

doi: 10.6046/zrzygg.2021126

引用格式: 晏红波, 韦晚秋, 卢献健, 等. 基于高光谱特征的土壤含水量遥感反演方法综述[J]. 自然资源遥感, 2022, 34(2): 1–9. (Yan H B, Wei W Q, Lu X J, et al. A review of remote sensing inversion methods for estimating soil water content based on hyperspectral characteristics [J]. Remote Sensing for Natural Resources, 2022, 34(2): 1–9.)

基于高光谱特征的土壤含水量遥感反演方法综述

晏红波^{1,2}, 韦晚秋¹, 卢献健^{1,2}, 杨志高¹, 黎振宝¹

(1. 桂林理工大学测绘地理信息学院, 桂林 541004; 2. 广西空间信息与测绘重点实验室, 桂林 541004)

摘要: 在不同时空尺度上快速、准确地估算土壤含水量是水文、环境、地质、农业和气候变化等领域研究的重点内容。目前, 如何准确获取土壤含水量仍然是一项具有挑战性的任务, 过去传统的基于“点”的土壤取样和分析方法费时费力, 利用遥感影像反演土壤含水量具有范围广、时效快、成本低、动态对比性强等优势。其中, 在高光谱遥感中土壤含水量与土壤反射率波长范围有关, 至今已有多种方法被用来描述土壤含水量与高光谱遥感的关系, 综述了现有的基于高光谱反射率估计土壤含水量的方法, 并将其分为4大类: 光谱反射率法、函数法、模型法和机器学习法。通过比较分析了不同方法在精度、复杂性、辅助数据要求、不同模式下的可操作性以及对土壤类型的依赖性等方面潜力和局限性, 并对未来土壤含水量-高光谱反射率方面的研究提出了相应建议。

关键词: 高光谱; 漫反射; 反射率; 土壤含水量; 光学遥感

中图法分类号: TP 79 文献标志码: A 文章编号: 2097-034X(2022)02-0001-09

0 引言

了解不同时空尺度上的土壤含水量 θ 对于监测和模拟水文过程、植物生长、气候变化、土壤侵蚀、土地退化和荒漠化是十分重要的^[1]。传统上, 土壤含水量是直接用称重法估计的^[2]。该方法虽然最准确, 但需要大量的人力进行采样和测量, 且样品本身也会遭到破坏, 使得测量结果无法重现。其他需要采样取点测量的间接方法包括张量计、时域反射计、中子仪探针、电容传感器和伽马射线扫描仪等^[3-6], 这些方法存在时空异质性, 不适合在不同时空尺度下表征土壤含水量。

随着遥感技术的广泛应用, 微波、热红外和光学遥感估算土壤含水量的潜力也被大家所认可^[7-8]。在微波遥感($5\sim1000\text{ mm}$)估算土壤含水量与波长后向散射系数有关, 其在大范围的应用中效果明显, 但是不足之处是它的空间分辨率较低, 不适用于小尺度以及野外测量; 对于热红外遥感($3.5\sim14\mu\text{m}$)监测反演土壤含水量, 一般来说, 当与能够提供植被指数的光学传感器协同使用时, 其估算精度较

高^[9], 但反演计算过程中涉及多种复杂的导数, 反演解算过程较为繁琐, 研究小范围的土壤含水量情况下不推荐使用该方法, 更推荐在大面积情况下使用; 高光谱分辨率的光学遥感($400\sim2500\text{ nm}$), 通常称为高光谱遥感(hyperspectral remote sensing, HRS), 由于土壤含水量 θ 与土壤的高光谱反射率 R 之间的相关性较大, 将其与地面、机载和高空气传感系统结合使用, 可以在不同时空尺度上估算出土壤含水量。因此, HRS 被认为是解决上述估计土壤含水量 θ 存在空间分辨率低、适用范围小等问题上最有前途的遥感技术之一。

1 土壤含水量与光谱反射率关系

图 1 反映的是土壤反射率随波长的变化关系。从图 1 可看出不同波长所对应土壤的反射率不尽相同, 在 1450 nm 和 1900 nm 波长附近土壤反射率较低, 出现了明显的波谷, 在 1300 nm 和 1700 nm 波长附近土壤反射率达到了一个较高值, 出现了较为明显的波峰, 因此可以根据这几个波长范围与土壤反射率之间的相互关系来估算出土壤含水量。作为

收稿日期: 2021-04-23; 修订日期: 2021-11-16

基金项目: 广西空间信息与测绘重点实验室开放基金项目“广西地区农业干旱遥感监测及预警方法研究”(编号:桂科能19-050-11-23)、广西自然科学基金项目“基于高分影像的喀斯特地区土壤水分反演关键问题研究”(编号:2022GXNSFBA035639)和国家自然科学基金项目“地基和星载GNSS-R融合的花岗岩滑坡高时空分辨率土壤湿度反演研究”(编号:42064003)共同资助。

第一作者: 晏红波(1983-), 女, 博士, 副教授, 主要从事遥感数据处理及其应用的研究。Email: 56403075@qq.com。

通信作者: 卢献健(1982-), 男, 硕士, 副教授, 主要从事3S技术数据处理及应用。Email: 285922956@qq.com。

HRS 应用于估计土壤含水量的一个步骤,一些实验室研究使用近距离高光谱传感器(通常也称为漫反射光谱)来研究不同 θ 下 R 的变化^[10]。一般来说,增加 R 会产生 2 个显著的影响:一是整体 R 的非线性程度降低使得其对湿度较为敏感的波段的吸收增加;二是非线性 R 随 θ 的增大而增大,其原因是土壤-水-空气界面的反射指数减小^[11],从而降低了入射光的散射和由于水-空气界面上的附加反射而引起的散射光的深度传播^[12],这种关系在电磁光谱的短波红外波段(1 400~2 500 nm)比可见光(400~700 nm)和近红外波段(700~400 nm)区域更为显著^[13]。另一方面,在湿度敏感波长(吸水特性)下的吸收增加主要出现在波长为 900 nm,1 400 nm 和 1 900 nm 附近^[14],是由于水中羟基(O-H)键特别的组合,但是在 1 400 nm 和 1 900 nm 附近,土壤的吸水特性被大气吸收所掩盖^[15],因此,除了近距离的高光谱传感器外,其他仪器则无法对其进行测量。

