

激光与光电子学进展

利用多通道加权投票的机载绿激光海陆波形分类

赵兴磊^{1*}, 梁刚¹, 赵建虎², 周丰年³¹山东农业大学信息科学与工程学院, 山东 泰安 271018;²武汉大学测绘学院, 湖北 武汉 430079;³长江水利委员会水文局长江口水文水资源勘测局, 上海 200136

摘要 为解决复杂海陆环境下机载绿激光海陆波形分类精度低的问题,本文提出了一种利用多通道加权投票的绿激光海陆波形分类方法,即多通道加权投票卷积神经网络(MWV-CNN)。首先,将绿激光深水和浅水通道采集的多通道波形经一个多通道输入模块分别输入到本文搭建的一维卷积神经网络(1D CNN)模块中;然后,各1D CNN模块对每个通道波形分别进行处理,获得各通道波形属于海洋和陆地类别的预测得分;最后,将各通道预测得分视为权值,利用一个多通道融合模块进行加权投票,确定波形最终类别。采用Optech CZMIL对中国连云港市沿海水域的实测数据进行实验验证,结果表明,MWV-CNN的总体分类精度、Kappa系数和总体精度标准差分别为99.45%、0.982和0.02%。与传统绿激光海陆波形分类方法相比,本文方法具有更好的分类精度和鲁棒性,为实现机载绿激光高精度海陆波形分类提供了一种新的有效途径。

关键词 大气光学与海洋光学; 机载激光雷达测深; 海陆波形分类; 绿激光多通道波形; 深度学习; 加权投票

中图分类号 P229

文献标志码 A

DOI: 10.3788/LOP223239

Ocean-Land Waveform Classification Based on Multichannel Weighted Voting of Airborne Green Laser

Zhao Xinglei^{1*}, Liang Gang¹, Zhao Jianhu², Zhou Fengnian³¹College of Information Science and Engineering, Shandong Agricultural University, Tai'an 271018, Shandong, China;²School of Geodesy and Geomatics, Wuhan University, Wuhan 430079, Hubei, China;³The Survey Bureau of Hydrology and Water Resources of Yangtze Estuary, Shanghai 200136, China

Abstract In order to improve the accuracy of ocean-land waveform classifications of airborne green lasers in complex ocean-land environments, an ocean-land waveform classification method based on multichannel weighted voting [i. e., multichannel weighted voting convolutional neural network (MWV-CNN)] is proposed. First, the multichannel green laser waveforms collected in the deep and shallow channels are input into the proposed one-dimensional convolutional neural network (1D CNN) module through a multichannel input module. Second, each 1D CNN module processes each channel waveform separately to obtain the predicted scores for each channel waveform belonging to the ocean and land categories. Finally, the predicted score of each channel is treated as weight, and a multichannel fusion module is used to determine the final waveform category via weighted voting. The measured data in the coastal waters of Lianyungang, China are verified by experiment using Optech CZMIL. The results indicate that the overall classification accuracy, Kappa coefficient, and overall accuracy standard deviation of MWV-CNN are 99.45%, 0.982, and 0.02%, respectively, and as compared with traditional ocean-land waveform classification methods, the proposed method exhibits better classification accuracy and robustness, thus providing a new effective way for realizing ocean-land waveform classification of airborne green laser with high accuracy.

Key words atmospheric optics and ocean optics; airborne LiDAR bathymetry; ocean-land waveform classification; green laser multichannel waveforms; deep learning; weighted voting

1 引言

机载激光测深(ALB)是一种主动发射蓝绿波段

激光脉冲并接收激光回波信号的浅水测量技术,具有高效、灵活、经济和安全等优点^[1-2],已被成功应用在水深测量、海陆识别、悬沙浓度反演、海面波浪分析和海

收稿日期: 2022-12-05; 修回日期: 2022-12-15; 录用日期: 2022-12-23; 网络首发日期: 2023-01-05

基金项目: 国家自然科学基金(41906166)

通信作者: *xingleizhao@126.com

底质分类等领域^[3]。ALB系统可分为单频和双频系统,单频ALB系统(如Fugro LADS-MK3)通常发射波长为532 nm的绿激光探测水面和水底^[2]。绿激光水面回波是气海交界面回波和水体后向散射回波的叠加,该叠加效应导致绿激光探测的海面点存在偏差,即绿激光存在水面不确定性问题^[2,4]。为克服绿激光水面不确定性问题,双频ALB系统(如Optech CZMIL)发射波长为1064 nm的红外激光和532 nm的绿激光分别用于探测水面和水底^[2,4]。双频ALB系统利用红外激光能准确探测海面,但系统复杂度高、体积重量相对较大。单频ALB系统仅采用绿激光波段,体积重量较小。但目前大部分ALB系统体积重量均较大,需要搭载于载重量大的有人驾驶飞机,由此带来测量成本高等不足,限制了ALB技术的应用和普及。相比有人驾驶飞机,无人机更加灵活方便、飞行成本低。如能将ALB系统搭载于无人机,可大大提高ALB测量的灵活性并降低测量成本。目前,RIEGL公司推出了基于无人机平台的BDF-1 ALB系统,山东科技大学、桂林理工大学^[5]等单位开展了无人机ALB系统研发。另外,为实现水深测量和地形测量模式之间的无缝转换,越来越多的ALB系统通过分割接收望远镜视场角(FOV)来接收多个通道的绿激光波形^[6]。

