DOI: 10.7500/AEPS20210629004

# 基于三维卷积神经网络的配电物联网异常辨识方法

股浩然<sup>1,2</sup>,苗世洪<sup>1,2</sup>,韩 佶<sup>1,2</sup>,王子欣<sup>1,2</sup>,毛万登<sup>3</sup>,牛荣泽<sup>3</sup> (1.强电磁工程与新技术国家重点实验室(华中科技大学),湖北省武汉市 430074;

2. 电力安全与高效湖北省重点实验室(华中科技大学电气与电子工程学院),湖北省武汉市 430074;
 3. 国网河南省电力公司电力科学研究院,河南省郑州市 450052)

摘要:由于配电物联网中电力网与通信网高度耦合,单一网络的异常状态会交互作用至另一网络,可能进一步造成异常范围扩大,而单独采用电力网或通信网的异动信息难以全面、准确地辨识配电物联网异动源的类型和位置。因此,提出一种基于三维卷积神经网络(3D-CNN)的配电物联网异常类型辨识及定位方法。首先,分析了配电物联网通信流量特征并构建了基于Simulink和OPNET的配电物联网交互仿真模型;其次,提出了一种面向3D-CNN的样本构建方法,将配电物联网中每个节点的电气量和通信流量信息组成一个特征子像素,进而将配电物联网每个时刻的状态表示为一幅特征帧画面,形成隐含配电物联网异动过程的立方样本矩阵;随后,构建了包含三维特征提取网络和层级 softmax 分类器的深度学习模型,通过提取和辨识立方样本矩阵中隐含的异常信息,可以同时实现配电物联网异常类型和位置的判定;最后,利用 IEEE 33节点配电物联网异常数据对模型进行测试,结果表明,所提方法可以对电力网短路故障、通信中断故障、通信数据异常引起的保护误动和拒动进行精确的分类及定位。

关键词: 配电物联网; 深度学习; 交互仿真; 异常辨识及定位; 三维卷积神经网络

#### 0 引言

当前,能源革命和数字革命正在深度融合,为适 应能源互联和"30·60目标"要求,配电网不断融入 先进的传感测量、保护控制和数据通信等技术,正逐 步由传统的电力网转变为电力网和通信网高度耦合 的配电物联网<sup>[1]</sup>。当电力网出现异常状态时,可能 会引起通信网络拥塞,降低通信网络性能,进一步导 致电力网故障扩大;当通信网出现通信中断、数据异 常等异常状态时,可能会引起电力网智能终端误动 或拒动,造成电力网故障。因此,为全面、准确地辨 识配电物联网异动源的类型和位置,需充分考虑电 力网和通信网的交互影响,综合分析电力网和通信 网的异动信息,以实现电力网和通信网异常类型和 位置的统一辨识。

针对配电物联网,当前研究主要从通信网流量 特征分析及建模、配电网信息物理系统仿真平台构 建和通信网异常流量检测等方面开展,针对电力网 和通信网异常辨识的研究较少。文献[2]分析了配

收稿日期: 2021-06-29; 修回日期: 2021-09-18。

上网日期:2021-11-01。

国家电网有限公司总部科技项目(SGHADK00PJJS2000026)。

电网的信息架构,为电力网与通信网的交互分析奠 定了基础;文献[3-5]分析了配电通信业务特点和数 据流量的自相似特征,文献[6-8]分析了电力网和通 信网出现异常时通信流量的特征,并建立了相应的 信源模型:在上述研究的基础上,文献[9-13]提出了 基于通信流量差分序列方差、小波分解能量值、时频 混合特征的通信网异常辨识方法。然而,上述研究 主要针对通信网异常开展,未考虑通信网异常对电 力网造成的影响。文献[14]指出需要对电力网故障 和通信节点故障进行统一辨识,并提出了基于多维 尺度分析和局部异常因子的配电网故障辨识方法, 但该方法仅考虑了电力网或通信网故障后最终反映 到电气量的特征,难以准确辨识通信网的异常状 态。综上,现有研究多单独针对电力网或通信网开 展,较少考虑电力网和通信网的交互影响,难以实现 配电物联网异常的统一辨识。

深度学习由数据驱动构建深层神经网络,可自动提取输入数据特征并进行归纳分类<sup>[15]</sup>。近年来 有学者将卷积神经网络(CNN)算法应用于输电线 路故障选相<sup>[16]</sup>、区内外故障判别<sup>[17]</sup>、故障定位<sup>[18]</sup>和 输电网故障线路判定<sup>[19]</sup>等问题。然而,上述研究均 基于二维卷积神经网络(2D-CNN)开展,当原始样 本数据较为复杂时,直接由时序数据排列形成的二 维样本往往难以满足要求,需要利用复杂的预处理 方法将电气量时序数据构建成二维图形<sup>[19-21]</sup>,最终 效果也依赖于数据预处理过程,限制了CNN在时序 数据特征提取方面的应用。文献[22]在2D-CNN 的基础上引入时间维度,提出了三维卷积神经网络 (3D-CNN),并被应用于视频检测<sup>[23]</sup>和三维图像辨 识<sup>[24]</sup>等问题,取得了良好效果,但还未被应用于电 力领域。

因此,本文提出一种配电物联网异常辨识方法, 利用 3D-CNN 提取电气量、通信量与配电物联网异 常状态之间的映射关系,实现了配电物联网异常类 型和异动源位置的统一辨识,并通过仿真数据验证 了本文方法的有效性。