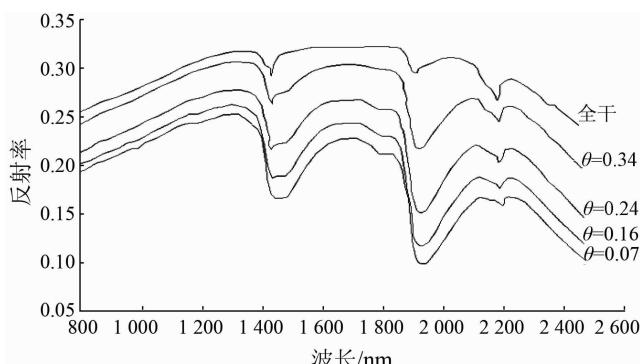


图 1 θ - R 的变化关系^[10]

Fig. 1 Variation of θ - R

HRS 方法的主要先决条件是建立 θ - R 模型,该模型可用于从新样本的 R 估计 θ 。但是,开发具有合理精度的 θ - R 模型仍然是一项艰巨的任务,因为 R 不仅取决于 θ ,而且还受土壤的颜色、结构、矿物成分、有机质含量、粒度分布、表面粗糙度、干燥度以及测量条件的影响^[16-19]。近几十年来,已有许多学者结合模型法对 θ - R 关系进行了研究,Bablett 等^[20]基于 MARMIT(土壤反射多层辐射传输模型),将土壤反射光谱与土壤含水量以及水膜厚度建立联系,反演得出更高精度的土壤含水量;Gao 等^[21]测量了来自江苏省东台东北部潮滩的土壤样品的多角度反射率后基于粒子群优化算法,利用土壤光谱双向反射模型测出土壤表面的光谱特征,并通过引入土壤的等效水膜厚度来反演出更高精度的土壤含水量。虽然许多结合模型的 θ - R 研究方法都获得不错的结果,但大多数使用的都是经验模型,而不同的条件下使用经验模型也会产生许多不同的情况,还不能达到稳定的效果。因此,本文对现有的推导 θ -

R 关系的方法进行了综述,并对它们的潜力和局限性进行了分析。

本文将建立 θ - R 关系的方法分为以下 4 类:光谱反射率法(I类)、函数法(II类)、模型法(III类)和机器学习法(IV类)。图 2 描述了现有 θ - R 关系的不同分类方法。

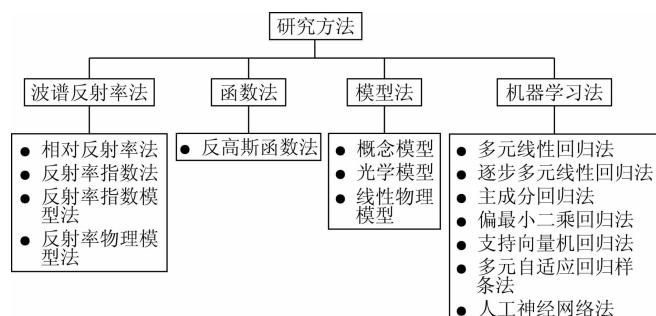


图 2 θ - R 关系的不同分类方法

Fig. 2 Different classification methods of θ - R relationships

1.1 波谱反射率法

1.1.1 相对反射率法

刘伟东等^[22]证明了简单线性和非线性函数估算土壤含水量的效用,并描述了土壤在每个波段的反射率 R 与相对反射率 R^* (在非干燥条件下)之间的关系,公式为:

$$\theta = a_0 R^* + b_0 , \quad (1)$$

$$\theta = d_0 \lg(R^* + e_0) + c_0 , \quad (2)$$

式中 a_0, b_0, c_0, d_0 和 e_0 为辅助参数。在低于临界水平的低湿度条件下,即在干燥条件下($\theta=0$), $R^*=1$ 时,上述方程可修改为:

$$\theta = a_0(1 - R^*) , \quad (3)$$

$$\theta = d_0 \lg \frac{(R^* + e_0)}{(1 + e_0)} . \quad (4)$$

1.1.2 反射率指数法

一般来说,光谱反射率指数表示 2 个或 2 个以上波长的光谱反射率值的组合^[22],可以是特定波长下光谱反射率的值(spectral index, SI)或它们变量的比值指数(ratio index, RI)、差分指数(difference index, DI)、导数(derivative, Der)和归一化指数(normalized difference index, NDI),通过一系列简单快速的计算,就可增强并获取相应目标土壤含水量的光谱特征,十分方便。公式分别为:

$$\theta = a(\lambda_i, \lambda_{i+1}) + b(\lambda_i, \lambda_{i+1}) SI , \quad (5)$$

$$RI(\lambda_i, \lambda_j) = \frac{R(\lambda_i)}{R(\lambda_j)} , \quad (6)$$

$$DI(\lambda_i, \lambda_j) = R(\lambda_i) - R(\lambda_j) , \quad (7)$$

$$Der = \frac{R(\lambda_{i+1}) - R(\lambda_i)}{\lambda_{i+1} - \lambda_i} , \quad (8)$$

$$NDI = \frac{R(\lambda_j) - R(\lambda_i)}{R(\lambda_j) + R(\lambda_i)} , \quad (9)$$

式中: λ_i 和 λ_{i+1} 为 2 个连续的波长; λ_j 为与 λ_i 不连续的波长; a 和 b 为辅助参数。在这类方法中, 式(5)表示的是特定波长下光谱反射率的值; 式(6)表示的是比值指数法, 即 2 个离散波长的反射率比值, 如基于 1 300 nm 和 1 450 nm 波长的土壤含水量指数法(WISOIL); 式(7)表示的差分指数法和式(8)的导数法均由刘伟东等^[22]提出, 2 种方法都尽量减少其他混杂因素的影响, 以提高 R 对 θ 的敏感性, 导数法近似于 2 个连续波长之间的有限差分而不是算术差分, 当在计算中使用连续波长, 即当 $\lambda_{i+1} = \lambda_j$ 时, 差分指数法和导数法则会产生相同的结果; 式(9)所示的归一化指数法是 2 个特定波长下的差值与反射率值之和的比值, 如基于 1 800 nm 和 2 119 nm 波长的归一化土壤含水量指数^[1]就属于归一化指数法。

