

DOI: 10.13382/j.jemi.B2104162

基于 CBAM-Res_UNet 电厂高压蒸汽泄漏检测研究*

彭道刚¹ 刘薇薇¹ 威尔江¹ 胡捷²

(1. 上海电力大学自动化工程学院 上海 200433; 2. 宝山钢铁股份有限公司能源环保部电厂 上海 201900)

摘要: 发电厂高压蒸汽泄漏检测关乎电厂设备长期稳定运行。为了提高电厂高压蒸汽泄漏检测的准确性,解决泄漏区域的错分割和漏分割问题,提出基于 CBAM-Res_UNet 图像分割网络的电厂高压蒸汽泄漏检测算法,在 UNet 结构中加入 ResNet 的残差块 residual_block 来获取泄漏图像更多的语义信息,并且融入 CBAM,加强高压蒸汽泄漏图像区域特征的学习,网络再根据不同损失函数和评价标准对图像分割结果的影响,选择损失函数 Focal Loss+Dice Loss 和性能指标 F1_score。通过在电厂高压蒸汽泄漏图像数据集上进行实验,CBAM-Res_UNet 网络得到的 F1_score 值为 0.985,实验结果表明,该网络可以更加完整的分割出蒸汽泄漏区域,对高压蒸汽泄漏图像多样性有较强的泛化能力。

关键词: 电厂高压蒸汽泄漏检测;CBAM-Res_UNet 图像分割网络;损失函数 Focal Loss+Dice Loss;性能指标 F1_score

中图分类号: TP391

文献标识码: A

国家标准学科分类代码: 520.2060

Research on leakage detection of high pressure steam in power plant based on CBAM-Res_Unet

Peng Daogang¹ Liu Weiwei¹ Qi Erjiang¹ Hu Jie²

(1. Faculty of Automation Engineering, Shanghai University of Electric Power, Shanghai 200433, China;

2. Power plant of Baoshan Iron & Steel Co., Ltd, Shanghai 201900, China)

Abstract: The detection of high pressure steam leakage in power plant is related to the long-term stable operation of power plant equipment. In order to improve the accuracy of high-pressure steam leakage detection in power plants and solve the problem of wrong segmentation and leakage segmentation of leakage areas, this paper proposes a high-pressure steam leakage detection algorithm based on CBAM-Res_UNet image segmentation network. The residual_block of ResNet is added to the UNet structure to obtain more semantic information of leakage images, and CBAM is integrated to strengthen the learning of regional characteristics of high-pressure steam leakage images. According to the influence of different loss functions and evaluation criteria on image segmentation results, the loss function Focal Loss+Dice Loss and performance index F1_score are selected. Through the experiment on the image data set of high-pressure steam leakage in power plant, the F1_score obtained by CBAM-Res_UNet network is 0.985. The experimental results show that the network can more completely segment the steam leakage area, and has a strong generalization ability for the variety of high pressure steam leakage images.

Keywords: detection of high pressure steam leakage in power plant; CBAM-Res_UNet image segmentation network; Loss function Focal Loss+Dice Loss; performance index F1_score

0 引言

发电厂管道因受环境、人为等因素的影响容易发生高压蒸汽泄漏,这不但会浪费资源,还会威胁现场工作人

员的生命安全。而发电厂设备长期稳定运行关乎整个电力系统供电的可持续性,所以快速准确识别出管道是否发生蒸汽泄漏具有重大的现实意义。

基于此,许多专家和学者做出了大量相关研究。气体泄漏检测基于硬件的方法通常是使用传感器或探测

器,但是该方法对泄漏的气体有较高要求,一般是针对刺激性气味的气体,焦洋等^[1]将六氟化硫作为测试气体,验证污染气体扫描成像红外被动遥测系统检测泄漏气体的可靠性;曾延安等^[2]基于 SF₆ 气体的光谱特性,利用便携式红外光谱成像的显示器实现对泄漏气体的识别和定位等,但是这些设备的成本居高,实际工程利用价值不大。基于传统的检测算法有任仲超^[3]根据气体泄漏点在红外图像中属于小目标的存在,单帧检测时提出了基于点源扩散的改进双边滤波算法提取泄漏点,而多帧检测时基于背景差分法检测出含有泄漏点的红外图像帧序列;但如 ViBe^[4]和 C 均值聚类方法 (PCM)^[5]等上述传统分割检测算法需要手动调整阈值,难以适应复杂多变的场景。随着深度学习的不断研究与应用,基于深度学习的图像分类缺陷检测^[6]和语义分割故障检测技术取得了重大的成果。2014 年 FCN 网络^[7]的首次提出拉开了基于深度学习像素级语义分割序幕,后续提出的 UNet^[8]和 Deeplabv 系列^[9-11]延续了 FCN 的思想。UNet 及其改进算法^[12-14]的网络结构是基于多尺度的,它们在生物医学、农林畜牧业、遥感导航和无人驾驶等应用上表现良好,也因此,该项技术在图像像素级语义分割领域备受欢迎。

