

DOI:10.13296/j.1001-1609.hva.2016.01.027

基于非负矩阵分解与改进极端学习机的 变压器油中溶解气体浓度预测模型

刘亚南, 范立新, 徐 钢, 唐一铭, 刘 全, 都 晨

(江苏方天电力技术有限公司, 南京 211102)

摘要: 变压器油中溶解气体浓度是评估变压器绝缘状态的重要依据,对气体浓度进行有效预测,可以及时识别变压器潜伏性故障。文中提出一种基于非负矩阵分解(nonnegative matrix factorization, NMF)与改进极端学习机(extreme learning machine, ELM)组合的变压器中溶解气体浓度预测模型。该方法通过NMF算法对输入样本进行分解,同时引入Adaboost算法对极端学习机进行改进;将低维矩阵作为模型的训练样本输入,剔除冗余数据,提高预测精度。实例分析结果表明,文中提出的方法能有效地降低输入样本维数,提高预测精度,能较好地解决变压器油中溶解气体浓度预测问题。

关键词: 变压器; 溶解气体; 非负矩阵分解; 极端学习机; Adaboost算法

Concentration Prediction Model of Dissolved Gases in Transformer Oil Based on NMF and Improved ELM

LIU Yanan, FAN Lixin, XU Gang, TANG Yiming, LIU Quan, DU Chen

(Frontier Electric Technology Co., Ltd., Nanjing 211102, China)

Abstract: The concentration of dissolved gases in transformer oil is an important parameter to evaluate insulation state of oil-immersed transformer. Effective concentration prediction of the dissolved gases can help to identify latent faults of transformer in time. In this paper, a concentration prediction model of dissolved gases in transformer oil is proposed based on the nonnegative matrix factorization (NMF) and the improved extreme learning machine (ELM). The input data is decomposed by using the NMF algorithm to reduce the dimension of input variables. Then Adaboost algorithm is introduced to improve the extreme learning machine, and the derived nonnegative lower-dimension mapping matrix is taken as the inputs of the model for training. Simulation illustrates the effectiveness and availability of the proposed method in reducing the dimension of the input variables, performing the concentration prediction of dissolved gases in transformer oil, and improving the prediction accuracy.

Key words: transformer; dissolved gas; nonnegative matrix factorization(NMF); extreme learning machine(ELM); Adaboost algorithm

0 引言

电力变压器是电力系统的重要设备之一,其安全稳定运行对电网起着非常重要的作用。变压器油中溶解气体的含量和故障类型有密切的联系,因此,建立科学、准确度高和可操作性强的预测模型是变压器在线监测和故障诊断的重要手段,根据已有的变压器油气体浓度对未来气体浓度进行准确

预测,能够全面评估变压器的绝缘情况,进而及时发现变压器的缺陷和潜伏性故障,从而合理安排检修工作^[1-2]。

目前常用的变压器油气体预测方法主要有灰色理论^[3-6]、人工神经网络方法^[7]、支持向量机方法^[8]等。文[9]中首先通过缓冲算子对原始数据进行弱化处理,然后采用最小二乘支持向量机与区间参数估计理论建立变压器油气体浓度的区间预测模型;文[10]中将灰色理论、遗传算法、BP神经网络和卡尔曼预测方法通过最优加权法组合进行预测,根据误差

平方和最小原则计算权值,从而求解最优加权系数,建立最优加权组合的变压器油气体浓度预测模型。但是这些方法中,BP神经网络存在容易陷入极小值,网络隐含层节点难确定的缺点,支持向量机参数难确定、训练时间长,同时对模型的输入变量没有进行优化处理,因此在一定程度上降低了预测精度。

极端学习机是 Huang 等人提出的一种新型的单隐含层前馈神经网络学习方法,它对于大量非结构性、非精确性规律具有自适应能力和自主学习能力,有很强的计算能力。文[11]中首次在短期负荷预测领域使用极端学习机,预测效果良好,但其容易产生过拟合现象;文[12]中提出了在线序贯学习的极端学习机思想,通过采用逐段学习数据,从而提高了算法的预测精度。但是,由于极端学习的权值是随机给定的,使得该算法的稳定性不能得到保证。同时考虑到变压器油中的气体是从同一时间的油样中分析得到的,它们在一定条件下能够相互转化,因此需要对气体数据进行分析,消除之间的冗余信息,从而选择更优的输入因素,提高模型的预测精度。

