

# 基于极限学习机的电力变压器故障诊断

杜文霞, 赵秀平, 杜海莲, 吕 锋

(河北师范大学 职业技术学院, 河北 石家庄 050024)

**摘要:**针对三比值法存在比值编码缺失无法诊断故障的不足,将泛化性能好的极限学习机与三比值法相结合,用于电力变压器的故障诊断。一方面将样本中特征气体的组分含量及对应的比值编码作为极限学习机的输入,使建立的极限学习机故障诊断模型包含了比值编码信息,进一步发挥三比值法在远离区间分界点时诊断准确率高的长处;另一方面,在故障诊断时,可根据待测样本输出矩阵中每列元素最大值所在的行,判断样本所属的故障类型,从而在一定程度上弥补了比值编码缺失无法诊断故障的不足。实例诊断结果表明,该方法计算简单,灵活方便,故障诊断正确率高,具有一定可行性和有效性。

**关键词:**极限学习机;电力变压器;故障诊断;三比值

中图分类号:TP206

文献标志码:A

文章编号:1672-3767(2017)05-0029-08

DOI:10.16452/j.cnki.sdkjzk.2017.05.005

## Fault Diagnosis of Power Transformer Based on Extreme Learning Machine

DU Wenxia, ZHAO Xiuping, DU Hailian, LÜ Feng

(College of Career Technology, Hebei Normal University, Shijiazhuang, Hebei 050024, China)

**Abstract:** In order to overcome the deficiency of three-ratio method that fault diagnosis cannot be made due to missing ratio coding, the extreme learning machine (ELM) with good generalization performance was combined with the three ratio method to diagnose the fault of the power transformer. On the one hand, to take full advantage of the high diagnosis accuracy of the three-ratio method while being far away from the interval boundary point, an ELM fault diagnosis model was established which included the ratio of coded information by taking the component content of the characteristic gas in the sample and the corresponding ratio of codes as the input of ELM. On the other hand, in the fault diagnosis, the fault type of the sample was judged according to the maximum line of the test output matrix, which, to a certain extent, made up for the failure to diagnose fault because of missing ratio encoding. The diagnosis result of the application example shows that the proposed method, with simple, flexible, and convenient calculations, is feasible and effective.

**Key words:** extreme learning machine; power transformer; fault diagnosis; three-ratio

电力变压器是供配电系统中的重要设备之一,在运行时容易出现由于相间或匝间短路引起的热性故障,或出现由于高电场强度作用造成绝缘性能下降或劣化的电性故障。研究电力变压器故障诊断技术,对提高变压器的运行维护水平具有重要意义。分析油中溶解气体的组分和含量是监视充油电力变压器

收稿日期:2017-03-11

基金项目:国家自然科学基金项目(61673160,60974063,61175059);河北省自然科学基金项目(F2014205115);河北省教育厅课题(ZD2016053);河北省科技厅项目(15212115)

作者简介:杜文霞(1973—),女,河北衡水人,博士,副教授,主要从事工业过程性能智能监测与故障诊断技术研究。

E-mail:dwx20040513@163.com

杜海莲(1978—),女,河北保定人,副教授,主要从事故障诊断方面的研究,本文通信作者。

E-mail:duhailian@126.com

安全运行的最有效措​​施之一。三比值法在油中溶解气体为特征量的充油变压器故障诊断中得广泛应用<sup>[1-3]</sup>,大量实践及事例验证,根据气体比值划分区间的编码规则基本合理,尤其是在远离区间分界点的地方,这样确定的编码准确率相当高,但是当气体组分比值编码缺失时,用三比值法则无法进行故障诊断。随着人工智能研究的发展,各种智能学习方法在变压器故障诊断中得到广泛应用<sup>[4-7]</sup>。基于传统神经网络和支持向量机的变压器故障诊断方法克服三比值法的不足<sup>[6-7]</sup>,提高了诊断准确率,但存在训练速度慢、调节参数多、参数确定困难等缺点。极限学习机(extreme learning machine, ELM)是一种典型的单隐含层前馈神经网络<sup>[8-9]</sup>,可随机初始化输入权重和偏置,并得到相应的输出权重,且在训练过程中无需调整连接权值,只需设置隐含层神经元的个数,便可获得唯一的最优解,克服了传统学习方法的一些缺点,具有学习速度快、泛化性能好等优点<sup>[10-14]</sup>。因此,本文将极限学习机用于电力变压器故障诊断,并对诊断结果进行分析。

