

DOI: 10.19783/j.cnki.pspc.210783

基于 CNN-GRU 组合神经网络的变压器短期故障预测方法

杨威¹, 蒲彩霞¹, 杨坤², 张安安¹, 曲广龙¹

(1. 西南石油大学, 四川 成都 610500; 2. 国网四川省电力公司广元供电公司, 四川 广元 628000)

摘要: 为挖掘变压器运行状态参量间的关联关系, 量化外部环境对变压器运行状态的影响, 提出了一种基于卷积神经网络和门控循环单元组合神经网络的变压器短期故障预测方法。首先, 通过关联规则挖掘变压器状态参量间的相关性, 结合变权思想进行综合状态评估, 引入指数函数建立表征变压器运行状态的故障率模型, 并将其作为预测状态参量。其次, 考虑外部环境对变压器运行状态的影响, 分别从日期因素、气象因素和生产工艺因素构建变压器故障预测特征集。然后, 利用卷积神经网络在高维空间提取特征集与故障率间的特征向量, 将结果输入门控循环单元进行优化训练, 从而预测变压器故障率的发展趋势。最后, 通过某海上平台变压器的故障预测趋势分析, 验证了所提方法的可行性与有效性。该方法与长短期记忆模型、GRU 模型、CNN-LSTM 模型和支持向量机模型相比, 具有更高的预测精度与更高的预测效率。

关键词: 变压器; 状态参量; 故障预测; 卷积神经网络; 门控循环单元

Short-term fault prediction method for a transformer based on a CNN-GRU combined neural network

YANG Wei¹, PU Caixia¹, YANG Kun², ZHANG An'an¹, QU Guanglong¹

(1. Southwest Petroleum University, Chengdu 610500, China; 2. Guangyuan Power Supply Company, State Grid Sichuan Electric Power Company, Guangyuan 628000, China)

Abstract: To explore the relationship between transformer state parameters and quantify the impact of the external environment on a transformer, this paper proposes a short-term fault prediction method for a transformer based on a convolution neural network (CNN) and gating cycle unit combined neural network (GRU). First, mining the correlation between transformer state parameters through association rules, and incorporating variable weight method to evaluate the status of the transformer, an exponential function is introduced to establish the fault rate model representing the operational state of the transformer. This is used as the prediction state parameter. Secondly, considering the influence of the external environment on the operational status of the transformer, a fault prediction feature set is constructed based on the date, meteorological and production process factors. Then, the convolution neural network extracts the feature vectors between the feature set and the fault rate in the high-dimensional space, and inputs the result into the gating cycle unit for optimization training, so as to predict the development trend of the transformer fault rate. Finally, the feasibility and effectiveness of the proposed method are verified by the fault prediction trend analysis of a transformer on an offshore platform. Compared with the long short-term memory (LSTM), GRU, CNN-LSTM and support vector machine models, the proposed method has higher prediction accuracy and higher prediction efficiency.

This work is supported by the Science and Technology Planning Project of Sichuan Province (No. 2019YJ0279, No. 2020YFSY0037, and No. 2020YFQ0038).

Key words: transformer; state parameter; fault prediction; convolutional neural network; gating cycle unit

0 引言

变压器作为电力系统的核心电力设备之一, 其

运行状态直接关系到电网运行的可靠性与安全性, 变压器故障预测对于掌握变压器运行状态发展趋势、实现风险预警以及维修决策具有重要意义^[1-5]。国内外学者对变压器故障预测技术进行了深入研究, 主要通过对油中溶解气体、顶层油温、绕组温度和绕组振动信号等单一或少数状态参量进行预

基金项目: 四川省科技计划项目资助(2019YJ0279, 2020YFSY0037, 2020YFQ0038)

测,从而实现变压器故障预测的目的^[6-10]。文献[11]采用云模型对油中溶解气体样本数据进行训练,构建油中气体状态空间,基于变压器运行状态变化规律分析引入老化因子,构建加权半 Markov 退化模型对变压器运行状态进行预测。文献[12]根据油路结构特点和绕组冷却分析,建立了变压器流体网络模型,局部采用计算流体力学方法计算流场,求解得到变压器绕组温度。上述研究仅考虑了预测状态参量本身的历史数据,忽略了状态参量众多关联因素的影响,无法准确预测潜伏性故障。

考虑到预测参量间的相关性,文献[13]收集与变压器油中溶解气体相关的多维度影响因素数据,采用灰色关联分析提取关键预测输入参量,建立基于邻近算法的多因素预测模型,提升了预测精度。文献[14]采用云模型挖掘状态参量与不同状态间的关联规则,构建变压器状态转移矩阵,并建立修正因子体系对状态转移矩阵进行修正,实现变压器故障预测。由于以单一状态参量为输出的预测模型对变压器整体发展趋势的反映不够直观,文献[15-16]选择将能够代表变压器整体运行状态的健康指数及故障率等指标作为预测模型输出,能够为后续维修决策提供直观的参考信息。随着变压器状态参量以及相关外部环境等数据的大规模累积增多,常用数据挖掘算法工作计算量大^[17-18],实现复杂。文献[19]利用长短期记忆(Long Short-Term Memory, LSTM)神经网络自动提取变压器特征状态参量间的关联关系,并挖掘其与未来状态量之间的趋势联系,获取预测模型最优参数提高预测精度。LSTM 需要较多训练参数,且模型收敛速度较慢,门控循环单元(Gated Recurrent Unit, GRU)作为 LSTM 的一种优化网络,在保证较高预测精度的同时可有效缩短模型的训练时间^[20]。然而,GRU 网络不能充分挖掘非连续特征在高维空间中的联系,因此需要结合其他网络来提高对故障预测特征向量的数据挖掘能力。

鉴于此,本文提出了一种基于 CNN-GRU 组合神经网络的变压器短期故障预测方法。首先,采用关联规则结合变权综合思想进行变压器状态评估,引入指数模型得到故障率作为预测模型的预测状态参量,预测结果能够直观体现变压器的整体发展趋势;其次,分析影响变压器运行状态的外部环境因素,构建故障预测特征集,量化外部环境对变压器运行状态的影响;然后,采用卷积神经网络(Convolutional Neural Network, CNN)深度挖掘特征集与故障率间的内在联系,将结果输入到 GRU 循环神经网络进行训练,得到变压器故障率预测结果。最后以某海上平台变压器为例进行了算例分析,验

