Adaptive Intelligent Safety Risk Warning Method for Distribution Network Operations Based on Improved Transformer and Bidirectional Gated Loop Unit*

HAN Anbing*, XU Miao, NIU Xiaojun
(State Grid Panzhihua Power Supply Company, Panzhihua Sichuan 617000, China)

Abstract: With the large-scale integration of renewable energy equipment such as wind and solar power, as well as energy storage components, into the distribution network, multiple factors such as human, material, and environmental factors lead to increasing safety risks for distribution network workers, such as misoperation and non-standard work during high-voltage line operations. A self-adaptive intelligent safety risk warning method for distribution network operations is proposed, which improves the Transformer and bidirectional gate controlled loop unit. Firstly, an improved Transformer learning mechanism combined with self attention model is proposed to extract features from diverse heterogeneous data sources, such as equipment voltage, current, positioning, and height, in high-voltage line operation scenarios. Secondly, an improved method for extracting safety features of distribution network operations using bidirectional gate controlled loop units is proposed to obtain abnormal operation features. On this basis, thirdly, by combining transfer learning methods, knowledge transfer is carried out to identify safety risks during high-voltage line operations in distribution networks. Finally, taking the operation of a high-voltage transmission line in an actual distribution network as an example, the proposed method is validated, and the results show that the proposed method has the ability to accurately obtain abnormal operation modes and provide risk warnings.

Key words: distribution network; Transformer; bidirectional gate control loop unit; homework; risk warning
EEACC: 7220; 8130 **doi**: 10.3969/j.issn.1005-9490.2026.03.025

基于改进 Transformer 和双向门控循环单元的配电网高压线路作业自适应智能安全风险预警*

韩安兵*, 徐 森, 牛小俊
(国网攀枝花供电公司, 四川 攀枝花 617000)

摘 要: 随着风、光等可再生能源设备、储能元器件大量并入配电网, 人因、物因和环境因素多因素影响使配电网工作人员在高压线路作业过程中误操作、工作不规范等安全风险越来越大。对此, 提出了改进 Transformer 和双向门控循环单元的配电网作业自适应智能安全风险预警方法。首先, 针对高压线路作业场景的设备电压、电流以及定位、高度等多元异构数据, 提出了结合自注意力模型的改进 Transformer 学习机制, 以提取多元异构数据源的特征; 其次, 提出了改进双向门控循环单元的配电网作业安全特征提取方法以获取异常作业特征; 在此基础上, 第三, 结合迁移学习方法, 对配电网高压线路作业安全事故进行知识迁移以辨识作业时的安全风险; 最后, 以某实际配电网高压输电线路作业为例, 对所提出方法进行验证, 结果显示, 所提出方法能够准确获取异常作业方式、风险告警。

关键词: 配电网; Transformer; 双向门控循环单元; 作业; 风险预警
中图分类号: TM752 **文献标识码**: A **文章编号**: 1005-9490(2026)03-0650-07

在“碳达峰、碳中和”的降碳目标政策指导下[1-3], 风、光等可再生能源大量并入配电网, 使配电网中的电网构架范围不断扩大, 电网中的发电单元、负荷单元、变压器和输电线路以及电力电子设备等元器件不断变得复杂以适应新型设备运行与维护。而这些复杂设备之间是强相关联的, 即物的因素不断增多, 加之人的心理生理因素和环境温湿度等因素的相互影响, 导致工作人员在高压线路作业过程中误操作、工作不规范以及作业作弊行为频繁发生[4-5], 由此使电网运行及工作人员的作业安全

