

结合深度学习和植被指数的滨海湿地高分二号遥感影像信息提取

崔宾阁¹, 吴景¹, 李心慧¹, 任广波², 路燕¹

1. 山东科技大学 计算机科学与工程学院, 青岛 266590;

2. 自然资源部第一海洋研究所, 青岛 266061

摘要: 针对滨海湿地植被光谱特征相似而易被混淆分类的问题, 本文提出了结合深度学习和植被指数的滨海湿地信息提取网络 MFVNet。该网络以高分辨率遥感影像和典型植被指数为输入, 将 UNet 中的双卷积操作替换为本文提出的增强多尺度特征提取模块, 用于捕获不同尺度的上下文特征, 并在解码器中融合不同感受野的语义特征图, 增强了滨海湿地地物的特征表示。在黄河口滨海湿地高分二号遥感影像上进行了实验, 结果表明: (1) 深度学习方法的信息提取精度普遍优于传统的机器学习分类方法 SVM; 相比 HRNet 等深度语义分割网络, MFVNet 在滨海湿地植被类型上取得了更好的信息提取结果; (2) 将修正土壤调节植被指数 MSAVI、差值植被指数 DVI 和比值植被指数 RVI 与高分二号影像拼接对滨海湿地信息提取贡献较大。

关键词: 遥感, 滨海湿地信息提取, 高分二号, 深度卷积神经网络, MFVNet 模型, 植被指数

中图分类号: P2

引用格式: 崔宾阁, 吴景, 李心慧, 任广波, 路燕. 2023. 结合深度学习和植被指数的滨海湿地高分二号遥感影像信息提取. 遥感学报, 27(6): 1376-1386

Cui B G, Wu J, Li X H, Ren G B and Lu Y. 2023. Combination of deep learning and vegetation index for coastal wetland mapping using GF-2 remote sensing images. National Remote Sensing Bulletin, 27(6): 1376-1386 [DOI: 10.11834/jrs.20221658]

1 引言

滨海湿地是陆地生态系统和海洋生态系统的过渡地带, 在改善气候、维护区域生态平衡、维护生物多样性等方面发挥着重要的作用。同时, 滨海湿地承受着自然过程与人类活动的双重影响, 是敏感的生态脆弱区, 也是国家重点保护的湿地环境之一 (徐东霞和章光新, 2007)。快速准确地提取湿地地物类型信息是合理开展保护和恢复滨海湿地工作的前提 (Yang 等, 2016)。滨海湿地环境复杂, 大部分地区难以进入现场勘察, 遥感技术作为有效的大规模监测手段, 具有监测范围广、周期短等多种优点, 在滨海湿地信息提取方面发挥了重要作用 (范德芹 等, 2016)。

传统滨海湿地信息提取方法大多采用面向对

象分类方法或使用光谱分析、提取影像浅层特征等方法得到不同的遥感地物特征, 然后使用人工阈值或传统机器学习模型进行信息提取, 如决策树 DT (Decision Tree) (王建步 等, 2014)、支持向量机 SVM (Support Vector Machines) (Yang 等, 2016; Han 等, 2018)、随机森林 RF (Random Forest) (刘家福 等, 2018; 张磊 等, 2019) 等。但传统机器学习模型的结构较简单, 不能有效表达复杂的地物特征 (Wang 等, 2015)。

近年来, 以卷积神经网络 CNN (Convolutional Neural Networks) 为代表的深度学习方法受到了越来越多的关注。与传统机器学习方法相比, 深度学习拥有复杂的网络结构和更强大的特征学习能力, 已被证明能够很好地从原始图像中提取深层特征 (卢宏涛和张秦川, 2016; 周飞燕 等, 2017)。深度

收稿日期: 2021-10-21; 预印本: 2022-05-09

基金项目: 国家自然科学基金 (编号: 62072287, 42076189); 山东省自然科学基金 (编号: ZR2020MD096, ZR2020MD099)

第一作者简介: 崔宾阁, 研究方向为高光谱遥感、海洋和海岸带遥感监测技术。E-mail: cuibinge@sdu.edu.cn

通信作者简介: 路燕, 研究方向为智能信息处理、遥感图像分类和目标检测。E-mail: luyan@sdu.edu.cn

学习分类方法已在滨海湿地信息提取中得到了大量应用。Hu等(2019a, 2019b)采用深度卷积神经网络 DCNN (Deep Convolutional Neural Networks) 对黄河口湿地 CHRIS 高光谱影像进行了信息提取; 后提出了多目标 CNN 模型和决策融合方法解决类别混淆现象。Feng等(2019)提出了一种融合多时相不同传感器数据的多分支 DCNN, 对黄河三角洲湿地的 Sentinel 影像进行了信息提取。Liu等(2021)提出了一种融合高光谱影像和多光谱影像的多数据流 CNN, 对黄河口湿地和盐城湿地的高分五号和 Sentinel 影像进行了信息提取。上述方法在进行大尺度湿地地物信息提取时效果较好。

然而, 对滨海湿地植被进行精细信息提取仍是具有挑战性的任务。河流、地下水和海水的相互作用造成了滨海湿地含盐量的空间分异, 整体上, 滨海湿地的土壤含盐量呈现沿海岸线向内陆递减、河道向两侧递增的趋势。而滨海湿地植被的生长势与生物量会因生长区域水盐条件的不同产生较大差异(刘玉斌等, 2017), 这使得滨海湿地植被呈现形变程度高、尺度变化大的特点, 且部分植被在生物量峰值时光谱特征极其相似, 加大了植被精细信息提取的难度。此外, 在滨海湿地广袤的潮滩上, 盐地碱蓬与怪柳、芦苇、互花米草等植物混合交错生长, 且大多植株矮小、分布稀疏、底质湿度大, 导致其在遥感影像中信号较弱。与中低分辨率遥感影像相比, 高分辨率遥感影像能提供更丰富的地物信息, 如纹理、几何特征等(孟祥锐, 2019), 因此植株矮小且分布稀疏的植被可在高分辨率遥感影像上拥有更多信息。但空间分辨率的增加导致了地物类别之间的光谱可分离性降低, 使得光谱混淆现象较为严重。

