

农作物遥感识别与单产估算研究综述

赵龙才 李粉玲 常庆瑞

(西北农林科技大学资源环境学院, 陕西杨凌 712100)

摘要: 遥感凭借其快速、宏观、无损及客观等特点,在快速获取与解析作物类型、种植面积、产量等信息方面具有独特优势。遥感提取和解译的作物空间分布图、种植面积、产量信息可以服务于农业资源监管、农业信息普查、农业保险、农业投资、精准农业等方面。本文分别就农作物遥感识别与农作物单产遥感估算的研究现状、面临的问题、潜在研究方向进行了总结概述。首先总结了农作物遥感识别特征与分类模型的研究现状,针对遥感识别特征与作物类型缺乏知识关联的核心问题,提出利用深度学习方法协同学习作物生长过程中的“时-空-谱”特征,并构建面向农作物遥感识别的知识图谱,从而解决当前农作物遥感识别在识别精度和识别效率方面的问题。然后,分别从经验统计模型、遥感光合模型、作物生长模型方面对当前作物单产遥感估算进行分析总结,提出随着高空间分辨率、高光谱分辨率、高时间分辨率数据的普及和深度学习技术发展,未来应充分利用作物生长模型机理性强、深度学习对复杂问题建模能力强的特点,使用作物生长模型进行点位尺度模拟以驱动深度学习完成复杂场景下的建模学习,最终实现以机理做约束、以深度学习做空间外推的单产估算模式。

关键词: 农业遥感; 类型识别; 单产估算; 作物生长模型; 深度学习

中图分类号: P407.8 **文献标识码:** A **文章编号:** 1000-1298(2023)02-0001-19



Review on Crop Type Identification and Yield Forecasting Using Remote Sensing

ZHAO Longcai LI Fenling CHANG Qingrui

(College of Natural Resources and Environment, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: Remote sensing is of unique advantages in quickly obtaining and analyzing information such as crop types, planting areas, and yields duo to its rapid, macroscopic, non-destructive and objective observing characteristics. The crop spatial distribution map, planting area, and yield information extracted or interpreted by remote sensing can serve many agricultural applications such as resource supervision, information census, insurance and investment, and precision agriculture. The research status, problems and future potential research directions of crop type identification and yield estimation using remote sensing were summarized. Firstly, the research status of crop type identification was summarized from aspects of identification features and classification models. In view of the core problem of the lack of crop-wised identification feature knowledge, deep learning methods were proposed to be used to collaboratively learn the feature of “temporal-spatial-spectrum” in the process of crop growth, and finally a knowledge graph for crop remote sensing identification was constructed, so as to solve the problems, identification accuracy and identification efficiency, that affected current crop type identification using remotely sensed imagery. Secondly, by summarizing characteristics of three types of crop yield estimation models (i. e., empirical statistical model, remote sensing photosynthesis model and crop growth model), highly integrating crop growth model and deep learning methods were proposed to forecast crop yield which may be a valuable potential solution in the future, under the circumstance of the popularization of high spatial, high spectral, and high temporal-resolution data and the development of deep learning technology. Because crop growth model was of strong mechanism and deep learning methods were capable of learning complex problems. In the future, crop growth models can be used for

point-scale simulation to drive deep learning methods to build yield forecasting model in complex scenarios, and finally a yield estimation model was achieved which used growth mechanism as constraints and deep learning model as spatial extrapolation.

Key words: agricultural remote sensing; type identification; yield forecasting; crop growth model; deep learning

0 引言

粮食安全的首要关注点是粮食播种面积与产量。对农作物生长状态的实时动态监测与产量信息的快速准确把握,不仅对于国家粮食安全相关政策决策的制定、市场价格宏观调控、农村经济发展、以及对外粮食贸易等具有重要价值,同时还对农田生产的智能化管理、农业保险的精准服务等具有现实意义。

遥感技术凭借其快速、宏观、无损以及客观等特点,在快速获取与解析作物类型、种植面积、产量、长势、灾害等信息方面具有独特优势。农作物遥感识别是实现农田作物信息提取和解析的前提与基础,在一定程度上决定和影响其它信息解析的可行性和准确性,因此农作物遥感识别的精度和效率是农业遥感关注的核心问题之一。其次,基于遥感的作物单产估算已经成为获取大区域尺度粮食产量信息的重要方式,对分析国家粮食安全形势等具有重要作用,也是农业遥感的重要研究内容之一。本文从农作物遥感识别与农作物单产估算两方面进行总结,系统分析发展现状、存在的问题及未来发展方向。

1 农作物遥感识别研究

农作物遥感识别主要以监督学习为主,其基本过程是以遥感影像所表达出的不同作物的特征分布模式为基础,利用分类算法对特征分布模式进行判别,从而实现作物类型识别(图 1)。因此,分类算法和遥感识别特征是农作物遥感识别的两个决定性组成部分。其中,识别特征是表达类别间差异的媒介,其决定了不同作物间的可分离性的理论上限,识别算法则是在最大程度上识别这种特征分布差异并逼近该理论上限。因此,对于农作物遥感识别精度而言,识别特征相较于识别算法具有更重要的地位。本文分别从遥感识别特征与识别算法两方面对农作

物遥感识别进行总结。

1.1 作物遥感识别特征研究

1.1.1 光谱特征研究

不同作物的植株形态、冠层结构、生理生化特性等导致其在不同光谱波段上具有不同的光谱反射特性,从而使得光谱特征具备区分不同的农作物的能力,也是农作物遥感分类应用最广泛和最基本的识别特征。

(1)多光谱特征

利用多光谱特征进行农作遥感识别是农业遥感领域的基础应用之一,基于光谱特征的植被类型自动分类技术最早可以追溯到 1970 年。最初的基于多光谱特征的农作物遥感分类以目视解译为主,即解译人员凭借影像上所表现出的亮度、色调、空间位置、几何结构与形状,亮度明暗变化所形成的纹理等特征识别农作物类别。从参与农作物遥感识别的多光谱特征种类来看,多光谱特征的发展和应用与多光谱卫星传感器的发展高度相关,最典型的特征组合是 3 个可见光波段(蓝、绿、红)与近红外波段的组合;随着多光谱传感器加入红边波段、短波红外波段,红边及短波红外特征在农业遥感监测与识别中应用越来越广泛。基于光谱特征识别的作物类型基本涵盖了所有主要粮食作物,例如小麦、水稻、玉米、大豆、棉花、甘蔗及其他经济作物^[1-5]。

由于“同物异谱、异物同谱”现象的广泛存在,直接使用多光谱特征进行遥感识别的精度越来越不能满足现实需要。在此背景下,大量由人工知识参与的遥感植被指数特征被设计出来,它们通常是基于两个或两个以上的原始光谱特征进行特定的数学变换而得到。遥感植被指数通常综合两个及两个以上的原始光谱特征,可以反映植被在某一方面的特性从而对农作物遥感识别表现出更加重要的作用。例如归一化植被指数(NDVI)和绿度植被指数(VI green)经常被用于农情遥感监测,即监测农作物长势和生长过程^[6];土壤调整型植被指数(SAVI)可以在缓解土壤背景影响的基础上有效提高对不同作物的识别精度^[7]。目前,常用的遥感植被指数已经发展到了一百多种,是农作物遥感识中多光谱特征的一个重要组成部分^[8]。目前,农作物遥感识别常用的多光谱数据源见表 1^[9-13]。




图 1 农作物遥感识别基本流程图

Fig. 1 Flowchart of crop type identification using remote sensing

表 1 农作物遥感识别常用的多光谱遥感数据源

Tab.1 Common remote sensing data source for crop type identification

数据源	常用波段	空间分辨率/m	重访周期/d
Landsat 系列	B,G,R,Nir,SWIR1, SWIR2	30	16
SPOT 系列	B,G,R,Nir	6	4~5
IRS 系列	B,G,R,Nir	23.5,56	24
Sentinel 2A/B	B,G,R,Re1,Re2,Re3,Nir,SWIR1, SWIR2	10, 20	5
Worldview 2/3/4	B,G,R,Nir	<1.8	1
RapidEye	B,G,R, Re1,Nir	5	1
Gaofen-1,2,6	B,G,R,Nir	8,16	4(测摆)

注：B、G、R、Re、Nir、SWIR 分别表示蓝、绿、红、红边、近红外及短波红外波段。

(2)微波散射特征

可见光至短波红外范围内的光谱特征均是由传感器被动接收并记录地表反射的电磁波能量,而该波长范围的电磁波辐射传输过程极易受到大气状况影响,从而在一定程度上影响多光谱数据的可用性。合成孔径雷达(SAR)以微波频率发射和接收能量,由于其工作波段波长较长,不易受到大气影响,从而具有了“全天时全天候”可用的特性。SAR 传感器记录的后向散射电磁波能力很大程度上取决于目标的几何结构和介电性能。不同作物具有的不同冠层结构、植株形状、土壤背景等均随着作物的生长而变化,SAR 数据对这些结构差异及具有不同介电性能的土壤背景具有非常好的响应^[14],因此微波散射特征也被用于农作物遥感识别^[15],并有研究已经证明微波散射特征对作物生物物理参数,如叶面积指数^[16]、生物量^[17]、冠层高度^[18]等,具有良好的敏感性。尽管多光谱遥感特征已经广泛应用于农业遥感领域,但 SAR 应用研究的不断发展以及不同频率和极化条件下 SAR 数据的可用性提高了它在农业遥感领域中的地位。目前,在农作物遥感识别领域中,SAR 数据多用于识别水稻,常用数据类型见表 2。

表 2 基于微波散射特征的作物识别

Tab.2 Crop type identification based on SAR image

卫星名称	波段	极化方式	作物类型
ERS-1	C	VV	水稻 ^[19]
RADARSAT-1/2	C	HH	水稻 ^[20]
ASAR	C	HH, VV	水稻 ^[21]
ALOS PALSAR	L	HH, VV	水稻 ^[22]
TerraSAR	X	HH, VV	水稻 ^[23]

一般情况下,SAR 数据在作物生长中后期的识别精度高于作物生长的前期,作物生长前期,冠层覆盖度较低,雷达后向散射能量中有相当一部分是背

景土壤的贡献。因此,利用 SAR 数据进行早期作物类型识别存在一定困难。除此之外雷达数据受到噪声的影响大,数据获取成本较高,数据处理相对复杂,同时受极化方式的影响,微波遥感在识别农作物方面依然存在着很大的潜能。

(3)高光谱数据特征

高光谱成像仪光谱波段非常窄,辐射分辨率可以达到纳米数量级,光谱通道数通常多达数十甚至数百个,而且各光谱通道间往往是连续的,成像光谱仪的波段范围通常可以覆盖紫外、可见光、近红外和短波红外(350~2 500 nm)。光谱分辨率的提高大幅增加了 对地物的分辨识别能力。在农业应用方面,由于高光谱数据的电磁波波长范围更广,光谱分辨率很高,能探测到农作物在光谱特征上的微小差异,从而被广泛用于作物类型精确识别,叶片或者植株的生物物理及生物化学特性的探测,监测作物胁迫、作物疾病等。在利用高光谱数据进行作物识别方面,有研究基于 SDA 技术从高光谱数据选择了最佳频段区分观赏植物、豆类和油菜作物,结果表明:在近红外和中红外波段,具有鉴别豆类作物的 4 个最佳波段,即 750、800、940、960 nm;在油菜作物的区分过程中主要取决于 550、690、740、770、980 nm;而在花朵的区分过程中 420、470、480、570、730、740、940、950、970、1 030 nm 波段表现出非常良好的区分性^[24]。即使在作物种植情况比较复杂 的条件下,高光谱数据对于区分作物类型同样表现出良好的可用性^[25]。除作物识别应用外,有研究表明高光谱反射率数据在区分作物品种(基因型)方面同样有良好表现,充分体现了高光谱特征的光谱分辨率的优势^[26-27]。

高光谱数据虽然具有明显的光谱优势,但是其缺点也较为突出。一方面,高光谱数据包含特征波段太多,各波段之间具有明显相性,信息冗余现象较为严重,直接使用全部波段数据会导致模型分类精度出现“不升反降”的现象(特征维数灾难)。此外,由于不同作物之间光谱相似性更高,由此可能导致协方差矩阵的奇异性,严重影响农作物分类识别的精度^[28]。因此,高光谱数据降维方法研究成为必然,典型降维方法包括:主成分分析(PCA)、均匀特征设计(保留光谱形状信息但减少特征维数)、小波变换以及结合人工神经网络的特征选择^[29-30]。另一方面,高光谱数据在具有高辐射分辨率的同时,其空间分辨率往往较低,光谱遥感影像上混合像元问题较为突出,难以实现精细空间尺度的农作物类型识别。以上两点在一定程度上限制了高光谱数据在农作物遥感识别中的广泛应用。

