

doi: 10.6046/zrzyyg.2023245

引用格式: 骆振海, 张超, 冯绍元, 等. 土壤盐渍化光学遥感监测方法研究进展[J]. 自然资源遥感, 2024, 36(4): 9–22. (Luo Z H, Zhang C, Feng S Y, et al. Advances in research on methods for optical remote sensing monitoring of soil salinization[J]. Remote Sensing for Natural Resources, 2024, 36(4): 9–22.)

土壤盐渍化光学遥感监测方法研究进展

骆振海, 张超, 冯绍元, 唐敏, 刘锐, 孔纪迎

(扬州大学水利科学与工程学院, 扬州 225009)

摘要: 土壤盐渍化是导致土壤肥力下降、生产力衰退、植被覆盖减少以及作物产量降低的重要原因之一。光学遥感监测技术具有宏观、及时、动态和低成本等优点, 对于实现土壤盐渍化的动态监测具有重要意义。然而, 目前少有多尺度遥感数据、多类型遥感特征参量以及反演模型进行系统性梳理和总结的综述研究。为此, 该文首先对光学遥感数据源进行了梳理, 并总结了目前盐渍土监测相关研究中使用的遥感数据来源与尺度平台, 将多源遥感数据分为卫星、航空和地面3种不同平台; 其次, 整理了目前主流的建模特征参量以及统计回归和机器学习2类经典的反演方法, 并分析了各方法的研究现状; 最后, 对遥感数据源间的融合进行了探讨, 比较了各建模方法的优缺点, 并结合当前研究热点, 展望了将数据同化与深度学习应用于土壤盐渍化监测研究的前景。

关键词: 土壤盐渍化; 土壤盐分; 光学遥感; 反演模型; 特征参量

中图法分类号: TP 79 **文献标志码:** A

文章编号: 2097-034X(2024)04-0009-14

0 引言

土壤盐渍化问题在全球范围内普遍存在。根据联合国教科文组织(United Nations Educational, Scientific and Cultural Organization, UNESCO)和世界粮农组织(Food and Agriculture Organization of the United Nations, FAO)的数据统计, 全球盐渍土面积约为 $9.54 \times 10^9 \text{ hm}^2$ ^[1], 其中中国盐渍土总面积约为 $3.6 \times 10^7 \text{ hm}^2$ ^[2]。我国耕地中盐渍化面积达到 $920.9 \times 10^4 \text{ hm}^2$, 占全国耕地面积的6.62%。土壤盐渍化是导致土地肥力下降、生产力衰退、植被覆盖度减少以及作物产量降低的重要原因之一^[3]。盐渍土也是我国中低产土壤中的主要类型之一, 而土壤盐渍化又是我国干旱、半干旱和滨海地区最常见的土地退化问题, 严重影响着当地的作物产量、经济发展和环境可持续性。

盐渍土的形成是一个复杂的过程, 因此对其进行探测和动态监测是一项相对困难的工作。传统监测方法通常涉及人工野外取样和分析, 这种方法不仅耗时且工作量大, 只适用于小范围测量, 也可能存在样本的代表性问题, 因此难以实现大面积动态监

测^[4]。遥感技术通过获取地表影像数据, 能够快速获取大范围内不同时间下的地物信息。这种技术具有宏观、综合、及时、动态和低成本等特点, 在大面积土壤盐度反演中被广泛应用^[5]。对含盐量不同的土壤, 可见光和近红外波段的光谱响应存在差异, 高盐分土壤的光谱响应较强^[6]。利用遥感技术了解土壤盐分可能发生变化的时间、方式和地点, 实现土壤盐渍化的动态监测, 对于土壤和水资源高效利用具有重要意义。

在过去的几十年中, 研究学者们在盐渍化土壤的光谱特征、遥感数据源以及土壤盐分反演方法等方面取得了显著进展, 经历了从遥感影像目视解译到基于影像光谱特征的数字遥感影像计算机自动分类处理的演变, 并且利用了诸如可见光、多光谱、高光谱和热红外等多源遥感数据来进行相关研究^[7]。目前, 利用遥感数据特征参量构建反演模型已成为土壤盐渍化研究的热点^[8-9]。其中, 定量评价土壤盐化程度的核心任务是建立土壤含盐量、土壤电导率、盐渍化面积和遥感特征参量之间的关系, 建立可靠的遥感数据经验和物理反演模型, 以实现对研究区内土壤盐渍化时空动态的监测^[10-11]。

本研究在 Web of Science 核心合集数据库中

收稿日期: 2023-08-07; 修订日期: 2024-03-15

基金项目: 国家自然科学基金项目“多源遥感与作物-水盐耦合模型同化的盐渍化农田水盐反演方法研究”(编号: 52379049)和江苏省研究生科研与实践创新计划项目(SJCX23_1945)共同资助。

第一作者: 骆振海(2000-), 男, 硕士研究生, 主要研究方向为土壤盐渍化遥感定量监测。Email: MZ120221105@stu.yzu.edu.cn。

通信作者: 张超(1990-), 男, 博士, 副教授, 主要从事多尺度农田水肥盐遥感监测与模拟研究。Email: zhangc1700@yzu.edu.cn。

“soil salinization”“salinity”“salt”和“remote sensing”作为主题词检索了 2000—2023 年内共 2 163 篇相关研究文献。通过可视化分析,筛选出现频次超过 30 次的关键词,其中,出现频率较高的关键词主要有 remote sensing(遥感)、salinity(盐分)、soil salinity(土壤盐分)、soil moisture(土壤水分)、band(波段)、UAV(无人机)、satellite(卫星)、model(模型)等。这表明土壤盐分监测依赖于一定的模型和技术方法。利用光谱数据结合反演模型监测土壤盐渍化状况已成为常用的研究手段。在以往的研究中,研究者们主要集中于探索遥感技术在土壤盐渍化反演中的应用,特别是在单个建模因子的选择、模型建立及其精度验证等方面,如 Sahbeni 等^[12]深入分析和讨论了利用遥感技术进行土壤盐分测绘和监测的相关工作; Ma 等^[13]对中国盐渍土管理的研究历程、土壤盐渍化监测的研究进展以及主要的建模方法进行了梳理。但目前对多尺度遥感数据、多类型遥感特征参量以及反演模型进行系统性梳理和总结的综述研究较少。因此本文的主要内容将围绕以下几个方面进行梳理和总结:①总结光学遥感反演盐渍土信息的主要数据源;②梳理常用的土壤盐渍化反演模型;③分析目前土壤盐渍化遥感监测的局限性,并对未来的建模和反演方法进行展望。

1 光学遥感数据源

遥感是一种重要的对地观测技术,它主要利用卫星或飞机上的传感器,在无需物理接触的情况下获取遥感影像和地物信息^[14]。光学遥感成像是遥感技术的一个重要分支,其传感器工作波段限于可见光至红外波段范围(350~2 500 nm),包括可见光、近红外和短波红外,被广泛应用于植被监测、水质监测、精准农业等领域^[15]。光学遥感技术提供了高分辨率的多种类型影像数据,覆盖范围广且具有时间上的连续性,能够获取丰富的遥感信息。基于光谱信息表征土壤理化性质变化的特点,已验证了光学遥感数据在监测土壤盐渍化方面的有效性^[16]。光学遥感主要获取地物的辐射亮度和反射率数据^[17],依赖于卫星、航空和地面遥感平台等几种主要方式。

1.1 卫星遥感监测

自 20 世纪 70 年代开始,学者们开始使用卫星遥感影像数据进行土壤盐渍化监测的相关研究,主要基于土壤反射率随含盐量变化规律进行定量反演^[18]。到了 90 年代后期,随着遥感数据源的逐渐丰富,研究方法变得更加复杂^[19]。此后,随着航天

技术的进步,卫星传感器的空间分辨率不断提高,从 Landsat,MODIS,Sentinel 系列等中分辨率卫星扩展到包括 QuickBird,GeoEye,WorldView 等高分辨率卫星(表 1),这实现了更精细的地表特征观测。另一方面,传感器的光谱分辨率也显著提升,高光谱遥感数据为盐渍土的精准定量监测提供了更多的光谱波

表 1 常用卫星遥感主要参数

Tab.1 Main parameters and features of commonly used satellite remote sensing

卫星名称	波段范围/ μm	空间分辨率/m	时间分辨率
Landsat7	0.45~12.5	全色: 15 多光谱: 30	重访周期 16 d
Landsat8	0.43~12.51	多光谱: 15/30 热红外: 100	重访周期 16 d
Sentinel-2B	0.4~2.4	10/20/60	单星重访周期 10 d
高分一号 (GF-1)	全色:0.45~ 0.90 多光谱:0.45~ 0.89	PMS 全色: 2 PMS 多光谱: 8 WV 多光谱: 16	重访周期 4 d
高分六号 (GF-6)	高分相机: 0.45~0.90 宽幅相机: 0.45~0.89	PMS 全色: 2 PMS 多光谱: 8 WV 多光谱:16	与 GF-1 组网运行后,将使遥感数据获取的时间分辨率从 4 d 缩小到 2 d
Terra, Aqua	0.4~14.4	MODIS: 250 ~ 1 000 ASTER: 15 ~ 90	重访周期 1~2 d
资源三号 (ZY-3)	全色: 0.50~0.80 多光谱: 0.45~ 0.89	正视全色: 2.1 前、后视全色: 3.5 正视多光谱: 6	重访周期 5 d
HJ-1B	0.43~12.5	CCD 相机: 30 红外多光谱相机: 150/300	重访周期 4 d
Pleiades-1A	0.43~0.95	全色: 0.5 多光谱: 2.0	重访周期 1 d
HJ-1A	0.43~0.95	CCD 相机: 30 高光谱成像仪: 100	重访周期 4 d
RapidEye	0.45~0.9	全色 0.61 ~ 0.72 多光谱 2.44 ~ 2.88	重访周期 1 d
QuickBird	0.45~0.9	全色: 0.61 多光谱: 2.44	重访周期 1~ 3.5 d
IKONOS	全色 0.45~0.9 多光谱:0.45~ 0.88	全色: 1 多光谱: 4	重访周期 1~ 3 d
WorldView-2	0.4~1.04	全色: 0.5 多光谱: 1.8	重访周期 1.1 d
WorldView-3	0.4~1.04	全色: 0.31 多光谱: 1.24	重访周期 1 d
SPOT-6	0.45~0.89	全色: 1.5 多光谱: 6	重访周期 2~3 d

