

基于无人机多光谱的棉花叶片氮含量的估测研究

吴冠玉，张永江

(河北农业大学农学院，河北保定 071001)

摘要：传统的叶片氮素含量测定需要破坏性取样，费时费力，估计结果也较真实值偏差较大。遥感手段以其大面积监测的优点为作物叶片含氮量监测提供了有效方法。基于常用于作物叶片氮含量估算的多光谱植被指数，分析了植被指数与棉花冠层叶片氮含量的相关性，其中 NDVI、CIre、NDVIre 三个植被指数与棉花冠层叶片氮素含量的相关系数绝对值较高，分别达到了 0.69、0.71、0.70。将植被指数分别输入到随机森林(RFR)、XGBoost 和 CatBoost 模型中，对比了三种模型在不同指标输入时的估测精度，对 CatBoost 模型进行了粒子群优化算法(PSO)改进，得到了改进的 PSO-CatBoost 模型以适用于棉花冠层叶片氮含量的研究，发现 PSO-CatBoost 模型在棉花层叶片氮含量估算中精度最高， R^2 为 0.83，RMSE 为 3.42。

关键词：无人机；棉花；叶片氮含量；CatBoost

中图分类号：S252

Estimation of nitrogen content in cotton leaves based on UAV multispectral study

WU Guanyu, Zhang Yongjiang

(College of Agriculture, Agricultural University of Hebei)

Abstract: The traditional determination of leaf nitrogen content requires destructive sampling, which is time-consuming and labour-intensive, and the estimated results also deviate from the true value. Remote sensing provides an effective method for crop leaf nitrogen content monitoring with its advantages of large area monitoring. Based on the multispectral vegetation indices commonly used for crop leaf nitrogen content estimation, the correlation between vegetation indices and cotton canopy leaf nitrogen content was analysed, in which the absolute values of the correlation coefficients of three vegetation indices, namely NDVI, CIre, and NDVIre, and the nitrogen content of cotton canopy leaves were higher, reaching 0.69, 0.71, and 0.70, respectively. The vegetation indices were inputted into the random forests (RFR), XGBoost, and Catalogues respectively. , XGBoost and CatBoost models, compared the estimation accuracy of the three models at different index inputs, and improved the CatBoost model with particle swarm optimisation algorithm (PSO), and obtained the improved PSO-CatBoost model to be applied to the study of nitrogen content of cotton canopy leaves, and it was found that the PSO-CatBoost model has the highest accuracy in the estimation of nitrogen content in cotton layer leaves, with R^2 of 0.83 and RMSE of 3.42.

Key words: words: UAV; Cotton; Leaf nitrogen content; CatBoost

0 引言

棉花作为我国经济作物的重要支柱，对国民经济发展至关重要。随着科技进步，河北省的棉花种植逐渐走向轻简化和机械化，旨在提高效益^[1]。在此过程中，遥感技术成为监测棉花长势和环境的重要手段，显著减少了田间调查的繁琐和时间成本。作物氮素含量是评估生

基金项目：河北省重点研发计划项目（22326403D）

作者简介：吴冠玉 女 作物遥感

通信联系人：张永江 男 教授 博导 棉花栽培生理与信息技术. E-mail: yongjiangzh@sina.com

长状况和施肥量的关键指标^[2]。氮素不足会抑制作物生长，而过度施肥则可能引发环境问题。因此，无损、快速且准确地获取作物氮素含量至关重要^[3]。传统方法存在周期长、操作难等问题，难以实时指导农业生产。

