

doi: 10.7690/bgzd.2025.09.016

基于规则引擎与深度学习的电网防误操作方法

罗添允¹, 刘津铭¹, 李晟源¹, 代 勇²

(1. 广西电网有限责任公司电力调度控制中心, 南宁 547199; 2. 南京南瑞信息通信科技有限公司, 南京 211100)

摘要: 为解决现有防误策略忽略了电网操作的多维度指标、且无法对潜在的误操作进行防范的问题, 提出一种基于规则引擎与深度学习的电网多层次多维度防误操作智能判别方法。通过规则引擎驱动的误操作识别方法, 充分考虑命令执行、设备状态和人员操作行为等维度, 将最小完美哈希表筛选无用事件, 提高识别效率, 基于混合深度学习的多层次潜在误操作识别方法, 深入分析处理历史操作数据, 识别出潜在的误操作模式, 还能对规则引擎的规则库进行有效的补充和更新, 提升系统的自动化水平。仿真结果表明, 相比于 2 个对比算法, 所提方法能够将误操作识别成功率提高 2.10% 和 3.06%。

关键词: 电网自动化; 防误操作; 规则引擎; 深度学习

中图分类号: TM76 **文献标志码:** A

Misoperation Prevention Method of Power Grid Based on Rule Engine and Deep Learning

Luo Tianyun¹, Liu Jinming¹, Li Shengyuan¹, Dai Yong²

(1. Guangxi, Master, Electric Power Dispatching and Control Center Guangxi Power Co., Ltd., Nanning 547199, China; 2. Nanjing NARI Information and Communication Technology Co., Ltd., Nanjing 211100, China)

Abstract: In order to solve the problem that the existing anti-misoperation strategy ignores the multi-dimensional indicators of power grid operation and can not prevent potential misoperation, a multi-level and multi-dimensional anti-misoperation intelligent discrimination method for power grid based on rule engine and deep learning is proposed. Through the rule engine-driven misoperation identification method, taking full account of the dimensions of command execution, equipment status and personnel operation behavior, the minimum perfect hash table is screened out of useless events to improve the identification efficiency, and the multi-level potential misoperation identification method based on hybrid in-depth learning is used to analyze and process historical operation data in depth and identify potential misoperation. It can also effectively supplement and update the rule base of the rule engine, and improve the automation level of the system. The simulation results show that the proposed method can increase the success rate of misoperation recognition by 2.10% and 3.06% compared with the two comparison algorithms.

Keywords: grid automation; misoperation prevention; rules engine; deep learning

0 引言

随着技术的发展和新型电力系统的逐步成熟, 分布式电源和负荷的广泛接入导致了配电网中数据量的显著增长以及操作失误类型的多样化, 电网运行的复杂性和不确定性也随之增加^[1-4]。在电网运行过程中, 误操作事件可能导致重大的经济损失和安全隐患, 开发有效的电网防误操作方法具有重要意义。传统的电网误操作识别主要依赖于人工操作, 缺乏自动化的防误校核步骤, 不仅效率低下, 而且容易出错^[5-6], 操作复杂性高、环境变化快, 难以实时分析多维度数据, 如命令执行、设备状态和人员操作行为等, 导致对新型误操作的识别滞后。此外, 由于配电网防误操作类型繁多, 分析诊断过程复杂,

传统的规则引擎虽然能够处理大量预定义的规则, 但难以适应新的误操作类型, 且规则库的更新需要大量的人工干预, 限制了系统的自动化水平和对复杂未知误操作模式的预测能力^[7-9]。

卷积神经网络(convolutional neural network, CNN)和双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)等深度学习模型因其在处理复杂模式识别和时间序列数据方面的优势, 被广泛应用于电网误操作的识别中^[10-12]。这些模型能够处理和分析历史操作数据, 识别出潜在的误操作模式。从而实现多层次误操作识别, 提高系统的自动化水平。

目前, 已有很多针对电网防误操作的研究。文

收稿日期: 2024-09-13; 修回日期: 2024-10-28

基金项目: 中国南方电网有限责任公司科技项目(046000KK52222030)