段信息,发挥着重要作用。数据的分析与处理也经历了丰富的发展历程,从早期的人工可视化解读逐渐演变为自动化特征提取和分类算法,并进一步拓展到基于统计学、机器学习和深度学习等算法的遥感影像分类、识别和反演工作^[20]。在土壤盐渍化监测中,常用的光学数据源诸如高分辨率影像、高光谱影像和多光谱影像等能够提供详细的土壤信息,为研究人员提供了广泛的选择和应用空间。高分辨率遥感影像可用于准确描述地物纹理和形状,而高光谱影像则因其具有较高的光谱波段信息,在遥感建模和特征识别方面得到广泛的应用^[21]。另外,多光谱影像具备宽阔的视场、实时信息采集和周期性覆盖能力,使得监测土壤盐分变化变得更加容易^[22]。

Gorji 等^[23]分析了基于 Landsat8 OLI 和 Sentinel-2A 数据构建的光谱指数和实测土壤电导率的关系,对乌鲁米耶湖西部的土壤盐分进行了估算; Allbed 等^[24]通过构建土壤盐度指数和 IKONOS 影像波段反射率之间的关系,对土壤盐分的空间变化进行了研究; 陈实等^[25]基于 MODIS 数据监测分析了北疆农区土壤盐渍化状况及其空间动态变化; 陈俊英等^[26]在无人机和 GF-1 卫星遥感数据的基础上,进行了河套灌区沙壕灌域地区土壤盐渍化监测研究; Farahmand 等^[27]评估了基于光学 Sentinel-2A 影像数据的各种非线性回归模型估算土壤盐分含量的能力。自我国的 GF-1 卫星发射以来,空间对地观测能力得到了显著提升,并在各领域得到了广泛的应用。在基于卫星遥感影像的土壤盐渍化监测研究中,可见光到红外光谱中的特征参量能够更准确地估算土壤盐分含量,从而提高了土壤盐渍化监测的准确性^[3]。

1.2 航空遥感监测

近年来,航空遥感平台如无人机等技术迅速发展,并逐渐融入民用领域,成为农业研究和应用中热点工具。无人机具有便携、高灵活性和飞行时间自由等优点,能够在较低高度和不同类型的区域飞行,并捕获具有高时空分辨率的影像^[28]。在农业遥感监测中,固定翼、多旋翼和无人驾驶直升机是常用的无人机制式(表 2)。根据不同的监测任务,可以在无人机平台上安装多种传感器,如数码相机、多光谱相机、高光谱相机、热成像相机和激光雷达等光学设备(表 3)。相对于卫星传感器,机载传感器具有提供更高分辨率影像、受云层和大气气溶胶等噪声干扰较小等优点,使其更适用于农业生产实践。特别是在当前农业生产趋于高度区域化、一体化、精准化以及智能化的趋势下,低空遥感平台展现出更广阔的发展前景^[29]。Ivushkin 等^[30]研究指出,在土壤盐渍化监测中,无人机搭载高光谱相机、多光谱相机、热红外相机和激光雷达等设备显示出巨大的潜力。

表 2 农业遥感监测的无人机特性
Tab.2 UAV characteristics for agricultural remote sensing monitoring

类别	常见机型	优点	缺点
固定翼	DJI Phantom 4,	续航时间长,负载大,飞行速度快,可操作范围大	起飞需要助跑,着陆需要滑翔,不能悬停
	Parrot Bebop 2,		
	DJI Mavic Air 2		
多旋翼	大疆精灵,大疆 M600,	可水平和垂直飞行、起降,可悬停在特定位置,自主导航,结构简单	续航时间短,负载小,对恶劣环境的抵抗力较差
	大疆 S1000		
直升机	K-MAX, JT8D, VSR700	垂直起降,悬停在给定位置,飞行稳定性高	机翼结构复杂,维护成本高

表 3 不同类型的机载传感器及其特性
Tab.3 Different types of airborne sensors and characteristics

类型	传感器	光谱波段 ^①	波长范围/ μm	特性	参考文献
数码相机	Sony DSC-QX 100	R,G,B	—	分辨率: 2 020 万像素 感光度: 160~12 800 质量: 179 g	[31]
	Nikon D90	R,G,B	—	分辨率: 1 230 万像素 感光度: 200~3 200 质量: 620 g	[32]
多光谱成像仪	XCam Multi-Spectrum	G,R,R-edge,NIR	0.55~0.79	高度自动化,凝视成像 质量: 470 g	[33]
	Micro-MCA	G,R,R-edge,NIR	0.45~1	分辨率: 130 万像素 质量: 497~1 000 g 镜头焦距: 9.6 nm	[34]
	Parrot Sequoia	G,R,R-edge,NIR	0.55~0.79	分辨率: 120 万像素 质量: 72 g 帧频: 1 帧/s	[35]

(续表)

类型	传感器	光谱波段	波长范围/ μm	特性	参考文献
高光谱成像仪	Nano-Hyperspec	340 个波段	0.4~1	空间像素: 1 020 光圈: F/2.5 质量: 1 000 g	[36]
	Rikola	最大 380 个波段	0.5~0.9	波段反射率: 30 帧/s 质量: 720 g 地面采样距离: 100 m 时为 6.5 cm	[30,36]
	Gaia Sky-mini	128/256/520/ 1 040	0.4~1	质量: 1 000 g 像素间距: 6.45 μm 横向视场: 168 m	[37]
热红外成像仪	Tau \odot 2	—	8~14	红外分辨率: 640×512 像素尺寸: 17 μm 温度范围: -20~100 $^{\circ}\text{C}$	[38]
	Fluke TiX620	—	7.5~14	图像分辨率: 640×480 质量 1.5 kg 温度范围: -40~600 $^{\circ}\text{C}$	[39]
激光雷达	VUX \odot -1UAV	—	—	质量: 3 600 g, 波长: 1 550 nm, 光斑直径: 25 nm	[30]

① B 为蓝色波段; R 为红色波段; G 为绿色波段; NIR 为近红外波段; R-edge 为红边波段。

无人机具备携带不同传感器能力,可以在可见光、近红外和中红外波段上进行土壤盐分含量的反演,从而提高估算精度和可靠性^[40-41]。例如, Xie 等^[33]使用配备 XCam 多光谱相机的多旋翼无人机采集了中国浙江省杭州湾南岸的多光谱影像,并结合卫星数据采用支持向量机(support vector machines, SVM)分类方法对研究区裸地和植被进行分类,根据分类结果构建模型,充分发挥了无人机在提供准确光谱信息和大尺度卫星光谱数据互补方面的优势; Hu 等^[42]则利用搭载在无人机上的高光谱相机,定量表征了田间尺度的土壤盐分含量和状态。近年来,热红外传感器由于技术的改进和成本的降低越来越受到关注。目前,有 2 种主要类型的热红外成像设备,一种是能够捕捉点或线的扫描设备,另一种是具有二维红外焦平面阵列的扫描设备。热红外成像具有非入侵、非接触和无损的优势,能够快速确定植被冠层和土壤表面的温度分布。Tian 等^[39]利用热红外遥感数据研究了土壤盐分胁迫对植被蒸散和生长的影响,研究发现土壤盐分越高,植被冠层覆盖率越低。另外,机载激光雷达是一种新型的主动遥感技术,其最显著的优势是能够直接获取高精度三维点云数据。乔纪纲等^[43]结合激光雷达和多光谱数据,对莺歌海滨岸带进行地表信息提取,深入研究了该区域土地退化、植被分布以及湿地特征。尽管无人机在农业监测中得到广泛应用,但仍然面临一些挑战,包括续航能力、负载能力以及监测的有效性等方面的问题。此外,由于无人机搭载不同类型的相机,获取的影像通常呈现多元化和不规则的形态,需进一步借助专业软件进行特定的数据预处理和分析。未来的发展需要尽快实现轨迹飞行、数

据采集和诊断填图的智能化和自动化,以更好地应对当前的挑战,并进一步促进低空遥感在农业监测中的应用^[44]。

1.3 地面遥感监测

随着近端传感技术的不断发展,各种地面遥感平台逐渐增多。近端传感技术,如时域反射仪、大地电导率仪、地物光谱仪、荧光光谱仪(表 4)等,以及光学、热红外、微波影像等技术也日益成熟,为多要素、多尺度一体化盐渍化土壤水盐信息的获取提供了新的手段^[45]。例如,通过采集不同深度的土壤盐分数据,可利用电磁感应仪以水平和垂直 2 种模式来测量不同深度土壤电导率,进而根据相关关系计算出土壤盐分含量^[46]。Deng 等^[47]以渭干河—库车

