

引用格式: 闻宇, 陈艳霞, 李菁, 等. 一种基于 ICA-FNN 的多模型高压网络保护设备异常状态风险预警方法[J]. 电力科学与技术学报, 2024, 39(4): 78-83.

Citation: WEN Yu, CHEN Yanxia, LI Jing, et al. An ICA-FNN-based multi-model early warning approach for the abnormal state risks in high-voltage network protection devices[J]. Journal of Electric Power Science and Technology, 2024, 39(4): 78-83.

一种基于 ICA-FNN 的多模型高压网络保护 设备异常状态风险预警方法

闻宇¹, 陈艳霞¹, 李菁¹, 孙伯龙², 李鑫明¹, 姜健琳³

(1. 国网北京市电力公司电力科学研究院, 北京 100075; 2. 国网北京市电力公司, 北京 100041;

3. 上海泽鑫电力科技股份有限公司, 上海 201206)

摘要: 继电保护自动设备是确保高压网络安全稳定运行的主要防线之一。但基于当前主网拓扑结构复杂、线路架构繁多、分布跨度较大的应用场景环境下, 保护设备的潜在运行异常甚至故障难以完全避免; 同时, 保护设备种类、功能、分布的多样化也对设备的缺陷管理与检修反措提出了挑战。故亟待研究兼顾时效性与全面性的设备异常状态风险自动预警技术。为此, 针对继电保护自动设备, 提出一种基于数据挖掘的异常状态风险实时检测模型。其中, 首先采用独立成分分析方法, 生成独立分量的线性组合以面向海量异构监测数据实施降噪, 能够有效提升高维数据条件下的运算效率; 其次, 构建深度学习前馈神经网络, 使用端到端的训练方法以实现时间序列的异常检测, 能够有效缓解多类别时序条件下的运算复杂度。最后, 以某地区主网保护系统设备异常数据作为仿真实例, 实验结果验证了所设计模型的异常检测性能, 能够助推设备安全风险的自动识别和及时应对。

关键词: 保护设备; 深度学习; 异常检测; ICA-FNN

DOI: 10.19781/j.issn.1673-9140.2024.04.009 中图分类号: TM507 文章编号: 1673-9140(2024)04-0078-06

An ICA-FNN-based multi-model early warning approach for the abnormal state risks in high-voltage network protection devices

WEN Yu¹, CHEN Yanxia¹, LI Jing¹, SUN Bolong², LI Xinming¹, JIANG Jianlin³

(1. State Grid Beijing Electric Power Research Institute, Beijing 100075, China; 2. State Grid Beijing Electric Power Company, Beijing 100041, China; 3. Shanghai Zexin Electric Power Technology Co., Ltd., Shanghai 201206, China)

Abstract: Protection relay system is one of the main defense lines to ensure the stable operation of high-voltage networks. However, within the scenarios with the more complex network topology, the line architecture and the distribution, it is difficult to eliminate the potential operating anomalies or even failures. Also, the diversification of the protection equipment types, functions and locations poses new challenges to the defect management and equipment maintenance. Therefore, the automatic early warning technology of equipment abnormal state risk which considers both the timeliness and comprehensiveness should be studied. To this end, a real-time detection model of abnormal state risk based on data mining is proposed in this paper. Firstly, the independent component analysis is used for mass heterogeneous monitoring data to implement noise reduction. This can effectively improve the computational efficiency under high-dimensional data conditions. Secondly, the feed-forward neural network deep learning method which deploys the end-to-end training process to achieve time series anomaly detections is utilized. This can effectively alleviate the multi-category timing conditions of computational complexity. Finally, the protection system equipment in one area is exploited as empirical study, the results verify the abnormal detection performance of the designed model,

收稿日期: 2021-12-14; 修回日期: 2022-03-01

基金项目: 国网北京市电力公司电力科学研究院科技项目(26020120001M).

通信作者: 闻宇(1988—), 女, 硕士, 工程师, 主要从事电力系统继电保护与控制方面的研究; E-mail: edwardsy@126.com

which can promote the automatic identification and timely response of the protection relay system.