第一作者: 罗添允(1994—), 男, 广西人, 硕士。

献[13]通过电子模拟图板软件整合站内各部分数据孤岛,实现了变电站锁控、一二次设备统筹防误;文献[14]通过人工智能图像识别技术准确地识别电压电流端子排的各种状态和特征来防误操作;文献[15]结合深度强化学习算法构建智能防误图谱,自动生成符合防误规程的最优倒闸操作序列,实现智能防误校核;文献[16]基于机器学习的融合模型实现对变电站的一二次设备状态参数的实时监测,构建变电站二次防误操作系统。现有研究忽略了电网操作的多维度指标、且无法对潜在的误操作进行防范。

针对上述挑战,笔者提出基于规则引擎与深度学习的电网多层次多维度防误操作智能判别方法,并通过仿真验证了所提方法的有效性。

1 规则引擎驱动的误操作识别方法

提出电网多维度防误操作规则系统,介绍规则引擎的 β 网络,并在此基础上构建最小完美哈希表,帮助规则引擎高效筛出无用的操作数据后,对规则引擎的推理机进行介绍。规则引擎驱动的误操作识别方法流程如图1所示。




图1 规则引擎驱动的误操作识别原理

由图1可见:首先,根据当前时间发生的事件对最小完美哈希表进行更新,将规则集转换为 β 网络,以提取原子条件;然后,根据命令执行、设备状态和人员操作行为等维度来获取原子触发事件,并将这些原子触发事件作为键集,从而获得最小完美哈希表。只有通过最小完美哈希表检验的原子事件才能触发规则引擎中的相应规则,最后由推理机

对误操作进行响应。

1.1 规则系统

规则系统包括事实库和规则库,旨在实现对电网防误操作的有效监控与管理。

事实库包括命令执行、设备状态和人员操作行为等维度。在命令执行维度,错误的设备启停命令、设定参数不当、错误清除警报或误发紧急操作命令可能导致系统故障。设备状态维度则包括故障警报、运行参数超限、连接状态变化、维护状态更新和通信故障等,这些事件直接影响设备的运行安全。与此同时,人员操作行为维度涉及操作员的输入错误、不当技能级别操作、流程违例、信息传递失误和延迟处理状态反馈等。这些事件的监测、分析和管理对提升电网安全性和可靠性至关重要。

规则库是构建电网防误操作的方法核心,包含所有相关规则,为规则引擎实施误操作诊断提供重要依据。规则库的质量直接影响引擎的推理结果及运行效率。每条规则包括条件、动作和执行顺序3项内容,为准确识别误操作事件及其成因的判别机制提供支持。条件由各个维度的判定标准构成,动作则生成对应的误操作判别结果,并根据判别的维度生成相关的电网事实。

1.2 规则引擎

规则引擎可以基于规则库现有的规则对误操作进行快速识别。笔者所提规则引擎包括:1) 基于 β 网络的最小完美哈希表,能够以极低复杂度快速筛选出无用操作数据,提高规则引擎效率;2) 推理机,基于最小完美哈希表过滤后的规则集来进行对应防误操作。

在最小完美哈希表之前,笔者对每条规则进行预处理,并将规则集转化为 β 网络。规则公式表示为:

$$x_1 \wedge x_2 \wedge (x_3 \vee (y_1 \wedge y_2)) \rightarrow A_1. \quad (1)$$

式中: x_i, y_i 为条件; A_1 为动作。由于每个命题式都可以转换成一个等价的非结正则表达式(disjunctive normal form, DNF)公式,通过预处理后规则 $x_1 \wedge x_2 \wedge (x_3 \vee (y_1 \wedge y_2)) \rightarrow A_1$ 依次转化如下:

$$(x_1 \wedge x_2 \wedge x_3) \vee (x_1 \wedge x_2 \wedge y_1 \wedge y_2) \rightarrow A_1. \quad (2)$$

规则 $x_1 \wedge x_2 \wedge (x_3 \vee (y_1 \wedge y_2)) \rightarrow A_1$ 被分解成式(3)中2条原子规则。

$$\left. \begin{aligned} (x_1 \wedge x_2 \wedge x_3) &\rightarrow A_1 \\ (x_1 \wedge x_2 \wedge y_1 \wedge y_2) &\rightarrow A_1 \end{aligned} \right\}. \quad (3)$$

基于 DNF 转换, 将一个复杂规则分解为多个原子规则。为规则引擎的优化奠定了基础, 在规则执行过程中, 原子规则是相互独立的, 可以并行解析。

基于规则集中的原子规则, 笔者构建出一个 β 网络。将每条规则转换成一棵树, 行动是树根, 原子条件是树叶。对规则树进行优化, 将原子条件转换为组成条件, 通过多路复用原则构建 β 网络。

