

基于边缘代理及轻量化深度学习模型的变电站智能运检技术研究

杨冬冬¹, 王瑞珏², 郑志宏¹, 杨 罡¹

(1. 国网山西省电力公司电力科学研究院, 太原 030001; 2. 国网山西省电力公司, 太原 030001)

摘要: 随着物联网和人工智能技术日趋发展, 巡检机器人已在变电站开展研究并取得了较多成效, 但因受现场地形、电磁等环境影响, 以及监测对象安装位置的局限性, 实用性存在一定不足, 且受限于作业时间窗口, 无法对重点设备重点对象实现实时在线监测。为此文中提出了以边缘代理集成轻量化深度学习算法作为变电站重要设备的运检补充手段。文中在基于开源的深度学习模型基础上进行了裁剪优化, 采用了百度较为先进的飞桨 Paddle Lite 框架, 实现了在边缘代理装置上集成部署, 并以变压器油温表计读数识别为典型应用案例进行研究。实验结果验证了文章研究成果实现了在边缘代理设备有限的硬件资源下的集成部署深度学习模型, 并满足了变压器油温表识别的准确率和性能的应用要求。研究成果可应用在变电站内对人员身份识别、违章违规作业、环境安全监控、仪表自动读数等智能运检业务领域, 具备较好的先进性和推广性。

关键词: 变电站; 智能运检; 深度学习; 边缘代理

Study on Intelligent Operation and Inspection Technology of Substation Based on Edge Agent and Lightweight Deep Learning Model

YANG Dongdong¹, WANG Ruijue², ZHENG Zhihong¹, YANG Gang¹

(1. Electric Power Research Institute of State Grid Shanxi Electric Power Company, Taiyuan 030001, China; 2. State Grid Shanxi Electric Power Company, Taiyuan 030001, China)

Abstract: With the development of Internet of things and artificial intelligence technology, patrol inspection robot has carried out research in substation and achieved many results. Due to the influence of the terrain and electromagnetic environment on the site, as well as the limitations of the installation location of the monitoring object, there are many deficiencies in the practicability of the inspection robot. So we propose to use the edge agent integrated lightweight deep learning algorithm as a supplementary means for the operation inspection of important substation equipment. Based on the open source in-depth learning model, we have carried out cutting optimization, adopted Baidu's advanced paddle Lite framework and taken the reading recognition of transformer oil thermometer as a typical application case. The researching results can be widely used in the field of power grid intelligent operation inspection, such as personnel identification, illegal operations, environmental safety monitoring, automatic meter reading, etc. in substations. The research results of this paper have good progressiveness and popularization.

Key words: Substation; intelligent operation and inspection; deep learning network; edge agent

0 引言

基于人工智能视觉分析技术在电网智能运检领域近些年已开展过较多研究, 如在配电房内有导轨式巡检机器人可替代或辅助人员进行巡检作业, 其具备的智能识别包括: 电力仪器仪表数字和指针仪器仪表读数、刀闸开合状态识别、移动物体检测识别等^[1]。变电站通常有智能巡检机器人可按既定巡检计划对变电站内的设备开展设备外观检查、表计

抄录、红外测温、声音检测等常规巡检等工作^[2]。对于室外作业场景, 智能巡检机器人只能按照巡检计划规划行径路线, 存在较大局限性, 比如: 室外一些区域地形不好或有异物, 容易出现巡检机器人摔倒; 一些区域受强磁影响, 通讯干扰严重导致机器人失控或数据采集传输失败; 一些巡检对象安装位置或角度不佳, 如变压器油位表或油温表, 机器人拍照或识别效果不好^[3], 见图 1。同时, 机器人巡检只能按计划按时间轮询, 受限于时间窗口, 无

基金项目: 国网山西省电力公司科技项目(520530202002)。

Project Supported by Key Science and Technology Project of State Grid Shanxi Corporation (520530202002).

