

基于多核主动学习和多源数据融合的农田塑料覆被分类

冯权泷^{1,2} 牛博文^{1,2} 朱德海^{1,2} 刘逸铭³ 欧 聪^{1,2} 刘建涛⁴

(1. 中国农业大学土地科学与技术学院, 北京 100083; 2. 自然资源部农用地质量与监控重点实验室, 北京 100193;
3. 中国移动通信集团广东有限公司, 广州 510623; 4. 山东建筑大学测绘地理信息学院, 济南 250101)

摘要: 通过引入多源多时相卫星遥感数据,提出了一种基于多核主动学习的农田塑料覆被分类算法,实现农业塑料大棚和地膜的精准分类。首先基于多时相 Sentinel-1 雷达和 Sentinel-2 光学遥感影像,提取其光谱特征、纹理特征等,以构建多维特征空间。然后构建多核学习模型,实现多源、多时相特征的自适应融合。最后构建基于池的主动学习策略,通过引入训练样本的淘汰机制,进一步提升分类模型的泛化能力。试验结果表明,本文所提分类方法的总体精度为 95.6%,Kappa 系数为 0.922,相较经典支持向量机、随机森林、K 近邻、决策树、AdaBoost 模型,多核学习模型精度提高 5.7、12.1、11.4、22.3、10.3 个百分点;且在相同分类精度下,主动学习较被动学习可减少一半以上的标签数据;同时相较仅使用单时相及单传感器遥感影像而言,精度分别提高 3.7、12.7 个百分点。结果表明,多核主动学习能够有效进行多传感器、多时相数据融合,并可以在小样本条件下取得更高的分类精度,从而为农田塑料覆被的遥感监测提供模型参考。

关键词: 农田塑料覆被; 多源遥感数据; 多核主动学习; 遥感影像分类

中图分类号: S127 文献标识码: A 文章编号: 1000-1298(2022)02-0177-09 OSID: 

Classification of Agricultural Plastic Cover Based on Multi-kernel Active Learning and Multi-source Data Fusion

FENG Quanlong^{1,2} NIU Bowen^{1,2} ZHU Dehai^{1,2} LIU Yiming³ OU Cong^{1,2} LIU Jiantao⁴

(1. College of Land Science and Technology, China Agricultural University, Beijing 100083, China
2. Key Laboratory for Agricultural Land Quality Monitoring and Control, Ministry of Natural Resources, Beijing 100193, China
3. China Mobile Group Guangdong Co., Ltd., Guangzhou 510623, China
4. School of Surveying and Geo-Informatics, Shandong Jianzhu University, Ji'nan 250101, China)

Abstract: An agricultural plastic covering classification algorithm was proposed based on multi-kernel active learning to achieve accurate classification of agricultural greenhouses and mulch film by introducing multi-source and multi-temporal satellite remote sensing data, and their spectral features and texture features were firstly extracted to construct a multi-dimensional feature space based on the multi-temporal Sentinel-1 radar and Sentinel-2 optical remote sensing data. And then, a multi-kernel learning model was constructed to realize the adaptive fusion of multi-source and multi-temporal features. Finally, a pool-based active learning strategy is constructed to further improve the generalization ability of the classification model by introducing an elimination mechanism for training samples. The test results showed that the overall accuracy of the proposed classification method was 95.6%, the Kappa coefficient was 0.922. Compared with that of the classic SVM, random forest, KNN, decision tree, AdaBoost model, the accuracy of the active learning model was improved by 5.7, 12.1, 11.4, 22.3 and 10.3 percentage points. And under the same classification accuracy, active learning can reduce more than half of the label data than passive learning. The accuracy was improved by 3.7 and 12.7 percentage points, respectively, compared with using only single-phase and single-sensor remote sensing images. The research results showed that multi-kernel active learning can effectively perform multi-sensor and multi-temporal data fusion, and can achieve high classification accuracy under small sample conditions. It can provide model reference for remote sensing monitoring of agricultural plastic cover.

