doi:10.6041/j.issn.1000-1298.2022.09.023

基于加权算法的空-天遥感升尺度土壤含盐量监测模型

张智韬[1,2]　陈钦达[1,2]　黄小鱼[1,2]　宋志双[1,3]　张珺锐[1,2]　台　翔[1,2]

(1. 西北农林科技大学旱区农业水土工程教育部重点实验室, 陕西杨凌 712100;
2. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;
3. 西北农林科技大学信息工程学院, 陕西杨凌 712100)

摘要: 利用无人机-卫星遥感升尺度转换方法可以有效提高土壤含盐量监测精度。以内蒙古河套灌区沙壕渠灌域为研究区,4 月裸土期表层土壤为研究对象,分别采用主导变异权重法、局部平均法和最邻近法将试验区无人机 4 波段影像(0.1 m)升尺度至与 GF-1 卫星(16 m)同一尺度,引入 3 种变量组合作为模型输入变量并利用多元线性回归模型(Multivariable linear regression,MLR)和 BP 神经网络模型(Back propagation neural networks,BPNN)构建不同数据源关于土壤含盐量的定量监测模型。在此基础上,采用波段比值均值法对 GF-1 卫星数据进行修正,实现基于卫星因子的研究区土壤盐分升尺度反演。结果表明,经统计指标评价后得出主导变异权重法在 4 块试验区针对 4 波段影像的尺度转换效果总体上优于其他 2 种转换方法;3 种无人机-卫星遥感升尺度转换方法中,主导变异权重法监测效果最佳,局部平均法次之,最邻近法效果最差;对筛选得到的 2 个模型进行升尺度修正,得到验证效果最佳的监测模型为基于混合变量组的多元线性回归模型,其 R_v^2 为 0.420,RMSEv 为 0.219%,比直接采用 GF-1 卫星数据得到的混合变量组多元线性回归模型 R_v^2 高 0.217,RMSEv 低 0.013 个百分点。本文研究结果可为卫星、无人机多光谱遥感一体化监测裸土期农田土壤含盐量提供参考。

关键词: 土壤含盐量; 多光谱遥感; 无人机遥感; GF-1 卫星; 尺度转换; 主导变异权重法

中图分类号: S252; TP79　　**文献标识码**: A　　**文章编号**: 1000-1298(2022)09-0226-13　　**OSID**:

UAV - Satellite Remote Sensing Scale-up Monitoring Model of Soil Salinity Based on Dominant Class Variability-weighted Method

ZHANG Zhitao[1,2]　CHEN Qinda[1,2]　HUANG Xiaoyu[1,2]　SONG Zhishuang[1,3]　ZHANG Junrui[1,2]　TAI Xiang[1,2]

(1. *Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas*, *Ministry of Education*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *College of Water Resources and Architectural Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
3. *College of Information Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*)

Abstract: UAV - satellite remote sensing scale-up transformation method can effectively improve the monitoring accuracy of soil salt content. Sand trench canal irrigation area in Hetao Irrigation Area of Inner Mongolia was taken as the study area, the surface soil in bare soil period in April was taken as the research object. The dominant class variability-weighted method, local average method and nearest neighbor method were used to scale up the quadruple-band image (0.1 m) of UAV in the experimental area to the same scale as GF-1 satellite (16m). Subsequently, three combinations of variables were introduced as the input variables of the model for the UAV dataset and GF-1 satellite dataset, and the quantitative monitoring model of soil salt content was constructed by using multivariable linear regression (MLR) and back propagation neural networks (BPNN). On this basis, the GF-1 satellite data was modified by the mean band ratio method, and the scale-up inversion of soil salinity in the study area based on satellite factors was realized. The results showed that the dominant class variability-weighted method had the best monitoring effect, followed by the local average method. The nearest neighbor method had the worst monitoring effect among the three UAV - satellite remote sensing scale-up transformation methods; after comparing the four statistical evaluation indexes of mean value, standard

收稿日期: 2021-10-20　修回日期: 2022-01-27

基金项目: 国家重点研发计划项目(2017YFC0403302)和国家自然科学基金项目(51979232)

作者简介: 张智韬(1976—),男,副教授,博士,主要从事遥感技术在节水灌溉及水资源中的应用研究,E-mail: zhitaozhang@126.com

deviation, information entropy and average gradient with the original UAV image, it was found that the quadruple-band UAV image pushed by the three methods had scale differences with the original image data to different degrees; by comparing R^2 and RMSE of three variable combinations based on different data sources, it was found that the accuracy of the model constructed by the dominant class variability-weighted method was better than that of the other three data sources as a whole, and the scale-up dataset of the dominant class variability-weighted method based on mixed variable groups achieved the best monitoring effect in MLR model and BPNN model; the monitoring model with the best validation effect was multivariate linear regression model, its validation R^2 was 0.420, RMSE was 0.219%. The research results can provide reference for integrated monitoring of farmland soil salt content in bare soil period by multi-spectral remote sensing of satellite and unmanned aerial vehicle.

Key words: soil salt content; multi-spectral remote sensing; UAV remote sensing; GF－1 satellite; scale conversion; dominant class variability-weighted method

0　引言

土壤盐渍化是一个全球化的生态环境问题，不仅是引起土地退化的一个重要因素[1-2]，而且在很大程度上影响干旱半干旱地区灌溉农业的可持续发展。因此，利用遥感手段及时、准确地监测解析盐渍化的空间分布特征[3]，能为灌区盐渍化防治与农业生产提供实践指导。

传统土壤盐渍化监测手段多为野外实地采样，虽然监测精度较高，但采样耗时费力且只能针对单个点进行观测[4]。卫星遥感具有监测范围大和获取方便快捷等特点，在土壤大范围动态监测中发挥着不可替代的作用，目前已得到广泛应用[5-6]。然而，利用卫星遥感数据探究土壤盐渍化问题，在其特定尺度下获取的地表参数信息有限，这是因为土壤盐渍化具有极强的时空变异性，受各种环境因素协同作用影响[7]。并且，不同时空分辨率的遥感数据还存在如传感器差异、大气状态等诸多不确定因素。要想透彻了解土壤盐渍化现象的发生发展始终离不开对尺度问题的讨论[8]，因而，探究尺度转换方法来获取多时空分辨率遥感影像具有重要意义[9-12]。上述研究大多基于卫星到卫星的空间尺度转换，关于无人机到卫星尺度转换方面的相关研究较少。无人机具备高时效性和高精度等优势，可在一定范围内对土壤盐渍化进行监测，若能将无人机的高精度和卫星的大范围监测相结合[13]，便能在大范围区域开展遥感监测的基础上提高其监测精度。

鉴于此，本文以内蒙古自治区河套灌区沙壕渠灌域为研究区，选取研究区内 4 块地为试验区，以 4 月裸土期表层土壤含盐量为研究对象，采用主导变异权重法、局部平均法和最邻近法分别将试验区无人机四波段影像（0.1 m）升尺度至与 GF－1 卫星（16 m）同一尺度，经由统计评价指标分析空间变异权重算法和传统尺度转换方法对试验区各波段影像的转换效果，引入不同变量组合并结合多元线性回归方法和 BP 神经网络构建不同数据源关于土壤含盐量的定量监测模型，以期得到最优的无人机升尺度模型，再依据无人机与卫星影像之间关系进行模型修正，初步探索将无人机高精度优势和卫星大范围监测联系起来的结合方式，为实现无人机、卫星多光谱遥感一体化监测裸土期农田土壤含盐量和河套灌区农业可持续发展提供科学参考和数据支持。

1　监测模型建立

1.1　研究区概况

位于内蒙古自治区巴彦淖尔市西部的河套灌区是中国灌溉面积最大的灌区，它由一干灌域、解放闸灌域、永济灌域、义长灌域、乌拉特灌域和乌梁素海灌域组成。本文研究区沙壕渠位于解放闸灌域内部（40°52′～41°00′N，107°05′～107°10′E），如图 1 所示，形状类似一个狭长的倒置三角形。该区域位于西北黄土高原地带，平均海拔在1 000 m 以上，其土壤质地以粉壤土、砂壤土和壤土为主，气候属于典型的干旱半干旱大陆性气候，年降水量和蒸发量分别约为 158 mm 和 2 000 mm，降水少蒸发大[14]，导致区

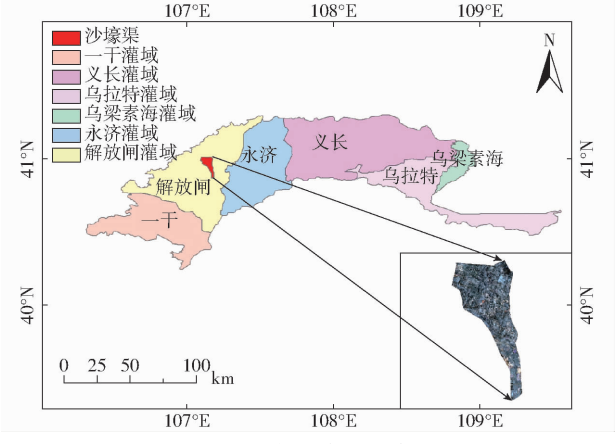

图 1　研究区位置示意图

Fig. 1　Sketch of study area

域内土壤水盐运移速率加快,使得深层土壤盐分易随潜水蒸发而逐渐向地表积聚,再加上土质因素及不合理的农业灌溉方式,多重因素综合作用下加重了该区域土壤盐渍化程度,严重制约了当地农业长期可持续发展。

