引用格式:刘鑫宇,曹新亮. 基于LSTM的GNSS-R镜面反射点预测算法[J]. 延安大学学报(自然科学版),2026,45(3):134-140.[LIU X Y,CAO X L. GNSS-R specular reflection point prediction algorithm based on LSTM[J]. Journal of Yan'an University(Natural Science Edition),2026,45(3):134-140.] **DOI**:10.13876/J.cnki.ydnse.250135

基于LSTM的GNSS-R镜面反射点预测算法

刘鑫宇[1],曹新亮[1,2*]

(1. 延安大学 物理与电子信息学院;2. 陕西省能源大数据省市共建实验室,陕西 延安 716000)

摘　要:在GNSS-R遥感领域中,镜面反射点预测是地面遥感探测的前提,其预测精度和运算速度会直接影响后续反演结果的可靠性,传统镜面反射点预测方法存在收敛速度慢、结果稳定性不足等问题。本文提出一种改进型LSTM的多变量时序预测算法,主要针对河流区域的反射点定位问题进行优化。通过对LSTM模型的改进,相较于传统的镜面反射点搜索算法,所提方法在预测稳定性和精度方面均有所提升。仿真结果表明,所采用方法在河流场景下具有较高的精度,其平均绝对误差较传统算法有显著下降,其决定系数R^2达到0.951 6。研究结果表明,将镜面反射点预测从"几何约束求解"转变为"时序特征学习"具有可行性,可为河流水位监测中的参数反演提供一定的参考价值。

关键词:GNSS-R;镜面反射点;长短时记忆网络(LSTM)

中图分类号:TP202　　**文献标志码**:A　　**文章编号**:1004-602X(2026)03-0134-07

全球导航卫星反射信号(Global Navigation Satellite System Reflectometry, GNSS-R)遥感技术,已成为当前国内外遥感领域的研究热点。随着全球对地观测需求的深化与卫星导航技术的成熟,GNSS-R技术凭借信号源丰富、成本低、多信号同步观测、具备一定穿透力等优势,在工程建造、精密导航等领域的应用价值逐步凸显[1]。其研究应用已覆盖河流水位反演、海冰厚度反演、降雨量监测、海水盐度反演、植被覆盖度监测等多个方向[2-5],在地表遥感、海洋环境动态监测等领域展现出良好的应用前景。

镜面反射点三维坐标搜索是GNSS-R遥感的核心任务,其精度直接影响地理定位、天线指向调整和参数反演效果[6,7]。现在的镜面反射点的搜索算法主要有Gleason算法、Wu算法和线段二分法。Gleason算法精度高,但是模型复杂、收敛速度慢[8];Wu算法精度高,但是在极端几何条件下稳定性较差[9];线段二分法模型简单、稳定,但是收敛速度慢,依赖初始线段的选择[10]。

鉴于GNSS-R技术在不同地表环境中反射机理存在差异,本文将研究对象限定于河流场景。相较于海洋环境,河流具有尺度适中、边界清晰及水面连续性较强等特点,更有利于分析镜面反射点的时序变化规律。同时,河流水位反演是GNSS-R遥感的重要应用方向之一,对镜面反射点定位精度具有较高要求。因此,本文围绕河流场景构建基于深度学习的改进型LSTM模型,借鉴现有研究中机器学习方法在GNSS-R参数反演中的应用思路[11-12],通过时序特征学习代替传统的几何约束求解,进一步提升了预测精度。

1　镜面反射点

镜面反射点三维坐标定位精度直接决定参数

收稿日期:2025-11-23
基金项目:国家自然科学基金项目(62141107)
作者简介:刘鑫宇(2002—),男,硕士研究生,主要从事卫星导航高精度定位研究。
*通信作者　E-mail:xinliangcao@yau.edu.cn

反演效果，而传统算法的缺陷本质源于对“镜面反射点核心特征与约束逻辑”的应用局限。因此，要构建更优的预测方法，需先明确镜面反射点的物理本质、几何约束及数学表达，为后续算法改进提供理论基准。

