

DOI: 10.19783/j.cnki.pspc.200989

# 基于多模型融合集成学习的智能变电站二次设备状态评估

叶远波<sup>1</sup>, 黄太贵<sup>1</sup>, 谢民<sup>1</sup>, 赵子根<sup>2</sup>, 刘宏君<sup>2</sup>

(1. 国网安徽省电力有限公司, 安徽 合肥 230022; 2. 长园深瑞继保自动化有限公司, 广东 深圳 518057)

**摘要:** 为准确评估智能变电站二次设备运行状态, 建立了二次设备状态评估指标体系, 并结合多种机器学习算法的差异性, 提出了基于多模型融合集成学习的二次设备状态评估法。该方法采用双层结构, 上层中利用划分好的数据对数个基学习器进行  $k$  折验证, 下层中利用全连接级联神经网络融合多个基学习器, 并采用改进的列文伯格-马夸尔特算法训练该神经网络加速模型收敛。实例分析表明, 所提出的方法可以准确地评估二次设备的运行状态, 并为智能变电站系统和二次设备的检修工作提供指导意见。

**关键词:** 二次设备; 状态评估; 集成学习; 多模型融合

## A state assessment method for intelligent substation secondary equipment based on multi-model ensemble learning

YE Yuanbo<sup>1</sup>, HUANG Taigui<sup>1</sup>, XIE Min<sup>1</sup>, ZHAO Zigen<sup>2</sup>, LIU Hongjun<sup>2</sup>

(1. State Grid Anhui Electric Power Limited Company, Hefei 230022, China;

2. CYG SUNRI CO., LTD., Shenzhen 518057, China)

**Abstract:** In order to accurately evaluate the operational status of secondary equipment in an intelligent substation, this paper establishes an evaluation index system of the secondary equipment status. Combined with the differences of various machine learning algorithms, it also proposes a secondary equipment condition evaluation method based on multi-model ensemble learning. The method adopts a double-layer structure. In the upper layer,  $k$ -fold verification is carried out by dividing the data into several base learners. In the lower layer, a fully connected cascaded neural network is used to fuse multiple base models, and the improved Levenberg Marquardt algorithm is used to train the neural network to accelerate model convergence. The case analysis shows that the proposed method can accurately evaluate the operational status of the secondary equipment, and provide guidance for the maintenance of the intelligent substation system and secondary equipment.

This work is supported by the Science and Technology Project of State Grid Corporation of China (No. 521200190081).

**Key words:** secondary equipment; state assessment; integrated learning; multi model fusion

## 0 引言

智能变电站是坚强智能电网的重要基础 and 支撑, 智能变电站二次设备的运行状态直接关系到智能变电站的安全和稳定<sup>[1-2]</sup>。目前国内变电站二次设备检修主要以故障检修和计划检修为主, 同时二次设备技术发展迅猛, 但维护人员配备不足且经验不足, 这一现状给变电站的安全稳定运行带来了巨大的风险<sup>[3-4]</sup>。

智能变电站二次设备状态评估是状态检修的基础, 可以及时且高效地为二次设备状态检修提供理论指导和检修计划<sup>[5-6]</sup>。准确的二次设备状态评估不仅能够提高二次系统运行的可靠性, 同时通过制定科学合理的检修计划, 可以提高综合经济效益<sup>[7]</sup>。

目前国内外学者主要针对一次设备的运行状态开展研究和评估工作, 在智能变电站二次设备主动运维和状态检修方面的研究并不多。针对二次设备状态评估通常采用模糊理论建模方法, 该方法适用于具有模糊性、不确定性的事物的状态评估, 通过模糊理论可以准确地量化各个指标对设备状态的影

响程度。文献[8]针对智能变电站二次设备单一指标无法有效评估潜在故障的问题, 提出了一种基于变权理论与梯形云模型的二次设备整体性能模糊综合评判方法。另外, 层次分析法在二次设备状态评估方面也有较多的应用。层次分析法采用定性和定量相结合的方式将状态评估问题进行分解, 结合其重要性计算出最终的权重。文献[9]应用层次分析法, 提出了一种基于专家会诊的状态评估标准, 可以很好地将定性和定量分析相结合以实现状态评估。文献[10]根据二次设备的各类信息和在线监测数据特点, 基于层次分析模型提出了电气二次设备状态检修策略。近年来随着人工智能算法的兴起, 各类智能算法(如支持向量机<sup>[11-13]</sup>、人工神经网络<sup>[14-15]</sup>等)被应用在了二次设备状态评估中, 并在实际应用中取得了一定的效果。文献[16]基于灰色聚类法建立了二次设备状态评估模型, 并根据评估指标的不确定性, 采用云模型构建灰色白化权函数, 并结合层次分析法计算状态指标的组合权重。文献[17]基于切比雪夫正交基函数神经网络, 并搭配教师模块作为电气设备状态评估的模型, 在对历史数据的学习

过程中通过教师模块来调整网络权值。

本文建立了二次设备状态评估指标体系, 并根据多种机器学习算法基学习器的差异性, 提出一种基于多模型融合集成学习的二次设备状态评估方法。该方法由两层结构组成, 先对原始数据进行划分, 并利用划分好的数据对第一层中的数个基学习器进行  $k$  折验证, 然后利用第二层中的全连接级联(Fully Connected Cascaded, FCC)神经网络对多个基学习器进行融合, 并采用改进的列文伯格-马夸尔特(Levenberg Marquardt, LM)算法训练 FCC 神经网络, 使得模型快速稳定地收敛。实例分析表明, 本文提出的方法能够准确地评估二次设备的运行状态, 可以为智能变电站系统和二次设备的检修工作提供可靠的理论指导和检修计划。

## 1 智能变电站二次设备评估模型

### 1.1 二次系统结构

智能变电站的二次系统架构为“三层两网”结构<sup>[18]</sup>, 如图 1 所示, 其中三层是指站控层、间隔层和过程层, “两网”是指过程层网络和站控层网络。

