

摘要

为了解鄱阳湖冬季栖息地类型的长期变化特征,探讨鄱阳湖冬季栖息地景观景观变化的驱动因素,本次研究利用 1990-2021 年的 18 张 Landsat 5 TM 和 Landsat 8 OLI 的 L2A 级无云影像提取鄱阳湖冬季栖息地景观类型。并对比了随机森林、支持向量机、梯度提升树和分类与回归树等这四种机器学习算法及卷积神经网络算法的分类精度。运用 NDVI、MNDWI、NDBI 和 EVI 来识别栖息地景观类型。通过制作转移矩阵来描述各种景观类型的转换情况并进行景观格局指数分析。结果表明:

(1) 随机森林、支持向量机、梯度提升树和分类与回归树这四种机器学习算法的总体分类准确率均在 98 % 以上, Kappa 系数均大于 0.98。在这四种机器学习算法中,随机森林算法分类性能最好。基于上述的研究,利用随机森林和卷积神经网络对鄱阳湖生态经济区进行分类后发现,卷积神经网络的分类精度高于随机森林,训练集的精度均在 99 % 以上且波动较小。

(2) 采用随机森林算法对 1990-2021 年的 Landsat 遥感影像进行鄱阳湖冬季栖息地景观分类,并根据 1990-2021 年鄱阳湖冬季栖息地景观类型的百分比图和 1990-2021 年的面积变化图发现,鄱阳湖在冬季水面面积缩小时,泥滩是该时期的主要栖息地景观类型。

(3) 根据 1990-2021 年鄱阳湖冬季栖息地景观类型的分类专题图发现:草洲一般出现在泥滩周围,沙地主要分布在鄱阳湖主河道附近。鄱阳湖周边耕地主要分布在研究区东南部,在 1998-2004 年间耕地面积呈下降趋势,这可能与“退耕还湖”的地方政策有关。

(4) 为了揭示三峡大坝对鄱阳湖生态环境的影响,对建坝前后的鄱阳湖栖息地景观类型进行了对比研究。通过转移矩阵的分析,发现建坝前的泥滩面积大幅增加,而建坝后更多的泥滩转化为草地。总体上,建坝后泥滩面积较建坝前有所减少。

(5) 分析了 1990-2021 年的景观格局指数变化。1990-1997 年景观斑块密度呈逐年波动趋势,表明鄱阳湖冬季栖息地类型进一步分散。而 1997-2021 年,景观斑块密度和景观干扰指数均呈下降趋势,景观聚集指数呈上升趋势,表明栖息地的完整性已经恢复。

(6) 通过研究不同年份的水位差异对鄱阳湖栖息地景观分类结果的影响,发现水域面积的长期变化与水位变化并不一致。这表明本研究分类结果的水域面积变化不太可能是由水位变化引起的,即水位不是影响鄱阳湖不同栖息地景观类型变化的主要因素。

关键词：鄱阳湖；栖息地；机器学习；卷积神经网络；景观指数

Abstract

In order to obtain the long-term evolution of winter habitat and explore the driving force in Poyang Lake, we use Landsat satellite imagery from 1990 to 2021 to systematically assess habitat characteristic changes over the past decades. Four machine learning methods including random forest, gradient boosting tree, support vector machine and classification and regression trees and convolutional neural network are analyzed by comparing the overall accuracy and Kappa coefficients. NDVI (Normalized Difference Vegetation), MNDWI (Modified Normalized Difference Water Index), NDBI (Normalized Difference Building Index), and EVI (Enhanced Vegetation Index) are used to identify habitat types. We use the land type transfer matrix to describe the land change. The landscape index was analyzed in the Fragstats and ArcGIS. The results showed that:

(1) The overall classification accuracy of the four machine learning algorithms, Random Forest, Support Vector Machine, Gradient Boosting Tree, and Classification and Regression Tree, is above 98 %, and the Kappa coefficients are all greater than 0.98. Among these four algorithms, Random Forest algorithm demonstrates the best classification performance. Based on the aforementioned research, it was discovered that the Convolutional Neural Network achieves higher classification accuracy than Random Forest when applied to classify the ecological and economic area of Poyang Lake. The accuracy on the training set remains above 99 % with minimal fluctuations.

(2) The Random Forest algorithm was employed to classify the winter habitat in Poyang Lake using Landsat remote sensing images from 1990 to 2021. Based on the percentage map of winter habitat types and the area change map from 1990 to 2021, it was found that during periods of reduced water surface area in winter, mudflats were the predominant habitat type.

(3) According to the thematic map of winter habitat types in Poyang Lake from 1990 to 2021, it was observed that grasslands generally appear surrounding mudflats, while sandy areas are primarily distributed near the main river channel of Poyang Lake. Cultivated land surrounding Poyang Lake is mainly concentrated in the southeastern part of the study area, and there was a declining trend in the cultivated land area from 1998 to 2004, which may be associated with the local policy of “returning farmland to lake”.

(4) In order to reveal the impact of the Three Gorges Dam on the ecological

environment of Poyang Lake, a comparative study was conducted on the habitat types of Poyang Lake before and after dam construction. Through the analysis of land use transition matrices, it was found that the mudflat area significantly increased before dam construction during 1990-2002, while more mudflats were converted into grasslands after the dam construction. Overall, the mudflat area decreased after the dam construction compared to before.

(5) The changes in landscape pattern indices from 1990 to 2021 were analyzed. The landscape patch density showed a fluctuating trend from 1990 to 1997, indicating further dispersion of winter habitat types in Poyang Lake. However, from 1997 to 2021, both the landscape patch density and landscape disturbance index exhibited a declining trend, while the landscape aggregation index showed an increasing trend, indicating the recovery of habitat integrity since 1997-1998.

(6) By studying the influence of water level variations on the classification results of Poyang Lake habitats in different years, it was found that the long-term changes in water surface area did not align with water level variations. This suggests that the water surface area changes in the classification results of this study are unlikely to be primarily influenced by water level fluctuations, indicating that water level is not the main factor affecting the variation of different habitat types in Poyang Lake.

Key words: Poyang Lake; habitat; machine learning; Convolutional Neural Network; landscape index

目 录

摘 要.....	I
Abstract	III
目 录.....	V
第 1 章 绪论	7
1.1 研究背景和意义.....	7
1.2 国内外研究现状.....	8
1.2.1 传统遥感图像分类研究进展.....	8
1.2.2 深度学习遥感图像分类研究进展.....	10
1.2.3 鄱阳湖研究现状.....	10
1.3 研究目标及内容.....	11
1.3.1 研究目标.....	11
1.3.2 研究内容.....	11
1.4 技术路线.....	11
1.5 论文的结构安排.....	13
第 2 章 研究区概况与研究方案	14
2.1 研究区概况.....	14
2.2 研究方案.....	15
2.2.1 遥感影像数据.....	15
2.2.2 遥感技术简介.....	16
2.2.3 遥感影像预处理.....	17
2.3 分类算法.....	17
2.3.1 非监督分类算法.....	18
2.3.2 监督分类算法.....	19
2.3.3 卷积神经网络分类算法.....	21
第 3 章 基于机器学习的鄱阳湖栖息地分类研究	24
3.1 光谱指数.....	24
3.2 分类精度评价方法.....	25
3.3 精度对比及结果分析.....	25
3.3.1 分类精度比较.....	25
3.3.2 栖息地类型的长期变化.....	27
3.3.3 鄱阳湖生态经济区栖息地变化.....	34
3.4 本章小结.....	36
第 4 章 鄱阳湖栖息地景观格局演变研究	37
4.1 景观格局指数.....	37
4.2 栖息地景观格局的演变.....	37
4.3 讨论水位对景观格局演变的影响.....	41
4.4 本章小结.....	43
第 5 章 结论与展望	44
5.1 结论.....	44

5.2 不足与展望.....	45
参考文献	46
致 谢.....	56
在读期间公开发表论文（著）及科研情况	58

第 1 章 绪论

1.1 研究背景和意义

鄱阳湖是中国最大的淡水湖。湖泊水位受东亚季风影响,呈现明显的季节变化^[1]。在雨季(4-9月),湖泊水位上升,鄱阳湖面积达 3000 km²^[2];在旱季(10月到次年3月),湖水水位显著下降,部分湖底出现,形成许多相互不连接的盘状湖,整个湖面面积缩小到 1000 km²^[3]。随着鄱阳湖水位的下降,出现了大面积的湿地和其它栖息地类型,构成了白鹤等越冬候鸟和其它野生动物的重要栖息地^[1,4],使得鄱阳湖具有丰富的生物多样性,并提高了该湖在生态保护方面的重要性^[5-6]。

