

引文格式:张丽,董有福,厉鸣.利用弹性反馈神经网络融合ASTER GDEM和SRTM1高程数据[J].武汉大学学报(信息科学版),2023,48(5):777-783.DOI:10.13203/j.whugis20200679



Citation:ZHANG Li,DONG Youfu,LI Ming.ASTER GDEM and SRTM1 Elevation Data Integration with RProp Neural Network[J].Geomatics and Information Science of Wuhan University,2023,48(5):777-783.DOI:10.13203/j.whugis20200679

# 利用弹性反馈神经网络融合ASTER GDEM和SRTM1高程数据

张丽<sup>1</sup> 董有福<sup>1</sup> 厉鸣<sup>1</sup>

1 南京工业大学测绘科学与技术学院,江苏南京,211816

**摘要:**由于数据获取与后期处理方式不同,先进星载热发射和反射辐射仪全球数字高程模型(advanced spaceborne thermal emission and reflection radiometer global digital elevation model, ASTER GDEM)和航天飞机雷达地形测绘任务(shuttle radar topography mission, SRTM)数据在高程精度上存在差异,采用弹性反馈(resilient backpropagation, RProp)神经网络算法对二者进行融合处理,实现优势互补以提升高程精度。选取两个黄土丘陵沟壑地貌样区分别用于模型建立与效果验证,1:10 000高程精度为参考数据,在建模样区应用RProp神经网络算法构建ASTER GDEM高程校正模型、SRTM1高程校正模型、ASTER GDEM与SRTM1高程融合模型,同时应用误差反向传播(back propagation, BP)神经网络建立ASTER GDEM与SRTM1高程融合模型,将这些模型的高程精度优化效果进行对比,并在验证样区检验RProp融合模型的可行性。结果表明,RProp融合模型的高程校正效果整体上优于ASTER GDEM高程校正模型、SRTM1高程校正模型和BP神经网络融合模型,高程均方根误差分别降低6.81 m、0.34 m与0.19 m,具有良好的适用性与误差校正效果。

**关键词:**误差模型;数据融合;弹性反馈神经网络;深度学习

中图分类号:P228;P237

文献标识码:A

收稿日期:2021-03-15

DOI:10.13203/j.whugis20200679

文章编号:1671-8860(2023)05-0777-07

## ASTER GDEM and SRTM1 Elevation Data Integration with RProp Neural Network

ZHANG Li<sup>1</sup> DONG Youfu<sup>1</sup> LI Ming<sup>1</sup>

1 School of Geomatics Science and Technology, Nanjing Tech University, Nanjing 211816, China

**Abstract:** Objectives: There exist some differences between the elevation accuracy of advanced spaceborne thermal emission and reflection radiometer global digital elevation model (ASTER GDEM) and shuttle radar topography mission (SRTM) data, because their methods of data acquisition and post-processing are different. Methods: To improve the DEM accuracy by taking advantages of ASTER GDEM and SRTM, the resilient backpropagation (RProp) neural network algorithm is adopted to integrate them. First, we use two units in loess hilly gully topography as test areas to construct models and validate their effects. Second, we take 1 : 10 000 DEM as the reference data to construct the corrected ASTER GDEM elevation model, the corrected SRTM1 elevation model and the integrated elevation model of ASTER GDEM and SRTM1 by RProp neural network algorithm. Meanwhile, the integrated elevation model of ASTER GDEM and SRTM1 is created with back propagation (BP) neural network. Then, the optimized effects of elevation precision of these models are analyzed. Finally, the model integrated by RProp is tested in the validation site. Results: The results show that the model integrated by RProp is better than the corrected ASTER GDEM elevation model, the corrected SRTM1 elevation model, and the model integrated by BP neural network, and its elevation deviation is reduced by 6.81 m, 0.34 m, 0.19 m, respectively. Conclusions: It confirms

基金项目:国家自然科学基金(41131360,41871324)。

第一作者:张丽,硕士,主要研究方向为数字地形建模。2919090165@qq.com

通讯作者:董有福,博士,副教授。dyf@njtech.edu.cn

that the model integrated by RProp has good applicability and error correction effect.