1.2 采样点设置和盐分数据采集

于 2019 年 4 月 12—21 日对沙壕渠灌域进行实地调研和采样,根据土壤盐渍化程度确定了 4 块试验区并对其进行编号,同时在每块试验区均匀布设了 30 个采样点,采样点大多为无植被覆盖的表层土壤,深度为 0 ~ 10 cm,如图 2 所示。为使采样时间和无人机影像获取时间保持一致,选取晴朗天气进行无人机影像收集和实地采样,利用手持式 GPS 定位仪记录每个采样点的地理位置,采用五点法获取表层土壤样本,并将所获土样放入标记好的铝盒内,在实验室对土样进行干燥研磨处理后,以土水质量比 1∶5 配置土壤溶液,经过搅拌、静置、沉淀、过滤后,使用电导率仪(DDS - 307 型,上海佑科仪器公司)测定土壤溶液电导率,对每个采样点的 5 个土样电导率取平均值作为该样点处的电导率 $EC_{1:5}$,依据经验公式 $C_{SSC} = (0.2882EC_{1:5} + 0.0183) \times 100\%$ 计算土壤含盐量(SSC)。整理 120 个样本数据,剔除其中 3 个异常值,剩余 117 个研究样本按照盐分含量由大到小排序,根据 2∶1 的比例划分建模集和验证集并进行等间隔采样。同时将 117 个土壤样本盐分划分为 4 个等级[15]:非盐土(含盐量 0 ~ 0.2%)、轻度盐渍化土(含盐量 0.2% ~ 0.5%)、重度盐渍化土(含盐量 0.5% ~ 1.0%)和盐土(含盐量大于 1.0%),对土壤样本的描述性分析结果如表 1 所示。其中非盐土、轻度盐渍化土、重度盐渍化土和盐土占比分别为 63.2%、27.4%、4.3% 和 5.1%,变异系数为 1.11。建模集和验证集变异系数分别为 1.13 和 1.08,相差不大,且从表 1 可以看出,建模集和验证集的数据范围分别为 0.06% ~ 1.49% 和 0.06% ~ 1.30%,两者范围几乎一致且分布均匀,提升了建模可靠性。

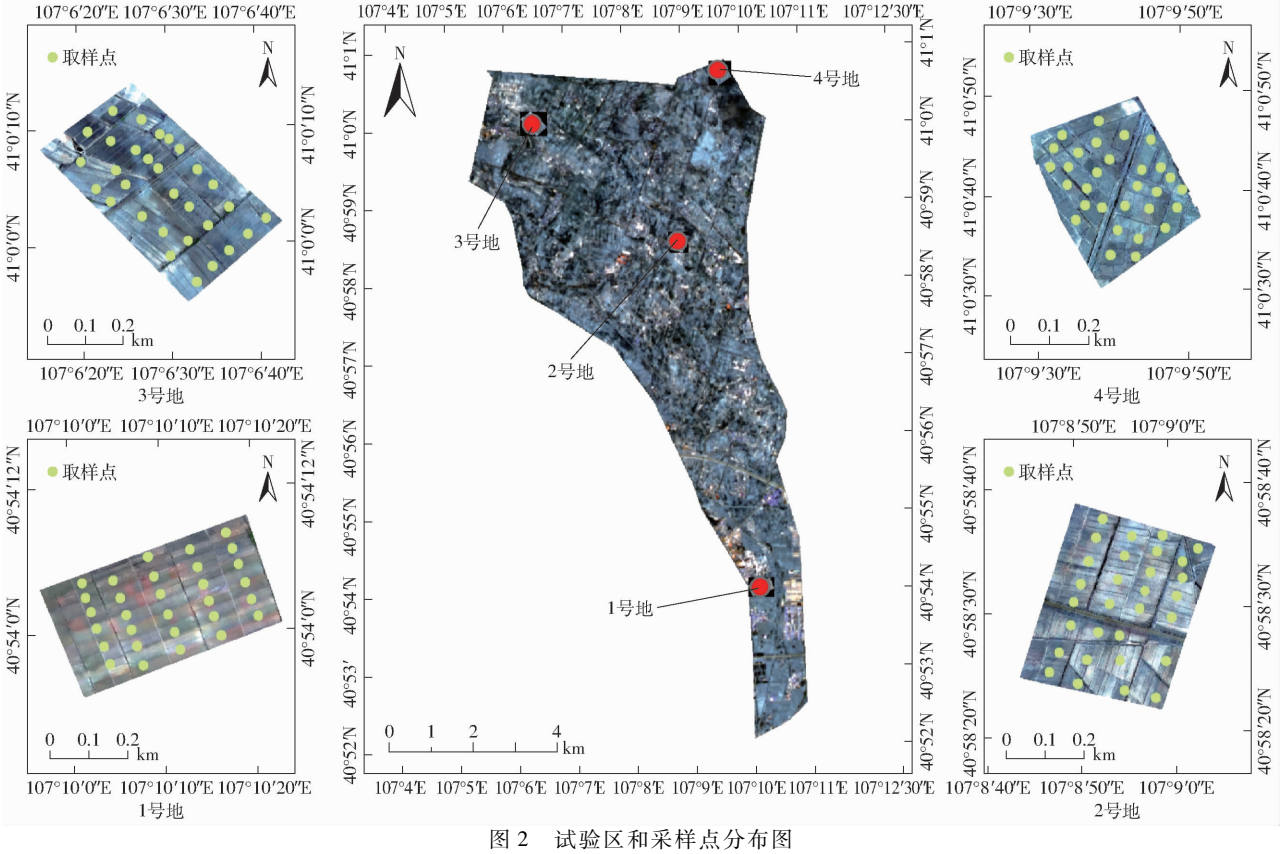

图 2 试验区和采样点分布图

Fig. 2 Schematic of study area and soil sampling locations

表 1 土壤盐分数据统计

Tab. 1 Summary statistics of soil salinity

数据集	样本数	非盐土数	轻度盐渍化数	重度盐渍化数	盐土数	最小值/%	最大值/%	均值/%	标准差/%	变异系数
总样本	117	74	32	5	6	0.06	1.49	0.26	0.28	1.11
建模集	78	50	20	3	5	0.06	1.49	0.26	0.30	1.13
验证集	39	24	12	2	1	0.06	1.30	0.24	0.26	1.08

1.3　遥感数据采集与处理

1.3.1　无人机多光谱遥感影像采集与处理

研究所使用的无人机为大疆公司生产的经纬 Matrice 600 型，该型无人机搭载具有体积小、质量轻且能远程触发等特点的 Mirco－MCA 型多光谱相机（简称 MCA），其包括蓝波段（490 nm）、绿波段（550 nm）、红波段（680 nm）、红边波段（720 nm）、近红外波段 1（800 nm）和近红外波段 2（900 nm）共计 6 个波段的光谱采集通道。无人机多光谱图像的采集时间与土样采集时间保持一致，将无人机飞行高度设置为 120 m（此时对应的影像空间分辨率为 0.1 m），每次飞行前在试验区放置标准白板以便对影像进行辐射标定。

使用相机配套软件 PixelWrench2 对相机内的无人机影像进行提取、校准和合成，最后导出 tif 格式的 6 波段多光谱遥感影像，对影像进行尺度转换，将升尺度后的多光谱影像导入 ENVI 5.3 软件中，并通过试验区样点的经纬度信息确定样点所在像元，提取该像元点 6 波段对应的像元值，并在标准白板标定后进一步计算得到相应的光谱反射率。

1.3.2　高分一号卫星多光谱遥感影像采集与处理

研究采用的卫星数据源为 GF－1 卫星，其搭载的 4 台宽覆盖多光谱相机 Wide Field View sensor（简称 WFV）可获取 16 m 多光谱影像，相机组合幅宽不小于 800 km，重访周期为 4 d。选用与地面采样时间同步的 GF－1 卫星 WFV 数据，其影像谱段包括蓝波段（B，450 ~ 520 nm）、绿波段（G，520 ~ 590 nm）、红波段（R，630 ~ 690 nm）和近红外波段（NIR，770 ~ 890 nm）4 个波段。在 ENVI 5.3 软件中导入下载的 GF－1 卫星影像，同时对影像进行辐射校正、几何精校正和大气校正等预处理操作，处理完毕后将地面样点的经纬度信息一并导入软件中以确定各采样点对应的地表光谱反射率。

1.4　光谱指数选取和计算

采用遥感影像构建的各类光谱指数作为间接指标来对盐渍化区域盐分进行评价和作图，已取得不错的效果。结合文献和经验，本文选取了常见的光谱指数 SI、SI1、SI3、BI[16]、NDVI、MSAVI[17]、SR[18]、SRSI[19]、NDSI[20]、DVI[21]作为土壤含盐量监测模型的输入变量因子。

1.5　主导变异权重法及统计评价方法

针对影像窗口内的地理要素进行尺度上推时，考虑到窗口范围覆盖的像元间存在局部空间自相关性，需要对地表要素间的相互作用进行监测，降低升尺度转换后所造成的信息损失，使转换结果更符合地表真实情况。为此，有学者提出空间变异性加权算法[22]，旨在将局部空间自相关性用像元值和主导空间特征值之间方差的形式加以衡量，方差越大，像元值与主要特征的距离越远，当数据从高分辨率转换到低分辨率时，该像元对应的权重也应越小，因此，权值可以定义为方差的倒数。对主导特征的不同度量导致了数据聚合的不同方法。

本研究采用主导变异权重法（Dominant class variability-weighted method，DCVW）获取局部窗口构建的趋势面的主导空间特征值，基于此主导空间特征值对局部窗口的趋势面内的地理要素进行聚合，利用 Python 软件编程实现对沙壕渠试验区影像的空间尺度上推。

主导变异权重法根据所构建的局部窗口的趋势面地理要素的频率分布确定主导值，取频率最大的值作为此局部窗口趋势面的主导空间特征值，计算此局部窗口趋势面中每个值与主导空间特征值间的方差，计算所得方差的倒数并将之累加，将每个值的倒数除以所得累加值的结果作为此值的权重，将局部窗口趋势面中每个值乘以其权重并累加，获得局部窗口趋势面的加权平均值。计算式为

$$\overline{y}^{(w)x} = \sum_{u=1}^{m} w(u)y(u) \tag{1}$$

其中

$$w(u) = \frac{\dfrac{1}{(y(u) - y^{(wd)})^2}}{\displaystyle\sum_{u=1}^{m} \frac{1}{(y(u) - y^{(wd)})^2}} \tag{2}$$

式中　$\overline{y}^{(w)x}$——基本地域单元内尺度上推后遥感信息值

$y(u)$——基本地域单元内某一像素遥感信息值

$w(u)$——权重

$y^{(wd)}$——主导空间特征像素遥感信息值

m——基本地域单元内总像素数

除此之外，本文还采用了局部平均法和最邻近法等传统的尺度转换方法对遥感影像进行空间尺度上推[23-24]，2 种方法对影像数据的处理在 ENVI 软件中完成。

通常情况下，对遥感影像数据进行尺度转换后会造成一定程度的信息损失及光谱、形状的变异，不同尺度转换方法导致的信息损失及变异程度不一，因而需要采取精度评价方法来客观衡量尺度转换后的效果[25]。现有的评价体系尚不完备，大多以尺度转换后的影像数据与高分辨遥感影像或地面实测数据进行评价指标的比较。本文主要采用均值、标准差、信息熵和平均梯度来评价遥感数据尺度上推后的效果[26-28]。