ALB系统通过接收从海洋和陆地反射的激光脉冲信号,获得海洋和陆地回波波形,实现海陆一体化测量^[3]。典型的陆地波形包括从植被和陆地表面反射的多次回波,而典型的海洋波形包括海面、海水后向散射和海底回波^[1]。海洋和陆地波形的处理方法不同,因此必须对ALB系统采集的原始波形进行海洋和陆地波形分类。海陆波形分类是ALB数据处理中关键的基础性工作。

目前,ALB海陆波形分类方法主要有三种:红外激光波形饱和法^[7]、红激光通道辅助法^[8]、波形特征法^[9-11]。Guenther^[1]最早提出了红外激光波形饱和法,并被Collin等^[7]成功应用在Optech SHOALS系列ALB海陆波形分类中。但随着ALB技术的发展,ALB系统中的模数转换器可以实现全波形信号记录,此时陆地的红外激光波形可能不再饱和。

由于拉曼散射效应,射入水体的532 nm绿激光中少部分光子波长产生变化,产生约647 nm的红激光信号^[9]。利用该现象,部分ALB系统(如Optech SHOALS系列)通过添加红激光通道接收红激光脉冲回波实现海陆波形分类^[8]。但激发拉曼信号需要很强的激光能量,且添加红激光接收通道会增加ALB系统复杂度,现代主流的ALB系统,如Optech CZMIL、AHAB HawkEye III、Fugro LADS-MK3和RIEGL VQ-880-G等,均未配备红激光接收通道^[9]。因此,红激光通道辅助法的适用性较差。

海洋和陆地的红外激光波形特征存在显著差异,陆地的红外激光波形振幅通常大于海洋的红外激光波

形振幅。利用红外激光波形特征可以实现高精度海陆波形分类^[3]。海洋和陆地的绿激光波形特征也不同,绿激光波形特征有助于提高海陆波形分类的总体精度^[9-11]。通过提取并组合红外激光和绿激光的波形特征,如振幅、半峰全宽、面积以及红外激光和绿激光波形的振幅比等,利用支持向量机(SVM)建立分类模型^[9-11]或采用深度学习方法自动提取特征^[12]进行海陆波形分类,是目前常用的分类方法。

理论上,仅使用绿激光波形即可实现海陆波形分类,这对于仅使用绿激光的单频ALB系统尤为重要^[9,13-14]。但鉴于复杂海陆环境下绿激光特性,该目标并不容易实现^[13]。在极浅水域,绿激光波形的海面、海水后向散射和海底回波叠加为单个回波,这种极浅水域波形叠加效应导致极浅水域绿激光波形与陆地的绿激光波形相似,因此容易被误分类为陆地^[14]。陆地特殊地形也会导致某些陆地的绿激光波形与典型的海洋绿激光波形相似,而被误分类为海洋^[14]。这些误分类波形降低了绿激光海陆波形分类精度。目前,通过提取绿激光波形特征利用模糊C均值聚类^[14]或SVM^[9]进行海陆波形分类的总体精度明显低于使用红外激光波形特征的海陆波形分类。原始绿激光波形包含了更多尚未利用的信息,深度学习可以自动提取出未发现的特征,最大限度地提高分类精度。胡善江等^[12]基于深度学习方法对ALB海陆波形进行分类,该方法具有较高精度和效率,但同时采用红外和绿激光波形,不适用单频ALB海陆波形分类。Liang等^[15]综合利用多通道绿激光波形,基于深度学习方法有效提高了单频ALB海陆波形分类精度。该方法采用多通道投票方法确定波形类别,但未考虑每个通道的权重信息。

综上,相比红外激光海陆波形分类,绿激光海陆波形分类方法精度还不足以满足实际应用需求。综合采用多通道波形能提高绿激光海陆波形分类精度,但现有方法未考虑每个通道的权重信息。为此,本文基于深度学习提出了一种利用多通道加权投票的卷积神经网络(MWV-CNN)的海陆波形分类方法,以进一步提高单频ALB海陆波形分类的总体精度。

2 多通道加权投票的绿激光海陆波形分类

2.1 ALB系统多通道

使用ALB系统在海岸带进行海陆一体化测量时,需要考虑水深测量和地形测量两种作业模式。在这两种作业模式下,测量目标的覆盖范围由激光光斑在地面上的分布方式和相关接收器的FOV所决定^[16]。地形测量需要更高的分辨率和光斑密度,而水深测量则需要更大的像素尺寸和更低的光斑间距^[16],即地形测量时,每个FOV通道分别进行测量,以获得更高的激光点分辨率和光斑密度,水深测量时,将多个小FOV

