

[故障诊断]

基于改进核极限学习机的变压器故障诊断

文/国网冀北电力有限公司廊坊供电公司 吕艳硕 张东亮 毕影娇 韩建晖 白晶晶

针对在核极限学习机中，单个全局核函数或者局部核函数不能很好地平衡拟合和泛化的矛盾，对核函数采用混合核函数的建模方法，采用混合核函数提高模型的学习能力和泛化能力来得到最佳的分类准确度，得到混合核极限学习机，考虑到混合核极限学习机的参数敏感性特点，用人工鱼群算法进行参数优化，提出了基于AFSA-MKELM的变压器故障诊断模型。

油中溶解气体分析法（Dissolved Gas Analysis, DGA）是变压器故障诊断的有效方法。传统的阈值检测手段存在着编码边界过于绝对、编码需要人为划定和缺编码等缺陷，导致在实际诊断过程中准确率较低。新兴的智能方法，如BP神经网络存在调整参数多、训练速度慢和容易陷入局部极值的缺点，限制了其诊断准确度；贝叶斯网络方法需要大量训练样本，而现有DGA数据集无法满足其大样本需求；SVM可解决过拟合和非线性高维度分类问题，但是其核函数需要受到梅西条件的限制，且分类输出为硬分割边界。

2006年，黄广斌等人提出了一种新的单隐层的前馈神经网络学习算法，即极限学习机（Extreme Learning Machine, ELM），并已应用到许多不同的领域。针对ELM随机设定隐含层初始权重和偏置导致分类准确度不稳定的缺点，一些学者作了改进。

核极限学习机（Kernel-based Extreme Learning Machine, KELM）在分类性能方面优于传统极限学习机（ELM）、支持向量机（SVM）和BP神经网络等智能分类方法。KELM不需设定隐含层初始权重和偏置，在保证网络具有良好泛化性能的同时，极大地

提高了前向神经网络的稳定性和学习速度，它不仅具有ELM算法的诸多优势，并且还结合了核函数，对线性不可分的情况进行非线性映射到高维特征空间，从而实现线性可分，进一步提高了分类的准确率。

但是，单一核函数无法兼顾算法的拟合性能和泛化性能，故本文采用混合核函数的思想，将全局核函数和局部核函数组合起来，构成了混合核函数极限学习机，并考虑到该模型的参数敏感性特点，采用人工鱼群算法对该模型进行参数寻优。综上，提出了基于人工鱼群算法优化的混合核函数极限学习机变压器故障诊断模型，实验证明该模型具有很好的实用效果。

混合核极限学习机

1. 核极限学习机模型

核极限学习机（KELM）是一种基于核函数的单隐层前馈神经网络，在非线性回归和分类方面具有较好的应用效果。与传统神经网络相比，其计算量和搜索空间较少，前馈神经网络模型输出如下

$$f(x) = h(x)\beta = H\beta \quad (1)$$

式中， $f(x)$ 为网络输出； $h(x)$ 为隐含层节点输入函数； x 为输入数据向量； H 为特征映射矩阵，由核函

数将输入样本映射产生； β 为连接隐含层和输出层的输出权值向量。

核函数极限学习机的核矩阵为

$$\begin{cases} \Omega_{\text{ELM}} = HH^T \\ \Omega_{i,j} = h(x_i)h(x_j) = K(x_i, x_j) \end{cases} \quad (2)$$

核矩阵 Ω_{ELM} 替代ELM中的随机矩阵 HH^T ，设定核参数之后，核矩阵 Ω_{ELM} 的映射值也随之确定； $h(x)$ 为隐层节点输出函数；核函数 $K(\mu, \nu)$ 包括RBF核函数、线性核函数和多项式核函数等类型。

将惩罚系数 C 添加到单位对角阵 HH^T 中的主对角线上，这样使矩阵特征根不为0，而且稳定性和泛化性也更好。此时KELM网络的输出权值变为

$$\begin{aligned} f(x) &= h(x)H^T(HH^T + \frac{I}{C})^{-1}T = \\ &= \begin{bmatrix} K(x, x_1) \\ K(x, x_N) \end{bmatrix}^T (\Omega_{\text{ELM}} + \frac{I}{C})^{-1}T \end{aligned} \quad (3)$$