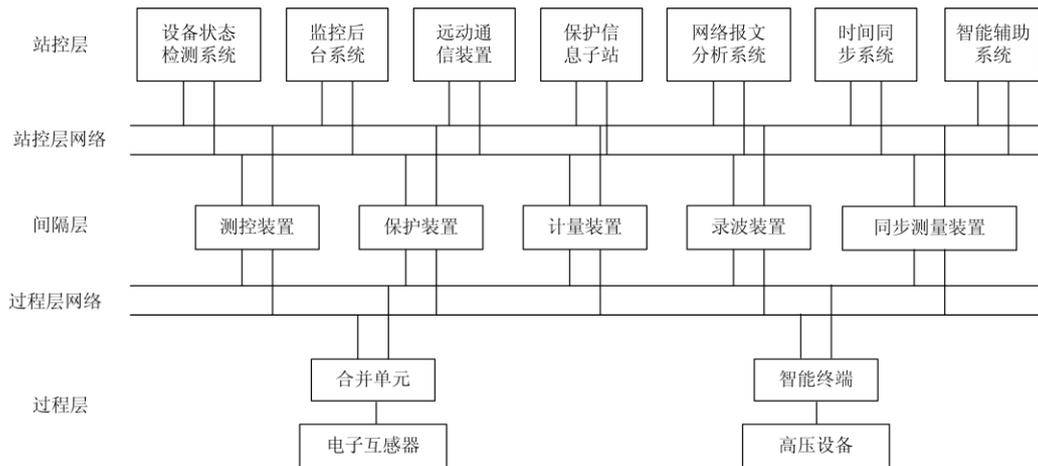


图 1 智能变电站二次系统结构

Fig. 1 Structure of intelligent substation secondary system

### 1.2 二次设备评估指标体系

合理的二次设备评价体系是状态评估方法研究的基础工作, 二次设备状态特征的选取直接决定了是否能够正确地反应设备实际的运行状态。

智能变电站二次系统中包含了多种设备, 同时不同设备的状态特征也各有不同, 因此需要结合实际运行情况、技术水平、相关技术规范以及操作经验, 才能制定出科学高效的评价体系。

#### 1) 测量回路评价指标

测量回路主要由电子式互感器以及合并单元组成。测量回路设备的运行时间代表了其老化程度, 平均无故障时间也是设备运行可靠性的度量; 采样过程是时间同步的, 合并单元需要接收外部时钟的同步信号, 因此需要考虑设备的绝对时延和对时脉冲误差指标。同时采样值的误差直接影响到数据的正确性。合并单元对工作环境的温度也有一定的要求。电气性能方面需要考虑绝缘电阻与泄漏电流, 电磁兼容性方面需要考虑工频磁场抗扰度以及脉冲磁场抗扰度, 因此测量回路评价指标如图 2 所示。

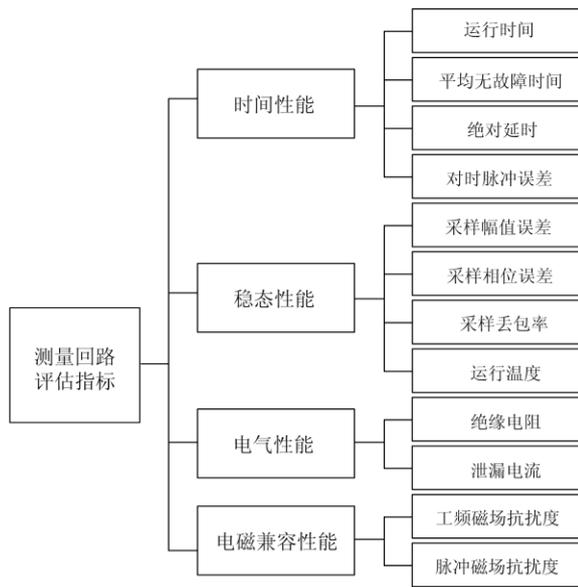


图 2 测量回路评价指标

Fig. 2 Evaluation index of measurement circuit

### 2) 保护装置评价指标

时间性能方面与测量回路相似，同样需要考察运行时间以及平均无故障时间指标。智能变电站的继电保护设备在数据传输方面与传统变电站有较大的不同，相关开关量信息、采样值信息都需要通过特定的报文经由网络来实现具体的传输，因而需要考虑通信系统的运行情况；继电保护设备自身缺陷会直接影响到是否能正确执行保护动作，因而需要考虑家族性缺陷情况以及随机性缺陷情况；平均动作正确率可以反映继电保护装置成功切除故障的能力。电气性能方面需要考虑母线、纵联、主变差动误差，因此保护装置评价指标如图 3 所示。

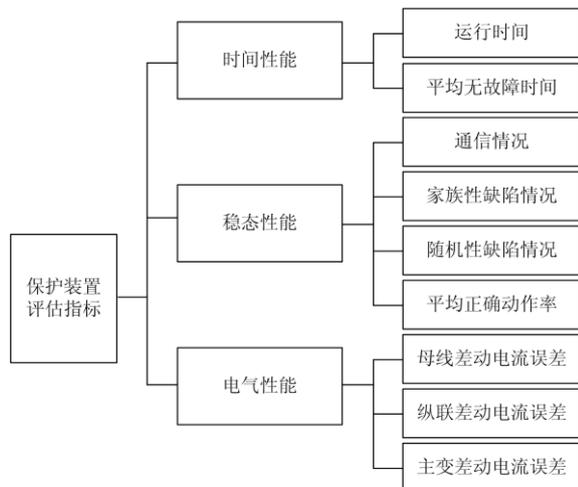


图 3 保护装置评估指标

Fig. 3 Evaluation index of protection device

### 3) 智能终端评价指标

智能终端负责接收来自二次设备的控制指令，并执行相应的动作，在这样的过程中涉及的指标有运行时间、动作时间、报文发送时间等。稳态性能方面与保护装置类似，需要考虑家族性缺陷和正确动作率，同时 SOE 分辨率以及通信接口性能也是智能终端的关键指标。

智能终端和测量回路都属于过程层设备，在电气性能方面有着相似性，需要考虑绝缘电阻以及泄漏电流，因此智能终端评价指标如图 4 所示。



图 4 智能终端评价指标

Fig. 4 Evaluation index of intelligent terminal

### 4) 测控装置评价指标

测控装置基于 IEC61850 标准，支持 GOOSE 跳闸和合闸功能，相较于保护装置，需要额外考察同期性能以及 GOOSE 延时。同时测控装置是通过通信手段来实现数据的接收和发送，对通信网络的性能和稳定性都有比较高的要求，因而需要关注谐波干扰、光纤接口性能等指标。电气性能方面与其他装置相似，需要考虑绝缘电阻与泄漏电流，因此测控装置评价指标如图 5 所示。

### 5) 通信装置评价指标

通信装置的通信性能是最为关键的指标，其中涉及到吞吐率、丢包率、广播率、组播率，这些指标都能直观地反应通信的质量。此外通信设备容易受到电磁干扰，故需要对设备的工频磁场抗扰度以及脉冲磁场抗扰度进行考察，因此测控装置评价指标如图 6 所示。