1.1.2 空间纹理特征研究

随着遥感数据空间分辨率不断提高,地物几何细节信息得到越来越充分的表达,不同地物之间的空间细节差异在影像上表现明显。因此,利用高空间分辨率光学影像或 SAR 影像(QuickBird、GeoEye、TerraSAR-X、RADARSAT-2 等)进行农作物遥感识别时,除了光谱特征及微波散射特征外,空间细节信息也是表达不同作物差异的重要特征源。因此,用于表达空间细节差异的空间纹理特征在遥感分类中发挥着越来越重要的作用。

目前,国内外学者发展了多种纹理度量方法,可以总结为 4 类:基于统计方法的纹理特征、基于结构方法的纹理特征、基于模型的纹理特征、基于数学变换的纹理特征^[31-34]。其中,遥感应用中最常用的是基于统计方法的灰度共生矩阵(Grey level co-occurrence matrix, GLCM)纹理特征和基于地统计学的特征纹理。

GLCM 可以同时反映图像的灰度分布特征和相同(相似)灰度像元的空间位置分布特性,是影像灰度变化的二阶统计特征^[35]。基于 GLCM 的纹理特征在遥感分类中被广泛应用^[36-37]。例如,在分析不同纹理特征对遥感分类精度影响的研究中发现:纹理特征和光谱特征的结合可以提高分类精度,相比于仅使用原始光谱特征的分类结果,纹理特征的加入使分类精度提高 9%~17%^[38]。在基于高分辨率影像的植被类型分类研究中,纹理特征与原始光谱特征的结合使分类精度提升 8% 以上^[39]。地统计学一般用于解释空间相关性,常被用于空间数据插值、空间抽样方法估计、空间预测模型构建等。在遥感分类领域中也越来越多的研究利用其作为一种纹理计算方法^[40],并将其与原始光谱特征相结合来改善遥感分类精度。相关研究表明基于地统计学的纹理测量方法可以提供比基于 GLCM 纹理更好的分类结果^[41-42]。除上述两种常用问题特征外,基于小波变化的纹理特征、Gabor 纹理特征进行农作物遥感分类识别,识别精度同样得到提升^[43-45]。

上述研究多数集中在将纹理特征和原始光谱特征结合使用,证明纹理特征的加入使分类精度提高,但有关纹理特征之间的相关性以及它们各自是如何影响分类结果的研究较少,即这些研究往往不能单独表明具体纹理特征对遥感分类的精度及对分类精度的改善。由于高空间分辨率遥感数据通常包含较少光谱波段,其空间信息丰富度高于光谱信息丰富度,在地物几何信息得到加强、“异物同谱”现象得到抑制的同时,“同物异谱”问题变得突出,即相同

地物内部差异变大。此外,高空间分辨率遥感影像易受阴影的影响,引起分类精度的降低。另外纹理特征随着研究目标和遥感影像而变化,纹理特征的提取方法、所使用的基础波段、滑动窗口尺寸等因素都将影响纹理特征的有效性,因此纹理特征很难标准化并提供稳定的有效性。

1.1.3 数据融合特征研究

综合利用不同类型(平台)传感器所获取的数据是对利用单一数据源进行农作物遥感分类识别的一种补充。多源遥感数据融合可充分利用不同数据的优点,达到提高分类识别精度的目的^[46]。典型的多源遥感数据融合应用包括光学数据与雷达数据融合、高空间分辨率数据与低空间分辨率数据融合应用^[47-49]。有研究表明综合利用雷达与光学数据对作物类型的识别精度远高于仅使用雷达数据或者仅使用光学数据^[50]。融合使用多波段 SAR 数据的农作物识别研究表明,利用 X 和 C 两个波段的 SAR 数据进行农作物分类,取得优于单波段 SAR 数据的分类效果,整体精度提高约 10%^[51]。多极化 SAR 数据的融合使用同样被证明可以有效提高农作物遥感识别精度,例如综合使用 PalSAR 的水平极化(HH)与交叉极化(HV)数据、ASAR 的垂直极化数据(VV)、以及 TM 多光谱数据进行农作物精细分类的研究中,发现双频多极化 SAR 数据对不同作物间潜在差异的表达能力较强,不同类型作物在该特征上的可分离性较高,有利于提高作物类型的整体识别精度^[52]。众多前人的研究结果都表明雷达数据融合多光谱数据在农作物类型识别中具有较大的优势^[53]。不同多光谱数据的融合使用,可以有效地缓解单一数据源可能面临的关键时相数据缺失的情况,在提高数据可用性的同时,提高农作物遥感识别精度。例如, Sentinel-2 数据与 Landsat 8 数据具备良好的协同使用条件,同时在地块尺度上的农作物遥感识别应用中取得了良好的精度,验证了不同多光谱遥感数据协同使用的优势^[54-55]。

数据融合特征的优势在于可以综合两种及以上类型数据的优势,融合后的特征空间对不同作物间的潜在特征差异表达能力更强,有利于提高农作物遥感识别精度;但同时不同遥感数据融合操作易受到数据融合方法、融合尺度等因素的影响,从而影响融合数据在实际应用中的稳定性。

1.1.4 时相变化特征研究

农作物生长是一个缓慢变化的动态过程,其植株形态、冠层结构、生理生化参数都随着作物生长而缓慢变化,从而导致其冠层反射率随作物生长过程而缓慢动态变化(如 NDVI 时间序列曲线,图 2)。

不同作物在其生长周期中会表现出不同的变化趋势，而单一时相的数据只捕捉了地表物体在一瞬间的电磁波反射信息，受“同物异谱，异物同谱”现象影响，单一时相特征对地物的辨别能力有限，在某些情况下分类识别精度不高^[56]。随着在轨卫星及传感器数量的增加，对于地面同一位置的重复观测频率越来越高，因此如何利用时间序列遥感数据来表达作物生长过程中丰富的季节性变化特征并将其用于农作物遥感识别，已经成为一个研究热点。




图 2 农田 NDVI 时间序列 (2000—2020 年)

Fig. 2 NDVI time series of farmland (2000—2020)

当前，利用时相变化特征进行农作物遥感识别主要是基于植被指数时间序列数据。即利用不同时相的多光谱遥感数据计算植被指数，然后将植被指数序列作为分类算法的主要输入来完成作物类型的识别^[57-58]。这种直接使用植被指数时间序列的识别方法对于具有明显的独特时相特征的作物来说是简单、有效的，例如利用时间序列数据进行水稻的识别^[59-61]。但是此类方法没有考虑时间序列遥感数据中的相对位置(时间)关系，从而导致时间序列中包含的重要作物生长过程信息没有被充分利用。为了充分利用植被指数时间序列信息、提高作物识别的精度，最直接的方法是从植被指数序列中提取时相或者物候特征。研究表明，相比于简单直接利用植被指数时间序列数据，使用基于统计或阈值分割方法提取到的包括植被指数最大值、植被指数峰值时间点、植被变绿(作物返青)时间点等在内的特征可以提高作物识别的精度^[62-64]。其次，基于特定的数学变换、预定义的数学模型从时间序列数据中提取时相及物候特征的方法同样被广泛应用于多时相数据的分类识别和作物物候研究。其代表性方法包括傅里叶变换^[65-66]、小波变换^[30,67]、SG 滤波^[68-69]、卡尔曼滤波^[70]、线性回归^[71]、样条拟合函数^[72-73]、隐含马尔科夫模型^[74]以及多种人工定义的曲线形状特征提取算法等^[75-76]。众多的研究结果已经表明随着参与作物分类识别的时相数量增加，识别精度总体上呈现上升趋势，表明不同时相特征可以有效地表现出不同作物生长过程变化趋势不一致的特点，有利于农作物遥感识别^[77-78]。因此，有许多研究使用了完整的时间序列进行作物识别研究，期望用完整的时间序列数据来详细描述作物生长过程，实现区分作物类型的目的^[79-83]。但是，农

作物的生长周期较短，再考虑到云雾天气影响和卫星重访周期等因素，获取同一地区的 2~3 个关键时相的高质量遥感数据存在一定困难，使得多时相遥感数据失去了提高农作物遥感识别精度的优势^[84]。尽管时间序列数据可以更加完善地表征不同作物的生长变化过程特征，但是构建完整的时间序列数据通常需要相关重建方法^[85-86]，导致时间成本更高，时效性相对较低，即不能在作物生长的早期、中期及时地识别作物的类型^[87-88]。此外，在地物变化不明显的区域中，时间序列数据会存在冗余和高度相关的现象，这限制了时间序列数据的应用^[89-92]。

目前，在实际应用中如何选择最适合且最有效的时间序列特征提取方法依旧是技术难题，面临的主要问题有：①人工设计模型或算法进行时间序列特征提取高度依赖于专家经验及先验知识。通用的特征提取方法对于一些特定目标的识别效果一般或无效。②人工特征工程是非常耗时且低效的，通常需要人为干预来应对变化的环境和天气状况，而且人类的知识很难同时考虑类内相似性、类间差异性、大气条件、辐射传输机制等多种复杂因素^[93]。③固定的数学模型或相关假设在一定程度上限制了特征提取算法的灵活性和可行性^[94]。

1.2 农作物遥感识别算法

农作物遥感识别的基本过程是根据遥感数据所表现出的特征差异进行类别属性信息的判断与提取，其本质是分类问题。在农作物遥感识别领域中，分类算法的发展可以概括为 3 个阶段(图 3)：早期的强学习方法；基于弱学习方式的集成学习方法；以神经网络为代表的深度学习方法。本文将早期的强学习方法与集成学习方法统一归纳为传统机器学习方法，以便与当前的研究热点——深度学习方法形成对照。




图 3 农作物遥感识别算法发展历程

Fig. 3 Development of crop type identification methods

1.2.1 基于传统机器学习方法的作物遥感识别

早期的强学习方式是基于概率统计方法构建单一分类器完成分类任务的过程，典型算法包括最小

距离法、最大似然法、决策树方法、支持向量机等。最大似然法 (Maximum likelihood) 是最常使用的监督分类方法之一,它假设数据近似服从正态分布,利用训练数据集求出均值、方差以及协方差等特征参数,从而建立各类别的先验概率密度函数,实现待分像元的归属概率计算从而完成分类。由于最大似然法简单易实施,且将贝叶斯理论和先验知识融入分类过程,在农作物遥感分类识别中应用广泛^[95-96],且与其他传统分类方法相比,最大似然法综合表现最优^[97]。但是该方法适用于特征波段较少的多光谱数据,在高光谱图像分类中的效果较差。决策树 (Decision tree) 是一种归纳推理的分类方法,通过对遥感图像光谱、颜色、空间等信息定义和不断更新规则来完成不同层次节点划分,直到节点不可再分为止。决策树类算法采用分层分类的形式,易于理解,可操作性高,能够处理多输出问题,从而被广泛应用于农作物遥感识别^[98-101],但其缺点是泛化能力较差,在处理高维数据时表现不佳。支持向量机 (SVM) 以结构风险理论、二次优化理论、核空间理论为基础,在高维特征空间中求解最优分类超平面,从而解决复杂数据的分类及回归问题。SVM 在农作物遥感分类中较为稳定、分类精度较高,但其在解决多类目标分类问题、特征空间维度较高时表现较差,且如何正确选择核函数也没有相关的理论依据^[102-103]。

集成学习算法将一系列独立或非独立的弱学习器的结果按照一定策略进行整合得到最终的结果,从而获得优于单个学习器的学习结果。其构建过程包括:基础分类器的生成和分类结果合并策略。其中,基础分类器生成过程中最常用方法是基于不同训练数据集生成一系列同质分类器,主要方法有 Bagging 和 Boosting。Bagging 方法采用随机有放回抽样技术构造不同训练数据集用于生成分类器; Boosting 方法首先为不同的样本赋予相同的权重,然后在训练过程中,降低正确分类样本的权重,增加错分类样本的权重,使得学习算法持续聚焦于错分样本,最后通过加权组合方式获得最终模型。集成学习的优势主要表现为:①统计学方面:多学习器可以获得一个相对稳定的假设空间,以减少泛化误差。②计算复杂度方面:集成学习可以有效降低算法陷入局部最优的可能性。③假设空间方面:多学习器可以让假设空间有所扩大,更有利于学到更好的近似。在农作物遥感分类识别中,应用最为广泛的机器学习方法是随机森林^[104-107]、Adaboost^[108-109]、梯度提升树^[110-111]等。

