

基于生成对抗网络模型的 SMAPL4 土壤水分产品降尺度分析

杨 赓^{1,2}, 杨明龙^{1,2}, 李国柱³, 夏永华^{1,2}, 严正飞^{1,2}, 李万涛^{1,2}

(1.昆明理工大学国土资源工程学院, 云南 昆明 650093; 2.云南省高校高原山区空间信息测绘技术
应用工程研究中心, 云南 昆明 650093; 3.云南海钜地理信息技术有限公司, 云南 昆明 650000)

摘 要:土壤水分是地表和大气水热过程交换的重要纽带,对于农业生产以及优化种植结构具有重要意义, NASA 卫星下的 SMAPL4 是一种以被动微波遥感技术为手段对土壤湿度监测的产品,具有可穿透云层和全天候监测能力,但其较低空间分辨率很难满足小尺度或小区域范围的的实际研究需求。鉴于此,根据云南省姚安县高原灌区特殊的地理位置,引用相关系数推演出与研究区土壤水分空间分布有关的解释变量,沿用随机森林算法,耦合 1 km 包含地表温度和归一化植被指数的 MODIS 地表产品,建立基于 RF 全局窗口线性回归的 1 km 级被动微波土壤水分空间降尺度模型;而后堆叠地表温度(LST)、归一化植被指数(NDVI)、降水量(Prec)、地表蒸散量(ET)等 4 个变量形成条件生成对抗网络框架,并使用均方误差(RMSE)和条件生成对抗性损失函数训练神经网络来建立低分辨率和高分辨率映射关系,随即获得降尺度后土壤水分空间分布结果;最后将实际采样和监测站点提供数据做空间平均聚合后,与 SMAPL4 原始结果的 CGAN、RF 降尺度结果进行对比分析。结果表明:LST、NDVI、Prec、ET 与土壤水分的相关性均值均大于 0.44,具有相关关系,条件生成对抗网络降尺度结果对指标 R^2 和 $Bias$ 表现效果最好,均值分别为 0.7 和 0.032;RF 降尺度结果对 RMSE 的效果最好,均值为 0.006。同比 SMAPL4 原始数据,RF 结果空间分布更为平滑,但极值差异性较大;CGAN 结果能有效表征土壤含水空间分布状况,其数据变异性及极值表征能力更为突出。经 RMSE 与对抗性损失函数训练后,认为 0.2~0.28 的值域分布为降尺度后的研究区土壤水分数值分布结果。

关键词:土壤水分;SMAP;随机森林算法;生成对抗网络;降尺度分析

中图分类号:S127 **文献标志码:**A

Downscaling analysis of SMAPL4 soil moisture products based on generative adversarial network models

YANG Zhen^{1,2}, YANG Minglong^{1,2}, LI Guozhu³, XIA Yonghua^{1,2}, YAN Zhengfei^{1,2}, LI Wantao^{1,2}

(1. School of Land and Resources Engineering, Kunming University of Science and Technology, Kunming, Yunnan 650093, China;

2. Application Engineering Research Center of Spatial Information Surveying and Mapping Technology in
Plateau and Mountainous Areas Set by Universities in Yunnan Province, Kunming, Yunnan 650093, China;

3. Yunnan Haiju Geographic Information Technology Co., Ltd, Kunming, Yunnan 650000, China)

Abstract: Soil moisture is an important link in the exchange of water and heat processes between the surface and the atmosphere, which is of great significance for agricultural production and optimization of planting structure. SMAPL4 under NASA satellite is a passive microwave remote sensing technology as a means of monitoring soil moisture, with the ability to penetrate the clouds, all-weather monitoring. However, due to its low spatial resolution, it is difficult to meet the practical research needs at small scale or small area scale. In view of this, according to the special geographic location of the plateau irrigation area in Yaoan County, Yunnan Province, the correlation coefficients were quoted to derive the explanatory variables related to the spatial distribution of soil moisture in the study area, and along the random forest algorithm, the coupled 1 km MODIS surface products containing surface tempera-

收稿日期:2023-11-11

修回日期:2024-01-22

基金项目:国家自然科学基金项目(62266026)

