

# 基于 IPSO 优化 KELM 的变压器故障诊断

石林, 王雅菲\*

内蒙古电力(集团)有限责任公司呼和浩特供电分公司, 内蒙古呼和浩特, 中国

\*通讯作者

**【摘要】**针对变压器故障诊断准确率不高的问题, 本文提出一种基于改进的粒子群优化算法(Improved Particle Swarm Optimization Algorithm, IPSO)优化核极限学习机(Kernel Extreme Learning Machine, KELM)的变压器故障诊断方法, 以KELM为分类核心, 引入IPSO对其进行超参数寻优。为提升建模效率, 在KELM建模前, 采用逐步回归法对高维DGA特征进行筛选与压缩, 兼顾信息保留与计算轻量化。实验结果表明, 所提出的IPSO-KELM模型在故障识别准确率上明显优于传统KELM、和PSO-KELM模型, 为变压器故障诊断提供了新的思路。

**【关键词】**DGA, KELM, IPSO, 变压器, 故障诊断

## 1. 引言

电力变压器作为电网骨干架构中的核心元件, 其运行状态直接关系到整个电力系统的安全与稳定, 一旦发生故障, 极易引发连锁性供电中断, 严重削弱系统可靠性[1]。尤其在高电压、大负荷工况下, 内部易出现局部放电、电弧击穿等电气异常, 进而加速绕组导体劣化与绝缘材料老化, 不仅导致电能质量下降, 还可能诱发短路、爆燃甚至火灾事故, 带来严重的经济损失与安全隐患[2]。由于其结构复杂、集成度高, 故障后的修复周期长、技术门槛高, 多数情况下需整体更换, 投入成本巨大。因此, 在日常运行与检修管理中, 构建高效、灵敏的早期故障预警机制尤为关键——这不仅能指导变压器油质的科学监测与精准维护, 还可显著压缩非计划停运时间、优化运维资源配置, 并为持续输出稳定、优质的电能提供坚实保障[3]。

当前, 针对变压器油中潜伏性故障的识别, 主流方法主要包括三比值法、罗杰斯比值法、特征气体分析法等。然而, 这些基于气体浓度比值的判别模型普遍依赖专家经验设定阈值, 其本质是将特定气体组合与典型故障模式进行经验性映射, 缺乏对复杂非线性关系的建模能力。各类方法均存在明显短板: 如判据区间刚性过强、边界模糊区域误判率高、对低浓度或共存故障敏感度不足, 且难以挖掘气体成分间潜在的耦合规律与动态演化特征。以特征气体法为例, 其诊断结论高度依赖某类标志性气体是否达到可检出水平, 当故障初期产气量微弱或多种故障并

存时, 极易出现“无结论”或“误归类”现象[4]。因此, 突破传统经验规则的局限, 构建更具自适应性与泛化能力的故障识别模型已成为亟待解决的关键问题。

近年来, 人工智能技术凭借其强大的非线性拟合、特征学习与模式识别能力, 在电力变压器状态评估、故障预测及诊断建模中展现出优异性能; 与此同时, 智能优化算法在提升模型精度、鲁棒性与收敛效率方面亦发挥了重要作用, 为实现更精准、更可靠的油色谱故障诊断提供了新路径[5]。常见的方法包括支持向量机(Support Vector Machine, SVM), 极限学习机(Extreme Learning Machine, ELM)和KELM等[6]。其中SVM作为一类成熟的监督式机器学习方法, 已在机械装备状态监测、电力系统故障识别及航空航天健康评估等多个工业领域获得广泛应用。其突出优势体现在: 在训练样本有限的情况下仍能保持良好的泛化性能, 并具备较强的高维特征空间建模能力。然而, 该算法亦存在若干实践瓶颈: 一是模型训练耗时较长, 尤其在大规模数据集上计算开销显著; 二是分类性能高度依赖于惩罚因子、核函数类型及其超参数的合理配置, 调参过程缺乏理论指导且易陷入局部最优; 三是面对多类别故障诊断任务时, 需借助“一对多”或“一对一”等策略进行扩展, 导致模型结构复杂度上升、决策逻辑冗余, 进而影响实时性与可解释性。KELM是在传统ELM基础上引入核函数机制所构建的改进模型。相较于原始ELM, KELM无需显式设定隐层节点数量,

