

DOI: 10.19783/j.cnki.pspc.201268

基于极限区间与改进 PCA-SOM 的电气运行参数对 专变健康影响的量化评价方法

邬程欢¹, 贺民¹, 龚明波¹, 林英鹤², 潘国兵³, 欧阳静³

(1. 国网浙江省电力有限公司宁波供电公司, 浙江 宁波 315000; 2. 浙江华云信息科技有限公司, 浙江 杭州 310012;
3. 浙江工业大学特种装备制造与先进加工技术教育部/浙江省重点实验室, 浙江 杭州 310014)

摘要: 专用变压器作为工业园区电力系统的重要组成部分, 对园区内电网的稳定性与安全性有着十分重要的影响。针对专变实时电气运行参数的波动性与异质性, 提出了一种基于极限区间的专变数据标准化方法。考虑了专变电气运行参数的动态集结方式与评价特征裕度, 为后续专变健康量化评价方法提供完整且公平的评价信息。为了将专变电气运行参数对专变自身健康的影响进行清晰量化, 将专家经验评价与神经网络相结合提出了一种基于极限区间与改进 PCA-SOM 的电气运行参数对专变健康影响的量化评价方法。在自组织映射神经网络的基础上, 通过引入主成分分析法中的主成分贡献度对目标函数进行修正, 并且结合各神经元的专家经验评分得到专用变压器的健康状态实时量化评分。最后采用“浙电云”大数据平台上采集的专变数据进行实验。结果表明该方法相比其他方法有着更好的评价效果, 更能准确反映专变的实时电气运行参数的变化对专变健康状况的影响。

关键词: 自组织映射神经网络; 主成分分析法; 极限区间; 专用变压器; 健康状况实时评估

Quantitative evaluation based on limit interval and improved PCA-SOM of electrical operating parameter health status of a special transformer

WU Chenghuan¹, HE Min¹, GONG Mingbo¹, LIN Yinghe², PAN Guobing³, OUYANG Jing³

(1. State Grid Zhejiang Power Co., Ltd. Ningbo Power Supply Company, Ningbo 315000, China; 2. Zhejiang Huayun Information Technology Co., Ltd., Hangzhou 310012, China; 3. Zhejiang Provincial Key Laboratory of Special Purpose Equipment and Advanced Manufacturing Technology, Ministry of Education, Zhejiang University of Technology, Hangzhou 310014, China)

Abstract: As a component of a power system, the special transformer has a very important impact on the stability and safety. Given the volatility and heterogeneity of real-time data of special transformers, a standardization method based on limit intervals is proposed. Considering the dynamic aggregation and limit interval of the real-time data of the special transformer, this method can provide complete information for quantitative evaluation. To clearly quantify the influence of specific electrical operation parameters on their own health, we combine expert experience evaluation with a neural network to propose a quantitative evaluation method based on limit interval and improved Self-Organizing Map-Principal Component Analysis (PCA-SOM) electrical operation parameters. Based on the SOM neural network, this method uses the contribution rate of each principal component in PCA to modify the objective function, and combines the artificial evaluation of each neuron to calculate a real-time evaluation of the health status of the dedicated transformer. Finally, the experiment uses real-time data from a special transformer on the “Zhedian Cloud” big data system. The results show that the method in this paper has higher accuracy than other methods and can better reflect the real-time health status of the special transformer.

This work is supported by the National Key Research and Development Program of China (No. 2017YFA0700300) and the Key Research and Development Program of Zhejiang Province (No. 2021C01112).

Key words: self-organizing map neural network; principal component analysis; limit intervals; special transformer; real-time evaluation of health status

0 引言

随着电网规模的不断扩大, 人们对于电力设备

的需求也日趋多元化, 工业园区特定行业大用电客户的增长使得专变在电网中所占的比例也越来越高。专变的安全运行无论对整个电网的安全性, 还是对供电的可靠性都具有十分重要的意义。利用专变电气运行参数对专变健康进行及时客观有效的量化评价不但有助于工作人员快速准确了解专变的工

基金项目: 国家重点研发计划项目资助(2017YFA0700300);
浙江省重点研发计划项目资助(2021C01112)

作状况,而且可以更加合理地安排维护检修,在保证工业园区大用户正常生产的基础上延长专变的使用寿命,从而有效提升社会效益。因此,从安全性、可靠性、经济性等多角度考虑,研究电气运行参数对专变健康影响的量化评价是十分必要的^[1-2]。

随着电力系统在线监测技术的不断发展^[3-5],部分地区已经基本实现了对专变运行数据的实时采集。但是基于上述专变实时数据的深度分析与应用却依然处于起步阶段。充分挖掘实时电气运行参数中的重要信息,研究电气运行参数对专变健康的影响,可以进一步提升专变健康状态的实时评估效果。