**Key words:** error model; data integration; resilient backpropagation neural network; deep learning

先进星载热发射和反射辐射仪全球数字高程模型 (advanced spaceborne thermal emission and reflection radiometer global digital elevation model, ASTER GDEM) 和航天飞机雷达地形测绘任务 (shuttle radar topography mission, SRTM) 数据是可免费获取的全球  $30\text{ m} \times 30\text{ m}$  数字高程模型 (digital elevation model, DEM) 数据, 在地学相关领域具有广泛应用<sup>[1-3]</sup>。广大学者对二者精度特征进行了大量研究。在误差规律方面,有学者发现 ASTER GDEM 和 SRTM 高程误差具有区域差异性<sup>[4-6]</sup>;在影响因素方面,相关研究表明,在相同位置,SRTM 误差和 ASTER GDEM 误差与坡度、坡向、地形位置指数 (topographic position index, TPI)、森林覆盖率等因子的相关程度不同<sup>[7-9]</sup>,一些学者通过加权平均<sup>[10]</sup>、傅里叶变换<sup>[11]</sup>、小波分析<sup>[12]</sup>等方法融合 SRTM 与 ASTER GDEM 以提升 DEM 精度,还有学者尝试引入反向传播(back propagation, BP) 神经网络<sup>[13-14]</sup>和深度置信网络<sup>[15]</sup>等机器学习方法来实现多源 DEM 数据的空间融合,取得了较好效果。

综上所述,将 ASTER GDEM 和 SRTM 融合起来可以提升高程精度,传统数据融合算法在挖掘非线性数据信息方面存在不足,而且训练速度慢,易陷入局部极小点,从而影响了高程优化精度。弹性反馈(resilient backpropagation, RProp)神经网络算法具有训练速度快、自适应性好的特点,能更好地寻求全局最优解<sup>[16]</sup>。因此,本文通过应用 RProp 神经网络算法构建 SRTM 与 ASTER GDEM 高程融合模型,以提升 DEM 精度,并对高程融合效果进行分析验证。

## 1 数据及其预处理

### 1.1 实验样区

本文选取了两个地貌类型相同的黄土丘陵沟壑区进行实验,分别用于高程融合模型建立和模型效果检验,建模区与验证区的平均坡度分别为  $29^\circ$ 、 $31^\circ$ ,沟壑密度分别为  $6.52\text{ km/km}^2$ 、 $6.78\text{ km/km}^2$ ,实验样区地形参考 DEM 晕染图见图 1,建模区和验证区均是西南部地势偏高。

### 1.2 实验数据

本文实验数据源主要包括 4 种类型:(1)  $30\text{ m}$  分辨率的 ASTER GDEM,坐标系为 1984 年世界

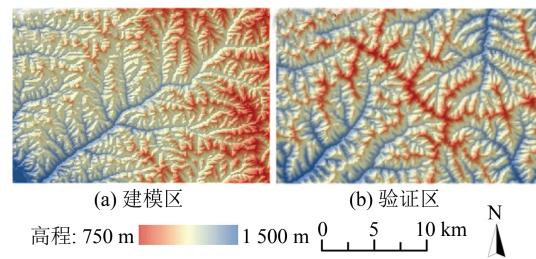


图 1 DEM 样区晕染图  
Fig.1 Shaded Relief Maps of Sample Sites

大地坐标系(world geodetic system 1984, WGS84),高程基准为地球重力模型(earth gravitational model 1996, EGM96),平面精度为  $\pm 30\text{ m}$ ,高程精度为  $\pm 20\text{ m}$ <sup>[17]</sup>;(2) 1 弧秒 SRTM(分辨率约  $30\text{ m}$ ),以下简称 SRTM1, SRTM 另一种数据产品分辨率为 3 弧秒,以下简称 SRTM3,二者坐标系和高程基准与 ASTER GDEM 的相同<sup>[18]</sup>,本文选择与 ASTER GDEM 分辨率相同的 SRTM1 构建高程融合模型,其平面精度为  $\pm 20\text{ m}$ ,高程精度为  $\pm 16\text{ m}$ <sup>[8]</sup>;(3) 参考高程基准为中国 1:10 000 基本比例尺 DEM,分辨率为  $5\text{ m}$ ,采用 1980 国家大地坐标系和 1985 国家高程基准,平坦区域高程精度为  $4\text{ m}$ ,丘陵山区高程精度为  $7\text{ m}$ <sup>[19]</sup>;(4) 2001 年和 2010 年的 MODIS 影像分别用于获取 SRTM1 和 ASTER GDEM 森林覆盖率。

前人研究表明,坡度与坡向两种基本地形参数和森林覆盖率对 ASTER GDEM 和 SRTM1 高程误差具有显著影响。TPI 是中心点高程值减去周围高程的平均值,反映了高程点在局部范围内的相对位置关系;地形耐用指数(terrain ruggedness index, TRI)是中心点高程与周围高程差的平均值,反映了局部地形异质性程度<sup>[20]</sup>。实验表明,二者与 ASTER GDEM 和 SRTM1 高程误差同样具有强相关性<sup>[21]</sup>。因此,本文选取上述 5 种因子作为变量来构建神经网络高程融合回归模型。

### 1.3 数据预处理

为保证上述不同类型的数据源能够有效融合,要对其分辨率、坐标系和高程基准进行空间匹配处理:(1) 将 1:10 000 DEM 数据转换到 WGS84 坐标系,同时将分辨率重采样为  $30\text{ m}$ ;(2) 由于中国境内 EGM96 与 1985 国家高程基准偏差均值约  $0.35\text{ m}$ ,且偏差值具有从东到西、从南至北逐渐增大的变化规律,同时,考虑到两个实验区域基本位于中国的中心位置,将 1:10 000 DEM 加  $0.35\text{ m}$ ,