通道波形相叠加形成一个虚拟 FOV 通道,其具有更高信噪比,以接收更多海底反射信号用于探测海底。为了同时满足这两种作业模式,ALB 系统的绿激光接收机通常具有多个 FOV。考虑到接收机 FOV,绿激光从深度 D 处的海底反射信号^[17]可表示为

$$P_r(D) = \frac{P_t \eta \rho T^2 A \cos^2(\theta) e^{-2L_s} F_p}{\pi(n_w H + D)^2 S_{TF}} \exp[-2(a + b_b)D \sec \varphi], \quad (1)$$

式中: P_r 为接收到的激光功率; P_t 为激光发射功率; D 为水深; H 为飞机高度; ρ 为反射系数; a 为吸收系数; b_b 为后向散射系数; θ 为波束扫描角; φ 为折射角; η 为接收系统的光学效能; n_w 为水体折射率; A 为接收机孔径面积; T 为透射率; L_s 为空气中光程长度; S_{TF} 为脉冲展宽因子; F_p 为 FOV 损失因子,是一个随着激光水下路径长度增加而从单位值 1 降为 0 的函数^[17]:

$$F_p(h_s, F_{OV}) = \frac{1}{2} \Psi^2 m^2 e^{-2b_i h_s} \times \int_0^\infty [x + \sqrt{1+x^2}]^{\frac{2b_i h_s}{x}} \times \exp\left[\frac{-x^2 m^2}{4} \left(\frac{r_0^2 + R_0^2}{h_s^2} + \Theta^2 + \Psi^2\right)\right] x dx, \quad (2)$$

式中: $\Psi = (F_{OV} \times \gamma)/2$; $\Theta = (D_{IV} \times \gamma)/2$, D_{IV} 为脉冲发散角; $\gamma = H_s(\theta)/h_s(\varphi) + 1/n_w$; b_i 为水体前向散射系数; h_s 为激光在水中的传输距离, $h_s(\theta) = D/\cos \varphi$; H_s 为激光在空气中的传输距离, $H_s(\theta) = H/\cos \varphi$; m 为 Dolin 参数; r_0 为初始光束横截面半径; R_0 为接收机孔径半径。通道的 FOV 越大,接收到的激光脉冲回波能量越多。

卷积神经网络(CNN)是一种经典的深度学习架构,其特点是有一连串的卷积层和池化层,然后连接一个或多个全连接层。如图 1 所示,本文提出的 MWV-CNN 包括一个多通道输入模块、多个一维(1D)CNN 模块和一个多通道融合模块。

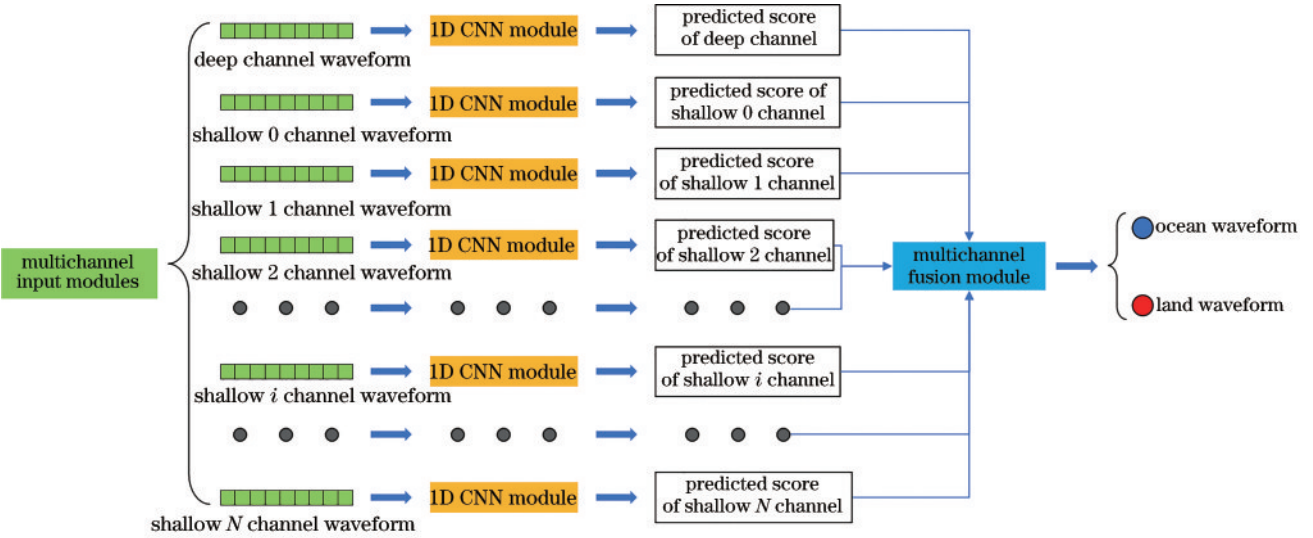


图 1 提出的 MWV-CNN 结构
Fig. 1 Structure of proposed MWV-CNN

2.2 多通道输入模块

图 2 为 Optech CZMIL 系统的多通道视场分布(非比例),该系统有一个视场角为 6 mrad 的红外(IR)通




图 2 Optech CZMIL 系统的多通道视场分布(非比例)
Fig. 2 Distributions of multichannel field of views of Optech CZMIL system (non-scaled)