证了本文所提方法的可行性与有效性。

1 变压器短期故障预测模型框架

基于 CNN-GRU 组合神经网络的变压器短期故障预测方法框架如图 1 所示。建立变压器状态评估指标体系,将关联规则和变权综合思想有机地结合,通过状态评估得到表征变压器整体运行状态的故障率,并作为预测状态参量;为量化外部环境对变压器故障预测的影响,构建变压器故障预测特征集,采用 CNN 神经网络在高维空间提取多维特征向量,将结果输入到 GRU 循环神经网络,得到变压器未来短期的故障率变化趋势。

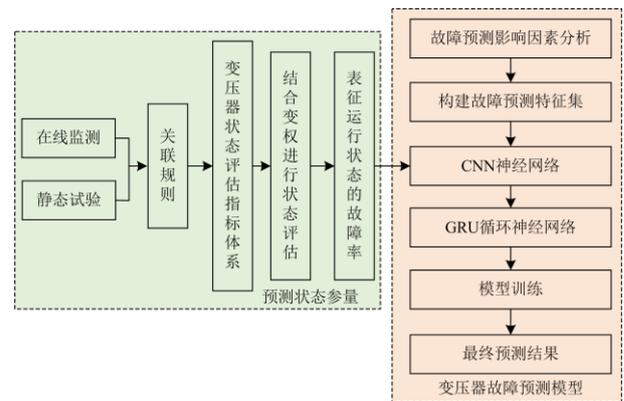


图 1 基于 CNN-GRU 组合神经网络的变压器短期故障预测方法框架

Fig. 1 Short-term fault prediction method framework for transformer based on CNN-GRU combined neural network

2 基于状态评估的变压器故障率模型

为使预测结果能够直观反映变压器状态的整体发展趋势,通过状态评估得到故障率作为模型的预测状态参量。

2.1 状态评估指标体系

反映变压器运行状态的指标量众多^[21],通过分析变压器的历史试验、检修及故障数据,结合国家电网公司发布的《油浸式变压器(电抗器)状态评价导则(Q/GDW 169—2008)》^[22],按照数据来源将影响变压器运行状态的指标分为在线监测和静态试验两类,采用关联规则确定综合状态量对应的评估指标,所建立的变压器状态评估指标体系如附图 1 所示,综合状态量对应评估指标如附表 1 所示。

2.2 变压器综合状态评估

1) 单项评估指标分值计算

依据关联规则的相关定义,可得到评估指标的支持度与置信度的数学表达式为

$$Z_{ij} = P(A_{ij} \cup B_i) = \frac{\sigma(A_{ij} \cup B_i)}{|B_i|} \times 100\% \quad (1)$$

$$C_{ij} = \frac{P(A_{ij} \cup B_i)}{P(A_{ij})} = \frac{\sigma(A_{ij} \cup B_i)}{\sigma(A_{ij})} \times 100\% \quad (2)$$

式中: Z_{ij} 与 C_{ij} 分别表示第 i 项综合状态量中第 j 项评估指标的支持度与置信度; A_{ij} 表示第 i 项综合状态量中第 j 项评估指标超标的相关项集合; B_i 表示第 i 项综合状态量发生时的相关项集合。支持度越接近 1, 表明综合状态量与评估指标关联程度越高^[21]。

根据式(2)可得评估指标的权重系数的数学表达式为

$$\delta_{ij} = \frac{C_{ij}}{C_{i1} + C_{i2} + \dots + C_{im_i}} \quad (3)$$

式中: δ_{ij} 表示第 i 项综合状态量第 j 项评估指标的权重系数; m_i 表示第 i 项综合状态量中包含的评估指标个数。

根据评估导则和实际工程情况, 评估指标的评分计算公式为

$$g_{ij} = \frac{y_e - y_{ij}}{y_e - y_f} \times 100 \quad (4)$$

式中, g_{ij} 、 y_e 、 y_f 、 y_{ij} 分别表示该第 i 项综合状态量中第 j 项评估指标的评分值、注意值、初始值和监测值。当 $g_{ij} < 0$ 时, 令 $g_{ij} = 0$; 当 $g_{ij} > 0$ 时, 令 $g_{ij} = 100$ 。

2) 综合状态量分值计算

根据评估指标的评分值与权重系数可得综合状态量的评分值为

$$g_i = \sum_{j=1}^{m_i} g_{ij} \delta_{ij} \quad (5)$$

式中, g_i 表示第 i 项综合状态量的评分值。

为解决变压器评估指标劣化不均衡问题, 采用变权重理论结合均衡函数来计算综合状态量的变权重系数^[23], 其数学表达式为

$$\delta_i^v = \frac{\delta_i g_i^{\alpha-1}}{\sum_{p=1}^q \delta_p g_p^{\alpha-1}} \quad (6)$$

式中: δ_i^v 表示变权重系数; q 表示评估体系中包含的综合状态量个数; δ_i 表示综合状态量的常权重系数, 一般取 $\delta_i = 1/q$; α 表示均衡函数, 取决于 F_i 的相对重要程度。

根据各项综合状态量评分以及对应变权重系数, 得到变压器综合状态评估评分值为

$$H = \sum_{i=1}^q g_i \delta_i^v \quad (7)$$

式中, H 表示变压器综合状态评估评分值。

2.3 变压器故障率模型

变压器故障率与运行状态符合指数分布^[24], 依据前文所得到的 H 可得到表征变压器运行状态的故障率模型的数学表达式为

$$\lambda = Ke^{CH} + \zeta \quad (8)$$

式中: λ 表示变压器故障率; C 表示曲率系数; K 表示比例系数; ζ 表示随机事件引起的变压器偶然故障率。

3 基于 CNN-GRU 组合神经网络的变压器故障预测

3.1 神经网络原理

1) CNN 神经网络

CNN 是一种前馈型神经网络, 广泛应用于深度学习领域, 主要由卷积层、池化层和全连接层组成, 输入特征向量可以为多维向量组, 采用局部感知和权值共享的方式。卷积层对原始数据提取特征量, 深度挖掘数据的内在联系, 池化层能够降低网络复杂度、减少训练参数, 全连接层将处理后的数据进行合并, 计算分类和回归结果^[25]。

