

金利山,王秀梅,董建军,等.结合 ASD 和无人机高光谱的内蒙古典典型草原植被氮反演 [J]. 中国环境科学, 2025,45(5):2713-2723.

Jin L S, Wang X M, Dong J J, et al. Vegetation nitrogen inversion of typical grassland in Inner Mongolia combined with ASD and UAV hyperspectral [J]. China Environmental Science, 2025,45(5):2713-2723.

结合 ASD 和无人机高光谱的内蒙古典典型草原植被氮反演

金利山¹,王秀梅^{1*},董建军^{2**},王若琛¹,温贺飞²,孙煜焱¹,吴文博²,张智航¹,康 灿² (1.内蒙古工业大学资源与环境工程学院,内蒙古 呼和浩特 010051; 2 内蒙古大学生态环境学院,内蒙古 呼和浩特 010021)

摘要: 采用地面遥感与无人机遥感相结合的方式对内蒙古典典型草原植被氮含量进行估测.实验于 2023 年 8-9 月在内蒙古大学草地生态学研究基地进行,采集了地面 ASD 光谱数据和无人机 Resonon 数据.基于 ASD 数据构建了植被指数、“三边参数”、连续统去除参数以及小波系数 4 种光谱参数,并运用 LASSO 进行敏感参数筛选.分别构建多元线性、XGBoost、SVM、ANN 和 KNN 共 5 种模型对植被氮含量进行估测,结果表明基于小波系数的 SVM 方法为最优模型(验证集 $R^2=0.72$,RMSE 和 MAE 分别为 0.26 和 0.18).最后将此模型用于无人机 Resonon 数据进行反演估算并制图(验证集 $R^2=0.41$,RMSE 和 MAE 分别为 0.42 和 0.32).研究显示,将 ASD 和无人机影像与机器学习算法相结合,能够实现草原植被氮含量的估算,为牧场优化施肥、提高牧草品质提供基础数据与技术支撑.

关键词: 高光谱; 氮; 内蒙古典典型草原; 反演模型

中图分类号: X171,S127 文献标识码: A 文章编号: 1000-6923(2025)05-2713-11

Vegetation nitrogen inversion of typical grassland in Inner Mongolia combined with ASD and UAV hyperspectral. JIN Li-shan¹, WANG Xiu-mei^{1*}, DONG Jian-jun^{2**}, WANG Ruo-chen¹, WEN He-fei², SUN Yu-yan¹, WU Wen-bo², ZHANG Zhi-hang¹, KANG Can² (1.School of Resources and Environmental Engineering, Inner Mongolia University of Technology, Hohhot 010051, China; 2.School of Ecological Environment, Inner Mongolia University, Hohhot 010021, China). *China Environmental Science*, 2025,45(5): 2713~2723

Abstract: The combination of ground remote sensing and UAV remote sensing was used to estimate the nitrogen content of typical grassland vegetation in Inner Mongolia. This experiment was carried out in the grassland ecology research base of Inner Mongolia University from August to September 2023, and the ground ASD spectral data and UAV Resonon data were collected. Based on ASD data, four spectral parameters of vegetation index, hyperspectral characteristic variable, continuum removal variable and wavelet coefficient were constructed, and LASSO was used to screen sensitive parameters. Five models of multiple linear, XGBoost, SVM, ANN and KNN were constructed to estimate the nitrogen content of vegetation. The results showed that the SVM method based on wavelet coefficients was the optimal model (validation set $R^2 = 0.72$, RMSE and MAE were 0.26 and 0.18, respectively). Finally, the model was used to estimate and map the UAV Resonon data (validation set $R^2 = 0.41$, RMSE and MAE were 0.42 and 0.32, respectively). The research showed that the combination of ASD and UAV images with machine learning algorithms could be used to realize the estimation of grassland vegetation nitrogen content, and was provided basic data and technical support for optimizing fertilization and improving forage quality.

Key words: hyperspectral; nitrogen; typical grassland in Inner Mongolia; inversion model

内蒙古草原作为我国重要牧区之一,天然草地占全国草原面积的 20%,是我国重要的畜牧业生产基地^[1-4].氮是支持草地植被生长发育的关键营养元素,影响着牧草品质^[5-6].因此,准确估测草地植被氮含量,明晰其空间分布特征,对优化施肥、提高牧草品质具有重要作用^[7-8].

传统的植被氮含量检测方法是破坏性采样,虽然可以取得高精度的结果,但耗时费力,还表现出应用范围小的缺点^[9-10].遥感可以在宏观尺度上对草

地植被进行快速、高效观测,得到区域植被氮的含量^[11-12].

众多学者在植被参数反演领域进行研究.冯海

收稿日期: 2024-08-31

基金项目: 内蒙古自治区自然科学基金(2022LHMS03006);内蒙古工业大学博士研究生启动基金(DC2300001284);内蒙古自治区直属高校基本科研业务费项目(JY20220108);巴林-奈曼(金沙)阜新 500KV 输变电工程(内蒙段)生态监测辅助工作(RH2400001221)

* 责任作者,副教授, xmw1980@163.com; ** 高级实验师, djj1978@163.com

宽等^[13]借助无人机成像高光谱的植被指数与光谱特征参数,致力于提升冬小麦关键生育期氮含量估算精度;孙法福等^[14]通过波段优化算法与相关性分析筛选敏感光谱指数,结合多种回归方法构建冬小麦叶片氮浓度估测模型;Gao 等^[15]基于高光谱及多种环境数据,发现支持向量机 SVM 模型在牧草 P 反演方面表现最优.这些研究为反演草原植被氮含量提供了思路与参考,但目前还缺乏将地面遥感和无人机遥感相结合,挖掘光谱特征,提高反演精度的研究.

无人机高光谱具有成本低、高时效的优势,能够快速获取大面积的高光谱数据.地面高光谱虽然在大区域监测方面存在一定局限性,但有高的光谱分辨率(1nm)识别植被氮含量敏感特征.因此本文结合 ASD 和无人机高光谱对内蒙古典型草原植被氮含量进行反演.采用植被指数、一阶导数变换、连续统去除变换、连续小波变换等 4 种光谱组合或变换方法突出光谱特征,并使用最小收缩算子法(LASSO)筛选高光谱敏感变量,构建基于 ASD 和无人机高光谱数据的草原植被氮估算模型.为牧场优化施肥,提高牧草品质提供基础数据与技术支持,对畜牧业草地的合理利用以及生态环境保护具有重要的参考价值.

1 材料与方法

1.1 研究区概况与试验设计

研究区是内蒙古大学草地生态学研究基地,位于内蒙古自治区锡林浩特市(44°12.621'N, 116°15.446'E).该区域属于温带半干旱大陆性气候,夏季炎热多雨,冬季寒冷干燥,年平均气温 3.5℃,年均降水量 270mm.实验区建群种为羊草(*Leymus chinensis*),优势种有糙隐子草(*Cleistogenes squarrosa*)、克氏针茅(*Stipa krylovii*)等^[16].样地面积约 1400m²,分为 40 个 5m×6m 的小区,设置 2 个刈割处理(刈割留茬 6cm、CK 对照)和 4 个施肥处理(N0P0 对照、N1P0 加氮 100kg/hm²、N0P1 加磷 30kg/hm²、N1P1 分别加氮 100kg/hm² 磷 30kg/hm²).选用尿素和过磷酸钙作为施用氮、磷肥,所有肥料一次性作为基肥施用,不额外施肥.