以消除高程基准差异<sup>[22]</sup>; (3)考虑到 1:10 000 DEM 与 ASTER GDEM 和 SRTM1 水平位置存在一定偏差, 应用全局拟合法<sup>[23]</sup>将 1:10 000 DEM 向南、向东分别平移 2 个和 3 个栅格, 使其与目标数据源在水平方向上对齐。

## 2 高程数据融合方法

### 2.1 RProp 神经网络回归算法

RProp 神经网络算法是传统误差 BP 神经网络的改进算法, 误差 BP 神经网络算法在训练过程中采用最速下降法调整网络的权值和阈值, 具有收敛速度慢、易陷入局部最小值等问题<sup>[24]</sup>。RProp 算法对上述问题进行了优化, 算法分为两步: 一是调整步长, 二是根据步长调整权重。

$$\Delta_{ij}(t) = \begin{cases} \eta^+ \Delta_{ij}^{(t-1)}, & \frac{\partial E^{t-1} \partial E^t}{\partial w_{ij} \partial w_{ij}} > 0 \\ \eta^- \Delta_{ij}^{(t-1)}, & \frac{\partial E^{t-1} \partial E^t}{\partial w_{ij} \partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{其他} \end{cases} \quad (1)$$

式中,  $\Delta_{ij}$  指权值, RProp 算法通过对  $\Delta_{ij}$  进行重新设置与更新来去除梯度对权值的影响;  $w_{ij}$  为从神经元  $i$  到神经元  $j$  的权值;  $E$  为误差函数(上标表示学习周期);  $\eta^+$  与  $\eta^-$  分别为权值更新公式中的增加因子和减小因子, 且满足  $\eta^- < 1 < \eta^+$ , 一般取  $\eta^- = 0.5$ ,  $\eta^+ = 1.2$ 。 $w_{ij}$  的梯度符号发生改变时, 就说明上一轮的更新权值选取过大, 算法会自动跳过此值, 同时减小  $\eta^-$  的值, 使更新权重  $\Delta_{ij}$  减小, 当梯度符号未改变时, 则说明更新权重比较小, 为使算法加快收敛, 通过增大  $\eta^+$  的值使更新权重增加, 直至达到所需精度, 完成算法训练学习<sup>[25]</sup>。

### 2.2 RProp 神经网络高程融合模型构建

实验流程见图 2, 首先对 ASTER GDEM 和 SRTM1 数据进行统一坐标系和分辨率等预处理; 然后提取其高程影响因素, 在建模区采用 RProp 神经网络构建 ASTER GDEM 高程校正模型、SRTM1 高程校正模型、ASTER GDEM 与 SRTM1 高程融合模型, 将其分别记为 RProp(GDEM)、RProp(SRTM1)、RProp(GDEM, SRTM1), 同时建立 BP 神经网络高程融合模型, 记为 BP(GDEM, SRTM1), 对模型高程精度优化效果进行对比, 最后用验证区数据对上述分析结果进行校验。

#### 2.2.1 样本训练集与测试集划分

考虑到建模区范围较大, 本文在建模区内以 150 m 为间距, 采样 2 440 个点, 在确保样本充足

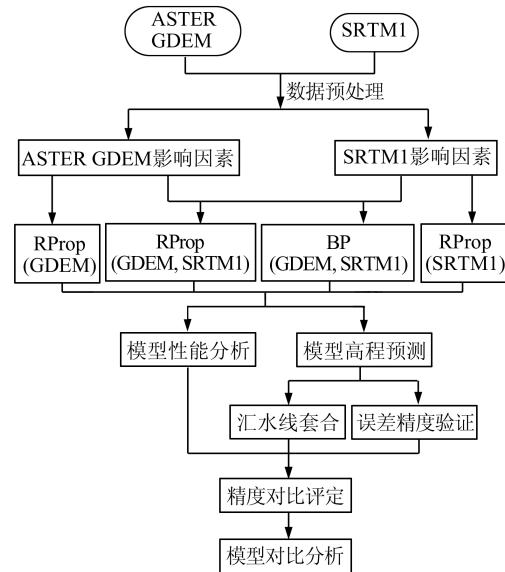


图 2 实验流程

Fig.2 Flowchart of the Experiment

条件下, 使采样点之间的高程误差自相关性达到最小, 以 70% 和 30% 的比例将样本单元划分为训练样本和测试样本。选取与 ASTER GDEM 和 SRTM1 对应的坡度、坡向、TPI、TRI 和森林覆盖率 5 个参数作为自变量, 结合原始 DEM 建立 RProp 神经网络高程融合回归模型。