但是目前尚未有将基于深度学习的语义分割技术应用于电厂高压蒸汽泄漏检测的实例,本文根据电厂高压蒸汽泄漏的特征和现场检测需求,针对原始 UNet 网络不能精确分割出电厂高压蒸汽泄漏区域的问题,结合残差学习模块 Residual Block^[15]和注意力机制模块 (convolutional block attention module, CBAM^[16]) 的特点,提出基于 CBAM-Res_UNet 的电厂高压蒸汽泄漏检测算法,主要包括 3 个方面:1) 在 UNet 特征提取网络中加入 ResNet^[15]的 Residual Block 结构和注意力机制模块;2) 通过数据增强的方法增加训练数据和验证数据的数量;3) 在改进模型的基础上,针对损失函数和性能指标对图像分割结果的影响,选择 Focal Loss^[17]+Dice Loss^[18]作为损失函数和 F1_score 作为性能指标。

1 高压蒸汽泄漏检测的网络结构

1.1 UNet 分割网络结构

UNet 网络结构特点是 U 型对称的,如图 1 所示,左边是收缩路径^[13],称为下采样过程,作用是提取高分辨率的特征信息,每一层经过两个 3×3 卷积和一个 2×2 的最大池化层,激活函数选择 ReLU,特征通道数经过 4 次下采样之后相应增加 4 倍;右边是扩张路径,也是上采样过程,作用是提取低分辨率的特征信息,每一次上采样先通过反卷积 ConvTranspose2D 使特征通道数缩小一半,然后通过复制和裁剪特征图大小,将收缩路径和扩张路径相同大小特征图进行基于通道的拼接,这是 UNet 针对

FCN 直接进行反卷积造成的特征信息丢失问题的改进,每一层上采样同样经过两个 3×3 卷积,最后一步经过 1×1×1 的卷积层,基于二分类问题选择激活函数 Sigmoid 输出两位的特征向量。图 1 中长方形是特征图,特征图上标表示特征通道数,中间拼接箭头上标表示特征图大小,特征图大小及其通道数变化如图所示。

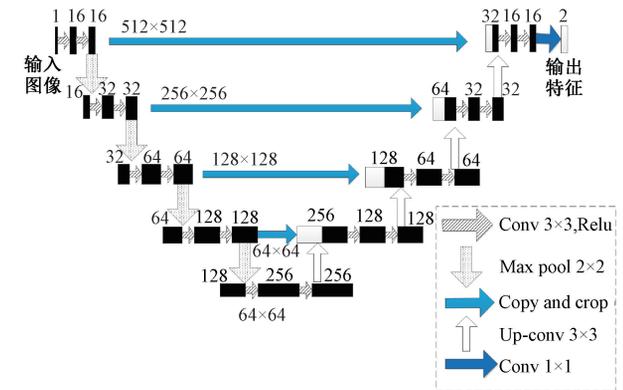


图 1 UNet 图像分割网络结构

Fig. 1 UNet image segmentation network structure diagram

1.2 改进的 UNet 网络结构

1) Res_UNet 网络结构

UNet 的收缩路径和 ResNet^[15]、VGG16^[19]、Inception^[20]等经典网络的结构相似,都是经过卷积层提取图像相应的特征。根据这一特性,在 UNet 两侧网络均加入 ResNet 结构 residual_block,形成新的网络结构 Res_UNet,这样不仅可以加深 UNet 特征提取网络的深度,提取到更多的蒸汽泄漏区域特征,还可以有效解决因网络深度加深而导致训练困难问题。

Res_UNet 的网络架构如图 2 所示,特征图大小和通道数设置和 UNet 网络相同,每次下采样应用两个 residual_block 模块,每个 residual_block 中包含两个卷积层,卷积核大小为 3×3,最开始卷积核个数为 16,步长设置为 1,基于 CNN^[21]的结构特点,采用 ReLU 为激活函数,为了使网络训练中每一个卷积层的输入都得到相同分布,对输入图像使用 BatchNormalization^[22]。

根据 UNet 的网络结构,同样为了获取更多的低分辨率语义信息,上采样过程中也采用了两个 residual_block,卷积层参数设置与下采样过程相同。因为网络深度的加深,不重要的网络参数也会相应增加,上采样和下采样过程使用 dropout 减少一些不必要的参数,从而减轻网络训练的负担,加快网络的训练速度。

2) 融入 CBAM

Res_UNet 网络结构虽然可以获取更多不同分辨率的高压蒸汽泄漏特征信息,然而没有考虑到不同像素类别、通道特征和上下文关联之间存在差异。Res_UNet 网络结构中包含基于通道的特征融合,不同的特征学习权重分配影响高压蒸汽泄漏区域分割效果,注意力机制模

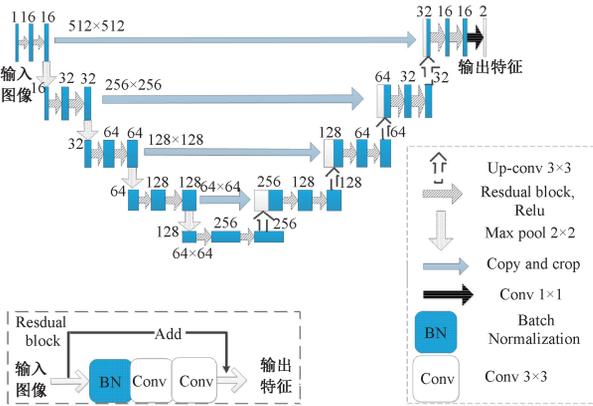


图 2 Res_UNet 结构示意图

Fig. 2 Res_UNet network structure diagram

块的运用使网络重点学习高压蒸汽泄漏区域的特征,减少背景区域学习的权重系数。所以 Res_UNet 网络进行跳跃连接之前,在每一个 residual_block 模块中加入注意力机制可以让网络对不同的特征添加不同的权重。

