doi:10.6041/j.issn.1000-1298.2025.05.035

基于 NDVI 时序特征的作物样本扩充与遥感精细识别

白燕英[1,2]　杨荣花[1,2]　王会永[3]　刘　辉[4]

(1.内蒙古农业大学水利与土木建筑工程学院,呼和浩特 010018;
2.内蒙古农业大学旱区水工程生态环境全国重点实验室,呼和浩特 010018;
3.内蒙古河套灌区水利发展中心供排水管理处,巴彦淖尔 015001;
4.内蒙古河套灌区水利发展中心义长分中心,巴彦淖尔 015001)

摘要:作物遥感识别精度提升是精准农业与智慧农业实现飞跃发展的关键驱动力。作物遥感识别精度取决于样本、图像特征和分类方法 3 个要素。为减小样本数据瓶颈导致的分类误差,本文通过样本数量扩充和质量控制协同提升作物遥感识别精度。以河套灌区乌兰布和灌域为研究区,构建 2023 年作物生育期 NDVI 时序图像,结合作物 NDVI 时序特征在图像上进行采样,实现作物样本数量扩充,并筛选剔除不合格样本实现样本质量控制。筛选出野外样本(扩充前样本)801 个像元,图像样本(扩充样本)17 917 个像元,总样本(扩充后样本)18 718 个像元。采用 4 种机器学习分类器开展样本扩充前后作物分类效果对比,结果表明,样本扩充后作物分类精度明显提升,分类总体精度提升约 5 个百分点,Kappa 系数提高约 0.05。其中 RF 和 NNC 分类精度较高,CART 和 SVM 分类精度略低。采用 CNN 和 LSTM 深度学习模型开展样本扩充后作物遥感识别,结果表明 CNN 和 LSTM 分类精度优于精度较高的 RF 和 NNC 分类精度。

关键词:作物分类;NDVI 时序特征;样本扩充;卷积神经网络;遥感

中图分类号:S127　　**文献标识码**:A　　**文章编号**:1000-1298(2025)05-0370-14　　**OSID**:

Crop Sample Expansion and Fine Remote-sensing Recognition Using NDVI Time-series Characteristics

BAI Yanying[1,2]　YANG Ronghua[1,2]　WANG Huiyong[3]　LIU Hui[4]

(1. *College of Water Conservation and Civil Engineering, Inner Mongolia Agricultural University, Hohhot* 010018, *China*
2. *State Key Laboratory of Water Engineering Ecology and Environment in Arid Area, Inner Mongolia Agricultural University, Hohhot* 010018, *China*
3. *Water Supply and Drainage Management Office of Inner Mongolia Hetao Irrigation District Water Conservancy Development Center, Bayannur* 015001, *China*
4. *Yichang Branch Center of Inner Mongolia Hetao Irrigation District Water Conservancy Development Center, Bayannur* 015001, *China*)

Abstract: The improvement of crop remote sensing identification accuracy is a key driving force for the leapfrog development of precision agriculture and smart agriculture. The accuracy of crop remote sensing identification depends on three elements: samples, image features and classification methods. Aiming to reduce the classification error caused by the bottleneck of sample data, the accuracy of crop remote sensing identification by jointly enhancing the sample quantity and quality control was improved. Taking the Wulanbuhe Irrigation District in the Hetao Irrigation Area as the study area, the time-series image of NDVI during the crop growth period in 2023 was constructed. Combined with the NDVI time-series characteristics of the crops, sampling was conducted on the image to expand the number of crop samples, and then the unqualified samples were screened and removed to achieve sample quality control. A total of 801 pixels of field samples (pre-expansion samples), 17 917 pixels of image samples (expanded samples), and 18 718 pixels of total samples (post-expansion samples) were selected. Four machine

收稿日期:2024-12-28　修回日期:2025-03-19

基金项目:内蒙古自治区教育厅高等学校青年科技人才发展计划项目(NJYT22045)、内蒙古自治区直属高校基本科研业务费项目(BR220103)、内蒙古自治区自然科学基金项目(2023LHMS05014)和内蒙古自治区科技重大专项(2021ZD0003)

作者简介:白燕英(1980—),女,副教授,博士,主要从事农田土壤-作物遥感监测研究,E-mail:baiyanying80@163.com

learning classifiers were used to compare the crop classification effects before and after sample expansion. The results showed that the classification accuracy of crops was significantly improved after sample expansion, with the overall classification accuracy increased by approximately 5 percentage points and the Kappa coefficient rose by about 0.05. Among them, the classification accuracy of RF and NNC was relatively high, while that of CART and SVM was slightly lower. The crop remote sensing recognition was carried out after sample expansion by using CNN and LSTM deep learning models. The results showed that the classification accuracy of CNN and LSTM was higher than that of RF and NNC, which had relatively high classification accuracy.

Key words: crop classification; NDVI time-series characteristics; sample expansion; CNN; remote-sensing

0　引言

准确掌握农作物种植面积信息至关重要,它是作物估产和国家宏观调控决策的基础[1]。遥感技术凭借覆盖范围广、重访周期短、数据易获取等优势,同时遥感数据处理与分析算法不断优化,已广泛应用于大范围农田提取和作物分类[2-3]。在云平台强大的计算能力、丰富的卫星数据资源以及耦合机器学习技术推动下[4],作物遥感识别和种植面积监测取得了长足发展,为大区域作物制图和面积测算提供了有力支撑[5]。进一步提高作物遥感识别精度,不仅能够获取更精细的作物空间分布信息,还能更有效地服务于精准农业和智慧农业,为作物长势监测、产量估算以及种植结构调整与优化等提供关键数据支撑[6]。

作物遥感识别精度取决于作物样本、图像特征和分类器 3 个核心要素,作物样本获取方式主要包括实地采集、目视解译和时空迁移[7-8]。定位系统、无人机、智能手机的快速发展,为野外实地样本快速采集提供了有力支持。图像分类特征主要包括光谱特征、植被指数和纹理特征[9]。以单时相(关键物候期)、多时相影像(关键物候期)或时间序列影像(覆盖作物生育期)为数据源,基于上述图像分类特征进行作物分类。其中,时间序列影像因充分利用作物物候信息而具有更高的分类精度[10-11]。

在众多机器学习算法中,随机森林、支持向量机、神经网络、朴素贝叶斯、分类决策树等表现出良好稳定的分类效果,其中随机森林和神经网络在特定区域和作物上分类精度更高[12-13]。近年来,越来越多的深度学习方法被应用于遥感图像分类[14-16]。其中,CNN 算法凭借其在空间数据处理方面的优势,能够有效捕捉遥感影像空间相关性、防止过拟合并自动学习多层次特征,已成为遥感图像分类的主流方法[17-18]。而 RNN 算法中的长短期记忆网络 LSTM 算法,因其门控机制能够有效捕捉时序数据中的长短期依赖关系,在基于时序遥感数据的分类任务中表现出显著优势[19]。处理植被指数时间序列数据,Landsat EVI 和 NDVI 数据[20]将时间序列特征上下文信息纳入模型,并在异质性较强的区域取得优于传统机器学习算法分类精度[21]。

高质量的训练样本对图像分类模型性能和泛化能力至关重要[22-23],充足的样本量有助于增强模型对未见数据的适应性和在多类别分类问题(尤其是不平衡数据集)中的分类精度,并有效提升对少数类别的识别性能[24]。与传统机器学习相比,深度学习模型因其参数更多,需要大量数据以避免过拟合并充分发挥其学习能力[25]。研究发现“高质量样本”对精度的影响超过了分类器的选择[26-27]。野外采样成本较高,但一定数量的实地样本对模型训练、验证和校准至关重要[28-29]。因此探索野外实地采样以外的有效采样方式,对提升作物分类精度具有重要意义。目前基于高分辨率影像(如 Google Earth)的目视解译应用较多[11,30-31]。

本文以河套灌区乌兰布和灌域为研究区,构建 2023 年作物生育期 NDVI 时序影像,结合作物物候信息,根据 NDVI 时序特征在时序 NDVI 图像上进行采样,通过样本数量扩充和质量控制协同提升作物遥感识别精度,减小样本数据瓶颈导致的分类误差。

1　研究区与数据

1.1　研究区概况

乌兰布和灌域(106°09′ ~ 107°10′E,40°08′ ~ 40°57′N)是河套灌区上游灌域,东西长 92 km,南北宽 65 km,地处乌兰布和沙漠东北端,沙丘分布广泛,属于典型的绿洲型农业区域,见图 1。研究区为典型的温带大陆型气候,冬季严寒干燥,夏季炎热短促,干旱少雨蒸发量大风沙大,日照时间长。主要粮食作物包括小麦、玉米、马铃薯等,经济作物以葵花、番茄、西葫芦、瓜类为主。

1.2　数据获取与处理

1.2.1　卫星遥感数据

选用 GEE 平台 Landsat 8/9 Collection 2 Level 2

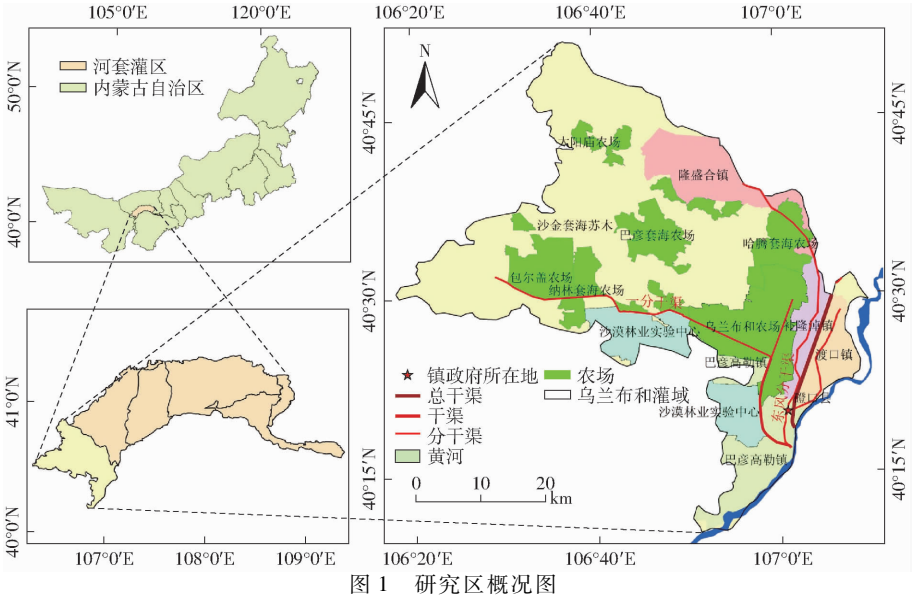

图 1 研究区概况图

Fig. 1 Overview of study area

数据集产品,该产品包括经过辐射定标和大气校正的地表反射率和地表温度,筛选云量小于 20% 的影像进行云掩膜。经过镶嵌、插补、投影等预处理,得到 2023 年 5—10 月覆盖作物生育期的 12 景高质量影像(表 1)。

