

doi:10.6041/j.issn.1000-1298.2022.02.001

# 基于深度学习的作物长势监测和产量估测研究进展

王鹏新 田惠仁 张 悅 韩 东 王 婕 尹 猛

(中国农业大学信息与电气工程学院,北京 100083)

**摘要:**作物长势是粮食产量估测与预测的主要信息源,随着高时空分辨率遥感数据的不断出现,遥感数据已呈现出明显的大数据特征,以深度学习为基础的作物长势监测和产量估测已成为指导农业生产的重要手段之一。本文通过总结深度学习模型样本以及模型结构的发展历程,概括了深度学习在区域尺度的研究现状,其中从样本构建和样本扩充两方面概述了模型样本,从卷积神经网络(CNN)、循环神经网络(RNN)及其优化结构和模型可解释性总结了深度学习模型结构的进展;随后从无人机平台和卫星平台两方面阐述了田块尺度国内外作物长势监测和产量估测研究的最新进展;最后指出了目前存在的问题和未来拟重点加强的研究任务,主要包括通过基于区域和参数的迁移学习以改善小样本的限制;深度学习模型和作物生长模型有机结合,以提高模型的可解释性;无人机平台与卫星平台相结合,确保时空融合过程中尺度转换的精度;深入探索深度学习在作物长势监测方面的应用潜力。

**关键词:**农作物;长势监测;产量估测;遥感;深度学习中图分类号:TP79 文献标识码:A 文章编号:1000-1298(2022)02-0001-14 OSID:

## Crop Growth Monitoring and Yield Estimation Based on Deep Learning: State of the Art and Beyond

WANG Pengxin TIAN Huiren ZHANG Yue HAN Dong WANG Jie YIN Meng

(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

**Abstract:** Crop growth conditions are key information sources for estimating and forecasting crop yields, which are of great value to food security and trade. With the continuous appearance of high spatial and temporal resolution remote sensing data, the remote sensing data have presented obvious characteristics of big data. Therefore, crop growth monitoring and yield estimation based on deep learning has become one of the important means to guide agricultural production. The research status of deep learning at the regional scale was investigated, which focused on the development of model samples and model structure. Among them, the model samples were summarized through two aspects of sample construction and sample augmentation. The progress of the deep learning model structure of convolutional neural network (CNN), recurrent neural network (RNN), and their optimized structures and model interpretability were also summarized. Besides, the latest progress of crop growth monitoring and yield estimation at field scale at home and abroad was elaborated from two aspects: unmanned aerial vehicle (UAV) platform and satellite platform. Finally, the existing problems and the future perspective were analyzed and discussed, including improving the limitation of small samples through region-based and parameter-based transfer learning, the organic combination of deep learning model and crop growth model to improve the interpretability of the model, and the combination of UAV platform and satellite platform to ensure the precision of scale conversion in the process of spatio-temporal fusion, which can further explore the potential of deep learning in crop growth monitoring.

**Key words:** crops; growth monitoring; yield estimation; remote sensing; deep learning

## 0 引言

作物长势是粮食产量估测与预测的重要信息来

源,对于我国粮食安全和贸易具有重大价值。其中遥感技术具有覆盖范围广、重访周期短、数据获取成本相对低等优势,在作物长势监测和产量估测中扮

收稿日期:2021-12-03 修回日期:2021-12-20

基金项目:国家自然科学基金项目(42171332,41871336)

作者简介:王鹏新(1965—),男,教授,博士,主要从事定量遥感及其在农业中的应用研究,E-mail: wangpx@cau.edu.cn

演着重要的角色。目前作物估产方法主要包括基于作物生长模型的估产方法和基于统计回归的经验估产方法。基于作物生长模型估产方法的最大特点是机理性强,但由于作物生长模型的参数众多,对于区域尺度的作物估产,往往无法充分获取作物生长模型所需的参数,在一定程度上限制了作物生长模型在大范围作物估产中的广泛应用<sup>[1-2]</sup>。基于统计回归模型的估产方法无需输入大量参数,因此更适用于区域的作物单产估测。基于统计回归模型的作物估产方法包括线性模型方法和非线性模型方法。由于农田生态系统较为复杂,涉及的许多过程都是非线性的,作物长势和产量形成的机理通常表现为非线性<sup>[3-6]</sup>,因此,目前研究者更多地使用非线性模型来监测作物长势和估测单产,如支持向量回归(Support vector regression, SVR)、随机森林(Random forest, RF)和人工神经网络(Artificial neural network, ANN)等<sup>[7-12]</sup>。在机器学习模型中,ANN由于能够学习和存储大量输入-输出模式的映射关系,可以得到较高的精度,并且存在一些衍生形式,如MAYA GOPAL等<sup>[13]</sup>在多元线性回归(Multiple linear regression, MLR)与ANN基础上提出了MLR-ANN混合模型,以提高作物产量估测精度。JOHNSON等<sup>[14]</sup>利用贝叶斯神经网络(Bayesian neural network, BNN)对加拿大大草原的作物产量进行估测。然而,这种传统机器学习方法对于捕获数据间复杂的非线性关系的能力较为有限,深度学习能够提取多尺度和多层次特征并将这些特征组合抽象成高层次特征<sup>[15-18]</sup>。因此,深度学习模型的表现优于传统机器学习模型,在利用遥感数据进行长势监测和产量估测方面表现出巨大的潜力<sup>[19]</sup>。

本文所涉及的区域尺度作物长势监测是指利用低空间分辨率的遥感数据及其产品进行的监测,而田块尺度作物长势监测是指利用中高空间分辨率的遥感数据及其产品进行的监测。随着精准农业的发展以及深度学习方法在区域尺度长势监测及产量估测中的广泛应用,将深度学习运用于田块尺度作物长势监测及产量估测成为目前研究热点之一。在田块尺度进行作物长势监测时要求遥感影像在时间和空间上具有高分辨率特征<sup>[20]</sup>。目前依据遥感平台的不同,可分为基于无人机平台和基于卫星平台的田块尺度作物长势监测及产量估测。

本文基于深度学习模型,在区域尺度和田块尺度对作物长势监测的研究进展及趋势进行综述,一方面在区域尺度对深度学习模型样本、模型结构及其优化进行归纳总结,一方面针对遥感数据获取平台的不同,分别从无人机平台和卫星平台总结和分

析田块尺度作物长势监测和产量估测的进展。在此基础上,针对深度学习存在的问题与发展趋势分析,提出今后的重点发展方向。

## 1 区域尺度的作物长势监测和产量估测研究进展

遥感数据具有明显的大数据特征,是作物长势监测的主要数据源。作物长势与其单产密切相关,受光、温、水、土、肥等因子影响,是表征农情和进行作物产量估测预测的重要指标之一,而应用遥感技术表征的与作物长势密切相关的监测指标是这些因子综合作用的结果。因此,多种参数结合被广泛地应用于区域尺度的作物长势监测和产量估测研究中。近年来,随着大数据技术与深度学习在各领域应用的逐步深入,开展基于多参数和深度学习的从数据到数据的作物长势信息提取是一个重要的研究方向。因此,本文从模型样本和模型构建与优化两方面,对深度学习模型在区域尺度的作物长势监测和产量估测进行描述和总结。

### 1.1 模型样本

#### 1.1.1 样本构建

人工神经网络和深度学习模型通常需要大量的训练样本,并且利用样本以实现对特征的提取。因此,选择合适的样本是一个必不可少的步骤<sup>[21]</sup>。尽管作物生长状况受多种因素的影响,且其生长过程又是一个非常复杂的生物生理过程,但作物生长状况可以用一些与其生长过程密切相关的参数进行表征<sup>[22-23]</sup>。在基于遥感数据进行作物长势监测的参数中(表1),主要包括植被指数、生物物理参数和生长环境参数<sup>[23-25]</sup>。其中,最常用的是利用植被光谱响应敏感波段构建能够反映作物生长状况的遥感指数进行监测,归一化植被指数(Normalized difference vegetation index, NDVI)的应用最为广泛。目前,国内外学者利用NDVI等植被指数进行了大量研究<sup>[14,26-29]</sup>,并且发现,相比于基于单生育时期的植被指数,综合多生育时期的植被指数与作物长势和单产具有更高的相关性<sup>[30-34]</sup>,这为在区域和国家范围内将多生育时期的植被指数与作物产量联系起来的众多研究奠定了基础。此外,一些学者也开展了以常见作物长势指标,如叶面积指数(Leaf area index, LAI)、条件温度指数(Temperature condition index, TCI)、条件植被指数(Vegetation condition index, VCI)、条件植被温度指数(Vegetation temperature condition index, VTCI)等进行样本的适用性和有效性评价研究,为提高作物长势监测的准确性发挥了重要作用<sup>[35-37]</sup>。BOLTON等<sup>[38]</sup>基于MODIS NDVI、

归一化差异水分指数 (Normalized difference water index, NDWI) 和使用 2 个波段的增强植被指数 (Two-band enhanced vegetation index, EVI2) 作为特征参数预测美国中部玉米和大豆的单产, 结果表明在玉米返青期后的 65~75 d 和大豆返青期后的 80 d, EVI2 与非干旱县玉米单产之间具有较高的相关性, 而 NDWI 对半干旱县的玉米单产估测性能更好。

由于作物生长受到光照、气温、降水等多种环境因素的影响, 因此每年的产量会因环境因素在年际间的改变而出现明显差异。此外, 随着高时间分辨率卫星数据产品的积累(如 MODIS 数据)和遥感大数据技术的发展, 时间序列数据作为模型样本在现阶段获得了广泛的应用。因此, 用于训练深度学习