## 1 配电物联网异常分析与交互仿真

# 1.1 配电物联网异常状态分析

配电物联网的分层结构如图1所示,由于电力 网与通信网的深度耦合,二者之间的交互作用易使 故障范围扩大,给电力网与通信网的统一异常辨识 增加了难度。



图 1 配电物联网电力网和通信网耦合关系 Fig. 1 Coupling relation between power grid and communication network in distribution Internet of Things

#### 1) 电力网异常

电力网通过配电终端与通信网进行信息交互, 当电力网正常运行时,通信网数据流包含配电终端 周期性上传的采样值报文、量测值和状态信息组成 的周期性数据流,以及由开关操作命令、跳闸命令等 外部事件驱动的随机性数据流;当电力网出现短路 故障等异常状态时,配电终端需彼此发送跳闸信号, 间隔层设备需上传保护动作信息和开关变位信息, 产生突发性数据流。因此,当电力网出现异常状态 时,通信网数据流量突发性上升,可能引起通信延迟 甚至网络拥塞,造成停电范围扩大。

2)通信网异常

相较于输电通信网,配电通信网建设相对落后, 部分通信业务需要由公网承担,这增加了配电通信 网的可靠性风险<sup>[4]</sup>。当某条通信链路发生故障时, 会导致主站丧失对相应终端的感知和控制能力,无 法及时对配电网故障进行处理;当通信网遭受数据 侵入攻击等信息安全事件时,可能导致传输错误、虚 假信息,进一步造成智能终端的拒动或误动。

# 1.2 通信网流量建模

## 1) 周期性数据流

周期性数据流由配电终端周期性上传的采样值 报文、量测值和状态信息构成,属于时间驱动型数据 流,可用周期性间隔、恒定长度的周期性报文来模 拟,其数学模型如式(1)所示。

$$F_{\rm p} = (L, P, T, D) \tag{1}$$

式中: $F_{p}$ 为周期性数据流量;L为报文长度;P为数 据流间隔周期;T为端对端时延;D为允许的最大时延,且满足 $T \leq D$ 。

2)随机性数据流

随机性数据流主要包含开关操作、跳闸命令、保 护功能连锁和保护定值修改、事件记录查看、录波数 据传输等,属于外部事件驱动型数据流,由故障等外 部事件触发,可以用 Poisson 过程来近似<sup>[3]</sup>。

设N(t)表示t时刻的报文总数, $\lambda$ 表示报文平均 到达速率,则在[s,s+t]时间段内到达k个报文的概 率满足式(2)。

$$P\{N(s+t)-N(s)=k\} = \frac{(\lambda t)^k e^{-\lambda t}}{k!} \quad (2)$$

报文到达时间间隔服从参数为1/λ的负指数分 布,其分布密度函数式(3)所示。

$$g(t) = \lambda e^{-\lambda t} \tag{3}$$

3)突发性数据流

突发性数据流主要包含故障情况下间隔层设备 上传的保护动作信息、开关变位信息,以及事件顺序 记录信号,具有自相似性,可以用服从广义Pareto分 布的On/Off数据源模拟其数据流<sup>[4]</sup>,Pareto分布函 数如式(4)所示。

$$G(t) = \begin{cases} 1 - e^{-\frac{t-\mu}{\delta}} & t \ge \mu \\ 0 & t < \mu \end{cases}$$
(4)

式中:μ为位置参数;δ为尺度参数。

#### 1.3 交互仿真模型

基于数据驱动的深度学习模型需要利用大量样 本数据进行训练,以获取样本特征信息与配电物联 网异常状态之间的映射关系,而实际配电网异常数 据难以满足训练要求。因此,需构建配电物联网仿 真模型。

配电物联网属于典型的信息物理系统,单一的 电气仿真无法准确描述通信系统特征,目前学者多 采用混合仿真方案构建其仿真模型,即基于通信仿 真平台和电气仿真平台分别建立通信模型和电气模 型,再实现二者的信息交互<sup>[25-27]</sup>。基于上述思想,本 文分别在 Simulink 和 OPNET 仿真平台中构建了 IEEE 33节点网络的电力网和通信网仿真模型,其 拓扑结构如附录 A 图 A1所示。基于文献[28]提出 的 Simulink 和 OPNET 联合仿真架构,通过二者提 供的外部接口实现二者的信息交互和时间同步,从 而模拟配电物联网出现异常时电力网与通信网之间 的交互影响,原理框图见附录 A 图 A2,其中 $F_p$ 、 $F_r$ 和  $F_b$ 分别表示周期性数据流、随机性数据流和突发性 数据流。

### 2 基于 3D-CNN 的异常辨识模型

配电物联网各节点电气量和通信流量的时序动态变化可以反映系统的运行状态,当电力网或通信 网出现异常状态时,整个系统的电气量与通信流量 存在由正常状态到异常状态的动态过程,本文通过 提取该动态过程的特征信息,以实现对配电物联网 的异常类型辨识和定位。

#### 2.1 立方样本矩阵构建

3D-CNN的输入样本为 $x \times y \times t$ 的三维矩阵, 可以看作由t帧 $x \times y$ 的画面组成。受文献[21]提 出的二维画面构建方法启发,可以将每个时刻的配 电物联网运行状态视为一帧 $x \times y$ 的画面,因此通 过t帧画面堆叠即可反映配电物联网在时间段  $(t_0, t_0+t)$ 内运行状态的动态过程。如图2所示,首 先,采集配电物联网各节点的电气量和终端通信流 量时序数据,在分别归一化后对齐电气量和通信流 量的时间标度;其次,针对每个时刻的采样值,将每 个节点的电气量和通信流量组合为一个特征子像 素,将所有节点对应的特征子像素按照拓扑节点编 号顺序排列形成 $x \times y$ 的特征帧画面;最后,将  $(t_0, t_0+t)$ 内的特征帧画面进行堆叠,即可构成面向 3D-CNN的立方样本矩阵 $C_{xyc}$ 