针对上述情况, 本文提出了基于空间金字塔技术和注意力机制(张宸嘉等, 2021)的增强多尺度特征提取模块 E-MFE (Enhanced Multi-scale Feature Extraction), 结合典型植被指数, 设计了滨海湿地遥感影像深度语义分割网络 MFVNet, 并分析了不同植被指数对信息提取的影响。

2 研究方法

编码器—解码器结构被广泛应用于现代语义和实例分割网络中。编码器逐步减少特征图的尺寸, 并通过更大的感受野(Luo等, 2016)学习抽象特征; 解码器将编码器输出的小尺寸特征图上

采样至输入图像的尺寸, 以实现逐像素分类。在遥感影像语义分割网络中, 感受野的大小影响着地物特征提取的范围。如果感受野太小, 则不利于模型提取大尺度地物特征; 如果感受野太大, 则不利于模型提取小尺度地物特征。将不同感受野或不同层次的地物特征进行融合, 可以提高网络对于不同尺度滨海湿地地物的提取效果, 如空洞空间金字塔池化 ASPP (Atrous Spatial Pyramid Pooling) (Chen等, 2018)、特征金字塔网络 FPN (Feature Pyramid NetWork) (Lin等, 2017)、金字塔场景解析网络 PSPNet (Pyramid Scene Parsing Network) (Zhao等, 2017)。

2.1 MFVNet 架构

本文提出的端到端 MFVNet 架构如图 1 所示。整体上, MFVNet 可分为编码器和解码器两个阶段。编码器由 5 个增强多尺度特征提取模块 E-MFE 和 4 个下采样操作构成, 在前 4 个 E-MFE 模块后接一个下采样, 以增大感受野, 使卷积操作能在更大的空间范围内进行特征提取。解码器由 5 个 E-MFE 模块、4 个 3×3 卷积、多个上采样操作和 1 个 1×1 卷积构成。前 4 个 E-MFE 模块接受编码器同层次 E-MFE 模块输出的特征图与解码器下一层次上采样后的特征图, 进行多尺度地物特征提取; 最后一个 E-MFE 模块接受前 4 个 E-MFE 模块不同倍率上采样和卷积后的特征图, 进行不同层次语义和细节信息融合。最后, 使用一个卷积核数目为地物类别数、激活函数为 Softmax 的 1×1 卷积来输出 MFVNet 的预测结果。

本研究使用交叉熵损失函数作为网络的损失函数, 其公式如式 (1) 所示。

$$loss = -\frac{1}{m} \sum_m \sum_i y_i \log(p_i) \quad (1)$$

式中, y 表示真实标签值, p 表示网络预测值, n 表示地物类别数, $i \in (1, n)$, m 表示像素总数。

2.2 增强多尺度特征提取模块 E-MFE (Enhanced Multi-scale Feature Extraction)

滨海湿地植被在遥感影像中呈现形变程度高、尺度变化大的特点, 这对精细尺度信息提取提出了挑战。受空洞卷积金字塔结构和注意力机制的启发, 本文设计了一种增强的多尺度特征提取模块 E-MFE, 将不同感受野的地物特征进行融合, 以获得滨海湿地植被多尺度特征, 其结构如图 2 所示。




图1 MFVNet整体架构

Fig.1 The overall architecture of the MFVNet




图2 增强多尺度特征提取模块

Fig.2 Enhance multi-scale feature extraction module

E-MFE由一个卷积核大小为3×3的双卷积分支、3个扩张率分别为2、3、5的空洞卷积分支、一个通道权重分支和两个1×1卷积构成。其中，通道权重分支使用全局平均池化来聚合每个通道的特征，并利用Sigmoid函数获得特征图不同通道的权重。E-MFE首先使用一个1×1卷积对输入特征图进行通道信息整合，然后分别使用3×3双卷积和扩张率为2、3、5的空洞卷积进行多尺度特征提取。由于特征图各通道的重要性不同，本文设计了一种通道注意力共享机制，即将通道权重与空洞卷积提

取的多尺度特征图相乘，得到通道注意力增强后的多尺度特征。进而，将双卷积分支提取的特征与增强后的多尺度特征进行拼接，并对拼接后的结果使用1×1卷积进行特征融合。最后，将前一个1×1卷积的输出作为恒等映射，与后一个1×1卷积的输出进行求和，以改善网络训练并提升网络表征能力。E-MFE计算过程可以表示为

$$X' = \text{Conv}_{1 \times 1}(X) \quad (2)$$

$$Z = S(G(X')) \times \begin{bmatrix} \text{Conv}_{3 \times 3, r_2}(X'), \\ \text{Conv}_{3 \times 3, r_3}(X'), \\ \text{Conv}_{3 \times 3, r_5}(X') \end{bmatrix} \quad (3)$$

$$X'' = \text{Conv}_{1 \times 1}(\text{Cat}(\text{Conv}_{3 \times 3}^2(X'), Z)) \quad (4)$$

$$Y = X' + X'' \quad (5)$$

式中， X 表示输入特征图， X' 表示前一个1×1卷积输出的特征图， X'' 表示后一个1×1卷积输出的特征图， Z 表示通道注意力增强后的多尺度特征， Y 表示输出特征图， $\text{Conv}_{1 \times 1}(\cdot)$ 表示1×1卷积操作， $\text{Conv}_{i \times i, r_j}(\cdot)$ 表示卷积核大小*i*×*i*、扩张率为*j*的空洞卷积操作， $\text{Conv}_{3 \times 3}^2$ 表示3×3双卷积操作， $\text{Cat}(\cdot)$ 表示拼接操作， $S(\cdot)$ 表示Sigmoid激活函数， $G(\cdot)$ 表示全局平均池化操作。