1.2 实测样品采集及处理

实验于 2023 年 7~8 月在 40 个小区中进行两次取样,每个小区设置 3 个 0.5m×0.5m 的样方,共采集

240 组植被样品.采集高光谱数据后,将叶片放入 120℃烘箱杀青 2h,然后在 65℃干燥 48h.将叶片粉碎、研磨、过筛后称取 0.02g 草样粉末,锡纸包样后选用元素分析仪(Vario MACRO Cube)分析植物的氮含量.

1.3 高光谱遥感数据的获取

本文选择 ASD FieldSpec 4 和 Resonon 同步采集冠层高光谱数据,参数见表 1 所示.

表 1 ASD 和无人机 Resonon 参数
Table 1 ASD and UAV Resonon parameters

| 光谱设备 | 地面-ASD | UAV-Resonon |
|-----------|------------------------------|-------------|
| 型号 | Field Spec 4 | Pika L |
| 光谱范围(nm) | 350~2500 | 400~1000 |
| 光谱分辨率(nm) | 3(350~1000) 10(1001~2500) | 2.1 |
| 光谱通道数(个) | 2151 | 561 |

利用 ASD FieldSpec 4 地物光谱仪采集植被群落冠层反射率,得到地面高光谱数据.由于样地较小,用 RTK 记录地理坐标.获得 ASD 高光谱数据后,首先利用软件 View SpecPro 进行反射率转换,然后分别计算每组样品的平均反射率.最后,在降维变换前还需要进行 SG 滤波(Savitzky-Golay),降低光谱的随机信号噪声^[17].

无人机 Resonon 光谱数据利用大疆六旋翼无人机(DJI Matrice 600Pro)搭载 Resonon 公司研发的 Pika L 推扫式高光谱成像仪拍摄样地范围高光谱影像.其中,飞行平台重量为 10kg,最大载荷 5kg,设置飞行高度为 30m,速度 2.6m/s,重叠率为 40%,垂直分辨率 1cm.Pika L 高光谱成像仪测量波段范围为 400~1000nm,光谱分辨率 2.1nm.

Resonon 数据首先要进行反射率转换.其次进行几何校正,根据 DJI 精灵 4 拍摄的正射影像,在 Arc Gis 软件中使用 Georeferencing 工具选择控制点进行手动地理配准,输出高精度的影像数据.之后在 ENVI 软件中使用 Mosaic 工具进行影像拼接,得到样地的整幅影像.最后,将影像重采样为空间分辨率为 5cm 的影像.

1.4 不同光谱参数

1.4.1 植被指数 构建植被指数可以减少或消除背景噪声,减低对植被光谱信息的影响,增强对植被结构的研究的准确性.本文选取了 21 个植被指数(表 2).

表 2 植被指数及计算公式
Table 2 Vegetation index and calculation formula

| 名称 | 计算公式 | 文献 | |
|-------------------|--|--|------|
| 归一化差异植被指数(NDVI) | $(R_{800} - R_{670}) / (R_{800} + R_{670})$ | [18] | |
| 土壤调节植被指数(SAVI) | $1.5 \times (R_{800} - R_{670}) / (R_{800} + R_{670} + 0.5)$ | [19] | |
| 归一化差异红边指数(NDRE) | $(R_{900} - R_{720}) / (R_{900} + R_{720})$ | [20] | |
| 修改土壤调节植被指数(OSAVI) | $1.16 \times (R_{800} - R_{670}) / (R_{800} + R_{670} + 0.16)$ | [21] | |
| 绿色归一化植被指数(GNDVI) | $(R_{750} - R_{550}) / (R_{750} + R_{550})$ | [22] | |
| 叶绿素红边指数(CIre) | $(R_{750}) / (R_{720}) - 1$ | [23] | |
| 两波段植被指数 | 叶绿素绿色指数(CIgreen) | $(R_{800}) / (R_{560}) - 1$ | [23] |
| | 植物生化指数(PBI) | $(R_{810}) / (R_{560})$ | [24] |
| | 植物色素比率(PPR) | $(R_{550} - R_{450}) / (R_{550} + R_{450})$ | [24] |
| | 两波段增强植被指数(EVI2) | $2.5 \times (R_{800} - R_{670}) / (R_{800} + 2.4 \times R_{670} + 1)$ | [25] |
| | 绿度指数(GI) | $(R_{554}) / (R_{667})$ | [26] |
| | 红边归一化植被指数(NDVI705) | $(R_{750} - R_{705}) / (R_{750} + R_{705})$ | [27] |
| | 氮素反射指数(NRI) | $(R_{560} - R_{670}) / (R_{560} + R_{670})$ | [28] |
| | 花青素反射指数(ARI) | $(1 / R_{559}) / (1 / R_{721})$ | [29] |
| | 修正归一化差异指数(mND705) | $(R_{750} - R_{705}) / (R_{750} + R_{705} - 2R_{445})$ | [30] |
| | 修正比值植被指数(mSR705) | $(R_{750} - R_{445}) / (R_{705} - R_{445})$ | [30] |
| | Meris 陆地叶绿素指数(MTCl) | $(R_{750} - R_{710}) / (R_{710} - R_{680})$ | [31] |
| 三波段植被指数 | 转化叶绿素吸收指数(TCARI) | $3 \times [(R_{700} - R_{670}) - 0.2 \times (R_{700} - R_{550})(R_{700} / R_{670})]$ | [32] |
| | 三角植被指数(TVI) | $0.5 \times [120 \times (R_{800} - R_{550}) - 200 \times (R_{670} - R_{550})]$ | [33] |
| | 光谱多边形植被指数(SPVI) | $0.4 \times [3.7 \times (R_{800} - R_{670}) - 1.2 \times (R_{550} - R_{670})]$ | [34] |
| | 增强植被指数(EVI) | $2.5 \times [(R_{864} - R_{660}) / (R_{864} + 6 \times R_{660} - 7.5 \times R_{487} + 1)]$ | [35] |

表 3 “三边参数”及提取方法
Table 3 'Trilateral parameters' and extraction method

| 类型 | 名称 | 定义 | 文献 |
|-----------|--------------|-------------------------------|------------------------|
| 光谱面积和位置参数 | Db | 蓝边 490~530nm 内一阶导数光谱的最大值 | [36] |
| | λ_b | Db 对应的波长位置 | [36] |
| | Dy | 黄边 560~640nm 内一阶导数光谱的最大值 | [36] |
| | λ_y | Dy 对应的波长位置 | [36] |
| | Dr | 红边 680~760nm 内一阶导数光谱的最大值 | [36] |
| | λ_r | Dr 对应的波长位置 | [36] |
| | Rg | 绿峰反射率, 波长 520~560nm 范围内的最大反射率 | [36] |
| | λ_g | Rg 对应的波长位置 | [37] |
| | Rr | 红谷反射率, 波长 650~690nm 范围内的最大反射率 | [37] |
| | λ_a | Rr 对应的波长位置 | [37] |
| | SDb | 蓝边波长 490~530nm 范围内一阶导数光谱的积分 | [37] |
| | SDy | 黄边波长 560~640nm 范围内一阶导数光谱的积分 | [37] |
| | SDr | 红边波长 680~760nm 范围内一阶导数光谱的积分 | [37] |
| | 光谱面积与位置的比值参数 | VI1 | 绿峰反射率 Rg 与红谷反射率 Rr 的比值 |
| VI2 | | 绿峰反射率 Rg 与红谷反射率 Rr 的归一化值 | [38] |
| VI3 | | 红边面积 SDr 和蓝边面积 SDb 的比值 | [38] |
| VI4 | | 红边面积 SDr 和黄边面积 SDy 的比值 | [38] |
| VI5 | | 红边面积 SDr 和蓝边面积 SDb 的归一化值 | [38] |
| VI6 | | 红边面积 SDr 和黄边面积 SDy 的归一化值 | [38] |

