

DOI: 10.19650/j.cnki.cjsi.J2514683

基于注意力分割与对抗重建的高压 电缆绝缘厚度测量*

邱文俊, 侯北平, 朱 文, 董建伟, 介 婧

(浙江科技大学自动化与电气工程学院 杭州 310023)

摘要:针对高压电缆绝缘层人工检测效率低、传统图像算法在弱边界条件下精度低的问题,提出了一套便携式测量方案,并设计了一种基于“粗定位-精细重建”的两阶段电缆绝缘厚度测量算法。首先,构建了融合多尺度特征与空间注意力机制的语义分割模型 SA-UNet,并结合提出的多尺度注意力融合编码器(MSAF)、精细多核池化模块(RMP)和跳跃注意力特征融合模块(SAFF),有效增强了模型对复杂细节与弱边界的感知能力,能够精准分割出包含导体屏蔽层、主绝缘层和绝缘屏蔽层的完整绝缘结构,通过注意力机制聚焦关键特征,准确提取高压电缆绝缘区域,有效缓解了因类别不平衡导致的分割精度下降问题;其次,引入 Pix2Pix GAN 生成对抗网络对分割后的低对比度区域进行图像重建,通过学习构建了图像边界从模糊到清晰的映射,以增强层间边界的梯度信息与纹理细节;最后,基于重建结果采用射线交点法自动计算厚度参数。在包含 3 300 张高压电缆截面图像的数据集上进行验证,实验结果表明,SA-UNet 模型在分割性能上表现优异,交并比(IoU)高达 99.36%,优于 U-Net、DeepLabv3+ 等主流模型;Pix2Pix GAN 重建图像具有极高的结构保真度(SSIM>0.98);绝缘层厚度测量的平均绝对误差(MAE)仅为 0.01 mm。该方法为高压电缆绝缘参数的高精度自动化测量提供了有效解决方案。

关键词: 高压电缆;绝缘层厚度;语义分割;生成对抗网络;机器视觉

中图分类号: TH701 TM247 文献标识码: A 国家标准学科分类代码: 460.50

Measurement of high-voltage cable insulation thickness using attention-based segmentation and adversarial reconstruction

Qiu Wenjun, Hou Beiping, Zhu Wen, Dong Jianwei, Jie Jing

(School of Automation and Electrical Engineering, Zhejiang University of Science and Technology, Hangzhou 310023, China)

Abstract: Manual inspection of high-voltage cable insulation is inefficient, and traditional algorithms falter at weak boundaries. To address this, we propose a portable measurement system and a two-stage “coarse localization-fine reconstruction” algorithm. First, a novel scale-aware attention U-Net (SA-UNet) performs precise segmentation. It incorporates a multi-scale attention fusion encoder (MSAF), a refined multi-kernel pooling (RMP) module, and a Skip attention feature fusion (SAFF) module to enhance perception of complex details and weak boundaries, effectively mitigating issues from class imbalance. Subsequently, a Pix2Pix generative adversarial network (GAN) reconstructs low-contrast regions, sharpening interlayer boundaries by learning a mapping from blurred to clear images. Finally, insulation thickness is automatically computed using the ray intersection method. Validated on a dataset of 3 300 cross-sectional images, the proposed SA-UNet achieves a 99.36% intersection over union (IoU), outperforming models like U-Net and DeepLabv3+. The GAN reconstruction achieves high structural fidelity (SSIM > 0.98), enabling a final thickness measurement with a mean absolute error (MAE) of only 0.01 mm. This work presents a robust, automated solution for high-precision measurement of high-voltage cable insulation parameters.

Keywords: high-voltage cables; insulation layer thickness; semantic segmentation; generative adversarial network; machine vision

0 引言

随着全球能源向可持续方向加速转型,高效输电技术的重要性不断凸显,而高压电缆在降低远距离输电过程中的能量损耗方面具有不可替代的作用^[1]。电缆以导体为核心传输电能,其绝缘层则是保障其安全运行的关键。绝缘层的结构参数不仅影响电性能和机械强度,还直接关系到电缆寿命与运行安全。存在制造缺陷的绝缘层可能导致热失控与故障,而精确测量绝缘参数则有助于预防潜在电缆质量隐患,减少经济损失^[2-4]。

传统测量方法如切片观察法^[5]虽能提供直观的基准数据,但属于破坏性检测。其测量前需从电缆上切取薄片试样,该过程不仅对操作技巧要求高以避免材料变形,后续的显微镜读数耗时费力,且易引入人为误差,难以满足现代工业对高效率、批量化检测的需求。无损测量方法如超声波检测^[6]和X射线检测^[7],虽然避免了物理损伤,但受限于对薄层材料的分辨能力以及对声学或射线特性相近材料的区分能力,测量精度往往难以满足要求。为此,研究者转向基于图像处理的机器视觉技术。Lenty等^[8]采用边缘提取算子与RDP(Ramer-Douglas-Peucker)算法测量了电缆导体直径。Wei等^[9]提出基于机器视觉的方法,通过零样本SAM(segment anything model)分割模型与优化骨架提取算法,实现了对复杂多支路电缆的高稳定性精准测量。王爱军等^[10]提出通过形态学运算提取边缘像素后运用切线法确定圆心位置,通过霍夫变换与线性映射计算直径参数的电缆尺寸测量方法。侯北平等^[11]提出了一种基于改进频域滤波的截面图像刀痕纹理消除方法,提升了电缆质量检测的效率。然而,这些方法大多依赖于特定的先验知识或理想成像条件。在实际工业环境中,高压电缆横截面图像常存在绝缘层与屏蔽层之间对比度低、边界模糊、光照不均以及绞合导体形成不规则内边界等问题,导致传统算法的性能显著下降,难以满足高精度测量需求。

近年来,深度学习技术在复杂的检测任务中展现出良好的鲁棒性与分割精度^[12],为解决复杂背景下的测量问题提供了新途径^[13-15]。Zhu等^[16]提出基于全卷积网络(fully convolutional networks, FCN)的电缆导体屏蔽层图像分割方法,通过改进外边界定位的加权损失函数消除干扰。赵恩玄等^[17]利用深度学习模型分析电缆接头的表层温度数据,实现了对绝缘劣化状态的非接触式诊断。陈研等^[18]通过迁移学习技术处理计算机断层扫描图像(computed tomography, CT)实现自动检测其内部的物理缺陷。Roy等^[19]融合深度卷积生成对抗网络(deep convolution generative adversarial networks, DCGAN)与卷