Key words: protection system; deep learning; anomaly detection; ICA-FNN

针对高压网络中潜在的故障或异常状况,继电保护系统能够实时自动隔离相应故障位置设备,从而降低设备异常状态对周围区域产生的不利影响,是高压电网安全运行的第一道^[1]。但继保系统设备仍然存在安全死区,例如出口压板或转换开关错投、漏投造成的保护拒动、误动^[2-3]。因此,亟待进一步改善设备的缺陷管理与检修反措水平,从而及时监测保护装置隐患,并减少周期性维护的次数^[4]。

面对当前继保设备人工运检工作存在的复杂、繁琐、效率低下等问题,利用设备运行数据实施异常状态风险实时检测能够助力继保设备的指向性运检,是解决上述问题的有效措施^[5-6]。同时,随着电力系统信息化水平的不断提升,传感器技术广泛应用于设备的在线监测和状态感知^[7-9],可提供实时多维度的运行状态数据。为此,研究者们提出了多种基于设备运行数据的继保设备异常状态风险检测方法。文献[10]针对超高压输电系统中存在的单间隔或多间隔线路差动主保护丢失这一极端状况,提出了基于站域开关量信息采集的多种主保护丢失的识别逻辑,并制定了后备保护主动和被动加速自调整应急优化方案。由于当前直流互感器存在故障和误差率偏高的问题,可能导致保护设备误动作。为此,文献[11]提出一种应用于配网换流站的基于因果网络的直流互感器数据异常识别策略;面对高压换流站系统直流电压测量异常,从而导致换流器误闭锁这一问题;文献[12]研究站内直流换流器误闭锁机理,并提出相应改进措施;文献[13]通过分布式并行频繁模式树模型挖掘了智能变电站二次设备缺陷和信号间的关系,有效降低了监控数据存储分散,主站获取设备缺陷特征的难度大等问题;为缓解海量异构的多源监测数据给保护开关设备的实时状态感知和诊断带来的挑战,文献[14]提出一种基于多重生成对抗网络和DS证据理论的开关设备状态感知方法。现有研究能够有效及时地检测与预警潜在继保设备异常状态风险,但大多面向特定类型的保护设备。面对目前继保系统设备所呈现的种类、功能、分布多样化趋势,亟须进一步研究多类型保护设备异常状态风险的监测识别途径。

为此,本文提出一种多模型高压线路保护设备的异常状态风险预警方法。针对多维度下的多

类型设备的可靠性指标参数,设置独立成分分析(independent component analysis, ICA)模型,将数据转化为多个统计独立分量的线性组合以实施解混过程,能够有效映射海量高维度异构可靠性数据,从而实现数据降维并提升运算效率;针对设备全时段可靠性监测要求下,多类别时序条件所导致的额外运算复杂度,构建深度学习前馈神经网络(feedforward neural network, FNN),利用端到端的数据训练方法,能够有效提升复杂时序场景中异常时间序列的检测性能。最后,通过基于区域主网保护系统实际算例,可以验证所提出方法的异常预警性能与效率,进而促进安全风险准确预警和及时处理。

1 模型构建

1.1 独立成分分析模型

ICA是从多维数据中寻找其内在成分的一种方法,并且是一个在多领域被应用的基础算法。针对数据集 X ,其ICA求解模型可以表述为

$$X = AS \quad (1)$$

设 X 为随机向量,且 $X \in \mathbb{R}^{m \times 1}$,则有

$$\begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_i \\ \vdots \\ x_m \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{i1} & a_{i2} & \cdots & a_{in} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{pmatrix} \begin{pmatrix} s_1 \\ s_2 \\ \vdots \\ s_i \\ \vdots \\ s_n \end{pmatrix} \quad (2)$$

式中, s_i 为一个随机变量,且两两相互独立; A 为满秩矩阵,且 $A \in \mathbb{R}^{m \times n}$ 。假设:

$$W = A^{-1} \quad (3)$$

则有

$$S = \begin{pmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{j1} & w_{j2} & \cdots & w_{jn} \\ \vdots & \vdots & \ddots & \vdots \\ w_{m1} & w_{m2} & \cdots & w_{mn} \end{pmatrix} X \quad (4)$$