## 2.2 三维特征提取网络

为了提取配电物联网运行状态的动态变化过程,需要同时捕获立方样本矩阵3个维度的信息,因此本文基于3D-CNN构建了三维特征提取网络,如图3所示。

首先,当判定系统出现异常状态时,截取阶数为  $x \times y \times t$ 的立方样本矩阵作为网络输入,利用多个 三维卷积核(阶数为 $k_{x1} \times k_{y1} \times k_{d}$ )对输入的立方样 本矩阵从3个维度进行滑步卷积计算,如式(5)所 示,获得多个三维特征体(阶数为 $m_x \times m_y \times m_t$ ),三 维特征体的阶数满足式(6),每个三维特征体均记录

#### ・面向现代电力系统的数据驱动方法・



图 2 面向 3D-CNN 的立方样本矩阵构建过程 Fig. 2 Construction process of cubic sample matrix for 3D-CNN



图 3 三维特征提取网络与层级 softmax 分类器 Fig. 3 Three-dimensional feature extraction network and hierarchical softmax classifier

着输入样本不同区域的高维特征。

$$\boldsymbol{M}_{\text{out}}^{(l)} = \boldsymbol{f}(\boldsymbol{M}_{\text{in}}^{(l)} \otimes \boldsymbol{K}_{\text{cov}}^{(l)} + \boldsymbol{b}^{(l)})$$
(5)

$$m_{xyt}^{(l)} = \frac{m_{xyt}^{(l-1)} - k_{xyt} + 2p}{s} + 1 \tag{6}$$

式中:l为网络层序号; $M_{out}^{(l)}$ 为第l层网络输出的三维 特征体矩阵; $M_{in}^{(l)}$ 为第l层网络的输入矩阵,也是第 l-1层网络的输出;  $\otimes$  表示滑步卷积运算过程; $K_{cov}^{(l)}$ 和 $b^{(l)}$ 分别为第l层的三维卷积核和偏置量;f(x)为 ReLU激活函数; $m_{xyt}^{(l)}$ 和 $m_{xyt}^{(l-1)}$ 分别为第l层和第l-1层三维特征体的阶数; $k_{xyt}$ 为三维卷积核的阶数;p和 s均为网络训练时设置的结构参数,分别表示对输入 矩阵的填补值和卷积运算的跨步值。

随后,在每个三维特征体后连接池化核(阶数为  $k_{x2} \times k_{y2} \times k_{a2}$ ),对特征体进行降分辨率采样,进一步 得到二次特征矩阵(阶数为 $s_x \times s_y \times s_z$ )。本文采用 最大值池化方法,如式(7)所示,即输出池化核连接 的域中的最大值。通过池化操作可以对高维特征进 行二次提取,并使网络具有空间不变性<sup>[29]</sup>,增强网络的泛化能力。

$$\boldsymbol{M}_{\text{out}}^{(l+1)} = \boldsymbol{f}_{\text{max}} \left( \boldsymbol{M}_{\text{in}}^{(l)} \otimes \frac{1}{K_{\text{sub}}} \right)$$
(7)

式中: $K_{sub}$ 为池化核矩阵; $f_{max}(\cdot)$ 为取最大值函数。

特征提取网络由若干组"卷积-池化"结构组成, 深度越深,特征空间的维度越高,网络的学习能力也 越强,但同时会增大网络的计算复杂度和过拟合可 能性,因此网络深度应结合实际问题确定。

最后,在特征提取网络末端加入全连接网络,与 前一层的所有神经元相连接,整合由"卷积-池化"结 构提取的高维特征,用于后续的异常类型辨识及定 位。同时,在全连接层加入Dropout<sup>[30]</sup>环节,以降低 模型发生过拟合的可能性,提高泛化能力。

# 2.3 层级 softmax 分类器

为实现对特征的辨识,通常利用 softmax 分类器 对网络的输出结果进行分类。传统的 softmax 属于 单层分类器,通过选择全连接层输出向量中最大元 素,得到深度学习模型的分类结果,因此仅能针对单 一问题进行分类。为利用一个神经网络统一辨识配 电物联网异常类型和异动源位置,本文提出层级 softmax 分类器,针对全连接层输出向量,利用第一 层级计算样本属于不同异常类型的概率,进一步利 用第二层级计算样本异动源位于不同位置的概率, 最后输出两层的综合判断结果。

## 2.4 模型训练策略

三维特征提取网络的监督学习训练过程通过小 批量梯度下降算法(SGDM)进行,包含网络初始 化、前向传播、反向传播3个步骤。

1) 网络初始化: 训练前, 按式(8) 对三维卷积核 和池化核参数进行随机初始化, 从而使网络获得学 习能力。

$$k_{ijl} = \text{rand} \{ [-1, 1] \}$$
 (8)

