

DOI:10.13296/j.1001-1609.hva.2020.06.036

监督自适应核熵成分分析特征提取的电力变压器故障诊断

彭丽维, 张彼德, 孔令瑜, 梅 婷

(西华大学电气与电子信息学院, 成都 610039)

摘要: 核熵成分分析(kernel entropy component analysis, KECA)方法在处理非线性数据集, 去除冗余信息方面具有独特的优势。针对电力变压器故障诊断中有效特征提取困难, KECA中核参数选择繁琐以及忽略了样本类别信息等问题, 文中提出一种自适应核函数优化学习的监督核熵成分分析特征提取方法, 用于电力变压器敏感特征量的提取。首先收集电力变压器不同状态下的样本数据, 并结合样本类别信息建立一个依赖数据的核函数; 其次基于余弦相似度以最小化类间相似度和最大化类内相似度为目标对核函数中表征样本类别信息的参数进行优化; 然后将优化得到的核函数与核熵成分分析相结合形成一种监督的自适应核熵成分分析(supervised adaptive kernel entropy component analysis, SAKECA)特征提取方法, 并运用该方法从原始特征量中提取出能有效表征电力变压器状态的敏感特征; 最后将提取的特征输入核极限学习机(KELM)建立变压器故障诊断模型。与常用特征提取方法进行对比分析, 结果表明所提方法具有良好的特征提取效果, 能有效提升故障诊断准确率。

关键词: 电力变压器; 特征提取; 故障诊断; 监督学习; 核熵成分分析

Power Transformer Fault Diagnose Based on Supervised Adaptive Kernel Entropy Component Analysis Feature Extraction

PENG Liwei, ZHANG Bide, KONG Lingyu, MEI Ting

(School of Electrical and Electronic Information, Xihua University, Chengdu 610039, China)

Abstract: Kernel entropy component analysis (KECA) method have shown unique advantages for removing redundant information and adjusting nonlinear structure of input data. In view of the difficulty of effective feature extraction in power transformer fault diagnosis, the tedious selection of core parameters in KECA and the neglect of sample type information, etc, a novel feature extraction method base on the optimization learning of feature extraction is proposed in this paper, it is used to extract sensitive feature of power transformer. Firstly, various state samples are collected, and then a data-dependent kernel function is build by considering sample class information. Secondly, based on cosine similarity, the parameters representing the class information in kernel function are optimized to minimize the similarity between classes and maximize the similarity within classes; Then the optimized kernel function and kernel entropy component analysis are combined to form a supervised adaptive kernel entropy component analysis (SAKECA)feature extraction method, and the sensitive features which can effectively represent the state of power transformer are extracted from the original feature quantity by using this method; Finally, the extracted features are taken as the input of KELM to set up transformer fault diagnosis model. Compared with common feature extraction methods, the results show that the proposed method has good feature extraction effect and can effectively improve the accuracy of fault diagnosis.

Key words: power transformer; feature extraction; fault diagnosis; supervised learning; kernel entropy component analysis

收稿日期:2020-02-07; 修回日期:2020-04-10

基金项目:教育部春晖计划合作科研项目(Z2017077);四川省科技厅应用基础研究项目(2017JY0204);四川省电力电子节能技术与装备重点实验室项目(SZJJ2015-064);四川省信号与信息处理重点实验室项目(SZJJ2017-049)。

Project Supported by Ministry of Education Chunhui Plan(Z2017077), Cooperation Research Project, Sichuan Provincial Department of Science and Technology (2017JY0204), Sichuan Provincial Key Laboratory of Power Electronics Energy-saving Technologies&Equipment(szjj2015064), Sichuan Province Key Laboratory of Signal and Information Processing(SZJJ2017-049).

0 引言

电力变压器的安全稳定运行是提升整个电力系统安全水平的关键之一,故障诊断技术的应用是保障电力变压器安全的重要手段。

油中溶解气体分析(dissolved gas analysis, DGA)可为变压器故障诊断提供重要依据。近年来,人工智能(artificial intelligence, AI)技术因能够建立表征原始特征参量与故障类别之间的复杂非线性关系模型,在电力变压器故障诊断领域取得了良好的效果^[1-10]。

应用AI技术进行变压器故障诊断时,以往大部分研究主要将部分特征气体比值或含量作为输入特征来建立故障诊断模型,且不同文献中智能诊断模型采用的特征量有明显的区别,尚未形成特征参量选取的统一标准。

文[11-12]基于遗传算法,以分类准确率为评价指标,分别从原始9维和28维特征比值中挑选出最优比值为;文[13]采用粗糙集约简方法对原始16维比值进行特征子集优选;文[14]运用统计理论方法对21种原始故障特征的重要性进行分析,并按照重要性进行排序,选取最优特征。上述几种方法较常用的DGA含量和IEC比值的诊断正确率有较为明显的提升,但以过滤形式剔除特征,有可能导致某些重要故障信息被忽略,影响最终的诊断效果。为了避免这种情况的发生,PCA、KPCA等特征提取方法被运用于电力变压器故障诊断,在实现维数约简的同时尽可能保持原始数据信息。文[15]提出了基于相对变换主元分析的变压器故障诊断建模,用相对变换实现非线性放大,然后用主元分析(PCA)实现降维,取得了较好的故障诊断效果。但是,PCA是线性的特征提取方法,分析处理非线性数据结构具有一定的局限性。为能够有效地提取数据的非线性特征,文[16]将核主元分析(KPCA)运用于电力变压器故障特征提取,提升了故障诊断准确率。