#### 2.2.2 高程融合模型构建

RProp 神经网络由输入层、隐藏层和输出层 3 部分组成, 模型构建最核心的 3 个问题是激活函数、隐藏层数目及每层节点数的确定。隐含层采用最常用的对数 S 型激活函数; 多个隐藏层会提高网络精度, 但也使网络变得复杂, 增加训练时长且易出现过拟合现象, 通过多次实验得到不同隐藏层数下的模型均方根误差(root mean square error, RMSE), 以 RMSE 越小, 模型越精准为原则确定最优隐藏层个数; 隐藏层的节点数能直接影响模型性能, 且与输入输出层的节点数密切相关<sup>[26]</sup>, 因此, 可根据式(2)确定每个隐藏层节点个数:

$$m = \sqrt{n + l} + \alpha \quad (2)$$

式中,  $m$  为隐藏层节点个数;  $n$  为输入层节点个数;  $l$  为输出层节点个数;  $\alpha$  为 1~10 之间的常数。

以 ASTER GDEM 和 SRTM1 对应的坡度、坡向、TPI、TRI、森林覆盖率和原始 DEM 为输入层, 以参考 DEM 为输出层, 由于输入层为 12 个, 输出层为 1 个, 根据式(2)可得隐藏层节点数为 5~13 个, 在此范围内对每一层的节点数进行遍历寻优, 确定最佳值, 通过多次实验确定第一个隐藏层节点数为 13 个, 在设置第二个隐藏层节点时发现出现过拟合现象, 预测精度下降, 因此只

设置一个隐藏层,模型训练结构如图3所示。

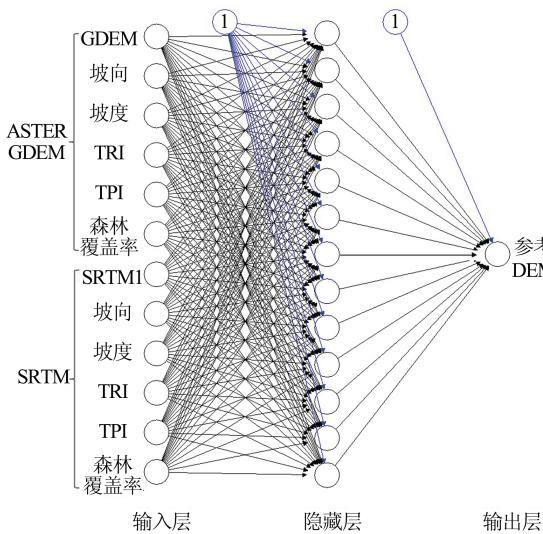


图3 RProp神经网络高程融合

Fig.3 Elevation Fusion of RProp Neural Network

### 2.2.3 模型评价

本文通过RMSE和平均绝对误差(mean absolute error, MAE)等指标来评价融合回归模型的效能。其中, RMSE的表达式为:

$$R_{\text{RMSE}} = \sqrt{\frac{1}{M} \sum_{i=1}^M (y_i - x_i)^2} \quad (3)$$

式中,  $y_i$  为样本真实值;  $x_i$  为模型预测值;  $M$  为样本总数。RMSE是衡量DEM数据精度的常用指标,描述了DEM与真实高程的离散程度。

## 3 结果分析

### 3.1 高程融合模型精度分析

#### 3.1.1 RProp神经网络融合DEM精度评估

以建模区未参与建模的30%数据为模型测试数据,1:10 000 DEM作为参考数据,由于在计算平均误差时,正负误差值抵消会影响数据评估,因此,本文选取预测值误差和原始值误差的绝对值作为比较对象。

误差分布结果如图4所示。相对于原始数据,RProp(GDEM,SRTM1)整体误差的上四分位数、中位数和下四分位数明显减小。在箱形图中,RProp(GDEM,SRTM1)与RProp(SRTM1)相比,整体误差分布变化不大,但是相较于RProp(GDEM),则有明显的优势。结合表1可以看出,RProp(GDEM,SRTM1)的RMSE、MAE整体仍优于RProp(GDEM)和RProp(SRTM1),其中, RMSE分别降低了5.81 m、0.87 m; MAE分别降低了4.42 m、0.25 m,可见RProp(GDEM,SRTM1)