刘伟东等^[22]比较了相对反射率法、导数法和差分法估算土壤含水量的性能, 得出一阶导数法估算土壤含水量优于其他方法的结论。最近, Tian 等^[23]建立了基于辐射传输的模型支持下的短波归一化指数(shortwave normalization index, SNI)用于土壤含水量估算, 经验证, 在土壤干燥阶段过程中, SNI 指数所使用的分割方法显著提高了土壤含水量估计精度; Yue 等^[24]通过使用短波红外波段的不同吸水率特性, 评估了 3 种标准化短波红外差异裸土水分指数(normalized shortwave – infrared difference soil moisture indices, NSDSI)估算裸土的含水量, 得到 2 个短波红外波段比单一短波红外波段对裸土湿度估计更准确的结论; 另外, Fabre 等^[25]提出另外 2 个新的归一化指数, 即使用近红外和短波红外波段从线性和非线性角度估算土壤含水量, 线性回归法使用的是 2 076 nm 和 2 230 nm 的波长($R^2 = 0.87$; $RMSE = 4.4$), 而非线性回归法是基于 2 122 nm 和 2 230 nm 的波长($R^2 = 0.74 \sim 0.85$; $RMSE = 4.8 \sim 6.2$), 经过比较得出非线性回归法估算土壤含水量的结果要优于其他方法的结论。

1.1.3 反射率指数模型法

Lobell 等^[26]提出的物理模型解释了湿润状态下 θ 与 R 之间的关系, 公式为:

$$R = R_{\text{sat}} + (R_{\text{dry}} - R_{\text{sat}}) \exp(-c\theta) , \quad (10)$$

式中: R_{sat} 和 R_{dry} 分别为水分饱和与干燥土壤状态下的土壤光谱反射率; c 为 R 随 θ 的变化率。

除 θ 外, 模型中的所有参数均与波长有关, 还尝试将 R 表示为分数形式, 用饱和曲线 S 代替 θ , f 为反射辐射表面积百分比, 从而简化了不同土壤状态下的反射率模型, 饱和曲线 S 的公式为:

$$S = -\ln\left[\frac{R - fR_{\text{dry}}}{(1 - f)R_{\text{dry}}}\right] \frac{1}{c} . \quad (11)$$

1.1.4 反射率物理模型法

van Genuchten^[27]提出描述基本电位 h 与 θ 关系的一种常用经验模型; Nolet 等^[28]在此基础上提出了用 R 代替模型中基本电位 h 的方法来描述 $\theta - R$ 之间的关系。公式为:

$$\theta = \theta_r + \frac{\theta_s - \theta_r}{[1 + (mR)^n]^{1-\frac{1}{n}}} , \quad (12)$$

式中: θ_s 和 θ_r 分别为残余含水量与饱和含水量; m 和 n 为辅助参数。

1.2 函数法

Whiting 等^[29]将反高斯函数 $g(\lambda)$ 与土壤光谱反射面相结合来估算土壤含水量, 其反射面积 A 和振幅 Z 的参数与 θ 相关联。当使用短波红外波长进行计算时, 辅助参数与反射面积 A 高度相关, 2 800 nm 左右的波长范围对其影响较大。 $g(\lambda)$, A 和 Z 的计算公式分别为:

$$g(\lambda) = R_{\lambda i} + (R_{\lambda 0} - R_{\lambda i}) \exp\left[-\frac{-(\lambda_i - \lambda_0)^2}{2\sigma^2}\right] , \quad (13)$$

$$A = Z\sigma \sqrt{\frac{\pi}{2} \operatorname{erf}\left[\frac{-(\lambda_0 - \lambda_i)^2}{\sqrt{2}\sigma^2}\right]} , \quad (14)$$

$$Z = R_{\lambda 0} - R_{\lambda i} , \quad (15)$$

式中: λ_0 和 λ_i 分别为光谱反射面中心和拐点处的波长; σ 为从光谱反射面区域中心到拐点的距离; $\operatorname{erf}(\cdot)$ 为误差函数。

1.3 模型法

1.3.1 概念模型

Philpot^[30]提出了一个类似于 Lobell 等^[10]的简单模型来描述光谱反射率, 包括水面的菲涅耳反射率 R_w 、土壤颗粒的反射率 R_s 、液态水的吸收系数 a_w 和光通过孔隙仪的日平均光程 d , 公式为:

$$R = f_w R_w + (1 - f_w) R_s \exp(da_w) , \quad (16)$$

式中 f_w 为水面反射辐射的表面积分数百分比。近红外波长范围的吸收系数值 a_w 可以从 Segelstein^[31] 和 Kou 等^[32]的研究中获得。

1.3.2 光学模型

Nolet 等^[33]针对小面积湿润土壤反映出来的土壤反射率的变化很小,因而忽略了该部分造成的影响,并提出了一个基于兰伯特定律的针对沿海海滩砂砾进行分析的简单指数模型,公式为:

$$R = \beta R_s \exp(-da_w), \quad (17)$$

式中 β 为湿润的海滩砂砾发生散射造成光谱反射率降低的影响因子。

1.3.3 线性物理模型

Sadeghi 等^[34]提出了一个简单的线性物理模型,该模型将土壤反射率即吸收与散射系数之比转换为干燥与饱和状态下土壤反射率的比值,公式为:

$$\frac{\theta}{\theta_s} = \frac{\omega(R - R_{dry})}{R_{sat} - R + \omega(R - R_{dry})}, \quad (18)$$

式中 ω 为干燥和饱和条件下土壤的散射系数之比。

1.4 机器学习法

深度学习法包括几种统计和机器学习方法,即多元线性回归法(multiple linear regression, MLR)、逐步多元线性回归法(stepwise multiple linear regression, SMLR)、主成分回归法(principal component regression, PCR)、偏最小二乘回归法(partial least squares regression, PLSR),支持向量机回归法(support vector machine regression, SVMR)、多元自适应回归样条法(multiple adaptive regression spline, MARS)和人工神经网络法(artificial neural network, ANN)。

