

文章编号: 2095-4980(2024)02-0152-08

基于改进 DeeplabV3+ 的 HFSWR 电离层杂波及 海杂波自动识别

申家维, 易建新*, 万显荣, 程 丰

(武汉大学 电子信息学院, 湖北 武汉 430072)

摘 要: 针对高频地波雷达(HFSWR)回波谱中背景噪声复杂、杂波占比较小且电离层杂波形态位置各异, 难以自动识别的问题, 以 DeeplabV3+ 深度学习算法为基础架构并加以改进, 提出一种 HFSWR 电离层杂波及海杂波自动识别方法。选用轻量级 MobileNetV2 作为主干特征网络, 加入通道注意力机制模块 SENet, 实现对杂波标签的侧重学习, 优化训练集中各类标签的损失权重; 采用模型预训练迁移法对网络进行预训练, 解决样本空间过小的问题。实测数据集上的实验结果表明, 本方法可以实现 HFSWR 电离层杂波及海杂波的自动识别。相比原 DeeplabV3+ 算法, 杂波识别结果更为准确和精细, 海杂波识别结果的平均交并比(mIoU)和准确率(ACC)分别提升 2.9% 和 5.1%; 电离层杂波识别结果的 mIoU 和 ACC 分别提升 3.0% 和 4.9%。

关键词: 高频地波雷达; DeeplabV3+ 算法; 通道注意力机制; 迁移学习; 电离层杂波; 海杂波; 杂波自动识别

中图分类号: TN958

文献标志码: A

doi: 10.11805/TKYDA2023059

Automatic recognition method of ionospheric clutter and sea clutter for High Frequency Surface Wave Radar based on improved DeeplabV3+

SHEN Jiawei, YI Jianxin*, WAN Xianrong, CHENG Feng

(School of Electronic Information, Wuhan University, Wuhan Hubei 430072, China)

Abstract: The background noise in the echo spectrum of High Frequency Surface Wave Radar (HFSWR) is complex, the clutter accounts for a small proportion and the ionospheric clutter has different forms and positions, therefore, it is difficult to automatically recognize the clutters. Based on DeeplabV3+ deep learning algorithm, an automatic identification method of ionospheric clutter and sea clutter is proposed for HFSWR. Selecting the lightweight MobileNetV2 backbone feature network, adding the channel attention mechanism module SENet, the focused learning of clutter labels is realized, and the loss weight of various labels in the training set is optimized. The model pre-training transfer method is employed to pre-train the network to tackle with the problem of too small sample space. The experimental results on the measured data set show that the proposed method can realize the automatic recognition of ionospheric clutter and sea clutter in HFSWR, and can obtain more accurate and finer clutter recognition results than the original DeeplabV3+ algorithm. The mean Intersection over Union (mIoU) and Accuracy(ACC) of sea clutter recognition results are increased by 2.9% and 5.1% respectively, and the mIoU and ACC of ionospheric clutter recognition results are increased by 3.0% and 4.9% respectively.

Keywords: High Frequency Surface Wave Radar; DeeplabV3+; channel attention mechanism; transfer learning; ionospheric clutter; sea clutter; automatic clutter recognition

收稿日期: 2023-03-08; 修回日期: 2023-04-04

基金项目: 国家自然科学基金资助项目(61931015; 62071335; 62250024); 湖北省自然科学基金创新群体资助项目(2021CFA002)

*通信作者: 易建新 email:jxyi@whu.edu.cn

高频地波雷达(HFSWR)是一种超视距探测雷达,主要用于低空飞行目标探测及海洋舰船探测。HFSWR的回波谱背景噪声复杂,且有较多杂波存在,主要包括电离层杂波和海杂波。回波谱上杂波的存在会干扰后续的目标检测工作,如,关于零多普勒频率轴对称的一阶海杂波会淹没这一频段范围内的所有可能目标;电离层杂波则往往在回波谱图像中居上的位置出现,呈片状或条状的杂波扩散区域内同样很难检测到目标。实现HFSWR回波谱图像上电离层杂波和海杂波的自动识别,可将这两种杂波自适应送入对应的杂波抑制方法模块,并指导后续目标检测策略的调整^[1]。