Key words: agricultural plastic cover; multi-source remote sensing data; multi-kernel active learning; remote sensing imagery classification

收稿日期: 2021-01-26 修回日期: 2021-03-27

基金项目: 国家自然科学基金项目(42001367)和国家重点研发计划项目(2018YFE0122700)

作者简介: 冯权泷(1988—),男,副教授,博士生导师,主要从事机器、深度学习在农业遥感中的应用研究,E-mail: fengql@cau.edu.cn

通信作者: 朱德海(1962—),男,教授,博士生导师,主要从事 3S 技术在农业和国土资源管理中的应用研究,E-mail: zhudehai@cau.edu.cn

0 引言

农田塑料覆被(如农业塑料大棚、地膜覆盖等)对提升农产品产量及其经济效益起到重要作用,是农业现代化建设的重要部分,是农业形式由粗放型向集约型转变的重要手段^[1-3]。其中,地膜对抑制杂草生长、保持土壤水分、调节土壤温度有着积极作用^[4];而农业塑料大棚拥有更多的配套设施,能满足更多农产品的生长条件,可以对当地农产品产业结构的建设和调整起到促进作用^[5]。因此,实时、高效地监测农田塑料覆被对农业产业发展有着重要意义。遥感技术具有宏观、动态、快速等特点,利用遥感技术手段可以摆脱传统人工方法低效、实时性差等劣势,能够可靠、高效地获取农田塑料覆被地物目标,进而达到实时动态监测的目的^[6-7]。

在遥感影像分类领域,支持向量机(SVM)得到了广泛应用^[8-13],并被引入到农田塑料覆被制图中^[14-15]。具体而言,文献[14]利用 WorldView-2 卫星影像和 SVM 分类器,对土耳其的库姆鲁卡地区的农业塑料大棚进行了提取,其总体分类精度为 90.28%,精度超过了随机森林以及最大似然分类器^[14]。SVM 的优异表现,得益于其对最佳分类超平面的定位能力^[9],仅需要有限的支持向量即可实现较好的分类效果^[16]。同时,考虑到不同核函数对 SVM 分类性能的差异性,因此通过组合一簇核函数从而构成多核学习模型,即可实现光谱特征、纹理特征等的有效融合,从而提高分类精度^[17]。其中,文献[18]提出了一种基于多核 SVM 的高光谱影像分类方法,结果表明在融合光谱和形态特征的情况下,多核 SVM 精度超过了单核 SVM,前者的最优精度为 91.05%。文献[19]基于多核 SVM 对多源遥感数据进行了分类研究,同样证明了多核 SVM 的分类性能。

同时,在遥感影像分类研究中,主动学习得到了广泛应用。主动学习可以筛选出不确定性最大以及最具代表性的样本,从而有效降低训练样本的数量,

并提升训练效率^[20-23]。其中,文献[24]在森林退化遥感监测中,分别提出了基于启发式的主动学习方法,结果表明主动学习方法具有更高的分类精度,并能有效提高模型的收敛速度。文献[25]利用多源 Sentinel-1 和 Sentinel-2 影像和主动学习方法进行林木年龄的估算,试验结果验证了主动学习的优势,在达到相同估算精度的情况下,主动学习的训练样本数量可减少 50% 左右。

综上所述,多核学习、主动学习在遥感影像分类中均取得了优异的性能。然而在农田塑料覆被制图的研究中,上述算法尚未得到深入研究。同时以往的研究并没有很好解决农业塑料大棚和地膜的混淆问题。因此本文研究一种多核主动学习模型,以提高小样本下农田塑料覆被的制图精度。具体而言,本文基于 Google Earth Engine(GEE)云计算平台,通过引入多源多时相 Sentinel 遥感影像,提取光谱特征、纹理特征等构建多维特征空间,并构建多核学习模型对多源多时相特征进行融合,最后构建基于池的主动学习策略,提升分类模型在稀疏样本下的泛化能力。

1 研究区与数据源

1.1 研究区概况

图 1 所示为本文研究区,位于山东省聊城市与莘县交界地区,东经 115°35′~115°51′,北纬 36°22′~36°16′,面积约为 300 km²,是典型的农业塑料大棚、地膜交错区域。研究区位于华北平原中部,地势平坦,属于温带季风气候,雨热同季,年平均气温为 13.4℃,年平均降水量在 501.9 mm 左右。

