



引文格式:熊思婷,韦如依,侯伟,等.结合 LSTM 模型与 InSAR 相干性矩阵的土地覆盖分类方法[J].武汉大学学报(信息科学版),2025,50(8):1542-1554.DOI:10.13203/j.whugis20240460

Citation: XIONG Siting, WEI Ruyi, HOU Wei, et al. Land Cover Classification Based on InSAR Coherence and LSTM Model [J]. Geomatics and Information Science of Wuhan University, 2025, 50(8): 1542-1554. DOI: 10.13203/j.whugis20240460

# 结合 LSTM 模型与 InSAR 相干性矩阵的 土地覆盖分类方法

熊思婷<sup>1</sup> 韦如依<sup>1</sup> 侯伟<sup>2</sup> 邓志超<sup>1</sup> 张博琛<sup>3,4,5,6</sup>  
燕琴<sup>2</sup> 李清泉<sup>1,4</sup>

1 人工智能与数字经济广东省实验室(深圳),广东 深圳,518107

2 中国测绘科学研究院,北京,100036

3 深圳大学广东省城市空间信息工程重点实验室,广东 深圳,518061

4 深圳大学自然资源部大湾区地理环境监测重点实验室,广东 深圳,518061

5 深圳大学深圳市空间信息智能感知与服务重点实验室,广东 深圳,518061

6 深圳大学土木与交通工程学院,广东 深圳,518060

**摘要:**土地覆盖类型检测对地表特征理解、生态环境监测和自然资源管理具有重要意义。基于哨兵 1 号(Sentinel-1)多时相相干性矩阵,搭建长短期记忆网络(long short-term memory, LSTM)土地覆盖分类模型,旨在评估其在土地覆盖分类中的效能,探讨不同分类方法对分类结果的影响,并以中国辽宁省阜新市彰武县为研究区对 4 种不同土地覆盖分类方法进行验证。实验结果显示,基于 Sentinel-1 相干性矩阵的 LSTM 分类模型方法在 3 个区域的分类精度分别高达 93.7%、89.9% 和 87.6%,具有较高的分类精度和鲁棒性,比基于 Sentinel-1 相干性向量的支持向量机(support vector machine, SVM)分类模型、基于 Sentinel-1 相干性矩阵的卷积神经网络分类模型以及基于哨兵 2 号(Sentinel-2)多光谱影像的 SVM 分类模型的方法分类精度高约 1%~10%。此外,基于 Sentinel-1 相干性矩阵的 LSTM 分类模型方法还在不同子研究区之间进行了迁移学习实验,结果显示,该模型在子区域迁移时的泛化能力仍需增强。

**关键词:**多时相相干性;LSTM 模型;土地覆盖分类;InSAR

中图分类号:P237

文献标识码:A

收稿日期:2025-01-15

DOI:10.13203/j.whugis20240460

文章编号:1671-8860(2025)08-1542-13

## Land Cover Classification Based on InSAR Coherence and LSTM Model

XIONG Siting<sup>1</sup> WEI Ruyi<sup>1</sup> HOU Wei<sup>2</sup> DENG Zhichao<sup>1</sup> ZHANG Bochen<sup>3,4,5,6</sup>  
YAN Qin<sup>2</sup> LI Qingquan<sup>1,4</sup>

1 Guangdong Laboratory of Artificial Intelligence and Digital Economy (Shenzhen), Shenzhen 518107, China

2 Chinese Academy of Surveying & Mapping, Beijing 100036, China

3 Guangdong Key Laboratory of Urban Informatics, Shenzhen University, Shenzhen 518061, China

4 Key Laboratory for Geo-Environmental Monitoring of Great Bay Area, Ministry of Natural Resources, Shenzhen University, Shenzhen 518061, China

5 Shenzhen Key Laboratory of Spatial Smart Sensing and Services, Shenzhen University, Shenzhen 518061, China

6 School of Civil and Transportation Engineering, Shenzhen University, Shenzhen 518060, China

**Abstract: Objectives:** Land cover classification is crucial for understanding surface features, monitoring ecological environments, and managing natural resources. The objective of this research is to construct a long short-term memory (LSTM) model for land cover classification using Sentinel-1 multi-temporal coherence matrices and to evaluate its effectiveness by comparing it against other three classification methods.

**基金项目:**地理信息工程国家重点实验室、测绘科学与地球空间信息技术自然资源部重点实验室联合资助基金(2023-03-11);广东省基础与应用基础研究基金(2022A1515110861);国家自然科学基金(42404012,42304014)。

**第一作者:**熊思婷,博士,副研究员,主要从事合成孔径雷达数据处理工作。xionsiting@gml.ac.cn

**通信作者:**侯伟,博士,副研究员。houwei@casm.ac.cn

**Methods:** Multi-temporal coherence matrices from Sentinel-1 synthetic aperture radar images were used to train an LSTM neural network for land cover classification. The Sentinel-1 coherence matrix was firstly transformed to sequences according to the temporal baseline intervals and then input into the LSTM model to predict the land cover types. This LSTM-based method was then compared against other three methods: (1) support vector machine (SVM) and (2) convolutional neural network models taking the Sentinel-1 coherence vectors and matrices as input, and (3) SVM model with the input of Sentinel-2 multi-spectral features. Transfer learning experiments were also conducted to assess the generalization capability of the LSTM-based method. **Results:** The study area was selected in Zhangwu County, Fuxin City, Liaoning Province, China, where three test regions are chosen to conduct the land cover classification by using the four different methods, respectively. Experimental results demonstrated that the LSTM model with the Sentinel-1 coherence matrices achieved classification accuracies of 93.7%, 89.9% and 87.6% in the three test regions, respectively, with an improvement in classification accuracy by approximately 1% to 10% compared to other methods. However, the results of the transfer learning experiments reveal that the generalization capability of the LSTM model is not desirable and needs further enhancement. When trained solely on region 1 and tested on regions 2 and 3, classification accuracies dropped to 45.7% and 47.4%. To enhance classification performance and model generalizability, a comprehensive sampling strategy was implemented by integrating data from all three regions for unified training. This approach achieved regional classification accuracies of 92.8%, 87.8%, and 86.4%, effectively mitigating sample distribution bias and significantly improving cross-region adaptability. **Conclusions:** The LSTM model utilizing Sentinel-1 coherence matrices as input features shows promising performance in land cover classification, particularly in areas affected by cloud cover. However, transferability of the model has high demand for the training samples, which can inhibit its applicability to wider regions. Future research is needed to optimize transfer learning strategies to enhance the model's adaptability and classification accuracy across different experimental regions.

**Key words:** multi-temporal coherence; LSTM model; land cover classification; InSAR

土地覆盖类型是生态系统全球变化中最重要的变量之一,土地覆盖分类对于地表特征理解、生态环境监测以及自然资源管理至关重要<sup>[1-3]</sup>,不仅有助于评估和监测土地利用变化,而且有助于气候变化研究、生物多样性保护和可持续发展政策的制定与实施<sup>[4-6]</sup>。高效、准确的土地覆盖分类能够为城市规划、环境保护、智慧农业等行业领域提供科学的数据支撑<sup>[7-9]</sup>。传统的野外采样与调查方法能够获取高精度的土地覆盖分类,然而时间和人力成本较高,难以实现大范围、高频率的监测,特别是在地形复杂或难以进入的区域。随着遥感技术的发展、遥感数据的不断积累,人们需要逐渐发展基于遥感技术的土地覆盖分类方法<sup>[10-12]</sup>。

根据不同遥感数据源,可以将基于遥感技术的土地覆盖分类分为基于光学遥感图像的土地覆盖分类和基于星载合成孔径雷达(synthetic aperture radar, SAR)图像的土地覆盖分类方法。近年来,大数据技术、人工智能技术等领域的迅猛发展,基于遥感技术的土地覆盖分类方法逐渐融合数据挖掘、人工智能等先进技术挖掘遥感信息

与土地覆盖分类之间的内在关联,以降低对野外采样数据的需求<sup>[13-16]</sup>。例如,文献[17]比较了4种非参数机器学习算法在瑞典中部复杂景观中的分类效果,采用多时相哨兵2号(Sentinel-2)多光谱影像进行实验,结果表明,支持向量机(support vector machine, SVM)在总体精度上表现最佳,达到了75.8%的准确率。文献[18]基于随机森林(random forest, RF)利用2017年多时相Sentinel-2多光谱影像进行土地覆盖分类,实现了覆盖欧洲大陆的大范围高分辨率土地覆盖制图,整体精度达到了86.1%。基于光学遥感图像的方法在土地覆盖分类上尽管取得了不错的分类精度,但也存在明显的不足。例如,植被生长可能导致光谱特征变化,从而影响分类结果的一致性与准确性<sup>[19]</sup>。此外,光学遥感受云雨影响无法获取有效的图像,这极大地限制了该方法在云雨频发区域的应用效果。