Dalal 等^[35]使用 MLR 建立 $\theta - R$ 之间的关系,而王涛等^[36]则采用了 SMLR 分析它们之间的关系,但这 2 种方法都存在一个缺点,即只用了某些特征波长点的光谱信息,忽略其他点的信息,从而造成信息丢失,导致模型的过适应性。PCR 方法很好地解决了这个问题^[37],PCR 涉及到数学过程,通过正交变换将多个可能相关的变量转换为多个不相关的变量,这类变换可以通过数据协方差矩阵的特征值分解或数据矩阵的奇异值分解来实现。与 PCR 类似的方法是 PLSR 方法^[38],它们最显著的特点是利用了全部的光谱信息,在 PLSR 中,预测变量和响应变量都被用于建立预测能力最强的分数,PLSR 算法集成了压缩和回归步骤,并选择了连续的正交因子,使预测变量和响应变量之间的协方差最大化,从而提高了预测精度,因此该方法在土壤光谱研究中广受欢迎,并已被广泛用于估算土壤含水量^[39]。

MARS^[40],ANN^[41] 和 SVMR^[42]作为强大的非参数预测工具,其性能也被广泛用于检验线性和非线

性 $\theta - R$ 间的关系。SVMR 是一种基于核的学习方法,将输入数据映射到高维特征空间,在 SVMR 中,训练数据被用来获得一个损失函数,根据训练数据的最大偏差映射输入数据,利用损失函数作为与实际值“差距”的度量,对大于损失函数的误差进行剔除,以获得较低复杂度的训练数据子集,从而提高估算精度。尚天浩等^[43]对盐渍地区土壤原始光谱反射率进行多种数学变换,运用逐步回归(stepwise regression, SR)和灰色关联度(grey correlation degree, GCD)筛选敏感波段,比较 MLR, PLSR 和 SVMR 这 3 种方法模拟土壤含水量的精度情况,得出 SVM 模型为供试土壤含水量拟合的最佳模型,能够准确获取重度盐渍化研究区土壤含水量状况的结论;吴士文等^[44]也对比分析不同光谱预处理方法与 PLSR, SVMR 建模方法两两组合条件下对土壤含水量的精度预测,结果表明,同一光谱预处理方法的 SVMR 模型预测精度均高于 PLSR 模型,因此也间接表明了 SVMR 法在某些方面优于一般的线性回归统计学习方法。

MARS^[45]是一种非参数回归技术,它利用基函数自动建立预测-响应联系(即不需要任何假设)。为了开发基函数,输入数据空间被细分为具有特定回归模型(分段线性回归)的区域或样条曲线。在进行分段线性回归时,允许回归模型的斜率沿预测轴改变 n 个节点,将由线性和非线性组合以及二阶和三阶变量因子组成的基函数,作为新的预测变量用于建模,通过一个严格的前向和后向逐步查找过程,找到一个具有最佳节点数和基函数的模型。正向逐步法通过增加基函数来构造一个过拟合模型,而反向逐步消除法消除了对模型精度贡献不足的函数,相比于线性回归模型,MARS 模型更加灵活。

ANN^[46]是一种用于模拟“输入-输出”联系的技术。它由各种相互关联的计算单元(节点或人工神经元)组成,可分为学习和优化 2 个阶段。在学习阶段,人工神经元则聚合成隐藏层,这些层能够对输入进行不同的转换,然后通过调整人工神经元相互影响的“权重”及其相互关系结构来表征系统行为的输入-输出关系;在优化阶段,ANN 通过对已知信息的反复学习训练,并逐步调整改变节点权重,达到处理信息、模拟输入输出信息的目的。

2 土壤含水量估测方法的潜力与局限性

为了简要讨论通过 R 来估计 θ 的不同方法在精度、复杂性、辅助数据要求、不同遥感模式下的可操作性以及对土壤类型的依赖性等方面潜力和局限

性,对描述 $\theta - R$ 关系的不同方法的性能进行了对比,结果如表 1 所示。这些方法是根据土壤的相关漫反射光谱研究所得出的,尽管比较这些研究的结果是不太合理的,因为它们是在不同的土壤和测量条件进行的,但通过比较可以大致了解各类方法下

$\theta - R$ 之间的相关性以及不同方法的优缺点。未来的研究应该尽可能在保证处于相同的基础条件下对不同方法进行定量比较,使结果更为合理恰当,从而进行更有意义的评估。

表 1 利用高光谱特征估计土壤含水量的不同方法性能比较

Tab. 1 Comparison of different methods for estimating soil water content using hyperspectral characteristics

类别	方法	波长/nm	N ^①	R ^{2②}	RMSE ^③	代表性文献	优点	缺点
波谱反射率法	反射率差分指数法	2 062, 2 250	18	0.69	0.08	Haubrock 等 ^[1]	土壤类型影响小	计算相对复杂
	反射率指数模型法	350 ~ 2 500	4	-	-	Lobell 等 ^[10]	短波红外范围应用良好	不适用土壤体积含水量低于 20% 的情况
	反射率比值指数法	1 944	18	0.68	0.08	刘伟东等 ^[13]	计算方便快速	依赖干燥土壤光谱信息
	反射率一阶导数法	1 834, 1 836	18	0.63	0.08	刘伟东等 ^[13]	无需先验土壤信息	产生冗余的光谱信息
	相对反射率法	1 998	10	0.84	0.04	刘伟东 ^[15]	计算简单快速	不适用于野外
函数法	反射率物理模型法	350 ~ 2 100	1	>0.99	-	van Genuchten ^[27]	考虑到土壤的物理特性	需获取特定初始信息, 应用具有局限性
	反高斯函数法	1 200 ~ 2 500	257	0.92	0.03	Whiting 等 ^[29]	可以结合各类高光谱模式使用	难以确定输入信息, 需对光谱进行额外处理
模型法	光学模型法	350 ~ 2 100	1	>0.97	-	Haubrock 等 ^[1]	无需考虑高光谱反射率	应用具有局限性
机器学习法	SMLR	1 623 ~ 2 467	1 571	0.88	5.19	申艳等 ^[38]	减少变量间的共线性问题	信息易丢失, 导致模型的过适应性
	PCR	400 ~ 2 498	802	0.84	0.005	申艳等 ^[38]	应用全部的光谱信息	计算繁琐
		401 ~ 1 699	360	0.97	0.02	Svante 等 ^[40]		
	PLSR	830 ~ 2 630	403	0.96	0.60	李晓明 ^[39]	应用全部的光谱信息	无法解释土壤光谱间的非线性效应
		370 ~ 1 979	1 160	0.66	0.76	Svante 等 ^[40]		
机器学习法	ANN	420 ~ 800	-	0.77	2.00	Leila 等 ^[45]	自动学习分析, 无需基础辅助参数	容易过度拟合
	SVMR	370 ~ 1 979	1 160	0.69	0.72	Vapnik 等 ^[46]	无需基础辅助参数	仅适用于密集型计算
	MLR	450 ~ 2 500	40	0.68 ~ 0.96	-	贾学勤等 ^[47]	不受土壤类型影响	忽略某些点的光谱信息
	MARS	370 ~ 1 979	1 160	0.73	0.67	Friedman ^[48]	自动建立联系, 无需基础辅助参数	过程繁琐