表 4 盐渍土遥感监测的近地仪器

Tab.4 Near-earth instruments for remote sensing monitoring of saline soils

类 型	传感器	特性	优点	缺点
土壤含水量测量	TDR	利用电磁波的传播时间来测量土壤含水量	非侵入性,实时测量,高精度	成本较高,结果需要根据特定的土壤类型进行校准
传导式电导率仪	Thermo Scientific Orion	适用于浅层土壤电导率测量	快速测量,无需采样,使用范围广	易受环境影响,空间分辨率有限,数据解释复杂
感应式电导率仪	EM38-MK2	适用于较深层土壤和地下水电导率测量		
手持式便携式光谱仪	SR-3500 地面光谱仪	操作界面简单、可快速获取光谱数据	高效、快速,可提供多个参数进行分析	覆盖的波长范围有限,需要校准,需要大量的参考样本
高分辨率光谱仪	ASD 光谱仪	可提供更精细的光谱信息		

河三角洲绿洲为研究区,运用电磁感应技术对典型地块的土壤电导率进行测量,以评估该地区土壤剖面中盐分的空间分布;Kahaer 等^[48]对野外采集的土壤样品进行了室内高光谱测量和电导率测定,通过参数筛选,建立了土壤电导率的高光谱估算模型,成功实现了土壤盐分的有效监测。电磁感应仪在评估多时空尺度下土壤盐渍化的性质、起源和演变方面得到广泛应用。Wu 等^[22]利用 EM38-MK2 电导率仪测量了伊拉克中部地区的土壤电导率,并结合卫星遥感影像建立了遥感盐分反演模型,盐分含量预测准确率达到 82.6%;Wu 等^[11]使用 SR-3500 光谱仪对平罗地区的土壤样品进行反射率测量,并基于 Landsat 影像、理化性质以及敏感波段,建立了一种新的模型来模拟和预测研究区土壤盐渍化状况,结果表明,绿光、蓝光和近红外光与土壤盐分含量存在显著相关性。电磁能、土壤表面和盐分的物理化学特征之间的相互作用使得在干旱地区遥感监测土壤盐碱化成为可能。相对于非盐渍土,受盐渍影响的土壤在光谱的可见光和近红外区域显示出更高的光谱反射率。Xu 等^[49]使用 ASD 光谱仪测定了中国内蒙古自治区河套灌区表层的不同土壤水分和盐浓度下的反射率,利用 540 nm,1 740 nm,2 010 nm 和 2 350 nm 波段数据得到的盐分估算模型决定系数 R^2 达到 0.951。

2 基于光学遥感数据的土壤盐渍化反演方法

土壤盐渍化的反演方法主要包括直接方法和间接方法 2 种。直接方法是指从遥感影像中直接对盐渍化土壤进行解译。由于盐分积累,土壤表层形成盐壳或盐皮,在地表呈现浅色或灰白色。遥感影像中的部分可见光和近红外波段数据对土壤盐分变化较为敏感,通过将其与土壤盐分含量关联构建土壤盐度指数,可以有效监测裸地土壤的盐渍化状况^[50]。间接方法主要通过植被特征、土壤温度、土壤水分和土壤理化性质等间接反演土壤盐渍化特征。受盐胁迫的植物会在形态上发生变化(如叶绿素、干物质和叶面积指数等),在光谱上呈现出不同的响应特征,可以提取此类特征作为特征参量建立其与土壤盐分含量之间的关系。

2.1 遥感特征参量

利用遥感数据定量评估土壤盐分的核心方法是明确相关盐分指标与遥感数据之间的关系。遥感影像通过预处理后具有丰富的地物光谱信息,大量研究表明,植被指数、盐分指数、水分指数以及温度指

数等常用于土壤盐分的反演研究,本文总结了现有研究中有代表性的遥感特征参量,如表 5 所示。

表 5 常用光谱指数计算公式
Tab.5 Commonly used spectral indices calculation formulas

特征参量	变量名称	公式 ^①	参考文献
盐分指数	盐分指数 (salinity index, SI)	$\sqrt{B \times R}$	[9]
	盐分指数 (SI1)	$\sqrt{G \times R}$	[17,51,52]
	盐分指数 (SI2)	$\sqrt{G^2 + R^2 + NI R^2}$	[17,51,52]
	盐分指数 (SI3)	$\sqrt{G^2 + R^2}$	[17,51,52]
	盐分指数 (SI6)	$B \times \frac{R}{G}$	[52]
	盐分指数 (SI7)	$NIR \times \frac{R}{G}$	[53]
	亮度指数 (brightness index, BI)	$\sqrt{R^2 + NI R^2}$	[51,54]
	归一化盐分指数 (normalized salinity index, NDSI)	$\frac{R - NIR}{R + NIR}$	[55]
	盐分指数 (salinity index, SI-T)	$\left(\frac{R}{NIR}\right) \times 100$	[56]
	强度指数 (intensity index, INT1)	$\frac{G + R}{2}$	[51,57]
植被指数	土壤调节植被指数 (soil-adjusted vegetation index, SAVI)	$\frac{(NIR - R) \times 1.5}{NIR + R + 0.5}$	[17,58]
	归一化植被指数 (normalized vegetation index, NDVI)	$\frac{NIR - R}{NIR + R}$	[16,17,22,59]
	重整化差异植被指数 (renormalize differential vegetation index, RDVI)	$\sqrt{\frac{NIR - R}{NIR + R}}$	[60]
	绿色归一化差分植被指数 (green normalized differential vegetation index, GNDVI)	$\frac{NIR - G}{NIR + G}$	[60]
	三角植被指数 (triangular vegetation index, TVI)	$\sqrt{\frac{NIR - R}{NIR + R}} + 0.5$	[60]
	差值植被指数 (differential vegetation index, DVI)	$NIR - R$	[16,17]
	归一化差值绿色指数 (normalized difference green index, NDGI)	$\frac{G - R}{G + R}$	[61]
	增强化归一植被指数 (enhanced normalized differential vegetation index, ENDVI)	$\frac{NIR + SWIR_2 - R}{NIR + SWIR_2 + R}$	[11]

(续表)

特征参量	变量名称	公式 ^①	参考文献
水分指数	水分指数 (water index, WI)	$\frac{NIR}{SWIR}$	[10]
	归一化水分指数 (normalized differential water index, NDWI)	$\frac{NIR - SWIR}{NIR + SWIR}$	[15,62]
温度	温度植被干旱指数 (temperature vegetation drought index, TVDI)	$\frac{T_S - T_S^{min}}{T_S^{max} - T_S^{min}}$	[63]
	植被温度条件指数 (vegetation temperature condition index, VTCI)	$\frac{LST_{NDVI}^{max} - LST_{NDVI}}{LST_{NDVI}^{max} - LST_{NDVI}^{min}}$	[64]

① $B, R, G, NIR, SWIR$ 和 $SWIR_2$ 分别为蓝光、红光、绿光、近红外和短波红外波段反射率; L 为常数 (通常取值为 1); T_S 为地表温度; T_S^{max} 和 T_S^{min} 分别为 T_S 的最大值和最小值; LST_{NDVI} 为 $NDVI$ 像素值的地表温度; LST_{NDVI}^{max} 和 LST_{NDVI}^{min} 分别为 LST_{NDVI} 的最大值和最小值。

1) 光谱特征参数。光谱特征参数是指在一定波长范围内的光谱数据中,通过对光谱曲线进行分析和计算获得的描述性指标。这些参数可以用来表征不同物质或对象的光谱特性,包括反射率、吸收率、辐射亮度等。土壤盐分会对土壤表面的反射率产生影响,盐渍化土壤在光谱的可见光和近红外区域呈现出比非盐渍化土壤更高的光谱响应^[65]。Sidike 等^[66]采用偏最小二乘回归方法筛选了土壤盐分敏感波段,研究结果表明近红外波段对土壤盐分的光谱响应最为显著; Fan 等^[67]通过统计分析方法证实土壤盐分与 NIR 和 $SWIR$ 波段的相关性更高; Zhang 等^[68]通过原始反射率相关图、一阶导数光谱相关图和偏最小二乘回归分析,发现 395~410 nm, 483~507 nm, 632~697 nm, 731~762 nm, 812~868 nm, 884~909 nm 和 918~930 nm 波长是土壤盐分的敏感光谱波段。此外,有学者提出采用 $NDSI$ 结合遥感影像可实现盐渍土区域监测^[55]。Abdullah 等^[69]通过主成分分析 (principal component analysis, PCA) 构建了基于 5 个盐度指数和 11 个环境变量的土壤盐分估算模型,并利用土壤调查和土地覆盖图的地面土壤盐分预测值评估模型的预测精度。同时, Khan 等^[70]研究表明, BI , $NDSI$ 和 SI 等指数在估算巴基斯坦旁遮普省中部土壤盐分方面表现出较好的有效性。

2) 植被指数和水分指数。植被指数是从植被的光谱反射特性中提取出来的一类指标。在高盐胁迫下,地表的植被形态会因根系吸水不足和离子毒害作用而发生变化,这种变化可以通过光学遥感技术进行诊断和分析。分散的植被或土壤表面的盐生植物可以作为土壤盐分状态的标志,通过利用植被的反射率可以间接监测土壤盐渍化情况。 $NDVI$ 和 $SAVI$ 等几种植被指数常被用于评估和绘制土壤

