

DOI: 10.3969/j.issn.1009-9492.2024.04.028

魏希来, 孙海江, 刘培勋, 等. 一种改进的基于深度学习的小目标检测方法 [J]. 机电工程技术, 2024, 53 (04): 125-128.

一种改进的基于深度学习的小目标检测方法

魏希来, 孙海江^{*}, 刘培勋, 孙兴龙

(中国科学院 长春光学精密机械与物理研究所, 长春 130033)

摘要: 提出了一种改进的基于深度学习的小目标检测方法, 用于解决当前主流算法针对小目标进行检测时输入图像需为小尺寸照片且模型参数过多等缺点的问题。为了解决这些问题, 首先对图像进行预处理, 将一张较大尺寸的图像按一定规则拆分成多张小尺寸图像后送入网络, 克服了以往算法需要小尺寸图像才能进行检测的问题。对DNANet网络结构进行改进, 减少其网络层数, 提高了网络推断速度。使用TverskyLoss为像素分割的损失函数对损失函数进行优化, 并采用渐进式学习法训练模型, 使网络从普通目标到小目标的检测过程更为稳定。实验结果表明, 该方法有效提升了深度学习在小目标大尺寸图像方面的收敛速度, 改进后的网络对大尺寸图像的预测准确率提升了5%, 预测时间缩短了25%。综上所述, 提出的基于深度学习的小目标检测方法, 可以方便地应用于工程实践中, 并具有较高的实际应用价值。

关键词: 小目标检测; 深度学习; 图像预处理; 网络结构改进; 渐进式学习

中图分类号: TP391.4; TP18

文献标志码: A

文章编号: 1009-9492(2024)04-0125-04

An Improved Deep Learning-based Approach for Small Object Detection

Wei Xilai, Sun Haijiang, Liu Peixun, Sun Xinglong

(Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China)

Abstract: An improved deep learning-based method is presented for small object detection to address the limitations of current mainstream algorithms. These algorithms often require input images to be small-sized photos and suffer from excessive model parameters. To overcome these challenges, a preprocessing technique is proposed where a larger-sized image is divided into multiple smaller-sized images following specific rules. These fragmented images are then inputted into the network, eliminating the previous requirement of small-sized images for detection. The DNANet network structure is also enhanced by reducing its network layers, resulting in improved network inference speed. The loss function is optimized using TverskyLoss, a pixel segmentation loss function. Furthermore, a progressive learning approach is employed to train the model, ensuring a more stable transition from detecting ordinary to small objects. Experimental results demonstrate the effectiveness of the proposed method in enhancing the convergence speed of deep learning for small object detection in large-sized images. The improved network achieves a 5% increase in prediction accuracy for large-sized images and reduces prediction time by 25%. Consequently, the deep learning-based small object detection method presented in the study can be readily applied in engineering practice, offering significant practical value.

Key words: small object detection; deep learning; image preprocessing; network architecture improvement; progressive learning

0 引言

基于深度学习的目标检测问题是计算机视觉领域最基本和重要的一环。随着军事、工业和医疗等领域中红外成像技术的广泛应用, 提高小目标检测的精度和速度已成为计算机视觉和图像处理领域中的一个重要研究方向^[1-4]。

传统的小目标检测方法通常采用基于显著性目标的增强方法或基于传统滤波方式的背景抑制方法。Chen等^[5]在2014年提出了一种基于局部对比度策略的检测方法, 其原理是采用区域分块方法, 将图像分为中心目标区域与周围背景区域, 并利用两者比值来表征目标显著性, 以此实现高亮目标的增强与提取。一些学者在之后对该方法进行了更新^[6-8], 但该系列方案都对背景存在较

强的依赖性, 泛化能力一般。

目前常用的另一类方法是利用图像背景在空域、时域或频域上的特性, 对其进行建模后进行差分运算。对于所检测的图像, 背景通常在时域上具有不变性, 在空域上存在相关性, 在频域上则处于低频部分; 而目标则在时域上存在相对运动, 在空域上与背景无关, 在频域上处于高频部分。因此, 提出了基于背景与目标在时域差异的帧间差分法^[9]、基于背景与目标在空域差异的中值滤波算法^[10]以及基于背景与目标在频域差异的高通滤波算法^[11-12]。然而, 这些方法都高度依赖于图像本身的成像环境, 鲁棒性较差。而且这些方法的计算量也较大, 难以满足实时性的需求。

