

doi: 10.6046/gtzyyg.2020.04.19

引用格式: 杜方洲, 石玉立, 盛夏. 基于深度学习的 TRMM 降水产品降尺度研究——以中国东北地区为例[J]. 国土资源遥感, 2020, 32(4): 145–153. (Du F Z, Shi Y L, Sheng X. Research on downscaling of TRMM precipitation products based on deep learning: Exemplified by northeast China [J]. Remote Sensing for Land and Resources, 2020, 32(4): 145–153.)

基于深度学习的 TRMM 降水产品降尺度研究

——以中国东北地区为例

杜方洲, 石玉立, 盛夏

(南京信息工程大学遥感与测绘工程学院, 南京 210044)

摘要: 降水的季节性时空分布研究对东北地区的生态保护和农业生产有重要意义。基于植被指数、地形因子与降水的相关性, 采用深度学习模型, 对 2009—2018 年 10 a 间平均 1, 4, 7, 10 月 TRMM_3B43 产品降尺度至 0.01° (约 1 km), 使用站点实测数据进行精度校正, 并填补 TRMM 未覆盖的 50°N 以上地区。结果表明, 该模型效果优于随机森林, 可有效获得各季节较高空间分辨率与精度的研究区域降水分布, 校正后全局决定系数 R^2 介于 0.881 ~ 0.952 之间, 均方根误差介于 1.222 ~ 13.11 mm 之间, 平均相对误差介于 7.425% ~ 28.41% 之间, 其中 4 月和 10 月份拟合度较好, 1 月和 7 月份相对稍差。

关键词: TRMM; 东北地区; NDVI; 深度学习

中图法分类号: TP 79 **文献标志码:** A **文章编号:** 1001-070X(2020)04-0145-09

0 引言

降水对土壤湿度、作物生长和区域径流等均有重要影响^[1-4]。东北地区是我国最主要的天然林分布区之一, 动植物资源丰富^[5], 也是我国重要的农牧业和商品粮基地, 粮食产量占全国总量的 1/3 左右^[6], 降水变化势必对东北地区植被生长及农作物生长有重要影响^[7]。因此, 降水时空分布研究对东北地区的农业生产有重要意义。传统观测降水的方法是通过气象站中的雨量计来记录当地的降水量, 这种方法在小范围内精度高, 但受限于地形等因素, 某些偏远地区站点稀少, 导致观测数据稀缺。而基于遥感卫星获取的降水产品具有覆盖范围大、不受地形限制、连续观测时间长等特点, 能在一定程度上弥补站点观测法的不足。

热带降雨测量任务卫星 (Tropical Rainfall Measurement Mission, TRMM) 是由美国国家航空航天局和日本航空航天局联合研制的, 旨在记录全球降水以进行气候研究, 具有覆盖范围广、时效性好等优势^[8-9]。然而在降水和地形复杂地区进行研究时, TRMM 产品的空间分辨率 (0.25° × 0.25°) 不能满足

要求, 需要对其进行降尺度以提升空间分辨率。目前国内外常用的 TRMM 降尺度方法是基于降水相关因子构建降尺度模型, 蔡明勇等^[10]以雅鲁藏布江为研究区域, 构建复杂地形下的 TRMM 产品多元线性回归降尺度模型; Shi 等^[11]使用增强型植被指数 (enhanced vegetation index, EVI) 和其他地形因子构建青藏高原地区随机森林 (random forest, RF) 降尺度模型; 徐彬仁等^[12]基于 RF 算法, 构建 TRMM 产品与归一化植被指数 (normalized difference vegetation index, NDVI) 和地形因子的降尺度模型, 最终得到青藏高原 8 km 分辨率降尺度降水结果; 刘小婵等^[13]构建东北地区年尺度 TRMM 产品 GWR 降尺度模型, 并与全局 OLS 回归模型进行对比。随着计算机性能的不断突破和人工智能的兴起, 深度学习 (deep learning) 在各研究领域得到广泛应用^[14]。相比传统神经网络, 深度学习拥有更多的神经网络层数, 具备更强的学习能力和更有效的训练机制, 模型的层次结构仅连接在相邻层神经元之间, 同层和跨层神经元则不相互连接, 因此可以模仿人脑高效、准确的表示信息^[15]。目前, 深度学习多应用于图像识别、计算机视觉等领域^[16], 在遥感建模方面还鲜有应用。

收稿日期: 2020-01-02; 修订日期: 2020-03-15

基金项目: 国家自然科学基金项目“异速增长和资源限制模型结合多源遥感数据估算森林地上生物量研究”(编号: 41471312)资助。

第一作者: 杜方洲 (1996-), 男, 硕士研究生, 主要从事遥感反演、3S 集成等研究。Email: dufangzhou0101@163.com。

通信作者: 石玉立 (1973-), 男, 博士, 教授, 主要从事降水、机器学习等研究。Email: ylishi@nuist.edu.cn。

综上所述,目前国内对 TRMM 产品的降尺度研究是以构建传统机器学习算法模型为主,鲜有使用深度学习构建模型,模型时间尺度大多为年尺度,缺少季节性降水研究,因 TRMM 卫星扫描范围的限制,50°N 以上地区没有卫星数据覆盖,因此这部分区域少有研究。本文以东北地区为研究区,基于植被指数和地理因子,以 1,4,7,10 月代表不同季节,构建 TRMM 产品深度学习降尺度模型,并与 RF 模型进行比较,而后以站点实测降水数据作为依据,计算模型在全局和 TRMM 未覆盖地区的精度,并校正模型预测结果,最终得到东北地区各季节降尺度降水分布。