盐分的间接指标^[16-17]。Allbed 等^[71]通过分析 $NDVI$ 值和盐度指数的特性,实现了对多光谱图像中土壤盐度和植被覆盖变化的监测; Wu 等^[11]结合了多光谱冠层响应盐分指数 (canopy response salinity index, $CRSI$)、垂直干旱指数 (perpendicular dryness index, PDI) 以及 $ENDVI$,建立了大尺度、高精度的土壤盐分遥感定量反演模型; 张思源等^[72]选用引入短波红外波段的 $ENDVI$ 和半干旱区反演效果最优的 $SI3$ 构建 $ENDVI-SI3$ 特征空间,建立改进型盐渍化监测指数模型,为半干旱区盐渍化反演特征空间中特征参量的选取提供了新思路。水分指数是一类用于表征土地或植被水分含量和干旱程度的指标。遥感技术获取的光谱数据能够反映出土地或植被在不同波段上的吸收与反射特性,进而推测水盐分布状况。由于土壤盐分通常与土壤水分含量密切相关,水分指数如 $NDWI$ 和 WI 等可以用于估算土壤盐分含量。丁建丽等^[73]结合 Landsat TM 数据和野外实测数据,分析土壤盐分与修改型土壤调整植被指数 (modified soil-adjusted vegetation index, $MSAVI$) 以及湿度指数 (wetness index, WI) 的关系,在此基础上提出了 $MSAVI-WI$ 特征空间的概念,并构建了土壤盐渍化遥感监测指数模型 (MWI); Chi 等^[17]建立了基于改进的陆面综合因子体系的盐分预测模型,该体系预测因子由光谱值、盐度指数、植被指数、热湿指数等组成,研究利用此系统绘制了黄河三角洲湿地的土壤盐分含量分布图。

3) 热红外辐射。土壤盐分会改变土壤表面的热红外辐射特征,进而影响热红外辐射亮温和地表温度。Tian 等^[39]基于热红外遥感对中国甘肃石羊河地区的作物水分状况及其盐胁迫耐受性进行分析,研究指出随着土壤盐分含量的增加,作物冠层覆盖率降低,生长速度减慢; Ivushkin 等^[59]结合 $MODIS$ 卫星热图像、 $NDVI$ 和 EVI 植被指数以及土壤盐分数据图,证明了卫星反演的冠层温度与土壤盐分水平之间存在显著的相关性; Tajgardan 等^[74]通过 PCA 和回归分析方法,利用高级星载热发射和反射辐射数据,绘制了伊朗北部地区的土壤盐分分布图。

4) 土壤理化性质。土壤质地也是影响土壤盐分含量的重要因素之一。地表粗糙度变化导致光影区域分布发生变化,进而改变土壤的光学反射特性。土壤团聚体的大小和形状也影响反射特性,直径膨胀的土壤骨料会减少反射,而光滑平坦的表面则反射率更高。此外,土壤有机质含量和矿物质成分同样影响光谱反射。Howari 等^[75]研究了不同类型的盐分结皮的光谱反射和吸收特征,揭示了其光谱响应差异,并明确了土壤颗粒大小对光谱反射曲线的

影响; Song 等^[51] 基于光谱和地形指数与广义可加模型的综合方法对中国黄河三角洲地区的土壤盐分进行了估算。

2.2 遥感反演模型

监测区域土壤盐渍化状况时,受时空变化的影响,构建高鲁棒性的遥感反演模型成为盐渍土监测研究的重中之重。通过遥感技术获取数据和图像信息,并选择合适的特征参量来建立模型,进而评估研究区域内的土壤盐分含量的空间分布。在构建土壤盐渍化遥感监测模型时,通常采用 2 种方法:一是

统计回归模型,利用线性回归、偏最小二乘回归 (partial least squares regression,PLSR) 等统计方法,根据遥感特征参量和地面实测数据的经验关系进行建模;二是机器学习模型,例如 BP 神经网络 (back propagation neural network,BPNN)、SVM、随机森林 (random forest,RF) 等,通过训练大量样本数据,学习土壤盐分与遥感特征参量之间的关系,构建更复杂和准确的模型。对文中引用的参考文献涉及的数据来源、建模特征参量、建模方法及反演精度等进行了梳理(表 6)。

表 6 多平台、多源遥感数据土壤盐分指标反演研究

Tab.6 Summary of research study on soil salinity inversion based on multi-platform and multi-source remote sensing data

建模类别	建模特征参量	反演目标变量	建模方法	结 果	参考文献
统计 回归 模型	光谱参数、植被指数、垂直干旱指数、反射率	土壤盐分含量	相关性分析、多元线性回归 (multiple linear regression, MLR)	植被指数中,土壤盐分响应最高决定系数 $R^2=0.577$	[11]
	盐度指数、植被指数、热湿指数	土壤盐分含量	PLSR	研究区四季土壤盐分含量平均值分别为 8.00 g/kg, 7.53 g/kg, 7.83 g/kg 和 6.90 g/kg	[17]
	植被指数、盐度指数	土壤电导率	MLR	$R^2=0.77$ $R^2=0.75$	[23]
	盐度指数、电导率	土壤盐度空间变化	回归分析	$R^2=0.65$	[24]
	盐度指数	土壤盐分含量	MLR	相关系数 $R>0.3$	[26]
	植被指数、冠层温度、植被株高	作物株高、气孔导度、盐分含量	MLR	$R^2=0.64$	[30]
	土壤有机质含量、反射率	土壤盐分含量	相关性分析、MLR	校准: $R^2=0.684$ 验证: $R^2=0.663$	[37]
	土壤水分、电导率、热红外数据、作物生长数据	土壤盐分含量	回归分析	$R^2=0.86$	[39]
	反射率、土壤湿度和质地	土壤盐分含量、土壤含水量	多元逐步回归	$R^2=0.47$	[49]
	盐分指数、植被指数	土壤盐分含量	线性和非线性回归	$R^2=0.59$	[53]
	盐度指数、植被指数	土壤电导率	PLSR	$R^2=0.52$	[57]
	盐度指数、亮度指数、植被指数	土壤盐分含量	MLR、多元逐步回归	$R^2=0.992$ 均方根误差 (root mean square error, RMSE) 为 0.195 g/kg	[66]
	反射率、	土壤盐分含量	PLSR	$R^2=0.749$	[67]
	植被指数	土壤盐分含量	PLSR	$R^2=0.50\sim0.58$	[68]
	植被指数	土壤盐分含量	线性回归	平均误差 (mean error,ME) 和 RMSE 分别为-0.61 ds/m 和 52.2 ds/m	[74]
	盐度指数、亮度指数、植被指数	土壤盐分含量	MLR	标准误差约为 12.1 $\mu\text{s}/\text{cm}$	[76]
	电导率	土壤盐分含量	PLSR	相关系数 $R=0.700$	[77]
	pH 值、电导率	土壤盐分含量	PLSR,MLR	土壤 pH 值和电导率模型的 R^2 平均值分别为 0.77 和 0.48	[78]
	电导率、反射率	土壤盐分含量	PCA,PLSR	PLSR 和 PCA 模型的校准精度分别为 $R^2=0.862$ 和 $R^2=0.537$	[79]
	植被指数、盐度指数	土壤盐分含量	相关性分析	$R^2=0.739$ (无盐渍化)、0.469 (轻度)、0.677 (重度)	[25]
	电导率、盐度指数	土壤盐分含量	逻辑回归模型	$R^2=0.88$, $RMSE=20.85$ ds/m	[27]
	植被指数、水分指数	土壤盐分含量	特征空间	MW1 与土壤表层盐分含量相关性较高 ($R=0.844$)	[73]
	植被指数、冠层温度	土壤盐分含量	统计分析、方差分析	$F=0.245$, $P=0.865$	[59]
	盐分指数	土壤盐分含量	监督最大似然分类法	分类精度约为 90%	[52]

(续表)

建模类别	建模特征参量	反演目标变量	建模方法	结 果	参考文献
机器学习模型	反射率、电导率	土壤盐分含量	PLSR,SVM	相对差异百分比(relative percent difference,RPD)为 3.35%	[3]
	植被指数、盐分指数、反射率	土壤盐分含量	MLR,PLSR,SVM,RF	RF 拟合精度最高,训练: $R^2=0.870$,验证: $R^2=0.766$	[8]
	电导率、反射率	土壤盐分含量	PLSR,人工神经网络(artificial neural network,anN)	PLSR: $R>0.81$, $RPD>2.1\%$ ANN: $R>0.92$, $RPD>2.3\%$	[16]
	反射率、光谱指数	土壤盐分含量	MLR,RF,SVM,BPNN	$R^2=0.770$ (裸土) $R^2=0.676$ (植被覆盖)	[33]
	盐分指数	土壤盐分含量	BPNN,SVR,RF	校准: $R^2=0.835$,验证: $R^2=0.812$, $RPD=2.299\%$	[34]
	反射率、植被指数、盐分指数	土壤盐分含量	PLSR,BPNN,SVR,RF	建模: $R^2=0.724$, $RMSE=1.764\text{ g/kg}$ 验证: $R^2=0.745$, $RMSE=1.879\text{ g/kg}$, $RPD=2.211\%$	[35]
	反射率	土壤盐分含量	RF	$R^2=0.95$	[42]
	植被指数	土壤盐分含量	BPNN,SVM,RF	$R^2=0.885$	[60]
	盐分指数	土壤水盐信息	BPNN	$R^2=0.624$	[80]
	植被指数、盐分指数、亮度指数	土壤盐分含量	BPNN	建模: $R^2=0.769$ 验证: $R^2=0.774$	[81]
	地下水深度、灌溉水量、蒸发量	土壤电导率	SVM	建模: $MRE=2.14\%$,验证: $MRE=3.48\%$,预测: $MRE=6.37\%$	[82]