2.3 植被指数选择

滨海湿地植被易被混淆分类, 且部分稀疏植被的影像特征不明显, 因此本文引入了典型植被指数以增强植被特征表示。针对滨海湿地植被影像特征不明显的问题, 本文选择了对植被灵敏度高的归一化植被指数 (NDVI) (Rouse 等, 1974) 和比值植被指数 (RVI) (Pearson 和 Miller, 1972); 针对滨海湿地植被覆盖密度不同致使土壤背景会对信息提取结果造成影响的问题, 本文选择了能减弱土壤反射率变化的修正土壤调节植被指数 (MSAVI) (Qi等, 1994) 和差值植被指数 (DVI) (Li 等, 1995; 朱玉玲, 2020)。

以上植被指数定义如表 1 所示, 其中, NIR 表示遥感影像中近红外波段反射率, R 表示红光波段反射率。

表 1 植被指数定义

Table 1 Definition of vegetation index

植被指数	计算公式	描述
NDVI	$(\text{NIR}-\text{R})/(\text{NIR}+\text{R})$	归一化植被指数
RVI	NIR/R	比值植被指数
MSAVI	$\frac{\text{NIR} + 0.5 - \sqrt{(2\text{NIR} + 1)^2 - 8(\text{NIR} - \text{R})}}{2}$	修正土壤调节植被指数
DVI	$\text{NIR}-\text{R}$	差值植被指数

3 实验结果与分析

3.1 实验数据

本文所用的遥感数据为 2016 年 8 月 GF-2 卫星拍摄的黄河口湿地多光谱遥感影像。黄河口湿地位于黄河入海口处, 经纬度范围约为 37°35'N—

37°55'N、119°1'E—119°20'E, 处于山东省东营市黄河三角洲国家级自然保护区内。研究区位置与实验影像如图 3 所示, 影像大小为 7300×6908, 空间分辨率为 4 m, 以标准假彩色 (NIR、R、G) 图像显示。




图 3 研究区位置与实验影像
Fig.3 Location of the study area and experimental images

根据对黄河口湿地现场踏勘情况与使用的影像数据特点, 结合专家目视解译结果, 确定该影像的分类类别为芦苇、互花米草、怪柳混生区、海草床、裸潮滩、潮滩稀疏植被、水体和其他等 8 类。考虑到潮滩稀疏植被在遥感影像中可视化效果较差 (如图 4 (a) 中红框所示), 本文在目视解译时使用归一化植被指数 NDVI 增强视觉效果 (图 4 (b))。结合现场踏勘获取的数据资料, 得到的标签图像如图 4 (c) 所示。

3.2 实验参数及实验数据预处理

本文选择 TensorFlow 为后端的 Keras 框架实现 MFVNet 模型和其他深度学习模型, 并在 NVIDIA Tesla P100 上进行训练, 训练迭代次数为 100。采用 10 折交叉验证, 优化器为 Adam 算法, 学习率为 0.0001, 批量大小为 8。




图 4 遥感影像与标签图像
Fig.4 Remote sensing image and label image

首先对遥感影像进行辐射定标和大气校正，然后根据黄河口湿地典型地物的空间分布和现场踏勘结果，选择训练样本区域，如图5中红框所示。训练样本区域约占整幅影像11%，测试数据为去除训练样本区域后的影像数据，测试数据和训练样本区域的像素数目如表2所示。




图5 训练样本区域选取
Fig.5 Training samples area selection

表2 训练样本区域与测试数据的像素数目
Table 2 The number of pixels in the training samples area and test data

地物类别	训练样本区域	测试数据
海草床	143698	298326
互花米草	701014	1682374
芦苇	1100718	3120637
柽柳混生区	341651	783466
裸潮滩	737181	12045212
潮滩稀疏植被	841425	3897468
水体	1874400	22506202
其他	25913	211279

由于GPU内存的限制，本文以128×128大小的图像作为深度学习模型的输入。为扩充模型的训练数据并保持上下文信息的完整性，本文将选择的训练样本区域切割成128×128大小的图像，切割时步长设为32。然后，将切割后的图像进行归一化处理，使图像数据保持在0—1，以提高模型的收敛速度。

3.3 评价指标

为评估各种方法的精度，本文使用混淆矩阵对测试样本进行类别统计，混淆矩阵构造如表3所示。

表3 混淆矩阵表示
Table 3 Confusion matrix representation

预测标签	真实标签				
	类别1	类别2	...	类别n	总计
类别1	x_{11}	x_{12}	...	x_{1n}	x_{1+}
类别2	x_{21}	x_{22}	...	x_{2n}	x_{2+}
...	...	...	...	...	...
类别n	x_{n1}	x_{n2}	...	x_{nn}	x_{n+}
总计	x_{+1}	x_{+2}	...	x_{+n}	N