项目来源: 国网四川省电力公司科技项目(B7199624M006)
收稿日期: 2025-06-06 **修改日期**: 2025-07-31

风险日渐增大,迫切需要研究高压线路作业风险的智能预警方法[6-8]。

对于电网安全的高压输电线路作业风险评估已经受到国内外电力科学专家学者的广泛关注,提出了一系列解决方案。文献[9-10]针对高温环境下的高压输电线路作业问题,提出了针对环境热值、人体心理生理状态的高温作业风险预测模型;文献[11-13]针对电网输电线路作业人员不规范佩戴安全帽行为,提出了基于 YOLOv3 的电网安全作业正确佩戴安全帽的检测方法;文献[14-15]基于深度学习的目标检测提出了绝缘衣服和安全帽的检测方法;文献[16-18]基于 YOLOv4 方法提出了电网高压线路现场作业中的电子围栏、杆塔安全检测系统;文献[19-20]针对高压线路带电作业现场安全距离问题,提出了考虑作业设备电位及人体体表场强、屏蔽防护的方法;文献[21-22]考虑了变电站高压线路作业人员专业技能、身份信息、身体机能、安全知识考核等作业要求,提出了施工作业人员安全管控评价系统;文献[23-24]针对高压输电线路带电作业施工中,工作人员安全监测难度较大问题,提出了考虑飞行时间深度相机的作业安全距离及绝缘绳索甄别预警方法;文献[25-26]为了提高作业人员的人身安全指数,从安全行为学、心理学、事故致因理论,提出了人-机-料-法-环的影响人身安全因素评估方法;文献[27-28]针对电网施工人员未正确佩戴安全帽、违规吸烟问题,提出了 YOLOv7 结构的安全风险在线监测系统。

总之,目前对于配电网中的工作人员安全预警的研究较少,尤其从作业环境、人员心理和生理、作业对象、工作票等多角度、多源特征评估作业人员安全方面的研究较少。本文以此作为出发点,基于多源数据,提出了基于改进 Transformer 和双向门控循环单元的配电网高压线路作业自适应智能安全风险预警方法。所提方法的创新点有:

①提出了考虑人的因素、物的因素和环境因素相互作用影响的高压线路异常作业预警框架方案;

②提出了多元异构数据与人的因素、物的因素和环境因素等多元提取方法;

③提出了结合自注意力模型的改进 Transformer 学习机制,以提取多元异构数据源的特征。

④提出了改进双向门控循环单元的配电网作业安全特征提取方法。

1　多源异构数据与事故关联模型

在工作票安全措施智能解析模式下,以配电网输电线路作业安全措施为核心,研判作业安全模型。

配电网线路作业时,对于作业人员的人身安全涉及多元异构数据源,主要有作业人员的安全帽、绝缘防护服、绝缘手套、安全靴(绝缘鞋)等,本文将此作为一级安全预警数据源,即若作业人员没有安全帽、绝缘防护服、绝缘手套、安全靴(绝缘鞋)其中之一,则进行人身安全的预警。此外,还涉及作业对象的输电线路电流、电压、断路器开关状态、作业输电线路高度、环境温度湿度、风速等六项外部数据源,作为二级安全预警数据源。

本文主要以该外部六项数据源为核心,作为作业人员安全预警的输入数据源,该数据源具有随作业时间变化特性,且该数据源的数量级和异常标准不同,对应作业人员人身安全产生的事故原因不同,需要挖掘输入源与事故之间的关联模型,以作为人身安全预警及事故反演的根本。

1.1　单输入与事故之间的关联规则

关联规则就是输入数据源与输出数据源之间的对应关系,其输入输出之间的关联通过概率的模型予以形成:

$$\begin{cases} S(X\rightarrow Y)=P(X\cup Y)=\dfrac{\mathrm{sum}(X\cup Y)}{N} \\ C(X\rightarrow Y)=P(Y\mid X)=\dfrac{\mathrm{sum}(X\cup Y)}{\mathrm{sum}(X)} \end{cases} \tag{1}$$

式中:$S(X\rightarrow Y)$表示事件 X 和 Y 同一时间发生数值,其计算形式为事件 X 和 Y 同一时间发生数值的总数 $\mathrm{sum}(X\cup Y)$除以人身事故的次数 N;$C(X\rightarrow Y)$表示事件 X 发生时,也存在事件 Y 发生,其计算方式为 X 和 Y 同一时间发生数值的总数除以事件 X 发生的次数 $\mathrm{sum}(X)$。

式(1)的关联规则是挖掘事件 X 与事件 Y 之间关联的置信度关系,若式(1)计算数值较大,则说明事件 X 与事件 Y 之间是强关联关系,若数值较小,则说明事件 X 与事件 Y 之间是弱关联关系。

