doi:10.6041/j.issn.1000-1298.2026.17.015

融合时序 RGB-多光谱的油菜冠层叶片氮监测模型与追肥处方图构建方法

曾繁国[1,2]　丁幼春[1,2]　张栋津[1,2]　董万静[1,2]　邢肖扬[1,2]　徐春保[1,2]
沈志强[1,2]　王思达[1,2]
(1.华中农业大学工学院,武汉 430070;2.农业农村部长江中下游农业装备重点实验室,武汉 430070)

摘要:氮元素含量是表征作物生长状况的重要指标,氮含量监测对作物生长发育和施肥管理决策具有重要意义。针对传统氮含量监测精度不足、成本高、空间覆盖有限等问题,提出了一种融合时序 RGB-多光谱的油菜氮监测与追肥处方图构建方法。首先利用大疆 Mavic 3M 型多光谱无人机,连续两年采集试验田油菜冠层叶片氮含量值和对应油菜生育关键期 RGB 与多光谱时序遥感影像,建立了冠层 RGB 与多光谱特征组合;采用相关性分析方法筛选对油菜叶氮敏感的特征,通过最大相关和最小冗余(Maximum relevance and minimum redundancy, mRMR)算法对筛选后特征值进行重要性排序,将排序后特征值依次利用随机森林(Random forest, RF)、岭回归(Ridge regression, RR)、支持向量回归(Support vector regression, SVR)、梯度提升回归(Gradient boosting regression, GBR)模型获取最优时序特征组合,用于构建苗期(六叶期)、越冬期和蕾薹期氮监测模型;根据种植区域的油菜氮含量分布图,对田块进行栅格划分并决策追肥量,生成了油菜追肥处方图。数据分析结果显示:基于 RF 模型、融合多生育期时序信息的 RGB 与多光谱最优特征组合(LCI、MSAVI、NDVI、ExG、TH)监测效果最佳,可同时监测六叶期、越冬期和蕾薹期氮含量,R^2 分别为 0.825、0.800 和 0.806,RMSE 分别为 0.210%、0.231% 和 0.217%;相较于仅使用单一生育期数据建模,融合时序信息后六叶期、越冬期和蕾薹期的 R^2 分别提高了 0.100、0.036 和 0.061。通过分析无人机 20~50 m 不同飞行高度对监测精度的影响,确定了 40 m 为油菜氮含量监测的适宜飞行高度,六叶期、越冬期和蕾薹期的 R^2 分别为 0.792、0.770 和 0.787。研究表明,融合时序 RGB-多光谱可有效监测油菜冠层叶片氮含量,研究结果可为油菜作物氮营养精准管理与追肥处方决策提供理论依据和技术参考。

关键词:油菜;氮含量监测;无人机;多光谱;时序;植被指数
中图分类号:S126;S565　　**文献标识码**:A　　**文章编号**:1000-1298(2026)17-0152-13　　**OSID**:

Integrated Time-series RGB – Multispectral Approach for Canopy Leaf Nitrogen Monitoring Model and Topdressing Prescription Mapping in Rapeseed

Zeng Fanguo[1,2]　Ding Youchun[1,2]　Zhang Dongjin[1,2]　Dong Wanjing[1,2]　Xing Xiaoyang[1,2]
Xu Chunbao[1,2]　Shen Zhiqiang[1,2]　Wang Sida[1,2]
(1. *College of Engineering*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*
2. *Key Laboratory of Agricultural Equipment in Mid-lower Yangtze River*, *Ministry of Agriculture and Rural Affairs*, *Wuhan* 430070, *China*)

Abstract: Nitrogen content is a crucial indicator for assessing crop growth status, and its monitoring plays an important role in crop growth, development, and fertilization management decisions. Aiming to address the limitations of traditional nitrogen monitoring methods, including insufficient accuracy, high costs, and limited spatial coverage, a method was proposed for monitoring nitrogen content in rapeseed and constructing topdressing prescription maps by integrating time-series RGB and multispectral features. Firstly, a DJI Mavic 3M multispectral drone was used to collect canopy leaf nitrogen content values and corresponding time-series RGB and multispectral remote sensing images of rapeseed during key growth stages over two consecutive years, and a combination of canopy RGB and multispectral features was

收稿日期:2026-01-20　修回日期:2026-04-20
基金项目:国家重点研发计划项目(2023YFD2001001、2023YFD2001001-1)和湖北省农业关键核心技术攻关项目(HBNYHXGG2023-2)
作者简介:曾繁国(1997—),男,博士生,主要从事智慧农业技术与装备研究,E-mail:zengfg9896@163.com
通信作者:丁幼春(1978—),男,教授,博士生导师,主要从事智慧农业技术与装备研究,E-mail:kingbug163@163.com

established. Correlation analysis was employed to identify the features sensitive to rapeseed leaf nitrogen content, and the maximum relevance and minimum redundancy (mRMR) algorithm was applied to rank the importance of the selected features. The ranked features were then sequentially input into random forest (RF), ridge regression (RR), support vector regression (SVR), and gradient boosting regression (GBR) models to obtain the optimal time-series feature combination for constructing nitrogen content monitoring models at the seedling stage (six-leaf stage), overwintering stage, and bolting stage. Based on the nitrogen content distribution map of the rapeseed planting area, the field was divided into grids to determine topdressing rates, and a rapeseed topdressing prescription map was generated. The data analysis results showed that the optimal feature combination based on the RF model and integrating multi-growth-stage time-series information (LCI, MSAVI, NDVI, ExG, TH) achieved the best monitoring performance, with R^2 values of 0.825, 0.800, and 0.806 and RMSE values of 0.210%, 0.231%, and 0.217% for the six-leaf stage, overwintering stage, and bolting stage, respectively. Compared with modeling using only single-growth-stage data, the integration of time-series information improved the R^2 values for the six-leaf stage, overwintering stage, and bolting stage by 0.100, 0.036, and 0.061, respectively. Additionally, by analyzing the effect of different UAV flight altitudes (20 ~ 50 m) on monitoring accuracy, 40 m was determined as the optimal flight altitude for rapeseed nitrogen content monitoring, with R^2 values of 0.792, 0.770, and 0.787 at the six-leaf stage, overwintering stage, and bolting stage, respectively. The research result demonstrated that integrating time-series RGB and multispectral features could effectively monitor nitrogen content in rapeseed canopy leaves. The findings can provide a theoretical basis and technical reference for precision nitrogen management and topdressing prescription decisions in rapeseed crops.

Key words: rapeseed; nitrogen content monitoring; UAV; multispectral; time series; vegetation index

0　引言

油菜是我国最重要的油料作物之一，在农业生产中占有重要地位[1-2]。氮元素是作物的关键营养物质和表征作物生长状况的重要指标，氮含量监测对作物生长发育和施肥管理决策具有重要意义[3]，氮肥施用不足或者过量均会影响作物的生长发育，进而影响产量和品质[4]。在油菜生长过程中，实时掌握油菜氮养分状况，构建追肥量决策方法，并及时对缺氮油菜田追施氮肥，对区域油菜生产精细化、精准化和实现油菜产业高质量发展具有重要意义[5]。

传统油菜氮估测方法以田间破坏性采样和实验室测定为主，测定结果比较精确，但难以实现大面积无损诊断[6]。目前，作物氮含量监测方法主要基于作物叶片尺度的地面监测、卫星遥感以及无人机近地遥感[7]。由于叶绿素浓度与植株氮含量紧密相关，叶绿素含量常用于评估作物氮营养丰缺状况，因此叶绿素 SPAD 仪逐渐被应用于地面作物氮快速、无损诊断，该方式具有简便、低耗等优点[8]。然而其测试敏感性易受作物品种、生育时期和叶片厚度等因素影响，在实际应用时需采取合理有效的数据分析措施以校正其偏差[9]。同时，专家学者开展了手持式相机作物氮元素监测方法研究[10-11]，证实了作物可见光图像监测氮元素的可行性，该方式易受相机类型、拍摄时间等因素影响，对数据采集、处理等操作具有严格要求。

遥感技术因其具备监测覆盖面积广、包含的光谱信息能较好反映农作物生长情况等优势，被应用于作物养分监测[12]。卫星遥感具有数据获取周期短、探测范围大等特点，在使用过程中可获取大块、连续农田图像，常用于大面积农情监测，然而其分辨率较低，监测精度易受云覆盖和气象等自然条件干扰[13]。无人机近地遥感技术具有高精度信息获取、多指标信息采集和机动性高等优势，许多国内外研究学者在无人机遥感图像信息的农作物生长状况监测、农作物管理等领域做了大量的研究并取得了较好结果[14-15]。已有研究[7,16]多基于 RGB 或多光谱等单一类别特征开展作物营养元素的监测研究，进而生成作物追肥量决策方法。然而，RGB 特征（如颜色、纹理）易受光照影响，而多光谱特征包含的光谱信息又相对有限[17]。与单一特征相比，多源特征融合可提升监测精度，但会引入高维冗余，降低模型效率[18]。同时，仅依赖单一生育期的数据，难以全面反映作物生长过程中的氮素相关特征的动态变化，导致无法同时监测多个生育期，或监测多个生育期精度不足，难以构建有效的油菜氮含量监测和追肥量决策模型。