镜面反射点的几何关系如图1所示，存在一个特殊交汇点，这个交汇点使“发射机-地球表面-接收机”这条传播链路的空间距离达到最小，该点被定义为镜面反射点，在理想环境假设下，镜面反射点要同时满足三项核心条件[13-14]：1）空间位置严格处于地球表面；2）对应的信号反射路径长度是所有可能路径里最短的，约束条件如式（1）所示；3）信号入射角度和反射角度相等，约束条件如式（2）所示。

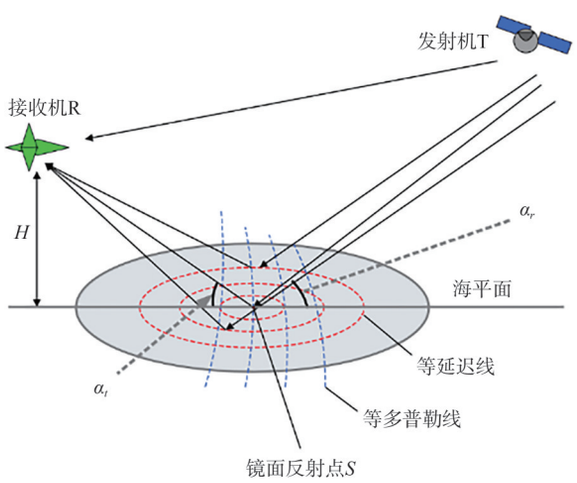


图1　镜面反射点示意图

在理想的条件下，搜索镜面反射点的约束条件为

$$l = |R - S| + |T - S| = \sqrt{(X_r - X_s)^2 + (Y_r - Y_s)^2 + (Z_r - Z_s)^2} + \sqrt{(X_t - X_s)^2 + (Y_t - Y_s)^2 + (Z_t - Z_x)^2}, \quad (1)$$

$$\alpha_r = \alpha_t, \quad (2)$$

其中，R为接收机坐标，T为发射机坐标，S为镜面反射点三维坐标。它们的几何关系如图1所示，α_r与α_t分别为反射角与入射角，根据菲涅尔定律，α_r与α_t是相同的。

后续精度评价环节中，大地坐标系下的经度（L）、纬度（B）以及高度（h），均通过WGS84椭球参数转换为ECEF直角坐标系下的$X\backslash Y\backslash Z$坐标，统一量纲后完成误差计算，转换公式如下：

$$\begin{cases} X = (N + H)\cos B\cos L, \\ Y = (N + H)\cos B\sin L, \\ Z = \left(N\left(1 - e^2\right) + H\right)\sin B, \end{cases} \quad (3)$$

其中，N为WGS84椭球的卯酉圈曲率半径，e为椭球第一偏心率，对应WGS84椭球基准的标准参数为长半轴a=637 813 7 m，f=1/298.257 223 563。

基于上述镜面反射点的三重约束，传统算法通过几何求解实现三维坐标搜索，但该类方法依赖严格的理想假设，在近岸多散射、动态水文等实际场景中，易因约束条件的简化导致收敛慢、稳定性差。因此，需从新的技术方向来构建三维坐标预测模型。

2　镜面反射点的预测

针对传统“几何约束求解”方法在实际场景中存在的适应性不足，并结合镜面反射点三维坐标预测具有的“多变量时序关联”特性，本文引入深度学习方法构建预测模型。为评估不同时序模型性能，本文选取循环神经网络（RNN）作为基线模型[15]、门控循环单元（GRU）用于考察模型效率与性能[16]以及长短时记忆网络（LSTM）作为基准模型来进行对比分析[17]。

LSTM依靠门控机制，可有效改善RNN处理长序列时普遍存在的梯度消失与梯度爆炸问题，进而更稳定地捕捉时序数据中不同时间步间的动态关联特征。但将传统LSTM直接应用于GNSS-R镜面反射点预测时，仍面临两方面挑战：一是对长时序变化的适应性仍存在不足，难以充分捕捉遥感数据中跨越长时间尺度的依赖特征；二是在多变量耦合的高维i场景下，其门控机制的运算效率与特征交互能力仍有提升空间。这些限制使得传统LSTM难以完全适应GNSS-R数据高动态、非线性的特点，从而限制三维坐标预测精度与稳定性的进一步提升。为此，本文从以下3个方面对LSTM模型进行优化。