1.4.2 “三边参数” 一阶导数变换能消除土壤背景噪音,同时根据导数光谱曲线的弯曲点、最大和最

小反射率处的波长位置等,提取“三边参数”分析光谱差异.本文总结 19 个基于不同光谱位置和光谱面积的特征参数(表 3).

1.4.3 小波系数 小波变换是一种基于傅里叶变换的信号处理和重要方法^[39].能很好地描述信号的瞬时特性^[40].小波变换可以在不改变原始波段范围和位置的情况下,对不同尺度对地物反射率进行缩放,检测光谱变化^[41].因为 mexh 小波与植被光谱曲线特征相似,故采用 mexh 小波作为母小波基^[42].在 Matlab 软件设置了 9 个缩放尺度,分别是 $2^1, 2^2, \dots, 2^9$.

1.4.4 连续统去除参数 连续统去除法是一种通过去除原始光谱中的连续性信息,突出光谱吸收特征的方法^[43].此方法能抑制背景噪声,有效分离光谱吸收特征^[44].本文提取 7 个参数用于特征筛选和模型建立(表 4).

表 4 连续统去除参数及定义

Table 4 Continuum removal parameters and definitions

| 名称 | 定义 |
|------------------|-------------------------------|
| 最大吸收深度 H | 吸收峰中的最大吸收值 |
| 吸收波段波长 P | 吸收峰中最大吸收深度 H 对应的波长 |
| 吸收峰总面积 A | 吸收峰中起始和终止波长内的波段深度的积分 |
| 吸收峰左面积 LA | 吸收峰中左边吸收峰积分面积 |
| 吸收峰右面积 RA | 吸收峰中右边吸收峰积分面积 |
| 对称度 S | 吸收峰中左面积 LA 和右面积 RA 的比值 |
| 面积归一化最大吸收深度 NMAD | 吸收峰最大吸收深度 H 与吸收峰总面积 A 的比值 |

1.5 变量筛选方法

光谱变换后的特征参数采用 LASSO 进行筛选.LASSO 是由 Tibshirani^[45]提出的一种用于处理多重共线性数据的有偏估计方法,可以在不产生显著影响的情况下将系数压缩到零,以推动部分特征系数稀疏化,从而能自动选择与目标变量相关的重要的特征.LASSO 在 R Studio 中调用“glmnet”包实现.

1.6 模型算法

机器学习回归是一种用于预测连续值输出的监督学习方法,可以显著提高建模的性能.本文采用极致梯度提升(XGBoost)、支持向量机(SVM)、人工神经网络(ANN)、K-近邻算法(KNN)建立氮含量估测模型.

XGBoost 在 GBDT 的基础上进行了正则化、近

似优化、特征分裂策略的改进和优化^[46],使得 XGBoost 在训练速度、模型的准确性和泛化能力上都具有一定的优势^[47].

SVM 是基于监督学习的机器学习模型,常用于解决分类和回归问题^[48].解决回归问题时,SVM 仅存在一类样本点,SVM 算法寻求的最优超平面是所有样本点与超平面的总偏差^[49].本文将径向基函数作为核函数.

ANN 是一种模拟人脑神经元之间信息传递、处理机制的数学模型^[50].输入数据后,经过多层神经元计算和激活函数处理,得到最终输出结果.其训练过程是通过反向传播算法,不断调整神经元之间的权重和偏置,使神经网络的输出结果接近真实结果^[51].本文采用的是单隐藏层神经网络结构.

KNN 回归模型最早于 1968 年由 Cover 等^[52]首先提出,其原理是将待测样本用其最近的 k 个相邻样本估计,把 k 个相邻样本属性的平均值赋给待测样本,最终将 k 个样本输出值的平均值作为预测值^[53].

所有过程均在 R Studio 中完成,采用“tidymodels”包,完成数据集划分、参数优化和最终建模.并且,采用 5 折交叉验证进行重抽样,使用网格搜索对 4 种建模方法进行超参数优化.超参数包包含 XGBoost 的“mtry”、“tree_depth”、“learn_rate”;SVM 的“cost”、“margin”;ANN 的“hidden_units”、“penalty”、“epochs”;KNN 的“neighbors”、“weight_func”.最终,得到最优超参数的植被氮含量估算模型.

1.7 模型验证

为了客观、全面地评价模型,选择决定系数(R^2)、均方根误差(RMSE)以及平均绝对误差(MAE)对模型进行综合评价,公式如下:

$$R^2 = \frac{\sum_{i=1}^n (M_i - \bar{M})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (M_i - \bar{M})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \quad (1)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (M_i - P_i)^2}{n}} \quad (2)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |M_i - P_i| \quad (3)$$

式中: M_i 为实测值, \bar{M} 为实测值的平均值, P_i 为预测模型的预测值, \bar{P} 为预测值的平均值, n 为样本数.

2 结果与分析

2.1 植被氮含量统计分析

实验共采集 240 个样本,剔除 11 个异常值,最终得到 229 个样本用于后续建模处理(表 5).整个数据集中,植被冠层氮含量变化范围为 1.45%~3.55%,均值为 2.49%,SD 为 0.47,变异系数为 19.0%.训练集和验证集的植被氮含量平均值分别为 2.48%和 2.49%,方差 SD 为 0.47 与 0.48,CV 为 18.9%和 19.3%,两者数据较为平均.

表 5 植被氮含量统计描述(%)

Table 5 Statistical description of vegetation nitrogen content (%)

| 数据 | Max | Min | Mean | SD | CV |
|----------|------|------|------|------|------|
| 总体(229) | 3.55 | 1.45 | 2.49 | 0.47 | 19.0 |
| 训练集(189) | 3.55 | 1.45 | 2.48 | 0.47 | 18.9 |
| 验证集(40) | 3.42 | 1.45 | 2.49 | 0.48 | 19.3 |

2.2 ASD 和 Resonon 数据可靠性验证




图 1 植被冠层的光谱曲线

Fig.1 Spectral curve of vegetation canopy




图 2 ASD 和 Resonon 光谱曲线对比

Fig.2 Comparison of ASD and Resonon spectral curves

利用 Arcgis 提取了植被光谱曲线(图 1).曲线具有绿色植被独有的绿峰、红谷以及红边特征,植被整体反射率较低,红边区域反射率值在 0.25 附近.