虽然传统机器学习方法能够较好地完成不同地

区不同作物的遥感识别,但在识别过程中主要使用浅层的直接观测特征和人工设计特征,对遥感数据中的深层次特征以及不同类型特征的协同学习能力较差。

1.2.2 基于深度学习的作物遥感识别

深度学习 (Deep learning) 作为机器学习领域中的一个分支,其目标在于建立模拟人脑进行分析学习的神经网络,采用海量训练数据驱动深度神经网络学习更有用的深层次特征,最终提升分类准确性。深度神经网络模型具有大量的参数,一方面使得模型具有足够的复杂性,另一方面使得模型具备从端到端的数据中学习特征的能力,替代了基于人类经验和先验知识的手动特征工程^[112]。近年来,以人工神经网络为基础的深度学习在包括遥感在内的机器学习和数据挖掘领域中取得一系列突破性进展,主要是得益于深度学习在特征表示方面的灵活性、不依赖于专家知识的端到端特征学习方式、自动化以及计算效率^[113-119]。

卷积神经网络 (CNN) 是最成功的深度学习网络架构之一。CNN 的学习过程计算效率高,并且对图像数据中空间关系敏感,使得 CNN 网络成为识别图像中 2 维 (2D) 特征模式的最有效模型^[120]。在遥感领域中,2D CNN 已被广泛用于提取空间特征,从而实现基于高分辨率图像的目标检测和语义分割^[121-125]。CNN 的另一个主要应用是高光谱图像分类,即分别利用 1D、2D、3D CNN 进行光谱特征、空间特征、“空-谱”特征的提取^[115,126-129]。在农作物遥感分类应用中,研究表明空间域中的 2 维卷积操作比光谱域中的 1 维卷积操作能取得更好的精度,将不同生长期的多光谱影像拼接起来,然后在光谱域中运用 1 维卷积操作同样可以提升地物分类的精度^[130-131]。虽然卷积操作可以很好地在空间域、光谱域或同时在“空-谱”域中提取有效特征,但是 CNN 很少用于时间域特征的提取,即无法有效地提取时间序列遥感数据中的时间变化特征。

循环神经网络 (RNN) 是专门用于处理时间序列数据的另一类深度学习网络模型^[132-133],由于可以捕捉长序列数据中的前后依赖关系,已在众多遥感应用中取得了成功。例如,RNN 已经被成功用于多光谱数据中空谱相关性以及波段差异变换趋势^[115];将 CNN 与 RNN 进行结合进行图像分类,即使用 CNN 生成从浅到深的多级卷积特征图,然后使用 RNN 作为解码器递归收集多尺度特征图并按顺序聚合形成高分辨率语义分割图像^[134]。RNN 网络有许多改进的模型用于提高学习效率,其中最著名的改进网络是长短期记忆网络 (LSTM),主要是为

了解决长序列训练过程中的梯度消失和梯度爆炸问题。相比于普通 RNN,LSTM 在基于长时间序列的变换检测^[135]、农作物分类^[82,136]等方面有更好的表现。此外,将 CNN 与 LSTM 相结合,一方面通过使用 2D 卷积操作提取影像中的空间特征信息,另一方面使用 LSTM 机制捕捉时间序列数据中的时间依赖关系,取得了比传统方法更好的结果^[137-138]。有研究对比分析了 LSTM 模型和传统机器学习之间的表现,结果表明 LSTM 模型在提取时间序列特征方面全面占据优势地位。例如,LYU 等^[135]发现在多个实验中,LSTM 的准确率约 95%,而支持向量机(SVM)和决策树的准确率分别约 80% 和约 70%;MOU 等^[137]同样进行了一系列对比试验发现,将 CNN 和 LSTM 联合使用,准确率可以达到 98%,精度优于 SVM(约 95%)和决策树(约 85%);RUßWURM 等^[139]通过构建多时相的 LSTM 模型取得了 90.6% 的准确度,略高于 CNN(89.2%),远高于 SVM(40.9%)。

以长短时记忆网络(LSTM)为代表的循环神经网络在处理时间序列遥感数据方面具有较大的优势,但是以门限机制为基础的循环神经网络在处理长时间序列数据或长程依赖问题上容易出现梯度消失,无法捕捉长距离信息依赖的情况。为此,以自注意力机制为基础的 Transformer 网络应运而生。目前,Transformer 模型及其变种已经成为处理序列问题的主流方法,在基于时间序列遥感数据的农作物分类识别领域取得了成功^[140-142],成为当前研究的热点。

1.3 讨论

目前,对于大区域尺度农作物遥感识别存在的核心问题是:

(1)识别特征方面,当前所使用的主要特征类型以浅层特征为主,且作物生长过程中的时间信息、空间纹理特征、光谱反射特征(“时-空-谱”特征)协同表达不够充分,且具体作物类型与作物识别特征缺乏知识关联,导致以监督学习为主的农作物类型识别高度依赖于当季真实样本,间接影响了农作物遥感识别的时效性和大区域作物类型识别的可用性。

(2)在作物的识别特征与具体作物类型缺乏知识关联的背景下,通过增加识别模型复杂度提升农作物识别精度,一方面可以提升识别精度,另一方面模型训练所需的样本量急剧增加,进一步导致了识别过程对当季已知样本的依赖、识别结果滞后,制约农作物遥感识别结果服务于现实应用。

在此背景下,应重点研究如何根据历史的时间

序列遥感数据及对应样本数据,提取面向具体作物的“时-空-谱”特征知识,形成面向作物类型识别的知识图谱,实现从数据到知识的转化。一方面摆脱识别过程对当季真实样本的依赖,另一方面提高识别精度与效率,提升农作物遥感识别的现实服务价值。

2 作物遥感估产

农作物产量的形成过程极为复杂,受到品种、气候环境、土壤养分和田间管理措施等多种因素的综合影响。作物遥感估产是农业遥感的基础应用之一,其大致经历了经验模型、半经验模型、物理估产模型 3 个阶段。早期的经验模型没有充分考虑作物产量形成过程中的各种复杂因素,仅利用作物冠层光谱反射特征或气象条件与地面实测产量数据进行回归建模,实现作物单产遥感反演。经验模型缺少机理约束,时空泛化能力差,而作物生长模型则从机理上模拟了作物生长的全过程,机理性更强,但只能模拟点位尺度的情况。不同模型各具特点,在实际应用时各有优劣。

2.1 统计模型

基于统计方法的作物单产估算大体可以分为 3 类(图 4),其中遥感指数模型和产量三要素模型的总体思路是直接建立遥感数据与作物实测产量或产量形成要素之间的关系模型进而完成单产估算;农业气象模型则是通过评估农业生产过程中的气象因素影响,实现作物单产估算。




图 4 基于统计模型的单产估算方法
Fig.4 Statistical model for crop yield estimation

2.1.1 遥感指数模型

农作物冠层光谱反射特性与其地上部生物量/产量之间存在密切联系,特别是红色和近红外波段由于包含超过 90% 的植被信息^[143-144]而被用于监测绿色植被、估算产量^[145-146]。早期的作物单产估算统计模型是寻求建立单一遥感波段或多波段反射率数据与地面观测产量数据之间的线性/非线性回归模型,是一种比较简单有效的作物单产统计估算方法。例如在利用 Landast TM 影像进行水稻单产估算研究中发现,蓝波段、近红外、中外红外波段的

反射率与实际产量之间具有良好的相关性,可通过多元线性回归模型较好地预测水稻产量^[147];在玉米、大豆估产研究中同样发现各波段反射率数据与大豆和玉米作物产量之间具有良好的相关性,并据此建立了包括线性、对数、指数和幂模型^[148]等在内的经验模型,取得了较好的估产效果。

植被指数通常综合了两个及以上的原始波段信息和专家知识,被广泛应用于研究植被健康和作物生产力^[149-152]。其中,归一化差值植被指数(NDVI)^[153]作为最常用的植被指数被大量单产估算研究采用。一种方式是选择作物生长季内最佳时期的NDVI(如作物生长最旺盛时期)与地面观测产量数据进行回归建模,但选择最佳时相与估产的生态区位、气候条件、作物类型等多种因素有关,且无定律可循^[154-155]。另一种方式是使用作物生长周期内的NDVI时间序列数据进行作物估产,例如建立NDVI时间序列积分与产量的线性关系或者从NDVI时间序列中提取作物活力值、生长峰值、增长率、衰老率、及曲线面积等更高级特征参数与产量进行多元回归建模来估算^[156-158]。除了NDVI之外,不同传感器数据、不同类型的植被指数被广泛用于全球不同地区的作物单产估算,作物类型涵盖了水稻、玉米、大豆等。同时,随着估产模型中变量类型的增加,单产估算的精度在提高,且多时期复合模式估产精度要优于单一生育期估产^[159-161]。

单纯基于原始遥感波段或植被指数建立经验模型进行作物估产,在特定区域特定作物类型上能取得较好的估算精度,但是经验统计模型缺乏机理约束,导致模型的时空泛化能力差。为此,有研究在回归模型中加入独立的气象变量进行条件约束,用于提高估产精度^[162-163]。此类,条件约束变量既可以直接测量,也可以通过遥感反演,例如降雨量、ETa(实际蒸发蒸腾量)或土壤水分等农业气象参数。研究表明将降雨量、温度数据与NDVI数据同时用于建立普通最小二乘回归模型对小麦单产的早期预测精度较好,表明将降雨量和温度因子纳入作物单产估算模型对于干旱少雨的地区更为重要^[164]。引入额外生物气候变量的谷物产量回归模型比仅使用遥感指数的模型具有更高的相关性和预测能力^[156];将基于CWSB模型计算出的ETa和土地覆盖加权NDVI(CNDVI)作为自变量与玉米产量进行多元线性回归来预测肯尼亚玉米产量,模型精度(R^2)达到0.83^[165]。但值得注意的是通过遥感反演得到的生物、气候指标并不独立于遥感植被指数,因此,将他们和光谱参数协同建模时,应考虑并纠正不同输入变量的相关关系。

近10年,随着传感器的发展,红边植被指数、太阳诱导叶绿素荧光(SIF)等新的波段或植被指数在遥感估产方面展现了巨大的潜力^[166-167]。在单产估算建模方法方面,除了经典(多元)线性回归、偏最小二乘回归(PLSR)或主成分回归(PCR)等统计方法之外^[168],模糊数学和机器学习算法也被用于估产模型构建,例如随机森林算法(RF)、自适应神经模糊系统(ANFIS)和深度学习^[169-172]。

总体而言,基于经验模型来估算作物产量的方式简单、易实施,在特定区域针对特定作物的估产可以达到较高的精度。但经验统计模型一方面缺乏理论机理支撑,另一方面受限于特定地理区域的环境特征、数据集,难以将已校准的估产方法推广到其他地区或其他尺度,模型的扩展性与移植稳定性差。此外,经验模型构建时需要大量地面真实产量数据作为支撑,对于大面积估产来说费时费力,经济性与时效性均不能满足实际应用的需求。

2.1.2 农业气象模型

农业气象模型主要思想是将作物产量划分为趋势产量(潜在产量)、气象胁迫产量(胁迫产量)与随机产量3部分,故又称潜在-胁迫模型。趋势产量是由作物生理结构、农田管理措施等非环境因素所形成的产量,即作物在正常生长环境下的产量;气象胁迫产量则是由于气温、降水、日照等气象条件导致的产量波动部分;随机产量是由自然或者人为灾害导致的不确定部分,一般只能在模型外进行处理。农业气象模型通过分离趋势产量与气象产量、外推趋势产量、预测波动产量、修正预测误差等工作来进行作物产量估算。

农业气象模型在我国应用广泛,中国科学院开发的全球农情遥感速报系统(Cropwatch)中也运用了农业气象模型进行产量预测^[173],实现了以作物产量预报业务系统为主体,农业气象情报和遥感应应用系统为辅助的作物产量预报综合技术支持体系,对全球主要粮食产区进行跟踪监测、评价和产量预测^[174]。

2.1.3 产量三要素模型

产量构成三要素方法将作物产量表示为单位面积作物株数、每株平均粒数与籽粒质量的乘积。在对产量三要素与作物光谱之间关系的研究中发现小麦的株数与植被绿度相关性非常高;穗粒数主要取决于环境因子,特别是拔节至灌浆初期温度因子;籽粒质量则主要取决于灌浆期的长短,可以使用绿度的变化速率来表征^[175],而垂直植被指数(PVI)与单产三要素均具有较强的相关性^[176-177]。利用遥感信息反演产量构成三要素进而估算作物单产,思路

简洁明确,在对冬小麦进行估产时精度达到了95%以上^[178]。但是,产量三要素模型的空间扩展能力较弱且估产精度不稳定,主要原因是产量三要素的遥感反演模型主要是经验模型。