①N 为土壤样例数; ②R² 为相关系数; ③RMSE 为均方根误差。

表 1 中相对反射率法考虑了不同土壤类型、粗糙度和结构的具体特征,虽然它是经验性的,但在 1944 年主要验证光谱反射率波长的实验室条件下,该方法是有效的,但却不适用于野外条件,因为野外条件下土壤的反射率被大气吸收所掩盖,此外,该方法还依赖于每种土壤在干燥条件下的光谱反射率信息,如在土壤样品干燥时,光谱反射率会随方向相位角变化而变化^[49],但由于空间和时间上的异质性使得干土光谱反射率信息难以获取,因此该方法也难以实现。差分和导数法使用多个波段进行计算,土壤类型对其产生的影响较小,土壤总反照率的损失也降低了,更有利于波段组合计算,因此差分和导数法相对更为稳定。在导数法中,样品光谱在不同波长处的反射率值可以相互关联,因此不需要先验的土壤信息,且该方法不需要考虑水蒸气吸收波长的影响,因此能够与野外、机载和星载测量方法结合使用。然而,由于使用具有强相关性的连续波段,导数法会带来冗余的光谱信息,相比之下,差分法可以使

用相关性较小且光谱分离程度较低的具有独立信息的波段进行计算。指数模型最适合用短波红外波段的光谱反射率来估算土壤质量 θ_m 或体积含水量 θ_v ,它们与可见光和近红外波段结合使用可能不适合于土壤体积含水量低于 20% 的情况,且其受不同土壤类型的影响,而为了减少土壤类型的影响,目前的指数模型已发展为使用土壤饱和含水量来代替土壤质量含水量 θ_m 或体积含水量 θ_v 来计算; 土壤物理模型则需要残余含水量 θ_r 和饱和含水量 θ_s 作为初始信息输入,但其应用只局限于 $\theta_r - \theta_s$ 范围内。

反高斯函数法是通过近红外和短波红外区域 1.2 ~ 2.5 μm 的反射率下降来估计水分含量,基本吸水率在 2.8 μm 处的扩散,对其影响较少,因此,该方法可与所有高光谱反射率测量模式结合使用。但是,它需要对光谱进行额外的预处理,以削弱短波红外区域的噪声,同时其面临难以确定的输入信息^[50]。Philpot^[30] 所证明的简单的概念模型在实验研究中被发现是成功的,可以解释 4 种土壤类型的

$\theta - R$ 关系,但是这种模式是“肤浅”的,不足以令人信服。

光学模型法是一种简单的概念模型,无需考虑高光谱反射率,在土壤体积含水量的估算方面表现良好。线性物理模型简单、准确(尤其是在短波红外波段),不受限于单个波长,并且只需要少次的校准,因此,它被认为是一种最有前途的估计土壤含水量的方法,但是该模型仍需要在干燥和饱和土壤条件下测量的高光谱反射率进行校准,这也是该模型的难点之一。

尽管与其他方法相比,机器学习方法在计算上比较复杂,但在光学领域它们能够较好地证明 $\theta - R$ 之间的关系,并且无需考虑土壤类型。由于 MLR 中的预测变量必须是不相关的,不适合处理与高光谱反射率相关的多个共线光谱变量; PCR 和 PLSR 方法都是通过正交变换来解决多共线问题的经典方法,但 PCR 只考虑了光谱信息,而 PLSR 方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,经过这样的信息筛选,排除了对因变量无解释作用的噪声,不仅提高了其计算效率,使得计算结果更可靠^[51-52]。但这 2 种经典的方法无法解释土壤光谱和属性之间的非线性效应(由于土壤的光谱复杂性),特别是在大型土壤光谱数据库中,在这种情况下,可以选择 SVMR, MARS 和 ANN 等替代技术来开发性能更好的高光谱反射率模型,SVMR 方法解释了模型开发时过度拟合的原因^[53],并由此产生了一个处理高维光谱变量的高效全球模型^[54],然而,这种模型的识别是计算密集型的,因为它涉及 2 次规划和非线性方程组的求解^[55]。MARS 是一种非参数方法,更像是线性回归的一种扩展,它将高光谱反射率简单地转换为图像像素,因此,它被认为比经典的线性回归模型更灵活、更准确^[56]。ANN 模型相比其他方法拥有更好的性能,但是它容易过度拟合,并且结果过于依赖于初始化参数,因而不可避免地含有误差而无法保证对土壤含水量进行预测时有较高的精度^[57]。

3 结论及展望

根据不同土壤光谱反射率与土壤含水量之间的关系,本文将 $\theta - R$ 研究方法分成 4 类,并从精度、复杂性、辅助数据要求、不同遥感模式下的可操作性以及对土壤类型的依赖性等方面分析了它们的潜力和局限性。大多数方法在试验区范围内能有效证明 $\theta - R$