式中， I 为对角矩阵； T 为目标输出矩阵； C 为惩罚系数，用以权衡结构风险和经验风险之间的比例； HH^T 是通过核函数将输入样本映射产生的。

KELM模型输出权值为

$$\beta = (\Omega_{\text{ELM}} + \frac{I}{C})^{-1}T \quad (4)$$

输入数据经核函数变换为

$$\Omega = \begin{bmatrix} k(x, x_1) \\ \vdots \\ k(x, x_N) \end{bmatrix}^T \quad (5)$$

所以

$$f(x) = \Omega\beta \quad (6)$$

在基于核的KELM算法中，隐层节点的特征映射函数 $h(x)$ 的具体形式不用特意给出，只需要知道核函数 $K(\mu, \nu)$ 的具体形式就可以求出输出函数的值。同时，因为核函数直接采用内积的形式，在求解输出函数值时也不必去设定隐层节点的个数，从而不需设定隐含层初始权重和偏置。

2. 混合核函数

核函数的正确选取是决定核极限学习机分类性能优劣的关键因素，高斯核函数是一个典型的全局核函数，多项式核函数是一个典型的局部核函数，但它们都有各自的局限性，采用混合核函数是一种改善模型性能的有效方法。本文将这两种核函数结合得到一个混合核函数，用该混合核函数构成的极限学习机同时兼具两者的优点，具有更好的学习能

力和泛化能力，可更加准确地实现输入空间到高维隐层特征空间的映射，混合核函数表达式为

$$K(x, x_i) = \lambda e^{-\frac{\|x - x_i\|^2}{\delta^2}} + (1 - \lambda)[(x_i x_j) + n]^d \quad (7)$$

式中， δ 、 n 、 d 和 λ 是混合核函数的参数。在训练过程中利用人工鱼群算法对混合核参数进行优化。

人工鱼群算法

1. 人工鱼群算法的实现

设人工鱼个体当前位置的食物浓度用 $Y=f(x)$ 表示，式中， Y 表示目标函数的适应值； x 表示人工鱼个体的位置想要寻优的变量； $\|X_i - X_j\|$ 表示两条人工鱼 X_i 、 X_j 之间的距离； ρ 表示拥挤度因子，可以用来描述某个位置附近的拥挤程度；step表示步长；visual表示人工鱼的感知范围； X_{iv} 表示第 i 条人工鱼在某时刻所感知的位置；try_number表示最大尝试次数。人工鱼群算法首先需要对某一群人工鱼进行初始化，然后利用迭代的方式进行寻优，在每一次迭代过程中，人工鱼个体通过觅食、聚群和追尾的行为对自己的位置不断更新，实现寻优的目的。由于本文想通过人工鱼群算法获得最大值，因此下面对人工鱼群算法的介绍都以寻找极大值为例。

(1) 觅食行为

设第 i 条人工鱼个体当前的位置为 X_i ，适应值为 Y_i ，根据式(8)在其感知范围内随机的选择一个位置 X_{iv} ，然后根据适应值函数计算在该位置的适应值 Y_{iv} ，若 $Y_{iv} > Y_i$ ，则 X_i 向 X_{iv} 方向前进一步，移动过程按照式(9)；否则，继续根据式(8)在感知范围内随机选择位置

$$X_{iv} = X_i + \text{visual} \cdot \text{rand}() \quad (8)$$

$$X_i(\text{new}) = X_i(\text{old}) + \frac{X_{iv} - X_i(\text{old})}{\|X_{iv} - X_i(\text{old})\|} \text{step} \cdot \text{rand}() \quad (9)$$

如果重复的次数达到设定的尝试次数，仍然不满足前进的条件，那么就按照式(10)随机的移动一步，达到新的位置，即

$$X_i(\text{new}) = X_i(\text{old}) + \text{step} \cdot \text{rand}() \quad (10)$$

(2) 聚群行为

聚群行为是让每条人工鱼个体在移动过程中尽量朝着邻近伙伴的中心方向上移动，同时不至于太过拥挤的行为。设第 i 条人工鱼个体当前的位置为 X_i ，适应值为 Y_i ，以自己当前的位置为中心，搜索其感知范围内的所有人工鱼的数量为 N_f ，若 $N_f \geq 1$ ，

说明第*i*条人工鱼的感知范围内存在其他的人工鱼，那么按照式（11）求得中心的位置为 X_c 以及中心位置的适应值 Y_c ，即

$$X_c = \frac{\sum_{j=1}^{N_f} X_j}{N_f} \quad (11)$$

若满足 $Y_c > Y_i$ 且 $Y_c/N_f > \rho Y_i$ ，说明这几条人工鱼的中心位置食物浓度大，并且不拥挤，则朝着鱼群中心的方向前进一步；否则，继续执行觅食行为。