表 1 时序遥感影像日期

Tab. 1 Dates of time-series remote-sensing images

月份	影像日期		
5 月	05 - 02	05 - 17 + 05 - 18	05 - 25 + 05 - 26
6 月	06 - 03	06 - 10 + 06 - 11	06 - 19 + 06 - 26
7 月	07 - 04 + 07 - 05	07 - 28 + 07 - 29	
8 月	08 - 14 + 08 - 21	08 - 29 + 08 - 30	
9 月	09 - 14 + 09 - 15		
10 月	10 - 08 + 10 - 09		

注:05 - 17 + 05 - 18 表示 5 月 17 日遥感影像有云区域用 5 月 18 日遥感影像插补。

1.2.2 野外采样数据

2023 年 7 月 6—8 日、8 月 22—24 日、10 月 10—12 日对研究区作物类型进行野外采样。采样具体步骤为:在 Landsat 8/9 遥感影像(最接近采样时间)上布设采样点,尽量在作物种植面积较大的区域布点(避免采集到混合像元),并均匀分布在整个灌域。将布好的采样点存储在智能手机 BIGEMAP 里,野外采样结合 BIGEMAP 定位找点,根据作物种植情况实时调整采样点位置,选取作物类型一致,长势均匀且面积大于 50 m × 50 m 的作物,尽量在田块的中央进行定点拍照,实时记录作物类型、物候期信息及生长状况。

研究区主要种植葵花和玉米,由于牧场较多,青储玉米和苜蓿种植面积也较大。大部分瓜类(蜜瓜、香瓜、西瓜等)与葵花套种,见图 2。野外采集样本小麦 80 个、玉米 160 个、青储玉米 63 个、葵花 167 个、番茄 49 个、西葫芦 82 个、瓜类 12 个、瓜类套种葵花 24 个、马铃薯 48 个、苜蓿 80 个和林草地 36 个,采样点空间分布见图 3。

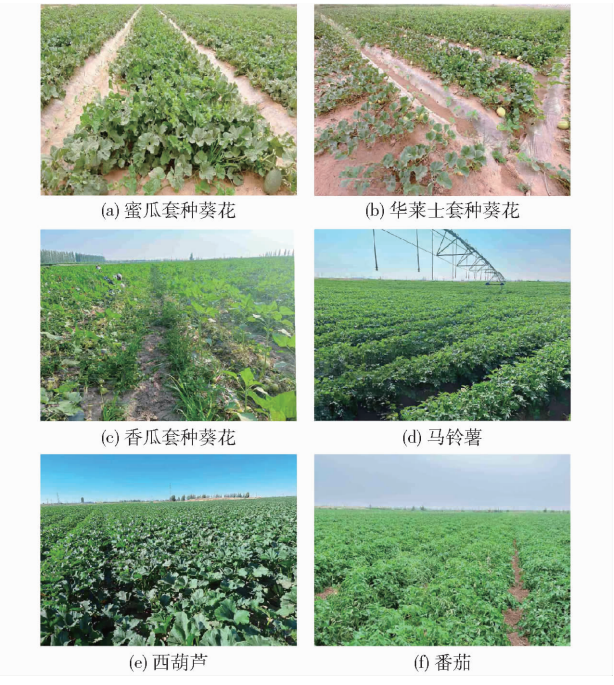

图 2 作物田间种植示意图

Fig. 2 Schematics of crop field planting

2 研究方法

将 12 景 NDVI 图像按时间顺序叠合为时序 NDVI 图像,提取所有野外采样点时序 NDVI 曲线,结合作物物候期信息(表 2),明晰每种作物 NDVI 时序变换规律。在时序 NDVI 图像上进行采样以扩充样本。筛选剔除不合格样本。开展样本扩充前后 RF、NNC、SVM、CART 4 种分类器分类结果对比,揭

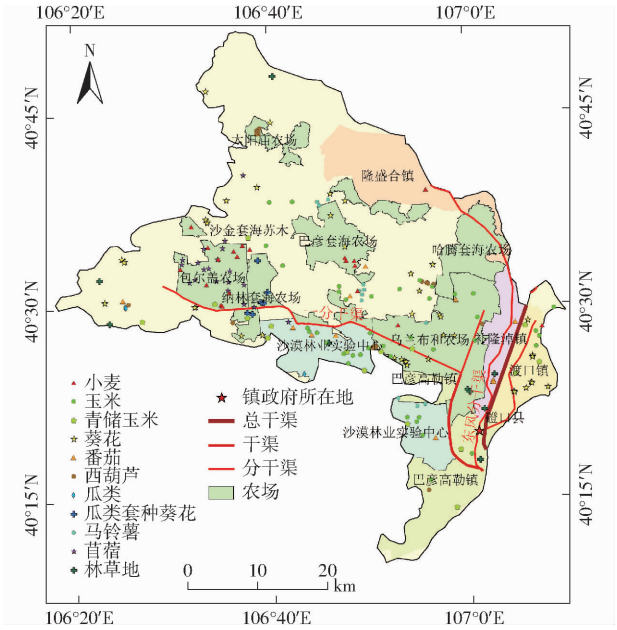

图 3　作物野外采样点分布

Fig. 3　Distribution of crop field sampling points

表 2　作物物候期

Tab. 2　Crop phonological period

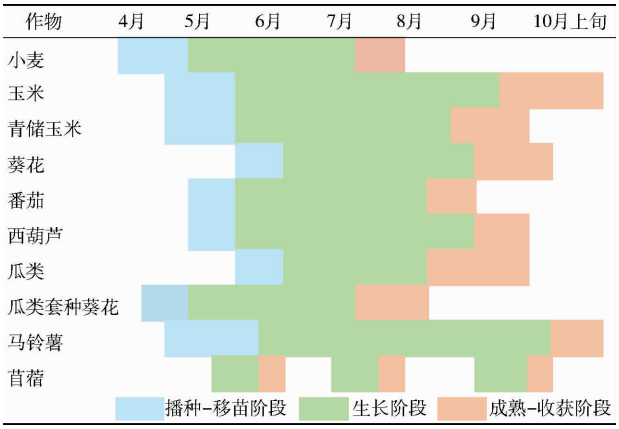

示样本数量对作物分类精度的影响。开展基于深度学习模型 CNN 和 LSTM 的作物分类，对比深度学习模型与机器学习模型分类精度。筛选最优模型，并分析基于最优模型的作物种植空间分布信息。技术流程见图 4。

2.1　作物 NDVI 时序特征

NDVI 时序特征可表征作物物候轨迹及生长节律差异，可描述同一作物在不同生育期及不同作物在同一生育期的差异。时序 NDVI 影像能充分利用作物季相节律特征清晰反映不同作物随时间的变化趋势，可以有效减少作物误分现象。

2.1.1　作物 NDVI 时序特征曲线提取

计算时序每个像元 12 个时间点的 NDVI 最大值，得到 NDVI 最大值图像以表征生育期植被覆盖茂密状态，用 0.5 作为阈值区分农田（包括部分林草地，在作物分类时考虑林草地遥感识别）和非农田。对时序 NDVI 影像的非农田区域进行掩膜处理。

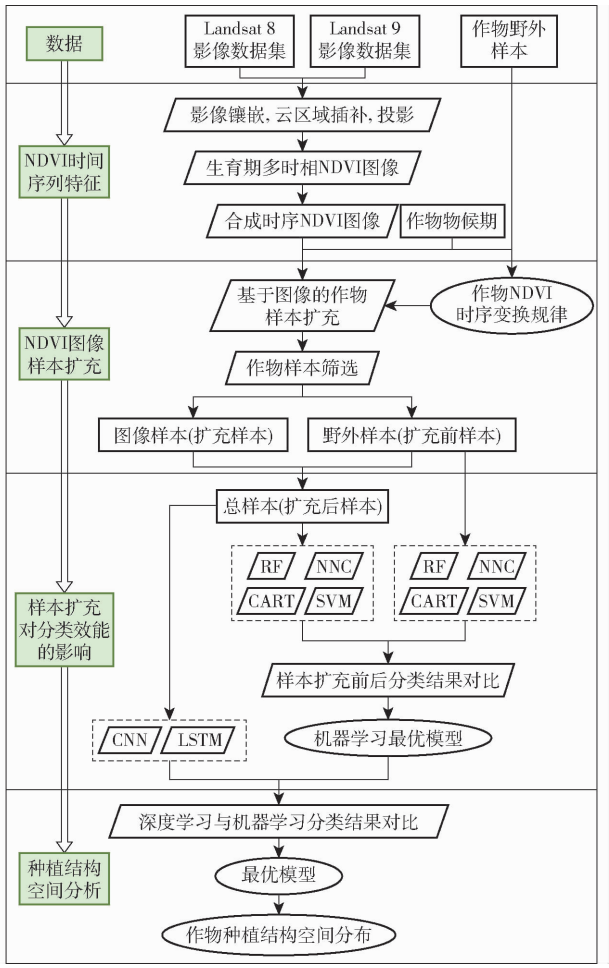

图 4　技术流程图

Fig. 4　Technical flow chart

应用 ENVI 5.6 将每种作物的野外实地采样点加载到时序 NDVI 图像上，以记事本格式导出采样点对应像元的时序 NDVI 值，应用 Excel 或 Origin 绘制每个采样点的 NDVI 时序特征曲线，结合物候信息，确定每种作物 NDVI 时序变换规律及其时序特征。