式中, W 为满秩矩阵,且 $W \in \mathbb{R}^{m \times n}$ 。

ICA的目标就是利用各独立成分统计独立且非高斯的特性作为目标函数,寻找合适的变换矩阵 W ,进而获得独立成分 S 。根据目标函数的不同选取,ICA可以分为包括极大似然估计法、极小互信息法等不同方法。其中,FastICA算法通过将负熵作

为随机变量的非高斯性的度量,在约束条件下利用负熵的最大化作为目标函数求解独立成分。此方法相比其他方法具有收敛速度快、计算方便的特点。其具体步骤如下。

1) 计算 X 的平均值 M , 根据下式得到去均值后的 Y 。

$$Y = X - M \quad (5)$$

2) 求 Y 协方差矩阵 $C = \text{cov}(Y, Y^T)$ 以及矩阵的特征值对角阵 Q 和特征向量 α ; 令 $U = Q^{-1/2} \alpha^T$, 利用下式得到处理数据。

$$H = U \times Y \quad (6)$$

3) 初始化随机矩阵 $W^{(0)}$, 且列向量的模值为 1。设 k 为迭代指示器, 令 $k = 0$ 。

4) 利用下式对 $w^{(k)}$ 进行数值迭代计算。

$$\begin{aligned} w^{(k)} = \\ \alpha \left\{ HG(w_d^{(k-1)T} H) \right\} - \alpha \left\{ HG(w_d^{(k-1)T} H) \right\} \cdot w_d^{(k-1)} \end{aligned} \quad (7)$$

式中, $G(\cdot)$ 取双曲正切函数, 假设系数为 1 时, 即 $G(t) = \tanh(t) = (e^t - e^{-t}) / (e^t + e^{-t})$; $g(\cdot)$ 为 $G(\cdot)$ 的一阶导数。

5) 对 W 进行矩阵正交化和标准化。

$$w_j^{(k)} \rightarrow \sum_{i=1}^m (w_j^{(k)Y} w_i) w_i \quad (8)$$

$$w_j^{(k)} \rightarrow \frac{w_j^{(k)}}{\|w_j^{(k)}\|} \quad (9)$$

6) 得出当 $|w_j^{(k)T} w_j^{(k-1)} - 1| < \epsilon$, 则表示 $d = d + 1$; 反之则没有收敛, 返回步骤 3)。

7) 当 $d = m$ 时, 得出矩阵 W , 再根据式(4)求出独立成分 S 。

由以上讨论可知, ICA 是一种线性变换, 能够将数据样本分离为独立且非高斯分布的线性组合。整体来看, ICA 主要将数据通过乘以一个分解矩阵求解其中的独立成分, 使每个成分分量尽可能多地反映数据中与时间无关的有效信息, 且无须正交处理; 而另一种传统降维方法 PCA 基于正交混合矩阵对数据实施去相关处理, 使每个主成分尽力涵盖数据样本中的方差, 即前述有效信息。因此, ICA 可归纳为针对若干独立分量线性组合的解混过程, 而 PCA 是一个基于信息提取实现数据降维的过程, 实际为 ICA 实现过程中的数据标准化预处理步骤。尽管 ICA 需要预先定义需要分解的独立成分总数, 即需要数据先验知识。但相比 PCA, ICA 刻画变量随机统计特质的性能更强, 且具有抑制数据中白噪

声的作用。

1.2 前馈神经网络算法的设计

1.2.1 FNN 结构

FNN 中存在 2 个基本的信号流动方向, 分别是函数信号的前向传播和误差信号的反向传播。而每一层的神经元可以接收前一层神经元的信号, 并产生信号输出到下一层。第 0 层叫输入层, 最后一层叫输出层, 其他中间层叫作隐藏层。当输出层的输出值和期望输出不同时, 会转入反向传播返回误差信号, 通过修改权值使误差信号最小。前馈神经网络的结构如图 1 所示。