无人机遥感技术凭借灵活、低成本和高分辨率优势，成为监测作物氮含量的新手段^[4]。无人机可搭载多种传感器，快速获取田间数据，为精准农业实践提供有力支持。这种技术不仅提高了农业生产效率，还为作物的精细化管理提供了数据基础，有助于实现农业的可持续发展。本研究提出的 PSO-CatBoost 模型，经粒子群优化算法改进后，在估算棉花冠层叶片氮含量方面表现卓越，较其他模型具有更高的准确性和更小的误差。这一成果为棉花生长监测和施肥管理提供了科学依据，有助于提升棉花产量和品质，推动棉花产业的健康发展。基于无人机遥感技术结合优化的 PSO-CatBoost 模型，为棉花等作物的氮素监测和管理提供了有效手段，有望在未来农业生产中发挥更大作用。

55 1 材料与方法

1.1 试验地概况

研究区位于河北省邢台市河北农业大学威县试验站（115°27'E, 36°56'N），威县位于河北省邢台市东南部，东邻清河县，西接广宗县，北与南宫市毗连，南与临西县、邱县接壤，总面积 1012 平方千米。威县属暖温带大陆性半干旱季风气候区，四季分明。该地 2023 年日照 2575 h，年平均气温 13.1 °C，无霜期 183 d。年平均降水量 574.3 mm。2023 年棉花生长季降水量为 586.1 mm，平均气温 23.9 °C。

1.2 试验材料

供试品种为“石抗 126”。

1.3 试验设计

65 试验采用大区对比设计，共设 10 个处理，其中我们将十个大区每个大区划分为四个小区作为重复，共有 40 个小区。设置十个处理分别为 CK：不施肥对照、CKF：常量化肥（亩纯养分 N-P₂O₅-K₂O 为 12-5-10）、M1：常量有机肥，鸡粪 1500 kg/hm²、M2：高量有机肥，鸡粪 3750 kg/hm²、L1：常量有机肥，化肥减 10%、L2：常量有机肥，化肥减 30%、L3：常量有机肥，化肥减 50%、H1：高量有机肥，化肥减 10%、H2：高量有机肥，化肥减 30%、H3：高量有机肥，化肥减 50%。每个大区长 20 m，宽 10 m，76 cm 等行距种植。所有肥料撒施于地表后旋耕灌水，4 月 25 播种，其它管理措施同当地高产田。

1.4 测定指标和方法

棉花叶片氮含量测定：采集的棉花植株样本，将该样本的叶片以主茎高度将冠层叶片平均分为上、中、下三部分，将叶片放入烘箱进行上述的烘干过程，烘干完成后将样品进行粉碎，过筛（60 目），采用凯氏定氮法进行棉花光层叶片氮含量的测定，及用 H₂SO₄-H₂O₂ 进行消化处理，使用石墨消解仪进行消煮，消煮后进行定容，稀释，将稀释后的液体用连续流动化学分析仪测定获取叶片全氮含量。

无人机遥感数据获取：为了保证无人机拍摄的影像质量，无人机遥感数据获取需在晴朗

80 无云的天气情况下，在上午 11 点到下午 2 点间，获取植株样本前进行。本试验结合试验地大小和无人机平台的电池续航问题，在保证图片质量的情况下，设置航向重叠率和旁向重叠率为 80% 和 90%，飞行高度为 50 m，地面分辨率为 3.5 cm。本试验使用四旋翼大疆精灵 4 多光谱版无人机搭载 RGB 和多光谱传感器。在获取多光谱图像数据之前，需要用多光谱相机拍摄定标板，对后续处理多光谱数据时进行辐射定标。

85 植被指数计算：在本文中，我们在深入研究前人工作的基础上挑选了 20 个多光谱植被指数，用于对作物叶片氮含量进行估算。为了清晰地呈现这些植被指数的计算方法，我们在表 1 中详细列示了它们的名称及相应的计算公式。