图5 测控装置评价指标

Fig. 5 Evaluation index of measurement and control device

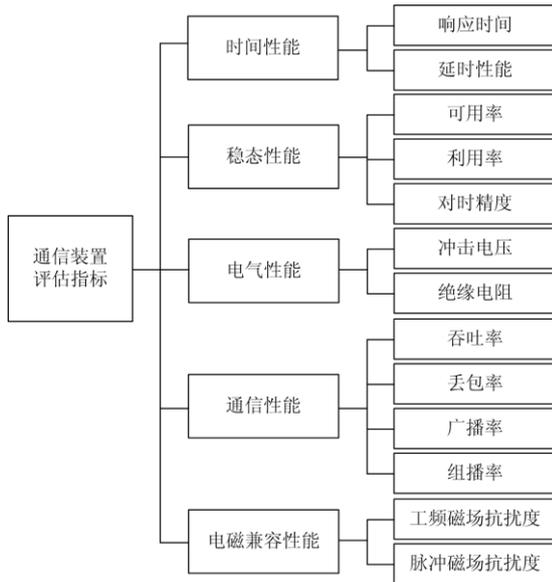


图6 通信装置评价指标

Fig. 6 Evaluation index of communication device

### 6) 同步系统评价指标

智能变电站中, 信号的传输与采集都是基于同一的时间基准, 这样才可以保障传输信号的实时性、准确性以及可靠性。智能变电站的时间基准是通过同步系统来维持的, 通过准确的时间标准, 可以使系统精确地完成采集、记录、控制、保护、计算等功能。依照时间同步装置的相关规范, 需要考察其平均无故障时间、对时抖动指标; 稳态特性方面, 脉冲宽度误差、脉冲准时延精度、对时精度、授时精度都是反映同步系统是否准确工作的重要指标,

电磁兼容特性与上述装置类似, 因此同步系统评价指标如图7所示。

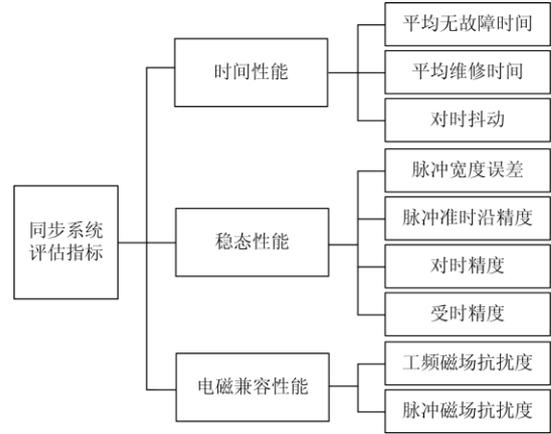


图7 同步系统评价指标

Fig. 7 Evaluation index of synchronous system

### 1.3 二次设备评估样本建立

二次设备的评估样本, 应当包含评估指标以及对应的评估结果。根据上一小节分析, 二次系统设备评价指标可以表示为  $X = [\chi_{1,1}, \dots, \chi_{n,m}, \dots]$ , 式中  $\chi_{n,m}$  表示  $n$  设备的  $m$  指标, 共计 65 项指标。

不同的评价指标具有不同的量纲, 在处理过程会带来一定的困难, 本文借鉴文献[19], 采用了相对劣化度的方法来表征设备偏离正常状态的程度, 劣化度是一个定量的指标, 取值范围为 0 到 1。根据不同指标的特性, 将其分为两类指标: 越大越优型和越小越优型。

越大越优型指标如对时精度和 SOE 分辨率等, 其劣化度  $x_i$  可以表示为

$$x_i = \frac{u_i - u_{i0}}{u_{i\max} - u_{i0}} \quad (1)$$

式中:  $u_i$  为设备的当前实际测量值;  $u_{i0}$  为状态指标出厂值, 也就是正常状态值;  $u_{i\max}$  为越大越优型的极度劣化状态量值。

越小越优型指标如对时抖动和响应报文延时等, 其劣化度  $x_i$  可以表示为

$$x_i = \frac{u_{i0} - u_i}{u_{i0} - u_{i\min}} \quad (2)$$

式中,  $u_{i\min}$  为越小越优型的极度劣化状态量值。

此外为了获得对智能变电站二次设备运行状态的评估样本, 需要邀请数名专家根据采集到的二次设备运行数据结合实际运行情况对各个二次设备状态以及总体运行状态进行评估, 状态评估结果可以表示为  $Y = [y_1, y_2, \dots, y_6, y_\Sigma]$ ,  $y_i$  分别表示六类二次设

备的运行状态评估结果,  $y_2$  表示二次系统状态评估结果。

## 2 基于集成学习的二次设备状态评估

人工分析智能变电站二次设备状态需要花费较多时间, 同时评估准确度无法保证。本文采用了多模型融合集成学习算法来对人工评估结果进行学习, 使得训练完的模型可以像专家一样对二次设备状态进行评估, 以此实现对二次设备状态的快速在线评估。

### 2.1 多模型融合集成学习

目前已有较多的研究通过各种模型或方法建立了多种指标与二次设备状态之间对应关系<sup>[2,8,16-17]</sup>, 然而单一的模型在处理此类复杂问题时表现并不稳定。多模型融合集成学习<sup>[20]</sup>则是根据已经评估好的数据训练出若干模型作为基学习器, 利用这些基学

习器的输出作为新的训练集, 以此来训练一个新的学习器。通常情况下不同的基学习器模型可以学习到数据的不同特征, 通过融合多种基学习器, 多模型融合集成学习模型可以取长补短得到更好的学习效果<sup>[21]</sup>。

多模型融合集成学习框架如图 8 所示, 首先将原始数据  $\{X, Y\}$  分为训练数据集  $D1$  和测试数据集  $D2$ , 并将训练数据集随机分成若干个子数据集, 子数据集的数量由第一层中基学习器的种类决定, 本文选取了 XGBoost(eXtreme Gradient Boosting)、LightGBM(Light Gradient Boosting Machine)、随机森林(Random Forests, RF)、梯度提升迭代决策树(Gradient Boosting Decision Tree, GBDT)、长短期记忆神经网络(Long Short-Term Memory, LSTM)这五种基学习器, 因而需要将数据集分为 5 份, 分别记为  $D1_1, D1_2, \dots, D1_5$ 。