随着数据挖掘以及人工智能技术的进步,众多先进方法被引入电力系统故障识别领域^[6-13],国内外已有大量关于变压器状态评估以及故障识别的研究^[14-15]。文献[16]提出了基于关联规则和变权重系数的变压器健康状态评价方法,利用关联规则分别计算置信度和变权重系数,并结合运行状态与检修对照关系,诊断变压器的健康状态。文献[17]提出了基于最小方差的最优组合赋权方法,并将雷达图法的特征量计算方法应用到变压器的健康状态评估当中。文献[18]采用支持向量机(SVM)作为变压器绕组形变程度的分类器,并应用天牛须算法对 SVM 的核函数和惩罚因子进行优化,使其具有较好的诊断精度。文献[19]提出了基于状态检修和马尔可夫过程的变压器健康状态评价模型,利用分指标研究变压器缺陷严重程度,结合变压器分部位故障频率计算模型,并采用熵权模糊计算量化变压器设备风险等级,构建设备风险评估矩阵。以上变压器的健康状态评价模型已经取得不错的效果,但是都需要提前获得故障数据或者进行人工打标,实际使用过程中较为困难。文献[20]建立了基于 3 层贝叶斯网络的变压器评价方法,可以得到具体各部件的故障概率,结果更加直观,有助于规划后期的检修策略,但是计算时需要大量长期统计值,短期投运设备容易出现数据不足的问题。文献[21]提出了采用支持向量机作为评价变压器健康状态的模型,结果正确率高,训练时间短,不存在局部最小,但是在进行大规模样本训练时存在误差难以控制的问题。文献[22]提出了一种基于人工神经网络和信息融合技术的变压器评价方法,具有很强的模式分类能力,容错性好,稳健性高,但是对数据的要求很高,当数据不充分时无法工作。

现有的专用变压器健康状态评价方法都是基于变压器的运行状态参数进行评价,属于直接评价,往往运行参数恶化时专变的健康状态已经存在问题了,提前预警难以实现。专变健康的恶化,专变的

评分存在由高变低的过程,利用训练好的模型进行新采集数据的实时评分,对于模型得分处于所设预警分数以下时则发出预警,实现专变健康状态的提前预警。针对这个问题,提出一种基于极限区间与改进 PCA-SOM 的电气运行参数对专变健康影响的量化评价方法,首先采用一种基于极限区间的专变数据标准化方法,通过线性变换提取专变数据中更加完整的实时信息,并使用不同专变特征的裕度进行标准化处理。为了将专家评价与神经网络相结合,文中提出了一种改进的 PCA-SOM 方法。在自组织映射(Self-Organizing Map, SOM)神经网络的基础之上,首先通过引入主成分分析法(Principal Component Analysis, PCA)处理后的各元主成分贡献度,将其作为目标函数中各维分量的权重系数,然后利用专家经验确定各个神经元对应的状态评分,最后结合 SOM 神经网络训练的特征权重得到根据电气运行参数量化的专变健康状态的实时评分。实验结果表明文中方法相较于其他方法具有更好的评价效果,并且能够更准确及时地反映出专变实时的健康状况。

1 基于极限区间的专变数据标准化

由于采集的专用变压器的实时运行数据存在不同的数值量纲,并且文中后续采用的 SOM 神经网络主要基于实时数据之间的欧式距离大小,因此在进行健康状况评估前需要使用标准化方法来降低专变特征间的异质性。不同于一般的数据特征,专变特征有着真实的物理意义,并且其中部分特征在电能质量评价领域已经给出了合理的区间范围,但是传统的标准化方法完全依赖样本数据,如 max-min 标准化和 z-score 标准化等,当样本数量不足时,特征的最值区间不能很好地体现理论的极限区间。本文就专变特征的上述特点与现有标准化方法的不足,考虑不同特征的理想值与可变范围,提出了一种基于极限区间的专变实时数据标准化方法,完成专变特征的同质化处理,有助于提升后续专变健康状况评估的准确性。

对于待评价的专用变压器,设其有 M 项实时监测特征,在时间序列 $t_k (k=1,2,\dots,K)$ 上,各项专变特征的裕度为 $(x_{\text{lim}}^{\text{lower}}, x_{\text{lim}}^{\text{upper}})$,其中, $x_{\text{lim}}^{\text{lower}}$ 和 $x_{\text{lim}}^{\text{upper}}$ 分别表示专变特征理论上可以容忍的下界与上界。假设专变特征在时间序列上是均匀变化的,即在 (t_k, t_{k+1}) 时段内将 t_k 时刻的专变特征值 $x(k)$ 和 t_{k+1} 时刻的专变特征值 $x(k+1)$ 之间的连线看作是专变特征的发展轨迹^[23],如图 1 所示。

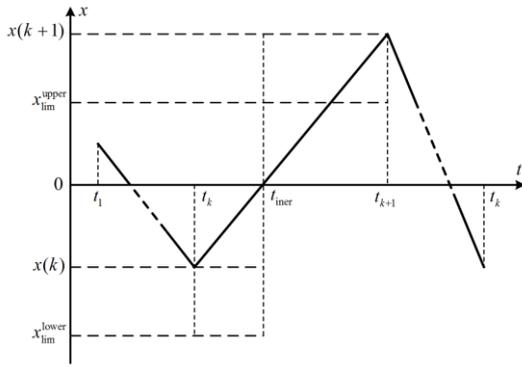


图 1 专变特征信息重构

Fig. 1 Feature information reconstruction of special transformer

在 (t_k, t_{k+1}) 内专变特征的初始评价值 \tilde{x} 为

$$\tilde{x} = \tilde{x}^{\text{upper}} + \tilde{x}^{\text{lower}} = \int_{t_k}^{t_{\text{inter}}} \xi(t) dt + \int_{t_{\text{inter}}}^{t_{k+1}} \xi(t) dt \quad (1)$$

