doi: 10.6046/zrzyyg.2021395

引用格式:李星佑,张飞,王筝. 土壤盐渍化遥感监测模型构建方法现状与发展趋势[J]. 自然资源遥感,2022,34(4):11-21. (Li X Y,Zhang F,Wang Z. Present situation and development trend in building remote sensing monitoring models of soil salinization [J]. Remote Sensing for Natural Resources,2022,34(4):11-21.)

# 土壤盐渍化遥感监测模型构建方法现状与发展趋势

李星佑<sup>1,2</sup>,张飞<sup>1,2,3</sup>,王筝<sup>1,2</sup>

 (1.新疆大学地理与遥感科学学院,乌鲁木齐 830017;2.新疆大学绿洲生态教育部 重点实验室,乌鲁木齐 830017;3.新疆大学智慧城市与环境

建模自治区普通高校重点实验室,乌鲁木齐 830017)

**摘要:**土壤盐渍化作为土壤退化的主要形式之一,会对农业生产和生态环境产生极大的危害。遥感手段能快速、宏观、及时地获取土壤光谱特征,通过构建遥感监测模型,可以实现大范围的土壤盐渍化监测和评估,开展土壤盐渍化遥感监测模型方法归纳讨论,提高土壤盐渍化遥感监测模型构建过程中因子的选取、模型的建立以及 新度验证等步骤进行总结,并针对当前研究热点对研究中的局限性与发展趋势进行讨论。主要得出:①土壤盐渍 化遥感模型作为盐渍土监测和预测的重要手段,近年来该领域的研究热点在于通过新型数据源和模型的使用来提 高土壤盐渍化遥感监测模型的精度;②不同研究在遥感数据源的使用上有所差异,但建模因子均是通过光谱敏感 波段、先验光谱指数及遥感衍生数据优选获得;③用于土壤盐渍化遥感监测的模型主要包括线性回归模型以及机 器学习模型,针对不同区域建立的遥感模型在模型精度和适用性上有所差异。

关键词:土壤盐渍化;遥感监测;建模因子;模型构建;精度验证

中图法分类号: TP 79 文献标志码: A 文章编号: 2097 - 034X(2022)04 - 0011 - 11

## 0 引言

土壤盐渍化是一个世界性问题,是土壤中盐分 积聚形成盐渍土的过程,广泛发生在内陆干旱地区 和滨海地区<sup>[1-3]</sup>。自然或人为过程引起的土壤盐渍 化是一种重大的环境灾害<sup>[4]</sup>,全球主要盐渍化土壤 范围约为9.55亿hm<sup>2</sup>,而次生盐渍化约为0.77亿 hm<sup>2</sup>,其中58%在灌区<sup>[5]</sup>。土壤盐渍化在不同程度 上影响了1/3以上的陆地河流流域<sup>[6]</sup>。盐渍化的主 要负面影响是限制植物的吸水和蒸散,降低土壤肥 力,导致农作物减产<sup>[7-8]</sup>,直接影响人们的生活。因 此,土壤盐渍化的动态监测尤为重要。

以往的土壤盐渍化监测体系主要基于人工样点 调查,费时费力,难以获取大面积宏观尺度的变化特 性<sup>[9-11]</sup>。尤其在下垫面条件复杂、自然环境恶劣地 区,监测站点布设不足,野外考察难度大,传统监测 手段更难以满足需求<sup>[6,12]</sup>。遥感卫星能够对特定区 域进行不同尺度上可靠、持续的影像观测,过去10 a 间,已经快速发展成为监测土壤盐渍化程度及分布 的重要工具<sup>[13-15]</sup>。单时相的卫星影像可以客观地 揭示某一时刻大范围区域内土壤质地空间差异,多 时相的卫星影像则可以对同一区域不同时间变化规 律进行比较分析<sup>[16-17]</sup>。近年来,随着对地观测技术 的发展,遥感数据的光谱信息逐渐丰富,时空分辨率 不断提升,能够实现对地高精度、高重访(高时效)、 多尺度、全天候观测,大大提高了遥感监测能 力<sup>[18-19]</sup>。利用多时相遥感影像,能够对不同地区土 壤盐渍化参数进行定量反演,实现盐渍化土壤的动 态监测和分析<sup>[17,20]</sup>。

利用遥感数据定量评价土壤盐渍化的核心是找 出相关指标的含量与遥感数据之间的关系,因此,利 用遥感技术研究土壤盐渍化的目的是建立一个可靠 的估算模型<sup>[21-22]</sup>。土壤盐渍化反演遥感模型的建 立需要探求土壤实际含盐量、盐渍化程度以及盐渍 土类型与遥感数据不同波段、波段组合及其他遥感

收稿日期: 2021-11-22;修订日期: 2022-05-25

基金项目: 国家自然科学基金项目"水盐胁迫下的艾比湖湿地国家级自然保护区植被高光谱诊断模型研究"(编号: U1503302)和新疆 维吾尔自治区第三期天山英才计划共同资助。

第一作者:李星佑(1996-),男,硕士,主要从事干旱区生态环境遥感应用研究。Email: lixingyou@stu.xju.edu.cn。

通信作者:张飞(1980-),男,教授,主要从事干旱区资源环境遥感应用研究。Email: zhangfei3s@163.com。

参数之间的关系<sup>[23-24]</sup>,因此需要获取土壤含盐量及 实际理化性质的量化数值,利用统计学等方法建立 与遥感数据的光谱信息数值之间线性或非线性模 型<sup>[25-26]</sup>,并对模型进行精度验证,精度较高的模型 在很大程度上可用于该研究区内土壤盐渍化情况的 监测<sup>[4,27]</sup>。遥感监测模型构建方法在步骤上存在一 定的差异,但总体流程是一致的,其目的是为了获取 更高精度的反演模型,用以评估区域盐渍化状况<sup>[11]</sup>。

因此,本文主要针对以下几点内容进行梳理和 总结:①探讨土壤盐渍化遥感研究的热点,论证遥 感反演模型构建在该研究领域的重要性;②总结和 梳理土壤盐渍化遥感监测模型构建的一般过程; ③针对当前研究现状,分析土壤盐渍化遥感监测模 型构建过程中的局限性并分析未来发展趋势。

1 土壤盐渍化遥感监测模型研究现状

为探讨土壤盐渍化遥感监测的研究历程以及当 前的研究热点,以"土壤盐渍化"、"遥感"和"模型" 作为主题检索词在中国知网(CNKI)进行检索,检索 结果包括414 篇相关度较高的文献,以"soil salt remote sensing"、"soil salinization remote sensing"和 "soil salinity remote sensing"作为主题进行检索,在 Web of Science 数据库中检索到1 598 篇相关文章。 对检索结果不同年份发表文章的数量进行总结梳理 (图1),发现国内外土壤盐渍化遥感监测模型构建 的相关研究兴起于 2000 年,在 2000 年以后相关研 究文章的发表数量呈逐年上升趋势,在近5 a 内发 文数量达到顶峰,土壤盐渍化作为全球性问题受到 广泛关注,众多学者开始利用遥感手段对土壤盐渍 化情况进行监测,逐步建立盐渍化严重地区的遥感 监测模型,并不断提高监测模型的精度,取得了丰富 的研究成果,体现了土壤盐渍化遥感监测建模研究 作为当前遥感领域的研究热点,对于土壤盐渍化监 测与防治具有重要意义。



