

荒漠草原区土壤水分 ELM-ESTARFM 遥感反演模型构建与应用

王欢¹, 李瑞平¹, 王福强¹, 赵建伟¹, 苗存立², 籍晓婧³

(1. 内蒙古农业大学水利与土木建筑工程学院, 内蒙古 呼和浩特 010018; 2. 赤峰市克什克腾旗自然资源局, 内蒙古 赤峰 025350; 3. 内蒙古自治区测绘地理信息中心, 内蒙古 呼和浩特 010018)

摘要: 土壤水分的高时空分辨率和高精度评估对于干旱监测具有重要意义。为探究我国内蒙古荒漠草原区土壤水分遥感反演最优模型, 基于 Landsat 和 MODIS 数据进行改进型自适应反射率时空融合 (Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model, ESTARFM), 结合下垫面因子、地形因子、气象因子、植被因子等多要素环境因子, 通过极限学习机 (Extreme learning machine, ELM) 和随机森林 (Random forest, RF) 两种方法构建土壤含水率反演模型, 并与 Landsat (未进行融合) 构建的土壤含水率反演模型进行对比, 最终筛选得到最优土壤含水率反演模型, 并对研究区不同土地利用类型土壤含水率分布特征进行应用分析。结果表明: 归一化植被指数是土壤含水率环境因子相关分析中最重要的预测因子 (0~10、10~20、20~30 cm 土壤深度处 $R^2=0.85、0.82、0.79$), 其次为降水量 ($R^2=0.73、0.68、0.71$)、高程 ($R^2=0.71、0.70、0.71$)、水体指数 ($R^2=0.69、0.69、0.68$)、归一化盐分指数 ($R^2=0.68、0.67、0.65$)。与未进行时空融合所构建的模型相比, 利用 ESTARFM 时空融合所构建的模型精度均有所提升, 考虑 ESTARFM 时空融合时, ELM 模型的 R^2 、RMSE、MAE 分别为 0.89、6.58%、3.93%, RF 模型的 R^2 、RMSE、MAE 分别为 0.78、7.25%、4.95%; 未考虑 ESTARFM 时空融合时, ELM 模型的 R^2 、RMSE、MAE 分别为 0.75、7.37%、5.24%, RF 模型的 R^2 、RMSE、MAE 分别为 0.71、7.48%、5.30%。表明 ELM 模型比 RF 模型的土壤含水率反演效果更好, 且 ELM-ESTARFM 为土壤含水率反演最优模型。在此基础上, 运用改进后的 ELM-ESTARFM 遥感反演模型监测了乌审旗全域土壤含水率, 发现研究区北部和西北部的土壤含水率较高, 南部地区的土壤含水率较低; 对于不同土壤深度, 土壤含水率由大到小依次为耕地、林地、草地、沙地, 耕地区域 0~10、10~20、20~30 cm 土层含水率分别为 18.92%、19.34%、21.84%, 林地为 11.80%、11.87%、12.40%, 草地为 10.97%、11.02%、12.22%, 沙地为 5.07%、5.35%、5.67%。

关键词: 土壤水分; 环境因子; 极限学习机; 随机森林

中图分类号: S161.3 **文献标志码:** A

Construction and application of ELM-ESTARFM remote sensing inversion model for soil moisture in desert steppe area

WANG Huan¹, LI Ruiping¹, WANG Fuqiang¹, ZHAO Jianwei¹, MIAO Cunli², JI Xiaojing³

(1. College of Water Conservancy and Civil Engineering, Inner Mongolia Agricultural University, Hohhot,

Inner Mongolia 010018, China; 2. Natural Resources Bureau of Keshiketengqi, Chifeng, Inner Mongolia 025350, China;

3. Inner Mongolia Autonomous Region Center for Surveying, Mapping and Geoinformation, Hohhot, Inner Mongolia 010018, China)

Abstract: The high spatiotemporal resolution and high-precision assessment of soil moisture are of great significance for drought monitoring. To explore the optimal model of remote sensing inversion for soil moisture in the desert steppe region of Inner Mongolia, China, the Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model (ESTARFM) was carried out based on Landsat and MODIS data. Combining with multi-factor environmental factors including underlying surface factors, topographic factors, meteorological factors, and vegetation factors, the soil moisture content inversion model was constructed by extreme learning machine (ELM) and random forest (RF) methods. Comparing with the soil moisture content inversion model constructed by Landsat (without fusion), the

optimal soil moisture content inversion model was selected. The soil moisture content distribution characteristics of different land use types in the study area were analyzed. The results showed that the normalized vegetation index was the most important predictor of soil moisture content and environmental factors ($R^2 = 0.85, 0.82, 0.79$ at soil depth of 0~10, 10~20, 20~30 cm), followed by precipitation ($R^2 = 0.73, 0.68, 0.71$), elevation ($R^2 = 0.71, 0.70, 0.71$), water index ($R^2 = 0.69, 0.69, 0.68$), and normalized salinity index ($R^2 = 0.68, 0.67, 0.65$). Compared with the model without spatiotemporal fusion, the accuracy of the model constructed by ESTARFM spatiotemporal fusion was improved, and the R^2 , $RMSE$, and MAE of the ELM model were 0.89, 6.58%, and 3.93%, respectively, and the R^2 , $RMSE$, and MAE of the RF model were 0.78, 7.25%, and 4.95%, respectively. The MAE was 0.75, 7.37%, and 5.24%, respectively, and the R^2 , $RMSE$, and MAE of the RF model were 0.71, 7.48%, and 5.30%, respectively, indicating that the ELM model had a better inversion effect on soil moisture content than the RF model, and ELM-ESTARFM was the optimal model for soil moisture content inversion. On this basis, the improved ELM-ESTARFM remote sensing inversion model was used to monitor the soil moisture content in the whole area of Wushenqi, and it was found that the soil moisture content in the north and northwest of the study area was high, and the soil moisture content in the southern area was low. For different soil depths, the soil moisture content was 18.92%, 19.34%, and 21.84% in the cultivated land area at 0~10, 10~20, and 20~30 cm soil depths, 11.80%, 11.87%, 12.40% in woodland, 10.97%, 11.02% and 12.22% in grassland, and 5.07%, 5.35%, and 5.67% in sandy land, respectively.