1.2 数据源

本文采用 Sentinel-1 雷达卫星以及 Sentinel-2 光学卫星影像作为数据源。其中 Sentinel-1 由两颗极地轨道合成孔径雷达卫星组成,可在多云或缺少光照的条件下进行正常成像。Sentinel-2 由两颗多光谱光学卫星组成,具有较高空间分辨率(包含中心波长 10、20、60 m 的波段),重访周期为 5 d,具




图 1 研究区
Fig. 1 Study area

有较高的实时性,已广泛应用于作物分类、土地管理、灾害监测等领域。在本文中,分别选取 2019 年 5 月 10 日至 2019 年 6 月 1 日以及 2019 年 10 月 15 日至 2019 年 10 月 31 日的 Sentinel-1 和 Sentinel-2 的两幅遥感影像,通过 GEE 中的 median() 函数计算并输出遥感影像。

所选样本的土地利用类型分为 3 类:农业塑料大棚、地膜和其他土地利用类型。样本数据划分为初始训练集、验证集、测试集和未标记样本池。在初始训练集(125 个样本)中,农业塑料大棚、地膜和其他土地利用类型的数量分别为 35、15 和 75;验证集中,农业塑料大棚、地膜和其他土地利用类型的数量分别为 84、36 和 180;测试集中,农业塑料大棚、地膜和其他土地利用类型的数量分别为 300、119 和 581。

同时,本文基于 GEE 云计算平台对 Sentinel-1 和 Sentinel-2 影像进行预处理。其中对 Sentinel-1 雷达影像进行辐射定标、斑点噪声去除等操作,对 Sentinel-2 光学影像进行辐射定标、大气校正、正射校正等操作。此外,还基于 GEE 进行光谱特征、纹理特征等的计算,从而为分类提供一个多维特征空间。

2 研究方法

2.1 总体技术路线

本文通过引入多源多时相卫星遥感数据,构建多核主动学习模型进行农田塑料覆被制图的研究,总体技术路线如图 2 所示。




图 2 总体技术路线图
Fig. 2 Flow chart of proposed method

如图 2 所示,首先通过 GEE 云计算平台进行遥感数据的选取和预处理;然后计算其光谱、纹理等特征,并与原始遥感数据进行波段叠加,从而得到多维

特征空间;下一步构建多核学习模型,对多源多时相数据进行自适应融合,最后通过构建主动学习策略对分类模型进行训练,并利用测试样本对模型精度进行评价,最终输出研究区的农田塑料覆被空间分布结果。

2.2 特征提取

2.2.1 光谱特征

通过文献[1-2,7]以及前期分类试验,本文共选择 NDVI(归一化植被指数)、EVI(增强植被指数)、MSAVI(改进的土壤调节植被指数)、NDBI(归一化建筑指数)、MNDWI(改进的归一化差异水体指数)等 5 个光谱指数作为光谱特征。其中 NDVI^[26] 主要反映植被的生长状况,可用于提升植被与塑料覆被之间的差异;EVI^[27] 和 MSAVI^[28] 都是 NDVI 的改进指数,可以进一步削弱土壤和大气的影 响,以进一步提升植被与塑料覆被之间的区分度;NDBI^[29] 主要用于提取人工建设用地;MNDWI^[30] 用于提升水域的区分度。

2.2.2 纹理特征

通过目视解译和实地采样发现,农业塑料大棚和地膜的几何、纹理特征较为明显,因此采用以下 6 个最不相关的纹理特征:均值(MEA)、标准偏差(STD)、同质性(HOM)、相异度(DIS)、熵(ENT)和角度秒矩(ASM)^[1],用来进一步提升设施农业目标地区同其他类型地物的分离度。在计算纹理特征时,采用 3×3 大小的滑动窗口。

2.3 多核主动学习模型

2.3.1 多核学习

在 SVM 的研究中,核函数的提出在一定程度上解决了非线性数据的线性可分问题以及多特征数据中的“维度灾难”问题,然而经典的单核学习方法在学习多维空间的多特征时往往性能不佳^[31]。同时在遥感分类中,多特征(如光谱特征、纹理特征等)得到了广泛应用,而多核学习能够根据不同特征的特性构建合适的核方法,从而实现对多维特征的有效学习^[18,32-33]。