利用 VOS Viewer1.6.16 平台进行分析,得到与 土壤盐渍化遥感监测研究相关的 CNKI 和 Web of Science 出版物中的关键词密度、网络和标签。由两 者关键词密度可知,近年来国内外土壤盐渍化遥感 监测研究的热点在于遥感监测模型的建立,热点区 域为干旱区,在建模构建过程中越来越多地使用到 新型的遥感数据与建模方法,种类多样的多光谱、高 光谱、雷达以及无人机遥感数据被应用于土壤盐渍 化监测,其中 Landsat, MODIS, RADARSAT - 2 和 Sentinel-2 遥感影像的使用频次较高,偏最小二乘 回归模型、支持向量机(support vector machine, SVM)模型、BP-神经网络模型和特征空间模型为 当前研究中使用最广泛的模型构建方法。土壤盐渍 化监测模型的建立并结合 3S 技术制作的土壤盐渍 化程度分布专题图实现了区域土壤盐渍化的动态监 测与预测,展现了土壤盐渍化与时空分布特征动态 变化,对区域内生态环境的改善做出了重要的参考 贡献。从 Web of Science 网络来看,遥感监测模型 探讨的热点在于建立实测土壤含盐量与遥感数据光 谱信息之间的联系,主要通过对盐渍化土壤遥感影 像的光谱分析与指数的构建来获取建模因子,作为 模型构建的前提;与土壤盐渍化联系最紧密的因素 是地表水、地下水埋深以及植被覆盖度(fractional vegetation cover, FVC),不同深度、不同季节土壤含 盐量的主导影响因子是不同的;土壤盐渍化遥感模 型构建的目的是实现对区域内土壤盐渍化变化情况 以及盐渍化对生态环境造成影响的长期遥感动态监 测。CNKI标签则反映了近10 a 来相关研究文献热 点关键词随时间的变化状况,从一定程度上反映出 近期土壤盐渍化遥感监测的研究热点在于新型光谱 指数的建立与高光谱和高空间分辨率遥感数据的使 用,不同类型的遥感数据的协同使用以及尺度转换 方法将为模型构建提供更多的建模因子,新兴的数 据挖掘算法等技术将为土壤盐渍化的时空特征变化 监测提供新的研究思路。

对比分析 CNKI 和 Web of Science 数据库相关 文献检索结果,发现 Web of Science 数据库中关于 土壤盐渍化遥感监测方面的相关文章数量多于 CNKI,二者文章数量整体呈现上升趋势且变化趋势 相似。在这2个数据库中,土壤盐渍化遥感监测模 型构建研究领域的热点都在于不断发掘新的数据源 与模型构建算法,从而提高反演模型精度,CNKI 数 据库中更侧重于模型构建方法的研究与创新,使用 的建模方法与理论更为丰富,Web of Science 数据库 中在模型构建基础上更侧重于土壤盐渍化影响因素 与动态变化方面的研究。 2 模型构建因子的选取

#### 2.1 实测数据

实测土壤含盐量是遥感监测模型建立的基础, 是进行建模因子优选以及模型精度验证的依据,其 一般获取方法是野外采集,在样本采集过程中使用 全球定位系统(global positioning system, GPS)仪记 录土壤坐标位置信息,将野外采集的土壤样本带回 实验室进行测定实验。具体采样过程中,需要采集 表层及地下不同深度的盐渍土,一般采用多点采样 法,将采集到的样品封装后带回实验室,经过风干、 研磨、过筛获得盐渍土细土样品,之后配置土壤溶液 使用电导率仪测定土壤电导率、pH 值及主要离子含 量<sup>[7]</sup>,或采用残渣烘干法获得土壤盐分含量及含水 量<sup>[9]</sup>,也可以使用电磁感应法和接触电极法测定土 壤电导率,如土壤传感电磁感应 GER3700 和 Field-Spec FR 设备以及 EM38 来获取表征土壤盐分的数 据<sup>[28-29]</sup>,还有部分学者使用仪器 85070E 介电常数 测量套件测定土壤介电常数来探讨其与土壤含盐量 之间的关系<sup>[30]</sup>。

在土壤样品采集过程中,使用便携式光谱测量 仪可获得不同采样点的光谱曲线数据。经常被使用 的野外便携式光谱测量仪包括美国 SVC HR - 768 便携式野外光谱仪、美国 Unispec - SC(波段为 310 ~ 1 130 nm)便携式光谱仪<sup>[16]</sup>、美国 ASD 公司的 ASD Fild Specpro FR 光谱仪<sup>[31]</sup>、科罗拉多州博尔德制造 的 FieldSpecfiPro 光谱测量仪<sup>[32]</sup>、FieldSpec - 4 高分 辨率光谱辐射计<sup>[33]</sup>、CI700 便携式野外光谱仪<sup>[34]</sup>和 PSR - 3500 ©便携式 VisNIR 光谱辐射计等设备。

根据野外实际情况以及数据使用的特定需求制 定一系列的测定操作规范,获取光谱曲线数据后需 要利用光谱仪的后处理软件进行取均值、归一化等 处理,通常采用最小二乘拟合的多项式低通平滑 Savitzky – Golay 滤波方法对光谱曲线进行平滑处 理,以增强光谱的有效性和准确性,最大程度消除噪 声。为更好地分析光谱数据与土壤含盐量之间的相 关关系,对土壤光谱反射率分别进行倒数、对数、对 数倒数和均方根等数学变换,然后再进行一阶、二阶 微分变换以消除基线漂移或平滑背景的干扰<sup>[35]</sup>。 一阶、二阶微分方程分别为:

$$R'_{\lambda_{i}} = (R_{\lambda_{i+1}} - R_{\lambda_{i-1}})/(\lambda_{i+1} - \lambda_{i-1}) , \quad (1)$$

$$R''_{\lambda_{i}} = (R'_{\lambda_{i+1}} - R'_{\lambda_{i-1}})/(\lambda_{i+1} - \lambda_{i-1}) , (2)$$

式中: i 为光谱通道;  $\lambda_{i+1}, \lambda_{i-1}$  和  $\lambda_i$  为波长;  $R'_{\lambda_i}$  和

 $R''_{\lambda i}$ 分别为波长 $\lambda_i$ 的一阶和二阶微分光谱。

选择适当的数学方法改变高光谱反射率可以更 好地突出光谱的反射和吸收特性,并有助于筛选敏 感波段<sup>[36]</sup>。将反射率、反射率一阶微分变换、反射 率二阶微分变换、倒数变换、倒数一阶微分变换、对数 数变换、对数一阶微分变换、对数倒数变换、对数倒 数一阶微分变换、均方根变换和均方根一阶微分变 换等数学变换的结果可作为土壤的高光谱指数<sup>[37]</sup>。 分别将不同盐渍化程度的土壤盐分解译数据与去噪 后得到的土壤光谱及其变换形式进行相关性分 析<sup>[31]</sup>,选取相关性较高的波段作为土壤含盐量的敏 感波段,作为模型构建的因子,即

$$r_{j} = \frac{\sum_{i=1}^{n} (R_{ij} - \overline{R}_{j}) (SC_{i} - \overline{SC})}{\sqrt{(R_{ij} - \overline{R}_{j})^{2} \sum_{i=1}^{n} (SC_{i} - \overline{SC})^{2}}}, \quad (3)$$

式中: $r_j$ 为高光谱指数与土壤含盐量的相关系数;j为波段; $R_{ij}$ 为第i个土样第j波段的反射率值; $\overline{R_j}$ 为 土样在第j波段反射率的平均值; $SC_i$ 为第i个土样 的盐分含量; $\overline{SC}$ 为土壤样本含盐量的平均值;n为 土壤采样个数。

#### 2.2 遥感影像数据

近年来,国内外学者研究建立了利用遥感影像 反演土壤盐分的有效方法,常用的遥感数据源有 Landsat TM、中巴地球资源卫星 CBERS,ASTER,EO – 1 ALI,Landsat7 ETM + ,Landsat8 OLI,Sentinel – 2A、 高分系列卫星数据、HJ1A – CCD2 和 IKONOS 卫星 图像。

高光谱成像技术具有光谱分辨率高、图谱合一的独特优势,众多国内外学者开展了基于高光谱遥 感影像的土壤盐分反演。常用的高光谱遥感影像有 美国 EO -1 卫星的 Hyperion, Terra 卫星和 Aqua 卫 星的 MODIS, Tacsat - 3 的 ARTEMIS、欧空局 PROBA 卫星的 CHRIS 和中国环境一号卫星 A 星 HJ - 1A 的高光谱成像仪 HSI 等。

光学遥感虽然应用广泛、解译方法比较成熟,但 受天气与时间的限制比较大。而对于雷达遥感来 说,因其具有全天候、全天时、穿透性等特点,可以很 好解决以上限制,继而成为获取盐渍化程度及分布 信息的有效技术手段<sup>[38]</sup>。常用的雷达影像数据有 全极化 PolSAR 数据、RADARSAT - 2 数据、探地雷 达数据、Sentinel 1 和 PALSAR 全极化数据等。

