

DOI: 10.13382/j.jemi.B2306591

基于改进 U-Net 的高压电缆绝缘层图像分割研究*

侯北平^{1,2} 李丰余¹ 朱文^{1,2} 胡飞阳¹
(1. 浙江科技学院自动化与电气工程学院 杭州 310023;
2. 浙江省智能机器人感知与控制国际科技合作基地 杭州 310023)

摘要:针对目前高压电缆绝缘层检测操作繁琐、效率低、重复测量差异大等问题,设计了一种新型电缆绝缘层检测装置,提出了一种基于改进 U-Net 的高压电缆绝缘层图像分割方法。首先替换主干特征提取网络为 VGG16 网络,结合迁移学习将 VGG16 在 Pascal VOC2012 数据集中训练的权重作为预训练权重,利用通道注意力模块在跳跃连接处融入自适应特征加权机制,在上采样过程中添加分组卷积,提高了语义分割精度;然后利用训练的最优权重进行绝缘层图像分割,提取轮廓区域特征并进行二值化处理,使用连通区域算法对轮廓区域进行填充;最后,融合原始图像和分割区域生成完整绝缘层分割图像。实验结果表明,平均交并比和平均像素准确率达到 99.56% 和 99.81%,较原网络效果提升明显,验证了该方法在高压电缆绝缘层分割上的有效性。

关键词:绝缘层;图像分割;特征提取网络;注意力机制;迁移学习

中图分类号: TP391;TN911 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Research on image segmentation of high-voltage cables
insulation layer based on improved U-Net

Hou Beiping^{1,2} Li Fengyu¹ Zhu Wen^{1,2} Hu Feiyang¹

(1. School of Automation and Electrical Engineering, Zhejiang University of Science and Technology, Hangzhou 310023, China;
2. Zhejiang International Science and Technology Cooperation Base of Intelligent Robot Sensing and Control, Hangzhou 310023, China)

Abstract: Aiming at the current problems of cumbersome operation, low efficiency and large variation in repeated measurements of high-voltage cable insulation layer quality inspection, a new type of cable insulation layer inspection device is designed, and a high-voltage cable insulation layer image segmentation method based on improved U-Net is proposed. Firstly, the backbone feature extraction network is replaced with the VGG16 network, the weights trained by VGG16 in the Pascal VOC2012 dataset are used as the pre-training weights in combination with the transfer learning, the adaptive feature weighting mechanism is incorporated in the jump connections by using the channel attention module, as well as the grouped convolution is added in the up-sampling process, which improves the semantic segmentation accuracy. Next, the insulating layer image segmentation is performed using the trained optimal weights, the contour region features are extracted and binarised, and the contour region is filled using the connected region algorithm. Finally, the complete insulation layer segmentation image is generated by fusing the original image and the segmented region. The experimental results show that the mean intersection-over-union and mean pixel accuracy reach 99.56% and 99.81%, which is a significant improvement over the original network effect, and verifies the effectiveness of the method on the segmentation of the insulation layer of high-voltage cables.

Keywords: insulation layer; image segmentation; feature extraction network; mechanism of attention; transfer learning

0 引言

绝缘层^[1]结构参数是评估高压电缆质量的重要指标,绝缘层结构参数的高效精准检测是高压电缆安全运行的可靠性保障,减少因电缆质量问题引起的生命财产损失。

当前传统的电缆绝缘层结构参数测量^[2]主要是人工方式,首先抽出电缆导体部分和隔离层,然后沿电缆轴线切取横截面薄片,使用读数显微镜或投影仪进行观测,该方法操作繁琐、效率低、准确性差。

随着机器视觉、图像处理技术的高速发展,智能检测逐渐取代人为检测,成为电缆质量安全检测的主流技术。针对电缆内部各项参数的检测,董辉平等^[3]提出了基于脊线多层级分水岭算法的图像分割方法,实现了电缆截面分析。沈炫等^[4]利用 Canny 和亚像素边缘检测算法精确计算了电缆护套厚度。王爱军等^[5]利用形态学方法获取边缘像素信息,采用线性映射方法获得直径和绝缘厚度。Lenty 等^[6]使用边缘提取算子和 RDP 算法实现了电缆导体直径的测量。阴法明等^[7]基于 Sobel 边缘算子提出了灰度矩亚像素重定位算法来计算护套厚度。上述电缆参数检测算法都是基于边缘提取的方法,在提取过程中准确性和鲁棒性均受检测样本质量的影响,在干扰较多的情况下,边缘检测算法无法对复杂图像进行精准处理。

由于电缆内部干扰因素较多,采用消除纹理等方法提高检测精度。董霏等^[8]提出了基于 Gabor 滤波器的刀痕纹理消除方法,消除干扰因素的同时保留了线芯导体的边缘轮廓信息。侯北平等^[9]改进了巴特沃斯陷波滤波器,设计了椭圆形邻域窄阻带来消除刀痕纹理。通过去噪提高电缆检测质量,但对于复杂的电缆截面图像,消除图像干扰区域的同时会对图像细节进行滤除,影响检测结果。