基于此，本文提出一种融合时序 RGB-多光谱的油菜氮监测与追肥处方图构建方法，获取 RGB-多光谱特征值，采用相关性分析方法筛选特征值之间的相关性，基于最大相关和最小冗余算法（Maximum relevance and minimum redundancy

algorithm, mRMR)对筛选后特征值重要性排序后,将特征值依次递增输入随机森林(Random forest, RF)、岭回归(Ridge regression, RR)、支持向量回归(Support vector regression, SVR)、梯度提升回归(Gradient boosting regression, GBR)模型,提取最优特征组合,并进一步融合关键生育期的时序信息,以构建高效的油菜氮含量监测模型。在此基础上,根据种植区域的油菜氮含量分布图,对田块进行栅格划分并决策追肥量,生成油菜追肥处方图,以期为油菜作物氮营养精准管理提供理论依据和技术参考。

1 材料与方法

1.1 研究区域概况

本文研究区域位于湖北省襄阳市襄州区无人化试验示范农场(32°08′06″N, 112°19′27″E, 海拔105 m),研究区域及试验区域如图 1 所示。该地区属亚热带湿润季风气候,气候特点为四季分明,冬季温和湿润,夏季高温多雨,年平均降水量为878.3 mm,年均气温 15.3 ~ 15.8℃,为油菜的生长发育提供了良好环境。本研究以关键生育期油菜为研究对象,开展油菜冠层叶片氮含量监测研究。

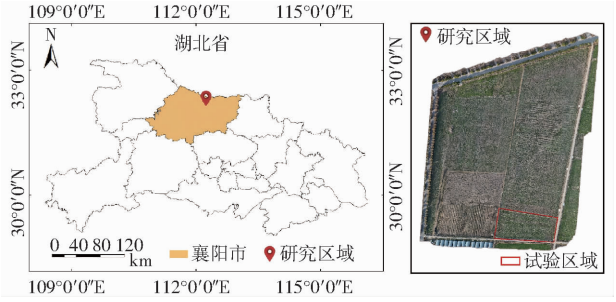

图 1 研究区域及试验区域

Fig. 1 Research area and experimental area

1.2 试验设计

试验于 2023—2024 年和 2024—2025 年在上述试验田进行,涵盖 2 个完整的油菜生长季。该区域施肥作业方式为智能农机精量施肥,保证了施肥的精量性和均匀性。供测试油菜种植品种为“中油杂19”,设置了 4 个施肥梯度(CK、N1、N2 和 N3),5 次重复,共 20 个区块,每个小区尺寸为 2.3 m × 100 m。其中,CK 为对照组,不施用基肥;N2 为当地标准氮肥施用水平,施用量为 600 kg/hm^2;N1 为低氮水平,施用量为 300 kg/hm^2;N3 为高氮水平,施用量为 900 kg/hm^2。同时,设置了一块农学专家推荐施肥及追肥方式管理小区(AE),试验区域设计如图 2 所示,试验中 AE 小区的专家推荐施肥方案为:基肥施用 600 kg/hm^2,六叶期、越冬期和蕾薹期的氮肥追用量分别为 90、90、120 kg/hm^2。油菜种植前耕层土壤表层(0 ~ 25 cm)基础养分状况如表 1 所示,该区域水分与病虫害等管理措施遵循当地冬油菜田间标准。其中,2023—2024 年试验数据主要用于建模分析,2024—2025 年试验数据用于模型验证。

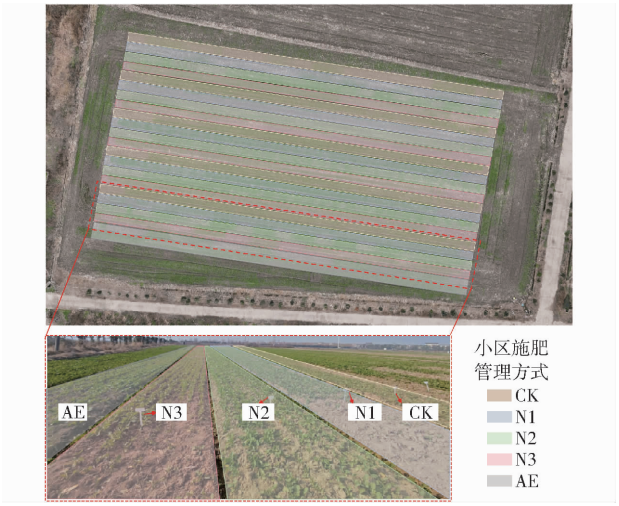

图 2 试验区域设计

Fig. 2 Experimental area design

表 1 试验田土壤基础养分状况

Tab. 1 Soil fertility status of experimental fields

年份	pH 值	有机质含量/(g·kg^{-1})	铵态氮含量/(mg·kg^{-1})	有效磷含量/(mg·kg^{-1})	速效钾含量/(mg·kg^{-1})
2023—2024	6.2	18.2	42.8	58.0	171.9
2024—2025	6.0	22.6	48.5	60.5	154.3

1.3 数据获取

本研究数据采集时间为 2023—2025 年,通过连续 2 年田间试验,获取了 2 个完整生长季的油菜冠层叶片氮含量实测数据及时序 RGB 与多光谱遥感影像。油菜数据获取时间及对应油菜生育关键期如图 3 所示,每个生长季包含 10 次关键生育期,主要包括苗期(出苗期、二叶期、四叶期和六叶期)、越冬前期、越冬后期、蕾薹期、开花期、角果期和成熟期。

1.3.1 无人机可见光-多光谱遥感影像获取

数据采集平台为大疆 Mavic 3M 型四旋翼无人机,该设备搭载 1 个可见光相机及 4 个多光谱相机,飞行时会同时拍摄同一位置的 5 个波段通道的图像,最大连续作业时长可达 43 min。其中,可见光相机通道为 4/3 英寸 CMOS,2 000 万有效像素;多光谱相机分别包含绿(G,中心波长(560 ± 16) nm)、红(R,中心波长(650 ± 16) nm)、红边(RE,中心波长(730 ± 16) nm)、近红外(NIR,中心波长(860 ± 26) nm)不同波段。无人机顶部集成多光谱光强传感器,可捕捉太阳辐照度并记录于影像文件中,校正太阳光照对影像造成的影响,提高了不同光线强度下数据采集的准确性与一致性。无人机数据采集平台如

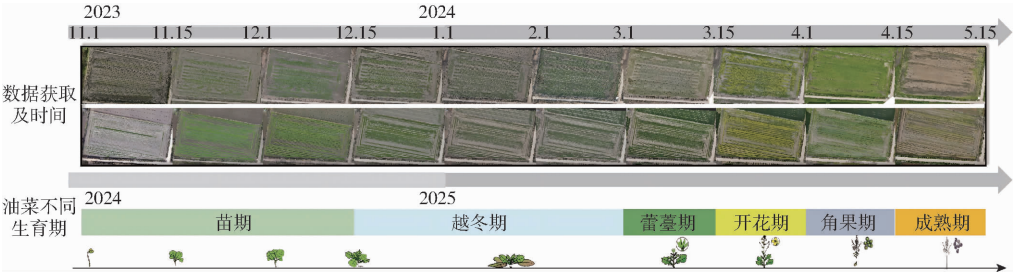

图 3　油菜时序数据获取时间及对应油菜生育关键期

Fig. 3　Acquisition times and corresponding key growth stages of rapeseed in time-series data

图 4 所示，垂直地面飞行，设置无人机自动拍摄间隔为 3 s，航向重叠度 80%，旁向重叠度 70%，以全面覆盖目标区域。

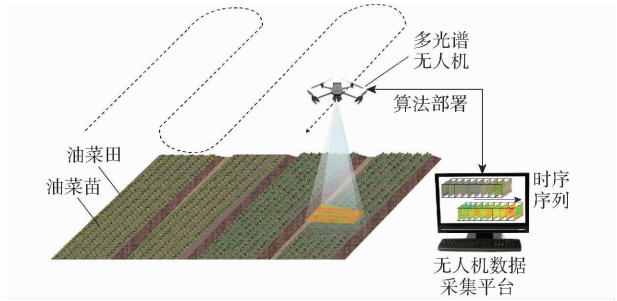

图 4　无人机数据采集平台

Fig. 4　Unmanned aerial vehicle data collection platform

为探究数据采集时无人机不同飞行高度对油菜冠层叶片氮含量检测的影响，在采集数据过程中，分别获取了不同飞行高度的遥感影像，飞行高度分别设置为 20、30、40、50 m，试验在晴天、微风条件下进行。