模型的样本主要包括基于多生育时期和长时间序列的遥感数据和气象数据, 为进一步提高长势监测精度提供了依据<sup>[39~42]</sup>。

除上述遥感数据和气象数据作为样本的作物长势监测和产量估测外, 国内外学者也陆续开展了以作物品质为样本的长势监测和产量估测研究<sup>[43~44]</sup>。从研究对象来看, 主要集中在小麦与水稻两大粮食作物上, 以籽粒蛋白质品质监测预报居多<sup>[2,45]</sup>。由于随着作物品种的提高和科技的进步, 好的品种对特定疾病或虫害的抵抗力更强, 并且它们适应了以气候和土壤等多种条件为特征的特定环境<sup>[46~47]</sup>。因此, 利用作物品质作为样本对于提高估产精度具有重要的作用。

表 1 主要遥感指标及适用性

Tab. 1 Major remote sensing indices and applicability

类型	名称	定义	指标适用性描述
	归一化植被指数 (Normalized difference vegetation index, NDVI)	近红外波段与红光波段反射率之差与之和的比值	能定量描述绿色植被的丰度、覆盖度和作物长势, 适用于植被早、中期生长阶段的动态监测
	比值植被指数 (Ratio vegetation index, RVI)	近红外波段与红光波段反射率的比值	能够消除大量的地形影响, 适用于植被覆盖度较高的区域, 可用于检测和估算植物生物量
	差值植被指数 (Difference vegetation index, DVI)	近红外波段与红光波段反射率的差值	对土壤背景的变化较 RVI 敏感, 能较好地识别植被和水体
	增强植被指数 (Enhanced vegetation index, EVI)	综合处理了土壤背景、大气噪声和饱和度等问题, 是 NDVI 的继承和改进	考虑了植被辐射量和植被生物量密度两方面, 能解决 NDVI 在高生物量覆盖区易饱和问题, 对植被变化的监测具有更高的灵敏性和优越性
	土壤校正植被指数 (Soil adjusted vegetation index, SAVI)	描述土壤-植被系统的植被指数, 解释背景的光学特征变化并修正 NDVI 对土壤背景的敏感	去除了土壤背景信息的影响
	归一化差异水分指数 (Normalized difference water index, NDWI)	红光波段与短波红外波段反射率之差与之和的比值	能较好地监测植被冠层的水分含量
	条件植被指数 (Vegetation condition index, VCI)	通过将某段时间内的 NDVI 值与历史同期值归一化, 得到当前时间段的干旱情况	消除了 NDVI 的空间变异, 具有不同地区间的可比性; 适用于有植被覆盖的区域
生物物理参数	叶面积指数 (Leaf area index, LAI)	单位土地面积上植物叶片单侧总面积占土地面积的倍数	广泛应用于作物生长模型、冠层反射模型、气候模型等方面
	光合有效辐射分量 (Fraction of photosynthetically active radiation, FPAR)	吸收性光合有效辐射在光合有效辐射中所占的比重	广泛应用于各种生产力模型、作物估产模型等方面
生长环境参数	条件温度指数 (Temperature condition index, TCI)	当前的地表温度与多年来同一时间段地表温度最大与最小值比率	强调温度与植物生长的关系, 只需要某一时间序列白天热红外遥感数据
	条件植被温度指数 (Vegetation temperature condition index, VTCI)	某一研究区域 NDVI 值等于某一特定值的所有像素间 LST 差异的比率	适用于监测某一特定年内某一时期(如旬)区域级的干旱程度, 并可用于研究干旱程度的空间变化特征 <sup>[24]</sup>
	温度植被干旱指数 (Temperature vegetation dryness index, TVDI)	一种基于光学与热红外遥感通道数据进行植被覆盖区域表层土壤水分反演的方法	用于研究干旱程度的空间变化特征
垂直干旱指数 (Perpendicular drought index, PDI)		在近红外和红光反射率二维散点空间中垂直于经过坐标原点的土壤基线的法线, 描述了水分含量在近红外和红光反射率光谱特征空间的分布规律	应用于土壤水分的空间分布特征分析, 尤其适用于裸土

### 1.1.2 样本扩充

深度学习是一种数据驱动的技术,模型通常具有较为复杂的结构,需要大量的训练样本量使得深度学习模型学习到可能的分布<sup>[48-49]</sup>。然而,受作物品种特性和科技进步的影响,作物长势监测和估产模型的构建一般是应用近5年的数据<sup>[50]</sup>,能作为训练样本的数据有限,而深度学习模型对训练样本的要求较高,并且在较大规模样本的训练下可达到较高的精度,在较小规模样本下易出现过拟合现象。因此使用数据增强技术进行样本集的扩充对于在一定程度上改善样本量的限制和解决过拟合问题有重要作用,从而改进整体学习过程并获得最佳性能。

INOUE<sup>[51]</sup>提出一种高效的数据增强方法 Sample Pairing,它简单易操作,并且与具体数据无关,通过从训练集中随机抽取两个样本,以平均值的方式合成一个新的样本。ZHANG 等<sup>[52]</sup>通过引入 Mixup 方法构建虚拟训练样本,此方法同样随机选择两个样本,以一个服从 Beta 分布的比例进行叠加,从而改进了 Sample Pairing 在 ImageNet、CIFAR、语音和表格数据集中的泛化误差,且有助于消除对错误标签的记忆、对对抗样本的敏感性以及对对抗训练的不稳定性。由于在样本中类不平衡是一种很常见的现象,因此对原始数据过采样来处理样本不平衡问题也是一种数据增强方法。过采样是以多数类样本为标准,通过直接复制少数类样本或者人工合成少数类样本等方式提升少数类样本的数量以达到扩充和平衡数据集的目的。其中比较经典的是 CHAWLA 等<sup>[53]</sup>提出的合成少数类过采样技术(Synthetic minority oversampling technique,SMOTE),该算法通过 k 近邻法代替原先的简单随机复制样本法,合成新的少数类样本。

当样本数量较少时,传统的 Sample Pairing 和 Mixup 等方法很难补充到样本中隐含的潜在分布规律。生成式对抗网络(Generative adversarial network, GAN)作为一种近年来最具潜力的非监督数据增强技术,可以通过生成逼近训练数据真实分布的样本,从而实现对已有类别数据的模拟<sup>[54]</sup>。然而,GAN 在基于梯度下降训练时存在梯度消失的问题,导致优化目标不连续。为了解决训练梯度消失问题,ARJOVSKY 等<sup>[55]</sup>提出了 Wasserstein GAN(W-GAN)。考虑到 GAN 的输出为连续实数分布而无法产生离散空间的分布,YU 等<sup>[56]</sup>提出了一种能够生成离散序列的生成式模型 Seq-GAN。针对模型的不同问题,各种基于 GAN 的衍生模型相继被提出,从而进一步提高对抗网络的生成和判别能力,并学习出新的、更具代表性的样本。

### 1.2 作物长势监测和产量估测深度学习模型

尽管深度学习模型具有良好的通用性,但单一的网络框架不能解决所有问题。迄今为止,已经开发了不同的深度学习模型来实现对不同作物的产量估测,从而证明了深度学习网络框架的重要性。主流的深度学习模型包括卷积神经网络(Convolutional neural network, CNN)和循环神经网络(Recurrent neural network, RNN),下面进一步开展对每个模型结构及其优化的归纳总结。此外,针对深度学习模型可解释性弱的问题,优化模型结构从而提高模型可解释性。

#### 1.2.1 CNN 及其优化

相比于 ANN,CNN 更加易于训练,对于大型图像处理有出色的表现。CNN 是一种既有深度结构又包含卷积计算的深层前馈神经网络,是深度学习的常用算法之一。CNN 的设计思想受到了视觉神经科学的启发,主要由卷积层(Convolutional layer)和池化层(Pooling layer,也称子采样层)组成。CNN 本质上是实现一种输入到输出的映射关系,通过训练数据来进行学习,使得输出数据和标签数据共享相同的维度,避免了显式的特征提取,而是隐式地从训练数据中学习特征,且同一特征映射面上的神经元权值相同,网络可以并行学习,这也是 CNN 相对于其他神经网络的一个优势。因此,基于 CNN 模型的作物长势监测和产量估测研究取得了诸多成果,也激发了更多的研究者不断挖掘<sup>[57-59]</sup>。如周亮等<sup>[60]</sup>使用 MODIS 数据构建了基于 CNN 的冬小麦估产模型,该模型可以从遥感影像中有效地学习与冬小麦产量相关的特征,从而实现冬小麦单产的复杂拟合,对未来冬小麦产量预测可以做到实时高效。深度学习模型的训练过程中存在大量需要探索的技巧,即需要对网络结构和各项参数(如神经元、层数、滤波器大小、步幅、学习率和激活函数等)进行优化来提高网络的收敛性以及网络的泛化能力<sup>[49]</sup>。为了提高学习效率,得到更高精度的估产模型,NEVAVUORI 等<sup>[58]</sup>测试了 CNN 各方面(训练算法的选择、网络深度、正则化策略和超参数的调整)对预测效率的影响,并确定了性能最佳的网络,从而显著提高了产量估测的精度。YOU 等<sup>[57]</sup>提出了一种新的深度学习估产框架(2D Histogram CNN)(图 1),其创新之处在于使用遥感影像的直方图信息作为模型输入,既达到了数据降维的效果,同时又取得较高的产量预测精度。TERLIKSIZ 等<sup>[61]</sup>在 YOU 构建的深度学习估产框架基础上,利用遥感图像的空间、时间和光谱维度,提出了一种用于大豆产量预测的 3D CNN。研究结果表明,3D CNN 产量预