Keywords: soil moisture; environmental factors; extreme learning machine; random forest

干旱是人类面临的主要自然灾害之一,对农业、生态环境、社会经济产生重大影响^[1]。土壤水分是干旱监测的重要因子之一,土壤水分作为连接土壤-植物-大气的重要纽带,在物质与能量交换过程中发挥着不可替代的作用。受气候、地形和植被分布等生物和非生物因素的影响,土壤水分分布特征和影响因素非常复杂,地形因子和植被因子是小尺度上影响土壤水分的主要因子,地形因子是气候、植被等影响因子的主要载体,植被因子是土壤水分在干旱地区的集中体现^[2]。因此,全面分析不同土地利用类型土壤水分的分布特征及其与地形和植被因子之间的关系,可为干旱地区抗旱减灾提供科学依据。

土壤含水率在时空分布上变化极大,传统测量方法需消耗大量人力、物力及财力,难以实现大范围实时监测,而遥感具有重访周期短、分辨率高、覆盖范围广等优势,因此,遥感技术已经成为监测土壤水分的一种重要手段。在点尺度上,可以通过烘干法、水势法、中子仪法和介电常数法测定土壤水分;在面尺度上,可以通过电磁感应法、电阻率层析成像法、宇宙射线中子法测定土壤水分^[3]。由于技术条件等因素的制约,遥感数据的获得经常需要在空间分辨率和重访周期之间进行权衡^[4]。MODIS数据的时间分辨率较高,在对土壤水分变化监测应用中具有不可比拟的优势,但其空间分辨率较低,混合像元效应显著,无法解析像元内下垫面的变化

并由此带来土壤的估算误差。Landsat 8 数据相对 MODIS 数据来说,其空间分辨率较高,反演的土壤水分在精度上要明显高于 MODIS 数据,但时间分辨率很低,当天气变化较大时可能周期更长,所以对其遥感应用带来诸多限制,因此单一数据源的遥感影像已经不能满足日益广泛的对地观测需求^[5],如果能将高空间分辨率的 Landsat 与高时间分辨率的 MODIS 进行有效的融合生成高空间分辨率、高时间分辨率的遥感数据,将会对干旱监测及灌溉农业具有重要意义。

确定高时间和高空间分辨率数据在时间上的变化,是提高融合精度的关键,近些年国内外学者不断对时空融合算法进行更新和改进。Maselli 等^[6]假设像元反射率在邻域内不会有较大的改变,构建了一种新的改进模型;Busetto 等^[7]综合考虑与目标像元的距离差异和光谱差异,提出了一种改进方法;Gao 等^[8]通过提取丰度矩阵和低分辨率影像的平均反射率构建了时空自适应反射率融合模型 (Spatial and Temporal Adaptive Reflectance Fusion Model, STARFM),取得了很好的效果,但如果地表的变化持续的时间很短,而且还不能在现有影像上反映出来,会产生双向反射分布函数效应问题及混合像元问题。在此基础上,Hilker 等^[9]通过选择最佳时相的数据进行融合,提出了 STAARCH 时空融合算法。Zhu 等^[10]在 STARFM 的基础上,在假设一段时间的内陆物反射率为线性变化的前提下,将混合像元从不同的地表覆盖层线性地结合起来,并引

入一个转换系数,尝试着对 STARFM 中的混合像元问题进行求解,提出了一种改进型自适应反射率时空融合方法(Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model, ESTARFM)。以上模型很好地适用于湖泊水体监测^[11]、作物识别^[12]等方面。由于成像指标之间相互制约,传感器的空间、光谱分辨率与成像幅宽之间相互制约,单一遥感系统观测的地表信息往往并不全面,难以同时满足大面积、高精度、快速率的土壤水分监测要求。因此,充分利用多源遥感数据的互补优势,将多源遥感进行 ESTARFM 融合,是提高区域土壤水分遥感反演精度的必然途径。经典回归方法难以实现参数的无偏和有效估计,很多学者将拥有能够处理复杂非线性关系问题的机器学习算法运用到了土壤水分反演模型的构建中,现有研究表明极限学习机和随机森林是土壤水分定量反演的可行方法,李向龙等^[13]针对传统反馈型神经网络模型在土壤含水量反演时容易陷入局部最优解和模型计算效率低等问题,利用极限学习机构建土壤含水量反演模型,其决定系数达到了 0.86。张艳灵等^[14]利用广义线性模型(GLM)、广义加性模型(GAM)和随机森林(RF)模型研究了土壤水分与地形-植被因子之间的关系和变化规律,结果表明 RF 模型的精度优于 GLM 和 GAM 模型。

在研究土壤水分选取环境因子时,归一化植被指数 NDVI 被广泛应用于土壤水分估算模型中,是地表特征的重要参数^[15]。增强型植被指数 EVI、比值植被指数 RVI、差值环境植被指数 DVI 是常用的植被指数,在土壤水分反演中能够反映较多的波段信息^[16]。此外,地形数据是反映地表信息的重要参数,与土壤水分反演有着一定的联系^[17],土壤水分对降雨的响应特征与降水在地表和土壤中的分配密切相关^[18]。目前为止,下垫面因子被广泛考虑到土壤水分研究中,而土壤水分是一个动态变量,受多种因素的影响,在不同的时空尺度上,即使在较小的区域内也会发生显著的变化。因此,全面考虑下垫面因子、地形因子、气象因子、植被因子对土壤水分的影响及哪种因子对土壤水分的作用机制较强显得尤为重要。

以地处毛乌素沙地的典型荒漠草原的乌审旗为研究区域,将基于 Google Earth Engine(GEE)云平台处理 Landsat 8、MODIS09 A1 遥感影像获取的下垫面因子、基于地理空间数据云获取到的地形因子、基于国家气象科学数据中心获取的气象因子、基于野外实测获取的植被因子作为环境因子,利用

逐步多元线性回归筛选最优解释变量,并将其中的下垫面因子进行 ESTARFM 时空融合,将融合后的下垫面因子与其余的最优环境因子作为模型的解释变量,实测土壤含水率作为被解释变量,利用极限学习机(ELM)、随机森林(RF)构建土壤含水率反演模型,并与真实 Landsat 8(未进行融合)构建的土壤含水率反演模型进行对比,最终筛选出最优反演模型,并研究不同土地利用类型下土壤含水率的分布特征,为干旱区土壤水分的监测提供参考。

