



引文格式:叶世榕,罗歆琪,南阳,等.一种改进的星载GNSS-R卷积神经网络海冰检测方法[J].武汉大学学报(信息科学版), 2024, 49(1):90-99.DOI:10.13203/j.whugis20220585

Citation: YE Shirong, LUO Xinqi, NAN Yang, et al. An Improved Sea Ice Detection Method Based on Spaceborne GNSS-R Using CNN[J]. Geomatics and Information Science of Wuhan University, 2024, 49(1):90-99.DOI:10.13203/j.whugis20220585

一种改进的星载GNSS-R卷积神经网络 海冰检测方法

叶世榕¹ 罗歆琪¹ 南阳² 夏朋飞¹

¹ 武汉大学卫星导航定位技术研究中心, 湖北 武汉, 430079

² 天津大学海洋科学与技术学院, 天津, 300072

摘要:卷积神经网络(convolutional neural network, CNN)已用于星载全球导航卫星系统反射测量(global navigation satellite system-reflectometry, GNSS-R)海冰检测,其具有数据预处理简单、最大限度保留反射面信息等优势,但已有GNSS-R CNN海冰检测方法研究的数据集时间跨度较小,代表性有限,且未考虑训练集内海水、海冰时延多普勒图(delay-Doppler map, DDM)的比例对方法泛化能力的影响。针对该问题,首先提出一种筛除畸形DDM方法,有效筛除错误数据;然后,设计合适的CNN结构及参数,通过小样本对比实验发现CNN模型在训练集内海水、海冰DDM的比例为1:1时具有高准确率和最佳泛化能力,并优化数据集选取策略;最后使用2018年全年大样本数据集评估改进的方法在大数据量和大时间跨度时的有效性和可靠性。研究表明,改进的方法通过加强数据质量控制、优化数据集选取策略,提升了CNN海冰检测方法的泛化能力及可靠性,使其更适用于实际应用场景,为海冰消融等研究提供参考。

关键词:卷积神经网络;时延多普勒图;海冰检测;全球导航卫星系统反射测量技术

中图分类号:P237

文献标识码:A

收稿日期:2022-09-15

DOI:10.13203/j.whugis20220585

文章编号:1671-8860(2024)01-0090-10

An Improved Sea Ice Detection Method Based on Spaceborne GNSS-R Using CNN

YE Shirong¹ LUO Xinqi¹ NAN Yang² XIA Pengfei¹

¹ GNSS Research Center, Wuhan University, Wuhan 430079, China

² School of Marine Science and Technology, Tianjin University, Tianjin 300072, China

Abstract: Objectives: Convolutional neural network (CNN) has been used in spaceborne global navigation satellite system-reflectometry (GNSS-R) sea ice detection, which has the advantages of simple data pre-processing and maximum retention of reflector information. However, the data sets used in previous studies of the GNSS-R CNN sea ice detection method have a small span in time and limited representativeness, and the influence of the delay-Doppler map (DDM) ratio of seawater and sea ice in the training set on the generalization ability of the method is not considered. **Methods:** To solve these problems, a method of screening out malformed DDM is proposed. The appropriate CNN structure and parameters are designed, and the dataset selection strategy is optimized through comparative tests of small samples. A large sample dataset from 2018 is used to evaluate the validity and reliability of the improved method in the case of large data volume and large time. **Results and Conclusions:** The results show that the proposed method can screen the wrong data effectively. The CNN model has high accuracy and the best generalization ability when the DDM ratio of seawater and sea ice in the training set is 1 : 1, and the improved method is still

基金项目:国家自然科学基金(41974031);武汉大学测绘遥感信息工程国家重点实验室专项科研经费;国家重点研发计划(2019YFC1509603);中交公规院科技创新专项(C22030A)。

第一作者:叶世榕,博士,教授,主要从事GNSS-R海冰探测研究。srye@whu.edu.cn

通讯作者:罗歆琪,硕士生。xqluo7278@163.com

effective and reliable in large data volume and large time span. The improved method improves the generalization ability and reliability of the CNN sea ice detection method by strengthening data quality control and optimizing the dataset selection strategy, to make it more applicable to practical application scenarios and provide a reference for studies on sea ice melting.

Key words: convolutional neural network (CNN); delay-Doppler map(DDM); sea ice detection; global navigation satellite system-reflectometry (GNSS-R)

海冰作为地球极区重要组成部分,对全球气候变化和海上人类活动有重要影响。在气候方面,海冰相较于海水对太阳辐射有着更大反照率,可以显著减少进入海洋的太阳辐射能^[1]。同时,海冰能够阻碍风场对海水动量的输入,减缓海洋与大气之间的能量交换,是全球气候系统稳定的重要影响因素^[2]。在人类活动方面,海冰会造成港口和航道封锁、海上运输阻断以及海洋工程设施和船只毁坏,阻碍海上资源开采,甚至导致严重灾害^[3]。因此,海冰检测对全球气候研究以及人类活动都具有重要意义。