亦不依赖随机权值初始化，而是通过核技巧将输入数据映射至高维特征空间，从而显著增强对复杂非线性关系的表征能力。该方法在保持训练高效性的同时，展现出更优的泛化性能、更强的抗干扰鲁棒性以及更高的分类准确率；此外，其结构简洁、超参数数量少，便于与智能优化算法协同调参，在故障诊断等实际工程任务中具备良好的适配性与实用性，因此本文采用 KELM 作为故障诊断模型。但是 KELM 模型的关键参数对模型的性能影响较大，需要采用合适的优化算法对其进行参数优化。

基于以上分析，本文提出一种基于 IPSO 优化 KELM 的变压器故障诊断新方法。在采用训练集对 KELM 模型进行训练前本研究引入逐步回归分析方法对原始特征集进行筛选与精简，旨在剔除冗余或低贡献度变量，保留对故障识别最具判别力的关键气体组分及其比值特征。该过程不仅有效降低了输入维度，缓解了“维数灾难”问题，更提升了特征的物理可解释性与模型训练效率，确保后续 KELM 建模所依赖的数据集兼具代表性与有效性。针对 KELM 关键参数取值问题，本文采用 IPSO 算法对其进行参数优化，建立 IPSO-KELM 模型，将测试集样本输入到 IPSO-KELM 模型中进行故障诊断。

## 2. 理论基础

### 2.1 逐步回归法降维

逐步回归是一种基于统计推断的特征筛选方法，其核心机制是通过迭代引入或剔除自变量，依据偏  $F$  检验等统计准则动态评估各变量对模型解释力的边际贡献[7]。该方法无需人工预设特征子集，可自动识别并保留对故障类型判别具有显著统计意义的关键气体组分及其衍生比值，在训练集与测试集上同步实现特征空间的精炼与优化。借助偏  $F$  统计量的显著性检验，不仅能量化不同气体成分对分类结果的影响强度，还可揭示其在故障演化过程中的主导作用机制，从而为构建物理意义明确、诊断逻辑清晰的 KELM 模型提供可靠的数据支撑。

本研究采用前向逐步回归策略开展特征筛选，以油中溶解气体分析检测所得的各类气体组分作为候选变量，依据其在模型构建过程中对响应变量（即故障类型标签）的统计显著性，依次纳入最优子集。具体而言，每一轮迭代中，系统自动评估各未入选变量的偏  $F$  检验  $p$  值，仅当  $p$  值小于预设进入阈

值  $\alpha$  时，该变量才被引入模型；反之，在已入选变量中，若某变量的  $p$  值超过剔除阈值  $\beta$ ，则将其移出。该过程持续至无变量满足进出条件为止，最终形成的特征组合不仅具备严格的统计学支撑，也更契合变压器故障机理的物理表征需求。

### 2.2 KELM

作为 ELM 的升级算法。KELM 摒弃了 ELM 中隐层权值与偏置随机赋值的方式，转而通过核函数隐式映射输入数据至高维再生核希尔伯特空间，从而在无需显式构造隐层结构的前提下，实现对复杂非线性关系的高效建模[8]。理论与实验均表明，KELM 在保持训练速度优势的同时，显著提升了模型的泛化能力、数值稳定性及分类鲁棒性[9]。其输出函数可形式化表示为：

$$f(x) = H \times \omega = L \# \quad (1)$$

其中， $L$  为期望输出， $\omega$  为权重，具体为：

$$\omega = H^T \cdot L \quad (2)$$

其中， $H^T$  为  $H$  的逆矩阵，为增强模型对噪声与异常样本的容忍能力，提升训练过程的数值稳定性与泛化鲁棒性，本研究在 KELM 的目标函数中引入正则化项，通过惩罚系数  $C$  控制模型复杂度与经验风险之间的平衡，并采用单位矩阵  $I$  构建正则化约束。由此将原始无约束最小二乘问题转化为如下带正则项的优化形式：

$$\omega = H^T (HH^T + \frac{1}{C})^{-1} L \quad (3)$$

核函数本文采用径向基核函数，具体为：

$$\Omega = \exp(-\gamma |x, x_i|^2) = \begin{bmatrix} K(x_1, x_1) & \dots & K(x_1, x_n) \\ \vdots & \ddots & \vdots \\ K(x_n, x_1) & \dots & K(x_n, x_n) \end{bmatrix} \# \quad (4)$$