ASD 和 Resonon 两种仪器采集的光谱数据在绿峰和红谷附近有所差异,其他位置基本一致(图 2).两者 Pearson 相关系数为 0.94($P<0.01$),存在极显著相关.说明结合 ASD 来辅助无人机 Resonon 数据,对区域范围植被氮含量的估测是可靠的.

2.3 基于 ASD 高光谱数据的植被氮含量估测

2.3.1 植被氮含量与高光谱数据的相关性分析 图 3 为植被指数与氮含量的相关性分析,两者之间存在显著的正相关关系($P<0.05$),但相关系数较低.相关系数较高的植被指数为 EVI2、SPVI 和 mSR,相关系数分别为 0.46、0.36、0.33.而 SAV、mND705、TCARI 以及 EVI 等植被指数与氮含量之间相关性较弱($R<0.1$),其中 EVI 与氮含量相关性最差($R<0.01$).

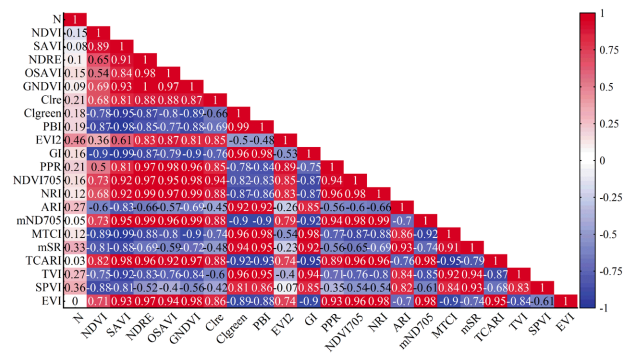


图 3 植被指数与氮含量的相关性分析

Fig.3 Correlation analysis between vegetation index and nitrogen content




图 4 “三边参数”与氮含量的相关性分析

Fig.4 Correlation analysis between 'trilateral parameter' and nitrogen content

图4为“三边参数”与氮含量之间的相关性分析,氮含量与“三边参数”存在极显著的相关关系($P<0.01$),植被氮含量与 Db 、 Dr 、 SDr 、 SDy 以及 $VI6$ 之间存在较好的相关性($|R|>0.4$),与 λr 、 Rg 、 Rr 、 $VI4$ 之间相关性较弱($|R|<0.1$),其中与 Dr 和 SDr 之间呈现最大正相关关系($R=0.54$),与 SDy 之间呈现最大负相关关系($R=-0.41$)。

图5为连续统去除参数与氮含量之间的相关性分析,植被氮含量与连续统去除参数之间整体相关性较弱,仅与最大吸收深度 H 和对称度 S 之间存在极显著的正相关关系($P<0.01$),相关系数为 0.22。

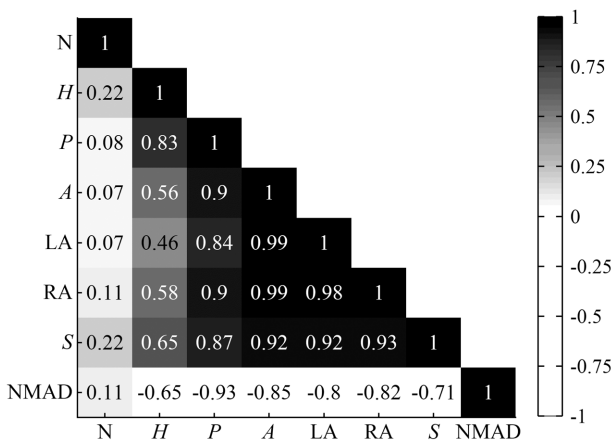


图5 连续统去除参数与氮含量的相关性分析

Fig.5 Correlation analysis between removal parameters of continuum and nitrogen content

图6为小波系数与植被氮含量相关系数热图.植被冠层光谱经过连续小波变换后,有效信息主要集中在中间的4~6尺度,而在1~3低尺度和7~9高尺度中相对较少.植被冠层氮含量的敏感小波特征区域在尺度5的491nm和541nm处,以及尺度6的817nm处,最佳小波特征为 $WF491,5$ ($R^2=0.363$).

2.3.2 LASSO特征筛选 利用LASSO能从4种光谱变量中选择对氮含量有显著影响的变量.经过LASSO方法特征筛选后,能筛选出的与植被氮含量相关性较好的变量,而且变量数量显著减少(表6).

2.3.3 植被氮含量估测模型及精度评价 通过LASSO特征筛选得到了与植被氮含量显著相关的4组变量,分别建立多元线性回归、XGBoost、SVM、ANN以及KNN共5种回归模型,并对比不同算法间

的差异确定最佳模型.




图6 小波系数与氮含量相关系数热图

Fig.6 Heatmap of correlation coefficient between wavelet coefficient and nitrogen content

表6 LASSO特征筛选结果

Table 6 LASSO feature screening results

| 变量类型 | 变量个数 | 变量 |
|---------|------|--|
| 植被指数 | 2 | EVI2、ARI、SPVI |
| “三边参数” | 3 | Db 、 Dr 、 $VI6$ |
| 连续统去除参数 | 3 | H 、 S 、 $NMAD$ |
| 小波系数 | 26 | 尺度1: $WF536$ 、 $WF608$ 、 $WF620$ 、 $WF621$ 、 $WF690$ 、 $WF691$ 、 $WF693$ 、 $WF699$ 、 $WF703$ 、 $WF738$ 、 $WF739$ 、 $WF995$; 尺度2: $WF520$ 、 $WF660$ 、 $WF696$ 、 $WF707$ 、 $WF957$; 尺度3: $WF657$ 、 $WF717$; 尺度4: $WF627$ 、 $WF788$ 、 $WF957$; 尺度5: $WF401$ 、 $WF573$ 、 $WF876$ 、 $WF927$ 、 $WF962$ |

表7为植被氮含量预测模型的精度检验,4种机器学习模型精度均高于多元线性模型.基于LASSO-植被指数变量的4种机器学习模型验证集 R^2 介于 0.60~0.68 之间, $RMSE$ 介于 0.27~0.30 之间, MAE 介于 0.19~0.21 之间; LASSO-“三边参数”的4种机器学习模型验证集 R^2 介于 0.50~0.64 之间, $RMSE$ 介于 0.27~0.36 之间, MAE 介于 0.19~0.29 之间; LASSO-连续统去除参数的4种机器学习模型精度较差,验证集 R^2 介于 0.18~0.22 之间, $RMSE$ 介于 0.42~0.44 之间, MAE 介于 0.30~0.32 之间; 基于LASSO-小波系数的4种机器学习模型验证集 R^2 介于 0.41~0.72 之间,模型之间性能差距较大,但以SVM算法构建的植被氮含量反演模型精度最高,可以解释72%的氮含量变化,并且 $RMSE$ 和 MAE 分别为 0.26 和 0.18,模型误差较小.