作为目前海冰研究的主要观测手段,光学遥感受气象条件影响较大,微波遥感重访周期较长且费用较高^[4],新兴的全球导航卫星系统反射测量(global navigation satellite system-reflectometry, GNSS-R)技术可以很好地规避这些问题。GNSS-R利用经地表反射的卫星导航信号,与卫星导航直射信号进行协同处理,根据反射信号相对直射信号在波形、相位、幅度等方面的变化,提取其中携带的地表特征信息^[5]。在提出 GNSS-R 对地观测概念^[6-7]及 GNSS-R 双基雷达前向散射模型^[8]后,GNSS-R 技术飞速发展,观测平台由地基、机载发展到低轨卫星,星载 GNSS-R 进一步发挥了 L 波段双基雷达的优点^[9]。信号发射源由免费且全球覆盖性好的 GNSS 系统提供,无需额外布置信号源^[10],且接收卫星体积小、功耗低,经济成本较低^[11]。另外,星载 GNSS-R 可实现全天候工作,重访周期短,时间分辨率高^[12-14]。目前除已退役的英国 TechDemoSat-1(TDS-1)卫星^[15-16]外,仍有超过 11 颗 GNSS-R 卫星在轨运行,如美国的旋风全球导航卫星系统(cyclone global navigation satellite system, CYGNSS)卫星^[17]、中国风云 3E 卫星^[18-19]和捕风 1 号卫星^[20]等。随着星载 GNSS-R 数据积累,已有学者将该技术应用于海洋^[21]、陆地^[22]和冰冻圈^[23]的地球物理参数反演中。其中,星载 GNSS-R 技术应用于海冰检测的研究起步较晚,目前数据集公开且覆盖地球两极的只有英国 TDS-1 卫星。TDS-1 卫星于 2014 年成功发射,许多学者利用其时延多普勒图(delay-

Doppler map, DDM)观测值研究海冰检测方法。为提高用于后续处理的数据质量,一般需对 DDM 数据进行预处理。文献[26]介绍了几种常见 DDM 数据预处理方法,包括以峰值信噪比(signal-to-noise ratio, SNR)为指标过滤数据、数据对齐、DDM 正常化等;文献[24-26]通过研究海水和海冰的各种 DDM 特征值差异,实现高准确率的海冰检测;机器学习方法也被引入星载 GNSS-R 海冰检测^[27-30]。大部分机器学习方法需自行提取 DDM 特征值,数据预处理较复杂且存在丢失信息风险,而将整幅 DDM 作为输入值的卷积神经网络(convolutional neural network, CNN)算法可简化数据预处理,模型复杂度低且最大限度保留 DDM 所含反射面信息。卷积神经网络是一类包含卷积计算的前馈神经网络,能直接与图像像素进行卷积提取特征值,常用于图像分类,是深度学习代表算法之一^[31-32]。相较于全连接神经网络, CNN 的权值共享属性可降低参数量,提升训练效率并降低网络过拟合的可能^[33],文献[28]验证了 CNN 比全连接神经网络方法更适用于海冰检测。将 CNN 运用于海冰检测可实现自动提取 DDM 特征值,大大减少数据预处理工作量,并通过卷积层中滤波器降低 DDM 噪声。

已有利用机器学习的 GNSS-R 海冰检测研究大都选用 TDS-1 卫星 2 月数据,数据集时间跨度较小,代表性有限,且未对训练集内不同类型数据比例设置进行讨论,缺乏对方法泛化能力和可靠性的研究,在实际应用场景的适用性较为有限。此外, TDS-1 产品中含部分错误数据,可能对机器学习造成负面影响,但在已有研究中未被考虑。本文针对现有问题,首先提出了一种剔除畸形 DDM 的方法以加强数据质量控制,限制天线增益和翻转部分 DDM 以增强数据质量。然后设计合理 CNN 结构,采用合适的初始化方法和优化器,使网络更适用于 DDM 产品。选取 TDS-1 2018 年 2 月数据,通过对比实验,分析数据集内海水和海冰比例对 CNN 海冰检测方法泛化能力的影响,验证已有研究的不足并优化数据集选取策略。最后利用 2018 年全年数据集评估

改进的方法在大数据量和大时间跨度时的有效性及可靠性。

1 数据集和预处理

1.1 数据集

1.1.1 TDS-1 数据

搭载在 TDS-1 卫星上的载荷 SGR-ReSI (space global positioning system receiver remote sensing instrument) 可接收处理 GNSS 反射信号,并于 2014-09 开始下传 DDM 观测数据、接收机及发射机参数等产品,自 2018-02 开始全时段运行至 2018-12。本文选用英国 TDS-1 卫星 2018-02—2018-12 纬度大于 55° 地区的 Level-1B 产品 (ftp.merrbys.co.uk/Data/L1B/)。

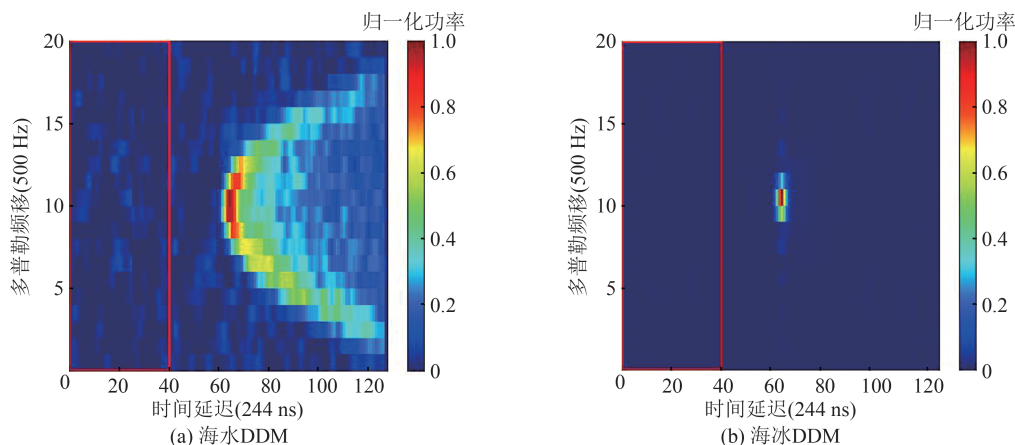


图1 海水和海冰 DDM

Fig. 1 DDMs of Seawater and Sea Ice

1.1.2 参考数据

OSISAF (Ocean and Sea Ice Satellite Application Facility) 隶属于欧洲气象卫星组织,利用传统遥感技术生成的海冰产品可靠性较高,包括海冰密集度、海冰边界和海冰种类等,其中海冰边界产品将海洋表面划分为海水(海冰密集度 $< 30\%$)、开放冰 ($30\% \leq$ 海冰密集度 $< 70\%$) 和密集冰 (海冰密集度 $\geq 70\%$),开放冰和密集冰统称为海冰^[34]。本文采用 OSISAF 海冰边界产品 (ftp://osisaf.met.no) 作为真值训练卷积神经网络,并验证海冰检测结果。