2.2.1 统计回归

回归分析是一种统计过程,用于估计变量之间的关系,特别是解释自变量与因变量之间的关系。当涉及多个自变量时,称为多元回归。研究表明,在特定条件下,各类遥感特征参量与土壤盐分呈现出较强的相关关系,在土壤盐分建模中具有巨大的潜力^[14]。Bouaziz 等^[76]利用 MODIS 数据和多元线性回归,在土壤盐分监测研究中发现,将盐分指数(SI2)与波段 3(648 nm)反射率结合到统计模型中,能够更好地反映出土壤盐分在空间的扩散情况。Judkins 等^[83]研究发现,Landsat5 TM 传感器的波段 7、变换型归一化植被指数(transformed normalized difference vegetation index,TNDVI)以及通过缨帽变换法(tasseled cap transformation,TCT)得到的缨帽指数 3 和 5,与土壤盐分变化呈现较高的相关性,随后将这些光谱参量混合到多元回归模型中,成功进行了土壤表面盐分制图。Allbed 等^[24]利用遥感数据对沙特阿拉伯哈萨绿洲进行了研究,采用基于遥感指标的统计回归模型,成功预测和绘制了该地区的土壤盐分含量空间变化图;吴霞等^[84]利用 Landsat8 数据构建了盐渍化评价指数,基于相关分析与曲线回归分析法对宁夏银北灌区土壤盐度进行了定量分析和预测。

然而,基于线性回归的反演模型无法完全解释变量之间的复杂相互作用^[85]。混合模型通过组合多个模型来克服各模型中的局限性,可提供更为准确、可靠的模型反演精度,逐渐应用于数据采集较差地区的土壤盐分含量预测^[86],如统计模型中的协同

克里格和回归克里格法可以利用多个变量之间的回归分析来预测目标变量在低采样区的分布^[87]。

2.2.2 PLSR

PLSR 方法综合了 PCA、典型相关性分析和多元线性回归的优点,在同时多个遥感特征参量建模条件下,能够有效地处理变量之间强共线性和噪声影响等问题^[77]。PLSR 首先对各变量成分进行有效性验证,并根据相关性自动筛选和重组变量,最终提取具有最佳系统解释力的新成分进行回归建模^[88]。近年来,PLSR 被广泛用于高光谱数据建模,能够建立光谱数据与土壤理化性质之间的可靠关系。例如,Bai 等^[78]将 PLSR 模型应用于 HJ-1A 高光谱数据,成功绘制了中国松嫩平原北部土壤盐度和碱度的空间分布图,Zhang 等^[79]建立了土壤盐分与土壤光谱反射率的 PLSR 模型和 PCA 模型,并证实了 PLSR 模型准确性明显优于 PCA 模型;Sidike 等^[66]采用 PLSR 对中国平罗地区的土壤盐分进行估算,结果显示其估算精度明显优于逐步回归方法。

2.2.3 特征空间

光谱特征空间是指由一组光谱特征参数构成的多维空间。在该空间中,每个点代表了经光谱数据计算得到的某个物体或区域的独特光谱特征。通过分析土壤盐渍化参数(如电导率、盐分含量)在二维或三维特征空间中到达某个特征点的距离,可以反映不同盐分含量程度,并清晰揭示不同参数之间的变化趋势。

研究表明,通过各类特征参量构建不同维度的特征空间反演模型,能够实现土壤盐渍化的定量监

测^[89]。丁建丽等^[73]从 Landsat TM 影像中提取了改良土壤调整后的植被指数(modified soil-adjusted vegetation index, MSAVI)和 WI,构建了二维特征空间,并证实其与干旱区绿洲表层的土壤盐分密切相关;王飞等^[90]综合植被和土壤信息,提出了 NDVI-SI 特征空间概念,对新疆玉田绿洲土壤盐碱化进行定量分析和监测;Guo 等^[91]利用土壤与植被的协同关系构建了二维特征空间模型,证实该模型在监测黄河三角洲地区土壤盐渍化方面具有较大的潜力;冯娟等^[92]以表面反照率为基础构建特征空间,发现基于地表反照率和土壤调节植被指数的监测模型能够准确、高效地分析研究区域的土壤盐渍化程度。除此之外,三维技术通过引入更多的特征空间,以弥补二维特征空间对盐渍化土壤多因素分析不足。如 Yao 等^[93]基于地表温度、SI 和 NDVI 构建了三维特征空间模型,对中国渭干河-库车绿洲的土壤盐分含量进行了评估,研究结果表明,该模型能够快速、相对准确的监测研究区土壤盐渍化状态。

2.2.4 BPNN

BPNN 是一种前馈式的神经网络,由多个神经元组成,每个神经元与前一层的所有神经元相连。与传统的数学方程构建方法不同,BPNN 能够学习与识别复杂系统输入和输出数据集之间的非线性关系。其展示出强大的自学习能力、适应性和抗干扰能力,已被证实土壤理化参数反演方面具有较大的潜力。Wang 等^[80]利用 Landsat8 卫星数据成功建立了基于 BPNN 的土壤水分和盐分的预测模型;Zhang 等^[81]基于无人机多光谱数据、Sentinel-2A 卫星数据以及地面实测盐分数据的多源数据融合监测方法,发现综合估算模型中的 BPNN 是土壤盐分含量的最佳预测模型,其能够快速且准确地监测区域土壤盐渍化分布。

2.2.5 RF

RF 是一种集成学习方法,该方法通过使用随机不相关的决策树来建立分类和回归问题的预测模型^[94]。近年来,RF 在植被生长指标反演和土壤理化参数估计中得到广泛的应用。如黄晓宇等^[8]在干旱地区绿洲土壤盐分研究中,基于 Landsat8 OLI 影像建立了多个土壤盐分反演模型,并指出相比于经典统计模型,RF 建模方法的反演精度更高;Sui 等^[95]基于水文连通性度量和 RF 算法,在海岸带土壤盐分研究中开发了基于原始观测和卫星数据的土壤盐分反演模型;胡婕^[96]以高光谱一阶微分、宽带谱指数和窄带谱指数作为输入变量,比较了 PLSR 和 RF 方法对土壤盐分的估算效果,结果表明,RF 模型能够更好地利用光谱数据预测土壤盐分含量,

并在裸土区模型的预测精度表现最佳。

2.2.6 SVM

SVM 是一种能够实现结构风险最小化思想的方法,可有效解决小样本、非线性和高维数据等问题。相比传统的统计方法,SVM 具有较强的表达能力、泛化能力和学习效率等优势,便于与多源信息相结合,从而实现更高的反演精度^[97]。Cai 等^[98]基于多光谱和纹理特征组合,利用 SVM 分类器对受盐分影响的土壤进行识别,证实了 SVM 分类器能够有效提取银川平原土壤盐渍化分布信息;Guan 等^[82]在土壤电导率值的动态预测中引入 SVM 理论,构建了土壤盐分动态预测模型,用于盐渍化灌区的灌溉水管理,结果表明,相较于神经网络模型,SVM 在土壤电导率值预测方面具有更大的优势。

各类机器学习算法均能使预测模型从光谱和空间模式中进行学习,并根据输入的数据特征进行评估。研究表明,在土壤盐分遥感反演中,BPNN 收敛速度较慢,存在局部极小值,且没有结构判定的理论支持^[99];SVM 基于结构风险最小化原则,可以较好地解决局部极小值、非线性和高维数等实际问题^[13],但其对参数和核函数的选择过于敏感,在求解多分类问题时存在不足^[100];RF 对异常值不太敏感^[101],在预测结果方面具有高准确性、计算变量重要性的优点,能够对大量预测变量之间复杂的相互作用进行解释^[102]。目前,将多机器学习方法相结合构建土壤盐渍化反演模型的手段也在逐渐应用,以尽可能提高模型反演精度。

3 研究和应用展望

伴随着遥感分辨率和相关技术的不断发展,卫星、航空和近地遥感平台将会构成星空地一体化的动态监测网,为土壤盐渍化监测提供高时间、空间、光谱和辐射分辨率的多元数据产品,并表现出以下的研究和应用趋势:

1)多源遥感数据融合。在区域土壤盐渍化监测中,单一传感器数据难以满足大面积、高精度和高效率的需求。因此,融合不同光学遥感数据源,实现高精度、大尺度的土壤盐渍化监测,已逐渐成为当前研究的热点。在区域土壤盐渍化定量反演中,根据应用的目的和目标不同,多源光学遥感数据的融合方式也不尽相同。例如融合具有不同时空分辨率的两个或多个影像,可以改进影像的质量,进而建立基于融合影像的土壤盐分反演模型。或将卫星影像与无人机影像相融合,使用高空间或光谱分辨率的无人机近地影像对卫星影像进行校正,以此克服无人

机影像覆盖范围有限的问题,进而构建土壤盐分估算模型以进行大面积反演。另外,还可以将卫星遥感影像和地物光谱融合,地谱分析是定量遥感反演的基础,可以实现土壤盐度的精确分析。地面光谱与卫星影像数据相互补不仅可以提高遥感反演的精度和实用性,而且通过这 2 种数据的融合还可以提高土壤盐分预测的精度。

2) 反演方法对比与协同。遥感技术被认为是监测土壤表面盐分含量的有效手段之一。然而,数据挖掘的不足严重制约了其高效、高精度监测的发展。线性回归模型在建模速度、小样本数据和简单关系方面具有优势,因此成为许多非线性模型的基础,但其预测精度通常低于非线性模型。BPNN 算法具有强大的非线性拟合能力和自主学习能力, SVM 算法能够避免传统的归纳到演绎的过程,而 RF 算法更适用于处理非线性数据,具有实现简单、训练速度快和抗过拟合能力强的特点。然而, BPNN 的学习速度慢且容易陷入局部最小值,可能需要更多的训练时间才能收敛到最佳解,而且可能停留在非理想解上,无法达到全局最优解; SVM 更适用于小样本、非线性的样本集合,这也意味着该模型容易受到数据质量的影响,对超参数调整很敏感。目前,机器学习算法已经在土壤盐渍化监测领域得到广泛应用。面向未来,研究的焦点可以转向开发更先进的模型融合策略,特别是通过创新性地结合不同机器学习算法,来克服土壤盐渍化监测中面临的特殊挑战。此外,为了增强模型的泛化能力和在实际应用中的价值,研究可能将深入探索自适应算法,以自动调整和优化模型参数。同时,将更广泛地利用多元化遥感数据源,如卫星、无人机和地面观测数据的综合,进一步提升监测精度。这些发展不仅能够提升土壤盐渍化反演的准确性,也将为土壤管理与农业生产决策提供更加可靠的支持,推动农业科技的进步。