但KPCA处理数据方式与PCA类似,即利用特征值大小来实现降维,降维效果存在一定的波动性。Jenssen将信息论的思想融入了特征提取的过程中,在KPCA的基础上提出核熵成分分析(kernel entropy component analysis, KECA),以原始高维数据的信息熵为主要指标,基于最小信息熵损失策略提取原始高维特征空间中的低维敏感特征,使得数据在维数约简后能保留更多熵的信息,且不需要高斯分布这样的数据假设,在特征提取上具有独特的优越性^[17]。鉴于此文中尝试将其运用于电力变压器故障诊断。

考虑到KECA作为一种典型的无监督核属性约简方法,存在核函数与核参数选择繁琐、样本的类别信息没有充分利用等问题。文中构建了基于数据驱动的核函数自适应优化框架,具体方法是将样本类别信息引入基核函数,并基于余弦相似度度量准则,以最小化类间相似度与最大化类内相似度为优化目标,对核函数中表征样本类别信息的参数进行优化,实现核函数的自适应优化学习。

综上所述,文中提出电力变压器故障的监督自适应KECA特征提取方法。首先构建核函数自适应优化学习框架对核函数中表征样本类别信息的参数进行优化,完成核函数的自适应优化学习;其次将优化得到的核函数与KECA相结合形成一种监督的自适应KECA(supervised adaptive kernel entropy component analysis, SAKECA)特征提取方法;然后采用SAKECA方法实现电力变压器非线性敏感故障特征提取;最后以诊断准确率为评价指标,与常用特征提取方法对比,结果验证了所提方法的有效性与优越性。

1 自适应核函数优化学习

1.1 自适应核函数

针对无监督核属性约简方法忽略样本类别信息以及属性约简效果受核参数设置影响大的问题,文中使用与类别信息相关的权值来表示不同类别间的差距,建立一个对数据敏感的自适应核函数,并通过核函数中表征样本类别信息的权值进行优化,有效削弱核参数的取值对属性约简效果的影响。

假设一个数据集 $X=[x_1, x_2, x_3, \dots, x_n]$,样本数为 n ,样本属于 c 个类别, c 个类别对应的 c 个权重值为 $\{u_1, u_2, \dots, u_c\}$,样本 x_i 对应的权值 w_i 根据其类别信息确定

$$w_i = u_l \quad \text{if} \quad x_i \in \text{第} l \text{类} \quad (1)$$

定义对数据敏感的自适应核函数为

$$K_s(x_i, x_j) = w_i w_j k(x_i, x_j) \quad (2)$$

式(2)中: $k(x_i, x_j)$ 为基础核函数。文中以Guassain核函数为基核函数,即

$$k(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / \gamma_1) \quad (3)$$

式(3)中, γ_1 为基核参数。

令 $K_{ij}^{(s)} = K_s(x_i, x_j)$, $k_{ij} = k(x_i, x_j)$ 并将自适应核矩阵表示为 $K_s = [K_{ij}^{(s)}]$,基核矩阵表示为 $K = [k_{ij}]$,由式(2)可知

$$K_{ij}^{(s)} = w_i w_j k_{ij} \quad (4)$$

当样本 x_i 与 x_j 分别隶属于第 a 和第 b 类时 $K_{ij}^{(s)} = \mu_a \mu_b k_{ij}$, $a, b \in [1, c]$, 由此可以看出样本的类别信息被引入到自适应核矩阵 K_s 中。

1.2 自适应核函数优化学习

非线性映射函数 ϕ 将原始数据集 $X = [x_1, x_2, \dots, x_n]$ 映射到高维核空间 $F: \phi(X) = [\phi(x_1), \phi(x_2), \dots, \phi(x_n)]$

采用余弦相似度度量核空间高维样本间的相似度为

$$r_{ij} = \frac{\phi(x_i)^T \phi(x_j)}{\sqrt{\|\phi(x_i)\|^2 \|\phi(x_j)\|^2}} \quad (5)$$

式(5)中, r_{ij} 表示样本 $\phi(x_i), \phi(x_j)$ 之间的相似度。

运用核运算规则, 式(5)可转换为

$$r_{ij} = \frac{K_{ij}^s}{\sqrt{K_{ii}^s K_{jj}^s}} = K_{ij}^s = w_i w_j k_{ij} \quad (6)$$

以最小化类间相似度, 最大化类内相似度为目标, 二分类问题核函数优化目标函数为:

$$J_2 = \arg \max S_{12} \quad (7)$$

$$S_{12} = \frac{\frac{1}{N_1} \sum_{i=1}^{N_1} \frac{1}{N_1} \sum_{j=1}^{N_1} r_{ij} + \frac{1}{N_2} \sum_{i=1}^{N_2} \frac{1}{N_2} \sum_{j=1}^{N_2} r_{ij}}{\frac{1}{N_1} \sum_{i=1}^{N_1} \frac{1}{N_2} \sum_{j=1}^{N_2} r_{ij}} = \frac{\frac{1}{N_1} \sum_{i=1}^{N_1} \frac{1}{N_1} \sum_{j=1}^{N_1} K_{ij}^s + \frac{1}{N_2} \sum_{i=1}^{N_2} \frac{1}{N_2} \sum_{j=1}^{N_2} K_{ij}^s}{\frac{1}{N_1} \sum_{i=1}^{N_1} \frac{1}{N_2} \sum_{j=1}^{N_2} K_{ij}^s} \quad (8)$$