积神经网络(convolutional neural networks, CNN),实现了高压电缆绝缘层内的电树生长阶段的描述。王晓康等^[20]为解决单一信息源存在的局限性,将深度学习与D-S证据理论相结合,通过融合高频、超声等多种局部放电信号,显著提升了电缆接头故障诊断的准确性与鲁棒性。侯北平等^[21]基于UNet模型通过高压电缆线芯截面分割获得高压电缆绝缘图像。尽管深度学习在电缆状态评估与故障诊断领域已取得显著进展,但在高精度结构参数量化,特别是构建从图像输入到参数输出的完整自动化测量系统方面的研究有待提升。

基于上述分析,该研究打破了传统的高压电缆绝缘层厚度测量依赖物理切片的常规模式,设计了一种基于“粗定位-精细重建”策略的便携式高压电缆绝缘厚度测量装置,本研究通过直接分析电缆截面的数字图像,避免了传统方法中复杂的物理切片制备过程,实现了从图像采集到参数输出的自动化处理,为高压电缆的高效、快速质检提供了新途径。同时还设计了一种语义分割网络SA-UNet,通过不同的空间注意力融合机制,有效缓解了由类别不平衡引起的分割偏差,并实现了绝缘区域的精准定位;引入Pix2Pix GAN生成模型对分割结果进行图像重建与边界增强,提升了系统在真实工业环境下的鲁棒性;最后基于增强图像的几何算法完成对绝缘层厚度参数计算。该研究构建了一套从图像采集到参数输出的整体框架,实验表明,该框架在图像存在模糊边界条件下测量精度达到微米级(约10 μm),为高压电缆的高精度自动化测量提供了可靠的技术方案。

1 研究框架

高压电缆的截面结构如图1所示,由绞合导体及依次包裹的导体屏蔽层、主绝缘层与绝缘屏蔽层构成。在对电缆截面图像分析基础上,实现对各绝缘层厚度的精确测量。然而,在实际成像过程中,获取的电缆灰度图像中各层之间的局部细节会呈现对比度低、边界模糊等特征,这对精确分割与测量带来挑战。




图1 高压电缆样品及其截面结构

Fig. 1 High-voltage cable samples and cross-sectional structure

为应对高压电缆绝缘图像中极端类别不平衡及层间边界模糊的难题,本研究设计一种由粗到精的两阶段测量框架,整体框架如图2所示。

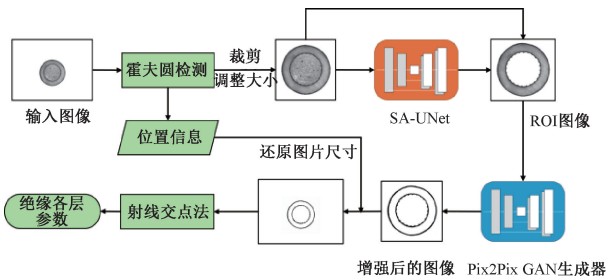


图2 整体实施框架

Fig. 2 The overall implementation flow chart of the experiment

在粗分割阶段,所提出的 SA-UNet 模型通过分割整体绝缘结构实现粗定位,精确提取感兴趣区域(region of interest, ROI),有效缓解类别不平衡问题;若直接进行多类别分割,占比较小的屏蔽层在损失函数计算中易被面积较大的绝缘层主导,导致模型训练偏向于绝缘层的分割,忽略对屏蔽层特征的学习,使得屏蔽层边界分割精度下降。

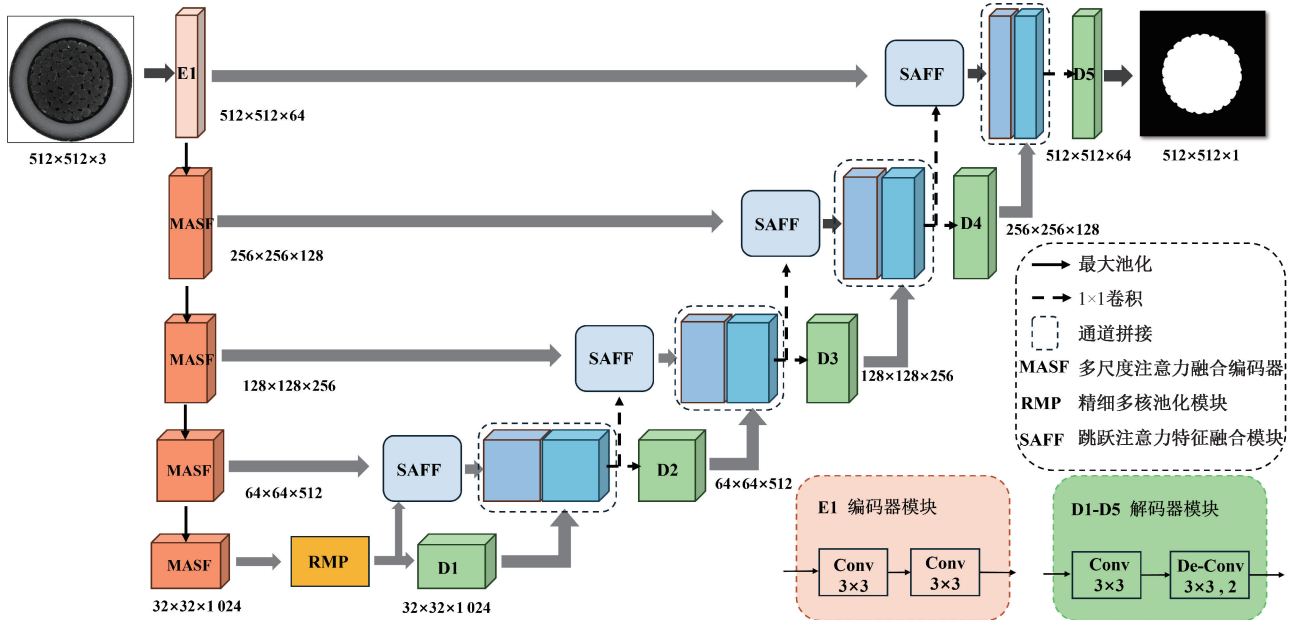


图3 SA-UNet的网络结构

Fig. 3 Overall architecture of SA-UNet

为增强模型对电缆截面图像中复杂细节和弱边界的感知能力,研究在经典 U-Net 框架基础上进行改进,提出了 SA-UNet 分割网络,核心设计思路通过以下 3 个协同工作的模块实现。

模块 1:在编码器路径中,设计的多尺度注意力融合编码器(multi-scale attention fusion encoder, MASF)取代

在精细重建阶段,通过 Pix2Pix GAN^[22]将 ROI 图像转换成边界结构清晰的绝缘层图像。与仅依赖像素分类的方法不同,Pix2Pix GAN 学习将低对比度、边界模糊的 ROI 图像映射为对比度更高、边界清晰的理想分割掩码。对抗训练机制能够强化边缘表达,因此在解决传统分割方法易受模糊性影响时展现出明显优势。