基于以上分析,文中采用 Adaboost 算法来改进 ELM 算法,提出一种基于非负矩阵分解和改进 ELM 的变压器油中溶解气体浓度预测模型,这样既能够结合 NMF 的提取能力,又能利用改进的 ELM 算法的非线性逼近能力,从而使模型的预测精度和泛化能力得到提高,为变压器油中溶解气体浓度预测提供新的方法。

1 非负矩阵分解算法原理

非负矩阵分解是 1999 年 Lee 等人提出的一种新的矩阵分解算法,其分解后的矩阵元素具有非负性^[13],该算法的优点就是实现简便、分解的结果能够被解释等。非负矩阵分解问题可以描述为^[14-15]:任意 $n \times m$ 的非负矩阵 V ,可以把它分解成一个 $n \times r$ 的非负矩阵 W 和一个 $r \times m$ 的非负矩阵 P 的乘积

$$V=WP。 \quad (1)$$

式(1)中,左矩阵 W 中所有列向量的加权和是原矩阵 V 中的列向量,右矩阵 P 中列向量中的元素为权重系数,分解后数据的存储空间大小为 $r \times (m+n)$ 。

NMF 的实现可转化为最优化问题处理,文中选择欧式距离平方作为 NMF 目标函数,其中, i 和 j 分别表示矩阵的行和列。

矩阵 V 与矩阵 WP 的欧式距离的平方

$$\|V-WP\|^2 = \sum_{ij} [V_{ij}-(WP)_{ij}]^2。 \quad (2)$$

式(2)当且仅当在 $V=WP$ 时达到最小值 0。

因此,优化问题就转变为求取矩阵 W 和 P 使得目标函数最小。Lee 等人提出了一种乘法迭代算法,具体步骤如下,其中 k 表示矩阵降维后的维数:

1)对于非负矩阵 W 和 P 随机赋初值;

2)更新 W 和 P ;

$$W_{ik} \leftarrow W_{ik} \frac{(VP^T)_{ik}}{(WPP^T)_{ik}}; \quad (3)$$

$$P_{kj} \leftarrow P_{kj} \frac{(W^TV)_{kj}}{(W^TW P)_{kj}}。 \quad (4)$$

3)重复步骤 2)直至收敛。

2 极端学习机

极端学习机的优点就是随机产生隐含层与输入层的连接权值及隐含层神经元的阈值,而且在训练过程中不需要调整,只需要对隐含层的个数进行设置,就能够获得唯一的全局最优解,因此极端学习机的收敛速度远快于其他神经网络模型。

给定样本集合 $\Theta=\{(x_1, y_1), \dots, (x_i, y_i)\}$, 其中 $i=1, 2, \dots, Q, x_i \in R^n, y_i \in R^m$, 则具有 L 个隐含层神经元的 ELM 回归模型^[16-19]表示为

$$f(x_i) = \sum_{ij}^L \beta_j g(w_j \cdot x_i + b_j) \quad i=1, 2, \dots, Q。 \quad (5)$$

式(5)中: w_j 为输入节点与第 j 个隐含层神经元之间的连接权值; β_j 为第 j 个隐含层神经元与输出节点之间的连接权值; b_j 为第 j 个隐含层神经元的阈值; $g(x)$ 为隐含层神经元激励函数。

式(5)可以采用式(6)表示

$$H\beta=Y'。 \quad (6)$$

式(6)中, H 为隐含层输出矩阵,其形式为

$$H = \begin{bmatrix} g(w_1 x_1 + b_1) & g(w_2 x_1 + b_2) & \dots & g(w_l x_1 + b_l) \\ g(w_1 x_2 + b_1) & g(w_2 x_2 + b_2) & \dots & g(w_l x_2 + b_l) \\ \vdots & \vdots & \ddots & \vdots \\ g(w_1 x_Q + b_1) & g(w_2 x_Q + b_2) & \dots & g(w_l x_Q + b_l) \end{bmatrix};$$

$$Y=[y_1, y_2, \dots, y_Q]_{m \times Q}。$$

极端学习机中 w 和 b 在训练之前是随机选择的,而且在训练过程中保持不变。隐含层与输出层的连接权值 β 可以通过求解方程组的最小二乘解获得:

$$\min_{\beta} \|H\beta - Y'\|。 \quad (7)$$

解为

$$\hat{\beta} = H^+ Y'。 \quad (8)$$

式(7)、(8)中, H^+ 为隐含层输出矩阵 H 的 Moore-Penrose 广义逆。

3 Adaboost 算法简介

Adaboost 算法^[20]是一种重要的特征分类算法,

现在主要在分类问题和回归问题中使用。Adaboost算法是对同一个样本进行训练得到不同的弱学习器,然后再把这些弱学习器组合构成一个强学习器,从而使组合得到的强学习器有更强的泛化能力。核心思想是提高学习能力强的弱学习器权值,降低学习能力弱的弱学习器权值。

Adaboost算法的步骤如下:

1)给定训练样本:\$(x_i, y_i), x_i \in X, y_i \in Y, X\$ 和 \$Y\$ 表示某个实例空间。

2)初始化样本权值,样本分布 \$D_t(i)\$ 表示第 \$t\$ 次迭代中样本权值, \$D_t(i)=1/N, N\$ 为训练样本的个数。

3)在训练样本的概率分布下,训练弱学习器 \$h_t(x)\$。

4)计算每个弱学习器得到的误差 \$\varepsilon_i\$ 以及平均误差 \$\varepsilon_t, \varepsilon_t = \frac{1}{N} \sum_{i=1}^N \varepsilon_i\$。

5)计算预测序列权重。根据预测误差计算权重 \$a_t, a_t = \frac{1}{2} \ln(\frac{1-\varepsilon_t}{\varepsilon_t})\$。

6)更新样本权重 \$D_t(i) = \frac{D_{t-1}(i)\beta^{-\varepsilon_i}}{Z_t}\$, 其中 \$\beta_t = \frac{\varepsilon_t}{1-\varepsilon_t}\$, \$Z_t\$ 是归一化因子。

7)回到步骤 3),继续迭代,直到迭代 \$T\$ 次。

8)根据训练得到的弱学习器组合得到最后的强学习器 \$H(x) = \sum_{t=1}^T W_t h_t(x)\$。

4 基于 NMF 与改进 ELM 神经网络的变压器油中溶解气体浓度预测模型

4.1 数据预处理

由于传输通道等原因,气体浓度数据通常有异常数据存在,这些数据会影响到预测精度。因此,有必要对量测数据进行预处理。文中主要采用横向数据对比法进行预处理。

4.2 模型输入输出数据的选择

变压器在运行过程中,绝缘油和绝缘材料会逐渐老化分解,产生少量低分子烃类和氢气等微量气体并溶解在油中,这些溶解气体具有一定的内在关系,可以相关转化。文中选取变压器 7 种特征气体数据进行分析建模,7 中气体分别为 \$H_2\$、\$CO\$、\$CO_2\$、\$CH_4\$、\$C_2H_6\$、\$C_2H_4\$、\$C_2H_2\$。文中在建立模型时,将待测气体浓度作为输出,其余气体作为输入。例如,在对 \$H_2\$ 进行预测时,输入变量为 \$CO\$、\$CO_2\$、\$CH_4\$、\$C_2H_6\$、\$C_2H_4\$、\$C_2H_2\$ 气体时刻的浓度和 \$H_2\$ 气体 \$t\$ 时刻的浓度,输出为 \$H_2\$ 气体 \$t+1\$ 时刻浓度,其余气体建模方式类似^[21-23]。

4.3 基于 Adaboost 的 ELM 建模与预测

ELM 预测模型的主要参数是隐含层节点数, Huang 等人提出:若隐含层节点个数与训练集样本个数相等,预测效果最好。然而,当训练样本个数较大时,计算量会很大,通常隐含层节点个数要小于训练样本数,文中通过大量实验隐含层节点数目定为 15。激励函数选择 Sigmoid 函数

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

ELM 网络训练结束以后,计算出各个样本的预测误差,根据预测的误差更新每个样本的权重和网络的权重。重复上述操作,直至 \$T\$ 个网络训练结束,文中 \$T=15\$。基于 Adaboost 的 ELM 神经网络算法流程图见图 1。