2.1.2　基于 NDVI 时序特征的作物样本扩充

依据作物关键物候期差异，凸显目标作物颜色为红色或接近红色，增强目标作物与其他作物视觉对比度，对目视理想的目标作物，逐一查看其像元 NDVI 时序曲线，对符合目标作物 NDVI 时序变换规律的像元绘制感兴趣 ROI（图 5）进行图像采样，实现对作物样本扩充。样本选取过程中特别关注作物物候期规律与 NDVI 时序曲线形态的一致性，充分保证样本质量。与野外采样的点尺度样本不同，从图像上采集的样本（绘制感兴趣区 ROI）是包含多个连续像元面文件，属于面尺度样本，包含每个像元时序 NDVI 特征信息，因此具有较强的空间代表。

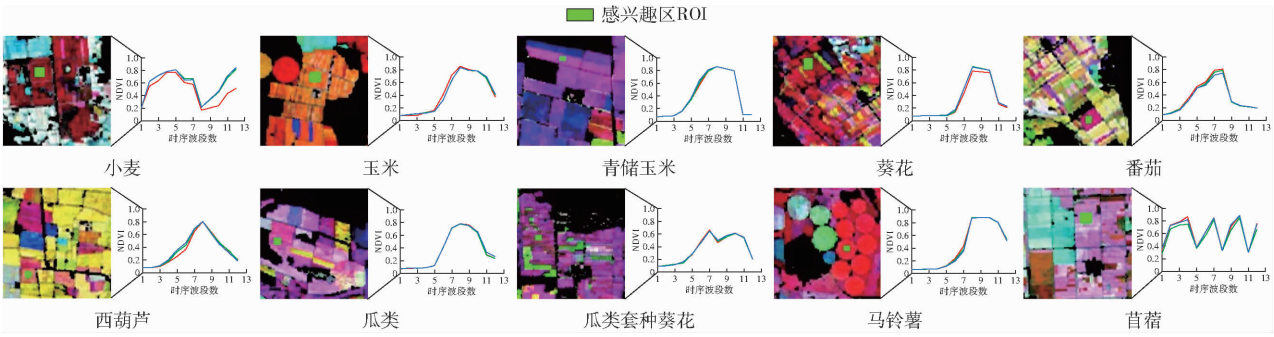

图 5 基于 NDVI 时序图像的作物样本扩充

Fig. 5 Crop sample expansion using NDVI time-series images

2.1.3 基于 NDVI 时序特征的作物样本筛选

依据每种作物物候特征和 NDVI 时序变换规律,筛选并剔除不符合要求的误选样本和混合像元样本。野外采样点属于点尺度像元,如果不符合要求可以直接剔除点;面尺度样本仅剔除不符合要求的点像元,其它像元仍保留。

筛选过程:①将每类作物样本 ROI 导出为 CSV 格式文件。②用 Excel 或 Origin 打开 CSV 文件,绘制 NDVI 时序特征曲线,初步剔除明显不符合该作物时序特征的样本;寻找其他不符合特征的样本,通过 NDVI 值排序进行筛查。③根据所有异常样本点经纬度,在 ENVI5.6 下定位到相应位置后剔除异常像元,得到合格作物样本。图 6 为小麦和番茄 20 个样本筛选前后 NDVI 时序曲线。由图 6 可知,剔除异常样本后 NDVI 时序特征曲线能更真实地刻画目标作物季相节律特征,有效提高了样本空间代表性。

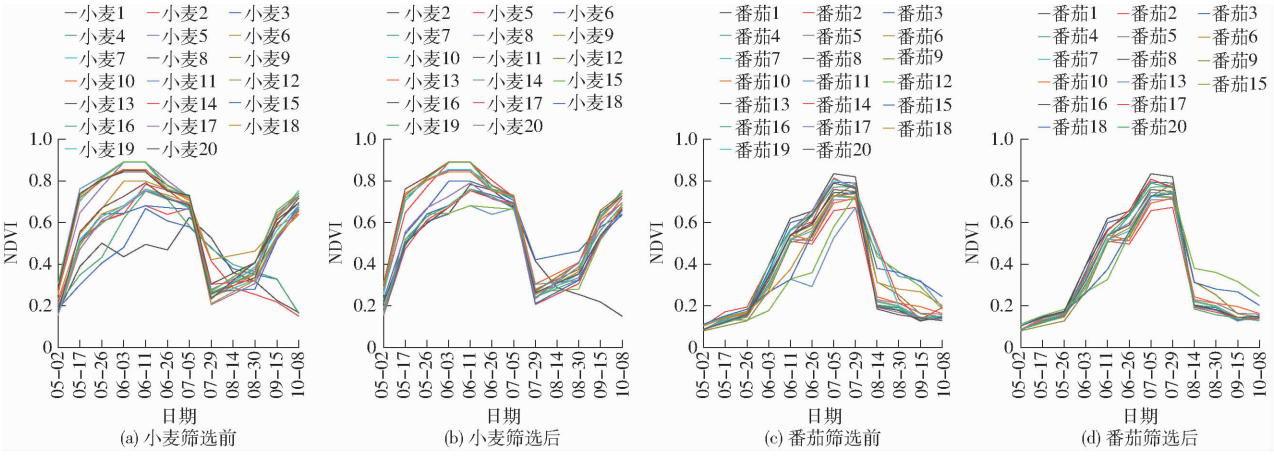

图 6 作物样本筛选前后 NDVI 时序曲线

Fig. 6 Comparison of NDVI time-series curves

筛选后作物样本数为:小麦 363 个、玉米 280 个、青储玉米 123 个、葵花 265 个、番茄 106 个、西葫芦 99 个、瓜类 30 个、瓜类套种葵花 104 个、马铃薯 107 个、苜蓿 184 个、林草地 98 个,作物图像样本空间分布见图 7。

2.2 作物分类模型

随机森林(RF)通过在训练中构建多个决策树并将投票次数最多的类别指定为最终输出。由于它是一个集成分类器,因此相比于单个决策树很少出现过拟合现象[32]。神经网络分类器 NNC 基于多层感知器架构,通过非线性激活函数学习高维光谱特征,输出像素级类别概率分布[33];CART 决策树分类通过选取一个能够最大程度提升分裂后各个子集纯度特征进行分裂,从而将数据划分为不同类别[34]。支持向量机(SVM)通过构建最优超平面,将不同类别作物数据进行分离[35]。卷积神经网络(CNN)通过卷积和池化操作自动学习图像层次化特征,从而实现图像分类。卷积层捕捉局部特征,池化层降低维度并增强鲁棒性,最终由全连接层输出分类结果[36]。长短期记忆网络 LSTM 通过引入“门控机制”来控制信息流动和记忆,解决了传统 RNN 梯度消失和梯度爆炸等问题[37]。

3 结果与分析

3.1 作物 NDVI 时序变换规律

作物 NDVI 时序特征曲线见图 8。由图 8 可知,作物 NDVI 时序差异特征较显著,NDVI 曲线时间跨度与作物生育期有关,曲线上升或下降速度与作物生长或枯萎速度有关,峰值时间跨度与作物生育高峰期持续的时间有关。作物时序特征差异为作物高

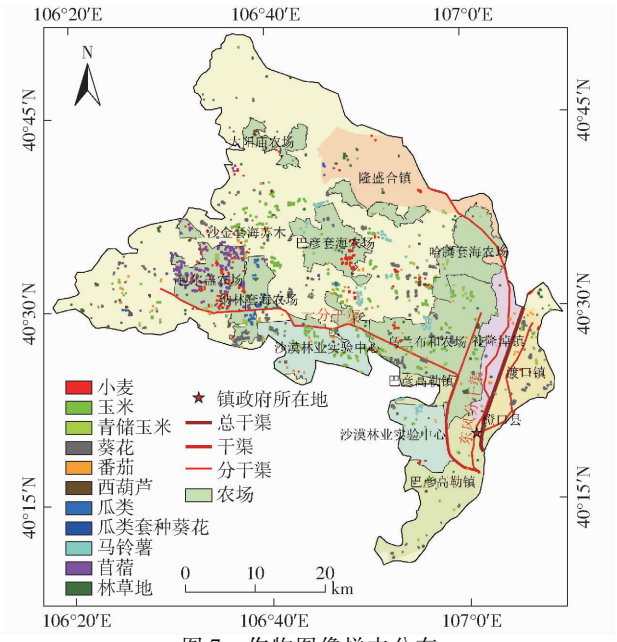

图 7　作物图像样本分布

Fig. 7　Distribution of crop image samples

精度分类提供了重要的时序判别依据，作物时序变换规律：

（1）小麦：3 月下旬播种，4 月上旬出苗后 NDVI 开始增加，6 月中旬进入作物生育高峰期-抽穗期，NDVI 达到峰值，7 月中旬成熟收割后 NDVI 迅速下降。部分小麦会在收获后复种苜蓿或燕麦，这是小麦 NDVI 曲线在 9 月又上升的原因。

（2）玉米：4 月下旬播种，5 月进入苗期，6—7 月进入快速生长期，NDVI 呈较快速度增长，7 月底 8 月初进入生育高峰期-抽雄孕穗期，NDVI 达到峰值。9 月进入乳熟期 NDVI 开始逐渐下降，9 月底开始收获。

（3）青储玉米：播种时间与普通玉米相近，但生育期较普通玉米短，仅约 4 个月，NDVI 曲线自 8 月底进入衰减期，为确保营养成分和水分含量适宜，9 月初开始收获，收获后 NDVI 呈断崖式下降，与普通玉米的 NDVI 缓降模式形成鲜明对比。

