

Research on Feature Optimization for Land Use/Cover Classification Based on Google Earth Engine

Huan Fan Rui Li Hui Yao Yi Ma Weihai Hou

College of Plant Science, Xizang Agriculture and Animal Husbandry University, Linzhi, Xizang, 860000, China

Abstract

[Objective] This study utilizes the Google Earth Engine (GEE) platform to analyze Sentinel-1 and Sentinel-2 satellite imagery data, evaluating the effectiveness of different satellite features in land cover classification tasks. The research aims to establish an efficient automated feature optimization framework on GEE to obtain more representative feature sets. [Methods] Taking the area near Lake Trasimeno in Umbria, Italy as a case study, we employed Jeffries-Matusita (JM) distance to assess feature discriminative power and combined it with correlation analysis for feature selection. [Results] The study found that the average JM value showed a significant positive correlation with the Kappa coefficient of classification accuracy (correlation coefficient = 0.53). [Conclusion] This research demonstrates the effectiveness of building an automated feature selection framework on GEE, which can enhance the performance of land cover classification tasks. The findings provide effective methodological support for remote sensing data feature selection and classification accuracy improvement.

Keywords

feature preference; Google Earth Engine; JM distance; land use

基于 GEE 的土地利用分类特征优选研究

范欢 李锐 姚慧 马一 侯维海

西藏农牧学院植物科学学院, 中国·西藏 林芝 860000

摘 要

【目的】本研究基于 Google Earth Engine (GEE) 平台, 分析 Sentinel-1 和 Sentinel-2 卫星影像数据, 并评估不同卫星特征在土地覆盖分类任务中的有效性。研究旨在 GEE 平台上搭建一个高效的自动化特征优化框架, 以获取更具代表性的特征集。【方法】以意大利翁布里亚地区特拉西梅诺湖附近地区为例, 运用杰弗里斯-默特尔斯 (Jeffries-Matusita, JM) 距离评估特征间的区分能力, 并结合相关性分析进行了特征优选。【结果】研究发现, 所选区域的 JM 平均值与分类精度 Kappa 系数呈现出显著的正相关关系 (相关系数为 0.53)。【结论】此研究证明了在 GEE 平台上构建自动化特征优选框架的有效性, 特征优选可提高土地覆盖分类任务的性能。本研究的发现为遥感数据的特征选择和分类精度提升提供了有效的方法支持。

关键词

特征优选; Google Earth Engine; JM 距离; 土地利用

1 引言

【研究意义】在遥感识别土地利用类型 Geographic Information System (GIS) 领域^[1], 特征选择和优化对于提

高土地利用分类精度和处理效率具有重要意义^[2,3]。随着遥感技术的飞速发展, 尤其是 Google Earth Engine (GEE) 平台的兴起^[4], 为研究人员提供了前所未有的大量地理空间数据。这些数据不仅覆盖广泛的区域, 同时包含了丰富的地理和环境信息。然而, 如何有效地处理和分析这些庞大的数据集以提取有价值的信息, 成为目前面临的挑战。在众多分析技术中, 特征选择和优化在提高分类任务的性能方面起着至关重要的作用。因此, 从更宏观的视角来看, 遥感技术在土地利用方面本身具有不可替代的核心意义: 它突破了传统土地调查依赖人工实地勘测的局限, 能够快速、动态地监测大范围土地利用现状及变化趋势, 为国土空间规划、生态环境保护、农业资源管理、城市扩张监测等关键领域提供及时、准确的基础数据支撑, 是实现土地资源精细化管理、可持续利用以及应对气候变化等全球性议题的重要技术

【基金项目】西藏农区粮油作物碳汇监测与固碳增汇技术研究 (项目编号: XZ202501ZY0045); 高原特色农牧科技小院建设及学科综合服务能力提升 (藏财预指 (2025) 001 号) - 日喀则边雄乡塔玛村油菜科技小院。

