

地理要素分类机器学习方法发展与前景

王卷乐^{1,3,5}, 李凯^{1,2}, 严欣荣^{1,3}, 郑莉^{1,4}, 韩雪华^{1,3}

1. 中国科学院地理科学与资源研究所 资源与环境信息系统国家重点实验室, 北京 100101;

2. 中国矿业大学(北京) 地球科学与测绘工程学院, 北京 100083;

3. 中国科学院大学, 北京 100049;

4. 防灾科技学院, 三河 065201;

5. 江苏省地理信息资源开发与利用协同创新中心, 南京 210023

摘要: 地理要素一般包括自然和人文两类对象。日益增加的遥感大数据和泛在的社交媒体数据为这两类对象的要素分类提供了丰富的数据源。基于遥感影像分类为主的自然要素提取和基于网络文本和社交媒体的人文要素提取, 是当前地理要素分类的两大主流。前者以图像处理技术为支撑, 后者则以自然语言处理技术为核心。随着机器学习等人工智能分类方法的介入, 两类要素分类呈现越来越多的共性相通特点。本文以机器学习方法的演变历程为媒介, 剖析了其在自然地理要素遥感影像分类和人文社会要素网络文本分类方面的异同。以遥感单一对象、复合对象分类和微博社交媒体话题分类提取为实例, 指出二者在机器学习分类方法上具有相通性。遥感大数据和网络文本大数据分类方法的相互借鉴能够促进自然与人文地理要素的智能分类应用。

关键词: 地理要素分类, 自然地理要素, 人文地理要素, 机器学习, 遥感分类, 网络文本分类, 自然语言处理

中图分类号: P2

引用格式: 王卷乐, 李凯, 严欣荣, 郑莉, 韩雪华. 2023. 地理要素分类机器学习方法发展与前景. 遥感学报, 27(8): 1757-1768

Wang J L, Li K, Yan X R, Zheng L and Han X H. 2023. Development and prospects of machine learning methods in geographic elements classification. National Remote Sensing Bulletin, 27(8): 1757-1768 [DOI: 10.11834/jrs.20232299]

1 引言

地理对象涵盖了多种地球或行星表层空间的地理要素, 是对地理综合体的空间分布规律、时间演变过程和区域特征的一种直接或抽象表达, 是自然与人文科学的交叉, 具有综合性、交叉性和区域性特点(傅伯杰等, 2015; 傅伯杰, 2017)。地理对象包括岩石、大气、水(含冰冻圈)、生物和人类圈这5大圈层在地球表层中的自然和人文要素。自然属性要素对象包括地貌、土地类型、土壤、沙漠、冰川、冻土、戈壁、气候、流域、湖泊、河流、潜水、植被、地表环境、自然疫源地等各类单一要素或其地理综合体。人文属性要素对象包括人口、社会、经济、文化、政治、旅游、公众情感(观点、情绪、满意度、喜好等)等各方面。如何获取这些包括自然属性和

人文属性的海量地理要素信息, 是大数据时代开展地理科学研究的基础, 也是地理学大数据驱动科学发现研究范式转变的根本。

地理要素的时空分布信息来源于地理大数据的挖掘和分析。对地观测卫星、物联网传感器、社交媒体和网络公共平台获取了海量的地理要素相关数据。挖掘和应用这些数据是研究地理规律的重要途径, 对这些地理要素提取信息的过程, 也是对其进行特定分类的过程。由于以往受制于数据源和大数据处理技术的限制, 自然地理要素多只由科学考察与调查、人工或人机交互的遥感解译等方式获取, 人文地理要素信息则主要通过社会调查和统计等方式提取。这二者之间少有交集。然而, 随着大数据和人工智能应用的快速崛起, 海量的遥感数据和网络社交媒体文本都是产生地理要素信息的大数据来源, 如何智能地提取

收稿日期: 2022-07-03; 预印本: 2022-12-27

基金项目: 中国科学院战略性先导专项(A类)(编号: XDA19040501); 中国工程科技知识中心建设项目(编号: CKCEST-2022-1-41)

