

基于 BiLSTM-CNN 的地基 SAR 永久散射体选取<sup>\*</sup>陈 姣<sup>1,2</sup> 刘 毓<sup>1</sup> 邓云开<sup>3</sup> 金重阳<sup>1,2</sup> 杨志航<sup>1</sup>

(1. 重庆三峡学院电子与信息工程学院 重庆 404130; 2. 北京理工大学重庆创新中心 重庆 401120;

3. 北京理工大学信息与电子学院雷达技术研究所 北京 100081)

**摘 要:**针对地基合成孔径雷达(SAR)形变测量中,常规永久散射体(PS)选取方法在时间欠相干复杂场景下,PS选取数量、质量难以满足形变测量需求的问题。提出了一种基于双向长短期记忆-卷积神经网络(BiLSTM-CNN)的PS选取方法,该方法采用幅度离散与幅度联合选取正、负样本构建训练数据集,并把干涉相位、幅度差分与相关系数作为数据集的时序特征,然后利用BiLSTM和多尺度CNN分别学习PS全局时序特征及局部时序特征,再通过多头自注意力机制(MHSA)对全局和局部时序特征进行加权融合学习,最后进行特征概率映射以构建PS分类模型。利用重庆市万州区九道拐雷达监测数据对所提方法性能进行实验分析,结果表明该方法改善了网络准确度、 $F_1$ 分数、召回率、精确度等指标,提高了雷达图像PS选取数量及质量。

**关键词:**地基 SAR;永久散射体;双向长短期记忆;卷积神经网络;多头自注意力机制

**中图分类号:** TN95      **文献标识码:** A      **国家标准学科分类代码:** 510.4050

## Permanent scatterers selection of ground-based SAR based on BiLSTM-CNN

Chen Jiao<sup>1,2</sup> Liu Yu<sup>1</sup> Deng Yunkai<sup>3</sup> Jin Chongyang<sup>1,2</sup> Yang Zhihang<sup>1</sup>

(1. School of Electronic and Information Engineering, Chongqing Three Gorges University, Chongqing 404130, China;

2. Beijing Institute of Technology Chongqing Innovation Center, Chongqing 401120, China;

3. Radar Research Lab, School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China)

**Abstract:** Aiming at the ground-based synthetic aperture radar (SAR) deformation measurement, the conventional permanent scatterer (PS) selection method is difficult to meet the deformation measurement requirements in terms of the quantity and quality of PS selection in the time-incoherent and complex scenarios. The article proposes a PS selection method based on bi-directional long short-term memory-convolutional neural network (BiLSTM-CNN), which uses amplitude dispersion and amplitude to jointly select positive and negative samples to construct the training dataset, and takes the interfering phase, amplitude divergence and correlation coefficient as the temporal features of the dataset, and then learns the PS global temporal features and the PS local temporal features by using the BiLSTM and the multi-scale CNN, respectively, and then the global and local temporal features are weighted and fused to learn by the multi-head self-attention (MHSA), and finally feature probability mapping is carried out in order to construct the PS classification model. The performance of the proposed selection method is experimentally analyzed by using the radar monitoring data of Jiudaoquan in Wanzhou District, Chongqing Municipality, and the results show that the method improves the network accuracy,  $F_1$  score, recall, precision, and other indexes, and improves the quantity and quality of radar image PS selection.

**Keywords:** ground-based synthetic aperture radar; permanent scatterer; bi-directional long short-term memory; convolutional neural network; multi-head self-attention

收稿日期:2024-03-19

<sup>\*</sup> 基金项目:国家重点研发计划子课题(2021YFB3901400)、重庆市教委科学技术项目(KJQN202101215)资助

## 0 引言

地基合成孔径雷达(ground-based synthetic aperture radar, GB-SAR)<sup>[1]</sup>,其形变信息主要通过差分干涉测量技术获取。在差分干涉测量时首先是获取同一位置、不同时刻观测场景两张及以上的 GB-SAR 图像,然后进行干涉处理得到干涉相位,基于干涉相位实现形变反演<sup>[2]</sup>。通常地基 SAR 图像中包含许多低质量像素点,利用这些点的干涉相位进行形变反演会出现较大误差。因此 PS 选取是 GB-SAR 高精度形变测量的关键<sup>[3]</sup>。

目前 GB-SAR 常用幅度离差、相关系数等方法选取永久散射体(permanent scatterer, PS)。幅度离差法选取 PS 时,首先计算图像中每个像元幅度标准差与幅度均值的比值,然后通过设置阈值进行筛选<sup>[4]</sup>。该方法对城镇、矿山等高相干场景性能较好,但对植被边坡等低相干场景,选取 PS 数量较少且会引入相位误差较高的点,难以满足后续形变反演。相关系数法是以当前像素点为中心设置矩形窗口,利用窗口内点的复信息计算该像元的相关系数,并以相关系数值评判该点质量高低。该方法使用周围点复信息计算相关系数,相关系数大小受周围点的影响,会造成 PS 漏选、误选<sup>[5]</sup>。