1 材料与方法

1.1 研究区概况

乌审旗位于内蒙古自治区鄂尔多斯市西南部(108°17'~109°40'E,37°38'~39°23'N),地势西北高、东南低,平均海拔 1 305 m(图 1,见 241 页)。属典型的温带大陆性季风气候,年平均气温 6.8℃,年平均降水量 350~400 mm。主要土地利用类型为草地、沙地、林地、耕地、水体和建筑用地,主要草本植物为羊草、刺草、小麦草、早熟禾、紫斑牡丹,草原类型以荒漠草原为主。

1.2 数据来源

1.2.1 环境因子数据 本文通过 GEE(<https://earth-engine.google.com/>)平台对 Landsat 8、MODIS09A1 遥感数据在线处理及野外采集共选取 16 个环境因子,10 个下垫面因子:归一化植被指数 NDVI、增强型植被指数 EVI、比值植被指数 RVI、差值环境植被指数 DVI、水体指数 NDWI、归一化盐分指数 NDSI、土壤调节植被指数 SAVI、转换型土壤调节植被指数 TSAVI、盐分指数 SI、垂直干旱指数 PDI,其中,Landsat 8 云层覆盖度小于 30%,时间分辨率为 16 d,空间分辨率为 30 m,MODIS09A1 时间分辨率为 8 d,空间分辨率为 500 m;2 个地形因子:高程 DEM、坡度 Slope;2 个气象因子:降水量 P、平均温度 T;2 个植被因子:株高 H(植物从地面到顶部的垂直距离)、多度 M(植物群落中物种个体数量)。

1.2.2 土壤水分数据 本研究参照荒漠化程度分布图、土地利用、土壤质地及道路交通等情况,在乌审旗选择 24 个采样区域,其中耕地、林地、草地、沙地各 6 个区域,分别于 2023 年 4 月 26 日、5 月 27 日、6 月 28 日进行野外试验数据采集,采样区域之间的最小间隔为 1 km,每个采样区域的大小为 30 m×30 m,每个采样区域选取 5 个点,包括中心点。利用土钻分别采集 0~10、10~20、20~30 cm 土层土壤样品,并借助手持 GPS 实时记录采样点的位置信息,通过烘干法测定土壤含水率^[19]。对野外实测土

壤含水率数据(120个)随机分为训练集和测试集,训练集(70%,84个样点)用于训练模型,测试集(30%,36个样点)用于测试模型。

1.3 研究方法

1.3.1 逐步多元线性回归 最优解释变量筛选采用逐步多元线性回归(Stepwise Multiple Linear Regression, SMLR)方法,该方法是建立一个简化而有效的回归模型,以通过最少的自变量解释尽可能多的因变量变异,这种方法能够减少不必要的变量,提高模型的预测精度和解释能力,如式(1)所示。

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (1)$$

式中, Y 为因变量, X_1, X_2, \dots, X_n 是独立变量, β_0 为常数, $\beta_i (1 \leq i \leq n)$ 为标准偏回归系数。

1.3.2 ESTARFM 时空融合模型 ESTARFM 时空融合模型是在 STARFM 模型的基础上进行了改进,ESTARFM 通过对像元的异质性进行分析,调整了赋权方法,并引入了一个用来对预测结果进行改进的转换系数,尤其对异质性较大区域的预测精度进行了提高,可以更好地保留空间细节^[20]。ESTARFM 模型通过某个窗口大小 w 在整个影像上逐一移动,从而来逐一确定移动位置中心像元的预测值,中心像元预测值的表达式如式(2)所示^[21]。

$$\hat{R}_{high}(x_{w/2}, y_{w/2}, T_b) = T'_a \hat{R}_{a_high}(x_{w/2}, y_{w/2}, T_b) + T'_c \hat{R}_{c_high}(x_{w/2}, y_{w/2}, T_b) \quad (2)$$

$$\hat{R}_{t_high}(x_{w/2}, y_{w/2}, T_b) = R_{high}(x_{w/2}, y_{w/2}, T_t) + \sum_{i=1}^N \omega_i \rho_i (R_{low}(x_i, y_i, T_b) - R_{low}(x_i, y_i, T_t)), \quad (t = a, c) \quad (3)$$

$$T'_t = \frac{1 / \left| \sum_{i=1}^w \sum_{j=1}^w R_{low}(x_i, y_i, T_t) - \sum_{i=1}^w \sum_{j=1}^w R_{low}(x_i, y_i, T_b) \right|}{\sum_{t=a,c} \left(1 / \left| \sum_{i=1}^w \sum_{j=1}^w R_{low}(x_i, y_i, T_t) - \sum_{i=1}^w \sum_{j=1}^w R_{low}(x_i, y_i, T_b) \right| \right)} \quad (4)$$

式中, $\hat{R}_{high}(x_{w/2}, y_{w/2}, T_b)$ 为预测期 T_b 最终高分辨率融合数据, $\hat{R}_{a_high}(x_{w/2}, y_{w/2}, T_b)$ 和 $\hat{R}_{c_high}(x_{w/2}, y_{w/2}, T_b)$ 分别为 T_a 和 T_c 时期原始数据与预测期 T_b 相关的高分辨率数据,通过式(3)求得^[20]; T'_a 和 T'_c 是时间权重,通过式(4)计算得到^[21], $(x_{w/2}, y_{w/2})$ 为搜索窗口中心位置,也就是待预测的中心像元位置, w 是移动窗口大小。 N 为相似像元的个数, ρ_i 是转换系数, ω_i 是距离权重。 $R_{high}(x_{w/2}, y_{w/2}, T_t)$, $(t = a, c)$ 是 T_a 和 T_c 时期原始高空间低时间分辨率数据,本文是 Landsat8 数据, $R_{low}(x_i, y_i, T_b)$ 和 $R_{low}(x_i, y_i, T_t)$ 分别是 T_b 和 $T_c(t = a, c)$ 时期原始高时间低空间分辨率数据,本文是 MODIS 数据。

本文基于 Landsat 8 和 MODIS 遥感影像选择待预测时期(2023年5月27日)及待预测时期前后两个时期(2023年4月26日、2023年6月28日)进行影像融合,生成待预测时期高时空分辨率的影像数据。