图1 基于 Adaboost 的 ELM 神经网络流程图

Fig. 1 The flow chart of ELM neural network based on Adaboost

4.4 NMF 与改进 ELM 相结合的变压器油中溶解气体浓度预测算法

由于输入变量有不同的单位和取值范围,为了便于计算,采用归一化方法对气体浓度数据进行规范化,使其取值范围在 \$[0, 1]\$。

$$\hat{x}(i) = \frac{x(i) - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式(10)中: \$\hat{x}(i)\$ 为归一化后的数据值; \$x_{\max}\$、\$x_{\min}\$ 分别为样本的最大值和最小值。

非负矩阵分解在实际应用过程中存在一个问题,就是原矩阵降维后的维数,目前还没有有效的方法进行选择。通常情况下,只要矩阵 \$\mathbf{P}_{r \times m}\$ 行数 \$r\$ 满足 \$(m+n)r \leq mn\$ 即可。文中根据文[13]采用 \$k\$ 折交叉训

练方法,得到维数的最优取值,通常的取值为10。文中提出的 NMF 和改进 ELM 神经网络相结合的变压器油中溶解气体浓度预测算法首先利用 NMF 对输入样本进行分解,然后分别建立各个气体的预测模型,具体流程图见图 2。




图 2 NMF 与改进 ELM 组合预测算法流程图

Fig. 2 The flow chart of prediction algorithm based on NMF and improved ELM

4.5 误差分析

文中主要采用平均绝对值百分误差(mean absolute percent error, MAPE)指标来检验预测结果。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|X_f - X_r|}{X_f} \times 100\% \quad (11)$$

表 2 两种改进 ELM 模型的预测结果

Table 2 The prediction results of two improved ELM models

气体		2013-04-26 数	2013-04-27 数	2013-04-28 数	2013-04-29 数	2013-04-30 数	MAPE/%
		值/($\mu\text{L} \cdot \text{L}^{-1}$)	值/($\mu\text{L} \cdot \text{L}^{-1}$)	值/($\mu\text{L} \cdot \text{L}^{-1}$)	值/($\mu\text{L} \cdot \text{L}^{-1}$)	值/($\mu\text{L} \cdot \text{L}^{-1}$)	
H_2	1	95.463	103.270	102.020	98.015	99.729	1.31
	2	104.297	103.497	108.672	87.708	98.512	2.82
CO	1	220.092	332.207	379.746	322.484	346.198	2.44
	2	231.312	328.337	340.627	335.406	315.183	3.89
CO_2	1	784.700	847.760	814.244	785.343	803.996	1.21
	2	731.697	829.094	830.695	754.912	841.802	3.89
CH_4	1	4.843	5.216	6.666	5.845	5.763	3.07
	2	5.094	5.874	5.698	5.775	5.946	4.73
C_2H_6	1	1.568	1.527	1.795	1.646	1.602	3.02
	2	1.381	1.615	2.034	1.642	1.532	6.07
C_2H_4	1	2.692	2.770	3.288	2.925	2.914	3.15
	2	2.631	3.069	3.045	3.378	3.281	6.37
C_2H_2	1	6.808	7.195	7.661	7.943	8.321	1.30
	2	6.614	7.264	7.888	8.458	8.602	3.06

注:1—NMF-改进 ELM 模型预测得到的结果;2—改进 ELM 模型得到的预测结果。

式(11)中: X_r 表示实际气体浓度值; X_f 表示预测气体浓度值; N 为预测个数。

5 算例分析

文中选择某变压器 2013 年 4 月 1 日至 4 月 25 日的变压器油中溶解气体浓度数据作为训练集,用来建立预测模型,4 月 26 日至 4 月 30 日的变压器油中溶解气体浓度数据作为测试集,用来检验预测效果。各种气体的真实值见表 1。

表 1 各种气体的真实值

Table 1 True value of gas $\mu\text{L/L}$					
气体	2013-04-26	2013-04-27	2013-04-28	2013-04-29	2013-04-30
H_2	97.4	101.0	101.0	97.0	100.0
CO	226.0	335.0	365.0	329.0	337.0
CO_2	781.0	851.0	799.0	701.0	825.0
CH_4	4.9	5.6	6.4	5.7	5.8
C_2H_6	1.5	1.5	1.9	1.7	1.6
C_2H_4	2.7	2.8	3.2	3.1	3.1
C_2H_2	6.6	7.4	7.6	8.0	8.5