道、一个视场角为 6~40 mrad 的绿激光深水通道和七个视场角为 1.9 mrad 的绿激光浅水通道。为使 MWV-CNN 能够利用绿激光多通道波形,在 1D CNN 模块前设置一个多通道输入模块,用于将绿激光多通道波形分别输入到相应的 1D CNN 模块中。

2.3 1D CNN 模块

图 3 为本文提出的 1D CNN 模块结构。1D CNN 模块主要包括四个特征提取模块、一个注意力机制模块和一个分类模块。

2.3.1 特征提取模块

每个特征提取模块由一个 1D 卷积层、一个批量归一化(BN)层和一个线性整流函数(ReLU)层组成。1D 卷积层使用预设宽度的 1D 滤波器按步长顺序对输入数据进行局部卷积,然后输出相应特征。1D 卷积的计算公式^[18]为

$$z_{ik}^l = \mathbf{w}_k^{lT} \mathbf{x}_i^l + b_k^l, \quad (3)$$




图3 1D CNN 模块结构

Fig. 3 Structure of 1D CNN module

式中: \mathbf{x}_i^l 为第 l 卷积层输入数据中以位置 i 为中心的数据片段; \mathbf{w}_k^l 和 b_k^l 分别为卷积层第 k 个滤波器的权重矩阵和偏置项; \mathbf{z}_{ik}^l 为卷积层输出的第 k 个特征图。四个特征提取模块中卷积层的卷积核宽度均设置为 3, 数量分别设置为 32、32、64、64。为了加速模型收敛, 提高网络的鲁棒性和非线性表达能力, 在卷积层后面设置一个 BN 层和一个 ReLU 层。卷积层提取出的大量特征直接输入到全连接 (FC) 层会导致参数量巨大, 因而耗费大量的计算资源和时间, 且容易使网络模型过拟合。为此, 在第四个特征提取模块和注意力机制 (AM) 模块之间设置一个全局最大池化层对特征图进行子采样来减少 AM 模块和分类模块中 FC 层的参数量, 有效抑制过拟合。

2.3.2 AM 模块

复杂海陆环境下, 不同时间和区域采集的绿激光波形特征存在差异。有些特征可用于海陆波形分类, 而有些特征可能会干扰分类, 降低模型的泛化能力和鲁棒性。因此, 必须引入 AM 对提取的特征进行自适应加权, 使模型关注具有重要信息的特征, 抑制无用特征。AM 模块包括一个 FC 层和一个 sigmoid 层。全连接层的神经元数量与特征图的数量相同, 设置为 64。设全局最大池化操作后的特征序列为 $\mathbf{G} = [g_1, g_2, \dots, g_K]^T$, K 为特征图的数量。首先, 将特征序列输入到 FC 层, 然后, 通过 sigmoid 激活得到每个特征图的注意力权重 \mathbf{S} , 公式表示如下:

$$\mathbf{S} = \delta(\mathbf{W}\mathbf{G} + \mathbf{b}) = [s_1, s_2, \dots, s_K]^T, \quad (4)$$

式中: \mathbf{W} 和 \mathbf{b} 分别为 FC 层的权重矩阵和偏置向量; δ 为 sigmoid 函数。经 sigmoid 激活后, s 的取值分布在 (0, 1) 之间。最后, 将注意力权重 \mathbf{S} 和原始特征序列 \mathbf{G} 相乘, 得到 AM 筛选后的特征序列 \mathbf{G}' , 计算公式为

$$\mathbf{G}' = \mathbf{S}\mathbf{G}. \quad (5)$$

2.3.3 分类模块

经 AM 筛选后的特征序列被输入到分类模块中执行分类任务。分类模块包括一个 FC 层和一个 softmax 层。在分类模块中, FC 层的神经元数量与绿激光波形类别数量相同, 设置为 2。softmax 函数的计算公式^[19]为

$$y_i = \frac{e^{x_i}}{\sum_{j=1}^2 e^{x_j}}, \quad (6)$$

式中: x_i 为 FC 层第 i 个神经元的输出; y_i 为输入到 CNN 中的绿激光波形属于类别 i 的概率 (即预测得分)。

2.4 多通道融合模块

极浅水体的绿激光波形被误分类为陆地, 以及陆地特殊地形的绿激光波形被误分类为海洋, 降低了单频 ALB 系统海陆波形分类精度^[14]。对于同一个激光照射点, 不同视场的绿激光通道采集的激光回波具有不同特性。因此, 不同通道的绿激光海陆波形分类受海陆环境影响不同。比如, 极浅水域波形叠加效应对浅水通道波形的影响小于对深水通道波形的影响, 而浅水通道波形相比于深水通道波形对陆地特殊地形的影响更加敏感。当单独使用深水通道或浅水通道波形进行海陆波形分类时, 分类的总体精度较低^[9,14]。为此, 本文提出了基于加权投票算法的多通道融合模块, 以综合利用深水和浅水通道采集的绿激光多通道波形, 减少特殊波形对海陆波形分类的影响。