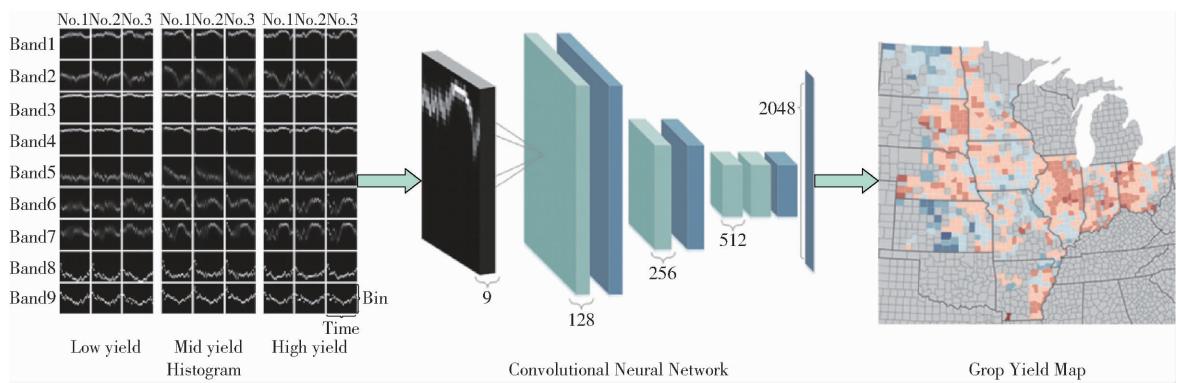
图 1 2D Histogram CNN 估产架构<sup>[57]</sup>

Fig. 1 Architecture of 2D Histogram CNN yield estimation

测精度显著优于 2D Histogram CNN，并揭示了利用深度时空特征学习模型进行作物产量预测将是未来的一个发展方向。

### 1.2.2 RNN 及其优化

CNN 模型能够较好地处理遥感影像的空间自相关性，但其不能充分地考虑复杂的时间相关性，因此，基于 CNN 模型不能够充分地提取时序遥感数据所反映的作物物候特征。而 RNN<sup>[62]</sup>是一种以序列数据为输入，利用序列数据之间的相关性在序列的演进方向进行递归的递归神经网络，其主要目的是针对序列型数据进行建模。这类数据在训练过程中需要保留序列上下文的信息，所以其隐节点中存在反馈环，即每一时刻的隐含节点需要综合之前时刻的信息以及当前时刻输入中包含的信息，将二者结合起来传递给下一时刻，RNN 能够利用过去时刻的信息，在各个时间上共享权重，使得模型参数大大减少，并且 RNN 因其在短序列处理方面的优异性能而成为分析遥感时间序列变化的重要模型。但是随着时间步长迭代的推移，RNN 存在梯度消失、梯度爆炸以及长期记忆能力不足的缺点<sup>[63]</sup>。为解决这一缺陷，长短时记忆 (Long short term memory, LSTM) 神经网络用改良后的记忆单元代替普通 RNN 中的记忆单元，这一改变可提升神经网络的长时间记忆能力，能够有效地利用更长时序信息。HAIDER 等<sup>[64]</sup>的研究结果表明，LSTM 神经网络模型估产精度明显高于 RNN。因此，LSTM 神经网络模型被广泛应用于处理时序数据问题<sup>[41, 65-67]</sup>。JIANG 等<sup>[68]</sup>

基于 LSTM 神经网络模型 (图 2, 其中, LSTM 表示长短记忆网络, WDRVI 表示宽动态范围植被指数, KDD 表示高温度日, GDD 表示生长期度日, Prec. 表示降水量, GP1 ~ GP5 表示玉米的 5 个生育时期,  $S_t$  为神经元当前状态,  $O_t$  为神经元当前输出,  $S_{t-1}$  为神经元前序状态,  $O_{t-1}$  为神经元前序输出,  $g_t^f$  为丢弃门,  $g_t^i$  为输入门,  $g_t^o$  为输出门,  $O_t$  为当前输入,  $\sigma$  为非线性激活函数 sigmoid, tanh 为输出激活函数, 操作符

$\otimes$  代表向量元素相乘运算, 操作符  $\oplus$  代表向量元素相加运算), 以玉米生育期作为时间序列, 通过将作物物候信息、气象数据和遥感数据相结合来估测县级玉米产量。结果表明, LSTM 神经网络模型能够提取出包含在数据序列中的隐含关系, 实现了准确的县级作物产量估测, 并且在极端天气条件下提供了稳健的产量估测。由于 CNN 无法学习时间相关性, 而 RNN、LSTM 捕捉空间特征能力有限, 针对此问题, SUN 等<sup>[69]</sup>提出了一种新的多级深度学习模型 (Multilevel deep learning network, MLDL - Net) (图 3, 其中, Level I 使用 CNN 网络在每个时间步进行时间序列数据空间特征探索; Level II 使用 LSTM 网络来探索时间序列特征; Level III 使用可以从土壤属性数据中提取空间特征的 CNN 网络; Level II 和 Level III 的输出被展平并连接成一个向量, 最后被送入用于估计的全连接层 FC), 该模型结合 LSTM 和 CNN 来提取空间和时间特征。该模型的评估结果表明, CNN - LSTM 模型相对于单一 CNN 模型或单一 LSTM 神经网络模型具有更高的准确性。作为 LSTM 的一种变体, 门控循环单元 (Gated recurrent unit, GRU)<sup>[70]</sup>可以用更少的训练时间处理长时间序列数据, 在收敛性以及参数更新方面表现出较高的性能。根据 BAHDANAU 等<sup>[71]</sup>在机器翻译方面的初步对比结果表明, 这两个模型的表现相当, 因此在长势监测和产量估测中需根据研究区、特征参数的类型和数量选择最合适的模型。

### 1.2.3 模型可解释性

由于深度神经网络模型具有“黑盒”属性, 使得其可解释性弱<sup>[19]</sup>。然而, 在应用深度学习模型开展作物长势监测和产量估测研究时, 实验或研究结果可能不理想, 这就要求根据特定的问题与数据来制定和优化深度学习的网络结构与训练参数, 以及学习策略等, 以解决深度学习模型可解释性弱的问题, 因此深度学习模型的可解释性成为目前的研究热点之一。可解释性可简单地理解为用人们可理解的方

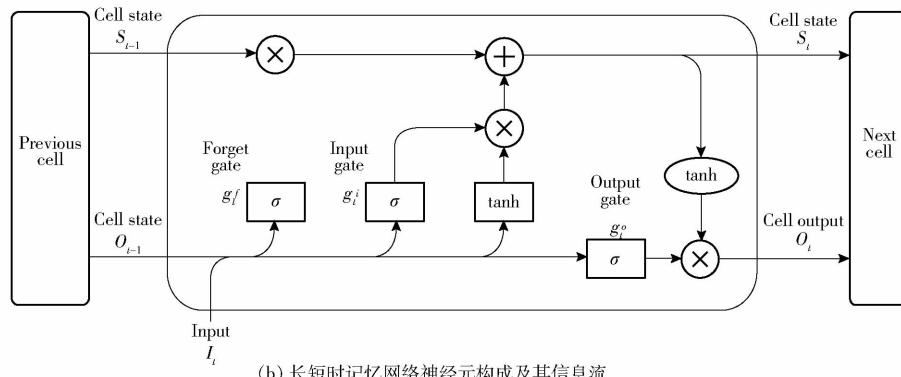
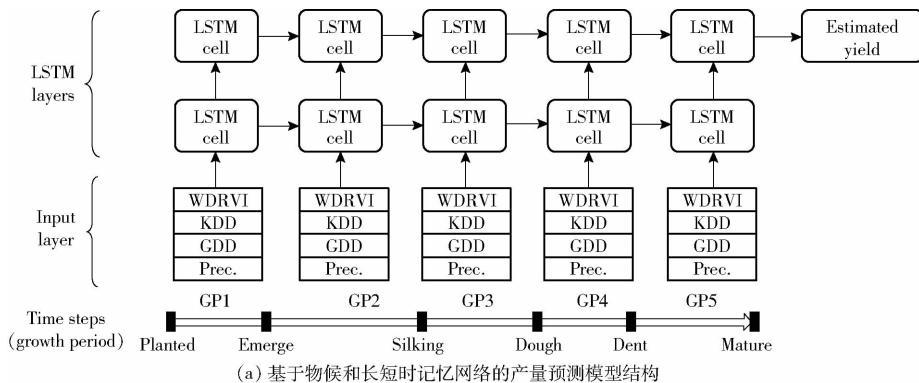