### 1 极限学习机基本理论

极限学习机是一种典型的单隐含层前馈神经网络,网络结构如图 1 所示。

在图 1 中,输入层有  $n$  个神经元,对应  $n$  个输入变量;隐含层有  $K$  个神经元,与输入层之间的连接权值矩阵为  $\mathbf{w} = \{\omega_{jt}\} (j = 1, 2, \dots, K; t = 1, 2, \dots, n)$ ,  $\omega_{jt}$  表示隐含层第  $j$  个神经元与输入层第  $t$  个神经元间的连接权值,  $b_j$  为隐含层第  $j$  个神经元的阈值;输出层有  $m$  个神经元,隐含层与输出层间的连接权值为  $\beta = \{\beta_{jk}\} (j = 1, 2, \dots, K; k = 1, 2, \dots, m)$ ,  $\beta_{jk}$  表示隐含层第  $j$  个神经元与输出层第  $k$  个神经元间的连接权值。

设有  $N$  个样本数据,每个样本有  $n$  个属性,则网络的输入及期望输出可分别表示为  $\mathbf{x}_i = [x_{i1} \ x_{i2} \ \dots \ x_{in}]^T$  和  $\mathbf{y}_i = [y_{i1} \ y_{i2} \ \dots \ y_{im}]^T, (i = 1, 2, \dots, N)$ 。隐层神经元的激励函数  $g(x)$  可选“Sigmoid”函数或“RBF”函数等,网络实际输出为  $\mathbf{T} = [t_1 \ t_2 \ \dots \ t_i \ \dots \ t_N]$




图 1 ELM 结构

Fig. 1 ELM architecture

$$t_i = \begin{bmatrix} t_{i1} \\ t_{i2} \\ \vdots \\ t_{im} \end{bmatrix} = \begin{bmatrix} \sum_{j=1}^K \beta_{j1} g(\omega_{j1}x_i + b_j) \\ \sum_{j=1}^K \beta_{j2} g(\omega_{j2}x_i + b_j) \\ \vdots \\ \sum_{j=1}^K \beta_{jm} g(\omega_{jm}x_i + b_j) \end{bmatrix}, (i = 1, 2, \dots, N) . \quad (1)$$

其中,  $\mathbf{w}_j = [\omega_{j1}, \omega_{j2}, \dots, \omega_{jt}, \dots, \omega_{jn}]$ ,由上述定义描述的极限学习机能够以零误差逼近训练样本,即

$$\sum_i^N \|t_i - y_i\| = 0 , \quad (2)$$

以矩阵形式可表示为:  $\mathbf{Y}^T = \mathbf{H}\beta$  , (3)

$$\mathbf{H} = \begin{bmatrix} g(\mathbf{w}_1x_1 + b_1) & \dots & g(\mathbf{w}_Kx_1 + b_K) \\ \vdots & & \vdots \\ g(\mathbf{w}_1x_N + b_1) & \dots & g(\mathbf{w}_Kx_N + b_K) \end{bmatrix}_{N \times K} , \quad (4)$$

$$\beta = \begin{bmatrix} \beta_{11} & \beta_{12} & \cdots & \beta_{1m} \\ \beta_{21} & \beta_{22} & \cdots & \beta_{2m} \\ \vdots & \vdots & & \vdots \\ \beta_{K1} & \beta_{K2} & \cdots & \beta_{Km} \end{bmatrix}, Y = [y_1 \quad y_2 \quad \cdots \quad y_N]_{m \times N} = \begin{bmatrix} y_{11} & \cdots & y_{1N} \\ \vdots & & \vdots \\ y_{m1} & \cdots & y_{mN} \end{bmatrix}, \quad (5)$$

$H$  为隐含层的输出矩阵,当激励函数无限可微时,输入层与隐含层的连接权值以及隐含层的阈值可在训练随机选择,并且在训练过程中保持不变。通过求解方程组  $\min \|H\beta - Y^T\|$  的最小二乘解获得隐含层与输出层间的连接权值

$$\hat{\beta} = H^+ Y^T. \quad (6)$$

$H^+$  其解为隐含层输出矩阵  $H$  的 Moore-Penrose 广义逆。

因此,基于 ELM 极限学习机算法的步骤如下:

- 1) 确定隐含层神经元个数,随机设定输入层与隐含层连接权值  $w$  和隐含层神经元的阈值  $b$  ;
- 2) 选择一个激活函数,计算隐含层神经元的输出矩阵  $H$  ;
- 3) 计算输出权值。

## 2 基于 ELM 的电力变压器故障诊断

### 2.1 电力变压器的故障类型

在电力变压器运行过程中,一般通过采取油样,利用气相色谱法进行油中溶解气体分析(Dissolved Gas Analysis, DGA)技术,根据分析组分及其浓度的变化规律判断变压器所处的状态。电力变压器在运行时容易出现由于相间或匝间短路引起的热性故障,或出现由于高电场强度的作用造成绝缘性能下降或劣化的电性故障,具体包括:中低温过热、高温过热、低能放电、高能放电、放电兼过热和局部放电 6 种故障。为了有效进行故障诊断,须选择具有代表性的变量,以  $H_2, CH_4, C_2H_2, C_2H_4, C_2H_6$  在混合气中的相对含量和  $(C_2H_2/C_2H_4), (CH_4/H_2), (C_2H_4/C_2H_6)$  三组气体相对含量的比值作为 ELM 分类器的输入变量。

### 2.2 电力变压器的故障诊断的 ELM 模型

#### 2.2.1 样本数据选取

在电力变压器运行过程中,利用气相色谱法可多次测量  $H_2, CH_4, C_2H_2, C_2H_4$  以及  $C_2H_6$  5 种特征气体的含量(单位:  $\mu L/L$ )。由于不同地区不同部门的变压器数据库在记录形式、记录习惯、记录时间段以及数据汇总形式等方面存在差异,需对不同的数据源进行适当取舍,按统一形式整合。根据样本数据的广泛性、紧凑性和样本中各类故障占总类的百分比应与工程上实际各类故障发生率相近的原则,从电力公司检修工区油务组和文献[15-16]共收集了有明确结论的部分变压器故障数据。借鉴 DL/T 722—2000《导则》的三比值故障类,把正常情况作为一个类别考虑,对这 276 条数据进行分类,样本数据故障类型见表 1,部分数据样本如表 2 所示。其中,表 2 的故障类型:1 表示中低温过热;2 表示高温过热;3 表示低能放电,即火花放电;4 表示高能放电,即电弧放电;5 表示放电兼过热;6 表示局部放电;7 表示正常。表 2 中, $V$  表示混合气的体积, $V_{H_2}$  表示  $H_2$  的体积, $V_{CH_4}$  表示  $CH_4$  的体积, $V_{C_2H_2}$  表示  $C_2H_2$  的体积, $V_{C_2H_4}$  表示  $C_2H_4$  的体积, $V_{C_2H_6}$  表示  $C_2H_6$  的体积。

为了从样本数据中随机获取训练集和测试集,将样本按行随机排序,去掉样本序列号,剩余数据用矩阵  $X$  表示,则第  $i$  样本可表示为  $x_i = [x_{i1}, x_{i2}, \cdots, x_{i5}, x_{i9}]$ ,  $i = 1, 2, \cdots, N$ ,  $N$  为样本总数。若训练集和测试集的输入输出分别用矩阵  $X_{train}, T_{train}$  以及  $X_{test}$  和  $T_{test}$  表示,则矩阵  $X$  可划分为 4 部分:

$$X = \begin{bmatrix} X_{train} & T_{train} \\ X_{test} & T_{test} \end{bmatrix}. \quad (7)$$