首先对输入样本通过 NMF 进行分解,使用文中引入的 k 折交叉验证方法,分解得到最优维数为 3 维。然后将分解后的 3 维数据作为改进 ELM 网络的输入进行训练,得到预测模型,使用测试样本进行预测。采用文中模型与不经过非负矩阵分解筛选变量的改进 ELM 方法进行比较,预测结果见表 2。不同筛选方法得到的预测结果见表 3。

表3 不同筛选方法得到的预测结果

Table 3 The prediction results of different screening methods

气体		2013-04-26 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	2013-04-27 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	2013-04-28 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	2013-04-29 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	2013-04-30 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	MAPE/%
H_2	1	97.198	93.747	108.019	100.441	95.935	4.39
	2	93.711	98.313	103.452	93.359	98.910	2.74
CO	1	238.026	332.337	332.296	336.139	317.927	4.58
	2	205.013	366.622	351.093	323.237	348.249	5.52
CO_2	1	710.388	850.456	787.989	810.219	811.033	2.92
	2	778.266	889.179	834.128	751.399	836.774	3.13
CH_4	1	4.642	5.824	5.859	5.838	6.086	5.02
	2	5.113	5.770	5.893	5.635	5.723	3.55
C_2H_6	1	1.425	1.669	1.904	1.706	1.701	4.63
	2	1.435	1.514	1.910	1.823	1.565	3.05
C_2H_4	1	2.612	2.979	2.906	2.994	3.175	4.94
	2	2.690	3.040	3.038	2.987	3.155	3.88
C_2H_2	1	6.285	6.984	7.083	7.560	7.928	6.44
	2	6.458	7.262	7.811	8.038	8.329	2.43

注:1—主成分分析(PCA)-改进 ELM 模型预测得到的结果;2—灰色关联度-改进 ELM 模型得到的预测结果。

使用 BP 算法、SVM 算法分别建立各气体预测模型并与改进 ELM 模型进行比较,不同模型预测结果见图 3-9。

表4 不同模型的预测结果

Table 4 The prediction results of the different models

气体		2013-04-26 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	2013-04-27 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	2013-04-28 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	2013-04-29 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	2013-04-30 数 值/($\mu\text{L}\cdot\text{L}^{-1}$)	MAPE/%
H_2	1	99.623	99.552	99.618	101.550	97.559	2.44
	2	93.038	99.432	102.776	97.617	96.488	2.39
CO	1	208.574	353.980	355.809	350.770	341.627	4.78
	2	205.047	345.873	390.372	332.388	334.658	4.24
CO_2	1	889.169	874.499	797.927	813.315	819.103	4.06
	2	714.471	865.610	862.792	807.543	826.791	4.11
CH_4	1	4.796	5.255	5.879	5.199	5.565	5.86
	2	4.570	5.214	6.089	5.855	5.570	5.04
C_2H_6	1	1.466	1.468	1.753	1.707	1.732	4.16
	2	1.344	1.529	1.888	1.668	1.726	4.55
C_2H_4	1	2.480	2.599	3.574	3.287	3.170	7.06
	2	2.562	2.737	3.370	2.967	2.811	5.26
C_2H_2	1	5.883	6.879	6.868	7.419	7.853	9.01
	2	6.390	7.512	7.357	7.741	7.668	4.75

注:1—NMF-BP 模型预测得到的结果;2—NMF-SVM 模型得到的预测结果。

表5 不同模型的收敛时间

Table 5 The convergence time of the different models

模型	改进 ELM 模型	BP模型	SVM模型
收敛时间/s	1.38	1.62	3.46

从表 2 可以得知,NMF 在不改变样本数据结构的基础上,消除了冗余信息,减少了输入变量的维数,简化了网络结构,提高了网络的学习速率及工

作性能, H_2 、CO、 CO_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 预测结果的 MAPE 值分别降低了 53.55%、37.28%、68.89%、54.07%、50.25%、25.53%、57.52%。表 3 是分别采用 PCA 和灰色关联度对输入样本进行优化得到的预测结果,与文中方法相比,这两种方法的预测精度比较低,PCA 在抽取过程中会产生负值,而负值没有意义,使得信息部分丢失,灰色关联度分析方法