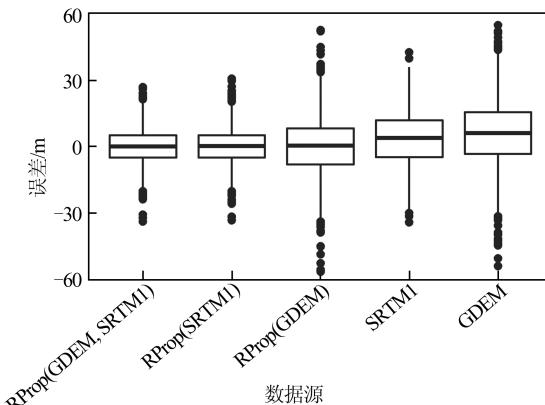


图4 高程误差分布箱形图

Fig.4 Box Plot of Elevation Errors

表1 RProp模型预测精度/m

Tab.1 Prediction Accuracy of RProp Models/m

类型	1/4分位数	3/4分位数	RMSE	MAE
GDEM	-3.26	15.47	14.63	12.48
SRTM1	-4.80	12.00	11.79	10.03
RProp(GDEM)	-8.03	8.29	13.52	10.45
RProp(SRTM1)	-4.96	5.08	8.58	6.28
RProp(GDEM, SRTM1)	0.98	-4.90	7.71	6.03

的校正效果更具优势。由此可初步证明,RProp(GDEM, SRTM1)能有效综合两种DEM的精度优势,提高了DEM精度。

#### 3.1.2 高程融合模型对比分析

为进一步验证RProp(GDEM, SRTM1)的综合性能,本文将BP(GDEM, SRTM1)与RProp(GDEM, SRTM1)进行对比。

在BP(GDEM, SRTM1)中分别引入从ASTER GDEM和SRTM1中提取的5类地形因子:坡度、坡向、TPI、TRI和森林覆盖率,分别统计RProp(GDEM, SRTM1)、BP(GDEM, SRTM1)数据与参考DEM的高程差,绘制高程误差预测频数分布图,见图5。整体上,RProp(GDEM, SRTM1)和BP(GDEM, SRTM1)的误差频率均呈现正态分布趋势,前者精度优于后者,表现为RProp(GDEM, SRTM1)误差较小的点所占比例大于BP(GDEM, SRTM1);同时,BP(GDEM, SRTM1)中误差值较大的样点所占比重更大。

表2展示了RProp(GDEM, SRTM1)与BP(GDEM, SRTM1)的高程误差统计结果。相较于BP(GDEM, SRTM1),RProp(GDEM, SRTM1)误差最大值和最小值分别减小了1.64 m、0.34 m; RMSE和MAE分别减小了0.61 m、0.44 m。综合来看,RProp(GDEM, SRTM1)对ASTER GDEM和SRTM1的精度提升效果更明显,克服了BP神

经网络模型数据易陷入局部最小值的缺点。

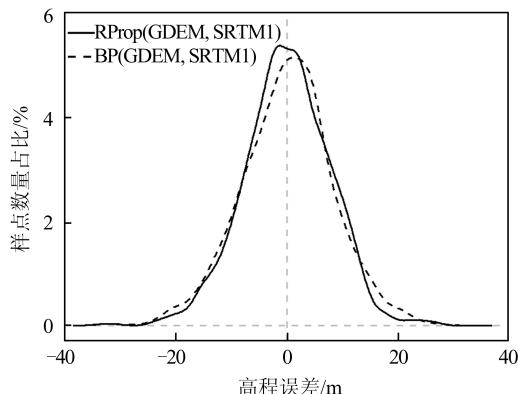


图 5 高程误差频数分布

Fig.5 Frequency Distribution of Elevation Errors

### 3.2 高程融合模型效果验证

#### 3.2.1 数值误差验证

将验证区数据代入 RProp(GDEM, SRTM1)、RProp(GDEM)、RProp(SRTM1)与 BP(GDEM, SRTM1), 以 1:10 000 DEM 为参考数据, 得到误差频数分布趋势, 见图 6。验证区地形复杂, SRTM1

受地形影响较大。地形越复杂, DEM 精度越低, 所以 SRTM1 的精度低于 ASTER GDEM 的精度。从图 6 中可以发现: 虽然 BP 神经网络模型能够优化原始 DEM 数据, 但是效果比 RProp 神经网络模型差; 单数据源模型的高程总体精度相较于原始数据有显著提升, 其中 SRTM1 优化效果最佳, 但是和 RProp(GDEM, SRTM1)的误差频数分布更具优势。结合表 3 分析得出:(1)RProp(GDEM, SRTM1)的 RMSE、MAE 分别为 9.04 m、7.27 m, 与 GDEM、SRTM1 相比, 其 RMSE 分别降低了 7.32 m、4.10 m, MAE 分别降低了 5.55 m、3.55 m;(2) RProp(GDEM, SRTM1) 与 RProp(GDEM)、RProp(SRTM1)相比, 最小值分别减少了 27.05 m、0.64 m; 最大值分别减少了 35.74 m、6.18 m;(3) RProp(GDEM, SRTM1) 与 BP(GDEM, SRTM1)相比, RMSE 减少了 0.19 m。可见 RProp(GDEM, SRTM1)不仅克服了单数据源模型中的系统性误差和粗差, 还比 BP(GDEM, SRTM1)更具优势。

