

# 分数阶微分技术在机载高光谱数据估算土壤含水量中的应用

王瑾杰<sup>1, 2, 3, 4, 5</sup>, 丁建丽<sup>1, 4, 5\*</sup>, 葛翔宇<sup>1, 4, 5</sup>, 张 喆<sup>1, 4, 5</sup>, 韩礼敬<sup>1, 4, 5</sup>

1. 新疆大学地理与遥感科学学院, 新疆 乌鲁木齐 830017
2. 北京师范大学防沙治沙教育部工程研究中心, 北京 100875
3. 中国科学院数字地球重点实验室, 北京 100094
4. 新疆大学新疆绿洲生态自治区重点实验室, 新疆 乌鲁木齐 830017
5. 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, 新疆 乌鲁木齐 830017

**摘要** 无人机高光谱遥感为精准农业和农业信息化监测提供崭新视角。高光谱传感器具有厘米级空间分辨率和精细的光谱分辨率, 可获取高质量的高光谱数据。然而, 高光谱数据通常伴随噪声和数据冗余, 高光谱信息利用效率低, 常规预处理难以满足精准估算的需求。因此, 为解决上述现实问题, 针对机载高光谱影像的数据挖掘必不可少。利用分数阶微分(FOD)技术逐像元处理机载高光谱数据(步长为0.1)。通过对比FOD技术与整数阶技术对高光谱数据的改善能力, 从光谱层面探寻最佳FOD阶数。在梯度提升回归树(GBRT)算法下构建土壤含水量(SMC)估算模型, 最终在最佳模型下评估SMC的空间分布。结果表明: FOD技术提高光谱与SMC的相关系数( $r_{\max}=0.768$ ), 与原始光谱、一阶微分和二阶微分处理后的光谱同SMC相关系数相比, 分别提升0.168, 0.157和0.158。FOD技术提升模型估算精度的主因是突出有效光谱信息的作用, 特别是与水分胁迫密切敏感的叶绿素、植物结构和水分响应波段(430, 460, 640, 660和970 nm)。即使FOD技术取得理想的结果, 不同阶数的效果仍有差异。高阶FOD对影像增加了一定噪声, 相较于高阶FOD( $1 < \text{阶数} < 2$ ), 低阶FOD( $0 < \text{阶数} < 1$ )对相关性的改善更为明显。FOD技术对SMC估算模型的性能有很大提高, 在0.4阶模型下取得最优结果( $R_p^2=0.874$ , RMSEP=1.458, RPIQ=3.029)。此外, 0.1—0.9阶和1.6—1.9阶的SMC估算模型比整数阶模型更优( $R_p^2$ 提升0.8%~13.8%), 但根据模的RPIQ发现, 低阶FOD模型在模型的预测能力方面更强。在0.4阶模型下反演农田土壤水分的空间分布表明干旱区农田SMC具有显著的空间异质性。研究结果表明低阶FOD技术有效地实现对高光谱数据挖掘, 从而实现农业SMC的精准估算。该研究提出了针对机载高光谱影像处理的新方法, 为干旱区精准农业实施和管理提供新的策略。

**关键词** 高光谱; 无人机; 分数阶微分; 精准农业; 土壤含水量

**中图分类号:** S152.7 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2022)11-3559-09

## 引言

土壤含水量(soil moisture content, SMC)是区域精准农业和水资源管理中易受影响的重要参量, 是约束作物生态学参数的关键指标<sup>[1]</sup>。在干旱和半干旱地区, 农业极易受到干旱胁迫, 造成作物长势稀疏、产量下降<sup>[2-3]</sup>。尽管干旱区农业水资源具有重要意义, 但在实践中仍然缺乏快速易行、无

损监测的手段。特别是农业土壤被作物覆盖, 土壤水分的变化以植被生物化学结构表现, 常见的星载光学遥感光谱分辨率较低, 难以完整捕捉植被生物化学结构的细微变化<sup>[4]</sup>。因此, 及时精准地掌握农业区域SMC的空间分布对精准农业和农业信息化发挥着重要作用。

随着无人机遥感技术在农业中的推广, 及时的无损监测逐渐成为可能<sup>[5-6]</sup>。机载高光谱成像传感器能有效捕捉作物冠层特征, 提供丰富的光谱信息, 并保留地理空间属性<sup>[7]</sup>。

收稿日期: 2021-09-20, 修订日期: 2022-03-24

基金项目: 中国科学院数字地球重点实验室开放基金项目(2019LDE002), 北京师范大学防沙治沙教育部工程研究中心开放课题(2020-B-2), 新疆绿洲生态自治区重点实验室开放课题(2020D04038), 国家自然科学基金项目(U2003202)资助

作者简介: 王瑾杰, 女, 1982年生, 新疆大学地理与遥感科学学院副教授 e-mail: skytian552@qq.com

\* 通讯作者 e-mail: watarid@xju.edu.cn

然而,从高维的高光谱数据中挖掘出敏感变量仍存在一定难度。高光谱成像仪的波段范围适用于农业区域作物覆盖区域的监测<sup>[8]</sup>。虽然光谱范围较小(400~1 000 nm),但包含植被生化结构敏感波段和植被红边信息波段,并被证明植被冠层的光谱特征在不同的 SMC 胁迫条件下发生变化<sup>[9]</sup>。因此,通过挖掘植被冠层信息估算 SMC 的研究值得探索。近年在高光谱数据挖掘研究中,微分处理受到广泛关注<sup>[10]</sup>。袁婕等通过一阶和二阶微分光谱变换,探寻与植被盐分关联程度较高的敏感波段,并提升模型定量估算的效果<sup>[11]</sup>。Wang 等考虑基于一阶和二阶微分光谱获得植被冠层的红边参数,并通过红边信息发现植被受到的胁迫程度<sup>[12]</sup>。尽管这些研究已经取得较好的结果,但整数阶微分处理仍有局限,整数阶微分可能造成光谱部分信息的丢失,并引入大量噪声峰<sup>[13]</sup>。此外,因一阶微分与二阶微分的波形差异较大,可能会忽略由于作物根部 SMC 造成冠层光谱细微的差异<sup>[14]</sup>。高整数阶微分处理可以增强成像光谱的图像边缘,然而精细的纹理和平滑的区域可能会被忽略<sup>[15]</sup>。分数阶微分利用较窄的阶数区

