

徐欢,任沂斌. 基于混合损失 U-Net 的 SAR 图像渤海海冰检测研究[J]. 海洋学报, 2021, 43(6): 157–170, doi:10.12284/hyxb2021084

Xu Huan, Ren Yibin. Detecting sea ice of Bohai Sea using SAR images based on a hybrid loss U-Net model[J]. Haiyang Xuebao, 2021, 43(6): 157–170, doi:10.12284/hyxb2021084

基于混合损失 U-Net 的 SAR 图像渤海海冰检测研究

徐欢¹, 任沂斌^{2,3*}

(1. 江苏海洋大学 海洋技术与测绘学院, 江苏 连云港 222005; 2. 中国科学院海洋研究所 海洋环流与波动重点实验室, 山东 青岛 266071; 3. 中国科学院海洋大科学研究中心, 山东 青岛 266071)

摘要: 渤海是我国重要的经济区, 海冰灾害严重威胁着人类生产活动。合成孔径雷达具有全天候成像能力, 研究渤海区域的 SAR 图像海冰检测具有重要意义。传统海冰检测方法受限于特征提取方法和建模方式, 检测精度有待提升。深度学习具有极强的特征自学习能力, 适用于图像检测问题。本文基于深度学习框架 U-Net, 以 Sentinel-1 双极化 (VV 和 VH) 合成孔径雷达图像为输入信息, 设计混合损失函数优化传统 U-Net 模型, 形成了基于混合损失 U-Net 的渤海海冰检测模型。将本文模型与传统海冰检测方法 [脉冲耦合神经网络 (PCNN)、马尔科夫随机场 (MRF) 和分水岭算法] 和基于深度卷积神经网络 (CNN) 的深度学习方法进行了对比。实验结果表明: 本文基于混合损失 U-Net 的海冰检测模型在重叠度、F1 分数、精确度和召回率 4 项度量指标上分别达到了 97.567%、98.769%、98.767% 和 98.771%, 检测效果明显优于对比方法; 双极化信息输入的检测结果比 VV 单极化输入的检测结果在 F1 分数、精确度、召回率和重叠度上分别提高了 0.375%、0.111%、0.639% 和 0.740%; 混合损失函数的检测结果比非混合损失函数的检测结果在 F1 分数、精确度、召回率和重叠度上分别提高了 1.129%、0.947%、1.794% 和 2.231%; 模型能对冰水沿线、冰间水道、冰间隙等细节进行有效检测; 可应用于渤海区域整幅 SAR 图像的海冰检测, 为海冰监测、海冰变化分析、海冰预报提供技术支撑。

关键词: 合成孔径雷达图像; 海冰检测; 深度学习; U-Net; 混合损失函数

中图分类号: P722.4; P731.15

文献标志码: A

文章编号: 0253-4193(2021)06-0157-14

1 引言

海冰作为 5 大海洋灾害之一, 对全球的水文、洋流、热力循环和生态系统都有重大影响^[1-2]。渤海每年都有 3 个多月不同程度的结冰现象, 对我国社会生产活动造成严重影响。渤海海冰不仅堵塞航道、损坏船只, 还破坏海上及海岸设施, 其融化甚至给海洋养殖带来次生灾害。2009/2010 年冬季至 2018/2019 年冬季, 我国受海冰灾害影响经济损失高达 75 亿元,

其中辽宁和山东两省受灾情况较为严重^[3]。合成孔径雷达 (Synthetic Aperture Radar, SAR) 具有不受气象条件限制、全天时、全天候的观测能力, 被广泛用于海冰的检测和监测^[4-6]。因此, 研究基于 SAR 图像的渤海海冰检测对海冰监测、海冰灾后应急、海洋运输、海洋渔业具有重要意义。

多年来, 学者们围绕海冰检测提出了一系列方法, 总体可分为两类: 传统方法和深度学习方法。传统方法包括阈值法^[7]、纹理分析^[8-10]、专家知识系统^[11]、

收稿日期: 2020-07-18; 修订日期: 2020-09-23。

基金项目: 中国博士后科学基金 (2019M662452); 中国科学院战略先导专项 (XDA19060101, XDA19090103); 山东省重大科技创新工程 (2019JZZY010102)。

作者简介: 徐欢 (1994—), 男, 江苏省扬州市人, 主要从事海洋空间信息技术研究。E-mail: 2018224050@jou.edu.cn

* 通信作者: 任沂斌 (1990—), 男, 山东省青岛市人, 博士后, 主要从事基于人工智能的海洋大数据信息提取、建模、预测等方面研究。E-mail: yibinren@qdio.ac.cn

马尔科夫随机场^[12]、支持向量机^[13-16]、神经网络^[17]等。大数据时代的到来,传统方法受限于手动特征提取和建模方式,制约了海冰检测精度的进一步提升^[18]。近年来,深度学习迅猛发展^[19]。典型的深度学习模型由多层神经网络堆叠而成,可以模拟人类的神经系统,从原始输入数据中逐层抽象特征,实现对目标的检测和识别^[20]。深度卷积神经网络(Convolutional Neural Network, CNN)由多个卷积层组成,是一种特殊的深度神经网络。卷积层通过卷积核与上一层卷积层连接,可以提取局部空间特征^[21],已在图像分类、目标识别和时空信息挖掘等领域取得了巨大成功^[22-26]。近些年,研究人员已将 CNN 应用到海冰检测与识别中。Li 等^[27]利用 CNN 实现了对高分 3 号影像的海冰检测。Xu 和 Scott^[28]以 CNN 的经典模型 AlexNet 为基础,引入迁移学习思想来加速网络参数训练,实现了 SAR 图像的海冰和海水分类。黄冬梅等^[29]将 CNN 和深度置信网络(Deep Belief Networks, DBN)相结合,用于 SAR 图像的冰水分类。Wang 等^[18]采用 Sentinel-1 SAR 数据,构建了具有 3 个 CNN 层和两个全连接神经网络层的海冰分类模型,实现了白令海附近海冰的多尺度分类。

海冰检测已由传统方法向深度学习方法转变。得益于强大的特征提取能力,基于深度学习模型的海冰检测方法取得了比传统方法更高的检测精度。然而,现有研究仍存在两方面的问题:一方面,现有深度学习检测模型多以早期的 CNN 架构和自定义 CNN 架构为主,模型的特征提取和表征能力有限,导致模型对海冰检测的精度有待进一步提升;另一方面,传统 SAR 海冰检测方法已发现双极化信息相对于单极化信息更有利于海冰和海水的区分^[30-31],而现有的研究还没有考虑双极化信息,制约了海冰检测精度的提高。

U-Net 是近年来提出的图像分割方法。U-Net 以 CNN 为基本组成单元,可以通过少量的训练样本获得较高的图像分割精度,在医学图像分割方面取得了巨大成功^[32-33]。已有研究将 U-Net 应用到遥感图像的目标分割并取得了较高的分割精度^[34-35]。因此,本文将 U-Net 引入到渤海海冰的检测中,以 Sentinel-1 VV 和 VH 双极化 SAR 图像为数据源,设计混合损失函数优化传统 U-Net 模型,形成了基于混合损失 U-Net 的渤海海冰检测模型。通过与传统方法——脉冲耦合神经网络(Pulse Coupled Neural Network, PCNN)、马尔科夫随机场(Markov Random Field, MRF)、分水岭算法(Watershed Algorithm, WA)和基于 CNN 深度学习

方法的对比实验,验证了本文方法的有效性。进一步分析了双极化信息和混合损失函数对海冰检测效果的影响。文章的第 2 节简要介绍了研究区域概况和数据处理步骤,第 3 节详细介绍了本文提出的混合损失 U-Net 海冰检测模型,第 4 节通过对比实验分析了本文模型与已有模型的海冰检测差异,分析了双极化信息和混合损失函数的效果,第 5 节为总结和 research 展望。