构建最小完美哈希表的核心问题是选择最小完美哈希函数 (minimal perfect hash function, MPHf) 中的键集。为了构建一个高效的最小完美哈希表, 将规则集转化为 β 网络, 以提取原子条件。然后, 可以根据命令执行、设备状态和人员操作行为等维度获取原子触发事件。通过将原子触发事件作为键集, 获得最小完美哈希表。

构建 MPHf, 为数据集 I 中的每个成员 I_i 分配一个质数 m_i , 要求对每个 I_i , $m_{i+1} > m_i$ 。且这组质数中 $m_i > i$, 构建完成的最小完美哈希函数表示为:

$$H(I_x, I_y) = d(I_x) + B(I_y). \quad (4)$$

式中 $d(I_x)$ 为第一次 I_x 出现的位置减 1。

基于 β 网络的原子条件设计一个高效的筛选表, 即最小完美哈希表。它能以 $O(1)$ 的时间复杂度筛选出无用数据。在一个特定的系统中, 原子条件通常由一个或多个事件组成。例如“设备状态正常”意味着应整合同一时期多个设备状态监测系统的事件。通过分析原子条件和系统中的事件源属性可以建立一个适配器, 确定原子条件和原子触发器之间的对应关系以及事件之间的对应关系。

最小完美哈希表 (H) 的每个表项由 3 个字段组成: id 、 $tWindow$ 和 p 。 id 字段用于识别原子触发事件, 该事件可以是命令执行、设备状态和人员操作

行为等维度的结合; $tWindow$ 字段表示一个时间段, 在该时间段内, 特定事件是有效的; p 字段是一个指针, 指向设计适配器中的原子触发事件。

当原子事件 e 到达时, 通过 $MPHF(e.id)$ 计算该原子事件的索引 i , 然后从哈希表中获取对应的项 $H(i)$ 。如果 $H(i).id$ 与 $e.id$ 不相等, 则该事件被视为无用事件, 从规则引擎中丢弃。否则, 需要通过 $H(i).tWindow$ 字段分析该事件的发生时间是否有效, $tWindow$ 字段可以动态更新。

采用传统规则引擎的推理机, 旨在实现电网防误操作的智能诊断与决策。推理机的核心组件由模式匹配器、议程和执行引擎构成。只有通过最小完美哈希表检验的原子事件, 才被用于触发规则引擎中的相应规则。规则引擎将评估这些事件是否满足已定义的规则条件, 如果满足, 则执行相应的动作, 以成功识别误操作。

2 基于混合深度学习的潜在误操作识别

通过规则引擎可以对规则库记录的误操作进行识别, 但规则库的构建需要依赖于经验积累, 难以及时适应新的误操作类型。笔者提出了一种基于混合深度学习的多层次潜在误操作识别方法算法原理如图 2 所示, 首先, 卷积神经网络对输入特征向量进行精准的特征提取, 以捕捉数据中的关键模式; 然后, 双向长短期记忆网络进一步增强了模型对长距离依赖关系的捕捉能力, 从而实现对识别结果的校正与优化。该方法不仅能够深入分析历史操作数据, 识别出潜在的误操作模式, 还能对规则引擎的规则库进行有效的补充和更新, 提升系统的自动化水平, 增强对复杂及未知误操作模式的预测能力。




图2 基于混合深度学习的多层次潜在误操作识别原理

2.1 操作票识别

操作票是指在电力系统和设备运行中, 为确保安全、可靠地进行操作而制定的书面文件^[17]。操作票识别流程包括词位特征提取, 指令标注以及信息提取 3 个过程。对操作票进行分词以提取词位特征。

操作票中包含字数为 n 的句子的分词操作公式为:

$$P(a_1, b_1, \dots, a_n, b_n) = \prod_{k=1}^n P(b_k) P[b_k | (a_1, \dots, a_s)]. \quad (5)$$

式中: $(a_1, \dots, a_n)$, $(b_1, \dots, b_n)$ 为变量, 分别对应状态与观测; $P(a_1, b_1, \dots, a_n, b_n)$ 为联合概率, 反应句子的