式(1)中仅给出了单个输入数据源 X 与事故 Y 之间的关联模型,对于一个人身事故的发生,可能是由输入数据中的一个产生,也可能是多个输入数据共同产生。式(1)只能给出一个输入与事故之间的发生置信度关系,无法判断由哪些输入导致,由此下面给出多源数据输入与事故之间的关联关系。

1.2　多源异构数据源与事故的关联关系

某一个事件的发生可能由一个或若干个原因导致,那么设多源异构数据源矩阵为 $\boldsymbol{X}=\{X_1,X_2,\cdots,X_n\}$,其元素 $X_1,X_2,\cdots,X_n$ 表示输入的列向量,每一列向量都表示随着时间变化采集的输入数据。在配

电网输电线路作业过程中,该输入数据可以是输电线路电流、电压、断路器开关状态、作业输电线路高度、环境温度湿度、风速六个数据源获取的时序数据向量。

设向量 $\boldsymbol{Y}=[Y_1,Y_2,\cdots,Y_m]$ 表示事故向量,其中元素 $Y_1,Y_2,\cdots,Y_m$ 表示随着时间变化的作业人员的人身事故,该事故向量需要抽象为一定的数值。

对于 $Y_t(t=1,2,\cdots,m)$ 其发生事故可以由输入中的若干导致,表达为:

$$Y_t=f_t(X_1^t,X_2^t,\cdots,X_n^t) \tag{2}$$

式中:f_t 表示作用函数;$X_1^t,X_2^t,\cdots,X_n^t$ 表示 t 时刻的输入数据。

式(2)给出了输入与输出之间的函数关系式,但该函数无法解析表达从而无法预测事件 Y_t。由此,本文提出了表征工作人员作业状态与人身发生危险事故状态的对比危险状态以解决该问题。

对于输入数据的六个数据源中,输电线路作业电流、电压、作业高度、风速越小越安全,环境温度湿度在合适范围内最好,该五个输入数据源(断路器开关状态以实际要求为基准)的危险状态指标为:

$$R_i^t=\begin{cases}\dfrac{x_i^t-a_i^0}{b_i^0-a_i^0} & x_i^t<b_i^0)\\ 1 & x_i^t\geqslant b_i^0\end{cases} \tag{3}$$

式中:x_i^t 表示第 i 个输入数据状态的量测值;a_i^0 表示第 i 个输入数据的额定值;b_i^0 表示第 i 个输入数据的安全警戒值。

在式(3)指标计算模式下,可以将多源输入数据量化,同时可以对应将工作人员作业安全程度建模为:

$$O=\begin{cases}o_1 & \text{正常}\\ o_2 & \text{警戒}\\ o_3 & \text{危险}\\ o_4 & \text{严重}\end{cases} \tag{4}$$

式(3)中的输入数据危险状态指标与式(4)的 o_1,o_2,o_3,o_4 事故(输出)之间的隶属模型为:

$$\Gamma_{o_1}=\begin{cases}1 & R_i^t<0.324\\ -6.48R_i^t+2.54 & 0.324\leqslant R_i^t\leqslant 0.562\\ 0 & R_i^t>0.562\end{cases} \tag{5}$$

式中:Γ_{o_1} 表示输入与输出 o_1 之间的隶属关系。

$$\Gamma_{o_2}=\begin{cases}6.48R_i^t-1.124 & 0.324<R_i^t\leqslant 0.562\\ -0.648R_i^t+3.124 & 0.562\leqslant R_i^t\leqslant 0.687\\ 0 & R_i^t>0.687 \text{ 或者 } R_i^t<0.324\end{cases} \tag{6}$$

式中:Γ_{o_2} 表示输入与输出 o_2 之间的隶属关系。

$$\Gamma_{o_3}=\begin{cases}6.48R_i^t-3.124 & 0.562<R_i^t\leqslant 0.638\\ -0.648R_i^t+3.124 & 0.638<R_i^t\leqslant 0.887\\ 0 & R_i^t>0.887 \text{ 或者 } R_i^t<0.562\end{cases} \tag{7}$$

式中:Γ_{o_3} 表示输入与输出 o_3 之间的隶属关系。

$$\Gamma_{o_4}=\begin{cases}0 & R_i^t<0.638\\ 6.48R_i^t-3.124 & 0.638\leqslant R_i^t\leqslant 0.887\\ 1 & R_i^t>0.887\end{cases} \tag{8}$$