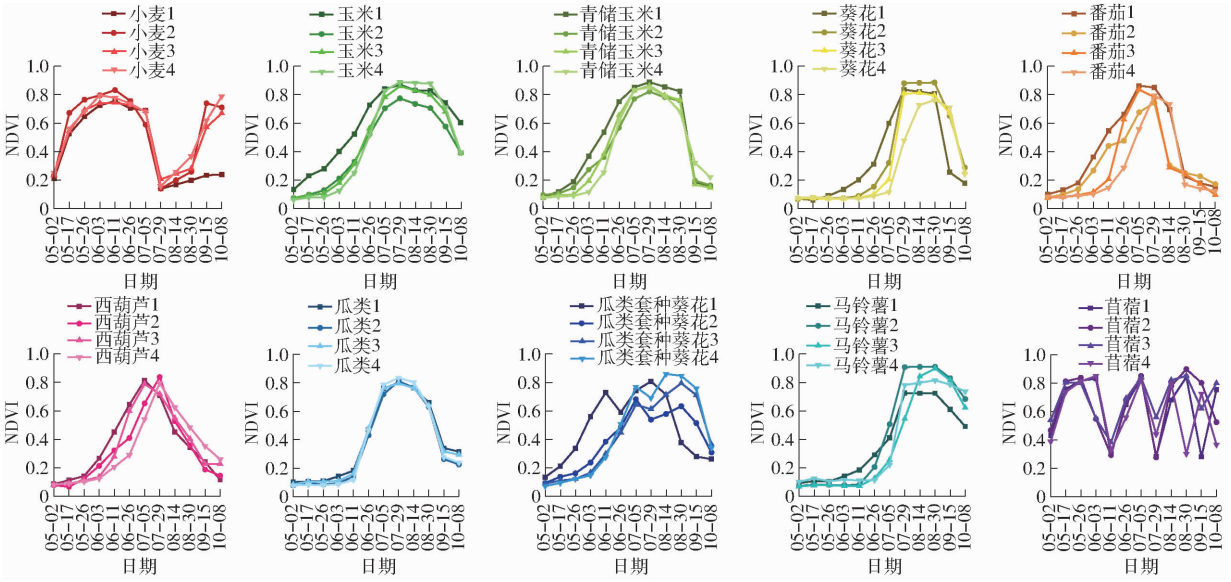

图 8　作物 NDVI 时序特征曲线

Fig. 8　Crop NDVI time-series curves

（4）葵花：5 月下旬播种，6 月进入苗期，7 月葵花进入快速生长期，NDVI 迅速攀升，7 月底进入生育高峰期-现蕾期，NDVI 达到峰值。9 月进入成熟期叶片迅速枯萎，其 NDVI 呈直线下降。葵花明显具有生长期快速上升，成熟期直线下降的时序 NDVI 特征。

（5）番茄：采用育苗移植方式，一部分番茄于 4 月中旬移苗，6—7 月生长迅速，7 月初 NDVI 值达到峰值，7 月底完成采摘，NDVI 时序曲线呈直线下降。另一部分番茄 5 月初移苗，6—7 月进入生长旺盛期，7 月底进入生育高峰期-结果期，NDVI 达到峰值，8 月中旬完成采摘。番茄为果实和秆茎叶同时机械采收，因此在 NDVI 时序曲线上表现为收获时 NDVI 呈断崖式下降。

（6）西葫芦：以籽用为主，通常 4 月底进行籽粒播种，5 月进入苗期，6 月进入快速生长期，NDVI 快速增加，早播西葫芦于 7 月初开始结果，NDVI 达到峰值，晚播西葫芦于 7 月底达到峰值。8 月生长后期，瓜蔓黄化导致 NDVI 逐渐下降，至 9 月中旬收获时叶片凋萎、瓜果裸露。西葫芦生育高峰期持续时间较短，因此其 NDVI 特征曲线呈尖峰形状。

（7）瓜类：以晚熟西瓜为主，采用单作模式。5 月中下旬播种，6 月初进入苗期，进入 6 月中旬，NDVI 快速上升，直至 7 月底开花结果达到峰值。农户通过种植晚熟西瓜实现错峰上市，通常在

8 月下旬至 9 月初采收,以满足中秋市场需求。

(8)瓜类套种葵花:瓜类(香瓜、蜜瓜、华莱士和西瓜)普遍与葵花套种,该种植方式利用二者生长周期差异,耐旱的葵花与需水量大的瓜类实现互补,可适应当地干燥气候条件。香瓜种植最早,4 月中旬移苗,苗前漫灌压碱,6 月中旬 NDVI 达到峰值,7 月初上市,套种的葵花 5 月初种植,9 月中旬收获。蜜瓜、华莱士和西瓜的物候期相近,均在 5 月初左右移苗,7 月初 NDVI 达到峰值,7 月下旬上市(7 月 28 日为磴口华莱士节),此后 NDVI 下降,套种的葵花于 5 月下旬至 6 月初播种,9 月下旬至 10 月初收获。瓜类套种葵花表现为双波峰 NDVI 曲线特征,第 1 个峰值对应瓜类生育高峰期,第 2 个峰值对应葵花生育高峰期。

(9)马铃薯:4 月下旬播种,5 月进入苗期,6 月份进入生长期,7 月初进入块茎膨大期后 NDVI 显著上升,8 月进入生育高峰期并达到峰值,9 月随着叶片枯萎 NDVI 开始下降,但在 10 月初仍维持较高水平,直至 10 月下旬收获后明显下降。马铃薯与葵花在生长初期时序特征曲线相似,9 月后马铃薯 NDVI 下降速度明显低于葵花下降速度,该特征差异为马铃薯与葵花遥感识别提供了关键时序特征。

(10)苜蓿:为多年生牧草,生长第 1 年收割 3 茬(5 月初播种,分别在 6 月初、7 月 20 日前及 10 月初收割),之后每年收割 4 茬,间隔 35 ~ 40 d,到第 7 年破根重新种植。苜蓿 NDVI 时序曲线呈“锯齿状”周期波动特征,与其他作物差异明显。苜蓿 NDVI 时序曲线随每个生长收获周期出现 1 次峰值,生长第 1 年时序曲线出现 3 个峰值,1 年后苜蓿时序曲线出现 4 个峰值。

3.2 分类结果与精度验证

3.2.1 作物样本扩充前后分类结果对比

以时序 NDVI 影像为输入影像,应用随机森林、神经网络、CART 决策树、支持向量机 4 种分类器,分别以扩充前样本(野外样本)、扩充后样本(野外样本 + 图像样本)作为训练样本进行作物遥感识别。样本扩充前图像分类选取 3/4 野外样本作为训练样本(601 个像元),以 1/4 野外样本(200 个像元)作为验证样本。样本扩充后分类图像选取 3/4 野外样本 + 3/4 图像样本作为训练样本(15 379 个像元),以 1/4 野外样本 + 1/4 图像样本作为验证样本(3 339 个像元),见表 3。

表 3 样本扩充前后数量(像元)统计

Tab. 3 Statistics of sample quantity (pixels) before and after expansion

作物	训练样本			验证样本		
	扩充前样本(野外样本)	扩充样本(图像样本)	扩充后样本(总样本)	扩充前样本(野外样本)	扩充样本(图像样本)	扩充后样本(总样本)
小麦	60(60)	267(881)	327(941)	20(20)	90(763)	110(783)
玉米	120(120)	205(4 041)	325(4 161)	40(40)	69(570)	109(610)
青储玉米	47(47)	88(1 002)	135(1 049)	16(16)	29(142)	45(158)
葵花	125(125)	180(3 390)	305(3 515)	42(42)	61(652)	102(694)
番茄	37(37)	78(426)	115(463)	12(12)	26(103)	38(115)
西葫芦	62(62)	68(426)	130(488)	20(20)	24(131)	44(151)
瓜类	9(9)	21(43)	30(52)	3(3)	8(10)	11(13)
瓜类套种葵花	18(18)	73(379)	91(397)	6(6)	25(80)	31(86)
马铃薯	36(36)	79(893)	115(929)	12(12)	27(223)	39(235)
苜蓿	60(60)	130(2 600)	190(2 660)	20(20)	44(329)	64(349)
林草地	27(27)	68(697)	95(724)	9(9)	24(136)	33(145)
合计	601(601)	1 886(14 778)	2 487(15 379)	200(200)	522(3 139)	722(3 339)

样本扩充前后分类图像混淆矩阵见图 9,分类精度对比结果见表 4,无论扩充前样本还是扩充后样本,RF、NNC、CART 和 SVM 4 种分类器中 RF 和 NNC 分类精度最高且基本接近,SVM 和 CART 分类精度略低。在验证样本也扩充的情况下,样本扩充后图像分类精度仍有明显提升,总体精度提升约 5 个百分点,Kappa 系数提升约 0.05。总体精度提升到 89.57% ~ 93.02%,Kappa 系数提升到 0.877 ~ 0.917。其中 RF 和 NNC 分类精度较高,Kappa 系数达到 0.912 和 0.917。分类精度略低的 CART 和 SVM 的 Kappa 系数也达到 0.895 和 0.877。说明样本扩充后机器学习分类能明显提升分类精度。

3.2.2 基于机器学习和深度学习的作物分类对比

基于扩充后样本,以时序 NDVI 图像为输入影像,分别应用卷积神经网络 CNN 和长短期记忆网络 LSTM 深度学习模型进行作物分类,并与基于扩充后样本机器学习分类中精度较高的 RF、NNC 分类结果进行对比分析。基于上述 4 种分类方法的作物分类结果见图 10,分类结果局部区域细部见图 11,对分类图像进行精度验证的混淆矩阵见图 12。