收稿日期: 2024-02-02

在传统的小目标检测方法中,通常需要使用手工设计的分类器进行分类。然而,在红外小目标检测中,这些方法往往会遇到以下几个问题:分类器难以设计;鲁棒性较差;实时性较差。因此,应当考虑使用基于深度学习的检测方案完成对小目标的检测。王昊然等^[13]提出的高阶融合模型,在PASCALVOC数据集上取得了良好的性能表现。林两魁等^[14]通过在检测任务中同时使用回归型和分类型网络,有效提升了检测性能。蒋昕昊等^[15]提出了一种轻量化实时检测网络模型YOLO-IDSTD用于小目标检测,在考虑精度和速度的同时,明显减少了计算量和参数量,并将模型尺寸压缩至7.27 MB,减少了对硬件平台运算能力的依赖。李博阳等^[16]设计了DNANet网络用于小目标检测,这有效地解决了深层神经网络中小目标易丢失的问题。通过反复融合和增强来整合和充分利用该模型,从而提高了目标的检出率。

本文在DNANet网络的基础上做出下面几个方面的改进,使其更适用于实际检测应用场景,并对修改结果进行了测试:(1)对输入图像进行预处理,将较大尺寸的图像拆分成多张小尺寸图像;(2)修改DNANet网络结构,减少网络层数并提升对图像的推断速度;(3)优化损失函数,使用TverskyLoss为像素分割的损失函数;(4)使用渐进式学习模式,使得网络的训练过程更为稳定。

1 改进的小目标检测方法网络结构

DNANet的结构主要包含3个部分:特征提取模块、特征金字塔融合模块和模型预测模块。红外小目标的尺寸不统一,其尺寸可能仅有数个像素,也可能有数十个像素。因此为避免在卷积过程中丢失小目标信息,网络结构不应过于追求深层次。DNANet采用了多个U型子网络进行紧密嵌套,以更好地避免信息丢失的问题。为了提高该网络的鲁棒性和训练速度,对其特征提取模块网络架构进行了修改和精简。修改后的特征提取模块架构如图1所示。

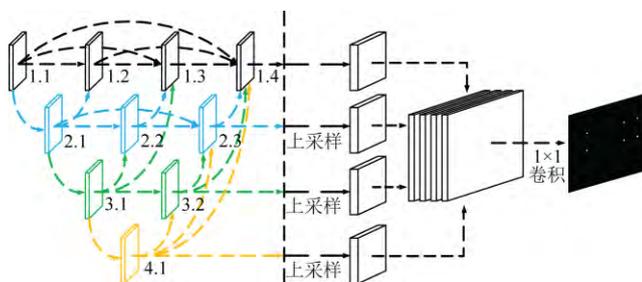


图1 修改后的特征提取模块架构

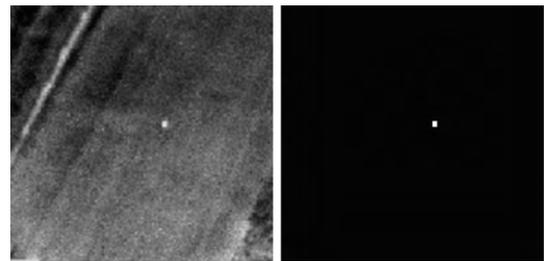
相较于原始的特征提取模块,本文对该模块架构的修改主要体现在两个方面:(1)减少了整体的网络层数。笔者在实践中发现,红外小目标图像在经过四次卷积及下采样后,原始图像中的目标与背景已趋于相同,因此选择裁剪掉网络的最后一层,以保持信息可以在每一层网络中均可存在,同时提高网络的计算速度;(2)为加

强不同特征层之间的联系,笔者额外引入了4层连接。这些新增的连接分别为:3.1层向1.3层的连接、3.2层向1.4层的连接、4.1层向2.3层的连接和4.1层向1.4层的连接。实际结果表明,新增连接可以有效提高网络预测的准确率。