栖息地条件受到自然因素和人类活动的共同影响^[7]。对土地进行广泛开发利用可能会对生态环境造成重大负担^[8-9]。景观格局是量化栖息地健康状况的重要参数,主要由景观异质性和景观多样性决定^[10]。栖息地退化会影响景观格局并导致景观破碎化^[11]。景观格局分析可用于描述和解释相关土地类型变化过程^[12-13]。

利用遥感方法获取的卫星影像数据已成为研究土地类型和栖息地特征的重要数据来源。遥感是在远离目标和非接触目标条件下利用电磁波探测目标地物的技术。遥感技术具有能够进行大规模同步观测、获取信息的速度快及周期短、不受地面条件限制等特点,为土地覆被类型的空间分布信息提取提供了可靠的技术手段。近年来,随着科技的进步,遥感技术呈现飞速发展的态势,可获取到的遥感影像数量与日俱增。这些影像数据在各行各业都发挥着不同的作用。例如,在农业方面,利用遥感技术监测农作物种植面积、根据农作物长势信息估算农作物产量,监测和分析粮食供应数量^[14]。

传统遥感图像分类方法是基于光谱、纹理等特征对图像进行分类。由于高分辨率遥感图像呈现的地表物体信息越来越精细,导致同类地物的类内差异和不同地物的类间相似性都发生了显著的增加,同时光谱特性的冗余性和研究尺度的变化等都给遥感解译带来了严峻的挑战^[15]。相对于传统遥感图像分类方法,深度学习理论的快速发展为遥感图像分类提供了新的解译思路。深度学习的多层结构与人类大脑皮层信息处理机制相类似,神经网络中包含了大量的隐层神经元。这些神经元可根据输入输出数据,隐层学习它们之间的映射关系,实现从海量的输入数据中挖掘出深层次抽象特征,在诸多领域取得很好的表现^[16-21]。近年来,卷积神经网络技术在图像分类上取得了很好的效果。

鄱阳湖具有随季节变化的独特水文特征,导致鄱阳湖湿地拥有丰富的植被、

泥滩等生物资源。鄱阳湖湿地的浅水、草地和松软的泥滩地区是西伯利亚鹤越冬的理想栖息地。近年来，鄱阳湖水位异常低，导致栖息地类型发生变化，这严重影响了西伯利亚鹤的主要食物来源和栖息地^[22-24]。西伯利亚鹤是全球极度濒危物种，在全球范围内，这个物种可以分为三个种群。最大的种群是在西伯利亚东北部繁殖的东部种群^[25]。这个东部种群占全球种群的 98 % 以上，主要在中国长江流域的鄱阳湖越冬^[26]。此外，鄱阳湖湿地的水文过程也因人类活动发生了变化，如防洪、水电、灌溉、水产养殖、水利工程等^[27-29]。

目前，对鄱阳湖地区的栖息地变化及原因分析研究较少，也不清楚水位的变化对栖息地变化是否存在影响。因此，研究鄱阳湖冬季栖息地特征及其景观格局对了解鄱阳湖生态系统的变化具有重要意义。本研究意在寻求一种最佳的机器学习方法，从 Landsat 卫星图像中获取鄱阳湖冬季栖息地景观类型和计算景观格局指数，并通过分析栖息地景观类型和景观格局指数的长期变化，揭示了它们对不同因子的响应。

1.2 国内外研究现状

1.2.1 传统遥感图像分类研究进展

利用遥感影像对土地覆盖进行分类，并进一步提高土地覆盖分类的精度和效率是一直在研究的问题。它通过区分影像中所有像元的不同特征从而将其划分为不同类别，然后对分类结果进一步分析后获得所有土地类别的信息^[30]。传统的遥感影像分类方法分为监督分类方法和非监督分类方法。常用的监督分类算法有支持向量机、人工神经网络、决策树、随机森林和面向对象分类等，非监督分类算法有 K-means、ISODATA 和主成分分析法等。

(1) 非监督分类算法研究进展

遥感影像中的非监督分类算法是指人们在对遥感影像进行分类之前不依靠任何的先验知识，只是根据遥感影像不同地物的光谱特征分布规律对其特征值进行分类^[31]。李寄等（2008）利用非监督分类方法并结合 MODIS-NDVI 数据提取湖北省的冬小麦种植面积并进行遥感估算^[32]。赵丽花等（2011）综合利用非监督分类和监督分类方法对江苏省姜堰市的冬小麦种植面积进行分类，分析结果可知，总体面积提取精度达到 90.22 %^[33]。Wang 等（2014）基于影像光谱特征的不同阶段结构，结合影像光谱特征提出了一种基于迭代自组织（ISODATA）的改进算法，发现该算法在高光谱遥感影像上比 SAM 算法具有更好的分类性能^[34]。樊利恒等（2014）通过修正数据分布的方式改进最大似然分类方法，提高了数据模型的正确性，有效区分了玉米、大豆、小麦等作物^[35]。周林飞等（2015）基于 Landsat 8 遥感影像数据利用最大似然法进行土地类型分类的研究^[36]。范应龙等（2015）利用决策树分类算法对热带森林覆盖变化信息进行分类，其结果表明 MKT 差值、

干扰指数差值结合决策树都能检测出森林内部的细微变化^[37]。赵洁(2016)基于三种相似性度量的 K 均值的分类方法对高光谱遥感影像进行分类研究, 研究表明, 基于欧式距离的 K 均值分类结果效率最高、精度最高^[38]。廖东等(2019)基于 Landsat 8 遥感影像利用最大似然和 ISODATA 分类法对宿州市埇桥区遥感影像进行处理, 通过结果可知, 监督分类比非监督分类的精度更高、分类效果更好, 但非监督分类不需要先验知识, 分类速度更快^[39]。王冬利等(2019)利用非监督分类算法对 2014 和 2015 年辛集市冬小麦种植信息进行提取, 得到的制图精度和用户精度分别为 94.23 %-96.64 % 和 92.31 %-95.45 %^[40]。Li 等(2022)采用最近邻法将鄱阳湖栖息地区划分为森林、草地、农田、建设用地和未利用地这五种类型^[41]。

(2) 监督分类算法研究进展

近年来, 支持向量机、分类和回归树、梯度提升树和随机森林等各种机器学习算法已被应用于分析来自不同遥感数据源的土地利用类型。这些机器学习算法已被证明在土地类型分类中比传统的非监督分类算法表现更好。

Pal 等(2008)利用支持向量机、神经网络和最大似然分类器等三种机器学习分类器对土地覆盖进行分类, 其结果表明支持向量机分类方法的精度更好^[42]。Shao 等(2012)对支持向量机、神经网络和分类和回归树等三种机器学习算法进行比较, 结果表明支持向量机优于其他分类器, 且在训练样本量较小的情况下效果更佳^[43]。Jia 等(2014)利用不同的分类器进行土地覆盖分类, 发现支持向量机比传统的最大似然分类器具有更好的分类精度^[44]。Wang 等(2013)利用支持向量机的分类方法对遥感对象的信息特征进行提取, 然后再根据提取的信息对遥感影像进行反演^[45]。后斌等(2008)利用不同的遥感影像分类方法对遥感数据集进行分类实验, 通过分析结果发现, 支持向量机分类方法的分类精度优于其他分类方法^[46]。Sergi 等(2007)将神经网络和 K 近邻算法分别应用于农作物提取, 实验结果表明神经网络的分类效果更好^[47]。王利军等(2018)集合决策树分类方法和 SVM 分类方法实现秋季主要作物种植面积遥感提取, 较好地减少了小尺度地物提取不全和“椒盐”现象等问题的出现, 与只采用单一方法相比, 这能够有效提高作物的分类精度^[48]。王娜等(2017)利用单变量特征选择方法提取用于分类的特征, 然后利用随机森林分类方法对试验区主要农作物进行识别和提取, 不仅降低特征维度, 而且保证了较高的分类精度^[49]。

上述监督分类算法都需要人工目视解译根据不同土地利用类型的特征选取样本点, 而不同的特征对于区分不同的土地类型所起的作用不同, 所占的权重也会有所差别。权重的分配主要依靠人工经验, 而不同的权重分配可能直接影响到后续的提取结果。虽然非监督分类算法不需要人为选择特征, 但是这些方法没有选用训练样本, 无先验信息, 分类精度低^[50]。因此, 监督分类算法和非监督分类算法都存在一定的局限性。

1.2.2 深度学习遥感图像分类研究进展

近年来,随着卷积神经网络技术在图像处理方面表现突出,越来越多的学者将 CNN 应用于土地利用类型的提取上。卷积神经网络设计用于识别和提取二维图像的特征,其特有的二维卷积核特别适用于提取二维特征以形成二维特征向量矩阵^[51]。因此,其主要应用于遥感图像在内的图像识别、分割、分类等。