（3）追尾行为

追尾行为是让人工鱼个体向着附近的最活跃（适应值最大）的伙伴进行追赶的行为。设第*i*条人工鱼当前的位置为 X_i ，其适应值为 Y_i ，该条人工鱼的感知范围内的所有的人工鱼中适应值最大的为 X_{max} ，其适应值为 Y_{max} ，若 $Y_{max} \leq Y_i$ ，则执行觅食行为；否则，以 X_{max} 为中心在其感知范围内的人工鱼的数量为 N_r ，若满足 $Y_{max} > Y_i$ 且 $Y_{max}/N_f > \rho Y_i$ ，说明 X_{max} 附近的食物浓度较高且不拥挤，则朝着 X_{max} 的方向前进一步；否则，继续执行觅食行为。

（4）行为选择

首先试探的执行聚群行为和追尾行为，选择这两个行为中变化最快的行为执行，即向着食物浓度最大的方向移动，缺省的行为是觅食行为，也就是当聚群行为和追尾行为的结果不如当前位置的适应值时，执行觅食行为。

（5）设立公告板

设立公告板的目的是为了记录当前最优的人工鱼的位置和适应值，其他的人工鱼在执行各种行为后，将自己当前的适应值和公告板进行比较，若比公告板的适应值更大，则用该人工鱼的位置和适应值取代公告板上记录的人工鱼的位置和适应值，这样在算法结束时，公告板上记录的就是人工鱼的最佳位置和最大的适应值，也就是想要得到的最优解。

2. 人工鱼群算法的流程

通过对人工鱼群算法的理论分析，可以将人工鱼群算法寻优的过程归纳为以下几个步骤：

1) 对人工鱼群算法的参数进行初始化，包括鱼群中人工鱼的数量、移动步长、感知范围、最大迭代次数、最大尝试次数、拥挤度因子以及人工鱼中每个个体的初始值。

2) 计算出人工鱼中每个个体所在位置的适应值（即食物浓度），并将适应值最大的人工鱼的位置

和适应值记录在公告板上。

3) 通过试探的执行聚群行为和追尾行为，缺省行为为觅食行为，对每个人工鱼个体的位置进行调整，并与公告板上的数据进行比较和替换。

4) 与步骤1) 设定的最大迭代次数进行比较，如果达到最大迭代次数则执行步骤5)，否则执行步骤3)，进入下一次迭代。

5) 迭代结束，公告板上显示的结果就是想要的最优解。

人工鱼群算法的实现流程图如图1所示。




图1 人工鱼群算法流程图

基于人工鱼群算法的混合核极限学习机

如前所述，利用混合核极限学习机来映射目标与其影响因素之间的关系，由人工鱼群算法来寻找混合核极限学习机的最优惩罚系数 C 、高斯核参数 δ 、多项式核参数 n 、 d 和组合系数 λ 。

1) 初始化算法参数，将MKELM算法的5个参数作为人工鱼群算法的解空间，即人工鱼个体的位置。

2) 定义人工鱼群算法的食物浓度为MKELM算法的诊断正确率。

3) 计算出人工鱼中每个个体所在位置的适应值（即食物浓度），并将适应值最大的人工鱼的状态和适应值记录在公告板上。

4) 通过试探的执行聚群行为和追尾行为, 缺省行为为觅食行为, 对每个人工鱼个体的位置进行调整, 并与公告板上的数据进行比较和替换。

5) 计算更新后人工鱼种群中每个人工鱼个体适应值, 找出此时人工鱼种群的最优人工鱼个体 (适应度函数值最大的个体)。

6) 与步骤1) 设定的最大迭代次数进行比较, 如果达到最大迭代次数则执行步骤5), 否则执行步骤3), 进入下一次迭代。

7) 迭代结束, 公告板上显示的结果就是想要的最优解。

流程如图2所示。




图2 人工鱼群算法优化混合核极限学习机流程图

基于AFSA-MKELM的变压器故障诊断模型

1. 特征量的选择

本文选取IEC推荐的DGA数据中的 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 和 C_2H_2 这五种气体溶解量作为HKELM的输入量, DGA数据值分布区间很大, 即使属于同类型的数据之间也可能存在着较大的差异, 为降低其相互之间由于量值差异造成的影响, 在将特征量输入分类器前首先要对数据按照式(12)作归一化处理, 即

$$x_{\text{normalize}} = L_0 + \frac{x - x_{\min}}{x_{\max} - x_{\min}}(U_p - L_0) \quad (12)$$