法对重点对象实现实时在线监测。



图1 变电站巡检机器人及油温、油位表

Fig. 1 Substation inspection robot and oil temperature and oil level thermometer

针对上述情况，文中提出对此类变电站重点巡检对象如变压器通过安装视频监控和边缘代理装置，通过边缘代理集成深度学习 AI 模型以满足上述变电站智能运检业务的应用场景，见图 2。

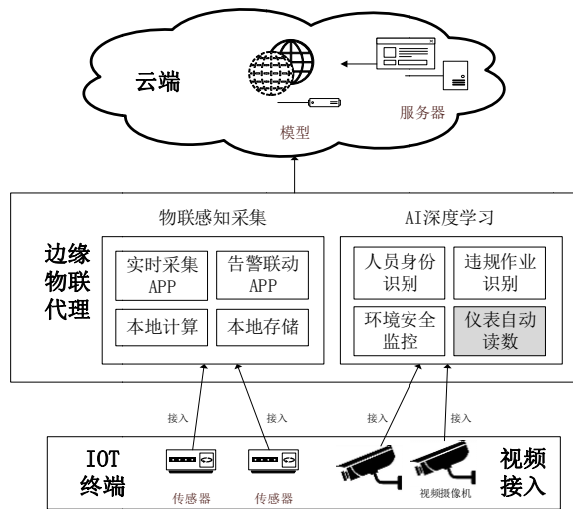


图2 边缘代理+深度学习智能运检应用场景示意图

Fig. 2 Schematic diagram of edge agent+deep learning for Intelligent operation inspection

因边缘代理作为端侧设备多部署在现场而非服务器机房中，其硬件在计算、存储、网络等方面资源和能力较为有限，某些应用场景如人员到岗到位识别还存在着移动性要求，某些室外应用场所供电存在一定困难，对设备低功耗也提出了一定要求，然而人工智能对计算机算力、缓存等方面资源要求高，由此对边缘设备和 AI 模型如何匹配集成，如何在低功耗、低配置的硬件中快速部署轻量型的 AI 分析模型提出一定挑战^[4]。

为了解决上述问题，文中对基于边缘代理及轻量化深度学习模型的变电站变压器油位表或油温表智能运检技术展开了详细研究。首先，对现有开源的深度学习检测模型进行优化，在保持其目标检测准确度的基础上减少了模型规模，满足了边缘代理低功耗、轻量化的资源能力和部署要求；其次，对目前较为主流的 Paddle Lite 框架进行研究，在支持更为广泛的硬件平台基础上构建轻量级、高性能的深度学习模型，使其满足硬件资源和能力有限情况下边缘代理设备的快速轻量部署；最后，以变电站电力变压器油温表智能识别为例，通过实验验证所提深度学习模型的有效性。

1 边缘代理及轻量化深度学习模型

传统机器学习的开发效率较低，往往需要 5 到 10 年才能出现一个受到广泛认可的算法。深度学习算法在训练深度卷积网络模型中，从训练的样本数据的像素中自动提炼出从低层次如边、角、梯度等特征到高层次抽象语义特征，基于这样的特征用交叉熵检测出目标的类别，用回归算法检测出目标的位置和大小^[5]。深度学习的开发数月即可得到满足需求的模型，性能也远超越传统机器学习，也一直被视为图像视觉人工智能的最优技术。然而开源的深度学习目标检测的模型一般针对 80 种甚至上百种类型的目标，而在文中的智能运检业务场景中只需要实现 10~20 种目标检测，因此需对开源的模型进行优化，减小其模型规模^[6]。MobileNets 是为边缘计算平台提出的高效模型，可作为深度学习目标检测的主干网络，提取图像中目标的特征。为满足边缘代理装置部署要求，文中提出了对开源的深度学习目标检测模型进行裁剪优化。

为较好满足边缘设备硬件要求，在处理器选型方面，GPU(graphics processing unit)作为图形处理器，在缓存能力、单任务处理速度、浮点运算及其他指令集的负载支持方面不如 CPU，但对硬件配置的要求相对较低，同时 GPU 对控制部分的能耗低，且具备较好的并行计算能力，更适合嵌入式 AI。论文在先进的百度飞桨 Paddle Lite 开源框架基础上对深度学习模型进行了轻量化部署研究实践。