针对复杂的检测场景,传统图像处理方法难以满足检测需要,深度学习被应用到电缆检测领域^[10]。Zhu 等^[11]提出了基于 FCN 的图像分割方法获取电缆半导电屏蔽层,改进加权损失法定位外边界并根据先验知识消除干扰区域。黄志豪等^[12]提出了基于残差和深度可分离卷积的神经网络模型,实现了电缆外表面的快速检测。徐子弘等^[13]提出了基于 AE 和 GRU 网络的电缆早期故障识别方法。翁玉尚等^[14]改进了 RCF 算法提高了绝缘层边缘检测的精度。刘宇等^[15]基于深度残差网络提取了绝缘层截面图像深层次特征,对绝缘层截面图像进行分类。李瑾等^[16]利用 YOLACT 模型改善了网络分割效果,对电缆边缘进行自适应检测识别与定位。

综上,国内外已对绝缘层护套外表面、绝缘层边缘、

绝缘层片结构参数以及分类方法展开研究。对于电缆绝缘结构参数的检测都是基于绝缘层切片,测量前需分离电缆绝缘层部分和导体部分,利用切片机对绝缘层部分进行切片,此过程繁琐且容易损坏样本,因此实现高压电缆绝缘层图像的提取问题亟待解决。高压电缆绝缘层检测任务较为复杂,研究过程中存在 2 个关键问题:1) 如何快速便捷地获取高质量电缆截面图像;2) 如何精确分割出电缆绝缘层区域。

本文提出了一种新型绝缘层检测装置以及一种基于改进 U-Net 的高压电缆绝缘层图像分割方法,通过分割算法消除人为、环境等干扰因素获取高质量的高压电缆绝缘层图像,进而实现高压电缆绝缘层结构参数的测量。该方法在 U-Net 网络基础上,选取主干特征提取网络为 VGG16 网络结构,结合迁移学习、自适应特征加权机制以及分组卷积提升了模型泛化能力和分割精度,通过语义分割得到高压电缆线芯和绝缘层两部分后对电缆线芯部分进行遍历替换得到绝缘层截面图像。本文方法有效分割了绝缘层区域,精确获取绝缘层图像,减少了对电缆的损伤,提升了绝缘层检测效率,对高压电缆绝缘层结构参数的检测至关重要。

1 高压电缆结构分析与检测装置实现

1.1 高压电缆及绝缘层切片实物

如图 1(a) 所示,为额定电压为 35 kV 的高压电缆实物图,结构由内而外为导体、导体屏蔽层、交联聚乙烯绝缘层和绝缘屏蔽层,后三者构成绝缘层部分。

图 1(b) 为绝缘层切片样本,针对切片对应的绝缘层样品,传统的视觉检测设备虽然可以识别绝缘层结构并进行参数测量,但尚存在以下不足:

1) 由于电缆内部的绞合导体和导体屏蔽层紧密连接,抽离导体时会因外力破坏导体屏蔽层,该环节对操作人员要求较高,不当操作易影响检测结果;

2) 对绝缘层进行切割时,要将剥离后的绝缘层部分切成厚度为 1 mm 的薄片,由于电缆内芯剥离,切割时受力不均,极易产生变形,造成绝缘参数尺寸失真导致检测精度降低;

3) 对绝缘片样本进行检测时需要手动摆放,摆放位置影响检测精度,且须使用室内特定检测设备,设备笨重难以移动,限制了测量的使用范围。

1.2 检测装置硬件实现

针对绝缘层测量时的不足,在深入研究线缆绝缘层结构测量方法的基础上^[2-7],本文提出了一种新型高压电缆绝缘层检测方法,具有以下特点:

1) 通过轻便式装置直接采集电缆截面图像,免去剥




图 1 高压电缆实物及绝缘层切片

Fig. 1 High-voltage cable and insulation layer cross section

离绞合内芯操作,避免了导体部分抽离时对绝缘层造成损伤,同时降低了人力成本;

2) 检测设备轻巧,无需在特定工位下进行检测,直接在工业现场随时随地展开测量,不受工作环境约束,便于户外、车间等复杂环境的快速测量;

3) 利用机器视觉技术可直接提取绝缘层部分,减少了切割绝缘片环节,杜绝了绝缘层外形畸变,提高了检测精度,降低了检测成本。

本文设计的新型高压电缆绝缘层检测装置如图 2 所示。其中机架为 PLA 碳纤维材质,材料拉伸强度可达 800 MPa,满足不同测量场景下的强度条件;镜头配合高分辨工业相机使用得到高清电缆截面图像,光源均匀照亮电缆截面,使感兴趣区域和其余部分的灰度值差异加大,保证图像的清晰度和对比度;石英玻璃保证电缆检测时处于水平状态的同时隔绝外部环境,使装置中所有零部件集成在一个密闭环境下以排除检测环境多样化等干扰因素。由于待检样品呈圆柱形检测时须保证镜头、高分辨率工业相机、环形光源、待检样品处于同一轴线上,实现高压电缆的同轴度轴向电缆截面的实时获取与测量。




