

Kernel PCA 与 BP 神经网络相结合的 变压器故障诊断*

胡青, 杜林, 杨丽君, 孙才新

(重庆大学输配电装备及系统安全与新技术国家重点实验, 重庆 400030)

摘要: 为了提高变压器故障诊断的准确率和抗干扰能力, 提出一种基于核特征量的 BP 神经网络故障诊断模型。通过核主成分分析将故障样本从低维的特征空间非线性地映射到高维的核空间, 提高了样本的可分性, 然后以核特征量作为 BP 神经网络的输入特征量, 建立变压器故障诊断模型。实验对比了结构相似、输入量不同的 BP 神经网络, 结果表明采用核特征量的诊断模型具有更好的诊断效果和抗干扰能力。

关键词: 核主成分分析; BP 神经网络; 电力变压器; 故障诊断

中图分类号: TP391 **文献标志码:** A **文章编号:** 1001-3695(2010)02-0580-02

doi:10.3969/j.issn.1001-3695.2010.02.049

Transformer fault diagnosis based on kernel PCA and BPNN

HU Qing, DU Lin, YANG Li-jun, SUN Cai-xin

(State Key Laboratory of Power Transmission Equipment & System Security & New Technology, Chongqing University, Chongqing 400030, China)

Abstract: To improve the accuracy and anti-noise ability for transformer fault diagnosis, this paper proposed a novel BP neural network based on kernel features. Samples were nonlinearly mapped from the low-dimensional feature space into the high-dimensional kernel space by kernel PCA, which improved samples' separability, then built BP neural network in kernel space. Experiments compared performances of BP neural networks with similar constructs, different input features, the results show that diagnostic models with kernel features achieve better performance and anti-noise ability.

Key words: kernel PCA; BP neural network; power transformer; fault diagnosis

变压器是电力系统中最重要设备之一, 研究变压器故障诊断对电力系统安全稳定运行具有重大意义。油中溶解气体分析(DGA)是监督和诊断变压器状态的重要方法, 常用特征气体有 H₂、CH₄、C₂H₄、C₂H₆ 和 C₂H₂, 工程中常用的改良三比值法具有编码不全、编码边界过于绝对等缺点, 因此多种人工智能方法应用于变压器故障诊断领域, 一定程度上提高了诊断准确率, 其中人工神经网络以其优良的非线性逼近能力在变压器故障诊断中取得了较好的效果^[1-7]。已有的神经网络诊断模型大都直接采用 DGA 特征气体作为输入量, 采用三层结构, 研究主要集中于对神经网络结构的调整^[1,3,5-6]以及神经网络算法^[4,7]的研究上, 对特征气体含量大多采用线性方法进行预处理, 使用较多的有百分比法和线性归一法^[2], 较少涉及对特征量的分析研究。然而变压器故障诊断是典型的非线性分类问题, 用线性方法对数据进行预处理, 无助于故障特征的提取, 因此本文采用非线性的核主成分分析方法, 将故障样本从特征空间映射到更高维的核空间, 提取故障特征, 用核特征量构造 BP 神经网络, 建立变压器故障诊断模型, 提高了诊断准确率和抗干扰能力。

1 核主成分分析

主成分分析(PCA)是统计学中应用较多的经典分析方法

之一。它是对数据原有坐标系统的线性变换, 数据点在新坐标系下的值被称为主成分, 通常少量主成分就可以说明数据集特性, 从而降低了数据维数。而核主成分分析(kernel PCA, KPCA)是对 PCA 的非线性推广, 不是分析输入空间的主成分, 是与输入样本呈非线性关系的特征空间的主成分, 特征空间可以是任意维数。KPCA 方法可以增加数据维数, 应用于特征提取、模式识别等领域^[8]。用 R^N 表示 N 维的输入空间, $x_i \in R^N$ ($i = 1, \dots, M$) 表示一组已经中心化的观测值, 即满足

$$\sum_{i=1}^M x_i = 0 \tag{1}$$

输入空间的观测值 x 通过非线性变换 φ 映射到特征空间 F , 即

$$\varphi: R^N \rightarrow F, x \mapsto X \tag{2}$$

假设映射到特征空间 F 中的数据同样是中心化的, 即 $\sum_{i=1}^M \varphi(x_i) = 0$, 那么协方差矩阵为

$$\bar{C} = \frac{1}{M} \sum_{i=1}^M \varphi(x_i) \varphi(x_i)^T \tag{3}$$

其特征向量位于 $\varphi(x_1), \dots, \varphi(x_M)$ 组成的空间中。设 \bar{C} 的特征值为 λ , 特征向量 V 可表示为

$$V = \sum_{i=1}^M \alpha_i \varphi(x_i) \tag{4}$$

对于 $k = 1, \dots, M$, 下式成立。

收稿日期: 2009-06-18; 修回日期: 2009-08-03 基金项目: 国家“973”计划重点基础研究发展资助项目(2009CB724506)