表 1 从多光谱和 RGB 影像中提取的植被指数

Tab.1 Vegetation index definitions extracted from MS and RGB images

植被指数 Vegetation Index	计算公式 Calculation formula	参考文献 References
Normalized difference vegetation index(NDVI) 归一化绿色植被指数	$NDVI=(NIR-R)/(NIR+R)$	S. M. E. GROTE[N ^[5]] 1993
Enhanced vegetation index(EVI) 增强型植被指数	$EVI=2.5 \times (NIR-R)/(NIR+6 \times R-7.5 \times B+I)$	C.L. Wiegand ^[6] 1991
Two-Band Enhanced Vegetation Index(EVI2) 两波段增强型植被指数	$EVI2=2.5 \times (NIR-R)/(NIR+2.4 \times R+I)$	Vera Potopová ^[7] 2020
Global Environment Monitoring Index(GEMI) 全球环境监测指数	$GEMI=[2 \times (NIR^2 R^3 + 1.5 \times NIR + 0.5 \times R)]/(NIR + R + 0.5)$	George D. Carpenter ^[8] 2009
Soil-Adjusted Vegetation Index (SAVI) 土壤调节植被指数	$SAVI=1.5*(NIR-R)/(NIR+R+0.5)$	Walter C Bausch ^[9] 1993
Modified Soil-Adjusted Vegetation Index (MSAVI) 改进型土壤调节植被指数	$MSAVI=0.5 \times [2 \times NIR + 1 - \sqrt{(2 \times NIR + 1)^2 - 8 \times (NIR - R)}]/[0.5 \times NIR + R - 0.5 \times 0.33 + (1 + 0.33^2)]$	A. Begue ^[10] 1995
Transformed Soil-Adjusted Vegetation Index (TSAVI) 转换型土壤调节植被指数	$TSAVI=0.33 \times (NIR - 0.33 \times R - 0.5) / [0.5 \times NIR + R - 0.5 \times 0.33 + (1 + 0.33^2)]$	Stefano Marino ^[11] 2014
Near-Infrared Reflectance times Vegetation(NIRv) 近红外反射率	$NIRv=NDVI*NIR$	Grayson Badgley ^[12] 2019
Chlorophyll Index Red Edge (CIre) 红边叶绿素指数	$CIre=NIR / REDedge - 1$	Carl F. Jordan ^[13] 1969
Red Edge Normalized Difference Vegetation Index (NDVIre) 红边标准化差异植被指数	$NDVIre=(NIR - REDedge) / (NIR + REDedge)$	Brigitte Leblon ^[14] 1991
Green Chromatic Coordinate (GCC) 绿色色度指数	$GCC=G / (R + G + B)$	ALAN R. Gillespie ^[15] 1987
Green Normalized Difference Vegetation Index (GNDVI) 绿色归一化差值植被指数	$GNDVI=(NIR - G) / (NIR + G)$	C.S.T Daughtry ^[16] 2000
Green Red Vegetation Index (GRVI)	$GRVI=(G - R) / (G + R)$	Assaf Chen ^[17] 2019

绿红植被指数 Red to Green Ratio Index(RGRI) 红绿比指数	$RGRI=R/G$	Paolo Villa ^[18] 2015
Woebbecke Index (WI) 沃贝克指数	$WI=(G-B)/(R-G)$	J. Torres-Sánchez ^[19] 2014
Visible Atmospherically Resistant Index(VARI) 可见光大气阻抗植被指数	$VARI=(G-R)/(G+R+B)$	G. J. Grenzdörffer ^[20] 2014
Green Leaf Index (GLI) 绿叶指数	$GLI=(2\times G-R-B)/(2\times G+R+B)$	Justin van Wart ^[21] 2013
Improved Green Leaf Index(GLI2) 改进的绿叶指数	$GLI2=(2\times G-R+B)/(2\times G+R+B)$	Elma MJ Salentijn ^[22] 2009
Infrared Percentage Vegetation Index (IPCA) 红外植被指数	$IPCA=0.994\times R-B/14\times G-R/$	Hossein ali Fallahi ^[23] 2016
Normalized Difference Index(NDI) 归一化差值植被指数	$NDI=(RN-GN)/(RN+GN+0.01)$	Karla Müller ^[24] 2008
Excess Green Index(EXG) 超绿指数	$EXG=2\times GN-RN-BN$	Narut Soontaranon ^[25] 2014