【作者简介】范欢 (2000-), 女, 在读硕士, 从事高原作物农田碳汇研究。

【通信作者】侯维海 (1985-), 男, 副教授, 从事高原作物研究。

手段。【前人研究进展】在地表覆盖和土地利用分类的遥感分析中,利用机器学习方法时,选取合适的特征集是关键^[5]。有效的特征选择不仅可以提高分类的准确性,还可以显著降低计算复杂性,提升分析的效率^[6]。此外,通过减少不必要的特征数量,模型的解释性和透明度也可得到提高。确定不同类别之间的可分离性常用方法有3种:可分离性指数(SI)^[7,8]、变换散度(TD)^[9]such as Moderate Resolution Imaging Spectroradiometer (MODIS 和杰弗里斯-默特尔斯(Jeffries-Matusita)距离^[10]。与SI和TD相比, JM 距离可以定量评估不同类别之间的可分离性^[11]。【本研究切入点】基于GEE平台利用JM距离寻找最优特征是可行的^[12,13]5.04%,4.48%;(2。而结合JM距离与相关系数构建了特征选择算法,不仅可以有效降低参与分类的特征数量,还能提高分类模型的运行效率和精度^[14]。【拟解决的关键问题】基于以上,本研究旨在基于GEE平台构建一个自动化的特征优选框架。该框架采用JM距离来评估特征在分类任务中的有效性,同时,结合相关性分析自动优化特征选择。通过分析Sentinel-1和Sentinel-2卫星数据,探索特征选择对分类准确性的影响,以及不同特征组合如何影响最终的分类结果。以提高GEE平台土地覆盖分类任务的自动化与高效化。

2 材料与方法

2.1 实验数据

研究区位于意大利翁布里亚地区特拉西梅诺湖周围,北纬43°06′、东经12°07′,该地区涵盖了多种土地利用类型,生态环境多样。研究区域内包含多种图斑类型,涵盖各类农用地(如耕地、草地、园地)、林地、人造地表,以及若干小型人造湖泊。本次实验使用的样点数据源自Tassi^[15]的公开数据集(表1),研究时间也与Tassi^[15]相同为2017年1月1日至2019年12月31日,筛选出云量低于10%的卫星影像,以减少云层干扰。

实验区域的土地利用类型划分为六类:(0)建成区,包括住宅区与其他人造表面;(1)一年生作物区,涵盖多种作物如谷物、豆类和园艺作物;(2)多年生作物区,主要由葡萄园和橄榄林构成;(3)草地;(4)林地;(5)灌木区,包括湖滨和河岸带植被以及其他稀疏的灌木覆盖区;(6)水体,囊括特拉西梅诺湖及其他小型私人湖泊。

表1 各用地类型样点数量

类型	标签	数量
建成区	1	35
一年生作物区	2	154
多年生作物区	3	40
草地	4	59
林地	5	65
灌木	6	17
水体	0	80
总计		450

在本研究中,综合参考了David总结的232个遥感指数。鉴于数据特性,最终选取了Sentinel-2卫星能够计算的所有指数共192个(详见附表1)。除外,本研究还纳入了Sentinel-1卫星的升轨(ascending)和降轨(descending)轨道上的VV和VH波段(分别标记为VVA、VVD、VHA、VHD),以及Sentinel-2的B1至B12波段。因此,本研究共涵盖了208个特征指数(见表2),为进行深入的遥感分析提供了丰富而全面的数据资源。除Sentinel-1、Sentinel-2基础波段之外的其他衍生指数的详细信息(包括指数类型、文献来源、计算方法等),均来源于David构建的Streamlit平台(Streamlit(davemlz-espectro-espectro-91350i.streamlit.app))。

2.2 研究方法

本研究采用了杰弗里斯-默特尔斯(Jeffries-Matusita, JM)距离和相关系数这两种统计方法进行特征优选实验。同时,通过随机森林算法进行像素级分类,并采用Kappa系数来进行精度分析。实验的具体流程如下:

特征提取:遥感影像中提取特征,构成分类的原始特征集。

特征评估:在构建的特征集基础上,分别计算每个特征的JM距离平均值和相关系数,以及其在分类任务中的精度。通过这些计算,研究分类精度与JM距离平均值及相关系数绝对值之间的关系。