图 2 高压电缆绝缘层检测示意图

Fig. 2 Schematic diagram of high-voltage cable insulation inspection

1.3 高压电缆截面图像分析

使用新型高压电缆绝缘层检测装置采集的多组高压电缆截面图像效果如图 3 所示。




图 3 电缆截面图例

Fig. 3 Cross section legend for cables

通过分析电缆截面图像发现具有以下特点:

图 3(a)、(b)为切割状况良好的不同规格电缆截面,绝缘层与内芯灰度值差别不大,绝缘层存在少许刀痕,在合适光照强度下电缆导体屏蔽层和电缆内芯相连紧密且灰度值区别较大;图 3(c)为磨损电缆截面,由于人为因素导致切割后电缆绝缘层和电缆内芯截面产生较多切痕、毛躁等噪声,导体屏蔽层和绝缘屏蔽层边缘部分磨损严重;图 3(d)为划痕电缆截面,切割导致出现较为明显的划痕,使内芯和绝缘层界限模糊;图 3(e)为损坏电缆

截面,电缆绝缘层部分区域缺失,如图 3(e)椭圆部分区域所示,使得电缆截面形状不规则,绝缘层灰度值分布不均匀;图 3(f)为锈蚀电缆截面,由于环境原因导致电缆截面长时间暴露在空气中,电缆内芯产生较多锈蚀使得导体屏蔽层和内芯连接处灰度值相近。

综合以上特点分析,对于不同种类、不同质量情况的图像由于人为、环境等因素的干扰,会出现结构细节退化,图像区域差异小、对比度低,绝缘层和电缆内芯界限模糊等情况,直接影响图像分割效果,因此除了在装置结构设计上提升绝缘层显示效果外,还需要设计合适的电缆绝缘层图像分割方法。

传统的图像分割方法鲁棒性较差,电缆内芯和导体屏蔽层之间容易产生过分割和欠分割现象,不能精确有效的实现绝缘层的分割与提取,进而影响参数的检测。综合考虑电缆绝缘层类型复杂多样、截面图像质量参差不齐、分割普适性及检测精度要求较高等因素,本文引入了深度学习的方法实现绝缘层和电缆内芯的有效分割。

2 改进 U-Net 的绝缘层图像分割算法研究

2.1 绝缘层图像分割算法概述

针对传统分割方法难以适应不同截面质量和类型的电缆图像,本文提出了一种基于深度学习的高压电缆绝缘层图像分割与提取算法,算法流程如图 4 所示。




图 4 绝缘层分割算法流程

Fig. 4 Insulation layer segmentation algorithm process

由于电缆公开数据量较少且各种文献中未见开放的电缆截面公开数据集,故由 1.2 节中的新型高压电缆绝缘层检测装置进行图像的获取,通过装置采集不同种类、不同位姿以及不同光照强度下的高压电缆截面图像,并

将采集的电缆截面图像制作成数据集。

首先将电缆截面图像数据集进行预处理,通过旋转、裁剪、缩放、色域变换、对比度增强等操作进行数据增强,防止网络训练时因数据量太少产生的过拟合现象;然后使用神经网络模型来提取图像特征,利用像素级分类方法将每个像素分为绝缘层和非绝缘层两类;根据分割效果进行参数的微调,将训练好的最优训练权重对高压电缆截面图像进行预测;对分割结果进行局部自适应二值化处理,通过连通区域算法将电缆截面图像中相邻且颜色相同的像素视为同一个连通区域,即将电缆内芯部分视为一个连通区域,进而对区域进行填充替换得到完整的绝缘层区域图像。

本文提出的高压电缆绝缘层图像分割算法结合 PyTorch 深度学习框架实现神经网络模型的搭建与训练,在 U-Net 以及 VGG16 网络结构分析基础上,使用注意力机制对电缆截面图像中不同区域的信息进行加权使模型更加关注绝缘层边缘的细节区域,提高分割准确度。同时,利用迁移学习来提高模型的泛化能力和适应性,更好地适应电缆绝缘层图像。

2.2 特征提取网络

U-Net^[17]作为经典的图像分割网络广泛应用于小样本数据集的分割,如图 5(a)所示为 U-Net 网络结构,该网络采用了对称的编码器-解码器网络结构实现端对端的语义分割。

编码器由 4 个卷积-池化模块组成,每个模块采用两次卷积操作和一次最大池化操作,其中通过设置卷积核大小为 3×3,步长为 1,填充为 1,使得输入输出图像大小一致;通过设置最大池化操作(如图 6 所示)的池化核大小为 2×2,步长为 2,将特征图分辨率减半,通道数加倍,实现图像深层特征的提取。

解码器由 4 个反卷积-双线性插值模块组成,通过两次卷积核大小为 3×3 的反卷积操作和一次双线性插值操作(如图 7 所示)将特征图恢复到高分辨率,减少因缩放导致的失真现象。