1.3.2　油菜冠层叶片氮素含量测定

为测定油菜冠层叶片氮素含量，记录采样点 0.5 m×0.5 m 中心点后，在该范围内对油菜植株进行随机取样，采集具有代表性的冠层叶片，并记录经纬度坐标，快速封装后带回实验室测定油菜冠层叶片氮元素含量。带回实验室后，设置烘干箱温度为 80℃，将叶片连续烘干 12 h 至恒质量，使用研磨机对烘干后的油菜叶片研磨至粉末，最后采用凯氏定氮法检测叶片氮元素含量。最后，通过采样点经纬度坐标与正射影像的对应关系，精确提取每个预设地面采样点对应影像位置的 RGB 与多光谱特征值。

油菜苗期（六叶期）、越冬期和蕾薹期为油菜追肥关键期，为构建 3 个关键期氮含量监测模型，分别在不同施肥梯度（CK、N1、N2 和 N3）试验田内随机、均匀采集油菜样本，用于测定氮含量。2023—2024 年六叶期、越冬期和蕾薹期分别获取有效数据 80 个，共获取 240 个样本用于氮含量建模及分析，其中，油菜冠层叶片氮质量分数最大值、最小值和平均值分别为 5.15%、2.50% 和 4.00%，标准差为 0.65%，变异系数为 16.3%，满足油菜冠层叶片氮含量监测建模要求。2024—2025 年六叶期、越冬期和蕾薹期分别获取有效数据 24 个，共获取 72 个样本用于氮含量模型验证，其中，油菜冠层叶片氮质量分数最大值、最小值和平均值分别为 5.20%、2.80% 和 4.16%，标准差为 0.59%，变异系数为 14.2%。

1.4　基于 RGB 和多光谱融合的特征提取

基于无人机 RGB 和多光谱遥感影像，使用 RGB 特征、多光谱特征和 RGB 融合多光谱特征 3 类特征向量集，用于构建油菜氮元素含量预测模型。

1.4.1　无人机多光谱影像特征

利用无人机搭载的多光谱传感器对不同波段的光谱信息进行特征提取，分析油菜植株冠层叶片氮元素含量。共采用 10 种植被指数来评估油菜叶片氮素含量[19-28]，分别为归一化植被指数（Normalized difference vegetation index，NDVI）、叶面叶绿素指数（Leaf chlorophyll index，LCI）、比值植被指数（Ratio vegetation index，RVI）、归一化差异红边指数（Normalized difference red edge，NDRE）、冠层叶绿素含量指数（Canopy chlorophyll content index，CCCI）、三角形植被指数（Triangular vegetation index，TDVI）、绿光归一化植被指数（Green normalized difference vegetation index，GNDVI）、叶绿素指数（Green chlorophyll index，GCI）、修正的土壤调节植被指数（Modified soil adjusted vegetation index，MSAVI）和修正的简单比值（Modified simple ratio，MSR），这些植被指数特征与油菜的生长状态及叶片氮素含量密切相关。

1.4.2　无人机 RGB 影像特征

利用无人机获取油菜田块的可见光影像后，从中提取图像的颜色特征和纹理特征。颜色特征通过测量作物对可见光的反射或吸收情况评估其生长和健康状况；纹理特征描述图像中像素间的空间排列及灰度变化规律。

选取 10 种可见光特征和 5 种纹理特征用于油菜叶片氮素含量评估。可见光特征可从影像中提取蓝光、绿光和红光波段的反射率值，可以反映油菜植株在不同波段的光谱响应，进而推断其氮元素含量

及其他生理状态指标，主要包括如下可见光特征[29-32]：过绿指数（Excess green index，ExG）、过绿减过红植被指数（Excess green minus excess red index，ExGR）、过红指数（Excess red index，ExR）、绿蓝比值指数（Green-blue ratio index，GBRI）、红绿比值指数（Red-green ratio index，RGRI）、改进的绿红植被指数（Modified green-red vegetation index，MGRVI）、植被提取颜色指数（Color index of vegetation extraction，CIVE）、归一化植被指数（Normalized difference index，NDI）、红绿蓝植被指数（Red-green-blue vegetation index，RGBVI）和植被因子（Vegetation index，VEG）。

灰度共生矩阵（Gray-level co-occurrence matrix，GLCM）是经典的纹理分析工具，能够适应不同环境、拍摄条件与设备差异，有助于提升油菜氮含量监测模型的鲁棒性与预测准确性[2,33]。通过 GLCM 可提取图像的对比度（Texture contrast，TCT）、不相似度（Texture dissimilarity，TD）、同质性（Texture homogeneity，TH）、能量（Texture energy，TE）和相关性（Texture correlation，TCN）等 5 种纹理特征。

1.5 油菜叶片氮含量监测模型构建

为提高油菜氮含量监测精度，本研究分别使用 RGB、多光谱和 RGB 融合多光谱 3 类特征值构建油菜氮元素含量最优监测模型，具体步骤如下：①采用皮尔逊相关性分析方法量化各植被指数与油菜氮元素含量之间的关系，筛选相关性较高的特征值。②基于 mRMR 算法对上述筛选后的特征值进行排序，得到特征值的重要性大小排列顺序。③将排序后的特征值融合不同生育期的时序信息，依次输入至 RF、RR、SVR 和 GBR 4 种机器学习算法中，建立油菜冠层叶片氮含量监测最佳模型。

1.5.1 基于相关性分析的特征筛选

针对油菜冠层叶片图像提取的特征存在冗余导致油菜叶片氮含量的建模精度较低的问题，为构建氮元素含量最佳监测模型，基于相关性分析对图像特征进行筛选。将特征值数据标准化处理后，采用皮尔逊相关性分析方法量化各植被指数与油菜氮元素含量之间的关系。皮尔逊相关系数可获得特征值与油菜氮元素含量之间的正负相关性及其强度，进而筛选对油菜氮含量具有显著影响的重要特征值。在分别分析 RGB、多光谱和 RGB 融合多光谱特征与油菜氮元素含量之间的相关性后，筛选相关性较强的特征作为构建油菜氮含量监测模型的重要特征。

1.5.2 图像特征优选

采用相关性分析方法筛选上述特征后，为进一步提高油菜氮含量的监测精度，需要对重要特征值之间的信息相关性进行评估，并选择最优特征组合。采用 mRMR 算法对筛选后的特征值进行重要性排序，通过增量分组方式选择最优特征组合用于后续机器学习模型的输入。mRMR 算法能够最大化原始特征集中的特征与目标变量之间相关性，最小化原始特征集中特征与特征之间的相关性，通过计算 2 个随机变量的互信息来度量变量之间的相关性，互信息计算公式为

$$I(x,y)=\sum_{x}\sum_{y}p(x,y)\lg\frac{p(x,y)}{p(x)p(y)} \tag{1}$$

式中 $I(x,y)$——变量 x 和 y 之间的互信息

$p(x,y)$——x 和 y 同时取得某 2 个值的概率

$p(x)$——变量 x 发生的概率

$p(y)$——变量 y 发生的概率

为了在原始特征集合中找到与最终输出结果相关性最大且特征之间相关性最小的一组特征，需要对目标函数进行计算，选择特征的目标函数计算式为

$$V=\frac{1}{|S|}\sum_{F_i\in S}I(F_i,H) \tag{2}$$

$$W=\frac{1}{|S|^2}\sum_{F_i,F_j\in S}I(F_i,F_j) \tag{3}$$

$$C=\max(V-W) \tag{4}$$

式中 S——候选特征集合

H——评价集合，由大于等于 0 的整数组成，分别代表特征值的不同种类

V——候选特征集合 S 与评价集合 H 的相关性

W——候选特征集合 S 中各特征之间的冗余性

F_i、F_j——候选特征

C——候选特征集合 S 的综合评价指标，C 值越大表明特征集合性能越优

1.5.3 油菜冠层叶片氮元素含量监测模型构建

为构建氮监测最优模型，首先基于特征重要性排序结果，将 3 类图像特征按排序依次递增输入至 RF、RR、SVR 和 GBR 4 种机器学习模型中，以确定各类特征的最优特征组合。4 种模型涵盖线性与非线性、单模型与集成模型的不同类别，便于全面评估氮元素含量监测算法的适用性[2]。在此基础上，为进一步融合不同生育期的时序信息以提升模型对氮含量动态变化的表征能力，在预测目标生育期（如蕾薹期）的氮含量时，使用该时期的最优特征组合的同时，将前期所采集关键生育期（如六叶期、越冬期）对应的最优特征组合作为输入，从而构建反映氮素累积与转化过程的时序特征集。该方法通过引

入作物生长过程中的连续光谱与图像特征变化，增强了模型对氮含量动态规律的捕捉能力，用于构建高精度、强适应性的氮含量监测最优模型。

在数据集划分方面，根据油菜 3 个追肥关键生育期（六叶期、越冬期和蕾薹期）与施肥梯度（CK、N1、N2、N3）的差异，将 2023—2024 年试验数据按等比例随机划分为训练集与验证集，其中 70% 样本（168 个）用于模型训练，30% 样本（72 个）用于模型验证，并采用五折交叉验证进行模型稳定性评估；2024—2025 年试验数据则作为独立测试集，用于评估模型泛化性。