提出的两阶段电缆图像处理策略通过任务解耦实现了优势互补:粗分割阶段解决了类别不平衡问题;精细重建阶段则用于克服边界模糊,最终共同提升整体的分割效果。这种由粗到精的模式已在医学影像分析^[23-24]和精密工业检测^[25]等高精度检测领域应用。

2 所提出的算法

2.1 SA-UNet 模型

经典的 U-Net 模型已在分割领域取得了广泛应用,但对小尺度和不规则形状(如电缆绝缘层与绞合导体的连接边界)的特征捕捉能力有限,难以满足高精度测量的要求^[26-27]。为此,提出了 SA-UNet 模型,整体结构如图3所示。

了传统的卷积块,通过并行扩张卷积和空间注意力机制,使得 MASF 能够在降采样的同时,有效捕捉不同感受野下的上下文信息,并自适应地增强与绝缘层边界相关的特征响应,为后续处理提供高质量的深层特征。

模块 2:在网络的瓶颈层,引入了精细多核池化模块(refined multi-kernel pooling, RMP),通过多尺度池化和

轻量级注意力分支,进一步聚合全局上下文信息,增强了模型对整个电缆结构布局的理解能力。

模块 3:在解码器路径的跳跃连接处,设计了跳跃注意力特征融合模块(skip attention feature fusion, SAFF),利用高层语义特征指导低层细节特征的筛选与融合,有效缓解了特征不匹配问题,提升了分割边界的精细度和准确性。

综上所述,SA-UNet 通过集成的三大核心模块协同工作:MSAF 负责捕捉多尺度细节特征,RMP 增强全局上下文感知,而 SAFF 则优化跨层级特征融合,将局部精细感知与全局结构理解结合,有效解决弱边界和复杂结构下的分割难题,最终实现对高压电缆绝缘区域的精确分割。

1) 多尺度注意力融合编码器

为提取多尺度特征,设计了 MSAF 模块,如图 4 所示。该模块采用多分支并行架构,每条路径通过 4 条并行路径对输入特征进行处理,结合标准卷积与不同扩张率的扩张卷积,实现局部细节与全局上下文的同步捕捉。

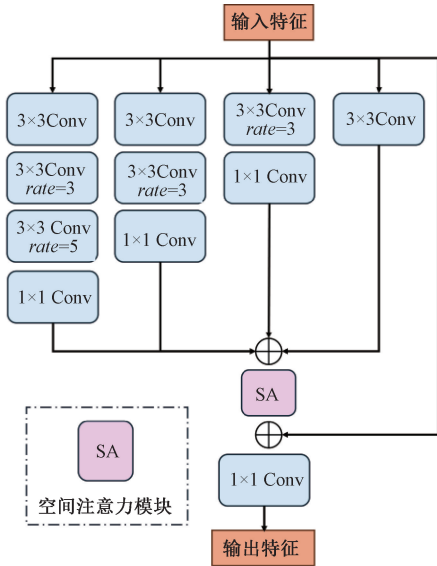


图 4 MSAF 模块
Fig. 4 MSAF module

通过逐元素求和操作,得到兼具细粒度与上下文信息的综合特征。融合后的特征被输入空间注意力模块(详见图 5)通过注意力权重校正特征图,从而增强关键区域响应并抑制背景噪声。为保持特征保真度并稳定训练过程,对注意力加权后的特征与原始输入进行残差连接。最后,将融合结果经过单位卷积进行通道整合,输出增强后的特征图。

2) 精细多核池化模块

设计了 RMP 模块以增强模型在瓶颈层的多尺度上下文建模能力,如图 6 所示。




图 5 空间注意力模块
Fig. 5 Spatial attention module

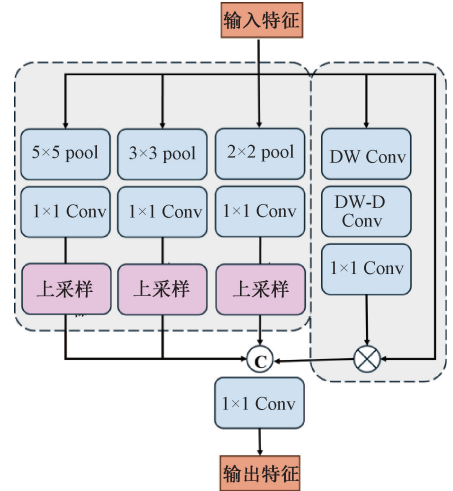


图 6 RMP 模块
Fig. 6 RMP module

该模块由两部分组成:(1)多尺度池化分支。受金字塔池化^[28]启发,输入特征分别经过不同核尺度的最大池化操作,获得不同感受野下的上下文信息。各池化输出通过 1x1 卷积进行通道压缩,随后上采样至与输入特征相同的空间尺寸。三路上采样特征在通道维度上进行拼接,并通过额外的 1x1 卷积进一步融合多尺度信息;(2)轻量注意力分支。该分支通过深度可分卷积(depthwise convolution, DW Conv)与深度可分膨胀卷积(depthwise dilated convolution, DW-D Conv)提取空间结构关联信息,扩张感受野信息,采用 1x1 卷积生成调制特征图。最终,多尺度池化分支的融合特征与注意力分支的调制特征图进行逐元素相乘,实现多尺度上下文的自适应加权。该模块计算开销较低,但能有效增强特征表达的判别性、全局上下文感知能力。

3) 跳跃注意力特征融合模块

为解决传统跳跃连接中因“语义鸿沟”(semantic gap)导致的特征不匹配问题,提出将 SAFF 模块嵌入语义分割跳跃连接处(如图 7 所示)。SAFF 模块充当一个智能的特征门控(feature gate),利用解码器的高层特征作为门控信号(gating signal),对编码器的低层特征进行

选择性过滤和增强,确保了只有与分割任务最相关的空间细节才能被传递和融合,有效桥接了语义鸿沟,显著提升了特征融合的效率。

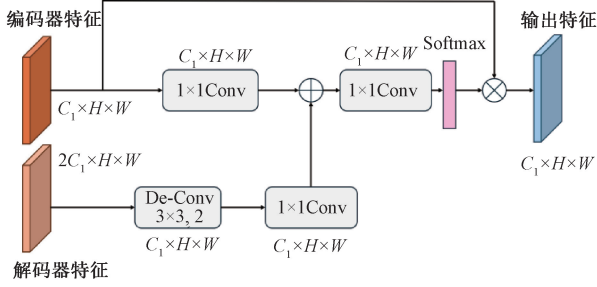


图7 SAFF模块

Fig.7 SAFF module

跳跃注意力特征融合模块可表示为:

$$F_x = Conv_{1 \times 1}(F_{en}) \quad (1)$$

$$F_g = Conv_{1 \times 1}(Up - Conv(F_{de})) \quad (2)$$

$$Att = \sigma(Conv_{1 \times 1}(F_x + F_g)) \quad (3)$$

$$Out = Att \otimes F_{en} \quad (4)$$

其中, F_{en} 表示编码器输入特征, F_{de} 表示解码器输入特征。Att 和 Out 分别代表注意力图和输出。 \otimes 表示元素级矩阵乘法运算。上卷积(Up-Conv)指匹配特征图空间维度的转置卷积操作。 σ 表示 sigmoid 激活函数。