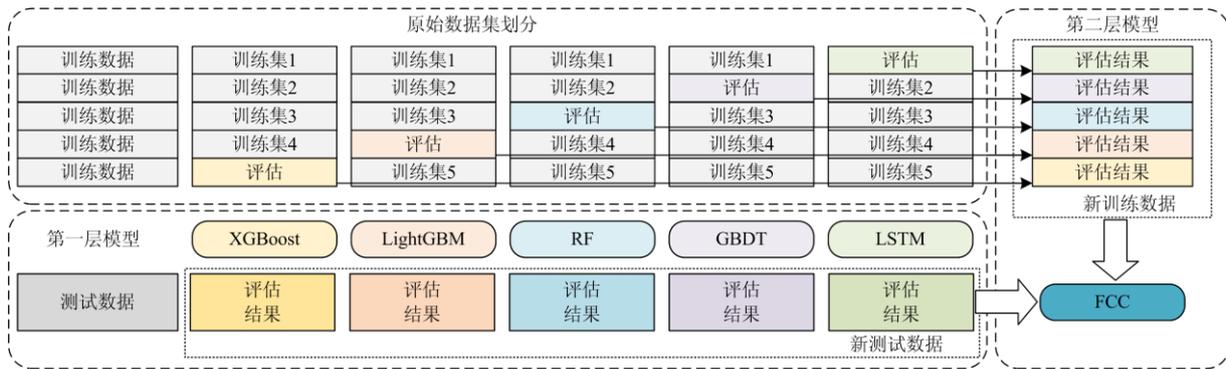


图 8 多模型融合集成学习框架

Fig. 8 Framework of ensemble learning with multi models

完成子数据集划分后, 将数据集中  $X$  作为输入,  $Y$  作为输出, 对第一层的基学习器进行 5 折验证, 5 折验证就是将其中 4 折的子数据集用于训练基学习器, 另外的 1 折作为测试数据。如图 8 所示, 训练数据集被分为 5 份, 在 XGBoost 的训练过程中使用了子训练集  $D1_1 \square D1_4$ , 完成训练后将训练集  $D1_5$  输入 XGBoost 基学习器, 得到对应的评估结果  $Y_{15}$ 。其余的基学习器也要重复上述步骤, 对于不同的基学习器所使用的训练集均不相同, 最终输出的评估结果  $Y_i$  将作为新的训练数据集  $D3 = \{Y_i, Y\}$ , 用于第二层模型的训练。

所有基学习器完成训练后, 利用基学习器对测试集数据  $D2$  进行评估, 得到的结果  $Y_i$  组合成为新的测试数据集  $D4 = \{Y_i, Y\}$ 。

### 2.2 基学习器

本文选取了 XGBoost、LightGBM、RF、GBDT、

LSTM 这五种基学习器, 对于基学习器的选择标准将在后文进行详细分析。由于篇幅原因, 不对该五种基学习器进行详细介绍, 具体原理和推导过程详见相关论文。

### 2.3 全连接级联神经网络

通过第一层的基学习器最终可以得到新的测试数据集以及新的训练数据集, 这些数据将会应用在第二层模型的训练中, 因此第二层中的输入则为第一层中各个基模型输出的评估结果, 输出则为调整后的最终评估结果。

第二层模型使用了全连接级联神经网络, 其网络结构如图 9 所示, 五个基学习器通过输入层与五个神经元相连, 前四个神经元使用  $\tanh(\cdot)$  激活函数, 最后一个神经元为线性求和函数。在相同神经元数量的情况下, FCC 神经网络可以提供比传统神经网络更多的连接数量, 得到更多的权重关系, 通过这样的结构优势, FCC 神经网络可以获得更好的效果。

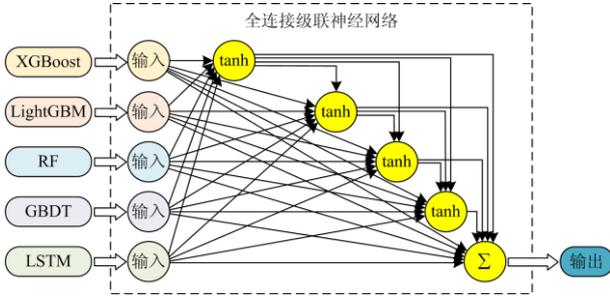


图9 FCC神经网络结构图

Fig. 9 Structure of FCC neural network

本文使用的浅层结构 FCC 神经网络能够在提供足够学习能力的同时, 避免过拟合问题。FCC 神经网络对每个输入和每个神经元的潜在变量都有一个直接的映射关系。

第一层模型损失函数可以通过平方和误差来表示, 如式(3)所示。

$$L(L_1; i) = \text{minimize}_{\omega_i} \sum_{T \in D_{L_1}} \left\| \hat{\ell}_n^{L_1, i} - \ell_n \right\|^2 + \alpha \cdot \|\omega_i\| \quad (3)$$

式中:  $L(L_1; i)$  表示第一层中基学习器  $i$  的损失函数;  $\hat{\ell}_n^{L_1, i}$  表示基学习器  $i$  对于第  $n$  个数据的评估结果;  $\ell_n$  表示第  $n$  个数据的实际评估结果, 即标签值;  $\omega_i$  表示基学习器  $i$  对应的权重;  $\alpha$  为权重系数。

根据第二层模型与第一层中基学习器的关系, 第二层模型输出的评估结果可以表示为

$$\hat{\ell}_n^{L_2} = f(\hat{\ell}_n^{L_1, 1}, \hat{\ell}_n^{L_1, 2}, \dots, \hat{\ell}_n^{L_1, 5}; \omega_{fcc}) \quad (4)$$

式中:  $f(\cdot)$  表示了 FCC 神经网络输出的评估结果;  $\omega_{fcc}$  表示了 FCC 神经网络的权重。

因此第二层模型的损失函数可以表示为

$$L(L_2) = \text{minimize}_{\omega_{fcc}} \sum_{n \in D_3} \left\| \hat{\ell}_n^{L_2} - \ell_n \right\|^2 + \beta \cdot \|\omega_{fcc}\| \quad (5)$$

式中:  $L(L_2)$  表示第二层中的损失函数;  $\hat{\ell}_n^{L_2}$  表示 FCC 神经网络对于第  $n$  个数据的评估结果;  $\omega_i$  表示基学习器  $i$  对应的权重;  $\beta$  为权重系数。

## 2.4 改进列文伯格-马夸尔特算法

一阶梯度下降算法误差反向传播法(error Back Propagation, BP)、随机梯度下降法(Stochastic Gradient Descent, SGD)以及 Adamax 算法, 已经在训练神经网络方面得到了广泛的应用, 然而一阶梯度下降算法容易陷入局部最优解和鞍点问题<sup>[22]</sup>。二阶梯度下降算法可以较好地处理此类问题, 因此在多模型融合集成学习框架的第二层中本文使用了改进的列文伯格-马夸尔特算法<sup>[23]</sup>, 算法伪代码如表 1 所示。