与光学图像相比,SAR成像不受云雨影响,且具备全球化的观测能力<sup>[20-21]</sup>,它不仅能够提供图像信息,还能够提供与土地变化过程相关的相干性信息,为土地覆盖分类提供重要依据<sup>[22-23]</sup>。

已有研究利用合成孔径雷达干涉测量(interferometric synthetic aperture radar, InSAR)技术获得的相干性进行土地覆盖分类,认为InSAR相干性作为一种反映土地覆盖类型稳定性的指标,在土地覆盖分类中展现出巨大潜力<sup>[24]</sup>。文献[25]利用哨兵1号(Sentinel-1)数据分析了美国南加州柯汶纳市及其周边区域不同地物的时间失相干现象,发现典型地物的失相干特征区别较大,可以较好地指导地物识别、辅助土地分类。文献[26]在黄河三角洲的研究表明,引入相干性时间序列变量后,SVM和RF分类结果的总体精度分别提升了3.07%和3.85%。文献[27]基于Sentinel-1数据评估了InSAR短期时间基线相干性在植被分类中的应用,并将其与基于后向散射强度的分类方法进行了对比,在复杂的农业区域的实验结果表明,结合后向散射强度与相干性特征的分类准确率显著高于仅使用后向散射强度的方法。文献[28]研究了多种Sentinel-1数据特征(干涉相干性、后向散射强度和极化信息)在土地覆盖和植被制图中的适用性,并在西班牙塞维利亚、意大利南蒂罗尔和波兰西部进行的实验结果表明,相干性作为输入特征有助于获得较高的整体准确率。文献[29]基于InSAR多时相相干性采用卷积神经网络(convolutional neural network, CNN)与SVM方法在法国尚贝里地区进行土地覆盖分类实验,结果表明,以相干性矩阵为输入特征的CNN在整体分类准确率比以相干性向量为输入特征的SVM提高了3%。上述研究表明,利用多时相InSAR相干性可以捕捉到不同土地覆盖类型随时间变化的模式特征,从而实现更加精细的土地覆盖分类。

InSAR相干性与时间基线密切相关,不同土地覆盖类型随着时间的推移其相干性变化不同,而长短期记忆网络(long short-term memory, LSTM)由于其特有的记忆单元和门控机制能够捕捉到这些动态特性。已有研究证明,LSTM可以有效地处理长时间序列数据,并且在处理分类任务上表现优异。例如,文献[30]利用灰度共生矩阵纹理分析和形态学剖面处理后的InSAR相干性图像,基于4层LSTM在西班牙西南部的湿地国家公园进行土地覆盖分类实验,结果表明,总体分类准确率达到90%,尤其在小面积土地覆盖元素上的性能尤为出色。文献[31]利用Sentinel-1影像序列强度值和资源三号光学图像,基于4层LSTM网络在中国湖南省北部对作物

类型进行了分类,实验结果显示,LSTM的分类总体精度达到了83.67%,比SVM和RF分类模型的总体精度分别提高了约8.0%和7.0%。文献[32]提出了一种融合时空信息的4层卷积LSTM(convolutional LSTM, ConvLSTM),并在两个真实的极化SAR图像数据集上进行了土地覆盖分类实验,结果表明,ConvLSTM总体精度达到了99%,比SVM和LeNet-5分别提升了约8%和2%。上述研究表明,LSTM及其变体在分类任务中展现出显著的优势与适用性。

鉴于此,本文提出利用LSTM模型来捕捉多时相InSAR相干性的变化,利用其变化规律与覆盖类型建立模型,从而实现较高精度的土地覆盖分类。以中国辽宁省阜新市彰武县为研究区域,研究结合Sentinel-1多时相相干性矩阵与LSTM模型进行土地覆盖类型分类的有效性,并对比分析LSTM模型、SVM和CNN模型对土地覆盖分类的影响。

## 1 研究区概况与数据

### 1.1 研究区域概况

研究区位于中国辽宁省阜新市彰武县( $42^{\circ}07'N\sim 42^{\circ}51'N$ ,  $121^{\circ}53'E\sim 122^{\circ}58'E$ ),如图1所示,其面积约3 641 km<sup>2</sup>,土地覆盖类型丰富,包括城区、森林、草原、灌丛、湿地和沙地等。本文选择彰武县境内3个具有代表性的子区域进行土地覆盖分类实验,如图2所示,区域1为沿河农村,主要特征是河流贯穿其中,周边分布着农田和少量的居民点,面积约为7.1 km<sup>2</sup>;区域2是附近有森林的农村区域,靠近大片森林,植被类型多样,包括耕地、草地和林地等,面积约为4.3 km<sup>2</sup>;区域3为城市郊区,呈现出明显的城乡结合部特点,密集的城市建筑群占主要地位,也有一定的裸地和植被,面积约为4 km<sup>2</sup>。

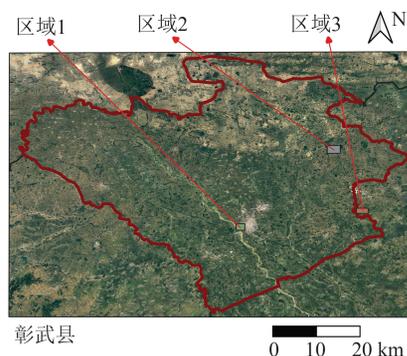


图1 研究区域地理位置示意图

Fig. 1 Location of the Study Area

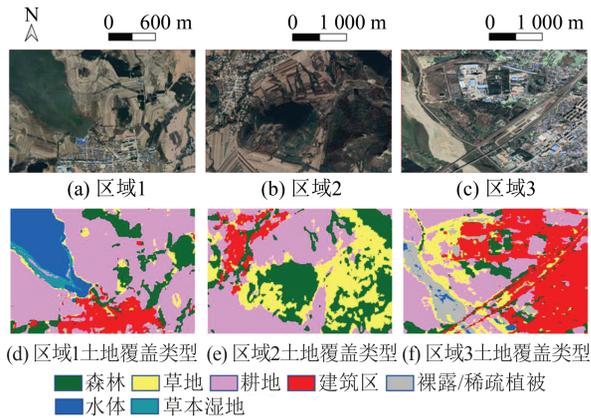


图 2 3 个主要研究地块及其土地覆盖类型  
Fig. 2 Land Cover Types in Three Main Study Areas

## 1.2 输入数据获取与处理

Sentinel-1 是欧洲空间局 (European Space Agency, ESA) 推出的哥白尼计划中的一项全天候、全天时的 C 波段 SAR 卫星任务,由两颗极轨 C 波段 SAR 卫星 (1A、1B) 组成,重访周期为 6~12 d<sup>[33]</sup>。本文获取了 2019-01-06—2019-08-10 的 19 景 Sentinel-1A 单视复数 (single look complex, SLC) 图像,重访周期为 12 d。干涉处理采用同极化干涉宽幅模式以及多视干涉方式:距离向多视视数为 20,方位向多视视数为 4,多视后距离向分辨率约 47 m,方位向分辨率约 56 m。

Sentinel-2 同样是哥白尼计划中的重要组成部分,是一项高分辨率多光谱成像卫星任务,由两颗太阳同步轨道卫星 (2A、2B) 组成,双卫星配合可实现 5 d 的重访周期,并提供 13 个光谱波段的高分辨率 (10 m、20 m 和 60 m) 数据<sup>[34]</sup>。得益于其高空间分辨率、较高的时间分辨率以及红边波段的优势, Sentinel-2 能够更精确地捕捉地表特征,从而有效提高土地覆盖分类的精度<sup>[35]</sup>。本文使用的 Sentinel-2 数据在谷歌地球引擎上进行检索和处理,检索 2019-01-06—2019-08-10 之间的 Sentinel-2 数据,计算不同时相的中值作为 B2、B3、B4、B8 波段值,在此基础上进一步计算归一化差异植被指数 (normalized difference vegetation index, NDVI) 和改进的归一化差异水体指数 (modified normalized difference water index, MNDWI)。

土地覆盖数据采用 ESA 的 WorldCover 数据集,该数据集基于 Sentinel-1 和 Sentinel-2 数据生产,提供了 2021 年 10 m 分辨率的全球土地覆盖图,包含森林、灌木丛、草地、耕地、建筑区、裸露/稀疏植被、雪和冰、水体、草本湿地、红树林以及苔藓地衣 11 个土地覆盖类别<sup>[36]</sup>。这一数据集官