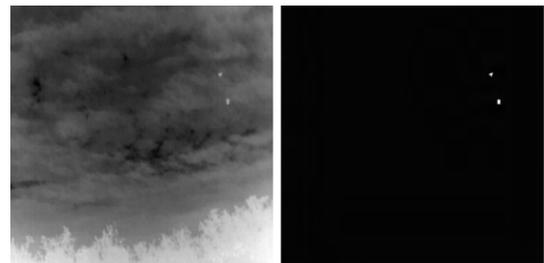
2 深度学习网络的数据集分析与训练

2.1 数据集

目前适用于深度学习网络的红外数据集相对稀缺。在以往传统方法的研究法中,通常是在其内部数据集进行测试并得出结论。然而,随着科技的发展,近年来出现了一些新的公开数据集,如2021年由YD等^[17]发布的NUAA-SIRST数据集和2022年由MZ等^[18]发布的IRSTD-1k数据集。NUAA-SIRST数据集包含427张图像,其中256张用于测试,图像尺寸在300 Pixel×300 Pixel附近。IRSTD-1k数据集包含1 001张图像,其中201张用于测试,图像尺寸均为512 Pixel×512 Pixel。数据集的样张如图2所示。



(a) NUAASIRST数据集训练图片 (b) NUAASIRST数据集标准图片



(c) IRSTD-1k数据集训练图片 (d) IRSTD-1k数据集标准图片

图2 数据集中图像示例

目前常用的红外设备大多成像大小已达到1 024 Pixel甚至以上,但所述两个数据集中图像宽高均小于512 Pixel,不能很好地适应目前红外观测设备的硬件升级。因此,本文手动将图像拉伸至1 024 Pixel×1 024 Pixel大小,以便更符合实际项目需求。但简单的图像放大会导致原来的小目标变成大目标,不利于网络对小目标的检测。本文采用了3种方式对图像进行处理以达到最好的训练效果:(1)直接将图像缩放至1 024 Pixel×1 024 Pixel;(2)将原始图像放置于1 024 Pixel×1 024 Pixel画布上的随机位置,并使用黑色像素填充其余像素;(3)将原始图像放置于1 024 Pixel×1 024 Pixel画布上的随机位置,并使用其他图像中无目标的背景部分填充其余像素。这些处理方式有助于确保提高网络对小目标的检测效果。最终形成的图像的数据集数量如表1所示。

表1 训练数据集详情

使用方法	图像数量	图像宽度	图像高度
方式1	702	1 024	1 024
方式2	1 428	1 024	1 024
方式3	1 428	1 024	1 024

2.2 深度神经网络的搭建与训练

本文所述的神经网络是在Python平台上基于pyTorch深度学习框架进行编程的,使用图像处理工具包PIL作为图像处理模块。用来训练网络的主机CPU为Intel i9-12 900 K, GPU为NVIDIA GeForce RTX 3090。

本文采用了渐进式学习策略进行训练。输入图像的大小对于训练模型所需的时间有着直接的影响。若输入的图像过大,每轮训练输入的图像数量就需要设置的相对较小,这可能导致网络收敛缓慢甚至不收敛。使用动态尺寸进行训练是一个不错的解决方案。若盲目地分多阶段训练从小尺寸图像开始逐渐过渡到大尺寸图像,可能会导致后阶段的训练结果不如前阶段的训练结果。为了解决这个问题,2021年Tan等^[19]提出了使用动态正则化方案来训练不同尺寸图像的方法。在训练尺寸较小的图片时,使用较弱的增强方案,而在训练尺寸较大的图片时,使用较强的增强方案。这种动态正则化方法可以使模型在不同尺寸图像上具有更好的鲁棒性和泛化性能。本文遵循该方法进行了训练,缩短了训练所需时间并取得了较好的效果。

2.3 损失函数

小目标检测方法存在着数据不平衡的现象。如果使用不平衡的数据进行训练,很容易导致高精度但召回率较低的情况。而在实际的场景预测中,误报成阴性比误报成阳性更难以令人接受。因此,在最终的损失函数中需要对精确性和召回率有一个权重的分配。TverskyLoss损失函数^[20]的计算公式如式(1)所示。

$$S = \frac{2|PG|}{|P||G| + \alpha|P/G| + \beta|G/P|} \quad (1)$$

式中: P 和 G 分别为预测值和真值的集合; α 和 β 分别为精确性和召回率的权重; S 为损失值。

通过调整 α 和 β ,可以控制假阳性和假阴性之间的平衡。

3 实验验证与结果分析

3.1 性能指标

对于像素分割的评价指标,通常以如IoU、准确度和召回率作为准确性的评估手段,但这些评价指标往往并不适用于红外小目标数据的检测。由于红外小目标数据的成像尺寸大多只有十几个像素,较小的像素量级可能导致位置预测偏移一个像素时,整体的IoU值发生极大的偏移。因此,上述指标并不完全适用于小目标的检测。为此,本文采用整体包围区域的中心点相较于真实