图 2 基于物候的长短时记忆(LSTM)模型的单产估测结构<sup>[68]</sup>

Fig. 2 Architecture of phenology-based LSTM yield estimation model

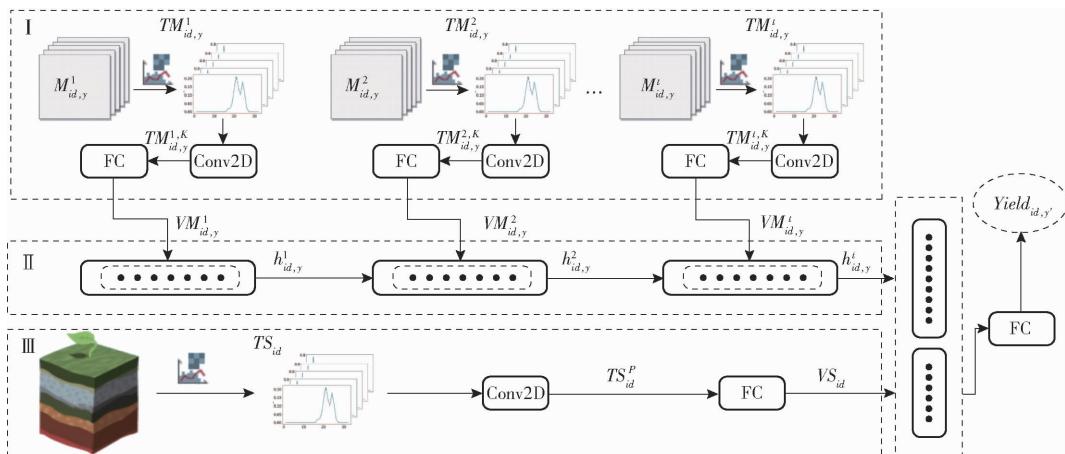


图 3 多级深度学习模型(MLDL-Net)架构<sup>[69]</sup>

Fig. 3 Architecture of multilevel deep learning network (MLDL-Net) framework

式来解释算法做出相应决策的原因<sup>[19, 71–72]</sup>。目前,对于深度学习模型的可解释性研究主要有2类研究方法<sup>[73–74]</sup>:一是从模型的可解释性分析入手,调整模型内部参数,对系统得到的结果进行分析,判断内部参数对于结果的影响;二是从模型的构建入手,直接构建本身就具有可解释性的模型,旨在学习更结构化和可解释的模型。后者往往具有更强的可解释性,但建模难度很大,且与应用领域密切相关。注意力机制是前者的典型代表,它与人类的选择性视觉注意力机制类似,是通过扫描全局图像获取重点关注的目标区域。注意力机制主要是在Encoder–Decoder(编码器–解码器)模型框架下提出的,它通

过对模型中不同关注部分赋予不同的权重,并从中抽取出更加重要和关键的信息,从而优化模型并做出更为准确的判断<sup>[70, 75–76]</sup>。

目前已出现了一些基于注意力机制的产量估测模型。TIAN 等<sup>[77]</sup>提出了基于注意力机制 LSTM (LSTM neural network with an attention mechanism, ALSTM) 的冬小麦单产估测模型(图 4),该模型相比于 LSTM 不仅能够提高估产精度,而且能够提取更重要的特征变量,提高神经网络的可解释性。为了能够清楚了解时间累积效应对于区域作物产量估计和不同地区作物生长的空间差异,LIN 等<sup>[78]</sup>开发了一个名为 DeepCropNet (DCN) 的深度时空学习框

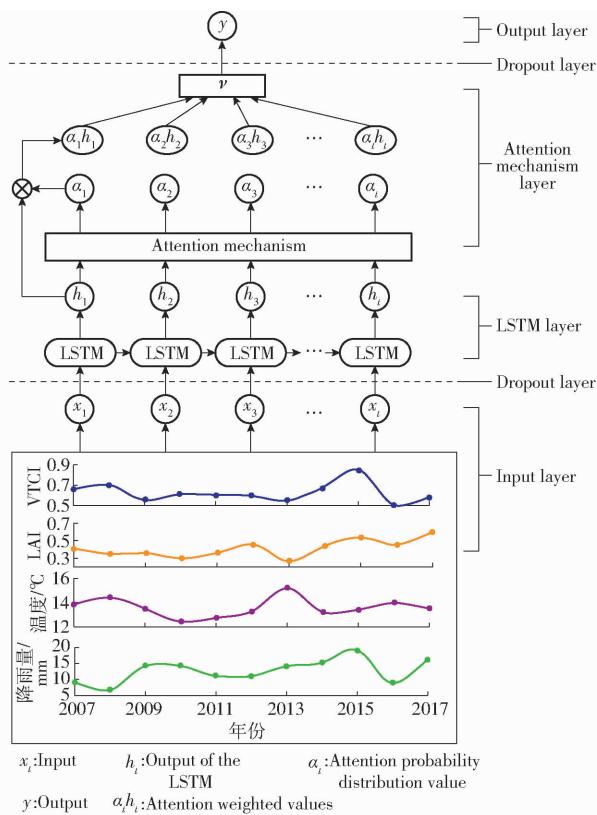


图4 用于县级冬小麦产量估算的 ALSTM 模型的总体结构<sup>[77]</sup>

Fig. 4 Overall structure of ALSTM model for county-level wheat yield estimation

架,其中时间特征由基于注意力机制的 LSTM 学习,空间特征由多任务学习 (Multi-task learning, MTL) 机制进行学习,分层捕获县级玉米长势的特征。结果表明,DCN 模型可以通过时间学习模块识别玉米生长季节的关键生长阶段,空间学习模块根据 MTL 机制捕获区域特定特征(如过度降雨、干旱、极端高温),DCN 模型为气候条件和生产水平差异大的区域下进行作物产量估测提供了一个发展方向。此外,林靖皓等<sup>[79]</sup>将 CNN 和双向门控循环单元 (Bidirectional gated recurrent unit, BiGRU) 以统一的架构组合,并在 CNN 和 GRU 之间引入自注意力机制 (Self-attention),开发了一种基于自注意力机制双向门控循环单元和卷积神经网络组合 (Self-attention C-BiGRU) 的芒果产量预测模型。该模型利用 CNN 的卷积层提取局部特征,Self-attention 用于进一步提取依赖特征,BiGRU 充分考虑年份之间的关联性,学习长期依赖特征,能够更准确地学习影响产量的特征,从而在一定程度上提高了模型的可解释性。

## 2 田块尺度的作物长势监测和产量估测研究进展

随着深度学习在区域尺度作物长势监测和产量

估测研究的不断深入,进一步细化研究尺度,将长势监测及产量估测研究具体到田块尺度,推动精准农业的持续发展成为目前的研究热点之一。继续沿用区域尺度作物长势监测所使用的 1 km 级别或者十几天分辨率的遥感数据,均无法满足田块尺度监测的需要。因此,使用高空间分辨率或同时具备高时空分辨率的遥感数据实现田块尺度监测成为解决此类问题的有效方法。本节回顾深度学习方法在田块尺度作物长势监测及产量估测研究中应用的进展,并根据遥感数据获取平台的不同,分为基于无人机平台和基于卫星平台的田块尺度作物长势监测和产量估测。

### 2.1 基于无人机平台的田块尺度作物长势监测和产量估测

无人机平台因具有成本低、数据获取效率高、测试高度及测试时间可按需调节等优点<sup>[80-82]</sup>,在监测作物长势研究中具有地面平台和高空平台无法比拟的优势<sup>[83]</sup>,已被用于田块尺度的农情信息获取。当研究尺度为田块尺度时,影像的空间分辨率提高,包含了更为丰富的空间细节特征。不同于传统方法仅可捕获局部空间相关性<sup>[84]</sup>,深度学习方法可以同时获取局部和全局的空间依赖特征<sup>[85]</sup>,提取更复杂的特征,从而获得高精度的长势监测及产量估测结果。YANG 等<sup>[86]</sup>基于无人机平台获取 RGB 和多光谱图像,使用 CNN 架构学习与水稻籽粒产量相关的重要特征从而实现在水稻成熟期的产量估测研究。随着 CNN 模型的进一步发展,模型结构复杂度逐渐提升,为减少模型运行的时间成本,吴刚等<sup>[87]</sup>在考虑无人机采集图像特性的基础上,选取深度合适、允许原始输入信息直接传到后面层中的 ResNet18 作为识别玉米植株图像的基本网络结构,实现玉米作物营养状况识别。针对长势监测过程中作物发生的倒伏情况,YANG 等<sup>[88]</sup>利用无人机获取影像,采用 FCN-AlexNet 和 SegNet 两种神经网络架构建立图像语义分割模型,实现了大面积稻田的水稻倒伏情况估计。

为进一步研究不同 CNN 结构对作物长势监测的适用情况,蒋楠等<sup>[89]</sup>通过无人机采集可见光影像,分别构建基于 AlexNet、VGGNet、GoogLeNet 3 种网络框架的 CNN 模型,实现了棉花花蕾期各项生长参数监测,结果表明,AlexNet 模型在株高和地上生物量方面表现最好;GoogLeNet 模型在叶面积指数监测方面性能最优。张瑞杰等<sup>[90]</sup>利用无人机影像建立幼苗期油菜的可见光图像数据集,并由农学专家将作物长势标注为好、一般、较差 3 种情况,选择 5 种 CNN 模型:EfficientNet、ShuffleNet v2、ResNet、

DenseNet、ResNeXt 分别进行优化和实验,实验结果显示,DenseNet 的识别精度最高,但是从综合精度和推理时间来看 ResNet 的表现更佳。综上可以看出,对于具体应用场景,不同深度学习方法的适用性仍需要进一步研究。

利用深度学习方法基于无人机平台进行作物长势监测时存在平台容易受环境影响、无法大范围长时间连续稳定获取作物影像、深度学习算法复杂性高及耗时长等不足。未来可以进一步完善无人机遥感技术,提高数据获取及处理的稳定性和一致性,从而确保获取数据的准确性,实现长时间序列的作物长势监测和产量估测。此外,可尝试通过改进深度学习算法,来提高算法学习效率。