1 研究区概况与数据源

1.1 研究区概况

研究区为中国东北地区,经度范围 E97° ~ 135°,纬度范围 N37° ~ 54°,行政边界包括黑龙江省、吉林省、辽宁省和内蒙古自治区东五盟(锡林郭勒盟、兴安盟、呼伦贝尔市、赤峰市、通辽市),不包括辽宁省周边岛屿,总面积约 145 万 km²。地势起伏较大,海拔高度整体自西向东降低。地形复杂多变,主要地形包括高原、山地、丘陵、台地和平原。辽宁省地处欧亚大陆东岸,属于温带季风气候,四季分明,是东北地区降水最多的省份;吉林省、黑龙江省和内蒙古自治区东五盟属于温带大陆性季风气候,其中大兴安岭北段地区属于寒温带大陆性季风气候,冬季长,夏季短,降水主要集中在夏季。

1.2 数据源

本文使用的研究资料包括:TRMM3B43_V7 产品、MOD13A3 NDVI 产品、数字高程模型(digital elevation model, DEM)、气象站点数据,所有数据地理范围为(E97° ~ 135°, N37° ~ 54°),时间跨度为 2009—2018 年,选取 1,4,7 和 10 月这 4 个月份分别代表冬、春、夏、秋 4 个季节,目的是研究降尺度模型的季节适用性。

TRMM3B43_V7 降水产品下载于美国国家航空航天局降水测量计划网站(<https://www.pmm.nasa.gov/>),覆盖边界为纬度 N50° ~ S50°,经度 E180° ~ W180°,时间分辨率为月,空间分辨率为 0.25° × 0.25°,原始数据单位是 mm/h,针对不同月份进行预处理后得到完整月降水。NDVI 数据获取于美国国家航空航天局官方网站(<http://www.nasa.gov/>),产品由搭载于 TERRA 卫星上的 MODIS 传感器获取,是陆地 3 级标准数据产品,计算前经过表面的双向反射率大气校正,去除水、云、重气溶胶

和云影的影响,覆盖范围为全球,时间分辨率为 30 d,空间分辨率为 1 km × 1 km。DEM 数据来源于地理空间数据云(<http://www.gscloud.cn/>),空间分辨率为 30 m × 30 m。气象站点数据源于中国气象数据网(<http://data.cma.cn/>)提供的中国地面气候资料月值数据集,研究区内共有 102 个原始站点,经质量控制,筛选得到 92 个站点(图 1),分别计算各站点 1,4,7 和 10 月份 10 a 间平均降水量,用于模型预测结果检验与校正。

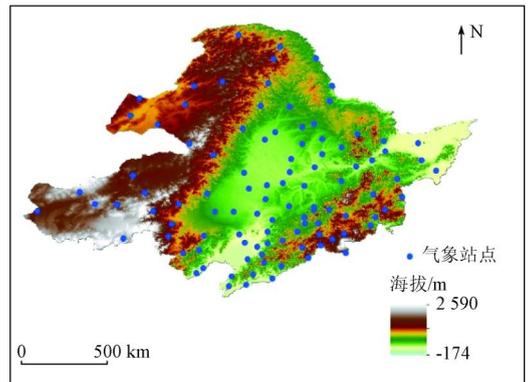


图 1 研究区地形及气象站点分布

Fig. 1 Topographic and meteorological station distribution in the study area

2 研究方法

降水是一个非常复杂的气象过程,与多个影响因素相互作用。要完成降水的降尺度工作,需要选择与降水尺度对应且相关性高的遥感因子作为输入自变量,构建与 TRMM 数据的降尺度模型,再对预测结果进行精度验证和校正。

2.1 模型构建

2.1.1 降尺度因子选择

根据以往的研究资料,研究区降水有十分明显的季节性和地域性,中部区域地势较平坦,植被分布相对密集,降水多;西北部与南部区域地形复杂,植被稀疏,降水少,且总体来看,研究区降水呈东多西少、夏多冬少的规律。降水对植被生长有非常重要的影响,二者存在着显著的相关关系^[17],因此选择 NDVI 作为构建模型的一个重要因子。同时,地形也是影响降水的重要因素,在植被稀疏的高海拔地区,地理位置对当地降水有着重要影响^[18]。综上所述,本文以 TRMM 数据为因变量,选择 NDVI、经度(LON)、纬度(LAT)、海拔(Altitude)、坡度(Slope)、坡向(Aspect)作为构建模型的自变量因子,构建以 $TRMM = f(NDVI, LON, LAT, Altitude, Slope, Aspect)$ 为形式的关系模型。主要处理步骤如下:

1)数据预处理。将所有数据裁切至研究区范围,对 DEM 数据提取经纬度、海拔、坡度和坡向因子,对 MOD13A3 产品提取 NDVI 数据。所有自变量因子分别重采样至 0.01° 和 0.25° 分辨率。其中 0.25° 分辨率的自变量因子均裁去纬度 50° 以上区域,保证在空间尺度上与 TRMM 数据匹配。

2)选择 0.25° 分辨率的自变量因子与同时空环境下的 TRMM 数据输入深度学习算法,构建各月降尺度模型。得到模型后,将各月 0.01° 分辨率的自变量因子输入,得到各月份模型预测降尺度降水。

2.1.2 模型介绍

本文使用的深度学习算法为深度前馈神经网络 (deep feedforward neural network, DFNN)^[19]。如图 2 所示,模型由输入层、隐藏层、输出层和各层之间的连接组成,其中隐藏层根据模型的复杂程度可以设计成任意数量的多层,各层之间的连接表示特征的权重。网络中的数据流向是单向的,只会按照输入层、隐藏层、输出层的顺序流动,即数据流经当前一层处理后,只会作为下一层的输入流入,而不会对上一层有任何影响和反馈。