间扩展了整数阶微分在光谱预处理中的应用<sup>[16]</sup>,从而为处理机载高光谱数据提供了新的视角。

基于此,以干旱区典型农业区为研究对象,利用机载高光谱传感器获取成像光谱数据,基于分数阶技术挖掘冠层光谱信息与 SMC 间的敏感关系,以期提高 SMC 估算精度,旨在为干旱区的精准农业和农业信息化提供准确而有前景的解决方案。

## 1 实验部分

### 1.1 研究区概况

试验田位于乌鲁木齐市东北隅的阜康市,北邻库尔班通古特沙漠,是绿洲与荒漠的交错带(图 1)。该地区以温带大陆性沙漠气候为特征,年平均降水量 200 mm,全年无霜期 176 d,年平均气温 7.1 °C,降水分布不均匀。阜康市是粮食、优质蔬菜和特殊作物生产的重要基地。试验田内种植冬小麦,熟制为一年一熟。

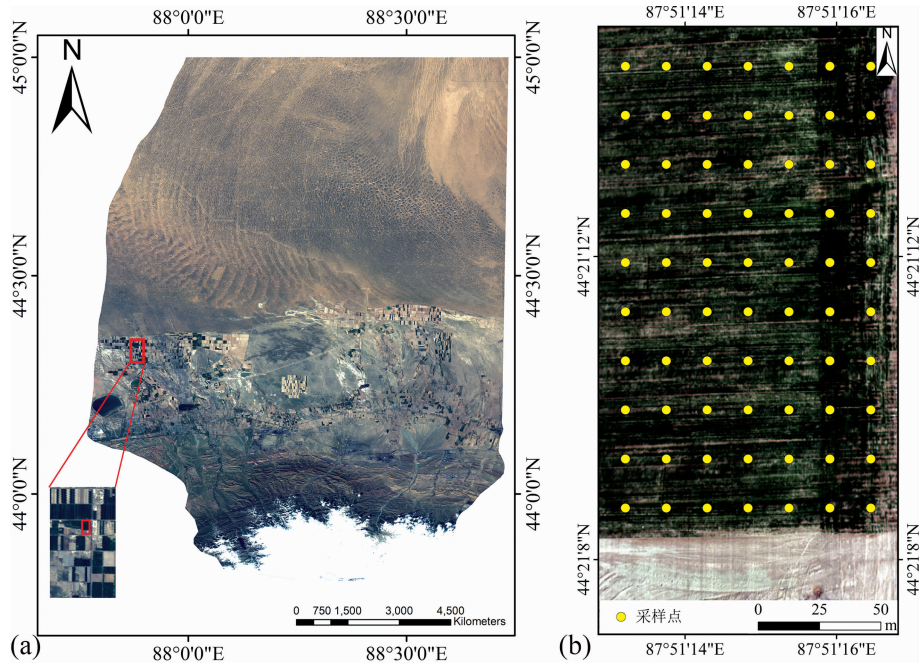


图 1 研究区及采样点分布

(a): 高分 1 号 RGB 真彩色合成的阜康市及采样区示意图; (b): 采样点示意图

Fig. 1 The study area and distribution of sampling points

(a): RGB true color image of Fukang city and study area using Gaofen-1; (b): Sampling points

### 1.2 数据获取与处理

在试验区内均匀地布设采样网格(0.5 m×0.5 m),并用 GPS 记录网格中心位值坐标。每份土样通过环株四点法混合收集,均为表层土(0~10 cm)。土壤样品采集时均以铝盒密封,在室内处理。通过室内烘干(105 °C 烘干箱,48 h)计算得到 SMC 数据集。

无人机作业采用 DJI Matrice600Pro<sup>®</sup>(中国深圳大疆创新科技有限公司)无人机平台和 Headwall Nano-Hyperspec<sup>®</sup>高光谱传感器(Headwall Photonics Inc., Bolton, MA,

USA)。成像光谱仪具有 400~1000 nm 的波段范围,6 nm 的光谱分辨率,2.2 nm 的重采样间隔和 272 个光谱波段。当航高为 100 m 时,所捕获影像空间分辨率为 4 cm。高光谱数据于 2018 年 4 月 17 日 15:00 获取,作业时响晴无风,并遵循暗电流去除和白板校正流程。室内通过 Hyperspec III 和 Headwall SpectralView 软件进行高光谱数据预处理和正射校正,利用 Savitzky-Golay 滤波器(second-order polynomial smoothing and 5-band window width, S-G)平滑处理影像(视为原始影像)。S-G 平滑处理在 MATLABR2016b(The Math-

Works, Natick, MA, USA) 中进行。所获取的影像长 250 m, 宽 100 m, 面积为  $2.5 \times 10^4 \text{ m}^2$ 。