投票法是一种遵循投票规则的算法, 通过多个模型的集成来降低模型的错误率, 提高模型的泛化能力和鲁棒性。投票法可分为硬投票和软投票。硬投票是直接对各通道 1D CNN 模块的预测类别进行投票, 选择得票数超过一半的类别作为波形最终类别, 各通道等权^[15]。硬投票计算公式为

$$L_{\text{label}} = \begin{cases} W_{\text{ocean waveform}} & O > L \\ W_{\text{land waveform}} & O < L \end{cases}, \quad (7)$$

式中, O 和 L 分别为多通道 1D CNN 模块对多通道绿激光波形属于海洋和陆地类别的投票数。

软投票则是先获取各通道 1D CNN 模块的各类预测得分, 即通道权重, 然后进行加权计算并选择得分高的类别作为波形最终类别。相对于硬投票, 加权投票考虑到了预测得分这一额外信息, 因此可以得出比硬投票更加准确的预测结果。加权投票的计算公式为

$$L_{\text{label}} = \begin{cases} W_{\text{ocean waveform}} \frac{\sum_i^C y_i^{\text{ocean}}}{C} > \frac{\sum_i^C y_i^{\text{land}}}{C} \\ W_{\text{land waveform}} \frac{\sum_i^C y_i^{\text{ocean}}}{C} < \frac{\sum_i^C y_i^{\text{land}}}{C} \end{cases}, \quad (8)$$

式中: y_i^{ocean} 和 y_i^{land} 分别为第 i 个通道 1D CNN 模块得到的该通道采集的绿激光波形属于海洋和陆地类别的预测得分 (通道权重); C 是单频 ALB 系统绿激光通

道数。

2.5 评估方法

以红外激光波形双聚类结果作为参考值,评估不同的绿激光海陆波形分类方法的性能^[3]。利用真实类别和预测类别计算总体精度(OA)、Kappa系数和总体精度标准差(SDOA)量化不同模型的性能,计算公式为

$$A_{OA} = \frac{S_{TP} + S_{TN}}{S_{TP} + S_{TN} + S_{FP} + S_{FN}}, \quad (9)$$

式中: S_{TP} 为被模型正确分类的正样本数量; S_{TN} 为被模型正确分类的负样本数量; S_{FP} 为被模型错误分类的正样本数量; S_{FN} 为被模型错误分类的负样本数量。

$$C_{Kappa} = \frac{A_{OA} - P_e}{1 - P_e}, \quad (10)$$

式中, P_e 为每个类别的真实样本数量与预测样本数量的乘积除以总样本数量的平方之和。由于深度学习具有随机性,使用相同训练数据训练得到的模型参数不同,从而导致模型对测试数据的分类精度不同。采用SDOA评估CNN模型的鲁棒性,其计算公式为

$$A_{SDOA} = \sqrt{\frac{\sum_{i=1}^M (A_{OA_i} - \frac{1}{M} \sum_{j=1}^M A_{OA_j})^2}{M - 1}}, \quad (11)$$

式中: M 为训练次数; A_{OA_i} 为第*i*个训练模型对测试数据分类的总体精度。SDOA越小,模型越稳健。

3 实验与分析

3.1 实验数据

采用Optech CZMIL系统在江苏省秦山岛近岸海域实测ALB数据验证和评估本文方法的有效性和精度。秦山岛周围有白沙或黑泥组成的宽阔潮间带,内部地表覆盖着裸土、岩石、植被等。实验区域水深变化范围从2 m到5 m,岛屿西北部海域为养殖区,海面漂浮着大量养殖筏架。CZMIL系统的脉冲重复频率、圆形扫描频率、扫描角、飞行高度、飞行速度、条带宽度的标称参数分别为10 kHz、27 Hz、20°、400 m、140 kts、294 m^[16]。CZMIL系统采用共线同步方式发射波长为532 nm的绿激光和1064 nm的红外激光,并使用多通道对每个激光照射点采集9个激光脉冲回波波形^[16,20],包括1个红外激光波形、1个绿激光深水通道波形和7个绿激光浅水通道波形。通过合并激光脉冲的传播距离、激光束的扫描角度、传感器的位置和方向数据以及系统安装的配置参数,计算出相应波形的激光照射点位置(即经度、纬度和高程)^[21]。训练集(C14条带)、验证集(C15条带)和测试集(C16条带)分别有304322、286328和294654个激光脉冲回波。图4和图5分别为典型的海洋和陆地的9通道波形图。由于陆地对绿激光有很强的反射作用,而绿激光可穿透海洋,较多能量被海水吸收,所以各通道的海洋波形振幅




图4 典型海洋激光波形。(a) 红外激光通道;(b) 绿激光深水通道;(c)~(i) 绿激光浅水0~6通道

Fig. 4 Typical laser waveforms of ocean. (a) IR laser channel; (b) green laser deep channel; (c)~(i) green laser shallow 0~6 channels




图 5 典型陆地激光波形。(a) 红外激光通道；(b) 绿激光深水通道；(c)~(i) 绿激光浅水 0~6 通道

Fig. 5 Typical laser waveforms of land. (a) IR laser channel; (b) green laser deep channel; (c)~(i) green laser shallow 0~6 channels