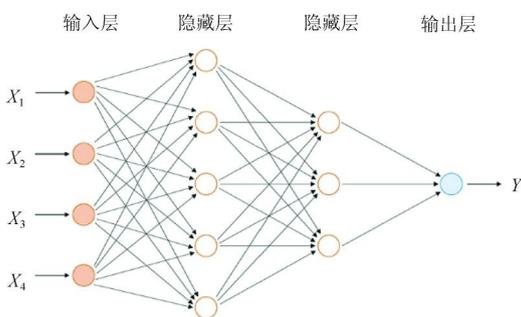


图 2 DFNN 结构示意图

Fig. 2 DFNN structure diagram

2.1.3 模型训练过程

模型具体训练过程包括:①自下而上的非监督学习。首先,使用无标定数据训练第一层,并学习第一层的参数,使生成的模型可以学习数据结构本身的特征,因此比输入数据具备更好的特征表达能力;在学习达到第 $n-1$ 层之后,将 $n-1$ 层的输出作为第 n 层的输入,并训练第 n 层,从而获得各层的参数。②自上而下的监督学习。通过使用带标签的数据进行训练,误差自上到下传播,对网络结构进行微调,并调整各层之间的权重。

算法基于 R 语言中的 h2o 包实现,可在 <http://www.h2o.ai> 中下载。模型训练及预测过程如下:①变量因子输入,将处理好的标准化 0.25° 空间分辨率自变量与因变量因子输入 DFNN 模型;②模型调参,需要通过调整模型参数以达到最好的训练效

果,主要参数包括隐藏层层数 L 、隐藏层每层神经元数量 N 和训练迭代次数 $epochs$;③降水预测,得到最优训练模型后,将 0.01° 空间分辨率的自变量因子输入训练好的模型,得到 0.01° 空间分辨率预测降水结果。

2.2 精度验证

本文使用决定系数 (R^2)、均方根误差 (root mean square error, RMSE) 和平均相对误差 (mean relative error, MRE) 来对模型预测结果进行精度判定。决定系数 R^2 用于评价模型对预测值的拟合优度,范围在 $[0, 1]$ 之间,越接近 1,表示模型模拟效果越好,预测值越接近实测值;RMSE 用于衡量预测值与站点实测值之间的偏差,RMSE 值越小,偏差越小,代表模型精度越高;MRE 用于反映预测值的可信程度,MRE 值越小,预测值可信度越高。各判定指标公式如下:

$$R^2 = 1 - \frac{SS_{\text{residual}}}{SS_{\text{total}}}, \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_{\text{station},i} - P_{\text{predict},i})^2}, \quad (2)$$

$$MRE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{P_{\text{station},i} - P_{\text{predict},i}}{P_{\text{station},i}} \right|, \quad (3)$$

式中: $P_{\text{station},i}$ 和 $P_{\text{predict},i}$ 分别为站点实测值和预测值; SS_{residual} 表示站点实测值与预测值差的平方之和; SS_{total} 为总方差; n 为样本数量。

2.3 结果校正

本文使用气象站点实测数据验证 TRMM 降水与降尺度降水的精度并进行对比。将站点随机均匀分为校正站点和验证站点,计算校正站点数据与降尺度数据的差值,基于 ArcGIS 软件平台进行插值运算,得到覆盖研究区的面状差值图,对降尺度降水进行校正,再用验证站点验证校正精度,最终得到校正后的研究区各月降尺度降水。

文中使用的插值方法是反距离权重插值法 (inverse distance weighted, IDW),原理是以插值点与样本点间的距离为权重进行加权平均,因此距离插值点越近的样本点被赋予的权重越大。

3 分析与讨论

3.1 模型参数调优

通过调整隐藏层层数 L 、神经元数量 N 和迭代次数 $epochs$,得到模型训练集和测试集的决定系数 R^2 和 RMSE,根据数据集大小和经验知识,设置神经元数量 N 为 400,表 1 为不同参数模型收敛情况。

表 1 模型参数调整结果

Tab. 1 Model parameter adjustment results

L	N	epochs	训练集		测试集	
			R^2	RMSE /mm	R^2	RMSE /mm
4	400	150	0.866	1.402	0.850	1.423
4	400	200	0.868	1.229	0.863	1.341
4	400	250	0.874	1.221	0.869	1.310
5	400	150	0.900	1.109	0.891	1.146
5	400	200	0.911	0.995	0.901	1.054
5	400	250	0.899	1.098	0.893	1.152
6	400	150	0.889	1.173	0.885	1.261
6	400	200	0.915	0.947	0.894	1.079
6	400	250	0.898	1.097	0.892	1.149
...