方评估的总体准确率为 76.7%,在亚洲的总体准确率达 82.1%,鉴于其较高的准确性,在实地数据难以获取的地区,常被作为验证数据来验证地物覆盖分类结果<sup>[37]</sup>。此外,WorldCover 数据集是利用 Sentinel-1 的 GAMMA0 后向散射时间序列结合 Sentinel-2 的多光谱影像提取出的特征,包括植被指数、地形信息 (如高程和坡度),以及从 TerraClimate 数据集中派生的年气象特征等辅助信息,而本文提出的方法是采用 InSAR 相干性,与 WorldCover 数据集利用的数据源信息不同,可起到交叉验证作用。本文选取的 WorldCover 数据和 Sentinel-2 数据则通过谷歌地球引擎平台直接获取。

## 2 研究方法

本文提出基于 Sentinel-1 的多时相相干性矩阵和 LSTM 模型进行土地覆盖类型分类,具体流程见图 3,包括 Sentinel-1 影像序列的预处理、Sentinel-2 多光谱图像的预处理、不同土地覆盖分类模型的构建,以及在研究区的土地覆盖分类预测及精度验证。Sentinel-1 影像序列预处理包括影像下载、裁剪与配准、多视相干性图计算、相干性图重采样和相干性矩阵生成,详细步骤见 §2.1。基于相干性矩阵按对角线特征提取构建 LSTM 分类模型,详见 §2.2。作为对比研究,根据相干性矩阵可按不同方式提取特征分别构建 SVM 分类模型和 CNN 分类模型,详见 §2.3。Sentinel-2 影像预处理包括波段提取和归一化指数计算,基于提取的多波段特征构建基于 SVM 的分类模型,详见 §2.3。并通过多个精度评估指标对各模型进行性能评估,评估方法详见 §2.4。

### 2.1 相干性计算与相干图像重采样

为了获取相干性数据,本研究选取了 19 景 Sentinel-1A SAR 影像序列,并将这些影像序列两两配对进行干涉处理形成了 171 个干涉图像对。每对影像在配对前经过了严格的几何校正,以确保干涉测量的准确性。随后,采用 20×5 像素的多视窗技术对这些干涉图像进行处理,以降低噪声并提高相干性估计的稳定性。干涉相干性是两幅配准的 SAR 图像之间的归一化互相关系数<sup>[27]</sup>,取值范围为 0~1。计算公式如下:

$$\gamma = \frac{E \{ S_1 \cdot S_2^* \}}{\sqrt{E \{ |S_1|^2 \} \cdot E \{ |S_2|^2 \}}} \quad (1)$$

式中, $S_1$  和  $S_2$  表示两幅 SAR 复数图像; $E \{ \cdot \}$  表示数学期望;\* 表示复共轭算子; $|S|$  表示  $S$  的幅度。

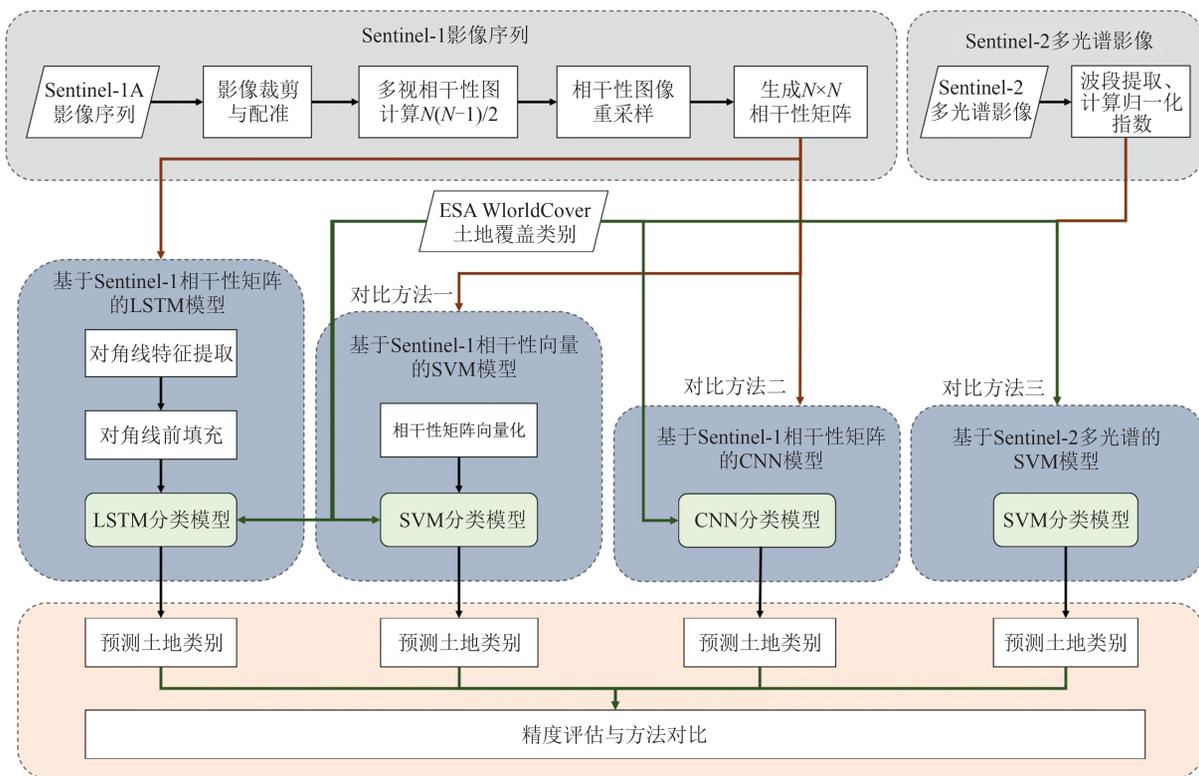


图3 总体工作流程图

Fig. 3 Overview of the Processing Workflow

计算出相干性数据后,根据 WorldCover 空间分辨率,对 171 张相干图像进行重采样处理。随后,按照每个干涉图像对之间的干涉时间间隔顺序对其进行排序,从而生成一个沿主对角线呈现对称特性的多时相相干性矩阵。由于相同干涉时间间隔的数值沿着对角线规律分布,本文沿对角线提取相干性矩阵的上三角部分,将该上三角矩阵转化为不等长的时间序列,这一过程的具体实现方式如图 4 所示。为统一序列长度,本文采取等长前填充的方式对特征进行补零调整,并使用 Masking 层标记填充值,确保模型在计算时忽略这些值。这样,每个序列不仅保持了其原始的时间动态特性,同时也能够被统一地输入到模型中进行处理。

对于基于 Sentinel-1 相干性向量的 SVM 分类模型(即图 3 中对比方法一),从多时相相干性矩阵中提取上三角部分后,采用行优先算法将其线性化为相干性向量,作为 SVM 分类模型的输入特征。而对于基于 Sentinel-1 相干性矩阵的 CNN 分类模型(即图 3 中对比方法二),直接利用多时相相干性矩阵作为输入特征,并将其输入至 CNN 模型中进行土地覆盖类型的识别。该方法保留了矩阵的二维结构,允许 CNN 通过卷积操作自动学习和提取特征。处理流程示意图如图 4 所示,图 4 中展示了 3 种不同的特征提取与模型

输入方式。

## 2.2 LSTM 土地覆盖分类模型构建

本文主要采用 LSTM 神经网络训练和测试土地覆盖分类模型。首先,将经过处理的多时相相干性序列作为输入特征送入 LSTM 分类模型,同时利用 WorldCover 采样数据训练并检验 LSTM 分类模型。将数据集划分为训练集和测试集两个子集,训练子集占数据集的 80%,用于训练模型,让模型掌握从相干性序列到不同类别的映射规律;测试子集占数据集的 20%,独立于训练过程,用于最终评估模型的泛化能力。

图 5 为 LSTM 模型的架构,包括一个单向 LSTM 层,含有 128 个隐藏单元和 ReLU 激活函数,后接一个全连接层用于分类,使用 Softmax 激活函数。模型训练的优化器选用 Adam 优化器,这种优化器能够自适应地调节学习速率,加速模型的收敛速度,损失函数则为分类交叉熵,并使用早停策略来监控损失变化,当损失不再改善时提前停止训练,防止过拟合。此外,模型编译时加入了 Masking 层以处理填充值,确保模型在训练时忽略这些值。模型的输入形状则由训练数据的时间步长和特征数确定。