作者简介:杨赓(1998-),男,云南普洱人,硕士研究生,研究方向为遥感图像处理、土壤墒情监测。E-mail:2274257590@qq.com

通信作者:杨明龙(1982-),男,贵州岑巩人,副教授,主要从事 3S 集成应用、三维激光扫描技术、自然资源管理研究。E-mail:20130051@

kust.edu.cn

ture and normalized vegetation index were used to establish a spatially descaled model of 1 km passive microwave soil moisture based on the linear regression of the RF global window, and then the four variables of surface temperature (LST), normalized vegetation index (NDVI), precipitation (Prec), and surface evapotranspiration (ET) were stacked to form a conditional generative adversarial network framework, and the neural network was trained using the mean squared error (*RMSE*) and the conditional generative adversarial loss function to establish the low-resolution and high-resolution mapping relationship, and then the results of the spatial distribution of soil moisture were obtained after the downscaling. In addition, the spatially averaged aggregated data from actual sampling and monitoring stations were compared and analyzed with the downscaled CGAN and RF results of the original SMAPL4 results. The results showed that the mean value of the correlation between LST, NDVI, Prec, ET and soil moisture was more than 0.44, which was correlated. The downscaling results of the conditional generation adversarial network (CGAN) had the best effect on the indicators R^2 and *Bias*, with the mean values of 0.7 and 0.032, respectively. The downscaling results of RF had the best effect on the *RMSE*, with the mean value of 0.006. Compared with the original data of SMAPL4, the spatial distribution of the RF results was better than that of the original data of SMAPL4, and the RF results had the best effect on the *RMSE* raw data, the RF results had a smoother spatial distribution, but the polar value variability was larger. The CGAN results effectively characterized the spatial distribution of soil water content, and its data variability and polar value characterization ability was more prominent. After the training of *RMSE* and adversarial loss function, the value range of 0.2~0.28 was considered as the numerical distribution of soil moisture in the study area after downscaling.

Keywords: soil moisture; SMAP; random forest algorithm; generative adversarial networks; scale reduction analysis

土壤水分是用以表示一定深度的土壤干湿程度的物理量^[1],主要是指地面以下、潜水面以上土层中的含水量与所占干土重量的比值。作为影响大气和地球表面水分交换的关键指标,土壤水分状况直接控制着地球生态环境气候变化和水循环,根据土壤湿度这一重要参量,直接反映了气候和环境的变化,对监测农作物种植结构、灌溉管理、水资源管理和环境保护等具有深远意义。

当前通常采用称重或者探针测量直接接触的方法来测定局部区域土壤水分含量,此方法不适用于大规模区域墒情监测^[2]。遥感具有多时效、成本低、非接触性等特点,逐渐成为区域土壤水分时空变化的监测手段。遥感影像及卫星产品反演土壤水分的研究已经在国内外得到了广泛关注和研究。基于光学遥感选用 Landsat8 卫星对比垂直干旱指数、改进的垂直干旱指数、温度植被干旱指数 3 个指数与站点土壤水分间相关性^[3],分析区域的土壤水分变化规律,但是受到云、大气状况因素的影响,基于主动微波遥感通过 SAR 影像分析 VV/VH 同极化、交叉极化的后向散射系数建立与土壤水分函数关系式,具备全天候的工作能力^[4-5]。然而主动微波遥感土壤水分产品容易受到地貌因素和植被覆盖等因素影响^[6],被动微波遥感是监测大尺度范围内土壤水分较为成熟的技术手段,其工作原理为辐

射计探测地物在微波波段的亮度温度,并利用亮度温度反演土壤水分^[7]。但是由被动微波遥感反演出的土壤水分产品的空间分辨率大致在千米以上,难以满足局部区域土壤墒情监测和作物种植结构规划,针对土壤水分产品降尺度成为当下研究的热点^[8]。经验性、半经验性和基于物理机理模型是被动微波遥感土壤水分产品降尺度的主流方法^[9],以地表温度(LST)、数字高程模型(DEM)、增强型修改土壤植被指数(Enhanced Modified Soil-Adjusted Vegetation Index, EMSAVI)等作为降尺度因子的经验模型方法,构建了干旱区土壤水分降尺度模型^[10]。Lei 等^[11]利用改进的水云模型对高度覆盖植被区土壤水分含量的遥感定量反演提供了参考。Wakjari 等^[12]用 SMAPL3 数据替换 HYDROTEL 模型中 RHHV,获得降尺度后的区域局部土壤水分情况,基于物理机理的关系模型能准确表达降尺因子和土壤水分之间的机制,提出了一种基于广度深度学习的土壤水分降尺度框架^[13],能够表征 DNN 模型与土壤水分之间复杂非线性关系,因此越来越多的研究人员采用生成对抗网络(Generative Adversarial Network, GAN)方法来提高降尺度方法的性能^[14]。