图 1 FNN 结构

Figure 1 Structure of the FNN

1.2.2 反向传播算法

神经元 m 在呈现第 n 个训练例子, 输出处的函数信号为

$$y_m(n) = \varphi(v_m(n)) \quad (10)$$

其中, 激活函数采用 sigmoid 函数:

$$\varphi(v_m(n)) = \frac{1}{1 + \exp(-av_m(n))} \quad (11)$$

则输出误差信号为

$$e_m = l_m(n) - o_m(n) \quad (12)$$

式中, $l_m(n)$ 为预测输出的设定值。

神经元 m 定义的误差能量瞬间值为 $(1/2)e_m^2(n)$, 整个误差能量的瞬间值为

$$M(n) = \frac{1}{2} \sum_{m \in C} e_m^2(n) \quad (13)$$

式中, 集合 C 包括网络输出层的所有神经元数目。

在输入层, 神经元 m 的激活函数产生的诱导局部域 $v_m(n)$ 为

$$v_m(n) = \sum_{i=0}^m w_{mi}(n) x_i(n) \quad (14)$$

根据多元微分的链式求导法则:

$$\begin{aligned} \frac{\partial M(n)}{\partial w_{mi}(n)} = & -e_m(n) \frac{\partial y_m(n)}{\partial v_m(n)} \frac{\partial M(n)}{\partial w_{mi}(n)} = \\ & -e_m(n) \varphi'(v_m(n)) x_i(n) \end{aligned} \quad (15)$$

应用于突触权值的修正量 $\Delta w_{mi}(n)$ 为

$$\Delta w_{mi}(n) = -\eta \frac{\partial M(n)}{\partial v_m(n)} = \eta \delta_j(n) x_i(n) \quad (16)$$

式中, η 为反向传播算法的学习率参数。局部梯度 $\delta_m(n)$ 定义为

$$\begin{aligned} \delta_m(n) &= -\frac{\partial M(n)}{\partial v_m(n)} = \\ &= -\frac{\partial y_m(n)}{\partial v_m(n)} \frac{\partial M(n)}{\partial e_m(n)} \frac{\partial e_m(n)}{\partial y_m(n)} = -e_m(n) \varphi'_m(v_m(n)) \end{aligned} \quad (17)$$

用式(19)可以直接计算出当 m 是输出节点时的局部梯度;而当神经元 m 是隐含层节点时,重新定义局部梯度 $\delta_m(n)$ 为

$$\begin{aligned} \delta_m(n) &= -\frac{\partial y_m(n)}{\partial v_m(n)} \frac{\partial M(n)}{\partial y_m(n)} = \\ &= (v_m(n)) \sum_k \delta_k(n) w_{km}(n) \end{aligned} \quad (18)$$

1.3 模型性能分析流程的建立

为验证所提出可靠性异常检测模型性能,针对偏离正常范围的异常检测结果将与真实运行异常记录进行对比。混淆矩阵(confusion matrix, CM)^[15] 包含检测结果与真实结果对比的全部4种状态,能够区分模型的判断结果是否正确。CM的具体表现形式如表1所示。

表1 2×2混淆矩阵

Table 1 2×2 confusion matrix

混淆矩阵		记录结果	
		正确(True)	错误(False)
判断结果	阳性(Positive)	真阳(T_P)	假阳(F_P)
	阴性(Negative)	假阴(F_N)	真阴(T_N)

基于表1的结果能够推导出2种常用的评价变量:真阳率(true positive rate, TPR)、假阳率(false positive rate, FPR)。其数学表达可被表示为

$$T_{PR} = \frac{T_P}{T_P + F_N} = \int f_{1|s_j}(O_i) dO_i \quad (19)$$

$$F_{PR} = \frac{T_N}{T_N + F_P} = \int f_{0|s_j}(O_i) dO_i \quad (20)$$

式(21)、(22)中, $f_{1|s_j}$ 为检测对象 O_i 在场景 s_j 中被确认真阳性的条件概率密度函数; $f_{0|s_j}$ 为检测对象 O_i 在场景 s_j 中被排除是真阳性的条件概率密度函数。

当评价阈值 T 在 0 至 1 之间变化时, TPR 和

FPR 的数值将呈现出互为反比的变动趋势。接受者操作特性曲线(receiver operating characteristic, ROC)能够精确地描述 TPR 和 FPR 数值的变动趋势。

为从 ROC 曲线中更直观地评价检测效果,本文应用 ROC 曲线下面积(area under the ROC, AUROC)作为评价方法,其数学表达形式如下:

$$A_{\text{UROC}} = \iint I(T_1 > T_2) f_{1|s_j}(T_1) f_{0|s_j}(T_2) dT_1 dT_2 \quad (21)$$