## 2.2 基于卫星平台的田块尺度作物长势监测和产量估测

随着高空间分辨率卫星的不断出现以及相比于无人机平台所具有的覆盖范围广等优势,利用高空间分辨率卫星数据进行田块尺度作物长势监测及产量估测也取得了一定进展。如,CAO 等<sup>[91]</sup>通过整合谷歌地球引擎(Google earth engine, GEE)平台中公开可用的数据,对比深度神经网络(Deep neural network, DNN)、1D CNN 和 LSTM 在田块尺度产量预测的适用性,结果表明,DNN 在田块尺度表现较好。然而,在利用高空间分辨率卫星影像进行田块尺度作物长势监测时,光学遥感卫星容易受到天气影响,无法在时间尺度上满足监测需要。针对这一问题,可采用基于光学和微波遥感数据融合的方法以及基于时空数据融合的方法对缺失数据进行补充,从而满足时间尺度监测的需要。

相比于光学遥感,微波遥感可以接收来自地表较长的电磁波信息,这些较长的电磁波可以有效穿透云雾,从而使得微波遥感具备全天候监测地表的能力<sup>[92]</sup>。因此,融合光学和微波遥感数据可以进一步提高模型输入数据的获取能力。目前,在融合光学与雷达遥感卫星数据方面,大部分研究的关注点在于如何基于雷达数据填补光学遥感指数在时间序列上的缺失。如 ZHAO 等<sup>[93]</sup>基于时间序列 Sentinel-1 雷达卫星数据的 VV 和 VH 极化图像,首先利用 1D CNN 模型提取每种极化图像的特征,然后将提取出的时间序列雷达极化特征输入 LSTM 模型,用以模拟时间序列的 Sentinel-2 光学卫星数据反演的 NDVI 的动态变化,最终在时间序列上填补 NDVI 的缺失。物候是影响作物生长的一个重要因素,是作物长势监测的一个重要研究领域。得益于微波遥感卫星的全天候地表信息获取能力,基于微波遥感的作物物候监测受到越来越多的关注。如 MERONI

等<sup>[94]</sup>针对不同类型作物,比较了 Sentinel-1 和 Sentinel-2 数据在监测作物物候方面的表现,发现 Sentinel-1 反演的物候结果与 Sentinel-2 的反演结果具有可比性,且相比于夏季作物,冬季作物的可比性更高。上述研究表明,光学数据和微波数据在监测作物长势方面具有较高的协同潜力。为了更好地结合两种数据源各自的优势,也有一些研究以光学和雷达数据同时作为模型输入,这不仅弥补了仅依靠光学数据作为模型输入带来的信息不足的缺陷,同时也避免了只依靠微波数据带来的较多异常值的问题。如 IENCO 等<sup>[95]</sup>将时间序列的 Sentinel-1 和 Sentinel-2 数据集分别作为模型的输入数据,并分别通过 ConvGRU + Attention 分支和 CNN 分支,每个分支后连接一个辅助分类器以提高分支的预测能力,最后通过全连接层输出地表分类结果。鉴于目前田块尺度的作物产量标签获取难度较大,通过深度学习方法并融合光学和雷达数据的农业领域研究主要集中在作物分类方面,而在田块尺度的作物产量估测方面的研究还较少。

相比基于光学和微波遥感数据融合的方法,基于时空数据融合的方法不仅能够实现缺失数据的填补,还可以满足在田块尺度监测过程中高时间和高空间分辨率的要求,从而进一步提高田块尺度长势监测及产量估测的精度。基于时空数据融合的作物长势监测及产量估测方法通过融合高空间分辨率数据和高时间分辨率数据获取具有高时空分辨率的遥感数据,从而进行田块尺度的作物长势监测及产量估测。目前基于时空数据融合的田块尺度作物长势监测方法可以依据时空数据融合方法不同,分为基于混合像元分解、基于权重函数、基于贝叶斯、基于学习和基于混合的 5 类时空融合方法<sup>[96]</sup>,并已广泛应用于作物种植面积提取<sup>[97-98]</sup>、长势监测<sup>[99-100]</sup>及产量估测<sup>[101-102]</sup>。其中,基于学习的时空融合方法可利用机器学习算法学习不同分辨率影像之间的非线性变化关系建立模型,从而获取具有较高精度的高时空分辨率影像。

随着深度学习的不断发展,基于深度学习实现时空数据融合成为一种新的研究思路。CHU 等<sup>[103]</sup>使用两个反向传播神经网络(Back-propagation neural networks, BPNNs)和独立循环神经网络(Independently RNN, IndRNN)引入时间特征,从而提取数据的空间特征和时间特征,并通过全连接层对特征进行融合实现对水稻产量的预测,降低了时间特征对产量预测的影响。目前已出现了一些基于 CNN 的时空数据融合模型。相比于传统的时空数据融合模型,基于 CNN 的时空数据融合模型能够自

动、有效地学习影像上的特征,并在特征层面上进行数据融合。相比于像元层面的时空数据融合模型,特征层次的时空数据融合模型能够减少对影像噪声的敏感程度,然而在融合影像的清晰度方面有所降低。SAGAN 等<sup>[104]</sup>运用 2D 和 3D 的 CNN 集成 WorldView-3 和 PlanetScope 卫星数据中包含的光谱、空间和时间信息实现大豆生长季产量估测。为进一步适应时间变化,处理复杂和异质性的景观,以及集成其他卫星数据集,HTITIOU 等<sup>[105]</sup>提出了一种基于极深超分辨率 (Very deep super-resolution, VDSR) 的深度学习时空数据融合方法,将 Sentinel-2 和 Landsat 8 的 NDVI 数据进行融合,并对比分析了 VDSR 与增强型时空自适应反射率融合模型 (Enhanced spatial and temporal adaptive reflectance fusion model, ESTARFM) 和灵活时空数据融合 (Flexible spatiotemporal data fusion, FSDAF) 两种经典方法的性能,结果表明,VDSR 算法相较其他数据融合算法具有模糊程度最低和合成 NDVI 值预测最准确的特点,特别是在景观异质性和土地覆盖突变的地区。

除上述已运用于作物长势监测及产量估测的深度学习融合方法外,还有一些提出的深度学习融合方法尚未运用到农业领域,如 TAN 等<sup>[106]</sup>提出的深度卷积时空融合网络 (Deep convolutional spatiotemporal fusion network, DCSTFN),该算法充分利用 CNN 从高时间低空间分辨率和低时间高空间分辨率的遥感影像中提取高时空分辨率影像,结果表明,基于 CNN 的融合算法不仅达到了较高的精度,而且比传统的时空融合算法更具鲁棒性。此后,TAN 等<sup>[107]</sup>对现有的 DCSTFN 进行了细化和改进,提出了改进的深度卷积时空融合网络 (Enhanced DCSTFN, EDCSTFN),该算法通过构建残差编码器自动学习输入高空间分辨率影像与预测高空间分辨率影像之间的特征差异,同时,在损失函数中引入视觉损失函数来尽可能保留高频信息,从而进一步提高了模型预测精度。在今后的研究中可尝试将此类方法运用于作物长势监测及产量估测之中,扩展方法应用领域,进一步研究方法的适用性。

### 3 存在的问题与展望

虽然基于深度学习的长势监测和产量估测研究已经取得了全面发展,然而,相关领域的研究还存在一些需要解决的问题。主要表现在:

(1) 深度学习模型建立于大样本之上才能保证其精度,然而,目标产量的样本数量通常是有局限的,因此使用迁移学习可以在一定程度上改善小

样本的限制<sup>[108-109]</sup>。在这种方法中,可以使用有限的样本在大型数据集上预训练的模型中的参数进行微调,以在新任务中获得最佳性能。具体包括以下两方面:一是基于区域的迁移学习。首先利用样本数量充足的区域来学习模型,然后将该模型扩展到样本数量较少的其他区域,实现区域的传递。二是基于参数的迁移学习。针对相关任务的模型间共享部分参数,或超参数的先验分布以提高整体性能。迄今为止,虽然这两种方法都有助于提升模型性能,但由于数据具有复杂和多样的特点,目前对数据集相似度的界定还没有统一的办法,且以相似度为基础的迁移需要更多定量和定性的解释。因此,未来随着数据的累积,深度学习模型的优势将逐渐凸显。此外,基于区域的迁移学习中不同区域的环境是异构的,如何实现异构环境下的迁移是未来的研究方向。

(2) 深度学习的可解释性依旧是个难题。深度学习模型的本质是从数据到数据的特征提取,对作物生长过程的描述与机理表达无法学习到,而作物生长模型整合了很多已知的作物生理学、作物栽培学等先验知识。因此,未来可尝试探索作物生长模型和深度学习模型的并行和协同开发,以提高对作物生长过程的理解,从而提高模型的可解释性。此外,作物生长模型参数往往存在不确定性,从而导致模型输出错误,通过实际观测和其他辅助数据,使用深度学习模型来对作物生长模型输出进行校准。

(3) 在田块尺度利用深度学习进行作物长势监测及产量估测时,需利用深度学习复杂的网络结构对高分辨率数据进行充分学习,而在此过程中需要大量的时间进行训练,同时对计算机性能提出了较高要求。因此,如何高效、快速学习特征,保证学习特征的完整性,尽可能减少对冗余信息的学习是利用深度学习方法进行田块尺度长势监测的难点之一。

(4) 在田块尺度进行作物长势监测及产量估测时,卫星遥感难以克服空间异质性对于精度的影响,而无人机平台可以较好地识别异质性信息,因此可以尝试将无人机平台与卫星平台相结合,以无人机平台数据作为卫星数据时空融合过程中尺度转换的中间变量,确保在降尺度过程中的精度。

深度学习在产量估测方面取得了比传统机器学习和统计模型更高的精度,不断克服依赖专家经验、耗费人力物力等缺点,为作物长势监测及产量估测的研究拓展了全新的研究视角。本文从区域尺度和田块尺度两方面,通过代表性文献分析了深度学习