HFSWR杂波的识别本质上是一个图像语义分割的问题,即区分回波谱图像中哪些部分属于电离层杂波,哪些部分属于海杂波,并进行像素级的分割。以往主要采用传统图像处理方法识别杂波,如基于图像阈值分割的方法^[2]等,这些方法往往依赖杂波在回波谱中图形特征的先验知识和人工经验,不能自动识别杂波。近年来,深度学习算法在图像语义分割领域的应用增多,出现一些较为成熟的神经网络,如全卷积神经网络(Full Convolutional Neural network, FCN)^[3]、U-Net网络^[4]、Deeplab系列网络^[5]等。其中FCN网络是首个端到端的全卷积神经网络,但在背景噪声复杂的情况下会丢失很多细节;U-Net网络常用于医学图像分割,但在室内外场景下的适用性不强;Deeplab系列网络最早在2015年被提出,经优化改进后,DeeplabV3+^[6]在2018年被提出。DeeplabV3+采用以编解码模块为主体的网络体系并强化了解码模块的性能,使用空洞空间卷积池化金字塔(Atrous Spatial Pyramid Pooling, ASPP)融合多尺度信息,使网络模型整体对图像特征的提取更为深入。相比于其他深度学习算法,DeeplabV3+在HFSWR回波谱的特征提取上更具优势。

深度学习算法在HFSWR杂波识别中已有应用。文献[7]将监督学习模型自适应共振理论映射(Adaptive Resonance Theory Map, ARTMAP)用于HFSWR一阶海杂波的检测,检测概率能达到95%以上,代价是虚警率较高。文献[8]提出一种基于杂波聚类与贪婪策略的电离层杂波智能处理方法,对电离层杂波进行分类分情况处理。文献[9]第一次提出基于DeeplabV3+网络的HFSWR海杂波自动识别方法,以台风期间HFSWR实测回波谱图像为实验数据,实现了海杂波的自动识别,但电离层杂波识别的工作还有待进一步完善。文献[10]提出一种以DeeplabV3+为基本架构的HFSWR电离层回波自动获取深度学习改进算法,主要从损失函数、卷积层和空洞率3个方面改进了算法性能,提升了电离层回波获取效率,但在训练网络及训练数据集上还可进一步改进。

受上述文献启发,本文以DeeplabV3+深度学习算法为基础架构并加以改进,提出一种HFSWR电离层杂波及海杂波自动识别方法,并优化训练数据集,改进训练网络,进一步提升杂波识别准确率。

1 HFSWR 电离层杂波及海杂波自动识别方法

1.1 DeeplabV3+深度学习算法

DeeplabV3+深度学习算法通过空洞卷积^[11]减少下采样率;通过增大神经元的感受野减少低层特征空间位置信息的损失。该算法架构可概括为编码-解码2个模块,在编码模块,以Xception^[12]网络作为骨干网络进行特征提取,Xception网络的卷积层采用深度可分离卷积,参数量及计算量相比标准卷积大幅减小,而性能损失较小;在解码模块,该算法采用双线性插值逐步恢复图像的尺寸,在恢复过程中融合低层特征中的细节信息。针对目标的多尺度问题,该算法利用ASPP模块融合多尺度特征。ASPP模块由空洞率分别为6、12、18的3×3空洞卷积和1×1卷积以及全局平均池化操作共同组成。

1.2 主干特征提取网络

HFSWR回波谱存在细节不够精细,背景噪声复杂的问题,沿用传统的Xception网络则运算量过大,训练耗时过长。MobileNetV2^[13]网络体量较轻,独特的反残差单元结构使其在运算量不大的前提下仍具备较高性能。MobileNetV2在激活函数层将ReLU激活函数替换为线性激活函数,从而保存更多低维图像特征,减少训练损失,其单元结构与Xception压缩、卷积、扩张的顺序相反。本文方法采用MobileNetV2作为主干特征提取网络,能够使训练网络在不过多牺牲杂波识别准确率的前提下极大缩短训练耗时。

1.3 通道注意力机制模块

HFSWR回波谱图像中,电离层杂波和海杂波相比背景噪声占比较小,且在谱图像中的位置较为接近,不易分割识别。原DeeplabV3+网络对目标杂波区域及特征没有侧重学习,易出现漏检或误检。为此,本文在主干网络和ASPP模块间加入通道注意力机制模块SENet(Squeeze-and-Excitation Networks)^[14],其模块结构如图1所示。