1.1 深度学习实现目标检测

1.1.1 深度学习算法表述

深度学习对目标的检测包括两部分工作，对目标类别的识别(即目标分类)及对目标的定位(即位置回归)。

设训练样本集 (X, Y) 由 N 个标注好的图像组成，

$$X = \{x_1, x_2, \dots, x_N\}, Y = \{y_1, y_2, \dots, y_N\},$$

图像 x_i 中包括 M_i 个目标，标注为

$$y_i = \{(c_1^i, b_1^i), (c_2^i, b_2^i), \dots, (c_{m_i}^i, b_{m_i}^i)\},$$

其中 c_j^i 表示图像 x_i 中第 j 个目标属于 c 类， b_j^i 表示该目标的位置^[7]。

训练样本图像见图3，包含了6个目标，对每个目标标注了类型，分别是佩戴安全帽、未戴安全帽、长袖上衣、短袖上衣、长和短裤裤；以及标注了由红框表示的位置信息。



图3 样本标注示意图

Fig. 3 Sample labeling diagram

设深度学习网络模型为 $f(\theta)$ ，其中 θ 表示深度学习模型的参数。将 x_i 输入到 $f(\theta)$ ，得到对的计算公式为

$$y_{pred}^i = \{(c_{pred1}^i, b_{pred1}^i), (c_{pred2}^i, b_{pred2}^i), \dots, (c_{predM_i}^i, b_{predM_i}^i)\} \quad (1)$$

损失函数公式为

$$l(x, \theta) = \frac{1}{N} \sum_{i=1}^N l(y_{pred}^i, x_i y_i; \theta) + \frac{\lambda}{2} \|\theta\|_2^2 \quad (2)$$

对损失函数微分 $\frac{\partial}{\partial \theta} l(x, \theta)$ ，求得使误差最小的深度学习网络的参数 θ 。

深度学习模型的训练与生成主要关键点有样本图像的采集与标注、深度学习网络结构的设计和损失函数的设计^[8]。

1.1.2 深度学习卷积网络的构造

由于深度学习卷积网络不受目标位置影响，提取目标像素之间关联特性能力强，因而适合图像和视频的分析，其架构及网络元素组成见图4。




图4 卷积网络架构图

Fig. 4 Convolution network architecture

1)卷积层(convolutional layer)，卷积神经网络由多个卷积层组成，通过采用卷积算法层层提取目标特征，其计算公式为

$$o(x, y, m) = \sum_{k=0}^{C-1} \sum_{i=0}^{R-1} \sum_{j=0}^{R-1} I(k, x + i, y + j) * w(x, y, m) \quad (3)$$

输入的特征图的分辨率是 $H \times H$ ，每个特征点有 C 个通道 Channel，也即 C 维向量；输出的特征图的分辨率是 $E \times E$ ，每个特征点是 M 维向量；与输出向量维度对应的有 M 个卷积核，每个卷积核大小是 $R \times R$ ，与输入特征对应具有 C 维向量^[10]。

输出特征图 Channel 1 的红色像素值由左上上的卷积核 1 与输入特征图的见图 5 中上所示的红框部分点积而得。输出特征图 Channel M 的红色像素值由左下的卷积核 M 与输入特征图的见图 5 中下所示的红框部分点积而得。




图5 卷积层示意图

Fig. 5 Schematic diagram of convolution layer

2)激励函数层(rectified linear units layer, ReLU layer)，见图6，这一层神经的活性化函数(activation function)使用线性整流(rectified linear units, ReLU)。




图 6 激励函数层

Fig. 6 Excitation function layer

3)池化层(pooling layer), 由卷积层获得的特征维度很大, 但为了减小特征维度, 就必须利用池化层将其分切为若干个部分, 得到均值、最大值。

4)全连接层(fully-connected layer), 通过全连接层可将所有局部特征连接、组合起来, 由此得到全局特征。

1.1.3 深度学习目标检测网络

用于目标检测的深度学习网络一般分为两个部分, 主干网络提取图像的特征、头部网络由特征检测出目标的位置和类型, 具体的操作由分为两种类型, 两步式和一步式^[11]。

两步式的头部网络有两个分支, 一支检测目标在特征层位置, 另一支对检测出位置进行目标分类和位置回归。一步式的头部网络由特征层直接检测目标的分类和位置回归。一步式与两步式相比虽然准确率较低, 但由于网络紧凑、网络速度快、运算量较低, 非常适合于边缘深度学习网络模型, 典型的网络结构如 MobileNet SDD。故文中提出采用 MobileNet SDD 以构建边缘计算的高效机器深度学习网络。