本研究以高原山地云南省姚安县蜻蜒河流域灌区为研究区,借鉴一种深度神经网络(Deep Neural Net-

work,DNN)降尺度为超分辨率影像(Super-resolution Image,SRI)思路,由于生成对抗网络捕捉低分辨率影像梯度变化和空间模式表现良好^[15],利用生成对抗网络集成时序期间的地表温度(LST)、植被覆盖指数(NDVI)、降水(Prec)、地表蒸散(ET)等 4 个低分辨率影像集作为变量,用于对大尺度、粗分辨率的微波遥感土壤水分产品 SMAPL4 进行降尺度,并对比随机森林算法的土壤水分空间降尺后结果,SMAPL4 原产品和实测样本空间聚合结果精度,构建和探索新模型对于 SMAP 产品降尺度的合理性和适用性,实现高时空分辨率土壤水分的补充和完善,为高原山地灌区用水灌水制度提供数据支撑。

1 研究区概况和数据集

1.1 研究区概况

本研究选取云南省中部高原山地姚安部分区域为研究对象(100°56′~101°34′E,25°27′~25°39′N),如图 1(见 251 页)所示,该地东、西两面为群山环绕,中间平畴广川,形成滇中典型的高原盆地,蜻蛉河由南向北从坝子中央流过,种植业较为发达,有“滇中粮仓”之美誉。冬春干旱,夏秋阴雨,属于北亚热带冬干夏湿季风气候区,降水充沛,热量资源充足,加之海拔差距较大提供了复杂的植被类型以及作物种植结构,为该区域展开土壤水分量进行降尺度工作提供有利条件。

1.2 数据集

1.2.1 SMAPL4 土壤表层湿度数据 SMAPL4(Soil Moisture Active and Passive level-4)土壤湿度产品包括表层土壤湿度(0~10 cm 垂直平均值)、根区土壤湿度(0~100 cm 垂直平均值)。该产品通过使用一维集合卡尔曼滤波器同化方法^[16]将卫星衍生的土壤水分主、被动观测结果集成到修改后的土壤模型中生成的数据集,其空间分辨率为 9 km×9 km,由于 NDVI、LST 能较好表征地表状态,因此本研究选择土壤水分产品表层土壤湿度数据(0~10 cm)用以降尺度研究,筛选 2023 年 7—8 月份的影像通过时间聚合后进行研究。

1.2.2 ERA5-Land 全球气候数据 ERA5-Land 是通过反演 ECMWF ERA5 气候再分析的陆地部分而产生,利用物理模型将数据与来自世界各地的观测结果结合成全球完整且一致的数据集。ERA5-Land 最终运行产品可以在全球范围内提供更准确的估计时间序列,空间分辨率为 0.1°×0.1°,时间分辨率为逐小时。本研究选取 ERA5DAILY 提供的日均降水数据集“total_precipitation_sum”和日均潜在蒸散

量数据集“potential_evaporation_sum”作为降尺度对象,重采样至 9 km×9 km^[17],选择同时序影像确保降尺度方法的可行性。

1.2.3 归一化植被指数(NDVI)和地表温度(LST)数据 NDVI 是作物成长的重要指标且与土壤水分量呈正相关,LST 作为影响地表蒸散量的因素之一,对土壤水分量呈负向关系^[18],因此以 NDVI、LST 变量为代表的直接相关性将用以 SMAP L4 产品降尺度的研究中。本研究中,NDVI 和 LST 来自 MOD13A2/Terra16 天植被指数和 MOD11A1/Terra 每日地表温度,其空间分辨率均为 1 km×1 km,筛选时序相同的影像并重采样至 9 km×9 km 用以降尺度研究(表 1)^[19]。

表 1 降尺度所需数据源信息

Table 1 Data source information required for downscaling					
数据类型 Data type	数据来源 Data source	空间分辨率 Spatial resolution	范围 Scope	单位 Unit	
土壤水分产品 SM	NASA SMAP L4	9 km×9 km	[0,0.9]	%	
降水数据集 Prec	ERA5-Land	0.1°×0.1°	[0,0.4]	m	
蒸散数据集 ET	ERA5-Land	0.1°×0.1°	[0,1200]	mm	
归一化植被指数 NDVI	MOD13A2/ Terra 16d	1 km×1 km	[-2000,10000]		
地表温度 LST	MOD11A1/ Terra 16d	1 km×1 km	[7000,65535]	K	

1.2.4 土壤水分样本数据 3 个监测站点(JC1、JC2、JC3)数据由云南省水利水电科学研究院提供,采用频域反射原理:仪器发射一定频率的电磁波,探针检测传输到底部后返回,检测探头输出的电压,由输出电压和水分的关系则可计算出土壤的含水量,并以每小时间隔提供数据。31 个土壤表层(0~10 cm)样本点由云南省高校高原山地空间信息测绘技术应用工程研究中心采集与检测,本研究选取采样范围内最北(NP)、最南(SP)、最东(EP)、最西(WP)四向 4 点和 3 个监测站点(JC1、JC2、JC3)用于验证降尺度结果可靠性。