之间的关系,但方法的迁移性和扩展性还需要更多的实验验证。其中反射率指数法(除了差分法和导数法)、函数法和模型法在计算上有优势,但它们需要获得先验的土壤信息。在没有土壤信息的情况下,需要通过使用全部光谱反射率来估算土壤含水量,此时机器学习法更具优势,但是也取决于机器学习法在数据建模中使用的光谱数量的多少,数量过多则会影响计算效率。

针对以上存在的问题,笔者建议从以下几个方面进行改进或深入研究:①使用高信噪比的改良仪器更好地测量土壤含水量(以减少大气变量的影响);②改进对光谱反射率的预处理方法;③增加简约模型对光谱变量的选择;④新物理模型和机器学习算法的实现;⑤物理模型(理论驱动)和机器学习算法(数据驱动)相结合以消除与土壤含水量不相关的光谱信息和冗余信息。

目前,所有现有的方法本质上都是通过经验模型反映得出 $\theta - R$ 关系,很少涉及不同土壤类型之间的联系变化。本文中大多基于漫反射光谱的土壤含水量研究方法也都是在温带土壤状态下进行的,温带土壤有机质的分解率较低,黏土矿物的比例大致为 2:1。在热带和亚热带土壤中建立 $\theta - R$ 关系的研究非常有限,因为在此条件下,土壤有机质分解较强,黏土矿物的比例基本为 1:1,黏土矿物比例不占优势,而由于土壤有机质和黏土矿物具有光谱活性,它们显著地影响光谱反射率,因此在温带土壤中推导的 $\theta - R$ 关系在热带和亚热带土壤应用中可能失效。目前国内针对 $\theta - R$ 关系的土壤特性的研究相对较少,需要更进一步的研究。因此,未来对于 $\theta - R$ 关系的研究可以集中在比较不同方法在不同土壤类型下的应用,如建立不同类型土壤样本的公共光谱库等,以便更好地进行土壤含水量的估算,从而得到更准确的 $\theta - R$ 关系。

参考文献 (References) :

- [1] Haubrock S N, Chabriat S, Lemnitz C, et al. Surface soil moisture quantification models from reflectance data under field conditions [J]. International Journal of Remote Sensing, 2008, 29(1): 3–29.
- [2] Reynolds S G. The gravimetric method of soil moisture determination Part III: An examination of factors influencing soil moisture variability [J]. Journal of Hydrology, 1970, 3(11): 288–300.
- [3] Ledieu J, Ridder P, Clerck P, et al. A method of measuring soil moisture by time-domain reflectometry [J]. Journal of Hydrology, 1986, 88(3/4): 319–328.
- [4] Chanasyk D S, Naeth M A. Field measurement of soil moisture using neutron probes [J]. Canadian Journal of Soil Science, 1996, 76(3): 317–323.