该模块主要分为4个部分:降维、挤压、激励和注意。首先对原始输入图像进行卷积降维,然后采用全局平均池化进行挤压,如式(1)所示:

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

式中： z_c 为通道顺序为 c 的特征矩阵映射； F_{sq} 为挤压函数； $u_c(i, j)$ 表示大小为 $H \times W$ 的原始输入图像第 c 个通道 (i, j) 位置的像素值。

“激励”部分包括2个全连接层，以学习通道间的复杂关系：

$$s = F_{ex}(z, W) = \delta[g(z, W)] = \sigma[W_2 \delta(W_1 z)] \quad (2)$$

式中： F_{ex} 为激励函数； W_1 为第1个全连接层的 $c \times \frac{C}{16}$ 权重矩阵，将通道数降维为原通道数的1/16后再通过第2个权重矩阵为 W_2 的全连接层进行升维恢复，将通道数恢复为 c ； δ 为激活函数ReLU，其函数表达式为：

$$\delta(x) = \max(0, x) \quad (3)$$

σ 为Sigmoid函数，其函数表达式为：

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

该函数归一化权重矩阵 s 的值范围在 $(0, 1)$ 之间。

最后，“注意”部分通过线性尺度函数 F_{scale} 给每个通道赋值为权重 s ，输出矩阵 Y ，从而增强对图像某个通道的注意力：

$$Y = F_{scale}(u_c, s_c) = s_c u_c \quad (5)$$

式中 s_c 表示通道顺序为 c 的归一化函数权重。




Fig.1 Channel attention mechanism module
图1 通道注意力机制模块

1.4 权重优化

HFSWR回波谱图像中，电离层杂波、海杂波、背景噪声三者的占比差距较大，按原DeeplabV3+网络权重进行训练，无法有效识别目标杂波。为此，本文通过计算数据集中各类杂波标签的像素占比调整训练损失权重：

$$w_j = \left(\sum_i N_{ij} \right)^{-1} \quad (6)$$

式中： w_j 为第 j 类标签的训练损失权重； N_{ij} 为第 i 张图像中第 j 类标签的像素数。计算出背景噪声、海杂波、电离层杂波的训练损失权重为192:6:1，在训练时用该权重替换原网络单一权重，从而解决了3种标签像素占比差异导致的杂波识别效果不佳的问题。

1.5 改进后的DeeplabV3+网络结构

本文对原DeeplabV3+网络进行改进：a) 将主干网络从Xception替换为轻量级网络MobileNetV2，缩短训练耗时；b) 在主干网络和ASPP模块间加入通道注意力机制模块SENet，增强训练网络对海杂波和电离层杂波的注意力；c) 优化训练损失权重为192:6:1，提升训练效果。改进后的DeeplabV3+网络结构如图2所示(图中标注绿色模块为改进部分)。