式(7)、(8)中: $N_i (i=1, 2)$ 表示第 i 类样本个数, 分母部分 $\frac{1}{N_1} \sum_{i=1}^{N_1} \frac{1}{N_2} \sum_{j=1}^{N_2} r_{ij}$ 为两类样本间的相似度和, 用于表征类间相似度; 分子部分 $\frac{1}{N_1} \sum_{i=1}^{N_1} \frac{1}{N_1} \sum_{j=1}^{N_1} r_{ij}$ 与 $\frac{1}{N_2} \sum_{i=1}^{N_2} \frac{1}{N_2} \sum_{j=1}^{N_2} r_{ij}$ 分别表示 1、2 类样本的类内平均相似度, 用于表征内类相似度。可见类间相似度越小, 类内相似度越大, S_{12} 越大, 即两类样本可区分性越强。

令 $a_i = [1, 1, \dots, 1]^T$ 为单位列向量其元素个数为 N_i , μ_i 表征第 i 类样本的权重; 两类样本构成的基核矩阵为 $K = \begin{bmatrix} K_{11} & K_{12} \\ K_{21} & K_{22} \end{bmatrix}$, 则式(8)可写为以下矩阵形式

$$S_{12} = \frac{\frac{\mu_1^2}{N_1^2} a_1^T K_{11} a_1 + \frac{\mu_2^2}{N_2^2} a_2^T K_{22} a_2}{\frac{\mu_1 \mu_2}{N_1 N_2} a_1^T K_{12} a_2} \quad (9)$$

对于 c 分类问题 ($c > 2$), 可构造 $l = c(c-1)/2$ 个类对, 基于以上述推导的二分类问题目标函数, 构建 c 分类问题的核函数优化目标函数如下

$$J = \arg \max \sum_{i \neq j} S_{ij} = \arg \min (-\sum_{i \neq j} S_{ij}) \quad (10)$$

式(10)中: $i, j \in [1, c]$, S_{ij} 表示第 i 类与第 j 类样本的区分度, 按类别排序构建 c 个类别样本的基核矩阵

$$K = \begin{bmatrix} K_{11} & K_{12} & \dots & K_{1c} \\ K_{21} & K_{22} & \dots & K_{2c} \\ \vdots & \vdots & \ddots & \vdots \\ K_{c1} & K_{c2} & \dots & K_{cc} \end{bmatrix} \quad (11)$$

$$\text{令 } A_{ii} = \frac{a_i^T K_{ii} a_i}{N_i^2}, A_{ij} = \frac{a_i^T K_{ij} a_j}{N_i N_j}, \text{ 且满足 } A_{ij} = A_{ji}$$

其中 $i, j \in [1, c]$ 。参考式(9)可得 S_{ij} 计算式为

$$S_{ij} = \frac{A_{ii} \mu_i^2 + A_{jj} \mu_j^2}{A_{ij} \mu_i \mu_j} \quad (12)$$

式(12)易知 $S_{ij} = S_{ji}$ 。应用拉格朗日乘子法将式(10)转化为无约束最小值求解问题, 则 c 个类别权重向量 $U = [u_1, u_2, \dots, u_c]$ 中 c 个权重值 $u_k (k \in [1, c])$ 求解函数为

$$L(U) = \sum_{i \neq j} S_{ij} \quad (13)$$

将 $L(U)$ 对 $u_k (k=1, 2, \dots, c)$ 求偏导并置于零后得到如下可以得到如下 c 个式子

$$\begin{cases} A_{11} u_1^2 \sum_{i \neq 1} A_{1i} u_i - \sum_{i \neq 1} A_{1i} A_{ii} u_i^3 = 0 \\ A_{22} u_2^2 \sum_{i \neq 2} A_{2i} u_i - \sum_{i \neq 2} A_{2i} A_{ii} u_i^3 = 0 \\ A_{33} u_3^2 \sum_{i \neq 3} A_{3i} u_i - \sum_{i \neq 3} A_{3i} A_{ii} u_i^3 = 0 \\ \vdots \\ A_{cc} u_c^2 \sum_{i \neq c} A_{ci} u_i - \sum_{i \neq c} A_{ci} A_{ii} u_i^3 = 0 \end{cases} \quad (14)$$

运用 BFGS 拟牛顿法^[18]求解上述非线性方程组得到 c 个类别的权重值向量 $U = [u_1, u_2, \dots, u_c]$ 。参考式(1)–(4)与式(11)可得到优化后的自适应核矩阵 K_s

$$K_s = \begin{bmatrix} u_1^2 K_{11} & u_1 u_2 K_{12} & \dots & u_1 u_c K_{1c} \\ u_2 u_1 K_{21} & u_2^2 K_{22} & \dots & u_2 u_c K_{2c} \\ \vdots & \vdots & \ddots & \vdots \\ u_c u_1 K_{c1} & u_c u_2 K_{c2} & \dots & u_c^2 K_{cc} \end{bmatrix} \quad (15)$$