式中: t_{inter} 表示专变特征的发展轨迹与理想数值的交点时刻; \tilde{x}^{lower} 和 \tilde{x}^{upper} 分别表示 t_{inter} 时刻左右两侧的初始评价值; $\xi(t)$ 表示专变特征信息的线性集结函数, 当 $t \in (t_k, t_{k+1})$ 时, 其表达式为

$$\xi(t) = x(t_k) + (t - t_k) \frac{x(t_{k+1}) - x(t_k)}{t_{k+1} - t_k} \quad (2)$$

同理, 专变特征裕度的信息集结值 x_{lim} 为

$$x_{\text{lim}} = \begin{cases} x^{\text{lower}}, & t \in (t_k, t_{\text{inter}}) \\ x^{\text{upper}}, & t \in (t_{\text{inter}}, t_{k+1}) \end{cases} = \begin{cases} \int_{t_k}^{t_{\text{inter}}} x_{\text{lim}}^{\text{lower}} dt, & t \in (t_k, t_{\text{inter}}) \\ \int_{t_{\text{inter}}}^{t_{k+1}} x_{\text{lim}}^{\text{upper}} dt, & t \in (t_{\text{inter}}, t_{k+1}) \end{cases} \quad (3)$$

式中, x^{lower} 和 x^{upper} 分别表示专变特征在 (t_k, t_{inter}) 与 $(t_{\text{inter}}, t_{k+1})$ 时段内的信息集结值, 则在 (t_k, t_{k+1}) 时段内结合专变特征裕度的评价值 \hat{x} 为

$$\hat{x} = \hat{x}^{\text{upper}} - \hat{x}^{\text{lower}} = \frac{\tilde{x}^{\text{upper}}}{x^{\text{upper}}} - \frac{\tilde{x}^{\text{lower}}}{x^{\text{lower}}} \quad (4)$$

经过上述标准化方法, 不同的专变特征已经被较好规约到同一个数量级下。当专用变压器正常运行时, 大部分实时数据普遍满足 $0 \leq \tilde{x}^{\text{lower}} \leq x^{\text{lower}}$ 和 $0 \leq \tilde{x}^{\text{upper}} \leq x^{\text{upper}}$ 的条件, 即 $\hat{x} \in [0, 1]$, 可以基本将专变特征都约束在同一个数量级之内。当专用变压器发生异常时, 小部分实时数据会出现 $\tilde{x}^{\text{lower}} > x^{\text{lower}}$ 或 $\tilde{x}^{\text{upper}} > x^{\text{upper}}$ 的情况, 即 \hat{x} 可能大于 1, 这样可以在一定程度上突出异常时刻的专变特征数据值。

2 基于改进 PCA-SOM 的电气运行参数对专变健康影响的量化评价算法

自组织映射(Self-Organizing Map, SOM)神经网络

最早由芬兰 Helsinki 大学的 T.Kohonen 教授提出^[24], 是一种由全连接的神经元阵列组成的自组织、自适应、自学习的神经网络。

为了提升 SOM 神经网络的运算速率与聚类精度, 部分学者将其与主成分分析法 (Principal Component Analysis, PCA) 相结合, 进而提出一种 PCA-SOM 神经网络。但是传统的 PCA-SOM 神经网络只是简单地把以上两种方法进行串行融合, 并没有从真正意义上对网络本身进行改进, 因此直接将其用于电气运行参数对专变健康状态的实时量化评价中效果欠佳^[25-26]。文中针对以上问题将主成分贡献度引入 SOM 神经网络中的距离函数中, 进而对 PCA-SOM 神经网络进行进一步优化。

对于待评价的专用变压器, 实时监测数据经过上述标准化处理后, SOM 神经网络可以输出二维拓扑结构, 假设输出层神经元数量为 L , 具体算法过程如下:

1) 计算协方差矩阵

假设输入的专变实时数据矩阵为 \mathbf{X} , 那么对应的协方差矩阵为 \mathbf{S} :

$$\mathbf{X} = \begin{bmatrix} \hat{x}_{11} & \hat{x}_{12} & \cdots & \hat{x}_{1M} \\ \hat{x}_{21} & \hat{x}_{22} & \cdots & \hat{x}_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{x}_{K1} & \hat{x}_{K2} & \cdots & \hat{x}_{KM} \end{bmatrix} \quad (5)$$

$$\mathbf{S} = \frac{1}{M-1} \mathbf{X}^T \mathbf{X} \quad (6)$$

2) 对数据标准化后的专变特征进行降维

对协方差矩阵 \mathbf{S} 进行特征值分解, 进而计算特征值与其对应的特征向量。

$$\mathbf{S} = \mathbf{P} \mathbf{A} \mathbf{P}^T = \mathbf{P} \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_M) \mathbf{P}^T \quad (7)$$

$$\text{s.t. } \lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_M \geq 0$$

式中: \mathbf{A} 表示对角矩阵; \mathbf{P} 表示特征值降序排列后其对应特征向量组成的特征向量矩阵。其中最大的特征值与相应的特征向量可以表示第一个主成分的方差与方向, 同理直至最小的特征值与相应的特征向量可以表示最后一个主成分的方差与方向。各个主成分的方差在所有主成分方差中的占比即为该主成分的贡献度, 第 m 个主成分的贡献度 C_m 为

$$C_m = \frac{\lambda_m}{\sum_{i=1}^M \lambda_i} \quad (8)$$

式中, λ_m 越大说明该主成分的贡献度越高, 能够反映专变数据中的信息越全。特征值 λ_m 降序排列后前 m 个主成分的累积贡献度 ΣC_m 为

$$\Sigma C_m = \frac{\sum_{i=1}^m \lambda_i}{\sum_{i=1}^M \lambda_i} \quad (9)$$

文中以 95% 作为累积贡献度的期望阈值, 当 ΣC_m 达到阈值时, 主成分数量 m 即为降维后的专变特征维度 M' 。

3) 权值向量初始化

经过 PCA 特征降维后, 在 (t_k, t_{k+1}) 时段内的专变实时样本向量 \hat{x}_k 与输出层第 l 个神经元之间的权值向量矩阵 $\omega_l(n)$ 经过 n 次更新后为

$$\omega_l(n) = [\omega_{l1}(n), \omega_{l2}(n), \dots, \omega_{lm'}(n)] \quad (10)$$