特征数量分析:基于构建的特征集,逐步增加特征数量,并计算在这种特征排列下不同特征数量的分类精度,从而探索研究区分类精度与特征数量之间的关联性。

分类实验与验证:基于经过优选的特征集,结合随机森林算法进行基于像素的分类实验,并与前期研究结果进行对比,以验证本研究构建的框架的有效性。

2.2.1 概率距离——JM距离

“杰弗里斯-默特尔斯距离”(Jeffries-Matusita Distance),简称JM距离,是一个精细的统计度量,专门用于量化两个概率分布之间的相似性或差异性^[16]。在遥感、图像处理以及模式识别的领域,JM距离被广泛应用于评估不同特征在区分各类别中的效能。它的取值范围介于0到2之间,其中0表示两个分布完全相同,而2表示两者完全不同。

JM距离的核心是基于Bhattacharyya系数的改进。这种改进为比较两个统计样本或概率分布间的差异提供了方法,具体是通过计算两个概率密度函数的重叠区域来实现的。在复杂的监督分类任务中,特别是在区分多样化的地表类型时,JM距离的应用至关重要。它通过量化不同类别之间的可区分性,为精确的特征选择提供了科学依据。理想情况下,最有效的特征集应该是能够最大化类别JM距离的集合,进而提升分类算法的总体精度。因此,JM距离不仅是一个度量标准,更是特征选择和模型优化过程中的关键因素,在增强分类效果和深入理解数据结构方面发挥着显著作用。

JM距离的计算公式如下:

$$JM=2*(1-e^{-B^2})$$
$$B^2=\frac{1}{8}(\mu_P-\mu_Q)^T\Sigma^{-1}(\mu_P-\mu_Q)+\frac{1}{2}\ln\left(\frac{|\Sigma|}{\sqrt{|\Sigma_P||\Sigma_Q|}}\right)$$

其中， B^2 是 Bhattacharyya 距离,于两个概率分布 P 和 Q 以及其均值 μ_P 、 μ_Q 和协方差矩阵 Σ_P 、 Σ_Q , Σ 是 Σ_P 和 Σ_Q 的平均值。

表 2 特征名称表

指数名称	指数名称	指数名称	指数名称	指数名称	指数名称	指数名称	指数名称
B1	BITM	FCVI	MCARI705	NDBI	NIRvH2	S2REP	TriVI
B2	BIXS	GARI	MCARIOSAVI	NDCI	NLI	S2WI	UI
B3	BLFEI	GBNDVI	MCARIOSAVI705	NDDI	NMDI	S3	VARI
B4	BNDVI	GCC	MGRVI	NDGI	NRFIg	SARVI	VARI700
B5	BRBA	GDVI	MIRBI	NDGIaI	NRFIr	SAVI	VI700
B6	BWDRVI	GEMI	MLSWI26	NDII	NSDS	SAVI2	VIBI
B7	BaI	GLI	MLSWI27	NDMI	NSDSI1	SEVI	VIG
B8	CIG	GM1	MNDVI	NDPI	NSDSI2	SIPI	VgNIRBI
B8A	CIRE	GM2	MNDWI	NDPonI	NSDSI3	SR	VrNIRBI
B9	CSI	GNDVI	MNLI	NDREI	NWI	SR2	WDRVI
B11	CVI	GOSAVI	MRBVI	NDSI	NormG	SR3	WDVI
B12	DBSI	GRNDVI	MSAVI	NDSII	NormNIR	SR555	WI1
AFRI1600	DSI	GRVI	MSI	NDSInw	NormR	SR705	WI2
AFRI2100	DSWI1	GSAVI	MSR	NDSWIR	OCVI	SWI	WI2015
ANDWI	DSWI2	GVMi	MSR705	NDSaIi	OSAVI	SWM	WRI
ARI	DSWI3	IAVI	MTCI	NDSOI	PISI	SeLI	KEVI
ARI2	DSWI4	IBI	MTVI1	NDTI	PSRI	TCARI	kIPVI
ARVI	DSWI5	IKAW	MTVI2	NDVI	RCC	TCARIOSAVI	kNDVI
ATSAVI	DVI	IPVI	MuWIR	NDVI705	RDVI	TCARIOSAVI705	krVI
AWEInsh	DVIplus	IRECI	NBAI	NDVIMNDWI	REDSI	TCI	kVARI
AWEIsh	EMBI	LSWI	NBR	NDWI	RENDVI	TDVI	mND705
BAI	EVI	MBI	NBR2	NDWIns	RGBVI	TGI	mSR705
BAIM	EVI2	MBWI	NBRSWIR	NDYI	RGRI	TRRVI	VVA
BAIS2	ExG	MCARI	NBRplus	NGRDI	RI	TSAVI	VVD
BCC	ExGR	MCARI1	NBSIMS	NHFD	RI4XS	TTVI	VHA
BI	ExR	MCARI2	ND705	NIRv	RVI	TVI	VHD