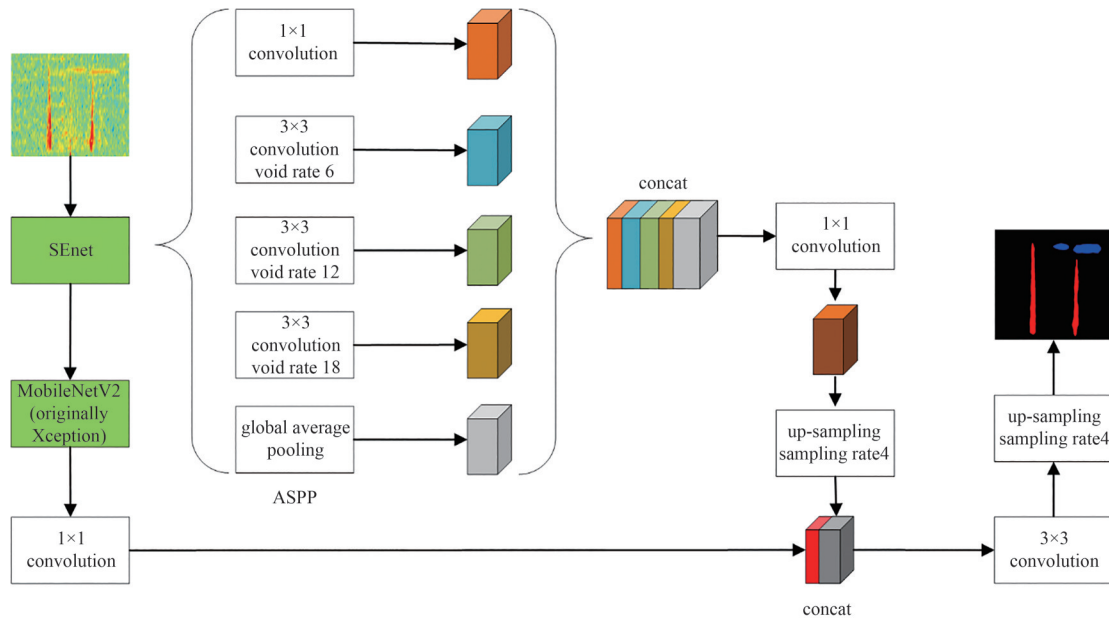


Fig.2 DeeplabV3+ network structure after improvement
图2 改进后 DeeplabV3+网络结构

2 实验过程

2.1 电离层杂波及海杂波数据集的建立

目前尚无可用于深度学习算法的 HFSWR 杂波数据集供公开使用，故本文所建立的数据集标签全部来自人工采集和标注。本次实验的 HFSWR 回波谱图像由武汉大学在福建省沿海采集，均为实测数据。其中一张回波谱如图 3(a)所示。

HFSWR 回波谱中，海杂波的位置和形状较为固定，从图像的角度看，均表现为关于中轴对称的长条状区域。电离层杂波则形状各异，有片状、条状等，还常伴随有杂波区域的扩展现象，且在回波谱上出现的位置也并不固定，需分别进行人工标注。本文将 250 张 HFSWR 回波谱图像组成的数据集按 22:3 的比例划分为训练集和测试集，随机选取 220 张作为训练集，30 张作为测试集。

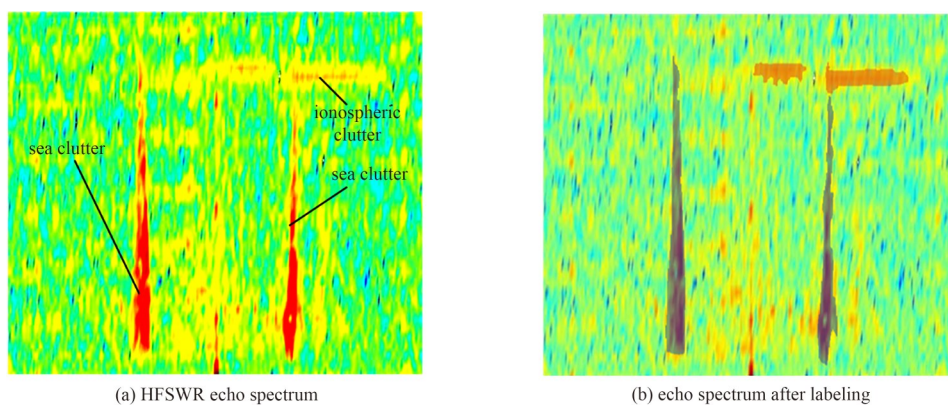


Fig.3 Original RD spectral image and annotated image for HFSWR
图3 HFSWR 原始回波谱图像及标注后图像

标注过程如下：使用 Image Labeler 工具，对 220 张 HFSWR 回波谱图像进行人工标注，每次标注 3 个标签：背景噪声、海杂波及电离层杂波。本文杂波属于有用信号，点目标不属于关注重点。图 3(a)经标注后如图 3(b)所示，标注数据集中全部图像后，3 种标签的像素数量及占比如表 1 所示。

由表 1 可知，数据集中海杂波及电离层杂波像素占比相对背景噪声非常小(这是由杂波本身的分布性质决定的)，导致训练集中目标杂波样本过少。本次实验所采集的 HFSWR 回波谱图像数量有限，故考虑采用模型预训练迁移法对本文网络进行预训练。这种预训练-微调(pretrain-finetune)方式，已广泛用于计算机视觉领域解决有