1.3.3 极限学习机模型 极限学习机(ELM)是一种单层前馈神经网络,其特点是随机初始化隐层权重和偏置,并以较快的速度进行训练,训练过程中只需要学习输出层权重,不需要反向传播算法,因此训练速度快,由于极限学习机随机初始化隐层权重和偏置,使得网络具有较好的泛化能力,模型的表达如式(5)、(6)所示^[22]。

$$y = H\beta \quad (5)$$

$$H = g(w_i, x, b) \quad (6)$$

式中, $g(w_i, x, b)$ 为激励函数, β 为输出层权值, w_i 为输入层权值, x 为输入样本, b 为偏置值, y 为输出样本。

1.3.4 随机森林模型 随机森林(RF)是一种集成学习方法,用于解决分类和回归问题,它由多个决策树组成,通过对每个决策树的预测结果进行综合,得出最终的预测结果,通过统计每个特征在决策树中的使用频率和分裂改善度,可以量化各个特征在预测中的重要性,在构建每个决策树时使用了随机性选择特征和自助采样方法,在一定程度上减少了模型的过拟合风险,模型预测结果如式(7)所示^[23]。

$$f(x) = \frac{1}{N} \sum_{n=1}^N f_N(x) \quad (7)$$

式中, $f(x)$ 表示 N 个 $f_N(x)$ 的集合, $f(x)$ 表示随机森林模型的预测结果, $f_N(x)$ 表示单个决策树的预测结果。

2 结果与分析

2.1 最优解释变量筛选

将10个下垫面因子、2个地形因子、2个气象因子、2个植被因子作为解释变量,实测土壤含水率作为被解释变量,构建逐步多元线性回归模型(SMLR),根据先用被解释变量对每一个所考虑的解释变量做简单回归,然后以对被解释变量贡献最大的解释变量所对应的回归方程为基础,再逐步引入其余解释变量,进而确定最优解释变量,结果如图2所示,首先,NDVI与土壤含水率的相关性最高,0~10、10~20、20~30 cm土壤深度的决定系数 R^2 分别为0.85、0.82、0.79,主要原因是NDVI与植物根系的土壤湿度具有显著相关性,且在半干旱区,利用

NDVI 数据可以很好地估算土壤水分^[24];其次为 *P* 与土壤含水率相关性,0~10、10~20、20~30 cm 土壤深度的 R^2 分别为 0.73、0.68、0.71,特别是在干旱区域,降水量的变化对土壤水分供应、水分胁迫以及植被的代谢和生理功能有显著影响^[25];其次为 *DEM* 与土壤含水率相关性,0~10、10~20、20~30 cm 土壤深度的 R^2 分别为 0.71、0.70、0.71,研究区地势呈现西北高、东南低特征,地形会影响地表径流与该地所受的太阳光照、植被生长环境等,从而对土壤水分产生影响^[26];其次为 *NDWI* 与土壤含水率相关性,0~10、10~20、20~30 cm 土壤深度的 R^2 分别为 0.69、0.69、0.68,*NDWI* 可以反映土壤干湿状况,作为土壤水分信息的有效补充,*NDWI* 具有易于获取的优势,但是,*NDWI* 也并不是最直接的土壤水分变量,对土壤水分信息的表达和反映是间接的^[27];其次为 *NDSI* 与土壤含水率相关性,0~10、10~20、20~30 cm 土壤深度的 R^2 分别为 0.68、0.67、0.65,*NDSI* 可以间接的反映土壤肥力、土壤退化及土壤水分^[28];最后 *EVI*、*DVI*、*RVI*、*SI*、*T*、*Slope*、*SAVI*、*PDI*、*TSAVI*、*H*、*M* 与不同土壤深度含水率之间的 R^2 分别为 0.51、0.50、0.50、0.41、0.41、0.41、0.36、0.34、0.35、0.26、0.25、0.24、0.23、0.21、0.23、0.19、0.19、0.18、0.15、0.15、0.11、0.15、0.13、0.14、0.13、0.12、0.12、0.11、0.11、0.10、0.06、0.05、0.06。最终选取 *NDVI*、*P*、*DEM*、*NDWI*、*NDSI* 为最优解释变量进行土壤含水率反演。

2.2 ESTARFM 模型融合结果

将真实 Landsat 8 影像下垫面因子与 ESTARFM 模型融合后影像下垫面因子进行定量分析评价,得到 *NDVI*、*NDSI*、*EVI*、*DVI*、*NDWI*、*PDI*、*RVI*、*SAVI*、*SI*、*TSAVI* 的决定系数 R^2 分别为 0.95、0.91、0.89、0.86、0.93、0.82、0.85、0.87、0.88、0.90,可以发现:*NDVI* 的融合效果最佳,其 R^2 为 0.95,*PDI* 的融合效果相对较

差, R^2 仅为 0.82,各因子 $R^2 > 0.80$,通过了 $P < 0.01$ 的显著性水平检验,表明基于 ESTARFM 模型融合得出的高时空分辨率数据具有较高的适用性。

2.3 土壤含水率反演模型

将 *P*、*DEM* 以及融合后的 *NDVI*、*NDWI*、*NDSI* 作为解释变量,2023 年 5 月 27 日实测土壤含水率作为被解释变量,运用 ELM 模型、RF 模型构建不同深度下土壤含水率反演模型,并与真实 Landsat 8 (未进行融合) 构建的土壤含水率反演模型进行对比,进而评价融合前后对土壤含水率的反演效果。为了全面评估土壤水分反演模型的精度及效果,采用训练集与测试集的决定系数 R^2 、均方根误差 *RMSE*、平均绝对误差 *MAE* 指标来进行评价与分析(表 1)。

由表 1 可知,各模型预测值与实测值均具有很高的相关性,训练集两种模型方法的精度有所差异,相比于未进行时空融合所构建的模型,利用 ESTARFM 时空融合所构建的模型中精度均有所提升,且在 ELM 模型的 R^2 最高,为 0.89,而 *RMSE* 和 *MAE* 均最小,分别为 6.58% 和 3.93%,RF 模型的 R^2 最高,为 0.71,而 *RMSE* 和 *MAE* 均最大,分别为 7.57% 和 5.37%;而未进行时空融合所构建的模型中,依然是 ELM 模型的 R^2 最高,为 0.75,而 *RMSE* 和 *MAE* 均最小,分别为 7.37% 和 5.24%,依旧是 RF 模型的 R^2 最高,为 0.65,而 *RMSE* 和 *MAE* 均最大,分别为 7.88% 和 5.76%。综上所述,训练集中 ELM 模型性能明显优于 RF 模型,反演效果由优到劣依次为 ELM-ESTARFM、RF-ESTARFM、ELM、RF。在测试集中,2 种模型各精度指标相比于训练集无明显下降,表明模型比较稳定,但二者比较而言,依然是 ELM 模型的各指标明显优于 RF 模型,无论是训练集还是测