总体而言,无论是遥感指数模型、农业气象模型还是产量三要素模型,其本质均是通过大量地面实测的产量数据与相应遥感数据进行统计分析与建模,所建立的经验模型在特定空间范围内对特定作物的单产可以进行高精度估算,且模型运算量小、计算简单易实行,具有一定的实际应用价值。但是经验模型一方面缺乏机理约束,另一方面高度受限于气候条件的制约,在具有不同气候条件的其他地理区域,模型稳定性与空间外推能力差。

2.2 净初级生产力模型

作物最终产量的形成是植株光合作用积累干物质以及干物质在不同器官分配的结果,因此可以通过计算植被净初级生产力(NPP)并结合收获系数估算作物产量,基于该原理的作物单产估算模型统称为NPP模型。NPP模型分为统计模型、过程模型、参数模型3种^[179]。其中,统计模型是根据光谱指数与作物地上部分干物质量之间的相关关系而建立的估算模型,对遥感数据及实测数据要求较高。过程模型理论严谨、精度高,如BEPS模型^[180]等。虽然过程模型具有一定的物理意义和理论基础,但是所需参数种类及数量较多,数据处理过程复杂,且往往难以直接观测。参数模型又称遥感光合模型,是对过程模型的简化。其基本思路是:首先计算植被光合有效辐射吸收比例(FAPAR),即植被吸收的光合有效辐射(APAR)与地球表面的瞬时光合有效辐射(PAR)之比;其次,植被光合有效辐射乘以光能利用率得到NPP;最后,将作物整个生长季的NPP进行累加,然后乘以收获指数(HI)得到作物最终产量(Y)^[181]。其中FAPAR与LAI、植被冠层反射率以及NDVI密切相关。研究表明FAPAR与LAI呈指数关系、与NDVI呈现出良好的线性关系,据此可以对FAPAR进行遥感反演^[182]。PAR为入射辐射总量,常用日照百分率结合经验公式计算得到。 ϵ_b 是指单位面积的土地上植被通过光合作用产生的有机物所包含的能量占对应土地上所接受的太阳能的比例。在理想状态下,植被所吸收的光合有效辐射转化为有机物的效率存在理论最高值,即存在最大光能利用率 $\epsilon_{\max}$,其主要利用通量观测数据计算或者根据先验知识得到^[183],每一种植被类型的最大光能利用率是恒定的。然而真实情况下,作物受各种外界因素(水分因素、温度因素等)胁迫,实际光能利用率会产生波动变化,其实际值的确定通常需

要对作物生长环境胁迫因子(如温度、降水)进行综合考虑。遥感光合模型具有生态物理学基础,所需参数较少,估算结果精度较高,在实际生产中得到了广泛的应用,代表性模型有CASA、GLO-PEM、C-FIX模型等^[184]。基于遥感光合模型的单产估算模型在区域尺度上对玉米、小麦等主要粮食作物的估产中取得良好的效果^[185-186],凭借较好的时间及空间泛化能力,NPP模型也被成功应用于农田生产力时空变化格局分析^[187]。

虽然利用遥感光合模型进行农作物估产的应用越来越多,但是相比于农作物估产,遥感光合模型在计算草地和森林生物量时具有更好的精度,可能原因是遥感光合模型未能考虑人为管理因素对农作物产量的影响。相比于统计模型,遥感光合模型有一定生物物理基础,模型时空泛化能力强。但利用该模型进行作物单产估算时需要输入作物生长周期内完整的长时间序列遥感数据,且不同区域不同作物的真实光能利用率以及收获指数的精确估算还需进一步深入研究,这在一定程度上影响了此类模型的实际应用。

2.3 作物生长模型

自荷兰瓦赫宁根大学DE WIT于1965年率先提出作物生长模拟理论以来^[188],全世界多个研究组开始从事作物生长模拟模型的研究,建立了各种作物的生长模拟模型。随着计算机科学技术以及作物生长理论的研究深入,作物生长模型的研究也取得了巨大的进展,成长为一门成熟的科学^[189]。目前,典型作物生长模型有:美国的DSSAT(Decision support system of agricultural technology transfer)^[190],包括针对42种以上作物的模拟模型(自4.7版起)以及辅助工具,其中CERES-Maize和CERES-Wheat模型是作物模型发展的典型代表;澳大利亚的APSIM(Agricultural Production Systems sIMulator)系统^[191];荷兰的WOFOST(World food studies)模型^[192]等。

作物生长模型通过初始化模型参数信息(作物参数、土壤参数等)模拟作物一定时间步长内(每日、每周、每月等)对驱动变量(气象参数、田间管理等)的响应从而更新模型状态变量(发育阶段、各器官干重、叶面积指数等),再现农作物生长发育及产量形成过程。作物生长模型的优势主要体现在以下方面:①模型按照固定时间步长对输入数据进行反映并更新状态变量,是动态连续的。②模型允许对不同区域、不同作物、不同生长情况进行模拟,机理性强,易于空间外推。③模型是多功能模块的集成系统,综合性强,可以进行不同应用的定量分析,如

气候效应对农作物影响的定量研究、土壤水肥模拟、生产力预测预警、农业生态评估等。

作物生长模型可以定量描述作物生长发育和产量形成过程及其与气候因子、土壤环境、品种类型和技术措施之间的关系,为不同条件下作物生长发育及产量预测、栽培管理、环境评价以及未来气候变化评估等提供了定量化工具。但是,作物生长模型是对点位尺度的模拟,在区域尺度应用时,由于空间尺度增大而出现的地表、近地表环境非均匀性问题,导致模型中一些宏观资料的获取和参数的空间化方面存在困难,从而使得作物生长模型模拟结果存在较大不确定性。遥感信息则凭借其宏观、快速、连续的观测特点可以在很大程度上弥补作物生长模型的不足,因此,作物生长模型与遥感数据的结合应运而生,具体结合方式见表 3。

表 3 遥感数据与作物生长模型的结合方式
Tab.3 Combination of remote sensing data with crop growth model

结合类型	结合方式
直接驱动作物生长模型	将遥感数据直接用于提供作物生长模型所需的模型参数,例如土壤质地信息、光合途径信息(C3、C4、CAM)、作物类型、播种日期等;或提供模型初始状态变量值,例如 LAI、ETa、干物质质量等
重新参数化/初始化模型	假设作物生长模型的某些参数校准或者初始状态变量不准确,遥感观测的状态变量通常被认为是模型模拟的绝对参考,通过迭代调整模型参数直到状态变量的测量值与模拟值彼此匹配
更新作物生长模型状态变量	用遥感数据简单地替换作物状态变量的模拟值,然后以这些更新的值继续运行作物生长模型进行计算,直到提供新的(遥感)输入为止
遥感观测与作物生长模型模拟同化法	充分考虑了遥感误差和模型模拟误差的数据同化方法 ^[193]

数据同化指在考虑数据的时空分布和观测场、背景场误差的前提下,在模型的动态运行过程中融合新观测数据的方法。其主要目标是利用多源观测数据不断校正与优化模型的模拟过程,使得模型的估算更加符合客观生物物理化学状态,进而改善模拟的估计精度,提高模型的预测能力。遥感耦合作物生长模型进行数据同化的方法主要包括连续数据同化和顺序数据同化,具体见表 4。

早期的遥感数据与作物生长模型的同化主要基于优化算法。对冬小麦单产估算的研究表明,将不同遥感数据源反演得到的 LAI 分别与 CERES - Wheat、EPIC 等作物生长模型进行同化,均取得了良

好的精度^[194 - 195]。LAUNAY 等^[196]将甜菜模型 SUCROS 与 SAIL 耦合,然后把 SPOT 影像数据和航空摄影数据同化到耦合后的模型中,通过调整模型中的部分敏感性参数,提高了产量预测的精度,均方根误差由原来的 20% 下降到 10%。基于优化算法的同化方案在实际应用易于实现,但需要极大的计算量,效率较低。基于变分法和滤波算法的同化方法则具有更高的效率,在近几年得到更多研究。例如在冬小麦的单产估算中,利用集合卡尔曼滤波算法(EnKF)将 MODIS 数据反演 LAI 和 ET 与 SWAP 模型进行同化,显著提高了小麦单产的预测精度^[197]。黄健熙等^[198]首先基于 S - G 滤波算法重构 MODIS LAI 时间序列;其次,通过构建地面观测 LAI 与 3 个关键物候期 Landsat TM 植被指数构建回归统计模型计算得到区域尺度的 TM LAI 数据;然后融合上述两种不同空间尺度的 LAI 数据生成尺度转换 LAI。最终利用 EnKF 算法将这 3 种不同时空分辨率的 LAI 数据同化到 PyWOFOST 模型中,研究结果表明同化尺度转换 LAI 获得最高的同化精度,潜在模式下的模拟产量均方根误差由 602 kg/hm²下降到 478 kg/hm²,证明了遥感数据与作物模型的 EnKF 同化方法在区域作物产量估算中的有效性。王鹏新等^[199]将遥感反演的条件植被温度指数 VTCI 与 CERES - Wheat 模型模拟的土壤浅层含水率相结合,运用四维变分同化算法(4D - VAR)实现冬小麦主要生育期旬尺度 VTCI 的同化,运用多种决策分析方法分别建立了同化前后的 VTCI 单产估测模型,结果同样表明应用同化后的 VTCI 构建的估测模型精度明显提高。

表 4 遥感数据与作物生长模型同化方法
Tab.4 Assimilation methods of remote sensing data and crop growth model

同化类型	同化思想	常用方法
连续数据同化	构建模拟结果与观测结果间的代价函数,利用优化算法循环调整作物遗传参数和模型模拟初始条件,使得代价函数趋于最小	基于优化算法的同化和基于变分算法的同化
顺序数据同化	利用遥感观测反射率数据或者遥感反演的状态变量,在观测和模型误差分别加权的基础上动态地更新作物生长模型模拟的状态变量,优化模拟预测轨迹,获得模型状态的后验优化估计	集合卡尔曼滤波法、粒子滤波法等

基于作物生理学建模的定量遥感估产方式是目前的研究热点。将遥感数据与作物生长模型相结合进行作物单产估算是理论性更完备的方式之一,因为遥感能够对作物生长状况进行概括性量化,而作物生长模型能够描述整个生长季作物的生长过程。

随着作物生长模型的不断完善,其模拟精度不断提高,但是所需参数多难以准确获取,此外作物生长模型需要输入整个生长期的驱动数据,无法进行产量的提前预测。因此,如何更进一步充分发挥遥感与作物生长模型的各自优势,提高对作物产量的估算精度和估算的时效性还有待深入研究。

2.4 问题与展望

总体来看,当前的农作物单产遥感估算模型也是形式繁多,在推广应用中明显存在泛化能力不足、监测时效滞后、单产制图不够精细等问题,难以满足当前智慧农业对于农作物单产估算时效性和空间精细程度的要求。

随着高分辨率、高光谱分辨率、高时间分辨率遥感数据的增加,以及深度学习等技术的发展^[200],研究如何耦合深度学习与作物生长模型,构建针对大区域范围的可扩展和高效移植的精细尺度农作物单产遥感动态估算模型是潜在的研究方向之一。充分利用作物生长模型模拟不同点位尺度、不同生境情况下的作物生长情况,捕捉作物生长规律,充分利用深度学习方法对复杂情况的学习与建模能

力,完成空间外推,实现用机理做约束,用深度学习做外推。

3 结束语

作物类型遥感识别与产量估算是农业遥感领域中的基础应用。当前农作物遥感识别特征与具体作物类型缺乏知识关联,导致识别过程过度依赖于当季样本、识别结果滞后的问题;单产估算模型则面临着估算精度较低、时空泛化能力较弱的问题。随着更高空间分辨率、更高光谱分辨率、更短重访周期数据的普及,以及深度学习技术的发展,同步学习作物生长过程中的“时-空-谱”特征知识,并基于与特征知识构建面向作物识别的知识图谱,实现从数据到知识转变,从而提高农作物遥感识别的精度和时效性。农作物单产遥感估算的潜在重点是深度协同作物生长模型和深度学习,以作物生长模型模拟的不同生境下作物生长状况为基础,驱动深度学习模型完成复杂种植结构、复杂生长环境下的建模学习,最终实现用机理做约束,用深度学习进行空间外推的作物单产估算模式。