限数据和模型泛化能力之间的矛盾。本文将 FastMRI 数据集^[15]作为源域，HFSWR 回波谱图像作为目标域，这是因为 FastMRI 数据集中的膝盖医学图像与 HFSWR 回波谱图像语义特征相似：膝盖医学图像中的两侧肌腱形如海杂波，中间部分腔体形如连续分布的电离层杂波，且二者都具有背景像素占比大，待识别目标像素占比少的特点。源域和目标域都带有可供学习的标签，满足模型预训练迁移法使用的条件。

预训练的目的在于使 HFSWR 回波谱图像可以与 FastMRI 数据共享深度学习算法中的部分参数，共享参数后针对两种杂波的特征对算法再进行微调，从而解决样本空间过小的问题。图 4 为预训练-微调过程。

表 1 各类标签像素数量及占比

label	number of pixels	proportion/%
background noise	67 374 462	96.25
sea clutter	2 265 534	3.24
ionospheric clutter	360 011	0.51
total	70 000 007	100

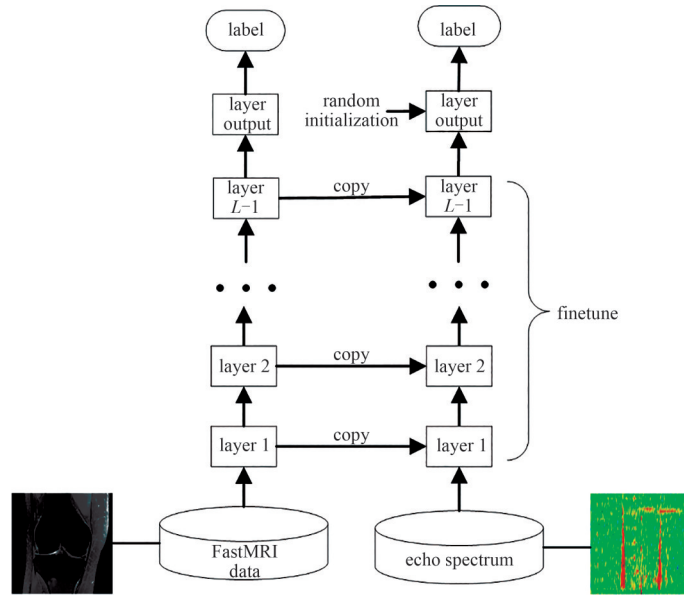


Fig.4 Pretraining-fine tuning process
图4 预训练-微调过程

2.2 训练参数设置及评价指标

实验的网络参数如下：初始学习率为 0.000 1；主干网络采用 MobileNetV2；输入图片的大小为 $500 \times 500 \times 3$ ；每次输入图像的批次设为 8，共迭代 140 轮；损失函数为交叉熵损失函数，激活函数为线性激活函数，背景噪声、海杂波、电离层杂波的训练损失权重设置为 192:6:1。

实验选取语义分割任务中常用的评价指标：平均交并比(mIoU)和准确率(ACC)量化杂波自动识别结果好坏。其中，ACC 用来衡量对电离层杂波及海杂波识别的误判程度：

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \quad (7)$$

式中： TP 表示正例预测正确的个数； FP 表示负例预测错误的个数； TN 表示负例预测正确的个数； FN 表示正例预测错误的个数。

mIoU 用来衡量电离层杂波及海杂波识别的准确程度，其计算公式为：

$$mIoU = \frac{1}{N} \left(\sum_{i=1}^N \frac{X_{ii}}{T_i + \sum_{j=1}^N (X_{ji} - X_{ii})} \right) \quad (8)$$

式中： N 为图像像素的类别； T_i 为某一类别的像素总数； X_{ii} 为预测正确的像素总和； X_{ji} 为预测错误的像素总和。

3 实验结果及分析

3.1 主干特征网络对比分析

为比较不同主干特征网络在 HFSWR 杂波识别任务下的表现，分别使用 MobileNetV2、Xception、Resnet101 作为主干特征网络对本文数据集进行训练，训练参数同 2.2 节一致，损失函数变化曲线如图 5 所示。其中，损失函数是代价函数的一部分，用于定义单个训练样本与真实值之间的误差。