通过融合不同粒度层级的特征并施加注意力引导,训练后的模型能够在电缆图像中更准确地聚焦于关键区域,提升绝缘层分割精度。

2.2 Pix2Pix GAN 模型

为进一步提升绝缘层边界的可辨识度,在 SA-UNet 分割结果的 ROI 引入条件生成对抗网络(conditional GAN)^[29]进行图像增强。由于绝缘材料存在非均匀透光、亮度差异及制造工艺导致的纹理变化,其内部各层之间的边界通常模糊且对比度较低,传统边缘检测或阈值方法难以获得稳定、精确的边界定位。为克服这一问题,采用 Pix2Pix 框架对 ROI 图像进行增强,生成具有清晰层级结构的截面图像。

Pix2Pix 旨在学习一个条件映射函数 $G: X \rightarrow Y$, 其中 X 为原始 ROI 图像,而 Y 为人工构建的理想化目标图像。与真实标注不同,这些目标图像对绝缘层结构进行了标准化设计,具有均匀的内部色彩与锐利的层间边界,从而为模型提供明确且一致的学习目标。

Pix2Pix 的网络结构包括生成器和判别器两部分,其整体架构如图8所示。生成器采用 U-Net 结构,通过跳跃连接保留局部纹理与全局结构信息,实现从输入到目标域的结构映射。判别器采用 PatchGAN 设计,不对整幅图像作真伪判断,而是基于多个局部像素块进行判别,从而更有效地约束生成图像中的纹理连贯性和高频细

节。通过成对样本的对抗式训练,生成器逐步学习到稳定可靠的输入—输出映射,使生成的增强图像在保持整体结构一致性的同时,具备更加清晰的层间边界。




图8 Pix2Pix GAN 模型结构

Fig.8 Pix2Pix GAN architecture

Pix2Pix GAN 的损失函数由两部分构成:对抗性损失(cGAN Loss)促使生成器产生视觉上逼真的图像,以“欺骗”判别器;而L1损失则作为更强的约束,从像素层面保证生成图像在结构上与理想化目标图像高度一致。其损失函数如式(5)~(7)所示。

$$L_{GAN}(G, D) = E_{x, y, p(x, y)} [\log D(x, y)] + E_{x, p(x)} [\log(1 - D(x, G(x)))] \quad (5)$$

$$L_{L1}(G) = E_{x, y, p(x, y)} [\|y - G(x)\|_1] \quad (6)$$

$$L = L_{GAN} + \alpha L_{L1} \quad (7)$$

其中, $E_{x, y, p(x, y)}$ 表示 SA-UNet 分割出的低对比度、边界模糊的 ROI 图像和与之配对的、人工标注的边界锐利、对比度高的理想化目标图像(y)从概率分布 $p(x, y)$ 中采样时的期望值。判别器的目标是最大化 $L_{GAN}(G, D)$, 而生成器的目标是最小化它。由于判别器(D)的输出值在0和1之间,因此当 $D(x, y) = 1$ 时, $E_{x, y, p(x, y)} [\log D(x, y)]$ 达到其最大值。从概率分布 $p(x)$ 中采样的低对比度、边界模糊的 ROI 图像的期望值用 $E_{x, p(x)}$ 表示。当 $D(x, G(x)) = 0$ 时, $E_{x, p(x)} [\log(1 - D(x, G(x)))]$ 得到最大值,而当生成器 G 成功骗过判别器 D 时,该项会被最小化。 $\|\dots\|_1$: 表示 L1 范数(L1 Norm),即两者绝对误差的求和。 α 是一个超参数,用于平衡两个损失函数,其数值设置为100,以有效提升生成图片的质量^[30]。


2.3 基于模型输出的电缆绝缘层厚度计算

鉴于电缆绝缘层呈典型的同心圆结构,如图9所示采用射线交点法对 Pix2Pix GAN 重建后的高对比度图像进行厚度测量。


流程如图9(a)所示,该方法依次包括边缘检测、中心定位与射线交点计算这4个步骤,具体为:

1) 从重建图像中提取绝缘结构各层的清晰内外边界。

2) 如图9(b)所示,对绝缘层的边界采用 Hough 圆变换确定电缆中心位置。以该中心为起点,均匀发射360条测量射线。对于任意绝缘层,记录每条射线与其内、外边界的两个交点,并将二者间的像素距离作为该方向上的局部厚度。



(a) 射线交点法计算绝缘厚度的流程
(a) Flowchart of insulation thickness calculation using the ray intersection method



(b) 射线交点法计算示意图
(b) Schematic calculation of ray intersection method

图 9 射线交点法计算绝缘层厚度

Fig. 9 Calculation of insulation thickness by the ray intersection method

3) 通过对所有方向的测量结果进行统计, 得到绝缘层的平均、最大与最小厚度, 实现对电缆几何参数的量化评估。上述过程对每一层绝缘结构均独立执行, 以确保测量精度。

4) 为将计算得到的像素尺寸转换为实际物理尺寸, 需进行相机标定。在固定工作距离下获得像素与毫米之间的换算系数, 即像素率。计算公式如式 (8) 所示。

$$\eta = D_1 / D_2 \quad (8)$$

其中, D_1 为两特征点的实际物理尺寸, D_2 为其在图像中测得的像素距离。最终的绝缘层厚度由像素值乘以像素率 η 得到。

3 实验与结果分析

3.1 实验装置与数据集

搭建了一套便携式高压电缆绝缘层图像采集与测量装置, 如图 10 所示。该装置采用了轻量化结构设计, 便于灵活部署与调整。为确保高质量成像, 装置集成了环形光源, 提供均匀且稳定的照明条件, 有效排除环境光干扰, 通过固定相机与被测电缆表面的距离, 保证了稳定的成像条件和一致的像素与物理尺寸转换关系。为确保测