式中: $k_{ijl}$ 为三维卷积核或池化核中的元素;rand {·}表示取随机数运算。

2)前向传播:每次以一组立方样本矩阵 C<sub>xyt</sub>作 为输入,按照式(9),逐层经过三维卷积运算、池化运 算、全连接网络运算3个环节,得到输出向量 O,表 示网络判定该组输入样本对应的异常类型和异动源 位置。

$$O = f_{\rm F}(f_{\rm S}(f_{\rm C}(C_{xyt}))) \tag{9}$$

式中: $f_{c}(\cdot)$ 表示三维卷积运算过程; $f_{s}(\cdot)$ 表示池化 过程; $f_{F}(\cdot)$ 表示全连接网络运算。

3)反向传播:通过比较网络输出与训练数据标 签之间的误差,并按式(10)反向传播至池化层和卷 积层,向降低误差的方向调整核参数。

$$k_{xyt1} = k_{xyt0} + Bp(\alpha E_{12})$$
 (10)

式中: k<sub>xy0</sub>和 k<sub>xy1</sub>分别为调整前后的核参数; Bp(·)表示小批量梯度反向传播的运算过程; E<sub>12</sub>为网络输出与数据标签之间的误差, 通常表示为二者的方差; a 为网络的学习率, 用于设定反向传播过程的调整幅度。

训练过程基于SGDM算法,将训练样本分批输入三维特征提取网络,进行多次前向传播与反向传播过程。由于每批输入样本的梯度具有一定的随机性,从而使模型在训练过程中更易跳出局部最优点。随着核参数随训练过程的逐步调整,即可使网络具备将输入样本映射到配电物联网异常类型和异动源位置的能力。同时,为避免网络优化过程中的参数过拟合问题,本文在训练集生成过程中尽可能覆盖配电物联网的运行场景,以使模型学习的规则和理想规则趋于一致<sup>[31]</sup>,从而避免网络参数过拟合问题。

#### 2.5 特征帧异常度

深度学习算法运算过程较为复杂,运算时长难 以满足对配电网异常状态的实时辨识。因此,本文 用式(11)所示的异常度衡量每个特征帧相较于配电 物联网额定运行状态下特征帧的差异程度,当异常 度大于特定阈值时调用深度学习异常辨识算法,从 而降低工程应用时对服务器的算力要求。

$$\Delta D = \frac{\sqrt{\sum_{i=1}^{X} \sum_{j=1}^{Y} \left( \frac{a_{ij} - n_{ij}}{b_{ij} - n_{ij}} \right)^2}}{XY}$$
(11)

式中: $\Delta D$ 为当前时刻特征帧的异常度; $a_{ij}$ 为当前时 刻特征帧第i行第j列的元素值; $b_{ij}$ 为电压和负荷在 正常范围波动时特征帧第i行第j列元素的平均值;  $n_{ij}$ 为额定运行状态下特征帧第i行第j列的元素值; X、Y分别为特征帧的行数和列数。

理论上,  $\Delta D$ 可以利用数学计算方法得到精确 结果。但是,考虑到配电物联网中异常场景的复杂 性、通信流量变化的差异性,实际中难以通过理论计 算得到该阈值。因此,本文利用仿真的方式覆盖了 异常场景中各个数据的取值范围,通过试验的方式 确定  $\Delta D$ 的取值。根据大量仿真结果,当  $\Delta D \ge 1.1$ 时认为配电物联网出现异常状态。

#### 3 算例分析

#### 3.1 典型样本生成

实际工程中的故障数据由于数量少、质量低、标签不全,很难满足深度学习的训练要求,本文考虑配电物联网实际运行特点,利用1.3节所述的IEEE 33

节点配电物联网仿真模型生成数量充足的典型样本,用于异常辨识模型的训练。

配电物联网运行过程中,其电压、负荷、异常位 置、异常类型等均可能分布在一定范围内,理论上有 无穷种运行场景。本文首先对上述可变参数取有限 个典型值,见附录A表A1,对参数典型值进行遍历 构成22400个故障场景;随后采集故障前后共0.1s 各节点对应的配电终端通信流量、节点电压、支路电 流时序数据,并记录故障标签,生成典型参数数据 集;最后,基于2.1节所述方法,将每个节点对应的 支路电流、通信流量和每条干线的末端电压时序数 据构建为17×17×50的立方样本矩阵,共生成 22400组典型样本数据集。基于典型样本数据集对 深度学习模型进行训练,可以使模型通过学习得到 异常辨识的规则,从而具备应对相似"新样本"的泛 化能力,当配电物联网运行场景与上述典型场景相 近时,模型依然有效。

#### 3.2 模型结构参数和超参数调整

目前,神经网络层数的确定并没有普适性方法, 需要根据所解决的问题特点进行试验。由于本文中 的样本立方矩阵由采集的电气量和通信量构成,其 样本特征与像素取值复杂度不高,利用深度较浅的 网络即可得到高精度的故障辨识结果。因此,本文 基于复杂度适中的LeNet-5网络结构设计了深度学 习网络,故障辨识模型中的特征提取网络主体结构 采用"卷积层I-池化层I-卷积层II-池化层II",在 此基础上需根据模型的训练效果调整结构参数和超 参数,以生成效果较好、训练速度较快的异常辨识模 型。网络的结构参数和超参数如表1所示。

	表	1 特征提	取网络的	结构参	数和超参数	
Table	1	Structure	paramete	rs and	hyperparame	ters
		of foots		4: am	terr o mla	

参数类型	符号表示	含义			
	$k_{x1} \times k_{y1} \times k_{t1}$	卷积核阶数			
结损余粉	$k_{x2}  imes k_{y2}  imes k_{t2}$	池化核阶数			
垣鸭参数	$P_{a}$	输入立方矩阵的三维填补值			
	$S_{\mathrm{t}}$	卷积运算三维跨步值			
	$B_{\mathrm{a}}$	批训练数目			
切全粉	α	学习率			
旭参奴	β	迭代次数			
	$D_{\mathrm{p}}$	Dropout随机失活率			