2 研究区域及数据

2.1 研究区域概况

渤海是有黄河、辽河、海河等入海的半封闭式内海,由辽东湾、渤海湾、莱州湾、中央浅海盆地和渤海海峡 5 部分海域组成,也是西太平洋的一部分,面积达 7.49 万 km²,海岸线长达 2 670 km,平均水深约为 18 m,如图 1 所示。渤海每年冬季都有 3~4 个月不同程度的结冰现象,一般情况下,海冰分布范围可达渤海面积的 1/3。本文选取 2015 年 12 月至 2020 年 3 月 5 个冬季共 10 景 SAR 图像数据进行海冰检测研究, SAR 图像详细信息如表 1。

2.2 数据获取和预处理

本文采用 Sentinel-1 A/B 卫星的 SAR 影像作为研究数据。Sentinel-1 A/B 是欧洲航天局(European Space Agency, ESA)于 2014 年发射的携带 SAR 传感器的卫星,工作波段为 C 波段,轨道高度为 693 km,重复周期为 12 d。Sentinel-1 A/B 数据产品分为 0、1、2 共 3 个级别,本文采用的是 1 级产品中的地距影像(Ground Range Detected, GRD)。渤海的 GRD 采用了宽幅干涉模式(Interferometric Wide Swath, IW),该工作模式将获得的 3 个子条带合成 1 幅影像,幅宽为 250 km,极化方式为 VV 和 VH。

首先,采用 SNAP(Sentinel Application Platform, SNAP)Desktop^[36]对 SAR 影像数据进行辐射校准、滤波和几何校正。然后,将每张影像裁剪成若干大小为 256×256 像素的切片,切片之间相邻且无重叠,如图 2 所示。最后,利用标注软件 LabelMe^[37]对 SAR 影像切片进行海冰标注,其中海冰像素标注为 1,背景像素标注为 0。标注结果见图 3。

3 研究方法

3.1 基于混合损失 U-Net 的海冰检测模型流程

基于混合损失 U-Net 的渤海海冰检测模型整体流程如图 4 所示。对原始 SAR 影像进行预处理并切片,对切片数据进行海冰标注;将标注后的海冰数据

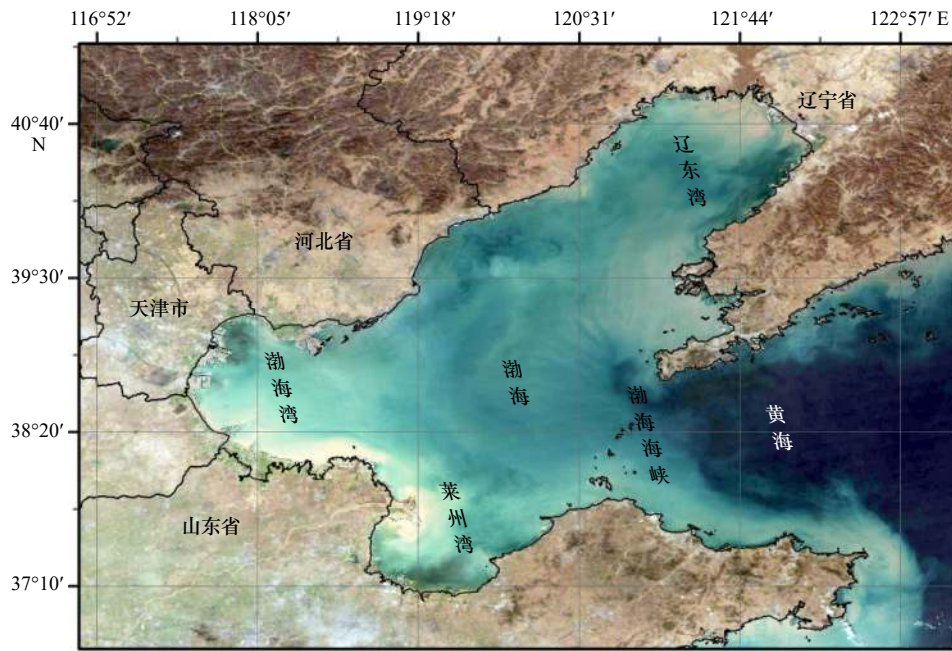


图 1 研究区域地理位置

Fig. 1 Geographical location of the study area

表 1 SAR 图像的详细信息

Table 1 Details of SAR images

图像集	成像时间	图像中心点坐标	极化方式	卫星
1	2016年1月28日21:55:43	40.430 2°N, 122.256 0°E	VH+VV	A星
2	2017年1月9日22:03:22	40.345 5°N, 120.186 9°E	VH+VV	B星
3	2017年1月21日22:03:21	40.345 5°N, 120.188 1°E	VH+VV	B星
4	2017年2月2日22:03:21	40.345 6°N, 120.188 1°E	VH+VV	B星
5	2017年2月9日21:55:17	39.780 9°N, 122.078 0°E	VH+VV	B星
6	2018年1月24日09:49:07	40.718 8°N, 121.724 4°E	VH+VV	A星
7	2019年1月19日09:49:14	40.718 8°N, 121.725 4°E	VH+VV	A星
8	2020年1月2日09:49:21	40.718 7°N, 121.724 5°E	VH+VV	A星
9	2020年2月7日09:49:20	40.718 5°N, 121.723 3°E	VH+VV	A星
10	2020年2月19日09:49:19	40.718 3°N, 121.722 8°E	VH+VV	A星

集划分为训练集、测试集和验证集,训练集用于混合损失 U-Net 海冰检测模型训练,测试集测试训练好的混合损失 U-Net 海冰检测模型;采用多种度量指标对测试结果进行精度验证,评估模型的海冰检测效果。

3.2 基于混合损失 U-Net 的海冰检测模型结构

U-Net 海冰检测模型的基本组成单元是 CNN, CNN 中,当前隐藏层神经元通过卷积核与上一隐藏层中与卷积核对应的部分元素建立局部连接,而不是与所有元素建立全局连接^[21],如图 5 所示。CNN 输出矩阵中某单元由输入矩阵中与卷积核对应区域的元

素与卷积核中权重加权求和得到。U-Net 的结构与字母“U”的形状相似,见图 6,所以被命名为 U-Net^[38]。U-Net 由输入、编码、解码和输出 4 部分组成。输入由 SAR 图像的 VV 和 VH 双极化信息组成,图像大小为 256×256 像素。编码部分用于提取抽象的、缩小的特征图来进行准确的分类;解码部分和编码部分之间存在跳跃连接,解码部分可以融合多尺度特征图,对感兴趣的目标进行更详细、更大信息量的描述。下面从编码器、解码器、输出层和混合损失函数 4 部分重点介绍混合损失 U-Net 海冰检测模型的具体结构。