2) GRU 循环神经网络

GRU 是 LSTM 的一种改进模型, 将遗忘门和输入门集成为单一的更新门, 同时混合了神经元状态和隐藏状态, 可有效地缓解循环神经网络中“梯度消失”的问题^[26], 并能够在保持训练效果的同时减少训练参数^[27], 其门控单元结构如图 2 所示。

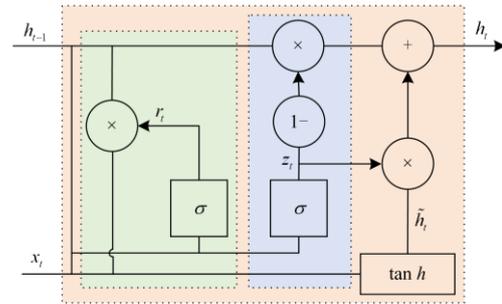


图 2 门控单元结构

Fig. 2 Structure of gate control unit

3.2 变压器故障预测特征集的构建

合理构建预测特征集对模型预测的精度和收敛性至关重要。分析变压器的运行特征, 影响变压器运行状态的外部环境因素主要是日期因素、气象因素和生产工艺因素, 据此本文构建的变压器故障预

测特征集包括以下 3 个因素。

1) 日期因素：主要考虑季节、节假日等日期因素对电力系统的生产工况具有较大影响，据此构建包括季节、月、日、周、节假日的 5 维日期特征集。

2) 气象因素：主要考虑天气类型、风力等气候因素的变化对变压器故障预测的影响，主要包括天气类型、风力类型、最高湿度、最低湿度、最高温度、最低温度的 6 维气候特征集。

3) 生产工艺因素：主要考虑生产工况对变压器运行状态的影响，构建包括电负荷、热负荷和伴生气产量的 3 维生产工艺特征集。

综上所述，本文构造了包含日期因素、气象因素、生产工艺因素在内的 14 维特征向量作为预测模型的输入，具体特征描述如表 1 所示。

表 1 变压器故障预测特征集

Table 1 Feature set of transformer fault prediction

影响因素	特征类型	特征描述
日期因素	季节	1~4 分布表示春、夏、秋、冬
	月	1~12 分布表示 1 月到 12 月
	日	1~31 分布表示 1 号到 31 号
	周	1~7 分布表示周一到周日
	节假日	1 与 0 分别表示节假日和非节假日
气象因素	天气类型	1~3 分别代表一级(大雨、大雪)、二级(小雨、小雪)、三级(晴天、阴天)
	风力类型	1~3 分别代表微风(风速小于 4 级)、中风(风速 4~8 级)、大风(风速大于 8 级)
	最高湿度	当日的最高湿度值, RH%
	最低湿度	当日的最低湿度值, RH%
	最高温度	当日的最高温度值, °C
	最低温度	当日的最低温度值, °C
生产工艺因素	电负荷	1 与 0 分别表示电负荷需求增加和减少
	热负荷	1 与 0 分别表示电负荷需求增加和减少
	伴生气产量	1 与 0 分别表示伴生气产量增加和减少

3.3 预测模型

在构建变压器故障预测特征集的基础上，为了充分挖掘多个非连续特征在高维空间中的内在联系，首先通过 CNN 神经网络对特征集与故障率进行特征提取，挖掘故障预测特征集与故障率间的内在联系，构建时间序列的一维特征向量，输入到 GRU 循环神经网络中进行优化训练，得到最终变压器故障率预测结果输出，预测模型训练流程如图 3 所示。

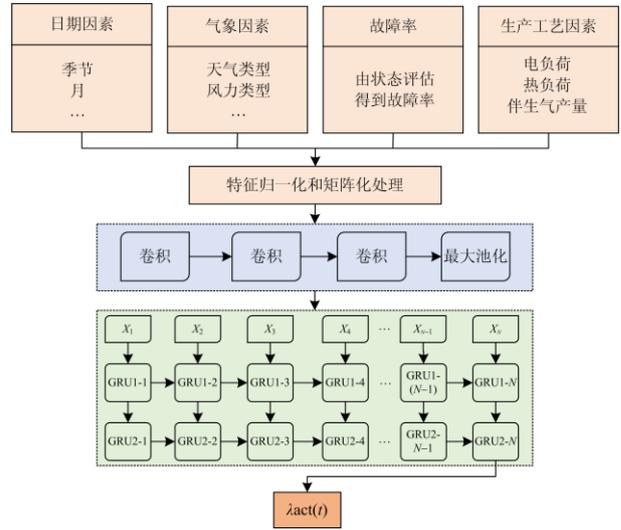


图 3 CNN-GRU 组合神经网络预测模型训练流程图

Fig. 3 Training flow chart of CNN-GRU combined neural network prediction model

3.4 预测流程

1) 数据归一化处理

为了解决输入数据的不同量纲与数值差异较大带来的不良影响，在预测之前需要将训练数据集进行归一化处理，以数据集的最大值和最小值为基准，对数据进行归一化处理，其数学表达式为

$$D_n = \frac{D - D_{\min}}{D_{\max} - D_{\min}} \quad (9)$$

式中： D_n 为归一化处理后的数据； D 为处理前的数据； D_{\max} 、 D_{\min} 分别为训练数据集中各类数据的最大值和最小值。

2) 模型训练

CNN 神经网络由 3 层卷积层与 1 层池化层构成，卷积核数目依次为 8、16、32，卷积步长为 1，卷积方式选取 same 卷积，激活函数选用 relu 函数，经过 3 次连续卷积后进行 Valid 最大池化，最终得到 n 个长度为 288 的一维向量，输入到 GRU 循环神经网络。GRU 循环神经网络对提取到的特征向量进行学习，构建 2 层 GRU 结构能够达到最好的预测效果，激活函数采用 relu 激活函数，最后将全连接层的输出经过反归一化得最终预测故障率值。在 GRU 循环神经网络进行训练时，采用 Adam 算法迭代更新权重^[28]，通过动量和自适应学习率不断更新各个神经元的权重和偏差，使得损失函数的输出值达到最优，模型损失函数的数学表达式为

$$F_{\text{loss}} = \frac{1}{n} \sum_{t=1}^n (\lambda_{\text{act}}(t) - \lambda_{\text{pred}}(t))^2 \quad (10)$$