式中, T_1 、 T_2 分别为 2 个不同评价阈值; $I(T_1 > T_2)$ 函数为指示函数,即 $T_1 > T_2$ 时,函数值为 1,反之为 0。

AUROC 原理阐释如图 2 所示, AUROC 即为 ROC 曲线与坐标轴之间的几何面积。由图 2 可知,一次完美判别的 TPR 数值为 1,而 FPR 数值为 0,故所生成的 ROC 曲线必然经过坐标(0,1)。异常检测模型的判别 ROC 曲线越接近左上角位置, AUROC 的数值越大,则模型性能越好。




图2 AUROC原理阐释

Figure 2 Illustration of AUROC

在实施算例仿真时,基于由训练数据集训练所得 ICA-FNN 异常检测模型,依据测试数据集里各条记录中的相关参数计算相应记录所在条件下的检测异常风险度,并归一化(0至1:不可能存在异常→一定存在异常)。其后,将检测异常风险度与测试集中相应记录的真实状态相比较(0或1:实际并非异常或确为异常),从而评估所提出模型的检测性能。

1.4 模型整体运行流程

本文基于 ICA-FNN 组合专家模型,针对高压网络保护设备的潜在异常状态风险实施预警,主要步骤包括如下:

- 1) 对输入数据进行预处理,如数据的正规化;
- 2) 收集相应设备的必要先验知识,构建特征空间;
- 3) 采用 ICA 求解数据独立成分,留存有效信

息,实现数据降维;

4) 应用FNN求解相应设备可靠性指标中的潜在异常值;

5) 将异常结果归一化,并与测试数据相对比,分析模型性能。

2 算例分析

本文依据某 220 kV 主网继电保护装置进行示例仿真,针对潜在异常装置可靠性指标参数实施检测。其中,以变电站保护设备为例,依据所在区域设备运检部门相关历史数据的汇总结果,相应继电保护设备定期检修和状态检修方式下的可靠性指标及其参考数值如表 2 所示。

表 2 保护设备可靠性指标

Table 2 Reliability indices of protection devices

可靠性指标	单位	参考值
保护平均修复效率 η_r	次/h	0.2
保护误动作失效率 ϑ_e	次/h	17.013×10^{-6}
保护拒动作失效率 ϑ_r	次/h	12.638×10^{-6}
保护定期检修频率 f_i	次/h	4.1227×10^{-5}
保护定期检修效率 θ_i	次/h	0.25
保护状态检修系数 c	—	0.85
保护状态检修周期 T_c	次/h	9.2×10^3
保护状态检修频率 f_c	次/h	1.1×10^{-4}
保护状态检修效率 θ_c	次/h	0.4
保护自检成功系数 s	—	0.85
保护故障概率 p_f	次/h	4.424
保护自检频率 f_{st}	次/h	3 600
保护自检功能频率 f_{stf}	次/h	4
保护检修人员平均应急效率 S_m	次/h	0.5

一方面在实际运行场景中,高压网络保护设备几乎不可能杜绝故障,故上述可靠性指标能够凭借运检部门的日常维护压缩至一个较低的水平,但往往仍大于零。另一方面,由于上述可靠性指标经由运检部门长期监测汇总得出,因此在通常情况下,正常运行的保护设备的可靠性指标必然处于以参考值为标定的数值范围内,而过高(未维护到)或过低(未检测到)的可靠性指标意味着该设备的运行已偏离正常范围,处于异常运行状态,亟须专门的检修处理。由上述分析可知,针对异常可靠性指标的检测成为潜在风险运行状态预警的有效参考方向。

依据相应数据集中各记录时间顺序进行排序,

将较早的 80% 记录作为模型的训练数据集,针对剩余 20% 测试数据集中的记录进行异常检测,并与相应记录的真实结果进行对比。

本算例基于 ROC 曲线将 ICA-FNN、PCA-FNN、FNN、DBSCAN 以及 K-means 这 5 种异常检测模型进行对比,以检验单位周期内偏离正常范畴的异常可靠性指标检测性能。其中,以保护误动作失效率 ϑ_e 为例,其生成的 ROC 曲线如图 3 所示。

