

DOI:10.13870/j.cnki.stbcb.2026.01.016 CSTR:32310.14.stbcb.2026.01.016

甄天乐,李继峰,薛澳亚,等.基于Sentinel-2A数据的河北坝上农田土壤风蚀可蚀性[J].水土保持学报,2026,40(1):392-404.

ZHEN Tianle, LI Jifeng, XUE Aoya, et al. Estimation of soil wind erodibility in farmland of bashang region in Hebei based on sentinel-2A data[J].

Journal of Soil and Water Conservation, 2026, 40(1):392-404.

基于Sentinel-2A数据的河北坝上农田土壤风蚀可蚀性

甄天乐^{1,2,3}, 李继峰^{1,2,3}, 薛澳亚^{1,2,3}, 李慧茹^{1,3},

郭中领^{1,2,3}, 常春平^{1,2,3}, 王仁德⁴, 安晨宇¹

(1.河北师范大学地理科学学院,石家庄 050024; 2.河北省环境变化遥感识别技术创新中心,石家庄 050024;
3.河北省环境演变与生态建设重点实验室,石家庄 050024; 4.河北省科学院地理科学研究所,石家庄 050011)

摘要: [目的] 为探究裸露农田土壤风蚀可蚀性的遥感光谱特征及遥感估算方法。[方法] 选取张家口市康保县为研究区,基于裸露农田表层样品的实测数据,提取Sentinel-2A的原始光谱反射率及倒数、对数变换的光谱反射率,利用随机森林(RF)、支持向量机(SVM)、偏最小二乘法(PLSR)和BP神经网络(BPNN)等4种机器学习模型对土壤风蚀可蚀性(EF)进行估算建模。[结果] 1)研究区裸露农田反射率整体偏低,反射率倒数和对数变换可增强影响EF的土壤理化性质的光谱响应能力,B1、B2、B8、B10和B11等波段可作为EF估算的敏感波段。2)RF、SVM、PLSR、BPNN等模型对EF估算精度随特征变量的增加趋于稳定,RF模型在较少特征变量条件下实现最佳估算效果, R^2 为0.836, RMSE为0.041。3)研究区裸露农田土壤EF值主要为0.7~0.9,占农田面积的87%以上,表明研究区裸露农田土壤抗风蚀能力较弱。[结论] 基于Sentinel-2A数据及机器学习模型能够有效估算裸露农田的土壤风蚀可蚀性,可为农田土壤风蚀灾害评估及防治提供技术支持。

关键词: 土壤风蚀; 风蚀可蚀性; 机器学习; 遥感估算

中图分类号:S157.1 文献标识码:A 文章编号:1009-2242(2026)01-0392-13

Estimation of Soil Wind Erodibility in Farmland of Bashang Region in Hebei Based on Sentinel-2A Data

ZHEN Tianle^{1,2,3}, LI Jifeng^{1,2,3}, XUE Aoya^{1,2,3}, LI Huiru^{1,3}, GUO Zhongling^{1,2,3},

CHANG Chunping^{1,2,3}, WANG Rende⁴, AN Chenyu¹

(1.School of Geographical Sciences, Hebei Normal University, Shijiazhuang 050024, China; 2.Hebei Technology Innovation Center for Remote Sensing Identification of Environmental Change, Shijiazhuang 050024, China; 3.Hebei Key Laboratory of Environmental Change and Ecological Construction, Shijiazhuang 050024, China; 4.Institute of Geographical Sciences, Hebei Academy of Sciences, Shijiazhuang 050011, China)

Abstract: [Objective] This study aims to investigate the remote sensing spectral characteristics of soil wind erodibility and remote sensing estimation methods in bare farmland. [Methods] Kangbao County in Zhangjiakou City was selected as the study area. Based on the measured data of surface soil samples from bare farmland, original spectral reflectance, reciprocal reflectance, and logarithmically transformed reflectance of Sentinel-2A were extracted. Four machine learning models-random forest (RF), support vector machine (SVM), partial least squares regression (PLSR), and backpropagation neural network (BPNN)-were employed to estimate and model the soil wind erodibility factor (EF). [Results] 1) The overall reflectance of bare farmland in the study area was relatively low. Reciprocal and logarithmic transformations of reflectance enhanced the spectral response to soil physicochemical properties influencing EF. Bands B1, B2, B8, B10, and B11 could serve as sensitive bands for

收稿日期:2025-06-30 修回日期:2025-08-28 录用日期:2025-09-25 网络首发日期(www.cnki.net):2025-10-17

资助项目:国家自然科学基金项目(41901001,42271002,42201002);河北省水利厅委托项目(2023-64);省部合作项目(2023ZRBSHZ006)

第一作者:甄天乐(2000—),男,硕士研究生,主要从事遥感应用与土壤风蚀防治研究。E-mail:zhentianle123@163.com

通信作者:李继峰(1987—),男,博士,副教授,主要从事水土保持与荒漠化防治研究。E-mail:lijifeng@hebtu.edu.cn

http://stbcb.alljournal.com.cn

EF estimation. 2) The estimation accuracy of EF by the RF, SVM, PLSR, and BPNN models tended to stabilize with the increase in feature variables. The RF model achieved the best estimation performance with fewer feature variables, yielding an R^2 of 0.836 and a root mean square error (RMSE) of 0.041. 3) The EF values of bare farmland soil in the study area were mainly concentrated between 0.7 and 0.9, accounting for more than 87% of the total farmland area, indicating that the farmland soil in the study area had relatively weak resistance to wind erosion. [Conclusion] The combination of Sentinel-2A data and machine learning models enables effective estimation of soil wind erodibility in bare farmland, providing technical support for the assessment and prevention of wind erosion disasters in farmland.

Keywords: soil wind erosion; soil wind erodibility factor; machine learning; remote sensing estimation

Received: 2025-06-30

Revised: 2025-08-28

Accepted: 2025-09-25

Online(www.cnki.net): 2025-10-17

土壤风蚀是风力作用导致表土物质脱离原位置的过程,其发生与发展受风力、土壤及地表粗糙元等因子影响。土壤风蚀可蚀性指风蚀过程中土壤对风力引起的剥离和搬运的敏感程度,是衡量区域土壤风蚀发生潜力的重要指标,也是土壤风蚀量准确评估和土壤风蚀防治技术研发的关键参数。作为表征土壤抵抗风力侵蚀能力的综合指标,土壤风蚀可蚀性受土壤颗粒组成、可蚀性颗粒含量、团聚体稳定性、有机质、碳酸钙等土壤理化性质影响^[1-3]。传统土壤风蚀可蚀性研究方法主要利用野外实地采样和室内分析,通过测定土壤理化性质表征土壤风蚀可蚀性,但随着土壤风蚀研究时空分辨率的提升,传统土壤可蚀性研究方法的局限性也愈发显现。首先,土壤风蚀可蚀性受土壤类型、地形、气候等多种自然因素和人类活动的影响而呈显著的空间异质性,而野外采集的有限样本点仅能反映野外调查区域及周边小范围的土壤风蚀可蚀性特征,难以代表调查区以外区域的土壤风蚀可蚀性。其次,土壤风蚀是随土壤风蚀过程、气候条件变化而变化的动态参数,而野外采样工作通常只能获取特定时刻的土壤风蚀特征,难以监测土壤风蚀不同时间尺度的变化。因此,为深入理解风蚀机制、提高风蚀模型预报精度、精准制定土壤风蚀防治措施,必须拓展面向区域的高时空分辨率土壤风蚀可蚀性研究方法。

近年来,随着遥感技术的不断进步,土壤粒径组成、土壤有机质、土壤碳酸钙等土壤理化性质在不同反射率区间内呈较大的光谱特征差异。作为影响土壤风蚀可蚀性的主要因素之一,土壤粒径组成对土壤光谱特征有着重要影响,不同土壤粒径在光谱特征中呈现明显差异。黏粒粒径细小,光谱曲线吸收特征明显,在可见光波段(400~700 nm)反射率较低,但在近红外波段(700~1 300 nm)和短波红外(1 300~2 500 nm)波段反射率较高^[4],组成黏粒的