3) 数据同化与深度学习。基于遥感信息的数据同化,主要思路是将遥感观测数据融入陆面模型,并通过不断校正数据模型以达到精确评估与预测的目的。如使用遥感观测数据作为驱动变量,以土壤溶质运移模型和植被生长模型作为模型算子,通过同化算法(如 EnKF, 4DVar)将遥感观测变量融入模型中,实现目标参量动态模拟与反演。土壤盐分的同化误差不仅受到遥感观测变量和植被生长特征诊断效能的影响,还与物理模型中土壤水盐运移模块和盐分胁迫模块的机理和模型参数鲁棒性相关。目前,土壤参量同化反演的研究主要集中在土壤含水量方面,对于土壤盐分含量的数据同化技术的研究

仍有待进一步开展。此外,随着更强大的图形处理器逐渐开发,基于卷积神经网络的深度学习技术的发展彻底改变了图像分析的基本规则,其在机器学习算法组成的基础上,增加了神经网络中的层级和非线性变换以及训练过程的效率,从而建立更为准确和真实的输出。目前,深度学习方法多以 RGB 影像单一数据源为主,植被特征提取、杂草识别和病虫害诊断为主要目标,针对土壤理化参数的量化研究鲜有报道。未来研究可以进一步探讨利用不同深度学习模型和多模态遥感数据进行综合评估和量化土壤盐渍化信息的有效性和准确性。

参考文献 (References) :

[1] 李洪义.滨海盐土三维土体电导率空间变异及可视化研究[D].杭州:浙江大学,2008.
Li H Y. Three dimensional variability and visualization of soil electrical conductivity in coastal saline land[D]. Hangzhou: Zhejiang University, 2008.

[2] 杨劲松.中国盐渍土研究的发展历程与展望[J].土壤学报, 2008, 45(5): 837-845.
Yang J S. Development and prospect of the research on salt-affected soils in China[J]. Acta Pedologica Sinica, 2008, 45(5): 837-845.

[3] Ali A A A, Weindorf D C, Chakraborty S, et al. Combination of proximal and remote sensing methods for rapid soil salinity quantification[J]. Geoderma, 2015, 239: 34-46.

[4] Sreenivas K, Venkataratnam L, Narasimha R P V. Dielectric properties of salt-affected soils[J]. International Journal of Remote Sensing, 1995, 16(4): 641-649.

[5] Wang L, Wei Y. Estimating the total nitrogen and total phosphorus content of wetland soils using hyperspectral models[J]. Acta Ecologica Sinica, 2016, 36(16): 5116-5125.

[6] Rao B R M, Sharma R C, Ravi Sankar T, et al. Spectral behaviour of salt-affected soils[J]. International Journal of Remote Sensing, 1995, 16(12): 2125-2136.

[7] 刘全明. 含盐土壤盐渍化雷达反演模拟研究[J]. 测绘通报, 2014(9): 43-46.
Liu Q M. On radar inversion and simulation of salty soil salinization[J]. Bulletin of Surveying and Mapping, 2014(9): 43-46.

[8] 黄晓宇, 王雪梅, 卡吾恰提·白山. 基于 Landsat8 OLI 影像干旱区绿洲土壤含盐量反演[J]. 自然资源遥感, 2023, 35(1): 189-197. doi: 10.6046/zrzyyg.2022047.
Huang X Y, Wang X M, Kawuqiati B. Inversion of soil salinity of an oasis in an arid area based on Landsat8 OLI images[J]. Remote Sensing for Natural Resources, 2023, 35(1): 189-197. doi: 10.6046/zrzyyg.2022047.

[9] 周磊, 贺聪聪, 吕爱锋, 等. 柴达木盆地土壤盐渍化程度快速动态监测[J]. 测绘科学, 2021, 46(7): 99-106, 114.
Zhou L, He C C, Lyu A F, et al. Research on quick dynamic monitoring of soil salinization in Qaidam Basin[J]. Science of Surveying and Mapping, 2021, 46(7): 99-106, 114.

[10] Zhang X, Huang B, Liu F. Information extraction and dynamic eval-

- uation of soil salinization with a remote sensing method in a typical county on the Huang-Huai-Hai Plain of China[J]. *Pedosphere*, 2020, 30(4): 496-507.
- [11] Wu D, Jia K, Zhang X, et al. Remote sensing inversion for simulation of soil salinization based on hyperspectral data and ground analysis in Yinchuan, China [J]. *Natural Resources Research*, 2021, 30(6): 4641-4656.
- [12] Sahbeni G, Ngabire M, Musyimi P K, et al. Challenges and opportunities in remote sensing for soil salinization mapping and monitoring: A review[J]. *Remote Sensing*, 2023, 15(10): 2540.
- [13] Ma Y, Tashpolat N. Current status and development trend of soil salinity monitoring research in China [J]. *Sustainability*, 2023, 15(7): 5874.
- [14] Benediktsson J A, Chanussot J, Moon W M. Very high-resolution remote sensing: Challenges and opportunities [J]. *Proceedings of the IEEE*, 2012, 100(6): 1907-1910.
- [15] Mulla D J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps [J]. *Biosystems Engineering*, 2013, 114(4): 358-371.
- [16] Farifteh J, Van der Meer F, Atzberger C, et al. Quantitative analysis of salt-affected soil reflectance spectra: A comparison of two adaptive methods (PLSR and ANN) [J]. *Remote Sensing of Environment*, 2007, 110(1): 59-78.
- [17] Chi Y, Sun J, Liu W, et al. Mapping coastal wetland soil salinity in different seasons using an improved comprehensive land surface factor system [J]. *Ecological Indicators*, 2019, 107: 105517.
- [18] Hick P T, Russell W. Some spectral considerations for remote sensing of soil salinity [J]. *Soil Research*, 1990, 28(3): 417.
- [19] Daliakopoulos I N, Tsanis I K, Koutroulis A, et al. The threat of soil salinity: A European scale review [J]. *Science of the Total Environment*, 2016, 573: 727-739.
- [20] Vaheddoost B, Guan Y, Mohammadi B. Application of hybrid ANN-whale optimization model in evaluation of the field capacity and the permanent wilting point of the soils [J]. *Environmental Science and Pollution Research*, 2020, 27(12): 13131-13141.
- [21] Ghassemian H. A review of remote sensing image fusion methods [J]. *Information Fusion*, 2016, 32: 75-89.
- [22] Wu W, Mhaimeed A S, Al-Shafie W M, et al. Mapping soil salinity changes using remote sensing in Central Iraq [J]. *Geoderma Regional*, 2014, 2: 21-31.
- [23] Gorji T, Yildirim A, Hamzehpour N, et al. Soil salinity analysis of Urmia Lake Basin using Landsat-8 OLI and Sentinel-2A based spectral indices and electrical conductivity measurements [J]. *Ecological Indicators*, 2020, 112: 106173.
- [24] Allbed A, Kumar L, Sinha P. Mapping and modelling spatial variation in soil salinity in the Al Hassa Oasis based on remote sensing indicators and regression techniques [J]. *Remote Sensing*, 2014, 6(2): 1137-1157.
- [25] 陈实, 徐斌, 金云翔, 等. 新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 S, Xu B, Jin Y X, 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.
- [26] 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 J Y, Wang X T, Zhang Z T, 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.
- [27] Farahmand N, Sadeghi V. Estimating soil salinity in the dried lake bed of Urmia lake using optical sentinel-2 images and nonlinear regression models [J]. *Journal of the Indian Society of Remote Sensing*, 2020, 48(4): 675-687.
- [28] Huang H, Deng J, Lan Y, et al. Accurate weed mapping and prescription map generation based on fully convolutional networks using UAV imagery [J]. *Sensors*, 2018, 18(10): 3299.
- [29] 李冰, 刘谿源, 刘素红, 等. 基于低空无人机遥感的冬小麦覆盖度变化监测 [J]. *农业工程学报*, 2012, 28(13): 160-165.
- Li B, Liu R Y, Liu S H, et al. Monitoring vegetation coverage variation of winter wheat by low-altitude UAV remote sensing system [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2012, 28(13): 160-165.
- [30] Ivushkin K, Bartholomew H, Bregt A K, et al. UAV based soil salinity assessment of cropland [J]. *Geoderma*, 2019, 338: 502-512.
- [31] 孙刚, 黄文江, 陈鹏飞, 等. 轻小型无人机多光谱遥感技术应用进展 [J]. *农业机械学报*, 2018, 49(3): 1-17.
- Sun G, Huang W J, Chen P F, et al. Advances in UAV-based multispectral remote sensing applications [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(3): 1-17.
- [32] Xu L, Zheng C L, Wang Z C, et al. A digital camera as an alternative tool for estimating soil salinity and soil surface roughness [J]. *Geoderma*, 2019, 341: 68-75.
- [33] Xie L, Feng X, Zhang C, et al. A framework for soil salinity monitoring in coastal wetland reclamation areas based on combined unmanned aerial vehicle (UAV) data and satellite data [J]. *Drones*, 2022, 6(9): 257.
- [34] Wei G, Li Y, Zhang Z, et al. Estimation of soil salt content by combining UAV-borne multispectral sensor and machine learning algorithms [J]. *PeerJ*, 2020, 8: e9087.
- [35] Yu X, Chang C, Song J, et al. Precise monitoring of soil salinity in China's Yellow River Delta using UAV-borne multispectral imagery and a soil salinity retrieval index [J]. *Sensors*, 2022, 22(2): 546.
- [36] Zhu C, Ding J, Zhang Z, et al. SPAD monitoring of saline vegetation based on Gaussian mixture model and UAV hyperspectral image feature classification [J]. *Computers and Electronics in Agriculture*, 2022, 200: 107236.
- [37] Sun M, Li Q, Jiang X, et al. Estimation of soil salt content and organic matter on arable land in the Yellow River Delta by combining UAV hyperspectral and landsat-8 multispectral imagery [J]. *Sensors*, 2022, 22(11): 3990.
- [38] Das S, Christopher J, Apan A, et al. UAV-Thermal imaging and agglomerative hierarchical clustering techniques to evaluate and rank physiological performance of wheat genotypes on sodic soil [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 173: 221-237.
- [39] Tian F, Hou M, Qiu Y, et al. Salinity stress effects on transpiration and plant growth under different salinity soil levels based on ther-