均值表示遥感影像的平均像素值。尺度转换后如果均值发生了较大变化,则表明尺度转换效果较差,因此均值越接近原始数据越好。

标准差描述了影像各像元灰度值偏离影像平均值的程度,标准差越大,意味着转换后影像的灰度级分布越分散,图像反差越大,可获取更多影像信息。

图像的信息熵 E 是从信息论角度反映影像信息丰富程度的一种度量方式,信息熵反映了图像携带的信息量,计算公式为

$$E = -\sum_{j=0}^{L-1} p_j \mathrm{lb} p_j \tag{3}$$

式中 p_j——遥感影像灰度中 j 值的像元数在总灰度中所占的比例

L——总的灰度级

平均梯度 G 能敏感地反映图像对微小细节反差表达的能力,平均梯度越大,表明影像越清晰,纹理信息越丰富,反差越好。计算公式为

$$G = \frac{1}{(m_0-1)(n_0-1)} \cdot \sum_{i=1}^{m_0-1}\sum_{j=1}^{n_0-1}\sqrt{\frac{\left(\frac{\partial p(x_i,y_i)}{\partial x_i}\right)^2 + \left(\frac{\partial p(x_i,y_i)}{\partial y_i}\right)^2}{2}} \tag{4}$$

式中 m_0、n_0——遥感影像总行数和总列数

$p(x_i, y_i)$——图像第 i 行、第 j 列遥感信息值

1.6 高分一号卫星影像光谱反射率升尺度修正

由于 GF-1 卫星影像的光谱分辨率与无人机升尺度影像存在差异,因而需要分别对 GF-1 卫星 4 个波段进行修正以达成一体化的目的。在试验区每个采样点对应的卫星影像单个像元范围内,提取升尺度后无人机图像各波段单一像元的光谱反射率 B 及对应波段的卫星单一像元的光谱反射率 b,参照前人研究[29],选用波段比值均值法确定卫星 4 个波段的修正系数 Z,计算式为

$$Z = \frac{\sum_{i=1}^{n_1} \frac{B_i}{b_i}}{n_1} \tag{5}$$

式中 n_1——参与计算样点数量

B_i——升尺度后无人机图像各波段单一像元光谱反射率

b_i——卫星图像单一像元光谱反射率

以各波段修正系数乘以对应卫星波段参量,对筛选出的模型内光谱自变量进行修正后,得到升尺度土壤含盐量监测模型。

1.7 土壤含盐量监测模型构建和评价

本文构建监测模型的数据来源有 4 种:基于主导变异权重法升尺度后的无人机数据、基于局部平均法升尺度后的无人机数据、基于最邻近法升尺度后的无人机数据和 GF-1 号卫星数据,每种数据源监测模型的变量因子分为 3 组:光谱波段组、光谱指数组和混合变量组。本文所用的统计分析方法为多元线性回归[30-31],所用的机器学习方法为 BP 神经传播网络[32-34],统计分析建模在 IBM SPSS 23 软件中完成,机器学习算法模型在 R 语言软件中完成。建模流程如图 3 所示。

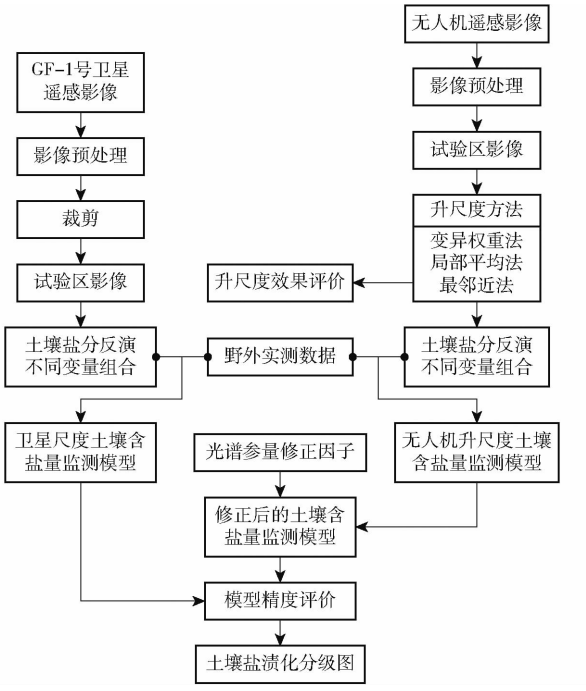

图 3 建模流程图

Fig. 3 Modeling flowchart

关于监测模型的评价,本文利用 39 个样本对各类方法构建的盐分估算模型进行验证分析,对验证集的模型预测值和实测值进行拟合,采用决定系数(Coefficient of determination, R^2)和均方根误差(Root mean square error, RMSE)2 个指标来评价建模集和验证集的精度。R^2 越接近 1,RMSE 越小,说明模型精度越好。

2 结果与分析

2.1 尺度转换方法对无人机数据的升尺度应用

对于 4 块试验区无人机影像的蓝波段、绿波段、红波段和近红外波段,分别对各单波段影像采用主导变异权重法、局部平均法和最邻近法升尺度至 16 m,再将各单波段影像合成为多波段影像,以试验区 2 号地为例,其尺度转换结果如图 4 所示。

通过空间尺度上推统计评价方法对比分析无人机影像经 3 种尺度转换方法尺度上推后的效果。图 5~8 是无人机单波段影像(蓝波段、绿波段、红波段和近红外波段)在 4 块试验区利用 3 种方法实

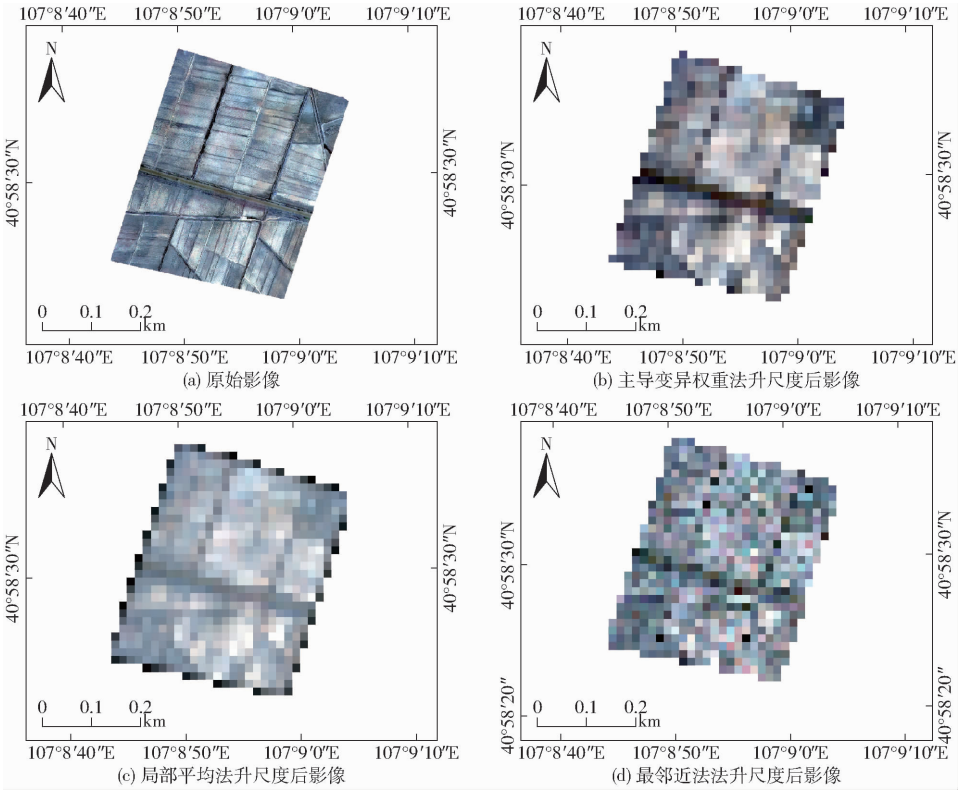

图 4　无人机 4 波段遥感影像升尺度结果

Fig. 4　Upscaling results of UAV's four-band remote sensing image

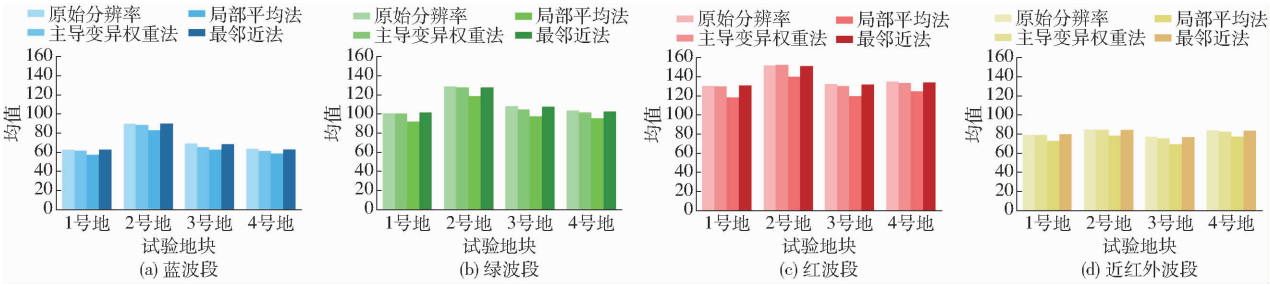

图 5　试验区无人机 4 波段影像均值对比

Fig. 5　Comparison of average values of UAV four-band images in test area

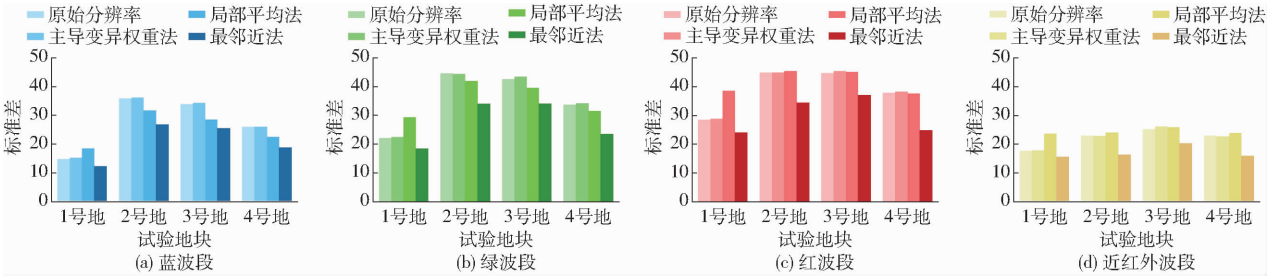

图 6　试验区无人机 4 波段影像标准差对比

Fig. 6　Comparison of standard deviation of UAV four-band image in test area

现尺度上推后与原始分辨率影像的均值、标准差、信息熵和平均梯度统计结果。

从图 5 可以看出，每种方法尺度上推后的均值都不同程度偏离原始分辨率影像的均值，这在无人机 4 个波段影像上表现各异，但对于同一试验区同一波段影像，除局部平均法的均值明显偏离原始分辨率影像，主导变异权重法和最邻近法的均值变化幅度较小，基本与原始分辨率影像均值保持一致。从图 6 可以看出，原始分辨率 4 个波段影像在试验区 2 号地、3 号地和 4 号地的标准差较大，说明遥感影像像元的灰度级分布分散，空间信息及纹理特征信息较为复杂且像元间变异明显，经 3 种方法尺度上推后无人机 4 波段影像的标准差在不同试验区的呈现效果不一，1 号地局部平均法的标准差大于主