表 1 改进列文伯格-马夸尔特算法

Table 1 Improved Levenberg Marquardt algorithm

算法 1: 改进列文伯格-马夸尔特算法

- 1 设置参数:  $0 < m < \alpha 1$ ;  $0 < p 0 < p 1 < p 2 < 1$ ;  $e = 1$
- 2 计算雅克比矩阵  $J(\omega_{fcc}^e)$
- 3 设 LM 标准步长为  $d_e = \Delta \omega_{fcc}^e$
- 4 线性搜索 LM 近似步长  $\Delta \omega_{fcc}^e$
- 5 结合步骤 3 和步骤 4,  $s_e = \Delta \omega_{fcc}^e + \alpha_e \Delta \omega_{fcc}^e$
- 6 如果  $J(\omega_{fcc}^e)^T J(\omega_{fcc}^e) = 0$ , 则结束算法
- 7 计算  $r_e = R_e^e / R_e^e$ , 并更新权重:

$$\omega_{fcc}^{e+1} = \begin{cases} \omega_{fcc}^e + s_e & \text{if } r_e > p 0 \\ \omega_{fcc}^e & \text{其他} \end{cases} \quad (6)$$

- 8 计算  $\alpha_{e+1}$

$$\alpha_{e+1} = \begin{cases} 4\alpha_e & \text{if } r_e < p 1 \\ \alpha_e & \text{if } r_e \in [p 1, p 2] \\ \max(0.25\alpha_e, m) & \text{if } r_e > p 1 \end{cases} \quad (7)$$

- 9  $e = e + 1$ , 并返回步骤 2

第  $e$  次迭代的雅克比矩阵  $J(\omega_{fcc}^e)$  可以通过计算式(5)的偏导数求得, 表达式如式(8)所示。

$$J(\omega_{fcc}^e) = \left[ \frac{\partial L(L_2)}{\partial \omega_1^e}, \frac{\partial L(L_2)}{\partial \omega_2^e}, \dots, \frac{\partial L(L_2)}{\partial \omega_z^e} \right] \quad (8)$$

式中:  $\omega_{fcc}^e$  表示 FCC 神经网络在第  $e$  次迭代时的权重, 其分量可以表示为  $\{\omega_1^e, \omega_2^e, \dots, \omega_z^e\}$ 。

海瑟矩阵可以通过  $J(\omega_{fcc}^e)^T J(\omega_{fcc}^e)$  来近似, 阻尼系数  $\mu_e$  通过式(9)进行更新。

$$\mu_e = \alpha_e \left\| L(L_2, \omega_{fcc}^e) \right\|^\beta, \beta \in (0, 2] \quad (9)$$

每次迭代, FCC 神经网络的权重通过式(10)或式(11)更新。

$$\omega_{fcc}^{e+1} = \omega_{fcc}^e + s_e \quad (10)$$

$$\omega_{fcc}^{e+1} = \omega_{fcc}^e + \Delta \omega_{fcc}^e + \alpha_e \Delta \omega_{fcc}^e \quad (11)$$

式中:  $s_e \approx \Delta \omega_{fcc}^e + \alpha_e \Delta \omega_{fcc}^e$ ;  $\Delta \omega_{fcc}^e$  是线性搜索得到的近似 LM 步长;  $d_e \approx \Delta \omega_{fcc}^e$  是一个标准的 LM 步长, 详细表达式分别如式(12)、式(13)所示。

$$\Delta \omega_{fcc}^e = - \left[ J(\omega_{fcc}^e)^T J(\omega_{fcc}^e) + \mu_e I \right]^{-1} J(\omega_{fcc}^e)^T L(L_2, \omega_{fcc}^e) \quad (12)$$

$$\Delta \omega_{fcc}^e = - \left[ J(\omega_{fcc}^e + \Delta \omega_{fcc}^e)^T J(\omega_{fcc}^e + \Delta \omega_{fcc}^e) + \mu_e' I \right]^{-1} \times J(\omega_{fcc}^e + \Delta \omega_{fcc}^e)^T L(L_2, \omega_{fcc}^e + \Delta \omega_e) \quad (13)$$

式中,  $\mu'_e = \left\| \mathbf{L} \left( \mathbf{L}_2, \omega_{fcc}^e + \Delta \omega_{fcc}^e \right) \right\|^\beta$ 。

其中  $\mathbf{J} \left( \omega_{fcc}^e + \Delta \omega_{fcc}^e \right)$  可以近似于  $\mathbf{J} \left( \omega_{fcc}^e \right)$ , 为了减少计算量, 在这里将  $\mu'_e$  近似为  $\mu_e$ , 因此可以将上式改写为

$$\Delta \omega_{fcc}^e = - \left[ \mathbf{J} \left( \omega_{fcc}^e \right)^\top \mathbf{J} \left( \omega_{fcc}^e \right) + \mu_e \mathbf{I} \right]^{-1} \times \mathbf{J} \left( \omega_{fcc}^e \right)^\top \mathbf{L} \left( \mathbf{L}_2, \omega_{fcc}^e + \Delta \omega_{fcc}^e \right) \quad (14)$$

为了验证  $s_e$  的正确性, 本文采用了信赖域法, 第  $e$  次迭代的真实削减量  $R_a^e$  和预测削减量  $R_p^e$ , 表达式分别如(15)、式(16)所示。

$$R_a^e = \left\| \mathbf{L} \left( \mathbf{L}_2, \omega_{fcc}^e \right) \right\|^2 - \left\| \mathbf{L} \left( \mathbf{L}_2, \omega_{fcc}^e + s_e \right) \right\|^2 \quad (15)$$

$$R_p^e = \left\| \mathbf{L} \left( \omega_{fcc}^e \right) \right\|^2 - \left\| \mathbf{L} \left( \omega_{fcc}^e \right) + \mathbf{J} \left( \omega_{fcc}^e \right) d_e \right\|^2 + \left\| \mathbf{L} \left( \omega_{fcc}^e + d_e \right) \right\|^2 - \left\| \mathbf{L} \left( \omega_{fcc}^e + d_e \right) + \alpha_e \mathbf{J} \left( \omega_{fcc}^e \right) \Delta \omega_{fcc}^e \right\|^2 \quad (16)$$

再利用  $r_e = R_a^e / R_p^e$  更新 FCC 神经网络权重, 具体如式(6)所示。

### 2.5 基于集成学习的二次设备状态评估流程

基于多模型融合集成学习的二次设备评估方法本质上是让集成学习模型来学习专家进行设备评估, 以此来获得对二次设备评估的能力。具体流程如图 10 所示。

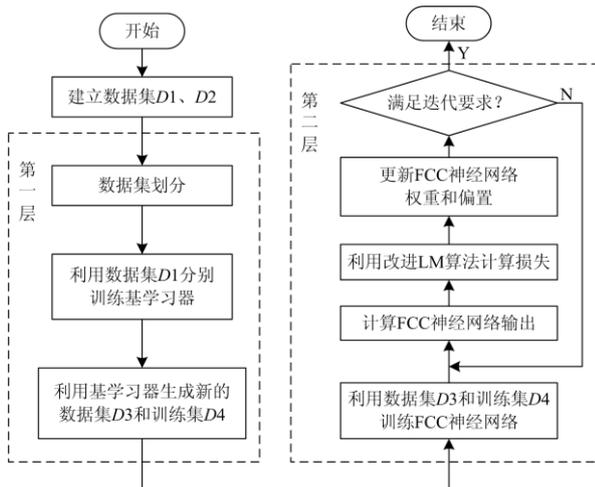


图 10 基于集成学习的二次设备状态评估流程图

Fig. 10 Flow chart of secondary equipment condition evaluation based on ensemble learning