参 考 文 献

- [1] BGU A, ARVOR D, BELLON B, et al. Remote sensing and cropping practices: a review[J]. Remote Sens., 2018, 10(1): 99.
- [2] DONG J, XIAO X. Evolution of regional to global paddy rice mapping methods: a review[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 119: 214 – 227.
- [3] MOSLEH M K, HASSAN Q K, CHOWDHURY E H. Application of remote sensors in mapping rice area and forecasting its production: a review[J]. Sensors, 2015, 15(1): 769 – 791.
- [4] SUN H, XU A, LIN H, et al. Winter wheat mapping using temporal signatures of MODIS vegetation index data[J]. International Journal of Remote Sensing, 2012, 33(16): 5026 – 5042.
- [5] 邢东兴, 常庆瑞. 基于光谱分析的果树树种辨识研究[J]. 光谱学与光谱分析, 2009, 29(7): 1937 – 1940.
XING Dongxing, CHANG Qingrui. Research on identification of species of fruit trees by spectral analysis[J]. Spectroscopy and Spectral Analysis, 2009, 29(7): 1937 – 1940. (in Chinese)
- [6] JIANG Z, HUETE A R, CHEN J, et al. Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction[J]. Remote Sens Environ, 2006, 101(3): 366 – 378.
- [7] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices[J]. Remote Sens. Environ., 1996, 55(2): 95 – 107.
- [8] XUE J, SU B. Significant remote sensing vegetation indices: a review of developments and applications[J]. Journal of Sensors, 2017;1353691.
- [9] KANDRIKA S, ROY P S. Land use land cover classification of Orissa using multi-temporal IRS – P6 awifs data; a decision tree approach[J]. International Journal of Applied Earth Observation & Geoinformation, 2008, 10(2): 186 – 193.
- [10] KAVZOGLU T. Erratum: simulating Landsat ETM + imagery using DAIS 7915 hyperspectral scanner data[J]. International Journal of Remote Sensing, 2004, 25(22): 5049 – 5067.
- [11] 梁友嘉, 徐中民. 基于 SPOT – 5 卫星影像的灌区作物识别[J]. 草业科学, 2013, 30(2): 161 – 167.
LIANG Youjia, XU Zhongmin. Crop identification in the irrigation district based on SPOT – 5 satellite imagery[J]. Pratacultural Science, 2013, 30(2): 161 – 167. (in Chinese)
- [12] 刘磊, 江东, 徐敏, 等. 基于多光谱影像和专家决策法的作物分类研究[J]. 安徽农业科学, 2011, 39(25): 1703 – 1706.
LIU Lei, JIANG Dong, XU Min, et al. Study on crops classification based on multi-spectral image and decision tree method[J]. Journal of Anhui Agricultural Sciences, 2011, 39(25): 1703 – 1706. (in Chinese)
- [13] 李长春, 陈伟男, 王宇, 等. 基于多源 Sentinel 数据的县域冬小麦种植面积提取[J]. 农业机械学报, 2021, 52(12): 207 – 215.
LI Changchun, CHEN Weinan, WANG Yu, et al. Extraction of winter wheat planting area in county based on multi-sensor

- Sentinel data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12): 207–215. (in Chinese)
- [14] CHAKRABORTY M, PANIGRAHY S. A processing and software system for rice crop inventory using multi-date RADARSAT ScanSAR data[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2000, 55(2): 119–128.
- [15] GEETHA M, KAREGOWDA A G. Crop mapping using SAR imagery: a review[J]. International Journal of Advanced Research in Computer Science, 2016, 7(7): 47–52.
- [16] PRASAD R. Estimation of kidney bean crop variables using ground-based scatterometer data at 9.89 GHz[J]. Int. J. Remote Sens., 2011, 32(1): 31–48.
- [17] WISEMAN G, MCNAIRN H, HOMAYOUNI S, et al. RADARSAT – 2 polarimetric SAR response to crop biomass for agricultural production monitoring[J]. IEEE J. Sel. Top. Appl. Earth Observ. Remote Sens., 2014, 7(11): 4461–4471.
- [18] SHANG J, JIAO X, MCNAIRN H, et al. Tracking crop phenological development of spring wheat using Synthetic Aperture Radar (SAR) in northern Ontario, Canada[C] // Proceedings of the 2013 Second International Conference on Agro-Geoinformatics (Agro-Geoinformatics). IEEE, 2013.
- [19] LE T T, RIBBES F, WANG L F, et al. Rice crop mapping and monitoring using ERS – 1 data based on experiment and modeling results[J]. IEEE Transactions on Geoscience and Remote Sensing, 1997, 35(1): 41–56.
- [20] SHAO Y, FAN X, LIU H, et al. Rice monitoring and production estimation using multitemporal RADARSAT[J]. Remote Sens. Environ., 2001, 76(3): 310–325.
- [21] YANG S, SHEN S, LI B, et al. Rice mapping and monitoring using ENVISAT ASAR data[J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5(1): 108–112.
- [22] ZHANG Y, WANG C, WU J, et al. Mapping paddy rice with multitemporal ALOS/PALSAR imagery in southeast China[J]. Int. J. Remote Sens., 2009, 30(23): 6301–6315.
- [23] PEI Z, ZHANG S, GUO L, et al. Rice identification and change detection using TerraSAR – X data[J]. Canadian Journal of Remote Sensing, 2011, 37(1): 151–156.
- [24] MANJUNATH K, RAY S S, PANIGRAHY S. Discrimination of spectrally-close crops using ground-based hyperspectral data[J]. Journal of the Indian Society of Remote Sensing, 2011, 39(4): 599–602.
- [25] KUMAR A, MANJUNATH K, BALA R, et al. Field hyperspectral data analysis for discriminating spectral behavior of tea plantations under various management practices[J]. Int. J. Appl. Earth Obs. Geoinf., 2013, 23: 352–359.
- [26] KAUR R, SINGH B, SINGH M, et al. Hyperspectral indices, correlation and regression models for estimating growth parameters of wheat genotypes[J]. Journal of the Indian Society of Remote Sensing, 2015, 43(3): 551–558.
- [27] SAHOO R N, RAY S, MANJUNATH K. Hyperspectral remote sensing of agriculture[J]. Current Science, 2015, 108(5): 848–859.
- [28] VAIPHASA C, SKIDMORE A K, DE BOER W F, et al. A hyperspectral band selector for plant species discrimination[J]. ISPRS-J Photogramm Remote Sens., 2007, 62(3): 225–235.
- [29] FILIPPI A M, JENSEN J R. Fuzzy learning vector quantization for hyperspectral coastal vegetation classification[J]. Remote Sens. Environ., 2006, 100(4): 512–530.
- [30] GALFORD G L, MUSTARD J F, MELILLO J, et al. Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil[J]. Remote Sens. Environ., 2008, 112(2): 576–587.
- [31] CARR J R. Spectral and textural classification of single and multiple band digital images[J]. Comput Geosci., 1996, 22(8): 849–865.
- [32] URSANI A A, KPALMA K, LELONG C C D, et al. Fusion of textural and spectral information for tree crop and other agricultural cover mapping with very-high resolution satellite images[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2012, 5(1): 225–235.
- [33] 潘洁, 李明诗. 基于信息量的高分辨率影像纹理提取的研究[J]. 南京林业大学学报(自然科学版), 2010, 34(4): 129–134.
- PAN Jie, LI Mingshi. Textural features analysis of high-resolution remote sensing image based on the information abundance[J]. Journal of Nanjing Forestry University(Natural Sciences Edition), 2010, 34(4): 129–134. (in Chinese)
- [34] 王妮, 彭世揆, 李明诗. 基于树种分类的高分辨率遥感数据纹理特征分析[J]. 浙江农林大学学报, 2012, 29(2): 210–217.
- WANG Ni, PENG Shikui, LI Mingshi. High-resolution remote sensing of textural images for tree species classification[J]. Journal of Zhejiang A&F University, 2012, 29(2): 210–217. (in Chinese)
- [35] 崔林丽. 遥感影像解译特征的综合分析与评价[D]. 北京: 中国科学院研究生院, 2005.
- CUI Linli. Integrative analysis and evaluation of the interpretation features in remote sensing image[D]. Beijing: Chinese Academy of Sciences, 2005. (in Chinese)
- [36] HASITUYA, CHEN Z, WANG L, et al. Monitoring plastic-mulched farmland by Landsat – 8 OLI imagery using spectral and textural features[J]. Remote Sens., 2016, 8(4): 353.
- [37] 李粉玲, 常庆瑞, 刘佳岐, 等. 基于多纹理和支持向量机的 ZY – 1 02C 星 HR 数据分类[J]. 武汉大学学报(信息科学版), 2016, 41(4): 455–461, 486.
- LI Fenling, CHANG Qingrui, LIU Jiaqi, et al. SVM classification with multi-texture data of ZY – 1 02C HR image[J]. Geomatics and Information Science of Wuhan University, 2016, 41(4): 455–461, 486. (in Chinese)

- [38] SHABAN M A, DIKSHIT O. Improvement of classification in urban areas by the use of textural features; the case study of Lucknow city, Uttar Pradesh[J]. *Int. J. Remote Sens.*, 2001, 22(4): 565–593.
- [39] 陈君颖, 田庆久. 高分辨率遥感植被分类研究[J]. *遥感学报*, 2007, 11(2): 221–227.
CHEN Junying, TIAN Qingjiu. Vegetation classification based on high-resolution satellite image[J]. *National Remote Sensing Bulletin*, 2007, 11(2): 221–227. (in Chinese)
- [40] YOU J, PEI Z. Error modeling based on geostatistics for uncertainty analysis in crop mapping using Gaofen-1 multispectral imagery[J]. *Journal of Applied Remote Sensing*, 2015, 9(1): 097096.
- [41] LLOYD C D, BERBEROGLU S, CURRAN P J, et al. A comparison of texture measures for the per-field classification of Mediterranean land cover[J]. *Int. J. Remote Sens.*, 2004, 25(19): 3943–3965.
- [42] BERBEROGLU S, LLOYD C D, ATKINSON P M, et al. The integration of spectral and textural information using neural networks for land cover mapping in the Mediterranean[J]. *Comput. Geosci.*, 2000, 26(4): 385–396.
- [43] KIANI S, AZIMIFAR Z, KAMGAR S. Wavelet-based crop detection and classification[C]//*Proceedings of the 2010 18th Iranian Conference on Electrical Engineering. IEEE*, 2013.
- [44] BOSSU J, GÉE C, JONES G, et al. Wavelet transform to discriminate between crop and weed in perspective agronomic images[J]. *Comput. Electron. Agric.*, 2009, 65(1): 133–143.
- [45] LI Z, LIU G, JIANG H, et al. Image copy detection using a robust gabor texture descriptor[C]//*Proceedings of the First ACM Workshop on Large-scale Multimedia Retrieval and Mining*, 2009.
- [46] MCNAIRN H, CHAMPAGNE C, SHANG J, et al. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories[J]. *ISPRS-J. Photogramm Remote Sens.*, 2009, 64(5): 434–449.
- [47] 钱永兰, 杨邦杰, 雷廷武. 用基于 IHS 变换的 SPOT-5 遥感图像融合进行作物识别[J]. *农业工程学报*, 2005, 21(1): 102–105.
QIAN Yonglan, YANG Bangjie, LEI Tingwu. Intensity-hue-saturation model based image fusion of SPOT-5 HRG1 data for crop identification[J]. *Transactions of the CSAE*, 2005, 21(1): 102–105. (in Chinese)
- [48] HILKER T, WULDER M A, COOPS N C, et al. A new data fusion model for high spatial-and temporal-resolution mapping of forest disturbance based on Landsat and MODIS[J]. *Remote Sens. Environ.*, 2009, 113(8): 1613–1627.
- [49] ZHU L, TATEISHI R. Fusion of multisensor multitemporal satellite data for land cover mapping[J]. *Int. J. Remote Sens.*, 2006, 27(5): 903–918.
- [50] MCNAIRN H, ELLIS J, VAN DER SANDEN J, et al. Providing crop information using RADARSAT-1 and satellite optical imagery[J]. *Int. J. Remote Sens.*, 2002, 23(5): 851–870.
- [51] KUN J, BINGFANG W, QIANGZI L, et al. Improvement of classification accuracy integrating C-and X-band synthetic aperture radar data[C]//*Proceedings of the 2009 3rd IEEE International Symposium on Microwave, Antenna, Propagation and EMC Technologies for Wireless Communications*, 2009.
- [52] 赵天杰, 李新武, 张立新. 双频多极化 SAR 数据与多光谱数据融合的作物识别[J]. *地球信息科学学报*, 2009, 11(1): 84–90.
ZHAO Tianjie, LI Xinwu, ZHANG Lixin. Agrotype recognition using dual-frequency multi-polarization SAR data and multi-spectral data[J]. *Journal of Geo-information Science*, 2009, 11(1): 84–90. (in Chinese)
- [53] ORYNBAIKYZY A, GESSNER U, CONRAD C. Crop type classification using a combination of optical and radar remote sensing data: a review[J]. *Int. J. Remote Sens.*, 2019, 40(17): 6553–6595.
- [54] MANDANICI E, BITELLI G. Preliminary comparison of Sentinel-2 and Landsat 8 Imagery for a combined use[J]. *Remote Sens.*, 2016, 8(12): 10.
- [55] PIEDELOBO L, HERNANDEZ-LOPEZ D, BALLESTEROS R, et al. Scalable pixel-based crop classification combining Sentinel-2 and Landsat-8 data time series; case study of the Duero river basin[J]. *Agricultural Systems*, 2019, 171: 36–50.
- [56] CONESE C, MASELLI F. Use of multitemporal information to improve classification performance of TM scenes in complex terrain[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 1991, 46(4): 187–197.
- [57] WARDLOW B D, EGBERT S L. Large-area crop mapping using time-series MODIS 250 m NDVI data; an assessment for the US Central Great Plains[J]. *Remote Sens. Environ.*, 2008, 112(3): 1096–1116.
- [58] 申健, 常庆瑞, 李粉玲, 等. 基于时序 NDVI 的关中地区冬小麦种植信息遥感提取[J]. *农业机械学报*, 2017, 48(3): 215–220, 60.
SHEN Jian, CHANG Qingrui, LI Fenling, et al. Extraction of winter wheat information based on time-series NDVI in Guanzhong area[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2017, 48(3): 215–220, 60. (in Chinese)
- [59] XIAO X M, BOLES S, FROLKING S, et al. Mapping paddy rice agriculture in South and Southeast Asia using multi-temporal MODIS images[J]. *Remote Sens. Environ.*, 2006, 100(1): 95–113.
- [60] DONG J, XIAO X, KOU W, et al. Tracking the dynamics of paddy rice planting area in 1986–2010 through time series Landsat images and phenology-based algorithms[J]. *Remote Sens. Environ.*, 2015, 160: 99–113.
- [61] ZHANG G, XIAO X, DONG J, et al. Mapping paddy rice planting areas through time series analysis of MODIS land surface temperature and vegetation index data[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 106: 157–171.