对输出层 L 个权值向量进行随机复制与归一化处理, 确定初始优胜领域 $M_l(0)$ 、初始学习率 $\mu_l(0)$ 以及初始权重向量 $\omega_l(0)$ 。

4) 寻找优胜神经元

将降维后的专变实时样本向量 \hat{x}_k 与输出层各个神经元的权值向量 $\omega_l(n)$ 做内积得 d_l , 其中内积 d_l 最大的神经元即为优胜神经元。优胜神经元可以通过计算最小欧氏距离得出, 因此内积 d_l 能够被改进为

$$d_l = \|\hat{x}_k - \omega_l(n)\| = \sqrt{\sum_{m'=1}^{M'} (\hat{x}_{km'} - \omega_{lm'}(n))^2} \quad (11)$$

传统 SOM 神经网络在计算 d_l 的过程中, 各个专变特征维度的权重系数相同都为 1, 即每个专变特征分量的贡献度一致, 没有区别。但在真实应用场景中, 各个专变特征在所有特征中的重要程度不同, 忽略它们之间的贡献度差异, 这势必会对 SOM 神经网络的训练造成影响。针对以上原因, 文中将主成分分析后的主成分贡献度引入距离函数, 作为各个专变特征维度的权重系数, 因此内积 d_l 能够被进一步改进为 d_l^* , 如式(12)所示。

$$d_l^* = \|C'(\hat{x}_k - \omega_l(n))\| = \sqrt{\sum_{m'=1}^{M'} C_{m'}' (\hat{x}_{km'} - \omega_{lm'}(n))^2} \quad (12)$$

式中, $C_{m'}'$ 表示改进后的专变特征的权重系数,

$$C_{m'}' = C_{m'} / \sum_{j=1}^{M'} C_j。$$

5) 调整优胜领域

以优胜神经元为中心, 调整优胜领域 $M_l(n)$ 以确定优胜区域。确定优胜领域可以利用多种距离函数, 文中使用常见的如欧式距离函数。

6) 调整权值

调整优胜领域内所有神经元的权重向量, 更新

公式为

$$\omega_l(n+1) = \omega_l(n) + \mu_l(n)(\hat{x}_k - \omega_l(n)) = (1 - \mu_l(n))\omega_l(n) + \mu_l(n)\hat{x}_k \quad (13)$$

7) 结束迭代

当学习率 $\mu_l(n)$ 衰减到预先设定的阈值时, 完成 SOM 神经网络的训练, 可以得到输出层各个神经元的最佳权值向量 ω_l^* 。

8) 输出专变健康状态的实时评分

在训练结束后分析每个优胜神经元下的专变实时数据样本, 根据专家经验对不同神经元进行人为赋值。 (t_k, t_{k+1}) 时段内的专变实时样本向量 \hat{x}_k 最终的健康状况评分 y_k 为

$$y_k = \sum_{l=1}^L A_l d_l^* = \sum_{l=1}^L A_l \sqrt{\sum_{m'=1}^{M'} C_{m'} (\hat{x}_{km'} - \omega_{lm'}^*)^2} \quad (14)$$

式中: A_l 表示输出层第 l 个神经元的专变健康状况等级评分; $\omega_{lm'}^*$ 表示第 m' 个专变特征相对于输出层的第 l 个神经元的权重值。具体基于极限区间与改进 PCA-SOM 的电气运行参数对专变健康影响的量化评价算法的具体流程如图 2 所示。

3 实例分析

基于电气运行参数的专变健康状态量化评价算法所用数据来源于国家电网“浙电云”大数据平台, 提取某地工业园区内的某台专用变压器一周的监测数据作为数据集, 先采用基于极限区间的数据标准化方法对原始的专变实时运行数据进行同质化处理, 再使用基于改进 PCA-SOM 的电气运行参数对专变健康影响的量化评价方法对该专变进行实时评分, 并且将此方法与 PCA-SOM 神经网络、SOM 神经网络和熵权法(EWM)的评价效果进行对比。

3.1 实验设置

算例使用的硬件平台如下: CPU 处理器为 i7-8700, RAM 内存为 16 GB, SSD 固态硬盘容量为 256 GB, GPU 显卡为 GTX1060-6GB。编程语言采用 Python 3.7, 主要涉及的第三方库包括 Numpy、Pandas、Scikit-Learn、MiniSOM 等, 其中 Scikit-Learn 为强大的机器学习工具包, 可以提供分类、回归、聚类、降维等方法的实现, MiniSOM 为基于 Numpy 开发的工具包, 可以实现 SOM 神经网络。

3.2 数据标准化

实验首先利用从“浙电云”大数据平台采集到的数据集构建专变健康评价体系所需的相关特征, 包括专变额定容量、设计寿命以及使用年限等基础信息。其次结合文献[27]中提出的专变实时型特征,