1.2 MobileNet SSD 构建边缘计算高效模型

1.2.1 SSD 预置框设置

SSD 预置框示意图见图 7, 图 7(a)是输入的图片, 其中有两个目标分别被框起标注。图 7(b)、(c)为 MobileNet 网络中不同层次的特征图。图 7(c)中, 在特征图每一点预置不同大小和比例的预置框, 由框内的特征向量检测图像中目标的种类和位置^[12]。

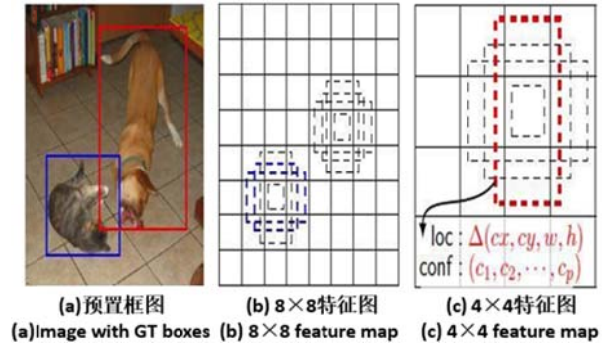


图 7 SSD 预置框示意图

Fig. 7 Schematic diagram of SSD preprocessing

分布在不同网络层的特征图预置框对应相应输入图像有不同的目标大小, 在同一层特征图预置框又有不同的长宽比例, 因此基本上可以覆盖输入图像中的各种形状和大小的目标。

1.2.2 SSD 损失函数

目标检测既要检测目标的类别, 也要检测目标的位置, 图 7(c)中所示 conf 对应从 p 个类别中分类的结果, loc 对应位置检测的结果, 其包括目标框中心点的坐标、长度和宽度。与之对应, 损失函数 l 对应分类误差 l_{conf} 和定位误差 l_{loc} , 公式定义为

$$l(x, c, l, g) = \frac{1}{N} (l_{conf}(x, c) + al_{loc}(x, l, g)) \quad (4)$$

$$l_{loc}(x, l, g) = \sum_{i \in \text{pos}}^N \sum_{m \in \{cx, cy, w, h\}} x_{ij}^k \text{smoothL1}(l_i^m - \tilde{g}_i^m) \quad (5)$$

$$l_{conf} = - \sum_{i \in \text{pos}}^N x_{ij}^p \log(\hat{c}_i^p) - \sum_{i \in \text{Neg}} \log(\hat{c}_i^0) \quad (6)$$

式(4)-(6)中: N 是匹配的预置框的数量; l 是检测的输出; g 是实际目标的位置; \tilde{g} 是回归的目标。SSD 算法对预置框(d)的中心(c_x, c_y)与实际目标标注框的中心之间的偏差实行回归算法^[13]

1.2.3 SSD 训练

首先寻找与每一个标注框有最大的交叠面积的预置框, 保证每一个标注框与唯一的预置框对应起来。之后将剩余还没有配对的预置框与任意一个标注框尝试配对, 只要两者之间的交叠面积大于阈值, 就认为匹配。匹配到的预置框记为正样本集, 否则记为负样本集。考虑到实际负样本数 \gg 正样本数, 选取正样本数: 负样本数大约为 1: 3。将样本输入到深度学习网络, 计算损失函数, 通过反向传

播梯度调整网络的参数。经过多轮次循环，将误差降到目标值以内，生成目标检测的深度学习模型^[7]。

1.3 深度学习网络的优化

开源的深度学习目标检测模型一般针对 80 种甚至上百种类型的目标，而文中提及的智能运检作业场景只需要对 10~20 种目标检测，因此应对开源模型进行优化，减小其模型规模，优化的模型更适合在边缘物联代理上运行，实现实时视频分析^[14]。文章提出通过剪裁和量化两种方法进行模型优化。

1)模型剪裁:通过去掉特定特征图的冗余维度,并细调训练,得到优化的模型,见图 8。




图 8 网络剪裁示意图

Fig. 8 Schematic diagram of network clipping

2)模型量化:原始的深度学习模型参数使用的是 f32 浮点数格式,占用内存大,运算电路占芯片的面积也大,功耗也大。当前普遍使用 8 位定点数拟合 f32 浮点数,实践效果非常理想,由于 8 位定点数运算的硬件所占芯片面积很小,可设计更多的运算单元,提高运算的并行度,系统运算能力提高,功耗也能显著下降。