- [62] WALKER J J, DE BEURS K M, HENEBRY G M. Land surface phenology along urban to rural gradients in the US Great Plains[J]. *Remote Sens. Environ.*, 2015, 165: 42 – 52.
- [63] WALKER J J, DE BEURS K M, WYNNE R H. Dryland vegetation phenology across an elevation gradient in Arizona, USA, investigated with fused MODIS and Landsat data[J]. *Remote Sens. Environ.*, 2014, 144: 85 – 97.
- [64] SIMONNEAUX V, DUCHEMIN B, HELSON D, et al. The use of high-resolution image time series for crop classification and evapotranspiration estimate over an irrigated area in central Morocco[J]. *Int. J. Remote Sens.*, 2008, 29(1): 95 – 116.
- [65] GEERKEN R A. An algorithm to classify and monitor seasonal variations in vegetation phenologies and their inter-annual change[J]. *ISPRS-J Photogramm Remote Sens.*, 2009, 64(4): 422 – 431.
- [66] ZHANG M, ZHOU Q, CHEN Z, et al. Crop discrimination in Northern China with double cropping systems using Fourier analysis of time-series MODIS data[J]. *Int. J. Appl. Earth Obs. Geoinf.*, 2008, 10(4): 476 – 485.
- [67] SAKAMOTO T, VAN NGUYEN N, OHNO H, et al. Spatio-temporal distribution of rice phenology and cropping systems in the Mekong Delta with special reference to the seasonal water flow of the Mekong and Bassac rivers[J]. *Remote Sens. Environ.*, 2006, 100(1): 1 – 16.
- [68] CHEN J, JONSSON P, TAMURA M, et al. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky – Golay filter[J]. *Remote Sens. Environ.*, 2004, 91(3 – 4): 332 – 344.
- [69] SHAO Y, LUNETTA R S, WHEELER B, et al. An evaluation of time-series smoothing algorithms for land-cover classifications using MODIS – NDVI multi-temporal data[J]. *Remote Sens. Environ.*, 2016, 174: 258 – 265.
- [70] VICENTE-GUIJALBA F, MARTINEZ-MARIN T, LOPEZ-SANCHEZ J M. Crop phenology estimation using a multitemporal model and a kalman filtering strategy[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(6): 1081 – 1085.
- [71] FUNK C, BUDDE M E. Phenologically-tuned MODIS NDVI-based production anomaly estimates for Zimbabwe[J]. *Remote Sens. Environ.*, 2009, 113(1): 115 – 125.
- [72] BRADLEY B A, JACOB R W, HERMANCE J F, et al. A curve fitting procedure to derive inter-annual phenologies from time series of noisy satellite NDVI data[J]. *Remote Sens. Environ.*, 2007, 106(2): 137 – 145.
- [73] BRADLEY B A, MUSTARD J F. Comparison of phenology trends by land cover class: a case study in the Great Basin, USA [J]. *Glob. Change Biol.*, 2008, 14(2): 334 – 346.
- [74] SIACHALOU S, MALLINIS G, TSAKIRI-STRATI M. A hidden Markov models approach for crop classification: linking crop phenology to time series of multi-sensor remote sensing data[J]. *Remote Sens.*, 2015, 7(4): 3633 – 3650.
- [75] SAKAMOTO T, GITELSON A A, ARKEBAUER T J. MODIS-based corn grain yield estimation model incorporating crop phenology information[J]. *Remote Sens. Environ.*, 2013, 131: 215 – 231.
- [76] SAKAMOTO T, WARDLOW B D, GITELSON A A, et al. A two-step filtering approach for detecting maize and soybean phenology with time-series MODIS data[J]. *Remote Sens. Environ.*, 2010, 114(10): 2146 – 2159.
- [77] 潘志强, 刘高焕, 周成虎. 黄河三角洲农作物种植分区的遥感研究[J]. *地理研究*, 2003, 22(6): 799 – 806.
PAN Zhiqiang, LIU Gaohuan, ZHOU Chenghu. The crop distribution of Yellow River Delta using remote sensing method[J]. *Geographical Research*, 2003, 22(6): 799 – 806. (in Chinese)
- [78] LI Y, CHEN X W, DUAN H W, et al. Application of multi-source and multi-temporal remote sensing data in winter wheat identification[J]. *Geography and Geo-Information Science*, 2010, 4: 47 – 49.
- [79] WARDLOW B D, EGBERT S L, KASTENS J H. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the US Central Great Plains[J]. *Remote Sensing of Environment*, 2007, 108(3): 290 – 310.
- [80] ZHANG G L, XIAO X M, DONG J W, et al. Mapping paddy rice planting areas through time series analysis of MODIS land surface temperature and vegetation index data[J]. *ISPRS-J Photogramm Remote Sens.*, 2015, 106: 157 – 171.
- [81] DEFOURNY P, BONTEMPS S, BELLEMANS N, et al. Near real-time agriculture monitoring at national scale at parcel resolution: performance assessment of the Sen2-Agri automated system in various cropping systems around the world[J]. *Remote Sens. Environ.*, 2019, 221: 551 – 568.
- [82] ZHAO L, LI Q, ZHANG Y, et al. Integrating the continuous wavelet transform and a convolutional neural network to identify vineyard using time series satellite images[J]. *Remote Sens.*, 2019, 11(22): 2641.
- [83] JAKUBAUSKAS M E, LEGATES D R, KASTENS J H. Crop identification using harmonic analysis of time-series AVHRR NDVI data[J]. *Comput. Electron. Agric.*, 2002, 37(1 – 3): 127 – 139.
- [84] 贾坤, 李强子. 农作物遥感分类特征变量选择研究现状与展望[J]. *资源科学*, 2013, 35(12): 2507 – 2516.
JIA Kun, LI Qiangzi. Review of features selection in crop classification using remote sensing data[J]. *Resources Science*, 2013, 35(12): 2507 – 2516. (in Chinese)
- [85] PAN Z, HU Y, CAO B. Construction of smooth daily remote sensing time series data: a higher spatiotemporal resolution perspective[J]. *Open Geospatial Data, Software and Standards*, 2017, 2(1): 1 – 11.
- [86] POGGIO L, GIMONA A, BROWN I. Spatio-temporal MODIS EVI gap filling under cloud cover: an example in Scotland[J]. *ISPRS-J Photogramm Remote Sens.*, 2012, 72: 56 – 72.
- [87] JU J, ROY D P. The availability of cloud-free Landsat ETM + data over the conterminous United States and globally[J]. *Remote Sens. Environ.*, 2008, 112(3): 1196 – 1211.
- [88] GÓMEZ C, WHITE J C, WULDER M A. Optical remotely sensed time series data for land cover classification: a review[J].

- ISPRS-J. Photogramm Remote Sens. , 2016, 116: 55 – 72.
- [89] BYRNE G, CRAPPER P, MAYO K. Monitoring land-cover change by principal component analysis of multitemporal Landsat data[J]. Remote Sens. Environ. , 1980, 10(3): 175 – 184.
- [90] COLLINS J B, WOODCOCK C E. An assessment of several linear change detection techniques for mapping forest mortality using multitemporal Landsat TM data[J]. Remote Sens. Environ. , 1996, 56(1): 66 – 77.
- [91] DENG J, WANG K, DENG Y, et al. PCA-based land-use change detection and analysis using multitemporal and multisensor satellite data[J]. Int. J. Remote Sens. , 2008, 29(16): 4823 – 4838.
- [92] DENG J S, WANG K, HONG Y, et al. Spatio-temporal dynamics and evolution of land use change and landscape pattern in response to rapid urbanization[J]. Landsc Urban Plan, 2009, 92(3 – 4): 187 – 198.
- [93] ZHU X X, TUIA D, MOU L, et al. Deep learning in remote sensing[J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(4): 8 – 36.
- [94] ZHONG L, HAWKINS T, BIGING G, et al. A phenology-based approach to map crop types in the San Joaquin Valley, California[J]. Int. J. Remote Sens. , 2011, 32(22): 7777 – 7804.
- [95] GIKOV A, DIMITROV P, FILCHEV L, et al. Crop type mapping using multi-date imagery from the Sentinel – 2 satellites[J]. Comptes Rendus De L Academie Bulgare Des Sciences, 2019, 72(6): 787 – 795.
- [96] ABOU EL-MAGD I, TANTON T W. Improvements in land use mapping for irrigated agriculture from satellite sensor data using a multi-stage maximum likelihood classification[J]. Int. J. Remote Sens. , 2003, 24(21): 4197 – 4206.
- [97] CASTILLEJO-GONZALEZ I L, LOPEZ-GRANADOS F, GARCIA-FERRER A, et al. Object- and pixel-based analysis for mapping crops and their agro-environmental associated measures using QuickBird imagery[J]. Comput. Electron. Agric. , 2009, 68(2): 207 – 215.
- [98] 赵小娟, 王霞, 李琳, 等. 基于多时相遥感影像识别与分析高原主要农作物[J]. 青海农技推广, 2022(2): 31 – 36.
- [99] 石莹, 穆岑, 田艳君, 等. 基于 Landsat – 8 数据对甘肃省金塔县主要农作物分类[J]. 测绘与空间地理信息, 2022, 45(2): 74 – 78, 81.
- SHI Ying, MU Cen, TIAN Yanjun, et al. Classification of main crops in Jinta county of Gansu Province based on Landsat – 8 data[J]. Geomatics & Spatial Information Technology, 2022, 45(2): 74 – 78, 81. (in Chinese)
- [100] 桑国庆, 唐志光, 毛克彪, 等. 基于 GEE 云平台与 Sentinel 数据的高分辨率水稻种植范围提取——以湖南省为例[J]. 作物学报, 2022, 48(9): 2409 – 2420.
- SANG Guoqing, TANG Zhiguang, MAO Kebiao, et al. High-resolution paddy rice mapping using Sentinel data based on GEE platform: a case study of Hunan Province, China[J]. Acta Agronomica Sinica, 2022, 48(9): 2409 – 2420. (in Chinese)
- [101] 王晨丞, 王永前, 王利花. 基于 SAR 纹理信息的农作物识别研究——以农安县为例[J]. 遥感技术与应用, 2021, 36(2): 372 – 380.
- WANG Chencheng, WANG Yongqian, WANG Lihua. Crop identification based on SAR texture information: a case study of Nong'an County[J]. Remote Sensing Technology and Application, 2021, 36(2): 372 – 380. (in Chinese)
- [102] 解文欢, 张海峰, 张有智, 等. 基于 GF – 1 数据的主要农作物种植结构提取 SVM 算法研究[J]. 现代农机, 2022(2): 68 – 69.
- [103] ZHAO L, LI Q, ZHANG Y, et al. Study on the potential of whitening transformation in improving single crop mapping accuracy[J]. Journal of Applied Remote Sensing, 2019, 13(3): 034512.
- [104] 孙庆松, 张晓楠, 陈利东, 等. 基于 Sentinel – 2 时序谐波特征的县域农作物分类[J]. 江苏农业学报, 2022, 38(4): 967 – 975.
- SUN Qingsong, ZHANG Xiaonan, CHEN Lidong, et al. Crop classification in counties based on Sentinel – 2 temporal harmonic characteristics[J]. Jiangsu Journal of Agricultural Sciences, 2022, 38(4): 967 – 975. (in Chinese)
- [105] 黄双燕, 杨辽, 陈曦, 等. 机器学习法的干旱区典型农作物分类[J]. 光谱学与光谱分析, 2018, 38(10): 3169 – 3176.
- HUANG Shuangyan, YANG Liao, CHEN Xi, et al. Study of typical arid crops classification based on machine learning[J]. Spectroscopy and Spectral Analysis, 2018, 38(10): 3169 – 3176. (in Chinese)
- [106] 王利民, 刘佳, 杨玲波, 等. 随机森林方法在玉米-大豆精细识别中的应用[J]. 作物学报, 2018, 44(4): 569 – 580.
- WANG Limin, LIU Jia, YANG Lingbo, et al. Application of random foresyt method in maize-soybean accurate identification [J]. Acta Agronomica Sinica, 2018, 44(4): 569 – 580. (in Chinese)
- [107] BELGIU M, CSILLIK O. Sentinel – 2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis[J]. Remote Sens. Environ. , 2018, 204: 509 – 523.
- [108] ZHOU Z, HUANG J F, WANG J, et al. Object-oriented classification of sugarcane using time-series middle-resolution remote sensing data based on AdaBoost[J]. PLoS ONE, 2015, 10(11): e0142069.
- [109] LUO H X, LI M F, DAI S P, et al. Combinations of feature selection and machine learning algorithms for object-oriented betel palms and mango plantations classification based on Gaofen – 2 imagery[J]. Remote Sens. , 2022, 14(7): 1757.
- [110] YANG L B, MANSARAY L R, HUANG J F, et al. Optimal segmentation scale parameter, feature subset and classification algorithm for Geographic object-based crop recognition using multisource satellite imagery[J]. Remote Sens. , 2019, 11(5): 514.
- [111] WEI M F, WANG H Y, ZHANG Y, et al. Investigating the potential of Sentinel – 2 MSI in early crop identification in