## 2.3 对比实验模型

为验证基于 Sentinel-1 相干性矩阵和 LSTM 模型的土地覆盖分类结果,本文选择了两种

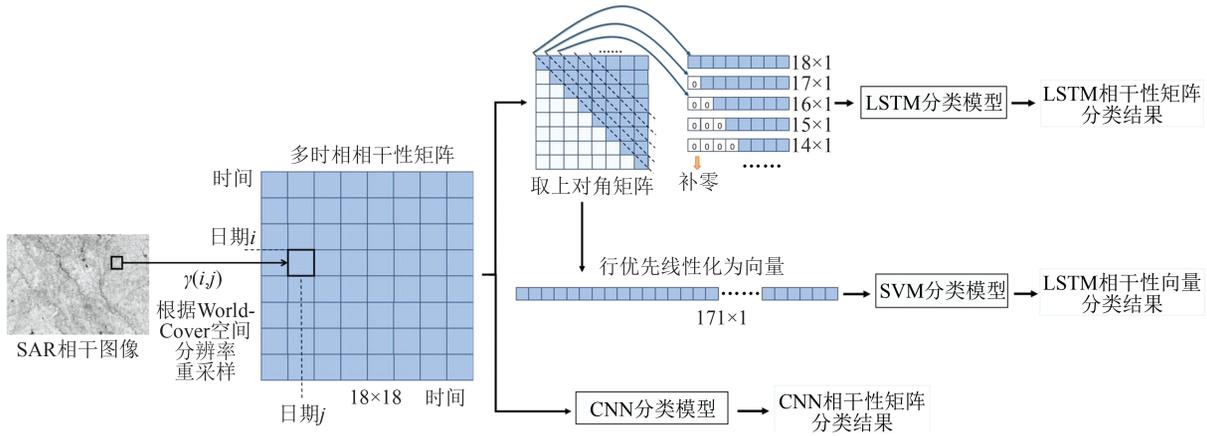


图 4 特征提取示意图

Fig. 4 Feature Extraction Diagram

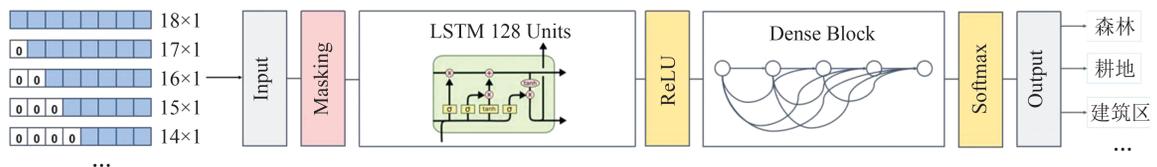


图 5 LSTM 模型架构

Fig. 5 LSTM Model Architecture

广泛使用的模型架构 SVM 和 CNN 进行对比实验<sup>[29]</sup>,对比方法一和对比方法二的输入特征已在 §2.1 说明,这里不再赘述。

对比方法一中的 SVM 模型使用径向基函数 (radial basis function, RBF) 作为核函数,通过计算数据点在高维特征空间中的相似度来实现分类。模型的惩罚参数  $C$  被设定为 1,用于调节模型的复杂度,从而控制过拟合的风险。训练过程中,优化算法选择了序列最小优化算法,该算法通过最大化决策边界来寻找最优超平面,从而提高分类性能。同时,模型使用了 Hinge 损失函数,以确保分类准确率,

并尽可能扩大不同类别之间的间隔。

对比方法二中的 CNN 模型由两个卷积层组成,第一层有 32 个  $3 \times 3$  卷积核,第二层有 64 个,均使用 ReLU 激活函数。每个卷积层后接  $2 \times 2$  最大池化层以降低特征图维度。第二个池化层后是展平层,将输出转换为一维向量,随后是一个含 128 个神经元的全连接层,同样使用 ReLU 激活函数。输出层神经元数量与土地覆盖类别数匹配,采用 Softmax 函数输出多类别概率。模型以 Adam 优化器和分类交叉熵损失函数进行训练,模型架构见图 6。

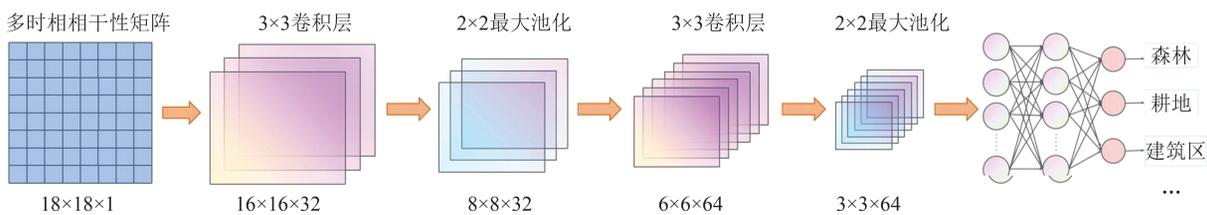


图 6 CNN 模型架构

Fig. 6 CNN Model Architecture

基于 Sentinel-2 多光谱影像的 SVM 模型 (即图 3 中对比方法三) 采用 Sentinel-2 的高分辨率多光谱影像 (B2、B3、B4、B8 波段,空间分辨率为 10 m) 作为输入特征,送入 SVM 分类模型中进行比较分析,如图 7 所示。为进一步增强分类的准确性,本文还将 NDVI 和 MNDWI 纳入分类过程中,其中 NDVI 有助于区分不同类型的植被覆盖,MNDWI 有助于

准确识别水体区域<sup>[17]</sup>。在对比方法三中,SVM 模型的参数设置与对比方法一保持一致。

### 2.4 精度评估指标

本文采用总体准确率 (overall accuracy, OA)、精确率 ( $P$ )、召回率 ( $R$ ) 和  $F1$  分数 4 个指标来评估分类模型的性能。OA 是指分类结果中被正确分类的样本占总样本数的比例,精确率是指

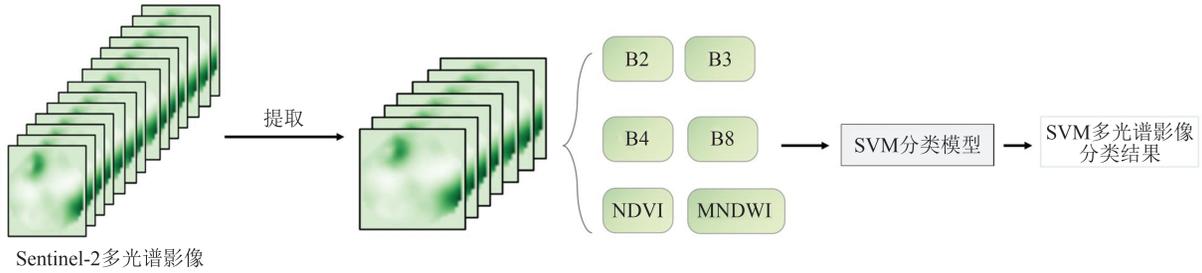


图7 基于 Sentinel-2 多光谱的 SVM 分类模型示意图

Fig. 7 SVM Classification Method Based on Sentinel-2 Multi-spectral

模型预测为正类别中实际为正类别的比例,召回率是指在所有实际为正类别的样本中,模型预测为正类别的比例;F1分数是精确率和召回率的调和平均数,用于综合考虑精确率和召回率的平衡。精确率、召回率和F1分数这3个指标能够全面评估模型的预测性能,其中精确率关注预测结果的准确性,召回率关注模型的覆盖能力,F1分数则提供了一个综合的评估标准。其计算式为:

$$\left\{ \begin{array}{l} P_{OA} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}} \times 100\% \\ P = \frac{N_{TP}}{N_{TP} + N_{FP}} \times 100\% \\ R = \frac{N_{TP}}{N_{TP} + N_{FN}} \times 100\% \\ F1 = 2 \times \frac{P \times R}{P + R} \times 100\% \end{array} \right. \quad (2)$$

式中,TP(true positive)、TN(true negative)、FP(false positive)和FN(false negative)分别表示真正例、真负例、假正例和假负例<sup>[38]</sup>;  $N_{TP}$ 表示实际为正类且被正确预测为正类的数量;  $N_{TN}$ 表示实际为负类且被正确预测为负类的数量;  $N_{FP}$ 表示实际为负类但被错误预测为正类的数量;  $N_{FN}$ 表示实际为正类但被错误预测为负类的数量。

### 3 结果与讨论

#### 3.1 基于 Sentinel-1 相干性矩阵和 LSTM 分类模型估测结果与对比

本文利用随机划分的训练集对 LSTM 分类模型进行训练,并在测试集上评估其分类精度。此外,为了全面评估模型性能,还对比了§2.3介绍的其他方法,具体结果详见表1。从表1中的数据可以看出,与3种对比方法相比,本文提出的基于 Sentinel-1 相干性矩阵和 LSTM 分类模型的方法在3个研究区域的土地覆盖分类任务中均展现出较高的精度,在区域1、区域2和区域3的OA分别为93.7%、89.9%和87.6%,明显优于 SVM 和