特征图像中目标像素通过坐标系反向变化得到浮点坐标 $(i+p, j+q)$,其中 i, j 为非负整数, p, q 为 $[0, 1]$ 区间的浮点数,像素值由特征图像中坐标为 (i, j) 、 $(i+1, j)$ 、 $(i, j+1)$ 、 $(i+1, j+1)$ 的像素点决定,如式(1)所示。

$$f(i+p, j+q) = (1-p)(1-q)f(i, j) + (1-p)qf(i+1, j) + p(1-q)f(i, j+1) + pqf(i+1, j+1) \quad (1)$$

最后通过一个卷积核大小为 1×1 的卷积操作进行通道的调整,输出分割结果。

为了减少编码器-解码器在上采样和下采样过程中的特征丢失, U-Net 网络引入跳跃连接把更多的浅层信息从编码器的阶段传递到解码器的阶段,减少编码器在




图 5 网络结构

Fig. 5 Network structure




图 6 最大池化操作

Fig. 6 Max pooling operation

主干提取网络将底层图像信息通过一系列操作转化为高层的语义信息, 本文将卷积神经网络 VGG16^[18] 作为主干提取网络, 如图 5(b) 所示。该主干提取网络一共有 5 个卷积-池化模块, 即 Conv1 ~ Conv5, 前两个模块分别进行了两次卷积操作和一次最大池化操作, 后 3 个模块分别进行了 3 次卷积操作和一次最大池化操作, 经过 3 层全连接层, 即 FC6 ~ FC8, 把图像展平得到一个输出向量, 最后由 *Softmax* 激活函数对每个像素点进行分类。

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} (i = 1, 2, \dots, K) \quad (2)$$

式中: x_i 为输出向量的第 i 个元素, K 为向量长度, 由 *softmax* 函数输出的概率值区分像素点所属的类别。

本文在原有网络模型的基础上在 ReLU 激活函数后引入 *Dropout* 层, 目的在于加快运算速度的同时防止高压电缆数据样品过少产生的过拟合现象。

2.3 自适应特征加权机制

为了更好地识别特征图中的有效信息, 增强绝缘层结构特征中边缘信息的提取, 本文结合通道注意力压缩-激励 (squeeze-and-excitation, SE) 模块^[19], 旨在通过自适应地学习通道之间的相关性增加重要信息的权重, 抑制不重要信息, 提高模型的表征能力, 如图 8 所示为压缩-激励模块结构图, 主要由压缩和激励两个步骤构成。

1) 压缩阶段 (图 6 中 $F_{sq}(\cdot)$ 运算) 将输入的特征图 U 进行空间维度的压缩, 在全局感受野中进行平均池化操作将特征图尺寸从 $H \times W \times C$ 压缩成 $1 \times 1 \times C$, 则有:

$$z_c = F_{sq}(u) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (3)$$

式中: z_c 表示压缩过后的输出标量, H 和 W 为特征图的




图 7 双线性插值操作

Fig. 7 Bilinear interpolation operation

最大池化操作时的特征丢失, 保留深层特征并融合细节丰富的浅层特征, 形成精细的分割效果。




图 8 压缩-激励模块

Fig. 8 Squeeze-and-Excitation module

高度和宽度, $u_c(i, j)$ 表示第 c 维的特征。

2) 激励阶段(图 6 中的 $F_{ex}(\cdot)$ 运算)把池化后的特征图在通道维度(C)进行一次全连接操作,得到 $\frac{C}{r}$ 维向量,全连接操作表达式为:

$$s = W_1 z + b_1 \quad (4)$$

式中: s 为映射的全新向量, z 为压缩操作的输出, W_1 和 b_1 分别表示全连接层的权重和偏置。

经过 ReLU 激活函数后,再进行一次全连接操作,将 $\frac{C}{r}$ 维向量重新变为 C 维向量,通过 Sigmoid 激活函数使得权重数值位于 0~1 之间,则有:

$$s_c = F_{ex}(z, w) = \sigma(W_2 \delta(W_1 z)) \quad (5)$$

式中: s_c 表示通道 C 的权重, W_1 和 W_2 分别表示两个全连接层的权重, δ 和 σ 分别表示 ReLU 激活函数和 Sigmoid 激活函数:

$$\delta = g(x) = \max(0, x) \quad (6)$$

$$\sigma = f(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

3) 通过权重相乘操作(图 6 中 $F_{scale}(\cdot, \cdot)$ 运算)将权重加到每个通道的特征上,其表达式可以描述为:

$$\tilde{X} = F_{scale}(u_c, s_c) = s_c u_c \quad (8)$$

式中: $\tilde{X}$ 为标量 s_c 和特征 u_c 相乘后的输出权重。

最后将输入的通道数与编码器的输出通道数对齐,输出即为加权后的特征图。

本文基于通道注意力机制,在 U-Net 的跳跃连接部

分融合自适应特征加权机制,对绝缘层分割中不同颜色、纹理、形状的细节特征进行区分和识别。

2.4 分组卷积

分组卷积^[20]将普通卷积分为两个过滤器分组进行操作,分组指的是在深度上进行分组,输入特征图的宽和高保持不变,在每个过滤器分组中进行正常卷积,对分组得到的特征图按照通道维度进行堆叠,如图 9 所示为分组卷积的原理图。