近年来,随着遥感技术的不断发展以及无人机 技术的日趋成熟,将无人机与遥感传感器结合,形成 的无人机遥感监测手段在土壤盐渍化监测领域正在 得到越来越广泛的应用。由于无人机遥感相对于近 地遥感而言,具有大区域监测的优势,同时相比卫星 遥感,影像的分辨率又有所提升,因此是广域范围内 低成本监测土壤盐渍化的一种有效手段,在精准遥 感监测领域具有较大的应用潜力<sup>[39]</sup>。目前用于土 壤盐渍化遥感监测研究的无人机传感器主要为美国 Tetracam 公司生产的 Micro – MCA 多光谱相机<sup>[40]</sup>以 及多光谱相机(ParrotS)<sup>[14]</sup>等。

#### 2.3 建模因子及优选

预处理后的遥感影像具有丰富的地物光谱信息,这些信息包含在影像不同波段的反射率值中,为 建立实测土壤盐分数据与遥感影像光谱信息之间的 联系,需要获取采样点空间位置下的遥感影像光谱 信息,通常的做法是将采样点的 GPS 坐标信息导入 到遥感影像中,提取这些位置像元点各波段的光谱 反射率 *R*,可对其进行倒数 1/*R*、对数 ln*R*、指数 e<sup>*R*</sup>、 幂函数 *R<sup>a</sup>*、S 曲线函数、一阶微分 *R'*、二阶微分 *R'*和 分数阶微分 *R<sup>0.\*</sup>*等数学变换<sup>[41-42]</sup>。

单个波段所包含的光谱信息是有限的,因此在 提取遥感影像的波段光谱反射率后可进行不同波段 之间的组合运算,这些指数通常是已有研究得出的 先验计算公式(表1),也可以使用不同的数学运算 组合计算得到,包括差异指数(differentation index, DI)、比率指数(ratio index, RI)、归一化差异指数 (normalized difference index, NDI)和土壤指数(soil index,SI)的二维波段组合光谱指数,也包括部分三 维波段组合指数(three dimensional band combination index,TBI),通过这些组合可构建功能强大的光谱 组合搜索模型<sup>[7,43]</sup>。计算公式分别为:

$$DI = R_i - R_i \quad , \tag{4}$$

$$RI = R_i / R_j \quad , \tag{5}$$

$$NDI = (R_j - R_i) / (R_j + R_i)$$
, (6)

$$SI = \sqrt{R_j^2 + R_i^2}$$
, (7)

$$TBI1 = R_i / (R_j + R_k)$$
, (8)

$$TBI2 = (R_i - R_j) / (R_j - R_k) , \qquad (9)$$

$$TBI3 = (R_i + R_j) / R_k$$
, (10)

$$TBI4 = (R_i + R_j) / [(R_i - R_j) - (R_j - R_k)] ,$$
(11)

$$TBI5 = (R_i - R_j) - (R_j - R_k) , \quad (12)$$

式中*R<sub>i</sub>*,*R<sub>j</sub>和 R<sub>k</sub>分别为从所有波段中选择的任意3个 波段的反射率,一阶和二阶微分计算公式与式(1)—(2)相同。* 

表 1 建模指数公式 Tab. 1 Modeling exponential formula

指数类型	指数	指数公式①	参考文献
	盐分指数(salinity index,SI-T)	$SI - T = (R/NIR) \times 100$	[44]
盐分指数	盐分指数(normalized difference salinity index,NDSI)	NDSI = (R - NIR)/(R + NIR)	[45]
	盐分指数(salinity index1,SII)	$SI1 = \sqrt{RG}$	[45]
	盐分指数(salinity index1,Sl2)	$SI2 = \sqrt{G^2 + R^2 + NIR^2}$	[45]
	盐分指数(salinity index1,SI3)	$SI3 = \sqrt{G^2 + R^2}$	[45]
	盐分指数(salinity index,S1)	S1 = B/R	[46]
	盐分指数(salinity index,S2)	S2 = (B - R)/(B + R)	[46]
	盐分指数(salinity index,S3)	S3 = (GR)/B	[46]
	盐分指数(salinity index,S5)	S5 = (B R)/G	[46]
	盐分指数(salinity index,S6)	S6 = (R NIR)/G	[46]
	盐分比指数(salinity ratio index,SAIO)	SAIO = (R - NIR)/(G + NIR)	[47]
	黏土指数(clay index,CLEX)	CLEX = SWIR1/SWIR2	[47]
	石膏指数(gypsum index,GYEX)	GYEX = (SWIR1 - NIR)/(SWIR1 + NIR)	[47]
	亮度指数(brightness index,BRI)	$BRI = \sqrt{G^2 + R^2}$	[47]
	碳酸盐岩指数(carbonate index,CAEX)	CAEX = R/G	[47]

( 徳主)

			(天代)
指数类型	指数	指数公式①	参考文献
植被指数	简单比值指数(simple ratio vegetation index,SR)	SR = NIR/R	[48]
	冠层响应盐指数(canopy response salinity index, CRSI)	$CRSI = \frac{\sqrt{(NIR R) - (G R)}}{\sqrt{(NIR R) + (G R)}}$	[49]
	归—化植被指数(normalized difference infrared in- dex,NDVI)	NDVI = (NIR - R)/(NIR + R)	[45]
	增强植被指数(enhanced vegetation index,EVI)	$EVI = 2.5\left(\frac{NIR - R}{NIR + 6R - 7.5B + 1}\right)$	[50]
	差值植被指数(difference vegetation index,DVI)	DVI = NIR - R	[51]
	修改土壤调节植被指数(modified soil adjusted vege- tation index,MSAVI)	$MSAVI = \frac{(2NIR - 1) - \sqrt{(2NIR + 1)^2 - 8(NIR - R)}}{2}$	[52]
	大气阻抗植被指数(atmospherically resistant vegeta- tion index,ARVI)	$ARVI = \frac{NIR - (2R - B)}{NIR + (2R + B)}$	[52]
	广义植被归一化指数(generalized difference vegeta- tion index,GDVI)	$GDVI = (NIR^2 - R^2)/(NIR^2 + R^2)$	[53]
	双波段增强植被指数(two – band enhanced vegeta- tion index,EVI2)	EVI2 = 2.5(NIR - R)/(NIR + 2.4R + 1)	[54]
	扩展植被归一化指数(extended NDVI,ENDVI)	$ENDVI = \frac{NIR + SWIR2 - R}{NIR + SWIR2 + R}$	[55]
	扩展植被增强指数(extented enhanced vegetation in- dex, EEVI)	$EVI = \frac{2.5(NIR + SWIR1 - R)}{NIR + 2.5(SWIR1 + 6NIR + R - 7.5SWIR1 - R)B + 1}$	[55]

①式中: B 表示蓝光波段; C 表示绿光波段; R 表示红光波段; NIR 表示近红外波段; SWIR1 和 SWIR2 分别表示短波红外波段1和2。

由于土壤盐渍化情况很大程度地受到气候因 素、土壤理化性质、地形因素、空间位置和植被因素 等环境变量的影响<sup>[24]</sup>,因此可引入环境变量遥感产 品数据参与建模。气候因素包括气温、降水等,土壤 理化性质包括土壤质地、地表温度、地下水位、土壤 湿度等,植物因素主要以一系列植被指数来表 征<sup>[29]</sup>,这些环境变量因子数据可以通过产品数据或 由原始遥感影像通过指数计算获得,空间位置要根 据样点坐标数据计算获得<sup>[24,56]</sup>,地形因素包括数字 高程模型(digital elevation model,DEM)数据及其衍 生数据,地下水位数据可由测站观测井获得<sup>[57]</sup>。

提取后的模型构建需要进一步优选,将提取到 的各个波段的反射率值、指数计算结果等数值与实 测土壤盐分含量进行相关性分析或回归分析,选取 相关性较高、回归系数较大的因子作为敏感波段及 敏感指数因子参与建模,并解决因子间的共线性问 题<sup>[20]</sup>。在建模前需要将样本点进行分组,建模集与 验证集比例通常接近 3:1,便于模型建立后的精度 验证。