第一作者简介: 王卷乐, 研究方向为资源环境科学数据共享。E-mail: wangjl@igsrr.ac.cn

地理对象的自然属性和人文属性成为地理学共同关注的问题。

本文从地理要素分类角度，回顾了人工智能和机器学习的历程，探索不同地理要素的分类方法，分析对比了基于遥感大数据的自然要素与基于文本大数据的人文要素信息的分类提取方法，并分析其差异和共性，预期使两类对象的分类提取都能够从大数据和人工智能应用中惠益。

2 机器学习分类方法的发展历程

2.1 机器学习方法的发展历程

人工智能 (Artificial Intelligence) 的最初理念是使用计算机来构造复杂的、拥有人类同样智慧的机器 (Eisenecker, 1995)。人工智能的实现包括专家系统、进化计算、推荐系统和机器学习 (Machine Learning) 等方式 (Mitchell, 1997)。人工智能的发展经历了萌芽、发展、瓶颈、复苏、爆发共 5 个时期 (图 1)。20 世纪 40 年代，M-P 神经元模型被提出 (McCulloch 和 Pitts, 1990)，将神经元的理念引入计算机模型。到 20 世纪 50 年代，人工智能算法得以发展，诞生了感知器 (Rosenblatt, 1958)、梯度下降法等算法。Novikoff (1962) 推导并证明感知器收敛理论，这为感知器学习规则的应用提供了理论基础。60 年代至 70 年代，受限于计算机性能和复杂非线性化的问题，人工智能发展遇到了瓶颈。80 年代开始，人工智能技术开始复苏，机器学习成为一个独立的研究方向，创立了第一本机器学习专业期刊《Machine Learning》，人工智能领域的权威期刊《Artificial Intelligence》出版机器学习专辑。期间也诞生了在深度学习领域影响深远的反向传播算法 (Rumelhart 等, 1988)、卷积神经网络 (Lecun 等, 1989)、决策树 (Quinlan, 1986) 等。20 世纪 90 年代后，人工智能算法爆发。自 1998 年前苏联统计学家 Cortes 和 Vapnik 在《Machine Learning》上发表 SVM (支持向量机) 起，以 SVM 为代表的统计学习便大放异彩 (Cortes 和 Vapnik, 1995)。与此同时，集成学习与深度学习的提出，成为机器学习的重要延伸。集成学习的核心思想是通过多个基学习器的结合来完成学习任务，最著名的是 Schapire (1990) 提出的 Boosting 算法、Freund 和 Schapire (1997) 提出的 AdaBoost 算法、Breiman (1996) 提出的

Bagging 算法以及 Breiman (2001) 提出的随机森林算法。Hinton 和 Salakhutdinov (2006) 提出深度学习，其核心思想是通过逐层学习方式解决多隐层神经网络的初值选择问题，从而提升分类学习效果。

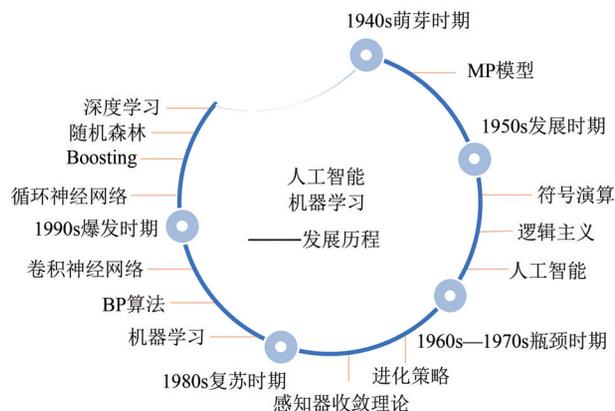


图 1 机器学习发展历程

Fig. 1 History of machine learning

机器学习具有可移植性强、鲁棒性高的特点，广泛应用于地理对象数据的分类研究，例如各类遥感影像地物信息提取、社交媒体文本信息挖掘、网络舆情话题分类等 (杜培军等, 2016; 郑治豪等, 2018; 徐军等, 2007)。在中国自然科学基金地理学科 2021 年项目申报中，深度学习和机器学习作为关键词的使用频数分别为第 1 和第 7 (高阳等, 2022)。这进一步证实了机器学习等信息分类方法已成为当前研究热点。