无人机遥感数据获取和取样时间：在播种后 75、90、105、120、135 天进行无人机遥感数据获取，同时进行棉花植物样本的获取

1.5 数据分析

采用大疆智图、ENVI、ArcMap 中进行辐射定标，得到正射影像、波段组合、地理配准、画小区、做掩膜消除土壤背景，提取植被指数。

2 结果与分析

2.1 有机肥替代棉花各时期冠层叶片氮含量的描述性统计

根据表 2 所示，本试验每次采集的棉花冠层叶片样本为 58 个，全部样本为 290 个，所有样本叶片氮含量介于 15.13~47.80 g/kg, 平均值为 30.36 g/kg，中位数为 30.30 g/kg，标准差 7.92，变异系数为 24.09%；建模集样本为 203 个其叶片氮含量的值在 15.13~44.65 g/kg，平均值为 28.73 g/kg，中位数为 28.31 g/kg，标准差为 6.89，变异系数为 24.00%。该样本的变异系数在 25% 左右，可以间接说明本次试验中采集的样本比较均，可以保证随机选取的样本具有代表性，减少在模型构建中的偏差估计的影响。

表 2 棉花各时期冠层叶片氮含量的描述性统计

Tab.2 The descriptive statistics of canopy leaf nitrogen content in cotton at various growth stages

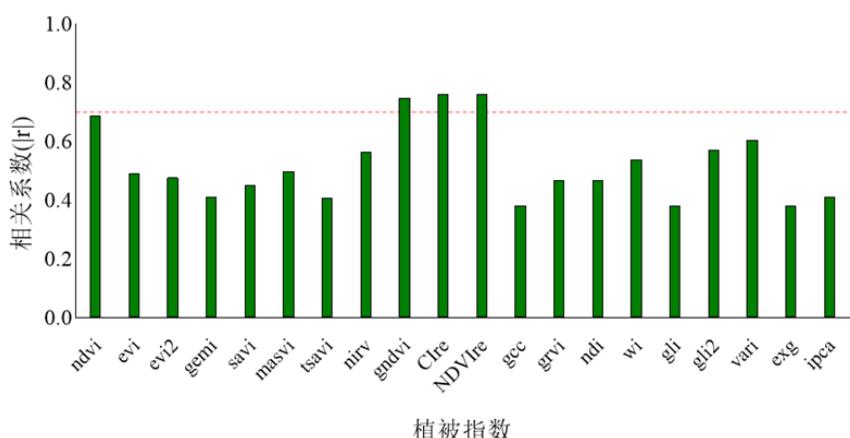
取样时间	样本数	叶片氮含量 (g/kg)					变异系数 (%)
		最小值	最大值	均值	中位数	标准差	
7月9日	58	30.02	47.80	39.20	39.60	4.31	11.00
7月24日	58	21.40	44.65	34.36	35.80	6.17	17.96

8月7日	58	18.82	39.40	30.79	31.22	4.78	15.53
8月23日	58	17.18	39.88	24.15	23.72	5.23	21.65
9月5日	58	15.13	39.88	23.55	22.95	5.43	23.06
总	290	15.13	47.80	30.36	30.30	7.92	24.09
建模集	203	15.13	44.65	28.73	28.31	6.89	24.00
验证集	87	17.04	47.80	34.16	35.80	8.85	24.89

105

2.2 植被指数与棉花叶片氮含量的相关性分析结果

由图 1 可以观察到所有基于原始光谱计算的植被指数与棉花叶片氮含量的相关系数绝对值均未超过 0.80, 这表明这些植被指数与棉花叶片氮含量的相关性没有达到极强相关的水平。尽管如此, 其中 NDVI、CIre、NDVIRE 这三个植被指数与棉花冠层叶片氮素含量的相关系数绝对值相对较高, 分别达到了 0.69、0.71、0.70。