多核学习的一般表达式为

$$k_{\eta}(x, z) = f_{\eta}(\{k_m(x^m, z^m)\}_{m=1}^P | \eta) \quad (1)$$

其中 $f_{\eta}: \mathbf{R}^P \rightarrow \mathbf{R}$ 为线性或非线性组合函数,参数 η 可决定组合函数。样本 $x = \{x^m\}_{m=1}^P, z = \{z^m\}_{m=1}^P$ 内含特征 P 个,且 $x^m, z^m \in \mathbf{R}^{D_m}, D_m$ 代表特征维数。 P 个特征将建立 P 个核函数 $\{k_m: \mathbf{R}^{D_m} \times \mathbf{R}^{D_m} \rightarrow \mathbf{R}\}_{m=1}^P$ 。

多核学习的常见构造形式包括合成核、多尺度核、无限核等,本文采用多尺度核进行多核学习模型的构建,原因在于多尺度核的方法更为灵活,并能提供较为完整的尺度选择机制。具体而言,多尺度核

首先采用大尺度核对分类决策面平滑区域的样本进行拟合,再用小尺度核对分类决策面变化相对剧烈的样本进行拟合,同时进行逐级优化,从而得到更为精确的分类结果。在本文中,基于多尺度径向基核函数进行多核学习模型的构建,公式为

$$k(x,z)=\sum_{i=1}^n\alpha_i k(x,z,\gamma_i)\tag{2}$$

其中 $k(x,z,\gamma_i)=\exp(-\gamma_i\|x-z\|^2)$ (3)

式中 α_i 、 γ_i 分别表示权重、径向基核的值。通过上述多核学习模型的构建,可以实现多源、多时相遥感数据的特征级融合,从而提高不同地物之间的类间可分性,改善农田塑料覆被分类的精度。

2.3.2 主动学习

在经典的监督学习中,分类问题的解决依赖于大量的训练样本,通过不断增加样本数量进而提升分类精度。然而训练样本的标注往往费时费力,因此设计一种学习策略,在减少人工标注工作量的同时提升模型的学习效率和分类精度,就成为了一个重要问题。在这一背景下,主动学习的算法框架被提出,并成功应用于遥感影像分类等领域。

具体而言,主动学习的主要思想表述如下:通过设计样本查询算法对未被标记的样本进行查询,从而完成样本池中候选样本的排序,并选择最具有代表性的未标记样本交由标注专家或人工定义的专家系统进行类别标注,重复上述过程,直到满足算法停止条件为止^[34-36]。由此可见,主动学习的目标就是利用最少的样本标注,得到最优的模型。

在本文中,采用的主动学习策略如下:构建包含125个样本的初始样本集 X ,利用其对多核学习模型进行训练,之后加入主动学习策略,对未标记样本池 U 中的样本计算其不确定性(信息熵),选择信息熵最大的样本 q ,并对其赋予标签,并将其添加到样本集 X 中,并继续对多核学习模型进行训练,如此往复,直至模型达到目标精度。同时,在试验开始前从训练集中划分300个样本作为验证集,用以在线监测模型的精度。经过500次查询,样本集 X 中的样本扩充至625个,最终在第410次查询前后得到收敛精度。

2.4 精度评价

在完成多核主动学习模型的训练后,使用测试集(1 000个样本)进行精度计算,并输出混淆矩阵、总体分类精度、Kappa系数以及其他精度评价指标作为定量评价依据。除此之外还将输出农田塑料覆被分类结果,通过目视解译的方法定性评价模型分类性能。

3 结果与分析

3.1 总体结果分析

基于本文的多核主动学习模型,对多源多时相 Sentinel 卫星影像进行分类,得到的农田塑料覆被分类结果如图3所示。

如图3所示,本文构建的多核主动学习模型可以实现农田塑料覆被的精确提取。其中,农业塑料大棚主要分布在研究区的西部以及东北部地区,在东南部地区和中部地区则呈零星分布;地膜主要分布在研究区的中部以及东南部地区,在西部地区呈零星分布。通过对比原始遥感影像,本文模型的分类结果与农业塑料大棚和地膜的实际分布情况高度一致,具有较好的分类效果。