表 7 植被氮含量预测模型的精度检验
Table 7 Accuracy test of vegetation nitrogen content prediction model

| 输入变量 | 模型 | T-R ² | T-RMSE | T-MAE | V-R ² | V-RMSE | V-MAE |
|--------------|---------|------------------|--------|-------|------------------|--------|-------|
| LASSO-植被指数 | 多元线性回归 | 0.38 | 0.37 | 0.29 | 0.43 | 0.38 | 0.29 |
| | XGBoost | 0.71 | 0.26 | 0.19 | 0.60 | 0.30 | 0.21 |
| | SVM | 0.72 | 0.26 | 0.17 | 0.68 | 0.28 | 0.19 |
| | ANN | 0.72 | 0.24 | 0.18 | 0.68 | 0.27 | 0.19 |
| | KNN | 0.72 | 0.24 | 0.17 | 0.65 | 0.28 | 0.19 |
| LASSO-“三边参数” | 多元线性回归 | 0.36 | 0.38 | 0.30 | 0.26 | 0.41 | 0.34 |
| | XGBoost | 0.57 | 0.32 | 0.25 | 0.50 | 0.36 | 0.29 |
| | SVM | 0.61 | 0.29 | 0.18 | 0.63 | 0.27 | 0.19 |
| | ANN | 0.63 | 0.29 | 0.20 | 0.64 | 0.29 | 0.22 |
| | KNN | 0.64 | 0.28 | 0.21 | 0.55 | 0.32 | 0.22 |
| LASSO-统去除参数 | 多元线性回归 | 0.26 | 0.41 | 0.33 | 0.28 | 0.42 | 0.32 |
| | XGBoost | 0.42 | 0.37 | 0.30 | 0.20 | 0.44 | 0.32 |
| | SVM | 0.42 | 0.37 | 0.27 | 0.20 | 0.43 | 0.32 |
| | ANN | 0.44 | 0.35 | 0.26 | 0.22 | 0.42 | 0.30 |
| | KNN | 0.55 | 0.32 | 0.24 | 0.18 | 0.44 | 0.30 |
| LASSO-小波系数 | 多元线性回归 | 0.50 | 0.33 | 0.27 | 0.53 | 0.33 | 0.27 |
| | XGBoost | 0.76 | 0.24 | 0.18 | 0.60 | 0.31 | 0.25 |
| | SVM | 0.83 | 0.19 | 0.12 | 0.72 | 0.26 | 0.18 |
| | ANN | 0.88 | 0.16 | 0.12 | 0.41 | 0.39 | 0.31 |
| | KNN | 0.62 | 0.26 | 0.22 | 0.58 | 0.31 | 0.24 |

注: T为训练集, $n=189$;V为验证集, $n=40$.

图 7 为植被指数反演结果.KNN 模型精度最高($R^2=0.74$),与多元线性模型相比 R^2 提高了 0.36. 其余三种机器学习反演模型 R^2 介于 0.71~0.72 之间,均具有较好的估测精度.在模型验证精度上,XGBoost 模型验证 R^2 为 0.60,比建模精度下降了 18%,KNN 模型精度也下降了 14%.相比之下,SVM 和 ANN 模型验证精度仅有 5%差异,模型更加稳定可靠.

图 8 为“三边参数”反演结果,多元线性模型的拟合效果较差($R^2=0.36$).与其相比,4 种机器学习模型的建模 R^2 精度有所提升,介于 0.57~0.64 之间.在模型验证精度上,ANN 模型精度最高($R^2=0.64$),RMSE 和 MAE 分别为 0.29、0.22.预测点和实测点均匀分布在拟合线两侧,模型验证精度没有下降,表现稳定.

图 9 为连续统去除参数反演结果,五种模型拟合效果较差,建模 R^2 介于 0.26~0.55 之间,RMSE 和 MAE 分别介于 0.32~0.41 和 0.24~0.33 之间,

模型验证 R^2 介于 0.18~0.28 之间,RMSE 和 MAE 分别介于 0.42~0.44 和 0.30~0.32 之间.预测值和实测值的点在 1:1 线附近分布凌乱,模型拟合效果较差.

图 10 为小波系数反演结果,ANN 和 SVM 模型精度较高,建模 R^2 分别为 0.88 和 0.83,KNN 模型和多元线性模型精度较差, R^2 分别为 0.62 与 0.50.但在模型验证精度上,ANN 模型验证精度较低, $R^2=0.41$,RMSE 和 MAE 分别是 0.39 和 0.31,与建模精度相比出现下降,可能存在过拟合的现象.SVM 模型验证精度 R^2 为 0.72,与建模精度差异较小,模型更加稳定,且 RMSE 和 MAE 分别为 0.26、0.18,模型误差较低.

植被氮含量反演的最佳模型为基于小波系数的 SVM 模型,训练集和验证集分别反映了 83%和 72%的氮含量变化,对应的 RMSE 和 MAE 分别是 0.19、0.12 和 0.26、0.18.该模型性能最佳,也具备较好的稳定性.

