泛化能力的平衡[10]。区别于仅追求训练误差最小的经验风险最小化范式,SVM通过引入间隔最大化机制,在样本数量有限、特征维度较高或类别分布呈非线性可分的情形下,展现出更优的稳定性与推广性能。该优化目标可严格建模为一个具有线性约束的凸二次规划问题,其标准数学表达形式如下所示。

$$\begin{cases} \min \frac{1}{2} (\omega \times \omega) + C \sum_{i=1}^n \varepsilon_i \\ \text{s.t. } y_i [(\omega \times x_i) + b] \geq 1 - \varepsilon_i, \varepsilon_i \geq 0, i=1, \dots, n \end{cases} \quad (5)$$

其中,  $C$ 为惩罚系数,  $\varepsilon_i$ 为松弛因子,为提升求解效率并便于引入核技巧,本文对式(11)所描述的原始约束优化问题引入拉格朗日乘子,构造其对偶形式。该等价转换不仅降低了问题维度,还使优化目标仅依赖于样本间的内积运算,从而将原问题转化为如下以拉格朗日乘子为优化变量的对偶规划问题:

$$\begin{cases} \max \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j a_i a_j \\ \text{s.t. } \sum_{i=1}^n a_i y_i = 0, 0 \leq a_i \leq C, i=1, \dots, n \end{cases} \quad (6)$$

在求解式(6)所表述的对偶优化问题后,可推导出SVM的最终判别模型,其分类决策函数表达为:

$$f(x) = \text{sgn} \left[ \sum_{i=1}^n a_i y_i K(x_i, x) + b \right] \quad (7)$$

其中,  $K$ 为核函数,本文采用径向基核函数。其具体为:

$$K(x_i, x) = \exp(-g \|x_i - x\|^2) \quad (8)$$

由以上分析可知,SVM模型的关键参数 $[K, C]$ 对模型的分类精度影响较大,需要采用智能优化算法对其进行参数优化。

## 2.3 IPSO

如前文所述,在SVM开展故障识别任务时,关键步骤之一是合理选取其关键参数 $[K, C]$ 。为高效获取这两类超参数的最优组合,本文引入一种IPSO策略,以提升搜索效率与全局寻优能力。

设二维优化空间中初始化一个由 $S$ 个粒子构成的种群,第 $s$ 个粒子的位置向量表示为 $q_s = (q_{s1}, q_{s2})$  ( $s=1, 2, \dots, S$ ), 每个位置对应一个待评估的候选解。相应地,该粒子的运动状态由速度向量 $v_s = (v_{s1}, v_{s2})^T$ 刻画;其历史最优位置记为 $P_s = (P_{s1}, P_{s2})^T$ 。在整个种群中,所有粒子迄今所发现的最佳解构成全局最优位置,记作 $P_g$ 。那么粒子的速度为:

$$v_{sd}(t+1) = wv(t) \cdot v_{sd}(t) + c_1(t)r_1(t)$$

$$(P_{sd}(t) - q_{sd}(t)) + c_2(t)r_2(t)(P_{gd}(t) - q_{sd}(t)) \quad (9)$$

$$q_{sd}(t+1) = q_{sd}(t) + v_{sd}(t+1) \quad (10)$$

其中,  $c_1(t)$ 和 $c_2(t)$ 分别为加速度常数,

$wv(t)$ 为速度权重。一般而言，惯性权重  $wv(t)$  的取值大小直接影响算法的搜索倾向：较大值有助于增强全局探索能力，促进种群跳出局部最优；较小值则有利于提升局部开发精度，加快收敛速度。然而，传统的线性递减策略形式固定、适应性不足，难以兼顾不同优化阶段对探索与开发的动态需求，从而制约了整体寻优性能。为此，本文设计了一种新型随机化惯性权重机制，以增强算法在复杂、非平稳优化环境下的自适应调节能力与鲁棒性。

$$\begin{cases} wv(t)=\alpha_1+\epsilon/2.0, k \geq 0.05 \\ wv(t)=\alpha_2+\epsilon/2.0, k < 0.05 \end{cases} \quad (11)$$

$$k = \frac{fit(t)-fit(t-10)}{fit(t-10)} \quad (12)$$

其中， $fit$  为适应度函数值， $\alpha_1$  等于 0.5， $\alpha_2$  等于 0.4， $\epsilon$  为区间 0 至 1 内随机数。 $c_1(t)$  和  $c_2(t)$  的具体调整办法如下式所示：

$$\begin{cases} c_1(t)=c_{11}+(c_{12}-c_{11})\frac{t}{T} \\ c_2(t)=c_{21}+(c_{22}-c_{21})\frac{t}{T} \end{cases} \quad (13)$$

其中， $c_1(t)$  和  $c_2(t)$  分别由  $c_{11}$  和  $c_{21}$  递减至  $c_{12}$  和  $c_{22}$ 。