字数, 即为序列; b_k 为词位, 对应第 k 个位置; b_a 为操作系数。可进一步明确词位特征, 提取完词位特征后, 通过应用隐马尔可夫模型, 可实现中文文本的分词及词性标注任务。在这一过程中, 观测序列中的每个元素对应于文本中的单个汉字, 而整个句子则构成了完整的观测序列。同时, 词性标注中的词位与模型中的状态序列相对应。以“检查 110 kV 出线开关合闸指示灯状态”为例, 分词结果为{检查、110 kV、出线开关、合闸、指示灯状态}, 其中词性标注为{动词, 名词, 名词, 名词, 名词}。因此, 该模型的状态空间可以如下描述:

$$\{s_1, s_2, s_3, s_4, s_5, s_6\} = \{n, v, p, ns, w, d\}。 \quad (6)$$

式中 v, n, ns, p, d, w 各元素依次为名词、动词、介词、地名、副词和标点符号。观测空间 $\{o_1, o_2, \dots, o_M\}$ 由所有词语构成的无重复集合组成, 这意味着每个词语在集合中只出现一次, 从而确保了观测空间的唯一性和完整性。

最后, 通过预先制定的语法规则, 从操作票中提取出所需要的状态动作等信息, 从而准确识别出操作票中的具体指令内容, 为网络进一步学习训练提供支持。

2.2 基于 CNN-BiLSTM 的潜在误操作识别

CNN 能够对输入的特征向量进行精准的特征提取, 充分挖掘数据中的局部特征和深层模式。BiLSTM 通过双向的信息流动, 能够综合考虑序列数据的历史和未来信息, 极大地增强了模型对长距离依赖关系的捕捉能力。结合 CNN 和 BiLSTM 的优势, 本文中的多层次潜在误操作识别方法实现了对历史操作数据的深入分析与识别, 能够有效补充和更新规则引擎的规则库, 进而提升系统的自动化水平。笔者构建了基于 CNN-BiLSTM 的多层次潜在误操作识别方法, 从而实现操作防误校正。

完成分词处理后, 接下来需要从分词结果中提取局部文本片段, 并将片段被送入 CNN-BiLSTM 模型进行进一步分析。在模型训练过程中, 通过不断迭代优化权重参数, 同时生成低维密集的词向量表示, 能够捕捉操作票文本中语义的关联性。用 i 和 j 表示两段操作票样本的分词向量, 则它们之间的关联程度 Ω_{ij} 可以表示为:

$$\Omega_{ij} = \frac{L_{\max} - \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (z_i - z_j)^2}}{L_{\max}}。 \quad (7)$$

式中: $L_{\max}$ 为 i 和 j 之间的最大距离; i 的坐标为 $x_i,$

y_i, z_i ; j 的坐标为 x_j, y_j, z_j 。

在 CNN-BiLSTM 多层次潜在误操作识别模型中, 卷积层能够对分词向量进行卷积操作, 之后对其进行激活处理。设单个卷积核大小及待处理的词向量分别为 $p \times q$ 和 a_k , 则模型的卷积输出可以表示为:

$$c = \sigma\left(\sum_k^{p \times q} w_k \cdot a_k + b\right); \quad (8)$$

$$\sigma(z) = \frac{1}{1 + e^{-k}}。 \quad (9)$$

式中: b 为偏置; w_k 为权重; e^{-k} 为卷积核函数参数。

在执行操作防误校正时, 为了捕捉长距离的依赖关系并对识别结果进行校正与优化, 需要进一步利用 BiLSTM 网络进行处理。BiLSTM 通过 2 个独立的 LSTM 网络来处理顺序数据的前向和后向, 一个网络处理输入序列的正向部分, 另一个则处理反向部分。在每个时间步或序列结束时, 这 2 个层的输出会被合并, 从而增强了模型捕捉双向上下文信息的能力。