CNN 分类模型在相同区域的性能。具体来说,在区域1,LSTM模型的OA比对比方法一提高了约5%,比对比方法三提高了约4%,比对比方法二提高了约1%;在区域2,LSTM模型的OA比对比方法一提高了约6%,比对比方法三降低了约6%(考虑到后者受到云遮挡影响,样本量过小),比对比方法二提高了约1%;在区域3,LSTM模型的OA比对比方法一提高了约8%,比对比方法三提高了约10%,比对比方法二提高了约1%。特别与对比方法一相比,本文方法在精确率、召回率和F1分数上均显示出更好的性能。值得注意的是,精度次好的模型为对比方法二,尽管在OA上,本文方法相较于对比方法二的提升幅度不大,但在召回率和F1分数上却表现出明显的优势。特别是在区域1,本文方法的召回率和F1分数分别比CNN模型分别提高了5.1%和3.2%。

表1 本文方法与其他方法土地覆盖分类精度比较/%

Table 1 Comparison of Land Cover Classification Accuracy Between Our Proposed Method and Other Methods/%

区域	方法	OA	P	R	F1分数
区域1	对比方法一	88.4	84.7	66.5	68.8
	对比方法二	92.8	83.7	78.2	80.2
	对比方法三	89.5	77.9	68.6	69.9
	本文方法	93.7	83.7	83.3	83.4
区域2	对比方法一	83.7	81.7	82.1	81.9
	对比方法二	88.5	87.3	87.1	87.2
	对比方法三	96.4*	70.9*	67.4*	94.1*
	本文方法	89.9	88.5	89.0	88.7
区域3	对比方法一	79.6	75.1	63.3	65.8
	对比方法二	86.4	80.8	78.1	79.3
	对比方法三	76.9	75.3	61.0	64.4
	本文方法	87.6	84.0	80.3	81.8

注:\*表示受云遮挡影响数据的训练结果。

图8展示了4种方法的混淆矩阵结果,可以看出,本文方法在不同区域和土地覆盖类别的分类准确率上表现出显著优势。在区域1、区域2和

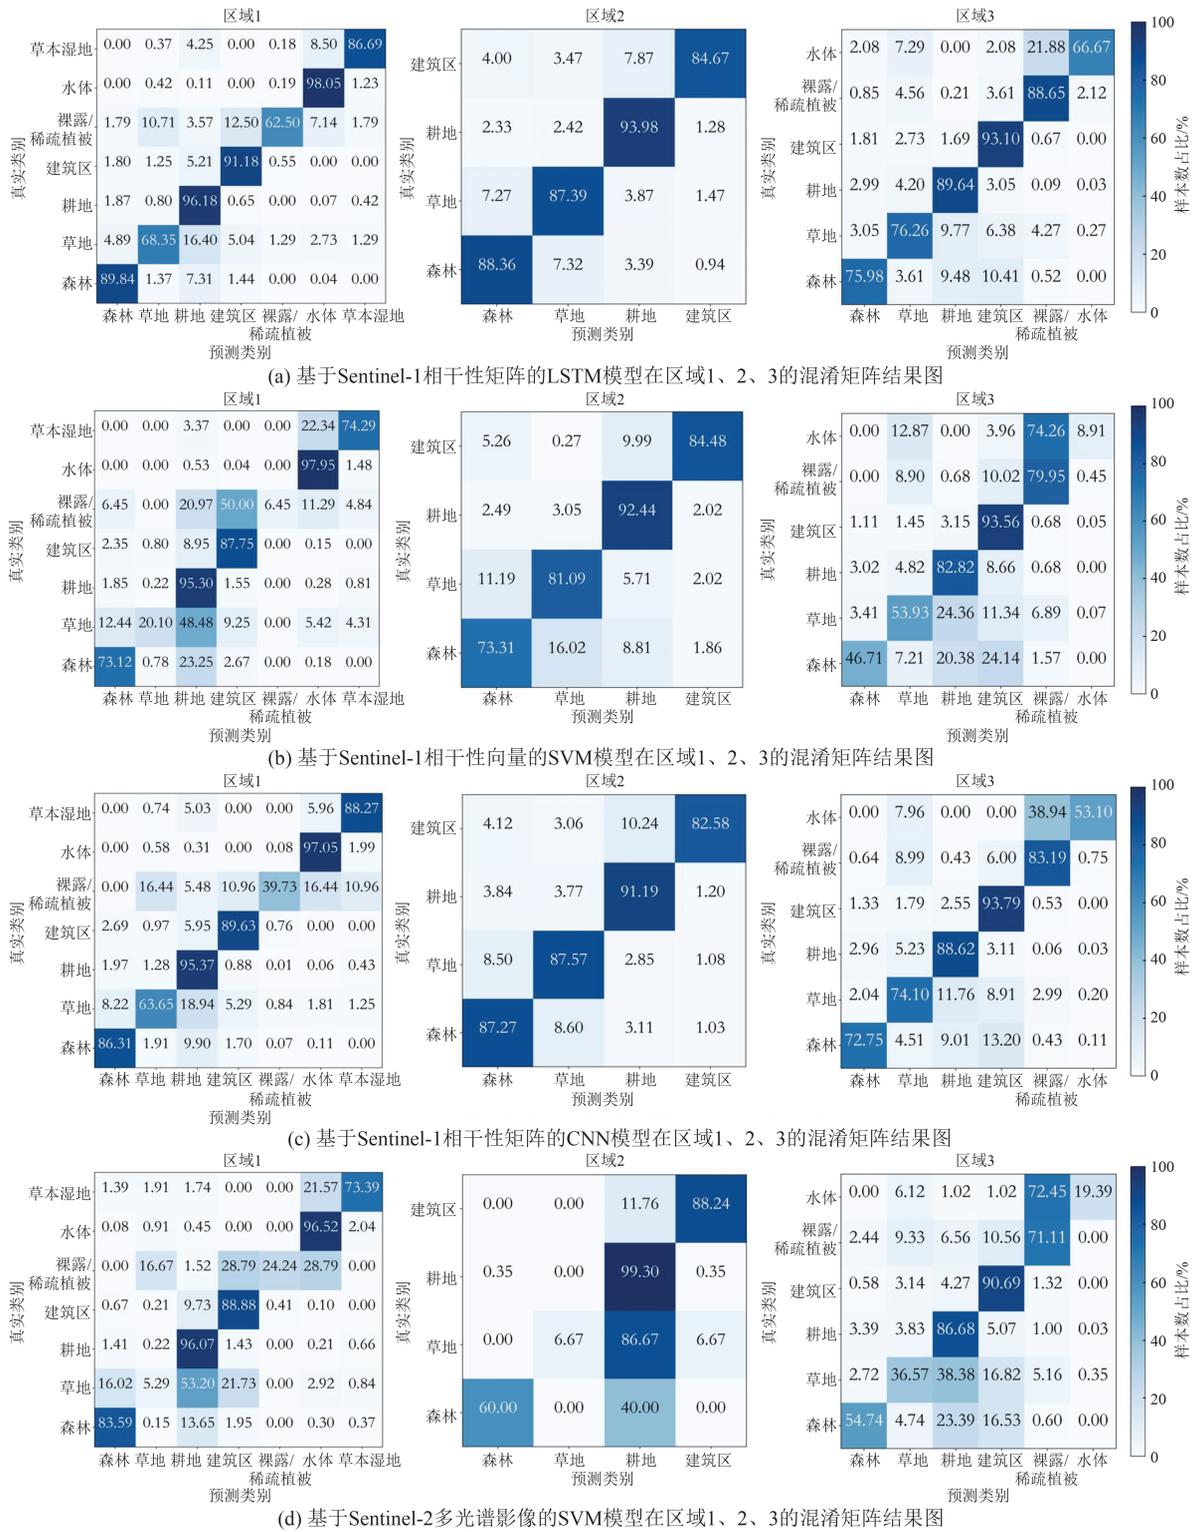


图 8 本文方法与其他方法在不同区域和土地覆盖分类结果的混淆矩阵

Fig. 8 Confusion Matrices of Land Cover Classification Results in Different Regions :  
Our Proposed Method and Other Methods

区域 3 中,本文方法在所有类别上均实现了较高的分类准确率,每个类别的准确率均超过 60%,尤其是在耕地和建筑区这两个类别上,3 个区域的平均准确率保持在 80% 以上。

相比之下,其他 3 种对比模型的分类效果略显不足,整体表现稳定性不及本文方法。对比方

法一和对比方法三在耕地和建筑区的分类上也表现良好,但在裸露/稀疏植被、草地和水体的分类上,特别是在区域 1 和区域 3,误判率相对较高。前者在区域 1 的裸露/稀疏植被分类准确率仅为 6.45%,在区域 3 的水体分类准确率为 8.91%,而本文方法的准确率分别为 62.50% 和 66.67%,分

别提升了56.05%和57.76%;后者在区域1的草地分类准确率仅为5.29%,在区域3的水体分类准确率为19.39%,而本文方法在对应区域类别的准确率分别为68.35%和66.67%,分别提升了63.06%和47.28%。此外,对比方法二的总体表现优于对比方法一和对比方法三,且在建筑区和林地的分类准确率与本文方法的接近,但其分类准确率仍有待提高,例如在区域1的裸露/稀疏植被分类准确率为39.73%,在区域3的水体分类准确率为53.10%,而本文方法对应的准确率相比分别提高了22.77%和13.57%。以上结果表明,本文提出的LSTM模型在不同地物类别和复杂环境条件下的分类性能更加稳定和可靠。