注： x_{ii} 表示第*i*类正确分类的样本数目， $x_{ij}(j \neq i)$ 表示第*j*类样本被预测为第*i*类的样本数目。 $x_{i+} = \sum_{j=1}^n x_{ij}$ 表示分类结果中第*i*类样本数目， $x_{+i} = \sum_{j=1}^n x_{ji}$ 表示真值图像中第*i*类样本数目， $N = \sum_{i=1}^n \sum_{j=1}^n x_{ij}$ 为测试样本总数，*n*为类别数。

本文采用精准率 Precision (*P*)、召回率 Recall (*R*) 和 *F1* 分数作为分类结果中各种地物的精度评价指标，其计算公式如式 (6) — 式 (8) 所示。

$$P = \frac{x_{ii}}{x_{i+}} \tag{6}$$

$$R = \frac{x_{ii}}{x_{+i}} \tag{7}$$

$$F1 = 2 \cdot \frac{P \times R}{P + R} \tag{8}$$

采用总体精度 OA 和 Kappa 系数作为分类结果的整体评价指标，其计算公式如式 (8) 和式 (9) 所示。

$$OA = \sum_{i=1}^n \frac{x_{ii}}{N} \tag{9}$$

$$Kappa = \frac{N \sum_{i=1}^n x_{ii} - \sum_{i=1}^n (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^n (x_{i+} \cdot x_{+i})} \tag{10}$$

式 (6) — (10) 中， x_{ii} 表示第*i*类正确分类的样本数目， $x_{ij}(j \neq i)$ 表示第*j*类样本被预测为第*i*类的样本数目。 $x_{i+} = \sum_{j=1}^n x_{ij}$ 表示分类结果中第*i*类样本数目， $x_{+i} = \sum_{j=1}^n x_{ji}$ 表示真值图像中第*i*类样本数目， $N = \sum_{i=1}^n \sum_{j=1}^n x_{ij}$ 为测试样本总数，*n*为类别数。

3.4 对比实验

本文将 MFVNet 与传统的机器学习模型 SVM 以及典型的深度学习模型 UNet (Ronneberger 等，2015)、MultiResUNet (Ibtehaz 和 Rahman，2020) 和 HRNet (Sun 等，2019) 应用于黄河口湿地地物分类实验，各种方法的信息提取结果如图6所示。




图6 黄河口湿地信息提取结果

Fig.6 Results of extraction of wetland information in the Yellow River Estuary

从整体来看, SVM 分类结果混淆现象比较严重。UNet 在潮滩稀疏植被上识别效果较好, 但对于颜色和纹理相近的芦苇与互花米草, 混淆分类较为严重, 如图 6 (c) 上方框图所示。MultiResUNet 采用多层卷积堆叠的方式增加感受野, 以提取多分辨率特征, 但对潮滩稀疏植被的提取效果不佳, 如图 6 (d) 下方框图所示。HRNet 在并行的多分辨率子网上反复交换信息以增强高分辨率特征表示, 在互花米草和其他上获得了较好提取效果, 但在柽柳混生区和芦苇上混淆分类较为严重, 如图 6 (e) 上方框图所示。MFVNet 使用修正土壤调节植被指数 MSAVI、差值植被指数 DVI 和比值植被指数 RVI 增强植被特征, 并用增强多尺度特征提取模块 E-MFE 获取不同尺度地物特征, 有效缓解了提取结果的混淆分类现象, 改善了多种地物的提取效果, 如图 6 (f) 框图所示。

各种模型和方法在测试数据上的结果如表 4

所示。MFVNet 的总体精度和 Kappa 分别达到了 93.89% 和 0.9072, 优于其他方法, 在柽柳混生区、海草床和潮滩稀疏植被等地物上的精确率、召回率和 F1 分数均远高于其他方法。

为了验证 MFVNet 的泛化能力, 本文使用另一幅 GF-2 遥感影像 (2017 年 8 月拍摄) 进行了对比实验, 因该幅影像云和阴影过多, 故裁剪了部分区域进行实验, 如图 7 所示。UNet、MultiResUNet、HRNet 和 MFVNet 这 4 种深度学习模型的信息提取结果如图 7 (c) 至图 7 (f) 所示。从整体来看, UNet 的混淆分类现象较为严重, MultiResUNet 和 HRNet 在海草床上识别较好, 但对潮滩稀疏植被提取效果不佳。MFVNet 缓解了混淆分类现象, 并极大提高了柽柳混生区和潮滩稀疏植被的提取精度。以上模型在测试数据上的精度如表 5 所示。MFVNet 的总体精度和 Kappa 达到了 92.18% 和 0.8998, 优于其他方法。

3.5 消融实验

E-MFE 模块使用多个空洞卷积同时捕获不同感受野的地物特征，并利用通道注意力共享机制对多尺度特征进行增强或抑制，选择出对滨海湿地地物分类有用的特征。为了验证 E-MFE 模块和植被指数 V-Index 的有效性，本文进行了消融实验，

结果如表 6 所示。从表 6 中可以看出，加入 E-MFE 模块后，网络模型的总体精度和 Kappa 分别提升 1.58% 和 0.0238；加入 V-Index 后，网络模型的总体精度和 Kappa 分别提升 1.01% 和 0.0155；同时加入 E-MFE 模块和 V-Index 后，网络模型的总体精度和 Kappa 分别提升 2.43% 和 0.0372。