2 研究方法

2.1 解释变量选择

在土壤水分降尺度过程中,往往选取与决定土壤水分变化最相关的因子作为解释变量,影响土壤水分的因子有很多,比如地表反射,植被覆盖状况等状况,研究区处于高原盆地区域,地势平坦,因此暂不考虑坡度、坡向因素。本研究对 LST、NDVI、

Prec、ET 数据集时间平均聚合为 3 小时级时间分辨率,空间平均聚合为 9 km 级空间分辨率等预处理后,将从整体和样本两个角度分析地表温度、植被覆盖,降雨、土壤表层蒸散对土壤水分的相关性。

2.2 随机森林模型

随机森林(Random Forest, RF)是采用 Bagging 方法^[20]为每棵决策树生成独立的同分布训练样本集,最终的分类结果取决于所有决策树的一种机器学习的方法,是基于决策树的集成算法对样本进行训练并预测。随机森林对于异常的数据和噪声具有较好的鲁棒性,对于多元数据反应具有良好的耦合性。因此本研究采用 Google Earth Engine 中的“smileRandomForest”功能,以土壤水分作为因变量,将选取的 NDVI、LST 为解释变量,解释变量集与土壤水分量训练出的映射关系构成了随机森林降尺度模型。

RF 全局窗口线性回归降尺度模型构建的具体步骤如下^[21]:首先将解释变量的影像下采样为 9 km,在 9 km 空间分辨率下训练 SMAP 土壤水分数据和 NDVI、LST 作为降尺度模型;得到 SMAP 土壤水分与 RF 模型做差得到 9 km 的残差项,经双线性插值重采样至 1 km 后,将 1 km 级分辨率的解释变量数据输入到训练好的降尺度模型,得到高空间分辨率 1 km 的未经残差校正的土壤湿度值;最后叠加残差项获得 1 km 降尺度结果^[22]。

2.3 生成对抗网络模型

生成对抗网络(Generative Adversarial Network, GAN)是一种由生成器(Generator)和判别器(Discriminator)构成的深度学习模型,生成器接收来自随机噪声或其他数据空间的输入,并试图生成与训练数据相似的新数据样本。判别器接收来自生成器或真实数据的输入,并尝试对其进行分类,其目标是区分生成器生成的数据与真实训练数据。

本研究将 9 km 分辨率的研究区裁剪为 9×7 网格单元,1 km 分辨率的研究区裁剪为 70×53 网格单元,选定的地表参数变量(SM、LST、NDVI、Prec、ET)堆叠形成三维张量并输入 CNN 模型,使用大小为 1×1、3×3 的内核来构建初始模块(图 2,见 251 页),以便建立低分辨率和高分辨率模拟生成土壤水之间的关系。如表 1 所示,由于土壤水分产品和其余四个变量之间的空间尺度、范围值、单位等不一致,本研究借用便于堆叠之前提取变量特征的卷积层,确保了堆叠过程中从每个变量提取的特征图具有相似特征,称此方法为 Encoded-Simple^[23]。

本研究根据土壤水分量和条件变量的输入条

件,形成条件生成对抗网络(Conditional Generative Adversarial Network, CGAN)框架,生成器和判别器的训练目标是互相对抗,通过交替优化两者的损失函数来达到平衡。目标生成器经过训练低分辨率影像的条件变量来生成高分辨率影像,这种模式会“欺骗”判别器训练出高分辨率土壤水分数据,将 CGAN 纳 Encoded-Simple 获得新模型(Encoded-CGAN)训练高辨率影像^[24],产生贴近于真实值的土壤水分数据。

2.4 评价指标

为了更好地评估所提出的降尺度方法的性能,选取相关系数(R^2)、均方根误差(RMSE)和相对偏差(Bias)评估指标用以验证降尺后结果精度,计算公式分别如式(1)~(3)所示:

$$R^2 = \frac{\sum_{i=1}^n (x_i - \bar{x}_i)(y_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^n (x_i - \bar{x}_i)^2 (y_i - \bar{y}_i)^2}} \tag{1}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \tag{2}$$

$$Bias = \frac{\sum_{i=1}^n (x_i - y_i)}{\sum_i y_i} \tag{3}$$

式中, x_i 和 $\bar{x}_i$ 分别为采样测得的含水量和均值, y_i 和 $\bar{y}_i$ 分别为降尺度结果的含水量和均值, i 为含水序列的个数, n 表示含水量对应的样本数。