结果表明,当测试集出现最大的 R^2 和最小的 $RMSE$ 时,测试集的 R^2 和 $RMSE$ 并不是最优值,盲目追求测试集评价系数的最小化可能会导致模型过拟合,造成测试集效果不佳,因此需要同时评估训练集和测试集的系数。本文最终选择输入参数为:隐藏层层数 $L = 5$, 神经元数量 $N = 400$, 迭代次数 $epochs = 200$ 。

3.2 降尺度结果与精度检验

图 3 是降尺度前后研究区各月份降水空间分布对比,可以看出,降尺度后的图像空间分辨率相较于原

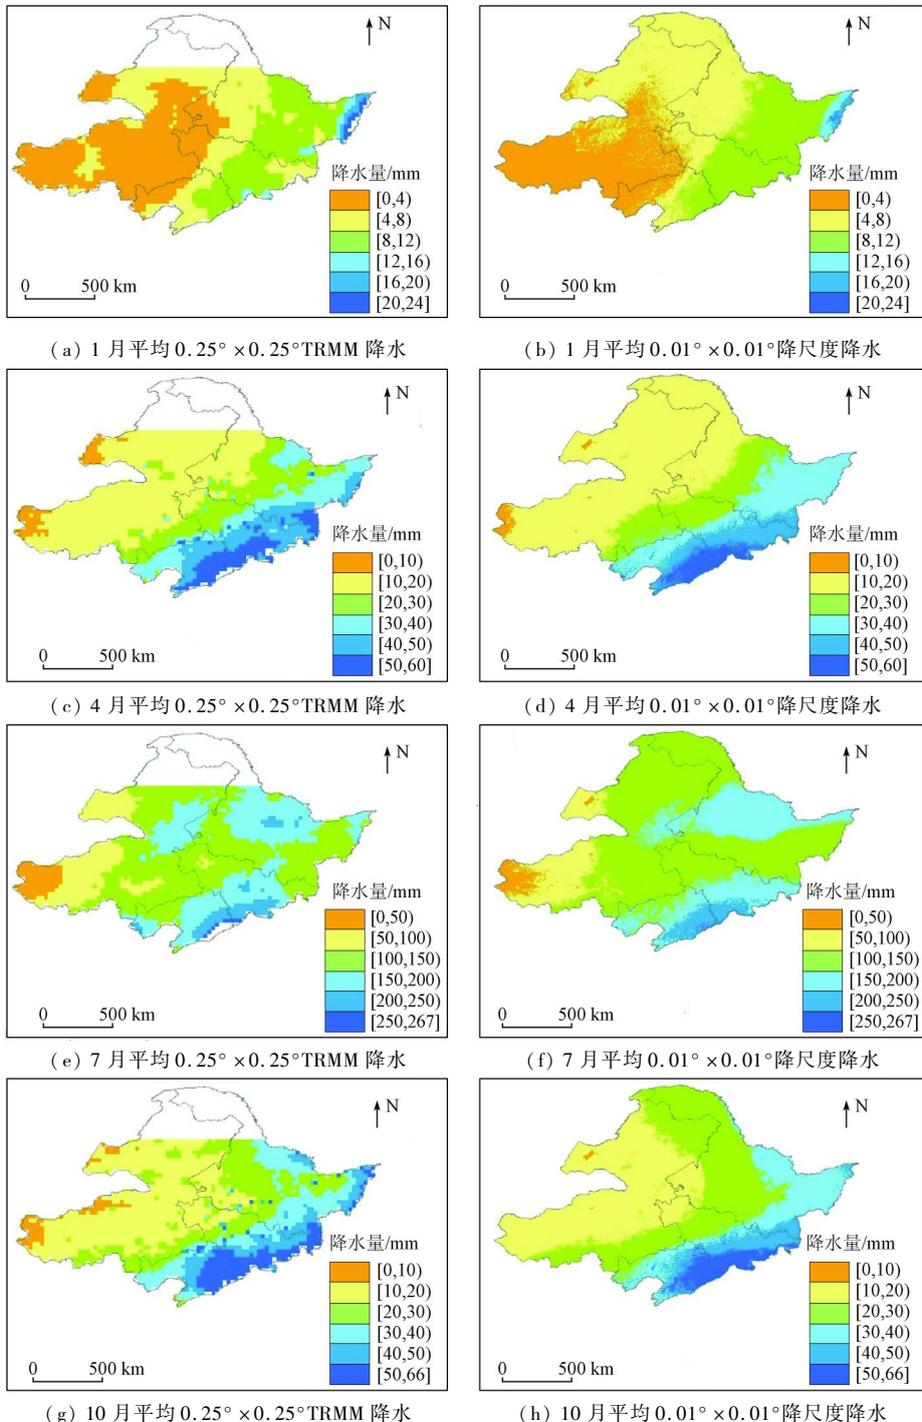


图 3 2009—2018 年 10 a 平均 1,4,7,10 月 $0.25^\circ \times 0.25^\circ$ TRMM 降水与 $0.01^\circ \times 0.01^\circ$ 降尺度降水对比
Fig. 3 Comparison of $0.25^\circ \times 0.25^\circ$ TRMM precipitation with $0.01^\circ \times 0.01^\circ$ downscale precipitation during 2009—2018

始 TRMM 图像有了明显的提升,降尺度前后空间分布一致性较高,对不同等级的降水量都有很好的还原效果。但空间分辨率提高不代表精度的提升,为进一步验证降尺度精度,本文使用研究区内站点实测数据对降尺度数据进行精度检验,计算降尺度前后评价指标 R^2 , $RMSE$ 和 MRE , 分别验证研究区全局预测降水量和 TRMM 未覆盖地区 (50°N 以上) 预测降水量的精度。

3.2.1 研究区全局结果精度验证

由图 4 可知,深度学习模型预测的降尺度降水量与实测降水量之间存在显著的线性相关关系,相比原始 TRMM 产品更接近实测降水量,说明深度学习降尺度模型有较高的拟合度。降尺度前后精度对比如表 2 所示,降尺度降水量的决定系数 R^2 在各月份都不同程度高于 TRMM 降水量,降尺度前 R^2 在 $0.784 \sim 0.879$ 之间,降尺度后 R^2 在 $0.817 \sim 0.935$