黏土矿物具有较高的水分吸附能力,在近红外边缘反射率出现一定下降^[5]。粉粒反射率介于黏粒与砂粒间,在可见光波段高于黏粒,但低于砂粒;受粒径和矿物组成的综合影响,其在红外波段反射率中等,吸收峰较弱且分散^[6],受土壤水分影响,粉粒在短波红外 1 400、1 900 nm 附近呈一定的吸收特征^[7-8]。砂粒主要由石英组成,含有硅酸盐、碳酸盐等矿物成分,砂粒光谱曲线较为平坦,无明显的吸收峰^[9-11],在可见光、近红外及短波红外区未呈明显吸收带,而在热红外区域其光谱特征具有一定波动^[12]。有机质作为土壤重要成分之一,在可见光波段(400~700 nm)反射率较低,尤其在蓝、绿波段呈较强吸收效应^[13],随着土壤有机质的增加光谱反射率呈下降趋势,尤其是在 400~1 320 nm 波段范围内,土壤有机质与光谱反射率呈明显负相关^[14-15]。土壤的光谱反射率明显随着碳酸钙质量分数的升高而升高^[16],由于碳酸钙的振动,土壤碳酸钙在可见光与近红外区域呈明显的吸收特征^[17],同时,在经过温度变化后的土壤碳酸钙光谱特征峰形基本不变,表明土壤碳酸钙的光谱特征较为稳定,受外界因素的影响较小^[18]。利用遥感技术估算土壤理化性质的研究为土壤风蚀可蚀性的遥感估算提供基础,使得获得较大空间尺度高时空分辨率的土壤风蚀可蚀性成为可能,但仍缺乏面向土壤风蚀研究的半干旱地区土壤可蚀性遥感估算研究。

目前,关于土壤属性制图建模的方式主要为线性建模与非线性建模^[19-20]。线性建模通过权重系数能够直接反映变量与目标变量间的关系^[21],同时,其模型参数较少,训练与计算速度较快,但线性模型难以捕捉复杂的非线性特征,且对异常值异常敏感,数据极值对估算建模影响较大,不利于模型的稳定性^[22-23],导致估算精度受限。随机森林^[24]、支持向量机^[25]、偏最小二乘法^[26]、BP 神经网络^[27]等非线性模

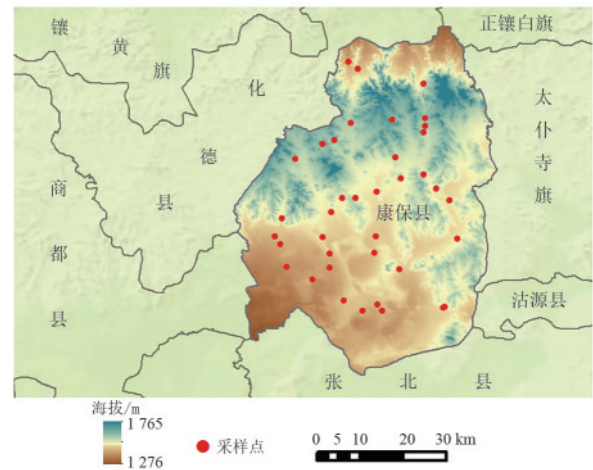
型可自动学习复杂的非线性关系,通过一定的数据训练,减小极端异常值对整体模型的稳定性影响^[28],结合投票或加权等多种集成方式显著增加估算精度。该方法为土壤风蚀可蚀性的空间估算与制图提供较好的方法支撑,可为土壤风蚀可蚀性遥感估算提供借鉴,但不同方法对土壤风蚀可蚀性遥感估算的精度影响仍需进一步评估。

综上所述,为克服传统土壤风蚀可蚀性研究方法难以满足当前土壤风蚀研究的需求,为建立适用于大尺度范围内高时空分辨率土壤风蚀可蚀性的遥感估算方法,本研究通过实地采集土壤样品,测定其理化性质并计算土壤风蚀可蚀性,结合 Sentinel-2A 多光谱遥感数据,分析土壤风蚀可蚀性与不同波段光谱特征间的响应关系,在此基础上,筛选出对土壤风蚀可蚀性具有敏感性的特征波段,评估 4 种机器学习回归方法在不同特征变量输入条件下的土壤风蚀可蚀性的遥感估算精度,以确定对土壤风蚀可蚀性遥感估算的最优模型及参数,研究结果可为实现高时空分辨率下的土壤风蚀动态监测提供新的方案与技术支撑。

1 材料与方法

1.1 研究区概况

研究区位于河北省张家口市康保县(41°25′24″~42°08′57″N, 114°11′21″~114°55′57″E)(图 1),平均海拔 1 450 m。该区域属温带大陆性季风气候,根据 1991—2020 年气象统计数据,康保县年平均降水量为 345.9 mm,最大和最小年降水量分别为 534.5、142.6 mm,7—9 月降水占全年降水量的 81.6%。年平均气温为 2.5℃,最高气温为 30.7℃,最低气温为 -33.6℃,无霜期为 92 d。多年平均蒸发量高达 1 772.6 mm,常年主导风向为西北风,平均风速 2.99 m/s,年平均大风日数为 40 d。土壤以栗钙土为主,质地松散,抗侵蚀能力低。研究区土地类型主要为农田、草地及林地,其中农田作物类型以粮食作物为主、经济作物为辅,粮食作物主要为春小麦(spring wheat)、莜麦(wheat)、土豆(potato),在作物收获完成后习惯于在秋季或者早春时节对农田进行翻耕作业,该传统做法导致研究区内大面积的农田翻耕后裸露无遮挡,而恰逢冬春季节,坝上地区强风天气多发,在自然与人为等多种因素的影响下,该区域农田土壤风蚀问题尤为严重。同时,研究区位于中国北方风蚀区中部,是京津冀风沙源治理工程、首都水源涵养功能区和生态环境支撑区的核心区域,开展研究区土壤风蚀可蚀性研究对区域生态文明建设具有重要意义。



注:基于自然资源部标准地图服务网站标准地图(审图号:GS(2022)4309号)制作,底图边界无修改。

图 1 研究区位置及采样点

Fig. 1 Location of the study area and sampling sites

1.2 数据来源

1.2.1 野外样品采集与分析 根据前期调查,研究区播种普遍集中在 5 月下旬、6 月上旬,为减少作物残茬、植被等因素对遥感影像中土壤光谱特征影响,于 2020 年 5 月下旬开展野外调查及采样工作,该时期农作物尚未播种,采样工作均在地表性质较为均一的较大裸露农田进行,采样点周围无林地、水体等遮挡与干扰,能够最大程度保留裸土的光谱信息,降低作物残茬等地表覆盖物等非土壤因素对遥感反射率的干扰。采样点设置于裸露农田内部,在 10 m×10 m 范围内随机采集 3 个平行样品,使用自制土壤取样器对裸露农田表层 0~1 cm 的土壤进行采集^[29],取样面积为 0.16 m²,样品重量为 1.0 kg,共采集 38 个样点。将野外采集的土壤样品带回实验室自然晾干,使用英国 Malvern Instruments Ltd 生产的 Mastersizer 3000 激光粒度分析仪进行粒度测定。依据乌登-温特沃思粒度分类标准进行土壤样品粒径统计分析。通过重铬酸钾-外加热法测定土壤样品有机质质量分数,土壤碳酸钙质量分数数据来自于世界土壤数据库(<https://gaez.fao.org/pages/hwsd>),土壤粒度、有机质质量分数均取 3 个平行样的平均值。

1.2.2 遥感影像获取及预处理 研究所使用的遥感数据为欧洲航天局(ESA)哥白尼计划(Copernicus Programme)中的哨兵 2 号(Sentinel-2)卫星遥感数据,该卫星系统由 Sentinel-2A 和 Sentinel-2B 2 颗相同卫星组成,双星重访周期为 5 d,共包含 13 个波段(B2、B3、B4、B8 空间分辨率为 10 m, B5、B6、B7、B8A、B10、B11 空间分辨率为 20 m, B1、B9、B10 空间分辨率为 60 m)。使用 Google Earth Engine(GEE, <https://code.earthengine.google.com/>)平台下载并

处理数据,影像采集时间为2020年5月下旬,与地面采样时间匹配,云量为0.02,GEE平台已对 Sentinel-2 的 L2A 级数据完成辐射定标、大气校正、几何校正等预处理,在此基础上,对 Sentinel-2A 数据进行去云处理、影像拼接、矢量裁切等操作,同时,为保证遥感影像空间分辨率与农田数据空间分辨率保持一致(农田数据来自 GEE 平台的 ESA/WorldCover/v100,空间分辨率为 10 m),将 Sentinel-2A 中的 B1、B5、B6、B7、B9、B10、B11、B12 波段重采样至 10 m 分辨率,重采样过程基于 GEE 平台,采用最邻近插值法进行处理,该方法能够在空间尺度转换过程中保持原始像元的光谱反射值不变,从而避免对定量估算结果造成影响。

$$EF = \frac{29.09 + 0.31Sa + 0.17Si + 0.33Sa/CI - 2.59OM - 0.95CaCO_3}{100}$$

式中:Sa 为砂粒质量分数,%;Si 为粉粒质量分数,%;CI 为黏粒质量分数,%;OM 为有机质;CaCO₃ 为碳酸钙质量分数,%。EF 为无量纲的量,为 0~1,EF 越接近 1,表示土壤越容易受到侵蚀;反之,EF 越接近 0,表示土壤对侵蚀的抵抗力越强。