目前已有很多研究利用卷积神经网络对图像进行处理。遥感影像土地利用类型的提取问题的实质是遥感影像分类。Zhang 等(2018)利用已经训练好的神经网络对多时相 Landsat8 数据进行分类,从而实现水稻空间分布信息的提取^[52]。焦计晗等(2018)利用改进的 Alex-Net 模型对油菜种植面积进行提取,并在改进的模型中加入 dropout,实验结果证明加入 dropout 有利于提高分类精度^[53]。随着 U-Net 等语义分割模型的出现,基于卷积神经网络的作物提取精度明显提高。马永建等(2021)基于高分一号遥感影像使用 U-Net 模型并结合植被指数和纹理指数进行耕地提取,精度最高达 92.31%^[54]。Xu 等(2020)提出了一种高分辨率 U-Net 模型用于耕地提取,其在 Landsat 影像上提取的精度达到 92.81 %^[55]。Kussul 等(2017)使用 Landsat 8 和 Sentinel-1A 多时相影像数据,利用卷积神经网络模型进行农作物提取,与多层感知器、随机森林方法相比,该方法能够更好的区分作物类型^[56]。Zhong 等(2019)使用 Landsat 增强植被指数时间序列数据,利用卷积神经网络对夏季作物进行分类,结果表明该方法优于随机森林、支持向量机的提取结果^[57]。Zhang 等(2020)基于高分二号遥感影像结合改进的 PSP-Net 模型进行耕地提取,该模型结合了高低层特征来提高耕地提取精度,精度最高达 92.31 %^[58]。魏青迪等(2020)利用改进的 ECL-Deeplab 模型对高分二号遥感影像进行耕地提取,提取精度达到 88.3 %^[59]。

基于卷积神经网络方法的遥感影像分类在很多分类任务中表现良好,因此本文利用卷积神经网络对鄱阳湖湿地进行分类。在分类的过程中,为了得到较好的分类结果,会对 U-Net 网络进行微调。最后将卷积神经网络的分类结果与机器学习算法得到的结果进行对比分析。

1.2.3 鄱阳湖研究现状

鄱阳湖是中国最大的淡水湖泊,具有为周边工业和农业提供灌溉用水、提供周边居民日常生活用水、繁衍水生生物及改善区域环境等多种功能。同时,鄱阳湖是越冬候鸟的栖息地,候鸟不仅种类多、数量大,而且具有大量国内外少有的珍稀濒危种类^[60]。其丰枯期的水文节律则造就出多样化的栖息地,为越冬候鸟提供了丰富的食物资源和栖息地环境。

近几十年来,气候变化和人为因素显著影响了鄱阳湖栖息地,降低了鄱阳湖生态功能^[61-64],危及鄱阳湖越冬候鸟的生存环境^[65-66]。基于 InVEST 模型分析发现,1988-2018 年鄱阳湖生态经济区的快速城市化可能导致土地利用变化和栖息

地退化^[67]。鄱阳湖水域面积受温度、蒸发量、降雨量等自然因素的影响，同时受三峡工程等人为因素的影响，呈现小幅下降趋势^[68]。有人认为湖泊的长期收缩可能有利于湿地面积的增加，并改变鄱阳湖地区的栖息地条件^[69]。一种基于植被的 IBI 方法被用于评估鄱阳湖湿地生态状况，并对湿地整体健康状况进行分类，研究表明，制定相应的措施对湿地恢复和保护至关重要^[70]。Jiang 等（2014）利用六个景观指数对鄱阳湖自然湿地中西伯利亚鹤的潜在适宜栖息地区域进行评估，结果表明湖面水位在 12m 以上将对鄱阳湖湿地的西伯利亚鹤越冬栖息地造成不利的条件^[71]。Dong 等（2020）利用时间序列卫星遥感提取了 2000-2009 年鄱阳湖的湿地类型覆盖，结果显示水文波动对不同类型的湿地植被转换有不同程度的影响^[72]。

1.3 研究目标及内容

1.3.1 研究目标

在 GEE 上利用四种机器学习算法对鄱阳湖湖区景观类型进行分类，对比不同分类算法的精度；分析鄱阳湖栖息地景观类型的长期变化及导致变化的可能原因；描述鄱阳湖栖息地景观格局演变的规律；讨论鄱阳湖湖区的水位变化是否对鄱阳湖湖区的栖息地景观类型产生影响，这将为保护鄱阳湖湿地的多样性提供参考。

1.3.2 研究内容

利用机器学习算法和卷积神经网络算法对鄱阳湖地区进行分类，将鄱阳湖栖息地类型分为水体、草洲、泥滩、沙地、农田和其他（包括道路和建筑），同时将鄱阳湖生态经济区地物类型分为水体、植被、农田、建筑和其他（包括裸地、泥滩、道路等），然后基于分类结果进行精度对比，并分析导致湿地长期变化的可能原因和鄱阳湖栖息地景观格局演变的规律。