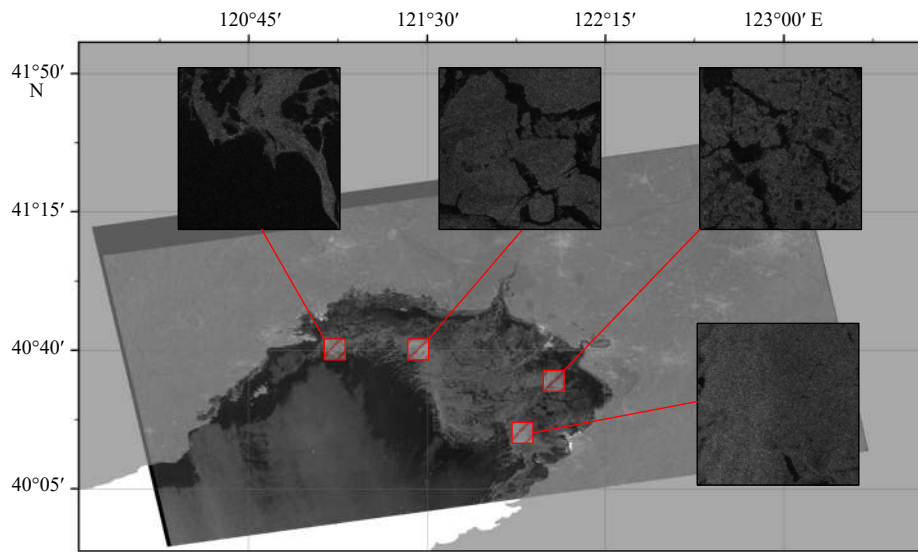


图 2 渤海海冰影像切片

Fig. 2 Image slices of sea ice in the Bohai Sea




图 3 海冰标注结果

Fig. 3 Labeled slices of sea ice

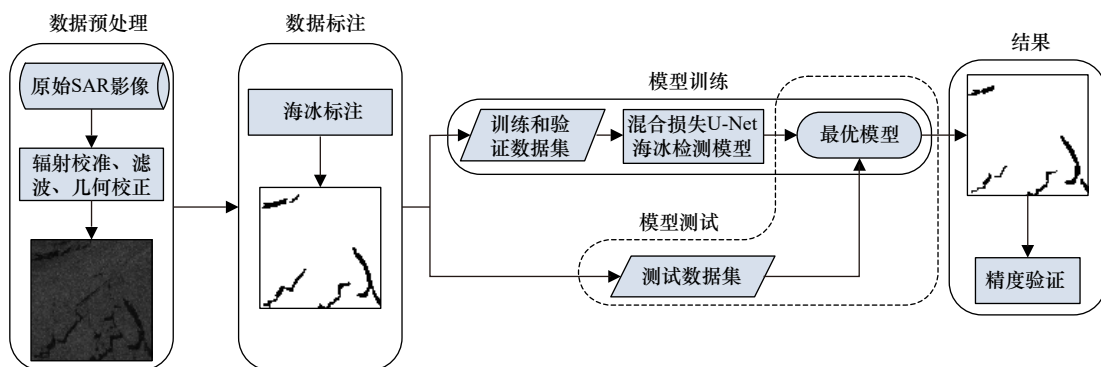


图 4 基于混合损失 U-Net 的海冰检测模型流程图

Fig. 4 Flow chart of sea ice detection model based on a hybrid loss U-Net model

3.2.1 编码器

编码器负责提取抽象的、缩小的特征图,常用的编码器包括 ResNet 18、VGG 16、VGG 19 等^[39-40],考虑到模型计算和海冰检测复杂度,我们选择 ResNet 18 作为编码器。本文 U-Net 模型的编码器由 ResNet 18 的 17 个卷积层组成,包括 5 个编码块。第 1 个编码块是步长为 2 的 7×7 卷积层。经第 1 编码块计算后,切片大小变为 128×128 像素。其余 4 个编码块均由两个编码单元堆叠而成。每个编码单元为 1 个残差卷积神经网络模块,由两组堆叠的“卷积层和非线性




图 5 卷积运算示例

Fig. 5 An example of convolution operation

输入矩阵为 5×5,卷积核为 3×3,则该卷积层共有 9 个参数,此 9 个参数被整个隐藏层共享,则输出矩阵中 Z 的计算如图 5 所示

The input matrix is 5×5, the convolutional kernel is 3×3, the convolutional layer has 9 parameters, which are shared by the whole hidden layer.

The calculation of Z in the output matrix is shown in Fig.5

激活层”和短路连接组成^[23]。编码单元对输入图像进行特征提取和非线性变换,输出变换后的高级特征。卷积层的卷积核大小为 3×3^[41],卷积层对特征图进行补充,使得卷积前后特征图的尺寸相同。激活函数为“ReLU”,如果输入小于 0,则输出为 0,否则输出与输入相等。使用“ReLU”作为激活函数,输出不会随着输入的增加而趋于饱和。在两个编码单元前堆叠一个最大池化层(除第 1 和第 5 编码块),池化层的核大小为 2×2,经过 1 次池化后,输出特征图的大小变为输入特征图大小的 1/2。

令 $X_i^{M \times N \times K}$ 表示第 i 个编码块的输入,其中 $M \times N$ 为输入图像的大小, K 为输入图像的通道数(由上一层编码块中的卷积核数量决定),当前编码块的卷积核数量为 L ,经当前编码块变换输出为 X_{i+1} 。原始输入为 $256 \times 256 \times 2$ 的 SAR 图像,经一次卷积核运算得到 $262 \times 262 \times 2$ 的图像,即 $X_1^{262 \times 262 \times 2}$ 为第 1 编码块的输入。编码器后,再经 1 次卷积核运算得到解码器的输入特征图 S 。 F 表示编码器及其后续一步的卷积操作, L 为卷积核数量,分别为 64、64、128、256、512 和 1 024, W 为需要学习的权重。经编码器及其后续一步的卷积操作得到 $16 \times 16 \times 1\ 024$ 的特征图,公式为

$$S^{16 \times 16 \times 1\ 024} = F(X_1^{262 \times 262 \times 2}, L, W). \quad (1)$$

3.2.2 解码器

本文 U-Net 模型的解码器包括 4 个解码模块。每个解码模块由两个解码单元堆叠而成。如图 6 所示,在两个解码单元前堆叠一个上采样层和一个连接层,上采样层的核大小为 2×2,经过一次上采样后,输出




图 6 基于混合损失 U-Net 的海冰检测模型网络架构

Fig. 6 Network architecture of sea ice detection model based on a hybrid loss U-Net model

特征图的大小变为输入特征图的 2 倍;连接层连接上采样结果与其在编码块中相对应的特征图,以融合编码块提取的浅层位置特征和解码块提取的深层语义特征。一个解码单元由两组堆叠的“卷积层和非线性激活层”组成,对连接层进行特征还原和非线性变换,输出变换后的所有特征。卷积层的卷积核大小为 3×3 ,卷积层对特征图进行补全,使得卷积前后特征图的尺寸相同。激活函数为“ReLU”。令 $Y_i^{M \times N \times K}$ 表示第 i 个解码块的输入,其中 $M \times N$ 为输入图像的大小, K 为输入图像的通道数(由上一层解码块中的卷积核数量决定),当前解码块的卷积核数量为 L ,经当前解码块变换输出为 Y_{i+1} 。 G 表示上采样操作、连接操作、卷积变换和非线性激活, L 为卷积核数量,分别为 512、256、128 和 64, W 为需要学习的权重。经过解码器后,原输入特征图 $S^{16 \times 16 \times 1024}$ (即 $Y_1^{16 \times 16 \times 1024}$) 被解码为 $256 \times 256 \times 1$ 的特征图 Y ,公式为

$$Y^{256 \times 256 \times 1} = G(S^{16 \times 16 \times 1024}, L, W). \quad (2)$$

3.2.3 输出层

本文 U-Net 模型的输出层由一个卷积层和一个非线性激活层堆叠而成,将特征图 Y 的像素级特征转换为像素级分类结果,映射到网络的输出层上。卷积层的卷积核大小为 1×1 ,卷积核的数量为 1。激活函数为“Sigmoid”,可以把输出值映射到 $(0,1)$ 区间,大于等于 0.5 的输出值为海冰,小于 0.5 的输出值为背景,公式为

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (3)$$

3.2.4 混合损失函数

损失函数是深度学习算法进行模型优化的核心。对于一个输入样本,模型的输出值与该样本真实值之间的差异称为损失。损失函数是描述这种差异的函数。对于一个深度学习模型,模型中的神经网络权重通过损失反向传播来完成训练^[42]。因此,损失函数决定了深度学习模型的训练效果,至关重要。

在二分类的图像分割问题中,交叉熵损失函数(Binary Cross Entropy Loss, BCE_{loss}) 是使用最为广泛的损失函数之一,公式为

$$BCE_{loss} = -P_1 \sum_{n=1}^N \ln P'_1 - P_0 \sum_{n=1}^N \ln P'_0, \quad (4)$$