式中:Γ_{o_4} 表示输入与输出 o_4 之间的隶属关系。

以式(3)作为输入数据,以式(5)~式(8)作为输出,训练神经网络中的权值,以作为未来工作人员作业时人身安全预测,对此本文提出改进的 Transformer 方法。

2 结合注意力机制的改进 Transformer 方法

Transformer 是 Google 团队于 2018 年提出的深度学习方法,该理论方法采用多种注意力机制,从全局视角来实现预测任务。由于额外关注全局视角,而忽略了部分局部细节,导致预测结果存在一定的缺陷。对此,在考虑传统 Transformer 方法基础上,结合时序卷积神经网络,能够充分利用时序输入数据中隐含的局部细节,使得预测结果精度更高。

2.1 传统 Transformer 方法

Transformer 学习方法主要由输入数据时序位置定位、多注意力机制和多层神经网络编码构成。其核心内容是多维度注意力网络,该注意力网络主要是用于解决输入时序数据中长期、短期的重要性和依赖度问题,已经出现了多种改进形式,如自注意力卷积模型、时序生成编解码器等,已经在负荷预测、风功率预测等领域得到广泛应用。

首先,对于输入数据时序位置定位来说,其目标是提取时序输入数据中的关键位置,关键位置信息的提取公式为:

$$\begin{cases}\mathrm{PE}_{(\mathrm{pos},2i)}=\sin\left(\dfrac{\mathrm{pos}}{10\ 000^{\frac{2i}{d}}}\right)\\ \mathrm{PE}_{(\mathrm{pos},2i+1)}=\cos\left(\dfrac{\mathrm{pos}}{10\ 000^{\frac{2i}{d}}}\right)\end{cases} \tag{9}$$

式中:d 表示输入数据块的长度大小,i 表示时序步长,pos 表示提取的数据位置。

其次,需要获取输入数据的位置编码,其计算方法为:

$$\begin{cases}\bar{E}_t(i,:)=E_t(i,:)+P_{(\mathrm{pos},2i)}\\ Q=\bar{e}W^q\\ K=\bar{e}W^k\\ V=\bar{e}W^v\end{cases}\tag{10}$$

式中:E_t 表示输入数据的单个数值,经过与式(9)的位置嵌入一起编码,获得编码后的 $\bar{E}_t$;将编码后的数据 $\bar{e}$ 分别与权值矩阵相乘得到变换后的查询向量 Q、关键向量 K 和数值向量 V。

第三,注意力机制是在式(10)基础上通过查询向量与关键向量的点积,从而获得输入数据中的细节信息:

$$H_{\mathrm{at}}=\mathrm{Attention}(Q,K,V)=\mathrm{Softmax}\left(\frac{QK^{\mathrm{T}}}{\sqrt{d_k}}\right)\cdot V\tag{11}$$

第四,为了提高式(11)的广域视角和泛化能力,一般将式(11)进行堆聚拼接,通过全连接层输出向量投影得到各个子空间特征的联合特征提取细节,即获得多注意力信息:

$$H_{\mathrm{muat}}=W_{\mathrm{matt}}[H_{\mathrm{at1}}\quad H_{\mathrm{at2}}\quad\cdots\quad H_{\mathrm{at}m}]\tag{12}$$

式中:H_{muat} 表示多注意力信息向量;$H_{\mathrm{at1}},H_{\mathrm{at2}},\cdots,H_{\mathrm{at}m}$ 表示由式(11)获取的单注意力向量信息。

2.2　改进 Transformer 方法

在传统的 Transformer 计算过程时,随着输入数据源的多源结构和时序长度增大,其计算效率和局部细节提取精度降低,对此,本文提出了考虑多数据源窗口移动提取的改进型 Transformer 方法。

该改进型 Transformer 是以传统式(9)~式(12)为基础,采用层级网络结构增加两级移动窗口、两个感知层、四个归一化层组成。由于增加了两级移动窗口,该改进方法能够灵活缩短数据源输入数据的时序长度,删除冗余数据,提高输入数据质量,使提取的特征精度更好。其结构如图 1 所示。