总之,为建立土壤含盐量与遥感影像之间的联 系,实现模型的构建,首先需要获取实测土壤含盐量 数据以及遥感影像的光谱信息。实测土壤样品经定 位采集、实验室理化测定与分析、数学变换后获得的 一系列表征土壤含盐量的数据可作为模型的因变量 输入因子,不同来源的遥感数据经预处理、影像融合 等操作后提取实测样品空间位置下的像元点属性 值,经过一系列数学变换及指数计算可获取极为丰 富的建模因子,为探讨不同类型的因子对土壤盐渍 化的影响程度以及减少因子间的冗余,需要对建模 因子进行分类及优选之后参与建模,还需要预留验 证因子集作为模型精度验证的依据。

### 3 遥感监测模型的构建及精度验证

模型的构建旨在建立土壤盐分含量与建模因子 之间的关系,越来越多的模型在盐渍化遥感监测领 域得以运用,在土壤盐渍化遥感监测模型构建过程 中最常用到以下几种模型。

1)一元线性回归分模型(linear regression model, LR)是原理最简单的建模方法<sup>[19]</sup>,是根据自变量 X和因变量 Y的相关关系,建立 X = Y的线性回归方程的方法,可以建立土壤盐分含量与某一单一建模因子之间的关系,通常可在 SPSS 软件中建模,一元线性回归分析法的模型为:

$$Y = aX + b \quad , \tag{13}$$

式中: Y 表示土壤含盐量值; X 表示某一建模因子; a 和 b 分别为公式参数。

 2)多元线性回归模型(multiple linear regression model, MLR)是将多个变量进行最优组合来预测因 变量,原理简单,应用广泛<sup>[2,8-9,17,22,24,40-42,56,58-59]</sup>, 其公式为:

$$Y = b_0 + \sum_{i=1}^{m} b_i x_i , \qquad (14)$$

式中: $b_0$ 为常数项;m为建模因子个数; $b_i$ 为第i个因子的偏回归系数; $x_i$ 为第i个因子。

3)偏最小二乘回归建模是结合主成分分析与 MLR 特点的一种新型多元统计数据分析算法,其主 要是针对多因变量对多自变量的回归建模,能较好 地解决样本个数少于变量个数等问题<sup>[60-61]</sup>,可用于 各变量之间具有多重共线性时,该算法不再直接考 虑因变量与自变量的回归建模,而是对变量系统中 的信息重新进行综合筛选,从中选取若干对系统具 有最佳解释能力的新成分用于回归建模。偏最小二 乘回归的基本步骤如下:首先,分析自变量与因变 量之间的关系,要从 *p* 个自变量和因变量中分别提 取出 *p* 个自变量的线性组合以及 *p* 个因变量的线性 组合,公式为:

 $t_1 = e_{1,1} x_1 + e_{1,2} x_2 + \dots + e_{1,p} x_p = e_1 x_1$ , (15)  $v_1 = v_{1,1} x_1 + v_{1,2} x_2 + \dots + v_{1,p} x_p = v_1 y_1$ , (16) 式中:  $e_1 = (e_{1,1}, e_{1,2}, \dots, e_{1,p})$ 为模型效应权重;  $v_1 = (v_{1,1}, v_{1,2}, \dots, v_{1,p})$ 为因变量权重。其次,分别建立 p个自变量和因变量对  $t_1$ 的回归方程,如果该方程 有较好的精度,则回归方程成立,否则,要对  $t_1$ 分别 对自变量和因变量解释后的信息进行再一次提取, 直到达到较好的精度为止。

4) BP - 神经网络被广泛用于土壤盐分反演 中<sup>[13,60]</sup>,主要由信号的正向传播和误差的反向传播 这2个过程组成。正向传播就是按照输入层、隐藏 层和输出层的顺序依次输出,若实际输出值与期望 输出值相差较大,则开始进行误差的反向传播,其与 正向传播的方向刚好相反,就是将输出误差按照输 出层、隐藏层和输入层的顺序输出,以此可对各单元 的权重进行修正,通过不断修正,减少实际输出值与 期望输出值的差距,从而达到预测的目的。

5) SVM 方法是一种新近的模式分类方法<sup>[62-63]</sup>,对于解决小样本、非线性及高维模式识别等问题具有优越性,它处理的是二元分类模型。二元模型假设一个土壤样本只属于一个类,并且只有2个类(*C* = {*c*<sub>1</sub>,*c*<sub>2</sub>})。每个有*l*个类的分类任务都可以使用一对一方法被建模为二进制任务,其中一个训练*l*(*l*-1)/2个二进制分类器,每个分类器对应一对类。最后的决策是通过投票的方式做出的,即选择最常被预测的类作为输出,在使用时需要确定核函数和惩罚因子。

(6)随机森林是一种新型的分类和预测模型<sup>[61]</sup>,"随机森林"的名称取自"随机"和""森林",
"随机"包括随机选取训练样本集和随机选取分裂属性集,这使得随机森林具有良好的抗噪能力。

"森林"即有许多的决策树,其实这也是随机森林的 主要思想-集成思想的体现。随机森林是决策树的 组合,每棵决策树都是通过对原始数据集中随机生 成新的数据集来训练生成,随机森林决策的结果是 多颗决策树的决策结果。

除上述模型外一些新型模型与改进模型也被用 于遥感监测模型的构建,如逐步多元回归(stepwise multiple regression analysis, SMR) 模型<sup>[17,35,64]</sup>、岭回 归模型(ridge regression, RR)模型<sup>[65-66]</sup>、普通最小 二乘法(ordinary least square, OLS)<sup>[67-68]</sup>、空间自回 归(spatial autore gression, SAR)模型<sup>[56]</sup>、决策树算 法(decision tree algorithm, DTA)<sup>[67]</sup>、支持向量回归 (support vector regression, SVR)模型<sup>[12,25,69]</sup>、粒子群 优化支持向量机(particle swarm optimization support vector machine, PSO - SVM) 模型<sup>[15,70]</sup>、网格搜索支 持向量机(grid search support vector machine, GS-SVM)<sup>[71]</sup>、差分进化支持向量机(differential evolution support vector machine, DE - SVM) 模型<sup>[15]</sup>、卷 积神经网络(convolutional neural network, CNN)模 型<sup>[70]</sup>、多元自适应回归样条 (multivariate adaptive regression spline, MARS) 模型<sup>[1,25,72]</sup>、人工神经网络 (artificial neural network, ANN)模型<sup>[7,26]</sup>、Bootstrap -BP神经网络模型<sup>[43]</sup>、极限学习机(extra learning machine, ELM)<sup>[61,73]</sup>、结构方程模型<sup>[74]</sup>(structural equation model,SEM)、溶质运移模型<sup>[28]</sup>、地理加权 回归(geographically weighted regression, GWR)模 型<sup>[24,66]</sup>、多布森模型(Dobson model)<sup>[75]</sup>和修正的残 差克里金模型<sup>[76]</sup>等模型。

基于光谱特征空间的方法也可以建立土壤遥感 监测模型<sup>[77-78]</sup>,通过建立影响土壤盐渍化参量的二 维或三维空间,可用特征空间中到某一特征点的距 离反映盐度,不同区域反映不同程度土壤盐渍 化<sup>[79]</sup>,确定不同参量之间的相互变化趋势,结合实 际经验对散点空间图进行分析,利用散点图的空间 特征参量建立相应模型。