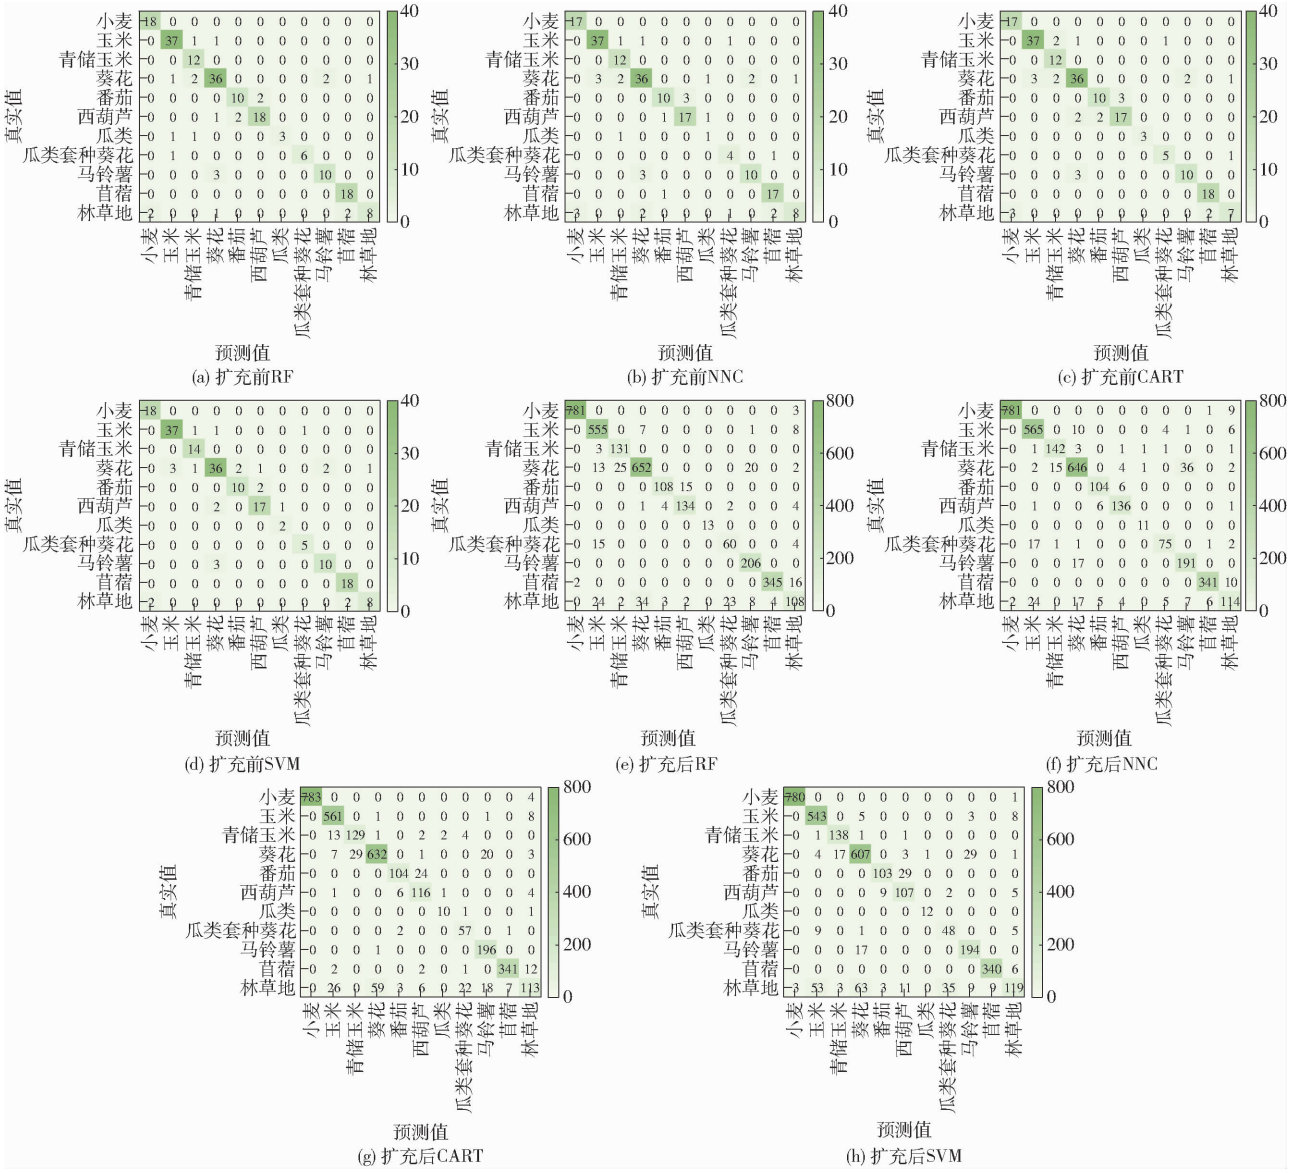

图 9　样本扩充前后分类图像混淆矩阵对比

Fig. 9　Comparison of confusion matrices before and after sample expansion

表 4　样本扩充前后分类图像精度对比

Tab. 4　Comparison of classification image accuracy before and after sample expansion

作物	RF				NNC				CART				SVM			
	扩充前		扩充后		扩充前		扩充后		扩充前		扩充后		扩充前		扩充后	
	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%
小麦	100	90.00	99.62	99.74	100	90.00	98.74	99.74	100	85.00	99.49	100	100	85.00	99.87	99.62
玉米	92.50	92.50	97.20	90.98	94.87	92.50	96.42	92.62	92.50	92.5	98.25	91.97	90.24	92.5	97.14	89.02
青储玉米	100	87.50	97.76	82.91	100	75.00	94.67	89.87	100	75.00	85.43	81.65	100	75.00	97.87	87.34
葵花	78.26	85.71	91.57	93.95	85.71	85.71	91.50	93.08	80.00	85.71	91.33	91.07	81.82	85.71	91.69	87.46
番茄	83.33	83.33	87.80	93.91	83.33	83.33	94.55	90.43	76.92	83.33	81.25	90.43	76.92	83.33	78.03	89.57
西葫芦	85.00	85.00	92.41	88.74	85.71	90.00	94.44	90.07	89.47	85.00	90.63	76.82	80.95	85.00	86.99	70.86
瓜类	100	66.67	100	100	60.00	100	100	84.62	50.00	33.33	83.33	76.92	100	100	100	92.31
瓜类套种葵花	100	83.33	75.95	69.77	85.71	100	77.32	87.21	80.00	66.67	95.00	66.28	83.33	83.33	76.19	55.81
马铃薯	76.92	83.33	100	87.66	76.92	83.33	91.83	81.28	76.92	83.33	99.49	83.40	76.92	83.33	91.94	82.55
苜蓿	100	90.00	95.04	98.85	100	90.00	97.15	97.71	94.44	85.00	95.29	97.71	100	90.00	98.27	97.42
林草地	66.67	88.89	51.92	74.48	61.54	88.89	61.96	78.62	50.00	88.89	44.49	77.93	58.33	77.78	38.64	82.07
总体精度/%	87.50		92.63		88.00		93.02		84.50		91.10		86.00		89.57	
Kappa 系数	0.856		0.912		0.862		0.917		0.822		0.895		0.839		0.877	