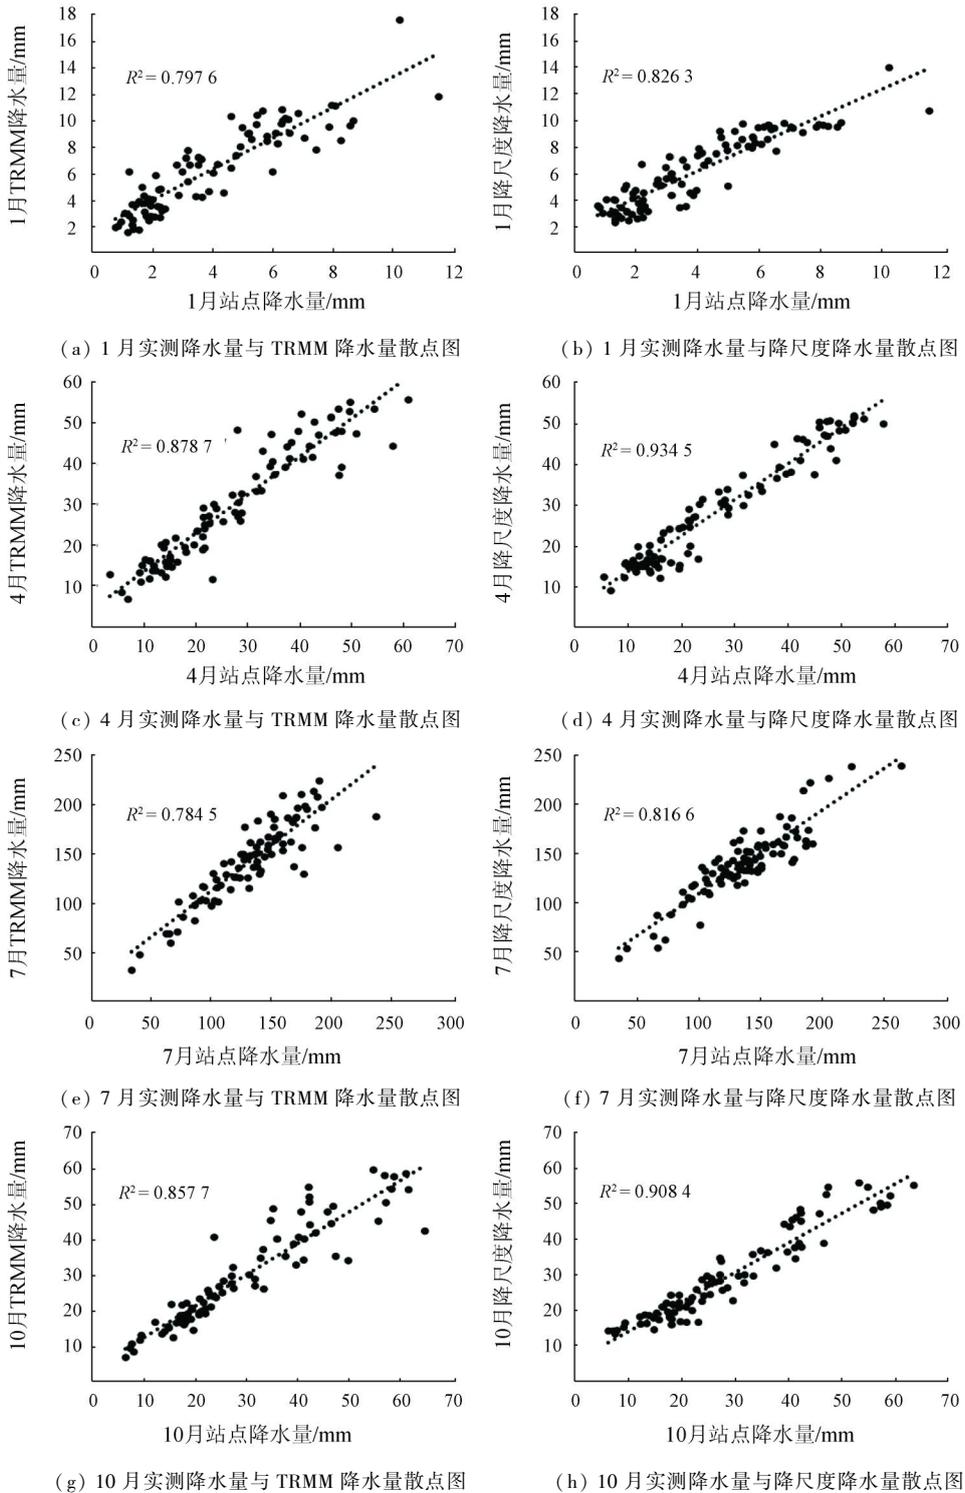


图4 各月份站点实测降水量分别与 TRMM 降水量和降尺度降水量的散点图

Fig. 4 Scatter plots of the station's measured precipitation with TRMM precipitation and downscale precipitation

表 2 降尺度前后精度对比
Tab. 2 Comparison of accuracy before and after downscaling

月份	R^2		$RMSE / mm$		$MRE / \%$	
	降尺度前	降尺度后	降尺度前	降尺度后	降尺度前	降尺度后
1 月	0.798	0.826	2.819	2.503	79.76	71.31
4 月	0.879	0.935	5.608	4.161	20.92	19.42
7 月	0.784	0.817	20.960	16.870	12.37	11.08
10 月	0.858	0.908	5.649	4.398	13.43	10.28