1.3.2 估算模型选择 为全面评估不同建模方法在 EF 估算中的适用性,本次研究选用随机森林(RF)、支持向量机(SVM)、偏最小二乘法(PLSR)、BP 神经网络(BPNN)4 种建模方法用于 EF 的遥感估算。RF 回归通过对特征的随机子集进行多个决策树训练,并将每棵决策树预测结果的平均值作为最后的预测结果,该方法不仅降低过拟合风险,还可显著增强模型的稳定性和泛化能力。在建模过程中选取的参数为决策树数量、最大树深度及最大叶子节点数。SVM 回归是指在特征空间中寻找最优超平面,使多数样本点落在以超平面为中心的特定宽度“管道”内,通过最小化“管道”外样本点到“管道”的距离之和,有效减少超出误差范围的数据点对模型的影响,从而实现对复杂数据的精准预测。为提高模型的鲁棒性,选取惩罚系数与核函数类型作为模型的关键参数。PLSR 回归通过将自变量与因变量投影到低维空间,提取出最能解释自变量与因变量之间的协方差,从而实现降维和回归的双重目的。在此模型中选取潜变量个数作为建模过程中的主要参数。BPNN 回归由输入层、隐藏层、和输出层组成,并采用误差反向传播算法进行训练,最后通过不断调整权重和偏置,使模型输出结果接近期望值。主要参数包括隐藏层数、学习率及每层神经元个数。

RF 与 SVM 作为主流的机器学习算法,具有良

1.3 研究方法

1.3.1 土壤风蚀可蚀性计算 土壤风蚀可蚀性通常由土壤质地、土壤团聚体、有机质、土壤水分、土壤结皮及可蚀性颗粒质量分数等土壤理化性质决定,其评价指标与量化表达形式也存在多种,随着土壤风蚀模型的发展与完善,土壤风蚀可蚀性评价方法也由单因素量化评价指标逐步发展为多因素综合量化评价指标。本研究选用修正土壤风蚀模型^[30](RWEQ)的土壤可蚀性因子(EF)表征土壤风蚀可蚀性,该因子综合考虑土壤粒径组成、有机质、碳酸钙质量分数等重要土壤属性对土壤风蚀可蚀性的影响,并在河北坝上地区的土壤风蚀评估中得到广泛应用^[31]。EF 的计算公式为:

100

好的非线性建模能力和抗过拟合特性,常用于处理复杂遥感变量与土壤属性间的非线性关系;PLSR 为经典的多元统计方法,能够有效降维并提取关键光谱特征,适用于小样本情况下的稳定建模;BPNN 则具备较强的模式识别与自动学习能力,适合高维遥感数据建模。4 种建模方式涵盖从线性统计模型到典型机器学习及基础神经网络算法在内的多种建模方式。同时,通过将多个模型的估算结果进行对比,可有效减少单一算法在 EF 遥感估算中的偏差,增强 EF 遥感估算结果的稳定性与区域适用性。

1.3.3 特征波段筛选 为比较多光谱数据中不同波段特征及其数学变换形式与 EF 的关联程度,分别通过不同机器学习方法对多光谱数据不同波段的光谱反射率(ρ)、对数变换反射率($\ln \rho$)、倒数变换反射率($1/\rho$)与 EF 进行特征重要性评估。本文选择的 RF、SVM、PLSR、BPNN 等 4 种回归模型在输入因子重要性评价中存在显著差异。RF 通过构建多棵决策树对特征进行重要性评估,模型在训练过程中统计每个特征在所有决策树中作为分裂节点所导致基尼指数下降的总和,下降值越大,说明该特征在划分样本、提高估算精度中的贡献越显著,重要性越高;SVM 特征重要性评估则采用权重法,通过比较各特征对应权重的绝对值大小,可实现特征的重要性排序,该方法具有清晰的数学解释,适用于线性划分问题,且在高维小样本条件下表现稳定;PLSR 基于变量投影重要性对特征进行排序,变量投影重要性通过量化特征变量在建模过程中的参与度进行特征排序,参与度越大,重要性越高;BPNN 选取 Garson 算法对输入的特征变量进行评估,该方法通过解析输入至输出间的权重路径,对

每个输入变量在模型中的贡献进行量化,该方法可有效揭示神经网络内部对特征变量的响应机制,适用于复杂特征变量与土壤属性间非线性关系的建模与解释。

为实现不同模型间特征重要性排序结果的对比,将各模型计算所得的重要性评分进行归一化处理。特征重要性评分越接近1,说明该特征在模型中对预测结果影响更显著。根据特征重要性评分将光谱波段及其数字变换后的波段进行排序,并作为特征变量从高到低逐次输入估算模型。

1.3.4 模型验证与精度评估 为评估 RF、SVM、PLSR、BPNN 4 种回归模型对 EF 的估算精度,采用决定系数(R^2)与均方根误差(RMSE)对拟合结果进行评估验证。同时,为提升估算模型的泛化能力与稳定性,选用 K 折交叉验证对各个估算模型的参数进行调优与筛选,避免因样本划分偏差导致的过拟合或欠拟合问题。

2 结果与分析

2.1 土壤理化性质与土壤风蚀可蚀性

研究区采样裸露农田土壤类型为壤质砂土、砂壤土和粉质壤土,其中砂壤土占比最高(图2)。整体来看,因研究区土壤长期受风蚀影响,土壤质地粗化比较明显,土壤样品黏粒质量分数较低,平均为 0.86%,粉粒与砂粒质量分数较高,平均分别为 43.29%、56.06%。土壤样品有机质平均质量分数为 1.98%,整体质量分数较低,碳酸钙的平均质量分数为 5.79%。EF 为 0.52~0.94,平均值为 0.71,变异系数为 14.42%,表明研究区裸露农田表土风蚀可蚀性较高,抵抗土壤风蚀能力较差(表 1)。

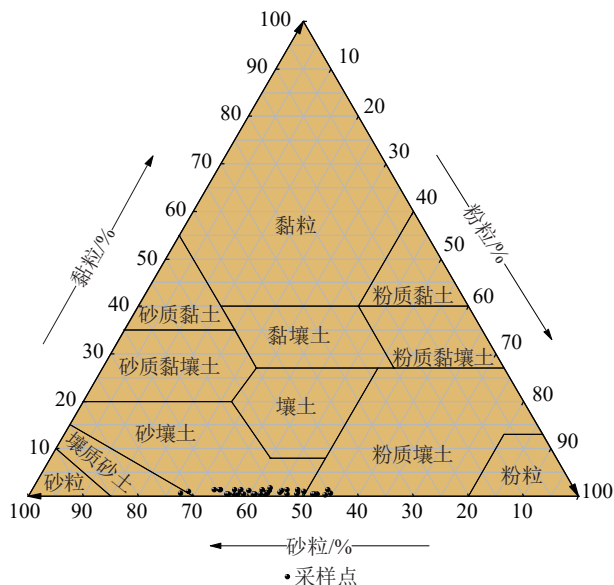


图 2 研究区裸露农田土壤样品质地

Fig. 2 Soil sample texture of bare farmland in the study area

表 1 研究区裸露农田土壤样品理化性质及 EF

Table 1 Physicochemical properties and EF of soil samples from bare farmland in the study area

项目	黏粉 砂/%	粉粒/ %	砂粒/ %	有机 质/%	碳酸 钙/%	EF
最大值	1.79	57.25	67.98	3.82	6.00	0.94
最小值	0.29	31.33	42.59	1.18	4.10	0.52
平均值	0.86	43.29	56.06	1.98	5.79	0.71
标准差	0.32	6.41	6.35	0.56	0.45	0.10
变异系数/%	37.73	14.81	11.32	28.26	7.90	14.42