1.2 数据初筛及预处理

受空间几何关系、姿态、天线增益、发射功率、反射面等因素影响,TDS-1 卫星数据质量参差不齐,需进行数据质量控制以筛选出质量较好的 DDM。本文数据质量控制准则如下:(1) TDS-1 数据受热噪声和散斑噪声影响,噪声水平过高的

图 1 给出了 TDS-1 Level-1B 产品中海水和海冰 DDM,时延像素和多普勒像素分别为 128 和 20,反映反射信号在时间延迟和多普勒频移两个方向的分布,图中红色框为相应 DDM 的 $20(\text{多普勒频移}) \times 40(\text{时间延迟})$ 像素窗口。从图 1 可看出,海水 DDM 呈现出典型的马蹄形,而海冰 DDM 在时延多普勒域分布集中,这是因为海水表面较粗糙,反射信号以非相干分量为主,在时延域和多普勒域扩散程度高,而海冰较光滑,反射信号具有更强的相干分量。根据 DDM 形态差异,可区分反射表面是海水还是海冰,从而实现海冰检测。除 DDM 外,本文在海冰检测过程中还使用了 SNR、入射角、天线增益及纬度 4 种信息,其中 SNR 和入射角用于数据质量控制,天线增益用于数据质量增强,纬度用于筛选北极地区数据。

数据无法提供有效反射面信息。采用峰值 SNR 作为衡量 DDM 噪声水平的依据,选取峰值 SNR 大于 0 dB 的数据。(2) GNSS 信号传播到地球表面的角度会影响信号损耗,入射角越大时,路径损耗越大。在海洋表面粗糙度相同时,入射角越大,相干散射分量占比越大,在海冰检测时更易将海水误判为海冰^[35-36],因此,选取卫星入射角小于 35° 的数据^[24,26]。(3) 为避免受 DDM 功率值影响,根据峰值功率将 DDM 归一化,生成正常化 DDM。(4) 受镜面点位置计算误差等因素影响,DDM 峰值点位置出现偏移。为便于检测,将 DDM 中心化,即移动 DDM 峰值点到几何中心位置。

1.3 畸形 DDM 剔除及数据质量增强

1.3.1 畸形 DDM 剔除

DDM 在经过 §1.2 中初筛和预处理后,仍残余畸形 DDM,如图 2 所示。畸形 DDM 是错误观测量,未剔除会降低数据集选取合理性并影响神经

网络训练效果。因此,本文提出一种畸形 DDM 筛除方法。

图 2 展示了两幅畸形 DDM,推测可能是射频干扰和海面上岛礁导致,图中红色框为相应 DDM 的 20(多普勒频移)×40(时间延迟)像素窗口。对比已对齐和归一化后的畸形 DDM(图 2)和正常 DDM(图 1)可看出,正常 DDM 在窗口(图 1 红框区域)内像素值一般较小,而畸形 DDM 窗口(图 2 红框区域)内则含有较高信号值的像素。因此,引入特征值 $A_{DDM}^{[37]}$,定义为对齐和归一化后 DDM 的 20(多普勒频移)×40(时间延迟)窗口的归一化功率均值,其中时间延迟从 0 侧开始选取,计算如下:

$$A_{DDM}^{20 \times 40} = \frac{\sum_{i=1, j=1}^{i=20, j=40} P_{i,j}^N}{800} \quad (1)$$





图 2 畸形 DDM

Fig. 2 Malformed DDM




图 3 筛除效果随阈值变化图

Fig. 3 Change of Screening Effect with Threshold

由图 3 可知,随着阈值的增大,筛除率先维持在 100% 再逐渐下降,筛除准确率逐渐上升至 100%,误筛除率逐渐下降至 0。由于在海冰检测

式中, $P_{i,j}^N$ 为第 i 个多普勒像素、第 j 个时延像素对应的归一化功率值。将 $A_{DDM}^{20 \times 40}$ 大于设定阈值的 DDM 判定为畸形 DDM,予以筛除。

为了确定最优阈值,从 2018 年全年所有 DDM 中随机抽取 10 000 张,以 0.001 为间隔,统计阈值从 0~0.05 对应的筛除率、筛除准确率、误筛除率,结果如图 3 所示。其中,筛除率表示筛除成功的畸形 DDM 在所有畸形 DDM 中的占比,体现方法对畸形 DDM 的筛除能力;筛除准确率表示畸形 DDM 在所有被筛除的 DDM 中的占比;误筛除率表示被筛除的正常 DDM 在所有正常 DDM 中的占比,筛除准确率和误筛除率共同体现方法对正常和畸形 DDM 的识别能力。

领域 DDM 数据量较为充足,且正常 DDM 数量远多于畸形 DDM,在评估筛除效果时优先考虑方法对畸形 DDM 的筛除能力,即筛除率是更为重要的指标。因此,设定畸形 DDM 筛除方法的阈值为 0.02,此时筛除率为 100%,筛除准确率为 95.38%,误筛除率为 0.03%,说明本文方法能够在最大限度保持数据完整度的前提下有效筛除畸形 DDM。