随着神经网络在自然语言处理、目标检测等领域的发展和突出效果,基于神经网络的 PS 选取方法也逐渐得到研究人员的广泛关注。2020 年, Tiwari 等<sup>[6]</sup>提出了干涉语义分割卷积神经网络(convolutional neural network for interferometric semantic segmentation, CNN-ISS)和干涉语义分割卷积长短期记忆网络(convolutional long short term memory network for interferometric semantic segmentation, CLSTM-ISS),它们分别用来学习 PS 空间和时空特性,实验表明该方法比常规方法具有更好的 PS 密度和可靠性。2021 年,曹琨等<sup>[7]</sup>针对人为经验阈值调整繁琐和图像中各个区域 PS 阈值存在差异性问题,提出了一种基于注意力机制的 PS 选择方法,该方法与递归神经网络(recurrent neural network, RNN)相比具有更短的训练时间,同时比 LSTM 等网络有更高的准确率。2022 年, Zhang 等<sup>[8]</sup>提出了一种双通道一维卷积神经网络的相关点选取方法,方法中的两个通道分别处理雷达图像振幅和干涉图的相关性。对农村和城市的实验表明所提方法选出的相关点具有更好的数量和质量,并且在时间上具有优势。

上述网络在 PS 选取过程中,都没有考虑 PS 时序特征中的全局时序和局部时序。针对 PS 时序特征,本文提出了一种基于双向长短期记忆一卷积神经网络(BiLSTM-CNN)的 PS 选取方法。本文方法利用 PS 在时间序列上的稳定特性,首先构建 PS 时序特征集,然后采用 BiLSTM 对 PS 全局时序特性建模,并利用多尺度 CNN 充分学习和捕捉 PS 局部时序特征,再通过多头自注意力机制(multi-head self-attention, MHSA)对全局和局部所有时

序特征进行加权学习,最后将特征映射到 PS 类的概率。通过实测数据进行训练和测试,验证了本文方法的有效性。

## 1 基于 BiLSTM-CNN 的永久散射体选取方法

## 1.1 训练集的准备

## 1) 正负样本获取

地基 SAR 图像中, PS 与非 PS 数量比例呈现非均衡特性,非 PS 数量远多于 PS 数量。若直接采用样本数据训练网络,网络会出现将 PS 分类为非 PS 的情况。因此,所提方法首先利用像素点归一化幅值剔除图像中不稳定的点,再联合使用幅度离差门限与幅值门限在余下像素点中选取高质量(PS)和低质量像素点(非 PS)作为正样本与负样本。

## 2) 特征构建

PS 是在长时间范围内保持高相干性的像素点<sup>[9]</sup>,其幅度和相位相比于非 PS 更加稳定。为使网络更好学习 PS 时序特征,提高 PS 分类准确性,本文方法将像素点幅度差值、干涉相位和相关系数作为 PS 特征。

像素点幅度差值  $\Delta A$  为当前时刻幅度  $A(t)$  与前一时

$$\Delta A = A(t) - A(t-1) \quad (1)$$

由式(1)可知,  $\Delta A$  值越小反映像素点幅度变化越小,则时间范围内幅度越稳定,符合 PS 幅度稳定特性。

干涉相位是将两幅雷达图像中对应像素点复共轭相乘取相位<sup>[10]</sup>,计算公式如下:

$$M = M_1 \cdot M_2^* = A_1 A_2 e^{j(\varphi_1 - \varphi_2)} = A e^{j(\Delta \varphi)} \quad (2)$$

式中:“\*”表示取共轭复数;  $A$  和  $\varphi$  表示像素点幅度和相位值。

由于 PS 干涉相位表现出相对较低的相位噪声和变化,因此通过分析 PS 干涉相位,可以帮助网络更好学习 PS 特性。

时序相关系数体现了时间序列中不同时刻像素点相位间的相关性,因此可利用相邻雷达图像间的相关系数作为 PS 特征,可采用下式得到<sup>[11]</sup>:

$$\gamma_k = \frac{\left| \sum_{L_1 \times L_2} w_k^{(1)} \cdot w_k^{(M)*} \right|}{\sqrt{\sum_{L_1 \times L_2} |w_k^{(1)}|^2 \cdot \sum_{L_1 \times L_2} |w_k^{(M)}|^2}} \quad (3)$$

式中:  $\gamma_k$  为相关系数值;  $w_k^{(M)}$  表示第  $M$  幅图像以  $k$  为中心的所有像素点复信息; \* 表示复共轭;  $\sum_{L_1 \times L_2} [\ ]$  代表窗口内所有复信息之和;  $||$  表示取模。

## 1.2 网络架构

## 1) BiLSTM

LSTM 是 RNN 的一种改进模型<sup>[12]</sup>,其缓解了 RNN 中梯度消失与梯度爆炸问题,能处理长时间依赖问题,结构如图 1 所示。




图1 LSTM 内部结构

Fig. 1 Internal structure of LSTM

(1) 遗忘门计算式如下:

$$f_t = \sigma(W_{if}x_t + W_{hf}h_{t-1} + b_f) \quad (4)$$

式中:  $W_{if}$ 、 $W_{hf}$  分别是遗忘门对当前输入  $x_t$ 、 $t-1$  时刻隐藏状态  $h_{t-1}$  的权重;  $b_f$  为遗忘门偏置;  $\sigma$  代表激活函数 sigmoid。

(2) 输入门计算式如下:

$$i_t = \sigma(W_{ii}x_t + W_{hi}h_{t-1} + b_i) \quad (5)$$

$$\tilde{c}_t = \tanh(W_{ic}x_t + W_{hc}h_{t-1} + b_c) \quad (6)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (7)$$

式中:  $\tilde{c}_t$  为当前时刻状态候选值;  $c_t$  代表细胞更新后的状态;  $W_{ii}$ 、 $W_{hi}$  分别代表输入门对  $x_t$ 、 $h_{t-1}$  的权重;  $b_i$  为输入门偏置;  $W_{ic}$ 、 $W_{hc}$  代表候选状态的权重;  $b_c$  是偏置;  $\odot$  代表哈达玛积。