CBAM^[16]是基于卷积模块的注意力机制模块,与 SENet^[23]不同,CBAM 是同时结合了空间和通道的注意力机制模块。CBAM 的整体模块如图 3 所示。

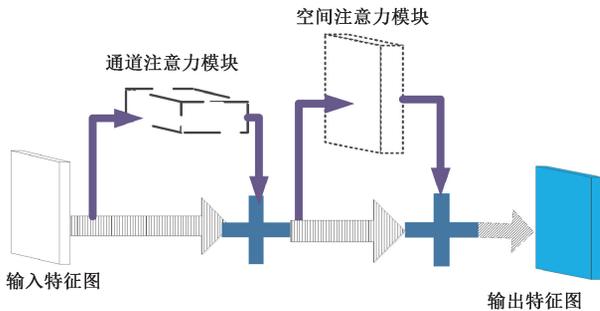


图 3 CBAM 结构示意图

Fig. 3 CBAM network structure diagram

CBAM 的通道注意力模块结构如图 4 所示,它在结构中采用了基于输入图像宽和高的全局平均池化 $AvgPool(F)$ 和最大池化 $MaxPool(F)$,通过多层感知器 MLP^[24] 的两个特征图进行基于像素的相加操作,最后经过激活函数 Sigmoid,生成该模块最终的特征图 $M_c(F)$; 它的数学计算如式(1)^[16]所示,其中 σ 代表 Sigmoid 函数。

$$M_c(F) = \sigma(MLP(MaxPool(F)) + MLP(AvgPool(F))) = \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \quad (1)$$

CBAM 的空间注意力模块注重特征图最具语义信息的部分,与通道注意力模块的作用相互补充,其结构如图 5 所示,它的输入特征图是通道注意力模块输出特征图与输入特征图进行基于元素的相乘操作,经过全局平均

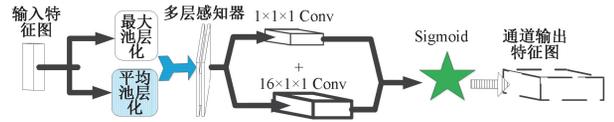


图 4 通道注意力模块结构示意图

Fig. 4 Schematic diagram of channel attention module structure

池化和最大值池化的特征图进行基于通道的相加操作,再通过卷积操作将通道数变为 1,最后经过激活函数 Sigmoid 生成该模块最终的特征图 $M_s(F)$,它的数学计算如式(2)^[16]。

$$M_s(F) = \sigma(f^{7 \times 7}([MaxPool(F); AvgPool(F)])) = \sigma(f^{7 \times 7}([F_{avg}^c; F_{max}^c])) \quad (2)$$

式中: σ 代表 Sigmoid 函数,卷积核的大小是 7x7。CBAM 的输出特征图需要将空间注意力模块的输出特征图与输入特征图做相乘运算。

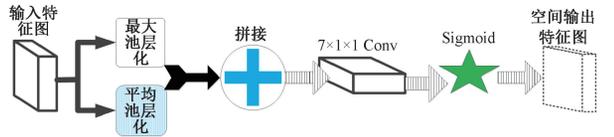


图 5 空间注意力模块结构示意图

Fig. 5 Schematic diagram of spatial attention module structure

1.3 系统总体网络结构及检测流程

综上所述,本文将以 UNet 网络为基础,在网络中加入 ResNet 的 residual_block 结构来获取有利于高压蒸汽泄漏检测的特征信息,为了适应因高压蒸汽泄漏速度快而不断变化的背景,同时融入 CBAM,重新给图像特征的不同等级像素分配适合的权重系数,形成新的网络结构如图 6 所示,将此网络 CBAM-Res_UNet 应用于电厂高压蒸汽泄漏的检测中,而本文整体算法体系如图 7 所示,最终图像分割结果通过电厂的软件平台反馈给工作人员。