式中, P_0 为标签图像下像素点为海冰的概率; P_1 为标签图像下像素点为背景的概率; P'_0 为输出层像素点为海冰的概率; P'_1 为输出层像素点为背景的概率; N 为像素总数。

本文中,标签样本的值为 $\{0, 1\}$, 分别表示背景和

海冰。公式(4)中, P_0 表示标签图像下像素为海冰的概率,值为 1; P_1 表示标签图像下像素为背景的概率,值为 0。模型在输出时经过“Sigmoid”函数输出一个概率值,当 $x=0$ 时, $f(x)=0.5$; 当 $x>0$ 时, $f(x) \approx 1$; 当 $x<0$ 时, $f(x) \approx 0$ 。把输出值映射到 $(0,1)$ 之间的数值概率上。预测输出就是“Sigmoid”函数的输出,表征了输出层为海冰像素和背景像素的概率,即 P'_0 和 P'_1 。概率间的关系为 $P'_0 + P'_1 = 1$ 和 $P_0 + P_1 = 1$ 。

采用 BCE_{loss} 优化 U-Net 模型,能够稳定地回传不同类别所对应的梯度,有效地解决模型在反向传播中梯度消失的问题。但由于 BCE_{loss} 在回传梯度时,对图像上每个类别都进行平等地估计,所以对于图像上类别不平衡的问题,最常见的类别更容易改变模型的优化方向,进而影响最终的分割结果。

此外,另一种用于图像分割问题的损失函数是 Dice 损失函数(Dice Loss, $Dice_{loss}$),公式为

$$Dice = \frac{2|A \cap B|}{|A| + |B|}, \quad (5)$$

$$Dice_{loss} = 1 - Dice, \quad (6)$$

式中, A 为真值图像; B 为预测图像; $|A \cap B|$ 为 A 和 B 之间的共同元素; $|A|$ 为 A 中的元素个数; $|B|$ 为 B 中的元素个数。

$Dice_{loss}$ 由 Dice 系数发展而来。如公式(5)所示, $Dice$ 系数度量两个集合的相似程度,取值范围为 $0 \sim 1$ 。当 $Dice$ 系数为 1 时,表示两个集合完全重合,分类效果最好;当 $Dice$ 为 0 时,表示两个集合不存在重合,即没有正确的分类结果。因此, $Dice_{loss}$ 能够引导模型持续学习,最大化 $Dice$ 系数,使预测结果逐渐逼近真实结果,最终实现预测结果与真实结果完全重合的目标。但如果预测结果中有部分像素预测错误,就会导致预测目标梯度的剧烈变化,从而增加模型训练的难度。

为发挥 BCE_{loss} 和 $Dice_{loss}$ 各自的优点,本文设计了 BCE_{loss} 和 $Dice_{loss}$ 结合的损失函数 $BCED_{loss}$,将 $BCED_{loss}$ 用于 U-Net 海冰检测模型的训练。 $BCED_{loss}$ 的定义如下:

$$BCED_{loss} = wBCE_{loss} + (1 - w)Dice_{loss}, \quad (7)$$

式中, w 为权重因子,反映了两个损失函数分别占的权重。一般情况下, w 的取值大于 0.5,具体的取值结果见 4.4 节。

4 模型验证与应用

4.1 实验设置

实验将 SAR 图像切片和对应的标签数据划分为训练集、验证集和测试集,包含的切片数量分别为

1 829、323 和 479。模型训练在 Linux 操作系统下完成,使用的设备配置有 1 个 NVIDIA TESLA V100 32 GB GPU。本文模型基于 TensorFlow-Keras 框架搭建,代码采用 Python 3.6 编写。本文混合损失 U-Net 模型采用适应性矩估计^[43](Adaptive Moment Estimation, Adam)优化算法来对模型中的参数进行优化。Adam 通过计算梯度的一阶矩估计和二阶矩估计为不同参数设计独立的自适应学习率,能够快速收敛,更高效的学习。

4.2 评价指标

在海冰检测的过程中,我们需要对 U-Net 网络进行训练和测试。因此,我们使用以下几项指标来评价模型的训练和测试结果:

重叠度 (Intersection over Union, IoU) 用于计算模型预测的海冰区域与真实海冰区域的重叠比例, IoU 值越大,预测结果越好,其公式为

$$\text{IoU} = \frac{P \cap G}{P \cup G}, \quad (8)$$

式中, P 为模型预测的海冰区域; G 为真实的海冰区域; $P \cap G$ 为 P 和 G 重叠的海冰像素; $P \cup G$ 为 P 和 G 并集的海冰像素。

精确度 (Precision) 指的是正确预测的正样本数占所有预测为正样本数量的比值,也就是所有预测为正样本的样本中真正的正样本数,只考虑预测为正样本的部分,其公式为

$$\text{Precision} = \frac{t_p}{t_p + f_p}, \quad (9)$$

式中, t_p 为正确检测的海冰像素; f_p 为错误检测的海冰像素。

召回率 (Recall) 指的是正确预测的正样本数占真实正样本总数的比值,也就是测试样本中能够正确预测出的正样本数,其公式为

$$\text{Recall} = \frac{t_p}{t_p + f_n}, \quad (10)$$

式中, f_n 为错误检测的背景像素。

F1 分数 (F1_Score) 是精确度和召回率的一种调和平均,通常作为衡量二分类模型精度的一种指标,其公式为

$$\text{F1_Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (11)$$

4.3 对比实验

为验证本文模型的有效性,本文进行了 3 组对比实验。首先将本文混合损失 U-Net 模型与已有的传统方法和深度学习方法进行对比,见表 2。传统方法包括分水岭算法、MRF^[12] 和 PCNN^[17] 3 种经典方法。深度学习方法为基于 CNN 的海冰检测模型^[27]。然后

针对本文 U-Net 模型的损失函数,进行了混合损失函数与非混合损失函数的对比实验,见表 3。混合损失函数是 BCE_{loss} 和 $\text{Dice}_{\text{loss}}$ 权重之和。 $\text{BCED}_{\text{loss}}$ 的权重 w 设置为 0.7, w 的取值由实验得到,见 4.4 节。非混合损失函数模型分别以 BCE_{loss} 和 $\text{Dice}_{\text{loss}}$ 为损失函数。最后根据 VH、VV、VV+VH 不同极化信息的输入进行模型预测结果的对比实验,见表 4。实验结果的评价指标为 F1_Score、Precision、Recall 和 IoU。所有测试模型的数据集划分方式一致。本文的 U-Net 模型 ($w=0.7$) 和 CNN 模型均进行了超参数的调节,取最优的测试效果为最终结果。

4.3.1 不同模型检测结果对比

由表 2 可知,与传统的图像检测方法和深度学习方法相比,本文基于混合损失 U-Net 的海冰检测模型在 F1_Score、Precision、Recall 和 IoU 4 项指标上均为

表 2 不同模型的度量结果

Table 2 Measurement results of different models

方法	度量标准			
	F1分数/%	精确度/%	召回率/%	重叠度/%
PCNN	89.077	86.189	92.332	81.929
MRF	89.455	86.754	93.405	84.034
分水岭算法	88.977	85.733	92.476	80.142
CNN	91.333	89.060	93.726	84.049
本文U-Net	98.769	98.767	98.771	97.567

表 3 不同损失函数的度量结果

Table 3 Measurement results of different loss functions

模型	度量标准			
	F1分数/%	精确度/%	召回率/%	重叠度/%
U-Net _{BCE}	97.666	98.310	97.030	95.438
U-Net _{Dice}	97.875	97.840	97.910	95.839
U-Net _{BCED}	98.769	98.767	98.771	97.567