其中， $\gamma$  为核函数参数。最终可得目标函数为：

$$f(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_n) \end{bmatrix}^T (\Omega + \frac{1}{C})^{-1} L \# \quad (5)$$

上述分析表明，KELM 模型的诊断性能高度依赖于两个核心超参数：RBF 核函数的宽度参数  $\gamma$  与正则化惩罚系数  $C$ 。因此，为突破人工调参的经验局限，亟须引入具备全局搜索能力与自适应机制的智能优化策略，以在高维超参数空间中高效定位最优组合，从而实现模型诊断精度与鲁棒性的同步提升。

### 2.3 粒子群算法

粒子群算法 (Particle swarm optimization

algorithm, PSO) 是一种源于群体智能范式的启发式全局优化算法, 其设计思想受自然界中鸟类集群觅食行为的启发[10]。该算法结构简洁、参数少、收敛速度快, 且无需梯度信息, 在超参数寻优等黑箱优化任务中展现出良好的鲁棒性与实用性。该算法的主要思想为:

首先, 对粒子群进行随机初始化, 为每个粒子赋予初始位置和初始速度。这些位置向量对应 KELM 的两个关键超参数: 核函数的宽度参数  $\gamma$  和正则化惩罚系数  $C$ 。接着, 基于当前粒子的位置, 训练 KELM 模型并评估其分类准确率, 该准确率即作为该粒子的适应度值。随后, 将各粒子当前的适应度与其历史最优个体适应度进行比较; 若当前适应度更优, 则更新  $pb_{id}^k$ , 同时将该粒子当前位置  $X_{id}^k$  设为其新的个体最优位置。所有粒子中适应度最高的个体适应度被选为全局最优适应度  $gb_{bd}^k$ 。最后, 依据标准 PSO 算法的速度—位置更新公式, 迭代调整各粒子的速度与位置。

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (6)$$

$$V_{id}^{k+1} = wV_{id}^k + c_2r_2(gb_{bd}^k - X_{id}^k) + c_1r_1(pb_{id}^k - X_{id}^k) \quad (7)$$

其中,  $c_1$  和  $c_2$  为加速因子,  $V$  为速度,  $X$  为位置。本研究中, 粒子位置向量  $X_i$  的各维度分别对应 KELM 模型的两个核心超参数: 核函数的宽度参数  $\gamma$  和正则化惩罚系数  $C$ 。惯性权重  $w$  则依据动态调整策略进行设定。

$$w = w_{max} - k \left( \frac{w_{max} - w_{min}}{k_{max}} \right) \quad (8)$$

其中,  $k_{max}$  为最大迭代次数。  $w$  为权重,  $w_{min}$  和  $w_{max}$  分别为其最大和最小值。

## 2.4IPSO

IPSO 在标准 PSO 框架基础上引入了一个关键机制: 为每个粒子单独维护一个“迭代最优解”  $I_b$ , 即该粒子在当前迭代轮次中探索到的最佳适应度值。这一设计有效增强了算法在搜索过程中的局部响应能力与收敛稳定性, 从而显著提升了最终解的精度与寻优效率。在 IPSO 中, 粒子的速度更新公式相应地进行了重构, 具体表达如下:

$$V_{id}^{k+1} = wV_{id}^k + c_3r_3(Ib_{id}^k - X_{id}^k) + c_2r_2(gb_{bd}^k - X_{id}^k) + c_1r_1(pb_{id}^k - X_{id}^k) \quad (9)$$

其中,  $Ib_{id}^k$  表示第  $k$  次迭代过程中, 任意粒子所探索到的最优适应度值; 参数  $c_3$  为动态引入的随机加速系数, 旨在增强粒子向该迭代最优解方向的趋近能力。其具体取值通