### 2.4IPSO 优化 SVM

针对 SVM 关键参数取值问题，本文采用所提 IPSO 算法对其进行参数优化，适应度函数本文采用 SVM 的故障诊断准确率，具体为：

$$Fit = \frac{F_T}{F_T + F_N} \quad (14)$$

其中， $F_T$  和  $F_N$  分别为分类正确和错误的样本数。具体流程如图 1 所示。




图 1.基于 IPSO 优化 SVM 流程图

### 3.故障诊断流程

如图 2 所示，本文提出了一种融合 PCA、SVM 与 IPSO 的变压器故障诊断框架。该框架由两个核心模块构成：首先，针对溶解气体浓度等多维故障特征数据，引入 PCA 进行降维与特征提取，以提升数据表征能力并削弱冗余信息；其次，采用 IPSO 智能算法对 SVM 的关键超参数进行自适应寻优，从而增强分类器的泛化性能与诊断精度。




图 2.故障诊断流程

### 4.实验分析

本文实验数据来自内蒙古地区某电力公司真实变压器数据，实验共采集变压器六类运行状态样本数据，样本数据分布如图表 1 所示。

表 1.实验数据分布

状态	类别标签	训练集	测试集
局部放电	1	50	50
中低温过热	2	50	50
高温过热	3	50	50
低能放电	4	50	50
高能放电	5	50	50
正常	6	50	50

首先将变压器六类运行状态样本数据采用 PCA 进行降维，采用 SVM 作为故障诊断模型，针对其关键参数， $[K,C]$  对模型的分类精度影响较大的问题，本文提出 IPSO 算法对其进行参数优化，建立 IPSO-SVM 故障诊断模型。将测试集样本输入到模型中进行故障诊断，最终的实验结果如图 3 所示。

如图 3 所示，基于 IPSO-SVM 模型的故障诊断结果中，300 个测试样本仅有 1 个样本分类错误，将一个低能放电样本错误的分类

高温过热，单一类别的故障诊断准确率为98%，其余五类运行状态分类均达到100%。六类运行状态综合故障诊断准确率为99.67%。为验证所提方法的有效性，将本文所提方法与SVM，PSO-SVM模型进行对比，所得结果如表2所示。




图3.基于IPSO-SVM的故障诊断结果  
表2 对比实验结果

方法	测试集样本数	分类错误样本数	准确率/%
SVM	300	23	92.33
PSO-SVM	300	9	97
本文所提	300	1	99.67

如表2所示，本文所构建的诊断模型取得了99.67%的最高识别准确率。相较于SVM模型和PSO-SVM模型，其综合故障分类准确率分别提升了7.34个百分点与2.67个百分点。

### 5. 结论

为提高变压器故障识别的可靠性与精度，本文设计了一种融合PCA与IPSO算法优化SVM诊断策略。主要研究成果如下：

1)采用PCA进行降维，有效去除特征冗余和虚假分量，为下一步的故障诊断提供了保证。

2)针对SVM模型故障诊断准确度受关键参数影响的问题，在PSO算法的基础上提出了IPSO算法，以模型的最大故障分类准确率为适应度函数对其进行了参数优化后建立了IPSO-SVM故障诊断模型，测试集样本的综合故障诊断准确率为99.67%。

3)将本文所提方法与SVM模型和PSO-SVM模型进行了对比，实验结果表明，所提方法的综合故障准确率分别提升了7.34%和2.67%。

### 参考文献

- [1]Rahim E A G A, Ibrahim H K, Ibrahim S M, et al. Fuzzy logic-based transformer fault diagnosis employing roger's and IEC techniques[J]. Journal of Engineering and Applied Science, 2025, 72 (1): 265-265.
- [2]舒勇, 谭政, 张昆, 等.不平衡样本下基于改进MWMOTE和优化LSSVM的变压器故障诊断方法[J].三峡大学学报(自然科学版), 2025, 47 (S1): 1-10.
- [3]Patel A R, Desai P J, Bhavsar C R, et al. Parallel support vector machine classification framework for diagnosis of transformer faults[J]. Electrical Engineering, 2026, 108(2): 74-74.
- [4]陈新岗, 敖怡, 张知先, 等.改进生成对抗网络结合MSDA-ViT对于小样本变压器故障特征气体的拉曼光谱判别方法[J].激光与光电子学进展, 2025, 62 (23): 414-424.
- [5]Alenezi M, Massoud J, Ghomeed T, et al. Bees Algorithm and PSO-Optimized Hybrid Models for Accurate Power Transformer Fault Diagnosis: A Real-World Case Study[J]. Energies, 2025, 18 (22): 5964-5964.
- [6]马月红, 王晓成, 李桂景, 等.基于ISSA优化SVM的牵引变压器故障诊断方法研究[J].铁道学报, 2026, 48 (02): 48-55.
- [7]Ding X, Li Z, Tang M, et al. An Integrated IEWT and CNN-Transformer Deep Architecture for Intelligent Fault Diagnosis of Bogie Axle-Box Bearings[J]. Electronics, 2026, 15 (4): 804-804.
- [8]张道俊, 耿进龙.电力输电线路IPSO-LS-SVM智能识别模型构建与测试[J].光源与照明, 2025, (12): 112-114.
- [9]管聪, 吴超, 张泽辉, 等.基于PSR-PCA-CNN的船舶滚动轴承小样本智能故障诊断[J].中国舰船研究, 2025, 20 (S1): 139-149.
- [10]Felix O L, Martins S S D C H D, Monteiro V B A U, et al. Multiple Fault Diagnosis in a Wind Turbine Gearbox with Autoencoder Data Augmentation and KPCA Dimension Reduction[J]. Journal of Nondestructive Evaluation, 2024, 43 (4): 114-114.