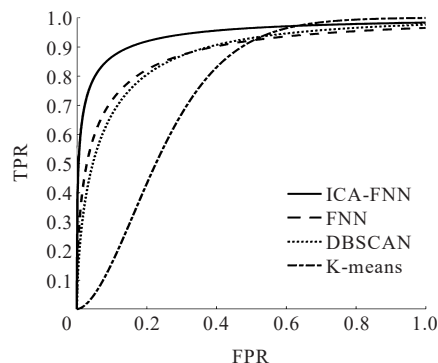


图 3 ROC 曲线对比结果示例

Figure 3 Example comparison of the ROC curve.

5 类异常检测模型的 AUROC 得分汇总如表 3 所示,其中相应得分越高则表明检测效果越好。

表 3 异常检测模型检测结果对比

Table 3 Performance comparison between outlier detection models

可靠性指标	ICA-FNN	PCA-FNN	FNN	DBSCAN	K-means
η_r	0.91	0.90	0.89	0.87	0.80
ϑ_e	0.95	0.92	0.91	0.88	0.81
ϑ_r	0.97	0.96	0.93	0.89	0.81
f_i	0.93	0.93	0.90	0.86	0.79
θ_i	0.90	0.87	0.87	0.81	0.73
c	0.89	0.85	0.84	0.82	0.75
T_c	0.94	0.94	0.88	0.84	0.73
f_c	0.93	0.91	0.89	0.82	0.76
θ_c	0.96	0.95	0.91	0.86	0.74
s	0.97	0.94	0.93	0.88	0.75
p_f	0.93	0.92	0.90	0.81	0.77
f_{st}	0.95	0.90	0.88	0.82	0.75
f_{stf}	0.91	0.90	0.86	0.81	0.72
S_m	0.88	0.84	0.82	0.78	0.70

由表 3 可知,所提出的 ICA-FNN 异常检测方法具有最高的准确度。其中,由于可靠性参数维度较高,相较普通 FNN、ICA 以及 PCA 模型在数据降维

方面能够发挥显著作用;但相较PCA,ICA在变量随机性较强以及具备潜在白噪声的场景中性能更强,在本算例中具有相对更高的检测效果。此外,相较以DBSCAN与K-means方法为代表的密度、距离异常检测思路,基于FNN的深度学习方法在检测效果上具有一定优势。考虑到保护设备可靠性参数源于设备的全时段运行状态,由此产生的多类别时序数据必然推高运算复杂度,而FNN模型中的端到端数据训练途径,能够更加有效地应对复杂时序场景。如表4所示,通过降维功能,ICA以及PCA模型的加入对于FNN异常检测模型的运算效率方面具有显著提升。此外,在诸如本算例等具有数据先验知识的场景中,相较PCA,ICA可直接求解独立成分分量,在运算复杂度上更胜一筹。

表4 异常检测模型运算时长对比

Table 4 Computation time comparison between outlier detection models

异常检测模型	运行时间/s
ICA-FNN	0.983 7
PCA-FNN	1.192 8
FNN	1.637 7

3 结语

本文针对多维度下的主网继电保护设备,提出一种基于ICA-FNN的异常状态风险预警方法,能够有效应对多维度多类别时序条件下的数据环境。本文的主要工作如下:

1) 构建基于ICA的数据降维模型,将高维度异构可靠性数据映射为独立分量的线性组合以实施解混,从而实现数据降维以提升运算效率;

2) 建立基于FNN的深度学习异常检测模型,采用端到端的数据运行架构,从而提升复杂时序场景下的异常时间序列检测性能;

3) 通过220 kV主网保护装置实际算例,检测潜在异常可靠性指标,验证了ICA-FNN方法的异常预警性能与效率,从而助力保护系统安全风险的准确预警和及时处理。

参考文献:

[1] 王文焕,郭鹏,祝洁,等.基于故障树及贝叶斯网络的继电保护系统风险评估及故障定位方法[J].电力科学与技术学报,2021,36(4):81-90.
WANG Wenhuan, GUO Peng, ZHU Jie, et al. Fault positioning and risk assessment method of relay

protection based on fault tree and Bayesian network[J]. Journal of Electric Power Science and Technology,2021, 36(4):81-90.