由图 5 可知，使用 MobileNetV2 网络训练迭代 20 轮左右，损失即可达到 0.1，并很快收敛；Xception、Resnet101 均需迭代 30 轮左右，损失才第一次达到 0.1，且即使趋于稳定，仍偶有振荡出现，训练最终的总损失也在 MobileNetV2 之上。综上，本文情景下选用 MobileNetV2 作为主干特征网络，收敛速度更快，杂波识别精确度更高。

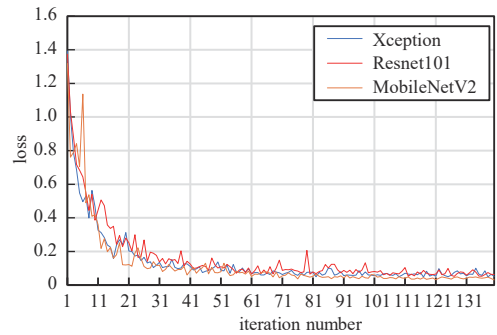


Fig.5 Comparison of different backbone network loss functions
图 5 不同主干网络损失函数对比

3.2 不同杂波识别方法对比分析

为评估本文方法的改进效果，在相同实验环境下对经典深度学习语义分割算法 U-Net、原 DeeplabV3+ 及本文方法开展对比实验。3 种方法的杂波识别可视化结果如图 6 所示，3 种方法均可较为准确地识别海杂波，这是因为海杂波在回波谱中的位置和形态结构较为固定。3 种方法的差距体现在海杂波的误判程度上，如图中白色框线所示，U-Net 最多，原 DeeplabV3+ 次之，本文算法最少。本文方法对电离层杂波的识别结果相对更为精细，尤其是对距离较近的两片杂波区域分辨能力更强，而 U-Net 和原 DeeplabV3+ 会把距离较近的两片杂波区域识别为连续的一片，导致较大面积的误判，如图中橙色框线所示。另外，由于电离层杂波在回波谱图像上的位置不固定，3 种方法都更容易将回波谱上连续的强噪声信号错判为电离层杂波，如图中绿色框线所示。本文方法的错判情况相比另两种方法较少，程度也较轻，说明本文方法对背景噪声干扰相对不敏感，鲁棒性更强。

3 种方法识别杂波类别评价指标结果如表 2 所示。本文方法的各项指标都优于 U-Net 算法，海杂波识别的平均交并比和准确率分别高出 4.4% 和 7.0%，电离层杂波识别的平均交并比和准确率分别高出 5.2% 和 6.3%。这主要是因为 HFSWR 回波谱图像背景噪声复杂，细节不精细，而 U-Net 算法训练网络较为简单，体积较小，因而能提取到的图像特征有限，杂波识别准确度一般。

对于海杂波，本文方法的平均交并比和准确率相比原 DeeplabV3+ 算法分别高出 2.9% 和 5.1%，在图 6 的可视化结果中分别体现为识别出的海杂波轮廓更接近于标注真值图像以及错检、漏检更少。对于电离层杂波，本文方法的平均交并比和准确率相比原 DeeplabV3+ 算法分别高出 3.0% 和 4.9%，同样在可视化结果中得到印证。综上所述，本文方法相比原 DeeplabV3+ 算法，在杂波识别结果的平均交并比、准确率上均有改进，性能更优越。




Fig.6 Comparison of clutter acquisition visualization results
图 6 杂波识别可视化结果对比

表 2 不同方法识别杂波类别评价指标结果对比

Table 2 Results comparison of different methods and evaluation indexes for clutter category identification

clutter categories	U-Net		DeeplabV3+		proposed method	
	mIoU	ACC	mIoU	ACC	mIoU	ACC
sea clutter	0.727	0.794	0.742	0.813	0.771	0.864
ionospheric clutter	0.635	0.685	0.657	0.699	0.687	0.748