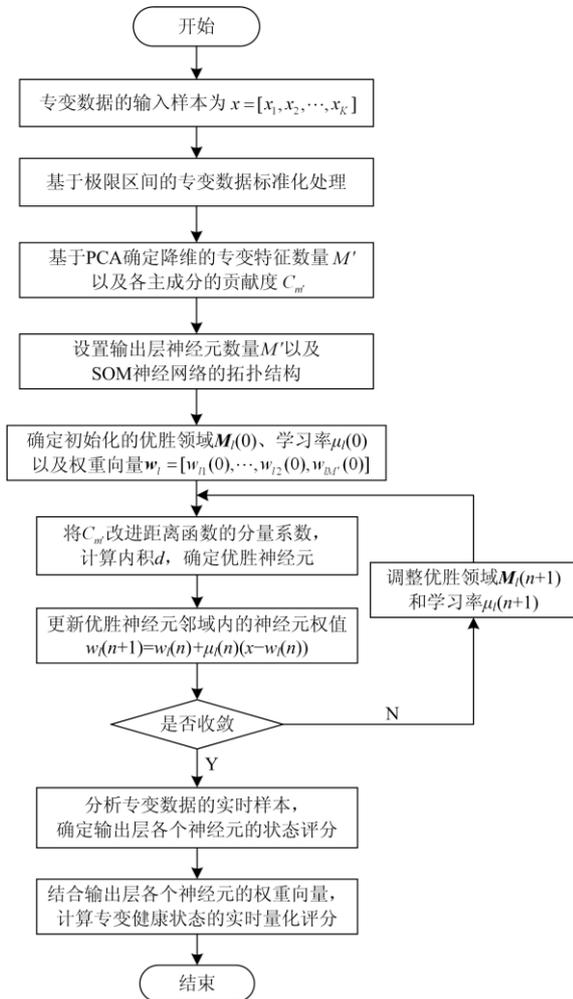


图 2 基于极限区间与改进 PCA-SOM 量化评价算法流程
Fig. 2 Quantitative evaluation algorithm flow based on limit interval and improved PCA-SOM

选取负载率 η 、电压偏差 V_d 、电压零序不平衡 V_z 、电流零序不平衡 A_z 、电压总谐波畸变率 THD_u 以及电流总谐波畸变率 THD_i 等专变特征。结合现有的国家标准^[28-31], 采用基于极限区间的数据标准化方法对上述特征值进行同质化处理, 其中各专变实时特征的理想值与极限值如表 1 所示。

表 1 专变实时特征的理想值与极限值

Table 1 Ideal and limit values of the special transformers feature

专变特征	理想值	上极限	下极限
负载率 η	0.6	0.8	0.4
电压偏差 V_d	0	0.07	-0.07
电压零序不平衡 V_z	0	0.02	0
电流零序不平衡 A_z	0	0.04	0
电压总谐波畸变率 THD_u	0	0.02	0
电流总谐波畸变率 THD_i	0	0.03	0

3.3 实验结果分析

对于数据标准化后的专变特征值, 首先使用 PCA 方法进行特征降维处理, 设置主成分分析的期望贡献度阈值为 95%, 累积贡献度达到阈值时的主成分数量为 4, 即基于 PCA 降维后特征维数为 4。再将降维后的专变特征值输入改进后的 SOM 神经网络进行训练, 设置输入层的神经元数量为 4, 输出层的神经元数量为 10×10 , 迭代次数为 2 000。输出层各神经元与周围神经元的距离如图 3 所示。

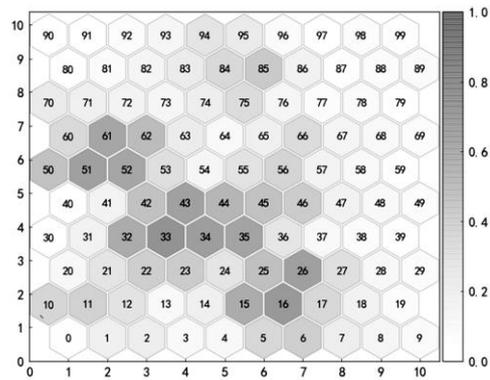


图 3 输出神经元

Fig. 3 Output neuron

图 3 中六边形灰色小方块代表神经元, 根据改进的欧式距离公式计算出临近神经元之间的距离, 并以六边形的底色反映神经元之间距离的远近, 颜色越深代表神经元之间的距离越远, 即神经元间对应状态的差异越大, 利用神经元间的距离辅助专家对各神经元进行评分。

从输出层各神经元对应的专变数据中随机抽取部分具有代表性的样本, 结合专家经验对不同神经元进行专家赋权。本算例中设置满分为 100 分, 每个神经元的评分上限为 10 分, 并以 1 分为颗粒度对其进行打分, 结果如图 4。各神经元的编号如图