2 监督自适应 KECA 方法原理

2.1 KECA 原理

KECA 的核心思想是将原始数据投影到高维特征空间后, 对生成的核矩阵进行特征分解, 选取前 l 个对瑞利熵贡献度最大的特征向量, 然后往这些特征向量方向做投影, 构成新的数据集。

在选用 Parzen 窗密度估计的基础上,瑞利熵估计为

$$\hat{V}(p) = \frac{1}{n^2} I^T K I \quad (16)$$

式(16)中: I 为 $n \times 1$ 阶单位向量, $K=[K_{ij}]$ 为 $n \times n$ 阶基核矩阵,文中以 Guassian 核函数为基核函数。

通过式(7)对核矩阵进行分解

$$K = E D_{\lambda} E^T \quad (17)$$

式(17)中: D_{λ} 为 n 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 构成的对角矩阵; E 为相应的 n 个特征向量 $e_1, e_2, \dots, e_n$ 构成的矩阵;

结合式(17)、(16)可表示为

$$\hat{V}(p) = \frac{1}{n^2} \sum_{i=1}^n (\sqrt{\lambda_i} e_i^T p)^2 \quad (18)$$

式(18)中每一项均对 $\hat{V}(p)$ 有贡献,每一项的贡献值具体为

$$\hat{V}_i(p) = (\sqrt{\lambda_i} e_i^T p)^2 \quad (19)$$

依据对 Renyi 熵估计的贡献度大小对 n 个特征值及特征向量进行降序排列,由前 d 个特征值及其对应的特征向量形成 KECA 的低维特征映射表达

$$\Phi_{KECA} = \hat{D}_d^{\frac{1}{2}} \hat{E}_d^T \quad (20)$$

式(20)中: $\hat{D}_d$ 是由前 d 个瑞利熵估计贡献度最大的特征值构成的对角阵, $\hat{E}_d$ 是由相应的 d 个特征向量构成的矩阵。

对一个新的测试样本 x_{new} ,其在特征空间上的投影则可表示为

$$t_{new} = D_d^{-\frac{1}{2}} E_d^T k(x, x_{new}) \quad (21)$$

2.2 监督自适应 KECA(SAKECA)方法

SAKECA 算法是将自适应核函数优化学习与 KECA 算法相结合形成的有监督核属性约简方法,克服了 KECA 算法没有充分利用样本标签信息以及核参数选取困难的不足。其思想如下:首先设置 c 个类别对应的 c 个权重值为 $\{u_1, u_2, \dots, u_c\}$,并将样本类别信息引入基核函数,建立一个对数据敏感的自适应核函数;然后基于余弦相似度度量准则,以最小化类间相似度与最大化类内相似度为优化目标,对核函数中表征样本类别信息的参数进行优化,实现自适应核函数的优化学习。

SAKECA 算法步骤如下:

1)数据预处理。对原始样本数据进行去均值处理。

2)选取 Guassian 核函数为基核函数,并为其随意设置一个核参数,构建如式(11)所示的 c 个类别样本的基核矩阵 K 。

3)计算 $A_{ij} = \frac{a_i^T K_{ij} a_j}{N_i N_j}$,其中 $i, j \in [1, c]$,然后计算

S_{ij} 并构建式(11)所示目标函数。

4)通过 BFGS 拟牛顿法求解式(14)的非线性方程组得到各类别对应的权重值 $\{u_1, u_2, \dots, u_c\}$,并根据式(15)构建优化后的自适应核矩阵 K_s 。

5)对 K_s 进行特征分解: $K_s = E_s D_s E_s^T$,其中 D_s 为 n 个特征值 $\lambda_{s1}, \lambda_{s2}, \dots, \lambda_{sn}$ 构成的对角矩阵; $E_s = [e_1, e_2, \dots, e_n]$ 为相应的 n 个特征向量构成的矩阵。

6)依据对 Renyi 熵估计的贡献度大小对 n 个特征值及特征向量进行降序排列,选取前 d 个瑞利熵贡献度最大的特征值及特征向量(对 Renyi 熵估计的累积贡献度达到 90%以上)形成样本的低维敏感特征表达为

$$\Phi_{SAKECA} = \hat{D}_{sd}^{\frac{1}{2}} \hat{E}_{sd}^T \quad (22)$$

式(22)中: $\hat{D}_{sd}$ 是由前 d 个瑞利熵估计贡献度最大的特征值构成的对角阵, $\hat{E}_{sd}$ 是由相应的 d 个特征向量构成的矩阵。

对一个新的未知类别的样本 x_{new} ,首先对其进行相同的预处理,预处理后的样本仍然记为 x_{new} ,其在特征空间上的投影则可表示为

$$t_{Snew} = D_{sd}^{-\frac{1}{2}} E_{sd}^T K_s(x, x_{new}) \quad (23)$$

3 基于 SAKECA 的电力变压器故障诊断

3.1 原始故障特征空间的构建与故障类型划分

参照 IEC 60599—2015,将电力变压器故障划分为低温过热、中温过热、高温过热、局部放电、低能放电与高能放电 6 类。文中对电力变压器的上述 6 类故障及正常状态共 7 种状态进行模式识别,各状态编号见表 1。所示为 IEC 和 IEEE 推荐的 5 种变压器故障诊断常用特征选取方法^[19],见表 2。在这 5 种常用方法基础上构建了更加完备的初始故障特征集,见表 3,并在此基础上进行后续的故障特征提取及诊断模型的建立。