2.2.2 相关系数计算

相关系数的计算通常采用皮尔逊相关系数^[17]（Pearson correlation coefficient）。该系数的值介于 -1 和 1 之间，其中，1 表示完全正相关，-1 表示完全负相关，0 表示无相关性。公式如下：

$$r=\frac{\sum_{i=1}^n(X_i-\bar{X})(Y_i-\bar{Y})}{\sqrt{\sum_{i=1}^n(X_i-\bar{X})^2}\sqrt{\sum_{i=1}^n(Y_i-\bar{Y})^2}}$$

其中， X_i 和 Y_i 分别是两个变量的观测值， \bar{X} 和 \bar{Y} 是它们的平均值。

2.2.3 优选方法

制定如下特征优化框架，旨在优化分类性能并提高解释性。

- 1. 选取 JM 平均值大于 0.8 的特征^[18]。

- 2. 剔除高度相关的特征：在所选的特征集中，如特征之间相关性系数大于 0.95。仅保留了与目标相关系数最高的一个特征，以降低多重共线性的风险。有助于提高模型的稳定性和解释性。

2.3 随机森林

随机森林^[19]是一种集成学习方法，它通过构建并整合多个决策树来执行分类或回归任务^[20]。在本研究中，采用随机森林算法进行土地利用类型的像素级分类，其中决策树的数量设定为 100。为有效实现这一分类框架，研究所用的数据集被分成两个部分：80% 的数据随机选取作为训练集，用于构建随机森林模型；剩余的 20% 则作为测试集，用于评估模型的性能。

2.4 精度分析

Kappa 系数是评估分类精度的一个重要指标，用于衡量分类精度，特别是在分类问题中评估观测分类结果与随机

分类的一致程度。混淆矩阵，又称错误矩阵，是一种特别的表格布局，用于可视化算法性能。它显示了实际类别与模型预测类别之间的关系，其中每列代表预测的类别，每行代表实际的类别。**Kappa** 系数基于混淆矩阵计算而来。在本研究中，**Kappa** 系数用于评估随机森林模型分类结果的准确性。通过比较不同特征的 **Kappa** 系数，研究旨在识别对分类精度影响最大的特征，以优化特征选择过程。

3 结果与分析

3.1 单一特征与分类精度关系

对每个特征与土地利用类型（Land Use and Land Cover, LULC）分类标签之间的关系进行了详尽分析，计算每个特征的 JM 距离。对于研究区的七种不同用地类型，分别计算了各自的 JM 值，并求得这些值的平均数。随后，利用随机森林算法进行了基于像素的分类，并获得相应的 **Kappa** 系数，以此评估每个特征在分类任务中的有效性。分析结果显

示 **Kappa** 系数与 JM 平均值之间存在显著的正相关关系（相关系数为 0.53）（图 1），这说明当特征的 JM 平均值较高时，基于该特征的分类精度通常也较高。

然而，有趣的是，尽管特征 RI4XS 拥有最高的 JM 平均值（详见图 2），其对应的 **Kappa** 系数却仅为 0.39。通过进一步的研究发现，虽然 RI4XS 在区分水体方面表现出色（精度达到 1），但在草地和林地的区分上效能有限，草地分类精度为 0，林地分类精度仅为 0.07。这表明 RI4XS 在特定土地类型（林地和灌木）的区分能力有限，导致整体分类效果受限。相比而言，特征 SeLI 的 JM 平均值为 0.93，其 **Kappa** 系数高达 0.79，相关系数也达到了 0.85，展现出极其出色的分类效果。这进一步表明在特征选择过程中，不仅要考虑特征的综合性能，还要考虑其区分不同类别的能力，从而更精准地优化特征选择，提升土地利用分类的准确性和效率。