在作物长势监测及产量估测相关研究中的最新应用进展。同时随着在时间、空间等维度的深度融合,对未来深度学习技术提出更高的要求,只有智能技术

的更进一步发展才能有效促进融合下的多维度数据分析,为农情监测和防灾减灾提供更强的科学依据和技术支撑。

## 参 考 文 献

- [1] 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)
- [2] 赵春江. 农业遥感研究与应用进展[J]. 农业机械学报, 2014, 45(12): 277–293.  
ZHAO Chunjiang. Advances of research and application in remote sensing for agriculture [J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(12): 277–293. (in Chinese)
- [3] 朱再春, 陈联裙, 张锦水, 等. 基于信息扩散和关键期遥感数据的冬小麦估产模型[J]. 农业工程学报, 2011, 27(2): 187–193.  
ZHU Zaichun, CHEN Lianqun, ZHANG Jinshui, et al. Winter wheat yield estimation model based on information diffusion and remote sensing data at major growth stages[J]. Transactions of the CSAE, 2011, 27(2): 187–193. (in Chinese)
- [4] MKHABELA M S, BULLOCK P, RAJ S, et al. Crop yield forecasting on the Canadian Prairies using MODIS NDVI data[J]. Agricultural and Forest Meteorology, 2011, 151(3): 385–393.
- [5] PASWAN R P, BEGUM S A. Regression and neural networks models for prediction of crop production[J]. International Journal of Scientific & Engineering Research, 2013, 4(9): 98–107.
- [6] SAMI K, JOHN F, ANDREW K, et al. Integration of high resolution remotely sensed data and machine learning techniques for spatial prediction of soil properties and corn yield[J]. Computers and Electronics in Agriculture, 2018, 153: 213–225.
- [7] 黎锐, 李存军, 徐新刚, 等. 基于支持向量回归(SVR)和多时相遥感数据的冬小麦估产[J]. 农业工程学报, 2009, 25(7): 114–117.  
LI Rui, LI Cunjun, XU Xin'gang, et al. Winter wheat yield estimation based on support vector machine regression and multi-temporal remote sensing data[J]. Transactions of the CSAE, 2009, 25(7): 114–117. (in Chinese)
- [8] FORTIN J G, ANCTIL F, PARENT L, et al. Site-specific early season potato yield forecast by neural network in Eastern Canada[J]. Precision Agriculture, 2011, 12(6): 905–923.
- [9] FIEUZAL R, SICRE C M, BAUP F. Estimation of corn yield using multi-temporal optical and radar satellite data and artificial neural networks[J]. International Journal of Applied Earth Observations and Geoinformation, 2017, 57: 14–23.
- [10] 刘峻明, 和晓彤, 王鹏新, 等. 长时间序列气象数据结合随机森林法早期预测冬小麦产量[J]. 农业工程学报, 2019, 35(6): 158–166.  
LIU Junming, HE Xiaotong, WANG Pengxin, et al. Early prediction of winter wheat yield with long time series meteorological data and random forest method[J]. Transactions of the CSAE, 2019, 35(6): 158–166. (in Chinese)
- [11] 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)
- [12] KIM N, HA K J, PARK N W, et al. A comparison between major artificial intelligence models for crop yield prediction: case study of the Midwestern United States, 2006—2015[J]. ISPRS International Journal of Geo-Information, 2019, 8(5): 240–262.
- [13] MAYA GOPAL P S, BHARGAVI R. A novel approach for efficient crop yield prediction[J]. Computers and Electronics in Agriculture, 2019, 165: 104968.
- [14] JOHNSON M D, HSIEH W, CANNON A J, et al. Crop yield forecasting on the Canadian Prairies by remotely sensed vegetation indices and machine learning methods[J]. Agricultural and Forest Meteorology, 2016, 218–219: 74–84.
- [15] KUWATA K, SHIBASAKI R. Estimating crop yields with deep learning and remotely sensed data[C]// IEEE International Geoscience and Remote Sensing Symposium, Milan, Italy, 2015: 858–861.
- [16] ZHANG L P, ZHANG L F, DU B. Deep learning for remote sensing data: a technical tutorial on the state of the art[J]. IEEE Geoscience and Remote Sensing Magazine, 2016, 4(2): 22–40.
- [17] 陈希亮, 曹雷, 何明, 等. 深度逆向强化学习研究综述[J]. 计算机工程与应用, 2018, 54(5): 24–35.  
CHEN Xiliang, CAO Lei, HE Ming, et al. Overview of deep inverse reinforcement learning[J]. Computer Engineering and Applications, 2018, 54(5): 24–35. (in Chinese)
- [18] KAMILARIS A, FRANCESCA X, PRENAFETA-BOLDÚ. Deep learning in agriculture: a survey [J]. Computers and Electronics in Agriculture, 2018, 147: 70–90.
- [19] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven Earth system science[J]. Nature, 2019, 566(7743): 195–204.
- [20] 蒙继华, 吴炳方, 李强子, 等. 农田农情参数遥感监测进展及应用展望[J]. 遥感信息, 2010(3): 122–128.  
MENG Jihua, WU Bingfang, LI Qiangzi, et al. Research advances and outlook of crop monitoring with remote sensing at field

- [J]. Remote Sensing Information, 2010(3): 122–128. (in Chinese)
- [21] YUAN Q, SHEN H F, LI T W, et al. Deep learning in environmental remote sensing: achievements and challenges [J]. Remote Sensing of Environment, 2020, 241: 111716.
- [22] 徐新刚, 王纪华, 黄文江, 等. 基于权重最优组合和多时相遥感的作物估产[J]. 农业工程学报, 2009, 25(9): 137–142.  
XU Xin'gang, WANG Jihua, HUANG Wenjiang, et al. Estimation of crop yield based on weight optimization combination and multi-temporal remote sensing data[J]. Transactions of the CSAE, 2009, 25(9): 137–142. (in Chinese)
- [23] 任建强, 陈仲新, 周清波, 等. 基于叶面积指数反演的区域冬小麦单产遥感估测[J]. 应用生态学报, 2010, 21(11): 2883–2888.  
REN Jianqiang, CHEN Zhongxin, ZHOU Qingbo, et al. LAI-based regional winter wheat yield estimation by remote sensing [J]. Chinese Journal of Applied Ecology, 2010, 21(11): 2883–2888. (in Chinese)
- [24] 王鹏新, 龚健雅, 李小文. 条件植被温度指数及其在干旱监测中的应用[J]. 武汉大学学报(信息科学版), 2001, 26(5): 412–418.  
WANG Pengxin, GONG Jianya, LI Xiaowen. Vegetation temperature condition index and its application for drought monitoring [J]. Geomatics and Information Science of Wuhan University, 2001, 26(5): 412–418. (in Chinese)
- [25] 陈仲新, 任建强, 唐华俊, 等. 农业遥感研究应用进展与展望[J]. 遥感学报, 2016, 20(5): 748–767.  
CHEN Zhongxin, REN Jianqiang, TANG Huajun, et al. Progress and perspectives on agricultural remote sensing research and applications in China[J]. Journal of Remote Sensing, 2016, 20(5): 748–767. (in Chinese)
- [26] 吴炳方, 张峰, 刘成林, 等. 农作物长势综合遥感监测方法[J]. 遥感学报, 2004, 8(6): 498–514.  
WU Bingfang, ZHANG Feng, LIU Chenglin, et al. An integrated method for crop condition monitoring[J]. Journal of Remote Sensing, 2004, 8(6): 498–514. (in Chinese)
- [27] BECKER-RESHEF I, VERMOTE E F, LINDEMAN M, et al. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data[J]. Remote Sensing of Environment, 2010, 114(6): 1312–1323.
- [28] 史舟, 梁宗正, 杨媛媛, 等. 农业遥感研究现状与展望[J]. 农业机械学报, 2015, 46(2): 247–260.  
SHI Zhou, LIANG Zongzheng, YANG Yuanyuan, et al. Status and prospect of agriculture remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(2): 247–260. (in Chinese)
- [29] 黄健熙, 罗倩, 刘晓暄, 等. 基于时间序列 MODIS NDVI 的冬小麦产量预测方法[J]. 农业机械学报, 2016, 47(2): 295–301.  
HUANG Jianxi, LUO Qian, LIU Xiaoxuan, et al. Winter wheat yield forecasting based on time series of MODIS NDVI[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(2): 295–301. (in Chinese)
- [30] 薛利红, 曹卫星, 罗卫红. 基于冠层反射光谱的水稻产量预测模型[J]. 遥感学报, 2005, 9(1): 100–105.  
XUE Lihong, CAO Weixing, LUO Weihong. Rice yield forecasting model with canopy reflectance spectra[J]. Journal of Remote Sensing, 2005, 9(1): 100–105. (in Chinese)
- [31] REN J Q, CHEN Z X, ZHOU Q B, et al. Regional yield estimation for winter wheat with MODIS–NDVI data in Shandong, China[J]. International Journal of Applied Earth Observation and Geoinformation, 2008, 10(4): 403–413.
- [32] 何亚娟, 汪庆发, 裴志远, 等. 冬小麦产量分阶段预测模型[J]. 农业机械学报, 2012, 43(1): 89–93, 133.  
HE Yajuan, WANG Qingfa, PEI Zhiyuan, et al. Winter wheat yield forecast multi-stage model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(1): 89–93, 133. (in Chinese)
- [33] 刘新杰, 魏云霞, 焦全军, 等. 基于时序定量遥感的冬小麦长势监测与估产研究[J]. 遥感技术与应用, 2019, 34(4): 756–765.  
LIU Xinjie, WEI Yunxia, JIAO Quanjun, et al. Growth monitoring and yield prediction of winter wheat based on time-series quantitative remote sensing data[J]. Remote Sensing Technology and Application, 2019, 34(4): 756–765. (in Chinese)
- [34] TIAN H R, WANG P X, TANSEY K, et al. An IPSO–BP neural network for estimating wheat yield using two remotely sensed variables in the Guanzhong Plain, PR China[J]. Computers and Electronics in Agriculture, 2020, 169: 105180.
- [35] 赵虎, 杨正伟, 李霖, 等. 作物长势遥感监测指标的改进与比较分析[J]. 农业工程学报, 2011, 27(1): 243–249.  
ZHAO Hu, YANG Zhengwei, LI Lin, et al. Improvement and comparative analysis of indices of crop growth condition monitoring by remote sensing[J]. Transactions of the CSAE, 2011, 27(1): 243–249. (in Chinese)
- [36] 李艳, 王鹏新, 刘峻明, 等. 基于条件植被温度指数的冬小麦主要生育时期干旱监测效果评价Ⅲ——干旱对冬小麦产量的影响评估[J]. 干旱地区农业研究, 2014, 32(5): 218–222.  
LI Yan, WANG Pengxin, LIU Junming, et al. Evaluation of drought monitoring effects in the main growth and development stages of winter wheat using vegetation temperature condition index Ⅲ—Impact evaluation of drought on wheat yield[J]. Agricultural Research in the Arid Areas, 2014, 32(5): 218–222. (in Chinese)
- [37] 王蕾, 王鹏新, 李俐, 等. 河北省中部平原玉米长势遥感综合监测[J]. 资源科学, 2018, 40(10): 2099–2109.  
WANG Lei, WANG Pengxin, LI Li, et al. Integrated maize growth monitoring based on gray correlation analysis and remote sense data in the central plain of Hebei Province[J]. Resources Science, 2018, 40(10): 2099–2109. (in Chinese)
- [38] BOLTON D K, FRIEDL M A. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics[J]. Agricultural and Forest Meteorology, 2013, 173: 74–84.
- [39] 孔令寅, 延昊, 鲍艳松, 等. 基于关键发育期的冬小麦长势遥感监测方法[J]. 中国农业气象, 2012, 33(3): 424–430.  
KONG Lingyin, YAN Hao, BAO Yansong, et al. Remote sensor monitoring method for winter wheat growth based on key