2.1　特征筛选与归一化

在模型训练前，需对数据集进行预处理。首先，从原始数据中筛选出7类与镜面反射点三维坐标预测强相关的输入特征（入射角、天线增益、菲涅尔反射系数平方、陆海掩码、卫星坐标、离岸距离和卫星仰角）；当单样本特征值缺失率超过30%时，模型会自动过滤掉无效样本；对缺失率小于30%的样本，采用线性插值法补全缺失值，保障数据的连续性与鲁棒性。然后，通过天线增益、陆海掩码以及卫星仰角对数据进行初步筛选，随后将数据集按照时间升序以8∶1∶1划分为训练集、验证集与测试集；由于不同特征量纲差异显著（如“离岸距离”为千米

级,“菲涅尔反射系数平方”为小数级),需将筛选后的特征与目标变量(镜面反射点经度、纬度、高度)分别归一化至[0,1]区间,以避免数值范围对模型训练的干扰,归一化公式为

$$x_{\text{scaled}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \tag{4}$$

其中,$x_{\min}$与$x_{\max}$分别为原始数据的最小值与最大值,用于后续预测结果的逆归一化。构建“历史特征-未来目标”的样本对,即使用第i至i+9步的7维特征数据,预测第i+10步的镜面反射点三维坐标预测值。

2.2 模型结构设计

经筛选与归一化后的多变量时序数据,既具备时间维度上的连续性,又存在各特征之间的耦合关联。为了充分挖掘数据中蕴含的深层规律,本文设计了一套堆叠式的LSTM网络结构。如图2所示,该模型的核心为编码器式的顺序结构,整体由输入层、双层LSTM特征提取层、正则化层和全连接输出层构成,各层协同完成镜面反射点三维坐标的预测任务。

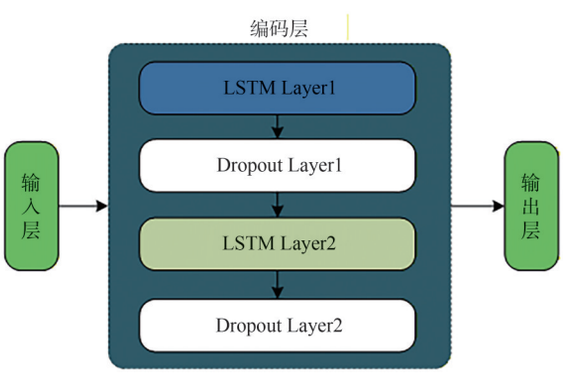


图2 改进型LSTM模型

该模型的输入层结构为“批量大小、时间步长、特征维度”的张量,结合数据特征与训练结果,将时间步长设为10、特征维度设为7,两层LSTM的隐藏单元数均设置为64,Dropout层的失活率定为0.3。

在本研究中,设置时间步长t=10,即利用历史连续10个时刻的7维特征观测数据,来预测下一时刻的镜面反射点三维坐标,输入层的核心作用是将预处理后的时序数据,组织成LSTM网络能够直接处理的张量格式。

其次该模型采用两层堆叠的LSTM单元构成核心特征提取器。第一层LSTM设置隐藏单元数为64,用于初步学习输入序列在时间维度的低维时序特征和短期依赖关系(入射角、菲涅尔反射系数平方、陆海掩码和天线增益);第二层LSTM同样设置隐藏单元数为64,接收第一层的输出序列。该层致力于捕捉更高级、更复杂的长期时序依赖与特征交互(卫星坐标、离岸距离和矫正信号参数)。堆叠结构增强了模型的表征能力,使其能够从原始数据中抽象出多层次的信息。层间设置Dropout=0.3,即在训练时随机屏蔽30%的神经元连接,以缓解深层网络可能出现的过拟合问题。

第二个LSTM层在最后一个时间步输出的隐藏状态h_T,被视为整个输入序列的浓缩表征。该状态向量首先通过一个独立的Dropout层进行进一步正则化,随后馈入一个全连接(Dense)层。全连接层执行线性变换$y = \boldsymbol{W}\cdot h_t + b$($\boldsymbol{W}$为特征矩阵),将64维的特征向量映射为三维的标量输出,即预测的镜面反射点经度、纬度、高度。