量精度, 采用张氏标定法^[31]对相机进行校准, 以确定内参并修正镜头畸变。

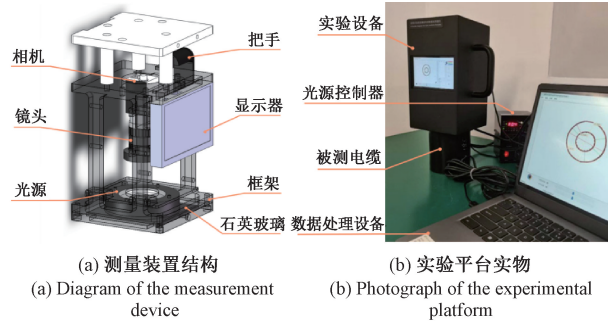


图 10 电缆绝缘层厚度测量装置
Fig. 10 Cable insulation thickness measurement device

在深度学习框架中, 数据集质量对模型训练效率和预测准确性起着决定性作用。采用如图 10 (b) 所示的便携式高压电缆图像采集装置, 获取了包含 3 300 张分辨率高压电缆横截面图像 (2 592 pixels × 1 944 pixels) 的初始数据集。这些图像涵盖了多种型号的高压电缆, 并在不同的光照、成像角度等条件下采集, 以增强数据的多样性。为提升计算效率与分割精度, 预处理流程为:

1) 对电缆截面图像裁剪, 去除了无关背景, 提高了目标区域占比的同时保留关键边界细节。

2) 在尺寸调整过程中保持恒定的长宽比, 最大限度降低几何失真。最后按照 8 : 1 : 1 的比例划分为训练集、验证集和测试集。所有图像统一调整为 512 pixels × 512 pixels 分辨率, 并作为 SA-UNet 模型的输入。

为训练 Pix2Pix GAN 模型, 制作了 1 700 组配对图像。每组包含了通过 SA-UNet 分割掩膜自动裁剪得到的 ROI 图像和对应的人工标注的边界清晰的目标图像。该数据集按 9 : 1 的比例划分为训练集和测试集。

3.2 实验环境配置

所有实验均在表 1 所示的软硬件环境下进行, 同时列出了 SA-UNet 模型的训练超参数。为了精确指导 SA-UNet 分割目标区域, 采用由 BCE Loss 和 Dice Loss 构成的复合损失函数。BCE Loss 侧重于像素级的分类准确性, 而 Dice Loss 则侧重于预测区域与真实区域之间的轮廓相似性与形状重叠度。二者结合后, 可以提升优化模型的分割效果。对于 Pix2Pix GAN, 实验采用了论文^[29]推荐的默认超参数进行训练 (学习率 0.000 2, 批量大小为 1, 进行 200 轮训练)。

3.3 评价指标

实验使用 4 项标准指标评估 SA-UNet 的分割性能: 交并比 (intersection over union, IoU)、召回率 (recall)、Dice 系数以及精确率 (precision)。各项评估指标的计算公式如式 (9) ~ (12) 所示。

表1 系统配置与训练策略

Table 1 System configuration and training strategy

配置环境	硬件环境	具体配置
硬件环境	CPU	Intel Xeon E5-2680 V4@ 2.40 GHz
	RAM	24 GB
	GPU	NVIDIA GeForce RTX 3090Ti
软件环境	操作系统	Ubuntu 18.04
	CUDA 版本	11.3
	Python 版本	3.10
	Torch 版本	1.12.1
训练策略 (SA-UNet)	优化器	Adam W
	批次大小	6
	损失函数	BCE Loss + Dice Loss
	初始学习率	0.001
	学习率下降策略	每20训练轮次学习率下降10倍
	训练轮数	100

$$IoU = TP / (FN + FP + TP) \quad (9)$$

$$Recall = TP / (TP + FN) \quad (10)$$

$$Dice = 2TP / (2TP + FP + FN) \quad (11)$$

$$Precision = TP / (TP + FP) \quad (12)$$

其中, TP 为正确识别的目标像素数; FP 为被误分类的背景像素数; FN 为被误分类为背景的导体像素数。

为评估 Pix2Pix GAN 的图像生成质量, 采用峰值信噪比 (peak signal-to-noise ratio, PSNR) 与结构相似性指数 (structure similarity index measure, SSIM) 进行评估。PSNR 用于衡量像素级重建精度, SSIM 则从感知层面评估图像的结构相似性。

生成图像 x 与目标图像 y 之间 SSIM 值计算如式 (13) 所示。

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (13)$$

其中, μ 和 σ^2 分别表示局部均值和局部方差, 而 σ_{xy} 是局部协方差。常数 $c_1 = (K_1L)^2$ 和 $c_2 = (K_2L)^2$ 作为稳定因子, L 为像素动态范围, 默认值设定为 $K_1 = 0.01$ 和 $K_2 = 0.03$ 。

PSNR 的计算基于均方误差 (mean square error, MSE), 其定义如式 (14) 所示。

$$PSNR(x, y) = 20 \lg \left(\frac{MAX_I}{\sqrt{MSE(x, y)}} \right) \quad (14)$$

$$MSE(x, y) = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \quad (15)$$

其中, MAX_I 表示像素的最大可能强度值。 N 为总像素数, x_i 和 y_i 分别表示两幅图像中对应像素的灰度值。

3.4 SA-UNet 模型

1) 与不同模型的性能对比

为验证所提 SA-UNet 模型的有效性, 将其与多个主流模型进行对比, 包括 U-Net^[32]、UNet++^[33]、Res-UNet^[34]、DeepLabv3+^[35]、Attention U-Net^[36] 和 TransUNet^[37]。采用 IoU、Recall、Dice、Precision、参数数量和响应时间 6 个指标对模型进行评估, 实验结果如表 2 所示。尽管 SA-UNet 的参数数量略高于基线模型, 但其单次推理时间仅为 30.2 ms, 仍保持较高的计算效率, 可充分满足工业检测的实时性要求。与此同时, SA-UNet 在 4 项核心指标上均取得最优表现: IoU 达 99.36%, Recall 为 99.81%, Dice 为 99.82%, Precision 高达 99.97%, 较基线模型 U-Net 分别提升了 0.91%、0.24%、0.80% 和 1.49%, 验证了其在电缆绝缘层区域分割任务中的卓越性能。

表2 不同模型的性能结果对比

Table 2 Comparison of performance results of different algorithms

模型名称	IoU/ %	Recall/ %	Dice/ %	Precision/ %	参数数量/ M	响应时 间/ms
U-Net	98.45	99.57	99.02	98.48	31.0	25.1
UNet++	98.59	99.38	99.30	99.19	47.1	65.5
Res-UNet	98.63	99.07	99.10	99.12	69.2	19.3
Attention U-Net	99.29	99.65	99.68	99.71	34.9	28.5
TransUNet	97.81	99.45	99.49	99.28	66.8	22.3
DeepLabv3+	98.17	99.59	99.45	99.31	54.7	20.5
SA-UNet	99.36	99.81	99.82	99.97	41.2	30.2