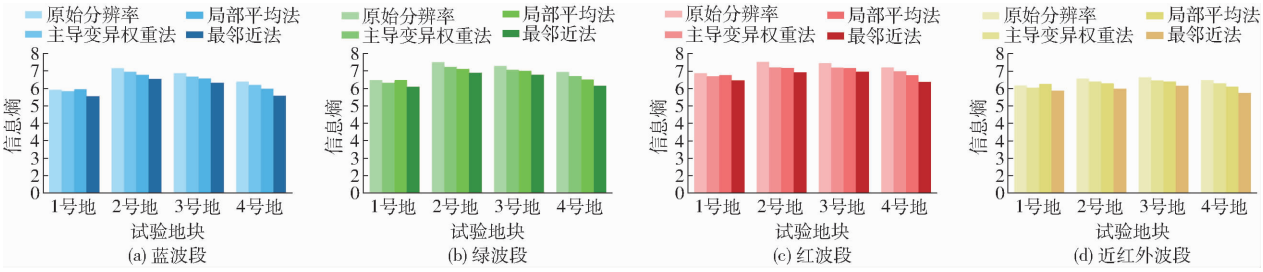

图 7 试验区无人机 4 波段影像信息熵对比

Fig. 7 Comparison of information entropy of UAV four-band image in test area

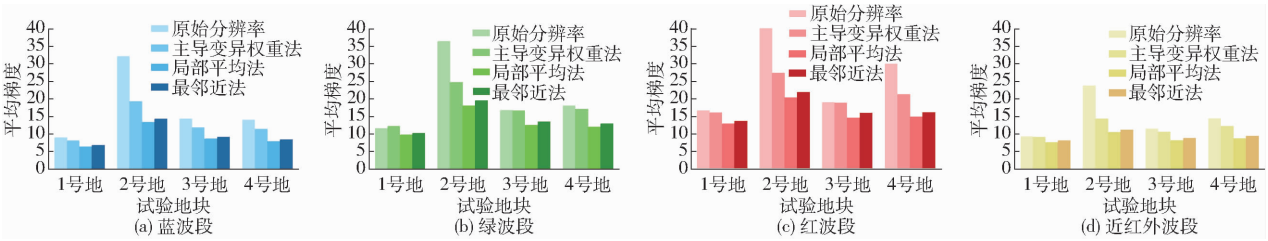

图 8 试验区无人机 4 波段影像平均梯度对比

Fig. 8 Comparison of average gradient of UAV four-band images in test area

导变异权重法和最邻近法，表示三者在分辨率为 16 m 的前提下，局部平均法升尺度后的无人机 4 波段影像的灰度级分布更广泛且像元间变异更为明显。对于 2 号地、3 号地和 4 号地，主导变异权重法升尺度后的蓝波段影像、绿波段影像的标准差要高于其他 2 种方法，对于升尺度后的红波段影像，局部平均法在 2 号地的标准差最高，主导变异权重法在 3 号地和 4 号地的标准差最高，但主导变异权重法和局部平均法的标准差之间的差异不明显。对于升尺度后的近红外波段影像，局部平均法在 2 号地和 4 号地的标准差最高，主导变异权重法在 3 号地的标准差最高，二者的值较为接近。总体而言，相较于局部平均法和最邻近法，主导变异权重法升尺度后的 4 波段影像提供了更为丰富的地表要素信息。

从图 7 可以看出，经过 3 种方法尺度上推后的 4 波段影像在 4 块试验区的影像信息熵与原始分辨率影像信息熵相比较小，说明由于地表异质性和土地利用类型的差异，尺度上推过程会造成影像信息在一定程度上的损失，经主导变异权重法升尺度后的试验区 4 波段影像与其他 2 种方法升尺度后影像的信息熵对比分析，三者在空间分辨率为 16 m 的前提下，除在试验区 1 号地，局部平均法升尺度后 4 波段影像信息熵高于主导变异权重法，在 2、3 和 4 号试验区域，主导变异权重法的信息熵要高于其他 2 种转换方法，信息量更丰富。从图 8 可以看出，原始分辨率 4 波段影像在不同试验区的平均梯度最大，对于 4 块试验区，主导变异权重法升尺度后的影像的平均梯度要高于局部平均法和最邻近法，说明其对影像微小细节和纹理特征的反映更为突出，不过 3 种方法转换结果的平均梯度都低于原始分辨率影像，可能原因是影像像元间差异部分在尺度上推过程中被以不同形式加以模糊，其边缘信息受到干扰，因而升尺度后的影像相较于原始影像平均梯度有所减小。

综合以上分析，经由均值、标准差、信息熵和平均梯度 4 种统计评价指标与原始影像对比后，发现主导变异权重法在 4 块试验区针对 4 波段影像的尺度转换效果总体上优于其他 2 种转换方法。

2.2 土壤含盐量与光谱波段、光谱指数的相关性分析

对不同数据集的多光谱 4 个波段光谱反射率、10 个光谱指数分别和对应的土壤含盐量进行相关性分析，得到的皮尔逊相关系数结果如图 9、10 所示。此外，与 2.1 节相同，用原始分辨率影像与土壤含盐量的相关分析结果与空间尺度上推后的影像结果作了对比。

从图 9 可以看出，空间尺度上推后的 3 类无人机数据的蓝波段(490 nm)、绿波段(550 nm)、红波段(680 nm)、近红外波段(800 nm)与 SSC 均表现极显著相关的相关关系，其中主导变异权重法和最邻近法的 4 个波段与 SSC 的相关性从高到低依次为：G、B、R、NIR，局部平均法与 SSC 的相关性从高到低依次为：B、G、R、NIR，总体而言，主导变异权重法、局部平均法的蓝波段、绿波段、红波段、近红外波段与 SSC 的相关系数变化范围为 0.4 ~ 0.7，最邻近法的蓝波段、绿波段、红波段、近红外波段与 SSC 的相关系数变化范围为 0.3 ~ 0.5。