- mal infrared remote (TIR) technique[J]. *Geoderma*, 2020, 357: 113961.
- [40] Bhardwaj A, Sam L, Akanksha, et al. UAVs as remote sensing platform in glaciology: Present applications and future prospects[J]. *Remote Sensing of Environment*, 2016, 175: 196–204.
- [41] Nevalainen O, Honkavaara E, Tuominen S, et al. Individual tree detection and classification with UAV-based photogrammetric point clouds and hyperspectral imaging[J]. *Remote Sensing*, 2017, 9(3): 185.
- [42] Hu J, Peng J, Zhou Y, et al. Quantitative estimation of soil salinity using UAV-borne hyperspectral and satellite multispectral images[J]. *Remote Sensing*, 2019, 11(7): 736.
- [43] 乔纪纲, 艾彬, 邹春洋. 基于多源遥感的莺歌海滨岸环境特征分析[J]. *热带地理*, 2011, 31(5): 456–462.
- Qiao J G, Ai B, Zou C Y. Analysis of coastal environment in yinggehai with multi-source remote sensing images[J]. *Tropical Geography*, 2011, 31(5): 456–462.
- [44] Zhang H, Wang L, Tian T, et al. A review of unmanned aerial vehicle low-altitude remote sensing (UAV-LARS) use in agricultural monitoring in China[J]. *Remote Sensing*, 2021, 13(6): 1221.
- [45] Mulder V L, de Bruin S, Schaepman M E, et al. The use of remote sensing in soil and terrain mapping: A review[J]. *Geoderma*, 2011, 162(1/2): 1–19.
- [46] 贡璐, 韩丽, 任曼丽, 等. 塔里木河上游典型绿洲土壤水盐空间分异特征[J]. *水土保持学报*, 2012, 26(4): 251–255, 278.
- Gong L, Han L, Ren M L, et al. Spatial variability of soil water-salt in a typical oasis on the upper reaches of the Tarim River[J]. *Journal of Soil and Water Conservation*, 2012, 26(4): 251–255, 278.
- [47] Deng K, Ding J, Yang A, et al. Modeling of the spatial distribution of soil profile salinity based on the electromagnetic induction technique[J]. *Acta Ecologica Sinica*, 2016, 36(20): 6387.
- [48] Kahaer Y, Yang S, Tashpolat N, et al. Hyperspectral estimation of soil electrical conductivity based on fractional order differentially optimised spectral indices[J]. *Acta Ecologica Sinica*, 2019, 39(19): 7237–7248.
- [49] Xu C, Zeng W, Huang J, et al. Prediction of soil moisture content and soil salt concentration from hyperspectral laboratory and field data[J]. *Remote Sensing*, 2016, 8(1): 42.
- [50] 蒲智, 于瑞德, 尹昌应, 等. 干旱区典型盐碱土壤含盐量估算的最佳高光谱指数研究[J]. *水土保持通报*, 2012, 32(6): 129–133.
- Pu Z, Yu R D, Yin C Y, et al. Optimal hyperspectral indices for soil salt content estimation on typical saline soil in arid areas[J]. *Bulletin of Soil and Water Conservation*, 2012, 32(6): 129–133.
- [51] Song C, Ren H, Huang C. Estimating soil salinity in the Yellow River Delta, Eastern China: An integrated approach using spectral and terrain indices with the generalized additive model[J]. *Pedosphere*, 2016, 26(5): 626–635.
- [52] 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.
- [53] 王飞, 丁建丽, 魏阳, 等. 基于 Landsat 系列数据的盐分指数和植被指数对土壤盐度变异性的响应分析——以新疆天山南北典型绿洲为例[J]. *生态学报*, 2017, 37(15): 5007–5022.
- Wang F, Ding J L, Wei Y, et al. Sensitivity analysis of soil salinity and vegetation indices to detect soil salinity variation by using Landsat series images: Applications in different oases in Xinjiang, China[J]. *Acta Ecologica Sinica*, 2017, 37(15): 5007–5022.
- [54] 郭鹏, 李华, 陈红艳, 等. 基于光谱指数优选的土壤盐分定量光谱估测[J]. *水土保持通报*, 2018, 38(3): 193–199, 205.
- Guo P, Li H, Chen H Y, et al. Quantitative spectral estimation of soil salinity based on optimum spectral indices[J]. *Bulletin of Soil and Water Conservation*, 2018, 38(3): 193–199, 205.
- [55] Khan N, Rastokuev V V, Shalina E, et al. Mapping salt-affected soils using remote sensing indicators: A simple approach with the use of GIS IDRISI[C]// 22nd Asian Conference on Remote Sensing, 2001, 5(9).
- [56] Tripathi N K, Rai B K, Dwivedi P. Spatial modeling of soil alkalinity in GIS environment using IRS data[C]// Proceedings of the 18th Asian Conference on Remote Sensing, Kuala Lumpur, Malaysia. 1997: 20–24.
- [57] Triki F H, Bouaziz M, Benzina M, et al. Modeling of soil salinity within a semi-arid region using spectral analysis[J]. *Arabian Journal of Geosciences*, 2015, 8(12): 11175–11182.
- [58] Huete A R. A soil-adjusted vegetation index (SAVI)[J]. *Remote Sensing of Environment*, 1988, 25(3): 295–309.
- [59] Ivushkin K, Bartholomeus H, Bregt A K, et al. Satellite thermography for soil salinity assessment of cropped areas in Uzbekistan[J]. *Land Degradation & Development*, 2017, 28(3): 870–877.
- [60] Qi G, Zhao G, Xi X. Soil salinity inversion of winter wheat areas based on satellite-unmanned aerial vehicle-ground collaborative system in coastal of the Yellow River Delta[J]. *Sensors*, 2020, 20(22): 6521.
- [61] Lyon J G, Yuan D, Lunetta R S, et al. A change detection experiment using vegetation indices[J]. *Photogrammetric Engineering and Remote Sensing*, 1998, 64(2): 143–150.
- [62] McFeeters S K. The use of the normalized difference water index (NDWI) in the delineation of open water features[J]. *International Journal of Remote Sensing*, 1996, 17(7): 1425–1432.
- [63] Sandholt I, Rasmussen K, Andersen J. A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status[J]. *Remote Sensing of Environment*, 2002, 79(2/3): 213–224.
- [64] Wan Z, Wang P, Li X. Using MODIS land surface temperature and normalized difference vegetation index products for monitoring drought in the southern Great Plains, USA[J]. *International Journal of Remote Sensing*, 2004, 25(1): 61–72.
- [65] Tziolas N, Tsakiridis N, Ben-Dor E, et al. A memory-based learning approach utilizing combined spectral sources and geographical proximity for improved VIS-NIR-SWIR soil properties estimation[J]. *Geoderma*, 2019, 340: 11–24.
- [66] Sidike A, Zhao S, Wen Y. Estimating soil salinity in Pingluo County of China using QuickBird data and soil reflectance spectra[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2014, 26: 156–175.
- [67] Fan X, Liu Y, Tao J, et al. Soil salinity retrieval from advanced multi-spectral sensor with partial least square regression[J]. *Remote Sensing*, 2015, 7(1): 488–511.
- [68] Zhang T T, Zeng S L, Gao Y, et al. Using hyperspectral vegetation indices as a proxy to monitor soil salinity[J]. *Ecological Indicators*,

