

基于 GWO 优化 KELM 的变压器故障诊断

杨建民*, 邵黎

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】溶解气体分析(Dissolved Gas Analysis, DGA)作为评估变压器内部运行状态与识别潜在故障的关键技术,已在电力系统中得到广泛应用。然而,传统依赖单一智能算法的诊断模型,在面对DGA数据固有的高维性、信息不完整性及类别边界模糊等问题时,往往泛化能力不足、判别精度受限。针对上述瓶颈,本文基于灰狼优化算法(gray wolf optimization, GWO)优化核极限学习机(kernel extreme learning machine, KELM)的变压器故障诊断新方法。具体而言:第一,基于Mercer条件,创新性地将径向基核(Radial Basis Function, RBF)与多项式核进行非线性加权组合,构造具备更强映射能力的复合核函数;针对核极限学习机(kernel extreme learning machine, KELM)模型的关键参数对模型分类性能影响较大的问题,利用GWO对其进行参数优化。实验部分内蒙古地区某电力公司变压器数据样本集,并融合多种DGA特征指标构建增强型输入特征空间。结果表明,所提方法的故障诊断准确率为98.89%,展现出更优的分类稳定性与诊断精度。

【关键词】DGA; GWO; KELM; 变压器; 故障诊断

1. 引言

作为电力系统中实现电压等级转换与能量高效传输的核心设备,电力变压器的运行状态直接关系到整个电网的安全稳定与经济运行,一旦发生突发性故障,不仅可能导致大面积停电,还可能引发高昂的维修成本与严重的社会影响[1]。因此,构建科学、及时、精准的故障预警与识别机制,对变压器健康状况进行动态评估与早期干预,已成为保障其长期可靠服役、提升电网韧性及优化运维成本的关键路径[2]。

DGA是识别油浸式变压器初期潜伏性故障的有效技术途径。当设备在运行中遭遇局部放电、过热或电弧等异常工况时,其内部绝缘体系会在电场与高温的协同作用下发生裂解反应,生成氢气、甲烷、乙炔等多种特征气体,这些气体溶解于油中并随油循环扩散,为故障类型与严重程度的判别提供了关键信息[3]。

基于油中溶解气体的种类构成与浓度分布特征,可有效反演变压器内部的异常物理化学过程,进而实现对故障性质(如过热、放电、受潮等)、演化阶段及风险等级的综合评估。长期以来,比值法、特征气体法、三角形图示法等经验性规则被广泛用于DGA数据解读[4-6]。尽管上述方法具有原理简明、实施便捷等优势,但其依赖人工设定阈

值、抗干扰能力弱、多准则间结论易冲突等问题,制约了诊断结果的一致性与鲁棒性[7]。近年来,人工智能技术的快速演进为DGA诊断范式升级提供了新契机:人工神经网络、SVM、模糊推理系统、贝叶斯网络、深度置信网络等智能模型相继被引入该领域[8]。这类数据驱动方法能够自动挖掘气体成分间的非线性关联,弱化对先验知识的依赖,在提升分类精度、增强泛化能力及支持早期预警等方面展现出显著优势,有力推动了变压器状态评估由经验判断向智能决策的转变。

极限学习机(Extreme Learning Machine, ELM)于2004年被提出,作为一种单隐层前馈神经网络的高效训练范式,其核心思想是随机初始化输入层到隐层的权值与偏置,仅需解析求解输出层权重,从而避免传统梯度迭代过程[9]。该方法在理论上具备万能逼近能力,可有效拟合任意连续函数,并适用于具有复杂边界或离散分布的数据分类任务。相较于SVM,ELM在模型训练效率、大规模数据适应性及泛化性能方面均展现出明显优势,因而被广泛拓展应用于多个工业故障诊断场景。但是ELM存在对隐层结构参数(如节点数量)及非线性映射函数高度依赖的问题,导致其输出结果易受随机初始化影响,稳定性不足、重复实验间波

动明显；同时，缺乏有效的正则化机制使其在小样本或噪声干扰较强场景下泛化性能受限。KELM通过引入核函数替代原始ELM中随机生成的隐层映射，从根本上规避了权值初始化带来的不确定性，显著增强了模型输出的稳定性与实验可重复性；同时，借助核技巧隐式实现高维特征空间映射，大幅提升了对复杂非线性关系的表征能力，在小样本、高噪声等实际工况下展现出更优的泛化表现[10]。