- northeast China[J]. *Remote Sens.*, 2022, 14(8): 1928.
- [112] LECUN Y, BENGIO Y. Convolutional networks for images, speech, and time series[J]. *The Handbook of Brain Theory and Neural Networks*, 1995, 3361(10): 1995.
- [113] LI W, FU H, YU L, et al. Stacked autoencoder-based deep learning for remote-sensing image classification: a case study of African land-cover mapping[J]. *Int. J. Remote Sens.*, 2016, 37(23): 5632 – 5646.
- [114] WAN X, ZHAO C, WANG Y, et al. Stacked sparse autoencoder in hyperspectral data classification using spectral-spatial, higher order statistics and multifractal spectrum features[J]. *Infrared Physics & Technology*, 2017, 86: 77 – 89.
- [115] LYU H, LU H, MOU L, et al. Long-term annual mapping of four cities on different continents by applying a deep information learning method to Landsat data[J]. *Remote Sens.*, 2018, 10(3): 471.
- [116] 宋怀波, 尚钰莹, 何东健. 果实目标深度学习识别技术研究进展[J]. *农业机械学报*, 2022, 53(11): 1 – 17.
SONG Huaibo, SHANG Yuying, HE Dongjian. Review on deep learning technology for fruit target recognition[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(11): 1 – 17. (in Chinese)
- [117] 李凯雨, 朱昕怡, 马浚诚, 等. 基于混合扩张卷积和注意力的黄瓜病害严重度估算方法[J/OL]. *农业机械学报*: 1 – 12. [2022 – 11 – 01]. <http://kns.cnki.net/kcms/detail/11.1964.s.20221102.1516.002.html>.
LI Kaiyu, ZHU Xinyi, MA Jucheng, et al. Estimation method of leaf disease severity of cucumber based on mixed dilated convolution and attention mechanism[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*: 1 – 12. [2022 – 11 – 01]. <http://kns.cnki.net/kcms/detail/11.1964.s.20221102.1516.002.html>. (in Chinese)
- [118] 田有文, 吴伟, 林磊, 等. 基于深度学习与高光谱成像的蓝莓果蝇虫害无损检测[J]. *农业机械学报*, 2023, 54(1): 393 – 401.
TIAN Youwen, WU Wei, LIN Lei, et al. Nondestructive detection of blueberry fruit fly pests based on deep learning and hyperspectral imaging[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(1): 393 – 401. (in Chinese)
- [119] 史博太, 常庆瑞, 崔小涛, 等. 基于 Sentinel-2 多光谱数据和机器学习算法的冬小麦 LAI 遥感估算[J]. *麦类作物学报*, 2021, 41(6): 752 – 761.
SHI Botai, CHANG Qingrui, CUI Xiaotao, et al. LAI estimation of winter wheat based on Sentinel-2 multi-spectral data and machine learning algorithm[J]. *Journal of Triticeae Crops*, 2021, 41(6): 752 – 761. (in Chinese)
- [120] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Imagenet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84 – 90.
- [121] CHEN X, XIANG S, LIU C L, et al. Vehicle detection in satellite images by hybrid deep convolutional neural networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(10): 1797 – 1801.
- [122] MAGGIORI E, TARABALKA Y, CHARPIAT G, et al. Convolutional neural networks for large-scale remote-sensing image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(2): 645 – 657.
- [123] KAMPFFMEYER M, SALBERG A B, JENSSEN R. Semantic segmentation of small objects and modeling of uncertainty in urban remote sensing images using deep convolutional neural networks[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2016: 1 – 9.
- [124] AUDEBERT N, LE SAUX B, LEF VRE S. Beyond RGB: very high resolution urban remote sensing with multimodal deep networks[J]. *ISPRS-J. Photogramm Remote Sens.*, 2018, 140: 20 – 32.
- [125] MARMANIS D, SCHINDLER K, WEGNER J D, et al. Classification with an edge: improving semantic with boundary detection[J]. *ISPRS-J Photogramm Remote Sens.*, 2018, 135: 158 – 172.
- [126] HU W, HUANG Y, WEI L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. *Journal of Sensors*, 2015: 258619.
- [127] YUE J, ZHAO W, MAO S, et al. Spectral-spatial classification of hyperspectral images using deep convolutional neural networks[J]. *Remote Sensing Letters*, 2015, 6(6): 468 – 477.
- [128] ZHAO W, DU S. Spectral-spatial feature extraction for hyperspectral image classification: a dimension reduction and deep learning approach[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 4544 – 4554.
- [129] LI Y, ZHANG H, SHEN Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network[J]. *Remote Sens.*, 2017, 9(1): 67.
- [130] KUSSUL N, LAVRENIUK M, SKAKUN S, et al. Deep learning classification of land cover and crop types using remote sensing data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(5): 778 – 782.
- [131] GUIDICI D, CLARK M L. One-dimensional convolutional neural network land-cover classification of multi-seasonal hyperspectral imagery in the San Francisco Bay Area, California[J]. *Remote Sens.*, 2017, 9(6): 629.
- [132] CONNOR J T, MARTIN R D, ATLAS L E. Recurrent neural networks and robust time-series prediction[J]. *IEEE Transactions on Neural Networks*, 1994, 5(2): 240 – 254.
- [133] ZAREMBA W, SUTSKEVER I, VINYALS O. Recurrent neural network regularization[J]. *arXiv preprint, arXiv:14092329*, 2014.
- [134] MOU L, ZHU X X. RiFCN: recurrent network in fully convolutional network for semantic segmentation of high resolution remote sensing images[J/OL]. *arXiv preprint, arXiv:180502091*, 2018. <https://doi.org/10.48550/arXiv.1805.02091>.
- [135] LYU H, LU H, MOU L. Learning a transferable change rule from a recurrent neural network for land cover change detection

- [J]. *Remote Sens.*, 2016, 8(6): 506.
- [136] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Comput.*, 1997, 9(8): 1735–1780.
- [137] MOU L, BRUZZONE L, ZHU X X. Learning spectral-spatial-temporal features via a recurrent convolutional neural network for change detection in multispectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 57(2): 924–935.
- [138] RUSSWURM M, KOERNER M. Multi-temporal land cover classification with sequential recurrent encoders[J]. *ISPRS International Journal of Geo-Information*, 2018, 7(4): 129.
- [139] RUßWURM M, KORNER M. Temporal vegetation modelling using long short-term memory networks for crop identification from medium-resolution multi-spectral satellite images[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2017.
- [140] WANG H, CHEN X Z, ZHANG T X, et al. CCTNet: coupled CNN and transformer network for crop segmentation of remote sensing images[J]. *Remote Sens.*, 2022, 14(9): 20.
- [141] LI Z T, CHEN G K, ZHANG T X. A CNN-transformer hybrid approach for crop classification using multitemporal multisensor images[J]. *IEEE J. Sel. Top. Appl. Earth Observ. Remote Sens.*, 2020, 13: 847–858.
- [142] REEDHA R, DERICQUEBOURG E, CANALS R, et al. Transformer neural network for weed and crop classification of high resolution UAV images[J]. *Remote Sens.*, 2022, 14(3): 592.
- [143] BARET F, GUYOT G, MAJOR D. TSAVI: a vegetation index which minimizes soil brightness effects on LAI and APAR estimation[C]// *Proceedings of the 12th Canadian Symposium on Remote Sensing Geoscience and Remote Sensing Symposium*, 1989.
- [144] BARET F, GUYOT G, TERES J, et al. Profil spectral et estimation de la biomasse[C]// *Proceedings of the Spectral Signatures of Objects in Remote Sensing*, 1988.
- [145] TUCKER C J, HOLBEN B N, ELGIN J H, et al. Relationship of spectral data to grain-yield variation[J]. *Photogrammetric Engineering and Remote Sensing*, 1980, 46(5): 657–666.
- [146] TUCKER C J. Red and photographic infrared linear combinations for monitoring vegetation[J]. *Remote Sensing of Environment*, 1979, 8(2): 127–150.
- [147] TENNAKOON S B, MURTY V V N, EIUMNOH A. Estimation of cropped area and grain-yield of rice using remote-sensing data[J]. *International Journal of Remote Sensing*, 1992, 13(3): 427–439.
- [148] THENKABAIL P S, WARD A D, LYON J G. Landsat-5 thematic mapper models of soybean and corn crop characteristics[J]. *International Journal of Remote Sensing*, 1994, 15(1): 49–61.
- [149] SELLERS P J. Canopy reflectance, photosynthesis and transpiration[J]. *International Journal of Remote Sensing*, 1985, 6(8): 1335–1372.
- [150] TUCKER C, VANPRAET C, BOERWINKEL E, et al. Satellite remote sensing of total dry matter production in the Senegalese Sahel[J]. *Remote Sensing of Environment*, 1983, 13(6): 461–474.
- [151] MACDONALD R B, HALL F G. Global crop forecasting[J]. *Science*, 1980, 208(4445): 670–679.
- [152] 程千, 徐洪刚, 曹引波, 等. 基于无人机多时相植被指数的冬小麦产量估测[J]. *农业机械学报*, 2021, 52(3): 160–167.
CHENG Qian, XU Honggang, CAO Yinbo, et al. Grain yield prediction of winter wheat using multi-temporal UAV based on multispectral vegetation index[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(3): 160–167. (in Chinese)
- [153] ROUSE J. Monitoring the vernal advancement and retrogradation of natural vegetation[R]. *NASA/GSFCT Type Report*, 1973.
- [154] LEWIS J E, ROWLAND J, NADEAU A. Estimating maize production in Kenya using NDVI: some statistical considerations[J]. *International Journal of Remote Sensing*, 1998, 19(13): 2609–2617.
- [155] MASELLI F, ROMANELLI S, BOTTAI L, et al. Processing of GAC NDVI data for yield forecasting in the Sahelian region[J]. *International Journal of Remote Sensing*, 2000, 21(18): 3509–3523.
- [156] RASMUSSEN M S. Assessment of millet yields and production in northern burkina-faso using integrated ndvi from the AVHRR[J]. *International Journal of Remote Sensing*, 1992, 13(18): 3431–3442.
- [157] MASELLI F, CONESE C, PETKOV L, et al. Environmental monitoring and crop forecasting in the sahel through the use of NOAA NDVI data: a case study niger 1986—1989[J]. *International Journal of Remote Sensing*, 1993, 14(18): 3471–3487.
- [158] KALUBARME A H, POTDAR M B, MANJUNATH K R, et al. Growth profile based crop yield models: a case study of large area wheat yield modelling and its extendibility using atmospheric corrected NOAA AVHRR data[J]. *International Journal of Remote Sensing*, 2003, 24(10): 2037–2054.
- [159] 唐延林, 黄敬峰, 王人潮, 等. 水稻遥感估产模拟模式比较[J]. *农业工程学报*, 2004, 20(1): 166–171.
TANG Yanlin, HUANG Jingfeng, WANG Renchao, et al. Comparison of yield estimation simulated models of rice by remote sensing[J]. *Transactions of the CSAE*, 2004, 20(1): 166–171. (in Chinese)
- [160] 王长耀, 林文鹏. 基于 MODIS EVI 的冬小麦产量遥感预测研究[J]. *农业工程学报*, 2005, 21(10): 90–94.
WANG Changyao, LIN Wenpeng. Winter wheat yield estimation based on MODIS EVI[J]. *Transactions of the CSAE*, 2005,