LSTM结构的核心在于输入门、遗忘门与输出门协同构成的门控逻辑,可针对长时序输入数据完成特征的选择性留存与跨步长传递,从根本上规避了传统循环神经网络处理长序列时的梯度消失与梯度爆炸痛点,完美契合本文GNSS-R镜面反射点预测任务中,带强时序相关性的遥感数据三维建模需求。

2.3 训练策略优化

“双层LSTM+Dropout”模型结构增强了时序特征的表征能力,但在训练过程中,仍然可能面临梯度不稳定、收敛速度波动和过拟合等问题。为了提高模型训练的稳定性和泛化能力,本文在训练过程中进行了梯度裁剪、动态学习率调整以及早停机制的优化。

首先,采用均方误差(MSE)δ_{MSE}作为损失函数,如式(5)所示。

$$\delta_{\text{MSE}} = \frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2, \tag{5}$$

其中,y_i代表归一化后的镜面反射点经度、纬度、高度的真实值,$\hat{y}_i$为模型对应纬度的归一化预测值,N为单次训练的样本数量,通过该损失函数能够直观地反映出预测值与真实值之间的差异。

优化过程中,本研究选用Adam优化器,并结合L2权重衰减以进行正则化,以此有效抑制模型的过拟合现象;初始学习率设置为0.001,这样既能保证模型有较快的收敛速度,又能保持训练过程的稳定性,避免因学习率过高导致的训练振荡。

在反向传播阶段,首先根据均方误差计算梯度,然后应用梯度裁剪策略限制梯度的L2范数。如

果梯度的L2范数超过设定的阈值(1.0)，则对其进行缩放，以确保参数更新的稳定性。具体计算公式如式(6)所示。

$$\hat{g} = \frac{\boldsymbol{g}.\max_norm}{\max(norm(\boldsymbol{g}).\max_norm)}, \tag{6}$$

其中，$\boldsymbol{g}$为原始梯度，$norm(\boldsymbol{g})$为L2范数(欧几里得范数)。对梯度向量$\boldsymbol{g}$计算其L2范数$\|\boldsymbol{g}\|_2$，若$\|\boldsymbol{g}\|_2 > 1.0$，则按$\boldsymbol{g} = \boldsymbol{g} \div \|\boldsymbol{g}\|_2$进行缩放，以确保梯度更新过程的稳定性，进而保障参数更新的稳定进行。

学习率采用基于验证集损失的动态调整策略。当验证集损失在连续15次训练迭代中未能进一步下降时，学习率会自动降低，从而帮助模型在后期训练中更稳定地收敛。

此外，本文还引入了早停机制。如果验证集损失在连续50轮训练中没有改善，训练将被终止，并恢复到验证性能最佳时的模型参数。这个机制能够避免无效的训练时间，同时减少训练后期过拟合的风险。

在训练完成后，测试集数据会输入到训练得到的最优模型中，预测出镜面反射点的经度、纬度和高度。然后，利用训练阶段保存的缩放器参数对预测值和真实值进行反归一化处理，再通过式(3)进行坐标转换，最终获得实际的镜面反射点位置。最后计算测试集上的平均绝对误差(Mean Absolute Error，MAE)δ_{MAE}以及决定系数(R^2)指标，通过量化指标来客观评价改进型LSTM模型的实际预测性能。其中，δ_{MAE}和R^2的计算公式如式(7)和式(8)所示。

$$\delta_{MAE} = \frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i), \tag{7}$$

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2}。 \tag{8}$$

其中，$\bar{y}$为所有样本标准值的均方。

如图3所示，本文提出的镜面反射点预测模型以改进型LSTM为核心组件。LSTM通过输入门、遗忘门和输出门完成时序特征提取与状态更新，可有效捕GNSS-R时序数据中镜面反射点的动态变化规律；模型基于提取的时序特征输出镜面反射点三维坐标预测值，通过计算预测值与真实值的MSE损失，结合Adam优化器、梯度裁剪、动态学习率策略完成参数迭代优化，最终实现镜面反射点的高精度稳定预测。