1.6　油菜精准追肥处方图生成方法

传统的农业生产中，通常采用统一的施肥量来满足油菜作物的养分需求，忽视了油菜作物生长发育过程中的差异性[9]。传统的统一施肥量可能导致长势较差作物追肥量不足，长势较好作物追肥过量，难以实现生产过程中的最优施肥效益。针对上述问题，本研究根据油菜氮含量监测最佳模型生成的油菜氮含量分布图进行差异化施肥，以实现不同生长状况的油菜作物针对性养分供给。同时，为更好地利用有限的资源，根据当地正常水平的田间管理，结合作物氮元素含量、肥料养分含量、肥料利用率等可利用的氮含量信息，提出一种追肥量决策方法，为生成油菜追肥量处方图提供关键决策[13,34]。

油菜冠层叶片氮含量分布图上每一个植被覆盖区域像素点都可以反演出一个氮含量值，根据农用无人机实际作业要求，结合农用无人机作业幅宽、作业速度和肥料施用响应时间等相关参数，将 4 m × 5 m 作为最小栅格划分作业区域。在对油菜种植区域的油菜氮含量分布图栅格划分后，获取每个栅格内的氮元素含量平均值作为该栅格内的氮元素含量。根据种植区域油菜氮含量分布图和栅格划分结果，用于构建油菜追肥量决策模型。

在试验区域的相邻田块，按照油菜种植专家给出的田间管理方案，开展追肥量人工标定工作，将 AE 小区作为施肥决策参考标准，同时将该小区内油菜栅格平均氮含量 F_{std}（质量分数，%）所推荐的追肥量 F_0（kg/hm^2）作为氮肥追施的目标，结合地理位置信息形成标准施肥量，将待追肥栅格油菜氮含量的数值记为 F_N，则油菜缺氮量为 F_x，计算式为

$$F_x = F_{std} - F_N \tag{5}$$

当 $F_x > 0$ 时，表明目前该位置的氮素含量低于标准田，需要增加追肥量；当 $F_x \leqslant 0$ 时，表明目前该位置的氮素含量高于标准田，需要减少追肥量。根据 F_x，判断该位置的追肥量高于标准田追肥量或低于标准田追肥量。通过获取栅格缺氮量，将其转换为油菜追肥量处方图，用于无人机追肥的精准作业[34-35]。每个栅格可分配追肥量，即 Q_N，最终生成油菜追肥处方图。Q_N 计算公式为

$$Q_N = F_0 + \frac{F_0}{\lambda k F_{std}}(F_{std} - F_N) \tag{6}$$

式中　Q_N——当前栅格追肥量，kg/hm^2

λ——肥料中氮质量分数，%

k——油菜对氮肥中氮元素的吸收效率

油菜生长不同发育期 k 的数值会发生变化，相关研究表明：六叶期 k 取值范围为 0.40 ~ 0.65，越冬期为 0.25 ~ 0.40，蕾薹期为 0.45 ~ 0.70，实际应用中可根据当地条件调整[36-37]。

1.7　评价方法

本研究选用决定系数（Coefficient of determination，R^2）、均方根误差（Root mean squared error，RMSE）和均方误差（Mean squared error，MSE）作为氮含量监测的评价指标。其中，R^2 数值越高且越接近于 1，RMSE 和 MSE 的值越小，表明模型的准确性和稳定性越好。

2　结果与分析

2.1　基于相关性分析的特征筛选结果及分析

本研究采用皮尔逊相关性分析方法，分别量化 RGB、多光谱及 RGB 融合多光谱 3 类特征与油菜氮含量之间的相关性，结果如图 5 所示。图 5a 展示了多光谱特征与氮含量的相关性，图 5b 展示了 RGB 特征与氮含量的相关性。在设定相关性阈值 $|r| \geqslant 0.80$ 条件下，可以观察到不同油菜特征与氮含量之间存在显著的相关关系。可见，随着油菜冠层叶片氮含量的增加，多光谱特征中 MSAVI、LCI、NDVI、MSR、TDVI、GNDVI、GCI、RVI 等整体呈上升趋势；RGB 特征中 ExG、GBRI、MGRVI、TCN 及部分特征组合（如 GBRI 与 ExG、TCN 与 ExG 等）也呈上升趋势，而 RGRI、CIVE、ExR 及部分组合（如 ExR 与 ExGR、TH 与 TD 等）呈下降趋势。上述特征均与氮含量具有显著相关性，因此被筛选用于后续特征组合优化研究。最终，本研究将多光谱的 8 个特征值和可见光的 11 个特征值作为评价油菜氮含量的关键特征集。

2.2　基于特征优选的多生育期模型构建与精度分析

将上述与氮含量相关的特征，基于 mRMR 算法分别得到 RGB 重要特征值排序从高到低为 ExG、TH、TCN、GBRI、RGRI、CIVE、TD、ExGR、MGRVI、GBRI、ExR；多光谱重要特征值排序为 LCI、MSAVI、NDVI、RVI、MSR、TDVI、GNDVI、GCI；RGB 融合多光谱重要特征值排序为 LCI、MSAVI、NDVI、ExG、TH、

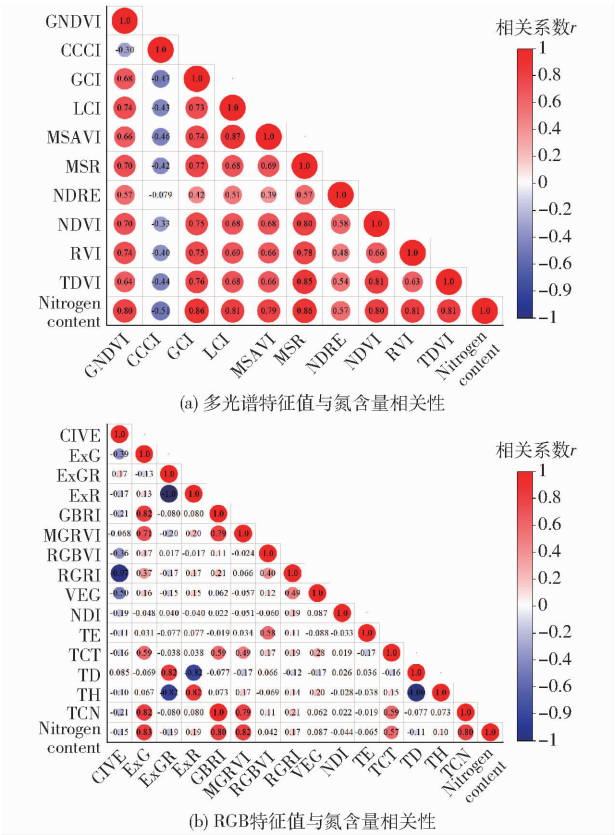

图 5 特征值与氮含量相关性

Fig. 5 Correlation between feature values and nitrogen content

RVI、TCN、GBRI、MSR、TDVI、GNDVI、GCI、RGRI、CIVE、TD、ExGR、MGRVI、GBRI、ExR。

为探究不同特征组合数量对模型精度的影响，首先按照上述重要特征值排序依次递增特征数量，构建不同维度特征组合，分别输入 RF 模型进行训练与测试。图 6a 展示了单一生育期在不同特征组合下的模型精度变化。随着特征数量增加，3 类特征组合的 R^2 均呈现先上升后趋于平稳的趋势。图中虚线为特征数量所达到的峰值，其中，多光谱特征在维度为 4 时达到峰值（六叶期 R^2 = 0.724、越冬期 R^2 = 0.715、蕾薹期 R^2 = 0.710）；RGB 特征在维度为 3 时达到峰值（六叶期 R^2 = 0.595、越冬期 R^2 = 0.630、蕾薹期 R^2 = 0.652）；RGB 融合多光谱特征在维度为 5 时达到最高精度（六叶期 R^2 = 0.725、越冬期 R^2 = 0.764、蕾薹期 R^2 = 0.745）。结果表明，多源特征融合相较于单一特征可提升监测精度。图 6b 进一步展示了融合时序生育期在不同特征组合下的模型精度对比，其变化趋势与单一生育期相似，但融合时序生育期的模型整体精度更高。其中，RGB 融合多光谱特征在维度为 5 时取得最高精度，融合时序信息后，同一特征组合的 R^2 分别提升至 0.825、0.800 和 0.806（图 6b）。两者相比，融合时序信息后 3 个生育期的 R^2 分别提高了 0.100、0.036 和 0.061。结果表明，时序数据的融合能够提供更丰富的作物生长动态信息，减少单一生育期数据采集期间造成的环境干扰（如光照、天气等），从而提高了模型精度。

综上，特征值数量为 5，即最优特征组合为 LCI、MSAVI、NDVI、ExG、TH 时，融合时序生育期数据模型表现最佳。结果表明，特征优选在消除冗余、提升模型效率方面的有效性，多源信息与融合时序信息在提升油菜氮含量监测精度中具有关键作用，为后续氮元素反演与精准追肥决策提供了最优模型基础。