(3) 输出门计算式如下:

$$o_t = \sigma(W_{io}x_t + W_{ho}h_{t-1} + b_o) \quad (8)$$

$$h_t = o_t \odot \tanh(c_t) \quad (9)$$

式中:  $W_{io}$ 、 $W_{ho}$  表示遗忘门分别对当前输入  $x_t$  和上一时刻隐藏状态  $h_{t-1}$  的权重;  $b_o$  代表输出门的偏置。

BiLSTM 网络是在 LSTM 基础上优化所得,它是通过对输入数据进行前向和后向建模<sup>[13]</sup>,充分捕捉时序数据之间的依赖性,从而增加网络可用信息量<sup>[14]</sup>,结构如图 2 所示。




图2 BiLSTM 结构

Fig. 2 BiLSTM structure

图 2 中,  $X_t$  代表  $t$  时刻的输入,  $Y_t$  代表  $t$  时刻的输出, 其输出为  $t$  时刻前向和后向得到的隐藏层拼接值  $[h_t^f, h_t^b]$ ,  $h_t, h_t^b$  为前向和后向  $t$  时刻隐藏层大小。

2) CNN

卷积神经网络通过对输入数据进行逐层卷积、池化操

作,深入提取蕴涵在数据中的结构特征,并且随着 CNN 层数累加,所得到的特征更加抽象,最终从输入数据中提取更加鲁棒的特征<sup>[15]</sup>。

CNN 包含输入层、卷积层、激活层、池化层等,卷积层数学模型可表示为:

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} \times k_{ij}^l + b_j^l\right) \quad (10)$$

式中:  $M_j$  代表输入的特征;  $l$  代表第  $l$  层网络;  $k$  代表卷积核;  $b$  网络的偏置;  $f(\cdot)$  是激活函数。在卷积后, CNN 通常采用修正线性单元 (rectified linear unit, ReLU) 等激活函数进行激活处理,主要是实现网络非线性特性的引入。

池化层用于减少特征的空间维度,同时保留重要信息。最常见的池化操作是最大池化 (Max Pooling) 和平均池化 (Average Pooling)。

3) 本文模型

为充分对 PS 特征建模,本文提出对 PS 全局和局部时序分别建模学习,模型框图如图 3 所示。模型结构中主要包括 3 个模块, BiLSTM-CNN 联合网络模块、特征融合模块和分类模块。针对 PS 时序特性,首先通过 BiLSTM-CNN 联合网络模块对 PS 全局时序和局部时序特征进行建模学习,其中采用 BiLSTM 对全局时序进行学习,采用多尺度小卷积模块捕捉相邻时序关系,然后由特征融合模块对所有全局和局部时序特征进行加权学习,最后由分类层通过特征映射得到不同类别的概率进行最终分类。

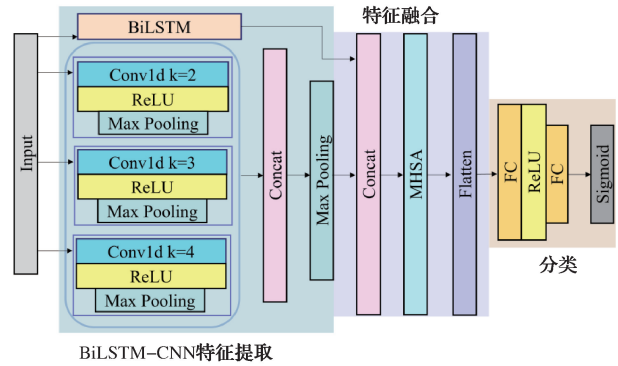


图3 BiLSTM-CNN 架构

Fig. 3 BiLSTM-CNN architecture

(1) BiLSTM-CNN 联合网络模块

BiLSTM-CNN 联合网络模块包含 BiLSTM 和 CNN。BiLSTM 能对 PS 时序进行前后向学习,这种方式能更好地理解 PS 特征时间序列中的模式和趋势,实现对全局时序关系的建模学习。本文方法中 BiLSTM 共包含 2 层 LSTM,隐藏节点数为 16。

本文方法基于 1D CNN<sup>[16]</sup>进行重新设计,以更好实现对 PS 局部时序特征进行增强学习。在数据输入时,将输入的时序特征进行维度变换以适应一维卷积神经网络的输入结构。对于地基合成孔径雷达 PS 特征而言,由于相邻时刻的干涉相位、相关系数、幅度差分具有高相关性,因



此网络结构需较好的对局部时序关系进行建模学习。为充分提取时序关系,本文搭建了卷积核大小分别为2、3、4的3种一维卷积神经网络,其中时间步长为1,Max Pooling时间步长和窗口大小设置为2。

### (2) 特征融合模块

该模块主要包括Concat、Flatten和多头自注意力机制<sup>[17]</sup>。首先用Concat对BiLSTM捕获的全局时序和CNN提取的多尺度局部时序特征进行拼接,实现全局与局部时序的组合,然后引入多头自注意力机制学习全局和局部时序特征的权重分布,对其重要特征进行加权处理<sup>[18]</sup>,并减少不重要信息对后续分类的干扰,进一步提高模型表达能力,最后利用Flatten将加权学习到的特征展平成一维特征,使得最终输出可以更全面地表示数据。

在多头自注意力计算中,查询(Q)、键(K)和值(V)都来自同一个输入序列,因此,它被称为“自注意力”。在每一个注意力头中进行式(11)的计算,其中每个注意力头*i*具体计算如式(12)所示,并通过式(13)将多个头的注意力进行拼接得到多头注意力。将多头注意力得到的权重与输入值相乘得到最终输入特征的加权输出。