图 2 无人机作业及机载高光谱传感器

Fig. 2 UAV operation and UAV-based hyperspectral sensor

### 1.3 分数阶微分技术

根据分数阶微分(fractional order differential, FOD)方法的几何和物理意义, FOD 理论更适合处理分形问题。分数阶的几何意义是函数曲线的一般斜率, 物理意义是分数流和广义振幅。一般来说, 物体的光谱被视为一个物理光电信号<sup>[15]</sup>。分数阶微分通常有三个定义, 包括 Caputo, Riemann-Liouville, Grünwald-Letnikov(G-L)。我们根据研究的可持续性选择了 G-L 定义<sup>[16]</sup>。先前的研究中表明, 三种算法定义中 G-L 在处理一维光谱时是有效的<sup>[16-17]</sup>。我们利用式(1)在 MATLABR2016b 中对成像光谱进行处理, 在  $0 \sim 2$  阶区间内进行了 20 次分数阶变换, 步长为 0.1。

$$\frac{d^v f(x)}{dx^v} \approx f(x) + (-v)f(x-1) + \frac{(-v)(-v+1)}{2} f(x-2) + \dots + \frac{\Gamma(-v+1)}{n! \Gamma(-v+m+1)} f(x-m) \quad (1)$$

式(1)中,  $x$  为自变量,  $v$  为阶数,  $\Gamma(g(x))$  为 Gamma 函数,  $m$  是微分上下限差。当  $v=0.0$  则表示原始光谱,  $v=1.0$  则表示一阶微分,  $v=2.0$  表示二阶微分。

### 1.4 建模策略

选择基于联合  $x-y$  距离 (Simple set partitioning based on joint  $x-y$  distance, SPXY) 方法<sup>[18]</sup> 对 70 个样本执行划分, 50 个样本为建模集, 其余 20 个样本作为验证集。在构建估算模型时, 全部波段作为预测变量, 实测 SMC 则为响应变量。

梯度提升回归树 (gradient-boosted regression tree, GBRT) 是基于决策树的集成学习模型<sup>[19]</sup>。GBRT 对解释冠层光谱信息与 SMC 的非线性关系极具潜力, 是一种鲁棒性较强的估算模型。因其集成了多个弱学习机, 并将多个弱学习机组合成共识模型, 在先前研究中 GBRT 表现出优于随机森林的潜能。GBRT 本质是在每次迭代时添加新的学习机, 并利用最小二乘法最小化负梯度, 对前一次遗留的残差的输入, 允许从中学习, 从而实现集成的效果<sup>[20]</sup>。GBRT 关键参数设置如下: 树的个数 ( $n$ . trees) = 500, 树深 ( $\max\_depth$ ) = 5。

### 1.5 模型评价

估算模型评价采纳决定系数 (the coefficient of determination,  $R^2$ )、均方根误差 (root mean square errors, RMSE)

和四分位数间隔 (ratio of performance to interquartile range, RPIQ) 3 个指标, 其中  $R^2$  和 RMSE 在建模集和验证集分别表示为:  $R_p^2$ ,  $R_v^2$ , RMSEC 和 RMSEP。RPIQ 分级标准参考文献<sup>[21]</sup>:  $RPIQ \geq 2.5$  表示模型极佳,  $2.0 \leq RPIQ < 2.5$  表示模型较好,  $1.7 \leq RPIQ < 2.0$  表示模型有较均衡的预测能力,  $1.4 \leq RPIQ < 1.7$  表示模型的可信度低,  $RPIQ < 1.4$  表示模型较差。3 个指标的详尽定义及公式可参考已发表的相关研究<sup>[21-22]</sup>。

## 2 结果与讨论

### 2.1 SMC 统计特征

经 SPXY 模型划分后样本集合描述性统计结果如图 3, 小提琴图中三条曲线为核密度估计, 其面积越大表示样本量越多, 箱线的上下限分别表示一分位数和三分位数。全集、建模集和验证集的均值 (Mean) 分别为 24.464%, 24.090% 和 25.400%, 标准差分别是 5.408%, 5.832% 和 4.148%。相近的统计特征可以最大程度保证估算模型的效果, 此外, 各数据集样本分布直方图也保持近似的分布, 可证明 SPXY 划分数据集具有较好的代表性, 尽可能降低在模型估算中的误差。




图 3 样本集的描述性统计图

Fig. 3 Descriptive chart of the sample sets

### 2.2 FOD 对成像光谱效果

无人机高光谱影像具有图谱合一的特征, 因而将从影像和光谱两个层面分析 FOD 处理后的效果。图 4 和图 5 分别是 RGB 影像和平均光谱。低阶 FOD ( $0 < \text{阶数} < 1$ ) 和高阶 FOD ( $1 < \text{阶数} < 2$ ) 的结果有显著差异。在 RGB 影像中, 低阶 FOD 的影像仍能保持较好的清晰度, 但从 0.6 阶逐渐呈现部分噪声, 使得随着阶数增加图像清晰度下降。高阶 FOD 而言, 噪声随着阶数增加而增加, 难以清晰地分辨影像目标。图 5 中红色为平均光谱, 蓝色区间表示均值加减标准差。低阶 FOD 的光谱区间能维持与植被光谱形似的光谱曲线, 特别是对于水、氧吸收谷区域 (760 nm 附近) 突显。然而, 高阶 FOD 处理后的光谱曲线随着阶数增加, 植被光谱曲线形态特征丧失越明显, 相应地增加了噪声峰。因此, 从光谱特征角度可确定低阶 FOD 是处理无人机成像高光谱数据的首

选方案。

不同 FOD 处理下光谱与 SMC 的相关系数如图 6 所示。与高阶 FOD 处理下光谱与 SMC 的相关系数相比,低阶 FOD 的相关系数较高,并集中于可见光波段范围内。通过比较不同预处理下光谱和 SMC 的最大绝对值( $r_{\max}$ ),表明在 0.4 阶时, $r_{\max}$  值最大( $r_{\max}=0.768$ ),低阶 FOD 的  $r_{\max}$  整体上优于