采用本文方法筛除 2018 年数据集内畸形 DDM,统计不同月份数据集内畸形 DDM 占比,结果如表 1 所示。由表 1 可知,畸形 DDM 占比在部分月份浮动较大,最高达 9.95%,而全年数据集内畸形 DDM 占比约 0.52%。统计本文方法在畸形 DDM 占比最大的 10 月数据集上的筛除率、筛除准确率和误筛除率,分别为 100%、95.70% 和 0.47%,验证了方法的有效性。

表1 2018年数据集内畸形DDM占比
Tab. 1 Proportion of Malformed DDM in the
2018 Dataset

时间	筛除前	畸形DDM数	筛除后	畸形DDM占比/%
2月	78 316	610	77 706	0.78
3月	107 747	320	107 427	0.30
4月	109 785	636	109 149	0.58
5月	23 401	91	23 310	0.39
6月	51 234	57	51 177	0.11
7月	149 113	388	148 725	0.26
8月	103 184	243	102 941	0.24
9月	44 695	34	44 661	0.08
10月	935	93	842	9.95
11月	92 676	1 570	91 106	1.69
12月	57 048	245	56 803	0.43
全年	818 134	4 287	813 847	0.52

1.3.2 数据质量增强

在神经网络训练过程中,为提高模型泛化能力和鲁棒性,可采用翻转、旋转和人为添加噪声等方法增强数据质量,改善网络效果^[38],因此分别设置1/3概率对DDM左右翻转、上下翻转和保持不变。由于天线增益会影响反射信号SNR,天线增益较低时数据质量较差,准备数据集时将天线增益值小于3 dB的DDM移入总训练集,再随机将剩余DDM分为两部分,并使总训练集和总测试集大小约为4:3,从而确保测试集内DDM天

线增益大于3 dB,而训练集内DDM的天线增益不进行控制,以此降低训练集数据质量,增加训练数据多样性。

2 基于CNN的海冰检测方法研究

CNN通常包括输入层、卷积层、池化层、全连接层和输出层。卷积层提取输入数据的特征,经过激活函数的非线性处理产生特征图。池化层能在保留有用信息的基础上减少数据处理量,提升网络训练效率。全连接层每个节点都与上一层所有节点相连,在CNN中起到分类器的作用。在将CNN运用到海冰检测时,需准备预处理后的训练集、测试集,将训练集内DDM作为输入进行训练,更新神经网络参数,而测试集用于检验准确率,不影响神经网络参数更新。

本文基于经典卷积神经网络LeNet-5^[39],根据DDM图像尺寸较小和像素矩阵较为稀疏的特点,减小卷积核大小并修改部分网络模型训练相关的超参数,设计CNN结构如图4所示,由3个卷积层(C1、C2、C3)、两个池化层(S1、S2)和两个全连接层组成。3个卷积层分别采用4个3×3的卷积核、8个2×2的卷积核和16个2×2的卷积核,卷积核与该层输入的图像做卷积处理,经过ReLU(rectified linear unit)激活函数生成新的特征图。ReLU函数可表示为:

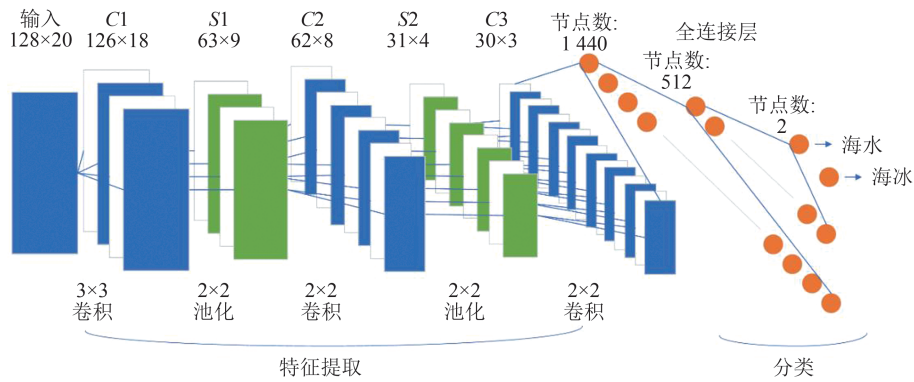


图4 采用的卷积神经网络结构

Fig. 4 Structure of Employed CNN

$$h(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (2)$$

在初始化CNN模型时,采用和ReLU激活函数更匹配的Kaiming初始化,其服从正态分布 $N(0, s^2)$,其中, s 可表示为:

$$s = \sqrt{\frac{2}{(1 + a^2) \times N_{in}}} \quad (3)$$

式中, s 表示标准差; N_{in} 为输入神经元个数; a 为默

认值0。

优化器选用更加适合稀疏网络分类问题的Adam优化器,学习率设置为0.001。与已有利用CNN进行海冰检测的研究采用的随机初始化和带动量的随机梯度下降(stochastic gradient descent with momentum, SGDM)优化器相比,此模型更不易陷入局部最优,准确率也有所提升。

损失函数是神经网络寻找最优权重参数的

指标,本文经实验对比后采用交叉熵损失函数。为降低过拟合,在两个全连接层后使用随机失活(dropout)方法,分别设置 0.2 和 0.1 的概率将节点丢弃。输出层设置两个节点,softmax 作为激活函数使两个输出节点输出值范围在 $[0, 1]$,且输出值之和为 1,输出值更大的节点为最终分类结果,实现海水和海冰二分类。本文海冰检测方法流程图如图 5 所示。