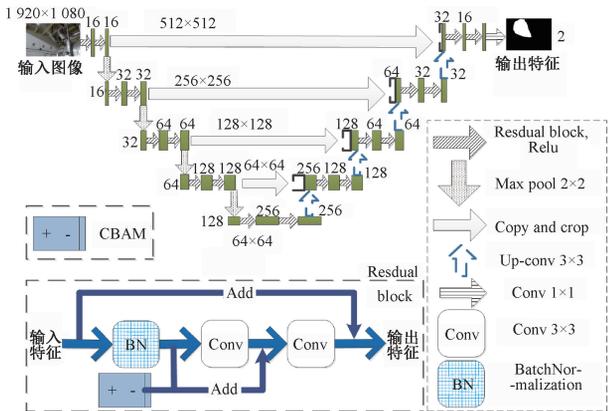


图 6 CBAM_Res_UNet 网络结构示意图

Fig. 6 CBAM_Res_UNet network structure diagram

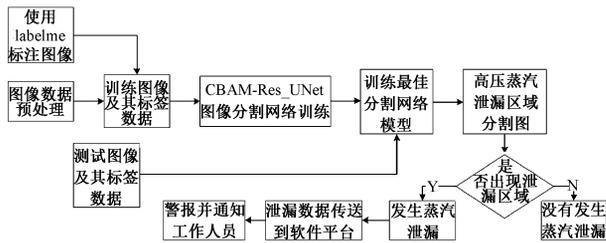


图 7 CBAM-Res_UNet 分割算法流程

Fig. 7 CBAM-Res_UNet segmentation algorithm flow chart

2 实验过程及结果分析

2.1 实验数据与预处理

因为目前还没有开源的电厂高压蒸汽泄漏语义分割数据集,并且实际电厂管道发生蒸汽泄漏的数据难以收集,所以没有直接可利用的图像数据集。而大多数蒸汽性质相差不大,具有透明、密度低于空气、形状不确定、边缘信息不明确、尺度变化快等性质。本文根据电厂进行高压蒸汽泄漏模拟实验来自建数据集,通过可见光视频拍摄,再将视频转化为有效的静态图片,从中随机抽取 50 张,每张图片的大小是 1 920×1 080,电厂高压蒸汽泄漏和正常情况如图 8 所示。

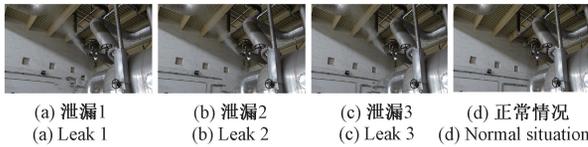


图 8 蒸汽泄漏图像

Fig. 8 Steam leak image

根据 UNet 网络对图像数据的要求,图像先进行统一灰度化,然后利用双线性插值原理将图像大小批量裁剪为 512×512。为了提高网络的分割效果,实验数据采用旋转、镜像、翻转、水平或垂直翻转等数据增强方法来增加数据样本数量为原来的 10 倍,这样可以保证网络两次看到的输入是不一样的,但它们是高度相关的,如图 9 所示,原图经过了水平翻转、向左旋转 40°和水平平移 0.2。最后通过交叉验证的方法 model_selection 随机将 60% 数据划分为训练集,20% 数据作为测试集,20% 数据作为验证集^[25]。本文使用 labelme 标记网络训练需要的标签数据,如图 10 所示,标签数据与图像数据相对应,根据实际场景中高压蒸汽泄漏扩散的特性,蒸汽泄漏面积在一定时间和一定压力的作用下迅速增大,标注泄漏的区域面积需要相应变大,所以不能按照原图的泄漏轮廓标注。

2.2 实验配置

本文的所有实验均采用 Adam^[26]一阶优化算法,学

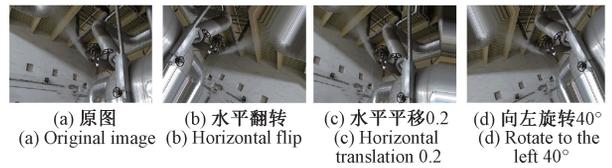


图 9 图像经数据增强变化

Fig. 9 The image is data-enhanced change map

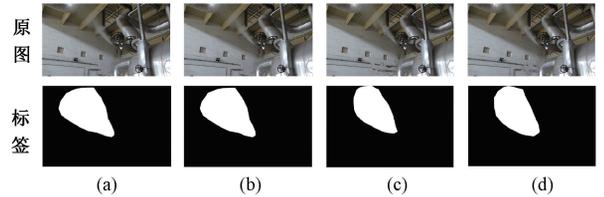


图 10 蒸汽泄漏图像及其对应标签

Fig. 10 Steam leak image and its corresponding label image

习速率是 0.000 02,其学习率衰减因子是根据计算梯度的一阶矩估计和二阶矩估计自适应得到的。根据实验室图形工作站的性能,将批量大小设置为 3,每个批量包含的样本数为 20,一共训练 400 次,总样本数为 50。实验环境配置如表 1 所示。

表 1 实验运行环境配置

Table 1 Experimental running environment configuration

实验环境	详细信息
硬件环境	处理器: Intteikuanel(R) Xeon® W-2123 CPU @ 3.60GHz; 显卡: NVIDIA Quadro P4000; 内存 RAM: 32GB
软件环境	开发环境: pycharm2019, Anaconda; 深度学习框架: keras, tensorflow; 编程语言: python3.6

2.3 损失函数与性能评价分析

1) 交叉熵损失函数

分割网络中损失函数的选取与图像分割结果有着密切的关系,图像分割主要使用交叉熵损失函数,交叉熵损失函数的权重更新速率与误差的大小成正比。它的损失函数的表达式如下所示:

$$L = -\frac{1}{N} \sum_{i=1}^N (y_i \log(\hat{y}_i) + (1 - \hat{y}_i) \log(1 - \hat{y}_i)) = -\frac{1}{N} \sum_{i=1}^N \begin{cases} \log(\hat{y}_i), & y_i = 1 \\ \log(1 - \hat{y}_i), & y_i = 0 \end{cases} \quad (3)$$

式中: N 是样本的数量; y_i 表示真实值; \hat{y}_i 表示预测值。

然而交叉熵损失函数先计算图像中单个像素的类别预测正确性,再计算预测所有像素正确性的平均值,因为高压蒸汽泄漏的图像特征不明显,图像中背景像素与泄漏像素相互交错,背景像素数量比泄漏像素多,模型可能