图 9 分组卷积原理

Fig. 9 Principle of group convolution

设输入每组的特征图尺寸为 $H \times W \times C_1$,输出每组的特征图尺寸为 $H \times W \times C_2$,单个卷积核尺寸为 $K \times K$,可得到标准卷积的参数量 P_1 为:

$$P_1 = C_1 \times K \times K \times C_2 \quad (9)$$

分组卷积包含了两个过滤器组的卷积层,其中每个过滤器组中的每个过滤器仅与前一层的 $1/2$ 特征图进行卷积,每个过滤器正好是等效法线卷积层参数数量的 $1/2$ (虚线部分),输入的特征会沿着通道分为 g 组,故分组卷积参数量 P_2 为:

$$P_2 = K \times K \times C_1/g \times C_2/g \times g \quad (10)$$

参数量与普通卷积相比减少为原来普通卷积的 $1/g$,因此分组卷积不会影响输入和输出特征图的尺寸,模型参数会随过滤器分组数的增大而减少,降低了计算复杂性和模型参数量。

为了在训练过程中减少训练参数量,使得模型在保证精度的同时更加轻量化,本文利用分组卷积代替解码器上采样时的普通卷积操作。

2.5 归纳迁移学习

高压电缆检测设备获取的数据集有限,为提高小样本数据集训练的效率和分割时的精度,采用归纳迁移

学习^[21],从预训练好的模型中学习通用的边缘、纹理和形状等特征,将学习到的通用知识转移到绝缘层特征识别中,实现模型参数的映射,加快模型训练效率,使模型在训练过程中更快地收敛,训练过程如图 10 所示。本文将 VGG16 网络在 Pascal VOC2012^[22]数据集上学习的预训练参数映射到高压电缆训练模型中,调整特征提取网络参数,然后在高压电缆数据集上进行训练,提高绝缘层分割的性能表现。




图 10 迁移学习训练过程

Fig. 10 Transfer learning training process

如图 11 所示,图 11(a)为未使用归纳迁移学习的分割效果,图 11(b)为使用归纳迁移学习后的分割效果,可明显看出添加迁移学习后像素点预测效果提高。

2.6 本文绝缘层分割网络

本文提出的基于深度学习的绝缘层分割网络如




图 11 迁移学习前后对比

Fig. 11 Before and after transfer learning comparison chart

图 12 所示,模型总体结构采用了 U-Net 网络的编码器-跳跃连接-解码器的结构,编码器部分采用 VGG16 网络作为模型的主干提取网络,在图像输入前,统一将输入图像尺寸变化为 $512 \times 512 \times 3$,这里 3 为图像通道数。

经过 VGG16 网络的 4 次下采样操作提取图像的语义信息并使特征图尺寸发生变化,每经过一个卷积-池化模块都在其池化操作前生成一个特征层,通过跳跃连接与解码器上采样后的特征层进行通道维度的融合,融合前在跳跃连接处引入自适应特征加权机制以提高模型表征能力,接着进行 4 次上采样将特征图恢复为原始尺寸,这里上采样的过程采用分组卷积设置卷积核大小为 3×3 ,组数 $g=2$ 。最后利用 1×1 卷积操作进行通道的调整,生成 $512 \times 512 \times 2$ 的特征图,这里 2 表示预测的类别数,即电缆内芯区域以及背景区域。




图 12 本文绝缘层分割网络

Fig. 12 Insulators divide networks

3 实验与分析

3.1 实验过程

实验基于 Pytorch 深度学习框架,在 GPU 环境下进

行训练和测试,采用硬件配置:GPU 型号为 NVIDIA GeForce RTX 3090 Ti,24 GB 显存;CPU 型号为 Intel Xeon E5-2680 V4 @ 2.40 GHz,14 核,125 GB 内存;软件配置:操作系统为 Ubuntu-18.04,CUDA 版本为 11.4,Python 版本为 3.9.7。

本实验共收集 260 张不同光照强度下的不同类型高压电缆截面图像,图像分辨率为 2592×1944 。在图像标注环节中,使用 Labelme 作为图像标注工具,标注所需类别标签并生成 Jason 文件,通过批量转换 Jason 文件为 png 格式的标注图像作为训练集如图 13 所示。



图 13 绝缘层分割数据集示例样本

Fig. 13 Sample insulation segmentation dataset

将收集到的电缆数据集进行划分,训练集、验证集和测试集的划分比例为 $8:1:1$ 。由于电缆数据集较少且绝缘层分割过程中对细节要求较高,因此在网络模型训练过程中选择 Adam 优化算法来适应小样本数据集,结合参数的变化范围自适应地调整学习率,设置优化器内部的动量参数为 0.9,设置模型的初始最大学习率为 0.0001,最小学习率为最大学习率的 0.01。

采用交叉熵损失函数作为模型训练的损失函数,有效量化二分类过程中模型预测值与真实值之间的差异,方便进行梯度计算和参数更新。实验中设置模型总训练迭代次数为 100 轮, batch_size 设置为 4,训练结果如图 14 所示,随着训练轮次的增加,训练集和验证集的损失值快速下降,在大于第 60 轮次时趋于收敛,在 80 轮次无限接近于 0。