- 21(10): 90–94. (in Chinese)
- [161] 朱婉雪, 李仕冀, 张旭博, 等. 基于无人机遥感植被指数优选的田块尺度冬小麦估产[J]. 农业工程学报, 2018, 34(11): 78–86.
- ZHU Wanxue, LI Shiji, ZHANG Xubo, et al. Estimation of winter wheat yield using optimal vegetation indices from unmanned aerial vehicle remote sensing[J]. Transactions of the CSAE, 2018, 34(11): 78–86. (in Chinese)
- [162] RASMUSSEN M S. Developing simple, operational, consistent NDVI-vegetation models by applying environmental and climatic information. Part II: crop yield assessment[J]. International Journal of Remote Sensing, 1998, 19(1): 119–139.
- [163] REYNOLDS C A, YITAYEW M, SLACK D C, et al. Estimating crop yields and production by integrating the FAO crop specific water balance model with real-time satellite data and ground-based ancillary data[J]. International Journal of Remote Sensing, 2000, 21(18): 3487–3508.
- [164] BALAGHI R, TYCHON B, EERENS H, et al. Empirical regression models using NDVI, rainfall and temperature data for the early prediction of wheat grain yields in Morocco [J]. International Journal of Applied Earth Observation and Geoinformation, 2008, 10(4): 438–452.
- [165] ROJAS O. Operational maize yield model development and validation based on remote sensing and agro-meteorological data in Kenya[J]. International Journal of Remote Sensing, 2007, 28(17): 3775–3793.
- [166] 项方林, 李鑫格, 马吉锋, 等. 基于冠层时序植被指数的冬小麦单产预测[J]. 中国农业科学, 2020, 53(18): 3679–3692.
- XIANG Fanglin, LI Xinge, MA Jifeng, et al. Using canopy time-series vegetation index to predict yield of winter wheat[J]. Scientia Agricultura Sinica, 2020, 53(18): 3679–3692. (in Chinese)
- [167] LI Z, ZHANG Q, LI J, et al. Solar-induced chlorophyll fluorescence and its link to canopy photosynthesis in maize from continuous ground measurements[J]. Remote Sensing of Environment, 2020, 236: 111420.
- [168] ATZBERGER C, GUERIF M, BARET F, et al. Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat[J]. Computers and Electronics in Agriculture, 2010, 73(2): 165–173.
- [169] NADERLOO L, ALIMARDANI R, OMID M, et al. Application of ANFIS to predict crop yield based on different energy inputs[J]. Measurement, 2012, 45(6): 1406–1413.
- [170] 熊雄. 基于深度学习的大田水稻稻穗分割及无损产量预估研究[D]. 武汉: 华中科技大学, 2018.
- XIONG Xiong. Research on field rice panicle segmentation and nondestructive yield prediction based on deep learning[D]. Wuhan: Huazhong University of Science & Technology, 2018. (in Chinese)
- [171] 王鹏新, 齐璇, 李俐, 等. 基于随机森林回归的玉米单产估测[J]. 农业机械学报, 2019, 50(7): 237–245.
- WANG Pengxin, QI Xuan, LI Li, et al. Estimation of maize yield based on random forest regression[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(7): 237–245. (in Chinese)
- [172] 周亮, 慕号伟, 马海蛟, 等. 基于卷积神经网络的中国北方冬小麦遥感估产[J]. 农业工程学报, 2019, 35(15): 19–28.
- ZHOU Liang, MU Haowei, MA Haijiao, et al. Remote sensing estimation on yield of winter wheat in North China based on convolutional neural network[J]. Transactions of the CSAE, 2019, 35(15): 19–28. (in Chinese)
- [173] WU B, MENG J, LI Q, et al. Remote sensing-based global crop monitoring: experiences with China's CropWatch system [J]. International Journal of Digital Earth, 2014, 7(2): 113–137.
- [174] 钱拴, 王建林. 农业气象作物产量预报的特点与思考[J]. 气象科技, 2003(5): 257–261.
- QIAN Shuan, WANG Jianlin. Special aspects of agrometeorological crop yields forecast and discussion[J]. Meteorological Science and Technology, 2003(5): 257–261. (in Chinese)
- [175] 王乃斌, 周迎春, 林耀明, 等. 大面积小麦遥感估产模型的构建与调试方法的研究[J]. 环境遥感, 1993(4): 250–259.
- WANG Naibin, ZHOU Yingchun, LIN Yaoming, et al. A study on modeling winter wheat yield of large area using remotely sensed information[J]. National Remote Sensing Bulletin, 1993(4): 250–259. (in Chinese)
- [176] 朱晓红, 谢昆青, 徐希孺, 等. 冬小麦产量构成分析与遥感估产[J]. 环境遥感, 1989(2): 116–127.
- ZHU Xiaohong, XIE Kunqing, XU Xiru, et al. The structure analysis of winter wheat yield and the principal of remote sensing estimation of winter wheat yield[J]. National Remote Sensing Bulletin, 1989(2): 116–127. (in Chinese)
- [177] 王延颐. 植被指数与水稻长势及产量结构要素关系的研究[J]. 国土资源遥感, 1996(1): 56–59.
- WANG Yangyi. The relationship between vegetation index and rice growth and rice yield components[J]. Remote Sensing for Natural Resources, 1996(1): 56–59. (in Chinese)
- [178] 王乃斌. 中国小麦遥感动态监测与估产[M]. 北京: 中国科学技术出版社, 1996.
- [179] RUIMY A, SAUGIER B, DEDIEU G. Methodology for the estimation of terrestrial net primary production from remotely sensed data[J]. Journal of Geophysical Research: Atmospheres, 1994, 99(D3): 5263–5283.
- [180] XIA C, XIONG L, ZHUANG D. Remote sensing estimating net primary productivity of temperate deciduous forest in Northeast China using satellite data: approach and preliminary results[C]//Proceedings of the Remote Sensing and Modeling of Ecosystems for Sustainability, International Society for Optics and Photonics, 2004.
- [181] 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)
- [182] BARET F. Un modèle simplifié de réflectance et d'absorptance d'un couvert végétal[C] // Proceedings of the Spectral Signatures of Objects in Remote Sensing, 1988.
- [183] SANCHEZ M L, PARDO N, PEREZ I A, et al. GPP and maximum light use efficiency estimates using different approaches over a rotating biodiesel crop[J]. Agricultural and Forest Meteorology, 2015, 214: 444-455.
- [184] 程志强, 蒙继华. 作物单产估算模型研究进展与展望[J]. 中国生态农业学报, 2015, 23(4): 402-415.
- CHENG Zhiqiang, MENG Jihua. Research advances and perspective on crop yield estimation models[J]. Chinese Journal of Eco-Agriculture, 2015, 23(4): 402-415. (in Chinese)
- [185] 史晓亮, 杨志勇, 王馨爽, 等. 基于光能利用率模型的松嫩平原玉米单产估算[J]. 水土保持研究, 2017, 24(5): 385-390.
- SHI Xiaoliang, YANG Zhiyong, WANG Xinshuang, et al. Maize yield estimation based on light efficiency model in Songnen Plain, Northeast China[J]. Research of Soil and Water Conservation, 2017, 24(5): 385-390. (in Chinese)
- [186] 宋富强, 郑壮丽, 王令超. 基于 CASA 模型的河南省冬小麦估产研究[J]. 河南科学, 2012, 30(10): 1466-1471.
- SONG Fuqiang, ZHENG Zhuangli, WANG Lingchao. Yield estimation for winter wheat of Henan province based on CASA model[J]. Henan Science, 2012, 30(10): 1466-1471. (in Chinese)
- [187] 闫慧敏, 刘纪远, 曹明奎. 中国农田生产力变化的空间格局及地形控制作用[J]. 地理学报, 2007, 62(2): 171-180.
- YAN Huimin, LIU Jiyuan, CAO Mingkui. Spatial pattern and topographic control of China's agricultural productivity variability[J]. Acta Geographica Sinica, 2007, 62(2): 171-180. (in Chinese)
- [188] DE WIT C T. Photosynthesis of leaf canopies[R]. Wageningen: Pudoc, 1965.
- [189] HOLZWORTH D P, SNOW V, JANSSEN S, et al. Agricultural production systems modelling and software: current status and future prospects[J]. Environmental Modelling & Software, 2015, 72: 276-286.
- [190] JONES J W, HOOGENBOOM G, PORTER C H, et al. The DSSAT cropping system model[J]. European Journal of Agronomy, 2003, 18(3-4): 235-265.
- [191] KEATING B A, CARBERRY P S, HAMMER G L, et al. An overview of APSIM, a model designed for farming systems simulation[J]. European Journal of Agronomy, 2003, 18(3-4): 267-288.
- [192] VANDIEPEN C A, WOLF J, VANKEULEN H, et al. WOFOST—a simulation-model of crop production[J]. Soil Use Manage, 1989, 5(1): 16-24.
- [193] CASA R, VARELLA H, BUIS S, et al. Forcing a wheat crop model with LAI data to access agronomic variables: evaluation of the impact of model and LAI uncertainties and comparison with an empirical approach[J]. European Journal of Agronomy, 2012, 37(1): 1-10.
- [194] DENTE L, SATALINO G, MATTIA F, et al. Assimilation of leaf area index derived from ASAR and MERIS data into CERES-Wheat model to map wheat yield[J]. Remote Sensing of Environment, 2008, 112(4): 1395-1407.
- [195] 杨鹏, 吴文斌, 周清波, 等. 基于作物模型与叶面积指数遥感影像同化的区域单产估测研究[J]. 农业工程学报, 2007, 23(9): 130-136.
- YANG Peng, WU Wenbin, ZHOU Qingbo, et al. Assimilating remotely sensed LAI into GIS-based EPIC model for yield assessment on regional scale[J]. Transactions of the CSAE, 2007, 23(9): 130-136. (in Chinese)
- [196] LAUNAY M, GUERIF M. Assimilating remote sensing data into a crop model to improve predictive performance for spatial applications[J]. Agriculture Ecosystems & Environment, 2005, 111(1-4): 321-339.
- [197] VAZIFEDOUST M, VAN DAM J, BASTIAANSEN W, et al. Assimilation of satellite data into agrohydrological models to improve crop yield forecasts[J]. International Journal of Remote Sensing, 2009, 30(10): 2523-2545.
- [198] 黄健熙, 李昕璐, 刘帝佑, 等. 顺序同化不同时空分辨率 LAI 的冬小麦估产对比研究[J]. 农业机械学报, 2015, 46(1): 240-248.
- HUANG Jianxi, LI Xinlu, LIU Diyou, et al. Comparison of winter wheat yield estimation by sequential assimilation of different spatio-temporal resolution remotely sensed LAI datasets[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(1): 240-248. (in Chinese)
- [199] 王鹏新, 孙辉涛, 王蕾, 等. 基于 4D-VAR 和条件植被温度指数的冬小麦单产估测[J]. 农业机械学报, 2016, 47(3): 263-271.
- WANG Pengxin, SUN Huitao, WANG Lei, et al. Winter wheat yield estimation based on 4D variational assimilation method and remotely sensed vegetation temperature condition index[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(3): 263-271. (in Chinese)
- [200] 王鹏新, 田惠仁, 张悦, 等. 基于深度学习的作物长势监测和产量估测研究进展[J]. 农业机械学报, 2022, 53(2): 1-14.
- WANG Pengxin, TIAN Huiren, ZHANG Yue, et al. Crop growth monitoring and yield estimation based on deep learning: state of the art and beyond[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 1-14. (in Chinese)