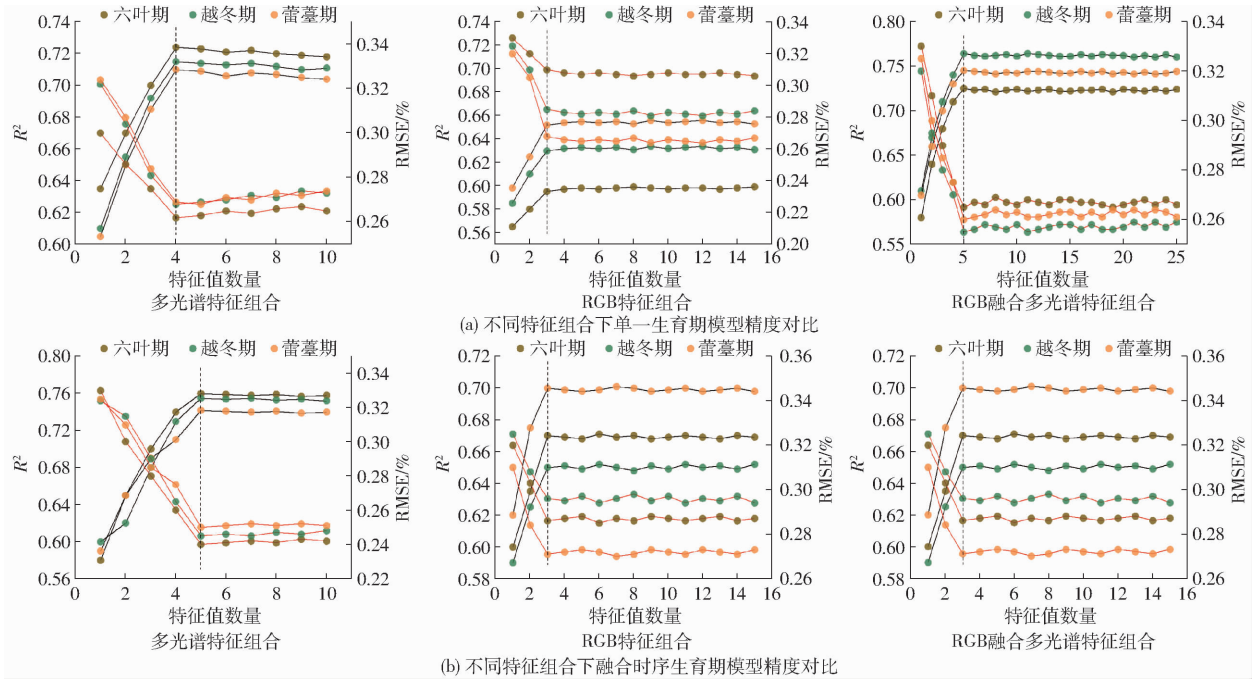

图 6 不同特征组合下单一生育期与融合时序的氮监测模型精度对比（验证集数量 n = 72）

Fig. 6 Accuracy comparison between single-growth-stage and fused temporal models under different feature combinations

2.3　油菜冠层叶片氮元素含量测试结果分析

为评估最优特征组合下不同机器学习模型性能，基于 2023—2024 年度试验数据，融合时序信息，对 RF、RR、SVR 和 GBR 4 种模型在六叶期、越冬期和蕾薹期的氮监测效果进行了验证分析，结果如表 2 所示。由表 2 可知，RF 模型在氮含量监测中效果最佳，在六叶期、越冬期和蕾薹期，RF 模型的 R^2 分别达到 0.825、0.800 和 0.806，其 RMSE 分别为 0.210%、0.231% 和 0.217%。与 GBR、RR 和 SVR 模型相比，RF 模型在六叶期 R^2 分别提高了 0.041、0.173 和 0.072，越冬期 R^2 分别提高了 0.038、0.166 和 0.068，蕾薹期 R^2 分别提高了 0.015、0.133 和 0.060。结果表明，RF 模型在处理时序多维与油菜氮含量关系方面具有显著优势，可有效获取不同时序生育期下作物的氮含量相关信息。

表 2　不同生育期、不同模型氮含量验证结果

Tab. 2　Nitrogen content validation results of different models at different growth stages

模型	生育期	R^2	RMSE/%	MSE/%^{2}
GBR	六叶期	0.784	0.245	0.060
	越冬期	0.762	0.252	0.063
	蕾薹期	0.791	0.239	0.057
RR	六叶期	0.652	0.324	0.105
	越冬期	0.634	0.296	0.088
	蕾薹期	0.673	0.282	0.080
SVR	六叶期	0.753	0.256	0.065
	越冬期	0.732	0.261	0.068
	蕾薹期	0.746	0.238	0.057
RF	六叶期	0.825	0.210	0.044
	越冬期	0.800	0.231	0.053
	蕾薹期	0.806	0.217	0.047

注：六叶期、越冬期和蕾薹期 n 均为 24。

图 7 为油菜 2 个生长季在六叶期、越冬期和蕾薹期的氮含量箱线与点重叠图，展示了该组样本数据的分布情况。统计结果表明，2024—2025 年氮含量整体分布位置和均值高于上一年，表明了第 2 年油菜氮素整体水平更高，长势更旺；2023—2024 年与 2024—2025 年氮含量变化均呈现高-低-中变化趋势，表明氮含量从六叶期的较高水平下降至越冬期的较低水平，在蕾薹期又回升到一个中等水平，表明油菜不同生育期对氮吸收与积累具有重要影响，符合油菜不同生育期的氮含量变化规律。

基于上述最佳模型，分别对 2023—2024 年与 2024—2025 年油菜进行氮含量反演，得到了油菜氮分布图，并对模型预测精度进行了验证。图 8 所示氮含量分布图通过颜色梯度直观反映了油菜氮含量空间分布变化，2023—2024 年与 2024—2025 年六叶期油菜氮含量在空间上呈现较高分布，表明该阶段油菜处于生长旺盛期，氮素积累较充分；越冬期氮含量下降较明显，作物冠层覆盖区域也呈现降低趋势，整体氮含量下降；蕾薹期氮含量较越冬期有所提高，这与蕾薹期油菜进入生殖生长阶段，新生叶快速发育有关，氮需求也同步增加。可见，图 8 六叶期、越冬期和蕾薹期油菜氮含量的可视化变化与图 7 变化规律一致，表明了本文模型的有效性。

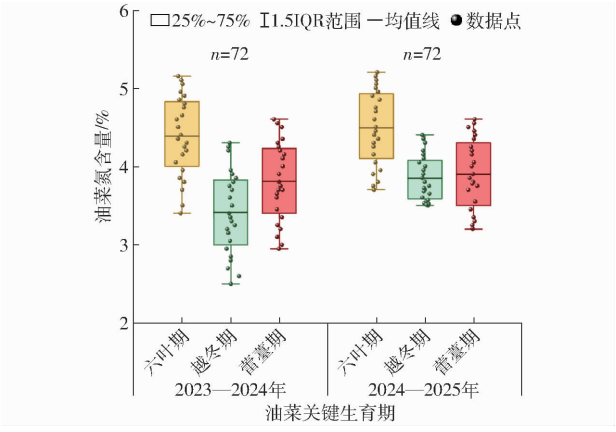

图 7　不同生育期氮含量箱线与点重叠图

Fig. 7　Box and overlaid point plots of nitrogen content across different growth stages

图 8 所示为油菜氮含量精度验证结果，图中，** 表示在 0.01 水平上极显著相关（$p < 0.01$），由图 8 可知，六叶期、越冬期和蕾薹期 2023—2024 年验证集 R^2 分别为 0.825、0.800 和 0.806，RMSE 分别为 0.210%、0.231% 和 0.217%；2024—2025 年测试集 R^2 分别为 0.792、0.770 和 0.787，RMSE 分别为 0.213%、0.135% 和 0.207%。结果表明，模型在 2 个年度各生育期均保持较高预测性能，所构建的时序特征融合模型具有良好的稳定性与泛化能力，能准确捕捉不同生长阶段油菜氮含量的空间分布特征，为后续精准追肥决策提供了可靠依据。

2.4　无人机不同飞行高度对油菜氮含量测试结果影响分析

为探究无人机不同飞行高度条件下油菜氮含量的监测效果，利用上述构建的最优监测模型，使用 2024—2025 年测试集分别在 20、30、40、50 m 4 种飞行高度下，对六叶期、越冬期和蕾薹期的油菜氮含量进行预测测试，结果如表 3 所示。由表 3 可知，飞行高度为 40 m 时模型性能最佳，六叶期、越冬期和蕾薹期的 R^2 分别为 0.792、0.770 和 0.787，RMSE 分别为 0.213%、0.135% 和 0.207%；在 20 ~ 50 m 飞行高度范围内，模型在各生育期均表现出较好的监测性能，六叶期、越冬期和蕾薹期的 R^2 分别为 0.780 ~ 0.792、0.760 ~ 0.770 和 0.778 ~ 0.787，RMSE 均