表 2 RProp(GDEM, SRTM1)和 BP(GDEM, SRTM1)分析结果/m  
Tab.2 Analysis Results of RProp(GDEM, SRTM1) and BP(GDEM, SRTM1)/m

模型	<i>t</i>		<i>p</i>		最小值	最大值	MAE	RMSE
	GDEM	SRTM1	GDEM	SRTM1				
RProp(GDEM, SRTM1)	26.83	23.60	$<2.2 \times 10^{-16}$	$<2.2 \times 10^{-16}$	-33.92	26.92	6.03	7.71
BP(GDEM, SRTM1)	25.87	22.18	$<2.2 \times 10^{-16}$	$<2.2 \times 10^{-16}$	-34.26	28.56	6.47	8.32
差值	0.96	1.42	0	0	0.34	-1.64	-0.44	-0.61

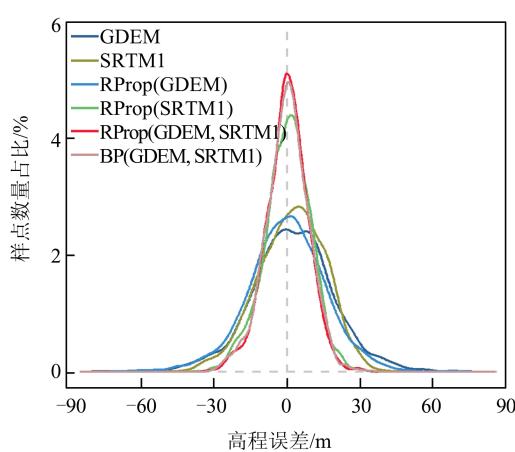


图 6 RProp 高程误差频数分布图

Fig.6 Frequency Distribution of RProp Elevation Errors

#### 3.2.2 汇水线套合验证

汇水线是重要的地形骨架线, 其结构形态可用来检验 DEM 融合模型的地形表达效果。对 RProp(GDEM)、RProp(SRTM1)、RProp(GDEM, SRTM1)、BP(GDEM, SRTM1)及参考 DEM 的汇水线进行提取, 叠加效果见图 7, 可以得出如下结论: (1) 虽然 RProp(GDEM)、RProp(GDEM,

SRTM1)与参考 DEM 汇水线整体走向一致, 但在河流交汇处, RProp(GDEM, SRTM1)与参考 DEM 汇水线的交叉点更接近, RProp(GDEM)汇水线明显向右偏移(A 处); (2) 与 RProp(SRTM1)汇水线相比, RProp(GDEM, SRTM1)汇水线位置和走向与参考 DEM 水系更接近(B 处); (3) 与 BP(GDEM, SRTM1)汇水线相比, RProp(GDEM, SRTM1)可以模拟出更多的河流分支细节, 与参考 DEM 水系形态结构更相似(C 处)。

## 4 结语

本文以黄土丘陵沟壑地貌为例, 引入 RProp 神经网络算法, 通过构建 RProp(GDEM, SRTM1)、RProp(GDEM)、RProp(SRTM1)高程模型对 DEM 精度进行优化, 并与 BP(GDEM, SRTM1)进行对比, 验证 RProp 神经网络高程融合模型的适宜性。

(1) 与 RProp(GDEM)、RProp(SRTM1)相比, RProp(GDEM, SRTM1)高程 RMSE 分别降低

表3 验证区RProp与BP神经网络模型比较结果/m

Tab.3 Comparison of Results Obtained by RProp and BP Neural Network Models in the Verification Area/m

模型	最小值	1/4分位数	中位数	MAE	3/4分位数	最大值	RMSE
GDEM	-69.69	-7.11	2.80	12.82	12.90	75.57	16.36
SRTM1	-38.83	-5.59	3.10	10.82	11.91	40.99	13.14
RProp(GDEM)	-54.58	-9.57	0.86	12.36	10.38	64.61	15.85
RProp(SRTM1)	-28.17	-5.35	1.09	7.37	6.77	35.05	9.38
RProp(GDEM,SRTM1)	-27.53	-5.97	0.31	7.27	6.72	28.87	9.04
BP(GDEM,SRTM1)	-29.58	-5.75	0.40	7.35	6.83	31.65	9.23

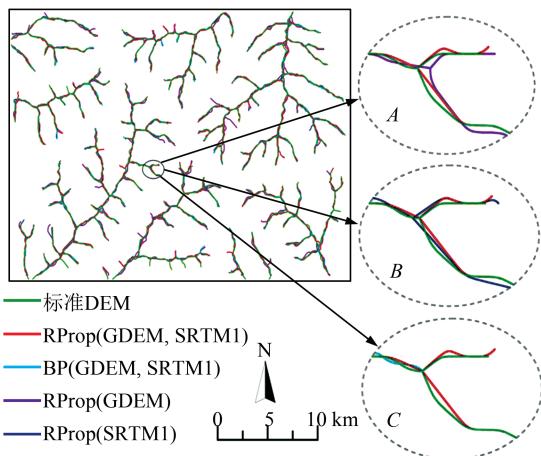


图7 验证区汇水线套合图

Fig.7 Overlay Diagram of Catchment Lines in the Verification Area

6.81 m 和 0.34 m, 高程精度提升效果更好; 与 BP (GDEM, SRTM1) 相比, RProp(GDEM, SRTM1) 高程 RMSE 减少了 0.19 m, 高程精度融合效果更具优势。