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (11)$$

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V) \quad (12)$$

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_h)W^O \quad (13)$$

式中:  $\frac{1}{\sqrt{d_k}}$  是缩放因子,  $softmax$  为激活函数,  $W_i^Q \in R^{d_{model} \times d_q}$ ,  $W_i^K \in R^{d_{model} \times d_k}$ ,  $W_i^V \in R^{d_{model} \times d_v}$ ,  $W^O \in R^{hd_v \times d_{model}}$  为映射参数矩阵,  $d_{model}$  是输入参数的特征维度;Concat表示对特征进行拼接操作。

### (3) 分类模块

该模块由全连接层(fully connected, FC)、ReLU层和Sigmoid层构成。其中,FC层实现高维特征到类别数量的映射,Sigmoid函数是将全连接层输出转化为正类别概率。本文将通过堆叠两层全连接层和一个激活函数层增

加模型非线性性能,以提高模型拟合复杂数据性能,其中FC层隐藏节点数为128。

## 2 实验信息

为验证本文方法选取PS的有效性,本次实验场景选择重庆市万州区钟鼓楼街道李家河沟北东侧九道拐的一处边坡,该边坡纵向长约170 m、横向宽度约300 m,实验场景如图4所示。由图4可见,边坡上有大量的植被覆盖和散射特性较为稳定的公路、房子与裸露山体。实验所用雷达是由北京理工大学雷科公司研发的直线扫描式地基干涉合成孔径雷达,如图5所示。该雷达工作在Ku波段,测量周期在3~10 min,1 km处的空间分辨率为0.3 m×4.0 m。



图4 实验场景

Fig. 4 Experimental scenario diagram



图5 地基合成孔径雷达

Fig. 5 Ground-based synthetic aperture radar

实验训练数据使用的是2021年5月7日14:41~16:09时段所获取的30幅雷达图像,该时段幅值平均成像如图6(a)所示。测试数据是2021年5月7日16:12~17:40所获取的雷达图像,该时段幅值平均成像如图6(b)所示。对于训练后的网络,训练所用数据与测试数据不同

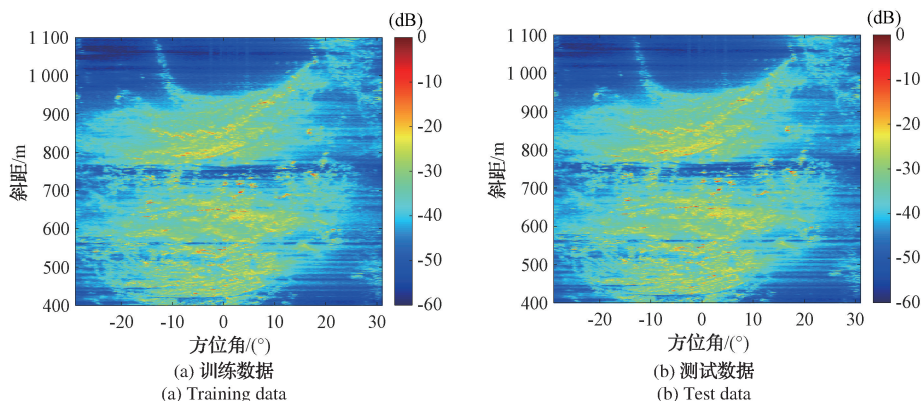


图6 幅度成像

Fig. 6 Amplitude imaging map



且无交集,但由于训练和测试所用数据间隔时间较短,使得它们特征具有相似性。

3 实验结果与分析

3.1 实验训练参数设置

将训练数据按 7 : 3 比例划分训练集和验证集。网络参数如下:批量大小为 64,学习率为 0.000 1,L2 正则化为 0.001,优化器为 Adam,训练轮次为 39。由于训练集样本中两个类别数目相差较大,将导致训练出现明显误差,因此实验通过二元交叉熵损失中添加类别权重降低训练误差。根据 PS 和非 PS 数目之间比例,其权重分别设置为 8 和 1。

3.2 网络性能结果

1)网络性能评估指标

本文训练网络将对 PS 特征学习建模,通过构建的 PS 分类模型实现雷达图像像素点 PS 分类,这与深度学习中的二分类相似。对于二分类模型,验证集预测的结果与实际标签之间形成混淆矩阵,关系如表 1 所示。

表 1 混淆矩阵  
Table 1 Confusion matrix

|      | 预测正例                        | 预测负例                        |
|------|-----------------------------|-----------------------------|
| 实际正例 | 真正例<br>(true positive, TP)  | 假负例<br>(false negative, FN) |
| 实际负例 | 假正例<br>(false positive, FP) | 真负例<br>(true negative, TN)  |

准确率(accuracy)表示所有正确预测样本占总样本数的比例:

$$Accuracy = (TP + TN)/(TP + FN + FP + TN)$$
(14)

精确率(precision)即正确预测正例数占预测正例总数比例:

$$Precision = TP/(TP + FP)$$
(15)

召回率(recall)即正确预测正例数占实际正例总数比例:

$$Recall = TP/(TP + FN)$$
(16)

$F_1$  分数( $F_1$ )为:

$$F_1 = 2 \cdot \frac{Precision \cdot recall}{Precision + recall}$$
(17)

由于 Precision 和 Recall 两个指标通常是相互矛盾的,很难同时提高二者。 $F_1$  分数是精确率和召回率的调和值,它提供了一种综合考虑这两个指标的方法,以平衡它们之间的矛盾。一般使用  $F_1$  来评价分类器的综合性能。

2)验证集的验证结果

将幅度阈值设置为 -40 dB 删除部分噪点,共选出 289 504 个候选样本。在候选样本中通过设置幅度离差门限 0.25 和幅值门限 -35 dB 选取网络训练所需正样本,共