表 4 不同极化方式的度量结果

Table 4 Measurement results of different polarization information

模型输入	度量标准			
	F1分数/%	精确度/%	召回率/%	重叠度/%
VH	93.240	93.240	96.061	89.806
VV	98.400	98.657	98.144	96.850
VV+VH	98.769	98.767	98.771	97.567

最优。传统方法中, Recall 均高于其他度量指标, 说明传统方法在检测过程中对海冰像素的敏感度高于背景像素; 深度学习方法的 Recall 偏高, 也说明其在检测过程中对海冰像素的敏感度高。基于混合损失 U-Net 的海冰检测模型在 F1_Score、Precision 和 Recall 上均较高, 说明其能较好地分辨海冰像素和背景像素。在 IoU 上, 本文模型的优势更加明显, 说明本文 U-Net 模型检测的海冰区域与真实的海冰区域重叠度比例较高。

为了进一步验证基于混合损失 U-Net 海冰检测模型的精度, 我们从测试集中选取了部分 SAR 图像切片, 来具体对比各个模型的预测结果, 如图 7 所示 (白色为海冰, 黑色为背景)。图 7 中共有 7 列数据, 每一行按顺序分别是单张切片的原始 SAR 图像、对应标签数据和 5 种对比方法的预测结果。总体来看, 相比本文 U-Net 模型, 另外 4 种方法的预测结果都有所不足。对比图 7b 和图 7d 两组数据, MRF 只能模糊地预测出海冰范围, 对于海冰密集度较低的地方, MRF 方法无法检测。从图 7 第 4 行的预测结果来看, 对于

不同灰度级别的海冰, PCNN 较其他方法的检测效果不明显, 但从图 7e 组其他的预测结果来看, PCNN 对冰水沿线的海冰检测效果较其他传统方法显著。对比图 7b 和图 7e 两组数据, PCNN 预测会误把海冰像素检测成背景像素, 导致海冰的不完整呈现, CNN 方法预测的结果也出现类似的情况。对比图 7b 和图 7f 两组数据, 分水岭算法的预测结果存在无法完整检测海冰范围的问题。对比深度学习 (本文 U-Net 和 CNN) 和传统方法 (MRF、PCNN 和分水岭算法) 预测的结果, 深度学习方法检测海冰的效果更好, 说明基于深度学习方法在区分海冰和背景特征方面具有优势。对比图 7b、图 7c 和图 7g 3 组数据, 本文混合损失 U-Net 模型检测海冰的效果更接近真值, 特别是对冰水沿线、冰间水道、冰间隙等细节的检测效果更好。

4.3.2 不同损失函数结果对比

为验证本文 $BCED_{loss}$ 的效果, 将混合损失 U-Net 模型和非混合损失 U-Net 模型进行对比。非混合损失 U-Net 模型包括两个: 以 BCE_{loss} 为损失函数的 U-Net 模型 ($U-Net_{BCE}$); 以 $Dice_{loss}$ 为损失函数的 U-Net 模




图 7 不同模型对海冰测试集的预测结果

Fig. 7 Prediction results of different models for sea ice test sets

1-5 中每行表示一个测试样本, 每行从 a-g 分别表示样本的原始 SAR 图像切片、标签数据、本文 U-Net 预测结果、MRF 预测结果、PCNN 预测结果、分水岭算法预测结果和基于 CNN 的深度学习方法预测结果, 白色为海冰, 黑色为背景

In 1-5, each row represents a testing sample, a-g of each row are the original SAR image slice, the label data, prediction result of U-Net, prediction result of MRF, prediction result of PCNN, prediction result of WA, and prediction result of deep learning method based on CNN; white pixels are sea ice and black pixels are water

型(U-Net_{Dice})。U-Net_{BCED}为本文混合损失 U-Net 模型($w=0.7$)。实验环境和实验数据保持不变。利用测试集对 3 种模型进行预测和精度评定,结果如表 3 所示。

由表 3 可知,与非混合损失函数模型 U-Net_{BCE}和 U-Net_{Dice}相比,本文混合损失函数模型 U-Net_{BCED}在 F1_Score、Precision、Recall 和 IoU 4 项指标上均有明显提升。进一步,选取 2020 年 2 月 19 日的 1 景渤海海冰图像,对比不同损失函数 U-Net 模型的预测结果。为清晰地对比三者的不同,本文选取了近岸和离岸的两个典型区域(图 8a 中绿色方框所示),放大对比 3 个模型的海冰检测结果,如图 8b 至图 8e 所示。从图 8b 至图 8e 可知,非混合损失函数 U-Net_{BCE}和 U-Net_{Dice}模型对海冰细节检测效果存在缺陷,特别是红圈标注的区域,而 U-Net_{BCED}的检测结果弥补了非混合损失函数模型检测结果的不足。所以,本文设计的 BCED_{loss}能综合 BCE_{loss}和 Dice_{loss}的优势,更好地实现 U-Net 模型的训练,减小模型预测结果与真值之间的差距,提高模型的海冰检测能力。

4.3.3 不同极化信息结果对比

为验证双极化信息在海冰检测方面的优势,将 VH、VV 和 VV+VH 3 种不同极化信息输入到本文混合损失 U-Net 模型($w=0.7$)中,保持实验环境不变,进行模型训练,并利用测试集对 3 种模型训练结果进行预测和精度评定,结果如表 4 所示。

由表 4 可知,与 VH 或 VV 单极化输入信息相比,

VV 和 VH 双极化输入信息在 F1_Score、Precision、Recall 和 IoU 4 项指标上均最优,且明显优于 VH 单极化输入信息。同样,选取了 2020 年 2 月 19 日的 1 景渤海海冰图像,对比不同输入信息 U-Net 模型的预测结果。为清晰地对比三者不同,也选取了近岸和离岸的两个典型区域(图 9a 中绿色方框所示),放大对比 3 个模型的海冰检测结果,如图 9b 至图 9e 所示。从图 9b 至图 9e 可知,VV 和 VH 双极化输入信息的 U-Net 模型对海冰检测能力明显强于 VH 单极化输入。VV 单极化输入信息的 U-Net 模型与其相比,也存在红圈标注的检测误区,图 9e 圈 1 处较明显。而在 VH 单极化输入的结果中,上述在 VV 极化中被错误检测的区域得到改正,如图 9d 所示。综合 VV+VH 双极化输入,VV 单极化输入出现的错误检测得到改正,如图 9c 所示。所以,VV+VH 双极化图像能为混合损失 U-Net 模型提供更完整的海冰像素信息,提高模型的海冰检测能力。

综上所述,相对于已有的传统和深度学习方法,本文提出的基于 VV 和 VH 双极化信息输入的混合损失 U-Net 模型对渤海海冰具有更高的检测精度,能够对海冰、背景进行有效区分,对冰水沿线、冰间水道、冰间隙等细节特征的检测效果更好。