图 1 kappa 值与特征 JM 平均值的关系




图 2 RI4XS JM 热力图

进一步对每个特征与土地利用及土地覆盖（Land Use and Land Cover, LULC）分类标签之间的相关性进行了细致的分析，并计算每个特征与 LULC 分类标签之间相关性的绝对值。与此同时，继续采用基于像素的随机森林分类方法，并对由此产生的分类结果的 Kappa 系数进行了对比。分析结果显示 Kappa 系数与各特征相关性绝对值之间存在一定程度的正相关关系，相关系数达到了 0.45。这表明，在一定程度上，特征与分类标签之间的相关性越高，基于该特征进行分类的准确性也越高。然而，这种相关性的综合表现并不如 JM 值。

3.2 特征数量与分类精度关系

为了深入理解不同特征组合对分类准确性的影响，本研究采用逐步增加特征数量的方法^[21]。按照表 2 所示特征的顺序（从上至下、从左至右），从单个特征开始，逐步增加特征数量，每次增加一个特征，直到涵盖所有特征。每种特征组合都被用于执行基于像素的随机森林分类任务，以此来模拟并观察特征数量变化对分类结果的影响。每次分类的 Kappa 系数被计算出来，作为评估分类准确度的关键指标。

通过对 Kappa 系数与特征数量之间的关系进行分析，

发现二者之间存在一定的关联。在特征数量较少时，随着特征逐渐增加，Kappa 系数呈现出显著的正相关关系。这表明在特征较少的初期阶段，每增加一个特征值都可能显著提升分类的精度，因为新加入的特征为模型提供了额外有用的信息，增强了分类器的判别能力。然而，随着特征数量的增加，这种正相关关系开始变得不那么明显。当特征数量达到 207 时，Kappa 系数达到其最大值 0.9049。而在特征数量为 25 时，Kappa 系数达到了一个局部最优值 0.8689。当特征数量增至全部的 208 个时，Kappa 系数略有下降，降至 0.9047。如图 4 所示，当特征数量达到一定程度后，可能出现了一定程度的冗余或过拟合现象，导致分类器在处理更多特征时效率下降。

实验表明在特征选择过程中要注意平衡性，既要选择足够的特征以提供必要信息，又要避免过多的特征导致的效率下降或过拟合，以达到分类精度的最优化。通过筛选出最具代表性和信息丰富的特征，能够有效减少模型处理的数据量，从而降低计算机算力的负担。这样的优选框架有助于避免模型处理不必要或冗余信息，预防过拟合的风险，并提高模型对关键特征的响应灵敏度。




图 3 kappa 值与特征相关性绝对值的关系

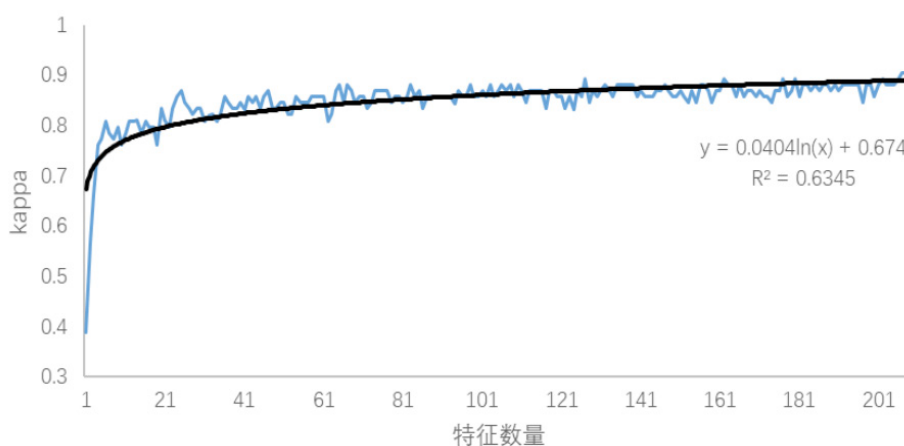


图 4 kappa 值与特征数量的关系

3.3 优选特征与分类精度

通过特征优化，精选了 BWDRVI、MSR、RI4X、ARI、VHA、MNLI、TCARIOSAVI、OCVI、VVA、kEVI、BAIM、TRRVI、WRI、MCARIOSAVI、PSRI、BRBA、NSDSI1、mND705、GARI、MCARI、SR3、TCARI、BAIS2 以及 BAI 这 24 个特征^[22]。这些特征因其高度的判别力和相关性而被选中，它们共同构成了一个高效且强大的特征集，确保了模型在处理复杂遥感数据时的高精度和高效