首先根据前文所建立的指标体系以及得到的评估样本, 其中训练数据集  $D1$  和测试数据集  $D2$ 。其

次对样本数据集进行划分, 利用  $k$  折验证原则来训练各基学习器, 完成训练后利用基学习器生成新的训练数据集  $D3$  和测试数据集  $D4$ 。然后利用得到的新数据集训练 FCC 神经网络, 并利用本文所提出的改进 LM 算法更新 FCC 神经网络权重, 直到满足要求。训练完成后的多模型融合集成学习模型, 可以准确评估二次设备运行状态, 为智能变电站的运维工作提供有力的支持。

### 3 算例分析

为了验证文中所提算法对于智能变电站二次设备状态评估的有效性, 采用某省电网所辖智能变电站的实测数据, 并邀请 6 名专家对二次设备状态进行评分, 每份数据对应的二次设备状态评分取各专家打分的平均值。相关模型是在 python3.7、keras2.2.4、与 tensorflow2.0-beta 环境下完成编程以及运行的。模型评估准确性指标采用了平均相对误差  $e_{MAPE}$  (Mean Absolute Percentage Error, MAPE) 公式如式(17)所示。

$$e_{MAPE} = \frac{1}{N} \sum_{n=1}^N \left| \frac{\hat{y}_n - y_n}{y_n} \right| \times 100\% \quad (17)$$

式中:  $N$  为样本总数量;  $\hat{y}_n$  为模型对于数据  $n$  的评估结果;  $y_n$  为数据  $n$  的实际评估结果, 即专家评分结果。

#### 3.1 基学习器超参数选择与评估性能分析

集成学习模型第一层中各个基学习器的性能会直接影响集成学习模型的综合性能, 因此在构建集成学习模型的过程中需要尽量挑选本身性能较好的模型。本文预先选择了 5 个基学习器, 并根据各自特点进行了调参, 为了更加严谨地展现基学习器的评估性能和学习能力, 重复数据划分和基学习器学习过程并记录平均相对误差, 最终得到的超参数表以及状态评估结果如表 2 所示, 其中  $\bar{e}_{MAPE}$  为多次重复学习过程中得到的平均相对误差的均值。

表 2 基学习器独立评估的误差

Table 2 Assessment error of different base learners					
基学习器	XGBoost	LightGBM	RF	GBDT	LSTM
$\bar{e}_{MAPE} / \%$	2.33	2.18	5.73	5.46	6.10

根据表 2 可知, 在当前的超参数设定下各个基学习器的平均相对误差都较低, 其中 LightGBM 平均相对误差最低, XGBoost 的正确率紧跟其后, 这两个基学习器都属于 GBDT 的算法实现, XGBoost 的损失函数使用了二阶泰勒展开, 同时使用了一阶和二阶的导数信息, 而 GBDT 仅使用一阶泰勒展开, 因此在优化过程中, XGBoost 可以使得模型训练更

加充分。此外 LSTM、RF 平均相对误差都较低, 可以满足二次设备评估的要求。

### 3.2 基学习器关联度分析

除了基学习器的性能之外, 基学习器之间的相关性也会直接影响集成学习模型的最终评估能力, 因此需要尽可能加入差异性大的基学习器。为了能够挑选出最佳的基学习器组合, 本文采用了皮尔逊相关系数<sup>[24]</sup>来对各基学习器之间的差异度进行分析, 以此来衡量基学习器的相关性, 基学习器之间的相关性分析如图 11 所示。

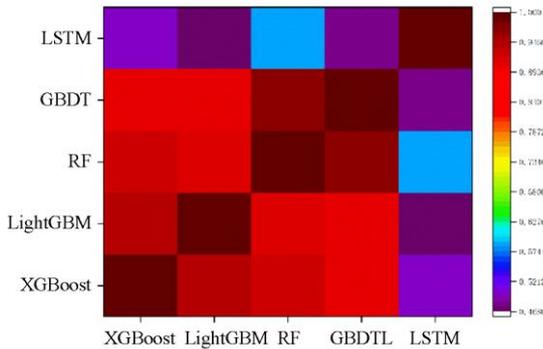


图 11 基学习器误差相关性分析

Fig. 11 Correlation of base learners error

由图 11 可知, 本文所使用的五个基学习器误差相关性较高, 其主要原因可以从几个方面来分析, 首先根据表 2 可知几个基学习器已经可以达到较高的正确率, 误差可能来自数据本身的固有误差, 这样容易引起误差相关性激增。其次除了 LSTM, 另外四种基学习器模型本身相似度很高, GBDT 和 RF 都是由大量的树组成, 区别在于树集成过程中分别使用了 boosting 和 bagging 的思想。而 XGBoost 和 LightGBM 又都属于 GBDT 的算法实现, 因此会存在较高的相似性。

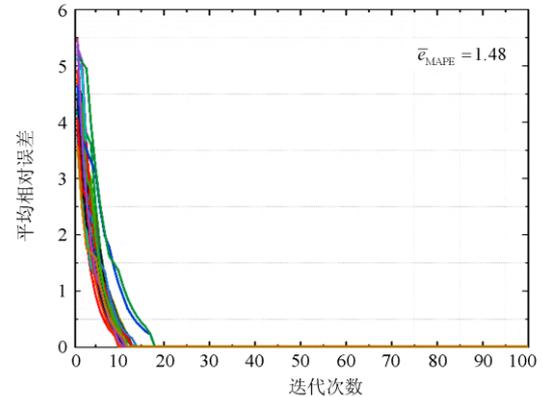
然而在本文所建立的集成学习模型并没有集成太多的基学习器, 同时这些基学习器都取得了较好的评估精度, 因而在本文中保留这些相关性较高的基学习器利远大于弊。

### 3.3 FCC 神经网络性能分析

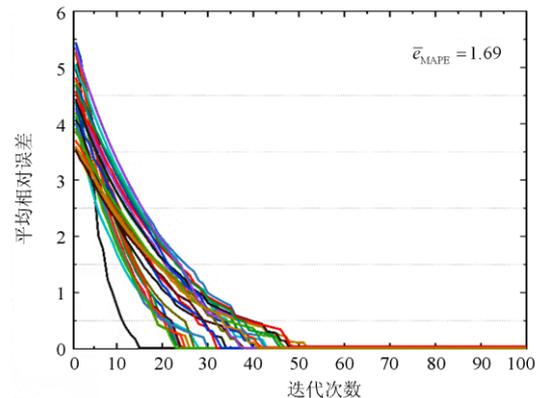
本文所建立的集成学习模型在第二层中使用 FCC 神经网络并利用改进的 LM 算法加速集成学习模型收敛, 为了验证改进 LM 算法对整个集成学习模型的影响, 本文分别测试了使用改进 LM 算法和普通 LM 算法情况下集成学习模型的平均相对误差结果如图 12 所示。