4 结论

本文提出了一种基于改进 DeeplabV3+ 的 HFSSR 电离层杂波及海杂波自动识别方法。在网络模型上, 通过比较损失函数的收敛速度及最终总损失, 确定了更适用于本文情景的 MobileNetV2 主干特征网络; 在主干网络和 ASPP 模块间加入通道注意力机制模块 SENet, 实现对杂波区的侧重学习。在训练数据集上, 通过统计数据集中各类杂波标签的像素占比, 优化训练损失权重; 采用模型预训练迁移法对本文网络进行预训练, 从而解决样本空间过小的问题。最后, 在实测数据集上开展对比实验。结果表明, 相比原 DeeplabV3+ 算法, 本文方法可以获得更为精细的杂波识别结果: 海杂波识别结果的平均交并比和准确率分别提升 2.9% 和 5.1%; 电离层杂波识别结果的平均交并比和准确率分别提升 3.0% 和 4.9%。本文方法旨在提升 HFSSR 杂波识别准确率, 未对本文网络的训练耗时进行优化, 未来将进一步提升本文方法的性能, 并用于 HFSSR 实时化场景下的杂波抑制目标检测。

参考文献:

- [1] 陈小龙, 牟效乾, 关键. 对海雷达多维图像特征融合智能检测方法[J]. 太赫兹科学与电子信息学报, 2022, 20(10): 1006–1016. (CHEN Xiaolong, MU Xiaoqian, GUAN Jian. Detection method of multi-dimensional images feature intelligent fusion for marine radar[J]. Journal of Terahertz Science and Electronic Information Technology, 2022, 20(10): 1006–1016.) doi: 10.11805/TKYDA2022119.
- [2] 曾文君. 基于多维谱特征的电离层杂波检测和识别方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2014. (ZENG Wenjun. Research on ionospheric clutter detection and identification method based on multi-dimensional spectral characteristics[D]. Harbin, China: Harbin Institute of Technology, 2014.) doi: 10.7666/d.D591355.
- [3] 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. doi: 10.1109/TPAMI.2016.2572683.
- [4] SONG Wei, ZHENG Nan, LIU Xiangchun, et al. An improved U-Net convolutional networks for seabed mineral image segmentation[J]. IEEE Access: Practical Innovations, Open Solutions, 2019(7): 82744–82752. doi: 10.1109/ACCESS.2019.2923753.
- [5] CHEN L C, PAPANDEOU 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. doi: 10.1109/TPAMI.2017.2699184.
- [6] CHEN L C, ZHU Yukun, PAPANDEOU R G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[M]. Cham: Springer, 2018: 833–851. doi: 10.1007/978-3-030-01234-2_49.
- [7] 张磊. 基于特征学习的双站高频地波雷达一阶海杂波检测技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2014. (ZHANG Lei. Detection of the BHFSWR first-order sea clutter based on feature learning[D]. Harbin, China: Harbin Institute of Technology, 2014.) doi: 10.7666/d.D593301.
- [8] 位寅生, 周建宇, 许荣庆. 基于杂波聚类与贪婪策略的电离层杂波智能处理方法[J]. 雷达学报, 2020, 9(4): 589–607. (WEI Yinsheng, ZHOU Jianyu, XU Rongqing. Intelligent suppression method for ionospheric clutter based on clustering and greedy strategy[J]. Journal of Radars, 2020, 9(4): 589–607.) doi: 10.12000/JR20086.
- [9] CHEN Haotian, LEE S, YAO D, et al. Sea clutter image segmentation method of high frequency surface wave radar based on the improved Deeplab network[J]. IEICE Transactions on Fundamentals of Electronics Communications and Computer Sciences, 2022, E105.A(4): 730–733. doi: 10.1587/transfun.2021EAL2057.
- [10] 吕哲. 高频地波超视距雷达电离层回波自动提取与动力学特征研究[D]. 哈尔滨: 哈尔滨工业大学, 2022. (LYU Zhe. Automatic acquisition and dynamical characteristics of ionospheric echoes from high frequency surface wave over-the-horizon radar[D]. Harbin, China: Harbin Institute of Technology, 2022.)
- [11] AHMAD F, HOU Wenguo, XIONG Jing, et al. Fully automated cardiac MRI segmentation using dilated residual network[J]. Medical Physics, 2023, 50(4): 2162–2175. doi: 10.1002/mp.16108.