值中心点的偏差作为评估检测能力的指标之一。中心点的计算方法采用质心法。当检出目标与真实目标的中心点欧式距离在5个像素以内认为是检出。

3.2 实验结果与结果分析

在网络结构进行修改后,本文首先构建了一个主体网络,即修改后的DNANet网络,并采用渐进式学习的训练策略和TverskyLoss函数作为损失函数进行神经网络的训练。本文依次在2.2节所述的3个训练集中进行了1 600轮训练,单次训练时长约20 h。随后在相同的测试集进行了测试,结果如表2所示。

表2 测试结果概况

数据集使用方法	训练轮数	中心定位精度	准确率/%	召回率/%
方式1	1 600	0.92 像素	97.62	85.55
方式2	1 600	0.55 像素	97.87	96.50
方式3	1 600	0.31 像素	98.25	99.55

通过本实验的结果可以发现,在面对3种不同的数据集时,直接对原始图像进行缩放后训练的结果远不及将原始图像放置于1 024 Pixel×1 024 Pixel画布上的随机位置并利用其他图像中无目标的背景部分填充剩余像素所生成的训练集的结果。本文认为:直接对图像进行缩放会破坏原本红外图像中小目标的特征,从而导致训练结果在小目标检测上的应用不佳。使用黑色像素填充剩余区域的方法则会使网络在学习的过程中更倾向于学习图像的黑色区域,从而难以完整地描绘图像的整体特征。因此,本文的剩余实验均采用了第2.1节中所介绍的方式3生成的数据集进行训练。

本文依次使用不同网络结构、不同训练策略和不同损失函数搭建了6组实验对象进行对比。其中,各个实验对象的情况如表3所示。

表3 实验对象情况表

实验对象名	网络结构	训练策略	损失函数
实验对象1	原始DNANet结构	无	Dice Loss
实验对象2	原始DNANet结构	渐进式学习	TverskyLoss
实验对象3	改进DNANet结构	无	Dice Loss
实验对象4	改进DNANet结构	无	TverskyLoss
实验对象5	改进DNANet结构	渐进式学习	Dice Loss
实验对象6	改进DNANet结构	渐进式学习	TverskyLoss

所有实验对象均经历了1 600轮的训练过程。具体来说,实验对象1和2的训练时长约为26 h,平均每轮训练耗时约1 min;而实验对象3~6的训练时长约为20 h,平均每轮训练耗时约45 s。显然,相对于原始网络结构,经过优化的DNANet网络结构在训练速度上实现了显著提升。值得注意的是,训练策略及损失函数的调整并未对网络的训练速度产生影响。在每轮训练结束后,各实验对象的平均损失值变化曲线如图3所示。