根据图 12 可知, 本文提出的改进 LM 算法不仅可以使得集成学习模型更加快速稳定地收敛, 而且

能够有效地提高集成学习的准确率。



(a) 使用改进 LM 算法的学习曲线



(b) 使用传统 LM 算法的学习曲线

图 12 不同算法下集成学习模型的学习曲线

Fig. 12 Learning curves of the ensemble learning model with different algorithms

### 3.4 集成学习模型评估性能分析

为了验证本文所建立的多模型融合集成学习模型的性能, 将文献[2]提出的梯形云方法(记作方法 T)、文献[8]提出的灰色理论和云模型方法(记作方法 C)、各基学习器与去除 LSTM 的集成学习模型(记作集成-L)、去除 GBDT 的集成学习模型(记作集成-G)、完整的集成学习模型进行对比分析, 考虑到评估的合理性, 在各个模型的训练过程中均采用了完整的训练集, 训练过程也彼此独立, 因此最终结果会与表 2 的结果略有不同。经过多次重复试验, 得到的各模型平均相对正确率分布如图 13 所示, 其中平均相对正确率可通过  $1 - e_{MAPE}$  计算得到。

由图 13 可知, 文献[2,8]中的方法都是基于云模型提出的, 其本质上是通过对矩阵建立了指标和评估状态的联系, 与后续各类基学习器有相似处, 然而在建立联系的过程中云模型的性能与其他方法有着较大的差距。

此外, 三个集成学习模型正确率都高于单独的

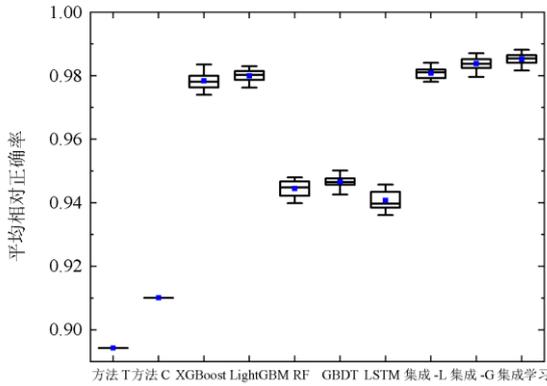


图 13 基学习器和集成学习平均相对正确率分布  
Fig. 13 Average relative accuracy distribution of base learners and ensemble learning

基学习器，从理论层面分析，多模型融合的集成学习模型充分可以发挥各个算法的自身优势，通过扬长避短充分获得更好的评估正确率。另一方面，二次设备评估指标数量多，彼此之间可能相互关联，会出现多种指标通过不同假设在空间上到达相同性能的可能性，本文所建立的多模型融合的集成学习模型可以有效解决单一模型泛化性能不佳的风险。除此之外，单一模型容易陷入局部最优解，而通过多模型的融合，集成学习算法可以很好地解决局部最优解的问题，从而提高整体评估性能。

对于三个集成模型做进一步分析可以发现，集成-L 模型与集成-G 模型都集成了四个模型，其中三个模型一致，第四个模型分别使用了 LSTM 和 GBDT，集成了 LSTM 的模型正确率明显高于集成 GBDT 的模型，同时集成 GBDT 的模型正确率和 XGBoost 以及 LightGBM 这两个高性能模型相差无几，其原因在于 LSTM 模型和其他四个模型差异度高，而 GBDT 差异度小，虽然 LSTM 单独的精度并不高，但是其差异化给集成模型带来更高的正确率提升，该结论与前文中的数学推导结果一致。此外集成了 5 个模型的集成学习模型正确率最高，因此可以知道在资源允许的条件下尽可能多地集成各类有效的基学习器，在条件不足的情况下应尽可能选择相关性小的基学习器进行集成。

#### 4 结论

为了解决智能变电站二次设备评估问题，本文根据其二次设备的特点，制定了全面的二次设备评估指标体系，并提出了一种基于多模型融合集成学习的二次设备状态评估方法，利用该方法可以综合多种基学习器的评估能力，扬长避短，获得更好的

评估效果。通过算例分析可知，集成学习可以获得比单一模型更好的评估能力，在选择基学习器方面应选择相关度较低的基学习器。本文所建立的集成了 XGBoost、LightGBM、RF、GBDT、LSTM 并结合改进 LM 算法来帮助 FCC 神经网络训练的集成学习模型可以非常好地实现二次设备的状态评估，在智能变电站二次设备评估方面有着较高的应用价值。

#### 参考文献

- [1] 方景辉. 智能变电站构架及一体化平台应用研究[D]. 北京: 华北电力大学, 2016.  
FANG Jinghui. Application research in integrated in formation platform and framework design for smart substation[D]. Beijing: North China Electric Power University, 2016.
- [2] 王月月, 陈民铀, 姜振超, 等. 基于云理论的智能变电站二次设备状态评估[J]. 电力系统保护与控制, 2018, 46(1): 71-77.  
WANG Yueyue, CHEN Minyou, JIANG Zhenchao, et al. A state assessment method for secondary equipment in intelligent substation based on cloud model[J]. Power System Protection and Control, 2018, 46(1): 71-77.
- [3] 曹楠, 王芝茗, 李刚, 等. 智能变电站二次系统动态重构初探[J]. 电力系统自动化, 2014, 38(5): 113-121.  
CAO Nan, WANG Zhiming, LI Gang, et al. Study on dynamic reconfiguration in secondary system of intelligent substation[J]. Automation of Electric Power Systems, 2014, 38(5): 113-121.
- [4] 王利平, 庞晓艳, 朱雨, 等. 基于物联网和移动互联网的二次设备运维技术研究与应用[J]. 中国电力, 2019, 52(3): 177-184.  
WANG Liping, PANG Xiaoyan, ZHU Yu, et al. Research and application of intelligent maintenance system based on internet of things and mobile internet technology[J]. Electric Power, 2019, 52(3): 177-184.
- [5] 黄晓明, 黄志华, 张华娇, 等. 变电站整站二次设备就地化及运维方案研究[J]. 电力系统保护与控制, 2019, 47(5): 173-178.  
HUANG Xiaoming, HUANG Zhihua, ZHANG Huajiao, et al. Research on the localization and maintenance scheme of secondary equipment in substation[J]. Power System Protection and Control, 2019, 47(5): 173-178.
- [6] SWAGATA D, SUNDARAVARADAN N A, SURYA S. Relay performance verification using fault event records[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 226-235. DOI: 10.1186/s41601-018-0094-0.
- [7] 陈安伟. 智能电网技术经济综合评价研究[D]. 重庆: 重庆大学, 2012.  
CHEN Anwei. Research on the technical economic problems of the smart grid[D]. Chongqing: Chongqing University, 2012.
- [8] 叶远波, 谢民, 黄太贵, 等. 基于灰色理论和云模型的智能变电站二次设备状态评估方法[J]. 电力系统保护