1.4 技术路线

本论文的框架如图 1-1 所示。

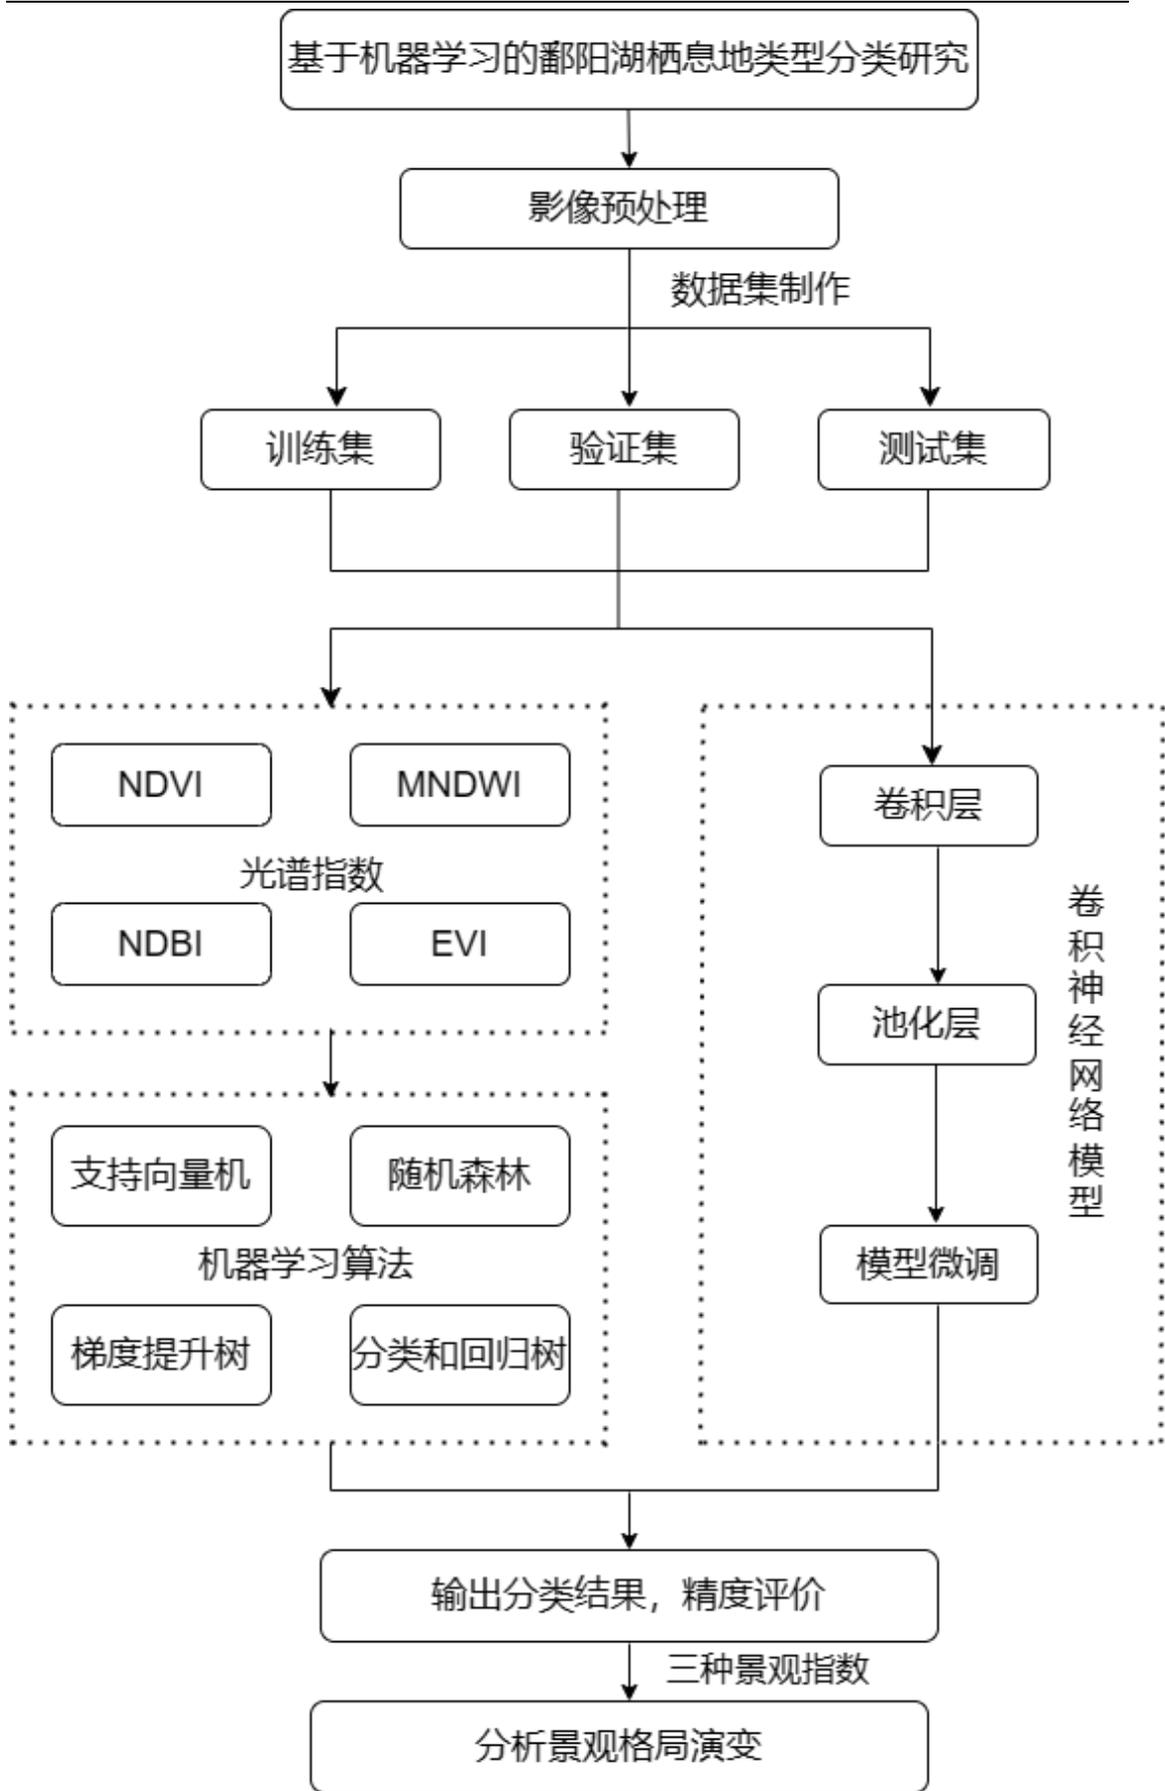


图 1-1 论文框架示意图

Fig.1-1 Schematic diagram of the framework of the paper

1.5 论文的结构安排

鄱阳湖是中国第一大淡水湖，具有调蓄水位、涵养水源、改善局部地区气候和维护生态平衡等方面的作用^[73]。因此本课题的主要研究内容是利用机器学习、卷积神经网络算法对鄱阳湖地区栖息地进行研究。本论文的组织架构包括五章节，具体内容如下：

第一章内容为绪论。主要对本文研究背景和遥感的相关知识进行介绍，阐述遥感影像分类的常用机器学习方法以及选择本文使用的深度学习方法。并对利用机器学习算法和卷积神经网络算法进行的国内外研究进展进行了简单的梳理。

第二章内容为研究区域与数据。主要介绍了研究区的基本概况以及本文所使用的研究数据、数据的预处理方法。

第三章内容为基于机器学习的鄱阳湖栖息地景观分类研究。首先是利用四种机器学习算法对鄱阳湖区进行分类并对精度，然后利用随机森林网络对 1990-2021 年的鄱阳湖区进行分类，并对分类结果进行分析。

第四章内容为鄱阳湖栖息地景观格局演变研究。利用 Fragstats 和 ArcGIS 软件制作鄱阳湖景观格局图并分析景观格局的演变，并讨论了影响景观格局演变的因素。

第五章内容为结论与展望。对本研究的研究结果进行总结，并分析本研究需要改进以及未来可加深研究的地方。

第 2 章 研究区概况与研究方案

2.1 研究区概况

鄱阳湖是中国最大的淡水湖，位于长江中游以南（ $28^{\circ} 22' - 29^{\circ} 45' N$ 和 $115^{\circ} 47' - 116^{\circ} 45' E$ ），是长江流域的一个过水性、吞吐型、季节性的重要湖泊，其流域面积为 $16.2 \times 10^4 \text{ km}^2$ 。鄱阳湖由南到北全长 173km，东西宽度不一，最宽处达 74km；湖体总面积约 3283 km^2 ，平均水深约 8.4m，容积约 276 亿 m^3 ^[74]。鄱阳湖湖水受饶河、修水、赣江、信江、抚河五条河流补给，五河流域面积为 16.22 万 km^2 ，占长江流域的 9%。同时在雨季的时候局部降水也是鄱阳湖重要的补给水源。鄱阳湖的水通过星子和湖口之间的一条相对狭窄的通道流入长江(图 2-1)。研究区域如图 2-1 所示，图中包括了鄱阳湖最大水面面积及周边有农田的区域和其他区域。这些区域构成了鄱阳湖地区冬季的主要栖息地，通过对该区域进行研究来揭示栖息地特征的长期变化。

鄱阳湖水系年均径流量为 1525 亿 m^3 ，约占长江流域年均径流量的 16.3%^[75]。“高水似湖，低水似河”、“洪水一片，枯水一线”是鄱阳湖的自然地理特征。鄱阳湖在调蓄水位、涵养水源、改善局地气候和维护生态平衡等方面都起着巨大的作用^[76]。经鄱阳湖的调节，赣江等支流的洪峰可减弱 15%-30%，同时也减轻了长江洪峰对沿岸的威胁^[77]。在秋冬季节由于入湖河流水量不足，鄱阳湖进入枯水期，形成“碧野无垠接天云”的广阔草洲。裸露的河滩与独立的碟形湖成为北方候鸟迁徙越冬的最佳之地。1992 年，鄱阳湖被列入“世界重要湿地名录”，主要保护对象为珍稀候鸟及湿地生态系统^[78]。如今，保护区内鸟类已达 300 多种，成为世界上最大的鸟类保护区。每年冬季来此越冬的白鹤数量占世界白鹤总数的 95% 以上，因此鄱阳湖被称为“白鹤的天堂，天鹅的故乡”。

鄱阳湖生态经济区，是以江西省鄱阳湖为核心，以鄱阳湖城市圈为依托，以保护生态、发展经济为重要战略构想的经济特区^[79]。国家把鄱阳湖生态经济区建设成为世界性生态文明与经济社会发展协调统一、人与自然和谐相处的生态经济示范区和中国低碳经济发展先行区^[80]。鄱阳湖生态经济区是环鄱阳湖地区，面积为 51200 km^2 ，人口数量为 2006.6 万人，包括南昌、九江、鹰潭、景德镇等经济大城市。鄱阳湖生态经济区是重要经济板块的直接腹地，同时也是中部地区正在快速形成的重要增长极，具有发展生态经济、促进生态与经济协调发展的良好条件^[81]。