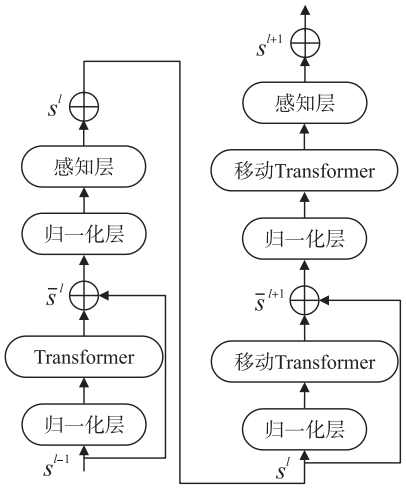

图 1　增加移动窗口的 Transformer 结构图

图 1 中的计算过程为:

$$\begin{cases}\bar{s}^{l}=\mathrm{Transformer}[\,G(s^{l-1})\,]+s^{l-1}\\ s^{l}=\mathrm{GZ}[\,G(\bar{s}^{l})\,]+\bar{s}^{l}\\ \bar{s}^{l+1}=\mathrm{HTransformer}[\,G(s^{l})\,]+s^{l}\\ s^{l+1}=\mathrm{HTransformer}\{G[\,\mathrm{GZ}(\bar{s}^{l+1})\,]\}+\bar{s}^{l+1}\end{cases}\tag{13}$$

式中:$\bar{s}^{l}$ 表示 Transformer 的第 l 窗口数据特征;s^{l} 表示感知层中输出的第 l 窗口的数据特征;函数 GZ( ) 表示感知层计算结果;G( ) 表示归一化层计算结果;HTransformer( ) 表示移动窗口的计算;$\bar{s}^{l+1}$ 表示经过 HTransformer( ) 和归一化计算结果;s^{l+1} 表示经过 HTransformer( )、归一化和感知层计算结果。

3　源域到目标域的迁移学习

经过第 2 部分的计算可以提取多源数据的特征,然而由于目标域(即人身故障)信息相对较少,因此为了保证预警信息的精确度,提出了源域至目标域的迁移学习方法以解决目标域的小样本情况。

3.1　传统迁移学习方法

传统迁移学习是将已经学习到的知识迁移到小样本目标域中的一种机器学习方法。它与传统机器学习方法不同之处在于学习测试样本足够多且样本之间满足独立性,传统迁移学习方法主要有以核学习为基础的迁移学习、以强化学习理论为基础的学习方法、以深度学习理论为基础的学习方法等。

传统迁移学习主要是将源域到源域目标中学习到的知识应用至目标域和目标域目标中。由于 Transformer 方法目前尚不能完全完成传统迁移学习的任务,由此,本文提出在 Transformer 前馈神经网络中加入损失函数以计算不同源域、目标域之间的相关性,从而缩小源域学习训练过程中泛化能力,更好地应用至目标域中。

3.2　改进的 Transformer 迁移学习方法

传统的迁移学习方法在源域的学习训练过程中,都是将损失函数进行多项式加权组合,从而构成多适应度的目标域应用,然而这种多项式组合会造成计算精度下降,对此,本文提出改进型 Transformer 损失函数方法。

设 Transformer 损失为 E_1,均方值差损失为 E_2,源域样本集合的特征值协方差向量为 E_S,目标域样本集合的特征值协方差向量 E_O,计算公式为:

$$\begin{cases}E_S=\dfrac{1}{N_S-1}\left[D_S^{\mathrm{T}}D_S-\dfrac{1}{n_s}(D_S)^{\mathrm{T}}D_S\right]\\ E_O=\dfrac{1}{N_O-1}\left[D_O^{\mathrm{T}}D_O-\dfrac{1}{n_O}(D_O)^{\mathrm{T}}D_O\right]\end{cases}\tag{14}$$