值得说明的是,对于区域2,由于云遮挡严重影响了Sentinel-2多光谱影像的质量,经过剔除受云影响的数据后,剩余样本仅占原始数量的5.2%,不足以支持有效的多光谱影像分类。尽管

这一结果具有较高的精度,但由于样本量过少,无法与其他方法进行有效比较。这一情况凸显了使用InSAR相干性在处理受云遮挡影响的区域时的优势,SAR成像不受云层影响,能够提供更稳定的分类结果。

为说明3个研究区内不同地物的相干性变化,本文在3个研究区域内针对每个类别随机选取了100个样本,绘制其相干性平均值随基线长度变化及最短基线季节性变化曲线图,见图9。从图9可以看出,所有类别的相干性普遍随着时间基线长度的增加而逐渐下降,但各类别之间的下降速率和变化范围存在显著差异。在随季节变化的最短时间基线上,相干性变化也表现出类别间差异。LSTM模型通过其门控机制,能够记住长时间的信息并抑制噪声,凭借其捕捉时间序列数据长期依赖关系的能力,能够有效地识别这些复杂的动态变化模式,从而在土地覆盖分类任务中展现出更高的精度和鲁棒性。

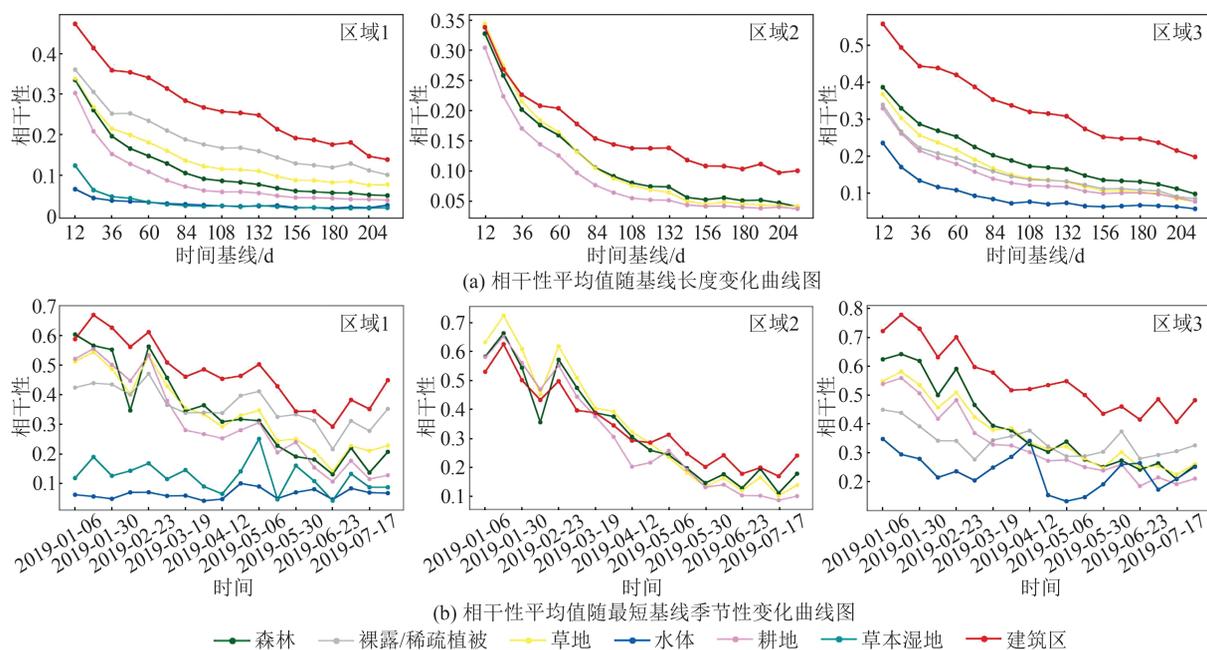


图9 区域1、区域2、区域3相干性平均值变化曲线

Fig. 9 Variation Curves of Mean Coherence for Regions 1-3

### 3.2 土地覆盖类型的分类结果细节

§3.1对3个研究区域进行土地覆盖分类的比较分析表明,本文提出的基于Sentinel-1相干性矩阵的LSTM分类模型在土地覆盖分类的准确性和可靠性方面均优于其他方法。为了更直观地展示这一点,将各个分类方法预测的土地覆盖类型结果与实际的WorldCover地图进行了对比,如图10所示。需要注意的是,图10的模型分类结果中,白色像素表示训练集。特别是在图10(e)中,白色像素不仅代表训练集,还包括了被云层

遮挡的像素点。

与WorldCover分类图相比,可以看到基于Sentinel-1相干性矩阵的LSTM模型的分类结果(图10(a))在区域1、区域2和区域3中与参考影像分布更为一致,特别是在区域边界和细节部分,本文方法的分类结果呈现出更高的精度和细致性,尤其在处理细节丰富的土地覆盖类别时,相较于其他方法,本文方法显著减少了漏检现象。这一结果对应了§3.1中的分析,即本文方法的F1分数较高,表明其在精确率和召回率之间达到了更好的平衡,确保了

分类结果的可靠性,尤其是在建筑区和林地的识别上,LSTM模型的分界清晰,误分类现象较少。例如,图 10 中黑框标注的小范围草地、水体和建筑区细节部分,LSTM模型的分界与实际分布高度一致,对比其他方法更为明显。比较图 10(c)和 10(e)可以看出,对比方法一和对比方法三在 3 个区域的分类结果较为粗糙,难以分辨出小范围的类型区别,出现了较多的误分类现象。特别是在区域 2 中,对比方法三由于云遮挡对 Sentinel-2 多光谱影

像质量的影响,有效样本数量不足,无法获取可靠的土地覆盖分类结果。此外,对比方法二(图 10(d))虽然在小范围类别的识别上比前两种方法更为准确,但类别边界的界定不如本文方法清晰,尤其是在区域 3 中的水体分类上存在一定的误差。这些结果进一步验证了本文方法在土地覆盖分类任务中的优越性和鲁棒性。