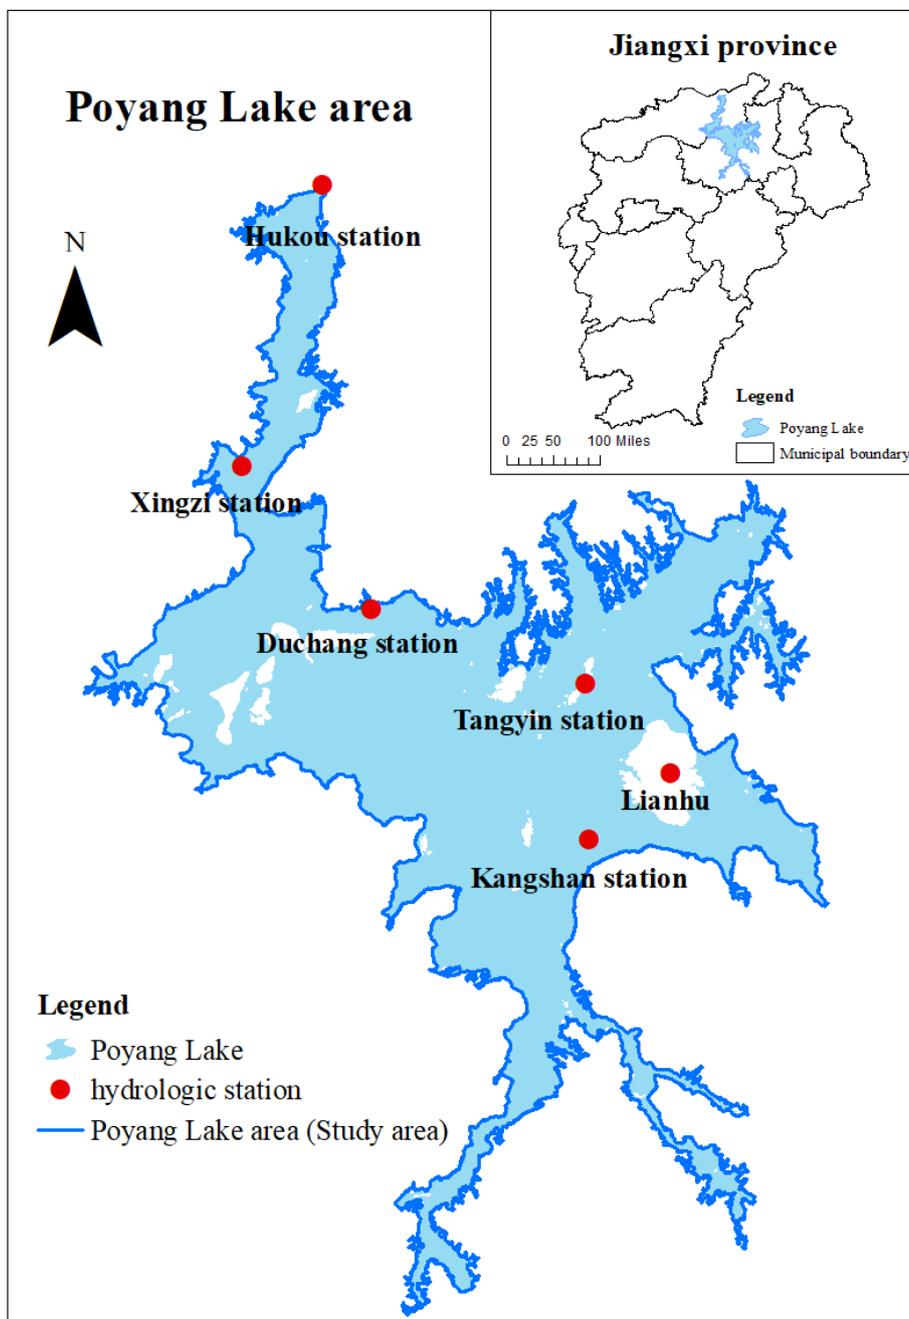


图 2-1 鄱阳湖的地理位置以及范围

Fig.2-1 The study area covering Poyang Lake and surrounding farmlands and other regions.

2.2 研究方案

2.2.1 遥感影像数据

本研究利用 1990-2021 年的 18 张 Landsat 5 TM 和 Landsat 8 OLI 的 L2A 级无云影像提取鄱阳湖冬季栖息地类型，如表 2-1 所示。Landsat 系列卫星是“地球

资源技术卫星”计划发射的卫星，它可以用于监测农作物长势、对农作物进行估产，考察和预报自然灾害以及制作各种专题地图。Landsat 8 OLI有8个空间分辨率为30m的波段和1个空间分辨率为15m的全色波段。Landsat 5 TM是由6个空间分辨率为30m的波段和1个空间分辨率为120m的波段组成。Landsat系列卫星的重访周期为16天。本研究所有陆地卫星图像都是从GEE(Google Earth Engine)平台获得的。

表 2-1 本研究使用的陆地卫星图像

Table 2-1 Landsat images used in this study

日期	遥感卫星	分辨率 (m)
1990.01.23	Landsat5 TM	30
1993.12.17	Landsat5 TM	30
1995.12.07	Landsat5 TM	30
1997.01.10	Landsat5 TM	30
1999.12.18	Landsat5 TM	30
2002.01.08	Landsat5 TM	30
2004.12.15	Landsat5 TM	30
2006.12.21	Landsat5 TM	30
2008.12.10	Landsat5 TM	30
2009.01.11	Landsat5 TM	30
2010.01.14	Landsat5 TM	30
2013.12.24	Landsat8 OLI	30
2015.01.13	Landsat8 OLI	30
2016.12.16	Landsat8 OLI	30
2017.12.19	Landsat8 OLI	30
2018.02.05	Landsat8 OLI	30
2019.01.23	Landsat8 OLI	30
2021.01.12	Landsat8 OLI	30

2.2.2 遥感技术及影像

遥感技术是根据电磁波理论应用各种传感器对远距离目标所辐射和反射的电磁波信息进行收集、处理，并在成像后对地面各种景观进行探测和识别的一种综合技术^[82-84]。它是从人造卫星、飞机或其他飞行器上收集地物目标的电磁辐射信息，判别地球环境和资源的技术^[85]。任何物体都具有不同的吸收、反射、辐射光谱的特性；即使是同一物体，由于太阳光照射角度不同，它们反射和吸收的光谱也各不相同^[86]，这就是所谓的“同物异谱，同谱异物”的现象。遥感技术就是

根据这些原理来对物体进行区分。

遥感按照辐射源分类,可分为被动遥感和主动遥感。靠太阳辐射和地物自身辐射作用的遥感称为被动遥感;雷达主动发射电磁波作为照射源的遥感称为主动遥感。光学遥感一般是靠太阳辐射和地物自身辐射作用的被动遥感。现在卫星影像的空间分辨率可以从千米级到米级,其时间分辨率从数十天到小时级,范围可以覆盖从几十公里到几千公里^[87]。相比主动成像数据,光学遥感影像虽然受到自然气候的影响,不能提供全天时、全天候的遥感影像,但自身仍有不可比拟的优势。常见的光学影像主要包括:全色影像、可见光影像以及多/高光谱影像等。

2.2.3 遥感影像预处理

在利用遥感影像前一般需要对遥感影像进行处理,主要包括重分类、影像增强、辐射校正和几何校正等处理^[88]。为达到某种应用目的,还需要对前期处理的遥感影像进行目标提取、影像分类、变化检测等数据处理。这三种数据处理方式的核心思想都是利用地物的特征差异性,通过某种变换或处理手段将不同特征点进行分离^[87]。地物的特征差异主要表现在光谱特征和空间特征上。

传感器接收地面目标电磁辐射能量时,受遥感传感器本身特性、大气作用以及地物光照等影响,致使遥感传感器探测值与地物实际光谱辐射值不一致、灰度失真,从而产生辐射畸变^[89]。辐射畸变产生后需要进行相应的辐射校正^[90]。完整的辐射校正包括:传感器校正、大气校正以及太阳高度和地形校正。(1) 传感器校正,是将传感器测量得到的测量值变换为绝对亮度值(绝对定标)或转换为与地表反射率、地面温度等物理量有关的相对值(相对定标)的处理过程。定标是遥感定量化的前提。(2) 大气校正。在卫星遥感成像过程中,由于大气散射和吸收的影响,主要是大气中水蒸气、氧气、二氧化碳、甲烷和臭氧等物质的存在,改变了传感器接收到的地表反射辐射能量,使传感器最终获得的地面目标的总辐射亮度与地表真实反射率并不相同,这会对遥感信息提取和参数反演的精度产生很大影响。大气校正的目的是为了消除大气散射、吸收、反射引起的误差,使影像能够真实反映对太阳光的辐射情况,从而能够精确识别地物^[91]。(3) 太阳高度和地形校正。是由于地球表面的变化而产生的。复杂地形下遥感影像受传感器方位与太阳高度、方位等影响,阳坡接收到的太阳辐射产生的亮度值高于阴坡^[92]。为了获得每个像元真实的光谱反射情况,经过传感器和大气校正的图像还需利用外部信息进行太阳高度和地形校正^[93]。地形校正是指通过各种变换,将所有像元的辐射亮度值变换到某一参考平面(通常取水平面),从而消除由于地形起伏而引起的影像辐射亮度值的变化,使影像更好地反映地物的光谱特征^[94]。

2.3 分类算法

遥感影像分类是利用计算机通过对遥感图像中各类地物的光谱信息和空间信息进行分析并选择特征,再利用一定的手段将特征空间划分为互不重叠的子空间,然后将图像中的各个像元划归到各个子空间去的过程^[95]。最简单的分类方法是只根据光谱亮度值进行分类,另一种分类方法则是在考虑亮度值的基础上还考虑像元之间的空间关系进行分类^[96]。显然后一种分类方式更加有效,但是自动化的难度也更大一些。分类的原理是根据光谱亮度值的集群将不同的像元归到不同的类别中去。传统的遥感图像分类方法有监督分类方法和非监督分类方法。