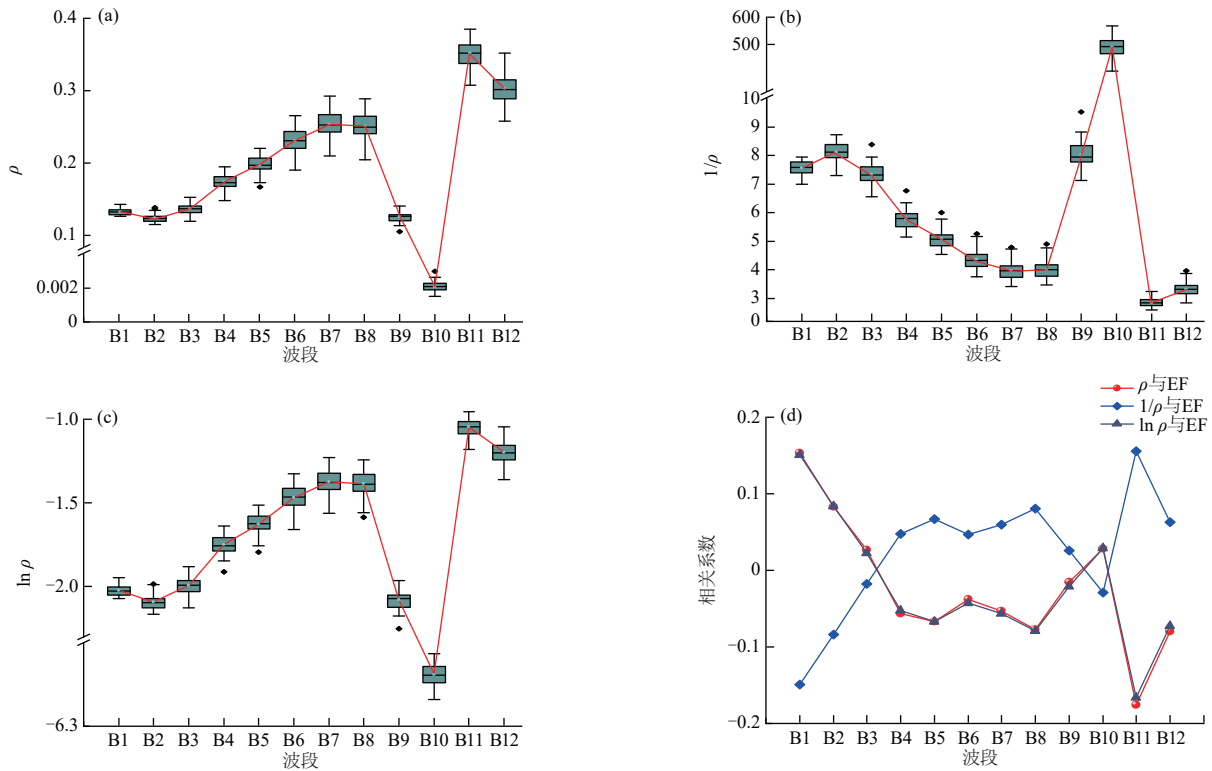
2.2 不同风蚀可蚀性土壤的光谱特征

根据裸露农田表土样品的采样点坐标明确采样点所在的农田地块,提取对应农田地块在 Sentinel-2A 数据中的光谱特征,并将 ρ 、 $\ln \rho$ 及 $1/\rho$ 分别与 EF 进行皮尔逊相关性分析(图 3)。整体上, ρ 、 $\ln \rho$ 及 $1/\rho$ 均呈较大的波动变化趋势,在 B1~B2 波段内, $1/\rho$ 与 $\ln \rho$ 呈平缓下降趋势, $1/\rho$ 呈增加趋势,有机质在可见光波段具有较强的吸收特性,高有机质质量分数土壤在该波段通常表现为较低的反射率^[32],表明土壤样品在 B1~B2 波段内光谱信息主要受有机质质量分数影响。在 B2~B7 波段内, ρ 、 $\ln \rho$ 随波长增加而增加,且增长速率较快, $1/\rho$ 随波长增加而下降,下降速率较快,其主要原因为碳酸钙等矿物成分在近红外波段的特征吸收,导致光谱反射率随碳酸钙质量分数增加呈上升趋势^[33]。在 B7~B8 波段内, ρ 、 $\ln \rho$ 及 $1/\rho$ 变化均较平稳;在 B8~B12 波段内, ρ 、 $\ln \rho$ 及 $1/\rho$ 均呈显著波动变化趋势, ρ 及 $\ln \rho$ 在 B8~B10 波段内呈陡降趋势,且在 B10 波段达到反射率最低值,在 B10~B11 波段内呈陡增趋势,且在 B11 波段达到反射率最高值,在 B10~B12 波段内呈平缓下降趋势,变化较为平缓; $1/\rho$ 在 B8~B10 波段内呈陡增趋势,且在 B10 波段达到反射率最高值,在 B10~B11 波段内呈陡降趋势,且在 B11 达到最低值,在 B10~B12 波段内呈平缓上升趋势,表明 B8~B12 波段对土壤粒径具有较高敏感性。短波红外波段的光谱特征能够有效反映土壤结构的稳定性,与 EF 的空间分异特征密切相关。由图 3 可知,B1、B2、B8、B10、B11 波段的光谱反射率呈明显的波动变化,表明 4 个波段对土壤风蚀可蚀性的响应较为敏感,是 EF 估算的关键光谱窗口。

土壤样品不同光谱特征与 EF 相关性在不同波长范围内具有一定差异, ρ 、 $\ln \rho$ 与 EF 在可见光 B1~B3 波段内呈正相关,相关系数逐渐降低;在近红外 B4~B9 波段内呈负相关,相关系数呈波动变化趋势;在短波红外 B10~B12 波段,相关系数呈下降后上升趋势,其中 B11 波段与 EF 的呈较大负相

关,主要原因为 B11 波段与黏粒质量分数相关性较高,黏粒成分在土壤团聚体构成中起到胶结作用,可降低 EF 值; $1/\rho$ 与 EF 在 B1~B3 波段内呈负相关,相关系数逐渐上升,在 B4~B9 波段内呈正相关,相关系数呈波动变化趋势,在 B10~B12 波段相关系数呈先上升后下降趋势。土壤可蚀性的光谱

特征明确 Sentinel-2A 数据在 EF 估算中的适用性,其中, B1、B2、B10、B11、B12 波段因显著的相关性特征可作为主要特征波段,可见光-近红外波段组合可有效表征土壤有机质与碳酸钙的差异,而短波红外波段对黏粒的敏感性则为 EF 估算提供补充信息。



注:箱体的上下边缘为分位数,箱体实线为中线,圆形平均值,菱形为异常值,箱体外的上下短线为最大值最小值,红线为平均值连接线。

图 3 研究区裸露农田土壤样品光谱特征

Fig. 3 Spectral characteristics of soil samples from bare farmland in the study area

2.3 光谱特征重要性筛选

4种机器学习模型的特征重要性对比,揭示不同光谱变换方法对EF估算的影响(图4)。在RF模型与PLSR模型中,倒数变换后的第B11波段和第B6波段对EF预测贡献最高;而在SVM模型与BPNN模型中,原始光谱的B10波段和B2波段重要性更为显著。倒数变换和对数变换光谱特征在前20个重要特征中占比达75%,其中,短波红外波段B11的倒数变换显著强化黏粒吸收特征,可见光-近红外波段B6的对数变换凸显碳酸钙的成分响应,表明光谱变换可有效增强模型对土壤理化特性的敏感性。研究进一步验证,光谱变换可增强黏粒吸收、有机质反射等波段的响应特征,能够克服原始光谱的信息冗余性,提升模型鲁棒性。不同机器学习模型对光谱特征的差异性筛选,表明利用机器学习估算EF可以综合利用光谱变换的优势,以实现区域尺度EF的高精度动态监测。

2.4 不同机器学习的土壤可蚀性估算

根据不同模型对光谱特征重要程度的筛选结果,将光谱特征变量按照重要性从大到小依次逐渐加入到RF、SVM、PLSR、BPNN等4种回归模型中。表明RF、SVM、PLSR和BPNN的 R^2 均呈前期迅速上升、后期逐渐稳定的两阶段变化特征(图5)。RF在光谱特征数量达12h, R^2 达到最大值0.836, RMSE为0.041,后续 R^2 波动幅度 $<5\%$; SVM在光谱特征数量达到13h, R^2 达到最大值0.777, RMSE为0.048,后续 R^2 波动较小; PLSR在光谱特征数量达到17h, R^2 逐渐趋于稳定,在光谱特征数量增加至20h, R^2 达到最大值0.647; BPNN在光谱特征数量达到16h, R^2 趋于稳定,当光谱特征数量增加至17h, R^2 达到最大值0.515, RMSE为0.071(图6)。整体上看,RF模型所需光谱特征数量最少,仅12个光谱特征即可达到较高拟合程度,且拟合结果与样品实测结果的偏差较

小, SVM 次之, 当光谱特征数量较少的情况下, BPNN 模型的拟合程度高于 PLSR 模型, 但当光谱

特征数量超过 15 h, PLSR 模型的拟合程度超过 BPNN 模型。




图 4 不同模型的光谱特征重要性

Fig. 4 Importance of spectral features of different models

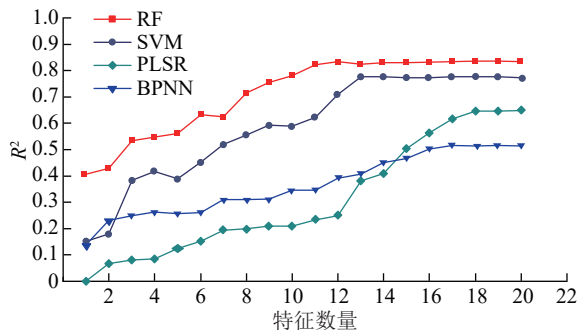


图 5 不同模型的光谱特征数量与 R^2 关系

Fig. 5 Relationship between number of spectral features and R^2 across different models