模型的实现可以使用 SPSS、R 语言、Matlab 和 Python 等软件实现,具体使用过程中需要调整数据 格式及模型参数。模型建立之后需要使用验证集对 模型精度进行验证,在预测模型进行精度评价时,通 常选取决定系数  $R^2$ 、均方根误差 (root mean square error,RMSE)、相对分析误差 (relative percent deviation, RPD)和平均绝对误差 (mean absolute error, MAE),其中  $R^2$ 与模型的精度成正比,RMSE 和 MAE 与模型的估算预测能力成反比,且当 RPD < 1.4,说 明模型不可靠, $1.4 \leq RPD \leq 2$  时,说明模型精度一 般,RPD > 2 时,说明模型有较强的预测能力。其计 算公式分别为:

$$R^{2} = \frac{\sum_{i=1}^{n} (X_{i} - \overline{X}) (Y_{i} - \overline{Y})}{\sqrt{\sum_{i=1}^{n} (X_{i} - \overline{X})^{2} \sum_{i=1}^{n} (Y_{i} - \overline{Y})^{2}}}, \quad (17)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n} (Y_i^0 - Y_i^8)^2}{n}} , \qquad (18)$$

$$RPD = \frac{stdev}{RMSE} \quad , \tag{19}$$

$$MAE = \frac{\sum_{i=1}^{n} (Y_i^0 - Y_i^8)}{n} , \qquad (20)$$

式中: stdev 为基于样本估算标准偏差;  $X_i$ 为某一采 样点的实测土壤盐分含量;  $Y_i$ 为某一采样点的预测 土壤盐分含量;  $\overline{X}$  为某实测土壤盐分含量平均值;  $\overline{Y}$ 为预测土壤盐分含量平均值;  $Y_i^{0}$ 和  $Y_i^{s}$ 分别为测 试集上的真实值和预测值。

当前研究中 MLR 以及机器学习算法被广泛应 用于土壤盐渍化遥感检测模型的建立,改进的数学 模型被不断地运用于该领域的研究,并取得了较高 的模型精度,经精度验证对比后的最优模型可用于 区域土壤盐渍化专题图制作,制图过程中还需要充 分利用制图技术及先验知识来进一步提高专题图精 度,为区域盐渍化时空分析及预测提供依据。

### 4 结论与展望

#### 4.1 结论

土壤盐渍化遥感监测模型的构建将作为土壤盐 渍化遥感监测领域的研究热点,目的是为了获取更 高精度的反演模型,用以表征区域内的土壤盐渍化 情况,反映土壤盐渍化状况与其影响因素的相互关 系。模型的建立通常包括实测土壤盐分数据的获 取、遥感影像的获取、建模因子的提取及优选、模型 的建立与精度验证等步骤,但不同研究之间存在一 定的差异。

土壤实测数据通常采用实地取实验室样化验的 方法测定,也可以使用土壤传感电磁感应等测定设 备更为快捷的获取,在实际采样过程中还需要根据 研究需要测定不同深度下土壤样品的含盐量,根据 分析需求测定土壤样品的离子含量、pH、土壤水分 等理化性质。当前研究中用到的遥感影像数据主要 有 Landsat TM, Landsat8 OLI, Sentinel – 2A, GF – 1, HJ – 1A – CCD2 和 MODIS 等,卫星雷达遥感影像以 及无人机遥感影像也有所使用,获取到的遥感影像 需要经过预处理达到使用要求,通过影像融合、微分 变换等手段可获取更多的光谱信息。

建模因子通过提取采样点坐标位置下表征与土 壤盐渍化有关因素的遥感影像像元数值以及波段反 射率数值获取,参与建模的因子可以是原始或经过 数学变换后的波段反射率值,也可以是通过先验指 数公式计算得到的指数数值,通过遥感产品数据获 得的像元点数值也是建模因子数据的重要来源。用 于建模的气候因素、土壤理化性质、地形因素、空间 位置和植被因素等因子,可以通过波段计算以及相 应的遥感数据获取。在建模过程中,不同因子可根 据建模需求划分成不同的集合参与建模。

模型建立的方法主要有线性回归模型以及机器 学习模型,为提高模型构建精度需要不断尝试改进 后的新型模型算法,模型的构建需要通过不同数学 分析软件的相应模块实现。模型的精度受到采样点 数目、样品测验精度、遥感影像质量、建模因子的选 取以及模型参数的影响,主要以选取 *R*<sup>2</sup>, RMSE, RPD 及 MAE 来体现和对比模型精度。建模完成 后,对不同模型进行对比优选,进行遥感影像反演, 制作土壤盐渍化专题地图。大量研究结果表明机器 学习模型的建模精度一般要高于线性模型,不同模 型精度在不同的实验研究中存在较大差异。

#### 4.2 存在的局限性

土壤盐渍化遥感监测模型的构建作为遥感研究 应用的热点领域,国内外众多学者不断利用新的技 术手段与研究方法实现了区域内土壤盐渍化的高精 度监测,取得了丰富的研究成果,但仍然存在以下 问题:

1)模型的适用性为当前研究中存在最主要的问题。研究区盐渍土的理化性质、采样方案的设计、 建模因子及建模方法的不同导致了所得模型具有专一性,单篇文章中所得模型可实现以少量的实测采 样点数据反映研究区范围内土壤盐渍化情况,但该 模型往往不适用于其他研究区或其他季节,因此如 何建立普适性较高的模型来实现不同研究区及不同 时序土壤盐渍化反演是该研究领域的一大难点。

2)耐盐植物可以在中度或轻度盐渍化土壤条件下生长,植被与裸地的光谱特征存在较大的差异性,因此在建立农田、草地及林地覆被下的土壤盐渍化监测模型时需要考虑区域内的植被覆盖情况,加大了采样方案设计及模型构建的难度,也使得模型对土壤盐渍化的反映能力下降,如何构建精度较高、能准确反映植被覆盖区域的土壤盐渍化模型是该研究领域的一大难点。

3)模型的构建需要选取多种土壤盐渍化影响 因子,相应遥感影像及产品数据的空间和时间分辨 率存在一定的差异,具体建模过程中通常对影像进 行重采样或选择时间相近的影像进行建模,受天气、 卫星状况影响,影像会存在缺失及质量问题,当建模 因子数量较多时会使误差增大,因此获取时间和空 间分辨率一致并保证所有参与建模因子对应的影像 质量均达到精度要求是难以实现的。

#### 4.3 发展趋势

遥感技术的不断进步,遥感产品数据的不断丰 富将为盐渍化反演模型的建立提供更多的数据选 择,更高精度、更多种类的遥感影像可为模型提供更 多的建模因子,在未来的研究中需要不断发现可用 于土壤盐渍化建模的新型遥感数据,利用这些数据 丰富建模因子。此外,多源遥感数据的协同使用如 多光谱遥感数据与微波遥感数据的协同使用将有助 于地下土壤盐分的估算,无人机因其机动灵活,数据 空间分辨率高等特点未来将被广泛运用于土壤盐渍 化的监测。

遥感模型的建立需要利用统计学和机器学习中 的模型算法,因此不断尝试改进的数学建模方法可 以使土壤盐渍化遥感建模领域产生新的发现,不同 模型之间的对比以及模型参数的优化改进将不断提 高盐渍化遥感监测的精度,专业遥感软件不断升级 以及数学分析软件模型构建模块算法的改进与创新 也会给土壤盐渍化反演模型建立提供新的方法。

当前研究建立的土壤盐渍化反演遥感模型通常 适用于某一特定的研究区域,受到遥感影像数据量、 数据精度与建模过程中不同数据间的匹配问题,缺 乏能够适应大尺度、长时间跨度使用的遥感监测模 型,随着遥感分析云平台的产生与发展,利用 Google Earth Engine(GEE)等云平台进行大的空间和时间 尺度上的土壤盐渍化遥感反演模型的建立与验证将 成为一种未来的发展趋势。盐渍化遥感监测模型与 专门的土壤模型以及生态模型相结合将会为土壤盐 渍化的动态监测与预测提供新的思路。

#### 参考文献(References):

- [1] Nawar S, Buddenbaum H, Hill J, et al. Modeling and mapping of soil salinity with reflectance spectroscopy and Landsat data using two quantitative methods (PLSR and MARS) [J]. Remote Sensing, 2014, 6(11):10813 - 10834.
- [2] 刘恩,王军涛,常步辉,等.小开河引黄灌区土壤盐渍化定量 遥感反演[J].中国农村水利水电,2019(12):20-24.
   Liu E, Wang J T, Chang B H, et al. Quantitative remote sensing inversion of soil salinization in Xiaokaihe Yellow River irrigation district[J]. China Rural Water and Hydropower,2019(12):20-24.
- [3] Wen W, Timmermans J, Chen Q, et al. A review of remote sensing

challenges for food security with respect to salinity and drought threats[J]. Remote Sensing, 2020, 13(1):3010006.