式中: F_{loss} 表示预测模型的损失函数; n 表示训练样本个数; $\lambda_{\text{act}}(t)$ 和 $\lambda_{\text{pred}}(t)$ 分别表示 t 时刻实际故障率和预测故障率。

3) 预测评价指标

为对 CNN-GRU 组合神经网络模型的预测精度进行评估, 本文选取预测误差最大百分比 $\sigma_{\text{E-max}}$ 、预测精度平均值 $\sigma_{\text{FA-arg}}$ 和平均绝对百分比误差 σ_{MAPE} 作为评价标准指标, 其数学表达式为

$$\sigma_{\text{E-max}} = \max\left(\frac{|\lambda_{\text{act}}(t) - \lambda_{\text{pred}}(t)|}{\lambda_{\text{act}}(t)}\right) \times 100\% \quad (11)$$

$$\sigma_{\text{FA-arg}} = \frac{1}{n} \sum_{t=1}^n \left(1 - \frac{|\lambda_{\text{act}}(t) - \lambda_{\text{pred}}(t)|}{\lambda_{\text{act}}(t)}\right) \times 100\% \quad (12)$$

$$\sigma_{\text{MAPE}} = \frac{1}{n} \sum_{t=1}^n \frac{|\lambda_{\text{act}}(t) - \lambda_{\text{pred}}(t)|}{\lambda_{\text{act}}(t)} \times 100\% \quad (13)$$

为比较不同应用场景及预测模型的预测效率, 本文选择训练时间 t_r 和调试时间 t_q 作为预测效率评价标准, 将损失函数衰减为稳定值作为终止条件。

4 算例分析

4.1 数据选择

为验证本文所建立故障预测模型与方法的可行性与准确性, 选取渤海某海上油气平台 2017—2018 年变压器的历史故障数据、环境气象数据和在线监测数据等信息, 设计不同场景及模型对该平台变压器进行故障预测, 并将预测结果与实际运行情况进行对比分析。

以一台型号为 SZ-120000/220 的变压器为例, 根据 2017 年 1 月 1 日到 2018 年 12 月 30 日的型号相同、运行环境相似的变压器历史故障数据、环境气象数据和在线监测数据等信息, 每隔 30 min 采集一次数据, 对变压器进行状态评估得到变压器故障率数据, 将故障率与特征集数据进行归一化与矩阵化处理之后, 组成输入特征矩阵作为故障预测模型的输入, 按照 7:3 分为训练集与测试集。

4.2 基于状态评估的故障率分析

本文选取了与被测变压器型号相同、运行环境相似的 1 112 组故障样本数据信息, 采用关联规则计算各评估指标支持度, 仿真结果如附表 2 所示。由附表 2 可知, 本文所建立评估指标体系各评估指标的支持度都在 0.832 1 以上, 且大多数都接近于 1, 表明建立的变压器状态评估指标体系较为合理。根据历史故障数据, 拟合可得 $C=-0.069$, $K=0.012 1$,

$\xi=0.000 5$, 则该变压器的故障率模型为

$$\lambda = 0.0121e^{-0.069H} + 0.0005$$

λ 作为表征变压器运行状态的故障率, 能够量化变压器的运行状态, 据此按照 λ 的大小划分变压器运行状态等级, 对应的维修决策如表 2 所示。

表 2 状态等级与维修决策

故障率	运行状态等级	维修决策
$5.12 \times 10^{-4} \leq \lambda < 5.48 \times 10^{-4}$	良好	照常检修
$5.48 \times 10^{-4} \leq \lambda < 6.93 \times 10^{-4}$	正常	加强监视
$6.93 \times 10^{-4} \leq \lambda < 3.54 \times 10^{-3}$	异常	提前检修
$3.54 \times 10^{-3} \leq \lambda < 12.6 \times 10^{-3}$	严重	立即检修

2018 年 6 月 14 日该变压器各评估指标的初始值、注意值和监测值如附表 3 所示, 取 $\delta_i = 1/9$ 、 $\alpha = 0$, 通过计算得到评估指标得分、综合状态量得分和变权重系数如表 3 所示, 可得变压器最终评分 $H = 50.671 9$, 依据该变压器的故障率模型得到 $\lambda = 8.667 2 \times 10^{-4}$, 属于异常运行状态。

4.3 变压器故障预测分析

为了进一步了解该变压器未来短期的运行状态演变趋势, 依据本文所构建的故障预测特征集, 设置以下 4 种不同场景进行变压器故障预测。

场景 1: 不考虑生产工艺与气象因素对变压器运行状态的影响。

场景 2: 不考虑生产工艺因素对变压器运行状态的影响。

场景 3: 不考虑气象因素对变压器运行状态的影响。

场景 4: 同时考虑气象因素与生产工艺因素对变压器运行状态的影响。

鉴于日期因素直接影响到电力系统的生产工况, 因此在设置应用场景时将日期因素作为生产工艺因素的一部分。通过对该变压器 6 月 1 日到 6 月 14 日的运行数据进行状态评估, 得到故障率数据集, 在 4 种应用场景下变压器故障率预测结果如图 4 所示。

对 4 种场景下的预测曲线计算预测误差最大百分比 $\sigma_{\text{E-max}}$ 、预测精度平均值 $\sigma_{\text{FA-arg}}$ 和平均绝对百分比误差 σ_{MAPE} 、训练时间 t_r 和调试时间 t_q , 对比结果如表 4 所示。由表 4 可知, 场景 4 的预测误差最大百分比相比较其他 3 种应用场景分别下降了 39.88%、17.37% 和 4.08%, 预测精度平均值分别提高了 20.89%、11.1% 和 3.57%, 绝对百分比误差分别下降了 20.64%、11.39% 和 3.63%, 且场景 4 的训练与调试时间更短, 具有更高的预测效率。