110

图 1 植被指数与棉花冠层叶片氮含量相关性分析图

Fig.1 Correlation analysis of indicators and canopy leaf nitrogen Content of cotton

2.3 基于随机森林 (RFR) 的棉花冠层叶片氮素含量反演模型建模分析

图 2 为随机森林回归模型对棉花冠层叶片氮素含量估算结果, 图中的 R^2 和 RMSE 表示验证集的结果精度。我们发现基于多光谱植被指数的监测模型得到的 R^2 为 0.69, RMSE 为 4.44, 由图可知, 我们可以发现估算结果中出现了明显的高估现象, 尤其是在叶片氮含量为 25~45 g/kg 高估现象更为明显。

115

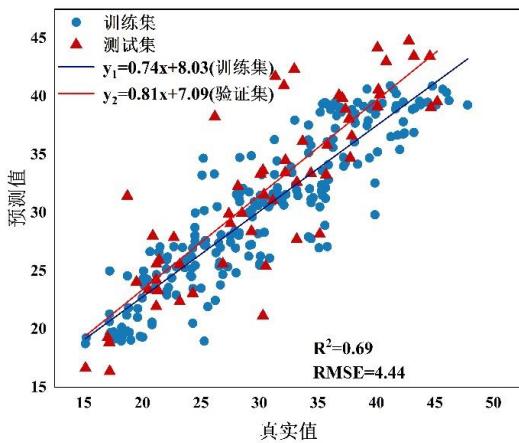


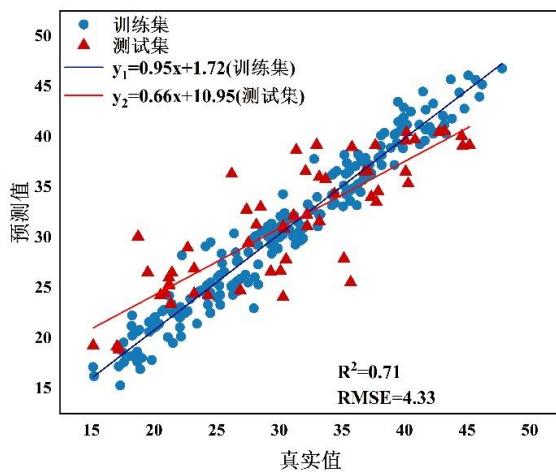
图 2 随机森林回归估算结果图

120

Fig.2 Figure of RFR estimation result

2.4 基于 XGBoost 的棉花冠层叶片氮素含量反演模型建模分析

图 3 展示了 XGBoost 回归模型对棉花冠层叶片氮素含量的估算结果，我们发现基于植被指数的监测模型得到的 R^2 值为 0.71，表明模型与数据之间具有一定的拟合程度，然而该模型的 RMSE 值为 4.33，意味着估算值与真实值之间存在一定的误差。



125

图 3 XGBoost 回归估算结果图

Fig.3 Figure of XGBoost estimation result

2.5 基于 CatBoost 的棉花冠层叶片氮素含量反演模型建模分析

图 4 展示了 CatBoost 回归模型对棉花冠层叶片氮素含量的估算结果，其表现与 XGBoost 模型相似。我们发现基于植被指数的模型与数据拟合度尚可， R^2 值为 0.72；但其 RMSE 值为 4.07，表明估算精度仍有提升空间。