图 3 H₂ 预测结果Fig. 3 The prediction results of H₂

图 4 CO 预测结果

Fig. 4 The prediction results of CO

图 5 CO₂ 预测结果Fig. 5 The prediction results of CO₂图 6 CH₄ 预测结果Fig. 6 The prediction results of CH₄

受到分辨系数的影响,客观性不足。通过与其他预测模型比较,改进 ELM 模型的预测精度比较高,而且收敛时间比较短,从而验证了改进 ELM 理论在变

图 7 C₂H₆ 预测结果Fig. 7 The prediction results of C₂H₆图 8 C₂H₄ 预测结果Fig. 8 The prediction results of C₂H₄图 9 C₂H₂ 预测结果Fig. 9 The prediction results of C₂H₂

压器油中溶解气体浓度建模的可行性。

选择另一台变压器的气体数据建立模型,测试集样本数据见表 6,仿真结果见表 7。

表 6 各种气体的真实值

气体	Table 6 True value of gas				μL/L
	2013-04-26	2013-04-27	2013-04-28	2013-04-29	2013-04-30
H ₂	97.0	92.0	90.0	97.0	104.0
CO	363.0	326.0	314.0	342.0	355.0
CO ₂	957.0	877.0	849.0	911.0	846.0
CH ₄	5.7	5.1	5.0	5.6	5.5
C ₂ H ₆	1.9	1.7	2.2	1.9	1.7
C ₂ H ₄	2.7	2.6	2.7	2.9	2.8
C ₂ H ₂	5.9	6.1	6.0	6.3	6.6

表7 不同模型的预测结果

Table 7 The prediction results of the different models

气体		2013-04-26 数	2013-04-27 数	2013-04-28 数	2013-04-29 数	2013-04-30 数	MAPE/%
		值/($\mu\text{L}\cdot\text{L}^{-1}$)	值/($\mu\text{L}\cdot\text{L}^{-1}$)	值/($\mu\text{L}\cdot\text{L}^{-1}$)	值/($\mu\text{L}\cdot\text{L}^{-1}$)	值/($\mu\text{L}\cdot\text{L}^{-1}$)	
H_2	1	87.083	86.526	87.257	89.791	91.651	7.71
	2	85.132	97.171	91.533	92.966	93.762	6.71
	3	94.931	91.792	91.014	99.838	107.966	2.05
CO	1	343.820	302.041	306.340	310.098	312.021	7.30
	2	320.846	309.050	339.448	361.890	341.739	6.89
	3	339.689	331.456	317.468	344.250	343.453	2.62
CO_2	1	887.865	904.897	897.370	890.573	894.548	4.82
	2	907.827	917.750	847.477	905.605	914.125	3.72
	3	949.409	870.178	839.259	926.109	847.594	0.91
CH_4	1	4.911	4.815	4.648	5.196	5.203	7.82
	2	5.016	4.954	4.773	5.316	5.008	6.69
	3	5.596	4.956	4.804	5.464	5.218	3.22
C_2H_6	1	1.816	1.712	2.048	1.956	1.812	4.30
	2	1.794	1.806	2.120	1.813	1.739	4.47
	3	2.054	1.685	2.083	1.977	1.746	4.22
C_2H_4	1	2.504	2.355	2.547	2.690	2.624	7.17
	2	2.532	2.481	2.492	2.618	2.637	6.81
	3	2.723	2.579	2.523	2.756	2.701	3.35
C_2H_2	1	5.635	5.505	6.599	6.658	6.510	6.26
	2	5.213	6.396	6.144	6.909	6.436	6.21
	3	5.528	5.795	6.308	6.199	6.767	4.12

注:1—NMF-BP 模型预测值;2—NMF-SVM 模型预测值;3—NMF-改进 ELM 模型预测值。

根据仿真结果可以得出,改进 ELM 模型适应性比较强,能够满足变压器油中溶解气体浓度建模的要求,具有一定的使用价值。

6 结论

文中利用 Adaboost 算法改进 ELM 神经网络建立变压器油中溶解气体浓度预测模型,并引入非负矩阵分解方法对影响因素进行分析,得到了具有非负性质的低维映射矩阵,以此作为改进 ELM 的输入样本进行训练和预测。此低维矩阵消除了冗余信息,减少了输入变量的维数,提高了模型的预测精度。实例分析结果验证了文中所提方法的合理性和有效性。