根据不同模型预测的 EF 与真实值比较结果, RF、PLSR、BPNN 等模型在对 EF 进行预测时, 预测值的极大值与极小值相对真实值均偏小; SVM 模型中对于极小值预测偏大, 极大值预测偏小。其主要由不同模型的算法特性所致, RF 取多棵决策树的平均值作为最后结果, 其集成策略使得极端值的影响变小; PLSR 作为线性回归模型, 受到数据正态分布的影响, 对极值的拟合能力不足; BPNN 在反向传播过程中, 深层次的网络出现梯度指数级衰减现象, 从而导致网络参数难以通过极值样本对预测值进行调整, 导致极值预测值趋于均值化。

2.5 土壤风蚀可蚀性空间分布特征

基于不同机器学习估算模型对研究区裸露农田表土 EF 的估算结果(图 7), 不同模型估算的 EF 主要为 0.7~0.9(图 8), 主要集中在研究区的中、南部, 可达研究区农田面积的 87% 以上, 其他可蚀性范围的面积相对较小。该结果与冯哲等^[34]在康保春季翻耕农田试验中获得的土壤可蚀度数据基本一致, 同时与李玄姝等^[35]在康保地区观测到的翻耕农田总输沙量较大的研究结论相吻合, 从侧面验证本研究 EF 估算结果的可靠性。

RF 与 BPNN 估算结果显示, 裸露农田 EF 值主要为 0.7~0.8, 该 EF 等级范围的农田面积分别为 428.21、554.53 km², 分别约占农田面积的 54%、70%, 其他 2 种模型估算的该 EF 等级范围的农田面积相对较小。SVM 与 PLSR 估算结果中, EF 值主要集中在 0.8~0.9, 该 EF 等级范围农田面积分别为 492.47、468.92 km², 分别约占农田面积的 62.1%、59.2%(表 2)。RF 与 PLSR 估算的 EF 为 0.6~0.7 的面积相对其他 2 种模型较高, 但整体上, 该 EF 等级范围农田面积不到研究区农田面积的 11.5%, 其他 EF 等级范围农田面积不足 5%。整体上看, 土壤风蚀可蚀性空间分布表明研究区裸露农田表土 EF 较高, 整体上抵抗风力侵蚀的能力较弱。