- 与控制, 2019, 47(9): 105-111.
- YE Yuanbo, XIE Min, HUANG Taigui, et al. A state assessment method for intelligent substation secondary equipment based on grey theory and cloud model[J]. Power System Protection and Control, 2019, 47(9): 105-111.
- [9] 高峰. 大中型水电站二次设备状态评估探索和实践[C] // 2012 年中国电机工程学会年会, 2012.
- GAO Feng. Exploration and practice on condition assessment of secondary equipment in large and medium sized hydropower stations[C] // 2012 Annual Meeting of China Society of Electrical Engineering, 2012.
- [10] 张晓瑞, 纪陵, 檀庭方, 等. 智能变电站二次设备在线故障运维平台架构研究[J]. 华电技术, 2019, 41(2): 1-5, 13.
- ZHANG Xiaorui, JI Ling, TAN Tingfang, et al. Intelligent substation secondary equipment online fault operation and maintenance platform architecture research[J]. Huadian Technology, 2019, 41(2): 1-5, 13.
- [11] 苗红霞, 萧旋旋, 江冰, 等. 基于信息融合的预装式变电站健康状态评估[J]. 电力系统保护与控制, 2017, 45(14): 85-91.
- MIAO Hongxia, XIAO Xuanxuan, JIANG Bing, et al. State evaluation of prefabricated substation based on information fusion[J]. Power System Protection and Control, 2017, 45(14): 85-91.
- [12] 丁雪梅. 电力二次设备的故障预测与健康关键技术研究与应用[D]. 沈阳: 中国科学院大学(中国科学院沈阳计算技术研究所), 2018.
- DING Xuemei. Research and application of key technologies of fault forecast and health management[D]. Shenyang: University of Chinese Academy of Sciences (Shenyang Institute of Computing Technology of Chinese Academy of Sciences), 2018.
- [13] 马博, 董海鹰, 任伟. 基于模糊综合支持向量机的特高压变电站二次设备状态评估[J]. 计算机系统应用, 2014, 23(9): 191-197.
- MA Bo, DONG Haiying, REN Wei. Status assessment of UHV substation secondary equipment based on fuzzy comprehensive support vector machine method[J]. Computer Systems & Applications, 2014, 23(9): 191-197.
- [14] 易鸣. 牵引变电所二次设备故障在线诊断及预警[D]. 湘潭: 湖南科技大学, 2017.
- YI Ming. Online diagnosis and early warning of secondary equipment fault of traction substation[D]. Xiangtan: Hunan University of Science and Technology, 2017.
- [15] 马博. 750 kV 变电站二次设备智能评估专家系统设计研究[D]. 兰州: 兰州交通大学, 2014.
- MA Bo. Design and research of 750 kV substation secondary equipment intelligent assessment expert system[D]. Lanzhou: Lanzhou Jiaotong University, 2014.
- [16] 王俏文, 丁坚勇, 陶文伟, 等. 基于层次分析模型的二次设备状态检修方法[J]. 南方电网技术, 2013, 7(4): 97-102.
- WANG Qiaowen, DING Jianyong, TAO Wenwei, et al. A condition-based maintenance method of secondary electrical equipments based on hierarchy model[J]. Southern Power System Technology, 2013, 7(4): 97-102.
- [17] 周炎涛, 向升, 吴正国. RBF 神经网络在电气设备状态评估中的应用[J]. 航空计算技术, 2005(3): 1-4.
- ZHOU Yantao, XIANG Sheng, WU Zhengguo. The application of RBF neural network in postural evaluations of electric equipments[J]. Aeronautical Computer Technique, 2005(3): 1-4.
- [18] 高翔. 智能变电站技术[M]. 北京: 中国电力出版社, 2012.
- [19] 侯文瑞, 蒋祖华, 金玉兰. 基于相对劣化度的视情维修决策模型[J]. 上海交通大学学报, 2008, 42(7): 1090-1094.
- HOU Wenrui, JIANG Zuhua, JIN Yulan. Relative-deterioration degree based policy research of condition-based maintenance[J]. Journal of Shanghai Jiaotong University, 2008, 42(7): 1090-1094.
- [20] TANG B, CHEN Q, WANG X, et al. Reranking for stacking ensemble learning[C] // International Conference on Neural Information Processing: Theory & Algorithms, Springer-Verlag, 2010.
- [21] ROONEY N, PATTERSON D, NUGENT C. Reduced ensemble size stacking [ensemble learning][C] // 16th IEEE International Conference on Tools with Artificial Intelligence, November 15-17, 2004, Boca Raton, FL, USA.
- [22] 林正根, 姚杰, 庄柯, 等. 基于 PCA-LMBP 神经网络模型的 SCR 脱硝催化剂工艺特性预测[J]. 热力发电, 2019, 48(11): 108-114.
- LIN Zhenggen, YAO Jie, ZHUANG Ke, et al. Process characteristics forecasting for SCR denitration catalyst based on PCA-LMBP neural network model[J]. Thermal Power Generation, 2019, 48(11): 108-114.
- [23] FAN J, PAN J. On the convergence rate of the inexact Levenberg-Marquardt method[J]. Journal of Industrial & Management Optimization, 2017, 7(1): 199-210.
- [24] 肖勇, 赵云, 涂治东, 等. 基于改进的皮尔逊相关系数的低压配电网拓扑结构校验方法[J]. 电力系统保护与控制, 2019, 47(11): 37-43.
- XIAO Yong, ZHAO Yun, TU Zhidong, et al. Topology checking method for low voltage distribution network based on improved Pearson correlation coefficient[J]. Power System Protection and Control, 2019, 47(11): 37-43.

收稿日期: 2020-08-13; 修回日期: 2020-10-18

作者简介:

叶远波(1973—), 男, 硕士, 教授级高级工程师, 研究方向为电力系统自动化; E-mail: yeyb7079@ah.sgcc.com.cn

黄太贵(1963—), 男, 硕士, 教授级高级工程师, 从事电力系统自动化专业运行管理和研究工作;

谢氏(1975—), 男, 硕士, 高级工程师, 从事电力系统继电保护专业运行管理和研究工作。

(编辑 张爱琴)