高阶 FOD。在高阶 FOD 中, $r_{\max}$  变化较缓,显示出略高于原始光谱(0 阶)与 SMC 的  $r_{\max}$  值。与整数阶微分(一阶微分和二阶微分)的结果相比,0.4 阶处理的光谱与 SMC 的相关性分别提高了 0.157 和 0.158。因此,FOD 可以很好地挖掘和凸显细微光谱间信息,提高光谱与 SMC 的相关性。




图 4 分数阶微分处理后的高光谱影像

(a): 高光谱影像立方体; (b)–(u): 0.1 阶–2 阶处理结果

Fig. 4 Hyperspectral images after FOD processing

(a): Hyperspectral image cube; (b)–(u): Processing results of 0.1 to 2 orders

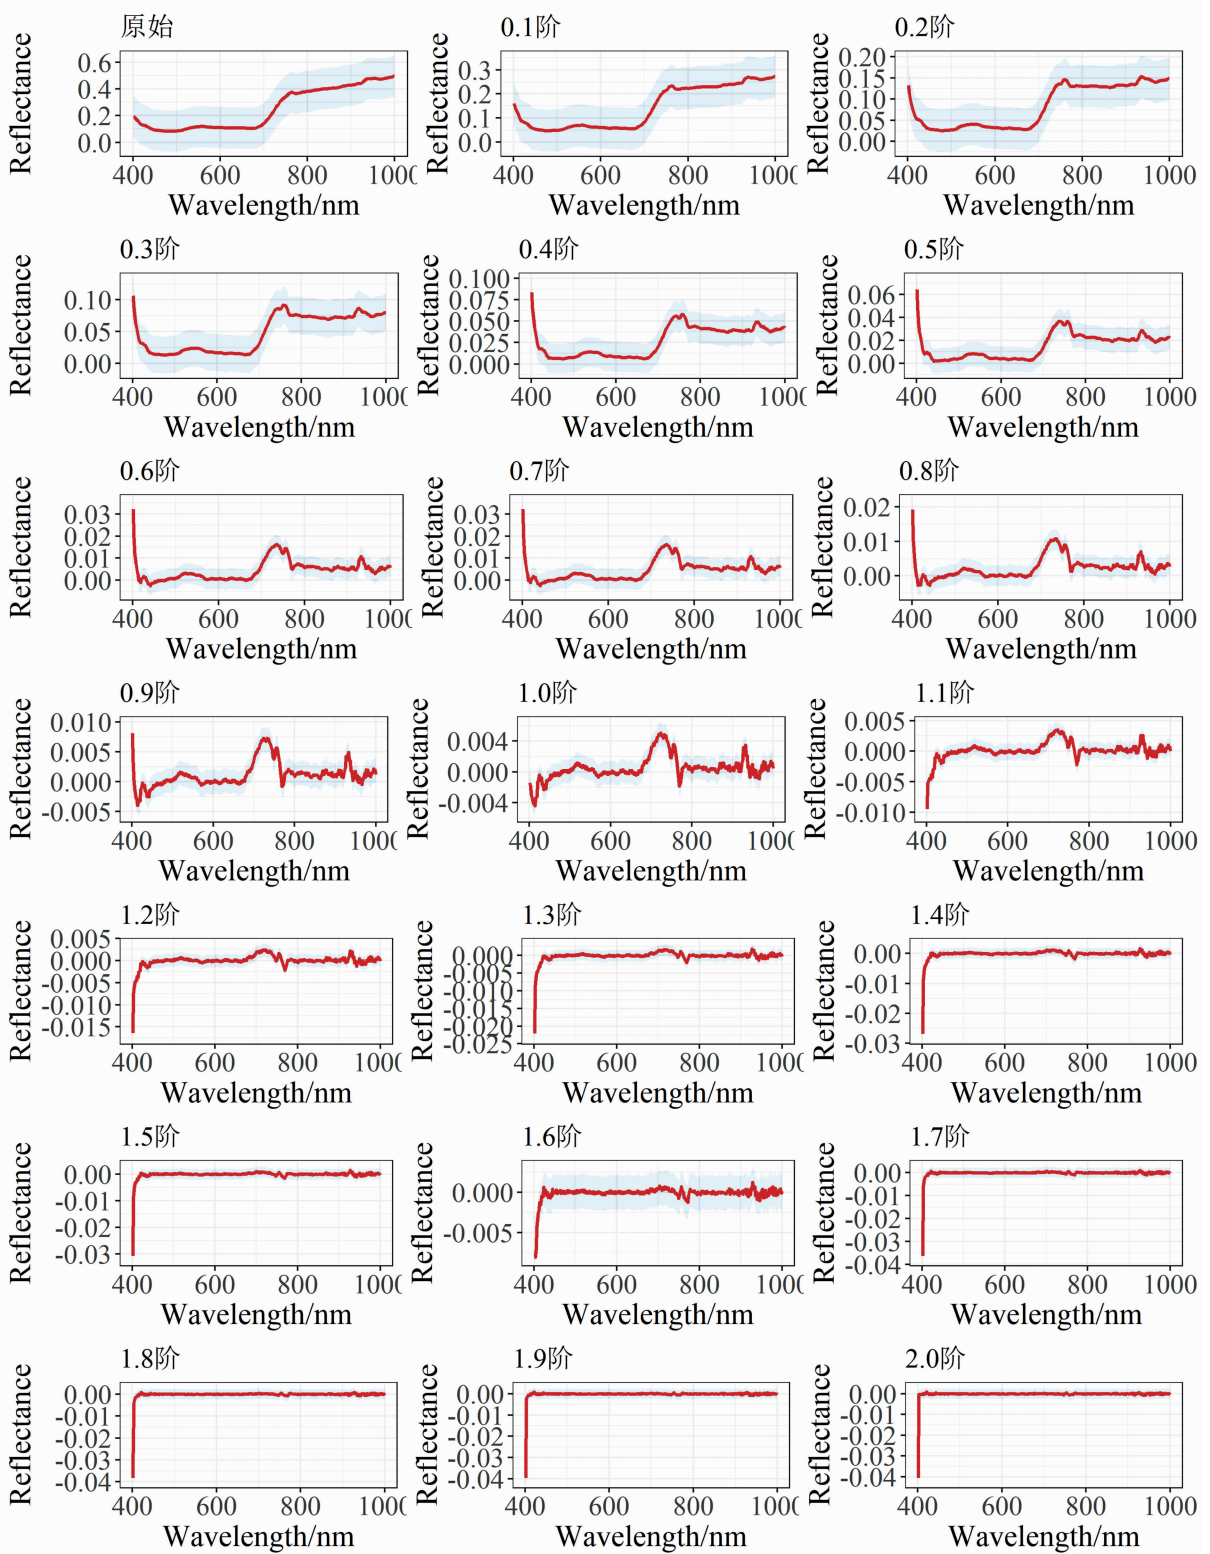


图 5 不同的 FOD 预处理光谱曲线

Fig. 5 Spectral preprocessed by different FOD

### 2.3 估算模型构建与对比

为了探明 FOD 对模型性能的效果，利用 GBRT 算法基于 FOD 处理后的全波段光谱信息估算 SMC，模型评价指标

分别列于表 1 中。结果表明，通过 FOD 处理的模型性能比原始光谱和整数阶微分构建的模型更好。特别是，0.4 阶模型最优 ( $R_p^2=0.874$ ,  $RMSEP=1.458$ ,  $RPIQ=3.029$ )，与原始

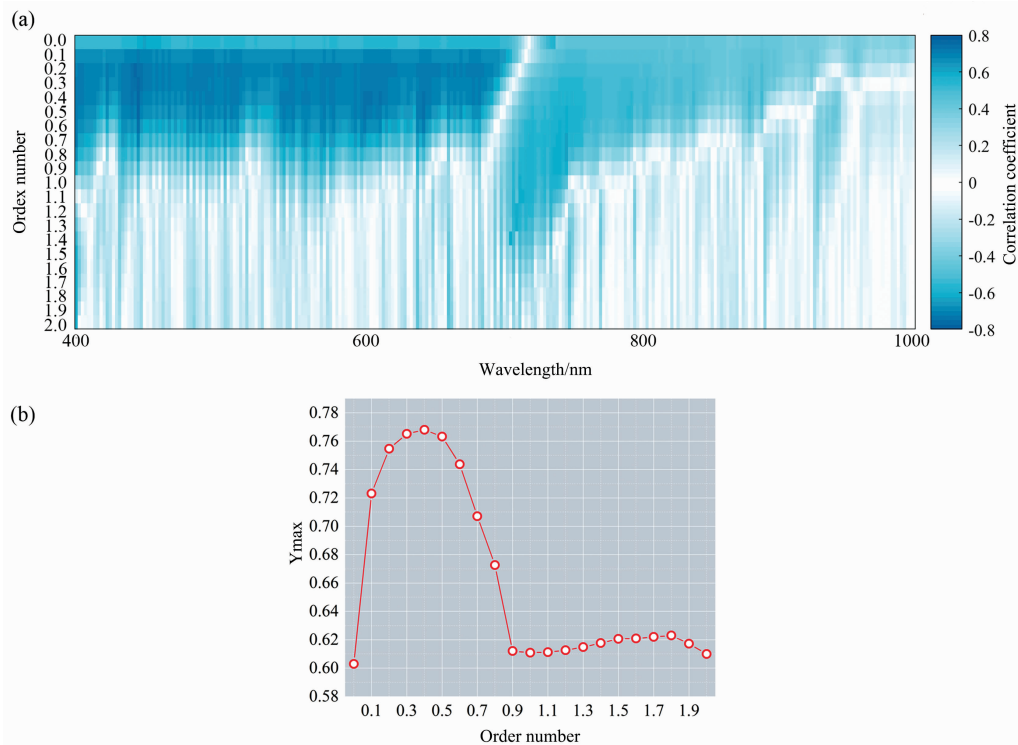


图 6 不同 FOD 处理下光谱与 SMC 的相关系数

(a): 不同预处理下光谱与 SMC 的相关系数热图; (b): 不同预处理下光谱与 SMC 相关性系数的最大绝对值

Fig. 6 The correlation coefficient between band and SMC under different FOD pretreatments