- [12] ZHU Yaolin, HUANG Jiayi, LI Yunhong, et al. Image identification of cashmere and wool fibers based on the improved Xception network[J]. Journal of King Saud University: Computer and Information Sciences, 2022, 34(10, Part B): 9301–9310. doi:10.1016/j.jksuci.2022.09.009.
- [13] WANG Wei, LI Yutao, ZOU Ting, et al. A novel image classification approach via Dense-MobileNet models[J]. Mobile Information Systems, 2020(2020): 7602384. doi:10.1155/2020/7602384.
- [14] WANG Jingjing, LUAN Zhenye, YU Zishu, et al. Superpixel segmentation with squeeze-and-excitation networks[J]. Signal Image and Video Processing, 2022, 16(5): 1161–1168. doi:10.1007/s11760-021-02066-2.
- [15] ZHAO Ruiyang, YAMAN B, ZHANG Yuxin. FastMRI+, clinical pathology annotations for knee and brain fully sampled magnetic resonance imaging data[J]. Scientific Data, 2022, 9(1): 152. doi:10.1038/s41597-022-01255-z.

作者简介:

申家维(1998–), 男, 在读硕士研究生, 主要研究方向为外辐射源雷达目标检测与杂波处理. email: 2016301200246@whu.edu.cn.

万显荣(1975–), 男, 博士, 教授, 博士生导师, 主要研究方向为外辐射源雷达系统、高频雷达系统及雷达信号处理等.

易建新(1989–), 男, 博士, 副教授, 主要研究方向为外辐射源雷达信号处理、目标跟踪和信息融合.

程丰(1975–), 男, 博士, 副教授, 主要研究方向为外辐射源雷达信号处理、目标检测与跟踪.

(上接第 151 页)

- [16] 朱应钊, 李嫚. 元学习研究综述[J]. 电信科学, 2021, 37(1): 22–31. (ZHU Yingzhao, LI Man. A review of metalearning research[J]. Telecommunications Science, 2021, 37(1): 22–31.) doi:10.11959/j.issn.1000-0801.2021009.
- [17] 赵春宇, 赖俊. 元强化学习综述[J]. 计算机应用研究, 2023, 40(1): 1–10. (ZHAO Chunyu, LAI Jun. Review of yuan reinforcement learning[J]. Computer Application Research, 2023, 40(1): 1–10.) doi:10.19734/j.issn.1001-3695.2022.06.0295.
- [18] FINN C, ABBEEL P, LEVINE S. Model-Agnostic Meta-Learning for fast adaptation of deep networks[C]// Proceedings of the 34th International Conference on Machine Learning. Sydney, Australia: [s.n.], 2017: 1126–1135.
- [19] DANG Xiangqian, LI Zhanbo. Network intrusion detection approach based on convolutional neural network[C]// 2022 the 4th International Conference on Communications, Information System and Computer Engineering (CISCE). Shenzhen, China: IEEE, 2022: 247–251. doi:10.1109/CISCE55963.2022.9851014.
- [20] QIAN Yunhan, QI Jie, KUAI Xiaoyan, et al. Specific emitter identification based on multi-level sparse representation in automatic identification system[J]. IEEE Transactions on Information Forensics and Security, 2021(16): 2872–2884. doi:10.1109/TIFS.2021.3068010.
- [21] 刘鑫尧, 秋勇涛, 皇甫雅帆, 等. 基于星座图和卷积神经网络的射频指纹识别[J]. 太赫兹科学与电子信息学报, 2022, 20(5): 458–463. (LIU Xinyao, QIU Yongtao, HUANGFU Yafan, et al. Radio frequency fingerprint identification based on constellation and convolutional neural network[J]. Journal of Terahertz Science and Electronic Information Technology, 2022, 20(5): 458–463.) doi:10.11805/TKYDA2020091.
- [22] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318–327. doi:10.1109/ICCV.2017.324.

作者简介:

段可欣(1996–), 女, 在读硕士研究生, 主要研究方向为雷达辐射源识别. email: 1346859039@qq.com.

张建廷(1986–), 男, 博士, 工程师, 主要研究方向为通信信号智能处理.

闫文君(1986–), 男, 博士, 副教授, 主要研究方向为空时分组码检测、智能信号处理.

李春雷(1996–), 男, 学士, 助理工程师, 主要研究方向为计算机软件应用.

刘凯(1986–), 男, 博士, 副教授, 主要研究方向为智能信息处理.

王艺卉(1992–), 女, 在读硕士研究生, 主要研究方向为辐射源个体识别.