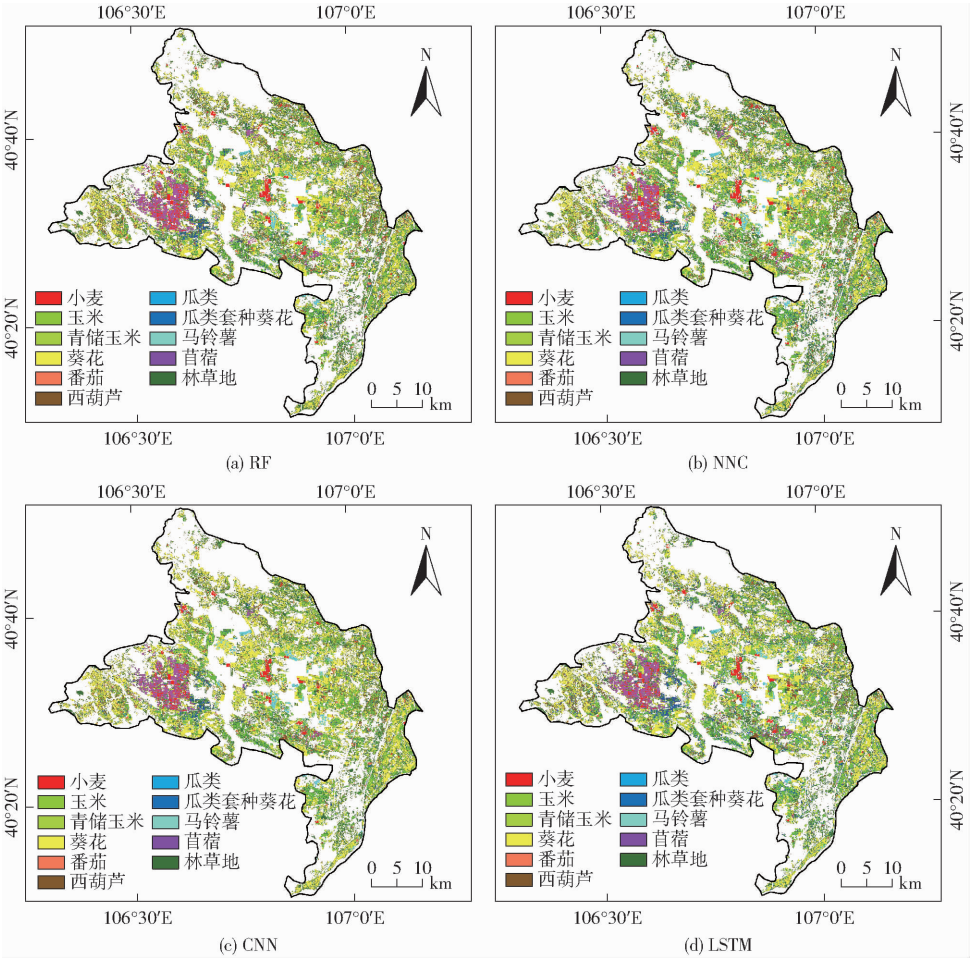

图 10 作物分类图

Fig. 10 Crop classification diagrams

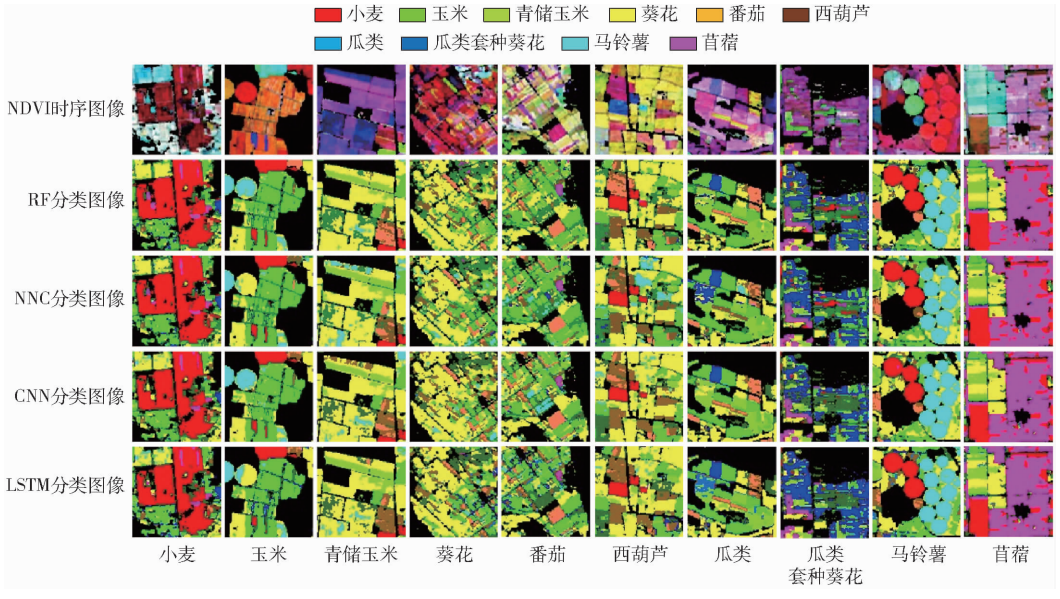

图 11 作物分类局部区域细部图

Fig. 11 Detailed map of crop classification for local areas

由图 12 可知 3 339 个验证样本在 RF、NNC、CNN 和 LSTM 分类图像上分别有 3 093、3 106、3 154、3 140 个像元被正确识别。分类结果验证精度见表 5,CNN 和 LSTM 分类图像总体精度分别为 94.46%、94.04%,Kappa 系数分别为 0.934、0.929,可见其分类精度优于机器学习模型 RF 和 NNC。其中 CNN 分类精度又略高于 LSTM,因此 CNN 模型为本文样本扩充后的最优作物分类模型。

CNN 模型对作物分类精度由高到低依次为小麦(100%)、苜蓿(100%)、玉米(97.44%)、马铃薯

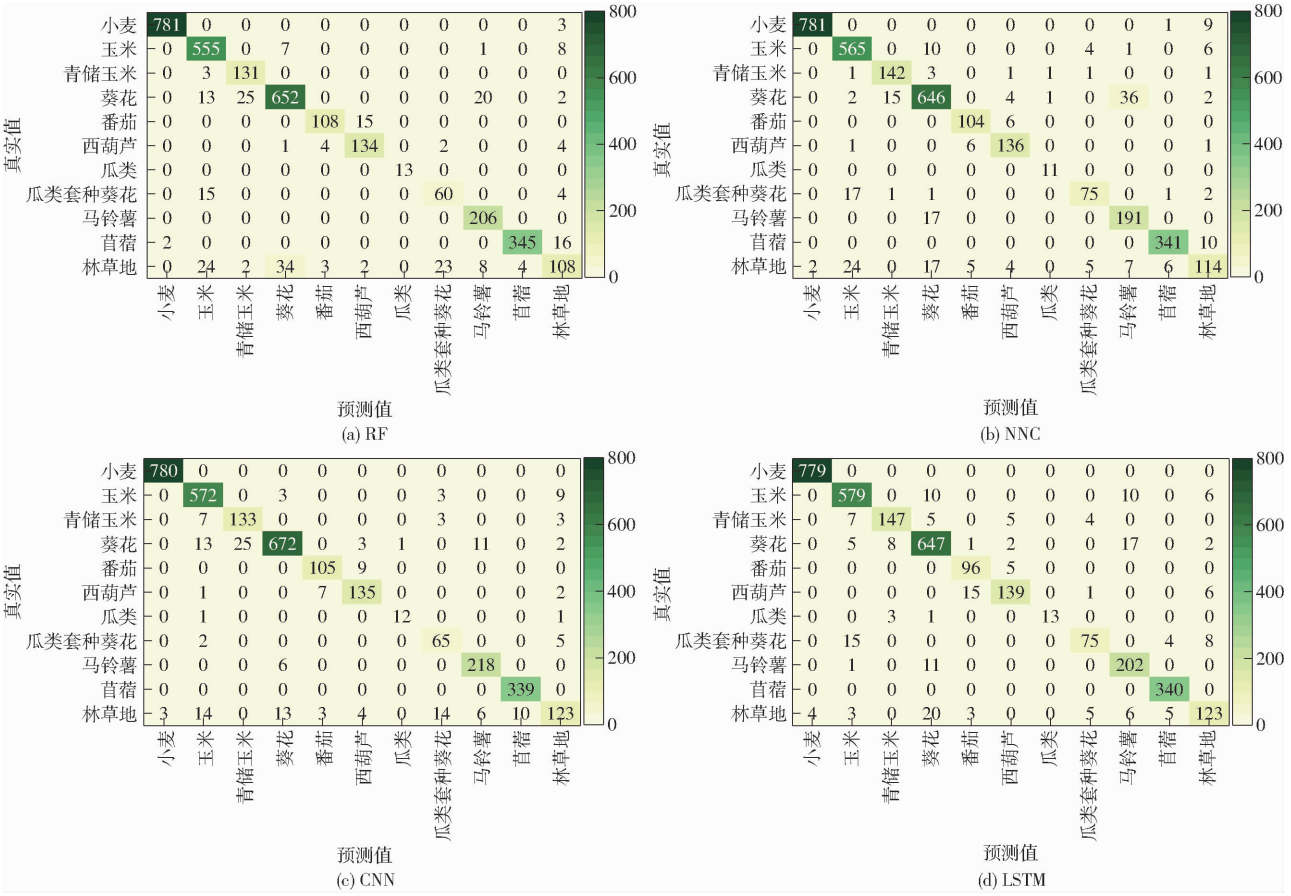

图 12　分类图像混淆矩阵

Fig. 12　Confusion matrices of classified images

表 5　基于机器学习和深度学习的图像分类精度

Tab. 5　Image classification accuracy based on machine learning and deep learning

作物	机器学习				深度学习			
	RF		NNC		CNN		LSTM	
	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%
小麦	99.62	99.74	98.74	99.74	100	99.62	100	99.49
玉米	97.20	90.98	96.42	92.62	97.44	93.77	95.70	94.92
青储玉米	97.76	82.91	94.67	89.87	91.10	84.18	87.50	93.04
葵花	91.57	93.95	91.50	93.08	92.43	96.83	94.87	93.23
番茄	87.8	93.91	94.55	90.43	92.11	91.30	95.05	83.48
西葫芦	92.41	88.74	94.44	90.07	93.10	89.40	86.34	92.05
瓜类	100	100	100	84.62	85.71	92.31	76.47	100
瓜类套种葵花	75.95	69.77	77.32	87.21	90.28	75.58	73.53	87.21
马铃薯	100	87.66	91.83	81.28	97.32	92.77	94.39	85.96
苜蓿	95.04	98.85	97.15	97.71	100	97.13	100	97.42
林草地	51.92	74.48	61.96	78.62	64.74	84.83	72.78	84.83
总体精度/%	92.63		93.02		94.46		94.04	
Kappa 系数	0.912		0.917		0.934		0.929	

(97.32%)、西葫芦(93.10%)、葵花(92.43%)、番茄(92.11%)、青储玉米(91.10%)、瓜类套种葵花(90.28%)、瓜类(85.71%)、林草地(64.74%)。青储玉米、马铃薯和葵花 3 种作物时序 NDVI 特征曲线接近,这 3 种作物易混淆。尤其是马铃薯和葵花物候期接近,生长过程也相似,尤其在 9 月前基本一致,因此容易误分。瓜类套种葵花与部分林地时序 NDVI 特征接近,容易被误分为林草地;田块周边作物与田埂杂草组成的混合像元 NDVI 时序特征随杂草占比增加会逐渐趋近杂草的 NDVI 时序特征,这是作物与林草地误分的主要原因。

3.3　基于 CNN 模型的作物空间分布

基于最优模型 CNN 的作物空间分布见图 13,种植面积见表 6。乌兰布和灌域葵花种植面积最大,达到 37 031.85 hm^2,占农田总面积的 46.27%;其次为玉米种植面积,达到 18 054.27 hm^2,占农田

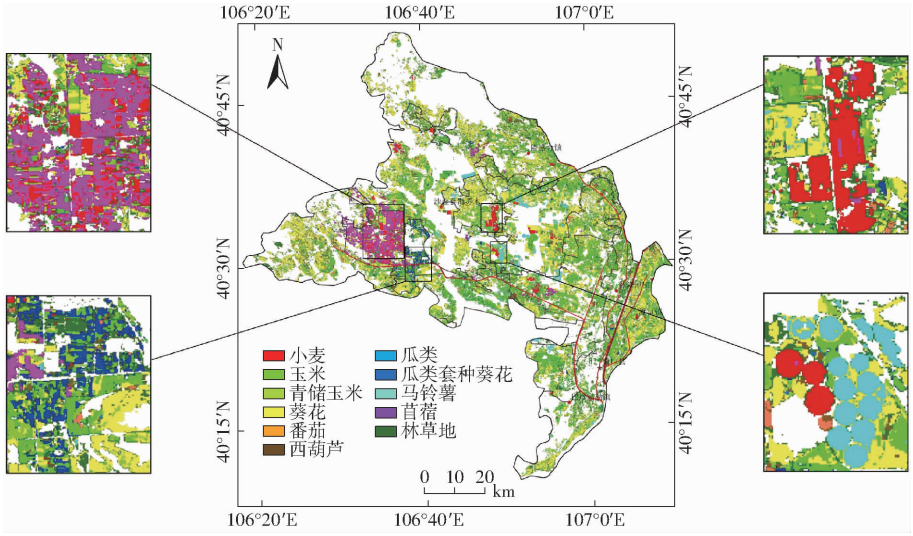

图 13 基于 CNN 模型的作物空间分布图

Fig. 13 Crop spatial distribution map using CNN model

表 6 基于 CNN 模型的作物分类面积

Tab. 6 Crop classification area using CNN model

作物	小麦	玉米	青储玉米	葵花	番茄	西葫芦	瓜类	瓜类套种葵花	马铃薯	苜蓿	合计
面积/hm^2	2 735. 46	18 054. 27	6 976. 80	37 031. 85	1 398. 60	4 715. 55	580. 50	1 786. 95	2 466. 27	4 290. 93	80 037. 18
占比/%	3. 42	22. 56	8. 71	46. 27	1. 75	5. 89	0. 73	2. 23	3. 08	5. 36	100. 00