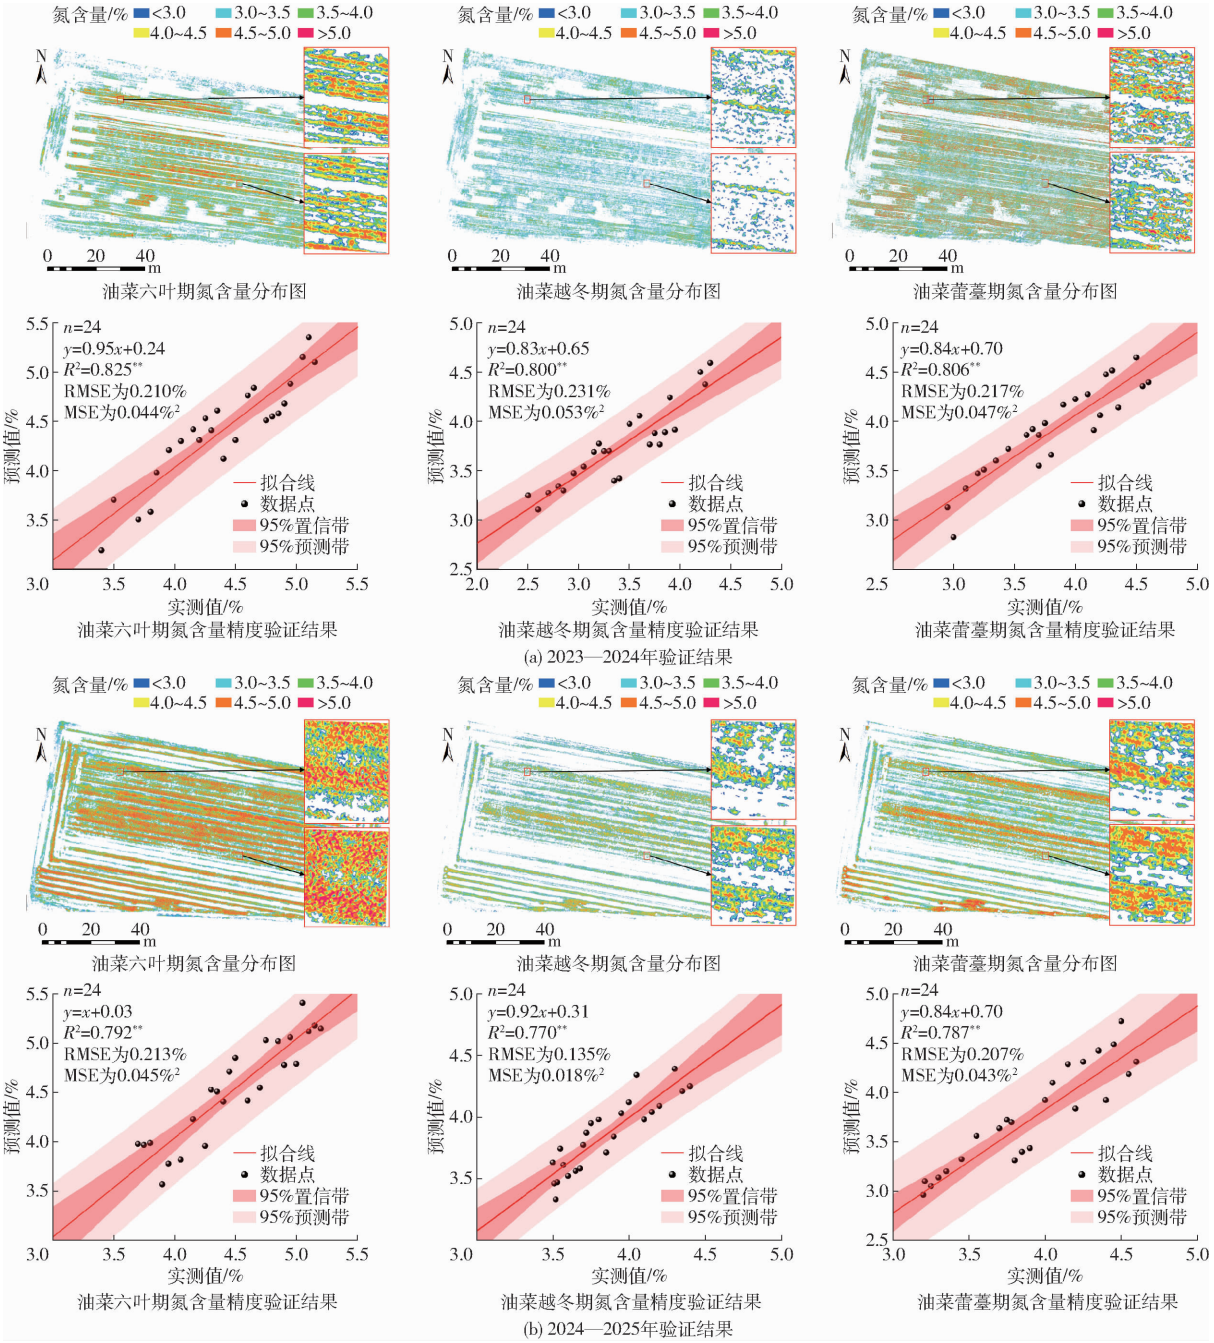

图 8 油菜氮含量分布图生成结果及精度验证

Fig. 8 Distribution map generation and accuracy validation of nitrogen content in rapeseed

低于 0.235%，MSE 均低于 0.055%²。结果表明，本研究构建的氮监测模型对不同采集高度具有良好的适应性和稳定性。

进一步分析发现，无人机飞行高度为 20 ~ 40 m 时，R^2、RMSE 和 MSE 随高度增加变化差别不大；当高度升至 50 m 时，各生育期的 R^2 均有所下降，RMSE 和 MSE 有所升高。分析原因如下，上述变化主要与无人机影像的空间分辨率及特征信息提取效果有关，在飞行高度 20 ~ 40 m 范围内，影像地面分辨率较高，可更充分捕捉冠层纹理与光谱细节，有利于模型识别精度的提升；当飞行高度增至 50 m 时，地面分辨率降低，冠层细微特征（尤其是纹理特征）信息损失增大，导致模型反演精度略有下降。综合考虑监测精度与作业效率，在飞行高度 20 ~ 40 m 区间内模型性能差异较小，而高度 40 m 在保证较高空间分辨率的同时，具备更优的作业覆盖效率（如数据采集时间更快），因此本研究将 40 m 作为无人机监测油菜氮含量的适宜飞行高度。

2.5 油菜追肥处方图生成结果分析

本研究依据农用无人机的实际作业参数，综合考虑飞行幅宽、作业速度及施肥响应时间等因素，将田块划分为最小栅格单元后，通过解析各区域的氮含量信息，可清晰识别出油菜田块中高、低氮含量区域的分布状况，为生成油菜追肥处方图提供了关键

表 3　不同生育期、无人机不同采集高度氮含量测试结果

Tab. 3　Nitrogen content test results at different growth stages and different UAV flight altitudes

生育期	采集高度/m	R^2	RMSE/%	MSE/%^{2}
六叶期	20	0.790	0.218	0.048
	30	0.785	0.225	0.051
	40	0.792	0.213	0.045
	50	0.780	0.235	0.055
越冬期	20	0.765	0.148	0.022
	30	0.768	0.140	0.020
	40	0.770	0.135	0.018
	50	0.760	0.155	0.024
蕾薹期	20	0.782	0.218	0.048
	30	0.785	0.210	0.044
	40	0.787	0.207	0.043
	50	0.778	0.225	0.051

注：六叶期、越冬期和蕾薹期 n 均为 24。

空间决策依据。基于图 8 所示的氮含量分布图，结合构建的追肥量决策算法，分别生成了 2023—2024 年和 2024—2025 年油菜六叶期、越冬期与蕾薹期不同关键追肥期的追肥处方图，如图 9 所示。由图 9 可知，处方图依据无人机可识别的最小栅格单元进行了划分，根据专家推荐的每个栅格追肥量及本文提出的决策算法计算出相应的推荐追肥量。在相同生育期内，氮含量较高的区域油菜长势较好，所需追肥量较少；而氮含量较低的区域则表明油菜植株氮素供应不足，需相应增加追肥量。同时由于油菜不同生育期需氮特性不同，专家推荐的追肥量也存在差异，使得各生育期处方图的追肥量分布呈现出对应的阶段性特征。为验证本方法生成的追肥处方图，将处方图推荐的追肥总量与常规均匀施肥进行对比。以图 9 中 2024—2025 年六叶期、越冬期和蕾薹期追肥为例，本文方法生成的处方图推荐的总追肥量较常规均匀施肥分别减少了约 16.50%、14.56% 和 14.19%，其中氮含量较高区域追肥量降低，氮含量较低区域追肥量增加，实现了按需施肥的