参考文献:

- [1] 孙才新,陈伟根,李 俭,等. 电器设备油中气体在线监测与故障诊断技术[M]. 北京:科学出版社,2003.
- [2] 马叶芝,焦彦军,王东升,等. 变压器故障诊断中溶解气体的 PSO-WFCM 算法研究[J]. 高压电器,2014,50(1):72-76.
MA Yezhi, JIAO Yanjun, WANG Dongsheng, et al. Detection of dissolved gas with PSO-WFCM algorithm for fault diagnosis of power transformer[J]. High Voltage Apparatus, 2014, 50(1): 72-76.
- [3] 罗运柏,于 萍,宋 斌,等. 用灰色模型预测变压器油中溶解气体的含量[J]. 中国电机工程学报,2001,21(3): 66-70.
- [4] LUO Yunbai, YU Ping, SONG Bin, et al. Prediction of the gas dissolves in power transformer oil by the grey model[J]. Proceedings of the CSEE, 2001, 21(3): 66-70.
- [5] 毛自娟. 基于灰色马尔可夫模型的变压器油中溶解气体体积分数预测[J]. 高压电器, 2012, 48(10): 47-51.
MAO Zijuan. Concentration prediction of gases dissolved in transformer oil via grey markov chain model[J]. High Voltage Apparatus, 2012, 48(10): 47-51.
- [6] 肖燕彩,朱衡君,陈秀海. 用灰色多变量模型预测变压器油中溶解的气体浓度[J]. 电力系统自动化, 2006, 30(13): 64-67.
XIAO Yancai, ZHU Hengjun, CHEN Xiuhai. Concentration prediction of dissolved gas-in-oil of a power transformer with the multivariable grey model[J]. Automation of Electric Power Systems, 2006, 30(13): 64-67.
- [7] 肖燕彩,陈秀海. 用灰色多变量模型预测变压器油中气体的方法[J]. 高电压技术, 2007, 33(8): 98-101.
XIAO Yancai, CHEN Xiuhai. Method for predicting dissolved gases in transformer oil by multivariable grey model[J]. High Voltage Engineering, 2007, 33(8): 98-101.
- [8] 张彼德,裴子春,袁宇春. 基于遗传算法优化的 BP 神经网络的变压器油中气体预测[J]. 西华大学学报(自然科学版), 2010, 29(2): 145-147.
ZHANG Bide, PEI Zichun, YUAN Yuchun. The prediction of gas-in-oil in a transformer based on BP neural network optimized by genetic algorithm[J]. Journal of Xihua Uni-