式中, $x_{\text{normalize}}$ 为归一化后的气体浓度数值; $x_{\min}$ 为气体含量最小值; $x_{\max}$ 为气体含量最大值; U_p 和 L_0 为归一化上界与下界, 分别取值1和-1。

2. 样本的选择

样本数据选取时, 由于变压器故障很罕见, 所以原始数据中的故障样本全部采用。本文所用变压器故障样本为在相关硕博学位论文和书籍中获得的样本232组。各类样本数量见表1

表1 各类样本数量

状态类别	数量
高温过热	69
中低温过热	40
高能放电	39
低能放电	47
局部放电	37

3. 变压器故障状态编码

变压器故障诊断是一个多分类任务, MKELM算法具有多分类能力, 可采用一个多分类器对高温过热、中低温过热、高能放电、低能放电和局部放电五种状态进行辨识。MKELM的输出为一个类标志向量, 类标志向量的维数为样本中状态类别的数量, 在应用中需要为每一类状态进行编码。各类故障编码见表2。

表2 各类故障编码

状态类别	编码
高温过热	(0, 0, 0, 0, 1)
中低温过热	(0, 0, 0, 1, 0)
高能放电	(0, 0, 1, 0, 0)
低能放电	(0, 1, 0, 0, 0)
局部放电	(1, 0, 0, 0, 0)

4. 基于AFSA-MKELM的变压器故障诊断实现

将KELM的核函数分别设置为高斯核函数、多项式核函数和混合核函数, 用鱼群算法进行参数优化, 设定鱼群算法的种群数量fishnum=50, 拥挤度因子 $\rho=0.2$, 感知距离visual=0.55, 最多试探次数try_number=10, 步长step=1, 迭代次数为50。

得到的基于AFSA-RBF-KELM的变压器故障诊断过程如图3所示, 最高故障诊断正确率为81.012 7%, 基于AFSA-Poly-KELM的变压器故障如图4所示, 最高故障诊断正确率为74.683 5%, 基于AFSA-

MKELM的变压器故障如图5所示，最高故障诊断正确率为86.075 9%。




图3 基于AFSA-RBF-KELM的变压器故障诊断




图4 基于AFSA-Poly-KELM的变压器故障诊断




图5 基于AFSA-MKELM的变压器故障诊断

基于AFSA-MKELM算法的变压器故障诊断实现过程为：

- 1) 选取特征量与样本集合，按照式（12）将样本数据进行归一化。
- 2) 按照1：2的比例将样本集合分割为测试集和训练集。
- 3) 将AFSA算法的适应度函数设置为变压器故障诊断正确率，并按图2进行参数寻优。
- 4) 用最优参数的MKELM 算法对测试集样本进行故障诊断，并计算最优故障诊断正确率。

实验分析

本文实验在Core i5-2410 M CPU 2.3 GHz、4 GB系统内存的硬件环境下，操作系统为 Windows7 64 bit，通过MATLAB语言在MATLAB2018a上进行编辑运行。数据采用论文和其他书籍提供的数据232组。

表3为用BP神经网络、SVM、ELM、AFSA-KELM和AFSA-MKELM方法在测试集上的诊断结果。由表3可以看出本文所提出的AFSA-MKELM算法与其他算法相比有相当的优越性。

表3 五种算法诊断结果比较

故障类型	(正确数/测试样本数) × 100%				
	BPNN	改进SVM	ELM	AFSA-KELM	AFSA-MKELM
高温过热	58.33	83.33	83.33	100	100
中低温过热	92.86	85.71	85.71	100	100
高能放电	23.08	69.23	69.23	69.23	61.54
低能放电	62.50	31.25	25	37.50	62.50
局部放电	83.33	91.67	100	91.67	100
平均准确率	63.29	72.15	72.15	81.01	86.08

结束语

本文将核极限学习机中单一的核函数改造为混合核函数，并用鱼群算法对混合核极限学习机的参数进行了寻优，提出了基于AFSA-MKELM的变压器故障诊断方法。此方法不仅可以更好地平衡拟合和泛化性能的矛盾，而且用鱼群算法对其进行寻优，保证了所选参数的妥当性。在实验过程中，与其他的故障诊断方法和KELM方法相比，在故障诊断正确率上有一定程度的提升。因此，该算法可以成功地应用到变压器故障诊断系统当中，取得了比较理想的应用效果。EA

(收稿日期：2021.04.29)