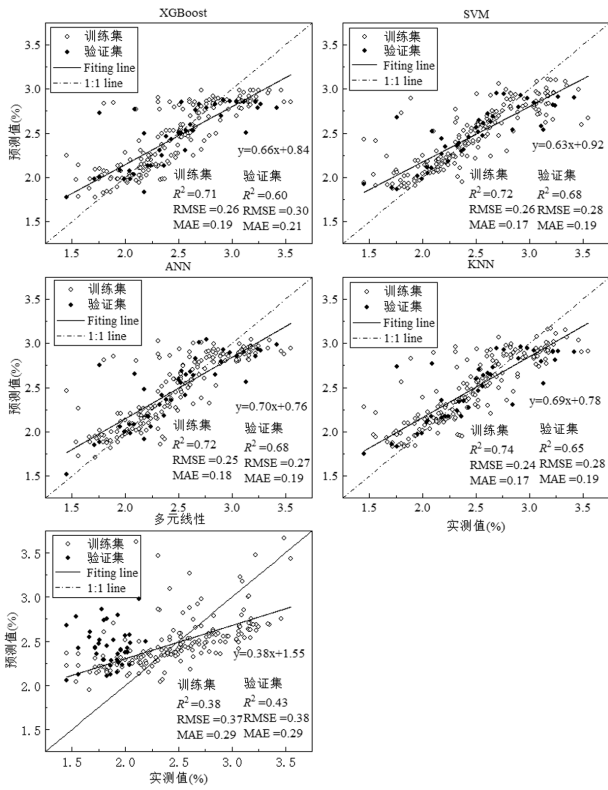


图7 植被指数反演结果

Fig.7 Vegetation index inversion results

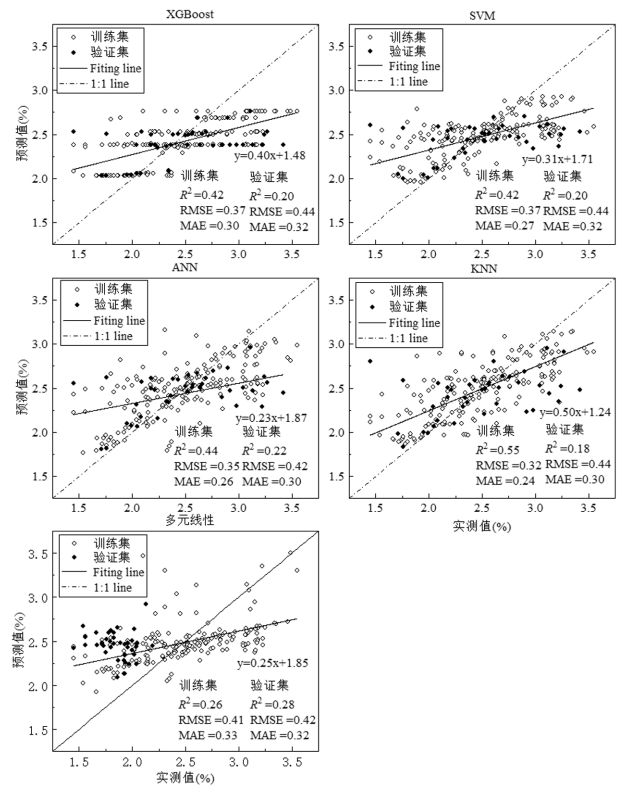


图9 连续统去除参数反演结果

Fig.9 Continuum removal parameter inversion results

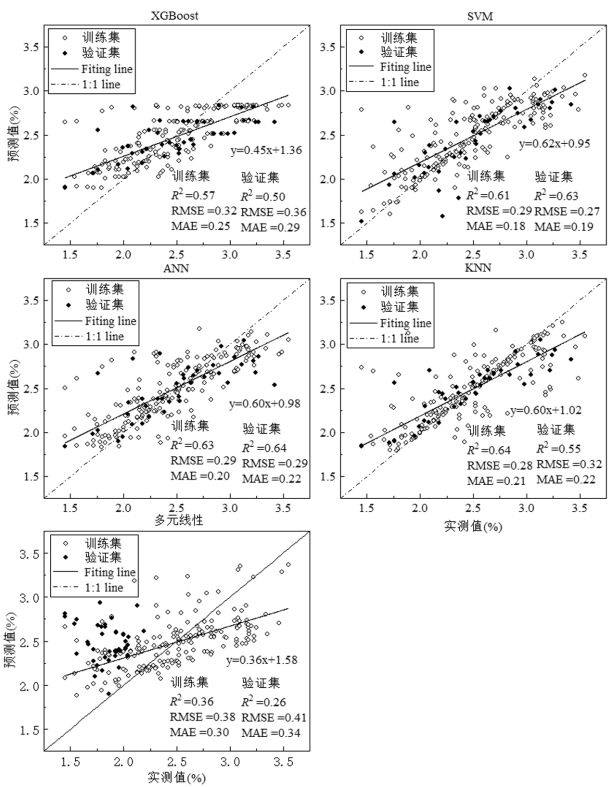


图8 “三边参数”反演结果

Fig.8 “trilateral parameter” inversion result

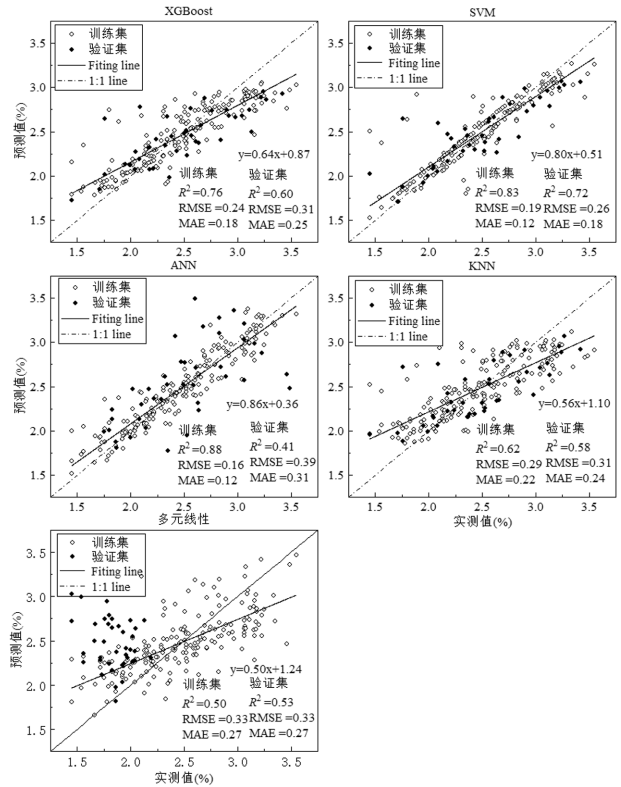


图10 小波系数反演结果

Fig.10 Wavelet coefficient inversion results

2.4 结合 ASD 的无人机高光谱影像反演

最终采用与 ASD 最佳反演模型相同的输入参数,构建基于无人机 Resonon 高光谱数据的 SVM 模型.模型训练集 $R^2=0.43$,RMSE 和 MAE 分别为 0.41 和 0.32,验证集 $R^2=0.41$,RMSE 和 MAE 分别为 0.42 和 0.32(图 11).




图 11 基于 Resonon 数据的小波系数-SVM 反演结果
Fig.11 Wavelet coefficient-SVM inversion results based on Resonon data

将无人机影像数据输入到基于小波系数构建的 SVM 氮反演模型中,最终获得样地区域植被氮含量的空间分布(图 12).




图 12 研究区植被氮含量空间分布
Fig.12 Spatial distribution of vegetation nitrogen content in the study area

3 讨论

利用 ASD 和无人机高光谱进行草原植被氮含量估测,能帮助牧场提高牧草品质,对草地的合理利用提供帮助.高光谱数据包含大量冗余信息,可能会产生多重共线性和高维性问题^[54].因此,本文探究不同光谱变换方法和机器学习算法估算植被氮含量的能力.

高光谱敏感参数的提取,以小波系数为自变量的反演模型精度最优,对应的小波特征的位置位于可见光和近红外(VNIR)区域.大多数研究都采用 VNIR 光谱指数来估算氮浓度^[55].VNIR 主要识别与叶绿素相关的氮^[56].大部分敏感波段集中在红边和近红外区域,与植物生化参数之间存在着很强的相关性^[57-58].此外,红边区域的某些波段和参数(如红边斜率、红边位置、红边斜率等)对植物的生化参数有较高的敏感性^[59-60].

在模型选择上,采用多元线性、XGBoost、SVM、ANN 和 KNN 五种建模方法.虽然小波系数-SVM 方法取得了较好的模型性能,但机器学习模型解释性相对较差.后续需累积野外试验数据、增加样本数据量、增加植被冠层和叶片参数数据来尝试使用物理模型反演植被氮素含量.

本文虽然通过结合 ASD 非成像高光谱和无人机成像高光谱数据完成了区域草地植被氮含量的反演,但将基于 ASD 数据的最佳氮估测模型的参数选择和建模方法应用到 Resonon 数据上时,模型性能出现下降.这可能是由于 ASD 以较高的光谱分辨率(1nm)所获得的敏感光谱参数在应用到 Resonon 数据(2.1nm)上产生了差异所导致的,也可能是在数据采集阶段仪器受到噪音干扰产生了误差,后续将深入研究两种传感器数据融合的更优方法.

4 结论

4.1 基于 ASD 数据的植被氮含量反演中,以小波系数-SVM 方法构建的氮估测模型精度最高,训练集 $R^2=0.83$,RMSE 和 MAE 分别为 0.19 和 0.12,验证集 $R^2=0.72$,RMSE 和 MAE 分别为 0.26 和 0.18.