之间,其中 4 月和 7 月的 R^2 提升较大。降尺度前, $RMSE$ 介于 2.819 ~ 20.960 mm 之间, MRE 介于 12.37% ~ 79.76% 之间,经过降尺度操作后,预测降水量与实测降水量的误差得到有效降低,预测精度得到了提升。 $RMSE$ 降低至 2.503 ~ 16.870 mm, MRE 降至 10.28% ~ 71.31%,各月均有不同程度的降低。这是因为站点实测数据仅记录以站点为中心区域的降水,数据描述范围有限,而经降尺度操作后的降水空间分辨率由 0.25°(约 26 km)提升至 0.01°(约 1 km),这与实际站点的描述范围更加匹配,因此降尺度降水量与实际降水量的拟合度和精度更高。

总体来看,深度学习降尺度模型不仅可以很大程度提高降水产品的空间分辨率,同时也降低了与实测降水量数据的误差,比 TRMM 降水产品精度更高。其中 4 月和 10 月降尺度效果较好,1 月和 7 月效果相对稍差,原因是 1 月份部分地区以降雪为主^[20],且分布极其不均匀,导致植被因子在模型中的贡献度较低,降水量与经纬度等地理因子相关性更高;7 月份实际降水情况复杂多变,多小尺度对流降雨,而 TRMM 产品分辨率相对较粗,不能很好地捕捉复杂降水变化,因而导致这 2 个月份模型模拟效果相对稍差。

3.2.2 TRMM 未覆盖地区预测精度检验

本文从东北地区已有站点中筛选出 50°N 以上地区气象站点共 8 个,计算精度评价指标,结果如表 3 所示。1—10 月间,决定系数 R^2 呈增大趋势,4, 7,10 月份的模拟精度相对较好,1 月份最差。这是因为 1 月份植被与降水量的相关性较低,且该部分地区降水的形式主要是降雪,TRMM 产品只记录降水,因此该地区 1 月份模型拟合效果较差,其他季节

表 3 TRMM 未覆盖地区预测精度验证

Tab. 3 TRMM data uncovered area prediction accuracy verification

月份	R^2	$RMSE / mm$	$MRE / \%$
1 月	0.324	2.813	54.130
4 月	0.556	3.331	19.220
7 月	0.653	10.580	6.315
10 月	0.800	2.251	29.730

因降水增多,模型拟合度相对较好,但由于站点数量的限制,精度较东北地区全局要低。

3.3 模型对比分析

前人在 TRMM 产品降尺度研究中,多用 RF 算法进行模型构建。为对比模型精度,本文同样使用 RF 算法进行降尺度模型构建,并与深度学习降尺度模型对比。2 种降尺度模型评价指标对比如表 4 所示,总体上来看,深度学习降尺度模型效果要好于 RF 模型效果。深度学习模型的决定系数 R^2 各月份均不同程度上高于 RF 模型,同时,深度学习模型的 $RMSE$ 和 MRE 也都低于同月份 RF 模型,说明深度学习算法能够更好地挖掘出输入特征因子与降水量的相关性,提升了模型拟合效果,预测出的降尺度降水精度更高。

表 4 基于 RF 与基于深度学习降尺度模型精度指标评价

Tab. 4 Precision evaluation between RF and DFNN

月份	R^2		$RMSE / mm$		$MRE / \%$	
	RF	DFNN	RF	DFNN	RF	DFNN
1 月	0.787	0.826	2.561	2.503	77.79	71.31
4 月	0.893	0.935	5.438	4.161	20.26	19.42
7 月	0.809	0.817	18.94	16.870	13.66	11.08
10 月	0.892	0.908	4.935	4.398	11.99	10.28

3.4 降尺度结果校正

为提升精度,得到更加接近实测降水量的降尺度降水,需要基于地面实测降水量对模型预测的降尺度降水进行校正,本文从研究区内 92 个气象站点中随机均匀选取 60%(约 55 个)用于校正,剩余 40%用于验证校正效果,计算验证站点数据与校正前后降尺度数据的精度评价系数,结果如表 5 所示。

表 5 各月降尺度结果校正前后精度指标

Tab. 5 Accuracy index before and after monthly downscaling results correction

月份	R^2		$RMSE / mm$		$MRE / \%$	
	校正前	校正后	校正前	校正后	校正前	校正后
1 月	0.833	0.881	2.413	1.222	70.86	28.410
4 月	0.939	0.952	4.297	3.508	20.41	9.473
7 月	0.825	0.891	16.460	13.110	11.66	7.555
10 月	0.924	0.932	4.474	3.301	10.34	7.425

从表 5 中可以看出,通过地面站点实测数据校正,各月预测降水量的决定系数 R^2 均有提升, $RMSE$ 和 MRE 都有所降低,说明经过校正的降尺度降水与实测值的误差更小,精度更高,更接近真实降水。图 5 为各月校正后的降水空间分布。