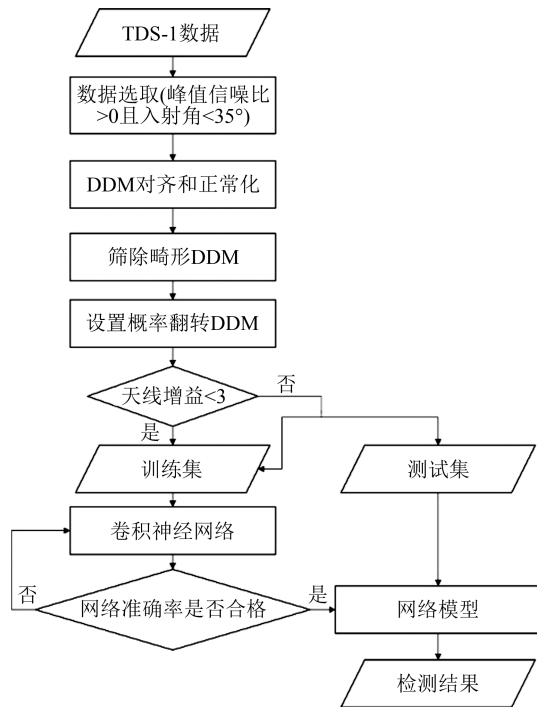


图 5 CNN 海冰检测流程

Fig. 5 CNN Sea Ice Detection Process

3 实验与结果分析

首先选取小样本的 2018-02 数据,初步评估本文方法的海冰检测准确率,并通过设置不同海水与海冰 DDM 比例的数据集研究数据集内水冰比对检测效果和方法泛化能力的影响,再使用筛除畸形 DDM 前后的数据重复以上实验。根据实验结果优化数据集选取策略后,使用大样本的 2018 年全年数据验证改进的方法在大数据量和大时间跨度时的可靠性。

3.1 实验设计

为对比实验效果,选取 2018-02 数据,固定训练集和测试集样本大小,设置训练集样本大小为 8 000,测试集样本大小为 6 000。此外,为研究数据集内海水与海冰 DDM 比例对训练效果的影响,设置 13 种水冰比例,训练集依次记为 A~M,测试集依次记为 $a\sim m$ 。表 2 为实验数据集内海水和海冰 DDM 分布情况。将每个训练集训练

表 2 不同海水-海冰比例的数据集

Tab. 2 Data Sets for Different Seawater-Sea Ice Ratios

海水:海冰	训练集名称	训练集	测试集名称	测试集
7:1	A	7 000:1 000	a	5 250:750
6:1	B	6 857:1 143	b	5 143:857
5:1	C	6 667:1 333	c	5 000:1 000
4:1	D	6 400:1 600	d	4 800:1 200
3:1	E	6 000:2 000	e	4 500:1 500
2:1	F	5 333:2 667	f	4 000:2 000
1:1	G	4 000:4 000	g	3 000:3 000
1:2	H	2 667:5 333	h	2 000:4 000
1:3	I	2 000:6 000	i	1 500:4 500
1:4	J	1 600:6 400	j	1 200:4 800
1:5	K	1 333:6 667	k	1 000:5 000
1:6	L	1 143:6 857	l	857:5 143
1:7	M	1 000:7 000	m	750:5 250

500 个历元,用每个历元所得神经网络模型测试所有测试集,得到共 13×13 组实验结果。为定量分析筛除畸形 DDM 对海冰检测的影响,分别使用未筛除和已筛除畸形 DDM 的数据重复以上实验。

3.2 实验结果分析

3.2.1 海冰检测准确率分析

计算准确率已趋于稳定的 300~500 历元平均值作为每个实验组最终准确率。表 3 给出了筛除畸形 DDM 前后海冰检测准确率统计情况,可看出筛除畸形 DDM 前,所有实验组海冰检测准确率均在 89% 以上,最高准确率为 98.00%;筛除畸形 DDM 后,所有实验组海冰检测准确率均在 90% 以上,最高准确率为 98.44%,说明方法有较高的海冰检测准确率。

表 3 筛除畸形 DDM 前后海冰检测准确率/%

Tab. 3 Sea Ice Detection Accuracy Before and After Removing Malformed DDM/%

实验组	最高准确率	最低准确率	平均准确率
筛除前	98.00	89.54	94.83
筛除后	98.44	90.35	95.33

图 6 给出了筛除畸形 DDM 前后海冰检测准确率对比,图中准确率为每个训练集对应所有测试集($a\sim m$)海冰检测准确率均值。从图 6 可以看出,每个训练集对应所有测试集($a\sim m$)的检测准确率均值在筛除畸形 DDM 后均有所提升。计算所有实验组在筛除数据前、后的检测准确率均值,分别为 94.83%、95.33%,得出本实验中海冰检测准确率在筛除畸形 DDM 后约有 0.5% 的提





图6 筛除畸形DDM前后准确率对比

Fig. 6 Comparison of Accuracy Before and After Removing Malformed DDM

升,提升幅度与2月数据集内畸形DDM占比相当。但由于畸形DDM占比在各月浮动较大,且畸形DDM在原始数据集内常连续出现,在数据量及时间跨度较小的实际应用场景下无法预估畸形DDM在数据集内的占比,导致该场景下方法的稳定性降低,因此有必要筛除。