- [4] Chen H, Ma Y, Zhu A, et al. Soil salinity inversion based on differentiated fusion of satellite image and ground spectra [J]. International Journal of Applied Earth Observation and Geoinformation, 2021,101:102360.
- [5] Metternicht G I,Zinck J A. Remote sensing of soil salinity: Potentials and constraints[J]. Remote Sensing of Environment, 2003, 85 (1):1-20.
- [6] Perri S, Suweis S, Holmes A, et al. River basin salinization as a form of aridity[J]. Proceedings of the National Academy of Sciences, 2020, 117(30): 17635 - 17642.
- [7] Wang Z, Zhang F, Zhang X, et al. Regional suitability prediction of soil salinization based on remote – sensing derivatives and optimal spectral index [J]. Science of the Total Environment, 2021, 775 (12):145807.
- [8] 吴亚坤,刘广明,苏里坦,等. 多源数据的区域土壤盐渍化精确 评估[J]. 光谱学与光谱分析,2018,38(11):214-219.
  Wu Y K,Liu G M,Su L T, et al. Accurate evaluation of regional soil salinization using multi - source data[J]. Spectroscopy and Spectral Analysis,2018,38(11):214-219.
- [9] 厉彦玲,赵庚星,常春艳,等. OLI 与 HSI 影像融合的土壤盐分 反演模型[J].农业工程学报,2017,33(21):173-180. Yan L L,Zhao G X,Chang C Y, et al. Soil salinity retrieval model based on OLI and HSI image fusion[J]. Transactions of the Chinese Society of Agricultural Engineering, 2017,33(21):173-180.
- [10] Ivushkin K, Bartholomeus H, Bregt A K, et al. Satellite thermography for soil salinity assessment of cropped areas in Uzbekistan[J].
   Land Degradation and Development, 2017, 28(3):870 877.
- [11] Abduldaem S A, Majed I, Ayad M F Q, et al. Detection and modeling of soil salinity variations in arid lands using remote sensing data [J]. Open Geosciences, 2021, 13(1):443 - 453.
- [12] Aldabaa 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 - 240:34 - 46.
- [13] Zhang X, Huang B, Liu F. Information extraction and dynamic evaluation 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):69 – 80.
- [14] Qi G, Chang C, Yang W, et al. Soil salinity inversion in coastal corn planting areas by the satellite – UAV – ground integration approach [J]. Remote Sensing, 2021, 13(16):13163100.
- [15] Zhou X, Zhang F, Liu C, et al. Soil salinity inversion based on novel spectral index [J]. Environmental Earth Sciences, 2021, 80 (16):1-13.
- [16] 关 红,武 丹. 干旱区土壤盐渍化遥感估测模型研究——以宁 夏平罗县为例[J]. 宁夏工程技术,2017,16(4):363-366.
  Guan H, Wu D. Research on models for the remote sensing of soil salinization in the arid region: A case of Pingluo, Ningxia [J].
  Ningxia Engineering Technology,2017,16(4):363-366.
- [17] 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(2):156-175.
- [18] 李德仁,童庆禧,李荣兴,等.高分辨率对地观测的若干前沿科

学问题[J].中国科学:地球科学,2012,42(6):805-813. Li D R, Tong Q X, Li R X, et al. Current issues in high - resolution earth observation technology[J]. Scientia Sinica(Terrae), 2012, 42(6):805-813.

- [19] Sahana M, Rehman S, Patel P P, et al. Assessing the degree of soil salinity in the Indian Sundarban Biosphere Reserve using measured soil electrical conductivity and remote sensing data – derived salinity indices [J]. Arabian Journal of Geosciences, 2020, 13 (24): 1289.
- [20] Zhuang Q, Shao Z, Huang X, et al. Evolution of soil salinization under the background of landscape patterns in the irrigated northern slopes of Tianshan Mountains, Xinjiang, China [J]. Catena, 2021, 206(8):105561.
- [21] Wang J, Peng J, Li H, et al. Soil salinity mapping using machine learning algorithms with the Sentinel - 2 MSI in arid areas, China [J]. Remote Sensing, 2021, 13(2):13020305.
- [22] Bouaziz M, Gloaguen R, Faust D. Modeling of soil salinity based on remote sensing processing and geochemical analysis in southern Tunisia[C]//EGU General Assembly Conference, 2013:1785.
- [23] 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.
- [24] Li Z, Li Y, An X, et al. Spatial prediction of soil salinity in a semiarid oasis: Environmental sensitive variable selection and model comparison [J]. Chinese Geographical Science, 2019, 29 (5): 784-797.
- [25] Mahajan G R, Das B, Gaikwad B, et al. Monitoring properties of the salt – affected soils by multivariate analysis of the visible and near – infrared hyperspectral data[J]. Catena, 2020, 198:105041.
- [26] Farifteh J, VanderMeer F D, 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.
- [27] Wang L, Zhang B, Shen Q, et al. Estimation of soil salt and ion contents based on hyperspectral remote sensing data: A case study of Baidunzi Basin, China[J]. Water, 2021, 13(4):559.
- [28] Farifteh J, Farshad A, George R J. Assessing salt affected soils using remote sensing, solute modelling, and geophysics [J]. Geoderma, 2006, 130(3-4):191-206.
- [29] Ding J, Yang S, Shi Q, et al. Using apparent electrical conductivity as indicator for investigating potential spatial variation of soil salinity across seven oases along Tarim River in southern Xinjiang, China[J]. Remote Sensing, 2020, 12(16):2601.
- [30] 魏 龙,王维真,吴月茹,等. 土壤水盐介电模型对比与分析
  [J]. 遥感技术与应用,2017,32(6):1022 1030.
  Wei L, Wang W Z, Wu Y R, et al. Comparative analysis of soil water and salt dielectric model[J]. Remote Sensing Technology and Application,2017,32(6):1022 1030.
- [31]姚 远,丁建丽,阿尔达克·克里木,等.基于实测高光谱和电磁感应数据的区域土壤盐渍化遥感监测研究[J].光谱学与光谱分析,2013,33(7):1917-1921.

Yao Y, Ding J L, Ardaq K, et al. Research on remote sensing monitoring of soil salinization based on measured hyperspectral and EM38 data[J]. Spectroscopy and Spectral Analysis, 2013, 33(7): 1917 – 1921.

- [32] Elnaggar A A, Noller J S. Application of remote sensing data and decision – tree analysis to mapping salt – affected soils over large areas[J]. Remote Sensing, 2009, 2(1):151–165.
- [33] Zahraa M A, Bannari A, Hassan R, et al. Validation and comparison of physical models for soil salinity mapping over an arid landscape using spectral reflectance measurements and Landsat – OLI data[J]. Remote Sensing, 2021, 13(3):494.
- [34] 张 飞,丁建丽,何祺胜. 塔里木盆地北缘绿洲盐渍化地地物光 谱特征分析[J]. 东北林业大学学报,2008(6):37-42.
  Zhang F, Ding J L, He Q S. Analysis of spectral characteristics of salinized land in oasis in the northern margin of Tarim Basin[J].
  Journal of Northeast Forestry University,2008(6):37-42.
- [35] 马 驰. 基于 Sentinel 2A 遥感数据对吉林白城市土壤含盐量的反演[J]. 干旱区研究,2020,37(3):591-597.
  Ma C. Inversion of soil salt content based on Sentinel 2A remote sensing in Baicheng City, Jilin Province[J]. Arid Zone Research, 2020,37(3):591-597.
- [36] 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.
- [37] 关 红,贾科利,张至楠,等. 盐渍化土壤光谱特征分析与建模
  [J]. 国土资源遥感, 2015, 27 (2):100 104. doi: 10.6046/ gtzyyg. 2015.02.16.
  Guan H, Jia K L, Zhang Z N, et al. Research on remote sensing monitoring model of soil salinization based on spectrum characteristic analysis[J]. Remote Sensing for Natural Resources, 2015, 27(2):
- [38] 李 彪, 王耀强. 土壤盐渍化雷达反演模拟研究[J]. 干旱区资源与环境, 2015, 29(8):180-184.
  Li B, Wang Y Q. Radar inversion and simulation of salty soil salinization [J]. Journal of Arid Land Resources and Environment, 2015, 29(8):180-184.