会无法充分学习到泄漏特征,最后只能通过背景预测概率来降低损失函数的值,出现损失函数的值可能不是全局最小值,网络训练模型没能达到预期效果。

2) Focal Loss 和 Dice Loss 损失函数

当图像分割训练正负样本处于不平衡的情况下,一般使用 Dice Loss^[18] 作损失函数,在网络训练过程中, Dice Loss 更注重对图像数据前景区域的挖掘,但是当蒸汽泄漏区域较小时,预测值出现局部错误就会导致 loss 值大幅度变动,它的梯度也会出现激烈震荡。

高压蒸汽泄漏检测的预测结果可以分为真阳性 TP、真阴性 TN、假阳性 FP、假阴性 FN。它们的含义如表 2 所示。

表 2 预测结果类型
Table 2 Forecast result type

	真实正样本	真实负样本
预测正样本	TP	FP
预测负样本	FN	TN

因为 Dice Loss 的训练过程容易出现不稳定,可能还会出现梯度饱和的问题,所以可以考虑将 Dice Loss 与其他损失函数相结合,这里使用 Dice Loss+Focal Loss^[27], Focal Loss 可以更好地学习像素分类不明确情况,它们相组合的数学计算如式(4)所示,因为它们的数量级不相同,需要分别对两者进行缩放。

$$TP_p(i) = \sum_{n=1}^N p_n(i) g_n(i) \quad (4)$$

$$FN_p(i) = \sum_{n=1}^N (1 - p_n(i)) g_n(i) \quad (5)$$

$$FP_p(i) = \sum_{n=1}^N p_n(i) (1 - g_n(i)) \quad (6)$$

$$L = L_{Dice} + \lambda L_{Focal} = i - \sum_{i=0}^{i-1} \frac{TP_p(i)}{TP_p(i) + \alpha FN_p(i) + \beta FP_p(i)} - \lambda \frac{1}{N} \sum_{i=0}^{i-1} \sum_{n=1}^N g_n(i) (1 - p_n(i))^2 \log(p_n(i)) \quad (7)$$

式中: $TP_p(i)$ 表示类别 i 的真阳性; $FN_p(i)$ 表示类别 i 的假阴性; $FP_p(i)$ 表示类别 i 的假阳性; $p_n(i)$ 表示对类别 i 的预测值; $g_n(i)$ 表示类别 i 的真实值; i 表示包括背景的种类数,这里的数值为 2; λ 表示 Dice Loss 与 Focal Loss 之间的权重取舍; α 和 β 分别是假阴性和假阳性的惩罚值,因为假阴性和假阳性对蒸汽泄漏检测同样重要,所以通常设置为 0.5; N 表示图像的所有像素值。

3) 性能评价标准

目前经常应用于图像分割的评价标准有精度 Accuracy、准确率 Precision、召回率 Recall 和 F1 score 等, F1_score 包括准确率和召回率。其中精度的计算方法如式(8)所示,取值范围是 0~1,取值为 1 说明网络性能是最佳的,准确率是对前景和背景分割精度整体上的评价,当真阴性 TN 的数值很高时, Accuracy 数值也会很高,而高压蒸汽泄漏检测需要重点关注图像泄漏区域的分割精

度,也就是只需要提高真阳性 TP 的数值。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

而准确率 Precision 可以细化精度的衡量,是网络的分割结果图中前景被正确分割出来的比例,其取值范围也是 0~1,越接近 1 说明网络的分割能力越好,如下所示:

$$P = \frac{TP}{TP + FP} \quad (9)$$

式中: TP 表示真阳性; FP 表示假阳性。

召回率 Recall 是网络分割正确的前景占有所有前景比例,其取值范围是 0~1,它的值越接近 1 说明网络的分割能力越好,如式(10)所示,其中 TP 是真阳性, FN 是假阴性。

$$R = \frac{TP}{TP + FN} \quad (10)$$

然而召回率和准确率是相互矛盾的,这两个指标是成反比例关系,但是蒸汽泄漏检测的性能指标需要获得两者的最高值,所以需要有一个指标来综合两者之间的矛盾。F Score 是通过准确率 F 和召回率 R 加权调和平均实现的,如式(11)所示,当参数 $\alpha = 1$ 时就是 F1_Score, F1_Score 的值越大说明网络的分割结果越好。

$$F = \frac{(\alpha^2 + 1) \cdot P \cdot R}{\alpha^2 \cdot (P + R)} \quad (11)$$

2.4 实验结果对比与分析

1) 不同网络的对比结果分析

为了验证 CBAM-Res_UNet 网络检测电厂高压蒸汽泄漏的有效性,根据控制变量法,在使用相同损失函数 Dice Loss+Focal Loss 和评价标准 F1_score 条件下对比分析不同模型的分割效果。如图 11 所示,选择 3 张不同时间的高压蒸汽泄漏图像,图 11(A) 测试图像,图 11(B) 是与测试图像对应的标签图,图 11(C)~(F) 依次是此次实验的 4 种网络模型分割效果图,包括 UNet 网络、融合 residual_block 的 Res_UNet 网络、加入 CBAM 的 UNet 网络以及加入 CBAM 和 residual_block 的 CBAM-Res_UNet 网络。由于电厂管道泄漏蒸汽的密度低于空气,而且它们的可见度不高、形状不确定以及停留在固定区域的时间较短,前 3 种模型的泛化能力不足,都不能很好地适应电厂高压泄漏蒸汽的多样变化,最终导致检测结果出现将管道、墙体等背景误以为是蒸汽、过度分割泄漏区域、分割界线模糊等问题。根据前文分析, CBAM 模块可以去除一些不重要特征信息对网络的干扰,加强网络对蒸汽泄漏特征信息的学习,减少一些多余特征通道的计算量,而 ResNet 结构特点是减少蒸汽泄漏特征信息的丢失,结合实验分割结果图和标签图的对比效果,虽然原始 UNet 网络可以分割出部分高压蒸汽泄漏区域,但是边缘