作者简介: 胡青(1975-), 女, 重庆人, 博士研究生, 主要研究方向为模式识别、电气设备与系统在线监测及诊断技术等(huqing@cqu.edu.cn); 孙才新(1944-), 男, 主任, 教授, 博导, 国务院学位委员会学科(电气工程)评议组成员, 主要研究方向为高电压绝缘、电气设备与系统在线监测及诊断技术。

$$\varphi(x_k) \cdot \lambda V = \varphi(x_k) \cdot \overline{CV}$$

将式(3)和(4)代入,得到

$$\lambda \sum_{i=1}^M \alpha_i (\varphi(x_k) \cdot \varphi(x_i)) = \frac{1}{M} \sum_{i=1}^M \alpha_i (\varphi(x_k) \cdot \sum_{j=1}^M \varphi(x_j) (\varphi(x_j) \cdot \varphi(x_i))) \quad (5)$$

定义 $M \times M$ 维矩阵 $K, K_{ij} = \varphi(x_i) \cdot \varphi(x_j)$, 式(5)可写为

$$M \lambda K \alpha = K^2 \alpha \quad (6)$$

KPCA 并不直接计算每个观测点 x_i 的非线性映射 $\varphi(x_i)$, 而是通过核函数 $h(\cdot)$ 间接计算特征空间 F 中映射点 $\varphi(x_i)$ 和 $\varphi(x_j)$ 的点积, 即

$$h(x, y) = \varphi(x) \cdot \varphi(y) \quad (7)$$

任何点积形式的算法都可作为核函数, 若 $h(x, y) = x \cdot y$, KPCA 就还原为 PCA 方法。设 $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_M$ 是矩阵 K 的特征值, $\alpha^1, \alpha^2, \dots, \alpha^M$ 是对应的特征向量, λ_p 是第一个不为 0 的特征值, 那么协方差矩阵 \overline{C} 的特征向量 $V^k (k = p, \dots, M)$ 的标准化, 可以变化为 $\alpha^p, \dots, \alpha^M$ 的标准化, 即

$$1 = \sum_{i,j=1}^M \alpha_i^k \alpha_j^k (\varphi(x_i) \cdot \varphi(x_j)) = \sum_{i,j=1}^M \alpha_i^k \alpha_j^k K_{ij} = \lambda_k (\alpha^k \cdot \alpha^k) \quad (8)$$

新观测点 x 在特征空间 F 中的映像为 $\varphi(x)$, $\varphi(x)$ 在特征向量 V^k 上的投影就是 $\varphi(x)$ 的非线性主成分, 即

$$(V^k \cdot \varphi(x)) = \sum_{i=1}^M \alpha_i^k (\varphi(x_i) \cdot \varphi(x)) \quad (9)$$

2 与 KPCA 相结合的 BPNN 诊断模型

本文将 KPCA 与 BPNN 相结合, 建立变压器故障诊断模型, 称为 KPCA-BP 模型。模型将变压器故障分为高温过热、中低温过热、低能放电、高能放电, 分别用 F_1, F_2, F_3 和 F_4 表示, 故障样本 $X = [x_1 \ x_2 \ \dots \ x_5]^T$ 为 $H_2, CH_4, C_2H_4, C_2H_6$ 和 C_2H_2 气体含量的百分比。选择 $h(x, y) = (x \cdot y + 1)^d$ 作为核函数, 分别对每一类故障样本进行 KPCA 分析, 得到对应的变换矩阵 $KTRAN_i (i = 1, \dots, 4)$ 。理论上, KPCA 分析后得到的核主成分个数等于故障样本个数, 但其中一些核主成分的特征值较小, 因此只保留 $\lambda \geq 10^{-2}$ 的主成分, 经 KPCA 变换后核主成分个数为 $N = \sum_{i=1}^4 N_i$ 。模型采用 BP 神经网络, 用 KPCA 变换后的核主成分作为神经网络的输入向量 $P = [kx_1 \ kx_2 \ \dots \ kx_N]^T$, KPCA-BP 模型结构如图 1 所示。