表 1 样本数据故障类型

Tab. 1 Fault types of sample data

序号	故障类型	样本数
1	中低温过热	26
2	高温过热	126
3	低能放电	59
4	高能放电	38
5	放电兼过热	16
6	局部放电	6
7	正常	5

表 2 部分数据样本  
Tab. 2 Part of data samples

样本 序号	$\frac{V_{H_2}}{V}$	$\frac{V_{CH_4}}{V}$	$\frac{V_{C_2H_6}}{V}$	$\frac{V_{C_2H_4}}{V}$	$\frac{V_{C_2H_2}}{V}$	$\frac{V_{C_2H_2}}{V_{C_2H_4}}$	$\frac{V_{CH_4}}{V_{H_2}}$	$\frac{V_{C_2H_4}}{V_{C_2H_6}}$	故障 类型
1	113.25	309.89	166.85	489.78	0.48	0	2	1	1
2	132.06	445.46	251.47	720.23	0.79	0	2	1	1
3	69.27	192.00	96.94	291.00	0.30	0	2	2	2
4	275.00	508.00	133.00	1 200.00	2.50	0	2	2	2
5	130.40	48.80	16.30	93.40	123.40	1	0	2	3
6	106.00	24.00	4.00	28.00	37.00	1	0	2	3
7	512.00	87.00	11.50	163.90	185.21	1	0	2	4
8	344.10	213.00	18.60	199.90	257.60	1	0	2	4
9	44.00	56.00	9.60	61.00	80.00	0	2	2	5
10	210.00	420.00	16.00	370.00	570.00	0	2	2	5
11	559.00	8.20	0.90	1.70	0	0	1	0	6
12	842.00	51.00	2.50	0.90	0	0	1	0	6
13	45.60	36.99	7.90	7.52	0.31	0	0	0	7
14	46.13	12.00	33.14	8.00	0.59	0	0	0	7
...	...	...	...	...	...	...	...	...	...
275	22.00	24.00	16.40	38.30	26.60	1	2	1	5
276	559.00	8.20	0.90	1.70	0	0	1	1	6

### 2.2.2 故障诊断的 ELM 分类器模型

利用训练集样本的输入输出数据可建立极限学习机故障分类模型。ELM 分类算法可概括为：先将原始训练数据作为输入，训练得到 ELM 分类模型；再将原始测试数据输入 ELM 分类模型，得到模型分类结果，具体步骤如下：

- 1) 确定故障样本数据的训练集和测试集输入矩阵。
- 2) 样本归一化处理

一般认为 DGA 数据变化规律受诸多因素如负荷、温度、压力等的影响，而数据本身的质量取决于采集数据过程仪器或人为等因素的影响，故通常需对 DGA 数据进行归一化处理，如下所示：

$$x'_{ij} = \frac{x_{ij} - x_{imin}}{x_{imax} - x_{imin}} \quad (8)$$

式中： $x_{ij}$  ( $i = 1, 2, \dots, 276; j = 1, 2, \dots, 8$ ) 为原始的气体体积分数数据。

- 3) 确立极限学习机的网络结构及参数

确立极限学习机的网络结构是指根据样本的属性和故障类型等因素确定 ELM 的输入层、隐含层以及输出层的节点个数。极限学习机的参数设置包括输入层与隐含层连接权值矩阵  $w_i$ ，隐层神经元阈值矩阵  $b$ 。

- 4) 确定训练集和测试集期望输出矩阵

在表 2 中，样本的最后一列对应样本的故障类型，可构成训练集和测试集的输出矩阵  $T_{train}$  和  $T_{test}$ ；

5) 计算隐含层神经元的输出矩阵  $\mathbf{H}$ 。

选择一个激活函数,输入层到隐含层的激活函数  $g(\cdot)$  采用 sigmoid 函数,

$$g(\mathbf{w}_i \mathbf{x} + b_i) = \frac{1}{1 + e^{-(\mathbf{w}_i \mathbf{x} + b_i)}} \quad (9)$$

将归一化的训练集输入矩阵中每一行,分别代入 sigmoid 激活函数中,可获得隐含层神经元的输出矩阵  $\mathbf{H}_{N \times K}$ 。

6) 计算输出权值

将训练集期望输出矩阵和隐含层神经元的输出矩阵  $\mathbf{H}$  代入式(6)中,可获得输出权值矩阵估计值  $\hat{\boldsymbol{\beta}}$ 。

7) 用训练好的 ELM 模型对测试样本集进行分类,测试分类准确率

在故障诊断时,将待测样本代入 ELM 故障诊断模型,可根据待测样本输出矩阵中每列元素最大值的所在行,判断样本所属的故障类型。

### 3 电力变压器故障诊断仿真实验

#### 3.1 批量样本故障诊断仿真

从按行随机排序后的样本数据中选择前 140 个作为训练集输入构成矩阵,剩余的样本作为测试集输入构成  $\mathbf{X}_{\text{test}}$ 。即

$$\mathbf{X}_{\text{train}} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{18} \\ x_{21} & x_{22} & \cdots & x_{28} \\ \vdots & \vdots & & \vdots \\ x_{1401} & x_{1402} & \cdots & x_{1408} \end{bmatrix}, \mathbf{X}_{\text{test}} = \begin{bmatrix} x_{1411} & x_{1412} & \cdots & x_{1418} \\ x_{1421} & x_{1422} & \cdots & x_{1428} \\ \vdots & \vdots & & \vdots \\ x_{2761} & x_{2762} & \cdots & x_{2768} \end{bmatrix}, \quad (10)$$