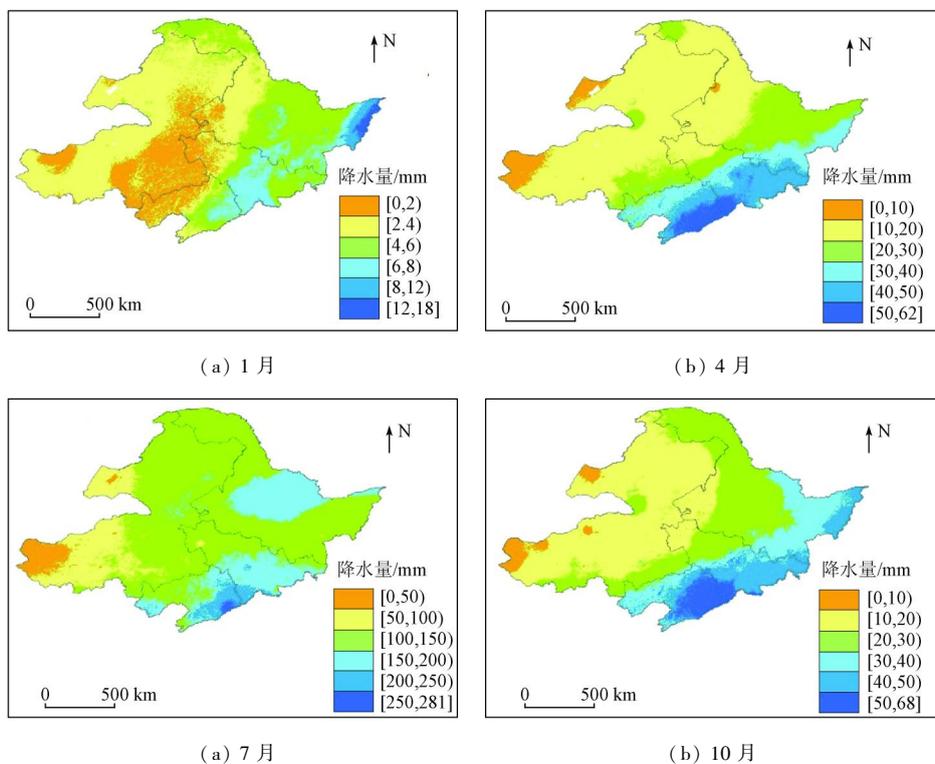


图 5 站点校正后的 1,4,7,10 月 $0.01^{\circ} \times 0.01^{\circ}$ 降尺度降水空间分布

Fig. 5 Spatial distribution of precipitation downscaled by $0.01^{\circ} \times 0.01^{\circ}$ in Jan., Apr., Jul., and Oct. after station correction

整体来看,受东亚冬季风和西太平洋副热带高压的影响^[21],研究区域各月份降水空间分布极其不均匀,其中夏季降水多,冬季降水少。降水量整体呈由西北方向往东南方向递增的变化趋势。

4 结论

本文研究东北地区季节性降水分布,基于降水和植被指数以及地理因子的相关性,使用 TRMM_3B43 月降水数据、MOD13A3 NDVI 数据、DEM 数据和气象站点数据,采用深度学习算法构建 TRMM 产品降尺度模型,将 TRMM 产品空间分辨率由 0.25° (约 26 km) 提升至 0.01° (约 1 km),并填补 TRMM 卫星原始数据未覆盖的 50°N 以上地区,再以实测站点数据对降尺度结果进行精度分析与校正。主要结论如下:

1) 基于深度学习的降尺度模型能够很好地完成 TRMM 产品的降尺度,有效提高了 TRMM 产品的空间分辨率和精度,模型适用性和估算精度优于随机森林模型,各月决定系数 R^2 均在 0.88 以上。校正后的降尺度降水结果能够更准确地反映研究区域内的降水空间分布,表明模型在东北地区有较好的实用性。

2) 模型预测精度有季节性差异,4 月和 10 月模

拟效果较好,1 月和 7 月相对稍差。主要原因是研究区冬季降雪和降水时空分布不均导致植被指数与降水量的相关性较低,夏季多小范围对流降雨导致 TRMM 卫星捕捉降水能力变差。

此外,模型在 TRMM 未覆盖地区的季节性偏差仍较大,后续研究可以考虑加入其他相关因子,如地表温度、水汽等,以进一步提升模型预测效果。

参考文献 (References):

- [1] Wang Q, Wang M, Fan X, et al. Trends of temperature and precipitation extremes in the Loess Plateau Region of China, 1961—2010 [J]. Theoretical and Applied Climatology, 2017, 129 (3): 949 - 963.
- [2] Xu C, Luo Y, Xu Y. Projected changes of precipitation extremes in river basins over China [J]. Quaternary International, 2011, 244 (2): 149 - 158.
- [3] Yu S, Xia J, Yan Z, et al. Changing spring phenology dates in the three - rivers headwater region of the Tibetan Plateau during 1960—2013 [J]. Advances in Atmospheric Sciences, 2018, 35 (1): 116 - 126.
- [4] Huang L, Liu J, Shao Q, et al. Changing inland lakes responding to climate warming in Northeastern Tibetan Plateau [J]. Climatic Change, 2011, 109 (3): 479 - 502.
- [5] 蒲真, 张芳玲, 古元阳, 等. 我国东北地区自然植被保护现状及保护优先区分析 [J]. 生态学杂志, 2019, 38 (9): 2821 - 2832.