得 15 886 个 PS。通过设置幅度离差 0.32 和幅值门限 -35 dB 用反阈值方法选取负样本,共 123 115 个非 PS。将正负训练样本按照 7 : 3 划分训练集和验证集,并计算样本幅度差分、干涉相位和相关系数等时序特征作为网络输入。为验证本文所提方法的有效性,对不同网络模型进行了实验分析,因为训练的目的是选出 PS,主要是对整体验证集分类结果和验证集 PS 分类结果进行分析。验证集的结果如表 2、3 所示。

表 2 各个模型整体验证集指标分析  
Table 2 Analysis of the overall validation set metrics

|                    | for each model (%) |       |       |          |
|--------------------|--------------------|-------|-------|----------|
| 模型                 | 准确率                | 精确率   | 召回率   | $F_1$ 分数 |
| LSTM               | 99.32              | 94.80 | 96.93 | 95.84    |
| TransformerEncoder | 99.04              | 92.32 | 96.42 | 94.27    |
| CNN                | 99.54              | 97.04 | 97.30 | 97.17    |
| BiLSTM             | 99.29              | 94.31 | 97.25 | 95.73    |
| BiLSTM-CNN         | 99.68              | 97.53 | 98.50 | 98.01    |

表 3 各个模型验证集 PS 类指标分析  
Table 3 Analysis of PS class metrics by model (%)

| 模型                 | 准确率   | 精确率   | 召回率   | $F_1$ 分数 |
|--------------------|-------|-------|-------|----------|
| LSTM               | 94.30 | 89.85 | 94.32 | 90.03    |
| TransformerEncoder | 93.57 | 84.92 | 93.57 | 89.04    |
| CNN                | 94.84 | 94.84 | 95.68 | 95.26    |
| BiLSTM             | 95.02 | 88.85 | 95.02 | 91.83    |
| BiLSTM-CNN         | 97.22 | 95.18 | 97.22 | 96.19    |

由表 2 可知,BiLSTM-CNN 网络整体验证集的分类性能更好,各项指标达到 97.5% 以上,准确率最高达到了 99.68%,精确率、召回率和  $F_1$  分数指标相比其他网络也有所提高。为能够进一步得出模型对 PS 特征的识别能力,PS 类的各项指标进行分析。由表 3 可知,BiLSTM-CNN 网络训练后在 PS 类上准确率最高达到 97.22%,说明该网络训练模型在整个验证集上 PS 的分类更加准确。召回率最高达到了 97.22%,表明该网络对 PS 特征学习更好,能将绝大部分标签的 PS 选出,反映出设计模型成功地捕获了大部分真正的正类别样本,表明该模型在发现和检测 PS 类方面具有很好的全面性与敏感性。BiLSTM-CNN 精确率最高达到了 95.18%,表明模型很少犯错地将负类别样本错误地预测为正类别,即将非 PS 识别为 PS 的概率更低。 $F_1$  高通常表明模型在精确度和召回率之间达到更好的平衡,高  $F_1$  得分意味着模型更精准的找到真正 PS,并且在区分 PS 与非 PS 具有更高的准确性,同时也表明了该模型在错误分类正类别和漏报正类别之间具有较好的全面性。

3.3 实测数据结果

1)常规方法

对测试集 30 幅雷达图像采用 0.25 的幅度离差门限,

只能选取 17 324 个 PS, PS 数量较少。实验场景幅度离差

图和幅度离差所选 PS 幅度离差值图如图 7(a)和(b)所示。

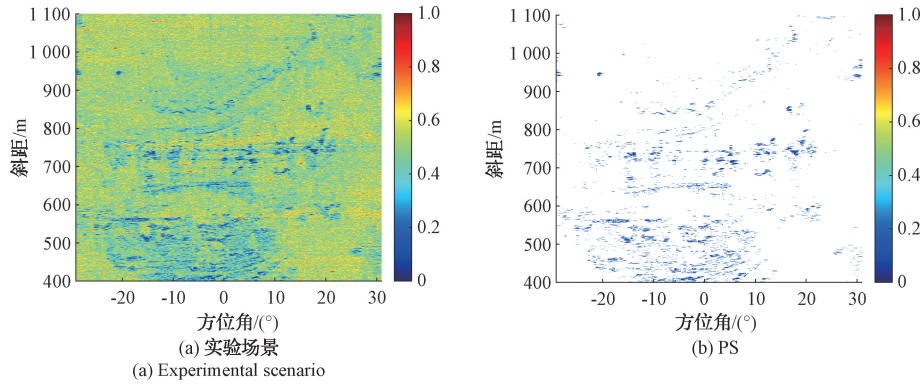


图 7 幅度离差图

Fig. 7 Amplitude dispersion map

测试集采用 0.925 的相关系数门限共选取 20 470 个 PS, 其实验场景和相关系数法所选 PS 点的时序平均相干系数如图 8(a)、(b)所示。从图 8(b)可