细节处理不够好,加入 CBAM 注意力机制模块的网络分割效果明显优于原始 UNet 网络,而传统 UNet 网络分割效果明显不如加入 residual_block 的 Res_UNet 网络,CBAM-Res_UNet 的整体分割效果是最佳的。综上所述,CBAM-Res_UNet 网络更能辨别有蒸汽泄漏区域和相似蒸汽泄漏区域,UNet 引入 residual_block 结构并加入 CBAM 模块可以提取更多的泄漏细节信息和较为完整的分割出发生泄漏区域。虽然结果也存在分割像素出错问题,但检测错误的像素数量相对变少。

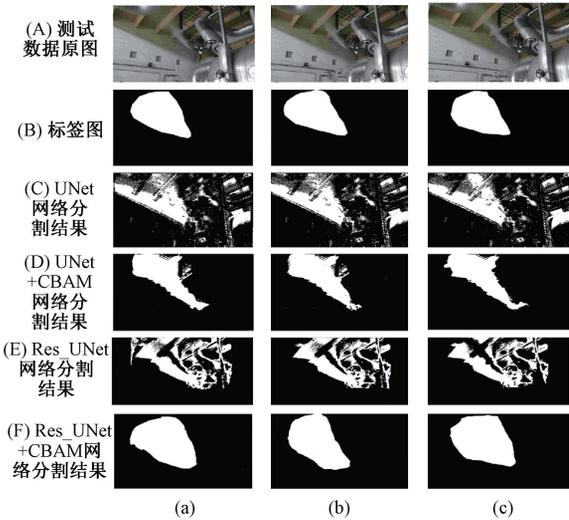


图 11 不同网络模型的蒸汽泄漏检测结果
Fig. 11 Diagrams of steam leak detection results of different network models

初始 UNet 模型、加入 residual_block 的 Res_UNet 模型、融合 CBAM 的 UNet 模型和 CBAM-Res_UNet 模型检测高压蒸汽泄漏的性能量化结果如图 12 所示,与初始 UNet 模型相比,虽然 Res_UNet 模型和 CBAM-UNet 模型的 F1_score 值有相应增加,但是 CBAM-Res_UNet 模型的 F1_score 值增加了 0.179,最接近 1。这里充分体现了 ResNet 的 Residual_block 模块、CBAM 与分割网络 UNet 相结合的优势。

2) 不同损失函数的对比结果分析

因为损失函数的选择可以影响模型训练和最后预测结果,根据分析,对比 3 个损失函数分割结果。如图 13 所示,根据之前的效果分析,实验统一使用 CBAM-Res_UNet 网络结构,只改变其损失函数,图 13(B)是使用交叉熵损失函数,图 13(C)是使用 Dice Loss 损失函数,图 13(D)使用 Focal Loss+Dice Loss 损失函数。从图 13 可以看出,使用相同的网络结构,不同损失函数会出现不同的分割结果,使用交叉熵损失函数的分割精度不佳,分割错误的像素数目居多,也是其中效果最差的;虽然使用 Dice Loss 的分割效果相对改进了很多,但是网络训练过

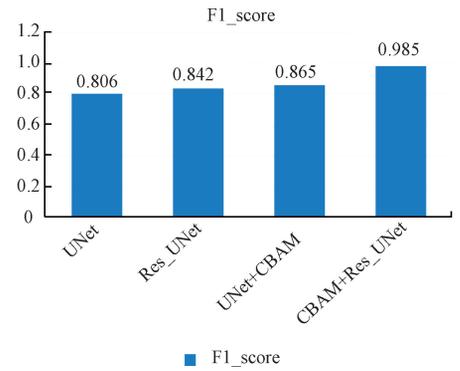


图 12 不同网络模型的分割性能得分图
Fig. 12 Segmentation performance score graph of different network models

程不稳定,分割结果也出现较多背景误认为前景的情况,这对蒸汽泄漏检测来说是非常不利的。高压泄漏蒸汽具有非刚性目标空间形态,容易出现对损失函数贡献较小的小部分泄漏区域,导致训练优化过程出现不平稳,这也是本文选择 Focal Loss+Dice Loss 作为损失函数的原因之一。加入 Focal Loss 可以让网络模型在训练过程中更加注重对界线模糊的泄漏区域学习,所以模型选择使用损失函数 Focal Loss+Dice Loss 解决高压蒸汽泄漏边缘模糊和小尺度蒸汽泄漏等问题。