GF－1 卫星数据 4 个波段与 SSC 的相关性从高到低依次为：B、G、R、NIR。其中蓝波段与 SSC 呈现

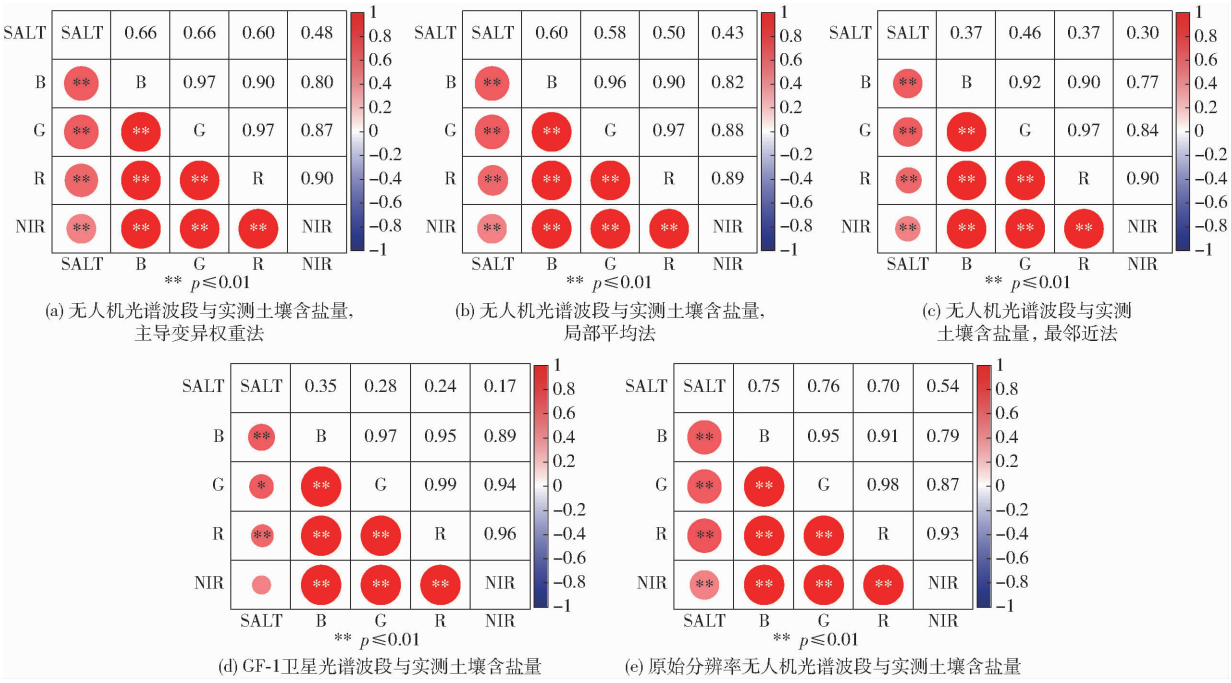

(a) 无人机光谱波段与实测土壤含盐量，主导变异权重法　(b) 无人机光谱波段与实测土壤含盐量，局部平均法　(c) 无人机光谱波段与实测土壤含盐量，最邻近法

(d) GF-1卫星光谱波段与实测土壤含盐量　(e) 原始分辨率无人机光谱波段与实测土壤含盐量

图 9　不同数据源下土壤含盐量与光谱波段相关系数

Fig. 9　Correlation coefficient of soil salinity and spectral band

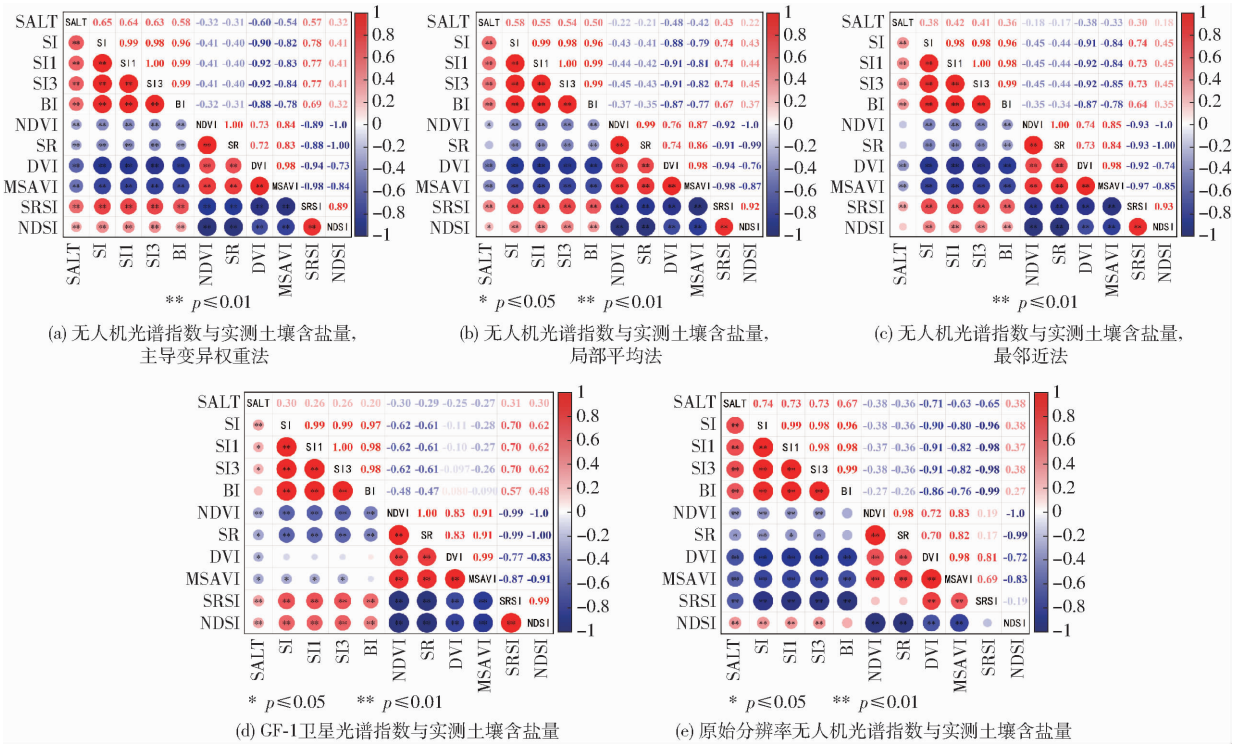

(a) 无人机光谱指数与实测土壤含盐量，主导变异权重法　(b) 无人机光谱指数与实测土壤含盐量，局部平均法　(c) 无人机光谱指数与实测土壤含盐量，最邻近法

(d) GF-1卫星光谱指数与实测土壤含盐量　(e) 原始分辨率无人机光谱指数与实测土壤含盐量

图 10　不同数据源下土壤含盐量与光谱指数相关系数

Fig. 10　Correlation coefficient of soil salinity and spectral index

极显著相关，相关系数为 0.349，绿波段和红波段与 SSC 呈现显著相关关系，相关系数分别为 0.282、0.241，近红外波段的相关系数为 0.166。

从图 10 可以看出，主导变异权重法尺度上推后无人机数据构建的光谱指数 SI、SI1、SI3、BI、NDVI、SR、DVI、MSAVI、SRSI、NDSI 与 SSC 均表现极显著相关的相关关系，其中 NDVI、SR、NDSI 这 3 个光谱指数与 SSC 的相关性较低，相关系数为 0.3 左右；SI、SI1、SI3、BI、DVI、MSAVI、SRSI 与 SSC 呈现出良好的相关性，这 7 个光谱指数相关性由高到低依次为 SI、SI1、SI3、DVI、BI、SRSI、MSAVI，并且相关系数均在 0.5 以上，其中 SI、SI1、SI3 和 DVI 相关系数超过 0.6。局部平均法尺度上推后无人机数据构建的光谱指数 SI、SI1、SI3、BI、DVI、MSAVI、SRSI 与 SSC

均为极显著相关,相关系数均在 0.4 以上,相关性由高到低依次为 SI、SI1、SI3、BI、DVI、SRSI、MSAVI,其中 SI、SI1、SI3 的相关系数超过 0.5,NDVI、NDSI 和 SR 这 3 个光谱指数与 SSC 相关性较低,相关系数在 0.2 左右。最邻近法尺度上推后无人机数据构建的光谱指数 SI、SI1、SI3、BI、DVI、MSAVI、SRSI 与 SSC 均表现极显著相关的相关关系,这 7 个光谱指数和 SSC 的相关性由高到低排序为 SI1、SI3、SI、DVI、BI、MSAVI、SRSI,其中 SI1、SI3、SI 的相关系数超过 0.4,NDVI、SR 和 NDSI 这 3 个光谱指数与 SSC 相关性较低,相关系数在 0.2 左右。

GF-1 卫星数据构建的光谱指数 SI、NDVI、SRSI、NDSI 与 SSC 均表现极显著相关,相关系数在 0.3 左右。SI1、SI3、SR、DVI、MSAVI 与 SSC 表现为显著相关,相关系数均超过 0.2。

从图 9、10 可以看出,原始尺度无人机数据除了近红外波段之外其他 3 个波段与 SSC 的相关系数均在 0.7 以上,其构建的光谱指数如 SI、SI1、SI3、BI、DVI、SRSI 与 SSC 呈现出较高的相关性,相关系数在 0.65 以上,相比之下 3 种升尺度无人机数据与 SSC 相关性较低的原因可能是在尺度上推的过程中损失了部分反映盐渍土光谱特性的影像信息,具体到各种尺度转换方法应用后的影像信息损失程度也不相同,就空间尺度上推后无人机数据与 SSC 的相关性而言,主导变异权重法要优于局部平均法和最邻近法,这从一定角度上反映了空间变异加权算法相较于传统方法在影像升尺度应用方面的优势。

2.3 土壤含盐量监测模型

本文以 3 种升尺度方法的无人机影像和 GF-1 卫星遥感影像为基础,将蓝波段、绿波段、红波段和近红外波段 4 个波段作为不同数据源构建模型的第一组变量因子,记为光谱波段组;通过 2.2 节土壤含盐量与光谱指数的相关性分析,以及考虑到升尺度修正时无人机和卫星的模型变量因子应保持一致,综合比较后选取 SI、SI1、SI3、DVI 4 个相关性较高的光谱指数作为不同数据源构建模型的第 2 组变量因子,记为光谱指数组;同时,通过比较不同数据源选取的 4 个光谱波段和 4 个光谱指数与土壤含盐量的相关性,依据相关性排序从高到低原则,从光谱波段组选取蓝波段、绿波段和红波段,从光谱指数组选取 SI、SI1,共计 5 个混合光谱波段和光谱指数的变量因子作为不同数据源构建模型的第 3 组变量因子,记为混合变量组。然后再用 4 种遥感图像依据 3 组变量因子分别构建土壤含盐量监测模型。

2.3.1 不同数据源基于 3 个变量组的统计回归模型

将不同数据源得到的光谱波段组、光谱指数组和混合变量组分别作为模型输入自变量,对应的含盐量作为因变量,利用多元线性回归方法(Multivariable linear regression,MLR)建立基于不同变量组的土壤含盐量监测模型。相关建模及验证结果如表 2 所示。

表 2 不同数据源基于 3 种变量组合的统计回归模型

Tab.2 Different data sources based on statistical analysis model of three sets of variable combinations

数据源	变量组合	回归方程	建模集($n=79$)		验证集($n=38$)	
			R_c^2	RMSEc/%	R_v^2	RMSEv/%
主导变异权重法升尺度后的无人机数据集	光谱波段	$Y=-0.2-1.512B_b+6.205B_g-2.225B_r-1.748B_{nir}$	0.503	0.209	0.550	0.175
	光谱指数	$Y=-0.264-1.426SI+34.29SI_1-22.905SI_3-1.86DVI$	0.478	0.214	0.511	0.182
	混合变量	$Y=-0.222\,7+30.290\,5B_b+31.973\,3B_g+33.434\,4B_r-46.010\,8SI-45.548\,9SI_1$	0.535	0.202	0.564	0.169
局部平均法升尺度后的无人机数据集	光谱波段	$Y=-0.129+1.296B_b+2.852B_g-1.458B_r-1.143B_{nir}$	0.391	0.231	0.397	0.231
	光谱指数	$Y=-0.161+2.165SI+22.237SI_1-16.36SI_3-0.999DVI$	0.378	0.233	0.395	0.227
	混合变量	$Y=-0.216\,7+48.274\,7B_b-50.233B_g-20.040\,3B_r-68.205SI+95.265\,3SI_1$	0.418	0.226	0.363	0.247
最邻近法升尺度后的无人机数据集	光谱波段	$Y=-0.087-0.928B_b+4.305B_g-2.098B_r-0.222B_{nir}$	0.298	0.248	0.325	0.217
	光谱指数	$Y=-0.121-1.682SI+22.913SI_1-14.513SI_3-0.274DVI$	0.263	0.254	0.199	0.236
	混合变量	$Y=-0.095+29.305B_b+81.316B_g+73.973B_r-43.481SI-136.784SI_1$	0.416	0.226	0.386	0.184
GF-1 卫星数据集	光谱波段	$Y=0.580+20.402b_b+1.532b_g-7.293b_r-7.868b_{nir}$	0.232	0.259	0.278	0.218
	光谱指数	$Y=0.532+36.422SI+105.216SI_1-96.606SI_3-8.383DVI$	0.227	0.260	0.296	0.215
	混合变量	$Y=0.392\,9+209.218\,7b_b+978.607\,0b_g+901.355\,0b_r-321.003\,8SI-1\,747.190\,2SI_1$	0.230	0.260	0.203	0.232