根据式(8)对输入样本数据进行归一化处理,变换后数据取值在 0~1 之间,归一化的训练集和测试集输入矩阵分别为  $\mathbf{X}'_{\text{train}}$  和  $\mathbf{X}'_{\text{test}}$ 。

由表 2 的样本数据可以看出,每个样本均包含溶于变压器油中的 5 种特征气体组分含量和  $\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$ 、 $\text{CH}_4/\text{H}_2$ 、 $\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$  三组气体含量比值,即每个样本有 8 个属性;另外,表 2 中 276 个样本一共包含 7 种故障类型,与样本属性和故障类型相对应,ELM 输入层取 8 个神经元节点,输出层取节点数为 7,若设定隐含层神经元个数  $K$  为 100,则 ELM 网络结构为(8-100-7)。

设  $\mathbf{w}_i$  为  $(-1,1)$  间的随机数,其维数为  $100 \times 8$ ,  $b$  为  $(0,1)$  间随机数,其维数为  $100 \times 1$ 。在表 2 中,样本的最后一列对应样本的故障类型,分别构成训练集和测试集的输出矩阵  $\mathbf{T}_{\text{train}}$  和  $\mathbf{T}_{\text{test}}$ 。

为训练、测试和故障诊断方便,将变压器的故障类型以 0 和 1 代码表示,构成训练集和测试集的期望输出矩阵  $\mathbf{T}'_{\text{train}}$ 、 $\mathbf{T}'_{\text{test}}$ ,该矩阵的每一列与极限学习机输出层神经元节点相对应。若第  $j(j=1,2,\dots,276)$  个样本的故障类型为  $i(i=1,2,\dots,7)$ ,则在期望输出矩阵中第  $i$  行和第  $j$  列的元素为 1,第  $j$  列的其他元素均为 0,即在期望输出矩阵中元素 1 所在的行表示故障类型,所在的列表示样本序号,表 2 数据样本的故障类型 ELM 输出节点的对应关系如表 3 所示。从表 3 中选取与训练集输入矩阵相对应的 140 列数据,构成训练集期望输出矩阵,其维数  $\mathbf{T}'_{\text{train}}$ ,表 3 中剩余的 136 列则构成测试集期望输出矩阵,其维数  $7 \times 136$ 。

将归一化的训练集输入矩阵  $\mathbf{X}'_{\text{train}}$  中每一行代入式(9),可获得隐含层神经元的输出矩阵  $\mathbf{H}_{N \times K}$ 。将训练集期望输出矩阵  $\mathbf{T}'_{\text{train}}$  和隐含层神经元的输出矩阵  $\mathbf{H}$  代入式  $\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{Y}^T$  中,可获得输出权值矩阵估计值  $\hat{\boldsymbol{\beta}}$ ,则为  $\mathbf{Y}^T = \mathbf{H}\hat{\boldsymbol{\beta}}$  故障诊断的 ELM 分类器模型。在故障诊断时,将待测样本代入分类器模型,可根据待测样本所在行判断样本所属的故障类型,训练集和测试集的诊断结果如表 4 所示。

从表 4 可以看出,训练集有 1 个样本被错分,139 个样本被正确分类,整体分类准确率为 99.286% (139/140),错分样本如图 2 所示;测试集有 2 个样本被错分,错分样本如图 3 所示,134 个样本被正确分类,整体分类准确率为 98.529% (132/136)。

从训练集和测试集的分类结果看,极限学习机的故障诊断错分样本少,分类准确率高,具有一定的可行性和有效性。

### 3.2 单个待测样本的故障诊断仿真

例 1 对某台变压器用气相色谱分析油中的溶解气体,测得各种气体含量,单位  $10^{-6} \mu\text{L/L}$ :

$$V_{\text{H}_2} = 2.004, V_{\text{CH}_4} = 9.739, V_{\text{C}_2\text{H}_6} = 2.750, V_{\text{C}_2\text{H}_4} = 5.112, V_{\text{C}_2\text{H}_2} = 0. \quad (11)$$

表 3 故障类型与对应神经元节点输出

Tab. 3 Fault types and the corresponding output of neuron nodes

序号	故障类型	期望输出															
		1	2	3	4	5	6	7	8	9	10	11	12	13	...	276	
1	中低温过热	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	高温过热	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	1
3	低能放电	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0
4	高能放电	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0
5	放电兼过热	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0
6	局部放电	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0
7	正常	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0