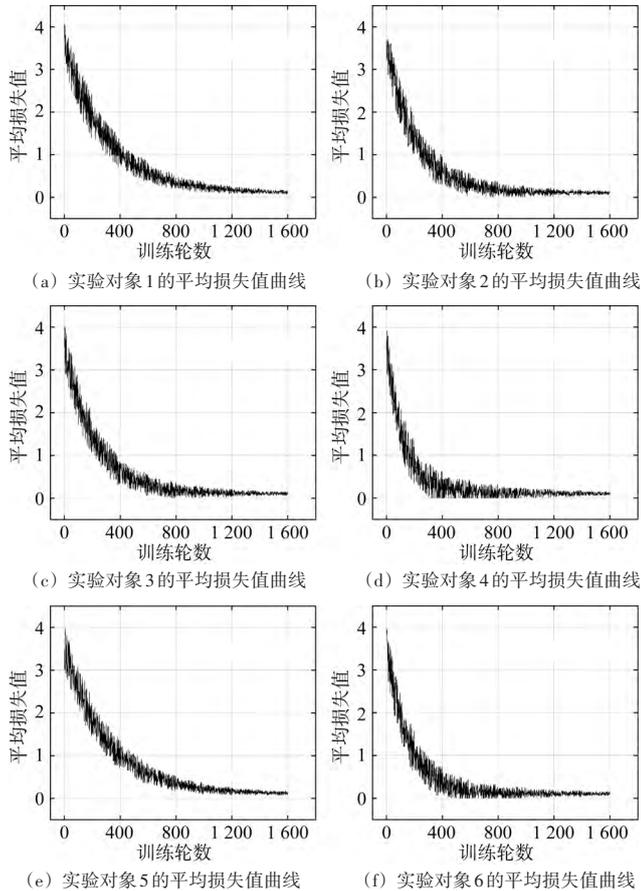


图3 各个实验对象训练的平均损失值变化曲线

对实验对象1与2、实验对象3与4以及实验对象5与6的比较分析可知,使用TverskyLoss损失函数的实验对象相较于使用Dice Loss损失函数的实验对象具有更佳收敛性。比较实验对象1与3、实验对象2与6,可以发现:在相同训练轮数的条件下,改进后的DNANet网络结构相比原始的DNANet结构收敛速度微微增快。比较实验对象3与5、实验对象4与6发现,渐进式学习策略对神经网络的训练速度影响不甚明显。最后,本文将6个实验对象的实验结果输入测试集进行验证,具体结果如表4所示。

表4 测试结果概况

实验对象	训练轮数	中心定位精度	准确率/%	召回率/%
实验对象1	1 600	0.45像元	97.62	95.25
实验对象2	1 600	0.38像元	97.87	98.50
实验对象3	1 600	0.35像元	98.25	100.00
实验对象4	1 600	0.45像元	97.62	95.25
实验对象5	1 600	0.38像元	97.87	98.50
实验对象6	1 600	0.35像元	98.25	100.00

通过对比实验对象1与3在测试集上的表现,观察到,相较于原始的DNANet网络结构,改进的DNANet结构在保持准确率和召回率不变的情况下,显著提升了目标的中心定位精度。进一步观察实验对象3与5及实验对象4与6的对比结果发现,采用渐进式学习模式的训练参数相对于未采用该策略直接训练的参数,虽然准确率没

有明显改变,但其召回率和中心定位精度有了显著提升。这表明渐进式学习策略在大尺寸小目标红外图像场景下具有显著的适应性。

4 结束语

本文提出了一种改进的深度学习小目标检测方法,旨在解决当前主流算法对小目标检测时需输入小尺寸图像且模型参数过多的问题。对DNANet网络结构进行了改进,相较于原始网络结构,该改进使得网络对相同数量图像的推理速度提升了25%。使用渐进式学习策略,克服了DNANet在处理大尺寸图像时收敛速度较慢的问题。对网络的损失函数进行了修改,进一步加快了网络的收敛速度。因此,本文提出的基于深度学习的小目标检测方法,可以方便地应用于工程实践中,并具有较高的实际应用价值。

参考文献:

- [1] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. Advances in neural information processing systems, 2012, 25.
- [2] Deng J, Dong W, Socher R, et al. Imagenet: A large-scale hierarchical image database[C]//2009 IEEE conference on computer vision and pattern recognition. Ieee, 2009: 248-255.
- [3] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2014: 580-587.
- [4] 裘瑾怡,任新新,陈希.基于卷积神经网络的输电线路金具缺陷检测方法[J].自动化与信息工程,2022,43(4):36-41,47.
- [5] Chen C L P, Li H, Wei Y, et al. A Local Contrast Method for Small Infrared Target Detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1): 574-581.
- [6] Han J, Ma Y, Zhou B, et al. A Robust Infrared Small Target Detection Algorithm Based on Human Visual System[J]. IEEE geoscience and remote sensing letters, 2014, 11(12): 2168-2172.
- [7] Wei Y, You X, Li H. Multiscale patch-based contrast measure for small infrared target detection[J]. Pattern Recognition, 2016, 58: 216-226.
- [8] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(6): 1137-1149.
- [9] Guiming, Shi, Jidong. Moving Target Detection Algorithm in Image Sequences Based on Edge Detection and Frame Difference [Z]. 2017.
- [10] Jun Z, Xinhua Z. Foreground Object Detection Combining Gaussian Mixture Model and Inter-Frame Difference in the Application of Classroom recording Apparatus[C]//Proceedings of the 2018 10th International Conference on Computer and Automation Engineering, 2018: 111-115.
- [11] 黄怡静,胡小平,彭向前,等.改进Canny算子的图像边缘检测算法[J].机械科学与技术,2023.
- [12] Scribner D A, Sarkady K A, Caulfield J T, et al. Nonuniformity correction for staring IR focal plane arrays using scene-based techniques[C]//Infrared Detectors and Focal Plane Arrays. Spie, 1990, 1308: 224-233.
- [13] 王昊然.基于多层卷积特征高阶融合的多任务目标检测系统研究[D].哈尔滨:哈尔滨工业大学,2017.