本文采取由结构参数到超参数的分步调整步骤,具体如下。

1)将超参数设置为典型值,如附录A表A2所示。根据输入立方样本矩阵的阶数确定结构参数的

可选值,构建结构参数不同的多个特征提取网络,并 利用典型样本集对所有模型进行训练和验证,记录 各组结构参数下模型的准确率和训练时间,如附录 A图A3所示。根据不同结构参数下模型的准确率 和训练时间,确定特征提取网络的结构参数。附录 A图A3中net1~net20表示不同结构参数下的特征 提取网络,具体结构参数见附录A表A3,其中下标 I、Ⅱ分别对应层I、层Ⅱ。由该结果可知,net10、 net12和net17准确率较高且训练时间较短,其网络 结构较适合配电物联网异常辨识问题。

2)针对 net10、net12 和 net17,进一步利用控制 变量法分别调整各超参数取值,记录不同超参数下 模型的准确率和训练时间,附录A图A4和表A4展 示了 net10、net12和 net17在改变单一超参数时准确 率的分布情况。结果表明:B<sub>a</sub>与准确率呈非线性关 系,其值增大有助于减小训练时间;α对准确率和训 练时间影响不大;β增大有助于提高准确率,但增大 到一定程度后对准确率提升的效果较小,而与训练 时间基本成正比;D<sub>p</sub>增大对准确率有小幅提升作 用,且对训练时间影响不大。

根据上述测试结果,综合考虑准确率和训练时间,确定异常辨识模型的结构参数和超参数如表2 所示。将训练好的模型保存后,后续测试可直接调 用模型进行异常辨识和定位,无需重复训练。

	of anomal	y identification model
序号	结构	参数
1	输入层	阶数为17×17×50的立方样本矩阵
2	三维卷积层1	卷积核:6×6×7(矩阵阶数,下同); 填补值:2×2×2;跨步值:2×2×3
3	特征面1	7组三维特征体,阶数为8×8×16
4	三维池化层1	池化核:1×1×1
5	三维卷积层2	卷积核:2×2×3;填补值:1×1×0; 跨步值:1×1×1
6	特征面2	17组三维特征体,阶数为9×9×14
7	三维池化层2	池化核:1×1×1
8	全连接层	输出:4×32(向量维数)
9	softmax 层	_
10	超参数	$B_{\rm a}$ 取35, $\alpha$ 取0.8, $\beta$ 取5, $D_{\rm p}$ 取0.6

表 2 异常辨识模型结构参数及超参数 Table 2 Structure parameters and hyperparameters of anomaly identification model

注:"一"表示无参数。

#### 3.3 异常辨识模型效果测试

调整配电物联网交互仿真模型的参数形成不同 于训练样本的35种参数组合,同时考虑32种异常 位置和4种异常类型,共生成35×32×4=4480组 故障数据,构成测试样本集。以其中一组故障数据 为例,当电力网节点13和14之间的线路L<sub>14</sub>发生AB 相接地短路故障时,附录A图A5展示了故障前后 节点13处的电气量和智能终端通信流量变化情况, 在-50~0 ms时,电力网正常运行,只触发周期性数 据流,在0~50 ms时,电力网出现短路故障,会触发 相应通信线路的随机数据流和突发数据流。在交互 仿真模型中,不同的异常类型会触发 OPNET中异 常节点相应类型的数据流,从而产生不同特征的通 信流量。

将故障前后采集的电气量和通信流量构建成立 方样本矩阵,输入训练好的异常辨识模型,全连接层 的输出结果为1×128的向量,每个元素 $x_i$ 代表一条 线路发生某种故障类型的概率,如图4所示,其中第 1~32个元素表示支路L<sub>1</sub>~L<sub>32</sub>发生异常A的概率, 第33~64个元素表示支路L<sub>1</sub>~L<sub>32</sub>发生异常B的概 率,以此类推。全连接层后连接层级 softmax分类 器,其中第1层分别计算 $\sum_{i=1}^{32} x_i \sum_{i=65}^{64} x_i n \sum_{i=97}^{128} x_i$ 的值,分别作为异常类型A~D的概率,以四者中的 最大值作为模型对异常类型的判断结果;第2层分 别计算 $x_i + x_{i+32} + x_{i+64} + x_{i+96}(i=1,2,\cdots,32)$ ,以 32个求和结果中的最大值代表模型对异动源位置 的判断结果。



图 4 表明,训练好的异常辨识模型能以较高的 可靠性对输入样本对应的异常类型和异动源位置进 行准确辨识。对于图 4 所示结果,层级 softmax 分类 器输出的综合判断结果为"A-14",即输入样本表明 配电物联网异常类型为短路故障,且故障位置位于 线路 L<sub>14</sub>,辨识结果与实际异常类型和异动源位置 一致。

将4种异常类型共计4480组测试样本均按上 述过程依次输入训练好的异常辨识模型进行测试, 共耗时40.86 ms,辨识结果如附录A图A6所示。由 附录A图A6可见,测试样本的异常类型均识别正确,其中A、B、D这3类异常的异动源位置均识别准确,C类异常中有59组样本的异动源位置识别错误,具体见附录A表A5,异动源位置准确率为 98.68%。结合附录A图A1所示拓扑结构进行了分析,对于59组异动源位置错误样本,模型识别结果均与真实异动源位置相邻,其主要原因在于相邻位置发生异常状态时在立方样本矩阵中的特征极为相似。