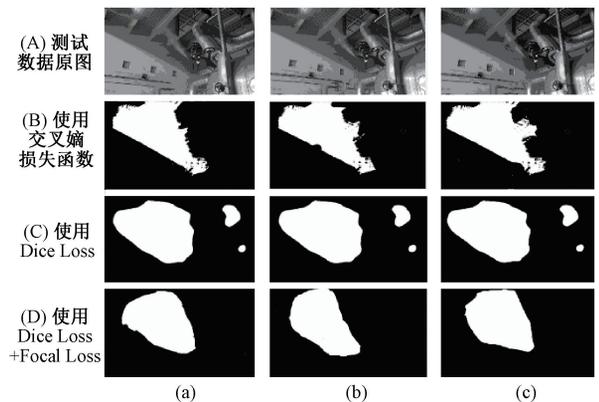


图 13 不同损失函数的蒸汽泄漏检测结果
Fig. 13 Diagram of steam leak detection results with different loss functions

3) 不同性能指标的对比结果分析

CBAM-Res_UNet 网络的训练曲线在训练集和验证集上是相对平滑的,它的 F1_score 训练过程变化曲线和最终值说明网络解决了准确率和查全率之间的平衡问题,有一定的现实利用价值。如图 14 所示,模型 CBAM-Res_UNet 分别使用 Accuracy 和 F1_score 作为性能指标,在相同网络模型和损失函数的条件下,如果选择 Accuracy 作为性能指标,因为高压蒸汽泄漏区域较小,它

没有重点关注蒸汽泄漏区域分割的精度,且 CBAM-Res_UNet 网络将泄漏区域误分割为非泄漏区域时,Accuracy 值是增加的,所以这不是高压蒸汽泄漏分割网络需要的性能指标,而 F1_score 中的精确度是针对高压蒸汽泄漏区域分割的准确性,查全率注重分割出完整的蒸汽泄漏区域,当 CBAM-Res_UNet 网络的 F1_score 值接近 1 时,说明这个网络的分割效果越好,网络的测试效果图也越接近于图像对应的标签图。

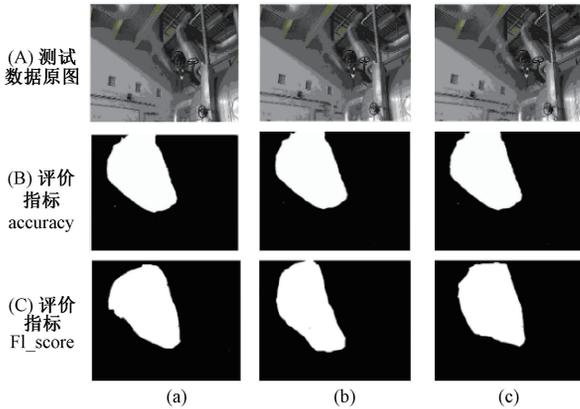


图 14 不同评价标准的蒸汽泄漏检测结果

Fig. 14 Diagram of steam leak detection results of different evaluation standards

3 结 论

本文基于 UNet 网络,将改进的网络结构 CBAM-Res_UNet 应用于电厂高压蒸汽泄漏检测。该网络依据 ResNet 的结构特点,在 UNet 的上采样和下采样过程中分别加入 residual_block 结构,以便于获取图像更多的高压蒸汽泄漏特征细节,融入 CBAM 使网络训练时增强对蒸汽泄漏区域的关注度,弱化背景区域的学习力度;根据高压蒸汽泄漏特征和 CBAM-Res_UNet 网络使用不同损失函数的分割效果,最终选择 Focal Loss+Dice Loss 作为损失函数来进一步提高模型对高压蒸汽泄漏检测精确度。与原始 UNet 网络相比,CBAM-Res_UNet 网络可以更加准确地分割出蒸汽泄漏区域,在 F1_score 评价标准上也有较好的表现,CBAM-Res_UNet 网络具有良好的整体场景理解能力和泄漏检测细节处理能力,有一定的实际工程应用价值。由于本文所用的数据没有包含电厂高压蒸汽泄漏的红外图像,所以未来还要利用高压蒸汽的温度特征,通过红外和可见光相结合的方式提升检测效果,进一步提升电厂高压蒸汽泄漏检测的效果。

参考文献

[1] 焦洋,徐亮,高闯光,等. 污染气体扫描成像红外被动遥测系统实时数据处理研究[J]. 物理学报,2013,62(14):124-130.

JIAO Y, XU L, GAO M G, et al. Real-time data processing of remote measurement of air pollution by infrared passive scanning imaging system [J]. Acta Physica Sinica, 2013, 62(14): 124-130.

[2] 曾延安,张超,元秀华,等. 便携式 SF₆ 气体红外光谱成像检漏仪[J]. 仪表技术与传感器, 2015(10): 23-26.

ZENG Y AN, ZHANG CH, YUAN X H, et al. Portable infrared spectral imaging leakage detector for SF₆ gas [J]. Instrument Technique and Sensor, 2015(10): 23-26.

[3] 任仲超. 基于红外图像帧序列分析气体泄漏检测方法研究[D]. 秦皇岛:燕山大学,2018.

REN ZH CH. Based on infrared image frame sequence analysis of gas leak detection method [D]. Qinhuangdao: Yanshan University, 2018.

[4] BARNICH O, VAN DROOGENBROECK M. ViBe: a universal background subtraction algorithm for video sequences [J]. IEEE transactions on image processing: A publication of the IEEE Signal Processing Society, 2011, 20(6): 1709-1724.

[5] 黄化入,谢维成,张彼德,等. 基于改进 PCM 聚类方法的绝缘子图像分割[J]. 电子测量与仪器学报, 2020, 34(12): 181-189.

HUANG H R, XIE W CH, ZHANG B D, et al. Segmentation method of insulator disk based on improved PCM [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(12): 181-189.