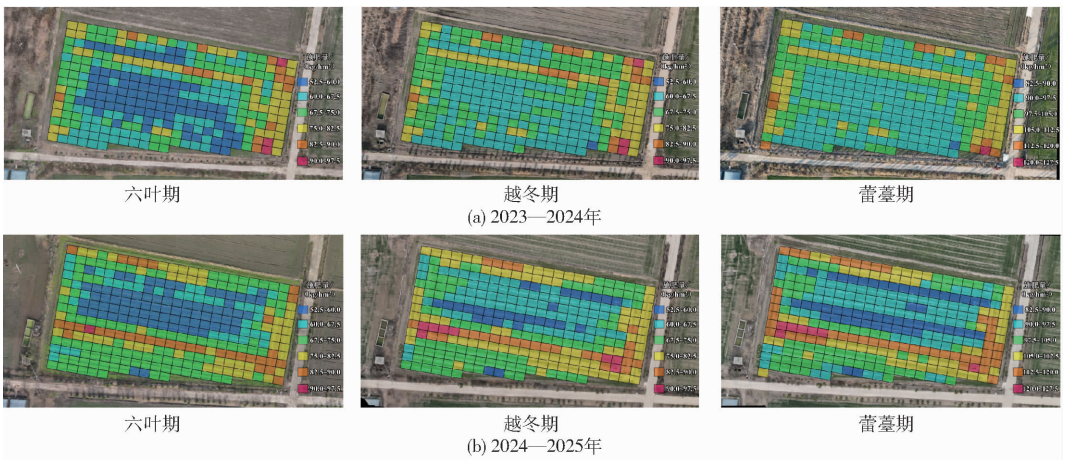

图 9　不同生育期油菜追肥处方图生成结果

Fig. 9　Prescription map generation results for rapeseed topdressing at different growth stages

目标。

综上所述，本研究构建的氮含量监测模型能够实现大范围油菜氮含量反演，有效支持六叶期、越冬期与蕾薹期等关键追肥阶段的氮含量监测，进而生成具有空间差异化的追肥处方图，为油菜氮营养精准管理及变量施肥作业提供重要技术支撑。

3　讨论

多源数据的特征融合已然成为无人机多光谱遥感反演作物生长指标的热点[38]，本研究结果表明融合时序 RGB 与多光谱特征增强了模型预测能力，可同时监测多个追肥关键期（苗期、越冬期与蕾薹期）氮含量，主要原因是最优特征组合（LCI、MSAVI、NDVI、ExG、TH）兼顾光谱与纹理信息，在保证精度的同时降低了特征冗余；同时，时序信息反映了作物生长过程中的氮素相关特征的动态变化，提高了监测多个生育期精度。然而，时序信息融合对数据采集与处理要求较高，且单一生育期模型仍具有较好的性能，因此可在实际应用中根据需求选择。未来研究可融合多源传感器与环境数据，结合土壤-作物系统模型，拓展至不同种植区域，以进一步提升模型的鲁棒性与适应性，推动油菜氮管理向智能化、精准化方向发展，为构建高效的油菜氮含量监测和追肥量决策模型提供技术支撑。在追肥决策方面，多数研究依据农学专家推荐的目标追肥量与作物氮含量空间分布进行处方图生成，该方式追肥效果较好，然而当前决策过程尚未融合土壤养分信息，且依旧面临人工管理的问题[16]，未来研究可进一步融合土壤养分信息，并集成作物生长模型、环境传感器数据等信息，构建基于生育期自动识别与氮素动态需求的

智能决策系统,提升追肥决策的自适应性与智能化水平。

4 结论

(1)以油菜关键追肥期为研究对象,提出了一种融合时序 RGB-多光谱的油菜氮监测与追肥处方图构建方法,生成了油菜氮含量分布图和油菜追肥处方图。

(2)为提高氮含量监测精度,降低特征冗余,分别基于多光谱、RGB 和 RGB 融合多光谱特征 3 种数据集,采用相关性分析筛选特征,并使用 mRMR 算法对特征重要性排序,融合时序信息后输入机器学习模型构建油菜冠层叶片氮含量监测模型。结果表明,基于 RF 模型、融合时序信息的 RGB 与多光谱最优特征组合(LCI、MSAVI、NDVI、ExG、TH)监测效果最佳,六叶期、越冬期和蕾薹期 R^2 分别为 0.825、0.800 和 0.806,RMSE 分别为 0.210%、0.231% 和 0.217%。相较于仅使用单一生育期数据建模,融合时序信息后六叶期、越冬期和蕾薹期的 R^2 分别提高了 0.100、0.036 和 0.061。结果表明,本文方法可降低特征冗余,监测多个生育期时提高氮含量模型精度,为作物氮含量高效监测提供方法参考。

(3)测试了无人机不同飞行高度下的氮含量监测性能。结果表明,模型在飞行高度 20~50 m 范围内均表现出良好的适应性和稳定性,无人机飞行高度为 40 m 时模型性能最佳,六叶期、越冬期和蕾薹期的 R^2 分别为 0.792、0.770 和 0.787,RMSE 分别为 0.213%、0.135% 和 0.207%,因此确定 40 m 为无人机监测油菜氮含量的适宜飞行高度。

(4)根据种植区域的油菜氮含量分布图,构建了油菜追肥量决策方法,生成了油菜追肥关键期(六叶期、越冬期和蕾薹期)的追肥处方图,为油菜作物氮营养精准管理和处方化追肥提供了理论依据与技术参考。

参 考 文 献

[1] 万星宇,廖庆喜,廖宜涛,等. 油菜全产业链机械化智能化关键技术装备研究现状及发展趋势[J]. 华中农业大学学报,2021,40(2):24-44.
Wan Xingyu, Liao Qingxi, Liao Yitao, et al. Situation and prospect of key technology and equipment in mechanization and intelligentization of rapeseed whole industry chain[J]. Journal of Huazhong Agricultural University, 2021, 40(2): 24-44. (in Chinese)

[2] Zeng F, Wang R, Jiang Y, et al. Growth monitoring of rapeseed seedlings in multiple growth stages based on low-altitude remote sensing and semantic segmentation[J]. Computers and Electronics in Agriculture, 2025, 232: 110135.

[3] Wang L, Zhou X, Zhu X, et al. Estimation of leaf nitrogen concentration in wheat using the MK-SVR algorithm and satellite remote sensing data[J]. Computers and Electronics in Agriculture, 2017, 140: 327-337.

[4] 苏伟,鲁剑巍,李云春,等. 氮肥运筹方式对油菜产量、氮肥利用率及氮素淋失的影响[J]. 中国油料作物学报,2010,32(4):558-562.
Su Wei, Lu Jianwei, Li Yunchun, et al. Effect of nitrogen management mode on yield, nitrogen using efficiency and nitrogen leaching of rapeseed[J]. Chinese Journal of Oil Crop Sciences, 2010, 32(4): 558-562. (in Chinese)

[5] Jin Z, Li S, Yu F, et al. Research on the rice fertiliser decision-making method based on UAV remote sensing data assimilation [J]. Computers and Electronics in Agriculture, 2024, 216: 108508.

[6] Li L, Ren T, Ma Y, et al. Evaluating chlorophyll density in winter oilseed rape (*Brassica napus* L.) using canopy hyperspectral red-edge parameters[J]. Computers and Electronics in Agriculture, 2016, 126: 21-31.

[7] 凌琪涵,孔发明,宁强,等. 基于无人机多光谱影像的水稻氮营养监测[J]. 农业工程学报,2023,39(13):160-170.
Ling Qihan, Kong Faming, Ning Qiang, et al. Rice nitrogen nutrition monitoring based on unmanned aerial vehicle multispectral image[J]. Transactions of the CSAE, 2023, 39(13): 160-170. (in Chinese)

[8] 孟沌超,赵静,兰玉彬,等. 基于无人机可见光影像的玉米冠层 SPAD 反演模型研究[J]. 农业机械学报,2020,51(增刊2):366-374.
Meng Dunchao, Zhao Jing, Lan Yubin, et al. SPAD inversion model of corn canopy based on UAV visible light image[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(S2): 366-374. (in Chinese)

[9] 李岚涛. 冬油菜氮素营养高光谱特异性及定量诊断模型构建与推荐追肥研究[D]. 武汉:华中农业大学,2018.
Li Lantao. Research on hyperspectral characteristics, quantitative diagnostic models, and topdressing application for winter oilseed rape nitrogen status[D]. Wuhan: Huazhong Agricultural University, 2018. (in Chinese)

[10] 袁道军,刘安国,原保忠,等. 基于计算机视觉技术的油菜冠层营养信息监测[J]. 农业工程学报,2009,25(12):174-179.
Yuan Daojun, Liu Anguo, Yuan Baozhong, et al. Nutrition information extraction of rape canopy based on computer-vision technology[J]. Transactions of the CSAE, 2009, 25(12): 174-179. (in Chinese)

[11] 张凯兵,章爱群,李春生. 基于 HSV 空间颜色直方图的油菜叶片缺素诊断[J]. 农业工程学报,2016,32(19):179-187.

Zhang Kaibing, Zhang Aiqun, Li Chunsheng. Nutrient deficiency diagnosis method for rape leaves using color histogram on HSV space[J]. Transactions of the CSAE, 2016, 32(19): 179 - 187. (in Chinese)

[12] Sharma M, Kumar C J, Bhattacharyya D K. Machine/deep learning techniques for disease and nutrient deficiency disorder diagnosis in rice crops: a systematic review[J]. Biosystems Engineering, 2024, 244: 77 - 92.