注:B_b、B_g、B_r、B_{nir}分别对应无人机的蓝、绿、红、近红外 4 个波段反射率,b_b、b_g、b_r、b_{nir}分别对应 GF-1 卫星的蓝、绿、红、近红外 4 个波段反射率。SI、SI_1、SI_3、DVI 分别为 SI、SI1、SI3、DVI。

从表 2 可以看出，经尺度上推后无人机 3 组变量构建的 MLR 模型的建模效果要优于 GF-1 卫星，无人机数据的建模集决定系数均在 0.26 以上，均方根误差均在 0.26% 以下，卫星数据的建模集决定系数变化范围在 0.22 ~ 0.24 之间，均方根误差在 0.26% 左右。不同尺度转换方法构建的 MLR 模型精度效果呈现出差异，主导变异权重法转换后不同变量组的 R_c^2 在 0.45 以上，其中，混合变量组的 R_c^2 达到 0.535，光谱波段组次之，光谱指数组最差，R_c^2 为 0.478，3 组变量组的 RMSEc 均在 0.22% 以下；局部平均法 3 组变量的 R_c^2 在 0.4 左右，RMSE 在 0.24% 以下，其中，混合变量组的建模效果最好，R_c^2 为 0.418，RMSE 为 0.226%；最邻近法 3 组变量的 R_c^2 变化范围为 0.26 ~ 0.38，RMSE 在 0.26% 以下，其中，混合变量组的建模效果最好，R_c^2 为 0.375，RMSE 为 0.231%。综合比较后，发现主导变异权重法转换后数据集的建模效果要好于局部平均法和最邻近法转换后的数据集，且不同数据源构建模型时所采用的混合变量组取得了最佳的建模效果。

对上述模型进行验证，发现无论是卫星还是尺度上推后的无人机，其不同变量组各自的 R_v^2 与建模时的 R_c^2 相差不大，同时 RMSEv 均在 0.25% 以下。除了最邻近法光谱指数组数据集验证效果要差于卫星光谱指数组数据集外，无人机数据集的验证效果普遍要好于卫星数据集，表明采用尺度上推后无人机进行光谱建模可以比卫星更有效提高土壤盐分的反演精度。

综合对比不同数据源基于 3 组变量 MLR 模型的建模和验证效果，发现采用主导变异权重法升尺度后基于混合变量组的无人机数据建模和验证效果相对更好且较为稳定，认为是最佳的多元线性回归含盐量监测模型。

2.3.2　不同数据源基于 3 个变量组的机器学习模型

将不同数据源得到的光谱波段组、光谱指数组和混合变量组分别作为模型输入自变量，对应的含盐量作为因变量，利用 BP 神经网络（Back propagation neural networks，BPNN）机器学习方法建立基于不同变量组的土壤含盐量监测模型。相关建模及验证结果如表 3 所示。

由表 3 可以发现，当同一变量组合作为模型输入变量的条件下，基于主导变异权重法升尺度后的无人机数据和基于局部平均法升尺度后的无人机数据分别构建的土壤含盐量监测模型的 R_c^2 和 R_v^2 要高于其他 2 种数据源，相较于局部平均法，基于主导变异权重法升尺度后数据集的 R_c^2 和 R_v^2 更高，且

表 3　不同数据源基于 3 种变量组合的机器学习模型

Tab.3　Machine learning model based on combination of three sets of variables from different data sources

数据源	变量组合	建模集（n=79）		验证集（n=38）	
		R_c^2	RMSEc/%	R_v^2	RMSEv/%
主导变异权重法升尺度后的无人机数据集	光谱波段	0.526	0.204	0.488	0.186
	光谱指数	0.552	0.198	0.440	0.194
	混合变量	0.537	0.202	0.491	0.186
局部平均法升尺度后的无人机数据集	光谱波段	0.412	0.228	0.382	0.231
	光谱指数	0.392	0.231	0.355	0.236
	混合变量	0.420	0.226	0.375	0.235
最邻近法升尺度后的无人机数据集	光谱波段	0.226	0.261	0.270	0.232
	光谱指数	0.196	0.266	0.213	0.264
	混合变量	0.226	0.261	0.275	0.230
GF-1 卫星数据集	光谱波段	0.210	0.265	0.310	0.217
	光谱指数	0.144	0.274	0.201	0.231
	混合变量	0.235	0.255	0.320	0.222

RMSEc 和 RMSEv 仅分别为 0.204%、0.198%、0.202% 和 0.186%、0.194%、0.186%，均是 4 个数据源中的最低值。在光谱波段构建的模型中，最邻近法升尺度数据集的 R_v^2 为 0.270，低于卫星数据集 R_v^2 的 0.310，同时最邻近法升尺度数据集 RMSEv 为 0.232%，高于卫星数据集的 0.217%；在光谱指数组中，最邻近法升尺度数据集的 R_v^2 为 0.213，虽然高于卫星数据集 R_v^2 的 0.201，但二者相差不大，同时最邻近法升尺度数据集 RMSEv 为 0.235%，高于卫星数据集的 0.231%；在混合变量组中，卫星数据集的 R_v^2 为 0.320，高于最邻近法升尺度数据集的 0.275，同时卫星数据集的 RMSEv 为 0.222%，低于最邻近法升尺度数据集的 0.230%。由此得出，在 4 种不同的数据源中，基于主导变异权重法升尺度后数据集在不同变量组的建模验证效果要优于其他数据集，局部平均法次之，而基于最邻近法升尺度后数据集和卫星数据集在不同变量组作为模型输入变量时，精度效果互有优劣。

综合对比不同数据源基于 3 种变量组合 BP 神经网络模型的建模和验证效果，发现采用主导变异权重法升尺度后基于混合变量组的无人机数据建模和验证效果相对更好且较为稳定，认为是最佳的 BP 神经网络土壤含盐量监测模型。

2.4　土壤含盐量监测模型的升尺度修正与应用

利用 ENVI 软件导出 GF-1 卫星影像下研究区各样点对应 4 个波段的像元值，计算修正后的光谱参数。将筛选得到的统计回归监测模型代入修正后的光谱参数，对于筛选得到的机器学习模型则直接将修正后的光谱参数、实测盐分数据放入机器学习模型中进行验证，然后根据 R^2 和 RMSE 判断模型修正效果。

通过比值均值法,计算得到 GF－1 卫星影像 4 个波段的修正系数分别为 2.325 4(b_b)、3.040 6(b_g)、3.113 4(b_r)、1.523 3(b_{nir}),对模型中的光谱指数使用卫星波段乘以修正系数进行修正,从而将基于无人机升尺度数据的土壤含盐量监测模型转换为基于卫星影像数据的监测模型。修正后的卫星光谱指数自变量为:$SI=\sqrt{3.113\,4b_r\times 2.325\,4b_b}$,$SI_1=\sqrt{3.113\,4b_r\times 3.040\,6b_g}$。

将已修正的光谱波段和光谱指数分别代入 2 个筛选得到的监测模型,结合实测土壤含盐量进行验证。其中多元线性回归监测模型:$Y=-0.222\,7+30.290\,5B_b+31.973\,3B_g+33.434\,4B_r-46.010\,8SI-45.548\,9SI_1$,其验证 R^2 为 0.420,RMSE 为 0.219%。BP 神经网络监测模型的验证 R^2 为 0.371,RMSE 为 0.235%。

对比分析 2 个模型的验证效果,发现基于混合变量组的多元线性回归模型具有更好的适用性和稳定性,选用该模型进行研究区的土壤盐分反演,得到研究区的土壤含盐量分布图如图 11 所示。其中非盐渍化土壤面积占比为 24.86%,轻度盐渍化土壤分布较广,面积占比达 63.99%,重度盐渍化土壤在研究区分散存在,在北部、中部和南部都有分布,但面积占比相对较小,为 9.67%,盐土则分布得更为零散,面积仅占 1.48%。

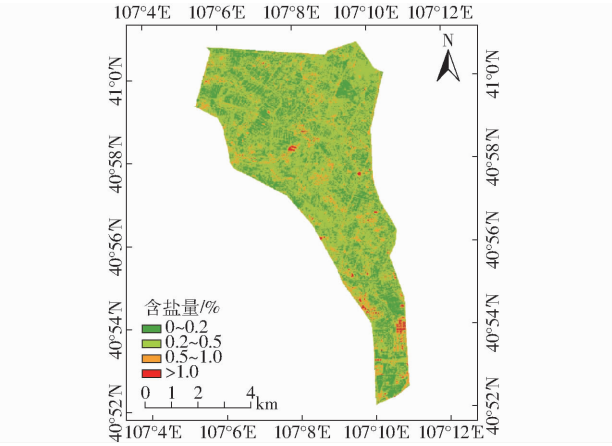

图 11 研究区土壤含盐量升尺度反演图

Fig. 11 Upscale inversion map of soil salinity in study area

3 讨论

将遥感影像的空间信息从原始尺度转换到研究所需的地域单元尺度时所采用方法会显著影响像元聚合结果,进而影响基于聚合结果的土壤盐渍化信息评估。对于地表非均质且空间异质性复杂的尺度转换研究,传统的尺度转换方法可能会面临应用上的局限性,如郝大磊等[35]认为局部平均法仅适用于相对均一的地表,针对其他复杂地表环境下垫面的实际变化情况反映能力不足。内蒙古河套灌区气候属于典型的干旱半干旱大陆性气候,地表蒸发大,研究区内地表盐渍化信息分布不均且强度差异明显,若将单元范围内的像元信息简单进行平均化,一定程度上会弱化地表盐渍化信息本身的自相关性和变异性,导致处理结果与实际情形产生偏差,故选用合适的尺度转换方法准确评估盐分信息具有重要意义[36],针对盐分信息的主导空间特征和过程成为一个重要的研究突破点。冯娟[37]曾用主导变异权重法对趋势面尺度上推模型进行改进,得到的升尺度结果与盐渍化定量监测的 MODIS－SRSI 影像空间分布一致性最好。因此本文尝试引入了空间变异算法,并和传统的尺度转换方法做比较,将试验区无人机各波段影像进行升尺度转换,然后采用不同的评价指标来衡量各种方法的转换效果。结果表明主导变异权重法能有效地实现遥感数据的尺度上推,在保持原始影像数据大部分信息量的基础上,较为合理地体现了数据的局部细节及其纹理特征,由此可看出主导变异权重法的应用对于无人机到卫星升尺度转换的研究领域是一种有益尝试。本文还对 GF－1 卫星数据和 3 种无人机升尺度数据集的光谱波段、光谱指数与实测盐分数据进行相关性分析。基于前人的研究成果[38],挑选与实测盐分数据相关性较高的光谱波段和光谱指数,针对不同数据源分别构建 3 个模型变量输入组,发现升尺度后无人机数据集监测模型精度普遍优于 GF－1 卫星数据。其中主导变异权重法升尺度后的无人机数据集在统计模型和机器学习模型的表现上均好于其他 3 种数据源,说明考虑周边像元的异质性,并在尺度转换过程中将范围内各像元信息以权重形式加以体现可突显区域内盐分信息的光谱特征,从而在提取影像光谱反射率时,其结果较为客观地反映研究区地表真实的盐渍化情况,有助于提升模型反演精度。