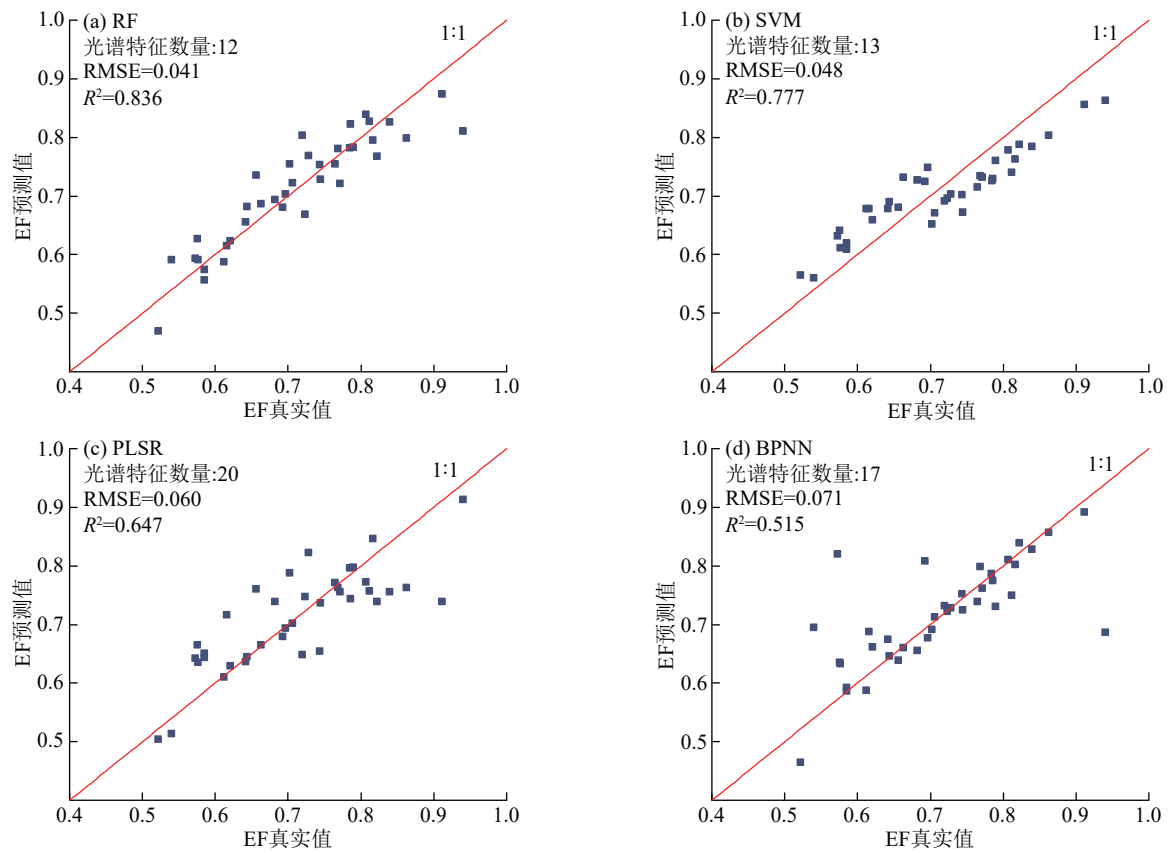


图 6 不同模型预测的 EF 与真实值

Fig. 6 Comparison between predicted and actual EF values in different models

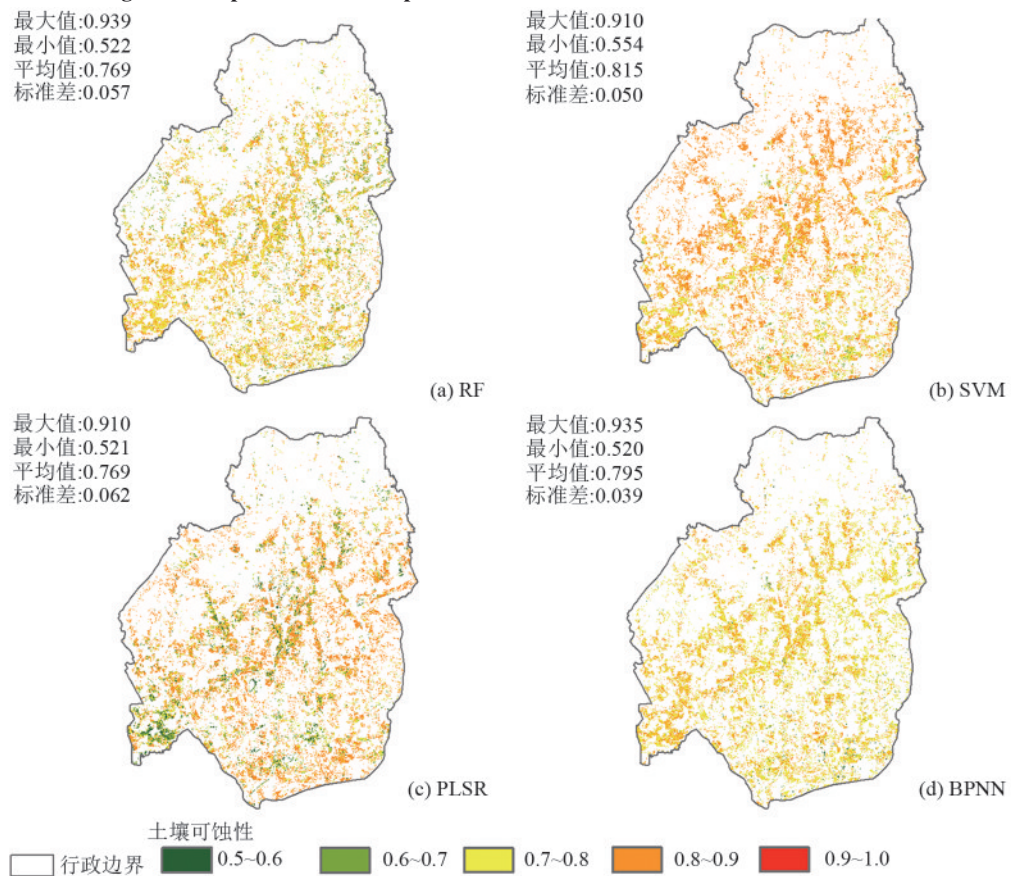


图 7 不同模型估算的 EF 空间分布

Fig. 7 Spatial distribution of EF estimated by different models




图 8 不同模型的 EF 等级耕地面积分布

Fig. 8 Distribution of cropland area by EF grade in different models

本次研究中所采用的 4 种 EF 估算模型在研究区 EF 空间分布的估算中表现出较高一致性,但在局部区域的估算中仍存在一定差异,其差异主要源于实测 EF 值本身的空间差异性,以及不同估算模型在建模机理上的差别。首先,受研究区不同地区土壤粒径组成、有机质质量分数及碳酸钙质量分数等土壤属性空间差异影响,根据野外调查实测的 EF 值亦具有空间分布差异。同一地块不同位置的 EF 也并不相同,模型在训练过程中受到差异样本的影响,从而导致 EF 的空间估算结果产生差异。其次,各个估算模型的建模内核机理不同,是造成 EF 空间估算差异的主要原因。RF 通过将多棵决策树的结果的平均值作为最终输出值,能够有效捕捉变量间复杂的非线性关系,建模过程中个别极值对整体估算的影响较小,因此,在整体 EF 的估算中较为稳定;SVM 通过构建最大回归超平面进行建模,导致其对边界样本较为敏感,在 EF 极值部分估算时,结果更加集中;PLSR 侧重于特征变量间的线性相关性,对于非线性关系和局部差异的捕捉能力较弱,且受样本数值分布影响较大,导致其在极值区域的拟合效果不足;BPNN 通过学习输入层与输出层间复杂的非线性映射关系,能够有效捕捉数据中的细微特征变化,在局部区域的 EF 估算中表现出更稳定的效果。

表 2 研究区不同等级 EF 裸露农田面积分布

Table 2 Area distribution of bare farmland with different EF grades in the study area km²

EF	RF	SVM	PLSR	BPNN
0.5~0.6	9.99	0.09	43.07	7.52
0.6~0.7	89.49	16.15	73.98	13.86
0.7~0.8	428.21	283.76	206.50	554.53
0.8~0.9	264.62	492.47	468.92	216.62
0.9~1.0	0.26	0.01	0.000 1	0.000 5

3 讨论

3.1 土壤风蚀可蚀性影响因子的光谱反映

利用遥感数据对 EF 的估算结果主要受土壤粒径组成、有机质、碳酸钙质量分数等因素的影响,土壤属性与光谱反射率间往往呈非线性的关系,原始

反射率受到大气散射、土壤背景等多种因素的影响,导致原始光谱反射率集中在某一范围内,土壤属性光谱特征差异较小,直接基于原始光谱反射率建模效果有限。为减少外界因素对光谱的干扰,本研究将光谱反射率进行倒数变换、对数变换以增强 EF 估算过程中反射率低值区与高值区的敏感程度。由图 3 可知,土壤样品的光谱及对数变换反射率在可见光波段范围呈上升趋势,在红外波段呈剧烈波动起伏,在 B10 波段达到最低, B11 波段呈最高值,在短波红外波段呈下降趋势。光谱反射率的倒数变换在可见光波段范围内呈下降趋势,在红外波段 B10 与 B11 达到反射率最高值与最低值,在短波红外波段呈上升态势。

土壤可蚀性光谱特征与土壤属性具有密切关系。可见光波段反射率主要受到土壤有机质质量分数影响,土壤有机质质量分数与光谱反射率呈负相关,在 400~600 nm 土壤有机质质量分数与光谱反射率负相关性较小,但在 400~900 nm,其负相关性显著增强,且随着波长增加,土壤有机质质量分数差异造成光谱反射率呈极高值与极低值的分化^[36]。由于碳酸钙中的氢氧离子的影响^[37],土壤碳酸钙光谱特征在近红外波段反射率明显高于可见光波段反射率^[38],土壤碳酸钙质量分数与光谱反射率呈明显正相关,且在近红外波段反射率增长速度明显高于可见光反射率增长速度,因此,图 3 中 B10~B11 波段反射率增长速度明显高于 B3~B8。作为土壤的重要属性,土壤质地对光谱特征影响明显,整体上,随着土壤粒径减小,光谱反射率呈明显上升态势,且在 1 490、1 910、2 100 nm 呈明显吸收谷,在可见光波段范围内,粒径大小对光谱反射率差异影响较小,在红外波段范围内,粒径差异越大导致的光谱反射率差异越大,且在短波红外波段范围内出现多个吸收带,主要是黏土中的碳酸矿物造成的^[39],因此,在本研究在中在 B10~B11 波段反射率出现较大波动。在可见光波段范围内,黏粒、粉粒、砂粒光谱反射率差异较小,但随着波长增加,不同粒径土壤光谱反射率差异逐渐增大,粉粒在 400~2 400 nm 范围内反射率最高,砂粒在

400~2 000 nm 范围内反射率最低^[40],通过微分、倒数、平方根等数学变换可有效增强不同土壤粒径间的光谱特征差异^[41]。本研究采用倒数、对数变换方式与原始光谱反射率进行差异对比,提取表征EF的光谱特征,证明利用光谱反射率的数学变换在估算EF同样具有适用性。

3.2 机器学习对土壤风蚀可蚀性遥感估算的适用性

土壤属性与卫星遥感数据多呈非线性关系,作为土壤属性的综合指标,EF受土壤有机质、碳酸钙及土壤粒径组成等多种因素的影响,单纯依靠线性回归难以解决数据冗余、共线性等问题。对于受到多种风蚀因子影响的EF,线性模型的预测精度与泛化能力较差,难以满足未来高时空分辨率的土壤风蚀研究需求。与线性回归等传统方法相比,机器学习方法更能适应遥感数据源多样、维度高、冗余强的特点,在建模过程中较大程度捕捉土壤属性与遥感卫星间非线性特征。机器学习模型还具备较强的特征识别和变量选择能力,能够提升建模效率和可解释性。不同模型的特征重要性排序差异源于其算法原理的不同,RF通过多棵决策树进行平均集成对光谱倒数变换特征更加敏感;SVM通过核函数映射侧重原始光谱的线性特征;PLSR依赖协方差最大化原则捕捉线性相关特征;BPNN则通过反向传播优化权重,擅长挖掘特征间的复杂非线性关系。

本研究中基于特征重要性程度,将数学变换后特征变量依次输入回归模型进行估算建模。RF、SVM、PLSR、BPNN的内核原理的差异,导致不同回归模型在研究区裸露农田表土EF估算中呈一定差异性。RF回归模型通过对多棵决策树的结果进行平均集成,能够有效减少拟合结果的方差,对中值区的EF具有较强的拟合能力,但弱化样本中极大值与极小值的权重,降低极端值的预测精度;SVM回归模型通过核函数将数据映射到高维空间,对EF极大值与极小值预测精度相对较高;PLSR通过提取数据中的潜变量缩小EF高值的影响,导致预测的EF高值区域农田面积最小;BPNN受到隐藏节点对训练数据分布过度拟合的影响,导致模型对EF极大值的预测精度下降,导致预测的EF值高区农田面积较低。RF、SVM、PLSR、BPNN在预测EF极值中有一定的差异,但是对EF中间值预测结果类似,验证EF在0.7~0.9中值区间范围内估算结果鲁棒性。

3.3 土壤可蚀性估算的局限性分析及研究前景

本次研究主要针对康保裸露农田进行EF的估算,在野外采样调查中所选择的样本点为裸露农田,所使用的遥感数据也为农田播种前的翻耕时期获得

的,以减少植被、作物残茬等外在因素对遥感光谱信息的干扰,从而获得更真实的土壤光谱信息并用EF估算。然而,在实际野外调查中,研究每年10月底至翌年5月底的风蚀易发生季节,农田地表并非完全裸露,往往有不同程度的作物残茬、杂草及砾石等地表覆盖物,覆盖物显著影响多光谱对土壤信息的响应,不利于EF估算中敏感波段的探寻,进而影响EF估算的准确性与区域适用性。因此,为准确获得干旱、半干旱地区风蚀季农田土壤风蚀可蚀性,需要剥离地表残留覆盖物对光谱信息的影响。与多光谱数据相比,高光谱遥感具有波段连续、光谱分辨率高等显著优势^[42],能够更细致地捕捉土壤理化性质在不同波段下的微弱光谱响应差异,尤其适用于提取土壤粒径组成、有机质质量分数、碳酸钙等关键影响因子的光谱特征,在未来农田土壤EF遥感估算研究中可引入高光谱数据,进一步提取EF影响因子的光谱特征,应注重高光谱与多光谱数据的融合应用,从而提高EF估算模型的稳定性与泛化能力。