基于以上分析本文提出一种基于GWO优化KELM的变压器故障诊断方法。本研究提出一种面向变压器故障诊断的混合核极限学习机框架：首先，构造由全局核与局部核按自适应权重线性加权构成的复合核函数，兼顾数据整体分布趋势与局部细节特征，从而增强模型对DGA多维非线性模式的刻画能力；其次，将GWO算法用于高效寻优混合核的关键超参数，进而构建性能更优的定制化KELM结构；实验结果表明，所提方法在变压器六类运行状态中均实现了高准确率的故障诊断。

2.基于KELM的变压器故障诊断

2.1KELM

当ELM采用单节点输出时，其输出函数为：

$$f(x) = \sum_{i=1}^L \beta_i G(a_i, b_i, x) = \beta \cdot h(x) \quad (1)$$

其中， β_i 为隐含层节点*i*与输出层的权重， β 为输出的权重向量， $G(a_i, b_i, x)$ 为隐含层节点*i*的输出， $h(x)=[G(a_1, b_1, x), \dots, G(a_L, b_L, x)]^T$ 为隐藏层的输出向量。向量 $h(x)$ 构成了一种非线性特征变换函数，能够将原始*n*维输入样本*x*映射至一个维度为*L*的隐含特征空间*H*，从而在更高维空间中挖掘数据内在的判别性结构与潜在模式。将核函数引入到KELM后，其核矩阵为：

$$\Omega_{ELM} = HH^T : \Omega_{ELM} = h(x_i) \cdot h(x_j) = K(x_i, x_j) \quad (2)$$

ELM分类器的最终决策输出可等价地表达为：

$$f(x) = h(x)H^T \left(\frac{I}{\lambda} + HH^T \right)^{-1} T = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix} \left(\frac{I}{\lambda} + \Omega_{ELM} \right)^{-1} T \quad (3)$$

其中，*I*表示与隐层维度相匹配的单位

矩阵， λ 为控制模型复杂度与拟合偏差之间权衡的正则化参数，*T*为训练样本对应的编码标签矩阵。

2.2混合核函数

核函数按其响应特性可分为全局型与局部型两类：前者（如RBF核、多项式核）对输入空间中所有样本均赋予非零响应，侧重刻画数据的整体分布规律，因而具备良好的泛化能力，但对局部细节拟合不足；后者（如三角核、B样条核）仅在邻近区域产生显著响应，擅长捕捉局部结构与细微差异，学习精度高，但易受噪声干扰、外推能力有限。依据Mercer定理，任意满足正定性条件的核函数的非负线性组合仍构成合法Mercer核。据此，本文引入可学习权重系数，将全局核与局部核进行自适应加权融合，构建兼具强拟合性与高鲁棒性的混合核函数，以协同提升模型在复杂故障模式下的判别效能。高斯核函数 $K(x, y) = \exp(-\gamma \|x - y\|^2)$ 可将输入空间映射到一个高维的特征空间。该核函数形式简洁、优化收敛迅速，并具备较强的非线性拟合能力。基于上述优势，本文采用高斯径向基核作为局部核函数。其中，参数 γ 控制核函数的宽度，进而影响其在输入空间中的局部响应范围与泛化能力。当输入样本在特征空间中分布跨度较大时，多项式核函数 $K(x, y) = (xy + \eta)^d$ 仍能保持对全局结构的敏感性，其响应随内积线性增长，具有较强的尺度鲁棒性与整体建模能力，因而泛化性能优异。鉴于此，本文选取该核作为全局核组件；将其与局部高斯核按可学习权重融合后，构建出兼具全局趋势捕捉与局部细节刻画能力的复合型混合核函数。

$$K_H(x, y) = (1 - \omega) \exp(-\gamma \|x - y\|^2) + \omega (xy + \eta)^d \quad (4)$$

其中， ω 为权重，该参数用于调控全局核与局部核在混合核结构中的协同比重，实现二者贡献度的动态平衡；通过引入可调权重系数，可分别赋予全局核函数与局部核函数独立的线性组合系数，从而灵活适配不同数据分布特性下的建模需求。

2.3GWO

GWO是一种受灰狼群体等级制度及协同围猎机制启发的元启发式智能优化方法[11]。在GWO框架中，每只灰狼对应搜索空间中的一个潜在解向量。依据适应度值排序，将最优、次优及第三优个体分别标记为 α 、 β 和 δ 狼，构成领导层；其余个体统称

为 ω 狼，服从领导层的协同引导。整个优化过程由 α 、 β 和 δ 三者共同主导，它们通过模拟围捕行为动态调整位置，进而牵引整个种群向全局最优区域收敛。具体的位置更新机制由式 (5) - (12) 给出，涵盖包围、追捕与攻击三个阶段的数学建模。