表 4 信息提取结果精度对比

Table 4 Accuracy comparison of information extraction results

类别	SVM			UNet			MultiResUNet			HRNet			MFVNet		
	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1
芦苇	78.7	60.1	0.68	81.9	87.9	0.85	88.3	91.5	0.90	84.5	91.6	0.87	89.5	91.6	0.91
互花米草	61.1	46.0	0.53	80.7	74.2	0.77	80.6	85.7	0.83	86.3	81.9	0.84	85.9	88.1	0.87
怪柳混生区	26.0	63.0	0.37	56.1	70.9	0.63	81.8	71.7	0.76	79.8	56.4	0.66	83.5	80.1	0.82
海草床	21.4	67.5	0.33	62.9	53.6	0.57	58.9	63.3	0.61	61.8	69.0	0.65	83.1	70.5	0.76
裸潮滩	85.3	90.8	0.85	93.5	91.0	0.92	91.2	90.9	0.91	91.5	92.5	0.92	94.1	92.7	0.93
潮滩稀疏植被	58.3	55.6	0.57	75.1	79.9	0.77	73.5	74.2	0.73	71.4	75.6	0.73	78.3	80.6	0.79
水体	99.5	89.9	0.95	98.6	98.0	0.98	98.5	97.8	0.98	98.6	97.0	0.98	98.3	98.5	0.98
其他	93.1	64.4	0.76	91.9	72.6	0.81	92.1	74.9	0.83	87.0	90.8	0.87	87.2	79.4	0.83
OA/%	81.42			92.01			92.19			92.05			93.89		
Kappa×100	73.38			87.90			88.16			87.95			90.72		

注：表中 P、R、F1 分别代表各个类别的精准率、召回率、F1 分数；黑体代表最高精度。




图7 2017年黄河口遥感影像信息提取结果

Fig.7 Yellow River Estuary remote sensing image information extraction results in 2017

表5 2017年遥感影像信息提取结果精度对比

Table 5 Accuracy comparison of information extraction results from remote sensing images in 2017

类别	UNet			MultiResUNet			HRNet			MFVNet		
	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1
芦苇	88.7	96.4	0.92	94.0	96.1	0.95	94.5	96.0	0.95	96.6	94.1	0.95
互花米草	92.8	53.5	0.68	91.7	89.1	0.90	90.9	93.4	0.92	90.3	94.7	0.92
怪柳混生区	78.5	82.8	0.81	68.6	91.3	0.78	79.9	91.0	0.85	94.1	88.0	0.90
海草床	83.2	88.1	0.86	97.8	83.5	0.90	94.3	86.9	0.90	95.3	81.3	0.88
裸潮滩	94.9	62.6	0.76	87.0	87.6	0.87	91.1	87.6	0.89	92.4	92.8	0.92
潮滩稀疏植被	39.4	79.2	0.53	52.3	38.6	0.44	60.8	59.4	0.60	75.7	77.0	0.76
水体	96.1	93.8	0.95	95.9	94.0	0.95	95.6	93.2	0.94	91.9	95.6	0.94
其他	61.9	78.7	0.69	93.7	74.0	0.83	89.2	79.6	0.84	93.9	72.3	0.82
OA/%	82.78			88.04			90.06			92.18		
Kappa×100	78.13			84.65			87.27			89.98		

注: 黑体代表最高精度。

表6 MFVNet消融实验结果

Table 6 MFVNet ablation experiment results

方法	E-MFE	V-Index	OA/%	Kappa
Baseline			91.46	0.8700
Baseline+E-MFE	√		93.04	0.8938
Baseline+V-Index		√	92.47	0.8855
Baseline+E-MFE+V-Index	√	√	93.89	0.9072

注: Baseline 为使用了FPN架构的简化版UNet(降低了UNet每一层的通道数),黑体代表最高精度。

3.6 植被指数影响分析

植被指数是人们通过长期实践总结出来的不同遥感光谱波段间的线性或非线性组合,被普遍认为能较好地反映植被覆盖度和生长状态的差异。为

了研究加入不同植被指数对滨海湿地信息提取的作用,本文开展了植被指数影响分析实验,结果如表7所示。为了消除深度学习模型训练的随机误差的影响,本文分别进行了10次实验,并计算了10次实验结果的均值与标准差。从表7中可以看出,加入NDVI之后模型的总体精度和Kappa均有所下降,但海草床的精准率提升较大;加入MSAVI之后,总体精度和Kappa提升较大,芦苇的召回率和怪柳混生区的精准率提升较大;加入RVI之后,芦苇和互花米草的精准率提升较大、怪柳混生区和潮滩稀疏植被的召回率提升较大。加入DVI之后,芦苇和怪柳混生区的召回率、互花米草和海草床的精准率提升较大,以上4种植被的F1分数均提升较大。

表7 MFVNet使用不同植被指数的结果

Table 7 The results of using different vegetation indices to MFVNet

类别	NDVI			MSAVI			RVI			DVI			原影像		
	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1
芦苇	87.0	91.4	0.89	88.7	92.4	0.91	89.3	89.4	0.89	88.0	91.2	0.90	86.6	87.0	0.87
互花米草	83.0	88.9	0.86	84.5	85.7	0.85	86.9	85.1	0.86	83.7	89.9	0.87	77.5	90.5	0.83
怪柳混生区	82.6	74.7	0.79	89.7	72.6	0.80	81.3	79.8	0.81	84.4	72.2	0.78	82.6	63.8	0.72
海草床	87.6	60.0	0.71	84.2	58.5	0.69	85.7	66.3	0.75	87.0	69.7	0.77	78.0	66.9	0.72
裸潮滩	91.9	90.5	0.91	92.3	92.3	0.92	92.4	92.9	0.93	92.2	91.6	0.92	92.4	93.3	0.93
潮滩稀疏植被	74.9	74.9	0.75	76.7	76.0	0.76	78.4	77.4	0.78	77.2	74.2	0.76	80.8	73.8	0.76
水体	98.0	98.3	0.98	98.0	98.6	0.98	98.0	98.6	0.98	97.9	98.7	0.98	98.1	98.8	0.98
其他	81.1	89.8	0.85	81.7	84.9	0.83	88.5	76.4	0.82	87.3	78.0	0.84	86.3	80.4	0.83
OA/%	92.88±0.22			93.40±0.07			93.29±0.09			93.09±0.13			93.01±0.09		
Kappa×100	89.16±0.32			89.95±0.10			89.79±0.13			89.47±0.19			89.35±0.11		