3.2.2 方法泛化能力分析

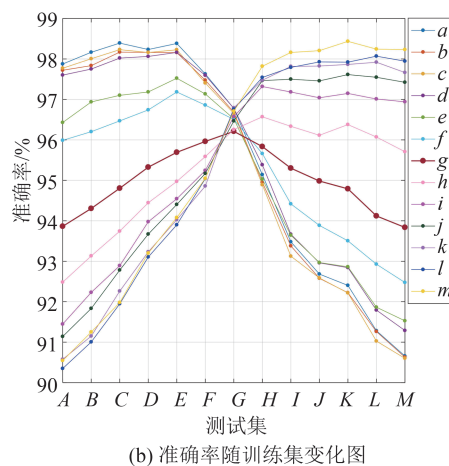
图7为筛除畸形DDM后所有实验组海冰检



(a) 准确率随测试集变化图

测准确率随数据集内水冰比变化情况,图8给出了海冰检测准确率均方差变化,此均方差表示每个训练集(A~M)所得网络模型在所有测试集(a~m)上检测准确率的均方差。

从图7(a)可以看出,当训练集内水冰比大于1(训练集A~F)时,检测准确率随着测试集内水冰比减小而减小;当训练集内水冰比小于1(训练集H~M)时,检测准确率随着测试集内水冰比减小而增大;当训练集内水冰比等于1(训练集G)时,其在各测试集上的海冰检测准确率仅在较小范围内波动,较为稳定。从图7(b)可以看出,当训练集内水冰比等于1(训练集G)时,其在各测试集(a~m)上的检测准确率较为集中,平均准确率为96.68%,最高准确率与最低准确率差值仅为0.58%;当训练集内水冰比不等于1时,其在各测试集上的检测准确率波动较大,最高准确率与最低准确率差值最高达7.63%,且训练集内水冰比越接近1时该波动越小,即模型泛化能力越强。因此,在图6和图8中,随着训练集内水冰比减小(训练集A~M),平均准确率先增大后减小,在比值为1时达到最大值;均方差先减小后增大,在比值为1时达到最小值。



(b) 准确率随训练集变化图

图7 海冰检测准确率变化图

Fig. 7 Accuracy Change of Sea Ice Detection

研究表明,当训练集内水冰比为1时,训练所得CNN模型能在各种水冰比的测试集内以最小波动和高准确率完成海冰检测,优于其他水冰比的训练集所得CNN模型。若以时间为标准选取数据,仅采用水冰比约1:4的2月数据作为训练集,所得模型泛化能力有限。因此,本文优化了CNN海冰检测方法的数据集选取策略,将训练集内水冰比设置为1,使所得CNN模型泛化能力更强,能够更好地适应水冰比未知或时间跨度较大

的实际应用场景。

3.2.3 方法可靠性分析

经筛除畸形数据和优化数据集选取策略后,本文方法的高准确率及强泛化能力已在2018-02数据集中得到初步验证,但为避免数据量和时间跨度较小导致数据代表性不足,仍需进一步实验验证。因此,从筛除畸形数据后的2018年全年数据中随机抽取80 000张DDM组成训练集,控制其水冰比为1:1,将训练所得模型在包含813 843张DDM的




图 8 海冰检测准确率均方差变化图

Fig. 8 Accuracy Change of Mean Square Error of Sea Ice Detection

2018年全年数据集中测试,准确率为95.11%,能较好完成海冰检测,证明改进的海冰检测方法可靠。

值得注意的是,全年海冰检测准确率与由2月数据组成的训练集G在各测试集(a~m)上平均准确率96.68%相比较低。根据文献[23],冰水混合区域更易呈现出与海水表面相似的特征,检测时更易误判为水,导致准确率降低,因此推测全年海冰检测准确率相比2月较低的原因是全年冰水混合区域相比2月更多。

表4给出了2月与全年数据集内开放冰在海冰中的占比对比。由表4可知,全年开放冰的占比与2月相比较大,即全年冰水混合区域更多。为进一步验证数据集内开放冰的比例对检测准确率的影响,从筛除畸形DDM后的全年数据中随机抽取组成同样大小和水冰比的两组数据集,数据集内开放冰比例分别与2月(13.70%)和全年(23.30%)相同,两组海冰检测准确率的对比如表5所示。

表 4 2018-02与全年数据集内开放冰 DDM 占比对比

Tab. 4 Comparison of Open Ice DDM in February and the Whole Year

数据集	DDM 总数	海冰	开放冰	开放冰/海冰/%	准确率/%
2月	77 706	61 858	8 477	13.70	96.68
全年	813 843	461 161	107 402	23.30	95.11

由表5可知,在其他条件相同时,数据集内开放冰的占比较大时,海冰检测准确率更低,因此在使用开放冰占比更大的全年数据集进行海冰检测时更易发生误判,其准确率较2月更低,但仍能以高准确率、泛化能力及可靠性完成海冰检测。

表 5 不同开放冰比例的海冰检测准确率对比

Tab. 5 Accuracy Comparison of Sea Ice Detection with Different Open Ice Ratios

数据来源	训练集	测试集	数据集内水冰比	开放冰/海冰/%	准确率/%
全年	20 000	10 000	1:1	13.70	96.17
全年	20 000	10 000	1:1	23.30	94.42

4 结 语

本文针对已有研究在数据代表性和方法泛化能力的不足,对星载 GNSS-R 卷积神经网络海冰检测方法进行研究和改进,并得出如下结论:

1)冰水混合区域在检测时更易发生误判,训练集内水冰比也会影响神经网络方法在不同测试集上的表现,仅以时间为标准选取时间跨度较小、冰水混合区域较少且水冰比不均衡的2月数据会导致数据代表性有限。

2)本文方法提出的筛除畸形DDM方法能够在最大限度保持数据完整性的同时有效剔除TDS-1数据集中的异常数据,加强数据质量控制,进而提升该方法在数据量及时间跨度较小的实际应用场景下的稳定性。

3)训练集内水冰比为1:1时所得CNN模型具有最好泛化能力和较高检测准确率,更适用于水冰比未知的实际应用场景,因此应对数据集选取策略进行优化,在数据集选取时将训练集内水冰比设置为1:1。