#### 3.4 单数据源与统一数据源模型效果对比测试

为测试电气量和通信流量数据分别对模型训练效果的影响,针对同样的 3D-CNN 网络结构,分别利用电气量数据、通信流量数据、电气量和通信流量统一数据对模型进行训练和测试,3组数据集对应的特征子像素如附录A图A7所示。

图 5 展示了 3 组数据集训练过程的损失值和准确率,3 组数据集训练过程的损失值均接近 0,表明模型已经对训练数据进行了充分的拟合;当仅利用电气量数据训练模型时,训练集和验证集的准确率趋势相同,但增大到约 90% 时无法继续提高;当仅利用通信流量数据训练模型时,训练集准确率约为50%,但验证集准确率达到 100%,说明模型出现了过拟合,说明单独利用通信流量判断异常类型和位置的可学习性较差。

将4480组测试集数据输入上述3个训练后的 网络,全连接层的输出可视化后如附录A图A8所 示。结果表明,仅利用电气量数据训练的网络无法 区分部分区域发生的异常类型A和异常类型B,其 综合准确率为89.67%;仅利用通信流量数据训练的 网络会将异常类型C和异常类型D完全混淆,部分 异常类型B也会定位错误,其综合准确率为 50.00%;利用电气量和通信流量综合数据训练的网 络可以准确判别4种异常类型,且定位准确率很高, 其综合准确率为98.68%。

上述结果表明,由于配电物联网出现异常状态 时电力网与通信网存在交互影响,仅电气量数据或 通信流量数据隐含的特征信息难以全面反映异常类 型和位置,需要综合提取异常后的电气量和通信流 量数据以准确辨识异常类型和位置。

## 3.5 3D-CNN与2D-CNN模型效果对比测试

为测试针对时序数据时 3D-CNN 相较于 2D-CNN的优势,基于文献[16]中的二维矩阵直接 排列构建方法,首先对节点的电气量和对应通信链 路的通信流量时序数据进行与2.1节相同的归一化 和间隔采样过程,形成离散时间序列;然后,按照线 路编号依次对上述时间序列进行排列,从而形成二 维样本矩阵,构建过程如附录A图A9所示。

附录A图A10展示了基于2D-CNN的异常辨 识模型训练过程的损失值和准确率,相较于图5(c) 中的3D-CNN训练过程,训练集和验证集的损失值



图 5 基于甲数据源和统一数据源的模型训练过程 Fig. 5 Model training process based on single data source and unified data source

随着训练过程无明显下降,且正确率较低。上述结 果表明,基于直接排列形成的二维矩阵训练的 2D-CNN模型难以适用于配电物联网异常类型辨识 及定位问题。

从 2D-CNN 和 3D-CNN 的训练效果对比可以 看出,若不采取经过设计的样本矩阵,2D-CNN 难以 应对较为复杂的时序数据特征提取和分类问题。当 均采用直接排列或堆叠方法构建样本矩阵时, 3D-CNN在提取时序数据特征方面具有较大优势。

## 4 结语

由于配电物联网中电力网与通信网高度耦合, 二者在出现异常时会产生交互影响,单独采用电力 网或通信网的异动信息难以全面、准确地进行异常 类型和位置的判断。针对上述问题,本文引入了 3D-CNN综合提取电力网和通信网的时序异动信 息,实现了配电物联网异常类型和位置的统一判 定。通过理论和算例分析结果可以得出如下结论:

1)配电物联网出现异常时,由于电力网和通信 网都存在异动信息,单独采用电力网或通信网异动 信息时难以区分不同的异常类型,准确率较低;

2)3D-CNN在数据预处理阶段无需复杂的数学 计算方法,通过对时序数据的依次堆叠即可形成效 果较好的立方样本矩阵,其异常类型辨识及定位效 果优于使用直接排列二维矩阵的2D-CNN;

3)本文构建的立方样本矩阵可以反映配电物联 网异常前后的动态过程,利用3D-CNN提取立方样 本矩阵中隐含的异动信息,可以实现对电力网短路 故障、通信中断故障、通信数据异常引起的保护误动 和拒动等几种异常的准确分类和定位。

多种传感监测装置的引入为配电网的态势感知 提供了数据基础,在本文构建的立方样本矩阵的基 础上,融入更多类型的传感监测数据,实现配电网的 精确运行态势感知,是后续研究的方向之一。

附录见本刊网络版(http://www.aeps-info.com/ aeps/ch/index.aspx),扫英文摘要后二维码可以阅读 网络全文。

## 参考文献

[1] 秦博雅,刘东.电网信息物理系统分析与控制的研究进展与展望[J].中国电机工程学报,2020,40(18):5816-5827.
 QIN Boya, LIU Dong. Research progresses and prospects on

analysis and control of cyber-physical system for power grid[J]. Proceedings of the CSEE, 2020, 40(18): 5816-5827.

- [2] 赵江河,王立岩.智能配电网的信息架构[J].电网技术,2009,33 (15):26-29.
  ZHAO Jianghe, WANG Liyan. Information structure of smart distribution network[J]. Power System Technology, 2009, 33 (15): 26-29.
- [3] 张志丹,黄小庆,曹一家,等.基于虚拟局域网的变电站综合数据流分析与通信网络仿真[J].电网技术,2011,35(5):204-209.
  ZHANG Zhidan, HUANG Xiaoqing, CAO Yijia, et al. Comprehensive data flow analysis and communication network simulation for virtual local area network-based substation [J]. Power System Technology, 2011, 35(5): 204-209.
- [4]高洪建.配电通信网业务自相似特性研究[D].昆明:云南大学, 2014.