(a): Heatmap; (b): Maximum correlation coefficient

表 1 基于不同 FOD 建模策略 SMC 的 GBRT 估算模型比较

Table 1 Comparisons of GBRT models based on different modeling strategies

建模策略	$R_c^2$	RMSEC	$R_p^2$	RMSEP	RPIQ
0 阶	0.749	3.005	0.685	2.414	1.211
0.1 阶	0.818	0.633	0.811	3.934	2.968
0.2 阶	0.858	2.649	0.849	1.664	3.027
0.3 阶	0.820	2.668	0.829	1.690	3.029
0.4 阶	0.898	2.320	0.874	1.458	3.152
0.5 阶	0.858	2.345	0.852	1.898	3.009
0.6 阶	0.820	3.359	0.811	1.940	2.812
0.7 阶	0.839	2.522	0.821	1.726	2.692
0.8 阶	0.863	2.318	0.867	1.545	3.050
0.9 阶	0.798	3.436	0.799	1.926	2.733
1 阶	0.790	4.384	0.719	2.358	1.498
1.1 阶	0.754	3.394	0.753	2.141	1.945
1.2 阶	0.750	3.480	0.759	2.451	1.332
1.3 阶	0.781	2.765	0.781	2.030	1.868
1.4 阶	0.755	3.619	0.753	2.310	1.359
1.5 阶	0.769	3.230	0.752	2.453	1.227
1.6 阶	0.799	3.017	0.759	2.607	1.601
1.7 阶	0.836	3.634	0.822	2.101	2.281
1.8 阶	0.824	3.504	0.816	2.129	1.985
1.9 阶	0.842	2.414	0.837	1.987	2.222
2 阶	0.760	2.985	0.723	2.221	1.979