过如下公式生成:

$$c_3 = c_1 [1 - \exp(-kc_1)] \quad (10)$$

该策略的核心作用在于有效延缓算法陷入早熟收敛的风险, 同时在迭代后期增强种群向全局最优区域的定向搜索能力, 从而加快收敛进程并提升解的全局性。

## 2.5IPSO 优化 KELM 模型关键参数

针对 KELM 模型的关键参数, 核函数的宽度参数  $\gamma$  与正则化惩罚系数  $C$  的取值影响故障诊断问题, 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 KELM 模型的故障诊断准确度, 具体如下式所示:

$$Fit = \frac{F_T}{F_T + F_N} \quad (11)$$

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。

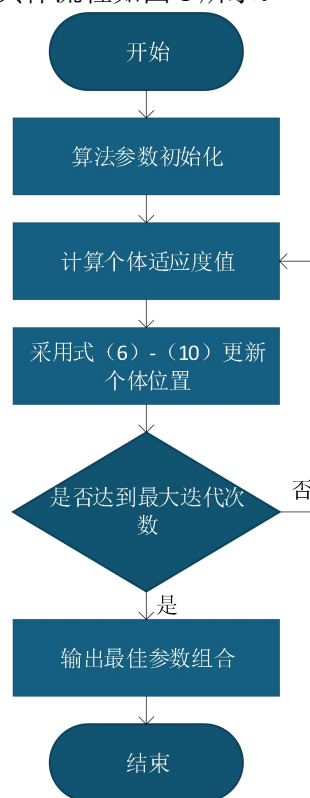


图 1. 基于 IPSO 优化 KELM 具体流程

## 3. 故障诊断流程

本文所提基于 IPSO 优化 KELM 的变压器故障诊断方法主要流程图如图 2 所示, 具体流程为:

1) 数据集采集, 本文针对变压器常见的六种运行状态进行研究, 因此需要采集变压器六种运行状态样本数据。

2) 采用逐步回归方法对故障特征进行降维处理, 并将其随机划分为训练集和测试集。

3) 采用 KELM 模型作为故障诊断模型，针对其关键参数， $\gamma$ 和  $C$  的取值问题，本文以模型最大分类准确率为适应度函数，采用所提 IPSO 算法对其进行参数优化，建立 IPSO-KELM 模型。

4) 将测试集样本输入到 IPSO-KELM 模型中进行故障诊断。

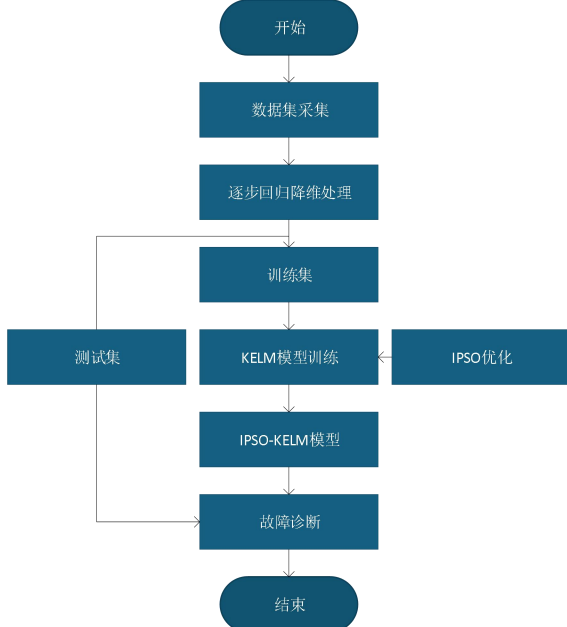


图 2.故障诊断程

#### 4.实验分析

本研究所用实验数据来源于内蒙古某地电力企业的实际运行记录，涵盖六种典型变压器工况样本，具体类别分布详见表 1。

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	80
中低温过热	2	50	80
高温过热	3	50	80
低能放电	4	50	80
高能放电	5	50	80
正常	6	50	80