2.3.1 非监督分类算法

非监督分类也称为聚类分析,是在图像中搜寻、定义其自然相似光谱集群组的过程^[97]。非监督分类不需要选择训练样本,仅根据像元间特征变量的相似度大小进行聚类,由计算机按照一定的规则自动的根据像元光谱或空间特征组成集群组并分类^[98]。常见的非监督分类算法有 K-均值法、ISODATA 算法等。

1. K-均值算法

K-均值算法(K-means)是一种聚类分析算法,其主要通过不断地选取离种子点最近均值^[99]。算法的主要步骤是:首先,从数据中选择 K 个对象作为初始聚类中心;再计算每个样本与各个聚类中心之间的距离,把每个样本分配给距离它最近的聚类中心;再将新的聚类中心移动到这个聚类所有样本的平均值处;最后重复第二步,计算标准测度函数,直到达到最大迭代次数,聚类中心不再移动为止。在实际应用中,常常把误差平方和(Sum of Squared Errors, SSE)与轮廓系数(Silhouette Coefficient)结合使用来评估聚类模型的效果。其中,误差平方和越小,轮廓系数越大,聚类效果越好。K-均值算法作为一种非监督分类算法,具有以下优点:(1)原理简单,容易理解,实现方便,收敛速度快;(2)当簇近似高斯分布的时候,聚类效果较优;(3)模型的可解释性强;(4)调参只需要调 K 值,算法复杂度低;(5)在处理大数据集的时候,该算法可以保证较好的伸缩性。但它也存在一些不可避免的缺点:(1)K 值需要人为设定,但 K 值的选取不好把握,不同 K 值得到的结果不同;(2)算法对初始的簇中心敏感,不同选取方式会得到不同结果;(3)对太离散、样本类别不平衡和非凸形状的分类,其分类结果不理想。

2. ISODATA 算法

当面对高维度、海量的数据集时,K 的大小很难人为确定。而 ISODATA 算法(迭代自组织数据分析法)正好解决了 K 值需要人为预先设定这一缺点。迭代自组织聚类算法在 K-近邻方法的基础上,增加对聚类结果的合并和分裂这两个操作^[100],当聚类结果中某一类样本数太少、类间距离太近或样本类别过多时进行合并;当聚类结果中某一类样本数太多、类内差异太大或样本类别较少时进行分裂。迭代自组织算法分析数据的基本步骤是:(1)选取初始值。可人为选择或修改参数指标,从而将 N 个模式样本按指标分配到各个聚类中心中去;(2)计算各

类中诸样本的距离指标函数；(3) 根据给定的条件，将前一次获得的聚类集依次进行分裂和合并处理，从而获得新的聚类中心^[101]；(4) 重新进行迭代运算，计算各项指标，判断聚类结果是否符合要求。经过多次迭代后，若结果收敛，则运算结束。

2.3.2 监督分类算法

监督分类算法是用已经确认类别的像元去识别其他未知类别像元的过程^[102]。在这种分类中，首先选取一定数量的训练集，训练集需包含每一类分类的类别(训练集中的像元是已知类别的)，并利用计算机统计同一类别像元的信息，然后将未知类别的像元信息与已知类别信息进行比较，并将相似的类别归类。监督分类可分为两个基本步骤：选取训练样本和统计信息、选取分类方法^[103]。训练样本的选择是监督分类的关键，样本的选取有一些关键点：同一类别的训练样本必须是均质的，不能包含其他类别；大小、形状和位置必须能同时在图像和实地容易被识别和定位^[104]。

遥感监督分类常见算法有人工神经网络、随机森林、支持向量机、决策树和梯度提升树等。下面主要介绍下随机森林、支持向量机、梯度提升树和分类与回归树算法，本论文使用这四种方法进行遥感影像分类，并进行了一系列分析。

1. 随机森林

随机森林(Random Forest, RF)是用于分类、回归和其他任务的集成学习方法^[105]，其通过在训练时构建多个决策树并输出作为类的模式(分类)或平均预测(回归)的类来操作个别树木。随机森林算法被广泛用于解决环境问题，如水资源管理和自然灾害管理^[106]。它可以处理各种数据，如卫星图像和数字数据。算法的具体步骤为：假设有一个大小为 N 的训练数据集，每次从该数据集中有放回的选取大小为 M 的子数据集，一共选 K 次，根据这 K 个子数据集，训练学习出 K 个模型^[107]。当要预测的时候，使用这 K 个模型进行预测，再通过取平均值或者多数分类的方式，得到最后的预测结果。随机森林可以运用在很多地方，如对离散值的分类、对连续值的回归、无监督学习聚类和异常点检测等。

随机森林算法具有很多优点：(1) 可以得到很高维度(特征很多)的数据，并且不用降维，无需做特征选择^[108]；(2) 可以判断特征的重要程度并判断出不同特征之间的相互影响；(3) 对于不平衡的数据集来说，可以平衡误差；(4) 如果有很大一部分的特征遗失，仍可以维持准确度。实现起来比较简单，训练速度比较快，不容易过拟合。正是因为随机森林算法有这么多优点，所以随机森林算法的表现更好。但是它仍然存在一些缺点：(1) 在某些噪声较大的分类或者回归任务中会存在过拟合现象^[109]；(2) 对于有不同取值的属性数据，随机森林对这种数据处理后产出的属性权值不可信。

2. 支持向量机

支持向量机 (Support Vector Machine, SVM) 就是一种二分类模型, 它的基本模型是定义在特征空间上的间隔最大的线性分类器, 间隔最大使它有别于感知机^[110]。SVM 还包括核技巧, 这使它成为实质上的非线性分类器^[111]。支持向量机的学习策略就是间隔最大化, 可形式化为一个求解凸二次规划的问题, 也等价于正则化的合页损失函数的最小化问题^[112]。支持向量机的目的是找到最优边界, 使支持向量之间的分离或边界最大化^[113]。所以支持向量机只关注在特定空间中最接近类间最佳边界的训练样本。支持向量机最初被设计用于识别线性类边界 (即超平面), 它是在分类与回归任务中分析数据的监督式学习模型^[114]。给定一组训练实例, 每个训练实例被标记为属于两个类别中的其中一个, 然后训练算法创建一个将新的实例分配给两个类别之一的模型, 使其成为非概率二元线性分类器^[115]。支持向量机模型是将实例表示为空间中的点, 这样映射就使得单独类别的实例被尽可能明显的间隔分开^[116]。然后, 将新的实例映射到同一空间, 并基于它们落在间隔的那一侧来预测所属类别^[117]。通过将特征空间投影到更高维度, 在假设高维特征空间中可能不存在线性边界的情况下, 解决了超平面的限制。这种向更高维度的投影被称为核技巧。在遥感中常用的核是多项式核和径向基函数核。支持向量机需要一个适当的核函数来准确地建立超平面并使分类误差最小化。支持向量机的主要功能取决于核的大小, 而光滑表面的相似性则取决于更重要的核密度。

支持向量机的优点有: (1) 对异常值有较好的鲁棒性; (2) 在高维空间中具有较强的分类性能; (3) 可以有效地处理大规模的数据; (4) 支持在线学习和内存有限的学习。但支持向量机也存在以下的缺点: (1) 训练慢, 特别是在大规模数据集上; (2) 对于数据的选择和核函数的选择非常敏感; (3) 对于大量数据和高维数据, SVM 容易出现过拟合现象。但是相对而言, SVM 仍然在许多分类任务中表现很好。此外, SVM 还有一个强大的特性, 即引入了惩罚项, 可以对误分类的样本点进行惩罚, 提高分类准确率。SVM 在实际应用中经常采用二次规划算法求解。需要注意的是, 在使用 SVM 模型时, 需要对数据进行预处理, 以确保数据具有线性可分性或线性不可分性。此外, 还需要考虑选择合适的核函数, 并对模型进行调参, 以获得最佳的分类效果。

3. 梯度提升树

梯度提升树 (Gradient Boosting Decision Tree, GBDT) 是一种迭代的决策树算法, 该算法由多棵决策树组成, 所有树的结论累加起来做最终答案^[118]。梯度提升树的思想使其具有天然优势可以发现多种有区分性的特征以及特征组合^[119]。梯度提升树是将残差计算替换成了损失函数的梯度方向, 将上一次的预测结果带入梯度中求出本轮的训练数据^[120]。梯度提升树中的树是回归树 (不是分类树), 其可用来做回归预测, 调整后也可以用于分类^[119]。梯度提升树的优点有: (1) 可以灵活处理各种类型的数据, 包括连续值和离散值; (2) 相对 SVM, 在相对较少的调节参数时间情况下, 预测的准备率也可以比较高^[121]; (3) 使用一些健壮