光谱模型相比, 0.4 阶模型的  $R_p^2$  增加 1.941, RPIQ 增加 1.042, RMSEP 减少 0.956。与高阶 FOD 模型相比, 低阶 FOD 产生更好的估算能力。此外, 同整数阶微分模型估算能力相比, 分数阶微分模型性能 ( $R_p^2 \geq 0.752$ ) 略胜一筹。图 7 表示实测 SMC 与估算 SMC 的散点图, 0.4 阶方案的拟合线最靠近 1:1 线。综上所述, FOD 模型估算 SMC 产生了较理想的效果, 0.4 阶模型策略为最佳估算 SMC 模型。在最佳模型下, 田间尺度的 SMC 空间分布如图 8 所示, 该区域 SMC 分布极不均匀。

#### 2.4 光谱变量的重要性分析

集成学习算法优势在于对参与模型的变量均能赋予相应重要程度, 不同 FOD 下的全波段重要性如图 9 所示。FOD 处理后的光谱对 SMC 重要性最高的波段集中在 400 nm 附近, 蓝光波段处通常为叶片含水量紧密相关。此外, 在低阶 FOD 中, 波段重要性主要集中在 400~500, 520 和 970 nm 附近。对于高阶 FOD, 更重要的区域集中在大约 400, 640 和 720 nm 附近。上述波段范围与植被的叶绿素、作物胁迫和水分存在较好的响应。相较于原始波谱重要性而言, FOD 技术挖掘了更多波段的协同响应。

图谱合一的无人机高光谱影像包含大量信息, 光谱微分技术是分析反射光谱的一种有利方法, 可以消除背景噪声、锐化光谱特征<sup>[20]</sup>。FOD 技术与整数阶微分相比, 挖掘了光谱中细微的信息, 并且光谱保留了光谱原始的特征(图 5), 低阶 FOD 处理后影像在红边区域非常明显。FOD 技术在提

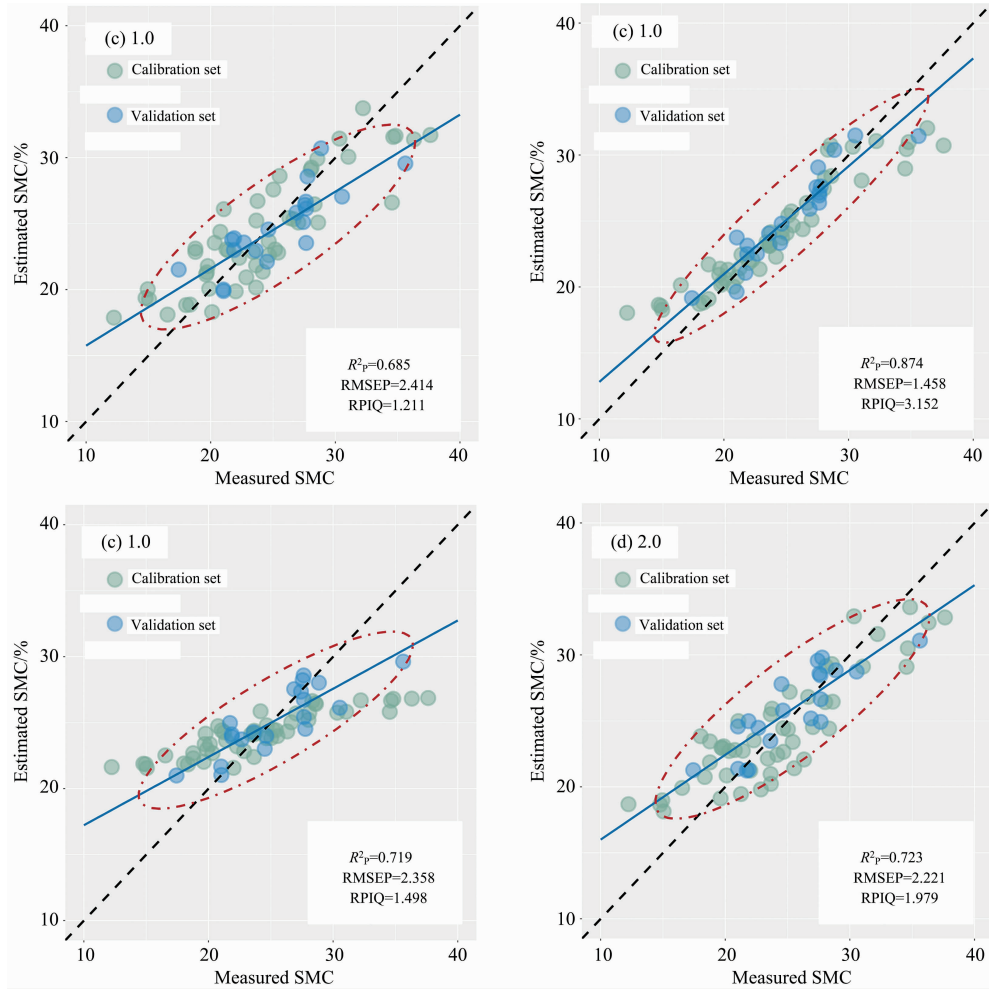


图 7 实测 SMC 与估算 SMC 散点图  
 Fig. 7 Scatter plot of measured SMC and estimated SMC




图 8 最优模型下 SMC 空间分布  
 Fig. 8 SMC spatial distribution under the optimal model




图 9 不同预处理下波段重要性  
 Fig. 9 Bands importance under different FOD pretreatment

高光谱与 SMC 相关性的同时，改善模型精度。近年来，对高光谱数据的预处理主要集中于整数阶微分处理，相较之下，二阶微分处理效果不如一阶微分处理，其结果表现不足<sup>[23]</sup>。