100 - 104. doi:10.6046/gtzyyg.2015.02.16.

- [39] Ivushkin K, Bartholomeus H, Bregt A K, et al. UAV based soil salinity assessment of cropland [J]. Geoderma, 2019, 338:502 – 512.
- [40] 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 Z T, Wei G F, Yao Z H, 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.

 [41] 周晓红,张 飞,张海威,等. 艾比湖湿地自然保护区土壤盐分 多光谱遥感反演模型[J]. 光谱学与光谱分析,2019,39(4): 1229-1235.

Zhou X H,Zhang F,Zhang H W, et al. A study of soil salinity inversion based on multispectral remote sensing index in Ebinur Lake wetland nature reserve [J]. Spectroscopy and Spectral Analysis, 2019,39(4):1229-1235.

- [42] 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.
- [43] Wang X, Zhang F, Ding J, et al. Estimation of soil salt content (SSC) in the Ebinur Lake Wetland National Nature Reserve (EL-

WNNR), Northwest China, based on a Bootstrap – BP neural network model and optimal spectral indices [J]. Science of the Total Environment, 2018, 615:918.

- [44] Tripathi N K, Rai B K, Dwivedi P. Spatial modeling of soil alkalinity in GIS environment using IRS data[C]//18th Asian Conference on Remote Sensing, Kualalampur, 1997;81 – 86.
- [45] Khan N M, Rastoskuev 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): 96-109.
- [46] 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, 30:1-8.
- [47] Taghizadeh Mehrjardi R, Minasny B, Sarmadian F, et al. Digital mapping of soil salinity in Ardakan region, central Iran [J]. Geoderma, 2014, 213:15 - 28.
- [48] Chen J M. Evaluation of vegetation indices and modified simple ratio for boreal applications [J]. Canadian Journal of Remote Sensing, 1996, 22(3):229 - 242.
- [49] Broge N H, Leblanc E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density [J]. Remote Sensing of Environment, 2001, 76(2):156-172.
- [50] Liu H Q, Huete A R. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise [J]. IEEE Transactions on Geoscience and Remote Sensing, 1995, 33 (2): 457-465.
- [51] Jiang Z, Huete A R, Chen J, et al. Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction[J]. Remote Sensing of Environment, 2006, 101 (3):366 - 378.
- [52] Qi J, Chehbouni A, Huete A R, et al. A modified soil adjusted vegetation index[J]. Remote Sensing of Environment, 1994, 48 (2): 119-126.
- [53] Wu W, Mhaimeed A S, Al Shafie W M, et al. Mapping soil salinity changes using remote sensing in Central Iraq[J]. Geoderma Reg ional, 2014,2(3):21 – 31.
- [54] Jiang H, Ding J, Tashpolat T, et al. Extracting salinized soil information in arid areas using ETM+ data[J]. Acta Pedologica Sinica, 2008,45(2):222-228.
- [55] Chen H,Zhao G,Chen J, et al. Remote sensing inversion of saline soil salinity based on modified vegetation index in estuary area of Yellow River[J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(5):107-114.
- [56] Scudiero E, Skaggs T H, Corwin D L. Regional scale soil salinity assessment using Landsat ETM+ canopy reflectance [J]. Remote Sensing of Environment, 2015, 169:335 – 343.
- [57] Jin X, Vekerdy Z, Zhang Y, et al. Soil salt content and its relationship with crops and groundwater depth in the Yinchuan Plain (China) using remote sensing[J]. Arid Land Research and Management, 2012, 26(3):227-235.
- [58] 张海威,张 飞,李 哲,等. 艾比湖流域盐渍土含水量光谱特征 分析与建模[J]. 中国水土保持科学,2017,15(1):8-14. Zhang H W, Zhang F, Li Z, et al. Modeling and analysis of spectral characteristic of soil water content in the salinized soil of Ebinur Lake Watershed [J]. Science of Soil and Water Conservation,

2017,15(1):8-14.

- [59] Morshed M M, Islam M T, Jamil R. Soil salinity detection from satellite image analysis: An integrated approach of salinity indices and field data [J]. Environmental Monitoring and Assessment, 2016, 188(2):119.
- [60] Jiang H, Shu H. Optical remote sensing data based research on detecting soil salinity at different depth in an arid – area oasis, Xinjiang, China[J]. Earth Science Informatics, 2018, 12(1):43 – 56.
- [61] 马国林,丁建丽,韩礼敬,等. 基于变量优选与机器学习的干旱 区湿地土壤盐渍化数字制图[J].农业工程学报,2020,36 (19):124-131.
  Ma G L, Ding J L, Han L J, et al. Digital mapping of soil salinization in arid area wetland based on variable optimized selection and machine learning[J]. Transactions of the Chinese Society of Agricultural Engineering,2020,36(19):124-131.
- [62] 段素素,依力亚斯江·努尔麦麦提,郭莉丹,等. 基于全极化微 波遥感的干旱区典型绿洲盐渍化信息提取[J]. 湖北农业科 学,2018,57(2):110-114.
  Duan S S, Eliasjan N, Guo L D, et al. Extraction of salinization information of typical oasis in arid region based on fully polarized microwave remote sensing[J]. Hubei Agricultural Sciences,2018,57 (2):110-114.
- [63] Wang N, Xue J, Peng J, et al. Integrating remote sensing and landscape characteristics to estimate soil salinity using machine learning methods: A case study from Southern Xinjiang, China [J]. Remote Sensing, 2020, 12(24):4118.
- [64] Fourati H T, 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.
- [65] 毛鸿欣, 贾科利,张 旭. 基于实测高光谱和 Sentinel 2B 影像的银川平原土壤盐分反演[J]. 云南大学学报(自然科学版), 2021,43(5):929-941.
  Mao H X, Jia K L, Zhang X. Inversion of soil salinity in Yinchuan Plain based on measured hyperspectral data and Sentinel 2B images[J]. Journal of Yunnan University(Natural Sciences Edition), 2021,43(5):929-941.
- [66] 贾萍萍,尚天浩,张俊华,等.利用多源光谱信息反演宁夏银北 地区干湿季土壤含盐量[J].农业工程学报,2020,36(17): 125-134.

Jia P P, Shang T H, Zhang J H, et al. Inversion of soil salinity in dry and wet seasons based on multi – source spectral data in Yinbei area of Ningxia, China [J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(17):125 – 134.

- [67] Tripathi A, Tiwari R K. A simplified sub surface soil salinity estimation using synergy of Sentinel – 1 SAR and Sentinel – 2 multispectral satellite data, for early stages of wheat crop growth in Rupnagar, Punjab, India [ J ]. Land Degradation and Development, 2021, 32(14):3905 – 3919.
- [68] Scudiero E, Skaggs T H, Corwin D L. Comparative regional scale soil salinity assessment with near – ground apparent electrical conductivity and remote sensing canopy reflectance[J]. Ecological Indicators, 2016, 70:276 – 284.
- [69] Taghizadeh Mehrjardi R, Toomanian N, Shamshirband S, et al. Predicting and mapping of soil salinity using machine learning algorithms in central arid regions of Iran[C]//EGU General Assem-

第4期

- [70] Wang Z, Zhang X, Zhang F, et al. Estimation of soil salt content using machine learning techniques based on remote – sensing fractional derivatives: A case study in the Ebinur Lake Wetland National Nature Reserve, Northwest China[J]. Ecological Indicators, 2020,119:1470 – 1600.
- [71] Wang X, Zhang F, Kung H, 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.
- [72] Erkin N, Zhu L, Gu H, et al. Method for predicting soil salinity concentrations in croplands based on machine learning and remote sensing techniques[J]. Journal of Applied Remote Sensing, 2019, 13(3):034520.
- [73] Xiao D, Wan L. Remote sensing inversion of saline and Alkaline Land based on an improved seagull optimization algorithm and the two - hidden - layer extreme learning machine [J]. Natural Resources Research, 2021, 30(5):3795 - 3818.
- [74] Liu Y, Pan X, Wang C, et al. Can subsurface soil salinity be predicted from surface spectral information? From the perspective of structural equation modelling [J]. Biosystems Engineering, 2016, 152:138-147.