4 结论

1)以康保地区裸露农田为研究对象,基于Sentinel-2A多光谱遥感数据及实测EF样本,系统评估倒数、对数等光谱变换在EF估算的增强作用,识别出B1、B2、B8、B10、B11等波段在多种变换下对EF具有较高敏感性,是EF估算的特征波段。

2)RF、SVM、PLSR和BPNN等不同机器学习模型在特征数量和估算精度上具有明显差异,各模型估算精度随特征变量的增加而趋于稳定,RF模型可在较少特征变量输入情况下实现对EF较好估算, R^2 最高为0.836, RMSE为0.041。

3)不同模型估算的研究区EF空间分布存在显著差异,研究区农田风蚀可蚀性为0.7~0.9,占农田面积的87%以上,主要分布于研究区中、南部,表明研究区农田土壤整体抵抗风力侵蚀能力较差。

参考文献:

- [1] 刘伟,邹学勇,刘博,等.1980—2016年中国北方风蚀气候侵蚀力的变化[J].地理科学,2024,44(4):703-710.
LIU W, ZOU X Y, LIU B, et al. Spatio-temporal variation of wind erosivity in the northern China from 1980 to 2016[J]. Geographical Science, 2024, 44(4):703-710.
- [2] 刘瑞娟,李继峰,冯哲,等.风蚀过程中翻耕农田土壤抗剪强度变化[J].水土保持学报,2022,36(4):112-120.
LIU R J, LI J F, FENG Z, et al. Changes in shear strength of ploughed farmland soil during wind erosion[J]. Journal of Soil and Water Conservation, 2022, 36(4):112-120.
- [3] 何超,王磊,郑粉莉,等.垄作方式对薄层黑土区坡面土

- 壤侵蚀的影响[J].水土保持学报,2018,32(5):24-28.
- HE C, WANG L, ZHENG F L, et al. Effects of ridge tillage on hillslope soil erosion in thin layer black soil region[J].Journal of Soil and Water Conservation,2018,32(5):24-28.
- [4] 聂磊超,曲柯莹,崔丽娟,等.不同粒径湿地土壤高光谱特征及碳氮磷含量反演模型研究[J].生态学报,2024,44(15):6618-6629.
- NIE L C, QU K Y, CUI L J, et al. Hyperspectral characteristics and inversion model of carbon, nitrogen, and phosphorus contents in wetland soil with different particle sizes[J].Acta Ecologica Sinica,2024,44(15):6618-6629.
- [5] 杨雪红.土壤粒径对土壤光谱特征的影响[J].科技信息,2010(25):390-391.
- YANG X H. Effect of soil particle size on soil spectral characteristics[J].Science and Technology Information,2010(25):390-391.
- [6] 李想,张永彬,刘明月,等.滨海湿地土壤质地高光谱估测模型对比分析[J].光谱学与光谱分析,2024,44(9):2568-2576.
- LI X, ZHANG Y B, LIU M Y, et al. Comparative analysis of hyperspectral estimation models for soil texture in coastal wetlands [J]. Spectroscopy and Spectral Analysis,2024,44(9):2568-2576.
- [7] 张雅梅,施梦月,王德彩,等.基于高光谱的土壤不同颗粒含量预测分析[J].土壤通报,2021,52(4):777-784.
- ZHANG Y M, SHI M Y, WANG D C, et al. Different soil particle contents prediction based on hyperspectral data[J].Chinese Journal of Soil Science,2021,52(4):777-784.
- [8] 李晨,张国伟,周治国,等.滨海盐土土壤水分的高光谱参数及估测模型[J].应用生态学报,2016,27(2):525-531.
- LI C, ZHANG G W, ZHOU Z G, et al. Hyperspectral parameters and prediction model of soil moisture in coastal saline [J]. Chinese Journal of Applied Ecology,2016,27(2):525-531.
- [9] SI Y T, CHONG D, TANG Z N. Inversion estimation of soil organic matter in Songnen Plain based on multi-spectral analysis[J].Land,2022,11(5):608-608.
- [10] YUE P, XIN L Z, HUAN J L, et al. Remote sensing inversion of soil organic matter by using the subregion method at the field scale[J].Precision Agriculture,2022,23(5):1813-1835.
- [11] 马创,申广荣,王紫君,等.不同粒径土壤的光谱特征差异分析[J].土壤通报,2015,46(2):292-298.
- MA C, SHEN G R, WANG Z J, et al. Analysis of spectral characteristics for different soil particle sizes[J].Chinese Journal of Soil Science,2015,46(2):292-298.
- [12] 李诗朦,包妮沙,刘善军,等.草原露天煤矿区土壤粒径分布及热红外辐射特征研究[J].地理与地理信息科学,2018,34(2):27-33.
- LI S M, BAO N S, LIU S J, et al. Study on the distribution of soil grain size and the characteristics of thermal infrared radiation in the prairie open-cast mine area[J].Geography and Geo-Information Science,2018,34(2):27-33.
- [13] 王世芳,宋海燕.土壤有机质可见-近红外反射光谱特性研究[J].中国农业科技导报,2024,26(7):183-188.
- WANG S F, SONG H Y. Study on characteristics of visible and near infrared reflectance spectra of soil organic matter [J]. Journal of Agricultural Science and Technology,2024,26(7):183-188.
- [14] 邓响,王君,陈守学,等.基于PCA-DBO-SVR的林地土壤有机质高光谱反演模型[J].光谱学与光谱分析,2025,45(2):569-583.
- DENG Y, WANG J, CHEN S X, et al. Hyperspectral inversion model of forest soil organic matter based on PCA-DBO-SVR [J]. Spectroscopy and Spectral Analysis,2025,45(2):569-583.
- [15] 吴奇涛,郑毅,李晓琳,等.基于ZY1E遥感影像的杞麓湖流域耕地土壤有机质含量预测[J].南方农业学报,2025,56(1):64-73.
- WU Q T, ZHENG Y, LI X L, et al. Prediction of soil organic matter content in cultivated land of Qilu Lake basin based on ZY1E remote sensing images [J]. Journal of Southern Agriculture,2025,56(1):64-73.
- [16] 林卡,李德成,刘峰,等.基于可见-近红外反射光谱的土壤碳酸钙含量与反演效果关系研究[J].土壤学报,2018,55(2):304-312.
- LIN K, LI D C, LIU F, et al. Study on relationship between soil calcium carbonate content and inversion effect based on visible near-infrared reflectance spectra [J].Acta Pedologica Sinica,2018,55(2):304-312.
- [17] 赵雪莱,何兴东,薛苹苹,等.土壤碳酸钙/有效磷化学计量特征对油蒿群落植物密度的影响[J].科学通报,2012,57(1):80-87.
- ZHAO X L, HE X D, XUE P P, et al. Effects of soil stoichiometry of the CaCO₃/available phosphorus ratio on plant density in *Artemisia ordosica* communities [J]. Chinese Science Bulletin,2012,57(1):80-87.
- [18] 王冬,马智宏,潘立刚,等.近红外光谱法定量测定小麦粉中的石灰类添加物的研究[J].光谱学与光谱分析,2013,33(1):69-73.
- WANG D, MA Z H, PAN L G, et al. Research on the quantitative determination of lime in wheat flour by near-infrared spectroscopy [J]. Spectroscopy and Spectral Analysis,2013,33(1):69-73.
- [19] 程治允,陈冬勤,朱玮玮,等.土壤有机质遥感反演研究进展与展望[J].农村经济与科技,2024,35(4):15-18.
- CHENG Z Y, CHEN D Q, ZHU W W, et al. Progress