高阶 FOD 处理效果同样不如低阶 FOD 处理结果,因在高阶 FOD 处理结果中,光谱在近红外区域(900~1 000 nm)出现大量噪声峰,图像随着阶数的增加清晰度开始下降。因此高阶 FOD 可能不适合机载高光谱数据。FOD 技术一定程度上扩展高维数据对预处理需求,同时对数据的挖掘极具潜力。值得注意的是, FOD 技术理论上对等距间隔数据才可执行,对于非等距光谱间隔的星载遥感影像略显乏力。

植物生物物理特性和生物化学特性极易受到土壤属性的胁迫。特别是,干旱胁迫使叶绿素吸收强度变化,从而诱发植被冠层光谱的差异,在作物生长的早期,干旱胁迫的影响尤为明显。采样时节正值冬小麦返青期, SMC 对作物叶绿素含量的边际效应随 SMC 的增加而增加<sup>[24]</sup>。从植物生化组分的光谱吸收特征及形成机理的角度出发,与叶绿素极大相关的关键位值基本在 430, 460, 640 和 660 nm<sup>[25]</sup>。结合图 9 所示的波段重要性分析,不难发现分数阶微分处理后的光谱挖掘出更多与叶绿素强相关的光谱信息并协同了部分水分强吸收的信息。低阶 FOD 更多地拓展了 430~460 nm 的光谱信号,而高阶 FOD 更倾向于在红边和近红外附近挖掘更多信息。在此基础上,基于植被光谱信息定量估算 SMC 在物理原理上是可行的,利用植被光谱信息反演 SMC 存在清楚的遥感和光谱机制。在作物覆被较高的生长期,利用机载高光谱数据获取冠层光谱信息,从而方便制定更合理的精准农业灌溉管理方案。

即使机器学习往往能很好的解释非线性关系,但模型的训练尽可能需要大量样本和适合的超参数<sup>[25]</sup>。正因如此,本工作采用集成学习算法进行估算,集成学习可以有效地规避小样本建模估算的问题。从实测值与估算值的散点图(图 7)

中发现,算法出现了部分低估的现象,但在建模过程中取得了较好的精度和性能。总之,间接估算受胁迫的植被冠层光谱可能为 SMC 定量估计提供新的视角。此外,辐射传输模型和热红外数据在近年研究中应用于水分胁迫等研究<sup>[26]</sup>,结合更多的理论和数据可能会带来更令人期待的估算结果。虽然本研究通过 FOD 技术有效地挖掘了“返青期”的冬小麦冠层信息,但由于现实情况限制,物候情境下的无人机高光谱数据未能采集,我们将进一步探索和实践。在此基础上,有助于实现了精确的灌溉管理,为干旱地区的绿洲农业日益脆弱的农业生态系统提供科学支持。

### 3 结 论

基于分数阶微分技术,同原始无人机高光谱影像和经传统整数阶微分(一阶微分和二阶微分)处理后影像进行对比,探讨分阶微分技术在机器学习框架下估算土壤含水量能力。结果表明:分数阶微分技术提高光谱与土壤含水量的相关性,低阶分数阶微分相较于高阶分数阶微分处理效果更好,其中 0.4 阶处理效果最佳( $r_{\max}=0.768$ ),相较于原始光谱、一阶微分光谱和二阶微分光谱分别提高了 0.168, 0.157 和 0.158。分数阶微分技术可以提高土壤含水量的估算精度,特别是 0.4 阶处理下的梯度提升回归树估算模型达到最优性能( $R_p^2=0.874$ , RMSEP=1.458, RPIQ=3.029),与整数阶微分相比,  $R_p^2$  提高 0.151。分数阶技术之所以提高土壤含水量估算性能是因为其挖掘了高光谱的多波段的协同响应,尤其是受水分胁迫的叶绿素响应波段。

### References

- [1] Martínez-Fernández J, González-Zamora A, Sánchez N, et al. Remote Sensing of Environment, 2016, 177: 277.
- [2] Sankey T T, McVay J, Swetnam T L, et al. Remote Sensing in Ecology and Conservation, 2018, 4(1): 20.
- [3] Yan W, Zhong Y, Shangguan Z. Agricultural and Forest Meteorology, 2017, 247: 311.
- [4] Maimaitiyiming M, Ghulam A, Bozzolo A, et al. Remote Sensing, 2017, 9(7): 745.
- [5] Jay S, Baret F, Dutartre D, et al. Remote Sensing of Environment, 2019, 231: 110898.
- [6] SHI Zhou, XU Dong-yun, TENG Hong-fen, et al(史舟, 徐冬云, 滕洪芬, 等). Progress in Geography(地理科学进展), 2018, 37(1): 79.
- [7] Gago J, Douthe C, Coopman R E, et al. Agricultural Water Management, 2015, 153: 9.
- [8] Liu H, Zhu H, Wang P. International Journal of Remote Sensing, 2017, 38(8-10): 2117.
- [9] Steidle Neto A J, Lopes D C, Pinto F A C, et al. Biosystems Engineering, 2017, 155: 124.
- [10] Nawar S, Buddenbaum H, Hill J, et al. Soil and Tillage Research, 2016, 155: 510.
- [11] YUAN Jie, ZHANG Fei, GE Xiang-yu, et al(袁婕, 张飞, 葛翔宇, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2019, 35(10): 115.
- [12] Wang X, Zhang F, Kung H T, et al. Ecological Indicators, 2017, 81: 222.
- [13] Wei G, Li Y, Zhang Z, et al. PeerJ, 2020, (8): e9087.
- [14] Wang F, Jay G, Yong Z. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 136: 73.
- [15] PU Yi-fei, WANG Wei-xing, ZHOU Ji-liu, et al(蒲亦非, 王卫星, 周激流, 等). Science in China (Series E): Information Sciences(中国科学·E 辑: 信息科学), 2008, 38(12): 2252.
- [16] Wang X, Zhang F, Kung H T, et al. Remote Sensing of Environment, 2018, 218: 104.
- [17] ZHANG Zhi-tao, LAO Cong-cong, WANG Hai-feng, et al(张智韬, 劳聪聪, 王海峰, 等). Transactions of the Chinese Society for Agricultural Machinery(农业机械学报), 2020, 51(1): 156.
- [18] Galvão R KH, Araujo M C U, José G E, et al. Talanta, 2005, 67(4): 736.