GAO Hongjian. Research on self-similarity characteristics of distribution communication network service [D]. Kunming: Yunnan University, 2014.

[5] 孙毅,李世豪,李彬,等.基于 IEC 61850 的智能配电通信网络仿 真平台设计[J].电力建设,2016,37(2):118-124.
SUN Yi, LI Shihao, LI Bin, et al. Communication network simulation platform design of intelligent power distribution based on IEC 61850[J]. Electric Power Construction, 2016, 37(2): 118-124.

- [6] YANG T, ZHAO R, ZHANG W X, et al. On the modeling and analysis of communication traffic in intelligent electric power substations [J]. IEEE Transactions on Power Delivery, 2017, 32(3): 1329-1338.
- [7] 章堅民,张嘉誉,倪明,等.智能变电站通信网络的广义信源和 流量计算模型[J].电力系统自动化,2019,43(13):147-155.
  ZHANG Jianmin, ZHANG Jiayu, NI Ming, et al. Generic message source and flow calculation model for communication network in smart substation [J]. Automation of Electric Power Systems, 2019, 43(13): 147-155.
- [8] ZHOU X, YANG Z, NI M, et al. Analysis of the impact of combined information-physical-failure on distribution network CPS[J]. IEEE Access, 2020, 8: 44140-44152.
- [9]张嘉誉,章坚民,杨才明,等.基于信息物理融合的智能变电站 过程层网络异常流量检测[J].电力系统自动化,2019,43(14): 173-181.

ZHANG Jiayu, ZHANG Jianmin, YANG Caiming, et al. Abnormal traffic detection on process layer network of smart substation based on cyber physical fusion [J]. Automation of Electric Power Systems, 2019, 43(14): 173-181.

- [10] 张敖翔.CRH5型高速列车通信网络故障诊断系统研究[D].长春:长春工业大学,2019.
   ZHANG Aoxiang. Research on fault diagnosis system for CRH5 high speed train communication network [D]. Changchun: Changchun University of Technology, 2019.
- [11] 陈钊渊,黄良毅,张铁刚,等.基于特征流量分析的配电通信网数据侵入研究[J].电气自动化,2019,41(2):53-55.
  CHEN Zhaoyuan, HUANG Liangyi, ZHANG Tiegang, et al. Research on data intrusion in the distribution communication networks based on characteristic flow analysis [J]. Electrical Automation, 2019, 41(2): 53-55.
- [12] 杨挺,侯昱丞,赵黎媛,等.基于时-频域混合特征的变电站通信
   网异常流量检测方法[J].电力系统自动化,2020,44(16):
   79-86.

YANG Ting, HOU Yucheng, ZHAO Liyuan, et al. Abnormal traffic detection method of substation communication network based on time-frequency domain mixed features[J]. Automation of Electric Power Systems, 2020, 44(16): 79-86.

- [13] 陈家璘,周正,李磊,等.配电网信息物理系统异常检测研究
  [J].电测与仪表,2021,58(8):185-189.
  CHEN Jialin, ZHOU Zheng, LI Lei, et al. Research on anomaly detection of information physical system in distribution network[J]. Electrical Measurement & Instrumentation, 2021, 58(8): 185-189.
- [14] 张志鹏,李勇,曹一家,等.通信和电网联合仿真的配电网局部
   异常因子故障辨识算法[J].电力系统自动化,2016,40(17):
   44-50.

ZHANG Zhipeng, LI Yong, CAO Yijia, et al. A local outlier factor fault identification algorithm based on the co-simulation between cyber and power system for distribution network [J]. Automation of Electric Power Systems, 2016, 40(17): 44-50.

[15] 周念成,廖建权,王强钢,等.深度学习在智能电网中的应用现状分析与展望[J].电力系统自动化,2019,43(4):180-191.
ZHOU Niancheng, LIAO Jianquan, WANG Qianggang, et al. Analysis and prospect of deep learning application in smart grid
[J]. Automation of Electric Power Systems, 2019, 43(4): 180-191.

[16]杨毅,范栋琛,殷浩然,等.基于深度-迁移学习的输电线路故障选相模型及其可迁移性研究[J].电力自动化设备,2020,40 (10):165-172.
 YANG Yi, FAN Dongchen, YIN Haoran, et al. Transmission

line fault phase selection model based on deep-transfer learning and its transferability [J]. Electric Power Automation Equipment, 2020, 40(10): 165-172.

- [17]魏东,龚庆武,来文青,等.基于卷积神经网络的输电线路区内外故障判断及故障选相方法研究[J].中国电机工程学报,2016,36(增刊1):21-28.
  WEI Dong, GONG Qingwu, LAI Wenqing, et al. Research on internal and external fault diagnosis and fault-selection of transmission line based on convolutional neural network [J]. Proceedings of the CSEE, 2016, 36(Supplement 1): 21-28.
- [18] CHEN Y Q, FINK O, SANSAVINI G. Combined fault location and classification for power transmission lines fault diagnosis with integrated feature extraction [J]. IEEE Transactions on Industrial Electronics, 2018, 65(1): 561-569.
- [19] YANG D S, PANG Y H, ZHOU B W, et al. Fault diagnosis for energy Internet using correlation processing-based convolutional neural networks [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2019, 49 (8): 1739-1748.
- [20] 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.

- [21] WANG S Y, FAN S X, CHEN J W, et al. Deep-learning based fault diagnosis using computer-visualised power flow [J].
  IET Generation, Transmission & Distribution, 2018, 12 (17): 3985-3992.
- [22] JI S W, XU W, YANG M, et al. 3D convolutional neural networks for human action recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(1): 221-231.
- [23] 徐访,黄俊,陈权.基于 3D 卷积神经网络的动态手势识别方法 [J/OL].计算机工程[2021-04-27].https://doi.org/10.19678/j. issn.1000-3428.0059314.