的损失函数,对异常值的鲁棒性非常强。比如 Huber 损失函数和 Quantile 损失函数。但是梯度提升树也存在一些缺点,如由于各学习器间存在依赖关系,难以并行训练数据^[122]。不过可以通过自采样的 SGBT 来达到部分并行。

4. 分类与回归树

分类与回归树 (Classification and Regression Tree, CART) 是一种以二叉树为逻辑结构的典型的决策树,可以用来处理涉及连续数据的分类或者回归任务^[123]。决策树使用的过程比较简单,首先,分割特征空间,也就是将样本分组;然后为每一组样本分配一个预测值;最后,在预测阶段为样本找到分组和预测值。假设预测任务的输出和输入都是离散值,我们可以直接以特征的各个取值为候选分割平面(即对训练样本分组),进行决策树的构建,这就是针对离散值的分类决策树。当特征为连续变量或者输出值为连续变量,则需要使用分类与回归树。针对离散值的决策树在对训练样本进行分组时,一般情况下不允许重复使用一个特征。而有能力处理连续变量的分类与回归树允许重复使用一个特征。构建一个可用的分类与回归树的关键是设计一个标准来指导机器按照最有利于准确计算因变量的情况来切分特征空间。一般来说,在回归类任务中,我们使用平均方差 (Mean Square Error, MSE) 作为模型“误差”的度量指标。使用这个指标的好处有很多:可以度量预测值和真实值的总体偏离情况;并且在使用梯度下降这类方法优化的时候,推导计算较为方便^[123]。由于特征取值为连续值,同时允许重复使用,分类与回归树可以生长到非常大的规模,直到每一个样本都拥有一个专门的规则路径——形成非常严重地过拟合。为了减少过拟合的现象,我们需要合并节点或阻止节点分裂来对分类与回归树进行剪枝。

总的来说,监督分类算法具有如下的优点:(1)能够确定分类类别,不是盲目分类;(2)能够充分利用先验的知识^[124]。在特征选择、训练样本选择和制作等方面都有体现;(3)训练过程中能够通过调整训练样本,提高分类精度;(4)有些算法具有一定的“学习”能力。但是监督分类算法也有一些缺点:(1)监督分类最大的缺点就是需要大量的标签数据;(2)标签数据的选择和制作过分依赖于人工,这会引入主观判断所带来的各种人为误差,甚至是错误;(3)特征选择难度很大,往往依赖人工经验;(4)一些算法对特征维度与训练样本数量要求比较严苛,工程实践时,很难把握;(5)虽然有些算法有一定的“学习”能力,但是,由“记忆”能力产生的经验再利用能力比较弱^[125]。

2.3.3 卷积神经网络分类算法

卷积神经网络 (Convolutional Neural Network, CNN) 是当前计算机视觉研究领域中的一个非常重要的工具。通常,卷积神经网络有两种主要框架,即基于补丁和端到端(像素到像素)。卷积神经网络被用来对基于像素的语义信息进行分类。在基于像素的方法中,采用全卷积网络 (Fully Convolutional Network, FCN)

或编码器-编码器框架来识别输入数据集的可接受事实。基于补丁的技术通常也利用小图片来训练 CNN 分类器的进程，并使用滑动窗口方法来预测每个像素的分类。相对于传统的机器学习算法如 KNN、K-Means 等方法，CNN 的优势在于特征提取是基于前向和反向传播学习的，能够提取高维度、深层次特征，方便计算机理解，而传统的方法需要人工设计提取特征^[126]，特征少，且需要专业知识指导。

卷积神经网络最主要的结构就是卷积层，依靠卷积层，网络能够提取视觉信息中的有效特征。在这之前，许多神经网络都是全连接的网络，即每个神经元和其它神经元之间连接。然而全连接神经网络的参数量大、学习效率低，并且层数也有所限制，因此不适合处理大尺度图像。而 CNN 使用了卷积操作，使其具有局部感受野和权值共享的特点，因此网络的参数量就减少了很多，更适合处理大尺度图像^[127]。除此之外，卷积神经网络还有池化层，可以有效的扩大卷积核的感受野大小。而非线性激活函数可以引入非线性操作，提高卷积神经网络的非线性表达能力。接下来本节将依次介绍卷积神经网络中的各个主要模块。

1. 卷积层

卷积神经网络中的卷积层即是使用二维甚至更高维的卷积核对输入的二维或高维特征矩阵进行卷积操作^[51]。其主要特征提取的原理是利用了图像的位移不变性，即在图像中某区域通过反向传播算法学习到的特性在图像其它部分或者同一类别的图像中的某些部分依然有效。利用该特性，在一张图片中学习到的特征可用于在其他图片中进行特征提取。在卷积神经网络中，学习特征的过程是将特征通过卷积核进行“过滤”。通过逐层连续卷积操作，图像中对模式识别有意义的特征被保留和加强，无意义的特征被丢弃。同时一个卷积层可以有多个卷积核，因此可提取多个不同的特征，且一般情况下，卷积核的数量都是冗余的^[51]。卷积层是卷积神经网络的核心，其主要功能是获取输入图像的特征^[128]。卷积核是卷积层的核心，具体操作是利用卷积核对输入的特征图进行卷积运算，并输出运算结果^[129]。卷积操作就是利用卷积核在图像上滑动，使图像上每个点的像素值与卷积核对应点的数值相乘，然后将所得的值相加作为特征值，最后滑动完所有图像得到输出特征图^[130]。通常一个卷积核提取一种特征，卷积层有多个卷积核，组成一个立方体块，可以提取多种特征，如图像的色彩特征，纹理特征等，然后将不同的特征组合起来作为下一层的输入。对于图像卷积而言，卷积核大小通常会设计为奇数，这样的好处是可以提取卷积核锚点对应的图像中心邻域信息作为该点的特征值，而对于卷积核锚点不与图像像素点重叠时的计算，一般会舍弃。这种情况发生在卷积核在图像边界计算时，有时需要使输入图像与输出特征图大小相等，因此会选择对图像边界进行填充，通常的填充方式为边界填充固定值零^[131]。

卷积层能够抽取图像的各种特征，浅层卷积可以学习到简单的边缘特征，深层卷积可以学到更加复杂抽象的特征，这使得 CNN 可以自动提取图像中的特征。

此外，卷积层有局部连接和权值共享的优点，这大大降低了网络的参数量^[104]。

2. 池化层

在网络中，通过卷积运算操作可对输入图像进行降维操作和特征提取，但是经过此操作后维度依然很高。维数高不仅仅会使得数据计算非常费力，而且很容易就会造成模型过度拟合，从而对其他数据的表现很差，使得模型泛化能力较差^[132]。为了有效解决这类问题，引入了一种下采样的技术，即池化^[66]。池化层是 CNN 中常见的部分之一，池化一般在卷积的后面，池化层通过下采样方式来降低特征图的尺寸，从而可以进一步减少网络的参数量。很直观地，在经过池化层作用之后，可以将输入特征图的尺寸缩小一倍甚至更小，但是缩小后的特征图仍保留有原始特征图的关键特征，只是去除了其中一些冗余的、不重要的特征，从而在一定程度上优化了网络、减少了过拟合风险。同时，经过池化降维操作之后的特征图，也可以降低后续网络的计算量^[133]。

池化层常用的方式有最大池化和平均池化。最大池化是在特征图中选定一个固定尺寸的窗口，并用这个窗口中像元的最大值来代替此窗口，然后窗口按固定步长在特征图中进行滑动采样，以此来降低特征图的尺寸。而平均池化是用窗口中所有像元的平均值来代替窗口^[127]。池化层一般将特征图的尺寸降低一半，这样可以进一步减少模型后续的参数量。与卷积操作相同，池化层输出特征同样受到池化核尺寸、池化层滑动步长与边缘填充方式影响^[134]。池化层主要有以下几个功能：（1）降维，缩减了模型的大小，提高了计算效率^[132]；（2）降低了模型过拟合的几率，提升了特征量的提取鲁棒性；（3）对于平移和转动不敏感。

U-Net 发表于 2015 年，属于 FCN 的一种变体。U-Net 的初衷是为了解决生物医学图像方面的问题，由于效果确实很好后来也被广泛的应用在语义分割的各个方向，比如卫星图像分割，工业瑕疵检测等^[135]。U-Net 基于 Encoder-Decoder 结构，通过拼接的方式实现特征融合，结构简明且稳定。Encoder 负责特征提取，由卷积操作和下采样操作组成。本文使用 U-Net 网络对鄱阳湖栖息地进行分类，并与随机森林的分类结果进行对比。