[2] 杨超,伏晓燕.智能变电站继电保护设备全防误状态监测技术研究[J].电网与清洁能源,2023,39(7):73-79.
YANG Chao, FU Xiaoyan. Research on the full error prevention state monitoring technology of relay protection equipment in intelligent substations[J]. Power System and Clean Energy,2023,39(7):73-79.

[3] REZAEI N,UDDIN M N.An analytical review on state-of-the-art microgrid protective relaying and coordination techniques[J]. IEEE Transactions on Industry Applications,2021,57(3):2258-2273.

[4] 郑玉平,吕鹏飞,李斌,等.新型电力系统继电保护面临的问题与解决思路[J].电力系统自动化,2023,47(22):3-15.
ZHENG Yuping,LÜ Pengfei,LI Bin,et al.Problems faced by relay protection in new power system and their solution ideas[J].Automation of Electric Power Systems, 2023,47(22):3-15.

[5] 马红明,李倩,陶鹏,等.基于贝叶斯与数据驱动的智能电能表状态感知技术研究[J].电测与仪表,2022,59(2):176-182+188.
MA Hongming,LI Qian,TAO Peng,et al.Research on the state perception technology of smart meters based on Bayesian and data-driven[J].Electrical Measurement & Instrumentation,2022,59(2):176-182+188.

[6] LIM S T,LIM S H.Analysis on protective coordination between over-current relays with voltage component in a power distribution system with SFCL[J]. IEEE Transactions on Applied Superconductivity, 2020, 30(4): 5601706.

[7] 李梅,唐菊生.基于综合制动判据的变压器差动保护研究[J].电力科学与技术学报,2020,35(2):135-141.
LI Mei, TANG Jusheng. Transformer differential protection method based on the comprehensive braking criterion[J]. Journal of Electric Power Science and Technology,2020,35(2):135-141.

[8] 谢庆,张焯宇,王春鑫,等.新一代人工智能技术在输变电设备状态评估中的应用现状及展望[J].高压电器, 2022,58(11):1-16.
XIE Qing, ZHANG Xuanyu, WANG Chunxin, et al. Application status and prospect of the new generation artificial intelligence technology in the state evaluation of power transmission and transformation equipment[J]. High Voltage Apparatus,2022,58(11):1-16.

[9] VLAHINIĆ S,FRANKOVIĆ D,JURIŠA B,et al.Back up protection scheme for high impedance faults detection in transmission systems based on synchrophasor measurements[J].IEEE Transactions on Smart Grid,2021, 12(2):1736-1746.