XU Fang, HUANG Jun, CHEN Quan. Dynamic gesture recognition method based on 3D convolutional neural network [J/OL]. Computer Engineering[2021-04-27]. https://doi.org/ 10.19678/j.issn.1000-3428.0059314.

- [24] 杜帅煜.基于三维卷积神经网络的脑肿瘤分割算法研究[D]. 南京:南京邮电大学,2020.
  DU Shuaiyu. Research on brain tumor segmentation algorithm based on 3D convolutional neural network [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020.
- [25] 吴优,付立军,马凡,等.基于HLA的舰船综合电力系统信息物 理混合仿真[J].电网技术,2019,43(7):2422-2429.
   WU You, FU Lijun, MA Fan, et al. Cyber-physical cosimulation of vessel integrated power system based on HLA[J].

Power System Technology, 2019, 43(7): 2422-2429.

[26] 付灿字,王立志,齐冬莲,等.有源配电网信息物理系统混合仿 真平台设计方法及其算例实现[J].中国电机工程学报,2019, 39(24):7118-7125.

FU Canyu, WANG Lizhi, QI Donglian, et al. Design and experiments of active distribution network CPS simulation platform [J]. Proceedings of the CSEE, 2019, 39(24): 7118-7125.

- [27] 梁英,王耀坤,刘科研,等.计及网络信息安全的配电网CPS故障仿真[J].电网技术,2021,45(1):235-242.
  LIANG Ying, WANG Yaokun, LIU Keyan, et al. CPS fault simulation of distribution network considering network information security[J]. Power System Technology, 2021, 45 (1): 235-242.
- [28] 陈寅,宋杨,费敏锐.基于Simulink和OPNET的交互式联合仿 真研究[J].系统仿真技术,2011,7(3):242-247.
  CHEN Yin, SONG Yang, FEI Minrui. Interactive cosimulation based on Simulink and OPNET [J]. System Simulation Technology, 2011, 7(3): 242-247.
- [29] 周飞燕,金林鹏,董军.卷积神经网络研究综述[J].计算机学 报,2017,40(6):1229-1251.

ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of

convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.

- [30] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(6): 1929-1958.
- [31] LI H D, LI J C, GUAN X M, et al. Research on overfitting of deep learning [C]// 2019 15th International Conference on Computational Intelligence and Security (CIS), December 13-16, 2019, Macao, China: 78-81.

殷浩然(1997—),男,硕士研究生,主要研究方向:人工智能在电力系统中的应用。E-mail:hr\_yin@126.com

苗世洪(1963—),男,通信作者,博士,教授,博士生导师, 主要研究方向:电力系统保护与控制、配电网及微电网新技 术、电网智能调度与自动化技术、压缩空气储能建模及应用

- 个、也两有肥啊反为日幼儿孜个、压缩至儿随肥足侠及应用
- 等。E-mail:shmiao@hust.edu.cn
- 韩 信(1993—),男,博士研究生,主要研究方向:新能源 技术与人工智能技术等。E-mail:han\_ji1993@163.com

(编辑 蔡静雯)

# Anomaly Identification Method for Distribution Internet of Things Based on Three-dimensional Convolutional Neural Network

YIN Haoran<sup>1,2</sup>, MIAO Shihong<sup>1,2</sup>, HAN Ji<sup>1,2</sup>, WANG Zixin<sup>1,2</sup>, MAO Wandeng<sup>3</sup>, NIU Rongze<sup>3</sup>

(1. State Key Laboratory of Advanced Electromagnetic Engineering and Technology (Huazhong University of Science and Technology), Wuhan 430074, China; 2. Hubei Provincial Key Laboratory of Electric Power Security and High Efficiency (School

of Electrical and Electronic Engineering, Huazhong University of Science and Technology), Wuhan 430074, China;

3. Electric Power Research Institute of State Grid Henan Electric Power Company, Zhengzhou 450052, China)

**Abstract:** The power grid and communication network are highly coupled in the distribution Internet of Things (DIoT). The anomalies of a single network interact with another network, which may lead to the expansion of anomaly range. However, it is difficult to comprehensively and accurately identify the types and locations of the anomaly source in the DIoT by using the information of the power grid or the communication network alone. Therefore, this paper proposes an anomaly type identification and location method for DIoT based on the three-dimensional convolutional neural network (3D-CNN). Firstly, the communication flow characteristics of DIoT are analyzed and an interactive simulation model of DIoT based on Simulink and OPNET is built. Secondly, a 3D-CNN oriented sample construction method is proposed, in which the electric parameters and communication flow information of each node in DIoT are composed into a feature sub-pixel, and the state of DIoT. Thirdly, a deep learning model is built, which includes the three-dimensional feature extraction network and the hierarchical softmax classifier. By extracting and identifying the abnormal information hidden in the cubic sample matrix, the type and location of anomalies in DIoT could be determined simultaneously. Finally, the model is tested by using abnormal data of the IEEE 33-node DIoT. The results show that the proposed method can precisely classify and locate the short-circuit fault, communication interruption fault, and protection maloperation and rejection caused by abnormal communication data.

This work is supported by State Grid Corporation of China (No. SGHADK00PJJS2000026).

**Key words:** distribution Internet of Things (DIoT); deep learning; interactive simulation; anomaly identification and localization; three-dimensional convolutional neural network (3D-CNN)