表 3 状态评估表

Table 3 Condition assessment form

综合状态量	评估指标	评估指标评分值	综合状态量分值	变权重系数
F_1	[$S_{11} S_{21} S_{22} S_{23} S_{24} S_{25} S_{26} S_{28}$]	[25.94 74.47 28.97 38.87 61.00 80.00 48.31 80.92]	58.961 2	0.095 5
F_2	[$S_{14} S_{15} S_{27} S_{28}$]	[83.66 82.11 66.67 80.92]	76.620 7	0.073 5
F_3	[$S_{14} S_{17} S_{18} S_{213}$]	[83.66 81.54 63.08 26.19]	68.079 6	0.082 7
F_4	[$S_{11} S_{29} S_{214} S_{216}$]	[25.94 40.23 93.10 92.73]	76.553 7	0.073 5
F_5	[$S_{11} S_{13} S_{16} S_{22} S_{211} S_{213}$]	[25.94 27.12 20.69 28.97 11.61 26.19]	22.871 1	0.246 2
F_6	[$S_{12} S_{16} S_{21} S_{26} S_{215}$]	[83.08 20.69 74.47 48.31 96.09]	73.289 8	0.076 8
F_7	[$S_{11} S_{12} S_{211} S_{213}$]	[25.94 83.08 11.61 26.19]	37.449 7	0.150 3
F_8	[$S_{16} S_{21} S_{26} S_{29} S_{210} S_{212}$]	[20.69 74.47 48.31 40.23 85.19 80.77]	65.688 1	0.085 7
F_9	[$S_{16} S_{21} S_{22} S_{23} S_{26} S_{28}$]	[20.69 74.47 28.97 38.87 48.31 80.92]	48.647 0	0.115 7

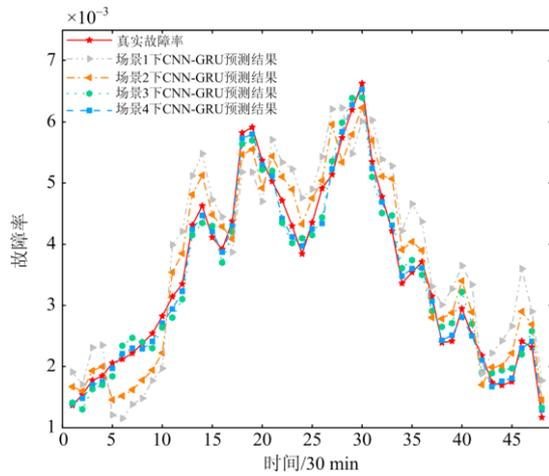


图 4 不同场景下 CNN-GRU 预测模型预测曲线

Fig. 4 Prediction curve of CNN-GRU prediction model in different scenarios

表 4 不同场景下 CNN-GRU 预测模型预测精度与效率比较

Table 4 Comparison of prediction accuracy and efficiency of CNN-GRU prediction model in different scenarios

场景	$\sigma_{E-max}/\%$	$\sigma_{FA-arg}/\%$	$\sigma_{MAPE}/\%$	t_t/s	t_q/s
1	52.22	76.22	24.02	168.47	0.96
2	29.71	86.01	14.77	139.08	0.73
3	16.42	93.54	7.01	114.36	0.49
4	12.34	97.11	3.38	93.11	0.31

与场景 1 的预测结果相比, 场景 2、场景 3 和场景 4 的预测精度和效率都更高, 说明气象和生产工艺因素都对变压器运作状态具有较大的影响, 不可忽略。与场景 3 相比, 场景 2 的预测精度与效率更低, 可见在此运行环境下, 生产工艺因素对变压器运行状态的影响更大。

在此基础上, 分别采用本文所提出的 CNN-GRU 组合神经网络模型与 GRU 模型、CNN-LSTM 模型、LSTM 模型和 SVM 模型, 在本文所建立的故障预测特征集(场景 4)的基础上, 得到该变压器在不同预测模型下故障率的演变趋势如图 5 所示。

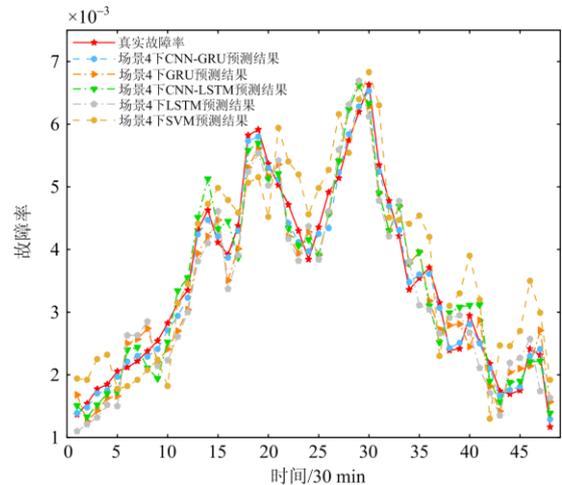


图 5 场景 4 下不同模型预测曲线

Fig. 5 Prediction curves of different models in scenario 4

由表 5 可知, 与传统 GRU、CNN-LSTM、LSTM 和 SVM 模型相比, 本文所提出的 CNN-GRU 组合神经网络模型预测误差最大百分比分别下降了 22.67%、27.32%、52.17%, 预测精度平均值分别提高了 9.86%、12.84%、18.82%, 绝对百分比误差分别下降了 9.88%、12.35%、17.79%。与 CNN-LSTM 模型相比, 在模型训练与调试时间几乎相同的基础上, 本文所提出的模型具有更高的预测精度, 极大地提升了预测效率。

表 5 场景 4 下不同模型预测精度与效率比较

Table 5 Comparison of prediction accuracy and efficiency of different models in scenario 4

预测模型	$\sigma_{E-max}/\%$	$\sigma_{FA-arg}/\%$	$\sigma_{MAPE}/\%$	t_r/s	t_q/s
CNN-GRU	12.34	97.11	3.38	93.11	0.31
GRU	35.01	87.25	13.26	112.78	0.39
CNN-LSTM	27.49	89.25	10.74	96.33	0.37
LSTM	39.66	84.27	15.73	135.03	0.52
SVM	64.51	78.83	21.17	166.73	0.88

综合图 4 与图 5 可知, CNN-GRU 组合神经网络模型能够充分挖掘多个非连续特征与故障率间的内在联系, 提高预测精度与效率。考虑气象因素能量化变压器潜在偶然故障的影响, 考虑生产工艺因素能量化变压器所处复杂耦合物质能量流对其运行状态的影响, 同时考虑两种因素具有更好的预测效果。该变压器在 6 月 15 日运行情况发生两次较大波动, 在 15:00 采取检修措施之后, 变压器的运行状态回到正常范围, 从而预防了变压器故障发生。