表 1 电力变压器状态分类

Table 1 State classification of power transformer

编号	状态描述	编号	状态描述
F_1	低温过热	F_5	低能放电
F_2	中温过热	F_6	高能放电
F_3	高温过热	F_7	正常
F_4	局部放电	—	—

3.2 故障特征提取及诊断流程

基于 SAKECA 的电力变压器故障特征提取及

表2 传统故障特征选取方法

Table 2 Input features of traditional DGA methods

方法	对应特征量
ICUSU 法	H ₂ /总气 CH ₄ /总气 C ₂ H ₆ /总气 C ₂ H ₄ /总气 C ₂ H ₂ /总气
Doernenburg 法	CH ₄ /H ₂ C ₂ H ₂ /C ₂ H ₄ C ₂ H ₂ /CH ₄ C ₂ H ₂ /C ₂ H ₆
大卫三角法	CH ₄ /K C ₂ H ₂ /K C ₂ H ₄ /K
IEC 三比值法	C ₂ H ₂ /C ₂ H ₄ CH ₄ /H ₂ C ₂ H ₄ /C ₂ H ₆
关键气体法	H ₂ CH ₄ C ₂ H ₆ C ₂ H ₄ C ₂ H ₂

注:总气=H₂+CH₄+C₂H₆+C₂H₄+C₂H₂,K=CH₄+C₂H₂+C₂H₄。

表3 电力变压器特征量集

Table 3 Feature set of power transformer

编号	特征量	编号	特征量	编号	特征量
X ₁	H ₂	X ₁₀	C ₂ H ₄ /C ₂ H ₆	X ₁₉	H ₂ /总气
X ₂	CH ₄	X ₁₁	C ₂ H ₂ /CH ₄	X ₂₀	CH ₄ /总气
X ₃	C ₂ H ₆	X ₁₂	C ₂ H ₄ /H ₂	X ₂₁	C ₂ H ₆ /总气
X ₄	C ₂ H ₄	X ₁₃	C ₂ H ₆ /CH ₄	X ₂₂	C ₂ H ₄ /总气
X ₅	C ₂ H ₂	X ₁₄	C ₂ H ₆ /H ₂	X ₂₃	C ₂ H ₂ /总气
X ₆	C ₂ H ₂ /C ₂ H ₄	X ₁₅	CH ₄ /H ₂	X ₂₄	CH ₄ /总烃
X ₇	C ₂ H ₂ /C ₂ H ₆	X ₁₆	CH ₄ /K	X ₂₅	C ₂ H ₆ /总烃
X ₈	C ₂ H ₂ /CH ₄	X ₁₇	C ₂ H ₂ /K	X ₂₆	C ₂ H ₄ /总烃
X ₉	C ₂ H ₂ /H ₂	X ₁₈	C ₂ H ₄ /K	X ₂₇	C ₂ H ₂ /总烃

注:总烃=CH₄+C₂H₆+C₂H₄+C₂H₂。

诊断流程见图1。




图1 故障诊断流程图

Fig. 1 Flow chart of fault diagnosis

具体步骤如下:

1)收集电力变压器不同状态下的样本数据,利用反正切变换(AT)对原始特征量进行处理后再进行

去均值处理,构建原始特征样本集 X 。

2)将样本数据分为训练样本集 $\{(x_i,y_i)\}_{i=1}^{N_{tr}}$ 和测试样本集 $\{(x_i,y_i)\}_{i=1}^{N_{te}}$

3)用2.2节介绍的SAKECA方法步骤提取低维敏感特征,构造KELM的训练样本集 $\{z_{tr,i},y_{tr,i}\}_{i=1}^{N_{tr}}$ 和测试样本集 $\{z_{te,i},y_{te,i}\}_{i=1}^{N_{te}}$,训练KELM分类器,其中KELM中的核函数选用高斯核函数。

4)将测试集样本输入至训练好的分类模型,确定各测试样本所属故障类别。

5)将步骤4)所得测试集诊断结果与真实情况对比,计算诊断准确率。

4 实例对比分析

从历年的相关文献中收集了412个电力变压器7种状态下的样本数据用于文中的实例分析。从各状态样本中随机选取部分作为训练样本,剩余作为测试样本,具体划分见表4。可以看出训练样本共263个,测试样本共149个。文中采用表3中的27维原始特征变量,因此每个样本向量包含27个元素,可构成行数为263、列数为27的训练样本集 $\{(x_i,y_i)\}_{i=1}^{263},x\in R^{27}$,及行数为149、列数为27的测试样本集 $\{(x_i,y_i)\}_{i=1}^{149},x\in R^{27}$ 。

表4 不同状态样本构成

Table 4 Composition of different state samples

数据集	F ₁	F ₂	F ₃	F ₄	F ₅	F ₆	F ₇	总计
训练样本	39	47	41	33	43	31	29	263
测试样本	22	26	23	19	24	18	17	149
总计	61	73	64	52	67	49	46	412

为了更直观地说明SAKECA特征提取的能力强弱,基于相同的训练与测试样本数据,设置以下几种对比方法,按照累积贡献率不低于90%的原则分别对原始27维特征量进行特征提取与维数约简。各方法及其参数设定为:①PCA方法;②KPCA方法。采用高斯核,核参数为4;③KECA方法。采用高斯核,核参数为4;④监督自适应KPCA(SAKPCA)方法。基核采用高斯核,核参数为4;⑤SAKECA方法。基核采用高斯核,核参数为4。