130

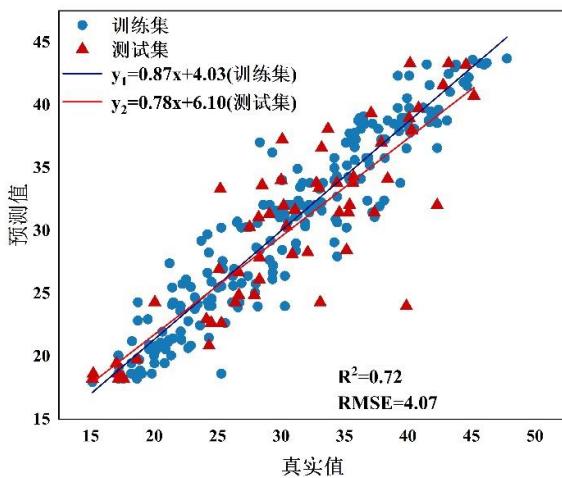


图 4 CatBoost 回归估算结果图

Fig.4 Figure of CatBoost estimation result

135

2.6 基于 PSO-CatBoost 的棉花冠层叶片氮素含量反演模型建模分析

140

从图 5 中我们观察到 PSO-CatBoost 回归模型在棉花冠层叶片氮素含量估算中的应用结果。用植被指数作为输入参数时，PSO-CatBoost 模型的 R^2 值达到了 0.75。与 CatBoost 模型和 PSO-XGBoost 模型相比，经过 PSO 优化后的模型与数据之间的拟合程度更佳。PSO-CatBoost 的 RMSE 值为 3.70，相较于 CatBoost 模型和 PSO-XGBoost 模型有所降低，表明 PSO-CatBoost 的预测精度提升，误差减少。

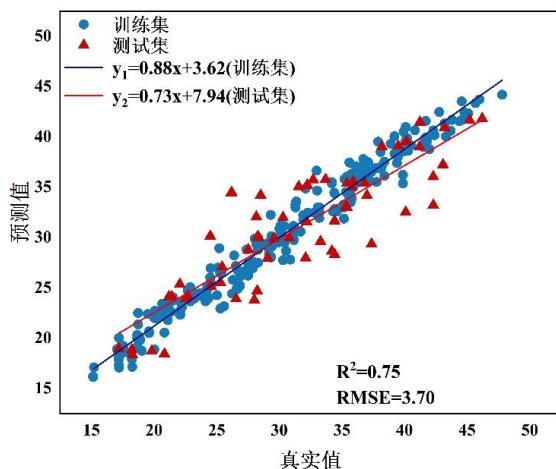


图 5 PSO-CatBoost 回归估算结果图

Fig.5 Figure of PSO-CatBoost estimation result

145

3 讨论

以往的研究往往仅依赖单一的植被指数来估算作物叶片氮浓度，但这会由于信息量的局

150

限，而导致预测精度受限。在本研究中，我们尝试了一种不同的方法，即将所有测得的植被指数作为输入特征，输入到机器学习模型中。虽然多个植被指数之间可能存在潜在的干扰，但这也为模型提供了更丰富的信息，有助于提升预测的准确性^[26]。本研究采用了多种机器学习方法，对所有测得的植被指数进行综合分析，对棉花冠层叶片氮含量进行估计。经过对比分析，我们发现 PSO-CatBoost 模型在估计效果上表现更佳。这一结果进一步验证了 PSO-CatBoost 模型在复杂数据环境下的优越性能，为作物氮素营养监测提供了更加可靠和准确的方法。

155

在本研究中，与 CatBoost 和 XGBoost 模型相比，RFR 在本研究中的估计效果较差。这可能是因为 RFR 在处理本试验数据时存在一定的局限性，无法做出超出训练集数据范围的预测，导致在验证某些具有特定噪声的数据时性能不佳^[27]。

160

基于多光谱植被指数的 XGBoost 和 CatBoost 模型在估算棉花冠层叶片氮素含量时存在高估和低估现象，因此，在这两种模型的基础上我们对其进行了仔细调参，降低模型过拟合风险，确保模型的准确性。其中，CatBoost 在处理类别特征较多的数据集时相比于 RFR 和 XGBoost 模型具有明显优势，即便在较小数据集上也能展现良好性能。为进一步提升模型性能，我们采用了 PSO 算法对 CatBoost 进行参数优化，得到了 PSO-CatBoost 模型。结果显示，PSO 优化显著提高了模型的预测精度和稳定性。所以 PSO-CatBoost 是一种有效的棉花叶片氮含量估算方法^[28]。