2.2 遥感影像分类的发展历程

1970 年代以来，遥感分类技术随着对地观测数据的积累不断发展。机器学习在遥感影像分类中的应用包括土地利用/覆盖制图、目标检测、变化监测以及回归方法等 (Salcedo-Sanz 等, 2020)。不同尺度的土地利用/覆盖信息制图是遥感影像分类的主要驱动力。20 世纪 80 和 90 年代，多数的分类都采用像元作为分析单元，每个像元被标记为一个单一的土地利用/覆盖类别。以像素为基本分析单元的一系列分类技术如无监督 (K-Means 和 ISODATA 等)、有监督 (即极大似然、人工神经网络、决策树、支持向量机、随机森林等)、混合分类 (即半监督和融合监督和无监督学习) 被开发出来 (Alajlan 等, 2012; Zhang 等, 2005)。机器学习算法被广泛应用于各类自然地理要素的监测

和制图中,并被集成在一系列经典的遥感分类软件中。

许多研究人员发现当这些像素级分类方法应用于异构对象区域时有一定的局限性,因为对象的大小可能比像素小得多(Li等,2014)。一个像元不仅可以包含单一的土地利用/覆盖类型,还可能包含多种类型的混合。因此,针对像素混合问题的模糊分类和光谱混合分析技术在20世纪90年代发展起来(Adams等,1995;Wang,1990)。这些基于亚像素的分析方法已经应用于多种地理对象的研究中,包括植被和城市分析(Legleiter等,2022;Zhu等,2022a)。机器学习参与亚像素的分类,可为混合像元分解(于丰华等,2022)、亚像元制图(任武和葛咏,2011)等任务提供模型方法的支持。

随着超高分辨率传感器的推出,面向对象的分类方法自20世纪90年代末开始发展(Blaschke,2010;Yu等,2006)。面向对象的方法将许多具有相同属性的像素分组为一个对象,“对象”而不是单个像素被认为是分析的基本单位(Walter,2004)。机器学习算法在多种尺度的面向对象分类中都表现出良好的稳定性和精度水平(宋茜,2016;赵丹平等,2016)。除土地利用/覆盖的遥感影像分类之外,机器学习方法结合夜间灯光影像被用于描述城市发展程度、绘制难民安置地图等,广泛应用于地理对象中的人文要素研究(Xu等,2021)。

近年来,获取遥感数据的对地观测平台数量呈指数级增长,越来越多的在轨和计划发射的卫星,以及可获得高空间分辨率数据的新平台(如无人机等)都让机器学习算法在遥感应用中富有前景。目前在遥感分类或信息提取中,机器学习的应用不局限于单次或某一步骤使用,而是贯穿在数据获取、处理、融合、分类或验证的全过程(Salcedo-Sanz等,2020)。例如在数据预处理阶段,卷积神经网络、支持向量机等机器学习方法能够实现云、阴影、霾、缺失数据和噪声的处理,使遥感数据具有更高的质量。此外机器学习方法还能够融合不同遥感传感器数据,生成更高时空分辨率影像。

2.3 文本分类的发展历程

文本挖掘也称网络文本数据挖掘(Web Text

mining),是指从大量网络或社交媒体文本数据中抽取事先未知的、可理解的、最终可用的信息的过程。文本挖掘的典型任务包括文本分类、文本聚类、语义标签提取、观点抽取、情感分析、文档摘要和文本主题模型等。文本分类技术TC(Text Categorization)作为组织和管理文本信息的有效手段,主要是将无标签文档自动分类到预定的类别集合中。文本分类是自然语言处理中最基本的任务之一,主要包括情感分析(SA)、主题标签(TL)、新闻分类(NC)、问题解答(QA)、对话行为分类(DAC)、自然语言推断(NLI)和事件预测(EP)等。