表 1 基于不同方法土壤含水率反演模型

Table 1 Inversion model of soil moisture content based on different methods

方法 Method	深度 Depth /cm	训练集 Training set			测试集 Test set		
		R^2	<i>RMSE</i> /%	<i>MAE</i> /%	R^2	<i>RMSE</i> /%	<i>MAE</i> /%
ESTARFM-ELM	0~10	0.89	6.58	3.93	0.86	6.71	4.02
	10~20	0.87	6.67	4.11	0.85	6.86	4.35
	20~30	0.83	6.95	4.69	0.81	6.99	4.84
ESTARFM-RF	0~10	0.78	7.25	4.95	0.72	7.43	5.28
	10~20	0.75	7.32	5.16	0.73	7.40	5.23
	20~30	0.71	7.57	5.37	0.68	7.74	5.62
ELM	0~10	0.75	7.37	5.24	0.71	7.50	5.31
	10~20	0.72	7.45	5.25	0.67	7.78	5.69
	20~30	0.73	7.42	5.28	0.66	7.85	5.73
RF	0~10	0.71	7.48	5.30	0.69	7.68	5.57
	10~20	0.68	7.72	5.63	0.63	8.14	6.29
	20~30	0.65	7.88	5.76	0.59	8.56	6.72

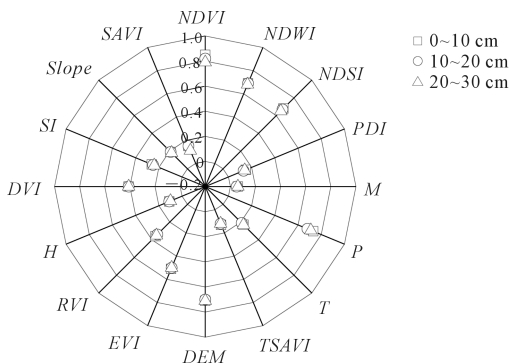


图 2 不同土壤深度环境因子与土壤含水率的相关分析图

Fig.2 Correlation analysis of environmental factors and soil moisture content at different soil depths

试集,各模型的精度均随着土壤深度的增加而有所小幅度的降低。综合各模型训练集与测试集的精度评价指标,模型的预测性能从高到低排序依次为 ELM-ESTARFM、RF-ESTARFM、ELM、RF,这是因为土壤组成复杂,而且土壤水分还受人类活动的影响,随机森林算法无法做出超越训练集数据范围的预测,这可能导致在某些特定噪声的数据进行建模时出现过度拟合,导致随机森林算法构建的土壤含水率反演模型存在一定不足。而 ELM 模型由于过程不需要调整隐含层节点参数,输入层至隐含层的特征映射可以是随机的或人为给定的,其学习过程易于在全局极小值收敛,该模型充分考虑了各环境

因子对土壤含水率的影响,因此,ELM-ESTARFM 为最优土壤含水率反演模型。

2.4 乌审旗土壤含水率空间分布特征

利用优选的 ELM-ESTARFM 土壤含水率反演模型反演 2023 年 5 月不同深度土壤含水率(图 3),可以发现,表层土壤受外界环境影响大,随着深度的增加土壤所受的环境影响减弱;研究区北部和西北部的土壤含水率较高,而南部地区的土壤含水率较低,主要是由于北部和西北部地区植被覆盖率较高使得水分蒸腾作用减弱,南部地区植被覆盖率较低使得地表蒸散强烈。