2) 由汇水线套合法结果可知, 与 RProp (GDEM)、RProp(SRTM1)、BP(GDEM, SRTM1) 相比, RProp(GDEM, SRTM1) 生成的河网与参考 DEM 水系形态结构重叠度更高。

应用 RProp 神经网络构建的 ASTER GDEM 和 SRTM1 高程融合模型具有良好的适宜性, 高程误差校正效果明显。但本文仅对常见的丘陵沟壑区进行了融合实验, 不同地貌类型区高程融合效果有待进一步研究。

## 参 考 文 献

- [1] Tang Guoan. Progress of DEM and Digital Terrain Analysis in China [J]. *Acta Geographica Sinica*, 2014, 69(9): 1305-1325. (汤国安. 我国数字高程模型与数字地形分析研究进展[J]. 地理学报, 2014, 69(9): 1305-1325.)
- [2] Gou Jiaojiao, Wang Fei, Luo Mingliang, et al. Fractal Characteristics of Channel Junctions (CJs) Based on DEM [J]. *Journal of Soil and Water Conservation*, 2016, 30(3): 109-114. (苟娇娇, 王飞, 罗明良, 等. 基于 DEM 的黄土高原沟谷节点分形特征研究[J]. 水土保持学报, 2016, 30(3): 109-114.)
- [3] Chen Jiabing, Li Hui, Chen Wenhui, et al. Auto-classification of Geomorphological Types Based on DLG and DEM for Fujian Province [J]. *Journal of Geo-Information Science*, 2013, 15(1): 75-80. (陈加兵, 李慧, 陈文惠, 等. 基于 DEM 与 DLG 的福建省地貌形态自动分类[J]. 地球信息科学学报, 2013, 15(1): 75-80.)
- [4] Guan Xiaorong. Spatial Distribution of SRTM DEM and ASTER GDEM Error [D]. Nanjing: Nanjing Normal University, 2017. (关小荣. SRTM DEM 和 ASTER GDEM 误差的空间分布特征[D]. 南京: 南京师范大学, 2017.)
- [5] Zhang Quan, Yang Qinke, Cheng Jie, et al. Characteristics of 3" SRTM Errors in China [J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(5): 684-690. (张泉, 杨勤科, 程洁, 等. 中国地区 3" SRTM 高程误差特征[J]. 武汉大学学报(信息科学版), 2018, 43(5): 684-690.)
- [6] Sun G, Ranson K J, Kimes D S, et al. Forest Vertical Structure from GLAS: An Evaluation Using LVIS and SRTM Data [J]. *Remote Sensing of Environment*, 2008, 112(1): 107-117.
- [7] Hu Z H, Peng J W, Hou Y L, et al. Evaluation of Recently Released Open Global Digital Elevation Models of Hubei, China [J]. *Remote Sensing*, 2017, 9(3): 262.
- [8] Zhang Q, Yang Q K, Wang C M. SRTM Error Distribution and Its Associations with Landscapes Across China [J]. *Photogrammetric Engineering & Remote Sensing*, 2016, 82(2): 135-148.
- [9] Hu Jiapei, Guan Xiaorong, Liu Xuejun. Spatial Distribution of SRTM DEM and ASTER GDEM Error in China [J]. *Geography and Geo-Information Science*, 2017, 33(4): 28-33. (胡加佩, 关小荣, 刘学军. 中国区域 SRTM DEM 与 ASTER GDEM 误差空间分布特征[J]. 地理与地理信息科