文本分类研究模型分为统计模型和深度学习模型。统计模型中,朴素贝叶斯(Naïve Bayes Classifier)是Maron(1961)基于应用Bayes定理提出的算法模型。该算法主要使用先验概率来计算后验概率,由于结构简单而被广泛使用。Cover和Hart(1967)提出K近邻算法(KNN)对未标记的样本进行分类,每个样本都可以用它最接近的K个邻近值来代表。分类与回归树CART(Classification and Regression Trees)由Breiman(1984)提出。CART决策树使用“基尼系数”来选择和划分属性,不仅可用于分类也可用于回归。Quinlan(1993)基于信息增益比对特征进行划分,提出C4.5算法,通过“增益率”来选择最优划分属性。Cortes和Vapnik提出支持向量机(SVM)来解决模式识别的二元分类问题(Cortes和Vapnik,1995)。Joachims(2002)首次使用SVM方法对文本分类,该模型将每个文本表示为一个向量。随机森林(RF)是一种重要的基于Bagging的集成学习方法(Breiman,2001),可以用来做文本分类和回归等问题研究。

深度学习模型中,Socher等(2011)、Socher等(2012)、Socher等(2013)提出RAE(Recursive AutoEncoder)、矩阵-向量RNN(Matrix-Vector RNN, MV-RNN)和递归神经张量网络RNTN(Recursive Neural Tensor Network)。Kim(2014)提出将卷积神经网络CNN应用到文本分类任务,利用多个不同尺寸大小的卷积核来提取句子中的关键信息(类似于多窗口大小的单词组),能够更好地捕捉局部相关性。Tree-LSTM通过改进经典的递归神经网络,引入LSTM中的记忆单元和门机制,从而更好地进行词向量的组合得到整个句子

的向量表示 (Tai, 2015)。Bahdanau 等 (2016) 首次将 Attention 机制应用于自然语言处理领域中。2017 年谷歌团队提出采用自注意力机制 (self-Attention) 进行文本分类, 可以减少训练的时间 (Vaswani 等, 2017)。HAN (Hierarchical Attention Networks for Document Classification) 是一个针对文本分类任务的层次化模型, 通过“词—句子—文章”的层次化结构来表示一篇文本, 通过对文本中重要性不同的句子和词给予不同“注意力”, 提高模型的可解释性 (Yang 等, 2016)。之后有学者提出了将这些深度学习模型进行混合, 将 CNN、RNN、LSTM、GRU 和 Attention 结合用于文本分类。

3 地理要素分类的机器学习方法原理与应用

3.1 地理要素分类流程

地理要素的分类流程主要分为数据获取、数据预处理、特征构建或模型训练以及精度评价等环节。面向自然要素和人文要素的分类流程如图 2 所示, 其在相应环节中存在异同。数据预处理阶段, 影像分类需要辐射校正、影像裁切等, 而文

本分类则需要语料清洗、文本分词、去停用词等。特征信息构建阶段, 影像分类需要构建易于目标地物分类的特征信息, 比如归一化差值植被指数 NDVI (Normalized Difference Vegetation Index)、归一化差值水体指数 NDWI (Normalized Difference Water Index) 等。这些特征能体现植被、水体与其他地物的差异, 在植被、水体要素分类中能起到较好的效果。文本分类则需要利用文本词典和语料, 在特征空间里度量各个词语的相关性。常用的词向量模型有 Word2Vec、BERT 等。在模型训练过程中, 参与的模型往往都是可以在遥感和文本分类中通用的, 比如 SVM、KNN、K-Means、决策树等。这是因为图像和文本都在上述方式中进行了数字化处理, 输入神经网络模型的数据为格式化后的数字信号。对影像数据和存在语序问题的文本语料, 针对性地选择符合特定目标的分类器往往能取得更好的分类效果。比如, CNN 常用于图像分类, RNN、Transformer、LSTM 常用于文本分类。相较于影像分类大量文本语料中的分词、词向量构建等预处理, 以及分类器构建过程中的语序问题, 是文本分类中难点。