165

本研究对棉花冠层叶片氮含量的估计结果中显示，未进行优化的模型中 CatBoost 的预测效果更好其 R 值达到了 0.72，RMSE 值为 4.07。对其对其进行 PSO 优化后的预测结果中 R 值达到了 0.75，RMSE 值为 3.70。这证明了 PSO 算法在对于该模型的参数寻优对本试验的数据有更好的效果，为 CatBoost 提供了最佳的参数设置，从而克服了手动调参的繁琐性，提升了模型的预测性能。而 CatBoost 模型本身可以通过不断修正和更新样本权值来提高模型的准确性，并通过学习训练集的特征来控制误差。对数据的适应性更强，具有较强的成图能力和抗干扰能力^[29]。此外，CatBoost 对传统的梯度增强决策树方法进行了优化，采用有序增强进行梯度估计。这使得它可以获得梯度的无偏估计，从而减少梯度估计偏差的影响，并且模型具有更强的泛化能力。而经过 PSO 优化后的模型在参数优化、处理分类和数值变量以及缺失值处理等方面具有显著优势，在本实验的小训练集下，该方法仍然具有很高的自适应能力和抗噪声能力，估计结果最优。

170

175

4 结论

180

本文提出了一个更适合于估计棉花冠层叶片氮含量的 PSO-CatBoost 模型。对于不同模型在估算棉花冠层叶片氮含量时的性能进行对比分析后，发现经过粒子群优化算法改进的 PSO-CatBoost 模型在 R 和 RMSE 方面明显领先于其他模型，表现最佳。本研究结果表明优化后的 PSO-CatBoost 模型在棉花冠层叶片氮含量的估算中具有更高的准确性和更小的误差。

[参考文献] (References)

- [1] 邱慧. 河北省棉花产业发展研究[D]. 河北科技师范学院, 2024.
- [2] 薛利红, 罗卫红, 曹卫星, 等. 作物水分和氮素光谱诊断研究进展[J]. 遥感学报, 2003(1): 730-80.
- [3] 陈鹏飞, 梁飞. 基于低空无人机影像光谱和纹理特征的棉花氮素营养诊断研究[J]. 中国农业科学, 2019,