率。此外，这一特征集的 JM 平均值约为 2.00（见图 5），进一步佐证了特征优化框架的有效性。通过这一框架，自动化的提取了特征集，提高了分类的准确性。

优化后的特征集在研究区实现了 93.20% 的总体精度（Overall Accuracy, OA）和 0.917 的 Kappa 系数（图 6），优于 Tassi^[15] 在同一区域采用随机森林像元分类方法所获得的 82% 的 OA，也超过了其基于随机森林对象分类的 89.3% 的 OA。




图 5 优化特征集 JM 热力图




图 6 研究区分类与影像图

4 讨论

本研究基于 Google Earth Engine (GEE) 平台, 通过结合杰弗里-默特里斯 (Jeffries-Matusita, JM) 距离与相关系数, 构建了一个高效的自动化特征优化框架, 显著提升了土地利用分类任务的性能^[23]。这一研究成果不仅为遥感数据的特征选择和分类精度提升提供了新的方法支持, 也展示了 GEE 平台在处理大规模地理空间数据方面的强大潜力。

通过实证量化了 JM 距离与土地覆盖分类精度的耦合关系, 发现 JM 平均值与 Kappa 系数之间存在显著的正相关关系 (相关系数为 0.53)。这一发现与 Sen et al. 的研究相呼应, 他们同样指出 JM 距离可以作为特征选择的有效工具^[5]。本研究进一步证实了 JM 距离在评估特征可分离性方面的可靠性, 并通过动态 JM 阈值初筛高分度特征, 有效解决了维度灾难问题。这种基于 JM 距离的特征初筛方法, 不仅降低了特征维度, 还提高了分类精度和计算效率。

在特征优化过程中结合了相关性分析, 通过剔除高度相关的特征, 降低了多重共线性的风险, 提高了模型的稳定性和解释性。这一做法与 Jeon and Oh 提出的 Hybrid-Recursive Feature Elimination (H-RFE) 方法中的相关性分析步骤相似^[6]。本研究的方法更加自动化和高效, 通过构建“JM 距离初筛 + 相关性精筛”的双阶段框架, 实现了特征集的快速优化。这种结合 JM 距离和相关系数的特征优化方法, 不仅提升了遥感图像分类的精度, 还增强了模型的解释能力和计算效率。

本研究提出的基于 GEE 平台的自动化特征优化框架^[24], 为遥感数据的特征选择和分类精度提升提供了有效的解决方案。通过实证分析和与前人研究的对比, 验证了该框架的有效性和可靠性。未来, 可以进一步探索该框架在不同地区和不同遥感数据源上的适用性, 以及与其他特征选择方法的结合使用, 以推动遥感分类技术的不断发展。

5 结语

本研究基于 GEE 平台构建了一种结合概率距离和相关系数的特征优化框架。通过该框架在研究区执行的土地利用分类实验取得了显著的成果。实验证明即使是应用基础分类算法, 通过优化特征, 获得更好的数据集, 也能显著提高分类精度。此外, 还成功构建了一套简单实用的自动化特征优化框架, 不仅有效解决了特征选择的难题, 提高了遥感图像分类精度和计算效率。优化后的特征集不仅提升了遥感图像分类的精度, 还增强了计算效率和模型的解释能力。因此, 本研究证明了通过构建自动化的特征优选框架, 在 GEE 平台上可以实现更高效、更准确的数据分析。

参考文献

[1] Gong, P., Liu, H., Zhang, M., et al. (2019). Stable classification with limited sample: transferring a 30-m resolution sample set collected in 2015 to mapping 10-m resolution global land cover in

2017. *Science Bulletin*, 64(18), 1354-1361.