[6] 伊欣同,单亚峰. 基于改进 Faster R-CNN 的光伏电池内部缺陷检测[J]. 电子测量与仪器学报, 2021, 35(1): 40-47.

YI X T, SHAN Y F. Photovoltaic cell internal defect detection based on improved Faster R-CNN [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(1): 40-47.

[7] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4): 640-651.

[8] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]. International Conference on Medical Image Computing & Computer-assisted Intervention, 2015.

[9] CHEN L, 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.

- [10] CHEN L, ZHU Y K, PAPANDREOU G, et al. Encoder decoder with atrous separable convolution for semantic image segmentation [C]. Computer Vision-ECCV 2018, 2018:833-851.
- [11] CHOLLET F. Xception: Deep learning with depth wise separable convolutions [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [12] ZHOU Z W, SIDDIQUEE M M R, TAJBAKHS N, et al. UNet++: Redesigning skip connections to exploit multiscale features in image segmentation [J]. IEEE Transactions on Medical Imaging, 2020, 39 (6): 1856-1867.
- [13] 柳小波, 张育维. 基于 U-Net 和 Res_UNet 模型的传送带矿石图像分割方法 [J]. 东北大学学报(自然科学版), 2019, 40(11): 1623-1629.
LIU X B, ZHANG Y W. Ore image segmentation method of conveyor belt based on U-Net and Res_UNet models [J]. Journal of Northeastern University (Natural Science), 2019, 40(11): 1623-1629.
- [14] 李梅梅, 胡春海, 龙平, 等. 基于 MultiRes+UNet 网络的车道线检测算法 [J]. 电子测量与仪器学报, 2020, 34(9): 117-122.
LI M M, HU CH H, LONG P, et al. Lane line detection algorithm based on MultiRes+UNet network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(9): 117-122.
- [15] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.
- [16] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. European Conference on Computer Vision, 2018.
- [17] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2018, 42(2): 318-327.
- [18] MILLETARI F, NAVAB N, AHMADI S A. V-Net: Fully convolutional neural networks for volumetric medical image segmentation [C]. Fourth International Conference on 3D Vision, 2016: 565-571.
- [19] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]. Third International Conference on Learning Representations (ICLR). Hilton San Diego: Computer Science, 2015: 1150-1210.
- [20] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [21] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks [C]. NIPS, Curran Associates Inc, 2012.
- [22] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [C]. International Conference on Machine Learning, ACM, 2015: 448-456.
- [23] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 42 (8): 2011-2023.
- [24] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep Learning [M]. Cambridge: The MIT Press, 2016.
- [25] 胡志伟, 杨华, 姜甜田, 等. 基于全卷积网络的生猪轮廓提取 [J]. 华南农业大学学报, 2018, 39(6): 111-119.
HU ZH W, YANG H, LOU T T, et al. Extraction of pig contour based on fully convolutional networks [J]. Journal of South China Agricultural University, 2018, 39(6): 111-119.
- [26] KINGMA D, BA J. Adam: A method for stochastic optimization [C]. Proceedings of the 3rd International Conference for Learning Representations, 2015: 15.
- [27] ZHU W T, HUANG Y F, ZENG L, et al. AnatomyNet: Deep learning for fast and fully automated whole-volume segmentation of head and neck anatomy [J]. Medical Physics, 2018, 46(2): 576-589.

作者简介



彭道刚, 2009 年于同济大学获博士学位。现为上海电力大学自动化工程学院教授, 主要研究方向为智能发电、综合智慧能源、电力巡检智能机器人、电力控制系统信息安全、电力设备状态监测与故障预警等。
E-mail: pengdaogang@126.com

Peng Daogang received his Ph. D. degree from Tongji University in 2009. He is currently a professor in the Faculty of Automation Engineering of Shanghai University of Electric Power. His main research interests include intelligent power generation, integrated intelligent energy, intelligent power inspection robots, power control system information security, power equipment status monitoring and fault warning, etc.



刘薇薇, 2015 年于广州航海学院获学士学位, 现为上海电力大学自动化工程学院硕士研究生, 主要研究方向为电力巡检智能机器人和图像识别。
E-mail: 583054812@qq.com

Liu Weiwei received her B. Sc. degree

from Guangzhou Maritime University in 2015. She is currently a M. Sc. candidate in the Faculty of Automation Engineering of Shanghai University of Electric Power. Her main research interests include intelligent power inspection robots and image identification.



戚尔江 (通信作者) 2018 年于上海电力大学获硕士学位, 现为上海电力大学自动化工程学院实验员, 主要研究方向为电力巡检智能机器人和嵌入式软件开发。

E-mail: 13818619785@163.com

Qi Erjiang (Corresponding author) received his M. Sc. degree from Shanghai University of Electric Power in 2018. He is currently an experimenter in the

Faculty of Automation Engineering of Shanghai University of Electric Power. His main research interests include intelligent power inspection robots and embedded software development.



胡捷, 硕士, 现为宝山钢铁股份有限公司能源环保部高级工程师, 主要研究方向为发电厂生产管理。

E-mail: hujie@baosteel.com

Hu Jie, M. Sc. degree, and he is currently a senior engineer of the Energy and Environmental Protection Department of Baoshan Iron and Steel Co., Ltd.. His main research interest includes power plant production management.