本文改进的方法通过加强数据质量控制和优化数据集选取策略,提升方法泛化能力和可靠性,使其更适用于复杂的实际应用场景,是一种更稳定且更有效的星载 GNSS-R 海冰检测方法,可为今后星载 GNSS-R 冰水混合物、海冰消融等研究提供参考。随着 GNSS 系统的完善及未来星载 GNSS-R 在有效载荷的质量和数量上的进一步发展,相信更高时空分辨率、更高质量的 GNSS-R 观测数据会给冰冻圈遥感带来更多创新方法和应用,从而为全球气候变化研究和人类海上活动提供有效帮助。

参 考 文 献

[1] Liu Tingting, Yang Zijian, Wang Zemin, et al. Evaluation of Arctic Sea Ice Concentration Estimated by Fengyun-3D Microwave Radiation Imager [J]. *Geomatics and Information Science of Wuhan University*, 2021, 46(12): 1843-1851. (刘婷婷, 杨子健, 王泽民, 等. 利用风云3D微波成像仪数据估算

- 北极海冰密集度的精度评价[J]. 武汉大学学报(信息科学版), 2021, 46(12): 1843-1851.)
- [2] Ke Changqing, Peng Haitao, Sun Bo, et al. Spatio-temporal Variability of Arctic Sea Ice from 2002 to 2011[J]. *Journal of Remote Sensing*, 2013, 17(2): 459-466. (柯长青, 彭海涛, 孙波, 等. 2002—2011年北极海冰时空变化分析[J]. 遥感学报, 2013, 17(2): 459-466.)
- [3] Zhang Ming, Lü Xiaoqi, Zhang Xiaofeng, et al. Research on SVM Sea Ice Classification Based on Texture Features[J]. *Acta Oceanologica Sinica*, 2018, 40(11): 149-156. (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.)
- [4] Meng Wanting. Research on Sea Ice Detection Based on GNSS Reflected Signal[D]. Shanghai: Shanghai Ocean University, 2016. (孟婉婷. 基于GNSS反射信号的海冰检测的研究[D]. 上海: 上海海洋大学, 2016.)
- [5] Yang Dongkai, Li Xiaohui, Wang Feng. Analysis of Application Status of GNSS Reflected Signal in Ocean Remote Sensing [J]. *Radio Engineering*, 2019, 49(10): 843-848. (杨东凯, 李晓辉, 王峰. GNSS反射信号海洋遥感应用现状分析[J]. 无线电工程, 2019, 49(10): 843-848.)
- [6] Hall C D, Cordey R A. Multistatic Scatterometry [C]//International Geoscience and Remote Sensing Symposium, Remote Sensing: Moving Toward the 21st Century, Edinburgh, UK, 2002.
- [7] Martín-Neira M. A Passive Reflectometry and Interferometry System (PARIS) Application to Ocean Altimetry [J]. *ESA Journal*, 1993, 17(4): 331-355.
- [8] Zavorotny V U, Voronovich A G. Scattering of GPS Signals from the Ocean with Wind Remote Sensing Application[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2000, 38(2): 951-964.
- [9] Du Hao, Guo Wenfei, Guo Chi, et al. Adaptively CDF Matching Method in GNSS-R Wind Speed Retrieval[J]. *Geomatics and Information Science of Wuhan University*, 2021, 46(12): 1924-1931. (杜皓, 郭文飞, 郭迟, 等. 针对GNSS-R海面风速反演的自适应CDF匹配方法[J]. 武汉大学学报(信息科学版), 2021, 46(12): 1924-1931.)
- [10] Wan Wei, Li Huang, Hong Yang, et al. Definition and Application of GNSS-R Observation Patterns [J]. *Journal of Remote Sensing*, 2015, 19(6): 882-893. (万玮, 李黄, 洪阳, 等. GNSS-R遥感观测模式及陆面应用[J]. 遥感学报, 2015, 19(6): 882-893.)
- [11] Zhang Guodong, Guo Jian, Yang Dongkai, et al. Sea Ice Edge Detection Using Spaceborne GNSS-R Signal [J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(5): 668-674. (张国栋, 郭健, 杨东凯, 等. 星载GNSS-R海冰边界探测方法[J]. 武汉大学学报(信息科学版), 2019, 44(5): 668-674.)
- [12] Yan Songhua, Tang Fengyu, Chen Yongqian, et al. Review of Deformation Monitoring Based on GNSS-R Technology [J]. *Radio Engineering*, 2021, 51(10): 1086-1092. (严颂华, 唐风雨, 陈永谦, 等. GNSS-R形变监测技术综述[J]. 无线电工程, 2021, 51(10): 1086-1092.)
- [13] Di Simone A, Park H, Riccio D, et al. Sea Target Detection Using Spaceborne GNSS-R Delay-Doppler Maps: Theory and Experimental Proof of Concept Using TDS-1 Data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(9): 4237-4255.
- [14] Zhu Yongchao, Zou Jingui, Yu Kegen. A New Sea Ice Distribution Detection Method Using GNSS Reflected Signals[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(10): 1472-1477. (朱勇超, 邹进贵, 余科根. 一种使用卫星反射信号探测海冰分布新方法[J]. 武汉大学学报(信息科学版), 2018, 43(10): 1472-1477.)
- [15] Unwin M, Jales P, Tye J, et al. Spaceborne GNSS-Reflectometry on TechDemoSat-1: Early Mission Operations and Exploitation[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(10): 4525-4539.
- [16] Zhu Y C, Yu K G, Zou J G, et al. Sea Ice Detection Based on Differential Delay-Doppler Maps from UK TechDemoSat-1 [J]. *Sensors*, 2017, 17(7): 1614.
- [17] Ruf C, Chang P, Clarizia M P, et al. CYGNSS Handbook[M]. Ann Arbor: Michigan Pub., 2016.
- [18] Sun Y Q, Wang X Y, Du Q F, et al. The Status and Progress of Fengyun-3e GNOS II Mission for GNSS Remote Sensing [C]// IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japan, 2019.
- [19] Zhang P, Hu X Q, Lu Q F, et al. FY-3E: The First Operational Meteorological Satellite Mission in an Early Morning Orbit[J]. *Advances in Atmospheric Sciences*, 2022, 39(1): 1-8.
- [20] Jing C, Niu X L, Duan C D, et al. Sea Surface Wind Speed Retrieval from the First Chinese GNSS-R Mission: Technique and Preliminary Results[J].