- [5] Dean T J, Bell J P, Baty J B. Soil moisture measurement by an improved 400 capacitance technique, Part I. Sensor design and performance[J]. *Journal of Hydrology*, 1987, 401(1–2): 67–78.
- [6] Engman E T. Applications of microwave remote sensing of soil moisture for water resources and agriculture[J]. *Remote Sensing of Environment*, 1991, 35(2–3): 213–226.
- [7] Qin Y, Liu X N, Jonathan L, et al. Lithology identification of the north Qilian belt by surface temperature and spectral emissivity information derived from ASTER TIR data[J]. *International Journal of Remote Sensing Applications*, 2013, 3(4): 235–239.
- [8] Wang X, Venugopal G. Optical fiber meta magnetics[J]. *Optics Express*, 2011, 19(21): 19813–19821.
- [9] Sandholt I, Kjeld R, Jens A. A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status[J]. *Remote Sensing of Environment*, 2002, 79(2): 213–224.
- [10] Lobell D B, Asner G P. View angle effects on canopy reflectance and spectral mixture analysis of coniferous forests using AVIRIS[J]. *International Journal of Remote Sensing*, 2002, 23(11): 2247–2262.
- [11] Stevens A, Marco N. Prediction of soil organic carbon at the European scale by visible and near infrared reflectance spectroscopy[J]. *PLoS ONE*, 2013, 8(6): 337–347.
- [12] Dalal R C, Mayer R J. Long term trends in fertility of soils under continuous cultivation and cereal cropping in southern Queensland. II. Total organic carbon and its rate of loss from the soil profile[J]. *Soil Research*, 1986, 24(2): 281–292.
- [13] 刘伟东, Baret F, 张兵, 等. 应用高光谱遥感数据估算土壤表层水分的研究[J]. 遥感学报, 2004, 8(5): 434–442.
Liu W D, Barnet F, Zhang B, et al. Study on the estimation of soil surface water by hyperspectral remote sensing data[J]. *Journal of Remote Sensing*, 2004, 8(5): 434–442.
- [14] Haubrock S N, Chabrilat S. Surface soil moisture quantification models from reflectance data under field conditions[J]. *International Journal of Remote Sensing*, 2008, 29(1): 3–29.
- [15] 刘伟东. 高光谱遥感土壤信息提取与挖掘研究[D]. 北京: 中国科学院研究生院(遥感应用研究所), 2002.
Liu W D. Extraction and mining of soil information from hyperspectral remote sensing[D]. Beijing: Graduate School of Chinese Academy of Sciences, 2002.
- [16] Etienne M, Henri D. Modeling soil moisture – reflectance[J]. *Remote Sensing of Environment*, 2001, 76(2): 173–180.
- [17] Bob S B, Raphael A, Viscarra R, et al. Visible and near infrared spectroscopy in soil science[J]. *Advances in Agronomy*, 2010, 107: 163–215.
- [18] Sarathjith M C, Bhabani S D, et al. Diffuse reflectance spectroscopic approach for the characterization of soil aggregate size distribution[J]. *Soil Science Society of America Journal*, 2014, 78(2): 369–376.
- [19] Tian J, Philpot W D. Relationship between surface soil water content, evaporation rate, and water absorption band depths in SWIR reflectance spectra[J]. *Remote Sensing of Environment*, 2015, 169: 280–289.
- [20] Babet A, Vu P V, Jacquemoud S, et al. MARMIT: A multilayer radiative transfer model of soil reflectance to estimate surface soil moisture content in the solar domain (400–2 500 nm)[J]. *Remote Sensing of Environment*, 2018, 217: 1–17.
- [21] Gao C, Xu M, Xu H Z Y, et al. Retrieving photometric properties and soil moisture content of tidal flats using bidirectional spectral reflectance[J]. *Remote Sensing*, 2021, 13(7): 1402.
- [22] 刘伟东, Baret F, 张兵, 等. 高光谱遥感土壤湿度信息提取研究[J]. 土壤学报, 2004, 5: 700–706.
Liu W D, Baret F, Zhang B, et al. Extraction of soil moisture information from hyperspectral remote sensing[J]. *Acta Pedologica Sinica*, 2004, 5: 700–706.
- [23] Tian J, Yue J B, Philpot W D, et al. Soil moisture content estimate with drying process segmentation using shortwave infrared bands[J]. *Remote Sensing of Environment*, 2021, 263: 112552.
- [24] Yue J B, Tian J, Qing J T, et al. Development of soil moisture indices from differences in water absorption between shortwave – infrared bands[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 154: 216–230.
- [25] Fabre S, Xavier B. Estimation of soil moisture content from the spectral reflectance of bare soils in the 0.4–2.5 mm domain[J]. *Sensors*, 2015, 15: 3262–3281.
- [26] Lobell D B, Gregory P A. Moisture effects on soil reflectance[J]. *Soil Science Society of America Journal*, 2002, 66(3): 722.
- [27] van Genuchten M T. A closed – form equation for predicting the hydraulic conductivity of unsaturated soils[J]. *Soil Science Society of America Journal*, 1980, 44(5): 892–898.
- [28] Nolet C, Ate P, Peter R, et al. Measuring and modeling the effect of surface moisture on the spectral reflectance of coastal beach sand[J]. *PLoS ONE*, 2014, 9(11): 112–151.
- [29] Whiting M L, Lin L, Susan L U. Predicting water content using Gaussian model on soil spectra[J]. *Remote Sensing of Environment*, 2004, 89: 535–552.
- [30] Philpot W D. Spectral reflectance of wetted soils[C]//Proceedings of Art, Science and Applications of Reflectance Spectroscopy (ASARS), 2010: 1–12.
- [31] Segelstein D J. The complex refractive index of water[D]. Kansas: University of Missouri, 1981.
- [32] Kou L H, Daniel L, Petry C R. Indices of water and ice in the 0.65 to 2.5 mm spectral range[J]. *Applied Optics*, 1993, 32(19): 3531–3540.
- [33] Nolet C, Poortinga A, Roosjen P, et al. Measuring and modeling the effect of surface moisture on the spectral reflectance of coastal beach sand[J]. *PLoS ONE*, 2014, 9(11): 112–151.
- [34] Sadeghi M, Jones S B, Philpot W D. A linear physically – based model for remote sensing of soil moisture using short wave infrared bands[J]. *Remote Sensing of Environment*, 2015, 164: 66–76.
- [35] Dalal R C, Henry R J. Simultaneous determination of moisture, organic carbon, and total nitrogen by near infrared reflectance spectrophotometry[J]. *Soil Science Society of America Journal*, 1986, 50(1): 120–123.
- [36] 王涛, 喻彩丽, 姚娜, 等. MLR 和 PLSR 的沙壤土盐分含量光谱检测对比研究[J]. 干旱区地理, 2018, 41(6): 1295–1302.
Wang T, Yu C L, Yao N, et al. Comparative study on spectral detection of salt content in sandy loam soil by MLR and PLSR[J]. *Arid Land Geography*, 2018, 41(6): 1295–1302.
- [37] Chang C W, David H. Near – infrared reflectance spectroscopy –