1.4 Paddle Lite 及推理部署

1.4.1 Paddle Lite 特性

Paddle Lite 又名“飞桨”,是由百度推出近年比较流行的手机、边缘代理等嵌入式设备提供轻量化高效的 AI 框架,具备轻量型、高效性和通用性等特性,也具备模型兼容性、框架支持性高等特性。

1)轻量型方面,Paddle Lite 实现了优化阶段与执行阶段充分解耦,在执行阶段,移动或嵌入式设备可直接部署。模型经过优化后,对 ARMV7 格式的文件大小只有 700 K,对于 ARMV7 格式不到 1.2 M,模型经部署后可直接执行,无需再额外优化。

2)性能方面,模型经剪裁后,可实现计算性能最优,且通过 INT8 量化计算和训练后,可实现更

高精度和性能的预测。

3)通用性方面,已实现对 ARM CPU、Adreno GPU、华为 NPU 及 FPGA 等多种硬件兼容。

4)模型兼容性方面:除原生的 Paddle Lite 与 PaddlePaddle 训练的模型外,对其他框架训练的模型实现了全兼容覆盖,包括 18 个模型及 OCR 模型。

5)框架支持性方面:除 PaddlePaddle 外,通过 X2Paddle 转换工具可实现对其他框架如 Caffe 和 TensorFlow 的充分支持。

1.4.2 架构设计

PaddleLite 设计之初即为手机、边缘侧嵌入式多类硬件类型开发着重考虑,并满足了 Caffe、Tensorflow 等多个 AI 平台兼容性支撑。在满足准确率的基础上,实现了一个模型可适应多个硬件上混合执行,其轻量化设计性能更优,尤其适用于低功耗、移动性高的边缘侧应用^[15]。

PaddleLite 架构设计见图 9,架构及其模型分析原理分为分析阶段、优化阶段、执行阶段 3 个环节^[16]。

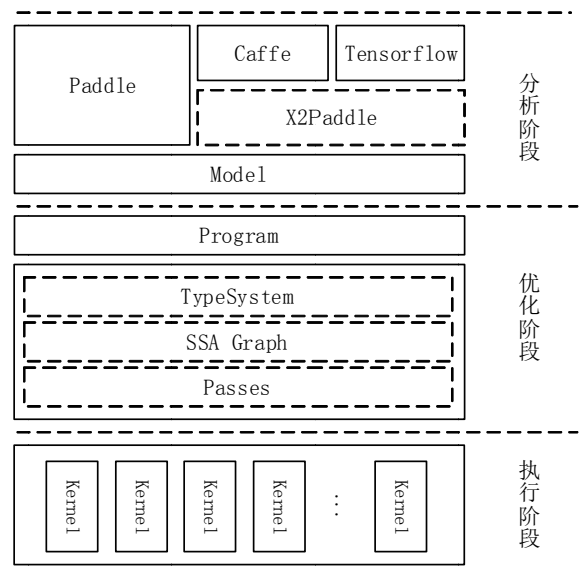


图 9 PaddleLite 架构设计图

Fig. 9 Architecture design drawing of PaddleLite

1)分析阶段:包括了机器智能研究 MIR(Machine IR)的相关模块,对于不同的硬件,可根据其硬件特性对模型的计算图进行优化。

2)优化手段:包含计算裁剪、算子融合等方式方法。

3)执行阶段:支持单独部署,满足了轻量化部

署要求。

1.4.3 推理部署

Paddle Lite 支持 Windows 系统的服务器端安全部署及 Linux 系统的 jetson 嵌入式设备安全部署两种模式，因文中采用嵌入式边缘代理设备已 GUP 架构进行部署，参见 Paddle Lite 开源平台，具体部署流程如下。

1) 下载 PaddleX 源码，执行以下命令：`git clone https://github.com/PaddlePaddle/PaddleX`；`cd PaddleX`；`git checkout release/1.3`。

2) 将配置文件备份及拷贝到部署目录 `PaddleX/deploy/cpp` 目录下，具体包括 `meter_reader` 文件夹及 `CMakeList.txt`。