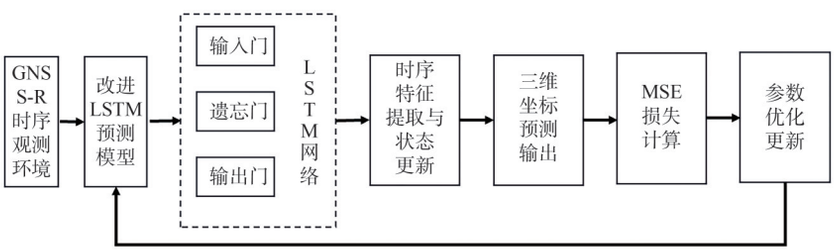


图3　模型训练和预测流程

3　仿真分析

为了验证本文所搭建的改进型LSTM模型在镜面反射点三维坐标预测任务中的性能，本文基于FY-3 GNOS-R在长江流域的实测数据[18]构建仿真实验，将该模型与RNN、GRU两种时序神经网络以及传统的Gleason几何求解算法进行对比分析。实验从训练过程的稳定性、三维空间坐标的实际预测精度、核心评估指标的量化表现三个角度切入，重点分析不同模型在经度、纬度、高度三个维度的预测差异，以此客观验证改进型LSTM模型的优越性。

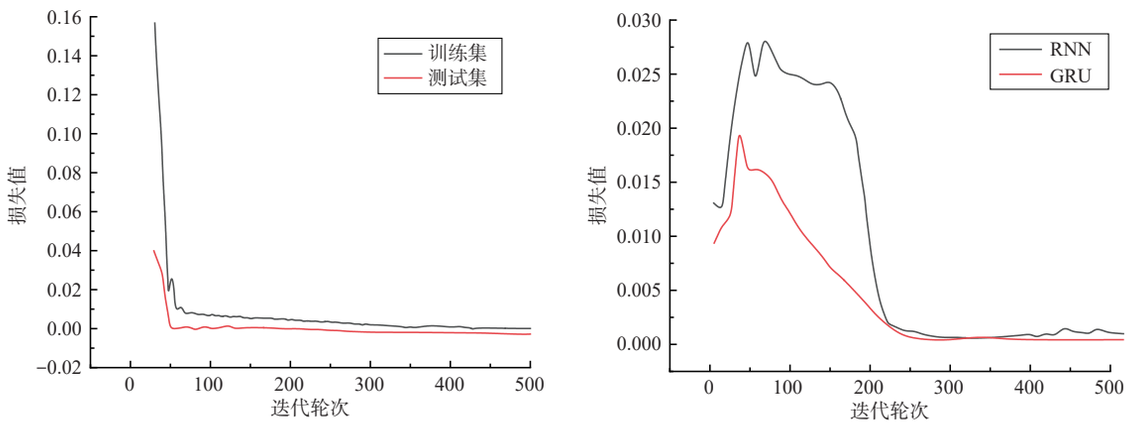
本次仿真实验的参数设置，综合考虑了模型训练需求与实测数据的自身规律。结合改进型LSTM模型设定的10步历史特征窗口，将输入时间步长确定为10；通过前期试训的模型收敛曲线分析，把基础训练迭代轮次设为100次。同时为保障训练稳定性，在优化策略中设置早停机制的耐心值为50个训练轮次，学习率动态调整的触发条件为连续15个训练轮次验证损失无下降，确保所有对比模型的训练参数保持一致，让实验结果更具可比性。

3.1　损失曲线和优化策略验证

模型训练过程的稳定性与收敛效率，是其能否落地应用的重要前提。图4展示了不同时序模型在训练集和验证集上三维坐标预测的综合损失变化曲线。

图4A为改进型LSTM模型的损失变化情况，可以明显看出其损失曲线呈平滑且快速的下降趋势，在迭代约30个周期后就进入了稳定平台期，没有出现明显的振荡现象。同时，验证集的损失曲线与训

练集贴合度极高,最终均稳定在较低水平。实验结果表明,这些标准优化策略的集成应用有效地抑制了深层LSTM在处理三维坐标回归时的不稳定性,证明了通过参数更新策略调优,可使模型在特定遥感预测任务中获得理想的收敛效果。经计算,验证集最终损失较初始值下降了48.7%,进一步验证了改进策略对模型训练的优化效果。