要小于陆地波形振幅；通道的 FOV 越大，接收到的激光脉冲能量越多，因此深水通道的波形振幅高于浅水通道；由于激光束发散，激光光斑中的能量分布不均匀，靠近光斑中心的浅水通道比远离光斑中心的浅水通道接收到更多能量，因此不同浅水通道的波形振幅不同。

3.2 实验分析与讨论

利用多通道输入模块将训练集的八通道原始绿激光波形输入到 2.2 节所述的 8 个 1D CNN 中训练，网络训练参数分别为：学习率 0.001，批处理量 1024，迭代次数 891 (3 轮)，梯度下降优化器 Adam，在每轮训练之前将训练集样本的顺序打乱一次。如图 6 所示，本文所提出的 1D CNN 在迭代 891 次后收敛，模型的准确率和损失函数值分别接近 100% 和 0。在相同的实验条件下，对 MWV-CNN 连续训练 10 次，得到 10 组 MWV-CNN 分类模型。随后，使用多通道融合模块获得各组模型对测试集的预测类别。

为评估本文方法相比于传统方法的有效性，选取了基于波形特征的 SVM 机器学习方法^[22]、1D CNN 深度学习^[12]以及使用硬投票算法的多通道 CNN (MV-CNN)^[15]三种代表性方法进行对比。SVM 机器学习方法通过提取训练集浅水通道原始绿激光波形的 6 种特征 (即振幅、饱和时间、面积、有效范围长度、偏度和峰度) 训练 SVM，然后用训练后的 SVM 对测试集进




图 6 MWV-CNN 中 1D CNN 训练过程

Fig. 6 Training process of 1D CNN in MWV-CNN

行分类；1D CNN 深度学习将训练集深水通道、浅水 0 通道和浅水 1 通道的原始绿激光波形同时输入到文献 [12] 构建的 1D CNN 中训练，在相同的实验条件下连续训练 10 次，然后用训练后的 1D CNN 分类模型分别对测试集进行分类。MV-CNN 除多通道融合模块使用硬投票算法外，其他与 MWV-CNN 实验相同。

表 1 统计了 SVM、1D CNN、MV-CNN 和 MWV-CNN 的混淆矩阵和性能指标。由表 1 可知，综合利用多通道波形的 MV-CNN 和 MWV-CNN 分类精度和鲁棒性均具有明显优势。相比于 MV-CNN，MWV-

表 1 不同海陆波形分类方法的混淆矩阵与性能指标

Table 1 Confusion matrices and performance metrics of different ocean-land waveform classification methods

Method	Class	Prediction		OA / %	Kappa	SDOA / %
		Ocean	Land			
SVM	Ocean	240461	672	98.52	0.949	—
	Land	3699	49822			
1D CNN	Ocean	237975	3158	98.70	0.957	0.48
	Land	684	52837			
MV-CNN	Ocean	240309	824	99.42	0.980	0.03
	Land	898	52623			
MWV-CNN	Ocean	240366	767	99.45	0.982	0.02
	Land	849	52672			

CNN 具有更好的分类结果,说明加权投票算法更有效。图 7 展示了各方法海陆波形分类结果,其中第一

行和第二行分别表示海洋和陆地,实线表示采用红外激光海陆波形分类获得的参考水边线。由图 7 可知,浅水通道采集的绿激光波形对极浅水域波形叠加效应不敏感,但易受陆地特殊地形影响,SVM 在陆地区域存在大量误分类波形;文献[12]构建的 1D CNN 显著克服了陆地特殊地形的影响,但将多通道波形同时输入,受极浅水域波形叠加效应和养殖筏架的影响较大,在极浅水域和养殖区存在许多误分类波形;而 MWV-CNN 和 MV-CNN 充分发挥了多通道优势,将每个通道波形分别输入 1D CNN 模块,根据每个通道的预测得分,采用投票方法综合确定波形类别,对陆地特殊地形、极浅水域波形叠加效应和养殖筏架的影响均不敏感,误分类波形最少。