3) 按照 NvidiaJetson 开发板部署中的 Step2 至 Step3 完成 C++ 预测代码的编译。

4) 编译成功后，可执行程序 `build/meter_reader/meter_reader`，执行时可参见表 1 所示主要命令参数进行配置。

表 1 表计识别模型执行参数表

Table 1 Table of execution parameters of identification model

参数	说明
<code>det_model_dir</code>	表计检测模型路径
<code>seg_model_dir</code>	指针和刻度分割模型路径
<code>image</code>	待预测的图片路径
<code>image_list</code>	按行存储图片路径的.txt 文件
<code>use_gpu</code>	是否使用 GPU 预测，支持值为 0 或 1
<code>gpu_id</code>	GPU 设备 ID，默认值为 0
<code>save_dir</code>	保存可视化结果的路径
<code>seg_batch_size</code>	分割的批量大小，默认为 2
<code>use_camera</code>	是否使用摄像头，支持值为 0 或 1
<code>camera_id</code>	摄像头设备 ID，默认值为 0
<code>erode_kernel</code>	图像腐蚀操作时的卷积核大小，默认为 4
<code>score_threshold</code>	检测模型输出结果中，预测得分低于该阈值的框将被滤除，默认值为 0.5

5) 推理预测：用于部署推理的模型应为 `inference` 格式，本案例提供的预训练模型均为 `inference` 格式，如若是重新训练的模型，需参考部署模型导出将模型导出为 `inference` 格式^[17]。

Paddlite 使用未加密的模型支持 3 种方式进行推理预测：对单张图片做预测；对图像列表做预测；开启摄像头做预测。文章采用对图像列表的方式开

展推理预测，也即将准备好的图像集列入图像列表文件 `image_list.txt`，然后执行 `det_inference_model` 程序即可开展推理预测。

2 实验结果与分析

变压器是变电站重要设备，见图 10，文中以其油温表为实例进行识别实验研究。相关研究成果也可用于其他变电站智能运检的场景，比如：人员身份识别、正确着装识别、抽烟烟火识别等。



图 10 变压器油温表计样本示例图

Fig. 10 Sample diagram of transformer oil thermometersample

1) 图像样本采集。通过现场采集及网络爬取两种方式收集并整理表计图像共约 3 000 张，开关约 5 000 张，指示灯约 4 000 张，共计 12 000 张图像作为训练样本集。考虑表针表计图像多样性较差，后续针对个别数据需要添加现场图像数据作为补充来完善算法。

2) 表计图像标注。由于目前暂时考虑表计在图像中的坐标是固定的，所以不需要使用目标检测来定位表计的位置，只需要计算表计的读数即可，所以标注时对每种表计，只需要表计的表框点以及指针两端点，标注文件只需要按预先定义好的顺序存储标注点坐标即可，标注示例图见图 11。



图 11 变压器油温表计标记示例图

Fig. 11 Sample diagram of marking transformer oil

thermometer

3)神经网络的选择。由于表计图像外形基本一致，图像较为单一，可采用较为简单的卷积神经网络就可以完成任务。见表2对比结果，VGG11网络深度适中，耗时较短，效果较好，适应于表计图像关键点的识别^[10]。

表2 VGG网络选择表

Table 2 VGG network selection table

网络	特点
VGG16	网络较深，耗时大，易过拟合
VGG11	网络深度适中，耗时较短，效果较好
轻量级VGG	网络浅，速度快

4)神经网络的训练。把前述已预训练好的模型，导入paddle_model中，使用训练集中60000张图片进行再训练，设置训练参数如下：class_num=60；batch_size=256；Learning rate=0.1。在训练了100个epoch之后，对训练参数进行微调，将Learning rate以 7×10^{-5} 的衰减率衰减，并再练习100个epoch，直到参数收敛。训练结果见图12。




图12 loss测试结果图

Fig. 12 Loss test result diagram

训练中途会显示训练的损失loss和验证集上的准确率，当训练的loss很小且基本不再变化，此时验证集的准确率也是最大且基本无变化，即可终止训练，保存最优模型。

5)性能评估及测试。本次测试采用了训练集938张、测试集228张图像样本，标注目标检测2826处。测试结果见图13，最高Map(mean average precision)达到了0.9768，测试结果表明研究成果符合设计预期。