22. 56%；青储玉米面积 6 976. 8 hm^2，占比 8. 71%；苜蓿面积 4 290. 93 hm^2，占比 5. 36%；西葫芦面积 4 715. 55 hm^2，占比 5. 89%；小麦面积 2 735. 46 hm^2，占比 3. 42%；瓜类种植以瓜类套种葵花为主，面积 1 786. 95 hm^2，瓜类单种面积较小，仅为 580. 5 hm^2。马铃薯、番茄面积分别为 2 466. 27、1 398. 6 hm^2。

作物主要分布在总干渠两侧的渡口镇、补隆淖镇和乌兰布和农场、哈腾套海农场、包尔盖农场、纳林套海农场、巴彦套海农场、太阳庙农场等。葵花耐旱耐盐碱，能适应乌兰布和灌域干旱的气候条件和盐碱化、沙化土壤，因此种植面积最大，玉米种植面积其次。近几年小麦种植面积呈逐年增加趋势，主要分布在包尔盖农场和巴彦套海农场。养殖业发展迅速，牧场较多，作为饲料作物的青储玉米和苜蓿种植广泛。苜蓿主要集中于已形成产业化种植模式的包尔盖农场，青储玉米主要分布在渡口镇和哈腾套海农场及周边。西葫芦以籽用为主，主要用于加工籽粒等产品，小部分作为蔬菜供应市场，在渡口镇、哈腾套海农场、乌兰布和农场和太阳庙农场均有零星分布。瓜类作为特色作物，种植形式以瓜类套种葵花为主，主要分布于纳林套海农场，该农场土壤肥沃，适宜甜瓜生长，且已建成万亩纳林甜瓜无公害农产品示范基地，形成规模化种植。近些年滴灌推广和沙区开垦种植为灌域马铃薯种植发展开辟了新途径。马铃薯喜好沙性土壤，主要种植于巴彦套海农场周边新开垦的沙地上，大型时针式喷灌能高效满足大规模种植的灌溉需求，形成了特色鲜明的沙漠马铃薯种植产业。番茄主要分布在渡口镇、哈腾套海农场和乌兰布和农场，由于当地日照时间长，番茄糖分含量高，品质好，主要供番茄生产企业深加工。作物种植结构空间分布印证了研究区“耐旱作物主导、饲草作物支撑、特色作物补充”的种植格局，该遥感分类结果可为乌兰布和灌域种植结构优化调整、农业决策管理提供重要数据支撑。

4 讨论

4.1 作物样本扩充对分类精度的影响

研究表明样本扩充后分类图像在验证样本也扩充的情况下，机器学习分类精度仍都有明显提升，总体精度提升约 5 个百分点，Kappa 系数提升约 0. 05。说明基于大量扩充样本机器分类方法能明显提升作物分类精度，有效减少作物误分现象。大量样本扩充也满足了应用深度学习模型进行分类的条件，深度学习模型 CNN 和 LSTM 的分类精度优于机器学习 RF 和 NNC 分类精度。

研究表明基于 NDVI 时序特征的图像采样高效准确，既能有效扩充样本数量也能有效控制样本质量，为作物图像采样探索了新方法，为满足深度学习模型需要获取大量样本提供了有效途径。拥有大量优质样本基础上，机器学习算法也都能实现精度理想的作物分类结果，适宜的分类器更有助于分类精度提升。深度学习模型分类精度优于机器学习分类

精度。研究发现高质量样本对精度影响超过了分类器的选择[27]，与该结论一致。

4.2　时序 NDVI 图像识别作物的适用性和时效性

同一年份不同区域或同一区域不同年份可能获取的遥感影像时间序列都不尽相同，因此同一作物在不同区域或不同年份的时间序列 NDVI 图像上表现的时序 NDVI 特征曲线也有差异，但 NDVI 时序特征描述的同一种作物总体趋势总是一致的。河套灌区乌兰布和灌域位于北纬 40°～41°之间，大部分时间天气晴朗，云雨天气少，容易获得优质的遥感影像，但是夏季 7—8 月正值作物生育高峰期，也进入北方雨季，此时的遥感影像多受云雨天气影响。因此 7—8 月获取的图像至关重用，高质量图像越多，NDVI 时序特征就能更细致地刻画作物生长关键期；反之描述的作物生长过程就较为粗略。因此基于时序 NDVI 图像的作物遥感识别适用条件为：获取的时序遥感影像能覆盖作物生育期，而且至少有 2～3 景能捕获 7—8 月作物生育关键期，每种作物的时序 NDVI 曲线能清晰描述作物生长过程，不同作物间有明显的 NDVI 时序特征差异。

时效性在作物遥感识别中至关重要，对作物种植结构进行及时、实时、快速监测与预测对农业管理与决策具有重要意义。基于 NDVI 时序特征的作物遥感识别需要获取作物完整生育期的遥感影像构建时序 NDVI 图像，就意味着在每年 9 月底 10 月初大部分作物收获后才能进行遥感识别，时效性相对较低。为了提高作物遥感识别时效性，未来需尽可能缩短时间序列，将作物完整生育期（播种到收获）时间序列尽可能缩短到播种到生育高峰期或播种到拔节期，通过关键物候期优化算法筛选最佳识别时间窗口[38]，尽可能将作物遥感识别时间提前，提升遥感制图的时效性。

5　结论

（1）基于野外采样数据和物候特征信息，确定了小麦、玉米、青储玉米、葵花、马铃薯、西葫芦、番茄、瓜类、瓜类套种葵花、苜蓿 10 种作物的 NDVI 时序特征变换规律，为基于时序 NDVI 图像作物样本扩充提供参考依据。

（2）基于时序 NDVI 图像对符合作物 NDVI 时序变换特征的作物像元绘制感兴趣进行采样，并筛选剔除不符合作物 NDVI 时序特征的混合像元和误选样本。筛选出扩充前样本（野外样本）801 个像元，扩充样本（图像样本）17 917 个像元，扩充后样本（总样本）18 718 个像元。

（3）样本扩充前后 4 种分类器中 RF 和 NNC 分类精度较高，SVM 和 CART 分类精度略低。样本扩充后 4 种机器学习分类精度都有明显提升，总体精度提升约 5 个百分点，Kappa 系数提升约 0.05。分类精度较高的 RF 和 NNC 的 Kappa 系数分别为 0.912 和 0.917，分类精度略低的 CART 和 SVM 的 Kappa 系数也达到 0.895 和 0.877。深度学习模型 CNN 和 LSTM 分类精度优于机器学习模型 RF 和 NNC，其中深度学习模型 CNN 分类精度又略高于 LSTM，因此 CNN 模型为样本扩充后的最优作物分类模型。

（4）葵花和马铃薯生育期基本一致，因此二者 NDVI 时序特征相似，尤其 9 月前基本接近，9 月后葵花 NDVI 下降速度比马铃薯快，该特征成为识别葵花和马铃薯的关键特征。葵花和马铃薯相似的 NDVI 时序特征，是二者相互误分的主要原因。

参　考　文　献

[1] 赵龙才，李粉玲，常庆瑞. 农作物遥感识别与单产估算研究综述[J]. 农业机械学报，2023，54(2)：1－19.
ZHAO Longcai, LI Fenling, CHANG Qingrui. Review on crop type identification and yield forecasting using remote sensing [J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(2)：1－19. (in Chinese)

[2] ZHANG Kaixin, YUAN Da, YANG Huijin, et al. Synergy of Sentinel－1 and Sentinel－2 imagery for crop classification based on DC－CNN[J]. Remote Sensing，2023，15(11)：2727.

[3] 付东杰，肖寒，苏奋振，等. 遥感云计算平台发展及地球科学应用[J]. 遥感学报，2021，25(1)：220－230.
FU Dongjie, XIAO Han, SU Fenzhen, et al. Remote sensing cloud computing platform development and earth science application[J]. National Remote Sensing Bulletin, 2021，25(1)：220－230. (in Chinese)

[4] GORELICK N, HANCHER M, DIXON M, et al. Google Earth Engine：planetary-scale geospatial analysis for everyone[J]. Remote Sensing of Environment，2017，202：18－27.