- [19] Yang L, Zhang X, Liang S, et al. *Remote Sensing*, 2018, 10(2): 185.
- [20] Chen Di, Chang Naijie, Xiao Jingfeng, et al. *Science of the Total Environment*, 2019, 669: 844.
- [21] Nawar S, Abdul M M. *Catena*, 2017, 155: 118.
- [22] Pascucci S, Casa R, Belviso C, et al. *European Journal of Soil Science*, 2014, 65(6): 865.
- [23] GE Xiang-yu, DING Jian-li, WANG Jing-zhe, et al(葛翔宇, 丁建丽, 王敬哲, 等), *Spectroscopy and Spectral Analysis(光谱学与光谱分析)*, 2020, 40(2): 602.
- [24] XIAO Yan-fang, ZHOU De-min, GONG Hui-li, et al(肖艳芳, 周德民, 宫辉力, 等). *Journal of Remote Sensing(遥感学报)*, 2015, 19(3): 368.
- [25] ZHU Ye-qing, QU Yong-hua, LIU Su-hong, et al(朱叶青, 屈永华, 刘素红, 等). *Journal of Remote Sensing(遥感学报)*, 2014, 18(2): 335.
- [26] Jin X, Kumar L, Li Z, et al. *European Journal of Agronomy*, 2018, 92: 141.

## Application of Fractional Order Differential Technology in the Estimation of Soil Moisture Content Using UAV-Based Hyperspectral Data

WANG Jin-jie<sup>1, 2, 3, 4, 5</sup>, DING Jian-li<sup>1, 4, 5\*</sup>, GE Xiang-yu<sup>1, 4, 5</sup>, ZHANG Zhe<sup>1, 4, 5</sup>, HAN Li-jing<sup>1, 4, 5</sup>

1. College of Geography and Remote Sensing Science, Xinjiang University, Urumqi 830017, China

2. MOE Engineering Research Center of Desertification and Blown-Sand Control, Beijing Normal University, Beijing 100875, China

3. Key Laboratory of Digital Earth Science, Chinese Academy of Sciences, Beijing 100094, China

4. Xinjiang Key Laboratory of Oasis Ecology, Xinjiang University, Urumqi 830017, China

5. Key Laboratory of Smart City and Environment Modelling of Higher Education Institute, Xinjiang University, Urumqi 830017, China

**Abstract** UAV-based remote sensing technique provides a new perspective and platform for precision agriculture and agricultural information monitoring. The hyperspectral sensor has centimeter-level spatial and fine spectral resolution, allowing for the acquisition of high-quality hyperspectral data. However, hyperspectral data often bring question on noise, data redundancy and inefficient use of hyperspectral information, whereas conventional preprocessing is difficult to estimate with high-precision. Therefore, data mining for UAV-based hyperspectral images is essential to solve the above problems. Here we used fractional order differential (FOD) to process UAV-based hyperspectral data (with a step length of 0.1). The optimal FOD order is explored at the spectral level by comparing the ability of the FOD technique with the integer order technique to improve the hyperspectral data. Soil moisture content (SMC) estimation models were constructed under the Gradient-Boosted Regression Tree (GBRT) algorithm, and the spatial distribution of SMC was finally evaluated under the best model. The results found that the correlation between the spectrum and SMC also was increased (absolute maximum correlation coefficient,  $r_{\max} = 0.768$ ). Compared with the original image and processed images via first and second order derivatives,  $r_{\max}$  increased by 0.168, 0.157 and 0.158, respectively. The main reason for the FOD technique to enhance the accuracy of model estimation is to highlight the role of effective spectral information, especially chlorophyll, plant structure and water response bands closely sensitive to drought stress. (430, 460, 640, 660 and 970 nm). By comparison, the low-order FOD (order < 1) is more effective in the image quality, correlation and model accuracy than high-order FOD (order > 1). The higher order FOD adds a certain amount of noise to the image, though the FOD technology achieves the desired result. Estimated model achieved the best results in the 0.4-order model ( $R_p^2 = 0.874$ , RMSEP = 1.458, RPIQ = 3.029). In addition, the SMC estimation models of 0.1—0.9 order and 1.6—1.9 order outperformed the integer-order models ( $R_p^2$  improvement of 0.8%~13.8%), but the lower-order FOD models were found to be stronger in terms of model predictive power based on the RPIQ of the models. The spatial distribution of inverse farmland soil moisture under the 0.4 order model indicated significant spatial heterogeneity of farmland SMC in the arid regions. In conclusion, the low-order FOD technique effectively enables the mining of hyperspectral data to accurately estimate agricultural SMC. This study proposes a new approach to airborne hyperspectral image processing that provides a new strategy for precision agriculture implementation and management in arid regions.

**Keywords** Hyperspectral; UAV; FOD; Precision farming; Soil moisture content

\* Corresponding author

(Received Sep. 20, 2021; accepted Mar. 24, 2022)