表3 470~471 m之间井筒数据

井深 / m	理论半径值 / mm	实际最大半径值 / mm	实际最小半径值 / mm	理论横截面积 / mm ²	实际横截面积 / mm ²	面积变化
470	62	64.454	58.532 4	12 076.28	12 040.1	0.997
470.125	62	64.589 2	58.604 4	12 076.28	12 060.68	0.999
470.25	62	64.638 7	58.670 6	12 076.28	12 083.3	1.001
470.375	62	64.583 5	58.809 4	12 076.28	12 056.2	0.998
470.5	62	64.410 7	58.732 4	12 076.28	12 025.4	0.996
470.625	62	64.380 7	58.746 1	12 076.28	12 023.2	0.996
470.75	62	64.283 4	58.762 1	12 076.28	12 012.7	0.995
470.875	62	64.308 7	58.837 1	12 076.28	12 005.15	0.994
471	62	64.192 7	58.991 1	12 076.28	11 989.3	0.993

注: 面积变化=点云模型横截面积/理论横截面积

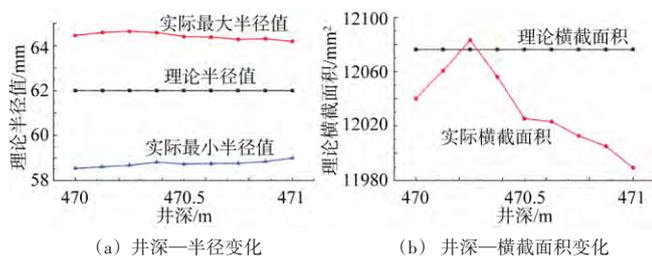


图13 SH54井470~471 m处井筒实际数据与理论数据折线图

再利用柱面坐标和直角坐标转换公式, 用直角坐标标定每个测点坐标值。以三维直角坐标值作为测点的特征值形成特征点, 提取所有特征点, 形成点云模型, 为测井数据转换提供了新思路。同时, 以SH54井的MIT测井数据作为实验对象, 实验成功生成了该井的井筒内壁点云模型, 验证了MIT数据点云转换方法的可实施性。并且对470~471 m井深处点云模型的横截面进行比对分析, 通过面积变化、图形对比, 可推断出该处井筒产生了非对称挤压缩径形变。基于点云数据处理的灵活高效性, 建议接下来利用点云建模算法, 对井筒点云模型进行三维重建, 实现井筒数字化三维建模。

参考文献:

[1] HU J Q. Common formats and format conversion of logging data [J]. Offshore Oil, 2003(1):75-80.
 [2] 陈绪龙, 牛步能, 杜旭, 等. 井筒管柱完整性测井评价技术的应用优化[J]. 测井技术, 2022, 46(4):487-492.
 [14] 林两魁, 王少游, 唐忠兴. 基于深度卷积神经网络的红外过采样扫描图像点目标检测方法[J]. 红外与毫米波学报, 2018, 37(2): 219-226.
 [15] 蒋昕昊, 蔡伟, 杨志勇, 等. 基于YOLO-IDSTD算法的红外弱小目标检测[J]. 红外与激光工程, 2022, 51(3): 502-511.
 [16] B L, C X, L W, et al. Dense Nested Attention Network for Infrared Small Target Detection[J]. IEEE Transactions on Image Processing, 2023, 32: 1745-1758.
 [17] Y D, Y W, F Z, et al. Asymmetric Contextual Modulation for Infrared Small Target Detection[C]. 2021.
 [18] M Z, R Z, Y Y, et al. ISNet: Shape Matters for Infrared Small Target Detection[C]. 2022.