在某一时刻 $t(t=1, 2, \dots, n)$, 前向传播层执行正向计算, 前向隐含层在时刻 t_i 的输出表示为 Z_f ; 在某一时刻 $t(t=n, n-1, \dots, 1)$ 后向传播层执行反向计算, 将后向隐藏层在时刻 t 的输出记为 Z_b ; 最后, 根据前向与后向层在每个时刻 t 计算得到的输出, 可以得到最终输出 Y_t 。 Z_f, Z_b, Y_t 的计算公式表示为:

$$Z_f = f(w_1 x_t + w_2 Z_{f-1}); \quad (10)$$

$$Z_b = f(w_3 x_t + w_5 Z_{b-1}); \quad (11)$$

$$Y_t = g(w_4 Z_f + w_6 Z_b)。 \quad (12)$$

式中 $\omega_i(i=1, 2, 3, 4, 5, 6)$ 为权重。

在经过卷积操作后, 池化层进一步提取输入向量特征得到特征值。当输入数据为 $a=(a_1, a_2, \dots, a_n)$ 时, 输出结果表示为:

$$\gamma = (a_1, a_2, \dots, a_k)。 \quad (13)$$

池化层输出特征值后, 全连接层对其进行加权, 添加偏置, 并通过非线性激活函数, 得到最终识别结果。接下来, 判断深度学习识别出的规则 $x_i \wedge y_i \dots \rightarrow A_i$ 是否存在于规则库中; 若不存在, 则需对规则库进行更新。

$$R = R' + \{x_i \wedge y_i \dots \rightarrow A_i\}。 \quad (14)$$

式中 R' 为规则库。

3 仿真分析

为验证笔者研究的基于规则引擎与深度学习的

电网多层次多维度防误操作智能判别方法的有效性，将某电力企业 4 个变电站共计 1 200 个操作票样本用于测试^[18-19]。测试过程中，采用 Python 的开源规则引擎函数包 Pyke 以及 Pytorch 库分别对规则引擎和深度学习模型进行开发，仿真参数如表 1 所示。考虑 2 个对比算法：对比算法 1 为基于传统 RETE 推理的规则引擎算法^[20]；对比算法 2 为基于深度学习的防误操作识别算法^[21]。

表 2 操作票内容的提取结果

操作票内容	分词结果	词性标注
确认 10 kVAB 线#56 杆 002 开关在分闸位置	{确认, 10 kVab 线, 56 杆, 002 开关, 分闸位置}	{v, n, n, n, n}
断开 110 kVA 站 10kVAB 线 001 开关	{断开, 110 kVA 站, 10 kVAB 线, 001 开关}	{v, n, n, n}
转换 110 kVA 站 10kVAB 线 001 开关运行状态为冷备用	{转换, 110 kVA 站, 10 kVAB 线, 001 开关, 运行状态, 冷备用}	{v, n, n, n, n, n}
退出 4 号配电变压器中性点接地装置	{退出, 4 号, 配电变压器, 中性点接地装置}	{v, n, n, n}
调整 3 号变压器的负荷分配设置	{调整, 3 号, 变压器, 负荷分配}	{v, n, n, n}

图 3 展示了全部操作票提取完整程度。仿真结果表明：所提算法操作票提取完整度平均在 96.12%，可以为 CNN-BiLSTM 模型的高效训练提供支持。




图 3 操作票提取完整程度

图 4 展示了误操作识别成功率随规则数量增加的变化情况。仿真结果表明：误操作识别成功率与规则数量并无明显相关，但在各个规则数量下所提算法的识别准确率均为最高，相比对比算法 1 和对比算法 2 分别提高了 2.10%和 3.06%。这是因为所提算法通过多维度多层次分析数据，充分提取规则间的隐藏关联，且通过深度网络对潜在误操作进行深度挖掘，并对规则库进行更新，提高了识别准确度。




图 4 误操作识别成功率

表 1 实验环境配置

参数	值	参数	值
最大迭代次数	200	卷积核尺寸	30
卷积核数量	30	学习速率	0.001
神经元数量	80	词向量维度	64

表 2 展示了所提方法对操作票内容提取后的分词结果以及词性标注情况。结果表明：词位特征提取，指令标注以及信息提取 3 个过程对操作票内容提取完整，能用于进一步网络学习对误操作的识别。

图 5 为不同算法时间开销随规则数量变化情况。仿真结果表明，随着规则数量的增加，3 种算法时间开销均在增加，相较对比算法 1 和对比算法 2 所提算法平均时间开销分别降低了 26.54%和 32.66%。这是因为所提算法采用最小完美哈希表，能够以极低复杂度快速筛选出无用操作数据，提高规则引擎效率。