见, 虽然相关系数的点数较之幅度离差的点数更多, 但是它选取的 PS 成块状分布, 很容易误选一些低质量的点。

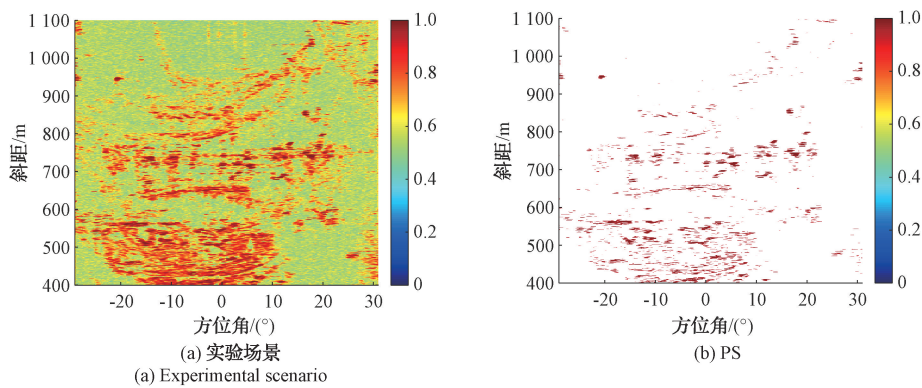


图 8 相关系数图

Fig. 8 Correlation coefficient map

## 2) BiLSTM-CNN 网络

为了减少测试时间与训练集保持一致, 通过幅值门限 -40 dB 剔除部分噪点, 共剩下 291 842 个候选 PS, 并

获取它们的差分幅度、干涉相位、相关系数输入训练好的网络进行 PS 的选取。通过网络一共选出 23 581 个 PS, 所选 PS 的幅度离差图和时序平均相干系数如图 9(a)和(b)

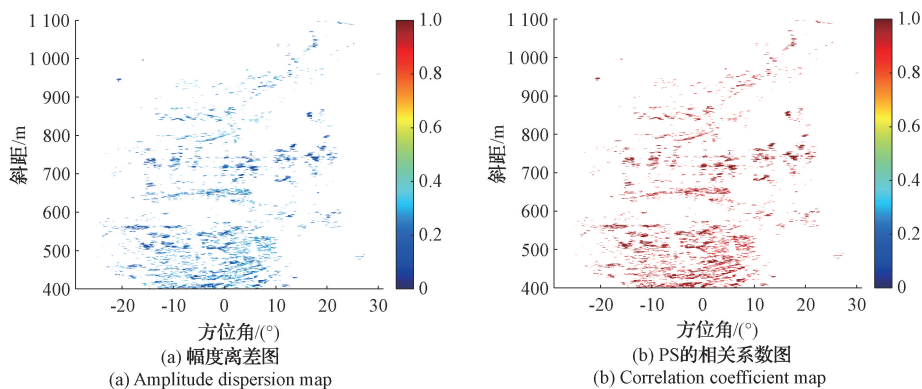


图 9 BiLSTM-CNN 选取的 PS

Fig. 9 PS selected by BiLSTM-CNN

所示。图 9(a)比图 7(b) PS 的密度较幅度离差法选取的有所增加,图 9(b)比图 8(b)块状更少。从图 9 可得,选取的 PS 大部分幅度离差值较低,且相关系数值较大。

### 3) 实测数据对比分析

对于实测雷达图像数据,由于 PS 的数量和质量将影响后续解缠以及形变测量的精度<sup>[19]</sup>,因此本文将通过所选 PS 的数量和质量来评价幅度离差法、相关系数法、BiLSTM、CNN 和 BiLSTM-CNN 方法性能。表 4 为这 5 种方法所选 PS 的数量。

表 4 PS 选取数量统计

Table 4 PS selection number statistics

| 方法         | PS 数量  |
|------------|--------|
| 幅度离差       | 17 324 |
| 相关系数       | 20 470 |
| BiLSTM     | 29 053 |
| CNN        | 22 296 |
| BiLSTM-CNN | 23 581 |

从表 4 可知,对于实测数据的 30 幅雷达图像采用 0.25 幅度离差门限选出 17 324 个 PS,采用 0.925 相关系数门限选出 20 470 个 PS,采用 BiLSTM-CNN 共选出

23 581 个 PS,采用本文方法分别比幅度离差法和相关系数法 PS 的数量提高了 36.12%、15.19%。从表 4 可得出 BiLSTM 的数量最高,但其实这些 PS 中存在一些非 PS 被识别为 PS 的情况,因此为了能更清楚 PS 选取的性能,进行下一步分析。

为了分析 PS 的质量,首先分别基于 5 种方法所选的 PS 采用最小费用流算法对这 30 幅雷达图像两两生成的干涉相相位图进行相位解缠,然后再利用二阶斜距模型进行大气相位补偿,最后得到 29 幅补偿后时序相位图。由于在监测的这 30 min 的场景并未发生形变,在进行大气相位补偿后,每一个 PS 的干涉相位中主要是噪声相位分量。因此,可以采用补偿后的时序相位的标准差来衡量 PS 相位的稳定性<sup>[20]</sup>。图 10(a)、(b)分别是 5 种方法的补偿后相位标准差的概率密度和概率分布。从图 10 可看出,5 种选取方法不同标准差区间 PS 占比出现明显差异。幅度离差法、相关系数、BiLSTM、CNN、BiLSTM-CNN 5 种方法选出的 PS 相位标准差小于 0.6 rad 的 PS 占比分别为 95.19%、87.95%、79.22%、79.21%、97.60%。当雷达系统工作在 Ku 波段(12~18 GHz)时,0.6 rad 的相位标准差对应的形变测量精度约为 0.796~1.194 mm,因此采用 BiLSTM-CNN 网络进行 PS 选取时,在保证 PS 相位质量条件下能选择出更多的 PS。