注: OA和Kappa分别为10次实验结果的均值±标准差,黑体代表最高精度。

为了得到最优的滨海湿地信息提取结果,本文基于表7的实验结果设计了5种植被指数组合方案。方案1是NDVI、MSAVI、RVI和DVI共4种植被

指数的组合;方案2是在大部分植被地物上表现较好的MSAVI、DVI和RVI的组合;方案3是MSAVI和DVI的组合;方案4是MSAVI和RVI的组合;方案5

是DVI和RVI的组合。不同植被指数组合方案在测试数据上的结果如表8所示。从表8中可以看出，方案2在所有植被类型上都获得最高的精度，且总体精度和Kappa与表7中加入单一植被指数的结果相比提升较大。因此，本文使用方案2中MSAVI、DVI和RVI等3种植被指数的组合增强植被特征表示。

表8 MFVNet增加不同植被指数组合方案的结果
Table 8 The results of MFVNet adds different vegetation index combinations

类别	方案1			方案2			方案3			方案4			方案5		
	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1	P/%	R/%	F1
芦苇	89.3	91.4	0.90	89.5	91.6	0.91	84.9	89.5	0.87	89.1	89.4	0.89	87.1	90.0	0.89
互花米草	85.6	86.8	0.86	85.9	88.1	0.87	86.9	85.0	0.86	78.8	89.2	0.84	81.6	87.9	0.85
怪柳混生区	82.3	77.3	0.80	83.5	80.1	0.82	79.1	74.8	0.77	82.7	77.7	0.80	73.4	73.9	0.74
海草床	67.0	60.3	0.64	83.1	70.5	0.76	73.1	76.8	0.75	80.9	65.1	0.72	74.1	70.4	0.72
裸潮滩	91.4	89.3	0.93	94.1	92.7	0.93	92.3	93.0	0.93	93.0	92.8	0.93	90.3	94.3	0.92
潮滩稀疏植被	80.0	73.8	0.76	78.3	80.6	0.79	80.6	76.7	0.78	80.5	76.0	0.78	80.1	67.5	0.73
水体	98.5	98.4	0.98	98.3	98.5	0.98	98.4	98.5	0.98	98.1	98.6	0.98	98.6	98.1	0.98
其他	89.3	79.4	0.84	87.2	79.4	0.83	86.0	84.3	0.85	87.0	83.7	0.85	90.0	74.2	0.81
OA/%	93.20±0.05			93.78±0.17			93.28±0.17			93.41±0.14			93.20±0.19		
Kappa×100	89.63±0.06			90.66±0.30			89.75±0.27			90.06±0.37			89.64±0.31		

注：OA和Kappa分别为10次实验结果的均值±标准差,黑体代表最高精度。

4 结 论

本文提出了一种结合深度学习和植被指数的滨海湿地信息提取网络MFVNet，缓解了植被易被混淆分类的问题，结果的总体精度和Kappa分别达到93.89%和0.9072。为了有效捕获不同尺度的地物特征，本文基于空洞卷积和注意力机制提出了增强多尺度特征提取模块，有效提高了滨海湿地信息提取精度。针对滨海湿地植被易被混淆分类，且部分植株矮小和分布稀疏导致在遥感影像上特征不明显的问题，本文引入了典型植被指数以增强植被特征，并基于MFVNet实验了不同植被指数对信息提取的影响。实验表明，同时增加修正土壤调节植被指数MSAVI、差值植被指数DVI和比值植被指数RVI可对滨海湿地信息提取的贡献最大。

本文的实验证明，在深度语义分割网络中加入植被指数有利于提高滨海湿地植被的信息提取精度，但本文仅初步探究了不同典型植被指数对滨海湿地信息提取的作用，未涉及不同时相植被指数的影响分析。下一步计划引入多时相遥感影像，研究不同时相下的植被指数与深度学习结合对改善滨海湿地植被信息提取精度的影响。

参考文献(References)

Chen L C, Zhu Y, Papandreou G, Schroff F and Adam H. 2018. Encoder-decoder with atrous separable convolution for semantic image