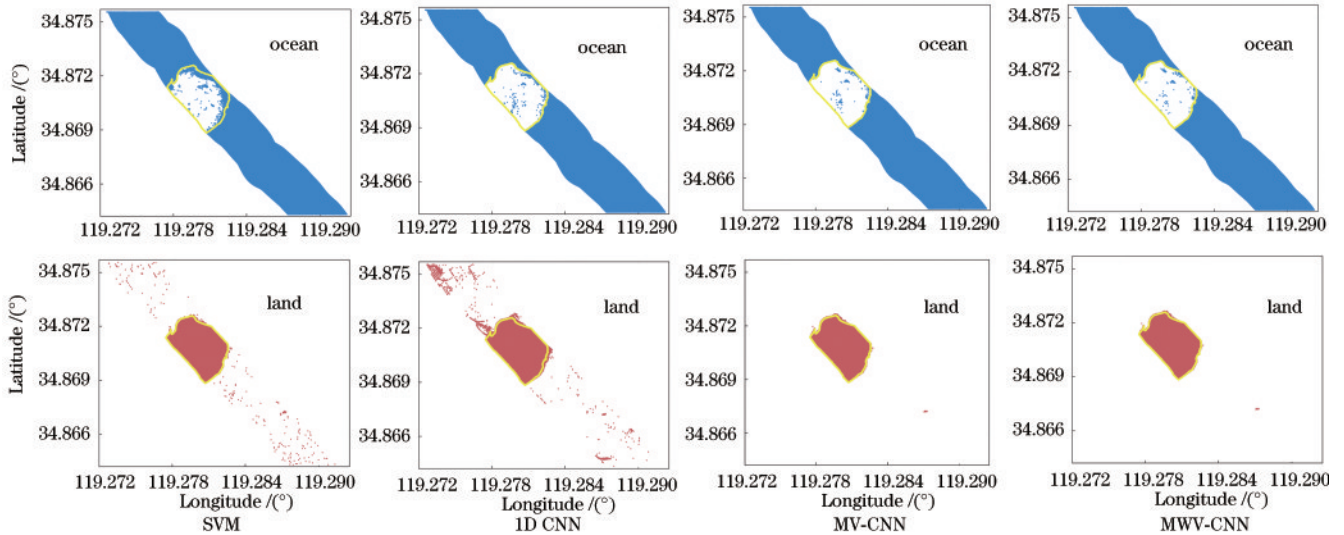


图 7 不同海陆波形分类方法的分类结果

Fig. 7 Classification results of different ocean-land waveform classification methods

为探讨 MWV-CNN 和 MV-CNN 分类精度与多通道关系,将深水通道和浅水 0~6 通道原始绿激光波形通过多通道输入模块逐一加入到 MWV-CNN 和 MV-CNN 中,结果如图 8 所示。随着通道数增加,MWV-

CNN 和 MV-CNN 分类精度都逐渐提升,MWV-CNN 相比于 MV-CNN 精度提升更快。当通道数为 2 时,MWV-CNN 优势更明显,可应用于只有一个深水和一个浅水通道的单频 ALB 系统中。




图 8 MWV-CNN 和 MV-CNN 分类精度与通道数的关系

Fig. 8 Relationship between classification accuracy and channel number of MWV-CNN and MV-CNN

4 结 论

为提高复杂海陆环境下绿激光海陆波形分类精度,本文基于深度学习提出了利用多通道波形加权投票的海陆波形分类方法。该网络结构由一个多通道输入模块、多个 1D CNN 模块和一个多通道融合模块组成。其中,多通道输入模块将绿激光多通道波形分别输入到相应的 1D CNN 模块中;多个 1D CNN 模块分别对每个通道波形进行处理,获得各通道波形属于海洋和陆地类别的预测得分;多通道融合模块根据每个通道波形得分进行加权投票,确定波形最终类别。采用江苏省连云港市近岸海域 Optech CZMIL 实测数据验证了本文方法的有效性。结果表明:

1) 提出的 MWV-CNN 方法的分类精度指标 OA、Kappa 和 SDOA 分别为 99.45%、0.982 和 0.02%,均

优于目前已有的单频 ALB 系统绿激光海陆波形分类方法。

2)MWV-CNN 能充分发挥多通道波形优势,将每个通道波形分别输入 1D CNN 模块,根据每个通道的预测得分,采用加权投票方法综合确定波形类别,对陆地特殊地形、极浅水域波形叠加效应和养殖筏架的影响均不敏感,分类精度高、鲁棒性强,为实现绿激光高精度海陆波形分类提供了一种新的途径。

多通道加权投票虽然综合利用了多通道波形,但未考虑到不同海陆环境下各通道实际海陆波形分类能力的强弱,还未完全发挥多通道波形的优势。下一步工作将结合虚拟 FOV 通道等信息设计一种自适应权重模块对不同通道进行加权,实现自适应的多通道加权投票海陆波形分类。本文只考虑了海洋和陆地两种类别,将漂浮在海面上的养殖筏架视为海洋类别参与训练和分类,在今后研究中需要在海陆波形分类的基础上,对陆地波形和海洋波形进行再分类,如陆地波形再细分为植被、岩石、裸土等,海洋波形再细分为深水、浅水、筏架等。另外,深水通道 FOV 较大,深水通道对应激光光斑中可能同时存在海洋和陆地,而本文未考虑这种特殊情况。未来将根据激光光斑中心位置和光斑直径,推算出每个小 FOV 浅水通道对应的光斑中心位置,并赋予各个小 FOV 浅水通道波形类别,进行精细化分类,提高海陆波形分类的分辨率和精度,为后续基于海陆波形分类的高精度水边线提取奠定基础。