图 11 展示了不同模型在 4 类典型电缆图像上的分割可视化结果, 其中虚线轮廓为标签边界, 实线轮廓为预测边界。示例图像涵盖多种光照条件, 包含了多种电缆类型, 便于对各语义分割模型的实验结果进行直观比较。

在特征清晰、对比度较高的区域, 各模型均能取得较为准确的分割结果, 整体表现差异较小。然而, 当图像出现光照不均、边界模糊或包含细小锐角结构时, 模型间的性能差异显著扩大。尤其是在导体绞线与绝缘层交界的低对比度区域, UNet++ 和 DeepLabv3+ 预测边界普遍出现偏移、局部断裂或对轮廓细节拟合不足, 表明这些模型对外观变化和局部噪声较为敏感。

相比之下, SA-UNet 在所有测试场景中均表现出更高的边界贴合度和稳定性, 能够较好地保持目标结构的完整性与连续性。其在复杂区域的优势主要体现在对弱边缘的保持能力及对细粒度结构的精确识别, 验证了引

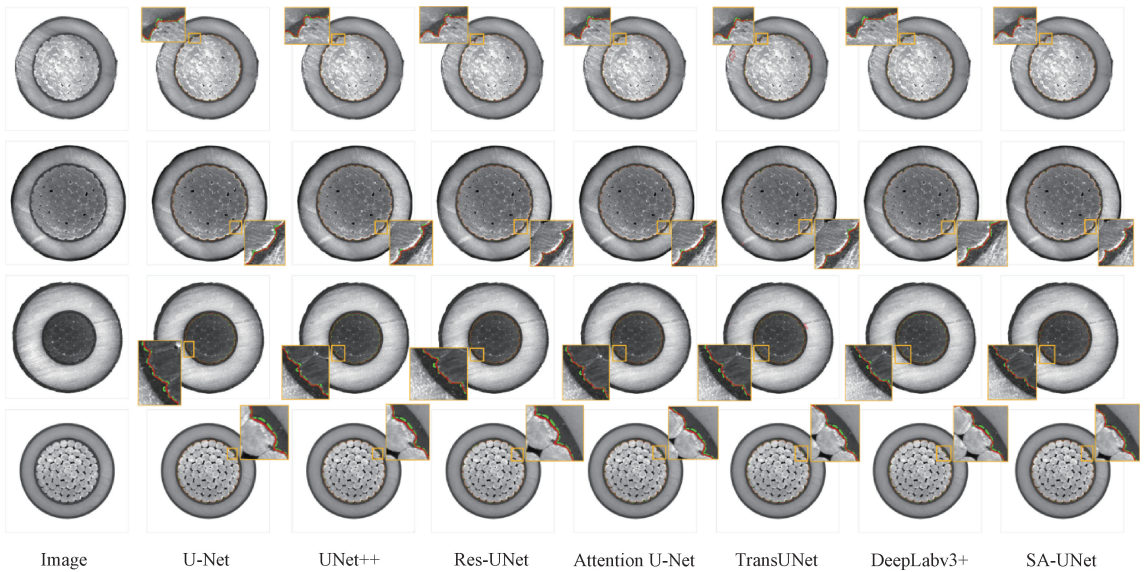


图 11 使用不同模型进行分割的可视化结果

Fig. 11 Visualization results of segmentation using different algorithms

人的注意力机制与多尺度特征融合策略在电缆图像分割任务中的有效性。

2) 消融实验

为验证 SA-UNet 中各改进模块的有效性,进行了消融实验,其结果如表 3 所示。表 3 中“√”表示启用相应模块,包括 RMP 和 SAFF。

表 3 消融实验结果

Table 3 Results of ablation experiments

模型名称	骨干网络	RMP	SAFF	IoU/%	Recall/%	Dice/%	Precision/%	参数量/M	响应时间/ms
U-Net	VGG16			98.45	99.57	99.02	98.48	31.0	25.1
B	MSAF			99.02	99.63	99.77	99.71	35.8	28.7
C	MSAF	√		99.27	99.76	99.76	99.86	35.9	28.5
SA-UNet	MSAF	√	√	99.36	99.81	99.82	99.97	41.2	30.2

以 VGG16 为骨干网络的 U-Net 作为基线模型(模型 A),其初始性能 IoU 为 98.45%、Recall 为 99.57%、Dice 系数为 99.02% 和 Precision 为 98.48%。在此基础上,将骨干网络替换为 MSAF(模型 B)后,各项指标均显著提升,尤其是 Precision 有大幅度提高,表明 MSAF 通过多分支扩张卷积与空间注意力机制的协同作用,能够更有效地聚焦真实边界并抑制背景干扰,构成性能提升的核心基础。

在模型 C 中进一步引入 RMP 模块后,尽管参数量略有增加,但 IoU 提升 0.25%,Recall 提升 0.13%,Precision 提升 0.17%。该结果说明 RMP 在增强多尺度上下文建模能力方面具有显著效果,有助于进一步强化特征表达。

最终,在同时引入 RMP 与 SAFF 的完整 SA-UNet 中(模型 D),各项性能指标均达到最高:IoU 为 99.36%,Recall 为 99.81%,Dice 为 99.82%,Precision 为 99.97%。

这表明各模块在边界细化方面均发挥了作用,其组合能够有效提升模型整体性能。

3.5 Pix2Pix GAN 模型性能评估实验

为验证 Pix2Pix GAN 在处理边界模糊问题上的有效性,从定性和定量两个维度评估了其图像重建性能。

从定性角度分析,图 12 展示了模型对不同电缆样本 ROI 的增强效果。如图 12 所示,模型成功地将原始 ROI 中对比度低、边界模糊的绝缘层(包括导体屏蔽层、主绝缘层与绝缘屏蔽层),转化为边界清晰锐利、内部区域均匀的高对比度图像。这种转换消除了因材料特性和光照不均引入的视觉模糊,为后续的几何测量算法创造了理想测量条件。

从定量角度评估,在整个测试集上计算了生成图像与理想化目标图像之间的 PSNR 和 SSIM 指标。实验结果表明,生成图像的平均 PSNR 达到 30 dB,平均 SSIM 超




图 12 Pix2Pix GAN 的可视化结果

Fig. 12 Visualization results of Pix2Pix GAN

过 0.98。高 PSNR 值证明了生成图像在像素级别上与目标图像高度保真,而接近 1 的 SSIM 值则表明生成图像在结构信息、亮度和对比度等感知维度上与目标图像高度相似,有效避免了结构扭曲或伪影的产生。