A. 改进型LSTM　　B. RNN与GRU损失函数

图4　损失曲线

图4B为RNN与GRU模型的损失函数曲线,二者的表现均不及改进型LSTM。传统RNN的损失曲线振荡较为剧烈,收敛速度也很慢,且验证集损失在训练后期出现明显上升趋势,暴露出其固有的梯度不稳定问题,也容易产生过拟合,难以适配镜面反射点的三维坐标预测任务;GRU模型的表现虽优于RNN,收敛速度更快、曲线振荡也有所减弱,但其验证集损失的稳定值仍显著高于改进型LSTM,说明其在捕捉GNSS-R数据中复杂的长时序依赖关系上仍有明显局限,对多变量耦合的特征提取能力不足。

3.2　三维坐标预测对比

镜面反射点预测的本质是三维空间定位问题,经度、纬度、高度的联合预测精度直接决定模型的实际应用价值,图5展示了各模型在测试集上,对镜面反射点三维坐标(经度、纬度、高度)的联合预测结果与实际轨迹的对比情况。采用大地坐标系进行可视化,可直观呈现镜面反射点的地理空间分布与轨迹拟合效果。

从图5中可以直观看出,改进型LSTM模型的预测点与真实轨迹在三维空间中高度重合,经纬度维度的预测点紧密贴合真实坐标的分布规律,高度维度的预测点也几乎分布在真实曲面附近,充分说明该模型能精准学习镜面反射点空间坐标的联合分布特征,对三维坐标的整体预测效果优异。而RNN与GRU模型的预测点则呈现出明显的离散性和偏差:RNN的预测结果在经度、纬度和高度三个维度均出现系统性偏移,其中在高度上的偏移最为突出,难以满足实际定位需求;GRU模型在经纬度维度的预测偏差相对较小,但在高度上的预测值波动依旧明显,与真实值的偏差远大于改进型LSTM。

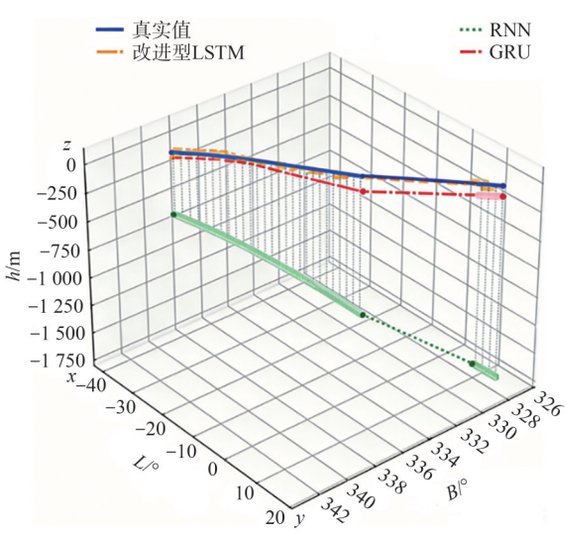


图5　实际值与预测值的三维坐标对比图

为进一步定量评估不同模型在三维坐标预测中的拟合能力,引入决定系数(R^2)作为补充指标,其作为三维坐标综合决定系数。通过对实验结果进行计算,改进型LSTM模型的R^2达到0.951 6,GRU模型为0.728以及RNN模型为0.552 4,说明改进型LSTM模型在整体趋势拟合与非线性关系刻画方面具有更强能力。这一结果进一步印证了RNN与

GRU在处理长序列、非线性映射任务时的固有缺陷，也凸显了改进型LSTM在镜面反射点这类三维空间定位长序列预测任务中的优势。

3.3　基于测试集的高度预测准确率

图6呈现了测试集高度的预测值与实际值的对比。从曲线趋势看，蓝色预测高度曲线与红色实际高度曲线整体贴合度较高，尤其在样本序号从0~600的变化过程中，对高度下降、平稳及上升等不同阶段的刻画都较为准确。经计算，测试集高度预测的MAE仅为0.424 4 m，这一误差水平在GNSS-R镜面反射点高度预测任务中处于较优水平，充分体现出所构建LSTM模型在高度这一关键维度的预测精度优势，能满足实际应用对镜面反射点高度精准获取的需求。