图 14 训练过程中损失值随训练轮数的变化趋势

Fig. 14 Trend of Loss with epoch during training

3.2 绝缘层分割评估

在绝缘层分割中,定义电缆内芯像素为正样本,其余像素为背景像素即负样本,定义指标如下:

真正例(true positive, TP),像素预测值和真实值都是正样本,表示电缆内芯像素正确预测为电缆内芯;真负例(true negative, TN),像素预测值和真实值都是负样本,表示背景像素正确预测为背景;假正例(false positive, FP),像素真实值为背景错误的预测成电缆内芯;假负例(false negative, FN),像素真实值为电缆内芯错误的预测成背景。

本文采用平均交并比(mean intersection over union, MIoU)衡量分割结果与真值的交并集比例,其计算公式为:

$$MIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{TP}{FN + FP + TP} \quad (11)$$

平均像素准确率(mean pixel accuracy, MPA)计算正确分割的像素数目占图像总像素数目的比例,其计算公式为:

$$MPA = \frac{1}{k+1} \sum_{i=0}^k \frac{TP}{FP + TP} \quad (12)$$

平均准确率(mean accuracy, MA)表示各类对象准确率平均值,其计算公式为:

$$MA = \frac{1}{k+1} \sum_{i=0}^k \frac{TP + TN}{TP + TN + FP + FN} \quad (13)$$

3.3 消融实验

本文通过平均交并比、平均像素准确率以及平均准确率来评估分割效果,评价指标对分割结果的微小变化非常敏感,微小的差别也可以对分割的准确性产生显著影响,通常情况下指标参数越大,模型分割效果越好。同时,本文引入了模型计算能力即每秒浮点运算次数(giga-floating-point operations per second, GFLOPs)和参数量来评估模型质量。

通过消融实验分别验证了注意力机制、迁移学习以及分组卷积对绝缘层图像分割的有效性。实验过程中,以 U-Net 网络与 VGG16 主干网络为基础设计实验,各项训练参数均保持一致,实验数据对比结果如表 1 所示。

原网络 UNet-VGG16 各项指标如 A 组所示,B、C、D 3 组在原网络的基础上单独添加了模块,分析各组数据可发现分割精度评价指标较原网络均有所提升。其中,A 组添加了注意力机制后模型的复杂程度变化不大;B 组增加了迁移学习后参数量略微减少,分割精度提升最大;C 组添加了分组卷积后减小了模型复杂度的同时提高了分割精度。E、F、G 3 组通过两两添加模块进行对比,分析得到两两组合后精度均有所提升,迁移学习与其他模块结合后对网络模型的精度提升较大,分组卷积与其他模块结合后参数量明显减少。

H 组为融合三者后的网络,通过各项数据表明,分割效果提升最大,平均交并比为 99.56%,相比原网络提高了 1.48%;平均像素准确率为 99.81%,较原网络提升了

0.8%;平均准确率为 99.81%,比原网络高了 1.15%;网络的计算能力为 306.780 GFLOPs,模型参数量为 19.891 MB,相比原 UNet-VGG16 网络更加轻量化的同时提高了分割的精度,因此本文选择 H 组网络作为绝缘层分割网络。

表 1 消融实验效果对比

Table 1 Comparison of ablation experiment effects									
网络	组别	注意力机制	迁移学习	分组卷积	平均交并比/%	平均像素准确率/%	平均准确率/%	计算能力/G	参数量/MB
UNet-VGG16	A				98.08	99.01	98.66	451.735	24.978
	B	√			98.59	99.19	99.38	451.735	24.978
	C		√		99.45	99.68	99.57	451.672	24.891
	D			√	98.63	99.12	99.07	306.780	19.891
	E	√	√		99.52	99.75	99.75	451.672	24.891
	F	√		√	98.35	99.04	99.28	306.780	19.891
	G		√	√	99.55	99.80	99.75	306.717	19.804
	H	√	√	√	99.56	99.81	99.81	306.780	19.891

3.4 对比实验

本节基于高压电缆数据集,给出了测试集中典型电缆截面图像分割效果,如图 15 所示,其中,图 15(a)为原始电缆截面图像,图 15(b)~(e)分别采用 PSPNet^[23]、DeepLabv3_Plus^[24]、U-Net 以及 UNet-SE-VGG 模型进行

实验并对模型进行量化评估,评价指标如表 2 所示。针对小样本图像的二分类分割问题,本文方法分割结果对比其他模型,更加接近真实分割结果,边界信息更为准确,准确度和鲁棒性较高,较其他模型和原 U-Net 更加轻量化。