- 学, 2017, 33(4): 28-33.)
- [10] Pham H T, Marshall L, Johnson F, et al. A Method for Combining SRTM DEM and ASTER GDEM2 to Improve Topography Estimation in Regions Without Reference Data [J]. *Remote Sensing of Environment*, 2018, 210: 229-241.
- [11] Chen Chuanfa, Zheng Zuoya, Yue Tianxiang. Efficient Fusion of ASTER and SRTM Based on Fast Fourier Transform [J]. *Remote Sensing for Land & Resources*, 2010, 22(4): 19-22. (陈传法, 郑作亚, 岳天祥. 基于快速傅里叶变换的ASTER与SRTM有效融合研究[J]. 国土资源遥感, 2010, 22(4): 19-22.)
- [12] Sun Liang, Yan Wei, Liu Pingzhi, et al. Data Fusion of SRTM DEM and ASTER DEM Based on Wavelet Analysis [J]. *Journal of Geomatics Science and Technology*, 2014, 31(4): 388-392. (孙亮, 严薇, 刘平芝, 等. 采用小波分析的SRTM DEM与ASTER DEM数据融合[J]. 测绘科学技术学报, 2014, 31(4): 388-392.)
- [13] Shen Huanfeng, Liu Lu, Yue Linwei, et al. A Multi-source DEM Fusion Method Based on Elevation Difference Fitting Neural Network [J]. *Acta Geodaetica et Cartographica Sinica*, 2018, 47(6): 854-863. (沈焕峰, 刘露, 岳林蔚, 等. 多源DEM融合的高差拟合神经网络方法[J]. 测绘学报, 2018, 47(6): 854-863.)
- [14] Yue Linwei. Research on DEM Fusion Blending Multi-source and Multi-scale Elevation Data [D]. Wuhan: Wuhan University, 2017. (岳林蔚. 多源多尺度DEM数据融合方法与应用研究[D]. 武汉: 武汉大学, 2017.)
- [15] Yue Linwei, Liu Xiuguo, Shen Huanfeng, et al. A Deep Belief Network Based Multi-source DEM Fusion Model [J]. *Geomatics and Information Science of Wuhan University*, 2021, 46(7): 1090-1097. (岳林蔚, 刘修国, 沈焕峰, 等. 基于深度置信网络的多源DEM点面融合模型[J]. 武汉大学学报(信息科学版), 2021, 46(7): 1090-1097.)
- [16] Riedmiller M, Braun H. A Direct Adaptive Method for Faster Backpropagation Learning: The RProp Algorithm [C]//IEEE International Conference on Neural Networks, San Francisco, USA, 2002.
- [17] Suwandana E, Kawamura K, Sakuno Y, et al. Thematic Information Content Assessment of the ASTER GDEM: A Case Study of Watershed Delineation in West Java, Indonesia [J]. *Remote Sensing Letters*, 2012, 3(5): 423-432.
- [18] Wang Ling. Brief Introduction of Radar Topographic Mapping Mission of US Space Shuttle [J]. *Bulletin of Surveying and Mapping*, 2000(12): 38-40. (汪凌. 美国航天飞机雷达地形测绘使命简介[J]. 测绘通报, 2000(12): 38-40.)
- [19] Ma Yanci, Ming Yanfang, Wang Kai, et al. Precision Evaluation of GlobeLand30 Products Based on High-Resolution Artificial Identification Land Type [J]. *Journal of Shandong University of Science and Technology (Natural Science)*, 2018, 37(5): 1-10. (马延慈, 明艳芳, 王凯, 等. 基于高分辨率人工识别地表类型的GlobeLand30产品精度评价[J]. 山东科技大学学报(自然科学版), 2018, 37(5): 1-10.)
- [20] Tran T A, Raghavan V, Masumoto S, et al. A Geomorphology-based Approach for Digital Elevation Model Fusion—Case Study in Danang City, Vietnam [J]. *Earth Surface Dynamics*, 2014, 2(2): 403-417.
- [21] Dong Y F, Shortridge A M. A Regional ASTER GDEM Error Model for the Chinese Loess Plateau [J]. *International Journal of Remote Sensing*, 2019, 40(3): 1048-1065.
- [22] Guo Hairong, Jiao Wenhui, Yang Yuanxi. The Systematic Difference and Its Distribution Between the 1985 National Height Datum and the Global Quasigeoid [J]. *Acta Geodaetica et Cartographic Sinica*, 2004, 33(2): 100-104. (郭海荣, 焦文海, 杨元喜. 1985国家高程基准与全球似大地水准面之间的系统差及其分布规律[J]. 测绘学报, 2004, 33(2): 100-104.)
- [23] Shortridge A, Messina J. Spatial Structure and Landscape Associations of SRTM Error [J]. *Remote Sensing of Environment*, 2011, 115(6): 1576-1587.
- [24] Sarkar D. Methods to Speed up Error Back-Propagation Learning Algorithm [J]. *ACM Computing Surveys*, 1995, 27(4): 519-544.
- [25] Cao Haidi. Fault Analysis of Transmission Line Based on RProp Neural Network [D]. Huainan: Anhui University of Science & Technology, 2017. (曹海迪. 基于RPROP神经网络的输电线路故障分析研究[D]. 淮南: 安徽理工大学, 2017.)
- [26] Li Weihong, Wen Lei, Chen Yebin. Property Crime Forecast Based on Improved GA-BP Neural Network Model [J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(8): 1110-1116. (李卫红, 闻磊, 陈业滨. 改进的GA-BP神经网络模型在财产犯罪预测中的应用[J]. 武汉大学学报(信息科学版), 2017, 42(8): 1110-1116.)