- and prospects of remote sensing inversion research on soil organic matter[J]. *Rural Economy and Science-Technology*, 2024, 35(4):15-18.
- [20] 贾鲁净, 杨联安, 冀泳帆, 等. 卫星遥感反演土壤有机质研究进展[J]. *遥感信息*, 2023, 38(2):1-9.
JIA L J, YANG L A, JI Y F, et al. Review on inversion of soil organic matter using satellite remote sensing[J]. *Remote Sensing Information*, 2023, 38(2):1-9.
- [21] 林楠, 刘翰霖, 孟祥发, 等. 基于高光谱的黑土区土壤重金属含量估测[J]. *农业机械学报*, 2021, 52(3):218-225.
LIN N, LIU H L, MENG X F, et al. Hyperspectral estimation of heavy metal contents in black soil region[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(3):218-225.
- [22] YA N W, ZONG L P, GENG X Z, et al. Comparison of Sentinel 2A MSI and Landsat 8 OLI for soil organic matter inversion in southwestern Shandong Province, China[J]. *Geocarto International*, 2022, 37(25):8214-8229.
- [23] 钟聪, 李小洁, 何园燕, 等. 广西土壤有机质空间变异特征及其影响因素研究[J]. *地理科学*, 2020, 40(3):478-485.
ZHONG C, LI X J, HE Y Y, et al. Spatial variation of soil organic matter and its influencing factors in Guangxi, China[J]. *Geographical Science*, 2020, 40(3):478-485.
- [24] 陈超群, 戴慧敏, 冯雨林, 等. 基于Sentinel-2A的孙吴地区土壤有机质反演研究[J]. *物探与化探*, 2022, 46(5):1141-1148.
CHEN C Q, DAI H M, FENG Y L, et al. Sentinel-2A based inversion of the organic matter content of soil in the Sunwu area[J]. *Geophysical and Geochemical Exploration*, 2022, 46(5):1141-1148.
- [25] 韩唯, 陈晓燕, 陶婷婷. 三峡库区典型农业小流域土壤饱和导水率特征[J]. *水土保持通报*, 2024, 44(5):83-91.
HAN W, CHEN X Y, TAO T T. Characteristics of soil saturated hydraulic conductivity in typical agricultural small watershed of Three Gorges Reservoir area[J]. *Bulletin of Soil and Water Conservation*, 2024, 44(5):83-91.
- [26] 周伟, 谢利娟, 杨晗, 等. 基于高光谱的三江源区土壤有机质含量反演[J]. *土壤通报*, 2021, 52(3):564-574.
ZHOU W, XIE L J, YANG H, et al. Hyperspectral inversion of soil organic matter content in the Three-rivers Source region[J]. *Chinese Journal of Soil Science*, 2021, 52(3):564-574.
- [27] 国佳欣, 赵小敏, 郭熙, 等. 基于PLSR-BP复合模型的红壤有机质含量反演研究[J]. *土壤学报*, 2020, 57(3):636-645.
GUO J X, ZHAO X M, GUO X, et al. Inversion of organic matter content in red soil based on PLSR-BP composite model[J]. *Acta Pedologica Sinica*, 2020, 57(3):636-645.
- [28] WEI Z, JIE Y X, HAO R L, et al. Soil organic matter content prediction using Vis-NIRS based on different wavelength optimization algorithms and inversion models[J]. *Journal of Soils and Sediments*, 2023, 23(6):2506-2517.
- [29] 安晨宇, 王仁德, 周海涛, 等. 秋免耕对坝上地区农田风蚀及土壤理化性质的影响[J]. *中国沙漠*, 2022, 42(2):95-103.
AN C Y, WANG R D, ZHOU H T, et al. Effect of no-tillage in autumn on farmland wind erosion and soil properties in bashang district[J]. *Journal of Desert Research*, 2022, 42(2):95-103.
- [30] 郭中领. RWEQ模型参数修订及其在中国北方应用研究[D]. 北京: 北京师范大学, 2012.
GUO Z L. Improvement and application of RWEQ model in north China[D]. Beijing: Beijing Normal University, 2012.
- [31] 张莉, 李继峰, 常春平, 等. 风速分辨率对土壤风蚀模数计算结果的影响[J]. *中国沙漠*, 2022, 42(3):21-30.
ZHANG L, LI J F, CHANG C P, et al. Influence of spatial-temporal resolution of wind speed data on calculation result of soil wind erosion modulus[J]. *Journal of Desert Research*, 2022, 42(3):21-30.
- [32] 冷佳欣, 刘春红, 高丹. 土壤含水率对高光谱反演紫色土有机质含量的影响研究[J]. *土壤通报*, 2024, 55(6):1593-1604.
LENG J X, LIU C H, GAO D. Effect of soil water on organic matter content of purple soil by hyperspectral inversion[J]. *Chinese Journal of Soil Science*, 2024, 55(6):1593-1604.
- [33] 马赵扬, 杜昌文, 周健民. 土壤碳酸钙中红外光声光谱特征及其应用[J]. *光谱学与光谱分析*, 2012, 32(5):1255-1258.
MA Z Y, DU C W, ZHOU J M. Characterization of soil calcium carbonate using mid-infrared photoacoustic spectroscopy[J]. *Spectroscopy and Spectral Analysis*, 2012, 32(5):1255-1258.
- [34] 冯哲. 农田土壤风蚀可蚀性动态变化及其对风沙流的影响研究[D]. 石家庄: 河北师范大学, 2023.
FENG Z. Temporal change of soil wind erodibility and its impact for sand flux on farmlands[D]. Shijiazhuang: Hebei Normal University, 2023.
- [35] 李玄姝. 河北坝上不同耕作管理措施下农田土壤风蚀研究[D]. 石家庄: 河北师范大学, 2013.
LI X S. The research of farmland soil erosion under different tillage measures in bashang, Hebei Province[D]. Shijiazhuang: Hebei Normal University, 2013.
- [36] 冉思, 丁建丽, 葛翔宇, 等. 基于稀疏网络的可见光/近红外反射光谱土壤有机质含量估算[J]. *激光与光电子学进展*, 2020, 57(24):389-397.
RAN S, DING J L, GE X Y, et al. Estimation method of VIS-NIR spectroscopy for soil organic matter based on

- sparse networks[J]. *Laser and Optoelectronics Progress*, 2020, 57(24):389-397.
- [37] 张婷婷. 基于PLS模型的农业土壤成分高光谱遥感反演研究[D]. 长春: 吉林大学, 2010.
ZHANG T T. Partial least squares modeling of hyperspectral remote sensing for mapping agricultural soil properties[D]. Changchun: Jilin University, 2010.
- [38] 吴倩, 姜琦刚, 史鹏飞, 等. 基于高光谱的土壤碳酸钙含量估算模型研究[J]. *国土资源遥感*, 2021, 33(1):138-144.
WU Q, JIANG Q G, SHI P F, et al. The estimation of soil calcium carbonate content based on hyperspectral data [J]. *Remote Sensing for Natural Resources*, 2021, 33(1): 138-144.
- [39] 聂磊超, 彭辉, 赵欣胜, 等. 浙江百山祖国家公园土壤养分含量高光谱预测模型应用探讨[J]. *陆地生态系统与保护学报*, 2022, 2(3):9-17.
NIE L C, PENG H, ZHAO X S, et al. Application of hyperspectral prediction model for soil nutrient content in Baishanzu National Park, Zhejiang Province [J]. *Terrestrial Ecosystem and Conservation*, 2022, 2(3):9-17.
- [40] 司海青, 姚艳敏, 王德营, 等. 不同颗粒大小对高光谱估算土壤有机质含量的影响[J]. *中国农学通报*, 2015, 31(18):173-178.
SI H Q, YAO Y M, WANG D Y, et al. Influence of soil particle size on the estimate of soil organic matter by hyperspectral spectroscopy [J]. *Chinese Agricultural Science Bulletin*, 2015, 31(18):173-178.
- [41] 汤娜, 张新乐, 刘焕军, 等. 土壤有机质与水分反射光谱响应特征综合作用模拟[J]. *土壤通报*, 2013, 44(1):72-76.
TANG N, ZHANG X L, LIU H J, et al. Synthesis simulation of correlation characteristics between organic matter and moisture reflectance spectra [J]. *Chinese Journal of Soil Science*, 2013, 44(1):72-76.
- [42] 吴建高, 汪泓, 张磊, 等. 基于ResNet-MHAM模型的山区耕地土壤有机质含量高光谱反演[J]. *环境科学*, 2025, 46(4):2313-2324.
WU J G, WANG H, ZHANG L, et al. Hyperspectral inversion of soil organic matter content in mountainous farmland based on ResNet-MHAM model [J]. *Environmental Science*, 2025, 46(4):2313-2324.
- (上接第391页)
- [29] 李豆, 李朋飞, 穆兴民, 等. 机载LiDAR测量复杂地形中滤波算法的比较研究[J]. *水土保持研究*, 2021, 28(4):171-178.
LI D, LI P F, MU X M, et al. Accuracy of airborne LiDAR point cloud filtering for areas with complex terrain [J]. *Research of Soil and Water Conservation*, 2021, 28(4):171-178.
- [30] 雷秋佳, 刘婧, 曹新运. 利用机载LiDAR数据的开放DEM产品精度评估[J]. *武汉大学学报:信息科学版*, 2025, 50(1):153-163.
LEI Q J, LIU J, CAO X Y. Accuracy evaluation of open DEM products based on airborne LiDAR data [J]. *Geomatics and Information Science of Wuhan University*, 2025, 50(1):153-163.
- [31] 贝祎轩, 陈传法, 王鑫, 等. 机载LiDAR点云密度和插值方法对DEM及地表粗糙度精度影响分析[J]. *地球信息科学学报*, 2023, 25(2):265-276.
BEI Y X, CHEN C F, WANG X, et al. Effects of airborne LiDAR point cloud density and interpolation methods on the accuracy of DEM and surface roughness [J]. *Journal of Geo-Information Science*, 2023, 25(2): 265-276.