首先，对采集的六类变压器运行状态样本实施逐步回归算法以实现特征降维；随后，构建基于 KELM 的故障识别模型。鉴于参数  $\gamma$  和  $C$  对分类性能具有显著影响，本文引入 IPSO 对其进行协同寻优，从而建立 IPSO-SVM 智能诊断模型。将预处理后的测试样本输入该模型，完成故障类型判别，最终分类效果如图 3 所示。

如图 3 所示，IPSO-KELM 模型在 480 个测试样本上的诊断表现优异：仅出现 1 例误判，即将 1 个正常运行样本误识别为高温过

热故障；对应地，正常类别的识别准确率为 98.75%，其余五类状态均实现 100%准确分类；整体六类综合诊断准确率达 99.79%。为进一步验证所提方法的优越性，本文将其与基础 KELM 模型及传统 PSO-KELM 模型开展对比实验，详细性能指标汇总于表 2。




图 3.基于 IPSO-KELM 模型的故障诊断结果

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/%
KELM	480	26	94.58
PSO-KELM	480	12	97.5
本文所提	480	1	99.79

如表 2 所示，本文所构建的诊断模型取得了 99.79% 的识别准确率。相较于 KELM 模型和 PSO-KELM 模型，其综合故障分类准确率分别提升了 5.21 个百分点与 2.29 个百分点。

#### 5.结论

为提升变压器故障识别的鲁棒性与判别精度，本文提出一种融合逐步回归与 IPSO 优化 KELM 的协同优化诊断框架。主要创新与成果归纳如下：

1) 引入逐步回归方法对原始特征集进行筛选与精简，在剔除冗余变量及噪声干扰项的同时保留最具判别力的特征子集，显著增强了输入数据的质量与模型泛化基础。

2) 针对 KELM 模型性能高度依赖核参数与正则化系数的问题，本文在标准 PSO 基础上设计了 IPSO 算法，并以最大化测试集分类准确率为目标函数开展参数寻优，构建出高性能 IPSO-KELM 诊断模型，其在测试集上的整体故障识别率达 99.79%。

3) 通过与基础 KELM 及 IPSO-KELM 模型进行对比实验，所提 IPSO-KELM 方法的综合准确率分别提升了 5.21 个百分点和 2.29 个百分点，验证了该融合策略的有效性与先进性。

参考文献

- [1]Çuhadaroğlu H, Uyaroğlu Y. Detection of Transformer Faults: AI-Supported Machine Learning Application in Sweep Frequency Response Analysis [J]. *Energies*, 2025, 18 (10): 2481-2481.
- [2]张富民, 张菁, 解大. 基于特征加权与 ISIA-RF 的油浸式变压器故障诊断 [J]. *实验室研究与探索*, 2026, 45 (01): 71-78+84.
- [3]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.
- [4]Abdelwahab M A S, Taha M B I, Fahim R, et al. Transformer fault diagnose intelligent system based on DGA methods. [J]. *Scientific reports*, 2025, 15 (1): 8263.
- [5]谭政, 张昆, 张军, 等. 基于等效电路模型的变压器匝间脉冲法绝缘故障诊断 [J]. *三峡大学学报 (自然科学版)*, 2025, 47 (S1): 11-16.
- [6]Lin L W, Fei P, Li Y Z. Transformer Fault Diagnosis Based on Online Sequential Extreme Learning Machine [J]. *Applied Mechanics and Materials*, 2014, 721 (721-721): 360-365.
- [7]韩智强, 左新黛, 周勇军, 等. 基于主成分-逐步回归的大跨弯连续刚构桥冲击系数计算 [J]. *公路交通科技*, 2022, 39 (01): 72-80.
- [8]Yao H, Zhang X, Guo Q, et al. Fault diagnosis method for oil-immersed transformers integrated digital twin model [J]. *Scientific Reports*, 2024, 14 (1): 20355-20355.
- [9]Qiang L, Chao W, Qing L. Application of GSABO-VMD-KELM in rolling bearing fault diagnosis [J]. *Journal of Vibroengineering*, 2025, 27 (8): 1474-1497.
- [10]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.