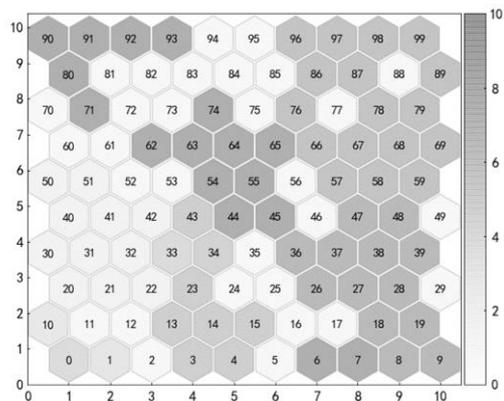


图 4 输出层各个神经元的状态评分

Fig. 4 State score of each neuron in the output layer

所示，以 SOM 神经网络左下角的神经元为初始值，从下往上、从左往右依次计数。

从图 3 和图 4 中可以看出，图 3 中深色神经元的评分与周围神经元的差别较大，而浅色神经元与周围神经元的差别较小。采用基于极限区间与改进 PCA-SOM 的电气运行参数对专变健康影响的量化评价算法得到的专变健康变化曲线如图 5 所示，图 6 为某园区内采样的专变的原始负荷数据。

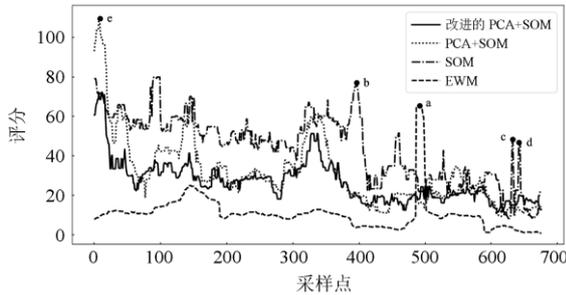


图 5 专变健康状态评分对比

Fig. 5 Health status score comparison of special transformer

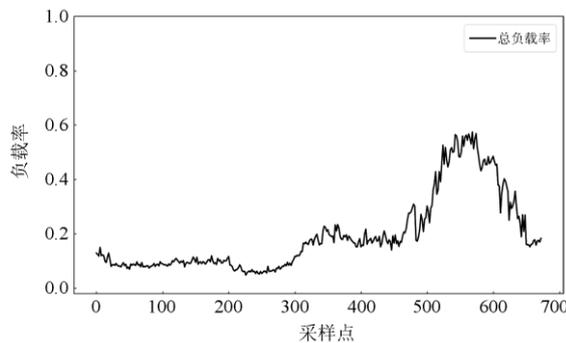


图 6 专变原始负荷数据变化

Fig. 6 Original load data of special transformer

通过对图 6 园区内采样的专变的原始负荷数据分析可以发现，采样时段内由于工况变化该专用变压器的负载基本上是逐渐增加的，健康状态的评分在整体上呈现趋势是逐渐降低。基于 SOM 神经网络评价方法得到的评分在趋势上与专变健康状态的整体变化趋势是相一致的，相较于基于 SOM 神经网络的评价方法，基于 EWM 的方法给出的评分普遍偏低且前后差异较小，不能体现该专变前后的健康变化趋势，同时不能反映专变健康状况的实时变化情况，因此该评价方法与实际情况不符。同时，在第 500 个采样点前后的点 a，由于传感器采集误差等原因使部分专变特征在该时段更加趋于理想值，进而导致基于 EWM 的健康状态评分极高，这与实际的由专变较高负载导致的专变健康评分较低的情

况不符。而基于 SOM 神经网络的评价方法依然可以给出较为合理的评分，说明相较 EWM 方法使用 SOM 神经网络进行专变健康评价模型的鲁棒性更强，且对噪声数据的抗干扰能力更强。

通过对图 5 专变健康评分曲线的进一步分析还可以发现，在不使用 PCA 对专变特征数据进行降维时，模型给出的评分普遍偏高且前后评分结果波动较大，特别在第 400 个采样点前后点 b 之后评分有段阶跃式的下降，在评分曲线末尾的 c、d 两点甚至出现了过冲现象，而采用 PCA 降维可以提取出专变特征中的重要信息，过滤无关的干扰信息，因此该方法给出的状态评分曲线相比直接利用 SOM 算法得到的评分曲线更加平稳，更符合实际情况。

由于改进后的方法在训练 SOM 神经网络时结合了 PCA 的主成份贡献度，可以提升降维后特征的重要性，突出重要电气运行参数对电能质量的影响，使得模型得到的评分曲线前后更加平缓，同时更可以体现该专变前后的健康变化趋势。如图原始的 PCA+SOM 评分算法在点 e 得到的评分严重脱离实际，而改进的 PCA+SOM 评分算法评分则更加符合实际。因此相较于其他方法，采用文中方法基于极限区间与改进 PCA-SOM 的电气运行参数对专变健康影响的量化评价方法得出的状态评分，能够更好地利用专变运行电气参数对工业园区专变健康状态进行实时的量化，从而客观反映专变健康的变化与发展趋势。

4 结论

本文基于极限区间与改进 PCA-SOM 神经网络构建了一种基于极限区间与改进 PCA-SOM 的电气运行参数对专变健康影响的量化评价方法，可以充分挖掘专变实时数据中的重要信息，进而能够客观反映专变健康状态的发展趋势，为工业园区专变的检修与维护提供重要的依据，从而提高电力系统的稳定性，保障园区生产的安全性有序性。

最后使用“浙电云”大数据平台上记录的专变实时数据进行实验，结果表明改进后的 PCA-SOM 方法相比与改进前的 PCA-SOM、SOM 和 EWM 方法更符合实际情况，特别是对于一些专变特征间数据质量存在差异的样本具有更好的评估能力，能够更加准确地反映专变的健康状况。

参考文献

[1] 周峰, 张丹丹, 刘弘景, 等. 温度对换流变压器绕组端部电场分布的影响研究[J]. 高压电器, 2020, 56(1): 80-86.
 ZHOU Feng, ZHANG Dandan, LIU Hongjing, et al.