参 考 文 献

- [1] Guenther G. Airborne laser hydrography: system design and performance factors[R]. Maryland: NOAA, 1985.
- [2] Guenther G C, Cunningham A G, Larocque P E, et al. Meeting the accuracy challenge in airborne LiDAR bathymetry[C]//Processing of 20th EARSeL Symposium: Workshop on Lidar Remote Sensing of Land and Sea Held. Dresden, Germany: AGRIS, 2000: 1-27.
- [3] Liang G, Zhao X L, Zhao J H, et al. Feature selection and mislabeled waveform correction for water-land discrimination using airborne infrared laser[J]. Remote Sensing, 2021, 13(18): 3628.
- [4] Mandlbürger G, Pfennigbauer M, Pfeifer N. Analyzing near water surface penetration in laser bathymetry—a case study at the River Pielach[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2013, II -5/W2: 175-180.
- [5] 周国清, 胡皓程, 徐嘉盛, 等. 机载单频水深测量 LiDAR 光机系统设计[J]. 红外与激光工程, 2021, 50(4): 20200297.
Zhou G Q, Hu H C, Xu J S, et al. Design of LiDAR optical machine system for airborne single frequency bathymetry[J]. Infrared and Laser Engineering, 2021, 50(4): 20200297.
- [6] Fuchs E, Tuell G. Conceptual design of the CZMIL data acquisition system (DAS): integrating a new bathymetric lidar with a commercial spectrometer and metric camera for coastal mapping applications[J]. Proceedings of SPIE, 2010, 7695: 76950U.
- [7] Collin A, Long B, Archambault P. Merging land-marine realms: spatial patterns of seamless coastal habitats using a multispectral LiDAR[J]. Remote Sensing of Environment, 2012, 123: 390-399.
- [8] Pe'eri S, Philpot W. Increasing the existence of very shallow-water LIDAR measurements using the red-channel waveforms[J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(5): 1217-1223.
- [9] Zhao X L, Wang X Y, Zhao J H, et al. Water-land classification using three-dimensional point cloud data of airborne LiDAR bathymetry based on elevation threshold intervals[J]. Journal of Applied Remote Sensing, 2019, 13(3): 034511.
- [10] 黄田程, 陶邦一, 毛志华, 等. 基于多通道海洋激光雷达的海陆波形分类[J]. 中国激光, 2017, 44(6): 0610002.
Huang T C, Tao B Y, Mao Z H, et al. Classification of sea and land waveform based on multi-channel ocean lidar [J]. Chinese Journal of Lasers, 2017, 44(6): 0610002.
- [11] 邱振戈, 曹彬才. 机载双频激光雷达水陆回波分类方法[C]//中国惯性技术学会高端前沿专题学术会议. 北京: 中国惯性技术学会, 2017: 328-338.
Qiu Z G, Cao B C. Water-land classification method for airborne LiDAR bathymetric data[C]//Proceedings of China Inertial Technology Society High-End Frontier Special Topics Academic Conference. Beijing: Chinese Society of Inertia Technology, 2017: 328-338.
- [12] 胡善江, 贺岩, 陶邦一, 等. 基于深度学习的机载激光海洋测深海陆波形分类[J]. 红外与激光工程, 2019, 48(11): 1113004.
Hu S J, He Y, Tao B Y, et al. Classification of sea and land waveforms based on deep learning for airborne laser bathymetry[J]. Infrared and Laser Engineering, 2019, 48(11): 1113004.
- [13] Pe'eri S, Morgan L V, Philpot W D, et al. Land-water interface resolved from airborne LIDAR bathymetry (ALB) waveforms[J]. Journal of Coastal Research, 2011, 62: 75-85.
- [14] Zhao X L, Wang X Y, Zhao J H, et al. An improved water-land discriminator using laser waveform amplitudes and point cloud elevations of airborne LIDAR[J]. Journal of Coastal Research, 2021, 37(6): 1158-1172.
- [15] Liang G, Zhao X L, Zhao J H, et al. MVCNN: a deep learning-based ocean-land waveform classification network for single-wavelength LiDAR bathymetry[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 656-674.
- [16] Fuchs E, Mathur A. Utilizing circular scanning in the CZMIL system[J]. Proceedings of SPIE, 2010, 7695: 76950W.
- [17] Carr D, Tuell G. Estimating field-of-view loss in bathymetric lidar: application to large-scale simulations [J]. Applied Optics, 2014, 53(21): 4716-4721.
- [18] Gu J X, Wang Z, Kuen J, et al. Recent advances in

- convolutional neural networks[J]. Pattern Recognition, 2018, 77: 354-377.
- [19] Banerjee K, Vishak C, Gupta R, et al. Exploring alternatives to softmax function[C]//Proceedings of the 2nd International Conference on Deep Learning Theory and Applications, July 7-9, 2021, Online Streaming. Setúbal: SCITEPRESS-Science and Technology Publications, 2021: 81-86.
- [20] Pierce J W, Fuchs E, Nelson S, et al. Development of a novel laser system for the CZMIL lidar[J]. Proceedings of SPIE, 2010, 7695: 76950V.
- [21] Zhao X L, Liang G, Liang Y, et al. Background noise reduction for airborne bathymetric full waveforms by creating trend models using Optech CZMIL in the Yellow Sea of China[J]. Applied Optics, 2020, 59(35): 11019-11026.
- [22] 王丹葭, 邢帅, 徐青, 等. 单频机载激光测深海陆回波自动分类方法[J]. 测绘学报, 2022, 51(5): 750-761.
- Wang D D, Xing S, Xu Q, et al. Automatic sea-land waveform classification method for single-wavelength airborne LiDAR bathymetry[J]. Acta Geodaetica et Cartographica Sinica, 2022, 51(5): 750-761.