4.2 以小波系数-SVM 方法构建基于无人机 Resonon 数据的植被氮含量反演模型,建模 $R^2=0.43$, RMSE 和 MAE 分别为 0.41 和 0.32,验证 $R^2=0.41$,

RMSE 和 MAE 分别为 0.42 和 0.32.

4.3 对比不同光谱参数,小波系数对内蒙古典型草原植被 N 浓度敏感性要相对高于作其他参数,特别在尺度 5 和尺度 6 出现较高 R^2 的小波系数.

4.4 对比 4 种不同的建模方法,SVM 模型表现出较高的植被氮浓度估算精度与稳定性.机器学习具有较强的大数据处理能力,能对高光谱数据进行深入挖掘.

参考文献:

- [1] Qin P, Sun B, Li Z, et al. Estimation of grassland carrying capacity by applying high spatiotemporal remote sensing techniques in Zhenglan Banner, Inner Mongolia, China [J]. *Sustainability*, 2021,13(6):3123.
- [2] 王秀梅,董建军.基于广义线性模型估算内蒙古荒漠草原及典型草原地上生物量变化 [J]. *草地学报*, 2020,28(6):1711-1718.
Wang X M, Dong J J. Estimation of the aboveground biomass of desert Steppe and typical steppe in Inner Mongolia using generalized linear model [J]. *Acta Agrestia Sinica*, 2020,28(6):1711-1718.
- [3] Fay P A, Prober S M, Harpole W S, et al. Grassland productivity limited by multiple nutrients [J]. *Nature Plants*, 2015,1(7):1-5.
- [4] 巴哈提汗·比山.草原畜牧与生态环境保护存在的问题及改进措施 [J]. *畜牧兽医科学(电子版)*, 2021,(13):194-195.
Bahatihan Bishan. Problems and improvement measures of grassland animal husbandry and ecological environment protection in [J]. *Graziery Veterinary Sciences (Electronic Version)* 2021,(13):194-195.
- [5] Riggs C E, Hobbie S E, Bach E M, et al. Nitrogen addition changes grassland soil organic matter decomposition [J]. *Biogeochemistry*, 2015,125:203-219.
- [6] He J S, Wang L, Flynn D F B, et al. Leaf nitrogen: phosphorus stoichiometry across Chinese grassland biomes [J]. *Oecologia*, 2008, 155:301-310.
- [7] Beeri O, Phillips R, Hendrickson J, et al. Estimating forage quantity and quality using aerial hyperspectral imagery for northern mixed- grass prairie [J]. *Remote Sensing of Environment*, 2007,110(2):216-225.
- [8] Mutanga O, Adam E, Adjorlolo C, et al. Evaluating the robustness of models developed from field spectral data in predicting African grass foliar nitrogen concentration using WorldView-2 image as an independent test dataset [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2015,34:178-187.
- [9] 王晶晶,孙玲,刘华周,等.基于高光谱的凤眼莲植株氮含量无损监测 [J]. *江苏农业学报*, 2014,30(4):752-757.
Wang J J, Sun L, Liu H Z, et al. Non-destructive estimation of nitrogen concentration of water hyacinth based on hyperspectral reflectance [J]. *Jiangsu Journal of Agricultural Sciences*, 2014,30(4): 752-757.
- [10] Bao N, Li W, Gu X, et al. Biomass estimation for semiarid vegetation and mine rehabilitation using worldview-3 and sentinel-1 SAR imagery [J]. *Remote Sensing*, 2019,11(23):2855.
- [11] 田永超,杨杰,姚霞,等.利用叶片高光谱指数预测水稻群体叶层全氮含量 [J]. *作物学报*, 2010,36(9):1529-1537.
Tian Y C, Yang J, Yao X, et al. Monitoring canopy leaf nitrogen concentration based on leaf hyperspectral indices in rice [J]. *Acta Agronomica Sinica*, 2010,36(9):1529-1537.
- [12] 王念一,于丰华,许童羽,等.基于机器学习的粳稻叶片叶绿素含量高光谱反演建模 [J]. *浙江农业学报*, 2020,32(2):359-366.
Wang N Y, Yu F H, Xu T Y, et al. Hyperspectral retrieval modelling for chlorophyll contents of japonica-rice leaves based on machine learning [J]. *Acta Agriculturae Zhejiangensis*, 2020,32(2):359-366.
- [13] 冯海宽,樊意广,陶惠林,等.利用无人机高光谱影像的冬小麦氮含量监测 [J]. *光谱学与光谱分析*, 2023,43(10):3239-3246.
Feng H K, Fan Y G, Tao H L, et al. Monitoring of nitrogen content in winter wheat based on UAV hyperspectral imagery [J]. *Spectroscopy and Spectral Analysis*, 2023,43(10):3239-3246.
- [14] 孙法福,赖宁,耿庆龙,等.基于无人机高光谱影像的冬小麦叶片氮浓度遥感估测 [J]. *干旱区研究*, 2024,41(6):1069-1078.
Sun F F, Lai N, Geng Q L, et al. Estimation of nitrogen concentration in winter wheat leaves based on hyperspectral images of UAV [J]. *Arid Zone Research*, 2024,41(6):1069-1078.
- [15] Gao J, Meng B, Liang T, et al. Modeling alpine grassland forage phosphorus based on hyperspectral remote sensing and a multi-factor machine learning algorithm in the east of Tibetan Plateau, China [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019,147:104-117.
- [16] Wu N T, Liu G X, Yang Y, et al. Dynamic monitoring of net primary productivity and its response to climate factors in native grassland in Inner Mongolia using a light-use efficiency model [J]. *Acta Prataculturae Sinica*, 2020,29(11):1-10.
- [17] Savitzky A, Golay E J M. Smoothing and differentiation of data by simplified least squares procedures. [J]. *Anal Chem*, 2002,36(8):1627-1639.
- [18] Tucker C J. Red and photographic infrared linear combinations for monitoring vegetation [J]. *Remote Sensing of Environment*, 1979, 8(2):127-150.
- [19] Huete A R. A soil-adjusted vegetation index (SAVI) [J]. *Remote Sensing of Environment*, 1988,25(3):295-309.
- [20] Barnes E M, Clarke T, Richards S E, et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data [C]. *proceedings of the Proceedings of the fifth international conference on precision agriculture*, Bloomington, MN, USA, 2000:1356.
- [21] Rondeaux G, Steven M, Baret F. Optimization of soil-adjusted vegetation indices [J]. *Remote sensing of environment*, 1996,24: 109-127.
- [22] Gitelson A A, Kaufman Y J, Merzlyak N M. Use of a green channel in remote sensing of global vegetation from EOS-MODIS [J]. *Remote Sensing of Environment*, 1996,58(3):289-298.
- [23] Gitelson A A, Gritz Y, Merzlyak N M. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves [J]. *Journal of Plant Physiology*, 2003,160(3):271-282.
- [24] Rao R N, Garg K P, Ghosh K S, et al. Estimation of leaf total chlorophyll and nitrogen concentrations using hyperspectral satellite imagery [J]. *The Journal of Agricultural Science*, 2008,146(1):65-75.
- [25] Jiang Z Y, Huete R A, Didan K, et al. Development of a two-band enhanced vegetation index without a blue band [J]. *Remote Sensing of Environment*, 2008,112(10):3833-3845.
- [26] Peuelas J, Gamon J A, Fredeen A L, et al. Reflectance indices associated with physiological changes in nitrogen- and water-limited sunflower leaves [J]. *Remote Sensing of Environment*, 1994,48(2): 135-146.
- [27] Gitelson A, Merzlyak M N. Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. spectral features and relation to chlorophyll estimation [J]. *Journal of Plant Physiology*, 1994,143(3):286-292.