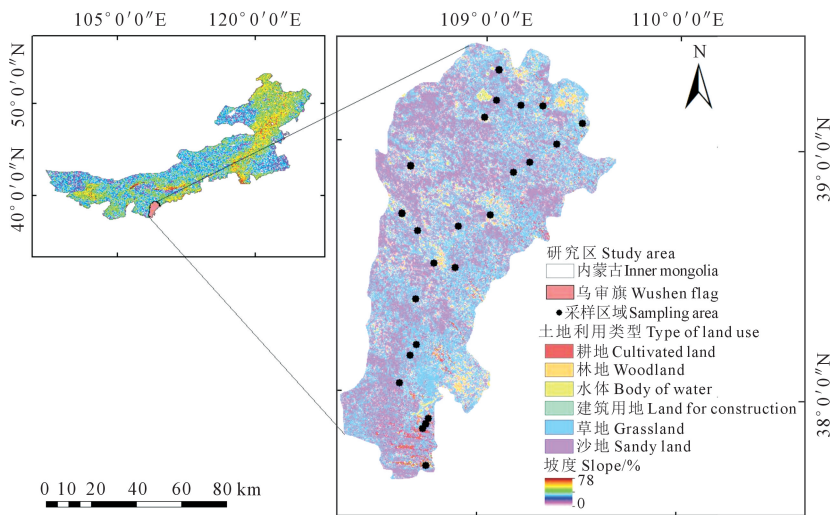


图 1 研究区地理位置与采样区分布图

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

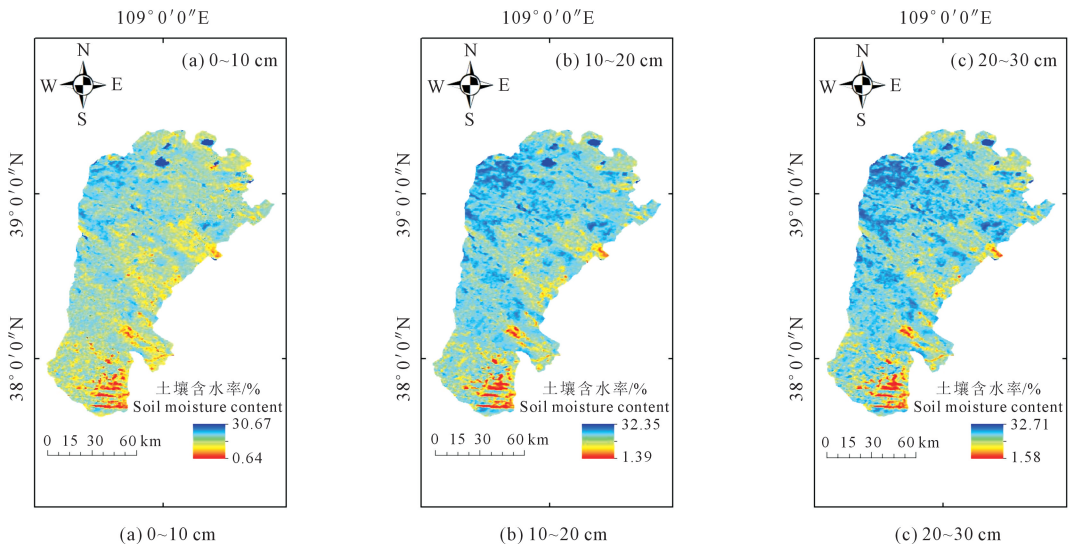


图 3 不同土壤深度含水率空间分布图

Fig.3 Spatial distribution of moisture content at different soil depths

分别对研究区 2023 年 5 月不同土壤深度耕地、林地、草地、沙地 4 种土地利用类型的土壤含水率进行统计分析,由表 2 可知,不同土壤深度,土壤含水率由大到小依次为耕地、林地、草地、沙地,耕地区域 0~10、10~20、20~30 cm 土壤深度的含水率分别为 18.92%、19.34%、21.84%,林地区域 0~10、10~20、20~30 cm 土壤深度的含水率分别为 11.80%、11.87%、12.40%,草地区域 0~10、10~20、20~30 cm 土壤深度的含水率分别为 10.97%、11.02%、

12.22%,沙地区域 0~10、10~20、20~30 cm 土壤深度的含水率分别为 5.07%、5.35%、5.67%;随着土壤深度的增加,耕地土壤含水率呈现出先减小再增大的趋势,林地和草地都呈现出先增大再减小的趋势,沙地呈现出逐渐增大的趋势,耕地土壤含水率最高,可能是由于植被覆盖率高使得对降水的截留作用比较大及蒸发潜力相对较低,沙地土壤含水率最低,可能是植被覆盖率低使得水分下渗加快及蒸发潜力相对较高。

表 2 不同土地类型土壤含水率统计分析表

Table 2 Statistical analysis of soil moisture content of different land types

类型 Type	深度 Depth /cm	最小值 Minimum /%	最大值 Maximum /%	均值 Mean /%	方差 Variance /%	标准差 Standard deviation/%	偏度 Skewness /%	峰度 Kurtosis /%	变异系数 Variation coefficient
耕地 Cultivated land	0~10	9.80	31.49	18.92	24.7	4.97	0.47	0.10	0.26
	10~20	11.4	27.62	19.34	23.24	4.82	0.06	-1.06	0.25
	20~30	12.6	29.60	21.84	22.44	4.74	-0.3	-0.92	0.22
林地 Woodland	0~10	7.48	18.5	11.80	6.49	2.55	0.51	-0.04	0.22
	10~20	7.49	17.45	11.87	5.20	2.28	0.25	-0.14	0.19
	20~30	8.46	16.49	12.40	5.32	2.31	0.12	-1.18	0.19
草地 Grassland	0~10	6.46	17.23	10.97	7.88	2.81	0.18	-0.37	0.26
	10~20	6.13	17.46	11.02	7.66	2.77	0.27	-0.31	0.25
	20~30	6.50	18.49	12.22	11.33	3.37	0.07	-0.77	0.28
沙地 Sandy land	0~10	2.80	8.45	5.07	1.78	1.33	0.83	0.78	0.26
	10~20	2.40	8.69	5.35	2.00	1.41	0.49	0.58	0.26
	20~30	2.20	9.53	5.67	2.39	1.54	0.50	1.05	0.27

3 讨论

本研究尝试考虑下垫面、地形、气象、植被多种环境因子对土壤含水率的影响,利用逐步多元线性回归筛选出对土壤含水率敏感的因子并有效解决了多重共线性问题,同时基于 ESTARFM 时空融合技术对 Landsat 和 MODIS 遥感影像进行融合得到高时空分辨率数据,选择 ELM 和 RF 构建土壤含水率反演模型。国内外已有许多土壤含水率反演研究,但选取的环境因子和采用的建模方法各有不同,在环境因子的选取中,大多考虑的是下垫面因子,综合考虑下垫面因子、地形因子、气象因子、植被因子的研究还比较少。张钧泳等^[29]通过构建不同植被指数的 Ts-VI 特征空间研究土壤含水率,发现多植被指数组合可有效提高模型精度。贺文君等^[30]在土壤水分研究中引入地形数据,发现随高程的增加,各土层土壤水分含量呈下降趋势。Kovacevic 等^[31]发现降水作为自然水循环的一部分,与土壤湿度存在时空相关性。本文考虑加入下垫面因子之外的地形因子、气象因子、植被因子作为多要素环境因子,因而选取了 10 个下垫面因子、2 个地形因子、2 个气象因子、2 个植被因子共 16 个环境因子,

通过步多元线性回归表明气象因子、地形因子对土壤含水率也具有重要影响,是土壤含水率反演模型中不可忽视的解释变量,这与 Guo 等^[25]和 Chen 等^[26]的研究结果一致,本研究的结果可为其他土壤含水率研究中环境因子的选择提供参考。在建模方法的选取中,机器学习方法能够在缺乏物理机理的情况下表达环境因子与土壤含水率之间的关系机制成为构建土壤含水率反演模型,在本研究中,无论是训练集还是测试集,ELM 模型的各指标明显优于 RF 模型,ELM 模型的 $R^2 = 0.66 \sim 0.81$,RF 模型的 $R^2 = 0.59 \sim 0.78$,这与蔡亮红等^[32]基于 ELM、SVM、RF、BP 构建的土壤水分预测研究中,得出 ELM 为最优土壤水分预测模型的结果一致,这是因为土壤组成复杂,而且土壤水分还受人类活动的影响,RF 算法不能够做出超越训练集数据范围的预测,这可能导致在某些特定噪声的数据进行建模时出现过度拟合,导致 RF 算法构建的土壤含水率反演模型存在一定不足,而 ELM 算法由于过程不需要调整隐含层节点参数,输入层至隐含层的特征映射可以是随机的或人为给定的,其学习过程易于在全局极小值收敛,该算法充分考虑了各环境因子对土壤含水率的影响。