- Influence of temperature on the electric field distribution of the winding end in converter transformer[J]. *High Voltage Apparatus*, 2020, 56(1): 80-86.
- [2] 孙勇, 张鹏, 皮杰, 等. 基于中心距和样本特征的换流变压器模糊状态评估模型[J]. *高压电器*, 2019, 55(12): 90-97.
SUN Yong, ZHANG Peng, PI Jie, et al. Fuzzy state assessment model of converter transformer based on center distance and sample features[J]. *High Voltage Apparatus*, 2019, 55(12): 90-97.
- [3] 方静, 彭小圣, 刘泰蔚, 等. 电力设备状态监测大数据发展综述[J]. *电力系统保护与控制*, 2020, 48(23): 176-186.
FANG Jing, PENG Xiaosheng, LIU Taiwei, et al. Development trend and application prospects of big data-based condition monitoring of power apparatus[J]. *Power System Protection and Control*, 2020, 48(23): 176-186.
- [4] 刘炎, 夏向阳, 李明德, 等. 高压电力电缆轨迹法在线监测方法[J]. *电力科学与技术学报*, 2019, 34(3): 202-210.
LIU Yan, XIA Xiangyang, LI Mingde, et al. Research on online monitoring system based on locus method of HV power cable[J]. *Journal of Electric Power Science and Technology*, 2019, 34(3): 202-210.
- [5] 曾祥君, 陈磊, 喻锬, 等. 基于配电网双端信息融合的单相断线故障实时监测方法[J]. *电力科学与技术学报*, 2020, 35(3): 12-18.
ZENG Xiangjun, CHEN Lei, YU Kun, et al. A real time monitoring method for the single-line break fault based on dual-terminal information in the distribution network[J]. *Journal of Electric Power Science and Technology*, 2020, 35(3): 12-18.
- [6] SUN Q, SHI L, NI Y, et al. An enhanced cascading failure model integrating data mining technique[J]. *Protection and Control of Modern Power Systems*, 2017, 2(1): 19-28. DOI: 10.1186/s41601-017-0035-3.
- [7] TALEBI N, SADRNI A M A, DARABI A. Fault detection of wind energy conversion systems using recurrent neural networks[J]. *International Journal of Solar Energy*, 2015, 34(1): 52-70.
- [8] LIN F J, SUN I F, YANG K J, et al. Recurrent fuzzy neural cerebellar model articulation network fault-tolerant control of six-phase permanent magnet synchronous motor position servo drive[J]. *IEEE Transactions on Fuzzy Systems*, 2016, 24(1): 153-167.
- [9] YANG Zhixin, WANG Xianbo, ZHONG Jianhua. Representational learning for fault diagnosis of wind turbine equipment: a multi-layered extreme learning machines approach[J]. *Energies*, 2016, 9(6).
- [10] 万书亭, 冉斌, 王志欢. 基于振动响应多维联合特征的瓷支柱绝缘子故障识别方法[J]. *广东电力*, 2020, 33(9): 18-26.
WAN Shuting, RAN Bin, WANG Zhihuan. Fault Identification method of porcelain post insulator based on combined characteristics of multi-dimensional vibration response[J]. *Guangdong Electric Power*, 2020, 33(9): 18-26.
- [11] 高拓宇, 赵贺, 李修金, 等. 基于 S 变换与奇异值分解的有载分接开关机械故障识别[J]. *广东电力*, 2019, 32(10): 111-118.
GAO Tuoyu, ZHAO He, LI Xiujin, et al. Mechanical fault recognition of on-load tap-changer based on s-transform and singular value decomposition[J]. *Guangdong Electric Power*, 2019, 32(10): 111-118.
- [12] 李天友, 杨智奇, 刘松喜. 基于物联网技术的低压配电网单相断线故障识别研究[J]. *供用电*, 2020, 37(12): 1-7.
LI Tianyou, YANG Zhiqi, LIU Songxi. Research on Single-phase recognition fault identification of low-voltage distribution based on internet of things[J]. *Distribution & Utilization*, 2020, 37(12): 1-7.
- [13] 李天友, 郭峰. 低压配电网的触电保护技术及其发展[J]. *供用电*, 2019, 36(12): 2-8.
LI Tianyou, GUO Feng. Electric shock protection technology and its development of low-voltage distribution[J]. *Distribution & Utilization*, 2019, 36(12): 2-8.
- [14] 谢鹏. 基于数据和模型的油浸式电力变压器健康管理研究[D]. 广州: 华南理工大学, 2020.
XIE Peng. Study on health management system of oil-immersed power transformer based on data and model[D]. Guangzhou: South China University of Technology, 2020.
- [15] RAJARAMAN P, SUNDARAVARADAN N A, MALLIKARJUNA B, et al. Robust fault analysis in transmission lines using synchrophasor measurements[J]. *Protection and Control of Modern Power Systems*, 2018, 3(1): 108-110. DOI: 10.1186/s41601-018-0082-4.
- [16] 谭贵生, 曹生现, 赵波, 等. 基于关联规则与变权重系数的变压器状态综合评估方法[J]. *电力系统保护与控制*, 2020, 48(1): 88-95.
TAN Guisheng, CAO Shengxian, ZHAO Bo, et al. An assessment of power transformers based on association rules and variable weight coefficients[J]. *Power System Protection and Control*, 2020, 48(1): 88-95.
- [17] 吴翔, 何怡刚, 张大波, 等. 基于最优权重与雷达图的