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (5)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (6)$$

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (7)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (8)$$

$$\vec{a} = 2 - 2 \left(\frac{t}{t_{\max}} \right) \quad (9)$$

$$\begin{cases} \vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \\ \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \\ \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \end{cases} \quad (10)$$

$$\begin{cases} \vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha) \\ \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta) \\ \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \end{cases} \quad (11)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (12)$$

其中， t 为当前迭代次数， \vec{A} 和 \vec{C} 为系数向量， \vec{X}_α 、 \vec{X}_β 、 \vec{X}_δ 为 α 、 β 、 δ 的位置。

2.4 GWO 优化 KELM

KELM 的分类性能高度依赖于其超参数的选择，不同参数组合会直接影响故障识别模型的准确率。为提升模型泛化能力与判别精度，本研究引入 GWO 对混合 KELM 的参数进行自适应寻优。优化流程如下：

1) 算法参数初始化。

2) 对灰狼种群中各个体的适应度值进行评估与降序排列，其中适应度最优的前三名个体分别被定义为 α 狼、 β 狼和 δ 狼。

3) 首先随机生成两个独立均匀分布的系数 r_1 与 r_2 ，随后依据式 (7) - (9) 依次求解收敛控制参数 \vec{A} 、 \vec{C} 及 \vec{a} ；最后，结合式 (10) - (12) 对种群中各灰狼个体的位置进行迭代更新。

重新评估更新后种群中各个体的适应度值，并按优劣进行排序；若达到预设的收敛准则（如最大迭代次数或精度阈值），则终止优化过程，输出当前最优解及其对应适应度；否则，返回步骤 (3) 继续迭代寻优。

3. 故障诊断流程

变压器故障识别本质上属于典型的多类

别分类任务。为更有效地挖掘故障样本中的非线性判别特征，本文设计了一种融合多种核函数优势的极限学习机作为核心分类模型。流程如图 1 所示。所提出的诊断框架涵盖以下几个关键组成部分：

1) 故障样本获取：通过采集变压器油中 DGA 数据，覆盖多种典型故障模式，构建具有代表性的多类别故障样本数据库。

2) 特征构建与筛选：将经融合处理的多维特征集作为故障诊断模型的输入变量，该特征集综合了气体浓度比值、特征气体含量及衍生统计指标等多源信息，并通过相关性分析与冗余剔除策略进行优化筛选。

3) 数据标准化：针对各特征维度在数值尺度上的显著差异，引入式 (13) 所示的最小-最大归一化方法，将原始特征映射至区间 [0,1] 内，以增强模型训练的稳定性与收敛效率。

$$x^* = \frac{x_i - x_{i\min}}{x_{i\max} - x_{i\min}} \quad (13)$$

4) 数据集划分：将样本数据随机划分为训练集和测试集样本。

5) 模型学习与构建：基于划分所得的训练样本，对混合核极限学习机进行参数学习与结构优化，最终确立具备最优判别能力的故障诊断模型。

性能评估与统计分析：在测试集上对训练完成的模型开展性能验证，以全面量化模型的诊断效能与稳定性。

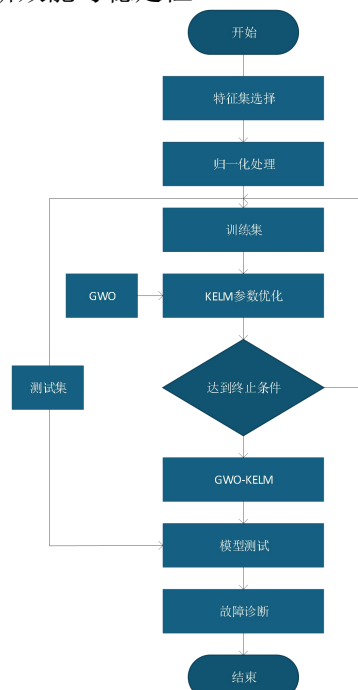


图 1. 故障诊断流程图

4. 实验分析

本研究数据来自内蒙古地区某电力公司变压器数据。实验数据分布具体如表 1 所示。

表 1. 实验数据分布

状态	类别标签	训练集	测试集
正常	1	70	30
中低温过热	2	70	30
高温过热	3	70	30
低能放电	4	70	30
高能放电	5	70	30
局部放电	6	70	30