式中:D_S 表示源域中的样本集合;D_O 表示目标域中

的样本集合;N_S 表示源域中的样本数量;N_O 表示目标域中的样本数量;上标 T 表示向量矩阵转置。

根据式(14),其源域和目标域中的欧氏距离可以表达为:

$$E_1 = L(D_S, D_O) = \frac{1}{4d^2}(E_S - E_O)_{\mathrm{F}}^2 \tag{15}$$

式中:$(E_S - E_O)_{\mathrm{F}}^2$ 表示源域与目标域矩阵的 F-范数(Frobenius 范数)。

根据第 2 部分的 Transformer 部分获取的源域样本进行学习训练和目标域的样本学习训练,源域和目标域的特征提取差别保存在全连接层和输出层,其在 Hilbert 空间中的差异分布特性用均值化差异损失函数计算:

$$D_H(D_S, D_O) = \left\| \frac{1}{N}\sum_{k=1}^{n} \Phi(S_k) - \frac{1}{M}\sum_{s=1}^{M} \Phi(O_s) \right\|_{\mathrm{H}} \tag{16}$$

式中:$\| \ \|_{\mathrm{H}}$ 表示 Hilbert 核函数;N 表示源域样本数;M 表示目标域样本数。

根据式(16)可以构建损失函数 E_2 为:

$$E_2 = -\frac{1}{N_S}\sum_{i=1}^{N_s} y\lg\bar{y} + \left(\frac{2}{1+\mathrm{e}^{-10p}} - 1\right) D_{\mathrm{H}}(D_S, D_O) \tag{17}$$

式中:N_S 表示样本数量;y 表示训练样本的实际值;$\bar{y}$ 表示 Transformer 预测值;p 表示训练次数。

4 算例仿真

以某实际配电网 2022 年 7—9 月三个月共 68 776 条人员高压线路的现场作业过程原始实际数据作为本文方法验证的支撑数据,其中 60 000 条高压线路作业数据作为样本训练集合,剩余 8 776 条数据作为测试算法的集合。选取的训练数据和测试数据均是校正过的正确实际样本,其中不含测量误差、虚假等因素。同时该训练数据涵盖了基本日常线路操作方式,数据分布完整且无缺失和噪声数据。

无论是样本训练集合还是测试集合,每一条线路作业过程包含作业对象、作业前线路电压向量、电流向量、作业线路高度、环境温湿度和风速共六个数据。作业对象主要针对不同电压等级的输电线路,主要有 10 kV\35 kV\66 kV\110 kV 和 220 kV,作业对象主要有杆塔、导线、绝缘子、金具、架空地线。作业内容包含如下十类:

第一类:更换或维修架空地线。

第二类:更换或维修或瓷质清理绝缘子。

第三类:更换或维修接地导线。

第四类:更换或维修杆塔拉线。

第五类:更换或维修避雷器台架。

第六类:更换或维修或清理合成、耐张绝缘子。

第七类:更换或维修间隔棒。

第八类:清理或砍伐线路周围遮挡树木。

第九类:更换或维修断路器。

第十类:更换或维修开关。

针对上述十种作业内容,对应有三种作业方式:

方式一:不停电作业。

方式二:停电作业。

方式三:带电作业。

不停电作业是指配电网线路中的部分线路、部分元器件停电,对该停电部分进行作业,输电线路仍然能够正常输电。停电作业是指输电线路停止运行,不能够正常输送电能。带电作业是指作业部分具有一定的电压和电流,线路能够输送电能。

在上述作业内容、作业方式情况下,将作业人员的安全分为四种级别:正常、警戒、危险、严重。

为了验证本文所提算法,分别对上述十种作业内容和三种作业方式进行仿真,采用 MATLAB 软件结合 Python 软件进行程序算法编写,经过仿真测试设置 Transformer 中的边界值为 0.5,批量输入数据窗口设置为 64,训练轮次为 32 轮,初始学习速率设置为 0.1,动量设置为 0.85,权值衰减系数设置为 5×10^{-5}产生的结果较好,本文选择在此参数下的结果。经过 10 轮、15 轮、20 轮、25 轮训练后,学习率缩小至原来的九分之一。

选取 100 个、200 个、300 个、500 个第一类作业内容采用方式一进行作业作为训练集,采用 10 个样本作为测试集,作业人员安全风险结果如表 1 所示。

表 1 作业人员按方式一的安全风险预测

训练样本数	预测精度/%			
	文献[12]	文献[13]	文献[29]	本文
100	74.168	76.247	75.268	88.272
200	79.854	79.996	84.573	92.841
300	81.365	83.247	86.914	94.645
500	85.638	87.654	88.972	96.857