- [75] Wu Y, Wang W, Zhao S, et al. Dielectric properties of saline soils and an improved dielectric model in C - band[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53 (1): 440 -452.
- [76] Garcia E L A. Detecting soil salinity in alfalfa fields using spatial modeling and remote sensing[J]. Soil Science Society of America Journal, 2008, 72(1):201-211.
- [77] 丁建丽,姚 远,王 飞. 基于三维光谱特征空间的干旱区土壤 盐渍化遥感定量研究[J]. 土壤学报,2013,50(5):853-861. Ding J L,Yao Y,Wang F. Quantitative remote sensing of soil salinization in arid regions based on three dimensional spectrum eigen spaces[J]. Acta Pedologica Sinica,2013,50(5):853-861.
- [78] 李艳华,丁建丽,孙永猛,等. 基于三维特征空间的土壤盐渍化 遥感模型[J].水土保持研究,2015,22(4):113-117,121.
  Li Y H,Ding J L,Sun Y M,et al. Remote sensing monitoring models of soil salinization based on the three dimensional feature space of MSAVI – WI – SI[J]. Research of Soil and Water Conservation, 2015,22(4):113-117,121.
- [79] Guo B, Yang F, Han, B, et al. A model for the rapid monitoring of soil salinization in the Yellow River Delta using Landsat8 OLI imagery based on VI – SI feature space [J]. Remote Sensing Letters, 2019,10(8):796-805.

# Present situation and development trend in building remote sensing monitoring models of soil salinization

LI Xingyou<sup>1,2</sup>, ZHANG Fei<sup>1,2,3</sup>, WANG Zheng<sup>1,2</sup>

(1. College of Geography and Remote Sensing Sciences, Xinjiang University, Urumqi 830017, China; 2. Key Laboratory of Oasis Ecology of Ministry of Education, Xinjiang University, Urumqi 830017, China; 3. Key Laboratory of Smart City and Environment Modeling, Xinjiang University, Urumqi 830017, China)

Abstract: As a major form of soil degradation, soil salinization can greatly harm agricultural production and ecological environment. Remote sensing methods can acquire soil spectral characteristics in a rapid, macroscopic, and timely manner. Based on this, remote sensing monitoring models can be built for a wide range of soil salinization monitoring and assessment. Thus, summarizing and discussing the building methods for remote sensing monitoring models of soil salinization is of great significance to improve the precision of remote sensing monitoring of soil salinization and to monitor and control salinized soil. This study reviewed the recent literature related to remote sensing studies concerning soil salinization at home and abroad. Then, it summarized the steps such as factor selection, model building, and precision verification in the building of remote sensing monitoring models of soil salinization. Focusing on the current hot research topic, this study discussed the limitations and development trends. The main conclusions are as follows. The remote sensing monitoring models of soil salinization are important means for monitoring and forecasting salinized soil. In recent years, the hot research topic in this field is to improve the model precision using new data sources and models. Differences exist in the use of remote sensing data sources among different studies, but the modeling factors are all optimized from spectral sensitive bands, prior spectral indices, and remote sensing - derived data. The remote sensing monitoring models of soil salinization mainly include the linear regression model and the machine learning model. The remote sensing models built for different regions have different precision and applicability.

Keywords: soil salinization; remote sensing monitoring; modeling factor; model building; precision verification (责任编辑:陈理) doi: 10.6046/zrzyyg.2022010

引用格式: 吕雅楠,朱红,孟健,等. 面向高分辨率遥感影像车辆检测的深度学习模型综述及适应性研究[J]. 自然资源遥感, 2022,34(4):22-32. (Lyu Y N, Zhu H, Meng J, et al. A review and adaptability study of deep learning models for vehicle detection based on high – resolution remote sensing images[J]. Remote Sensing for Natural Resources, 2022, 34(4):22-32.)

# 面向高分辨率遥感影像车辆检测的深度 学习模型综述及适应性研究

吕雅楠1,朱红1,孟健2,崔成玲3,宋其淇1

(1. 防灾科技学院生态环境学院,廊坊 065201;2. 防灾科技学院地球科学学院,廊坊 065201;

3. 北京吉威空间信息股份有限公司,北京 100043)

摘要:车辆检测问题是计算机视觉和摄影测量与遥感领域的研究热点。随着深度学习技术的发展,遥感影像车辆 检测已在智慧城市和智能交通等领域展开应用。文章系统归纳了现有的基于深度学习模型的遥感影像车辆检测 算法,着重从单阶段与双阶段的车辆检测算法进行了归类、分析及比较;重点梳理了大幅面、复杂背景环境下车辆 检测的关键技术,分析主流深度学习模型应用于遥感影像车辆检测的优缺点。利用 DOTA 和 DIOR 数据集对 YOLOv5,Faster – RCNN,FCOS 和 SSD 算法进行评估,在 DOTA 数据集上,车辆检测精度分别为0.695,0.410,0.370 和0.251;在 DIOR 数据集上,车辆检测精度分别为0.566,0.243,0.231 和0.154。实验结果表明,目标尺度较小仍 是制约遥感影像车辆检测性能的主要因素,深度学习模型应用于小目标检测存在较大的提升空间。最后,基于公 开数据集与已有研究算法分析的基础上,给出大幅面复杂背景下遥感影像车辆检测的解决方法及发展趋势。 关键词:遥感影像,车辆检测;深度学习,分析方法

中图法分类号: P 237 文献标志码: A 文章编号: 2097-034X(2022)04-0022-11

# 0 引言

随着我国社会经济的快速发展,智慧城市建设 已成为高科技发展的前沿领域,而智能交通建设是 智慧城市信息化建设的关键。城镇化推动人口大规 模地向城市地区聚拢,社会城市化进程不断加快,智 慧出行成为当今各大城市所面临的热点问题。如何 在"互联网+"时代基于遥感大数据实现全民智能 出行,解决复杂多变的交通状况、交通普查以及交通 安全是目前所面临的难点问题<sup>[1]</sup>。其中,车辆检测 作为智能出行的基础与核心,在目标跟踪与事件检 测等更高层次的视觉任务中具有重要的现实意义。 遥感影像具有地面覆盖范围广、适合大范围车辆检 测的优势,在智能出行道路车辆信息获取方面可以 克服设备成本高、安装工作量大且安装复杂等缺 陷<sup>[2-4]</sup>。然而,传统目标检测方法是基于滑动窗口 搜索或特征提取算法,存在繁杂的计算成本及特征 表征能力受限的问题。近年来,人工智能的快速发 展掀起了深度学习研究的新浪潮,深度学习算法在 图像处理领域取得了显著成果。利用深度卷积神经 网络自主学习图像特征,在图像目标检测方面的效 果明显优于传统方法。通过搭建深度学习网络模 型,可充分挖掘图像数据间的特征与关联,利用学习 到的参数,实现目标检测<sup>[5]</sup>。深度学习方法在自然 场景检测方面已经取得重大突破,但直接迁移到遥 感影像的小目标检测还存在许多问题,检测方法需 进一步优化<sup>[6]</sup>。

目前,深度学习模型应用于复杂背景下大幅面 遥感影像车辆目标检测仍存在以下亟待解决的难点 问题:①现有的深度学习方法多侧重于近景影像研 究,而对遥感影像特征提取方面涉及相对较少,深度 卷积神经网络图像特征提取与信息表达尚不清晰, 不能有效利用遥感影像自身的先验信息,很难实现

收稿日期: 2022-01-12;修订日期: 2022-06-10

基金项目:河北省自然科学基金项目"面向凝视卫星视频图像超分辨率重建的智能化车辆检测方法研究"(编号:D2020512001)、中央 高校基本科研业务费项目"基于凝视卫星视频图像的超分辨率重建研究"(编号:ZY20200202)和廊坊市科学技术研究与发 展计划自筹经费项目"面向多级金字塔式非线性细节提升的超分辨率重建研究"(编号:2021013164)共同资助。 第一作者:吕雅楠(1997-),男,硕士研究生,主要从事遥感图像识别方面的研究。Email:13835436519@163.com。

通信作者:朱 红(1989-),女,博士,副教授,主要从事目标检测、遥感图像超分辨率重建、卫星姿态等方面的研究。Email: zhuhong19890408@163.com。