- principal components regression analyses of soil properties [J]. Soil Science Society of America Journal, 2001, 65(2): 480–490.
- [38] 申艳, 张晓平, 梁爱珍, 等. 近红外光谱法在土壤有机质研究中的应用 [J]. 核农学报, 2010, 24(1): 199–207.
- Shen Y, Zhang X P, Liang A Z, et al. Application of near infrared spectroscopy in soil organic matter research [J]. Acta Nucifera Sinica, 2010, 24(1): 199–207.
- [39] 李晓明. 基于 PLSR 的土壤水分光谱特征研究 [J]. 西部大开发 (土地开发工程研究), 2017, 2(9): 49–54.
- Li X M. Spectral characteristics of soil moisture based on PLSR [J]. Western Development (Land Development Engineering), 2017, 2(9): 49–54.
- [40] Svante W, Michael S, Lennart E. PLS – regression: A basic tool of chemometrics [J]. Chemometrics and Intelligent Laboratory Systems, 2001, 58(2): 109–130.
- [41] Mouazen A M, Karoui R. Potential of visible and near – infrared spectroscopy to derive colour groups utilising the munsell soil colour charts [J]. Biosystems Engineering, 2007, 97(2): 131–141.
- [42] Nawar S, Mouazen A M. Comparison between random forests, artificial neural networks and gradient boosted machines methods of on – line VIS – NIR spectroscopy measurements of soil total nitrogen and total carbon [J]. Sensors, 2017, 17(10): 2428.
- [43] 尚天浩, 贾萍萍, 孙媛, 等. 宁夏银北地区盐碱化土壤水分光谱特征及模型拟合精度分析 [J]. 水土保持通报, 2020, 40(4): 183–189.
- Shang T H, Jia P P, Sun Y, et al. Spectral characteristics and model fitting accuracy of saline alkali soil water in Yinbei area of Ningxia [J]. Bulletin of Soil and Water Conservation, 2020, 40(4): 183–189.
- [44] 吴士文, 王昌昆, 刘娅, 等. 高光谱成像的土壤剖面水分含量反演及制图 [J]. 光谱学与光谱分析, 2019, 39(9): 2847–2854.
- Wu S W, Wang C K, Liu Y, et al. Retrieval and mapping of soil moisture content in hyperspectral imaging [J]. Spectroscopy and Spectral Analysis, 2019, 39(9): 2847–2854.
- [45] Leila H E, Alfonso T R. Assessment of surface soil moisture using high – resolution multi – spectral imagery and artificial neural networks [J]. Remote Sensing, 2015, 7(3): 2627–2646.
- [46] Vapnik V, Chapelle O. Bounds on error expectation for support vector machines [J]. Neural Computation, 2000, 12(9): 2013–2036.
- [47] 贾学勤, 冯美臣, 杨武德, 等. 基于 SPA – MLR 方法的土壤含水量光谱预测模型研究 [J]. 干旱地区农业研究, 2018, 36(3): 266–269, 291.
- Jia X Q, Feng M C, Yang W D, et al. Study on spectral prediction model of soil water content based on SPA – MLR method [J]. Agricultural Research in Arid Areas, 2018, 36(3): 266–269, 291.
- [48] Friedman J H. Multivariate adaptive regression splines [J]. The Annals of Statistics, 1991, 19(1): 1–67.
- [49] Kúrková V. Kolmogorov's theorem and multilayer neural networks [J]. Neural Networks, 1992, 5(3): 501–506.
- [50] Sarathjith M C, Bhabani S D, Hitesh B V, et al. Diffuse reflectance spectroscopic approach for the characterization of soil aggregate size distribution [J]. Soil Science Society of America Journal, 2014, 78(2): 369–376.
- [51] 翁永玲, 戚浩平, 方洪宾, 等. 基 PLSR 方法的青海茶卡—共和盆地土壤盐分高光谱遥感反演 [J]. 土壤学报, 2010, 47(6): 1255–1263.
- Weng Y L, Qi H P, Fang H B, et al. Hyperspectral remote sensing inversion of soil salinity in Chaka Gonghe basin of Qinghai Province based on PLSR method [J]. Acta Pedologica Sinica, 2010, 47(6): 1255–1263.
- [52] 朱亚星, 周桢津, 洪永胜, 等. 植物光谱数据估算土壤含水率的方法 [J]. 华中师范大学学报 (自然科学版), 2017, 51(1): 123–129.
- Zhu Y X, Zhou Z J, Hong Y S, et al. Method for estimating soil moisture content by coupling hyperspectral data [J]. Journal of Central China Normal University (Natural Science Edition), 2017, 51(1): 123–129.
- [53] Kaingo J, Nganga I K. Prediction of soil moisture – holding capacity with support vector machines in dry subhumid tropics [J]. Applied and Environmental Soil Science, 2018: 1–10.
- [54] Balabin R M, Ekaterina I L. Support vector machine regression (SVR/LS – SVM) – an alternative to neural networks (ANN) for analytical chemistry? Comparison of nonlinear methods on near infrared (NIR) spectroscopy data [J]. Analyst, 2011, 136: 1703–1712.
- [55] Thissen U, Bünt U, Willem J M, et al. Multivariate calibration with least – squares support vector machines [J]. Analytical Chemistry, 2004, 76(11): 3099–3105.
- [56] Nawar S, Abdul M M. Predictive performance of mobile VIS – NIR infrared spectroscopy for key soil properties at different geographical scales by using spiking and data mining techniques [J]. Catena, 2017, 151: 118–129.
- [57] 胡振琪, 张学礼. 基于 ANN 的复垦土壤水分特征曲线的预测研究 [J]. 农业工程学报, 2008(10): 15–19.
- Hu Z Q, Zhang X L. Prediction of reclaimed soil water characteristic curve based on ANN [J]. Journal of Agricultural Engineering, 2008(10): 15–19.

A review of remote sensing inversion methods for estimating soil water content based on hyperspectral characteristics

YAN Hongbo^{1,2}, WEI Wanqiu¹, LU Xianjian^{1,2}, YANG Zhigao¹, LI Zhenbao¹

(1. College of Geomatics and Geoinformation, Guilin University of Technology, Guilin 541004, China;
2. Guangxi Laboratory of Spatial Information and Mapping, Guilin 541004, China)

Abstract: The rapid and accurate estimation of soil water content at different spatial and temporal scales is key

research content in the fields of hydrology, environment, geology, agriculture, and climate change. However, it is still a challenge to obtain accurate soil water content presently. In the past, the traditional point – based soil sampling and analysis methods were time – consuming and laborious. By contrast, retrieving soil water content using remote sensing images has the advantages of a wide range, high timeliness, low cost, and strong dynamic contrast. In hyperspectral remote sensing, soil water content is related to the wavelength range of soil reflectance. So far, many methods have been used to describe the relationships between soil water content and hyperspectral remote sensing. This paper summarized existing methods for estimating soil water content based on hyperspectral reflectance and divided them into four categories: spectral reflectance methods, function methods, model methods, and machine learning methods. Moreover, this paper compared and analyzed the potential and limitations of different methods in terms of accuracy, complexity, auxiliary data requirements, operability under different modes, and the dependence on soil types. Finally, this study put forward corresponding suggestions for future research on the relationships between soil water content and hyperspectral reflectance.

Keywords: hyperspectral; diffuse reflectance; reflectance; soil water content; optical remote sensing

(责任编辑:陈理)

=====

下期要目

- | | |
|-----|-----------------------------------|
| 孙 肖 | 基于优化 K – P – Means 解混方法的高光谱图像矿物识别 |
| 王春霞 | 复杂环境下 GF – 2 影像水体指数的构建及验证 |
| 唐文魁 | 基于长时间序列遥感数据的深圳景观连通性动态变化研究 |
| 田义超 | 机载 LiDAR 在红树林林分平均高估算中的应用 |
| 董双发 | 基于 Landsat – 8 和无人机的福清核电温排水分布研究 |
| 鄢俊洁 | 基于朴素贝叶斯方法的 FY4A/AGRI 云检测模型 |
| 张 淑 | 多时相 SAR 的喀斯特山区耕地表层土壤水分反演 |
| 高俊华 | 基于遥感动态监测的吉林省矿山地质环境及生态修复变化特征分析 |
| 朱思佳 | 近 20 年洞庭湖流域植被 NPP 时空特征 及驱动因素分析 |
| 王泽坤 | 雪深和雪水当量被动微波反演及应用进展 |