ESTARFM 时空融合模型能够有效地解决关键时期内影像丢失问题且提高影像时空分辨率,各下垫面因子的融合决定系数均在 0.82 以上。对比分析结果也显示,相比于未进行时空融合所构建的模型,利用 ESTARFM 时空融合所构建的土壤含水率反演模型中精度均有所提升,ELM 模型在 0~10、10~20、20~30 cm 土壤深度的决定系数分别提高了 0.14%、0.15%、0.10% (训练集), 0.15%、0.18%、0.15% (测试集)。RF 模型在 0~10、10~20、20~30 cm 土壤深度的决定系数分别提高了 0.07%、0.07%、0.06% (训练集), 0.03%、0.10%、0.09% (测试集)。表明基于 ESTARFM 模型生成的高时空分辨率数据很好的结合了 Landsat 和 MODIS 这两种数据的优势,既添加了 Landsat 的空间互异信息,同时又包括了 MODIS 的时间变化特点,为融合数据应用于研究区高时空分辨率土壤含水率的研究提供了支撑,这与尉毓姣等^[33]研究结果一致。不同土地利用类型中,耕地土壤含水率最高,可能是由于植被覆盖率高使得对降水的截留作用比较大及蒸发潜力相对较低,沙地土壤含水率最低,可能是植被覆盖率低使得水分下渗加快及蒸发潜力相对较高,表明不同土地利用在不同程度上改变了土壤性质,使土壤中各因子发生了较大的变化,从而造成不同土地利用的土壤含水率之间存在着差异,这与常军霞等^[34]研究有着相同的结论。本研究由于选取的都是光学遥感,未来将考虑加入雷达遥感作为数据源以提高土壤含水率的反演精度;此外,建模算法上仅对环境因子与土壤含水率之间进行数量上的相关统计分析,它们之间是否存在其它内在机理等联系仍有待进一步研究。

4 结 论

1) *NDVI* 是土壤含水率环境因子相关分析中最重要的预测因子,其次为 *P*、*DEM*、*NDWI*、*NDSI*。

2) 基于 ESTARFM 模型融合后的 Landsat 数据与真实的 Landsat 数据相关分析中,*NDVI* 的融合效果最佳,*PDI* 的融合效果相对较差;且基于 ESTARFM 模型融合得出的高时空分辨率数据具有较强的适用性。

3) ELM 模型比 RF 模型的土壤含水率反演效果更好,且 ELM-ESTARFM 为土壤含水率反演最优模型。

4) 研究区北部和西北部的土壤含水率较高,南部地区的土壤含水率较低;不同深度土壤含水率由大到小依次为耕地、林地、草地、沙地,耕地区域 0~

10、10~20、20~30 cm 土壤深度的含水率分别为 18.92%、19.34%、21.84%,林地为 11.80%、11.87%、12.40%,草地为 10.97%、11.02%、12.22%,沙地为 5.07%、5.35%、5.67%。

参 考 文 献:

- [1] CONG D M, ZHAO S H, CHEN C, et al. Characterization of droughts during 2001-2014 based on remote sensing: a case study of Northeast China[J]. *Ecological Informatics*, 2017, 39: 56-67.
- [2] 李原,于瑞宏,赵元真,等.基于 GIS 的内蒙古自治区植被生态需水量研究[J]. *水土保持通报*, 2023, 43(6): 324-335, 401.
LI Y, YU R H, ZHAO Y Z, et al. GIS-based study on vegetation ecological water demand in Inner Mongolia Autonomous Region[J]. *Bulletin of Soil and Water Conservation*, 2023, 43(6): 324-335, 401.
- [3] 常学尚,常国乔.干旱半干旱区土壤水分研究进展[J]. *中国沙漠*, 2021, 41(1): 156-163.
CHANG X S, CHANG G Q. Advances in research and prospect on soil moisture in arid and semi-arid areas[J]. *Journal of Desert Research*, 2021, 41(1): 156-163.
- [4] PRICE R D, KING M D, DALTON J T. Earth science data for all: EOS and the EOS data and information system[J]. *Photogrammetric Engineering & Remote Sensing*, 1994, 60(3): 277-285.
- [5] HUANG B, ZHANG H K. Spatio-temporal reflectance fusion via unmixing: accounting for both phenological and land-cover changes[J]. *International Journal of Remote Sensing*, 2014, 35(16): 6213-6233.
- [6] MASELLI F. Definition of spatially variable spectral endmembers by locally calibrated multivariate regression analyses[J]. *Remote Sensing of Environment*, 2001, 75(1): 29-38.
- [7] BUSETTO L, MERONI M, COLOMBO R. Combining medium and coarse spatial resolution satellite data to improve the estimation of sub-pixel NDVI time series[J]. *Remote Sensing of Environment*, 2008, 112(1): 118-131.
- [8] GAO F, MASEK J, SCHWALLER M, et al. On the blending of the Landsat and MODIS surface reflectance: predicting daily Landsat surface reflectance[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(8): 2207-2218.
- [9] HILKER T, WULDER M A, COOPS N C, et al. A new data fusion model for high spatial-and temporal-resolution mapping of forest disturbance based on Landsat and MODIS[J]. *Remote Sensing of Environment*, 2009, 113(8): 1613-1627.
- [10] ZHU X L, CHEN J, GAO F, et al. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions[J]. *Remote Sensing of Environment*, 2010, 114(11): 2610-2623.
- [11] 程筱茜,洪友堂,陈劲松,等.基于 ESTARFM 的内陆湖泊遥感动态变化监测[J]. *国土资源遥感*, 2020, 32(3): 183-190.
CHENG X Q, HONG Y T, CHEN J S, et al. A study of the long-term remote sensing dynamic monitoring of inland based on ESTARFM[J]. *Remote Sensing for Land & Resources*, 2020, 32(3): 183-190.
- [12] GAO F, HILKER T, ZHU X L, et al. Fusing landsat and MODIS data for vegetation monitoring[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2015, 3(3): 47-60.
- [13] 李向龙,赵洪丽,赵红莉,等.极限学习机模型的土壤含水量反演研究[J]. *测绘科学*, 2021, 46(12): 91-97.
LI X L, ZHAO H L, ZHAO H L, et al. Soil water content inversion based on extreme learning machine model[J]. *Science of Surveying*