- 185 52(13): 2220-2229.
[4] Hansen P M, Schjoerring J K. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression[J]. *Remote Sensing of Environment*, 2003, 86(4): 542-553.
- 190 [5] GROTON S M E. NDVI-crop monitoring and early yield assessment of Burkina Faso[J]. TitleREMOTE SENSING, 1993.
- [6] C. L. Wiegand, A. J. Richardson, D. E. Escobar, et al. Vegetation indices in crop assessments[J]. *Remote Sensing of Environment*, 1991, 35(2-3): 105-119.
- [7] Vera Potopová Miroslav Trnka, Pavel Hamouz, , et al. Statistical modelling of drought-related yield losses using soil moisture-vegetation remote sensing and multiscalar indices in the south-eastern Europe[J]. *Agricultural Water Management*, 2020, 236: 106168.
- 195 [8] Carpenter G D. GEMI: Fostering Environmental Excellence by Business World-wide[J]. *Environmental Conservation*, Cambridge University Press, 1991, 18(2): 181-182.
- [9] Walter C. Bausch Soil background effects on reflectance-based crop coefficients for corn[J]. *Remote Sensing of Environment*, 1993, 46(2): 213-222.
- 200 [10] Begue A, Myneni R. Operational NOAA vegetation indices-absorbed PAR relationships for Sahelian vegetation canopies[J]. *IEEE*. 1995, 2: 1296-1298.
- [11] Marino S, Alvino A. Proximal sensing and vegetation indices for site-specific evaluation on an irrigated crop tomato[J]. *European Journal of Remote Sensing*, 2014.
- 205 [12] Badgley G, Anderegg L D L, Berry J A, et al. Terrestrial gross primary production: Using NIRV to scale from site to globe[J]. *Global Change Biology*, 2019, 25(11): 3731-3740.
- [13] Ismail M I. Assessment of genetic improvement in doubled haploid lines of bread wheat under heat-stressed environment[J]. Food and Agriculture Organization of the United Nations 2007.
- [14] Weicheng Wu. The Generalized Difference Vegetation Index (GDVI) for Dryland Characterization[J]. *Remote Sensing*, 2014, 6(2): 1211-1233.
- 210 [15] C. S. T. Daughtry, C. L. Walthall, M. S. Kim, et al. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance[J]. *Remote Sensing of Environment*, 2000, 74(2): 229-239.
- [16] Carl F. Jordan. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor[J]. : Ecological Society of America, 1969, 50(4): 663-666.
- 215 [17] Brigitte Leblon, Martine Guerif, Frédéric Baret The use of remotely sensed data in estimation of PAR use efficiency and biomass production of flooded rice[J]. *Remote Sensing of Environment*, 1991, 38(2): 147-158.
- [18] Villa P, Stroppiana D, Fontanelli G, et al. In-Season Mapping of Crop Type with Optical and X-Band SAR Data: A Classification Tree Approach Using Synoptic Seasonal Features[J]. *Remote Sensing*, 2015, 7(10): 12859-12886.
- 220 [19] ALAN R. GILLESPIE, ANNE B. KAHLE, RICHARD E. WALKER. Color enhancement of highly correlated images. II. Channel ratio and
- [20] Assaf Chen, Valerie Orlov-Levin, Moshe Meron. Applying high-resolution visible-channel aerial imaging of crop canopy to precision irrigation management[J]. *Agricultural Water Management*, 2019, 216: 196-205.
- [21] J. Torres-Sánchez, J.M. Peña, A.I. de Castro, et al. Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV[J]. *Computers and Electronics in Agriculture*, 2014, 103: 104-113.
- 225 [22] Grenzdörffer G J. Crop height determination with UAS point clouds[A]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences[C]. Copernicus GmbH, 2014, XL-1: 135-140.
- [23] Fallahi H ali, Ebrahimnejad S, Sabouri H, et al. Evaluation of Genotype × Interaction Effects on Grain Yield of Barely Genotypes using Additive Main Effects and Multiplicative Interactions (AMMI)[J]. *Journal of Crop Breeding*, 2018, 9(24): 144-151.
- 230 [24] Adam E, Mutanga O, Rugege D. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review[J]. *Wetlands Ecology and Management*, 2010, 18(3): 281-296.
- [25] Justin van Wart, Lenny G.J. van Bussel, Joost Wolf, et al. Use of agro-climatic zones to upscale simulated crop yield potential[J]. *Field Crops Research*, 2013, 143: 44-55.
- 235 [26] Salentijn E M, Goryunova S V, Bas N, et al. Tetraploid and hexaploid wheat varieties reveal large differences in expression of alpha-gliadins from homoeologous Gli-2 loci[J]. *BMC Genomics*, 2009, 10(1): 1-14.
- [27] Karla Muñller, Ulf Bo'tcher, Franziska Meyer-Schatz, et al. Analysis of vegetation indices derived from hyperspectral reflection measurements for estimating crop canopy parameters of oilseed rape (*Brassica napus* L.)[J]. *Biosystems Engineering*, Academic Press, 2008, 101(2): 172-182.
- 240 [28] Soontharanon N, Srestasathiern P, Rakwatin P. Rice growing stage monitoring in small-scale region using ExG vegetation index[A]. 2014 11th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)[C]. 2014: 1-5.
- [29] Irene Chrysafis, Giorgos Mallinis, Ioannis Gitas, et al. Estimating Mediterranean forest parameters using multi seasonal Landsat 8 OLI imagery and an ensemble learning method[J]. *Remote Sensing of Environment*, 2017, 199: 154-166.