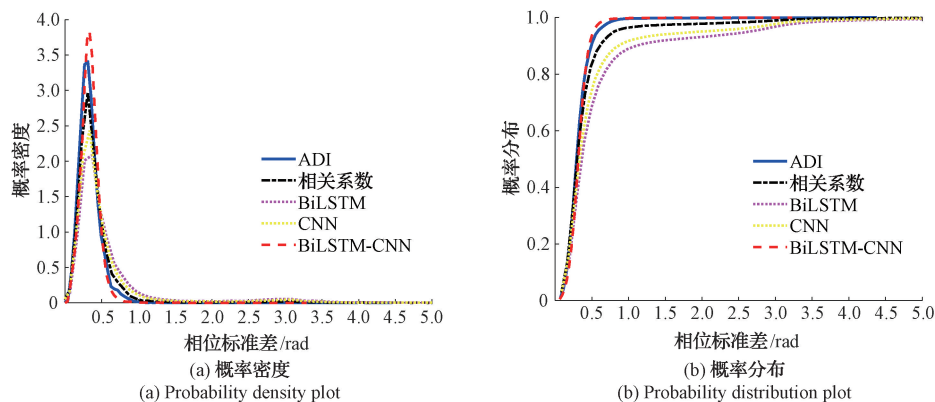


图 10 不同方法所选 PS 相位标准差的概率统计

Fig. 10 Probability statistics plots of PS phase standard deviation selected by different methods

表 5 为 5 种方法所选 PS 相位标准差区间统计数据。从表 5 可知,在 PS 相位标准差取小于 0.25 rad 时,幅度离差、相关系数、BiLSTM、CNN 和 BiLSTM-CNN 选取 PS 数量分别为 4 875、4 843、4 697、4 395 和 5 065,占比分别为 28.14%、23.66%、16.17%、19.71%、21.48%。BiLSTM 选出的 PS 数目较 CNN 多,但是占比很低,这是因为 BiLSTM 的 PS 类的精确率较低,网络将一些非 PS 误选为 PS 的原因。另外,CNN 和 BiLSTM 对于 PS 特征把握的全面性不如 BiLSTM-CNN,所选 PS 的数目较 BiLSTM 少且

占比低。由于幅度离差法、相关系数法、BiLSTM 选取的总 PS 不一样,虽然 BiLSTM-CNN 方法选取的 PS 占比较低,但是 BiLSTM-CNN 网络选取的 PS 最多。雷达系统工作在 Ku 波段时,0.25 rad 的相位标准差对应的形变测量精度约为 0.332~0.497 mm。因此若以 0.25 rad 的标准差作为 PS 质量的标准,采用 BiLSTM-CNN 网络所选 PS 数量更多。综合上所述,在植被覆盖的低相干场景下,相比幅度离差和相关系数,BiLSTM-CNN 网络能够在保证 PS 相位质量的前提下,选取更多的 PS。



表5 不同方法所选PS相位标准差统计  
Table 5 Phase standard deviation statistics of PS selected  
by different methods

| 相位标准差/rad | 方法         | 数量     | 占比/%  |
|-----------|------------|--------|-------|
| <0.25     | 幅度离差法      | 4 875  | 28.14 |
|           | 相关系数阈值法    | 4 843  | 23.66 |
|           | BiLSTM     | 4 697  | 16.17 |
|           | CNN        | 4 395  | 19.71 |
|           | BiLSTM-CNN | 5 065  | 21.48 |
| <0.3      | 幅度离差法      | 7 899  | 45.60 |
|           | 相关系数阈值法    | 7 919  | 38.69 |
|           | BiLSTM     | 7 806  | 26.87 |
|           | CNN        | 7 163  | 32.13 |
|           | BiLSTM-CNN | 8 940  | 37.91 |
| <0.4      | 幅度离差法      | 12 972 | 74.88 |
|           | 相关系数阈值法    | 13 287 | 64.91 |
|           | BiLSTM     | 14 088 | 48.49 |
|           | CNN        | 12 359 | 55.43 |
|           | BiLSTM-CNN | 17 445 | 73.98 |
| <0.5      | 幅度离差法      | 15 393 | 88.85 |
|           | 相关系数阈值法    | 16 387 | 80.05 |
|           | BiLSTM     | 18 408 | 63.36 |
|           | CNN        | 15 625 | 70.08 |
|           | BiLSTM-CNN | 21 747 | 92.22 |
| <0.6      | 幅度离差法      | 16 490 | 95.19 |
|           | 相关系数阈值法    | 18 003 | 87.95 |
|           | BiLSTM     | 21 328 | 73.41 |
|           | CNN        | 17 661 | 79.21 |
|           | BiLSTM-CNN | 23 016 | 97.60 |

4 结 论

PS选取数量及质量对地基SAR形变测量至关重要。本文提出了一种基于BiLSTM-CNN的PS选取方法,该方法采用BiLSTM和CNN网络对PS全局和局部时序特征进行学习,并通过MHSA机制实现对全局和局部时序特征进行加权融合学习,以构建PS时序特征分类模型。通过对多植被覆盖场景下实测雷达数据实验分析,有效证明了本文PS选取方法在保证一定相位质量的前提下比常规方法及基础网络能选取更多的PS。

参 考 文 献

[1] 曾涛,邓云开,胡程,等.地基差分干涉雷达发展现状及应用实例[J]. 雷达学报,2019,8(1):154-170.  
ZENG T, DENG Y K, HU CH, et al. Development state and application examples of ground-based differential interferometric radar[J]. Journal of Radars, 2019, 8(1): 154-170.  
[2] 杨鸿,田卫明,邓云开,等.面向植被边坡的地基SAR