表 4 训练集和测试集的分类结果

Tab. 4 The classification result of train and test set

序号	故障类型	训练集 样本数	训练集 分类结果	正分率/%	测试集 样本数	测试集 分类结果	正分率/%
1	中低温过热	12	12	100	14	14	100
2	高温过热	61	61	100	65	67	96.923
3	低能放电	29	28	96.552	30	29	96.667
4	高能放电	22	23	95.455	16	15	93.750
5	放电兼过热	9	9	100	7	7	100
6	局部放电	4	4	100	2	2	100
7	正常	3	3	100	2	2	100




图 2 训练集分类结果

Fig. 2 The classification result of train set




图 3 测试集分类结果

Fig. 3 The classification result of test set

采用以下两种方法进行故障诊断:

1) 利用三比值法诊断故障

首先,计算出三组气体比值:

$$V_{C_2H_2}/V_{C_2H_4} = 0, V_{CH_4}/V_{H_2} = 4.85978, V_{C_2H_4}/V_{C_2H_6} = 1.85927。 \quad (12)$$

其次,根据三比值法的编码规则得出比值编码为 021;最后查故障性质判断表<sup>[15]</sup>可知故障诊断结果为:300~700℃中等温度过热故障。

2) 利用极限学习机诊断故障

将变压器油中溶解气体的组分含量以及对应的三比值编码 021 代入极限学习机故障诊断模型,得到输出矩阵

$$Y = [4.0335 \quad -2.1466 \quad -2.4385 \quad 2.6022 \quad -1.0281 \quad -0.0273 \quad 0.0046]^T。 \quad (13)$$

根据输出矩阵中每一列元素最大值所在行确定该待测样本所属的故障类型,Y 最大值在第 1 行,故诊断为第 1 类故障,即中低温过热。实际检查结果,一次绕组引线与铁心螺栓相碰,相碰处熔化并有游离碳。

基于极限学习机故障诊断法的诊断结果,既与三比值法的诊断结果一致,又与实际检查结果相符,充分说明该方法的正确性。

**例 2** 在表 2 的最后两个样本中,5 种特征气体组分信息的三比值编码分别为 121 和 011,而在我国 DL/T722—2000《变压器油中溶解气体分析和判断导则》的故障类型判断方法表中不存在这两组编码对应的故障类型<sup>[16]</sup>,致使三比值法在故障诊断时失效,而利用极限学习机进行故障诊断则可弥补三比值法的不足。当样本 275 和 276 为待测样本时,则其对应的输出分别为:

$$Y_{275} = [-0.0002 \quad 0.0002 \quad 0.0007 \quad -0.0008 \quad 1.0001 \quad 0.0000 \quad 0.0000]^T,$$

$$Y_{276} = [0.0350 \quad 0.0214 \quad 0.0801 \quad 0.0179 \quad -0.0071 \quad 0.8527 \quad 0.0000]^T。 \quad (14)$$

根据输出矩阵中每一列元素的最大值所在行确定该待测样本所属的故障类型,Y<sub>275</sub> 最大值在第 5 行,故第 275 个样本被诊断为第 5 类故障,即放电兼过热;Y<sub>276</sub> 最大值在第 6 行,故第 276 样本被诊断为第 6 类故障,即局部放电。诊断结果均与实际故障相吻合,因此该方法在一定程度上弥补了比值编码缺失无法诊断故障的不足,较传统的三比值法更准确、更有效。

## 4 结论

将具有单隐层前馈神经网络结构的极限学习机与传统的三比值法相结合,对电力变压器进行故障诊断。由于训练样本中融入三比值数据信息,使得建立的 ELM 故障诊断模型既充分发挥了三比值法故障诊断正确率高的长处,又在一定程度上弥补了比值编码缺失无法诊断故障的不足。实例诊断结果表明,该方法较传统的三比值法更准确、更有效。