综上所述, Pix2Pix GAN 模块不仅显著提升了图像的视觉质量,更重要的是,它通过生成具有明确几何边界的标准化图像,为后续的精确定厚测量提供了稳定可靠的输入,是整个系统实现高精度测量的关键环节。

3.6 基于 SA-UNet 和 Pix2Pix GAN 的绝缘层参数测量

为评估提出的“SA-UNet + Pix2Pix GAN”算法的测量精度,本节将测量结果与高精度基准值进行对比,并参照国家标准对精度水平进行评价。

根据标准 GB/T 2951.11—2008 的规定,绝缘层厚度的读数应测量到小数点后两位(以 mm 计)^[38],这为本方法的精度评估提供了明确的工业基准。

基于 Python 编程实现了绝缘层厚度计算。从 3 300 张图像中随机选取 100 张进行厚度测量,得到相应的厚度测量值。通过将自动化测量结果与基准值进行比较,对系统的测量误差进行了统计分析,结果如图 13 所示。

实验结果表明,本测量系统的平均绝对误差(mean absolute error, MAE)为 0.01 mm,最大绝对误差未超过 0.02 mm。从图 13(b)的绝对误差分布直方图中可以看出,超过 90% 的样本测量误差集中在 0.015 mm 以内,表

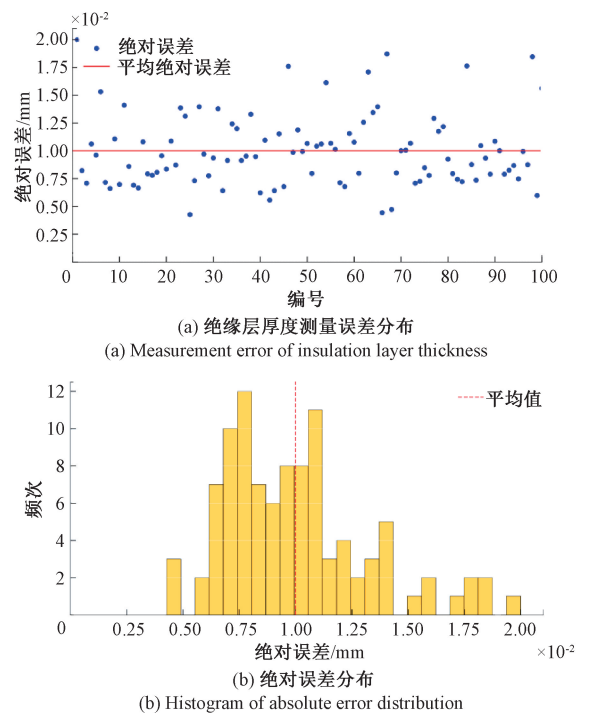


图 13 绝缘结构厚度计算结果

Fig. 13 Insulation system thickness calculation results

明该系统不仅精度高,而且在处理不同样本时表现出良好的一致性与稳定性。

综上所述,本方法实现的 0.01 mm 的平均绝对误差满足国家标准要求。与传统依赖人工、耗时较长的测量方式相比,本方法在保证微米级测量精度的前提下,实现了全自动化处理。

4 结 论

针对高压电缆绝缘层厚度人工测量效率低下、传统方法在边界模糊和低对比度条件下精度低的问题,提出了一种融合 SA-UNet 语义分割网络与 Pix2Pix GAN 图像重建网络的两阶段深度学习框架,利用自动化图像分析替代传统方法中物理切片制备与手动测量环节,本方法在保证高精度的同时,提升了检测效率。

所提出的 SA-UNet 通过引入多尺度特征提取与注意力机制,有效提升了细粒度特征表达能力,在绝缘结构分割任务中显著优于主流语义分割模型。针对分割后 ROI 图像中层间边界模糊的问题, Pix2Pix GAN 进行图像重建,有效增强了边界对比度与清晰度。定量评估显示,生成图像具有高的 PSNR (>30 dB) 和 SSIM (>0.98),为后续几何测量提供了高质量输入。基于重建后的清晰图像,结合射线交点法实现了绝缘层厚度的精确计算。最终实现平均绝对测量误差仅 0.01 mm 的厚度计算精度,验证了所提出的测量装置与两阶段策略的有效性。

实验表明,提出的方法能有效克服真实工业图像中边界模糊、对比度低等不利因素,实现了对高压电缆绝缘层厚度的高精度测量,具有良好的鲁棒性与稳定性。未来的工作将侧重于模型的轻量化设计,通过引入网络剪枝、知识蒸馏等技术,在保持高精度的同时降低模型复杂度和计算开销,以推动其在计算资源受限的工业现场或边缘设备上的部署与应用。

参考文献

[1] 杜伯学,李忠磊,杨卓然,等. 高压直流交联聚乙烯电缆应用与研究进展[J]. 高电压技术, 2017, 43(2): 344-354.
DU B X, LI ZH L, YANG ZH R, et al. Application and research progress of HVDC XLPE cables [J]. High Voltage Engineering, 2017, 43(2): 344-354.

[2] 李进,赵仁勇,杜伯学,等. 电工环氧绝缘件缺陷无损检测方法研究进展[J]. 电工技术学报, 2021, 36(21): 4598-4607.
LI J, ZHAO R Y, DU B X, et al. Research progress of nondestructive detection methods for defects of electrical epoxy insulators [J]. Transactions of China Electrotechnical Society, 2021, 36(21): 4598-4607.

[3] GUO D M, LI Q, LIU P, et al. Power shortage and firm performance: Evidence from a Chinese city power shortage

index[J]. Energy Economics, 2023, 119: 106593.

[4] 魏艳慧,郑元浩,龙海泳,等. 绝缘层厚度对高压直流电缆电场和温度场分布的影响[J]. 电工技术学报, 2022, 37(15): 3932-3940.
WEI Y H, ZHENG Y H, LONG H Y, et al. Influence of insulation layer thickness on electric field and temperature field of HVDC cable[J]. Transactions of China Electrotechnical Society, 2022, 37(15): 3932-3940.

[5] 叶刚,姚星辰,李涛,等. XLPE 电缆绝缘老化的时频域介电特性[J]. 高电压技术, 2018, 44(11): 3713-3719.
YE G, YAO X CH, LI T, et al. Time/frequency domain dielectric characteristics of XLPE cable insulation aging[J]. High Voltage Engineering, 2018, 44(11): 3713-3719.

[6] AUCLAND D W, MCGRAIL A J. Application of ultrasound to the inspection of insulation [J]. IEE Proceedings-Science, Measurement and Technology, 1996, 143(3): 177-181.

[7] ZHANG J, HUANG F Y, LIU S W, et al. X-ray image processing method for buffer layer defect in high voltage cable[J]. Journal of Physics: Conference Series, 2021, 1792(1): 012046.