图 15 电缆截面图像分割效果对比

Fig. 15 Comparison of segmentation effects of cable cross-section images

表 2 不同模型分割效果对比

Table 2 Comparison of the segmentation effects of different models

方法	网络骨架	平均交并比/%	平均像素准确率/%	平均准确率/%	计算能力/G	参数量/MB
PSPNet	MobileNet	88. 22	96. 12	91. 02	6. 034	2. 377
DeepLabv3_Plus	Xception-Net	96. 75	98. 91	97. 75	166. 841	54. 709
U-Net	ResNet	99. 01	99. 70	99. 30	133. 365	33. 758
本文方法	SE-VGG	99. 56	99. 81	99. 81	306. 780	19. 891

通过实验对比 3 种语义分割模型和 UNet-SE-VGG 模型在绝缘层分割上的应用效果,可以看出,PSPNet 和 DeepLabv3_Plus 对于小数据集分割效果不佳。

U-Net 网络能分割截面质量较好的图像,但细节处理效果不佳,对于不规则或磨损较为严重的截面图像容易出现过分割现象。对比原 U-Net 模型,本文 UNet-SE-VGG 模型引入了注意力机制使网络更加关注绝缘层区

域的边缘信息,通过自适应地分配注意力更好地区分绝缘层和其他区域,提高了分割的准确性。使用迁移学习将预训练的 VGG16 网络作为主干网络,从大规模数据集学习到通用特征以帮助模型更好地理解图像内容,提取关键的语义信息并准确地进行绝缘层分割,分割效果明显优于其他方法。本文方法高压电缆绝缘层分割及提取的结果如图 16 所示。




图 16 本文方法绝缘层的分割与提取结果示例

Fig. 16 Examples of segmentation and extraction results of insulation layer

4 结 论

针对传统的高压电缆绝缘层提取方式繁琐,结构尺寸测量效率低、重复测量差异大等问题,本文提出了一种新型高压电缆绝缘层检测装置以及一种基于 UNet-SE-VGG 的电缆绝缘层分割方法。首先设计了新型检测装置进行高压电缆截面图像的获取与分析,研究了基于 U-Net 的图像分割网络,替换主干提取网络为 VGG16 网络并融合迁移学习,在跳跃连接部分引入自适应特征加权机制,提高了模型的泛化能力和语义分割的精度,使用分组卷积模块使模型更加轻量化;对分割得到的区域轮廓进行填充及替换得到完整高压电缆绝缘层图像。

实验结果表明,本文提出的方法适用于不同类型及不同截面质量的高压电缆,分割指标平均交并比和平均

像素准确率达到 99. 56% 和 99. 81%,实现了高压电缆截面图像的快速获取以及绝缘层的精确分割。在机器视觉检测电缆质量安全场景中,该方法成功应用到便携式电缆实时测量设备中,提高了绝缘层检测精度及效率,对高压电缆结构参数的测量具有重要意义。

参考文献

[1] 邓磊,刘桂华,邓豪,等. 三维点云分割的交联聚乙烯电缆接头参数测量[J]. 电子测量与仪器学报, 2022, 36(9): 197-207.
DENG L, LIU G H, DENG H, et al. Parameter measurement of cross-linked polyethylene cable joint based on three-dimensional point cloud segmentation[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(9): 197-207.
[2] 中华人民共和国国家质量监督检验检疫总局. 电动