5 结论

提出了一种基于 CNN-GRU 组合神经网络的变压器短期故障预测方法, 以故障率作为预测状态参量, 在分析外部环境因素影响的基础上, 构建变压器故障预测特征集, 采用 CNN 神经网络深度挖掘特征集与故障率之间的内在联系, 将结果输入到 GRU 循环神经网络进行优化训练, 得到变压器未来短期的故障率变化趋势。通过算例仿真可得到以下结论:

- 1) 通过状态评估能够挖掘状态参量间的相关性, 从而更加全面、准确地预测变压器故障情况;
- 2) 采用故障率作为预测状态参量, 预测结果能够直观地反映变压器整体运行趋势, 为预防性维修提供支撑;
- 3) 构建包含日期因素、气象因素和生产工艺因素的特征集, 能够充分发挥 CNN 网络在高维空间提取非连续特征间内在联系的优势;
- 4) CNN-GRU 组合神经网络模型综合了 CNN 网络与 GRU 网络的优势, 与现有人工智能预测模型相比, 具有较高的预测精度与效率。

本文在构建故障预测特征集时, 考虑了日期因素、气象因素和生产工艺因素的影响, 下一步研究重点是进一步完善故障预测特征集的影响因素, 并在保证预测精度的同时优化模型结构, 从而提升模型训练效率。

附录

附表 1 综合状态量对应评估指标表

Attached Table 1 Comprehensive state quantity and evaluation index

编号	综合状态量	评估指标
F_1	绝缘受潮	$S_{11}, S_{21}, S_{22}, S_{24}, S_{25}, S_{26}, S_{28}$
F_2	铁芯故障	$S_{14}, S_{15}, S_{27}, S_{28}$
F_3	电流回路过热	$S_{14}, S_{17}, S_{18}, S_{212}$
F_4	绕组故障	$S_{11}, S_{29}, S_{214}, S_{216}$
F_5	局部放电	$S_{11}, S_{13}, S_{16}, S_{22}, S_{211}, S_{213}$
F_6	油流放电	$S_{12}, S_{16}, S_{21}, S_{26}, S_{215}$
F_7	电弧放电	$S_{11}, S_{12}, S_{211}, S_{213}$
F_8	绝缘老化	$S_{16}, S_{21}, S_{26}, S_{29}, S_{210}, S_{212}$
F_9	绝缘油劣化	$S_{16}, S_{21}, S_{22}, S_{23}, S_{26}, S_{28}$

附表 2 单项评估指标支持度

Attached Table 2 Single evaluation index support

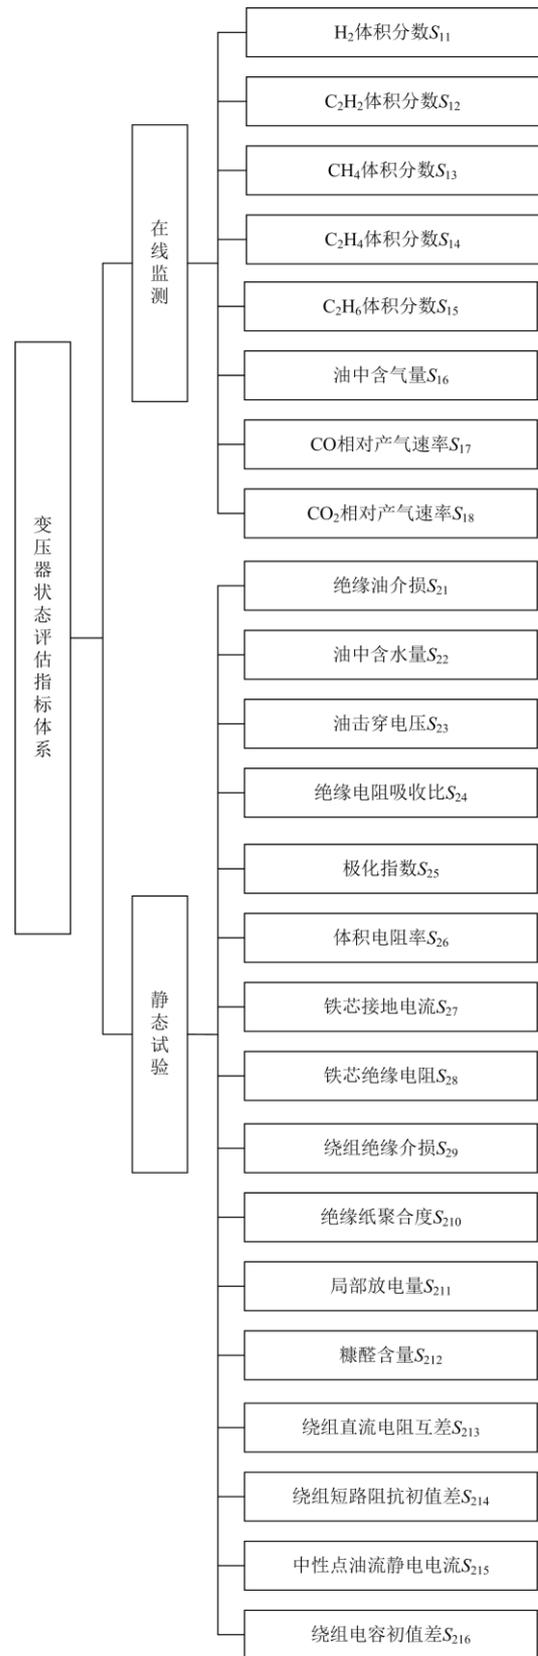
F_i	评估指标	故障案例数	评估指标超标次数	故障案例中评估指标超标总次数	Z_{ij}
F_1	S_{11}	131	110	344	0.832 1
	S_{21}		121	327	0.923 7
	S_{22}		129	346	0.984 7
	S_{23}		117	201	0.893 1
	S_{24}		120	129	0.916 0
	S_{25}		119	131	0.908 4
	S_{26}		123	313	0.938 9
F_2	S_{28}	146	112	228	0.854 9
	S_{14}		134	266	0.917 8
	S_{15}		131	201	0.897 6
	S_{27}		137	149	0.938 4
F_3	S_{28}	117	140	297	0.958 9
	S_{14}		105	241	0.897 4
	S_{17}		109	123	0.931 6
	S_{18}		113	123	0.965 8
F_4	S_{213}	109	111	314	0.948 7
	S_{11}		97	351	0.889 9
	S_{29}		99	232	0.908 3
F_5	S_{214}	134	103	117	0.944 9
	S_{216}		106	115	0.972 5
	S_{11}		129	231	0.962 7
	S_{13}		123	227	0.917 9
	S_{16}		131	187	0.977 6
	S_{22}		132	338	0.985 1
F_5	S_{211}	121	121	218	0.902 9
	S_{213}		127	317	0.947 8