同时,农业塑料大棚与地膜之间的混分情况较少,分类错误主要集中在农业塑料大棚/地膜与其他地物(尤其是人工建设用地)之间。其原因在于人工建设用地的反射率和后向散射系数均较高,并与农业塑料大棚/地膜存在一定的相似性,最终导致了混分。从图像细节(图3b)可以看出,混分并不是存在于单个地物中,而是存在于不同地物之间的交界处,这主要受限于 Sentinel 影像的空间分辨率,因为单个像素仅能表示 10 m × 10 m 的空间范围,导致不同地物边缘存在混合像元现象,从而在地物的边缘容易产生分类错误,这样就造成了地物之间的混分。

同时,基于测试集进行模型精度评估,计算混淆矩阵、总体精度、Kappa系数等,结果如表1所示。

由表1可知,农业塑料大棚和地膜的分类效果较好,模型的总体分类精度为95.6%,Kappa系数为0.922,农业塑料大棚的 F1 值为0.96,地膜的 F1 值为0.89。

3.2 单源与多源数据的分类精度

为了验证多源数据对农田塑料覆被制图的贡献,设计了对比试验,对单源与多源数据的分类结果和精度做了比较,具体试验设置为:使用 Sentinel-1 的多时相雷达影像进行分类;仅使用 Sentinel-2 的多时相光学影像进行分类;同时使用多时相雷达和光学影像进行分类。

上述试验的分类结果如图4所示。图4表明,相比于单源遥感影像分类,多源遥感影像的引入可以提高分类效果。这是由于多源遥感影像包含更多的地物信息,能够更好反映目标地物的相关特征,分类的细致度较单源遥感影像更好。同时,图4a表明,仅使用 Sentinel-1 雷达影像,其分类效果过于破碎,经目视解译发现,部分裸地和建设用地被错分为农业塑料大棚和地膜,同时农业塑料大棚和地膜




图 3 基于多核主动学习的农田塑料覆被制图结果

Fig. 3 Agricultural plastic cover mapping results based on multi-kernel active learning

表 1 混淆矩阵、总体精度和 Kappa 系数

Tab.1 Confusion matrix, overall accuracy and Kappa coefficient

类别	测试集			用户精度/%	F1 值
	农业塑料大棚	地膜	其他		
农业塑料大棚	297	1	2	99.0	0.96
地膜	8	106	5	89.1	0.89
其他	15	13	553	95.2	0.97
生产者精度/%	92.8	88.3	98.8		
总体精度/%	95.6	Kappa 系数		0.922	

之间也多有混分的情况出现。从图 4b 可以看出,仅用 Sentinel-2 光学影像,相较于仅用 Sentinel-1 雷达影像具有更优的分类结果,而联合使用光学和雷达影像取得了最好的分类效果(图 4c)。

表 2 列出了单源和多源的遥感分类精度,结果表明,仅使用雷达影像进行分类的精度最低,较仅使用光学影像分类的精度下降 23.2 个百分点。究其原因,在仅使用雷达影像分类时,采用后向散射系数作为分类依据,导致不同地物之间的可分性较差,从

而无法获取精确的农田塑料覆被分类结果。同时 Sentinel-2 可提供地物的多光谱反射信息,相比于雷达影像可有效提高地物的可分性,从而取得更好的分类结果。而通过光学和雷达影像的联合使用可以进一步提升地物之间的可分性,从而提升分类精度,这与文献[37-38]的结论一致。

3.3 单时相与多时相遥感影像分类精度对比

为了验证多时相数据对于农田塑料覆被分类精度的贡献,设计了对比试验,分别使用单时相影像和多时相影像进行分类试验。具体而言,本文选取的单时相影像的成像时间为 2019 年 10 月 15—31 日期间,此时农业塑料大棚和地膜同时存在。结果如图 5 所示。

图 5 表明,仅使用单时相影像进行分类,农业塑料大棚、地膜以及其他地物之间的混分现象较为严重,尤其是农业塑料大棚和地膜之间的混分现象尤为突出。如图 5a 所示,在农业塑料大棚的连片区域内增加了许多“地膜”,这是由于在仅使用单时相影像进行分类时,塑料大棚和地膜都呈现为白色,其光谱反射和后向散射系数均相近,导致了错分。为了




图 4 基于不同数据源的农田塑料覆被制图结果

Fig. 4 Agricultural plastic cover mapping results based on different data sources