图 5 算法时间开销随规则数量变化情况

4 结束语

笔者提出一种基于规则引擎与深度学习的电网多层次多维度防误操作智能判别方法：首先，提出规则引擎驱动的误操作识别方法，充分考虑命令执行、设备状态和人员操作行为等维度，并通过最小完美哈希表筛选无用事件，提高识别效率；其次，提出基于混合深度学习的多层次潜在误操作识别方法，深入分析处理历史操作数据，识别出潜在的误操作模式，还能对规则引擎的规则库进行有效的补充和更新，提升系统的自动化水平。仿真结果表明：相比于 2 个对比算法，所提方法能够将误操作识别成功率提高 2.10%和 3.06%，时间开销分别降低了 26.54%和 32.66%。该方法在解决军方电网中由于操

作复杂性和环境变化快速所带来的误操作防范问题上具有一定优势,能够在高风险环境中实现实时准确的误操作识别与应对。在未来,会进一步探索如何融合传感器数据、操作日志、天气信息等多模态数据来提高误操作识别的准确性。

参考文献:

- [1] 孙华东,赵兵,徐式蕴,等.高比例电力电子电力系统强度的定义、分类及分析方法[J].中国电机工程学报,2024,44(18):7039-7049.
- [2] 舒印彪,汤涌,张正陵,等.新型配电网构建及其关键技术[J].中国电机工程学报,2024,44(17):6721-6733.
- [3] 袁桂丽,丁宁,杨彪,等.源网荷储协同优化的主动配电网日前调度[J].科学技术与工程,2024,24(24):10337-10347.
- [4] 韩顺杰,于渲铎,李东奇,等.基于改进量子粒子群算法的新能源汽车换电站优化布局[J].科学技术与工程,2024,24(27):11720-11725.
- [5] 吕顺,陶永峰.智能变电站中的继电保护防误技术分析[J].集成电路应用,2024,41(8):330-331.
- [6] 李晋,高宜凡,张杰明,等.基于电网调度运行的智能防误方法研究[J].微型电脑应用,2024,40(5):112-115.
- [7] EL K C, KHAN I, VAN D B A, et al. SRE: Semantic rules engine for the industrial Internet-of-Things gateways[J]. IEEE Transactions on Industrial Informatics, 2017, 14(2): 715-724.
- [8] 周二专,冯东豪,冯长有,等.面向电网在线分析的复杂事件处理引擎研发[J].电力系统自动化,2019,43(20):105-113,122.
- [9] 李穆,文正其,向冬冬,等.基于 Drools 的变压器故障诊断专家系统[J].水电能源科学,2015,33(9):188-191.
- [10] 袁婧,潘甦,谢浩,等.融合投资者情绪的 SAM_BiLSTM 股价预测模型[J].计算机工程与应用,2024,60(7):274-281.
- [11] JIN R, CHEN Z, WU K, et al. Bi-LSTM-based two-stream network for machine remaining useful life prediction[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-10.
- [12] 陶林娟,华庚兴,李波.基于位置增强词向量和 GRU-CNN 的方面级情感分析模型研究[J].计算机工程与应用,2024,60(9):212-218.
- [13] 董仲星,林昊,郭雄白,等.变电站多元融合全站域智能防误系统设计与实现[J].自动化技术与应用,2024,43(9):163-166,188.
- [14] 胡帮雄.基于人工智能的防误操作电压电流端子排应用[J].大众用电,2024,39(8):61-62.
- [15] 胡新雨,郁海彭,何智,等.基于人工智能的变电站倒闸智能防误技术研究与应用[J].电器与能效管理技术,2024,(6):70-79.
- [16] 陈强,宫改花,张贾军,等.变电站二次防误技术研究[J].电气自动化,2024,46(2):47-50.
- [17] 范琪,章健军,瞿旭,等.基于神经网络的变电顺序控制及防误技术优化[J].农村电气化,2022,(8):46-50.
- [18] 杨忠富,常俊,许妍,等.联合胶囊和双向 LSTM 网络的 VPN 加密流量识别[J].计算机工程与应用,2023,59(23):246-253.
- [19] 张雪明,茅健.嵌入 SENet 的卷积神经网络的零件缺陷检测方法[J].农业装备与车辆工程,2023,61(1):94-98.
- [20] SAI T K, REDDY K A. New Rules Generation From Measurement Data Using an Expert System in a Power Station[J]. IEEE Transactions on Power Delivery, 2015, 30(1):167-173.
- [21] 苏晨阳,武文红,牛恒茂,等.深度学习的工人多种不安全行为识别方法综述[J].计算机工程与应用,2024,60(5):30-46.