[3] Li Z X. Review of logging data format conversion technology [J]. Chemical Engineering Design Communication, 2016, 42(4):36.
 [4] 韩耀图, 李进, 李疾翎, 等. 超声兰姆波测井技术在渤海油田的应用研究[J]. 石油机械, 2020, 48(5):8-15.
 [5] 刘硕, 闫家旭, 肖泉, 等. 开发过程中油田套管损坏研究现状[J]. 科技资讯, 2023, 21(15):157-161.
 [6] 刘群杰. 套管损坏机理分析及治理对策研究[J]. 石化技术, 2021, 28(12):35-36.
 [7] 周传喜, 田海锋, 郭伟, 等. 井筒温度对含缺陷套管抗挤强度的影响[J]. 石油机械, 2022, 50(10):142-148.
 [8] 舒慧珍, 林彩霞. 测井数据的读取及绘图[J]. 石油仪器, 2008(4): 82-84.
 [9] 胡佳庆. 测井数据常用格式及格式转换[J]. 海洋石油, 2003(1): 75-80.
 [10] 李忠新. 测井数据格式转换技术综述[J]. 化工设计通讯, 2016, 42(4):36.
 [11] 强伟帆, 潘懋, 刘庆彬, 等. 面向深度学习的Las格式测井数据转换器设计[J]. 科学技术与工程, 2021, 21(1):248-253.
 [12] ZHANG N N. Research on casing flaw detection Technology of Multi-arm caliper [D]. Xi'an Shiyou University, 2015.
 [13] 李潮林, 陈仲生, 左旺, 等. 基于3D点云数据的产品缺陷检测研究[J]. 电气, 2023(1):48-54.
 [14] 王慧萍, 王卫, 杨顿, 等. 基于特征库的测井数据格式自动识别与转换方法[J]. 测井技术, 2014, 38(1):65-68.
 [15] 党博, 李丹, 赵建平, 等. 偏心阵列式瞬变电磁探伤三维成像方法研究[J]. 仪表技术与传感器, 2020(8):86-91.
 [16] 林志伟, 钟守明, 宋琳, 等. 体积压裂改造非对称性对套管损坏影响机理[J]. 特种油气藏, 2021, 28(6):158-164.
 [17] 陈绪龙, 牛步能, 杜旭, 等. 井筒管柱完整性测井评价技术的应用优化[J]. 测井技术, 2022, 46(4):487-492.
 [18] 杨万霖. 基于惯性和三维激光技术的井筒安全检测研究[D]. 青岛: 山东科技大学, 2020.
 [19] 刘选朝, 田庚, 张家田, 等. VideoLog可视化测井系统在套管变形检测中的应用[J]. 信息记录材料, 2019, 20(7):134-135.
 [20] 王广涛, 刘美兰, 刘晓妹. X线平片与CT对胸部外伤的诊断价值比较[J]. 中国当代医药, 2023, 30(26):146-149.

作者简介:

屈文涛 (1970—), 男, 山东临邑人, 博士, 教授, 研究领域为石油机械、石油天然气机械节能减排、人机工效评价, 已发表论文140余篇。
 施伟毅 (1997—), 男, 江西赣州人, 硕士研究生, 研究领域为井筒三维可视化建模。
 徐剑波 (1977—), 男, 山东淄博人, 硕士, 讲师, 研究领域为石油机械, 计算机辅助设计、数字化设计, 车辆人机工程学等, 已发表论文100余篇。
 冯沛阳 (1997—), 男, 陕西西安人, 硕士研究生, 研究领域为井筒三维可视化建模和修井管柱通过性分析。
 夏 灿 (1999—), 男, 四川巴中人, 硕士研究生, 研究领域为井筒三维可视化建模。

(上接第128页)

[19] Tan M, Le Q V. EfficientNetV2: Smaller Models and Faster Training[J]. International Conference on Machine Learning, 2021.
 [20] Salehi S S M, Erdogmus D, Gholipour A. Tversky loss function for image segmentation using 3D fully convolutional deep networks[J]. Int. Workshop Mach. Learn. Med. Imag. Springer, 2017:379-387.

第一作者简介: 魏希来 (1999—), 男, 辽宁大连人, 硕士, 研究实习员, 研究领域为红外弱小目标检测。

※通讯作者简介: 孙海江 (1980—), 男, 吉林辉南人, 博士, 研究员, 博士生导师, 研究领域为目标识别与跟踪技术及高清视频图像增强显示。