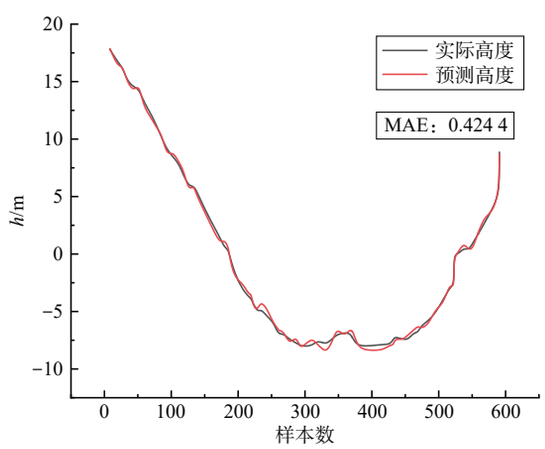


图6　测试集实际高度与预测高度对比图

3.4　改进型LSTM与传统算法的仿真误差对比

为定量对比不同方法在镜面反射点三维坐标预测任务中的性能，本文对传统几何求解算法（Gleason算法、Wu算法和线段二分法）采用统一输入数据，即基于改进型LSTM模型所使用数据集中的卫星坐标与接收机坐标进行镜面反射点计算。其中，Gleason算法通过向量几何关系直接求解反射点位置，Wu算法基于费马原理构建路径最短约束方程进行求解，线段二分法则通过迭代逼近满足反射条件的解。表1给出了不同方法在统一数据集上的MAE以及传统算法的迭代次数。由于传统几何方法为确定性解算过程，其输出不具备统计学习意义上的拟合过程，因此本文未对其计算R^2指标。

由表1可以看出，在统一数据集与实验条件下，传统几何方法均能够实现镜面反射点的基本定位，但其预测误差整体高于改进型LSTM模型。其中，Wu算法在传统方法中表现相对较好，而线段二分法由于依赖初始区间，其误差相对较大。本文改进型LSTM模型在三维坐标预测任务中取得了更低的MAE（0.534 7 m）。这主要是由于河流近岸场景的多路径效应、动态水文变化会打破传统算法依赖的理想镜面反射假设，导致几何约束求解误差放大。相比之下，LSTM模型通过对历史时序特征的学习，能够有效缓解复杂场景下的误差累积，具备更强的稳定性与场景适应性。

表1　不同方法的仿真误差对比

性能指标	改进型LSTM	Gleason算法	Wu算法	线段二分法
迭代次数		29	23	
三维坐标MAE/m	0.534 7	9.8	7.8	65.5

4　结论

本文提出了一种基于LSTM的GNSS-R镜面反射点三维坐标预测方法。该方法通过双层LSTM结构增强时序特征提取能力，并结合Dropout、L2正则化、梯度裁剪、动态学习率调度与早停机制对训练过程进行优化，从而提升模型的训练稳定性与泛化能力。实验结果表明，改进型LSTM模型相较于RNN和GRU模型更适用于镜面反射点预测任务，同时与传统算法相比，也表现出更高的预测精度，可为河流水位反演提供一定参考。

参考文献：

[1]RUF C, GLEASON S. Spaceborne GNSS-R bistatic radar remote sensing, CYGNSS, and future missions[J]. Proceedings of the IEEE, 2025, 68(8): 1-19.

[2]YANG C, MAO K, GUO Z, et al. Review of GNSS-R technology for soil moisture inversion[J]. Remote Sensing, 2024, 16(7): 1193.

[3]LI W, RIUS A, FABRA F, et al. Revisiting the GNSS-R waveform statistics and its impact on altimetric retrievals[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(5): 2854-2871.

[4]DU H, LI W, CARDELLACH E, et al. Deep residual fully connected network for GNSS-R wind speed retrieval and its interpretation[J]. Remote Sensing of Environment, 2024, 313: 114375.

[5]ZHANG Y, BU J, ZUO X, et al. Vegetation water content retrieval from spaceborne GNSS-R and multi-source remote sensing data using ensemble machine learning methods[J]. Remote Sensing, 2024, 16(15): 10616-10619.