4.4 混合损失函数权重比分析

为了获得本文 U-Net 模型损失函数的最优权重比,本文对损失函数中的权重因子 w 进行了探究,将

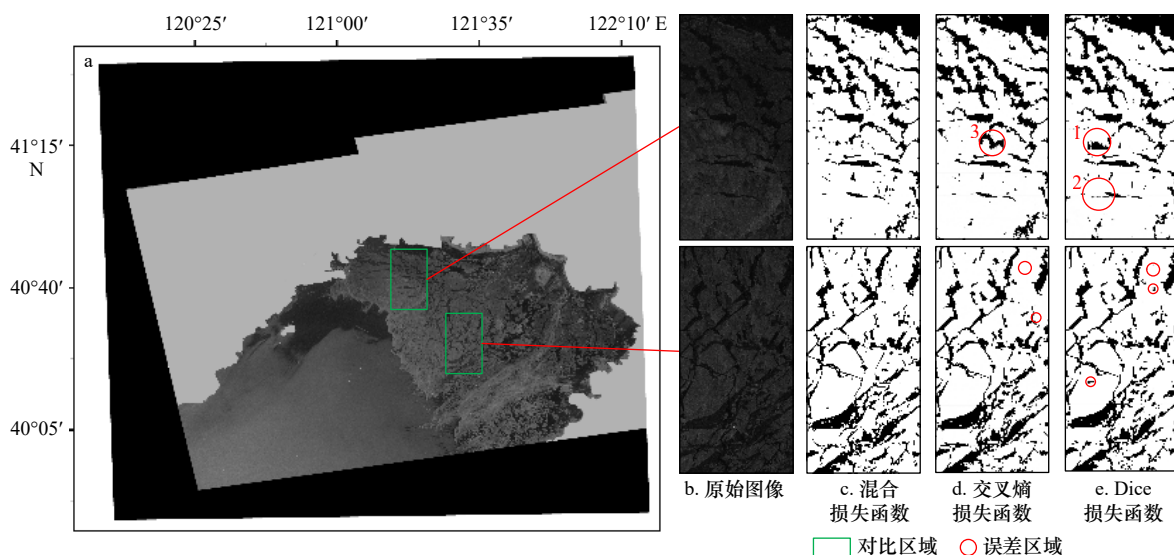


图 8 不同损失函数的海冰检测结果对比

Fig. 8 Comparisons of sea ice detection results with different loss functions

影像成像日期为 2020 年 2 月 19 日;中心点坐标为 40.718 3°N, 121.722 8°E; d 中误差区域 3 在 e 中能被正确检测,最后在 c 中能被正确检测,

同理可见误差区域 1 和 2

The imaging date is February 19, 2020; the coordinates of the central point are 40.718 3°N, 121.722 8°E; the error area 3 in d can be correctly detected in e, and

finally correctly detected in c, so are the error area 1 and 2

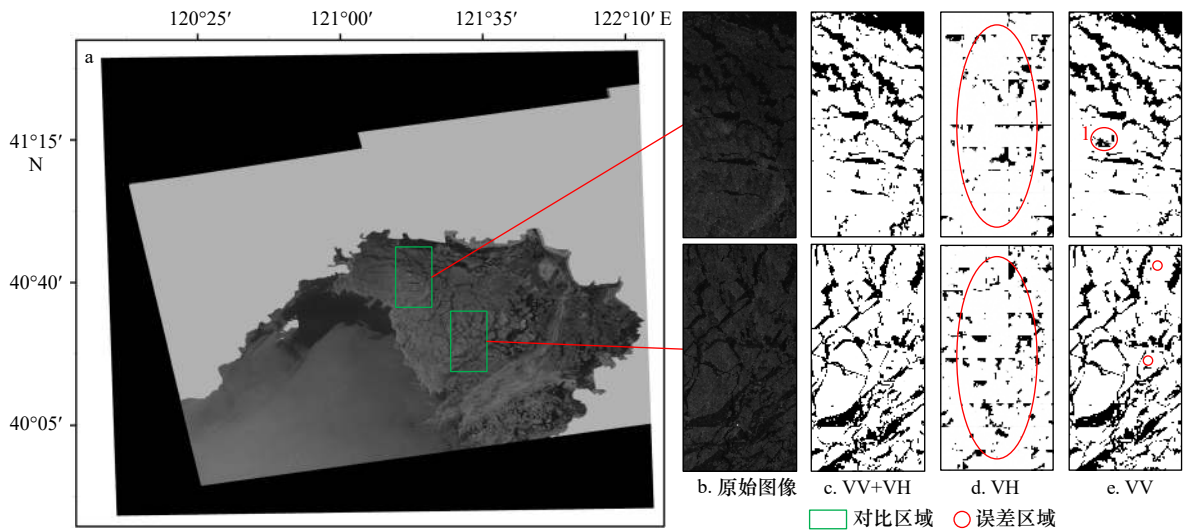


图 9 不同极化信息海冰检测结果对比

Fig. 9 Comparisons of sea ice detection results with different polarization information

影像成像日期为 2020 年 2 月 19 日; 中心点坐标为 40.718 3°N, 121.722 8°E; e 中误差区域 1 在 d 中能被正确检测, 最终在 c 中能被正确检测
 The imaging date is February 19, 2020; the coordinates of the central point are 40.718 3°N, 121.722 8°E; the error area 1 in e can be correctly detected in d, finally correctly detected in c

w 分别设置为 0.1、0.2、0.3、0.4、0.5、0.6、0.7、0.8 和 0.9, 并对测试集进行预测, 预测结果的度量指标值如图 10 所示。

图 10 展示了损失函数在不同权重比的情况下对本文 U-Net 模型性能的影响。从图中可以看出, w 不同取值下, 模型的各项指标存在波动。整体来看, 当 w 大于等于 0.5 时, 模型各项指标的变化趋于稳定。当 w 取 0.7 时, F1_Score、Precision、Recall 和 IoU 指标最优, 模型的性能最佳。因此, 在模型应用中, 建议 w 值设置为 0.7, 以 BCE_{loss} 为主要损失, Dice_{loss} 为辅助

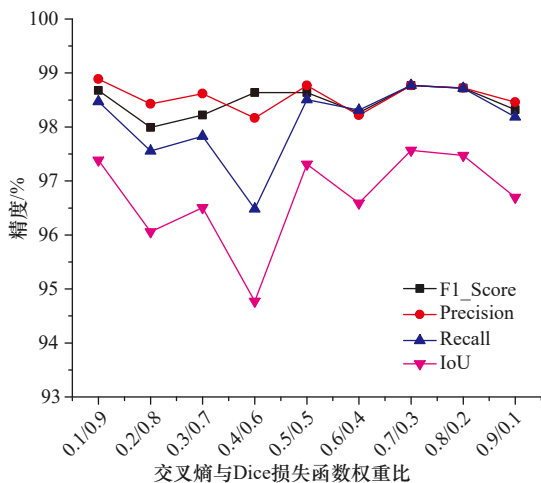


图 10 混合损失函数不同权重比实验结果

Fig. 10 Experimental results of hybrid loss functions with different weight ratios

损失, 得到最优效果。

4.5 模型应用

为了更好地验证本文混合损失 U-Net 海冰检测模型的应用性, 将训练好的模型用于渤海区域整幅 SAR 影像的海冰检测。此处, 选取 2020 年 1 月 2 日 (图 11) 辽东湾的 SAR 影像, 对影像进行预处理, 并输入到混合损失 U-Net 模型中进行海冰检测。可以看出, 本文模型对 SAR 影像中的海冰、背景能进行较好地分类, 对海冰及其细节能较好地检测。因此, 本文提出的 U-Net 模型可以应用于渤海区域整幅 SAR 图像的海冰检测, 可为海冰监测、海冰变化分析、海冰预报提供技术支持。

5 结论与展望

本研究针对渤海区域 SAR 影像的海冰检测问题, 以 Sentinel-1 VV 和 VH 双极化方式的 SAR 影像为数据源, 引入深度学习框架 U-Net, 用 ResNet 18 编码器, 设计了 BCE_{loss} 和 Dice_{loss} 结合的混合损失函数优化 U-Net 模型, 形成了基于混合损失 U-Net 的渤海海冰检测模型, 并与传统的海冰检测方法和已有的深度学习方法进行了对比, 研究了混合损失函数和双极化输入信息对海冰检测结果的影响, 同时分析了混合损失函数的权重比, 得出了如下结论:

(1) 本文提出的 U-Net 模型在测试集上的重叠度为 97.567%, F1 分数为 98.769%, 精确度为 98.767%, 召

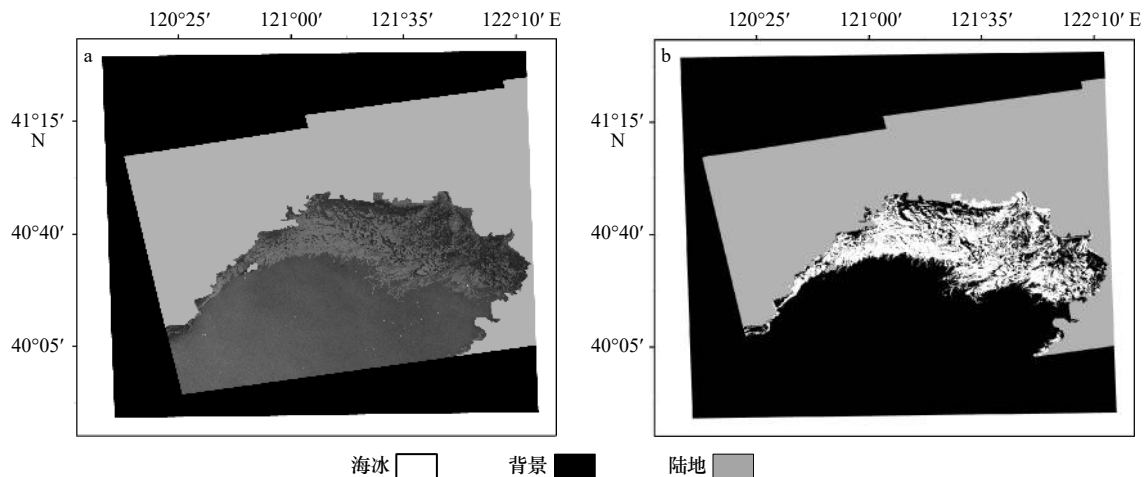


图 11 整幅 SAR 图像海冰检测结果

Fig. 11 The sea ice detection results of the whole SAR image

影像成像日期为 2020 年 1 月 2 日; 中心点坐标为 40.718 7°N, 121.724 5°E; a 是原始 SAR 影像; b 是模型检测的海冰

The imaging date is January 2, 2020; the coordinates of the central point are 40.718 7°N, 121.724 5°E; a is the original SAR image; b is the sea ice detected by the model

回率为 98.771%, 远远优于 PCNN、MRF、分水岭算法和基于 CNN 的深度学习方法 4 种对比方法。

(2) 本文设计的混合损失函数相对于非混合损失函数能够提高模型对海冰信息的检测能力。

(3) 从不同极化信息输入结果可知, 较单极化 SAR 图像, 模型能够从双极化图像中学习更完整的海冰信息。

(4) 从测试集的检测结果来看, 本文混合损失 U-Net 模型不仅可以实现海冰、背景的分类, 对冰水沿线、冰间水道、冰间隙等细节特征的检测效果较好。

(5) 本文混合损失 U-Net 模型可以应用于渤海区域整幅 SAR 图像的海冰检测, 可为海冰监测、海冰变

化分析、海冰预报提供技术支撑。

本实验中 U-Net 虽然在渤海海冰 SAR 影像数据集上获得了较好的结果, 但仍有拓展的空间。一方面, 本文采用的 SAR 数据为 VH 和 VV 极化, 下一步将研究融合多源 SAR 影像, 拓宽海冰信息, 提高模型检测精度和适用范围。另一方面, 将以本文的海冰检测模型为基础, 开展渤海海冰变化监测方面的相关研究。

致谢: 感谢欧洲航天局提供 Sentinel-1 数据和 SNAP Desktop 软件; 感谢标注软件 LabelMe 和 Anaconda 平台; 感谢李晓峰研究员对本文提出的修改意见。

参考文献:

- [1] Mori M, Kosaka Y, Watanabe M, et al. A reconciled estimate of the influence of Arctic sea-ice loss on recent Eurasian cooling[J]. *Nature Climate Change*, 2019, 9(2): 123–129.
- [2] Olonscheck D, Mauritsen T, Notz D. Arctic sea-ice variability is primarily driven by atmospheric temperature fluctuations[J]. *Nature Geoscience*, 2019, 12(6): 430–434.
- [3] 自然资源部. 中国海洋灾害公报[R]. 北京: 自然资源部, 2010–2019. Ministry of Natural Resources. China's maritime disaster communique[R]. Beijing: Ministry of Natural Resources, 2010–2019.
- [4] Soh L K, Tsatsoulis C. Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, 37(2): 780–795.
- [5] 王利亚, 何宜军, 张彪, 等. HY-2 卫星扫描微波辐射计数据反演北极海冰漂移速度[J]. *海洋学报*, 2017, 39(9): 110–120. Wang Liya, He Yijun, Zhang Biao, et al. Retrieval of Arctic sea ice drift using HY-2 Satellite scanning microwave radiometer data[J]. *Haiyang Xuebao*, 2017, 39(9): 110–120.
- [6] Daboor M, Geldsetzer T. Towards sea ice classification using simulated RADARSAT constellation mission compact polarimetric SAR imagery[J]. *Remote Sensing of Environment*, 2014, 140: 189–195.
- [7] Fetterer F, Bertoina C, Ye Jingping. Multi-year ice concentration from RADARSAT[C]//IGARSS'97. 1997 IEEE International Geoscience and Remote Sensing Symposium Proceedings. Remote Sensing—A Scientific Vision for Sustainable Development. Singapore: IEEE, 1997, 1: 402–404.