[8] LENTY B, KWIEK P, SIOMA A. Quality control automation of electric cables using machine vision[C]. Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments, 2018: 2501562.

[9] WEI ZH H, LI B R, XIA B ZH, et al. A method for visual recognition and length measurement of complex multi-branch cables[J]. Measurement, 2025, 244: 116456.

[10] 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): 111-115.
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): 111-115.

[11] 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.

- [12] XIE H, LIU G H, DENG L, et al. Measurement of outer diameter parameters of manual grinding cable joints based on 3D point cloud processing[J]. *Measurement*, 2024, 236: 115095.
- [13] LIU S Y, ZHANG F Q, ZHAO P, et al. Morel (*Morchella* spp.) target recognition and size measurement based on machine vision [J]. *Computers and Electronics in Agriculture*, 2025, 229: 109823.
- [14] RAHMAN A, STREET J, WOOTEN J, et al. MoistNet: Machine vision-based deep learning models for wood chip moisture content measurement[J]. *Expert Systems with Applications*, 2025, 259: 125363.
- [15] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [16] 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, 12(9): 2085.
- [17] 赵恩玄, 何云勇, 沈宽, 等. 基于深度学习的铸件 CT 图像分割算法 [J]. *仪器仪表学报*, 2023, 44 (11): 176-184.
ZHAO EN X, HE Y Y, SHEN K, et al. Casting CT image segmentation algorithm based on deep learning[J]. *Chinese Journal of Scientific Instrument*, 2023, 44 (11): 176-184.
- [18] 陈研, 倪松, 马天宇, 等. 在役高压电缆缓冲层缺陷检测 [J]. *仪器仪表学报*, 2023, 44(4): 82-90.
CHEN Y, NI S, MA T Y, et al. Detection of buffer layer defects of in-service high-voltage cables [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(4): 82-90.
- [19] ROY S S, PARAMANE A, SINGH J, et al. Characterization and identification of electrical tree growth stages inside high-voltage cable insulation [J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3295017.
- [20] 王晓康, 丁雷, 何嘉斌, 等. 基于深度学习融合证据理论的电缆接头故障检测方法研究 [J]. *绝缘材料*, 2025, 58 (3): 125-130.
WANG X K, DING L, HE J B, et al. Research on cable joint fault detecting method based on deep learning fusion evidence theory [J]. *Insulating Materials*, 2025, 58(3): 125-130.
- [21] 侯北平, 李丰余, 朱文, 等. 基于改进 U-Net 的高压电缆绝缘层图像分割研究 [J]. *电子测量与仪器学报*, 2023, 37(10): 232-243.
HOU B P, LI F Y, ZHU W, et al. Research on image segmentation of high-voltage cables insulation layer based on improved U-Net [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(10): 232-243.
- [22] ISOLA P, ZHU J Y, ZHOU T H, et al. Image-to-image translation with conditional adversarial networks [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 5967-5976.
- [23] NETO L C, RAMALHO G L B, ROCHA NETO J F S, et al. An unsupervised coarse-to-fine algorithm for blood vessel segmentation in fundus images [J]. *Expert Systems with Applications*, 2017, 78: 182-192.
- [24] DING Y, ZHANG CH, CAO M SH, et al. ToStaGAN: An end-to-end two-stage generative adversarial network for brain tumor segmentation [J]. *Neurocomputing*, 2021, 462: 141-153.
- [25] SU Y T, YAN P, YI R ZH, et al. A cascaded combination method for defect detection of metal gear end-face [J]. *Journal of Manufacturing Systems*, 2022, 63: 439-453.
- [26] PENG X, ZHOU K, DUAN B X, et al. A fast and simplified crack width quantification method via deep Q learning [J]. *Smart Structures and Systems*, 2023, 32(4): 219-233.
- [27] SONG Q S, YAO W, TIAN H J, et al. Two-stage framework with improved U-Net based on self-supervised contrastive learning for pavement crack segmentation [J]. *Expert Systems with Applications*, 2024, 238: 122406.
- [28] ZHAO H SH, SHI J P, QI X J, et al. Pyramid scene parsing network [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6230-6239.
- [29] KRICHEN M. Generative adversarial networks [C]. 2023 14th International Conference on Computing Communication and Networking Technologies, 2023: 1-7.
- [30] SUN J ZH, DU Y, LI C Y, et al. Pix2Pix generative adversarial network for low dose myocardial perfusion SPECT denoising [J]. *Quantitative Imaging in Medicine and Surgery*, 2022, 12(7): 3539-3555.
- [31] ZHANG ZH Y. A flexible new technique for camera calibration [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(11): 1330-1334.
- [32] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]. International Conference on Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015, 2015: 234-241.
- [33] ZHOU Z W, SIDDIQUEE M R, TAJBAKSH N, et al. UNet++: A nested U-Net architecture for medical image

- segmentation [C]. Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, 2018: 3-11.
- [34] LIAN SH, LI L, LIAN G R, et al. A global and local enhanced residual U-Net for accurate retinal vessel segmentation [J]. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 2021, 18(3): 852-862.
- [35] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-Net: Learning where to look for the pancreas[J]. ArXiv preprint arXiv:1804.03999, 2018.
- [36] CHEN J N, LU Y Y, YU Q H, et al. TransUNet: Transformers make strong encoders for medical image segmentation [J]. ArXiv preprint arXiv:2102.04306, 2021.
- [37] CHEN L C, ZHU Y K, PAPANDEOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]. Computer Vision-ECCV 2018, 2018: 833-851.
- [38] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. GB/T 2951.11—2008 电缆和光缆绝缘和护套材料通用试验方法 第11部分:通用试验方法——厚度和外形尺寸测量——机械性能试验[S]. 北京: 中国标准出版社, 2008.
- General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic

of China. GB/T 2951.11—2008 General test methods for insulation and sheathing materials of electric and optical cables-Part 11: General test methods-Measurement of thickness and overall dimensions-Mechanical tests [S]. Beijing: Standards Press of China, 2008.

作者简介



邱文俊, 2022年于绍兴文理学院获得学士学位, 现为浙江科技大学硕士研究生, 主要研究方向为机器视觉与深度学习。

E-mail: wjqu@zust.edu.cn



Qiu Wenjun received his B.Sc. degree from Shaoxing University in 2022. He is currently a master's student at Zhejiang University of Science and Technology. His main research interests include machine vision and deep learning.

侯北平 (通信作者), 2005年于浙江大学获得博士学位。现为浙江科技大学自动化与电气工程学院教授、博士生导师, 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 currently a professor and Ph.D. advisor in the School of Automation and Electrical Engineering at Zhejiang University of Science and Technology. His main research interests include machine vision, pattern recognition, and image processing.