在无人机与卫星协同监测土壤盐渍化研究方面,陈俊英等[39]将原始尺度无人机数据建立的趋势面应用在卫星数据上,其构建的升尺度模型反演精度比直接采用卫星模型反演精度更高。本文则依据升尺度后无人机影像与卫星影像之间的关系对模型加以修正。相较于奚雪等[40]在构建星机一体化的滨海麦区土壤含盐量监测模型时,利用无人机原始分辨率光谱波段对 Sentinel 卫星光谱波段进行修正的过程中,需要提取 Sentinel 卫星样点所在单个像元范围内对应的无人机平均光谱反射率。本文对该方法进一步改进,首先是对无人机数据进行升尺度转换,使其与 GF－1 卫星数据处于同一尺度,两者

所对应的像元尺寸保持一致，再通过波段比值均值方法，对卫星光谱波段修正以期达到一体化的目的。结果表明，将最佳的无人机监测模型，即基于混合变量组的多元线性回归模型，应用于实现一体化后的 GF－1 卫星数据，可有效提高后者对土壤盐渍化的监测精度。ZHANG 等[41]利用无人机模型结合波段修正后的 Sentiel－2A 卫星数据对黄河三角洲土壤盐分进行反演，发现当模型输入变量为敏感波段和光谱指数时构建的多元线性回归模型反演效果要好于其他变量组构建的模型，这与本文的研究成果相符合。

4　结论

（1）通过分析主导变异权重法、局部平均法和最邻近法 3 种空间尺度上推方法应用于试验区 4 波段影像后，其升尺度影像均值、标准差、信息熵和平均梯度与原始影像之间的比较结果，发现主导变异权重法在各项指标对比下总体上最为接近原始影像，说明主导变异权重法能较好地保持原始遥感数据的统计特征，更适用于无人机-卫星遥感针对区域盐渍化空间尺度上推研究。

（2）对不同数据源的表层土壤含盐量进行定量监测，结果表明主导变异权重法构建的升尺度土壤含盐量监测模型反演精度好于传统的局部平均法和最邻近法，同时也优于 GF－1 卫星数据，其中不同输入变量组合构建的模型精度存在差异性，表明尺度转换方法和变量组合两种因素在一定程度协同作用于升尺度模型，当确定合适的转换方法和变量组合后可最大程度发挥模型效力。

（3）对比多元线性回归方法和 BP 神经网络构建升尺度模型时精度表现最好的 2 个模型，结合波段比值均值法修正后的卫星数据，得出最佳监测模型为主导变异权重法下基于混合变量组的多元线性回归模型，其 R_v^2 为 0.420，RMSE 为 0.219%，比直接采用 GF－1 卫星数据得到的混合变量组多元线性回归模型 R_v^2 高 0.217，RMSE 低 0.013 个百分点。

参　考　文　献

[1] ABBAS A, KHAN S, HUSSAIN N, et al. Characterizing soil salinity in irrigated agriculture using a remote sensing approach [J]. Physics and Chemistry of the Earth, Parts A/B/C, 2013, 55: 43－52.

[2] El H A, LHISSOU R, CHOKMANI K, et al. Spatiotemporal monitoring of soil salinization in irrigated Tadla Plain (Morocco) using satellite spectral indices[J]. International Journal of Applied Earth Observation and Geoinformation, 2016, 50: 64－73.

[3] 哈学萍，丁建丽，塔西甫拉提·特依拜，等. 基于 SI－Albedo 特征空间的土壤盐渍化遥感监测指数研究[J]. 土壤学报，2009，46(4)：698－703.
HA Xueping, DING Jianli, TASHPOLAT·Tiyip, et al. SI－Albedo space-based remote sensing synthesis index models for monitoring of soil salinization[J]. Acta Pedologica Sinica, 2009, 46(4): 698－703. (in Chinese)

[4] 刘勤，王宏卫，丁建丽，等. 干旱区区域土壤盐渍化监测研究进展及其未来热点[J]. 新疆大学学报(自然科学版)，2014，31(1)：108－115.
LIU Qin, WANG Hongwei, DING Jianli, et al. Research advances on regional soil salinization monitoring in arid area[J]. Journal of Xinjiang University(Natural Science Edition), 2014, 31(1): 108－115. (in Chinese)

[5] 陈红艳，赵庚星，陈敬春，等. 基于改进植被指数的黄河口区盐渍土盐分遥感反演[J]. 农业工程学报，2015，31(5)：107－114.
CHEN Hongyan, ZHAO Gengxing, CHEN Jingchun, et al. Remote sensing inversion of saline soil salinity based on modified vegetation index in estuary area of Yellow River[J]. Transactions of the CSAE, 2015, 31(5): 107－114. (in Chinese)

[6] MULLER S J, VAN NIEKERK A. Identification of WorldView－2 spectral and spatial factors in detecting salt accumulation in cultivated fields[J]. Geoderma, 2016, 273: 1－11.

[7] MILLER B A, KOSZINSKI S, WEHRHAN M, et al. Impact of multi-scale predictor selection for modeling soil properties[J]. Geoderma, 2015, 239－240: 97－106.

[8] 姚远，陈曦，钱静. 定量遥感尺度转换方法研究进展[J]. 地理科学，2019，39(3)：367－376.
YAO Yuan, CHEN Xi, QIAN Jing. A review on the methodology of scale issues in quantitative remote sensing[J]. Scientia Geographica Sinica, 2019, 39(3): 367－376. (in Chinese)

[9] 刘良云. 叶面积指数遥感尺度效应与尺度纠正[J]. 遥感学报，2014，18(6)：1158－1168.
LIU Liangyun. Simulation and correction of spatialscaling effects for leaf area index[J]. Journal of Remote Sensing, 2014, 18(6): 1158－1168. (in Chinese)

[10] 王鹏新，刘郊，李俐，等. 基于点扩散函数的条件植被温度指数降尺度转换方法[J]. 农业机械学报，2017，48(12)：165－173.
WANG Pengxin, LIU Jiao, LI Li, et al. Downscaling transformation method for vegetation temperature condition index based on point spread function[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(12): 165－173. (in Chinese)

[11] 陈香月，丁建丽，葛翔宇，等. 基于机器学习的绿洲土壤盐渍化尺度效应研究[J]. 农业机械学报，2021，52(9)：312－320.
CHEN Xiangyue, DING Jianli, GE Xiangyu, et al. Scale effect on soil salinization simulation in arid oasis based on machine learning methods[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(9): 312－320. (in Chinese)

[12] 白雪娇，王鹏新，张树誉，等. 基于 VTCI 空间尺度上推方法的干旱影响评估[J]. 农业机械学报，2017，48(2)：172－178.

BAI Xuejiao, WANG Pengxin, ZHANG Shuyu, et al. Drought impact assessment based on spatial up-scaling methods of vegetation temperature condition index[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(2): 172 - 178. (in Chinese)

[13] 冯文哲,王新涛,韩佳,等. 基于卫星和无人机遥感数据尺度转换的土壤盐渍化监测研究[J]. 节水灌溉,2020(11):87 - 93,104.
FENG Wenzhe, WANG Xintao, HAN Jia, et al. Research on soil salinization monitoring based on scale conversion of satellite and UAV remote sensing data[J]. Water Saving Irrigation, 2020(11): 87 - 93, 104. (in Chinese)

[14] 毛威,杨金忠,朱炎,等. 河套灌区井渠结合膜下滴灌壤盐分演化规律[J]. 农业工程学报,2018,34(1):93 - 101.
MAO Wei, YANG Jinzhong, ZHU Yan, et al. Soil salinity process of Hetao Irrigation District after application of well-canal conjunctive irrigation and mulched drip irrigation[J]. Transactions of the CSAE, 2018, 34(1): 93 - 101. (in Chinese)

[15] 黄权中,徐旭,吕玲娇,等. 基于遥感反演河套灌区土壤盐分分布及对作物生长的影响[J]. 农业工程学报,2018,34(1):102 - 109.
HUANG Quanzhong, XU Xu, LÜ Lingjiao, et al. Soil salinity distribution based on remote sensing and its effect on crop growth in Hetao Irrigation District[J]. Transactions of the CSAE, 2018, 34(1): 102 - 109. (in Chinese)

[16] ALLBED A, KUMAR L, ALDAKHEEL Y Y. Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: applications in a date palm dominated region[J]. Geoderma, 2014, 230 - 231: 1 - 8.

[17] CHO K H, BEON M, JEONG J. Dynamics of soil salinity and vegetation in a reclaimed area in Saemangeum, Republic of Korea[J]. Geoderma, 2018, 321: 42 - 51.

[18] CHEN J M. Evaluation of vegetation indices and a modified simple ratio for boreal applications[J]. Canadian Journal of Remote Sensing, 1996, 22(3): 229 - 242.