表 2 不同数据分类精度对比

Tab. 2 Classification accuracy of different data sources

参数	雷达	光学	雷达加光学
总体精度/%	71.3	94.5	95.6
Kappa 系数	0.481	0.903	0.922

提高农业塑料大棚和地膜之间的可分性,本文引入地膜覆盖之前时相的影像(5月),这是因为在这两个时相内,农业塑料大棚一直存在,而地膜则表现出存在和不存在两个状态,多时相数据的引入可以有

效反映地膜存续的时间梯度信息,因此具有更好的分类效果。

表 3 给出了不同时相分类精度的对比结果,可以看出,相比于单时相分类,多时相数据的引入可以将分类精度从 91.9% 提高到 95.6%,这主要因为多时相数据考虑了地膜的存续时间,通过 film-on(存在地膜)和 film-off(不存在地膜)两个时相影像的引入,可以有效捕捉地膜的物候特征,从而提高其与农业塑料大棚的可分性。




图 5 基于不同时相遥感影像农田塑料覆被制图结果

Fig. 5 Agricultural plastic cover mapping results based on different temporal data

表 3 不同时相分类精度对比

Tab. 3 Accuracy of different temporal images

参数	单时相	多时相
总体精度/%	91.9	95.6
Kappa 系数	0.853	0.922

3. 4 不同分类模型的精度对比

3. 4. 1 主动学习的精度

为了验证主动学习在农田塑料覆被分类中的性能,本节计算了主动学习与非主动学习(被动学习)在不同标记样本数量下的精度,如图 6 所示。




图 6 主动学习和被动学习精度变化曲线

Fig. 6 Active learning model vs passive learning model

由图 6 可以看出,在多核 SVM 模型中添加主动学习策略,模型收敛更快。主动学习在样本数量达

到 410 个时,模型趋于收敛,而被动学习在达到 500 个样本点时,模型才趋于收敛。由此可见主动学习在达到最优精度时,可以减少 18% 的训练样本数量。

此外,图中黑色虚线 $y = 92.3\%$ 表示在相同精度下,主动学习所需要的样本数量比被动学习少得多;图中绿色虚线 $y = 95.6\%$ 表示,主动学习较被动学习需要更少的样本数量达到最优精度。同样达到精度 92.3%,主动学习仅需 130 个标记样本,而被动学习则需要 265 ~ 320 个样本,是主动学习的 2 倍多。因此主动学习策略在样本稀疏条件下更有优势。

3. 4. 2 多核学习和其他分类方法比较

同时为了进一步验证多核学习在农田塑料覆被分类中的优势,设置了对比试验,通过对比单核支持向量机 (SVM)、随机森林 (RF)、K 近邻 (KNN)、决策树 (DT)、AdaBoost 等模型,为了保证可比性,均选用初始样本集进行训练。同时由于本节主要对比不同分类器的性能,因此在训练过程中并不增加主动学习策略。精度对比如表 4 所示。

表 4 不同分类器的分类精度对比

Tab. 4 Classification accuracy of different classifiers		
类别	总体精度/%	Kappa 系数
单核 SVM	89. 8	0. 804
RF	83. 4	0. 673
KNN	84. 1	0. 713
DT	73. 2	0. 533
AdaBoost	85. 2	0. 744
多核学习	95. 6	0. 922

由表 4 可知,本文所构建的多核学习模型的分
类精度均高于其他模型。在其他分类器中,单核
SVM 的分类精度最高(89. 8%),然而多核学习的精
度较其提高了近 6 个百分点。究其原因,多核学习
采用一簇核函数对多特征数据集进行自适应学习,
从而能够结合不同核函数学习的优势,更加适合多
源多时相遥感数据的融合,最终达到更优的农田塑
料覆被分类效果。

4 结论

(1)将多核 SVM 和基于池的主动学习策略进
行耦合,构建了一种多核主动学习模型以进行农田
塑料覆被的遥感分类,总体分类精度为 95. 6%,
Kappa 系数为 0. 922;相比于传统经典机器学习模
型:单核支持向量机、随机森林、K 近邻、决策树、
AdaBoost,多核学习模型精度可较上述模型提高
5. 7、12. 1、11. 4、22. 3、10. 3 个百分点;且在相同的
分类精度下,主动学习较被动学习可减少标签样
本一半以上,更适合小样本条件下的影像分类
任务。