- 障暂态特征及其影响分析[J]. 电工技术学报,2022,37(3):655-666.
- QIN Suyu, XUE Yongduan, LIU Yizheng, et al. Transient characteristics and influence of small current grounding fault in active distribution network[J]. Transactions of China Electrotechnical Society, 2022, 37(3): 655-666.
- [18] 刘晓琴,王大志,江雪晨,等. 利用行波到达时差关系的配电网故障定位算法[J]. 中国电机工程学报, 2017, 37(14): 4109-4115.
- LIU Xiaoqing, WANG Dazhi, JIANG Xuechen, et al. Fault location algorithm for distribution power network based on relationship in time difference of arrival of traveling wave[J]. Proceedings of the CSEE, 2017, 37(14): 4109-4115.
- [19] 王阳,曾祥君,黎锐烽,等. 基于图论的配电网故障行波定位新算法[J]. 电力系统自动化, 2012, 36(18): 143-147.
- WANG Yang, ZENG Xiangjun, LI Ruifeng, et al. A traveling wave fault location algorithm for distribution network based on graph theory[J]. Automation of Electric Power Systems, 2012, 36(18): 143-147.
- [20] 曹璞璘,申忠友,束洪春,等. 基于波形突变特征的海量行波数据中雷击干扰波形辨识[J]. 电力系统自动化, 2023, 47(17): 178-186.
- CAO Pulin, SHEN Zhongyou, SHU Hongchun, et al. Identification of lightning interference waveforms in massive traveling wave data based on waveform mutation characteristics[J]. Automation of Electric Power Systems, 2023, 47(17): 178-186.
- [21] 穆利智,李泽文,吕佳佳,等. 结合 EMD-WVD 和布谷鸟搜索算法的输电线路故障暂态保护[J]. 电力系统自动化, 2020, 44(16): 137-144.
- MU Lizhi, LI Zewen, LÜ Jiajia, et al. Transient protection for transmission line fault combining empirical mode decomposition-wigner ville distribution and Cuckoo search algorithm[J]. Automation of Electric Power Systems, 2020, 44(16): 137-144.
- [22] 李浩,张禄亮,麦章渠,等. 基于改进离散型麻雀搜索算法的配电网恢复重构方法[J]. 智慧电力, 2023, 51(7): 16-22+30.
- LI Hao, ZHANG Luliang, MAI Zhangqu, et al. Distribution network recovery reconfiguration method based on improved discrete sparrow search algorithm[J]. Smart Power, 2023, 51(7): 16-22+30
- [23] 殷浩然,苗世洪,郭舒毓,等. 基于S变换相关度和深度学习的配电网单相接地故障选线新方法[J]. 电力自动化设备, 2021, 41(7): 88-96.
- YIN Haoran, MIAO Shihong, GUO Shuyu, et al. Novel method for single-phase grounding fault line selection in distribution network based on S-transform correlation and deep learning[J]. Electric Power Automation Equipment, 2021, 41(7): 88-96
- [24] 谢李为,李勇,罗隆福,等. 基于距离矩阵与分支系数的配电网故障定位方法[J]. 中国电机工程学报, 2020, 40(7): 2180-2191.
- XIE Liwei, LI Yong, LUO Longfu, et al. Fault location method for distribution networks based on distance matrix and branch coefficient[J]. Proceedings of the CSEE, 2020, 40(7): 2180-2191.

(上接第83页 Continued from page 83)

- [10] 闫晨光,张芑,徐雅,等. 换流变压器有载分接开关级间短路故障差动保护动作特性[J]. 电工技术学报, 2023, 38(21): 5878-5888+5912.
- YAN Chenguang, ZHANG Peng, XU Ya, et al. Differential protection performance for converter transformer intertap short-circuit faults in on-load tap changers[J]. Transactions of China Electrotechnical Society, 2023, 38(21): 5878-5888+5912.
- [11] 栾洪洲,殷伟,周飞,等. 直流控保设备互感器数据异常快速识别策略[J]. 电网技术, 2019, 43(8): 2853-2859.
- LUAN Hongzhou, YIN Wei, ZHOU Fei, et al. A fast recognition strategy for abnormal transformer data in DC protection and control device[J]. Power System Technology, 2019, 43(8): 2853-2859.
- [12] 安海清,李振动,金海望,等. 张北柔直电网直流分压器二次电压测量异常引起误闭锁机理分析及改进措施[J]. 电力自动化设备, 2021, 41(8): 156-160+168.
- AN Haiqing, LI Zhendong, JIN Haiwang, et al. Mechanism analysis and improvement measures of error block caused by abnormal secondary voltage measurement of DC voltage divider in Zhangbei flexible DC grid[J]. Electric Power Automation Equipment, 2021, 41(8): 156-160+168.
- [13] 韩平平,陈思远,张楠,等. 考虑分布式光伏的低压台区线损异常辨识方法[J]. 电力系统保护与控制, 2023, 51(8): 140-148.
- HAN Pingping, CHEN Siyuan, ZHANG Nan, et al. Line loss anomaly identification method for low-voltage station area considering distributed PV[J]. Power System Protection and Control, 2023, 51(8): 140-148.
- [14] 贾梦瑶,王玉玮,宋明浩. 基于时间生成对抗网络的风电随机场景预测[J]. 智慧电力, 2023, 51(8): 59-66.
- JIA Mengyao, WANG Yuwei, SONG Minghao. Stochastic scenario prediction of wind power based on time generative adversarial networks[J]. Smart Power, 2023, 51(8): 59-66.
- [15] FAWCETT T. An introduction to ROC analysis[J]. Pattern Recognition Letters, 2006, 27(8): 861-874.