- versity(Natural Science Edition),2010,29(2):145-147.
- [8] 肖燕彩,陈秀海,朱衡君. 以最小二乘支持向量机作组合器的变压器油中溶解气体体积分数预测[J]. 电力自动化设备,2008,28(7):33-36.
- XIAO Yancai, CHEN Xiuhai, ZHU Hengjun. Proportion forecast of dissolved gases in transformer oil by combined model of LS-SVM[J]. Electric Power Automation Equipment,2008,28(7):33-36.
- [9] 卞建鹏,廖瑞金,杨丽君. 应用弱化缓冲算子与最小二乘支持向量机的变压器油中溶解气体浓度预测[J]. 电网技术,2012,36(2):195-199.
- BIAN Jianpeng, LIAO Ruijin, YANG Lijun. Concentration prediction of gases dissolved in transformer oil based on weakening buffer operator and least square support vector machine[J]. Power System Technology,2012,36(2):195-199.
- [10] 杨廷方,刘 沛,李 浙,等. 应用新型多方法组合预测模型估计变压器油中溶解气体浓度[J]. 中国电机工程学报,2008,28(31):108-113.
- YANG Tingfang, LIU Pei, LI Zhe, et al. A new combination forecasting model for concentration prediction of dissolved gases in transformer oil[J]. Proceedings of the CSEE,2008,28(31):108-113.
- [11] 程 松,闫建伟,赵登福,等. 短期负荷预测的集成改进极端学习机方法[J]. 西安交通大学学报,2009,43(2):106-110.
- CHENG Song, YAN Jianwei, ZHAO Dengfu, et al. Short-term load forecasting method based on ensemble improved extreme learning machine[J]. Journal of Xi'an Jiaotong University,2009,43(2):106-110.
- [12] LIANG Nanying, HUANG Guangbin, SARATCHANDRAN P, et al. A fast and accurate online sequential learning algorithm for feedforward networks[J]. IEEE Transactions on Neural Networks/a Publication of the IEEE Neural Networks Council,2006,17(6):1411-1423.
- [13] LEE D D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization[J]. Nature,1999,401(6755):788-791.
- [14] 王文俊,张军英. 一种非负矩阵分解的快速方法[J]. 计算机工程与应用,2009,45(25):1-2.
- WANG Wenjun, ZHANG Junying. Fast algorithm for non-negative matrix factorization[J]. Computer Engineering and Applications,2009,45(25):1-2.
- [15] 黄帅栋,卫志农,高宗和,等. 基于非负矩阵分解的相关向量机短期负荷预测模型[J]. 电力系统自动化,2012,36(11):62-66.
- HUANG Shuaidong, WEI Zhinong, GAO Zonghe, et al. A short-term load forecasting model based on relevance vector machine with nonnegative matrix factorization[J]. Automation of Electric Power Systems,2012,36(11):62-66.
- [16] FENG Guorui, HUANG Guangbin, LIN Qingping, et al. Error minimized extreme learning machine with growth of hidden nodes and incremental learning[J]. IEEE Transactions on Neural Networks/a Publication of the IEEE Neural Networks Council,2009,20(8):1352-1357.
- [17] ZHANG Rui, DONG Zhaoyang, XU Yan, et al. Short-term load forecasting of australian national electricity market by an ensemble model of extreme learning machine[J]. IET Generation Transmission & Distribution,2013,7(4):391-397.
- [18] WAN Can, ZHAO Xu, PINSON P, et al. Probabilistic forecasting of wind power generation using extreme learning machine[J]. IEEE Transaction on Power Systems,2013,29(3):1033-1044.
- [19] 王守相,王亚旻,刘 岩,等. 基于经验模态分解和 ELM 神经网络的逐时太阳能辐照量预测[J]. 电力自动化设备,2014,34(8):7-12.
- WANG Shouxiang, WANG Yamin, LIU Yan, et al. Hourly solar radiation forecasting based on EMD and ELM neural network[J]. Electric Power Automation Equipment,2014,34(8):7-12.
- [20] 吴俊利,张步涵,王 魁. 基于 Adaboost 的 BP 神经网络改进算法在短期风速预测中的应用[J]. 电网技术,2012,36(9):221-225.
- WU Junli, ZHANG Buhan, WANG Kui. Application of Adaboost-based BP neural network for short-term wind speed forecast[J]. Power System Technology,2012,36(9):221-225.
- [21] 刘 云,李 响,官 澜,等. 特高压直流直接接入特高压 1 000 kV 交流系统单器身换流变压器设计方案研究[J]. 变压器,2014,51(5):20-22.
- LIU Yun, LI Xiang, GUAN Lan, et al. Research on design scheme of single active part converter transformer used to DC system from the UHVDC project to 1 000 kV UHVAC power grid[J]. Transformer,2014,51(5):20-22.
- [22] 陈模生,张良县,于 健,等. 特高压换流变压器涡流损耗及电磁屏蔽结构优化分析[J]. 变压器,2014,51(4):20-22.
- CHEN Mosheng, ZHANG Liangxian, YU Jian, et al. Analysis of eddy current loss and electromagnetic shielding structure optimization of UHV converter transformer[J]. Transformer,2014,51(4):20-22.
- [23] 刘 翮,刘小丹,王一军. 特大型组装变压器现场组装与干燥工艺研究[J]. 变压器,2014,51(4):46-47.
- LIU He, LIU Xiaodan, WANG Yijun. On-site assembly and drying process research of large assembly transformer[J]. Transformer,2014,51(4):46-47.
- 刘亚南(1988—),男,硕士研究生,主要从事电力系统负荷预测、故障诊断等研究工作。