(2)通过引入多源多时相遥感影像,提高了不
同地物之间的可分性,从而取得了更好的农田塑料
覆被制图效果。相比于单源雷达和光学数据,多源
数据可平均提升分类精度 12. 7 个百分点;同时多时
相数据可提高分类精度 3. 7 个百分点。

参 考 文 献

[1] 朱德海,刘逸铭,冯权泷,等. 基于 GEE 的山东省近 30 年农业大棚时空动态变化研究[J]. 农业机械学报,2020, 51(1): 168 - 175.
ZHU Dehai, LIU Yiming, FENG Quanlong, et al. Spatial-temporal dynamic changes of agricultural greenhouses in Shandong Province in recent 30 years based on Google Earth Engine[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 168 - 175. (in Chinese)

[2] OU C, YANG J, DU Z, et al. Long-term mapping of a greenhouse in a typical protected agricultural region using Landsat imagery and the Google Earth Engine[J]. Remote Sensing, 2020, 12(1): 55.

[3] GONZÁLEZ-YEBRA Ó, AGUILAR M A, NEMMAOUI A, et al. Methodological proposal to assess plastic greenhouses land cover change from the combination of archival aerial orthoimages and Landsat data[J]. Biosystems Engineering, 2018, 175(21): 36 - 51.

[4] HAO P, CHEN Z, TANG H, et al. New workflow of plastic-mulched farmland mapping using multi-temporal sentinel - 2 data[J]. Remote Sensing, 2019, 11(11): 1353.

[5] ARCIDIACONO C, PORTO S M C. A model to manage crop-shelter spatial development by multi-temporal coverage analysis and spatial indicators[J]. Biosystems Engineering, 2010, 107(2): 107 - 122.

[6] ESPI E, SALMERON A, FONTECHA A, et al. Plastic films for agricultural applications[J]. Journal of Plastic Film & Sheeting, 2006, 22(2): 85 - 102.

[7] WU C, DENG J S, WANG K, et al. Object-based classification approach for greenhouse mapping using Landsat - 8 imagery[J]. Int. J. Agric. Biol. Eng., 2016, 9(1): 79 - 88.

[8] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273 - 297.

[9] HUANG C, DAVIS L S, TOWNSHEND J R G. An assessment of support vector machines for land cover classification[J]. International Journal of Remote Sensing, 2002, 23(4): 725 - 749.

[10] 亓呈明. 基于多核学习的高光谱遥感影像分类方法研究[D]. 北京:中国地质大学(北京), 2016.
QI Chengming. Hyperspectral remote sensing image classification based on multiple kernel learning[D]. Beijing: China University of Geosciences (Beijing), 2016. (in Chinese)

[11] USTUNER M, SANLI F B, DIXON B. Application of support vector machines for landuse classification using high-resolution RapidEye images: a sensitivity analysis[J]. European Journal of Remote Sensing, 2016, 48(1): 403 - 422.

[12] 陈波,张友静,陈亮. 结合纹理的 SVM 遥感影像分类研究[J]. 测绘工程, 2007, 16(5): 23 - 27.
CHEN Bo, ZHANG Youjing, CHEN Liang. RS Image classification based on SVM method with texture[J]. Engineering of Surveying and Mapping, 2007, 16(5): 23 - 27. (in Chinese)

[13] 邓曾,李丹,柯樱海,等. 基于改进 SVM 算法的高分辨率遥感影像分类[J]. 国土资源遥感, 2016(28): 12 - 18.
DENG Zeng, LI Dan, KE Yinghai, et al. An improved SVM algorithm for high spatial resolution remote sensing image classification[J]. Remote Sensing for Land & Resources, 2016(28): 12 - 18. (in Chinese)

[14] KOC-SAN D, SONMEZ N K. Plastic and glass greenhouses detection and delineation from WorldView - 2 satellite imagery[J]. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, 41(B7): 257 - 262.