[13] 郭建华. 基于深度学习的遥感影像云检测研究[D]. 天津:天津大学,2021.
Guo Jianhua. Cloud detection of remote sensing imagery based on deep learning[D]. Tianjin: Tianjin University, 2021. (in Chinese)

[14] 任建强,张宁丹,刘杏认,等. 基于哨兵-2A 模拟反射率及其影像的冬小麦收获指数估算[J]. 农业机械学报,2022, 53(12):231 - 243.
Ren Jianqiang, Zhang Ningdan, Liu Xingren, et al. Estimation of harvest index of winter wheat based on simulated sentinel-2A reflectance data and its real remote sensing imagery[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12): 231 - 243. (in Chinese)

[15] Liu S, Li L, Gao W, et al. Diagnosis of nitrogen status in winter oilseed rape (*Brassica napus* L.) using in-situ hyperspectral data and unmanned aerial vehicle (UAV) multispectral images[J]. Computers and Electronics in Agriculture, 2018, 151: 185 - 195.

[16] 于丰华,曹英丽,许童羽,等. 基于高光谱遥感处方图的寒地分蘖期水稻无人机精准施肥[J]. 农业工程学报,2020, 36(15):103 - 110.
Yu Fenghua, Cao Yingli, Xu Tongyu, et al. Precision fertilization by UAV for rice at tillering stage in cold region based on hyperspectral remote sensing prescription map[J]. Transactions of the CSAE, 2020, 36(15): 103 - 110. (in Chinese)

[17] Guo A, Ye H, Huang W, et al. Inversion of maize leaf area index from UAV hyperspectral and multispectral imagery[J]. Computers and Electronics in Agriculture, 2023, 212: 108020.

[18] Zhai W, Li C, Cheng Q, et al. Exploring multisource feature fusion and stacking ensemble learning for accurate estimation of maize chlorophyll content using unmanned aerial vehicle remote sensing[J]. Remote Sensing, 2023, 15(13): 3454.

[19] Tucker C J. Red and photographic infrared linear combinations for monitoring vegetation[J]. Remote Sensing of Environment, 1979, 8(2): 127 - 150.

[20] 程志庆,张劲松,孟平,等. 杨树叶片叶绿素含量高光谱估算模型研究[J]. 农业机械学报,2015,46(8):264 - 271.
Cheng Zhiqing, Zhang Jingsong, Meng Ping, et al. Hyperspectral estimation model of chlorophyll content in poplar leaves[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(8): 264 - 271. (in Chinese)

[21] Broge N H, Mortensen J V. Deriving green crop area index and canopy chlorophyll density of winter wheat from spectral reflectance data[J]. Remote Sensing of Environment, 2002, 81: 45 - 57.

[22] Sims D A, Gamon J A. 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 - 3): 337 - 354.

[23] Ei-shikha D M, Barnes E M, Clarke T R, et al. Remote sensing of cotton nitrogen status using the canopy chlorophyll content index (CCCI)[J]. Transactions of the ASABE, 2008, 51(1): 73 - 82.

[24] Bannari A, Asalhi H, Teillet P M. Transformed difference vegetation index (TDVI) for vegetation cover mapping[C]//IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2002: 3053 - 3055.

[25] Candiago S, Remondino F, De G M, et al. Evaluating multispectral images and vegetation indices for precision farming applications from UAV images[J]. Remote Sensing, 2015, 7(4): 4026 - 4047.

[26] Gitelson A A, Gritz Y, Merzlyak M N. 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.

[27] 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.

[28] Xie Q, Dash J, Huang W, et al. Vegetation indices combining the red and red-edge spectral information for leaf area index retrieval[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(5): 1482 - 1493.

[29] Woebbecke D M, Meyer G E, Von B K, et al. Color indices for weed identification under various soil, residue, and lighting conditions[J]. Transactions of the ASAE, 1995, 38(1): 259 - 269.

[30] Sellaro R, Crepy M, Trupkin S A, et al. Cryptochrome as a sensor of the blue/green ratio of natural radiation in Arabidopsis [J]. Plant Physiology, 2010, 154(1): 401 - 409.

[31] Bendig J, Yu K, Aasen H, et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley[J]. International Journal of Applied Earth Observation and Geoinformation, 2015, 39: 79 - 87.

[32] 韩少杰. 基于深度学习的油菜苗期氮含量及角果期产量分级方法研究[D]. 武汉:华中农业大学,2022.
Han Shaojie. A deep learning-based method for grading the nitrogen content of oilseed rape seedlings and yield at the silique [D]. Wuhan: Huazhong Agricultural University, 2022. (in Chinese)

[33] 李阳,赵博,周利明,等. 多类型参数结合的冬小麦拔节期 SPAD 值估算[J]. 农业机械学报,2025,56(7):513 - 521.

Li Yang, Zhao Bo, Zhou Liming, et al. Combining multiple type parameters for estimating winter wheat SPAD values at jointing stage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(7): 513 - 521. (in Chinese)

[34] Zhu Y, Huang X, Yin C, et al. Key parameters determination based on seed movement process simulation for rice strip aerial seeding via UAV[J]. Computers and Electronics in Agriculture, 2025, 237: 110596.

[35] 黄小毛,刘宇,朱耀宗,等. 稻油兼用型成条飞播装置设计与试验[J]. 农业机械学报,2023,54(9):111 - 121.
Huang Xiaomao, Liu Yu, Zhu Yaozong, et al. Design and experiment of striped aerial seeding device for rice and oil rape[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(9): 111 - 121. (in Chinese)

[36] 曹兰芹,伍晓明,杨睿,等. 不同氮吸收效率品种油菜氮素营养特性的差异[J]. 作物学报,2012,38(5):887 - 895.
Cao Lanqin, Wu Xiaoming, Yang Rui, et al. Differences of nitrogen status between different N uptake efficiency rapeseed (*Brassica napus* L.) cultivars[J]. Acta Agronomica Sinica, 2012, 38(5): 887 - 895. (in Chinese)

[37] 王玉乾,巢成生,代晶,等. 不同氮效率油菜苗期碳氮代谢差异[J]. 中国油料作物学报,2022,44(3):589 - 601.
Wang Yuqian, Chao Chengsheng, Dai Jing, et al. Difference in carbon and nitrogen metabolism of rapeseed (*Brassica napus* L.) with contrasting nitrogen efficiency at seedling stage[J]. Chinese Journal of Oil Crop Sciences, 2022, 44(3): 589 - 601. (in Chinese)

[38] 谷晓博,徐洋,程智楷,等. 基于无人机多光谱遥感的覆膜冬小麦叶片含水率反演[J]. 农业机械学报,2025,56(9):547 - 556,565.
Gu Xiaobo, Xu Yang, Cheng Zhikai, et al. Inversion of leaf water content for mulched winter wheat based on multi-spectral remote sensing of unmanned aerial vehicle[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(9): 547 - 556,565. (in Chinese)

(上接第 133 页)

[29] Zhang X, Zhang K, Sun Y, et al. Combining spectral and texture features of UAS-based multispectral images for maize leaf area index estimation[J]. Remote Sensing, 2022, 14(2): 331.

[30] Cover T, Hart P. Nearest neighbor pattern classification[J]. IEEE Transactions on Information Theory, 1967, 13(1): 21 - 27.

[31] Hoerl A E, Kennard R W. Ridge regression: biased estimation for nonorthogonal problems[J]. Technometrics, 1970, 12(1): 55 - 67.

[32] Zhang J, Qiu X, Wu Y, et al. Combining texture, color, and vegetation indices from fixed-wing UAS imagery to estimate wheat growth parameters using multivariate regression methods[J]. Computers and Electronics in Agriculture, 2021, 185: 106138.

[33] Xu J, Quackenbush L J, Volk T A, et al. Forest and crop leaf area index estimation using remote sensing: research trends and future directions[J]. Remote Sensing, 2020, 12(18): 2934.

[34] Du R, Lu J, Xiang Y, et al. Estimation of winter canola growth parameter from UAV multi-angular spectral-texture information using stacking-based ensemble learning model[J]. Computers and Electronics in Agriculture, 2024, 222: 109074.

[35] Han Y, Zhang J, Bai Y, et al. Ensemble learning-driven and UAV multispectral analysis for estimating the leaf nitrogen content in winter wheat[J]. Agronomy, 2025, 15(7): 1621.

[36] Li Z, Zhou X, Cheng Q, et al. A machine-learning model based on the fusion of spectral and textural features from UAV multi-sensors to analyse the total nitrogen content in winter wheat[J]. Remote Sensing, 2023, 15(8): 2152.

[37] Tang Z, Lu J, Abdelghany A E, et al. Winter oilseed rape LAI inversion via multi-source UAV fusion: a three-dimensional texture and machine learning approach[J]. Plants, 2025, 14(8): 1245.