- development periods[J]. Chinese Journal of Agrometeorology, 2012, 33(3): 424–430. (in Chinese)
- [40] 黄青, 李丹丹, 陈仲新, 等. 基于 MODIS 数据的冬小麦种植面积快速提取与长势监测[J]. 农业机械学报, 2012, 43(7): 163–167.
- HUANG Qing, LI Dandan, CHEN Zhongxin, et al. Monitoring of planting area and growth condition of winter wheat in China based on MODIS data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(7): 163–167. (in Chinese)
- [41] CAI Y P, GUAN K Y, LOBELL D. Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches[J]. Agricultural and Forest Meteorology, 2019, 274: 144–159.
- [42] TIAN H R, WANG P X, TANSEY K, et al. An LSTM neural network for improving wheat yield estimates by integrating remote sensing data and meteorological data in the Guanzhong Plain, PR China[J]. Agricultural and Forest Meteorology, 2021, 310: 108629.
- [43] 王纪华, 李存军, 刘良云, 等. 作物品质遥感监测预报研究进展[J]. 中国农业科学, 2008, 41(9): 2633–2640.
- WANG Jihua, LI Cunjun, LIU Liangyun, et al. Progress of remote sensing monitoring and forecasting crop quality[J]. Scientia Agricultura Sinica, 2008, 41(9): 2633–2640. (in Chinese)
- [44] SHOOK J, GANGOPADHYAY T, WU L, et al. Crop yield prediction integrating genotype and weather variables using deep learning[J]. PLoS ONE, 2021, 16(6): e0252402.
- [45] 王纪华, 黄文江, 赵春江, 等. 利用光谱反射率估算叶片和籽粒品质指标研究[J]. 遥感学报, 2003, 7(4): 277–284.
- WANG Jihua, HUANG Wenjiang, ZHAO Chunjiang, et al. The inversion of leaf biochemical components and grain quality indicators of winter wheat with spectral reflectance[J]. Journal of Remote Sensing, 2003, 7(4): 277–284. (in Chinese)
- [46] WALTER A, LIEBISCH F, HUND A. Plant phenotyping: from bean weighing to image analysis[J]. Plant Methods, 2015, 11: 14.
- [47] WEISS M, JACOB F, DUVEILLER G. Remote sensing for agricultural applications: a meta-review[J]. Remote Sensing of Environment, 2020, 236: 111402.
- [48] 张荣, 李伟平, 莫同. 深度学习研究综述[J]. 信息与控制, 2018, 47(4): 385–397.
- ZHANG Rong, LI Weiping, MO Tong. Review of deep learning[J]. Information and Control, 2018, 47(4): 385–397. (in Chinese)
- [49] 胡越, 罗东阳, 花奎, 等. 关于深度学习的综述与讨论[J]. 智能系统学报, 2019, 14(1): 1–19.
- HU Yue, LUO Dongyang, HUA Kui, et al. Overview on deep learning[J]. CAAI Transactions on Intelligent Systems, 2019, 14(1): 1–19. (in Chinese)
- [50] 吴炳方, 张森, 曾红伟, 等. 全球农情遥感速报系统 20 年[J]. 遥感学报, 2019, 23(6): 1053–1063.
- WU Bingfang, ZHANG Miao, ZENG Hongwei, et al. Twenty years of CropWatch: progress and prospect[J]. Journal of Remote Sensing, 2019, 23(6): 1053–1063. (in Chinese)
- [51] INOUE H. Data augmentation by pairing samples for images classification [C] // International Conference on Learning Representations, 2018: 1801.02929.
- [52] ZHANG H Y, CISSE M, DAUPHIN Y N, et al. Mixup: beyond empirical risk minimization [C] // Proceedings of the 6th International Conference on Learning Representations, Vancouver Convention Center, Canada, 2018: 147–155.
- [53] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16(1): 321–357.
- [54] 王坤峰, 苟超, 段艳杰, 等. 生成式对抗网络 GAN 的研究进展与展望[J]. 自动化学报, 2017, 43(3): 321–332.
- WANG Kunfeng, GOU Chao, DUAN Yanjie, et al. Generative adversarial networks: the state of the art and beyond[J]. Acta Automatica Sinica, 2017, 43(3): 321–332. (in Chinese)
- [55] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks [C] // Proceedings of the 34th International Conference on Machine Learning, 2017: 214–223.
- [56] YU L T, ZHANG W N, WANG J, et al. SeqGAN: sequence generative adversarial nets with policy gradient[C] // The Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17), 2017: 2582–2858.
- [57] YOU J X, LI X C, LOW M, et al. Deep Gaussian process for crop yield prediction based on remote sensing data[C] // Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, 2017: 4559–4566.
- [58] NEAVAUORI P, NARRA N, LIPPING T. Crop yield prediction with deep convolutional neural networks[J]. Computers and Electronics in Agriculture, 2019, 163: 104859.
- [59] 刘峻明, 周舟, 和晓彤, 等. 基于 NDWI 和卷积神经网络的冬小麦产量估测方法[J]. 农业机械学报, 2021, 52(12): 273–280.
- LIU Junming, ZHOU Zhou, HE Xiaotong, et al. Winter wheat yield estimation based on NDWI and convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12): 273–280. (in Chinese)
- [60] 周亮, 慕号伟, 马海姣, 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): 119–128.
- 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): 119–128. (in Chinese)
- [61] TERLİKSİZ A S, ALTYŁAR D T. Use of deep neural networks for crop yield prediction: a case study of soybean yield in Lauderdale County, Alabama, USA[C] // 2019 8th International Conference on Agro-Geoinformatics, 2019: 1–4.