- [15] GÖKSEL Ç, BALCIK F, KESKIN M, et al. Evaluation of classification methods for detection of greenhouses from spot 5 satellite imagery[C]//6th International Conference on Cartography and GISAt. Albena,2016.
- [16] 李洪川. 多核支持向量机在高分辨率遥感影像分类中的应用研究[D]. 重庆:重庆邮电大学,2018.
LI Hongchuan. Study of multiple kernel support vector machine in the application of high-resolution remote sensing image classification[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2018. (in Chinese)
- [17] NIAZMARDI S, DEMIR B, BRUZZONE L, et al. Multiple kernel learning for remote sensing image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(3): 1425 – 1443.
- [18] TAN K, DU P. Classification of hyperspectral image based on morphological profiles and multi-kernel SVM[C]//2010 2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing. Reykjavik, 2010.
- [19] ZHANG Y, YANG H L, PRASAD S, et al. Ensemble multiple kernel active learning for classification of multisource remote sensing data[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014,8(2): 845 – 858.
- [20] TUIA D, VOLPI M, COPA L, et al. A survey of active learning algorithms for supervised remote sensing image classification [J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(3): 606 – 617.
- [21] CRAWFORD M M, TUIA D, YANG H L. Active learning: any value for classification of remotely sensed data? [J]. Proceedings of the IEEE, 2013, 101(3): 593 – 608.
- [22] PERSELLO C, BRUZZONE L. Active learning for domain adaptation in the supervised classification of remote sensing images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(11): 4468 – 4483.
- [23] JOSHI A J, PORIKLI F, PAPANIKOLOPOULOS N. Multi-class active learning for image classification[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami, 2009.
- [24] DALLAQUA F, FARIA F, FAZENDA A. Active learning approaches for deforested area classification[C]//31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). Parana, 2018.
- [25] HAMROUNI Y, PAILLASSA E, CHÉRET V, et al. Synergistic use of Sentinel – 1 and Sentinel – 2 time series for poplar plantations monitoring at large scale[J]. International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences, 2020, 43(B3): 1457 – 1461.
- [26] CARLSON T N, RIPLEY D A. On the relation between NDVI, fractional vegetation cover and leaf area index[J]. Remote Sensing of Environment, 1997, 62(3): 241 – 252.
- [27] WARING R H, COOPS N C, FAN W, et al. MODIS enhanced vegetation index predicts tree species richness across forested ecoregions in the contiguous U. S. A[J]. Remote Sensing of Environment, 2006, 103(2): 218 – 226.
- [28] QI J, CHEHBOUNI A, HUETE A R, et al. A modified soil adjusted vegetation index[J]. Remote Sensing of Environment, 1994, 48(2): 119 – 126.
- [29] ZHA Y, GAO J, NI S. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery [J]. International Journal of Remote Sensing, 2003, 24(3): 583 – 594.
- [30] XU H. Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery [J]. International Journal of Remote Sensing, 2006, 27(14): 3025 – 3033.
- [31] 汪洪桥, 孙富春, 蔡艳宁, 等. 多核学习方法[J]. 自动化学报, 2010, 36(8): 1037 – 1050.
WANG Hongqiao, SUN Fuchun, CAI Yanning, et al. On multiple kernel learning methods[J]. Acta Automatica Sinica, 2010, 36(8): 1037 – 1050. (in Chinese)
- [32] LAURIOLA I, AIOLLI F. MKLpy: a Python-based framework for multiple kernel learning[J]. arXiv preprint arXiv:2007.09982. 2020.
- [33] PHIENTHRAKUL T, KIJSIRIKUL B. Evolutionary strategies for hyperparameters of support vector machines based on multi-scale radial basis function kernels[J]. Soft Computing, 2010, 14(7): 681 – 699.
- [34] TUIA D, RATLE F, PACIFICI F, et al. Active learning methods for remote sensing image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(7): 2218 – 2232.
- [35] DANKA T, HORVATH P. modal: a modular active learning framework for Python[J]. arXiv preprint arXiv:1805.00979. 2018.
- [36] SETTLES B. Active learning literature survey[D]. Madison: University of Wisconsin, 2010.
- [37] FRANKLIN S E, SKERIES E M, STEFANUK M A. Wetland classification using Radarsat – 2 SAR quad-polarization and Landsat – 8 OLI spectral response data: a case study in the Hudson Bay Lowlands Ecoregion[J]. Int. J. Remote Sens., 2018, 39(6): 1615 – 1627.
- [38] FENG Q, GONG J, LIU J, et al. Monitoring cropland dynamics of the Yellow River delta based on multi-temporal landsat imagery over 1986 to 2015[J]. Sustainability, 2015, 7(11): 14834 – 14858.