### 参考文献:

- [1] 宋斌,刘志雄,李恩文,等. DGA 中三比值缺码研究初探[J]. 电力自动化设备,2015,35(12):60-65.  
SONG Bin, LIU Zhixiong, LI Enwen, et al. Preliminary study of undefined three-ratio code in DGA[J]. Electric Power Automation Equipment, 2015, 35(12): 60-65.
- [2] 李思. 三比值法在变压器故障类型判断中的应用[J]. 中国高新技术企业, 2016(15): 40-41.  
LI Si. Application of three-ratio method in fault diagnosis of transformers[J]. China High-tech Enterprises, 2016(15): 40-41.
- [3] 李林发,文正其,邓世聪,等. 基于模糊三比值法和案例匹配的变压器故障诊断方法研究[J]. 变压器, 2015, 52(12): 61-66.  
LI Linfa, WEN Zhengqi, DENG Shicong, et al. Research on fault diagnosis for power transformer based on fuzzy three-ratio method and case-based reasoning[J]. Transformer, 2015, 52(12): 61-66.
- [4] 公茂法,张言攀,柳岩妮,等. 基于 BP 网络算法优化模糊 Petri 网的电力变压器故障诊断[J]. 电力系统保护与控制, 2015(3): 113-117.  
GONG Maofang, ZHANG Yanpan, LIU Yanning, et al. Fault diagnosis of power transformer based on back propagation algorithm evolving fuzzy Petri nets[J]. Power System Protection and Control, 2015(3): 113-117.

- [5] XU B, PAN Y P, WANG D W, et al. Discrete-time hypersonic flight control based on extreme learning machine[J]. *Neurocomputing*, 2014(128): 232-241.
- [6] 石鑫, 朱永利, 宁晓光, 等. 基于深度自编码网络的电力变压器故障诊断[J]. *电力自动化设备*, 2016, 36(5): 122-126.  
SHI Xin, ZHU Yongli, NING Xiaoguang, et al. Transformer fault diagnosis based on auto-encoder network[J]. *Electric Power Automation Equipment*, 2016, 36(5): 122-126.
- [7] 吴坤, 康建设, 池阔. 基于改进多分类算法和相关向量机的电力变压器故障诊断方法[J]. *高电压技术*, 2016, 42(9): 3011-3017.  
WU Kun, KANG Jianshe, CHI Kuo. Fault diagnosis of power transformer based on the improved multiclass algorithm and vector machine[J]. *High Voltage Engineering*, 2016, 42(9): 3011-3017.
- [8] MATIAS T, SOUZA F, JO R, et al. Learning of a single-hidden layer feedforward neural network using an optimized extreme learning machine[J]. *Neurocomputing*, 2014, 129: 428-436.
- [9] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications [J]. *Neurocomputing*, 2006, 70(1/2/3): 489-501.
- [10] 苑津莎, 张利伟, 王瑜, 等. 基于极限学习机的变压器故障诊断方法研究[J]. *电测与仪表*, 2013(12): 21-26.  
YUAN Jinsha, ZHANG Liwei, WANG Yu, et al. Study of transformers fault diagnosis based on extreme learning machine [J]. *Electrical Measurement & Instrumentation*, 2013 (12): 21-26.
- [11] 秦波, 刘永亮, 王建国, 等. 基于极限学习机的滚动轴承故障诊断方法[J]. *组合机床与自动化加工技术*, 2016(5): 103-106.  
QIN Bo, LIU Yongliang, WANG Jianguo, et al. Fault diagnosis of rolling bearings based on extreme learning machine[J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2016(5): 103-106.
- [12] MENG L, LI C, ZHANG X, et al. Compound feature selection and parameter optimization of ELM for fault diagnosis of rolling element bearings[J]. *ISA Transactions*, 2016(65): 556-566.
- [13] 邓勇, 于晨松. 因子分析和 ELM 在模拟电路故障诊断的应用[J]. *电子测量与仪器学报*, 2016, 30(10): 1512-1519.  
DENG Y, YU C. Application of factor analysis and ELM in analog circuit fault diagnosis[J]. *Journal of Electronic Measurement & Instrumentation*, 2016, 30(10): 1512-1519.
- [14] ZHAO Z, ZHANG J, SUN Y, et al. Fault detection and diagnosis method for batch process based on ELM-based fault feature phase identification[J]. *Neural Computing and Applications*, 2016, 27(1): 167-173.
- [15] 李本铎. 智能算法在油浸式变压器故障诊断中的应用研究[D]. 南昌: 华东交通大学, 2015.
- [16] 张明慧. 基于 DGA 的变压器故障诊断算法研究[D]. 淮南: 安徽理工大学, 2013.
- [17] 中国电力科学研究院. DL/T722-2000, 变压器中溶解气体分析和判断导则[S].

(责任编辑: 高丽华)