图13 MAP指标随迭代次数的变化图示

Fig. 13 Diagram of map index change with iteration times

针对表计图像关键点识别网络的性能测试，只需要测试提前分出来的测试集，将网络预测的关键点与真实标注的关键点进行最近距离匹配，如果可以匹配到，则检测成功，否则失败。而网络的测试性能则可以使用一个准确率来表示，而该准确率的计算方式则为检测成功的关键点总个数除以所有关键点个数^[18]。经过测试，表计关键点识别准确率为85.1%左右。

通过实验测试，验证了文章研究成果实现了在边缘代理设备有限的硬件资源下的集成部署深度学习模型，并满足了变压器油温表识别的准确率和性能的应用要求。针对智能运检业务的其他应用场景，如人员身份识别、违规作业识别等，我们可通过部署相应的成熟模型或参照文章所述方法进行样本标注、训练等操作即可。

3 结论

针对变电站常规巡检机器人因地形、电磁环境及巡检对象安装位置等因素导致的智能识别应用的不足，以及受限于巡检作业时间窗口无法实现对重要设备重要对象进行实时感知、实时采集的短板，文中提出了通过视频监控+边缘代理装置，并集成深度学习视觉分析应用及解决方案，实现了现场数据实时采集及本地智能分析，弥补了常规巡检机器人巡检能力的不足，提高了现场运检业务智能化及电网生产安全管控水平。具体结论如下：

1)针对边缘代理装置移动性高、功耗要求低，提出了在现有开源深度学习检测模型基础上进行裁剪优化，在保持其目标检测准确度的基础上减少

了其模型规模,满足了边缘代理低功耗、轻量化的资源能力和部署要求。

2)针对计算能力、缓存能力等有限等特点,提出了采用目前较为主流的 Paddle Lite 框架,在支持更为广泛的硬件平台基础上构建轻量级、高性能的深度神经网络模型,较好地满足了硬件资源和能力有限情况下边缘代理设备的快速轻量部署。

3)以变电站电力变压器油温表智能识别为验证实验案例,开展样本采集、数据标注、神经网络训练等一系列实验,验证了文中所提技术的有效性。

在未来工作中,将进一步针对变电站智能运检场景实际环境开展模型优化研究,提高实际环境(如:复杂背景、光线条件、水珠干扰等)下识别的准确率,实现变电站更多智能运检场景的应用。

参考文献:

- [1] 蒲世亮, 袁婷婷. 基于云边融合的物联网智能服务架构探讨[J]. 智能物联网技术, 2018, 1(1): 1-6.
PU Shiliang, YUAN Tingting. Research on intelligent architecture for IoT services based on fusion of cloud and edge computing[J]. Technology of IoT&AI, 2018, 1(1): 1-6.
- [2] 周知, 于帅, 陈旭. 边缘智能: 边缘计算与人工智能融合的新范式[J]. 大数据, 2019, 5(2): 53-63.
ZHOU Zhi, YU Shuai, CHEN Xu. Edge intelligence: A new nexus of edge computing and artificial intelligence[J]. Big Data Research, 2019, 5(2): 53-63.
- [3] 李志海, 张荣华, 张天兵, 等. 基于视频监控的变电站智能巡检系统研究[J]. 计算机技术与发展, 2014, 24(10): 233-237.
LI Zhihai, ZHANG Ronghua, ZHANG Tianbing, et al. Research on intelligence substation routine inspection system based on video surveillance[J]. Computer Technology and Development, 2014, 24(10): 233-237.
- [4] 施巍松, 张星洲, 王一帆, 等. 边缘计算: 现状与展望[J]. 计算机研究与发展, 2019, 56(1): 69-89.
SHI Weisong, ZHANG Xingzhou, WANG Yifan, et al. Edge computing: State-of-the-art and future directions[J]. Journal of Computer Research and Development, 2019, 56(1): 69-89.
- [5] 汤鹏杰, 王瀚漓, 左凌轩. 并行交叉的深度卷积神经网络模型[J]. 中国图象图形学报, 2016, 21(3): 339-347.
TANG Pengjie, WANG Hanli, ZUO Lingxuan. Parallel cross deep convolution neural networks model[J]. Journal of Image and Graphics, 2016, 21(3): 339-347.
- [6] 卢宏涛, 张秦川. 深度卷积神经网络在计算机视觉中的应用研究综述[J]. 数据采集与处理, 2016, 31(1): 1-17.
LU Hongtao, ZHANG Qinchuan. Applications of deep convolutional neural network in computer vision[J]. Journal of Data Acquisition & Processing, 2016, 31(1): 1-17.
- [7] CARRLLL J. Deep learning continues growth in machine vision[J]. Vision Systems Design, 2020, 25(3): 20-23.
- [8] CARROLL J. Deep learning: Finding the optimal hardware for deep learning inference in machine vision[J]. Vision Systems Design, 2019, 24(8): 8-9.
- [9] 黄斌, 卢金金, 王建华, 等. 基于深度卷积神经网络的物体识别算法[J]. 计算机应用, 2016, 36(12): 3333-3340.
HUANG Bin, LU Jinjin, WANG Jianhua, et al. Object recognition algorithm based on deep convolution neural networks[J]. Journal of Computer Applications, 2016, 36(12): 3333-3340.
- [10] RIFAIOGLU A S, ATAS H, MARTIN M J, et al. Recent applications of deep learning and machine intelligence on in silico drug discovery: Methods, tools and databases[J]. Briefings in Bioinformatics, 2019, 20(5): 1878-1912.
- [11] 谢景洋, 王巍, 刘婷. 基于YOLOv3算法的不同主干网络对织物瑕疵检测[J]. 测控技术, 2021, 40(3): 61-66.
XIE Jingyang, WANG Wei, LIU Ting. Fabric surface defect detection based on YOLOv3 with different backbone networks[J]. Measurement & Control Technology, 2021, 40(3): 61-66.
- [12] 吴凤和. 基于计算机视觉测量技术的图像轮廓提取方法研究[J]. 计量学报, 2007, 28(1): 18-22.
WU Fenghe. A study on contour extraction method in computer vision measurement technology[J]. Acta Metrologica Sinica, 2007, 28(1): 18-22.
- [13] 曾爱林. 基于改进神经网络的图像生物特征识别方法[J]. 科技通报, 2015, 31(2): 224-226.
ZENG Ailin. Image biometric identification method based on improved neural network[J]. Bulletin of Science and Technology, 2015, 31(2): 224-226.
- [14] CAMILLO J. Deep learning machine vision[J]. Assembly, 2019, 62(5): 48-50.
- [15] 马艳军, 于佃海, 吴甜, 等. 飞桨: 源于产业实践的开源深度学习平台[J]. 数据与计算发展前沿, 2019, 1(1): 105-115.

MA Yanjun, YU Dianhai, WU Tian, et al. PaddlePaddle: An open-source deep learning platform from industrial practice[J]. *Frontiers of Data&Computing*, 2019, 1(1): 105-115.

[16] 陈玫玫, 玄玉波, 李兆玺, 等. 基于百度飞桨 AI Studio 的机器学习教学新模式实践与探索[J]. *计算机教育*, 2021(9): 46-50.

CHEN Meimei, XUAN Yubo, LI Zhaoxi, et al. et al practice and exploration of a new machine learning teaching mode based on baidu PaddlePaddle AI studio[J]. *Computer Education*, 2021(9): 46-50.

[17] 麻兴东. 计算机智能图像识别算法研究[J]. *科技资讯*, 2015, 13(20): 24-25.

MA Xingdong. Research on computer intelligent image recognition algorithm[J]. *Science & Technology Information*, 2015, 13(20): 24-25.

[18] 卢思缴, 张智宏, 刘颖, 等. 基于计算机视觉技术的

电力指针表自动读数识别研究[J]. *自动化技术与应用*, 2021, 40(11): 177-179.

LU Sijiao, ZHANG Zhihong, LIU Ying, et al. Research on automatic reading recognition of electric pointer based on computer vision technology[J]. *Techniques of Automation and Applications*, 2021, 40(11): 177-179.

杨冬冬(1983—), 男, 研究生, 高级工程师, 研究方向从事配电网运检及智能配用电工作; 长期从事配电网新技术研究、新产品推广、智能运检及配用电工作(E-mail: 594122581@qq.com)。

王瑞珏(1983—), 男, 研究生, 高级工程师, 研究方向为配电运行维护及设备状态评价。

郑志宏(1991—), 男, 研究生, 工程师, 研究方向为供电可靠性评价。

杨 罡(1983—), 男, 博士, 高级工程师, 研究方向为配电网运检及智能配用电研究。