[6]BAI D, RUF C S, MOLLER D. Calibration of the

polarimetric GNSS-R sensor in the rongowai mission [J]. IEEE Transactions on Geoscience and Remote Sensing, 2025,63(10):1-18.
[7]刘原华,孙毅,牛新亮. 两种GNSS-R镜面反射点搜索算法[J]. 全球定位系统,2020,45(4):83-88.
[8]GLEASON S, HODGART S, SUN Y, et al. Detection and processing of bistatically reflected GPS signals from low earth orbit for the purpose of ocean remote sensing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005,43(6):1229-1241.
[9]WU S, MEEHAN T, DUNN C, et al. The potential use of GPS signals as ocean altimetry observables [C]//Proceedings of the National Technical Meeting. Santa Monica: Institute of Navigation,1997:543-550.
[10]张波,王峰,杨东凯. 基于线段二分法的GNSS-R镜面反射点估计算法[J]. 全球定位系统,2013,38(5):11-16+26.
[11]WU F, ZHENG W, LI Z, et al. Improving the GNSS-R specular reflection point positioning accuracy using the gravity field normal projection reflection reference surface combination correction method[J]. Remote Sensing,2018, 11(1):33.
[12]ZHANG Y, HUANG S, HAN Y, et al. Machine learning methods for spaceborne GNSS-R sea surface height measurement from TDS-1 [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2021,15:1079-1088.
[13]SOUTHWELL B J, DEMPSTER A G. A new approach to determine the specular point of forward reflected GNSS signals[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2018,11(2):639-646.
[14]JUANG J C. On the determination of the specular reflection point in GNSS reflectometry [C]//Proceedings of the IEEE Specialist Meeting on Reflectometry using GNSS and Other Signals of Opportunity (GNSS+R). New York: IEEE,2021: 86-89.
[15]LIMSUPAVANICH N, GUO B, FU X. Application of RNN on GNSS Reflectometry Sea level monitoring[J]. International Journal of Remote Sensing,2022,43(10):3592-3608.
[16]TANG Y, JIANG J, LIU J, et al. A GRU and AKF-based hybrid algorithm for improving INS/GNSS navigation accuracy during GNSS outage [J]. Remote Sensing, 2022, 14(3):752.
[17]FANG W, JIANG J, LU S, et al. A LSTM algorithm estimating pseudo measurements for aiding INS during GNSS signal outages[J]. Remote sensing,2020,12(2):256.
[18]国家卫星气象中心. FY-3 GNOS-R数据[EB/OL]. [2026-02-16] http://satellite.nsmc.org.cn/.

[责任编辑 毕 伟]

GNSS-R specular reflection point prediction algorithm based on LSTM

LIU Xinyu[1], CAO Xinliang[1,2*]

(1. School of Physics and Electronic Information, Yan'an University;
2. Provincial-Municipal Joint Laboratory for Energy Big Data, Yan'an 716000, China)

Abstract: In the GNSS-R remote sensing field, the prediction of mirror reflection points is the prerequisite for ground remote sensing detection. The prediction accuracy and computing speed will directly affect the reliability of the subsequent inversion results. The traditional geometric-based specular reflection point prediction methods have problems such as slow convergence speed and insufficient result stability. This paper constructs a multivariate time series prediction model using an improved LSTM network, with targeted optimization for the characteristics of river scene reflection point positioning. This paper optimize the LSTM's dual-layer structure and training strategy to enhance its temporal feature extraction capability for GNSS-R observation data, which enables the model to outperform traditional algorithms in both prediction stability and positioning accuracy. Simulation test results verify that the proposed method achieves high-precision prediction in typical river scenarios, with a significant reduction in mean absolute error (MAE) compared to conventional methods, and the coefficient of determination (R^2) reaches 0.951 6. The research results prove that it is feasible to replace the traditional geometric constraint solving method with a temporal feature learning framework for specular reflection point prediction, which can provide valuable theoretical and technical support for parameter inversion in river water level monitoring.

Key words: GNSS-R; specular reflection point; Long Short-Term Memory (LSTM)