### 3.3 迁移学习可行性分析

为探讨本文方法的普适性和泛化能力,在 3

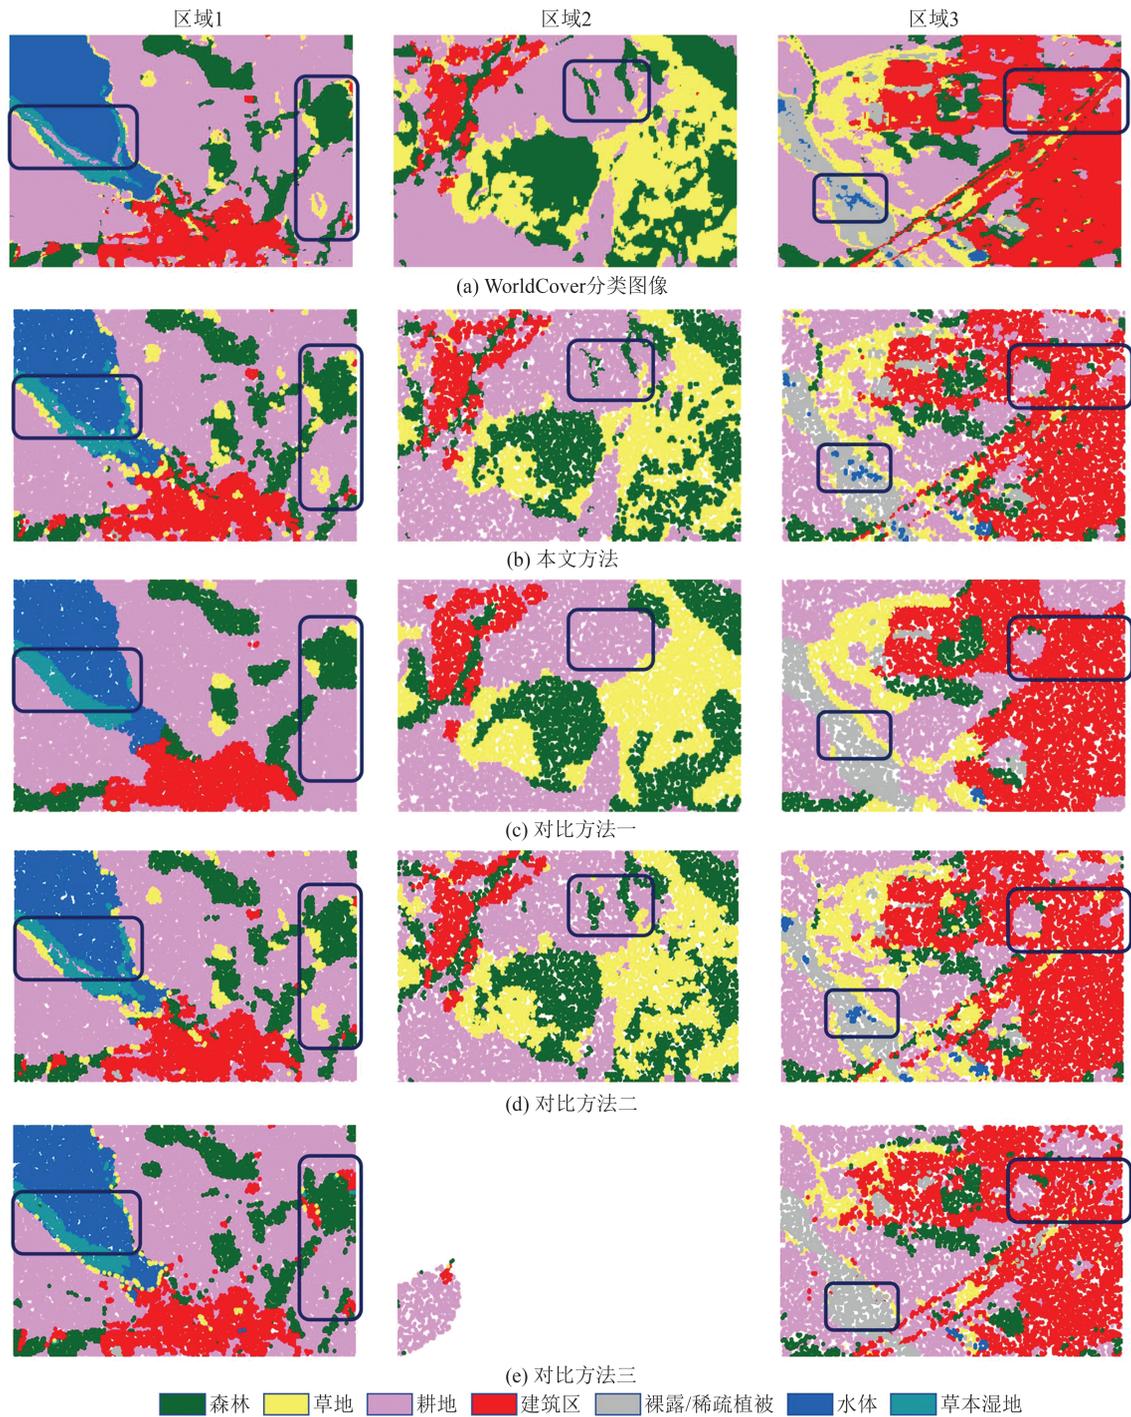


图 10 4 种不同土地覆盖分类方法在区域 1、区域 2、区域 3 中土地覆盖分类结果细节比较

Fig. 10 Detailed Comparison of Classification Results Using Four Land Cover Classification Methods in Regions 1-3

个区域进行了迁移学习实验。鉴于区域1土地覆盖类型的多样性,本文选择区域1的数据作为源域,用于构建迁移学习模型的训练集。相应地,区域2和区域3则作为目标域,构成迁移学习的测试集,用以评估模型的迁移学习效果。分类结果的混淆矩阵如图11所示,尽管LSTM迁移学习模型的训练精度均已达到94.6%,但在区域2

和区域3上估测土地覆盖类型的OA分别仅为45.7%和47.4%。原因可能在于目标区域与源域的土地覆盖类型分布存在显著差异,见图12,且源域的土地覆盖类型分布虽然相对全面,但并不均衡,这可能导致某些类型的的数据未能得到充分的训练,进而影响了模型对土地覆盖特征的全面捕捉,限制了模型在目标区域的泛化能力。



图11 迁移学习后分类结果的混淆矩阵

Fig. 11 Confusion Matrix of Classification Results After Transfer Learning

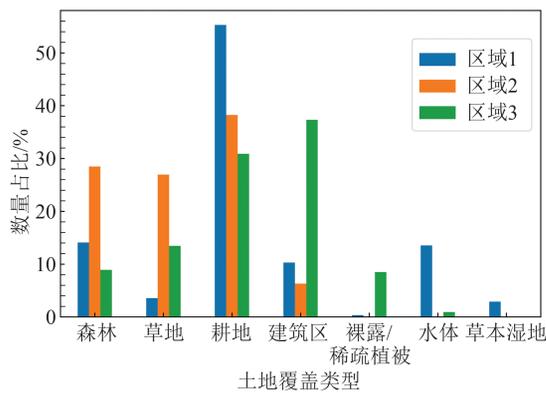


图12 3个研究区域数据分布图

Fig. 12 Data Distribution Map of Three Research Regions

此外,本文还尝试了一种基于总体采样数据的训练方式,即利用3个区域的综合数据进行统一训练,并分别对各区域进行预测。这种方式有效规避了单独采样导致的样本分布不均问题,显著提升了分类效果。采用此方法后,3个区域的土地覆盖类型分类OA分别达到了92.8%、87.8%和86.4%(混淆矩阵见图13)。因此可以合理推断,原有分类精度较低的现象主要是由源域和目标域的样本分布差异所引起的,而通过改进采样策略,可以有效地缓解这一问题,从而获得更为理想的分类结果。

## 4 结语

本文提出了一种基于Sentinel-1相干性矩阵和LSTM模型的土地覆盖分类方法,该方法在选定的实验区域中展现了较高的分类精度和鲁棒性,验证了利用Sentinel-1多时相相干性矩阵与LSTM模型进行土地覆盖分类的有效性。研究表明,本文方法在区域1、区域2和区域3的OA分别达到了93.7%、89.9%和87.6%,明显优于基于Sentinel-1相干性向量的SVM分类模型、基于Sentinel-1相干性矩阵的CNN分类模型以及基于Sentinel-2多光谱影像的SVM分类模型。此外,本文方法在处理受云遮挡影响的区域时表现出显著优势,SAR图像的穿透能力使其能够提供更稳定的分类结果。尽管如此,本文方法还存在一些局限性。本文研究区域涉及城市及城市周边,包含少量未被深入开发的郊区,主要包含7类常见地物类别。由于篇幅限制,本文选取的研究区域包含主要的用地类别,但无法同时包含WorldCover中其余土地覆盖类别(如红树林、苔藓和地衣、雪和冰等),计划在未来的工作中增加更多样化的自然环境场景,并对WorldCover中其余土地覆盖类别进行测试,以评估其在不同条件下的稳定性和准确性。

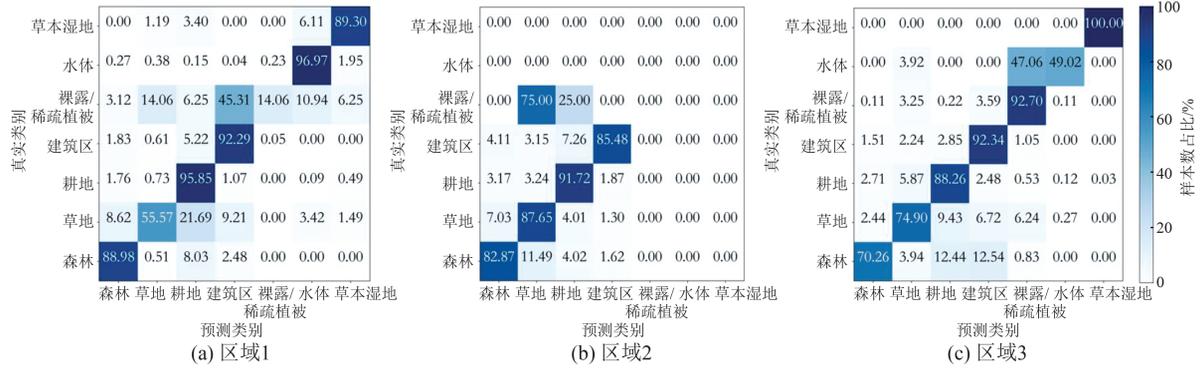


图 13 区域 1、区域 2 和区域 3 迁移学习后分类结果的混淆矩阵

Fig. 13 Confusion Matrix of Classification Results After Transfer Learning for Regions 1-3