方法说明:SAKPCA方法与SAKECA方法相似,是基于文中提出的自适应核函数优化框架来构建核矩阵,在此基础上根据KPCA特征提取流程,实现特征提取。各方法特征提取结果见表5。

从以下两个方面对上述各特征提取方法进行评估:

表5 主元个数及累积贡献率

Table 5 Number of principals and cumulative contribution rate

特征提取方法	主元个数	累积贡献率/%
PCA	8	90.346
KPCA	11	92.524
KECA	14	91.976
SAKPCA	9	92.857
SAKECA	7	93.231

1)用平均类间可分性参数指标来评价各方法特征提取的效果。平均类间可分性参数指标用于评估特征的类别区分能力,从而评价特征提取的效果,其计算方法具体可参考文[3]。基于训练样本集 $\{(x_i, y_i)\}_{i=1}^{263}, x \in R^{27}$,用上述各方法对原始27维特征进行维数约简,提取低维特征并计算相应的可分性参数,结果见表6。

表6 各特征提取方法对应的可分性参数

Table 6 Divisible parameter case on different feature extraction methods

特征提取方法	可分性参数	特征提取方法	可分性参数
PCA	0.044 3	ICUSU法	0.025 3
KPCA	0.062 1	Doernenburg法	0.041 8
KECA	0.076 4	大卫三角法	0.037 2
SAKPCA	0.097 3	IEC三比值法	0.019 7
SAKECA	0.119 5	关键气体法	0.033 6

分析表6可以得出以下结论:①在分类问题中,不同特征提取方法提取的特征量体现类别间差异的程度不同,PCA、KPCA、KECA、SAKPCA与SAKECA方法提取的特征量的可分性参数均大于5种传统方法对应的可分性参数,说明在初始完备故障特征集的基础上进行故障特征提取,能获得更具代表性的特征量;②电力变压器故障类型与特征量之间具有复杂的非线性关系,KPCA、KECA、SAKPCA与SAKECA为非线性的核属性约简方法,较PCA线性方法具有明显优势;③KECA方法以最小化信息熵损失为目标提取的特征区分故障的能力强于基于最小方差信息损失的PCA、KPCA方法,因此更加合理;④SAKPCA与SAKECA方法有效利用样本的类别信息,并克服核参数人为设置困难的问题,在处理分类问题时与传统的非监督KPCA与KECA方法相比,自动化程度更高且更有利于增大类间区分度。文中提出的SAKECA方法对应的可分性参数最大,明显优于其他方法,验证了其优越性。

2)将诊断准确率作为评价指标。基于相同的训练集与测试集,将上述各方法提取的特征量输入

KELM建立不同的诊断模型,并将测试集分类准确率作为最终的评价指标。KELM的原理及训练过程可参考文[20],文中设置KELM中广义逆矩阵的参数 $C=0.13$,核参数 $\gamma_2=4$ 。各诊断模型对测试集中各类状态的诊断准确率见图2,各特征提取方法下的测试集总体分类精度见表7。




图2 诊断效果对比

Fig. 2 Comparison of diagnosis effect

表7 不同特征提取方法下的诊断效果

Table 7 Diagnostic effects case on different feature extraction methods

特征提取方法	准确率/%	特征提取方法	准确率/%
PCA	84.84	ICUSU法	78.57
KPCA	88.28	Doernenburg法	84.14
KECA	90.31	大卫三角法	83.29
SAKPCA	91.28	IEC三比值法	64.86
SAKECA	93.36	关键气体法	81.43

分析图2和表7可以看出文中提出的SAKECA方法相比于PCA、KPCA、KECA等统计分析方法,明显提升了故障诊断准确率,将其与KELM相结合的故障诊断准确率为93.36%,明显优于其他方法。

上述分析验证了SAKECA特征选取方法在电力变压器故障特征提取中的有效性。

5 结论

文中提出一种监督自适应KECA特征选取方法,用于电力变压器故障特征提取,取得了良好的效果,结论如下:

1)基于余弦相似度提出一种面向多分类任务的核函数优化学习方法,以最大化内类相似度和最小化类间相似度为目标实现核函数自适应优化,削弱核参数设置不当对核属性约简方法带来的不利影响。

2)将自适应核函数优化学习与KECA相结合提出的SAKECA特征提取方法,有效结合样本标签信息克服了KECA核参数选取困难的问题,增大了类间区分度,降低了故障误诊率,具有良好的特征提取效果。

3)在电力变压器的故障特征提取中,相比于传统特征选取方法以及PCA、KPCA等统计分析方法,文中方法能有效提升故障诊断精度。

参考文献:

- [1] KHAN S A, EQUBAL M D, ISLAM T. A comprehensive comparative study of DGA based transformer fault diagnosis using fuzzy logic and ANFIS models[J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2015, 22(1):590-596.
- [2] 郭创新,朱承治,张琳,等.应用多分类多核学习支持向量机的变压器故障诊断方法[J].中国电机工程学报, 2010,30(13): 128-134.
GUO Chuangxin, ZHU Chengzhi, ZHANG Lin, et al. A fault diagnosis method for power transformer based on multi-class multiple-kernel learning support vector machine[J]. Proceedings of the CSEE, 2010, 30(13): 128-134.
- [3] 唐勇波,桂卫华,彭涛,等.基于相对重构贡献的变压器故障诊断方法[J].高电压技术, 2012, 38(11): 132-138.
TANG Yongbo, GUI Weihua, PENG Tao, et al. Transformer fault diagnosis method based on reconstruction - based contribution and grey relation entropy[J]. Chinese Journal of Scientific Instrument, 2012, 33(1): 132-138.
- [4] MIROWSKI P, LECUN Y. Statistical machine learning and dissolved gas analysis: A review[J]. IEEE Transactions on Power Delivery, 2012, 27(4):1791-1799.
- [5] GHONEIM S S M, TAHA I B M, ELKALASHY N I. Integrated ANN -based proactive fault diagnostic scheme for power transformers using dissolved gas analysis[J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2016, 23(3):1838-1845.
- [6] HUANG Y C, SUN H C. Dissolved gas analysis of mineral oil for power transformer fault diagnosis using fuzzy logic [J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2013, 20(3): 974-981.
- [7] AHMAD M B, YAACOB Z B. Dissolved gas analysis using expert system[C]//Student Conference on Research and Developmen(SCORed). [S.l.]:IEEE, 2002:313-316.
- [8] 董明,孟源源,徐长响,等.基于支持向量机及油中溶解气体分析的大型变压器故障诊断模型研究[J].中国电机工程学报, 2003, 23(7): 88-92.
DONG Ming, MENG Yuanyuan, XU Changxiang, et al. Fault Diagnosis model for power transformer based on support vector machine and dissolved gas analysis[J]. Proceedings of the CSEE, 2003, 23(7): 88-92.
- [9] QUISPE CARITA A J, CAMBRAIA LEITE L, PIRES ME-DEIROS A P, et al. Bayesian networks applied to failure diagnosis in power transformer[J]. IEEE Latin America Transactions (Revista IEEE America Latina), 2013, 11(4): 1075-1082.
- [10] 黄新波,李文君子,宋桐,等.采用遗传算法优化装袋分类回归树组合算法的变压器故障诊断[J].高电压技术, 2016, 42(5): 1617-1623.
- HUANG Xinbo, LI Wenjunzi, SONG Tong, et al. Application of bag-ging-CART algorithm optimized by genetic algorithm in transformer fault diagnosis[J]. High Voltage Engineering, 2016, 42(5): 1617-1623.
- [11] LI J, ZHANG Q, WANG K, et al. Optimal dissolved gas ratios selected by genetic algorithm for power transformer fault diagnosis based on support vector machine[J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2016, 23(2):1198-1206.
- [12] 汪可,李金忠,张书琦,等.变压器故障诊断用油中溶解气体新特征参量[J].中国电机工程学报, 2016, 23(6): 269-277.
WANG Ke, LI Jingzhong, ZHANG Shuqi, et al. New features derived from dissolved gas analysis for fault diagnosis of power transformers[J]. Proceedings of the CSEE, 2016, 23(6):269-277.
- [13] 陈嘉霖,段家华,张明宇.邻域粗糙集与相关向量机相结合的变压器故障综合诊断模型[J].电力系统及其自动化学报, 2016, 28(11): 117-122.
CHEN Jialin, DUAN Jiahua, ZHANG Mingyu, et al. Comprehensive fault diagnosis model of transformers based on combination of neighborhood rough set and relevance vector machine[J]. Proceedings of the CSU - EPSA, 2016, 28(11): 117-122.
- [14] SAMIRMI F D, TANG W, WU H. Feature selection in power transformer fault diagnosis based on dissolved gas analysis[C]//Innovative Smart Grid Technologies Europe. [S.l.]:IEEE, 2014:1-5.
- [15] 唐勇波,熊印国.相对变换主元分析特征提取的变压器故障诊断[J].系统仿真学报, 2018, 30(3):1127-1133.
TANG Yongbo, XIONG Yinguo. Transformer fault diagnosis based on feature extraction of relative transformation principal component analysis[J]. Journal of System Simulation, 2018, 30(3): 1127-1133.
- [16] 吴广宁,袁海满.基于特征评估与核主元分析的电力变压器故障诊断[J].高电压技术 2017, 43(8):2533-2540.
WU Guangning, YUAN Haiman. Fault diagnosis of power transformer based on feature evaluation and kernel principal component analysis[J]. High Voltage Engineering, 2017, 43(8):2533-2540.
- [17] JENSENSEN R. Kernel entropy component analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(5):847-860.
- [18] 孙娜,刘继文,肖东亮,等.基于BFGS拟牛顿法的压缩感知SLO重构算法[J].电子与信息学报, 2018, 40(10): 2408-2414.
SUN Na, LIU Jiwen, XIAO Dongliang, et al. SLO reconstruction algorithm for compressive sensing based on BFGS quasi newton method[J]. Journal of Electronics & Information Technology, 2018, 40(10): 2408-2414.
- [19] SAMIRMI F D, TANG W, WU H. Feature selection in

(下转第 261 页)