续附表 2

F ₆	S ₁₂	97	194	0.960 4	
	S ₁₆	91	301	0.900 9	
	S ₂₁	101	97	281	0.960 4
	S ₂₆	89	237	0.881 2	
	S ₂₁₅	99	113	0.980 2	
F ₇	S ₁₁	114	234	0.926 8	
	S ₁₂	109	197	0.886 2	
	S ₂₁₁	123	121	221	0.983 7
	S ₂₁₃	118	243	0.959 3	
F ₈	S ₁₆	111	324	0.888 0	
	S ₂₁	121	337	0.968 0	
	S ₂₆	125	119	397	0.952 0
	S ₂₉	115	238	0.920 0	
	S ₂₁₀	123	139	0.984 0	
	S ₂₁₂	117	141	0.936 0	
F ₉	S ₁₆	111	561	0.880 9	
	S ₂₁	107	411	0.849 2	
	S ₂₂	126	121	341	0.960 3
	S ₂₃	113	247	0.896 8	
	S ₂₆	121	479	0.960 3	
S ₂₈	117	365	0.928 6		

附表 3 单项评估指标数据
Attached Table 3 Single evaluation index data

评估指标	初始值	注意值	监测值
S ₁₁	6.1	150	146
S ₁₂	0	5	1.1
S ₁₃	8.7	100	97
S ₁₄	0.45	50	11
S ₁₅	2.3	65	17
S ₁₆	1	3	3.3
S ₁₇	0	100	24
S ₁₈	0	200	96
S ₂₁	0.5	4	1.7
S ₂₂	3.5	25	24.1
S ₂₃	58	35	39
S ₂₄	2	1.3	1.61
S ₂₅	2.5	1.5	2.23
S ₂₆	60	3	31
S ₂₇	0.01	0.1	0.05
S ₂₈	1 000	100	734
S ₂₉	0.17	0.8	0.69
S ₂₁₀	1 000	250	900
S ₂₁₁	30	500	578
S ₂₁₂	0	0.2	0.05
S ₂₁₃	1	4	4.1
S ₂₁₄	1	3	1.2
S ₂₁₅	0.02	1	0.07
S ₂₁₆	1	5	1.4



附图 1 变压器状态评估指标体系

Attached Fig. 1 Index system of transformer status assessment

参考文献

- [1] 周淙, 孙超, 廖瑞金, 等. 基于云理论的变压器多重故障诊断及短期预测方法[J]. 高电压技术, 2014, 40(5): 1453-1460.
ZHOU Quan, SUN Chao, LIAO Ruijin, et al. Multiple fault diagnosis and short-term forecast of transformer based on cloud theory[J]. High Voltage Engineering, 2014, 40(5): 1453-1460.
- [2] 余长厅, 黎大健, 汲胜昌, 等. 基于振动噪声及 BP 神经网络的变压器故障诊断方法研究[J]. 高压电器, 2020, 56(6): 256-261.
YU Zhangting, LI Dajian, JI Shengchang, et al. Research on transformer fault diagnosis method based on vibration noise and BP neural network[J]. High Voltage Apparatus, 2020, 56(6): 256-261.
- [3] 陈华, 王强, 刘晓坤. 基于 BAS-BP 模型的变压器故障诊断[J]. 信阳师范学院学报(自然科学版), 2020, 33(4): 635-639.
CHEN Hua, WANG Qiang, LIU Xiaokun. Transformer fault diagnosis based on BAS-BP model[J]. Journal of Xinyang Normal University (Natural Science Edition), 2020, 33(4): 635-639.
- [4] 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.
- [5] 吴君, 丁欢欢, 马星河, 等. 改进自适应蜂群优化算法在变压器故障诊断中的应用[J]. 电力系统保护与控制, 2020, 48(9): 174-180.
WU Jun, DING Huanhuan, MA Xinghe, et al. Application of improved adaptive bee colony optimization algorithm in transformer fault diagnosis[J]. Power System Protection and Control, 2020, 48(9): 174-180.
- [6] 谢国民, 倪乐水. 基于 IABC 优化 SVM 的变压器故障诊断[J]. 电力系统保护与控制, 2020, 48(15): 156-163.
XIE Guomin, NI Leshui. Transformer fault diagnosis based on an artificial bee colony-support vector machine optimization algorithm[J]. Power System Protection and Control, 2020, 48(15): 156-163.
- [7] 邓芳明, 温开云, 何怡刚, 等. 基于 RFID 传感标签及 QPSO-RVM 的变压器绕组故障在线诊断技术[J]. 中国电机工程学报, 2018, 38(24): 7183-7193.
DENG Fangming, WEN Kaiyun, HE Yigang, et al. On-line fault diagnosis for transformer windings based on RFID sensor tags and QPSO-RVM[J]. Proceedings of the CSEE, 2018, 38(24): 7183-7193.
- [8] 何先华, 张远鹏, 崔桂兴, 等. 基于回归算法的变压器故障检测方法研究[J]. 电力系统保护与控制, 2020, 48(21): 132-139.
HE Xianhua, ZHANG Yuanpeng, CUI Guixing, et al. Research on transformer fault detection method based on a regression algorithm[J]. Power System Protection and Control, 2020, 48(21): 132-139.
- [9] HAN Jiexiang, KONG Xiangping, LI Peng, et al. A novel low voltage ride through strategy for cascaded power electronic transformer[J]. Protection and Control of Modern Power Systems, 2019, 4(3): 227-238.
- [10] 王春明, 朱永利. 基于 NSGA2 优化正则极限学习机的变压器油色谱故障诊断[J]. 高压电器, 2020, 56(9): 210-215.
WANG Chunming, ZHU Yongli. Transformer oil chromatograph fault diagnosis based on regularized extreme learning machine optimized by NSGA2[J]. High Voltage Apparatus, 2020, 56(9): 210-215.
- [11] 周淙, 孙超, 安文斗, 等. 基于云推理及加权隐式半 Markov 模型的变压器故障预测[J]. 高电压技术, 2015, 41(7): 2268-2275.
ZHOU Quan, SUN Chao, AN Wendou, et al. Transformer failure prediction based on cloud reasoning and weighted implicit semi-Markov model[J]. High Voltage Engineering, 2015, 41(7): 2268-2275.
- [12] 徐永明, 刘飞, 齐玉麟. 基于流体网络的电力变压器绕组温度预测[J]. 高电压技术, 2017, 43(5): 1509-1517.
XU Yongming, LIU Fei, QI Yulin. Prediction of winding temperature in power transformers based on fluid network[J]. High Voltage Engineering, 2017, 43(5): 1509-1517.
- [13] 刘航, 王有元, 梁玄鸿, 等. 基于多因素的变压器油中溶解气体体积分数预测方法[J]. 高电压技术, 2018, 44(4): 1114-1121.
LIU Hang, WANG Youyuan, LIANG Xuanhong, et al. Prediction method of the dissolved gas volume fraction in transformer oil based on multi factors[J]. High Voltage Engineering, 2018, 44(4): 1114-1121.
- [14] 王有元, 周立玮, 梁玄鸿, 等. 基于关联规则分析的电力变压器故障马尔科夫预测模型[J]. 高电压技术, 2018, 44(4): 1051-1058.
WANG Youyuan, ZHOU Liwei, LIANG Xuanhong, et al. Markov forecasting model of power transformer fault based on association rules analysis[J]. High Voltage Engineering, 2018, 44(4): 1051-1058.
- [15] 赵婉芳, 王慧芳, 邱剑, 等. 基于油色谱监测数据的变压器动态可靠性分析[J]. 电力系统自动化, 2014,