Pu Z, Zhang F L, Gu Y Y, et al. Conservation status and priority

- conservation areas of natural vegetation in northeast China [J]. Chinese Journal of Ecology, 2019, 38(9): 2821–2832.
- [6] 赵秀兰. 近 50 年中国东北地区气候变化对农业的影响[J]. 东北农业大学学报, 2010, 41(9): 144–149.
Zhao X L. Influence of climate change on agriculture in northeast China in recent 50 years [J]. Journal of Northeast Agricultural University, 2010, 41(9): 144–149.
- [7] 房世波, 韩国军, 张新时, 等. 气候变化对农业生产的影响及其适应[J]. 气象科技进展, 2011, 1(2): 15–19.
Fang S B, Han G J, Zhang X S, et al. Climate change affects crop production and its adaptation [J]. Advances in Meteorological Science and Technology, 2011, 1(2): 15–19.
- [8] 朱红雷, 史晓亮, 李英臣, 等. 基于 SWAT 模型的 TRMM 降水数据径流模拟适宜性评价[J]. 水土保持研究, 2017, 24(5): 105–112.
Zhu H L, Shi X L, Li Y C, et al. Evaluation of runoff simulation using TRMM precipitation data based on SWAT model [J]. Research of Soil and Water Conservation, 2017, 24(5): 105–112.
- [9] 卢新玉, 魏 鸣, 王秀琴, 等. TRMM-3B43 降水产品在新疆地区的适用性研究[J]. 国土资源遥感, 2016, 28(3): 166–173. doi:10.6046/gtzyyg.2016.03.26.
Lu X Y, Wei M, Wang X Q, et al. Applicability research on TRMM-3B43 precipitation over Xinjiang [J]. Remote Sensing for Land and Resources, 2016, 28(3): 166–173. doi:10.6046/gtzyyg.2016.03.26.
- [10] 蔡明勇, 吕 洋, 杨胜天, 等. 雅鲁藏布江流域 TRMM 降水数据降尺度研究[J]. 北京师范大学学报(自然科学版), 2017, 53(1): 111–119.
Cai M Y, Lyu Y, Yang S T, et al. TRMM precipitation downscaling in the data scarce Yarlung Zangbo River Basin [J]. Journal of Beijing Normal University (Natural Science), 2017, 53(1): 111–119.
- [11] Shi Y, Song L, Xia Z, et al. Mapping annual precipitation across mainland China in the period 2001–2010 from TRMM3B43 product using spatial downscaling approach [J]. Remote Sensing, 2015, 7(5): 5849–5878.
- [12] 徐彬仁, 魏瑗瑗. 基于随机森林算法对青藏高原 TRMM 降水数据进行空间统计降尺度研究[J]. 国土资源遥感, 2018, 30(3): 181–188. doi:10.6046/gtzyyg.2018.03.25.
Xu B R, Wei Y Y. Spatial statistics of TRMM precipitation in the Tibetan Plateau using random forest algorithm [J]. Remote Sensing for Land and Resources, 2018, 30(3): 181–188. doi:10.6046/gtzyyg.2018.03.25.
- [13] 刘小婵, 张洪岩, 赵建军, 等. 东北地区 TRMM 数据降尺度的 GWR 模型分析[J]. 地球信息科学学报, 2015, 17(9): 1055–1062.
Liu X C, Zhang H Y, Zhao J J, et al. Spatial downscaling of TRMM precipitation data based on GWR model in northeast China [J]. Journal of Geo-Information Science, 2015, 17(9): 1055–1062.
- [14] Lecun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436–444.
- [15] Montavon G, Samek W, Müller K R. Methods for interpreting and understanding deep neural networks [J]. Digital Signal Processing, 2017, 73: 1–15.
- [16] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527–1554.
- [17] Ezzine H, Bouziane A, Ouazar D, et al. Sensitivity of NDVI-based spatial downscaling technique of coarse precipitation to some mediterranean bioclimatic stages [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(9): 1518–1521.
- [18] Jia S, Zhu W, Lyu A, et al. A statistical spatial downscaling algorithm of TRMM precipitation based on NDVI and DEM in the Qaidam Basin of China [J]. Remote Sensing of Environment, 2011, 115(12): 3069–3079.
- [19] Zhang D, Zhang W, Huang W, et al. Upscaling of surface soil moisture using a deep learning model with VIIRS RDR [J]. ISPRS International Journal of Geo-Information, 2017, 6(5): 130–139.
- [20] 邹旭东, 张飞民, 王澄海, 等. 我国东北地区冬季降水和东亚冬季风的关系研究[J]. 冰川冻土, 2013, 35(6): 1454–1461.
Zou X D, Zhang F M, Wang C H, et al. The relationship between winter precipitation and eastern Asian winter monsoon in northeast China [J]. Journal of Glaciology and Geocryology, 2013, 35(6): 1454–1461.
- [21] 梁 丰, 刘丹丹, 王婉昭, 等. 1961—2013 年东北地区夏季降水变化趋势分析[J]. 水土保持研究, 2015, 22(5): 67–73.
Liang F, Liu D D, Wang W Z, et al. Analysis on the trend of variation of summer precipitation in northeast China during the period from 1961–2013 [J]. Research of Soil and Water Conservation, 2015, 22(5): 67–73.

Research on downscaling of TRMM precipitation products based on deep learning: Exemplified by northeast China

DU Fangzhou, SHI Yuli, SHENG Xia

(School of Remote Sensing and Geomatics Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: The research on the seasonal spatial and temporal distribution of precipitation is of great significance to the ecological protection and agricultural production in northeast China. Based on the correlation between vegetation index, topographical factors and precipitation, this paper utilizes deep learning models to downscale TRMM_3B43 products to 0.01° (about 1 km) in January, April, July, and October during 2009–2018, and uses site measured

data to make accuracy correction and fill areas above 50° N which are not covered by TRMM. The results show that the model is better than random forest and can effectively obtain the precipitation distribution in the study area with higher spatial resolution and accuracy in each season. The corrected global determination coefficient R^2 is between 0.881 and 0.952, the root mean square error (RMSE) is between 1.222 mm and 13.11 mm, and the mean relative error (MRE) is between 7.425% and 28.41%, among which the fitting degree is good in April and October, and relatively poor in January and July.

Keywords: TRMM; northeast China; NDVI; deep learning

(责任编辑: 李瑜)