另外,在对比方法二中,采用的是 Giffard-Roisin 等<sup>[29]</sup>使用的 CNN 模型,模型结构较为简单,其针对法国尚贝里地区的总体精确度为 81%,比以相干向量为输入的 SVM 模型精度提高了 3%。复杂的 CNN 架构虽然在图像分割任务中表现出色,但其显著增加的训练时间和计算成本可能限制了实验的可重复性和扩展性,未来的研究也计划探讨更多深度学习模型在土地覆盖分类任务中的表现。在迁移学习实验中,当本文方法仅基于区域 1 的数据进行训练,并分别在区域 2 和区域 3 上进行测试时,OA 分别降至 45.7% 和 47.4%,表明该方法在跨区域迁移时的泛化能力需要进一步提升。为改善分类效果并增强模型的泛化性能,本文进一步尝试了一种基于总体采样数据的训练策略,即利用 3 个研究区域的综合数据进行统一训练,并对各区域单独预测。这种方法有效解决了单独采样可能引发的样本分布不均问题,显著提升了分类效果。

未来的工作需要进一步探索优化迁移学习策略,包括调整模型架构、优化特征选择和选择更佳的目标域,或考虑使用多源域迁移学习方法,以增强模型在不同区域的适用性和分类精度。同时,考虑到模型在处理不同土地覆盖类型时的性能差异,未来的研究可以探索更复杂的模型架构,如引入注意力机制等,以进一步提升模型的泛化能力和分类精度。由于条件限制,本文未能引入更高精度的实地测量数据,希望在未来工作中能够在具有实测数据的研究区域进行实验。此外,还需在更广泛的实验区域进一步验证本文方法的泛化能力,探讨其在实际应用中的价值。

参 考 文 献

[1] VITOUSEK P M. Beyond Global Warming: Ecolo-

gy and Global Change[J]. *Ecology*, 1994, 75(7): 1861-1876.

[2] PERRING M P, DE FRENNE P, BAETEN L, et al. Global Environmental Change Effects on Ecosystems: The Importance of Land-Use Legacies[J]. *Global Change Biology*, 2016, 22(4): 1361-1371.

[3] ELLIS E, PONTIUS R. Land-Use and Land-Cover Change[J]. *Encyclopedia of Earth*, 2007, 1: 1-4.

[4] 陈军,廖安平,陈晋,等. 全球 30 m 地表覆盖遥感数据产品: Globe Land30[J]. *地理信息世界*, 2017, 24(1): 1-8.

CHEN Jun, LIAO Anping, CHEN Jin, et al. 30-Meter Global Land Cover Data Product: Globe Land30[J]. *Geomatics World*, 2017, 24(1): 1-8.

[5] MENDOZA-PONCE A, CORONA-NÚÑEZ R, KRAXNER F, et al. Identifying Effects of Land Use Cover Changes and Climate Change on Terrestrial Ecosystems and Carbon Stocks in Mexico[J]. *Global Environmental Change*, 2018, 53: 12-23.

[6] VERBURG P H, NEUMANN K, NOL L. Challenges in Using Land Use and Land Cover Data for Global Change Studies[J]. *Global Change Biology*, 2011, 17(2): 974-989.

[7] 臧明润,廖远鸿,陈舟,等. 土地覆盖分类体系分析和总结[J/OL]. *自然资源遥感*, [2024-11-01]. <http://kns.cnki.net/kcms/detail/10.1759.P.20240205.0831.002.html>.

ZANG Mingrun, LIAO Yuanhong, CHEN Zhou, et al. Analysis and Summary of Land Cover Classification Systems[J/OL]. *Remote Sensing for Natural Resources*, [2024-11-01]. <http://kns.cnki.net/kcms/detail/10.1759.P.20240205.0831.002.html>.

[8] TOWNSHEND J, JUSTICE C, LI W, et al. Global Land Cover Classification by Remote Sensing: Present Capabilities and Future Possibilities[J]. *Remote Sensing of Environment*, 1991, 35 (2/3): 243-255.

- [9] DISPERATI L, VIRDIS S G P. Assessment of Land-Use and Land-Cover Changes from 1965 to 2014 in Tam Giang-Cau Hai Lagoon, Central Vietnam[J]. *Applied Geography*, 2015, 58: 48-64.
- [10] RWANGA S S, NDAMBUKI J M. Accuracy Assessment of Land Use/Land Cover Classification Using Remote Sensing and GIS [J]. *International Journal of Geosciences*, 2017, 8(4): 611-622.
- [11] PHIRI D, SIMWANDA M, SALEKIN S, et al. Sentinel-2 Data for Land Cover/Use Mapping: A Review[J]. *Remote Sensing*, 2020, 12(14): 2291.
- [12] GAŠPAROVIĆ M, JOGUN T. The Effect of Fusing Sentinel-2 Bands on Land-Cover Classification [J]. *International Journal of Remote Sensing*, 2018, 39(3): 822-841.
- [13] TALUKDAR S, SINGHA P, MAHATO S, et al. Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations — A Review[J]. *Remote Sensing*, 2020, 12(15): 1135.
- [14] ZHANG C, SARGENT I, PAN X, et al. Joint Deep Learning for Land Cover and Land Use Classification[J]. *Remote Sensing of Environment*, 2019, 221: 173-187.
- [15] VALI A, COMAI S, MATTEUCCI M. Deep Learning for Land Use and Land Cover Classification Based on Hyperspectral and Multispectral Earth Observation Data; A Review [J]. *Remote Sensing*, 2020, 12(15): 2495.
- [16] KARRA K, KONTGIS C, STATMAN-WEIL Z, et al. Global Land Use / Land Cover with Sentinel-2 and Deep Learning [C]// IEEE International Geoscience and Remote Sensing Symposium IGARSS, Brussels, Belgium, 2021.
- [17] ABDI A M. Land Cover and Land Use Classification Performance of Machine Learning Algorithms in a Boreal Landscape Using Sentinel-2 Data [J]. *GI-Science & Remote Sensing*, 2020, 57(1): 1-20.
- [18] MALINOWSKI R, LEWIŃSKI S, RYBICKI M, et al. Automated Production of a Land Cover/Use Map of Europe Based on Sentinel-2 Imagery [J]. *Remote Sensing*, 2020, 12(21): 3523.
- [19] INGLADA J, VINCENT A, ARIAS M, et al. Operational High Resolution Land Cover Map Production at the Country Scale Using Satellite Image Time Series [J]. *Remote Sensing*, 2017, 9(1): 95.
- [20] WASKEB, BRAUN M. Classifier Ensembles for Land Cover Mapping Using Multitemporal SAR Imagery [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2009, 64(5): 450-457.
- [21] MISHRA P, SINGH D, YAMAGUCHI Y. Land Cover Classification of Palsar Images by Knowledge Based Decision Tree Classifier and Supervised Classifiers Based on Sar Observables [J]. *Progress in Electromagnetics Research B*, 2011, 30(30): 47-70.
- [22] ZHANG R, TANG Z Z, LUO D, et al. Combined Multi-Time Series SAR Imagery and InSAR Technology for Rice Identification in Cloudy Regions [J]. *Applied Sciences*, 2021, 11(15): 6923.
- [23] 周鑫城, 左小清, 李勇发, 等. 不同地表覆盖对 InSAR 技术的相干性影响研究 [J]. 贵州大学学报(自然科学版), 2023, 40(3): 62-70.
- ZHOU Xincheng, ZUO Xiaoqing, LI Yongfa, et al. Study on the Influence of Different Surface Coverages on the Coherence of InSAR Technology [J]. *Journal of Guizhou University (Natural Sciences)*, 2023, 40(3): 62-70.
- [24] AMARSAIKHAN D, GANZORIG M, ACHE P, et al. The Integrated Use of Optical and InSAR Data for Urban Land-Cover Mapping [J]. *International Journal of Remote Sensing*, 2007, 28(6): 1161-1171.
- [25] 倡文娜, 何敏, 王茂山. 基于 Sentinel-1 的典型地物时间失相干分析 [J]. 地理空间信息, 2022, 20(2): 22-26.
- SI Wenna, HE Min, WANG Maoshan. Temporal Decorrelation Analysis of Different Land Coverage Types Based on Sentinel-1 Images [J]. *Geospatial Information*, 2022, 20(2): 22-26.
- [26] 李振今, 王志勇, 叶凯乐, 等. 联合时间序列相干性和后向散射系数的黄河三角洲湿地分类 [J]. 测绘通报, 2023(2): 52-57.
- LI Zhenjin, WANG Zhiyong, YE Kaile, et al. Combined Time Series Coherence and Backscattering Coefficient for Wetland Classification in the Yellow River Delta [J]. *Bulletin of Surveying and Mapping*, 2023(2): 52-57.
- [27] NIKAEIN T, IANNINI L, MOLIJN R A, et al. On the Value of Sentinel-1 InSAR Coherence Time-Series for Vegetation Classification [J]. *Remote Sensing*, 2021, 13(16): 3300.
- [28] JACOB A, NOTARNICOLA C, SURESH G, et al. Sentinel-1 InSAR Coherence for Land Cover Mapping: A Comparison of Multiple Feature-Based Classifiers [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13(1): 535-552.
- [29] GIFFARD-ROISIN S, BOUDAOUR S, DOIN M