- Remote Sensing*, 2019, 11(24): 3013.
- [21] Foti G, Gommenginger C, Jales P, et al. Spaceborne GNSS Reflectometry for Ocean Winds: First Results from the UK TechDemoSat-1 Mission[J]. *Geophysical Research Letters*, 2015, 42(13): 5435-5441.
- [22] Chew C, Shah R, Zuffada C, et al. Demonstrating Soil Moisture Remote Sensing with Observations from the UK TechDemoSat-1 Satellite Mission[J]. *Geophysical Research Letters*, 2016, 43(7): 3317-3324.
- [23] Li W Q, Cardellach E, Fabra F, et al. First Spaceborne Phase Altimetry over Sea Ice Using TechDemoSat-1 GNSS-R Signals[J]. *Geophysical Research Letters*, 2017, 44(16): 8369-8376.
- [24] Yan Q Y, Huang W M. Spaceborne GNSS-R Sea Ice Detection Using Delay-Doppler Maps: First Results from the U. K. TechDemoSat-1 Mission[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(10): 4795-4801.
- [25] Alonso-Arroyo A, Zavorotny V U, Camps A. Sea Ice Detection Using UK TDS-1 GNSS-R Data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(9): 4989-5001.
- [26] Zhu Yongchao. Study of Spaceborne GNSS-R for Sea Ice Detection and Sea Ice Concentration Retrieval Methods[D]. Wuhan: Wuhan University, 2018. (朱勇超. 星载GNSS-R海冰检测与海冰密集度反演方法研究[D]. 武汉: 武汉大学, 2018.)
- [27] Yan Q Y, Huang W M, Moloney C. Neural Networks Based Sea Ice Detection and Concentration Retrieval from GNSS-R Delay-Doppler Maps[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(8): 3789-3798.
- [28] Yan Q Y, Huang W M. Sea Ice Sensing from GNSS-R Data Using Convolutional Neural Networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(10): 1510-1514.
- [29] Yan Q Y, Huang W M. Detecting Sea Ice from TechDemoSat-1 Data Using Support Vector Machines with Feature Selection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(5): 1409-1416.
- [30] Shao Lianjun, Hu Lei, Li Bing, et al. Sea Ice Detection Using Spaceborne GNSS-R Data by CART Decision Tree[J]. *Hydrographic Surveying and Charting*, 2021, 41(1): 70-74. (邵连军, 胡磊, 李冰, 等. 基于CART决策树的星载GNSS-R海冰检测方法[J]. 海洋测绘, 2021, 41(1): 70-74.)
- [31] Yang Zhenzhen, Kuang Nan, Fan Lu, et al. Review of Image Classification Algorithms Based on Convolutional Neural Networks[J]. *Journal of Signal Processing*, 2018, 34(12): 1474-1489. (杨真真, 匡楠, 范露, 等. 基于卷积神经网络的图像分类算法综述[J]. 信号处理, 2018, 34(12): 1474-1489.)
- [32] Wu Zhengwen. Research on the Application of Convolutional Neural Network in Image Classification[D]. Chengdu: University of Electronic Science and Technology of China, 2015. (吴正文. 卷积神经网络在图像分类中的应用研究[D]. 成都: 电子科技大学, 2015.)
- [33] Peng X, Zhang X, Li Y, et al. Research on Image Feature Extraction and Retrieval Algorithms Based on Convolutional Neural Network[J]. *Journal of Visual Communication and Image Representation*, 2020, 69: 102705.
- [34] Wang K G, Debernard J, Sperrevik A K, et al. A Combined Optimal Interpolation and Nudging Scheme to Assimilate OSISAF Sea-Ice Concentration into ROMS[J]. *Annals of Glaciology*, 2013, 54(62): 8-12.
- [35] Cardellach E, Li W Q, Rius A, et al. First Precise Spaceborne Sea Surface Altimetry with GNSS Reflected Signals[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 13: 102-112.
- [36] Yang Dongkai, Zhang Qishan. GNSS Reflected Signal Processing: Fundamentals and Applications[M]. Beijing: Publishing House of Electronics Industry, 2012. (杨东凯, 张其善. GNSS反射信号处理基础与实践[M]. 北京: 电子工业出版社, 2012.)
- [37] Clarizia M P, Ruf C S. Wind Speed Retrieval Algorithm for the Cyclone Global Navigation Satellite System (CYGNSS) Mission[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 4419-4432.
- [38] Gao Zhenyu. Research and Application of Image Classification Method Based on Deep Convolution Neural Network[D]. Hefei: University of Science and Technology of China, 2018. (高震宇. 基于深度卷积神经网络的图像分类方法研究及应用[D]. 合肥: 中国科学技术大学, 2018.)
- [39] LeCun Y, Bottou L, Bengio Y, et al. Gradient-Based Learning Applied to Document Recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.