- [2] Gao W, Hu L, Zhang P, et al. Feature selection considering the composition of feature relevancy[J]. *Pattern Recognition Letters*, 2018, 112: 70-74.
- [3] Kuzudisli C, Bakir-Gungor B, Bulut N, et al. Review of feature selection approaches based on grouping of features[J]. *PeerJ*, 2023, 11: e15666.
- [4] Tateishi, R., & Oh, J. H. (2019). Global-scale land cover mapping using satellite imagery: A review and future perspectives. *ISPRS Journal of Photogrammetry and Remote Sensing*, 154, 120-135.
- [5] Sen R, Goswami S, Chakraborty B. Jeffries-Matusita distance as a tool for feature selection[C]//2019 International Conference on Data Science and Engineering (ICDSE). 2019: 15-20.
- [6] Jeon H, Oh S. Hybrid-Recursive Feature Elimination for Efficient Feature Selection[J]. *Applied Sciences*, 2020, 10(9): 3211.
- [7] Somers B, Asner G P. Multi-temporal hyperspectral mixture analysis and feature selection for invasive species mapping in rainforests[J]. *Remote Sensing of Environment*, 2013, 136: 14-27.
- [8] Hu Q, Sulla-Menasse D, Xu B, et al. A phenology-based spectral and temporal feature selection method for crop mapping from satellite time series[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2019, 80: 218-229.
- [9] Chen L, Jin Z, Michishita R, et al. Dynamic monitoring of wetland cover changes using time-series remote sensing imagery[J]. *Ecological Informatics*, 2014, 24: 17-26.
- [10] Arvor D, Jonathan M, Meirelles M S P, et al. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil[J]. *International Journal of Remote Sensing*, 2011, 32(22): 7847-7871.
- [11] Xu F, Xu Z, Xu C, et al. Automatic Extraction of the Spatial Distribution of *Picea schrenkiana* in the Tianshan Mountains Based on Google Earth Engine and the Jeffries-Matusita Distance[J]. *Forests*, 2023, 14(7): 1373.
- [12] 宁晓刚, 常文涛, 王浩, 等. 联合GEE与多源遥感数据的黑龙江流域沼泽湿地信息提取[J]. *遥感学报*, 2022, 26(2): 386-396.
- [13] Taheri Dehkordi A, Valadan Zoj M J, Ghasemi H, et al. Monitoring Long-Term Spatiotemporal Changes in Iran Surface Waters Using Landsat Imagery[J]. *Remote Sensing*, 2022, 14(18): 4491.
- [14] 朱梦豪. 基于时序遥感影像多特征优选的作物分类方法[D]. 河南理工大学, 2021.
- [15] Tassi A, Vizzari M. Object-Oriented LULC Classification in Google Earth Engine Combining SNIC, GLCM, and Machine Learning Algorithms[J]. *Remote Sensing*, 2020, 12(22): 3776.
- [16] Dabboor M, Howell S, Shokr M, et al. The Jeffries-Matusita distance for the case of complex Wishart distribution as a

- separability criterion for fully polarimetric SAR data[J]. International Journal of Remote Sensing, 2014, 35(19): 6859-6873.
- [17] Swain, P. H., & Davis, S. M. (1978). Remote sensing for agriculture: The use of the Jeffries-Matusita distance for the selection of discriminant features for the classification of agricultural crops. IEEE Transactions on Geoscience and Remote Sensing, 16(3), 161-167.
- [18] Benesty J, Chen J, Huang Y, et al. Pearson Correlation Coefficient[M]//Cohen I, Huang Y, Chen J, et al. Noise Reduction in Speech Processing: Vol. 2. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009: 1-4.
- [19] Breiman L. Random Forests[J]. Machine Learning, 2001, 45(1): 5-32.
- [20] Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random Forests for land cover classification. Pattern Recognition Letters, 27(4), 294-300.
- [21] Waske, B., & van der Linden, S. (2010). Classifying multispectral and hyperspectral data using feature extraction and feature selection methods. ISPRS Journal of Photogrammetry and Remote Sensing, 65(3), 257-272.
- [22] Guo, J., Liu, X., Du, S., et al. (2018). Feature selection for classification of hyperspectral imagery using improved ReliefF and particle swarm optimization. Remote Sensing, 10(6), 906.
- [23] Verrelst, J., Camps-Valls, G., Muñoz-Marí, J., et al. (2019). Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties—A review. ISPRS Journal of Photogrammetry and Remote Sensing, 150, 98-117.
- [24] Hansch, R., & Menz, G. (2020). Precision agriculture and digital farming: Concepts, challenges, and future trends. Agriculture, 10(4), 143.