第3章 基于机器学习的鄱阳湖栖息地分类研究

3.1 光谱指数

本文计算了几种光谱指数,以辅助机器学习分类。这些指数包括归一化植被指数(Normalized Difference Vegetation Index, NDVI)、改良归一化水体指数(Modified Normalized Difference Water Index, MNDWI)、归一化建筑指数(Normalized Difference Building Index, NDBI)和增强植被指数(Enhanced Vegetation Index, EVI),这些指数均可用于识别土地覆被基本类型。NDVI可显示植被分布,反映植被生长状况^[136],

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (3-1)$$

其中, NIR 表示近红外波段值(分别为 Landsat 5 中的 B4 和 Landsat 8 中的 B5), Red 表示红色波段值(分别为 Landsat 5 中的 B3 和 Landsat 8 中的 B4)。MNDWI 指数可用于识别卫星图像中的水面信息^[137],

$$MNDWI = \frac{p(Green) - p(SWIR)}{p(Green) + p(SWIR)} \quad (3-2)$$

其中 Green 为绿色波段值(其中, Landsat 5 为 B1 波段, Landsat 8 为 B2 波段), SWIR 为短波红外波段值(Landsat 5 为 B5 波段, Landsat 8 为 B6 波段), P 为常数。NDBI 指数可以识别地表建筑^[138],

$$NDBI = \frac{SWIR - NIR}{SWIR + NIR} \quad (3-3)$$

其中 SWIR 为短波红外波段值(分别为 Landsat 5 中的 B5 波段和 Landsat 8 中的 B6 波段), NIR 为近红外波段值(Landsat 5 中的 B4 波段和 Landsat 8 中的 B5 波段)。EVI 指数继承了 NDVI 指数的优点,改善了植被饱和、大气影响修正不完全、土壤背景等带来的问题^[139]。因此, EVI 增强了高栖息地植被的敏感性,降低了土壤背景和大气影响。EVI 指数是监测植被变化的重要指标,具有较高的敏感性和优越性^[140],

$$EVI = 2.5 \times \frac{(NIR - Red)}{(NIR + 6 * Red - 7.5 * Blue + 1)} \quad (3-4)$$

其中,红色代表 Landsat 5 中的红色波段 B3 和 Landsat 8 中的红色波段 B4,蓝色代表 Landsat 5 中的 B1 波段和 Landsat 8 中的 B2 波段。近红外是 Landsat 5 中的近红外 B4 和 Landsat 8 中的近红外 B5。

在卫星图像中选择的样本点的质量会对准确地提取栖息地信息产生很大的影响,因此应选择典型的、纯粹的代表性像素作为样本点。因此,本文统一从 GEE 获取的 Landsat 图像中选择样本点。这些样本点被随机排列,按照 7:3 的比例分

为训练样本和测试样本。最后使用 RF、SVM、GTB 和 CART 进行分类，得到了混淆矩阵、总体精度和 Kappa 系数。

3.2 分类精度评价方法

遥感图像分类的精度评价主要从三个属性来进行评价，分别是混淆矩阵、总体分类精度和 Kappa 系数^[51]。

1. 混淆矩阵 (Confusion Matrix)

混淆矩阵又称为可能性矩阵或错误矩阵。混淆矩阵就是分别统计分类模型归错、归对类的观测值个数，然后把结果放在一个表里展示出来^[141]。在图像精度评价中，主要用于比较分类结果和实际测得值，可以把分类结果的精度显示在一个混淆矩阵里面^[142]。矩阵中，通常列为各待分类元素通过分类器后被标注为某一类的数量，行为真实标记为某一类的元素被分类器分为各个类别的数量。

2. 总体分类精度 (Overall Accuracy, OA)

总体精度是用于表示分类结果中被正确分类的元素个数占总分类元素个数的比例，一般被作为最基本的分类评价标准。总体分类精度等于被正确分类的像元总和除以总像元数；其中，被正确分类的像元数目沿着混淆矩阵的对角线分布，总像元数等于混淆矩阵的和^[143]。

3. Kappa 系数

Kappa 系数是一个用于衡量分类效果的一致性检验的指标。对于分类问题中的一致性检验就是模型预测结果和实际分类结果是否一致^[144]。它是通过把所有真实参考的像元总数 (N) 乘以混淆矩阵对角线 (XKK) 的和，再减去各类中真实参考像元数与该类中被分类像元总数之积之后，再除以像元总数的平方减去各类中真实参考像元总数与该类中被分类像元总数之积对所有类别求和的结果^[145]。其数值处于区间 (-1, 1) 内，越接近 1 说明结果越好，一般认为大于 0.8 就达到非常一致的结果。上面提到的总体分类精度评价方法虽可以直接反映分类正确的比例，计算简单，但是由于分类过程中各个样本不平衡，总体分类精度高的时候部分类别可能很低，Kappa 系数则能反映这一问题，有一类分类结果差，Kappa 值就会明显降低。

3.3 精度对比及结果分析

3.3.1 分类精度比较

利用这四种机器学习方法计算得到的栖息地分类精度和 Kappa 系数见表 3-1。通过分析表格发现，这四种方法总体分类准确率均在 98% 以上，Kappa 系数均大于 0.98。由表 3-1 可知，随机森林算法的总体准确率为 99.6%，kappa 系数

为 0.994，分类性能最好。

四种机器学习算法的混淆矩阵如表 3-2 所示，从表中可以看出，随机森林方法的分类误差较小，水体和泥沙像素的混合程度较其他类型低。在利用随机森林方法进行分类时，草洲和泥滩的错分误差大于水面和沙地，这是因为通常泥滩和草洲在空间上是相连的。随机森林算法虽然对草洲、农田和泥滩存在一定的分类误差，但随机森林对研究区栖息地的分类结果优于本文提到的其他机器学习方法。

表 3-1 四种机器学习算法对 2021 年 1 月 12 日陆地卫星图像的总体分类精度和 Kappa 系数

Table 3-1 Overall accuracies and Kappa coefficients of the four machine learning algorithms for the Landsat image of 12 January 2021

年份	随机森林	梯度提升树	支持向量机	分类与回归决策树
总体精度	0.9960	0.9952	0.9930	0.9934
Kappa 系数	0.9941	0.9930	0.9896	0.9902

表 3-2a 2021 年 1 月 12 日陆地卫星图像的随机森林和梯度提升树算法的混淆矩阵

Table 3-2 Confusion matrices of RF and GTB for the Landsat image of 12 January 2021

随机森林						
	水体	草洲	泥滩	沙地	农田	其他
水体	8636	0	0	0	0	2
草洲	0	3448	10	0	1	2
泥滩	0	0	6635	1	2	3
沙地	0	0	0	1295	0	2
农田	0	2	8	7	50	1
其他	4	5	8	0	3	176
梯度提升树						
水体	8635	0	0	0	0	3
草洲	0	3443	16	0	1	1
泥滩	2	1	6632	0	0	7
沙地	0	0	27	1270	0	0
农田	0	2	8	6	51	1
其他	5	4	11	0	3	173

表 3-2b 2021 年 1 月 12 日陆地卫星图像的支持向量机和回归决策树算法的混淆矩阵

Table 3-2b Confusion matrices of SVM and CART for the Landsat image of 12 January 2021

支持向量机						
	水体	草洲	泥滩	沙地	农田	其他
水体	8635	0	1	0	0	2
草洲	0	3449	9	0	1	2
泥滩	0	0	6634	5	2	0
沙地	0	0	60	1236	1	0
农田	0	0	12	0	56	0
其他	20	7	18	0	3	148
回归决策树						
	水体	草洲	泥滩	沙地	农田	其他
水体	8636	0	0	0	0	2
草洲	0	3445	11	0	1	4
泥滩	0	3	6598	17	11	12
沙地	0	0	30	1267	0	0
农田	0	2	11	6	49	0
其他	4	4	11	0	6	171

3.3.2 栖息地类型的长期变化

根据上述精度和混淆矩阵的结果比较，本文采用随机森林方法对 1990-2021 年的 Landsat 遥感影像进行鄱阳湖冬季栖息地分类。利用随机森林对 Landsat TM 和 OLI 图像分类的分类结果、总体分类精度和 Kappa 系数如表 3-3 所示。从表 3-3 可以看出，随机森林得到的总体精度和 Kappa 系数大部分为 99% 左右。除了 2006 年的总体分类精度和 Kappa 系数分别为 98.78% 和 0.9828。这些结果表明，随机森林较其它几种机器学习算法更适用于分析鄱阳湖地区冬季栖息地特征。

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/988143111135006023>