- 2011, 11(6): 1552–1562.
- [69] Abdullah A Y M, Biswas R K, Chowdhury A I, et al. Modeling soil salinity using direct and indirect measurement techniques: A comparative analysis [J]. *Environmental Development*, 2019, 29: 67–80.
- [70] Khan N M, Rastokuev V V, Sato Y, et al. Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators [J]. *Agricultural Water Management*, 2005, 77(1/2/3): 96–109.
- [71] 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: 1–8.
- [72] 张思源, 岳楚, 袁国礼, 等. 基于 ENDVI-SI3 特征空间的盐渍化反演模型及风险评估 [J]. *自然资源遥感*, 2022, 34(4): 136–143.
- Zhang S Y, Yue C, Yuan G L, et al. Salinization inversion model based on ENDVI-SI3 characteristic space and risk assessment [J]. *Remote Sensing for Natural Resources*, 2022, 34(4): 136–143.
- [73] 丁建丽, 瞿娟, 孙永猛, 等. 基于 MSAVI-WI 特征空间的新疆渭干河-库车河流域绿洲土壤盐渍化研究 [J]. *地理研究*, 2013, 32(2): 223–232.
- Ding J L, Qu J, Sun Y M, et al. The retrieval model of soil salinization information in arid region based on MSAVI-WI feature space: A case study of the delta oasis in Weigan-Kuqa watershed [J]. *Geographical Research*, 2013, 32(2): 223–232.
- [74] Tajgardan T, Shataee S, Ayoubi S. Spatial prediction of soil salinity in the arid zones using ASTER data, Case study: North of Ag ghalala, Golestan Province, Iran [C]//28th Asian Conference on Remote Sensing 2007, ACRS 2007, 2007, 3: 1712–1717.
- [75] Howari F M, Goodell P C, Miyamoto S. Spectral properties of salt crusts formed on saline soils [J]. *Journal of Environmental Quality*, 2002, 31(5): 1453–1461.
- [76] Bouaziz M, Matschullat J, Gloaguen R. Improved remote sensing detection of soil salinity from a semi-arid climate in Northeast Brazil [J]. *Comptes Rendus Geoscience*, 2011, 343(11/12): 795–803.
- [77] 陈文娇, 翁永玲, 范兴旺, 等. 基于光谱转换的土壤盐分反演与动态分析 [J]. *东南大学学报(自然科学版)*, 2017, 47(6): 1233–1238.
- Chen W J, Weng Y L, Fan X W, et al. Soil salinity retrieval and dynamic analysis based on spectral band inter-calibration [J]. *Journal of Southeast University (Natural Science Edition)*, 2017, 47(6): 1233–1238.
- [78] Bai L, Wang C, Zang S, et al. Mapping soil alkalinity and salinity in northern Songnen Plain, China with the HJ-1 hyperspectral imager data and partial least squares regression [J]. *Sensors*, 2018, 18(11): 3855.
- [79] Zhang X, Huang B. Prediction of soil salinity with soil-reflected spectra: A comparison of two regression methods [J]. *Scientific Reports*, 2019, 9(1): 5067.
- [80] Wang J, Wang W, Hu Y, et al. Soil moisture and salinity inversion based on new remote sensing index and neural network at a Salina-alkaline wetland [J]. *Water*, 2021, 13(19): 2762.
- [81] Zhang Z, Niu B, Li X, et al. Estimation and dynamic analysis of soil salinity based on UAV and sentinel-2A multispectral imagery in the coastal area, China [J]. *Land*, 2022, 11(12): 2307.
- [82] Guan X, Wang S, Gao Z, et al. Dynamic prediction of soil salinization in an irrigation district based on the support vector machine [J]. *Mathematical and Computer Modelling*, 2013, 58(3/4): 719–724.
- [83] Judkins G, Myint S. Spatial variation of soil salinity in the Mexicali Valley, Mexico: Application of a practical method for agricultural monitoring [J]. *Environmental Management*, 2012, 50(3): 478–489.
- [84] 吴霞, 王长军, 樊丽琴, 等. 基于多光谱遥感的盐渍化评价指数对宁夏银北灌区土壤盐度预测的适用性分析 [J]. *国土资源遥感*, 2021, 33(2): 124–133. doi: 10.6046/gtzyyg.2020210.
- Wu X, Wang C J, Fan L Q, et al. An applicability analysis of salinization evaluation index based on multispectral remote sensing to soil salinity prediction in Yinbei irrigation area of Ningxia [J]. *Remote Sensing for Land and Resources*, 2021, 33(2): 124–133. doi: 10.6046/gtzyyg.2020210.
- [85] Alqasemi A S, Ibrahim M, Fadhil Al-Quraishi A M, et al. Detection and modeling of soil salinity variations in arid lands using remote sensing data [J]. *Open Geosciences*, 2021, 13(1): 443–453.
- [86] Zare S, Fallah Shamsi S R, Ali Abtahi S. Weakly-coupled geo-statistical mapping of soil salinity to stepwise multiple linear regression of MODIS spectral image products [J]. *Journal of African Earth Sciences*, 2019, 152: 101–114.
- [87] Jantaravikorn Y, Ongsomwang S. Soil salinity prediction and its severity mapping using a suitable interpolation method on data collected by electromagnetic induction method [J]. *Applied Sciences*, 2022, 12(20): 10550.
- [88] 蒋烨林, 王让会, 李焱, 等. 艾比湖流域不同土地覆盖类型土壤养分高光谱反演模型研究 [J]. *中国生态农业学报*, 2016, 24(11): 1555–1564.
- Jiang Y L, Wang R H, Li Y, et al. Hyper-spectral retrieval of soil nutrient content of various land-cover types in Ebinur Lake basin [J]. *Chinese Journal of Eco-Agriculture*, 2016, 24(11): 1555–1564.
- [89] Liu Y, Qian J, Yue H. Comparison and evaluation of different dryness indices based on vegetation indices-land surface temperature/albedo feature space [J]. *Advances in Space Research*, 2021, 68(7): 2791–2803.
- [90] 王飞, 丁建丽, 伍漫春. 基于 NDVI-SI 特征空间的土壤盐渍化遥感模型 [J]. *农业工程学报*, 2010, 26(8): 168–173, 8.
- Wang F, Ding J L, Wu M C. Remote sensing monitoring models of soil salinization based on NDVI-SI feature space [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2010, 26(8): 168–173, 8.
- [91] Guo B, Yang F, Fan Y, et al. Dynamic monitoring of soil salinization in Yellow River Delta utilizing MSAVI-SI feature space models with Landsat images [J]. *Environmental Earth Sciences*, 2019, 78(10): 308.
- [92] 冯娟, 丁建丽, 魏雯瑜. 基于 Albedo-MSAVI 特征空间的渭库绿洲土壤盐渍化研究 [J]. *中国农村水利水电*, 2018(2): 147–152.
- Feng J, Ding J L, Wei W Y. A study of soil salinization in Weigan and Kuqa Rivers Oasis based on albedo-MSAVI feature space [J]. *China Rural Water and Hydropower*, 2018(2): 147–152.

[93] Yao Y , Ding J , Wang S . Soil salinization monitoring in the Werigan - Kuqa Oasis , China , based on a three - dimensional feature space model with machine learning algorithm [J] . Remote Sensing Letters , 2021 , 12 (3) : 269 - 277 .

[94] Mutanga O , Adam E , Cho M A . High density biomass estimation for wetland vegetation using WorldView - 2 imagery and random forest regression algorithm [J] . International Journal of Applied Earth Observation and Geoinformation , 2012 , 18 : 399 - 406 .

[95] Sui H , Chen D , Yan J , et al . Soil salinity estimation over coastal wetlands based on random forest algorithm and hydrological connectivity metric [J] . Frontiers in Marine Science , 2022 , 9 : 895172 .

[96] 胡 捷 . 基于多源遥感的干旱地区土壤盐分反演研究 [D] . 杭州 : 浙江大学 , 2019 .
Hu J . Estimation of soil salinity in arid area based on multi - source remote sensing [D] . Hangzhou : Zhejiang University , 2019 .

[97] Tan K , Ye Y Y , Du P J , et al . Estimation of heavy metal concentrations in reclaimed mining soils using reflectance spectroscopy [J] . Spectroscopy and Spectral Analysis , 2014 , 34 (12) : 3317 - 3322 .

[98] Cai S , Zhang R , Liu L , et al . A method of salt - affected soil information extraction based on a support vector machine with texture features [J] . Mathematical and Computer Modelling , 2010 , 51 (11 / 12) : 1319 - 1325 .

[99] Nawi N M , Khan A , Rehman M Z . A new back - propagation neural network optimized with cuckoo search algorithm [M] // Lecture Notes in Computer Science . Berlin , Heidelberg : Springer Berlin Heidelberg , 2013 : 413 - 426 .

[100] Wang X , Zhang F , Kung H T , et al . Extracting soil salinization information with a fractional - order filtering algorithm and grid - search support vector machine (GS - SVM) model [J] . International Journal of Remote Sensing , 2020 , 41 (3) : 953 - 973 .

[101] Du P , Xia J , Chanussot J , et al . Hyperspectral remote sensing image classification based on the integration of support vector machine and random forest [C] // 2012 IEEE International Geoscience and Remote Sensing Symposium . Munich , Germany . IEEE , 2012 : 174 - 177 .

[102] 王 飞 , 杨胜天 , 丁建丽 , 等 . 环境敏感变量优选及机器学习算法预测绿洲土壤盐分 [J] . 农业工程学报 , 2018 , 34 (22) : 102 - 110 .
Wang F , Yang S T , Ding J L , et al . Environmental sensitive variable optimization and machine learning algorithm using in soil salt prediction at oasis [J] . Transactions of the Chinese Society of Agricultural Engineering , 2018 , 34 (22) : 102 - 110 .

Advances in research on methods for optical remote
sensing monitoring of soil salinization

LUO Zhenhai , ZHANG Chao , FENG Shaoyuan , TANG Min , LIU Rui , KONG Jiyong
(College of Hydraulic Science and Engineering , Yangzhou University , Yangzhou 225009 , China)

Abstract: Soil salinization is identified as a major cause of decreased soil fertility, productivity, vegetation coverage, and crop yield. Optical remote sensing monitoring enjoys advantages such as macro-scale, timeliness, dynamics, and low costs, rendering this technology significant for the dynamic monitoring of soil salinization. However, there is a lack of reviews of the systematic organization of multi-scale remote sensing data, multi-type remote sensing feature parameters, and inversion models. This study first organized the optical remote sensing data sources and summarized the remote sensing data sources and scale platforms utilized in current studies on saline soil monitoring. Accordingly, this study categorized multi-source remote sensing data into three different platforms: satellite, aerial, and ground. Second, this study organized the mainstream characteristic parameters for modeling and two typical inversion methods, i.e., statistical regression and machine learning, and analyzed the current status of research on both methods. Finally, this study explored the fusion of remote sensing data sources and compared the pros and cons of various modeling methods. Furthermore, in combination with current hot research topics, this study discussed the prospects for the application of data assimilation and deep learning to soil salinization monitoring.

Keywords: soil salinization; soil salinity; optical remote sensing; inversion model; characteristic parameter
(责任编辑: 张 仙)