由表 1 可见,文献[12]、文献[13]、文献[29]和本文分别采用机器学习、深度学习和传统 Transformer 以及改进 Transformer 方法进行预测,随着输入样本的增多,预测精度逐渐提高。由于增加了传统 Transformer 多层移动窗口及感知层,结合改进迁移学习方法,本文对于工作人员作业的安全在四类风险级别中的预测精度最高,表明了所提方法在泛化性和局部细节方面的有效性。

为了进一步验证在不同作业方式及作业内容下的预测情况,本文以训练样本为 500,测试数据集采

用 10 条数据,分别对十类作业内容、作业方式三进行测试,结果如表 2 所示。

表 2　十种作业内容按作业方式三的安全风险预测结果

作业内容类别	按作业方式三预测精度/%			
	文献[12]	文献[13]	文献[29]	本文
第一类	65.547	72.354	85.364	96.341
第二类	69.577	75.241	86.610	97.524
第三类	68.713	71.257	87.514	96.397
第四类	66.547	76.542	84.352	94.326
第五类	64.259	73.657	84.021	94.687
第六类	67.247	76.548	87.629	97.384
第七类	69.847	78.501	89.967	98.741
第八类	61.025	72.324	81.324	92.315
第九类	67.583	77.684	86.337	95.642
第十类	67.851	76.547	88.522	97.849

通过表 2 可见,在对十类作业内容的测试过程中,发现文献[12]传统机器学习方法的预测精度保持在 60%~70%,文献[13]的深度学习方法的预测精度保持在 70%~80%,文献[29]的 Transformer 方法预测精度在 80%~90%,而本文改进的方法预测精度在 90%以上,具有较高的精度。

5　结论

针对配电网作业人员的安全风险预警问题,本文提出了改进的 Transformer 和迁移学习的配电网自适应智能安全风险预警方法,通过实际配电网的算例进行仿真得到如下结论:

①将配电网工作人员作业安全进行量化细分,并与输入进行隶属度匹配符合实际情况。

②采用改进的 Transformer 方法学习训练输入多源样本能够增加样本的泛化能力和捕捉细节能力,因而具有较高的预测精度。

③采用改进的迁移学习方法能够将源域学习训练效果应用至目标域,可以进一步提高预测精度。

参考文献:

[1] 李佩樾,王致杰,金珈辉. 能量及调频市场下含储联盟体的竞价行为分析[J]. 电力科学与技术学报,2023,38(3):14-23.

[2] 汤旸,刘翊枫,王静,等. 电力市场售电公司最优购售电量决策模型及其应用[J]. 电力科学与技术学报,2022,37(4):3-12.

[3] 穆云飞,吴志军,郭浩辰,等. 煤矿区综合能源微网架构及低碳运行优化研究[J]. 中国工程科学,2023,25(5):111-121.

[4] 晋旭东,孙磊,丁明,等. 考虑用户响应不确定性的园区综合能源系统分布鲁棒低碳调度[J]. 电力系统自动化,2023,47(16):10-21.

[5] Li Y, Wang B, Yang Z, et al. Hierarchical Stochastic Scheduling of Multi-Community Integrated Energy Systems in Uncertain Environments via Stackelberg Game[J]. Applied Energy,2022,308:118392.

[6] 马燕峰,骆泽榕,赵书强,等. 基于改进蒙特卡洛混合抽样的含风光电力系统风险评估[J]. 电力系统保护与控制,2022,50(9):75-83.

[7] Kou X, Li F X. Interval Optimization for Available Transfer Capability Evaluation Considering Wind Power Uncertainty [J]. IEEE Transactions on Sustainable Energy,2020,11(1):250-259.

[8] Cheng L, Wan Y X, Qi N, et al. Coordinated Operation Strategy of Distribution Network with the Multi-Station Integrated System Considering the Risk of Controllable Resources[J]. International Journal of Electrical Power and Energy Systems,2022,137:107793.

[9] 沈雅利,毛焱,李华亮,等. 电网人员高温作业安全预警系统的研究与应用[J]. 广东电力,2023,36(11):106-113.