segmentation//Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich: Springer [DOI: 10.1007/978-3-030-01234-2_49]
Fan D Q, Zhao X S, Zhu W Q and Zheng Z T. 2016. Review of influencing factors of accuracy of plant phenology monitoring based on remote sensing data. Progress in Geography, 35(3): 304-319 (范德芹, 赵学胜, 朱文泉, 郑周涛. 2016. 植物物候遥感监测精度影响因素研究综述. 地理科学进展, 35(3): 304-319) [DOI: 10.18306/dlkxjz.2016.03.005]
Feng Q L, Yang J Y, Zhu D H, Liu J T, Guo H, Bayartungalag B and Li B G. 2019. Integrating multitemporal sentinel-1/2 data for coastal land cover classification using a Multibranch convolutional neural network: a case of the Yellow River delta. Remote Sensing, 11(9): 1006 [DOI: 10.3390/rs11091006]
Han X S, Pan J Y and Devlin A T. 2018. Remote sensing study of wetlands in the Pearl River delta during 1995-2015 with the support vector machine method. Frontiers of Earth Science, 12(3): 521-531 [DOI: 10.1007/s11707-017-0672-x]
Hu Y B, Zhang J, Ma Y, An J B, Ren G B and Li X M. 2019b. Hyperspectral coastal wetland classification based on a multiobject convolutional neural network model and decision fusion. IEEE Geoscience and Remote Sensing Letters, 16(7): 1110-1114 [DOI: 10.1109/LGRS.2018.2890421]
Hu Y B, Zhang J, Ma Y, Li X M, Sun Q P and An J B. 2019a. Deep learning classification of coastal wetland hyperspectral image combined spectra and texture features: a case study of Huanghe (Yellow) River Estuary wetland. Acta Oceanologica Sinica, 38(5): 142-150 [DOI: 10.1007/s13131-019-1445-z]
Ibtehaz N and Rahman M S. 2020. MultiResUNet: rethinking the U-Net architecture for multimodal biomedical image segmentation. Neural Networks, 121: 74-87 [DOI: 10.1016/j.neunet.2019.08.025]
Li X W, Ji G S and Yang J. 1995. Estimating cyanophyta biomass

- standing crops in Meiliang Gulf of Lake Taihu by satellite remote sensing. *Remote Sensing for Land and Resources*, 1995, 7(2): 23-28 (李旭文, 季耿善, 杨静. 太湖梅梁湖湾蓝藻生物量遥感估算. 国土资源遥感, 1995(02):23-28) [DOI: 10.6046/gtzyyg.1995.02.04]
- Lin T Y, Dollár P, Girshick R, He K M, Hariharan B and Belongie S. 2017. Feature pyramid networks for object detection//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE [DOI: 10.1109/CVPR.2017.106]
- Liu C, Tao R, Li W, Zhang M M, Sun W W and Du Q. 2021. Joint classification of hyperspectral and multispectral images for mapping coastal wetlands. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 982-996 [DOI: 10.1109/JSTARS.2020.3040305]
- Liu J F, Li L F, Ren C Y, Mao D H and Zhang B. 2018. Information extraction of coastal wetlands in Yellow River estuary by optimal feature-based random forest model. *Wetland Science*, 16(2): 97-105 (刘家福, 李林峰, 任春颖, 毛德华, 张柏. 2018. 基于特征优选的随机森林模型的黄河口滨海湿地信息提取研究. 湿地科学, 16(2): 97-105) [DOI: 10.13248/j.cnki.wetlandsci.2018.02.001]
- Liu Y B, Han M, Pan B and Liu Y R. 2017. The spatial distribution of vegetation biomass and soil salinity in new-born wetlands of the Yellow River delta. *Wetland Science*, 15(3): 364-368 (刘玉斌, 韩美, 潘彬, 刘延荣. 2017. 黄河三角洲新生湿地植物生物量和土壤含盐量空间分布. 湿地科学, 15(3): 364-368) [DOI: 10.13248/j.cnki.wetlandsci.2017.03.007]
- Lu H T and Zhang Q C. 2016. Applications of deep convolutional neural network in computer vision. *Journal of Data Acquisition and Processing*, 31(1): 1-17 (卢宏涛, 张秦川. 2016. 深度卷积神经网络在计算机视觉中的应用研究综述. 数据采集与处理, 31(1): 1-17) [DOI: 10.16337/j.1004-9037.2016.01.001]
- Luo W J, Li Y J, Urtasun R and Zemel R. 2016. Understanding the effective receptive field in deep convolutional neural networks//Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona: Curran Associates Inc.
- Meng X R. 2019. Study on Remote Sensing Finer Classification of Freshwater Wetland Based on Deep Learning. Harbin: Harbin Normal University (孟祥锐. 2019. 基于深度学习的淡水湿地遥感精细分类研究. 哈尔滨: 哈尔滨师范大学) [DOI: 10.27064/d.cnki.ghasu.2019.000087]
- Pearson R L and Miller L D. 1972. Remote mapping of standing crop biomass for estimation of the productivity of the short-grass prairie//Proceedings of the Eighth International Symposium on Remote Sensing of Environment. Ann Arbor: [s.n.]: 7-12 [DOI: 10.1177/002076409904500102]
- Qi J G, Chehbouni A, Huete A R, Kerr Y H and Sorooshian S. 1994. A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2): 119-126 [DOI: 10.1016/0034-4257(94)90134-1]
- Ronneberger O, Fischer P and Brox T. 2015. U-Net: convolutional networks for biomedical image segmentation//18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Rouse J W, Haas R H, Schell J A and Deering D W. 1974. Monitoring vegetation systems in the great plains with ERTS//Third Earth Resources Technology Satellite-1 Symposium. Washington: NASA: 309-317
- Sun K, Xiao B, Liu D and Wang J D. 2019. Deep high-resolution representation learning for human pose estimation//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach: IEEE [DOI: 10.1109/cvpr.2019.00584]
- Wang J, Song J W, Chen M Q and Yang Z. 2015. Road network extraction: a neural-dynamic framework based on deep learning and a finite state machine. *International Journal of Remote Sensing*, 36(12): 3144-3169 [DOI: 10.1080/01431161.2015.1054049]
- Wang J B, Zhang J, Ma Y and Ren G B. 2014. Classification method of hyperspectral image in typical surface feature of Huanghe River estuary wetland. *Journal of Marine Sciences*, 32(3): 36-41 (王建步, 张杰, 马毅, 任广波. 2014. 黄河口湿地典型地物类型高光谱分类方法. 海洋学研究, 32(3): 36-41) [DOI: 10.3969/j.issn.1001-909X.2014.03.005]
- Xu D X and Zhang G X. 2007. Impact of Human activities on coastal wetlands in China. *Wetland Science*, 5(3): 282-288 (徐东霞, 章光新. 2007. 人类活动对中国滨海湿地的影响及其保护对策. 湿地科学, 5(3): 282-288) [DOI: 10.13248/j.cnki.wetlandsci.2007.03.013]
- Yang J F, Ren G B, Ma Y and Fan Y G. 2016. Coastal wetland classification based on high resolution SAR and optical image fusion//2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Beijing: IEEE [DOI: 10.1109/IGARSS.2016.7729224]
- Zhang C J, Zhu L, Yu L. 2021. Review of Attention Mechanism in Convolutional Neural Networks. *Computer Engineering and Applications*, 2021, 57(20):64-72 (张宸嘉, 朱磊, 俞璐. 卷积神经网络中的注意力机制综述. 计算机工程与应用, 2021, 57(20):64-72)
- Zhang L, Gong Z N, Wang Q W, Jin D D and Wang X. 2019. Wetland mapping of Yellow River Delta wetlands based on multi-feature optimization of Sentinel-2 images. *Journal of Remote Sensing*, 23(2): 313-326 (张磊, 宫兆宁, 王启为, 金点点, 汪星. 2019. Sentinel-2影像多特征优选的黄河三角洲湿地信息提取. 遥感学报, 23(2): 313-326) [DOI: 10.11834/jrs.20198083]
- Zhao H S, Shi J P, Qi X J, Wang X G and Jia J Y. 2017. Pyramid scene parsing network//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE: 6230-6239 [DOI: 10.1109/CVPR.2017.660]
- Zhou F Y, Jin L P and Dong J. 2017. Review of convolutional neural network. *Chinese Journal of Computers*, 40(6): 1229-1251 (周飞燕, 金林鹏, 董军. 2017. 卷积神经网络研究综述. 计算机学报, 40(6): 1229-1251) [DOI: 10.11897/SP.J.1016.2017.01229]
- Zhu Y L. 2020. Remote-Sensed Monitoring and Analysis of Invasive Alien Species *Spartina Alterniflora* in Shandong Province Based on Deep Learning Classification Method. Qingdao: First Institute of Oceanography, Ministry of Natural Resources. (朱玉玲. 2020. 基于深度学习分类方法的山东省外来入侵物种互花米草遥感监测与分析. 青岛: 自然资源部第一海洋研究所) [DOI: 10.27058/d.cnki.gohyy.2020.000007]