高相干点选择[J]. 信号处理,2022,38(1):137-147.  
YANG H, TIAN W M, DENG Y K, et al. High-coherence pixel selection of ground-based SAR for vegetation slopes[J]. Journal of Signal Processing, 2022, 38(1):137-147.  
[3] HU C, DENG Y, TIAN W. Multistatic ground-based differential interferometric MIMO radar for 3D deformation measurement[J]. Science China Information Sciences, 2021, 64: 227301.  
[4] FERRETTI A, PRATI C, ROCCA F. Permanent scatterers in SAR interferometry[J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(1): 8-20.  
[5] 范锐彦,焦健,高胜,等. InSAR时序分析高相干目标选取方法比较研究[J]. 地球信息科学学报,2016, 18(6):805-814.  
FAN R Y, JIAO J, GAO SH, et al. Comparison research of high coherent target selection based on InSAR time series analysis[J]. Journal of Geo-information Science, 2016, 18(6):805-814.  
[6] TIWARI A, NARAYAN A B, DIKSHIT O. Deep learning networks for selection of measurement pixels in multi-temporal SAR interferometric processing [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 166(1):169-182.  
[7] 曹琨,崔紫维,李洋,等. 基于注意力网络的地基SAR永久散射体选取方法[J]. 信号处理,2021, 37(7): 1267-1276.  
CAO K, CUI Z W, LI Y, et al. GBSAR permanent scatterer points selection algorithm based on attention network [J]. Journal of Signal Processing, 2021, 37(7): 1267-1276.  
[8] ZHANG Y, WEI J, DUAN M, et al. Coherent pixel selection using a dual-channel 1-D CNN for time series InSAR analysis[J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 112: 102927.  
[9] 朱茂. 基于动态PS的地基合成孔径雷达高精度形变测量技术研究[D]. 北京:北京理工大学,2016.  
ZHU M. High precision deformation measurement using ground based synthetic aperture radar based on dynamic persistent scatterer technique [D]. Beijing: Beijing Institute of Technology, 2016.  
[10] 胡程,邓云开,田卫明,等. 地基干涉合成孔径雷达图像非线性大气相位补偿方法[J]. 雷达学报,2019, 8(6):831-840.  
HU CH, DENG Y K, TIAN W M, et al. A compensation method of nonlinear atmospheric phase applied for GB-InSAR images[J]. Journal of Radars, 2019,

- 8(6):831-840.
- [11] 王军飞,刘东烈,汪雯雯,等.一种PS选点方法的GB-SAR边坡监测数据处理应用[J].测绘科学,2020,45(12):108-115.  
WANG J F, LIU D L, WANG W W, et al. Application of a permanent scatterers selection method in GB-SAR slope monitoring data processing[J]. Science of Surveying and Mapping, 2020,45(12):108-115.
- [12] 熊敏,江德军,高志良,等.大坝监测数据多维度LSTM异常检测与恢复[J].电子测量技术,2023,46(6):51-56.  
XIONG M, JIANG D J, GAO ZH L, et al. Dam monitoring data multi-dimensional LSTM anomaly Detection and recovery [J]. Electronic Measurement Technology,2023,46(6):51-56.
- [13] BOHARA B, FERNANDEZ R I, GOLLAPUDI V, et al. Short-term aggregated residential load forecasting using BiLSTM and CNN-BiLSTM[C]. 2022 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT). IEEE, 2022: 37-43.
- [14] 杨进昆,党建武,杨景玉,等.基于时序分析及CNN-BiLSTM-AM的阶跃型滑坡位移预测[J].国外电子测量技术,2024,43(1):126-134.  
YANG J K, DANG J W, YANG J Y, et al. Displacement prediction of step-like landslide based on temporal analysis and CNN-BiLSTM-AM [J]. Foreign Electronic Measurement Technology, 2024, 43(1):126-134.
- [15] 曲建岭,余路,袁涛,等.基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J].仪器仪表学报,2018,39(7):134-143.  
QU J L, YU L, YUAN T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2018, 39 (7): 134-143.
- [16] WANG Z, YAN W, OATES T. Time series classification from scratch with deep neural networks: A strong baseline[C]. 2017 International Joint Conference on Neural Networks. IEEE,2017:1578-1585.
- [17] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 6000-6010.
- [18] 乐华钢,王文武,朱磊,等.融合自注意力与缺陷凸显的缺陷检测方法[J].电子测量与仪器学报,2023,37(9):85-92.  
YUE H G, WANG W W, ZHU L, et al. Defect detection method integrating self-attention and highlighting of defects[J]. Journal of Electronic Measurement and Instrumentation, 2023,37(9):85-92.
- [19] DENG Y, TIAN W, XIAO T, et al. High-quality pixel selection applied for natural scenes in GB-SAR interferometry[J]. Remote Sensing, 2021, 13(9): 1617.
- [20] 金重阳,刘毓,邓云开,等.面向复杂大气扰动的GB-InSAR相位误差补偿方法[J].信号处理,2022,38(11):2432-2442.  
JIN CH Y, LIU Y, DENG Y K, et al. Phase error compensation method for complex atmospheric disturbance in GB-InSAR[J]. Journal of Signal Processing,2022,38(11):2432-2442.

## 作者简介

陈姣,硕士研究生,主要研究方向为地基合成孔径雷达干涉测量技术。

E-mail:2414789586@qq.com

刘毓(通信作者),硕士,副教授,主要研究方向为雷达信号处理及高灵敏度导航定位技术。

E-mail:liuyu418@126.com

邓云开,博士,特别副研究员,主要研究方向为地基SAR高精度1维形变与3维形变实时测量算法。

E-mail:yunkai\_bit@bit.edu.cn

金重阳,硕士,主要研究方向为地基干涉雷达地形及形变测量技术。

E-mail:1074970891@qq.com

杨志航,硕士研究生,主要研究方向为雷达探通一体化波形设计与处理。

E-mail:2646943744@qq.com