[10] 吴建松,李乐天,韩新阳,等. 高温户外环境电网作业人员热应激预测评价[J]. 中国安全生产科学技术,2021,17(12):169-175.

[11] 屈文谦,邱志斌,廖才波,等. 基于 YOLOv3 的电网作业人员安全帽佩戴检测[J]. 中国安全生产科学技术,2022,18(2):214-219.

[12] 杨冬冬,王伟,王凯,等 新型电力系统背景下对传统故障隔离技术的融合性研究[J]. 电子器件,2025,48(1):155-163.

[13] 李华,王岩彬,益朋,等. 基于深度学习的复杂作业场景下安全帽识别研究[J]. 中国安全生产科学技术,2021,17(1):175-181.

[14] Li N,Lyu X,Xu S K,et al. Incorporate Online Hard Example Mining and Multi-Part Combination into Automatic Safety Helmet Wearing Detection[J]. Institute of Electrical and Electronics Engineers Access,2021,9:139536-139543.

[15] Wu X,Li Y,Long J,et al. A Remote-Vision-Based Safety Helmet and Harness Monitoring System Based on Attribute Knowledge Modeling[J]. Remote Sensing,2023,15(2):347-366.

[16] Peng G Y,Lei Y,Li H L,et al. CORY-Net:Contrastive Res-YOLOv5 Network for Intelligent Safety Monitoring on Power Grid Construction sites[J]. IEEE Access,2021,9:160461-160470.

[17] 曹捷,郭志彬,潘立志,等. 高空作业场景下的安全带穿戴检测[J]. 湖南科技大学学报(自然科学版),2022,37(1):92-99.

[18] Zhao B N, Lan H J, Niu Z W, et al. Detection and

Location of Safety Protective Wear in Power Substation Operation Using Wear-Enhanced YOLOv3 Algorithm[J]. IEEE Access,2021,9:125540-125549.

[19] 陶留海,孙超,李雪奎,等. ±1 100 kV 特高压直流输电线路带电作业实用化技术研究[J]. 中国电机工程学报,2020,40(S1):134-139.

[20] Ding Y J,Li J W,Sun W X,et al. Electric Field Characteristics of UHV DC Tension String during Insulator Replacement by Two Workers [J]. IET Science, Measurement & Technology,2022,16(2):78-89.

[21] 李稳,顾苏,汪志刚,等. 基于 ToF 技术的带电作业安 全监测与预警系统[J]. 中国电力,2020,53(2):63-68.

[22] 何剑军,林裕新,刘敬诚. 基于状态感知的智能电网接地线监测和自供电无线传感器研究[J]. 电子器件,2024,47(6):1589-1594.

[23] Zhou Q,He W,Li S,et al. Research on the Group-Type of High Voltage Electric Field Measurement Safety Distance Caution Apparatus[J]. International Journal of Grid and Distributed Computing,2016,9(8):109-120.

[24] 邹德华,严宇,王伟,等. 基于 TOF 技术的高压输电线路带电作业安全检测方法[J]. 高电压技术,2020,46(7):2570-2577.

[25] 陶留海,唐盼,刘凯,等. 哈郑±800 kV 直流接地极架空线路带电作业安全距离研究[J]. 高电压技术,2018,44(3):976-981.

[26] 魏秀宁,杨悦群,王淦彪,等. 供电作业人身安全风险评估与控制[J]. 电力系统及其自动化学报,2016,28(8):105-110.

[27] Vaurio J K. Human Factors,Human Reliability and risk Assessment in License Renewal of a Nuclear Power Plant [J]. Reliability Engineering and System Safety,2019,94(11):1818-1826.

[28] 彭放,刘甜甜,卢伟龙,等. 基于深度学习的智能电网主动式外部作业人员安全风险因素监测[J]. 电测与仪表,2025,62(7):209-216.

[29] 项俊,张金城,江小平,等. Transformer-CNN 特征跨注意力融合学习的行人重识别[J]. 计算机工程与应用. 2024,60(16):94-104.

韩安兵(1977—),男,四川泸州人,本科,高级工程师,主要研究方向:电力系统稳定与可靠性、电力系统自动控制,514792669@qq.com。