- 变压器状态评估[J]. 电力系统保护与控制, 2017, 45(2): 55-60.
- WU Xiang, HE Yigang, ZHANG Dabo, et al. Transformer condition assessment based on optimal weight and radar map[J]. Power System Protection and Control, 2017, 45(2): 55-60.
- [18] 张桦, 魏本刚, 李可军, 等. 基于变压器马尔可夫状态评估模型和熵权模糊评价方法的风险评估技术研究[J]. 电力系统保护与控制, 2016, 44(5): 134-140.
- ZHANG Hua, WEI Bengang, LI Kejun, et al. Research on risk assessment technology based on Markov state evaluation model for power transformer and entropy-weighted fuzzy comprehensive evaluation[J]. Power System Protection and Control, 2016, 44(5): 134-140.
- [19] 方涛, 钱晔, 郭灿杰, 等. 基于天牛须搜索优化支持向量机的变压器故障诊断研究[J]. 电力系统保护与控制, 2020, 48(20): 90-96.
- FANG Tao, QIAN Ye, GUO Canjie, et al. Research on transformer fault diagnosis based on a beetle antennae search optimized support vector machine[J]. Power System Protection and Control, 2020, 48(20): 90-96.
- [20] 白翠粉, 高文胜, 金雷, 等. 基于 3 层贝叶斯网络的变压器综合故障诊断[J]. 高电压技术, 2013, 39(2): 330-335.
- BAI Cuifen, GAO Wensheng, JIN Lei, et al. Integrated diagnosis of transformer faults based on three-layer Bayesian network[J]. High Voltage Engineering, 2013, 39(2): 330-335.
- [21] 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电力变压器故障诊断模型研究[J]. 中国电机工程学报, 2003, 39(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, 39(7): 88-92.
- [22] 阮聆, 谢齐家, 高胜友, 等. 人工神经网络和信息融合技术在变压器状态评估中的应用[J]. 高电压技术, 2014, 40(3): 822-828.
- RUAN Ling, XIE Qijia, GAO Shengyou, et al. Application of artificial neural network and information fusion technology in power transformer condition assessment[J]. High Voltage Engineering, 2014, 40(3): 822-828.
- [23] 袁金晶, 欧阳森, 石怡理, 等. 基于激励惩罚机制的区域电网电能质量综合评价方法[J]. 电力系统自动化, 2013, 37(7): 55-59.
- YUAN Jinjing, OUYANG Sen, SHI Yili, et al. Power quality comprehensive evaluation of regional power grid based on incentive and punishment mechanism[J]. Automation of Electric Power Systems, 2013, 37(7): 55-59.
- [24] KOHONEN T. Correlation matrix memories[J]. IEEE Transactions on Computers, 1972, 21(4): 353-359.
- [25] 胥学峰, 邢德恩, 宗炫君. 基于 PCA 与 SOM 神经网络算法的客户价值细分模型研究[J]. 电气自动化, 2017, 39(3): 49-52, 56.
- XU Xuefeng, XING De'en, ZONG Xuanjun. A research of customer value segmentation model based on PCA and SOM neural network[J]. Power System & Automation, 2017, 39(3): 49-52, 56.
- [26] 程国建, 安瑶. 基于 PCA 的 SOM 网络在基因数据聚类分析中的应用[J]. 软件导刊, 2013, 12(1): 127-130.
- CHENG Guojian, AN Yao. Clustering analysis of gene data based on PCA and SOM networks[J]. Software Guide, 2013, 12(1): 127-130.
- [27] 谢成, 曹张洁, 温典, 等. 基于实时运行数据挖掘的配电变压器状态评估[J]. 浙江电力, 2017, 36(8): 1-6.
- XIE Cheng, CAO Zhangjie, WEN Dian, et al. State evaluation of distribution transformers based on real-time operation data mining[J]. Zhejiang Electric Power, 2017, 36(8): 1-6.
- [28] 国家能源局. 电力变压器运行规程: DL/T 572—2010[S]. 北京: 中国电力出版社, 2010.
- National Energy Administration. Power transformer operation regulations: DL/T 572—2010[S]. Beijing: China Electric Power Press, 2010.
- [29] 国家标准化管理委员会. 电能质量供电电压偏差: GB/T 12325—2008[S]. 北京: 中国电力出版社, 2008.
- National Standardization Management Committee. Power quality power supply voltage deviation: GB/T 12325—2008[S]. Beijing: China Electric Power Press, 2008.
- [30] 国家标准化管理委员会. 电能质量三相电压不平衡: GB/T 15543—2008[S]. 北京: 中国电力出版社, 2008.
- National Standardization Management Committee. Power quality three-phase voltage unbalance: GB/T 15543—2008[S]. Beijing: China Electric Power Press, 2008.
- [31] 国家技术监督局. 电能质量公用电网谐波: GB/T 14549-93[S]. 北京: 中国电力出版社, 1993.
- National Bureau of Technical Supervision. Power quality public grid harmonics: GB/T 14549-93[S]. Beijing: China Electric Power Press, 1993.

收稿日期: 2020-10-20; 修回日期: 2021-05-03

作者简介:

邬程欢(1993—), 男, 硕士, 助理工程师, 研究方向为电力数据挖掘。E-mail: stonewch@163.com

(编辑 葛艳娜)