特征工程是提升分类模型判别性能的核心环节。在变压器故障诊断领域，不同方法对输入特征的选取策略存在显著差异，而传统 DGA 三比值法等规则型方法则侧重于构建具有物理意义的气体浓度比值作为判据。为充分挖掘数据内在判别信息，本文引入反映气体演化趋势与分布特性的衍生统计量，构建了一种兼具物理可解释性与数据驱动优势的复合特征集。具体为： C_2H_2 ， C_2H_4 ， CH_4 ， $CH_4/H_2CH_4/C_2H_6$ 。针对 KELM 的关键参数对模型分类准确度影响较大的问题，采用 GWO 基于训练集样本对其进行参数优化，建立 GWO-KELM 模型。将测试集样本输入到 GWO-KELM 模型中进行故障诊断，实验结果如图 2 所示。




图 2. 基于 GWO-KELM 模型的故障诊断结果

由图 2 可知，基于 GWO-KELM 模型的故障诊断结果中，180 个测试样本仅有 2 个样本分类错误，其余样本均分类正确，综合故障诊断准确率为 98.89%。为验证所提方法的有效性，将本文所提方法与 PSO-LELM，GWO-SVM 模型进行对比，所得结果如表 2

所示。

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/%
PSO-KELM	180	8	95.56
GWO-SVM	180	6	96.67
本文所提	180	2	98.89

由表 2 可知，本文所提方法具有最高的故障诊断准确率，98.89%。相比于 PSO-KELM 模型和 GWO-SVM 模型，故障诊断准确率分别提升了 3.33% 和 2.22%。

5. 结论

本文提出一种基于 KELM 的变压器故障诊断方法，从模型结构与参数优化双路径协同改进：一方面引入多核融合策略以增强特征映射能力，另一方面结合 GWO 对 KELM 的关键参数自适应寻优。实验结果表明，所提方法的故障诊断准确率能够达到 98.89%。与 PSO-LELM，GWO-SVM 模型进行对比，本文所提方法的故障诊断准确率分别提升了 3.33% 和 2.22%，验证了所提方法对变压器故障诊断的有效性和先进性。

参考文献

- [1] 曾贤强, 梁嘉, 刘仲民, 等. 基于 WGAN 数据增强和 ISSA-SVM 的变压器故障诊断[J/OL]. 高电压技术, 1-9 [2026-02-24]. <https://doi.org/10.13336/j.1003-6520.hve.20251068>.
- [2] 钱国超, 杨坤, 刘红文, 等. 基于格拉姆角场与融合注意力机制优化 CNN 的变压器绕组故障诊断[J]. 广东电力, 2026, 39(01): 106-117.
- [3] 龚文洁, 林国松, 韦晓广. 变压器声纹故障诊断研究综述[J/OL]. 电子与信息学报, 1-17 [2026-02-24]. <https://link.cnki.net/urlid/11.4494.TN.20260119.0906.014>.
- [4] 李友才, 彭威龙, 周玉明, 等. 基于 Borderline SMOTE 与 NGO 优化的双层 XGBoost 算法的变压器故障模式识别研究[J]. 电力科学与技术学报, 2025, 40(06): 32-42. DOI:10.19781/j.issn.1673-9140.2025.06.004.
- [5] 包艳艳, 马志程, 段军红, 等. 基于高斯核 Fisher 判别分析与 NRBO-BiLSTM 的变压器故障诊断[J]. 科学技术与工程, 2025, 25(33): 14298-14306.
- [6] 廖才波, 李兆国, 刘文宇, 等. 基于双通道

- 声纹特征融合的变压器故障诊断方法[J/OL]. 电网技术, 1-10 [2026-02-24]. <https://link.cnki.net/urlid/11.2410.TM.20251119.0946.002>.
- [7]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.
- [8]Yu L, Zhibin J, Yan Z. RMT: A Robust Multi-Scale Transformer Network for Power Transformer Fault Diagnosis[J].International Journal of Information Technologies and Systems Approach (IJITSA), 2026, 19(1): 1-18.
- [9]Swain K, Cherukuri M, Samanta S I, et al. IoT Based Transmission Line Fault Classification Using Regularized RBF-ELM and Virtual PMU in a Smart Grid[J]. Computer Modeling in Engineering & Sciences, 2025, 145(2): 1993-2015.
- [10]谭贵生, 赵波, 张桂莲, 等.多策略改进 DBO 算法与 KELM 的变压器故障辨识[J].电力系统保护与控制, 2025, 53(14): 111-122.
- [11]徐舒蓉, 刘君, 李堃, 等.基于 GWO-VMD 与 SOM 神经网络的变压器振动信号特征提取与状态识别方法研究[J].电力大数据, 2025, 28(04): 30-40.