- [8] Su Hua, Wang Yunpeng, Xiao Jie, et al. Improving MODIS sea ice detectability using gray level co-occurrence matrix texture analysis method: A case study in the Bohai Sea[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2013, 85: 13–20.
- [9] Zakhvatkina N Y, Alexandrov V Y, Johannessen O M, et al. Classification of sea ice types in ENVISAT synthetic aperture radar images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 51(5): 2587–2600.
- [10] 李小娜, 张杰, 戴永寿, 等. 灰度共生矩阵纹理特征对SAR海冰漂移监测的增强性能研究[J]. *海洋科学*, 2018, 42(4): 9–17.
Li Xiaona, Zhang Jie, Dai Yongshou, et al. Research on the enhanced performance of texture feature for sea ice drift monitoring based on gray level co-occurrence matrices[J]. *Marine Sciences*, 2018, 42(4): 9–17.
- [11] Soh L K, Tsatsoulis C, Gineris D, et al. ARKTOS: An intelligent system for SAR sea ice image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(1): 229–248.
- [12] Ochilov S, Clausi D A. Operational SAR sea-ice image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(11): 4397–4408.
- [13] 郑敏薇, 李晓明, 任永政. 高分3号星载合成孔径雷达极地海冰自动检测方法研究[J]. *海洋学报*, 2018, 40(9): 113–124.
Zheng Minwei, Li Xiaoming, Ren Yongzheng. The method study on automatic sea ice detection with GaoFen-3 synthetic aperture radar data in polar regions[J]. *Haiyang Xuebao*, 2018, 40(9): 113–124.
- [14] 张明, 吕晓琪, 张晓峰, 等. 结合纹理特征的SVM海冰分类方法研究[J]. *海洋学报*, 2018, 40(11): 149–156.
Zhang Ming, Lü Xiaoqi, Zhang Xiaofeng, et al. Research on SVM sea ice classification based on texture features[J]. *Haiyang Xuebao*, 2018, 40(11): 149–156.
- [15] 李晓明, 张强. 星载合成孔径雷达北极海冰覆盖观测[J]. *海洋学报*, 2019, 41(4): 145–146.
Li Xiaoming, Zhang Qiang. Observation of Arctic sea ice cover by spaceborne synthetic aperture radar[J]. *Haiyang Xuebao*, 2019, 41(4): 145–146.
- [16] Leigh S, Wang Zhijie, Clausi D A. Automated ice–water classification using dual polarization SAR satellite imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 52(9): 5529–5539.
- [17] Karvonen J A. Baltic sea ice SAR segmentation and classification using modified pulse-coupled neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(7): 1566–1574.
- [18] Wang Chao, Zhang Hong, Wang Yuanyuan, et al. Sea ice classification with convolutional neural networks using sentinel-L ScanSAR images[C]//IGARSS 2018–2018 IEEE International Geoscience and Remote Sensing Symposium. Valencia, Spain: IEEE, 2018: 7125–7128.
- [19] Li Xiaofeng, Liu Bin, Zheng Gang, et al. Deep-learning-based information mining from ocean remote-sensing imagery[J]. *National Science Review*, 2020, 7(10): 1584–1605.
- [20] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436–444.
- [21] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. Red Hook, NY, United States: Curran Associates Inc., 2012: 1097–1105.
- [22] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[C]. San Diego, CA: International Conference on Learning Representations, 2015.
- [23] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 770–778.
- [24] Ren Yibin, Chen Huanfa, Han Yong, et al. A hybrid integrated deep learning model for the prediction of citywide spatio-temporal flow volumes[J]. *International Journal of Geographical Information Science*, 2020, 34(4): 802–823.
- [25] Zhang Xudong, Li Xiaofeng. Combination of satellite observations and machine learning method for internal wave forecast in the Sulu and Celebes seas[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020: 1–11.
- [26] Zheng Gang, Li Xiaofeng, Zhang Ronghua, et al. Purely satellite data–driven deep learning forecast of complicated tropical instability waves[J]. *Science Advances*, 2020, 6(29): eaba1482.
- [27] Li Jinxin, Wang Chao, Wang Shigang, et al. Gaofen-3 sea ice detection based on deep learning[C]//2017 Progress in Electromagnetics Research Symposium-Fall (PIERS-FALL). Singapore, Singapore: IEEE, 2017: 933–939.
- [28] Xu Yan, Scott K A. Sea ice and open water classification of SAR imagery using CNN-based transfer learning[C]//2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Fort Worth, TX, USA: IEEE, 2017: 3262–3265.
- [29] 黄冬梅, 李明慧, 宋巍, 等. 卷积神经网络和深度置信网络在SAR影像冰水分类的性能评估[J]. *中国图象图形学报*, 2018, 23(11): 1720–1732.
Huang Dongmei, Li Minghui, Song Wei, et al. Performance of convolutional neural network and deep belief network in sea ice-water classification using SAR imagery[J]. *Journal of Image and Graphics*, 2018, 23(11): 1720–1732.
- [30] Dierking W. Mapping of different sea ice regimes using images from Sentinel-1 and ALOS Synthetic Aperture Radar[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 48(3): 1045–1058.
- [31] Geldsetzer T, Yackel J J. Sea ice type and open water discrimination using dual co-polarized C-band SAR[J]. *Canadian Journal of Re-*

- remote Sensing, 2009, 35(1): 73–84.
- [32] Fabijańska A. Segmentation of corneal endothelium images using a U-Net-based convolutional neural network[J]. *Artificial Intelligence in Medicine*, 2018, 88: 1–13.
- [33] Lian Sheng, Luo Zhiming, Zhong Zhun, et al. Attention guided U-Net for accurate iris segmentation[J]. *Journal of Visual Communication and Image Representation*, 2018, 56: 296–304.
- [34] Liu Bin, Li Xiaofeng, Zheng Gang. Coastal inundation mapping from bitemporal and dual-polarization SAR imagery based on deep convolutional neural networks[J]. *Journal of Geophysical Research: Oceans*, 2019, 124(12): 9101–9113.
- [35] Shen Dongliang, Liu Bin, Li Xiaofeng. Sea surface wind retrieval from synthetic aperture radar data by deep convolutional neural networks[C]//IGARSS 2019–2019 IEEE International Geoscience and Remote Sensing Symposium. Japan, Yokohama, IEEE, 2019: 8035–8038.
- [36] Fomelis M. ESA sentinel-1 toolbox generation of SAR backscattering mosaics[DB/OL].[2020-06-28]. <http://step.esa.int/main/doc/tutorials/>. 2015.
- [37] Russell B C, Torralba A, Murphy K P, et al. LabelMe: a database and web-based tool for image annotation[J]. *International Journal of Computer Vision*, 2008, 77(1/3): 157–173.
- [38] 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. Munich, Germany: Springer, 2015: 234–241.
- [39] Deepan P, Sudha L R. Object classification of remote sensing image using deep convolutional neural network[M]//Peter D, Alavi A H, Javadi B, et al. The Cognitive Approach in Cloud Computing and Internet of Things Technologies for Surveillance Tracking Systems. London: Academic Press, 2020: 107–120.
- [40] Wang Mingchang, Zhang Xinyue, Niu Xuefeng, et al. Scene classification of high-resolution remotely sensed image based on ResNet[J]. *Journal of Geovisualization and Spatial Analysis*, 2019, 3(2): 16.
- [41] Gao Ligang, Chen Paiyu, Yu Shimeng. Demonstration of convolution kernel operation on resistive cross-point array[J]. *IEEE Electron Device Letters*, 2016, 37(7): 870–873.
- [42] 袁非牛, 章琳, 史劲亭, 等. 自编码神经网络理论及应用综述[J]. *计算机学报*, 2019, 42(1): 203–230.
Yuan Feiniu, Zhang Lin, Shi Jinting, et al. Theories and applications of auto-encoder neural networks: a literature survey[J]. *Chinese Journal of Computers*, 2019, 42(1): 203–230.
- [43] Kingma D, Ba J. Adam: A method for stochastic optimization[C]. San Diego, CA: International Conference on Learning Representations, 2015.

Detecting sea ice of Bohai Sea using SAR images based on a hybrid loss U-Net model

Xu Huan¹, Ren Yibin^{2,3}

(1. School of Marine Technology and Geomatics, Jiangsu Ocean University, Lianyungang 222005, China; 2. Key Laboratory of Ocean Circulation and Waves, Institute of Oceanology, Chinese Academy of Sciences, Qingdao 266071, China; 3. Center for Ocean Mega-Science, Chinese Academy of Sciences, Qingdao 266071, China)

Abstract: The Bohai Sea is an important economic zone of China. Sea ice has been a significant threat to the human activities around the Bohai Sea. As the imaging capability of synthetic aperture radar (SAR) is independent of sun illumination and cloud condition, it is of great significance to detect the sea ice of the Bohai Sea from SAR images. Due to the limitation of the feature extraction mechanism, the accuracies of traditional sea ice detection methods need to be improved. Deep learning has a strong self-learning ability and is suitable for image detection. Here, we employ the well-known deep learning framework, U-Net, as the basic structure, and design a hybrid loss function to optimize the U-Net model, forming a hybrid loss U-Net model for sea ice detection in the Bohai Sea. The Sentinel-1 dual-polarization (VV and VH) SAR images are the inputs of the model. We compare the hybrid loss U-Net model with several traditional methods (Pulse Coupled Neural Network, Markov Random Field and Watershed Algorithm) and deep learning method based on CNN. Experiments show that the hybrid loss U-Net-based model achieves 97.567%, 98.769%, 98.767% and 98.771% in IoU, F1_Score, Precision and Recall respectively, outper-

forming the other methods. Compared with VV single-polarized input, the detection results of dual-polarized information input are 0.375%, 0.111%, 0.639% and 0.740% higher in F1_Score, Precision, Recall and IoU respectively. The detection results of the hybrid loss model are 1.129%, 0.947%, 1.794% and 2.231% higher than those of the non-hybrid loss function in F1_Score, Precision, Recall and IoU respectively. The model could effectively detect details such as ice water line, inter-ice water and ice gap. Our model is applied to detect the sea ice of a whole SAR image in the Bohai Sea, which can provide technical supports for sea ice monitoring, sea ice change analysis and sea ice prediction.

Key words: synthetic aperture radar images; sea ice detection; deep learning; U-Net; a hybrid loss function