[19] 陈实,徐斌,金云翔,等. 北疆农区土壤盐渍化遥感监测及其时空特征分析[J]. 地理科学,2015,35(12):1607 - 1615.
CHEN Shi, XU Bin, JIN Yunxiang, et al. Remote sensing monitoring and spatial-temporal characteristics analysis of soil salinization in agricultural area of northern Xinjiang[J]. Scientia Geographica Sinica, 2015, 35(12): 1607 - 1615. (in Chinese)

[20] 孙永猛,丁建丽,瞿娟. 基于 NDSI - Albedo 特征空间的 MODIS 积雪丰度信息反演方法研究[J]. 干旱区地理,2013,36(3):520 - 527.
SUN Yongmeng, DING Jianli, QU Juan. Inversion of the MODIS snow abundance radio based on NDSI - Albedo feature space [J]. Arid Land Geography, 2013, 36(3): 520 - 527. (in Chinese)

[21] JORDAN C F. Derivation of leaf-area index from quality of light on the forest floor[J]. Ecology, 1969, 50(4): 663 - 666.

[22] WANG G, GERTNER G, ANDERSON A B. Up-scaling methods based on variability-weighting and simulation for inferring spatial information across scales[J]. International Journal of Remote Sensing, 2004, 25(22): 4961 - 4979.

[23] 黄慧萍. 面向对象影像分析中的尺度问题研究[D]. 北京:中国科学院研究生院(遥感应用研究所),2003.
HUANG Huiping. Scale issues in object-oriented image analysis[D]. Beijing: Institute of Remote Sensing Applications, Chinese Academy of Sciences, 2003. (in Chinese)

[24] 徐凯健,田庆久,朱小波,等. 空间尺度上推转换对影像信息的影响分析[J]. 测绘科学,2019,44(5):117 - 125.
XU Kaijian, TIAN Qinjiu, ZHU Xiaobo, et al. Influences of commonly used up-scaling algorithms on image spectrum information of forest by comparision with multiscale satellite image data[J]. Science of Surveying and Mapping, 2019, 44(5): 117 - 125. (in Chinese)

[25] 韩鹏,龚健雅,李志林,等. 遥感影像空间尺度上推方法的评价[J]. 遥感学报,2008,12(6):964 - 971.
HAN Peng, GONG Jianya, LI Zhilin, et al. Comparing the effect of aggregation methods for remote sensing image[J]. Journal of Remote Sensing, 2008, 12(6): 964 - 971. (in Chinese)

[26] 李乐,宋维静,陈腊娇,等. 遥感数据的高斯金字塔尺度上推方法研究[J]. 地球信息科学学报,2017,19(5):682 - 691.
LI Le, SONG Weijing, CHEN Lajiao, et al. Research on scaling up of remotely sensed data with Gaussian pyramid method [J]. Journal of Geo-information Science, 2017, 19(5): 682 - 691. (in Chinese)

[27] 韩鹏,龚健雅,李志林. 基于信息熵的遥感分类最优空间尺度选择方法[J]. 武汉大学学报(信息科学版),2008, 33(7):676 - 679.
HAN Peng, GONG Jianya, LI Zhilin. A new approach for choice of optimal spatial scale in image classification based on entropy[J]. Geomatics and Information Science of Wuhan University, 2008, 33(7): 676 - 679. (in Chinese)

[28] 张学典,杨帆,常敏. 基于图像信息熵统计直方图的图像增强算法[J]. 包装工程,2020,41(13):251 - 260.
ZHANG Xuedian, YANG Fan, CHANG Min. Image enhancement algorithm based on entropy statistical histogram of image information[J]. Packaging Engineering, 2020, 41(13): 251 - 260. (in Chinese)

[29] 李萍,赵庚星,高明秀,等. 黄河三角洲土壤含水量状况的高光谱估测与遥感反演[J]. 土壤学报,2015,52(6):1262 - 1272.
LI Ping, ZHAO Gengxing, GAO Mingxiu, et al. Hyperspectral estimation and remote sensing retrieval of soil water regime in the Yellow River Delta[J]. Acta Pedologica Sinica, 2015, 52(6): 1262 - 1272. (in Chinese)

[30] MARSHALL F E, SMITH D T, NICKERSON D M. Empirical tools for simulating salinity in the estuaries in Everglades National Park, Florida[J]. Estuarine, Coastal and Shelf Science, 2011, 95(4): 377 - 387.

[31] LESCH S M, STRAUSS D J, RHOADES J D. Spatial prediction of soil salinity using electromagnetic induction techniques: 1. Statistical prediction models: a comparison of multiple linear regression and cokriging[J]. Water Resources Research, 1995, 31(2): 373 - 386.

(下转第 251 页)

297－306.
LUO Xianghua, NI Jinren, LUO Huaming. Multicollinearity problems and their treatment in statistical studies of land use change [J]. Journal of Basic Science and Engineering, 2001, 9(4): 297－306. (in Chinese)
[54] 张智韬,李援农,杨江涛,等. 遥感监测土壤含水率模型及精度分析[J]. 农业工程学报, 2008,24(8): 152－156.
ZHANG Zhitao, LI Yuannong, YANG Jiangtao, et al. Model for monitoring soil moisture using remote sensing and its accuracy analysis[J]. Transactions of the CSAE, 2008, 24(8): 152－156. (in Chinese)
[55] 屈创. 基于多源遥感数据的白龙江流域土壤水分反演研究[D]. 兰州: 兰州大学,2014.
QU Chuang. The study of soil moisture retrival based on multi-source RS data in the Bailong Basin[D]. Lanzhou: Lanzhou University, 2014. (in Chinese)
[56] 陈亮,姚保顺,何厚军,等. 基于 HJ－1B 数据的作物根系土壤水分遥感监测[J]. 华北水利水电大学学报(自然科学版),2016,37(3): 27－31.
CHEN Liang, YAO Baoshun, HE Houjun, et al. Monitoring soil moisture in root-system zone based on HJ－1B data with remote sensing technology[J]. Journal of North China University of Water Resources and Electric Power (Natural Science Edition), 2016, 37(3): 27－31. (in Chinese)
[57] 乔冬梅,史海滨,薛铸. 盐渍化地区油料向日葵根系吸水模型的建立[J]. 农业工程学报, 2006,22(8): 44－49.
QIAO Dongmei, SHI Haibin, XUE Zhu. Development of root-water-uptake model for oil sunflower in saline soil [J]. Transactions of the CSAE, 2006, 22(8): 44－49. (in Chinese)
[58] CHEN N C, LI J Z, ZHANG X. Quantitative evaluation of observation capability of GF－1 wide field of view sensors for soil moisture inversion[J]. Journal of Applied Remote Sensing, 2015, 9(1): 097097.
[59] NIE Y, TAN Y, DENG Y, et al. Suitability evaluation of typical drought index in soil moisture retrieval and monitoring based on optical images[J]. Remote Sensing, 2020, 12(16): 2587.
[60] WANG Q, LI J, JIN T, et al. Comparative analysis of Landsat－8, Sentinel－2, and GF－1 data for retrieving soil moisture over wheat farmlands[J]. Remote Sensing, 2020, 12(17): 2708.
[61] TAO L, WANG G, CHEN W, et al. Soil moisture retrieval from SAR and optical data using acombined model[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(2): 637－647.
[62] 贾艳茹,布和. 基于遥感农田表层土壤水分反演研究[J]. 内蒙古水利,2015(3): 9－10.
JIA Yanru, BU He. Research on retrieval of surface soil moisture in farmland based on remote sensing[J]. Inner Mongolia Water Resources, 2015(3): 9－10. (in Chinese)

(上接第 238 页)

[32] DIAO S, LIU C, ZHANG T, et al. Extraction of remote sensing information for lake salinity level based on SVM: a case from Badain Jaran desert in Inner Mongolia[J]. Remote Sensing for Land & Resources, 2016, 28(4): 114－118.
[33] 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 Dong, GUAN Qingsong, HUANG Wenjiang, et al. Remote sensing inversion of leaf area index based on support vector machine regression in winter wheat[J]. Transactions of the CSAE, 2013, 29(7): 117－123. (in Chinese)
[34] YAO R J, YANG J S, ZOU P, et al. BP neural network model for spatial distribution of regional soil water and salinity[J]. Acta Pedologica Sinica, 2009, 46(5): 788－794.
[35] 郝大磊, 肖青, 闻建光,等. 定量遥感升尺度转换方法研究进展[J]. 遥感学报, 2018, 22(3): 408－423.
HAO Dalei, XIAO Qing, WEN Jianguang, et al. Advances in upscaling methods of quantitative remote sensing[J]. Journal of Remote Sensing, 2018, 22(3): 408－423. (in Chinese)
[36] WANG J, DING J, YU D, et al. Machine learning-based detection of soil salinity in an arid desert region, Northwest China: a comparison between Landsat－8 OLI and Sentinel－2 MSI[J]. Science of the Total Environment, 2020, 707: 136092.
[37] 冯娟. 土壤盐渍化遥感建模尺度效应分析[D]. 乌鲁木齐:新疆大学,2018.
FENG Juan. Scale effect analysis of soil salinization modeling based on remote sensing[D]. Urumqi: Xinjiang University, 2018. (in Chinese)
[38] 张智韬,魏广飞,姚志华,等. 基于无人机多光谱遥感的土壤含盐量反演模型研究[J]. 农业机械学报,2019,50(12): 151－160.
ZHANG Zhitao, WEI Guangfei, YAO Zhihua, et al. Soil salt inversion model based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 151－160. (in Chinese)
[39] 陈俊英,王新涛,张智韬,等. 基于无人机-卫星遥感升尺度的土壤盐渍化监测方法[J]. 农业机械学报,2019,50(12): 161－169.
CHEN Junying, WANG Xintao, ZHANG Zhitao, et al. Soil salinization monitoring method based on UAV－satellite remote sensing scale-up[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 161－169. (in Chinese)
[40] 奚雪,赵庚星,高鹏,等. 基于 Sentinel 卫星及无人机多光谱的滨海冬小麦种植区土壤盐分反演研究——以黄三角垦利区为例[J]. 中国农业科学,2020,53(24): 5005－5016.
XI Xue, ZHAO Gengxing, GAO Peng, et al. Inversion of soil salinity in coastal winter wheat growing area based on sentinel satellite and unmanned aerial vehicle multi-spectrum—a case study in Kenli District of the Yellow River Delta[J]. Scientia Agricultura Sinica, 2020, 53(24): 5005－5016. (in Chinese)
[41] ZHANG S, ZHAO G. A harmonious satellite-unmanned aerial vehicle-ground measurement inversion method for monitoring salinity in coastal saline soil[J]. Remote Sensing, 2019, 11(14): 1700.