[5] 谢炎，曾红伟，田富有，等. 作物遥感分类的样本依赖与模型空间外推研究[J]. 遥感学报，2024，28(11)：2878－2895.
XIE Yan, ZENG Hongwei, TIAN Fuyou, et al. A study of sample dependence and spatial extrapolation of models for crop remote sensing classification[J]. National Remote Sensing Bulletin, 2024，28(11)：2878－2895. (in Chinese)

[6] 刘哲，刘帝佑，朱德海，等. 作物遥感精细识别与自动制图研究进展与展望[J]. 农业机械学报，2018，49(12)：1－12.
LIU Zhe, LIU Diyou, ZHU Dehai, et al. Review on crop type fine identification and automatic mapping using remote sensing [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018，49(12)：1－12. (in Chinese)

[7] 薛宇飞,张声晗,白娜娜,等. 耦合 Sentinel-1/2 多源时序遥感影像特征的红树林物种分类方法[J]. 地球信息科学学报,2024,26(11):2626-2642.
XUE Yufei, ZHANG Shenghan, BAI Na'na, et al. Classification of mangrove species using coupled Sentinel-1/2 multi-source time-series remote sensing image features[J]. Journal of Geo-information Science, 2024,26(11): 2626-2642. (in Chinese)
[8] 冯权泷,陈泊安,李国庆,等. 遥感影像样本数据集研究综述[J]. 遥感学报,2022,26(4):589-605.
FENG Quanlong, CHEN Boan, LI Guoqing, et al. A review for sample datasets of remote sensing imagery[J]. National Remote Sensing Bulletin, 2022,26(4):589-605. (in Chinese)
[9] XUAN F, DONG Y, LI J, et al. Mapping crop type in Northeast China during 2013—2021 using automatic sampling and tile-based image classification[J]. International Journal of Applied Earth Observation and Geoinformation,2023,117:103178.
[10] 甄彤,张威振,李智慧. 遥感影像中种植作物结构分类方法综述[J]. 计算机工程与应用,2024,12(9):1-15.
ZHEN Tong, ZHANG Weizhen, LI Zhihui. A review of classification methods for crop structure in remote sensing imagery[J]. Computer Engineering and Applications, 2024,12(9):1-15. (in Chinese)
[11] 牛乾坤,刘浏,黄冠华,等. 基于 GEE 和机器学习的河套灌区复杂种植结构识别[J]. 农业工程学报,2022,38(6):165-174.
NIU Qiankun, LIU Liu, HUANG Guanhua, et al. Extraction of complex crop structure in the Hetao Irrigation District of Inner Mongolia using GEE and machine learning[J]. Transactions of the CSAE,2022,38(6):165-174. (in Chinese)
[12] 张敬晓,蔡甲冰,许迪,等. 灌区种植结构反演优化与土壤盐分空间分布协同解析[J]. 农业机械学报,2023,54(6):373-385.
ZHANG Jingxiao, CAI Jiabing, XU Di, et al. Optimization of crop patterns inversion and collaborative analysis with soil salinity spatial distribution in large irrigation district[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(6):373-385. (in Chinese)
[13] MURTHY S C, RAJU V P, BADRINATH S V K. Classification of wheat crop with multi-temporal images: performance of maximum likelihood and artificial neural networks[J]. International Journal of Remote Sensing,2003,24(23):4871-4890.
[14] 解毅,张永清,荀兰,等. 基于多源遥感数据融合和 LSTM 算法的作物分类研究[J]. 农业工程学报,2019,35(15):129-137.
XIE Yi, ZHANG Yongqing, XUN Lan, et al. Crop classification based on multi-source remote sensing data fusion and LSTM algorithm[J]. Transactions of the CSAE, 2019,35(15):129-137. (in Chinese)
[15] 靳宁,孙林,张东彦,等. 基于 CBAM-U-HRNet 模型和 Sentinel-2 数据的棉花种植地块提取[J]. 农业机械学报,2023,54(11):159-168.
JIN Ning, SUN Lin, ZHANG Dongyan, et al. Classification of cotton planting area using CBAM-U-HRNet model and Sentinel-2 data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(11):159-168. (in Chinese)
[16] LI Heping, LU Jing, TIAN Guixiang, et al. Crop classification based on GDSSM-CNN using multi-temporal RADARSAT-2 SAR with limited labeled data[J]. Remote Sensing,2022,14(16):3889.
[17] KAVITA B, VIJAYA M. Evaluation of CNN model by comparing with convolutional autoencoder and deep neural network for crop classification on hyperspectral imagery[J]. Geocarto International,2020,37(3):1-15.
[18] PAPADOPOULOU E, MALLINIS G, SIACHALOU S, et al. Agricultural land cover mapping through two deep learning models in the framework of EU's CAP activities using Sentinel-2 multitemporal imagery[J]. Remote Sensing,2023,15(19):4657.
[19] 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)
[20] ZHONG Liheng, HU Lina, ZHOU Hang. Deep learning based multi-temporal crop classification[J]. Remote Sensing of Environment,2019,221:430-443.
[21] OSOULI M, SAMAVATI FF. Evaluation of data sufficiency for interannual knowledge transfer of crop type classification models [J]. Remote Sensing,2024,16(11):2426.
[22] 谷鹤,尚坤,秦爱羚,等. 地块尺度下基于多源卫星遥感数据的粮食作物识别[J]. 农业工程学报,2022,38(16):33-41.
GU He, SHANG Kun, QIN Ailing, et al. Identification of grain crop using multi-source satellite remote sensing data at field parcel scale[J]. Transactions of the CSAE,2022,38(16):33-41. (in Chinese)
[23] 陈洪,王亚昆,姚一飞,等. 基于光谱和纹理信息空间尺度优化的夏玉米冠层 EWT 反演模型[J]. 农业机械学报,2024,55(12):257-267.
CHEN Hong, WANG Yakun, YAO Yifei, et al. EWT inversion model of summer maize based on spatial scale optimization of spectral and texture information[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(12):257-267. (in Chinese)
[24] RAJDEEP B, RAJONYA D, ANURAN C, et al. Clustering based undersampling for effective learning from imbalanced data: an iterative approach[J]. SN Computer Science,2024,5(4):386.
[25] 高心怡,池泓,黄进良,等. 水稻遥感制图研究综述[J]. 遥感学报,2024,28(9):2144-2169.
GAO Xinyi, CHI Hong, HUANG Jinliang, et al. Review of paddy rice mapping with remote sensing technology[J]. National Remote Sensing Bulletin, 2024,28(9):2144-2169. (in Chinese)
[26] 刘晓亮,王志华,杨晓梅,等. 面向自然场景土地覆被分类的遥感物候模式分区[J]. 地理学报,2024,79(9):2206-2229.

LIU Xiaoliang, WANG Zhihua, YANG Xiaomei, et al. Remotely-sensed phenology pattern regionalization for land cover classification of natural scenes: a case study in China[J]. Acta Geographica Sinica, 2024,79(9):2206 - 2229. (in Chinese)

[27] 樊东东,李强子,王红岩,等.通过训练样本采样处理改善小宗作物遥感识别精度[J].遥感学报,2019,23(4):730 - 742.
FAN Dongdong, LI Qiangzi, WANG Hongyan, et al. Improvement in recognition accuracy of minority crops by resampling of imbalanced training datasets of remote sensing[J]. National Remote Sensing Bulletin, 2019,23(4):730 - 742. (in Chinese)

[28] 常婉秋,姚宇,席晓杰,等.基于迁移学习和非监督分类的制种玉米遥感识别方法[J].农业机械学报,2024,55(8):181 - 195.
CHANG Wanqiu, YAO Yu, XI Xiaojie, et al. Remote sensing identification for seed maize with integrated migration learning and unsupervised classification[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(8):181 - 195. (in Chinese)

[29] 许淇.基于随机森林算法的遥感分类方法优化研究[D]. 太原:山西农业大学,2019.
XU Qi. Research on optimization of remote sensing classification method based on random forest algorithm[D]. Taiyuan: Shanxi Agricultural University,2019. (in Chinese)

[30] 周俊伟,冯浩,董勤各.基于不同时间尺度与特征优选的黄淮海平原冬小麦识别[J].农业机械学报,2024,55(9):262 - 274.
ZHOU Junwei, FENG Hao, DONG Qin'ge. Identification of winter wheat in Huang - Huai - Hai Plain based on different time scales and feature preference[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(9):262 - 274. (in Chinese)

[31] 解毅,王佳楠,刘钰.基于 Sentinel - 1/2 数据特征优选的冬小麦种植区识别方法研究[J].农业机械学报,2024,55(2):231 - 241.
XIE Yi, WANG Jia'nan, LIU Yu. Research on winter wheat planting area identification method based on Sentinel - 1/2 data feature optimization[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(2):231 - 241. (in Chinese)

[32] 吴喜芳,化仕浩,张莎,等.基于多物候特征指数相关性迁移的冬小麦多年份分布信息识别[J].农业机械学报,2024,55(12):268 - 277,353.
WU Xifang, HUA Shihao, ZHANG Sha, et al. Identification of multi-year distribution information of winter wheat based on the correlation transfer of multi-phenological feature indices[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(12):268 - 277,353. (in Chinese)

[33] 赵静.基于 BP 人工神经网络的遥感影像土地覆盖分类研究[D]. 北京:中国地质大学,2010.
ZHAO Jing. A remote sensing study of land cover classification based on BP artificial neural network[D]. Beijing: China University of Geosciences,2010. (in Chinese)

[34] 刘惠楠,王井利,周斌,等.基于 MODIS 时序数据物候特征下的多源遥感玉米提取[J].江西农业学报,2023,35(4):113 - 121.
LIU Huinan, WANG Jingli, ZHOU Bin, et al. Maize extraction by multi-source remote sensing based on phenological characteristics of MODIS time series data[J]. Acta Agriculturae Jiangxi,2023,35(4):113 - 121. (in Chinese)

[35] TAN C Y, DUARTE L, TEODORO C A. Comparative study of random forest and support vector machine for land cover classification and post-wildfire change detection[J]. Land,2024,13(11):1878.

[36] 孙红,李松,李民赞,等.农业信息成像感知与深度学习应用研究进展[J].农业机械学报,2020,51(5):1 - 17.
SUN Hong, LI Song, LI Minzan, et al. Research progress of image sensing and deep learning in agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(5):1 - 17. (in Chinese)

[37] 刘照,李华朋,陈慧,等.基于时序影像及不同模型的玉米早期估产研究[J].光谱学与光谱分析,2023,43(8):2627 - 2637.
LIU Zhao, LI Huapeng, CHEN Hui, et al. Maize yield forecasting and associated optimum lead time research based on temporal remote sensing data and different model[J]. Spectroscopy and Spectral Analysis,2023,43(8):2627 - 2637. (in Chinese)

[38] JIANG Bo, ZHANG Heyi, SU Wenhao. Automatic localization of soybean seedlings based on crop signaling and multi-view imaging[J]. Sensors,2024,24(10):3066.