3 结果与分析

3.1 地表参数与土壤水分相关性分析

图 3 为 SMAP 土壤水分产品与各个解释变量之间整体相关系数的时间序列图,可以看出 7 月间归一化植被指数和降水与土壤水分之间呈高度正相关关系,相关系数维持在 0.580 左右,土壤水分与 NDVI 的相关性逐时间递增,月相关性均值为 0.632,土壤水分与 Prec 的相关性则逐时间递减,月相关性均值为 0.527。地表温度和地表蒸散与土壤水分之间呈负相关,相关系数维持在-0.210 左右,其中 ET 与 SMAP 土壤水分月均值相关性最小(-0.228)、LST 次之(-0.198)。因此,从整体情况分析下,解释变量与 SMAP 土壤水分相关性排序表现为归一化植被指数>降水>地表温度>地表蒸散。图 4 为采样点 34 个坐标解释变量的波段值与 SMAP 土壤水分产品之间的样本相关系数,根据样本数值建立回归方程,

其中 NDVI 和 Prec 的 Pearson 相关系数分别为0.854 和 0.671、 R^2 分别为 0.730 和 0.449,LST 和 ET 的 Pearson 相关系数分别为-0.734 和-0.665、 R^2 分别为 0.539 和 0.442,NDVI 和 Prec 对于 SMAP 土壤水分产品有程度较高且相对稳定的相关性,而 LST 与 ET 呈弱相关,可能在 9 km 的空间尺度下对地表辐射的表征能不够所致。

根据 4 个变量与土壤水分进行线性拟合发现,NDVI、LST 的 R^2 均高于 0.5,是刻画 SMAP 土壤水分最佳的解释变量,Prec、ET 虽不能表征最佳的土壤水分影响因素,但降水事件和地表辐射强度却是影响下垫面土壤湿度的主要因素。因此选用 LST、NDVI、Prec、ET 作为 SMAP 土壤水分降尺度的解释变量。




图3 SMAP 土壤水分与解释变量之间整体相关系数时间序列图(2023-07)

Fig.3 Time series plot of overall correlation coefficients between SMAP soil moisture and explanatory variables in July 2023




图4 SMAP 土壤水分与解释变量之间相关系数样本序列图

Fig.4 Sample series plot of correlation coefficients between SMAP soil moisture and explanatory variables

3.2 模型训练

通过 Encoded-CGAN 网络和 SM、LST、NDVI、Prec、ET 提供的低分辨率影像信息重建高分辨率土壤水分模型。在训练阶段前,将经过 ENVI 软件影像配准、重采样至统一分辨率和数据归一化至[0, 1]区间等预处理,之后将同一区域和相同像元尺寸的高分辨率空间平均聚合图像和低分辨率条件变量影像输入至 Encoded-CGAN 网络。

在重建过程中通过输入条件变量数据集,由于所提供的变量信息冗余不能较好地恢复高分辨率影像的空间映射关系,容易产生梯度消失和损失值难以反馈模型收敛等问题。因此本研究将原 SMAP14 数据上采样至 9 km×9 km,并与 LST、NDVI、Prec、ET 等条件变量输入至网络中,最后将此结果与平均聚合结果输入值重建网络中进行尺度修复工作。Encoded-CGAN 网络旨根据低分辨率与高分辨率土壤水分数据之间的关系实现模型迭代,因此使用传统损失函数 RMSE 验证网络生成结果与平均聚合结果的统计分布^[25]。

$$\lambda_{mse} = \frac{1}{N} \sum_{i=1}^N (X_i^H - G_\theta(X_i^L))^2 \quad (4)$$

式中, N 为研究域中网格单元的总数, XH_i 和 XH_i 分别为在高(1 km)和低(9 km)分辨率下模拟的网格

单元(i)的降水量, G_θ 为用 θ 参数化的深度神经网络。本研究通过 Pytorch 机器学习框架实现 Encoded-CGAN 网络模型,使用计算机配置为 1 个 NVIDIA GeForce GTX4090Ti 进行 2000 次迭代,并设置 batchsize 为 4 进行模型训练。生成器和判别器同时训练过程中,对抗性损失函数 l_2 反映模型预测值和土壤水分值的累积平方差,定义如下:

$$\lambda(\theta_c) = -\frac{W_a}{m} \sum_{i=1}^m D(G(V_1, V_2, V_3, V_4, V_5)) + \frac{W_c}{m} \|Y_i - \bar{Y}_i\|_1 \quad (5)$$