- 汽车充电用电缆: GB/T 33594-2017[S]. 北京: 中国标准出版社, 2017.
- General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China. Charging cables for electric vehicles: GB/T 33594-2017 [S]. BeiJing: Standards Press of China, 2017.
- [3] 董辉平, 谢娟敏, 沈奶连. 线缆绝缘和护套几何参数测试系统设计[J]. 电线电缆, 2015(5): 28-30.
- DONG H P, XIE J M, SHEN N L. The design about cable insulating & sheathing materials geometry auto-testing system [J]. Electric Wire & Cable, 2015(5): 28-30.
- [4] 沈彪, 周锋, 赵力, 等. 基于局部区域灰度亚像素法电缆护套厚度精确测量[J]. 电测与仪表, 2016, 53(8): 62-68.
- SHEN X, ZHOU F, ZHAO L, et al. A sub-pixel edge detection algorithm based on local area gray-scale of thickness measurement of cable sheath material [J]. Electrical Measurement & Instrumentation, 2016, 53(8): 62-68.
- [5] 王爱军, 田东哲, 李宇翔, 等. 基于切线法定位圆心的电缆横截面几何尺寸自动测量方法的设计与实现[J]. 郑州大学学报(理学版), 2018, 50(2): 114-118.
- WANG AI J, TIAN D ZH, LI Y X, et al. Design and realization of automatic measuring method of cable cross section geometry based on tangent method[J]. Journal of Zhengzhou University (Natural Science Edition), 2018, 50(2): 114-118.
- [6] LENTY B, SIOMA A, KWIEK P. Quality control automation of electric cables using machine vision[C]. Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments, 2018.
- [7] 阴法明, 王康, 赵力. 电缆护套厚度灰度矩亚像素测量研究[J]. 电子测量与仪器学报, 2019, 33(10): 128-133.
- YIN F M, WANG K, ZHAO L. Sub-pixel edge detection algorithm based on gray-moment for thickness measurement of cable sheath material [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(10): 128-133.
- [8] 董霏, 侯北平, 刘宇, 等. 基于机器视觉的线缆导体质量检测研究[J]. 电子测量与仪器学报, 2020, 34(6): 144-153.
- DONG F, HOU B P, LIU Y, et al. Research on quality inspection of cable conductor based on machine vision[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(6): 144-153.
- [9] 侯北平, 张晓刚, 朱文, 等. 基于频域滤波的电缆线芯图像纹理消除研究[J]. 仪器仪表学报, 2021, 42(11): 210-219.
- HOU B P, ZHANG X G, ZHU W, et al. Research on texture removal of the cable core image based on frequency domain filtering [J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 210-219.
- [10] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.
- [11] ZHU W, DONG F, HOU B P, et al. Segmenting the semi-conductive shielding layer of cable slice images using the convolutional neural network [J]. Polymers, 2020(9): 1-14.
- [12] 黄志豪, 郑盼龙, 许新宇, 等. 基于轻卷积神经网络的电力电缆绝缘损伤图像检测方法[J]. 电子设计工程, 2019, 27(13): 171-175.
- HUANG ZH H, ZHENG P L, XU X Y, et al. A power cable detection algorithm based on a light convolutional neutral network [J]. Electronic Design Engineering, 2019, 27(13): 171-175.
- [13] 徐子弘, 季天瑶, 邓伟民, 等. 基于 AE 和 GRU 神经网络的电缆早期故障检测和识别方法[J]. 广东电力, 2020, 33(9): 27-34.
- XU Z H, JI T Y, DENG W M, et al. Detection and identification of cable incipient fault based on auto-encoder and GRU neural network [J]. Guangdong Electric Power, 2020, 33(9): 27-34.
- [14] 翁玉尚, 肖金球, 汪俞成, 等. 改进 RCF 算法的电缆绝缘层边缘检测[J]. 光学技术, 2022, 48(1): 86-92.
- WENG Y SH, XIAO J Q, WANG Y CH, et al. Edge detection of cable insulation based on improved RCF algorithm[J]. Optical Technique, 2022, 48(1): 86-92.
- [15] 刘宇, 侯北平, 张晓刚. 基于深度残差网络的电缆绝缘层截面图像分类研究[J]. 电线电缆, 2021(5): 17-23.
- LIU Y, HOU B P, ZHANG X G. Research on image classification of cable insulation layer cross section based on deep residual network[J]. Wire & Cable, 2021(5): 17-23.
- [16] 李瑾, 范佳能, 刘屹然. 复杂环境基于 YOLACT 电缆识别与定位[J]. 电子测量技术, 2023, 46(4): 114-120.
- LI J, FAN J N, LIU Y R. Cable identification and location based on YOLACT in complex environment[J]. Electronic Measurement Technology, 2023, 46(4): 114-120.

- [17] 何晓云, 许江淳, 陈文绪. 基于改进 U-Net 网络的眼底血管图像分割研究[J]. 电子测量与仪器学报, 2021, 35(10): 202-208.
HE X Y, XU J CH, CHEN W X. Research on fundus blood vessel image segmentation based on improved U-Net network[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 202-208.
- [18] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014, DOI:10.48550/arXiv.1409.1556.
- [19] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [20] IOANNOU Y, ROBERTSON D, CIPOLLA R, et al. Deep roots: Improving cnn efficiency with hierarchical filter groups[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1231-1240.
- [21] 周强, 田鹏飞. 基于迁移学习多层次融合的运动想象 EEG 辨识算法[J]. 电子测量与仪器学报, 2021, 35(12): 174-181.
ZHOU Q, TIAN P F. EEG identification algorithm of motor imagination based on multi-level fusion of transfer learning[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(12): 174-181.
- [22] EVERINGHAM M, GOOL L V, WILLIAMS C, et al. The pascal visual object classes (VOC) challenge[J]. International Journal of Computer Vision, 2010, 88(2): 303-338.
- [23] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]. Proceedings of the IEEE Conference on

Computer Vision and Pattern Recognition, 2017: 2881-2890.

- [24] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40 (4): 834-848.

作者简介



侯北平(通信作者), 2005 年于浙江大学获得博士学位。现为浙江科技学院自动化与电气工程学院教授、硕士生导师、中国仪器仪表学会微型计算机应用分会委员会委员, 主要研究方向为机器视觉与模式识别、图像处理。

E-mail: bphou@zust.edu.cn

Hou Beiping (Corresponding author) received his Ph. D. degree from Zhejiang University in 2005. He is now a professor and master advisor in the School of Automation and Electrical Engineering at Zhejiang University of Science and Technology. His main research interests include machine vision and pattern recognition, and image processing.



李丰余, 2021 年于同济大学浙江学院获得学士学位, 现为浙江科技学院硕士研究生, 主要研究方向为深度学习、图像处理。

E-mail: li_fengyu0711@163.com

Li Fengyu received his B. Sc. degree from Tongji ZhengJiang College in 2021. He is now a M. Sc. degree at Zhejiang University of Science and Technology. His main research interests include deep learning and image processing.