- and Mapping, 2021, 46(12): 91-97.
- [14] 张艳灵, 张定海, 宁婷, 等. 古尔班通古特沙漠南缘固定沙丘上土壤水分与地形-植被因子的关系[J]. 水土保持学报, 2023, 37(4): 258-266, 277.
ZHANG Y L, ZHANG D H, NING T, et al. Relationship between soil moisture and topography-vegetation factors on fixed dunes in the southern margin of the Gurbantunggut desert[J]. Journal of Soil and Water Conservation, 2023, 37(4): 258-266, 277.
- [15] 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.
- [16] 梁栋, 管青松, 黄文江, 等. 基于支持向量机回归的冬小麦叶面积指数遥感反演[J]. 农业工程学报, 2013, 29(7): 117-123.
LIANG D, GUAN Q S, HUANG W J, et al. Remote sensing inversion of leaf area index of winter wheat based on support vector machine regression[J]. Transactions of the Chinese Society of Agricultural Engineering, 2013, 29(7): 117-123.
- [17] ZHAO W, SANCHEZ N, LU H, et al. A spatial downscaling approach for the SMAP passive surface soil moisture product using random forest regression [J]. Journal of Hydrology, 2018, 563: 1009-1024.
- [18] 秦诗洁, 师登峰, 高伟达. 吉林南部不同耕作管理下土壤水分对降雨事件的响应[J]. 农业工程学报, 2022, 38(18): 147-155.
QIN S J, SHI D F, GAO W D. Responses of soil water content to rainfall events under different tillage management in Southern Jilin Province of China[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(18): 147-155.
- [19] 王思楠, 李瑞平, 吴英杰, 等. 基于环境变量和机器学习的土壤水分反演模型研究[J]. 农业机械学报, 2022, 53(5): 332-341.
WANG S N, LI R P, WU Y J, et al. Soil moisture inversion based on environmental variables and machine learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(5): 332-341.
- [20] ZHU X L, CHEN J, GAO F, et al. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions [J]. Remote Sensing of Environment, 2010, 114(11): 2610-2623.
- [21] 郭娇. 基于 ESTARFM 模型的西安地区植被覆盖度遥感估算与应用[D]. 西安: 西安科技大学, 2017.
GUO J. Remote sensing estimation and application of vegetation coverage in Xi'an based on ESTARFM model[D]. Xi'an: Xi'an University of Science and Technology, 2017.
- [22] 张森, 孔盼, 李雁华, 等. 基于极限学习机的土壤硝态氮预测模型研究[J]. 农业机械学报, 2016, 47(6): 93-99.
ZHANG M, KONG P, LI Y H, et al. Research on soil nitrate nitrogen prediction model based on extreme learning machine [J]. Transactions of the Chinese Society of Agricultural Machinery, 2016, 47(6): 93-99.
- [23] 李小雨, 贾科利, 魏慧敏, 等. 基于随机森林算法的土壤含盐量预测[J]. 干旱区研究, 2023, 40(8): 1258-1267.
LI X Y, JIA K L, WEI H M, et al. Prediction of soil salt content based on the random forest algorithm[J]. Arid Zone Research, 2023, 40(8): 1258-1267.
- [24] WANG X W, XIE H J, GUAN H D, et al. Different responses of MODIS-derived NDVI to root-zone soil moisture in semi-arid and humid regions[J]. Journal of Hydrology, 2007, 340(1/2): 12-24.
- [25] GUO B B, ZHANG J, MENG X Y, et al. Long-term spatio-temporal precipitation variations in China with precipitation surface interpolated by ANUSPLIN[J]. Scientific Reports, 2020, 10(1): 81.
- [26] CHEN S, SHE D, ZHANG L, et al. Spatial downscaling methods of soil moisture based on multisource remote sensing data and its application[J]. Water, 2019, 11(7): 1401.
- [27] 刘素华, 韩宇平, 张仁华. 利用改进的 MOD16 模型估算区域蒸散发[J]. 农业工程学报, 2022, 38(12): 145-153.
LIU S H, HAN Y P, ZHANG R H. Estimating regional evapotranspiration by the improved Mod16 model[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(12): 145-153.
- [28] 丁丽华. 滨海盐渍土地区麦田土壤水分的微波遥感估测研究[D]. 泰安: 山东农业大学, 2019.
DING L H. Microwave remote sensing estimation of soil moisture in wheat field in coastal saline land area[D]. Taian: Shandong Agricultural University, 2019.
- [29] 张钧泳, 丁建丽, 谭娇. 基于 SVM 的绿洲荒漠交错带土壤水分与地下水埋深反演[J]. 农业机械学报, 2019, 50(3): 221-230.
ZHANG J Y, DING J L, TAN J. Inversion of soil moisture and shallow groundwater depth based on SVM in arid oasis-desert ecotone[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(3): 221-230.
- [30] 贺文君, 韩广轩, 颜坤, 等. 微地形对滨海盐碱地土壤水盐分布和植物生物量的影响[J]. 生态学杂志, 2021, 40(11): 3585-3597.
HE W J, HAN G X, YAN K, et al. Effects of microtopography on plant biomass and the distribution of both soil water and salinity in coastal saline-alkali land [J]. Chinese Journal of Ecology, 2021, 40(11): 3585-3597.
- [31] KOVACEVIC J, CVIJETINOVICZ, STANCIC N, et al. New downscaling approach using ESA CCI SM products for obtaining high resolution surface soil moisture[J]. Remote Sensing, 2020, 12(7): 1119.
- [32] 蔡亮红, 丁建丽. 基于变量优选和 ELM 算法的土壤含水量预测研究[J]. 光谱学与光谱分析, 2018, 38(7): 2209-2214.
CAI L H, DING J L. Prediction for soil water content based on variable preferred and extreme learning machine algorithm [J]. Spectroscopy and Spectral Analysis, 2018, 38(7): 2209-2214.
- [33] 尉毓姣, 朱琳, 曹鑫宇, 等. 南京地区蒸散发降尺度研究——基于增强型时空自适应反射融合模型[J]. 生态学报, 2022, 42(15): 6287-6297.
WEI Y J, ZHU L, CAO X Y, et al. A downscaling study of evapotranspiration in Nanjing based on the ESTARFM model [J]. Acta Ecologica Sinica, 2022, 42(15): 6287-6297.
- [34] 常军霞, 马海霞, 张佰林, 等. 安家沟流域不同土地利用方式水土流失对影响因素变化的响应[J]. 草原与草坪, 2023, 43(6): 73-80.
CHANG J X, MA H X, ZHANG B L, et al. Response of soil and water loss to changes of influencing factors under different land use patterns in Anjiagou watershed[J]. Grassland and Turf, 2023, 43(6): 73-80.