- by ± 660 kV Yin-dong DC system[J]. International Journal of Automation & Power Engineering, 2013, 2(4):157-160.
- [6] 丛培杰, 曲德宇, 白雨, 等. 面向变压器振动的分布式监测系统的设计与实现[J]. 电测与仪表, 2019, 56(18): 107-112.
- CONG Peijie, QU Deyu, BAI Yu, et al. Design and implementation of a distributed vibration monitoring system for power transformer[J]. Electrical Measurement & Instrumentation, 56(18):107-112.
- [7] 刘勇, 汲胜昌, 杨帆, 等. 检测变压器故障的扫频阻抗法特性研究及应用[J]. 高电压技术, 2016, 42(10):3237-3238.
- LIU Yong, JI Shengchang, YANG Fan, et al. Characteristics and application of sweep frequency impedance method for detecting transformer fault[J]. High Voltage Engineering, 2016, 42(10):3237-3238.
- [8] LIU Y, JI S, YANG F, et al. A study of the sweep frequency impedance method and its application in the detection of internal winding short circuit faults in power transformers[J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2015, 22(4):2046-2056.
- [9] 余长厅, 黎大健, 陈梁远, 等. 稳态条件下变压器绕组轴向振动分布特性研究[J]. 高压电器, 2019, 55(11):100-104.
- YU Zhangting, LI Dajian, CHEN Liangyuan, et al. Axial vibration distribution of transformer winding in steady state[J]. High Voltage Apparatus, 2019, 55(11): 100-104.
- [10] 王丰华, 王邵菁, 陈頌, 等. 基于改进MFCC和VQ的变压器声纹识别模型[J]. 中国电机工程学报, 2017, 37(5): 1535-1542.
- WANG Fenghua, WANG Shaojing, CHEN Song, et al. Voiceprint recognition model of power transformers based on improved MFCC and VQ[J]. Proceedings of the CSEE, 2017, 37(5):1535-1542.
- [11] 王佳音, 白保东, 刘宏亮, 等. 直流偏磁对变压器振动噪声的影响[J]. 电工技术学报, 2015, 30(8):62-67.
- WANG Jiayin BAI Baodong LIU Hongliang, et al. Research on vibration and noise of transformers under DC bias[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 56-61.
- [12] 汲胜昌, 师愉航, 张凡, 等. 电力变压器振动与噪声及其控制措施研究现状与展望[J]. 高压电器, 2019, 55(11): 1-17.
- JI Shengchang, SHI Yuhang, ZHANG Fan, et al. Review on vibration and noise of power transformer and its control measures[J]. High Voltage Apparatus, 2019 55(11):1-17.
- [13] YONG L, JI S, FAN Y, et al. A study of the sweep frequency impedance method and its application in the detection of internal winding short circuit faults in power transformers[J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2015, 22(4):2046-2056.
- [14] 白艳艳, 张晓俊. 建立弹簧-质量-阻尼系统数学模型的数轴法[J]. 噪声与振动控制, 2012, 32(3):59-62.
- BAI Yanyan, ZHANG Xiaojun. Numerical-axis method for establishing the mathematical model of mass - spring - damper system[J]. Noise and Vibration Control, 2017, 37(5): 1535-1542.
- [15] 宋志杰, 王健. 模糊聚类和LM算法改进BP神经网络的变压器故障诊断[J]. 高压电器, 2013, 45(5):59-64.
- SONG Zhijie, WANG Jian. Transformer fault diagnosis based on BP neural network optimized by fuzzy clustering and LM algorithm[J]. High Voltage Apparatus, 2013, 45(5): 54-59.
- [16] 孟卫东, 刘杨, 张伟, 等. 基于BP神经网络的变压器故障诊断[J]. 通信电源技术, 2020, 37(2):84-86.
- MENG Weidong, LIU Yang, ZHANG Wei, et al. Transformer fault diagnosis based on BP neural network[J]. Telecom Power Technology, 2020, 37(2):84-86.
- [17] 李笑竹, 陈志军, 樊小朝, 等. 基于ACS-SA文化基因算法的BP神经网络变压器故障诊断[J]. 高压电器, 2018 54(2): 134-139.
- LI Xiaozhu, CHEN Zhijun, FAN Xiaochao, et al. Fault diagnosis of transformer based on BP neural network and ACS-SA[J]. High Voltage Apparatus, 2018 54(2): 134-139.
- [18] ZHANG Q H. BP neural network and its improved algorithm in the power system transformer fault diagnosis[J]. Applied Mechanics & Materials, 2013(418):200-204.
- [19] LI Y, WANG X, ZHANG Y. Research on transformer fault diagnosis based on online sequential extreme learning machine[J]. Recent Advances in Electrical & Electronic Engineering (Formerly Recent Patents on Electrical & Electronic Engineering), 2019, 12(5):408-413.
- [20] ZOU A, DENG R, MEI Q, et al. Fault diagnosis of a transformer based on polynomial neural networks[J]. Cluster Computing, 2017(11):1-9.
- 余长厅(1991—), 男, 硕士, 工程师, 研究方向为变压器技术。

(上接第255页)

- power transformer fault diagnosis based on dissolved gas analysis[C]//Innovative Smart Grid Technologies Europe. [S.l.]: IEEE, 2014:1-5.
- [20] LU S, YU H, DONG H, et al. Single-step prediction method of burning zone temperature based on real-time wavelet filtering and KELM[J]. Engineering Applications of Artificial

Intelligence, 2018(70):142-148.

彭丽维(1995—), 女, 硕士研究生, 研究方向为电气设备故障诊断。

张彼德(1975—), 男, 博士, 教授, 主要研究方向为电气设备在线监测及故障诊断、电力系统规划、可靠性分析。