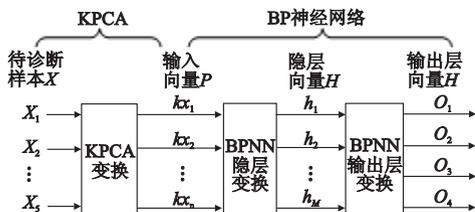


图1 KPCA-BP模型结构示意图

隐层向量 H 和输出层向量 O 的计算式如下:

$$H = f_1(IW \times P + a), O = f_2(LW \times H + b) \quad (10)$$

其中: $IW_{M \times N}$, a 和 $LM_{4 \times M}$, b 分别为隐层以及输出层的权重矩阵和偏差向量; M 为隐层节点数; f_1 和 f_2 分别表示隐层和输出层的传递函数。输出层节点的值说明待诊断样本对故障类 F_1, F_2, F_3, F_4 的隶属度, 样本属于隶属度最大的故障类。

3 模型构造及诊断性能分析

从收集到的故障样本中选择了 80 个样本作为训练集, 以 BP 神经网络模型 (BPNN) 作为比较对象。BPNN 用五种 DGA

气体含量的百分比作为输入向量, 网络结构为 5-14-4, 输出层节点数为 4, 选择隶属度最大的类别作为诊断结果。KPCA-BP 模型选择 $(x \cdot y + 1)^d$ 作为核函数 $h(x, y)$, 参数 d 取值为 3。用 KPCA 变换后的主成分作为输入向量训练 BP 神经网络诊断, 输入层节点数 $N = 33$, 网络结构为 33-66-4。为了充分比较两种模型性能, 分别以 tansig 和 logsig 作为传递函数, 训练 BPNN 和 KPCA-BP 模型, 函数输出如图 2 所示。

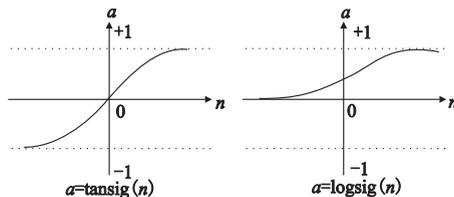


图2 传递函数tansig和logsig的输出

测试集 T 由 210 个实际收集到的故障样本组成, 为了比较两种模型的抗干扰能力, 在测试集 T 基础上, 分别增加 5%、10% 和 15% 的随机噪声形成测试集 T_5, T_{10} 和 T_{15} , 实验结果如表 1 所示。从实验情况可知, 在各种情况下, KPCA-BP 模型的性能均优于 BP 模型。

表1 BPNN与KPCA-BP模型的准确率 %

测试集	BPNN (tansig)	KPCA-BP (tansig)	BPNN (logsig)	KPCA-BP (logsig)
T	82.9	87	77.4	85.7
T_5	81.5	85.3	76	83.8
T_{10}	79.7	82.9	75	82
T_{15}	74.6	76.9	72.8	78.8

4 结束语

非线性的核主成分分析能有效地提取故障特征, 针对各个故障类样本分别进行分析, 所得核特征量比特征气体含量更能反映该故障类的特性。因此用核特征量作为诊断特征量, 建立 BP 神经网络诊断模型, 能够充分利用故障自身特性, 强化故障类特征, 实验结果说明新模型具有更好的准确率和抗干扰能力。核主成分分析的核心是核函数, 模型中核函数及函数参数的确定都是根据经验人工选择的, 如何选择合适的核函数以及函数参数, 是今后深入研究应用核主成分分析方法的重点。

参考文献:

- [1] ZHANG Y, DING X, LIU Y, et al. An artificial neural network approach to transformer fault diagnosis [J]. IEEE Trans on Power Delivery, 1996, 11(4):1836-1841.
- [2] 丁晓群, 孙军, 袁宇波, 等. 基于 BP 网络的故障诊断方法的改进 [J]. 电网技术, 1998, 22(11):63-65.
- [3] GUARDADO J L, NAREDO J L, MORENO P, et al. A comparative study of neural network efficiency in power transformers diagnosis using dissolved gas analysis [J]. IEEE Trans on Power Delivery, 2001, 16(4):643-647.
- [4] 章剑光, 周浩, 项灿芳. 基于 Super SAB 神经网络算法的主变压器故障诊断模型 [J]. 电工技术学报, 2004, 19(7):49-58.
- [5] 王雪梅, 李文申, 严璋. BP 网络在电力变压器故障诊断中的应用 [J]. 高电压技术, 2005, 31(7):12-14.
- [6] 李清泉, 王伟, 王晓龙. 利用 DGA2NN 诊断油浸式电力变压器故障 [J]. 高电压技术, 2007, 33(8):48-51.
- [7] 王南兰, 邱德润. 油中溶解气体分析的变压器故障诊断新方法 [J]. 高电压技术, 2006, 32(6):35-37.
- [8] SCHOELKOPF B, SMOLA A J, MUELLER K R. Kernel principal component analysis [R]. Lecture Notes in Computer Science. 1997.