- [62] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533–536.
- [63] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult [J]. IEEE Transactions on Neural Networks, 1994, 5(2): 157–166.
- [64] HAIDER S A, NAQVI S R, AKRAM T, et al. LSTM neural network based forecasting model for wheat production in Pakistan [J]. Agronomy, 2019, 9(2): 72–83.
- [65] CUNHA R L, SILVA B, NETTO M A, et al. A scalable machine learning system for pre-season agriculture yield forecast[C]// 2018 IEEE 14th International Conference on E-science, 2018: 423–430.
- [66] WANG X L, HUANG J X, FENG Q L, et al. Winter wheat yield prediction at county level and uncertainty analysis in main wheat-producing regions of China with deep learning approaches[J]. Remote Sensing, 2020, 12(11): 1744–1763.
- [67] SCHWALBERT R A, AMADO T, CORASSA G, et al. Satellite-based soybean yield forecast: integrating machine learning and weather data for improving crop yield prediction in southern Brazil [J]. Agricultural and Forest Meteorology, 2020, 284: 107886.
- [68] JIANG H, HU H, ZHONG R H, et al. A deep learning approach to conflating heterogeneous geospatial data for corn yield estimation: a case study of the US Corn Belt at the county level[J]. Global Change Biology, 2020, 26(3): 1754–1766.
- [69] SUN J, LAI Z L, DI L P, et al. Multilevel deep learning network for county-level corn yield estimation in the U.S. Corn Belt [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 5048–5060.
- [70] CHO K, MERRIENBOER B, BAHDANAU D, et al. On the properties of neural machine translation: encoder-decoder approaches[C]// Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation, 2014: 103–111.
- [71] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[J]. arXiv preprint, arXiv:1409.0473, 2014.
- [72] CHO Y R, KANG M. Interpretable machine learning in bioinformatics[J]. Methods, 2020, 179: 1–2.
- [73] MURDOCHA W J, SINGH C, KUMBIER K, et al. Definitions, methods, and applications in interpretable machine learning [J]. PNAS, 2019, 116(44): 22071–22080.
- [74] 成科扬, 王宁, 师文喜, 等. 深度学习可解释性研究进展[J]. 计算机研究与发展, 2020, 57(6): 1208–1217.  
CHENG Keyang, WANG Ning, SHI Wenxi, et al. Research advances in the interpretability of deep learning[J]. Journal of Computer Research and Development, 2020, 57(6): 1208–1217. (in Chinese)
- [75] 孙萍, 胡旭东, 张永军. 结合注意力机制的深度学习图像目标检测[J]. 计算机工程与应用, 2019, 55(17): 180–184.  
SUN Ping, HU Xudong, ZHANG Yongjun. Object detection based on deep learning and attention mechanism[J]. Computer Engineering and Applications, 2019, 55(17): 180–184. (in Chinese)
- [76] CHAUDHARI S, MITHAL V, POLATKAN G, et al. An attentive survey of attention models[J]. ACM Transactions on Intelligent Systems and Technology, 2021, 12(5): 1–32.
- [77] TIAN H R, WANG P X, TANSEY K, et al. A deep learning framework under attention mechanism for wheat yield estimation using remotely sensed indices in the Guanzhong Plain, PR China[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 102: 102375.
- [78] LIN T, ZHONG R H, WANG Y D, et al. DeepCropNet: a deep spatial-temporal learning framework for county-level corn yield estimation[J]. Environmental Research Letters, 2020, 15(3): 34016.
- [79] 林靖皓, 秦亮曦, 苏永秀, 等. 基于自注意力机制的双向门控循环单元和卷积神经网络的芒果产量预测[J]. 计算机应用, 2020, 40(增刊): 51–55.  
LIN Jinghao, QIN Liangxi, SU Yongxiu, et al. Prediction of mango yield based on self-attention CNN and bidirectional GRU [J]. Journal of Computer Applications, 2020, 40(Supp.): 51–55. (in Chinese)
- [80] COLOMINA I, MOLINA P. Unmanned aerial systems for photogrammetry and remote sensing: a review[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 92: 79–97.
- [81] GARCIA-RUIZ F, SANKARAN S, MAJA J M, et al. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees[J]. Computers and Electronics in Agriculture, 2013, 91(1): 106–115.
- [82] MATHEWS A J, JENSEN J L R. Visualizing and quantifying vineyard canopy LAI using an unmanned aerial vehicle (UAV) collected high density structure from motion point cloud[J]. Remote Sensing, 2013, 5(5): 2164–2183.
- [83] 汪小钦, 王苗苗, 王绍强, 等. 基于可见光波段无人机遥感的植被信息提取[J]. 农业工程学报, 2015, 31(5): 152–159.  
WANG Xiaoqin, WANG Miaomiao, WANG Shaoqiang, et al. Extraction of vegetation information from visible unmanned aerial vehicle images[J]. Transactions of the CSAE, 2015, 31(5): 152–159. (in Chinese)
- [84] WANG S Z, ZHANG X M, LI F X, et al. Efficient traffic estimation with multi-sourced data by parallel coupled hidden Markov model[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(8): 3010–3023.
- [85] ZHANG Q, CHANG J L, MENG G F, et al. Spatio-temporal graph structure learning for traffic forecasting[C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2020: 1177–1185.
- [86] YANG Q, SHI L S, HAN J Y, et al. Deep convolutional neural networks for rice grain yield estimation at the ripening stage using UAV-based remotely sensed images[J]. Field Crops Research, 2019, 235: 142–153.
- [87] 吴刚, 彭要奇, 周广奇, 等. 基于多光谱成像和卷积神经网络的玉米作物营养状况识别方法研究[J]. 智慧农业(中英)

- 文), 2020, 2(1): 111–120.
- WU Gang, PENG Yaoqi, ZHOU Guangqi, et al. Recognition method for corn nutrient based on multispectral image and convolutional neural network[J]. Smart Agriculture, 2020, 2(1): 111–120. (in Chinese)
- [88] YANG M D, TSENG H, HSU Y C, et al. Semantic segmentation using deep learning with vegetation indices for rice lodging identification in multi-date UAV visible images[J]. Remote Sensing, 2020, 12(4): 633–652.
- [89] 蒋楠, 戴建国, 薛金利, 等. 基于无人机可见光影像和卷积神经网络的棉花生长参数监测[J]. 石河子大学学报(自然科学版), 2021, 39(3): 282–288.
- JIANG Nan, DAI Jianguo, XUE Jinli, et al. Cotton growth parameter monitoring based on visible image of UAV and convolutional neural network[J]. Journal of Shihezi University (Natural Science), 2021, 39(3): 282–288. (in Chinese)
- [90] 张瑞杰, 李俐俐, 李礼, 等. 利用无人机影像数据进行油菜长势监测[J]. 测绘地理信息, 2021, 46(增刊): 227–231.
- ZHANG Ruijie, LI Lili, LI Li, et al. Rapeseed growth monitoring using UAV imagery[J]. Journal of Geomatics, 2021, 46(Supp.): 227–231. (in Chinese)
- [91] CAO J, ZHANG Z, LUO Y C, et al. Wheat yield predictions at a county and field scale with deep learning, machine learning, and google earth engine[J]. European Journal of Agronomy, 2021, 123: 126204.
- [92] STEELE-DUNNE S C, MCNAIRN H, MONSIVAIS-HUERTERO A, et al. Radar remote sensing of agricultural canopies: a review[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(5): 2249–2273.
- [93] ZHAO W Z, QU Y, CHEN J G, et al. Deeply synergistic optical and SAR time series for crop dynamic monitoring[J]. Remote Sensing of Environment, 2020, 247: 111952.
- [94] MERONI M, D'ANDRIMONT R, VRIELING A, et al. Comparing land surface phenology of major European crops as derived from SAR and multispectral data of Sentinel-1 and -2[J]. Remote Sensing of Environment, 2021, 253: 112232.
- [95] IENCO D, INTERDONATO R, GAETANO R, et al. Combining Sentinel-1 and Sentinel-2 satellite image time series for land cover mapping via a multi-source deep learning architecture[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 158: 11–22.
- [96] ZHU X L, CAI F Y, TIAN J Q, et al. Spatiotemporal fusion of multisource remote sensing data: literature survey, taxonomy, principles, applications, and future directions[J]. Remote Sensing, 2018, 10(4): 527–549.
- [97] 柳文杰, 曾永年, 张猛. 融合时间序列环境卫星数据与物候特征的水稻种植区提取[J]. 遥感学报, 2018, 22(3): 381–391.
- LIU Wenjie, ZENG Yongnian, ZHANG Meng. Mapping rice paddy distribution by using time series HJ blend data and phenological parameters[J]. Journal of Remote Sensing, 2018, 22(3): 381–391. (in Chinese)
- [98] 牛海鹏, 王占奇, 肖东洋. 基于时空数据融合的县域水稻种植面积提取[J]. 农业机械学报, 2020, 51(4): 156–163.
- NIU Haipeng, WANG Zhanqi, XIAO Dongyang. Paddy rice planting area extraction in county-level based on spatiotemporal data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4): 156–163. (in Chinese)
- [99] GAO F, ALFIERI J G, ANDERSON M C, et al. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery[J]. Remote Sensing of Environment, 2017, 188: 9–25.
- [100] ZHOU X J, WANG P X, TANSEY K, et al. Developing a fused vegetation temperature condition index for drought monitoring at field scales using Sentinel-2 and MODIS imagery[J]. Computers and Electronics in Agriculture, 2020, 168: 105144.
- [101] MENG L H, LIU H J, ZHANG X L, et al. Assessment of the effectiveness of spatiotemporal fusion of multi-source satellite images for cotton yield estimation[J]. Computers and Electronics in Agriculture, 2019, 162: 44–52.
- [102] ZHOU X J, WANG P X, TANSEY K, et al. Reconstruction of time series leaf area index for improving wheat yield estimates at field scales by fusion of Sentinel-2, -3 and MODIS imagery[J]. Computers and Electronics in Agriculture, 2020, 177: 105692.
- [103] CHU Z, YU J. An end-to-end model for rice yield prediction using deep learning fusion[J]. Computers and Electronics in Agriculture, 2020, 174: 105471.
- [104] SAGAN V, MAIMAITIJIANG M, BHADRA S, et al. Field-scale crop yield prediction using multi-temporal WorldView-3 and PlanetScope satellite data and deep learning[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 174: 265–281.
- [105] HTITIOU A, BOUDHAR A, BENABDELOUAHAB T. Deep learning-based spatiotemporal fusion approach for producing high-resolution NDVI time-series datasets[J]. Canadian Journal of Remote Sensing, 2021, 47(2): 182–197.
- [106] TAN Z Y, YUE P, DI L P, et al. Deriving high spatiotemporal remote sensing images using deep convolutional network[J]. Remote Sensing, 2018, 10(7): 1066–1081.
- [107] TAN Z Y, DI L P, ZHANG M D, et al. An enhanced deep convolutional model for spatiotemporal image fusion[J]. Remote Sensing, 2019, 11(24): 2898–2921.
- [108] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. MIT Press, 2016.
- [109] BURKE M, DRISCOLL A, LOBEL D B, et al. Using satellite imagery to understand and promote sustainable development [J]. Science, 2021, 371(6535): eabe8628.