式中, W_a 和 W_c 分别为对抗性损失和平均绝对误差的权重,分别为 1 和 5; m 为栅格个数; V_1, V_2, V_3, V_4, V_5 为包括 SM、LST、NDVI、Prec、ET 的条件变量; D 为鉴别器; G 为生成器; θ_c 表示生成器的可训练参数的权重; Y_i 为 i 网格单元的含水量; $\bar{Y}_i$ 为区域平均含水量。

如图 5 所示, $RMSE$ 损失函数的顶点位于 X 轴上的 0.28 处,当预测值位于 0.28 附近时, $RMSE$ 损失趋近于 0。然而该函数容易受到噪声影响,当真值存在偏差,则 $RMSE$ 损失函数可能会导致模型过度拟合,在 0.28 后损失函数迅速收敛,然而在 [0.20,

0.28] 区间则呈现一段较为平缓的过度,并且预测值与真值的 *RMSE* 损失在 1~3 之间,因此可认为 [0.20, 0.28] 区间为降尺后研究区土壤水分的数值分布状况。图 6 显示初始值为 0.7 的下降趋势曲线对抗性损失函数分布,随着迭代次数的提升,生成器和判别器的性能有所提高。当迭代次数超过 500 后,其对抗性损失保持在 0.3 附近并呈缓慢下行趋势。




图 5 *RMSE* 验证的统计分布图

Fig.5 Statistical distribution of *RMSE* validation




图 6 对抗性损失函数图

Fig.6 Plot of adversarial loss function

3.3 土壤水分空间降尺度结果

选用 NDVI、LST、Prec、ET 等解释变量作为土壤水分降尺度的空间模型,图 7 展示了经过采样点聚合和 RF、GAN 算法将空间分辨率 9 km 的 SMAP 土壤水分数据降尺度到 1 km 空间分辨率的结果。样本点基本覆盖研究区,因此采用平均聚合样本获得可以真实反映试验区土壤水分状况的面状数据。宏观上看,RF 降尺度结果较好地保持了平均聚合土壤水分结果的空间分布,影像容易平滑导致高频细节丢失,不能有效表征高、低值像素。CGAN 降尺度结果能有效建立不同解释变量与土壤水分的映射关系,从低分辨率影像中识别有利信息并恢复高分辨率影像的工作,并且继承 SMAP 土壤水分产品的空间分布属性和平均聚合结果的真实特征,但是噪声像素干扰图像质量导致 CGAN 结果平滑效果一般。

图 8 为 CGAN 和 RF 降尺后结果、SMAPL4 数据与样本实测数据的对比情况。从宏观上看,三者结果皆与样本实测数据呈正相关性,整体相关系数分别为 0.693、0.568、0.154,降尺后的结果与样本实测数据呈现强相关性。表 2 反映两种降尺度方法在三




图 8 降尺度结果对比实测结果及整体相关性评价

Fig.8 Comparison between downscaling and measured results and overall correlation evaluation

表 2 站点尺寸验证及精度评价
Table 2 Site dimension verification and accuracy evaluation

指标 Index		监测点 1 JC1	监测点 2 JC2	监测点 3 JC3	最北点 NP	最南点 SP	最东点 EP	最西点 WP	均值 Average value
CGAN	R^2	0.840	0.680	0.740	0.590	0.870	0.650	0.540	0.700
	<i>RMSE</i>	0.005	0.010	0.007	0.008	0.008	0.005	0.008	0.007
	<i>Bias</i>	0.030	0.044	0.032	0.033	0.030	0.023	0.037	0.032
RF	R^2	0.420	0.390	0.510	0.630	0.540	0.290	0.320	0.440
	<i>RMSE</i>	0.022	0.019	0.020	0.023	0.045	0.013	0.023	0.006
	<i>Bias</i>	0.020	0.076	0.079	0.110	0.211	0.064	0.114	0.036
SMAPL4	R^2	0.190	0.140	0.210	0.180	0.300	0.240	0.170	0.210
	<i>RMSE</i>	0.027	0.013	0.029	0.017	0.050	0.008	0.025	0.254
	<i>Bias</i>	0.133	0.059	0.146	0.076	0.239	0.038	0.125	0.117