Combination of deep learning and vegetation index for coastal wetland mapping using GF-2 remote sensing images

CUI Binge¹, WU Jing¹, LI Xinhui¹, REN Guangbo², LU Yan¹

1.College of Computer Science and Engineering, Shandong University of Science and Technology, Qingdao 266590, China;

2.First Institute of Oceanography, Ministry of Natural Resources, Qingdao 266061, China

Abstract: The biomass and growth of coastal wetland vegetation vary greatly due to different water and salt conditions in the growing area, and the spectral features of certain vegetation at the peak biomass are highly similar, making it easy for coastal wetland vegetation to be misclassified. In response to this problem, this study proposes a new semantic segmentation network called MFVNet to be combined with vegetation index for the fine mapping of coastal wetlands.

In the proposed MFVNet, an Enhanced Multiscale Feature Extraction (E-MFE) module was first constructed on the basis of atrous convolution and attention mechanism to capture features of different scales adaptively. Then, the E-MFE module was used to replace the double convolution operations in traditional encoder-decoder network architecture, such as UNet. It was also used to merge the semantic features and detailed features of different resolutions to enhance feature representation. Finally, some typical vegetation indices were selected and input into the proposed MFVNet to improve the ability of coastal wetland fine mapping.

The experiments of this study were conducted using GF-2 remote sensing images to study the coastal wetlands of the Yellow River Estuary. Experimental results indicated that the proposed MFVNet achieved good performance with an overall accuracy of 93.89% and a Kappa coefficient of 0.9072. On typical vegetation, such as reeds, *spartina alterniflora*, *tamarix* mixed area, and seagrass beds in the Yellow River Estuary, the F1 scores of MFVNet were 0.91, 0.87, 0.82, and 0.76, respectively, which were better than that of other methods. Moreover, ablation experiments showed that the combination of the E-MFE module and the vegetation index can increase the overall accuracy from 91.46% to 93.89%.

(1) Compared with deep semantic segmentation networks, such as HRNet, MFVNet can more effectively extract vegetation information of coastal wetlands. (2) The proposed EMFE module can adaptively capture features of different scales and improve the overall accuracy, which justified its effectiveness in coastal wetland mapping. (3) The inclusion of vegetation index can enhance the spectral features of coastal wetland vegetation and improve the accuracy of vegetation information extraction, indicating the importance of vegetation index in coastal wetland mapping. (4) Simultaneously splicing modified soil adjusted vegetation index, difference vegetation index, and ratio vegetation index in remote sensing images contributed the most to the extraction of coastal wetland information.

Key words: remote sensing, coastal wetland information extraction, GF-2, deep convolutional neural network, MFVNet model, vegetation index

Supported by National Natural Science Foundation of China (No. 62072287, 42076189); Natural Science Foundation of Shandong Province (No. ZR2020MD096, ZR2020MD099)