- [28] Schleicher T D, Bausch W C, Delgado J A, et al. Evaluation and refinement of the nitrogen reflectance index (nri) for site-specific fertilizer management. proceedings of the 2001ASAE Annual Meeting [C]. 1998.
- [29] Gitelson A A, Merzlyak M N, Chivkunova O B. Optical properties and nondestructive estimation of anthocyanin content in plant leaves [J]. *Photochemistry and Photobiology* 2001,74(1):38-45.
- [30] Sims A D, Gamon A J. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages [J]. *Remote Sensing of Environment*, 2002,81(2): 337-354.
- [31] Dash J, Curran J P. The MERIS terrestrial chlorophyll index [J]. *International Journal of Remote Sensing*, 2004,25(23):5403-5413.
- [32] Haboudane D, Miller R J, Tremblay N, et al. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture [J]. *Remote Sensing of Environment*, 2002,81(2):416-426.
- [33] Broge N, 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.
- [34] Vincini M, Frazzi E, D'alessio P. Angular dependence of maize and sugar beet VIs from directional CHRIS/Proba data [C]. Proceedings of the Proc 4th Esa Chris proba Workshop, 2006.
- [35] Huete A, Didan K, Miura T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices [J]. *Remote Sensing of Environment*, 2002,83(1):195-213.
- [36] Wang X, Xu G, Feng Y, et al. Estimation model of rice aboveground dry biomass based on the machine learning and hyperspectral characteristic parameters of the canopy [J]. *Agronomy*, 2023,13(7):1940.
- [37] Li C C, Chen P, Ma C Y, et al. Estimation of potato chlorophyll content using composite hyperspectral index parameters collected by an unmanned aerial vehicle [J]. *International Journal of Remote Sensing*, 2020,41(21):8176-8197.
- [38] Kong B, Yu H, Du R, et al. Quantitative estimation of biomass of alpine grasslands using hyperspectral remote sensing [J]. *Rangeland Ecology & Management*, 2019,72(2):336-346.
- [39] Zhang J C, Pu R L, Loraamm R W, et al. Comparison between wavelet spectral features and conventional spectral features in detecting yellow rust for winter wheat [J]. *Computers and Electronics in Agriculture*, 2014,100:79-87.
- [40] Wang Z L, Chen J X, Fan Y F, et al. Evaluating photosynthetic pigment contents of maize using UVE-PLS based on continuous wavelet transform [J]. *Computers and Electronics in Agriculture*, 2020, 169:105160.
- [41] Gu X, Wang Y, Sun Q, et al. Hyperspectral inversion of soil organic matter content in cultivated land based on wavelet transform [J]. *Computers and Electronics in Agriculture*, 2019,167:105053.
- [42] Zhuang T, Zhang Y, Li D, et al. Coupling continuous wavelet transform with machine learning to improve water status prediction in winter wheat [J]. *Precision Agriculture*, 2023,24:2171-2129.
- [43] Zhang J, Wang W, Qiao H, et al. Estimation of leaf nitrogen content in winter wheat based on continuum removal and discrete wavelet transform [J]. *International Journal of Remote Sensing*, 2023,44(18): 5523-5547.
- [44] Huang Z, Turner B J, Dury S J, et al. Estimating foliage nitrogen concentration from HYMAP data using continuum removal analysis [J]. *Remote Sensing of Environment*, 2004,93(1/2):18-29.
- [45] Tibshirani R. Regression shrinkage and selection via the lasso [J]. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 1996,58(1):267-288.
- [46] Moghimi A, Pourreza A, Zuniga-Ramirez G, et al. A novel machine learning approach to estimate grapevine leaf nitrogen concentration using aerial multispectral imagery [J]. *Remote Sensing*, 2020,12(21):3515.
- [47] Sudu B, Rong G, Guga S, et al. Retrieving SPAD values of summer maize using UAV hyperspectral data based on multiple machine learning algorithm [J]. *Remote Sensing*, 2022,14(21):5407.
- [48] Cortes C, Vapnik V. Support-vector networks [J]. *Machine learning*, 1995,20:273-297.
- [49] Mountrakis G, Im J, Ogole C. Support vector machines in remote sensing: A review [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2011,66(3):247-259.
- [50] Atkinson P M, Tatnall A R. Introduction neural networks in remote sensing [J]. *International Journal of Remote Sensing*, 1997,18(4):699-709.
- [51] Wang L, Chang Q, LI F, et al. Effects of growth stage development on paddy rice leaf area index prediction models [J]. *Remote Sensing*, 2019,11(3):361.
- [52] Cover T, Hart P. Nearest neighbor pattern classification [J]. *IEEE Transactions on Information Theory*, 1967,13(1):21-27.
- [53] Liu X, Zhang Z, Jiang T, et al. Evaluation of the effectiveness of multiple machine learning methods in remote sensing quantitative retrieval of suspended matter concentrations: A case study of Nansi Lake in North China [J]. *Journal of Spectroscopy*, 2021,2021:1-17.
- [54] Yi Q X, Huang J F, Wang F M, et al. Monitoring rice nitrogen status using hyperspectral reflectance and artificial neural network [J]. *Environmental Science & Technology*, 2007,41(19):6770-6775.
- [55] Alexander J, Hubert H, Ellen A H, et al. Investigating the potential of a newly developed UAV-mounted VNIR/SWIR imaging system for monitoring crop traits—a case study for winter wheat [J]. *Remote Sensing*, 2021,13(9):1697.
- [56] Stroppiana D, Fava F, Boschetti M, et al. Estimation of nitrogen content in herbaceous plants using hyperspectral vegetation indices [M]. *Hyperspectral Indices and Image Classifications for Agriculture and Vegetation*, 2019.
- [57] Murray A B. Reducing model complexity for explanation and prediction [J]. *Geomorphology*, 2007,90(3/4):178-191.
- [58] Clevers J G P W, Kooistra L. Using hyperspectral remote sensing data for retrieving total canopy chlorophyll and nitrogen content [C]. proceedings of the 2011 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), 2011.
- [59] Chakraborty S K, Mahanti N K, Mansuri S M, et al. Non-destructive classification and prediction of aflatoxin-B1 concentration in maize kernels using Vis-NIR (400~1000nm) hyperspectral imaging [J]. *Journal of Food Science and Technology*, 2021,58(2):437-450.
- [60] Knox M N, Skidmore K A, Prins H H, et al. Remote sensing of forage nutrients: Combining ecological and spectral absorption feature data [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2012, 72(1):27-35.

致谢: 本实验的场地由内蒙古大学草地生态学研究基地提供,在此表示感谢。

作者简介: 金利山(2001-),男,甘肃武威人,硕士研究生,主要从事高光谱遥感研究.发表论文 2 篇.20231800232@imut.edu.cn.