图 1 研究区地理位置及样本分布状况

Fig.1 Geographical location and sample distribution of the study area




图 2 Encoded-CGAN 及初始模块信息

Fig.2 Encoded CGAN and initial module information




图 7 降尺度结果空间分布示意图

Fig.7 Schematic of spatial distribution of downscaling results

个监测站点和四向 4 个采样点的精度评定性能,其中基于 CGAN 网络降尺后的结果能较好反映研究区土壤水分相关性,相较 RF 和 SMAPL4 原数据,CGAN 降尺后的结果在 SP 点的相关性最高($R^2=0.87$),JC1 点的 $RMSE$ 最小(0.005);RF 降尺后的结果在 JC1 点的 $Bias$ 值最小(0.020);SMAPL4 数据难以有效反映实测值结果,其中在 JC2 点的相关性最低($R^2=0.14$),在 SP 点的 $RMSE$ 最大(0.050),在 JC3 点的 $Bias$ 最大(0.146)。三者 R^2 、 $RMSE$ 、 $Bias$ 均值分别表现为 CGAN(0.70)>RF(0.44)>SMAPL4(0.21)、RF(0.006)<CGAN(0.007)<SMAPL4(0.254)、CGAN(0.032)<RF(0.036)<SMAPL4(0.117)。

4 结 论

1)通过对条件变量与土壤水分数据样本和整体两个维度相关性的计算,其相关性均大于 0.44,并且地表植被覆盖的相关性最高(0.73)。针对气候差异较大的云南省高原灌区,LST、NDVI、Prec、ET 等解释变量为 SMAPL4 土壤水分产品降尺度工作提供有效特征因子,并能够表征与土壤水分的关系。

2)由 $RMSE$ 、对抗性损失函数训练的 CGAN 网络模型,在 $RMSE$ 损失函数呈现预测值置于 0.20~0.28 区间变化平稳,0.28 后出现噪点导致模型过度拟合,因此[0.2, 0.28]的值域分布为降尺度后的研究区土壤水分数值分布结果。本研究设置初始值为 0.7、迭代次数为 2000 可以较好训练出预测结果,过高的迭代次数容易导致收敛速度缓慢,因此针对本研究减少迭代次数至 500 可有效训练出预测结果。

3)CGAN 降尺度结果对 R^2 、 $Bias$ 两个指标的效果最好,RF 降尺度结果对 $RMSE$ 指标的效果最好,表明经过降尺度后的数据在研究区范围内能较好表征土壤水分状况的空间分布。经 CGAN、RF 降尺度后研究区内的土壤水分在 $0.20\sim0.26\text{ m}^3\cdot\text{m}^{-3}$ 之间,而实测值介于 $0.18\sim0.28\text{ m}^3\cdot\text{m}^{-3}$,降尺度结果不能反映部分区域土壤含水的极端值情况。

参 考 文 献:

[1] WEIR P, DAHLHAUS P. In search of pragmatic soil moisture mapping at the field scale: a review[J]. Smart Agricultural Technology, 2023, 6: 100330.

[2] KIM Y, PARK H, KIMBALL J S, et al. Global estimates of daily e-vapotranspiration using SMAP surface and root-zone soil moisture[J]. Remote Sensing of Environment, 2023, 298: 113803.

[3] 高琪,王玉珍,冯春晖,等.基于改进型光谱指数的荒漠土壤水分

遥感反演[J]. 自然资源遥感, 2022, 34(1): 142-150.

GAO Q, WANG Y Z, FENG C H, et al. Remote sensing inversion of desert soil moisture based on improved spectral indices[J]. Remote Sensing for Natural Resources, 2022, 34(1): 142-150.

[4] 张新乐,秦乐乐,郑兴明,等.基于主动微波遥感的典型黑土区土壤水分反演[J].东北农业大学学报,2018,49(10):43-51.

ZHANG X L, QIN L L, ZHENG X M, et al. Soil moisture inversion based on active microwave remote sensing in typical black soil area [J]. Journal of Northeast Agricultural University, 2018, 49(10): 43-51.

[5] 潘宁,王帅,刘焱序,等.土壤水分遥感反演研究进展[J].生态学报,2019,39(13):4615-4626.

PAN N, WANG S, LIU Y X, et al. Advances in soil moisture retrieval from remote sensing[J]. Acta Ecologica Sinica, 2019, 39(13): 4615-4626.

[6] 覃湘栋,庞治国,江威,等.土壤水分微波反演方法进展和发展趋势[J].地球信息科学学报,2021,23(10):1728-1742.

QIN X D, PANG Z G, JIANG W, et al. Progress and development trend of soil moisture microwave remote sensing retrieval method[J]. Journal of Geo-Information Science, 2021, 23(10): 1728-1742.

[7] ZHANG R, CHAN S, BINDLISH R, et al. A performance analysis of soil dielectric models over organic soils in Alaska for passive microwave remote sensing of soil moisture [J]. Remote Sensing, 2023, 15(6): 1658.

[8] HE L, CHEN J M, MOSTOVOY G, et al. Soil moisture active passive improves global soil moisture simulation in a land surface scheme and reveals strong irrigation signals over farmlands [J]. Geophysical Research Letters, 2021, 48(8): e2021GL092658.