38(22): 38-42.
 ZHAO Wanfang, WANG Huifang, QIU Jian, et al. Analysis of dynamic reliability of transformer based on monitoring data of oil chromatography[J]. Automation of Electric Power Systems, 2014, 38(22): 38-42.

[16] 韩赛赛, 刘宝柱, 艾欣. 基于 MCMC 方法和油色谱数据的变压器动态故障率模型[J]. 电力系统保护与控制, 2019, 47(15): 1-8.
 HAN Saisai, LIU Baozhu, AI Xin. Transformer dynamic failure rate model based on MCMC method and oil chromatographic data[J]. Power System Protection and Control, 2019, 47(15): 1-8.

[17] 代杰杰, 宋辉, 盛戈峰, 等. 考虑复杂关联关系深度挖掘的变压器状态参量预测方法[J]. 中国电机工程学报, 2019, 39(2): 621-628.
 DAI Jiejie, SONG Hui, SHENG Gehao, et al. A prediction method for power transformers state parameters based on deep association relation mining[J]. Proceedings of the CSEE, 2019, 39(2): 621-628.

[18] GUO Chenxi, WANG Bin, WU Zhanyu, et al. Transformer failure diagnosis using fuzzy association rule mining combined with case-based reasoning[J]. IET Generation, Transmission and Distribution, 2020, 14(11): 2202-2208.

[19] 徐哲炜, 郑成航, 张涌新, 等. 基于改进关联规则算法的燃煤电厂脱硫系统工况参数优化[J]. 中国电机工程学报, 2017, 37(15): 4408-4414.
 XU Zhewei, ZHENG Chenghang, ZHANG Yongxin, et al. Operation optimization of flue gas desulfurization system in power plant based on an improved association rules algorithm[J]. Proceedings of the CSEE, 2017, 37(15): 4408-4414.

[20] MUHAMMAD S, ZULFIQAR A K, AMIN U, et al. A novel CNN-GRU-Based hybrid approach for short-term residential load forecasting[J]. IEEE Access, 2020, 8: 143759-143768.

[21] 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.

[22] 国家电网公司企业标准. 油浸式变压器(电抗器)状态评价导则: Q/GD169—2008[S]. 北京: 中国电力出版社, 2008.
 State Grid Corporation of China. Guide for condition evaluation of oil-immersed power transformers (reactors): Q/G DW169—2008[S]. Beijing: China Electric Power Press, 2008.

[23] 刘文奇. 均衡函数及其在变权综合中的应用[J]. 系统工程理论与实践, 1997, 17(4): 58-64.
 LIU Wenqi. Balanced function and its application for variable weight synthesizing[J]. Systems Engineering Theory & Practice, 1997, 17(4): 58-64.

[24] 郭创新, 王越, 王媚, 等. 表征内部潜伏性故障的变压器时变停运模型研究[J]. 中国电机工程学报, 2013, 33(1): 63-69.
 GUO Chuangxin, WANG Yue, WANG Mei, et al. Time-varying outage model for transformers representing internal latent fault[J]. Proceedings of the CSEE, 2013, 33(1): 63-69.

[25] 姜新猛. 基于 TensorFlow 的卷积神经网络的应用研究[D]. 武汉: 华中师范大学, 2017.
 JIANG Xinmeng. Application and research of convolution neural network based on tensorflow[D]. Wuhan: Central China Normal University, 2017.

[26] KANG Ke, SUN Hongbin, ZHANG Chengkang, et al. Short-term electrical load forecasting method based on stacked auto-encoding and GRU neural network[J]. Evolutionary Intelligence, 2019, 12(3): 385-394.

[27] 牛哲文, 余泽远, 李波, 等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. 电力自动化设备, 2018, 38(5): 36-42.
 NIU Zhewen, YU Zeyuan, LI Bo, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. Electric Power Automation Equipment, 2018, 38(5): 36-42.

[28] 杨观赐, 杨静, 李少波, 等. 基于 Dropout 与 ADAM 优化器的改进 CNN 算法[J]. 华中科技大学学报(自然科学版), 2018, 46(7): 122-127.
 YANG Guanci, YANG Jing, LI Shaobo, et al. Modified CNN algorithm based on dropout and ADAM optimizer[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2018, 46(7): 122-127.

收稿日期: 2021-06-29; 修回日期: 2021-10-18

作者简介:

杨 威(1990—), 男, 博士, 硕士生导师, 研究方向为电动汽车与电网互动、综合能源系统等; E-mail: yangwei_scu@126.com

蒲彩霞(1997—), 女, 硕士研究生, 研究方向为变压器故障诊断、预测与风险评估。E-mail: 1725496172@qq.com

(编辑 周金梅)