[9] 赵伟,文凤平,蔡俊飞.被动微波土壤水分遥感产品空间降尺度研究:方法、进展及挑战[J].遥感学报,2022,26(9):1699-1722.

ZHAO W, WEN F P, CAI J F. Methods, progresses, and challenges of passive microwave soil moisture spatial downscaling[J]. Journal of Remote Sensing, 2022, 26(9): 1699-1722.

[10] 薛智暄,张丽,王新军,等.古尔班通古特沙漠 SMAP 土壤水分产品降尺度分析[J].干旱区研究,2023,40(4):583-593.

XUE Z X, ZHANG L, WANG X J, et al. Downscaling analysis of SMAP soil moisture products in Gurbantunggut Desert[J]. Arid Zone Research, 2023, 40(4): 583-593.

[11] LEI J, YANG W, YANG X. Soil moisture in a vegetation-covered area using the improved water cloud model based on remote sensing [J]. Journal of the Indian Society of Remote Sensing, 2022, 50: 1-11.

[12] WAKIGARI S A, LECONTE R. Exploring the utility of the downscaled SMAP soil moisture products in improving streamflow simulation [J]. Journal of Hydrology: Regional Studies, 2023, 47: 101380.

[13] XU M, YAO N, YANG H, et al. Downscaling SMAP soil moisture using a wide & deep learning method over the Continental United States[J]. Journal of Hydrology, 2022, 609: 127784.

[14] 陈佛计,朱枫,吴清潇,等.生成对抗网络及其在图像生成中的应用研究综述[J].计算机学报,2021,44(2):347-369.

CHEN F J, ZHU F, WU Q X, et al. A survey about image generation with generative adversarialnets[J]. Chinese Journal of Computers,

[42] 王航, 周青云, 张宝忠, 等. 不同灌水处理对滨海盐碱地土壤阳离子组成及玉米干物质累积的影响[J]. 干旱地区农业研究, 2020, 38(4): 84-92.

WANG H, ZHOU Q Y, ZHANG B Z, et al. Effects of different irrigation treatments on cationic composition of soil and dry matter accumulation of maize in coastal saline-alkali area[J]. Agricultural Research in the Arid Areas, 2020, 38(4): 84-92.

[43] 刘云鹏, 王国栋, 张社奇, 等. 陕西 4 种土壤粒径分布的分形特征研究[J]. 西北农林科技大学学报(自然科学版), 2003, 31(2): 92-94.

LIU Y P, WANG G D, ZHANG S Q, et al. Fractal characteristics of particle-size distribution for four kinds of soil samples in Shaanxi[J]. Journal of Northwest Sci-Tech University of Agriculture and Forestry (Natural Science Edition), 2003, 31(2): 92-94.

[44] 邱琛, 韩晓增, 陈旭, 等. CT 扫描技术研究有机物料还田深度对黑土孔隙结构影响[J]. 农业工程学报, 2021, 37(14): 98-107.

QIU C, HAN X Z, CHEN X, et al. Effects of organic amendment depths on black soil pore structure using CT scanning technology[J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(14): 98-107.

[45] 蔡太义, 黄会娟, 白玉红, 等. 基于显微 CT 研究不同复垦年限土壤孔隙的微结构特征[J]. 煤炭学报, 2018, 43(11): 3196-3203.

CAI T Y, HUANG H J, BAI Y H, et al. Using X-ray CT scanning to quantify the microstructural characteristics of soil pore in mining areas along a reclamation time[J]. Journal of China Coal Society, 2018, 43(11): 3196-3203.

[46] 张伟, 马建刚, 王开德, 等. 滇西南不同土地利用方式坡地土壤大孔隙特征及与饱和导水率的关系[J]. 西北农林科技大学学报(自然科学版), 2023, 51(4): 84-93.

ZHANG W, MA J G, WANG K D, et al. Characteristics of sloping soil macropores and its relationship with saturated hydraulic conductivity of different land use patterns in southwest Yunnan[J]. Journal of Northwest A & F University (Natural Science Edition), 2023, 51(4): 84-93.

[47] 周宾, 胡树文. 不同种稻年限对苏打盐碱土孔隙和入渗性能的影响[J]. 土壤学报, 2023, 60(1): 99-105.

ZHOU B, HU S W. Effect of different rice planting years on pore and infiltration properties of soda saline-alkali soil[J]. Acta Pedologica Sinica, 2023, 60(1): 99-105.

[48] GUO Y F, FAN R Q, ZHANG X P, et al. Tillage-induced effects on SOC through changes in aggregate stability and soil pore structure[J]. Science of the Total Environment, 2020, 703: 134617.