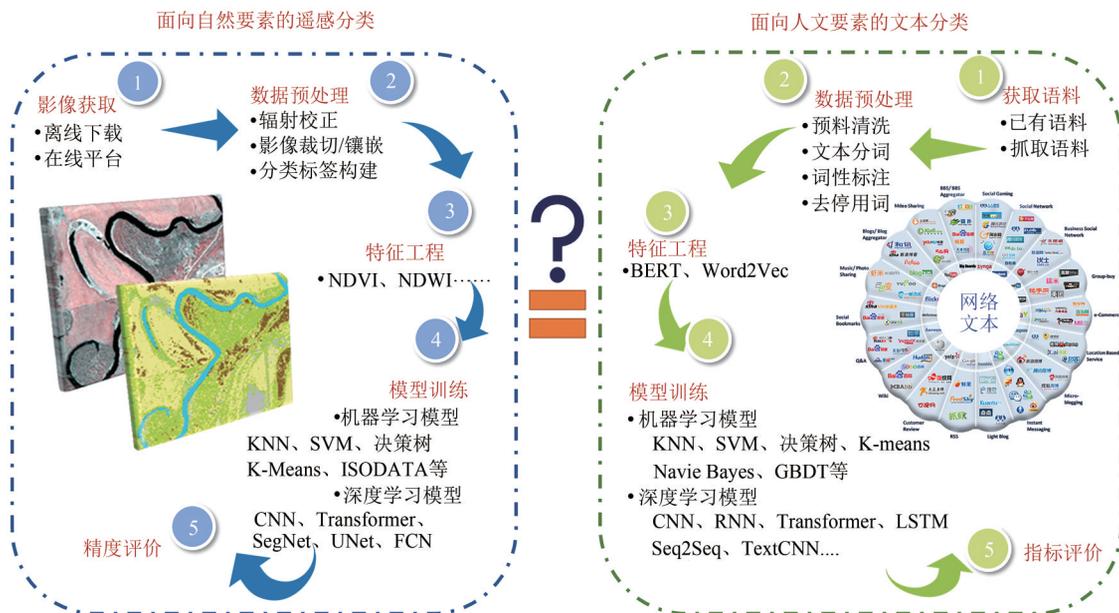


图 2 遥感影像和网络文本分类主要流程
Fig. 2 The main process of remote sensing image and web text classification

3.2 应用案例

应用案例从单一地表要素 (水体) 和复合地表要素 (土地覆盖) 遥感分类以及社交媒体文本

分类角度出发。水体分类和土地覆盖分类揭示遥感影像分类的具体流程和方法, 社交媒体文本分类则对应文本分类方法。

3.2.1 遥感影像单要素水体分类

以蒙古国北部的图拉河为例，利用深度学习监督分类技术可实现水体的高效提取。图拉河流经蒙古国首都乌兰巴托、图尔省以及布尔干省，经色楞格河汇入贝加尔湖。该地区的土地覆盖类型主要有草地、林地、耕地、建筑区以及水体5大类。其中，草地覆盖最广，林地主要位于乌兰巴托以及中央省东北部，耕地分布在中央省西北部，建筑区主要位于乌兰巴托市，水体以图拉河为主。Landsat 8 影像中条带号 131027、132027、133027

这3景影像可覆盖研究区。其中 131027 影像用于模型训练，131027、132027、133027 用于预测与验证。

图3为水体提取的技术路线图。图拉河水体提取的流程主要分为图拉河区域影像数据获取、数据预处理及标签数据构建、水体提取模型 Pixel-based CNN 模型构建 (Li 等, 2021)、模型训练和预测、精度评价，共5部分。Pixel-based CNN 水体提取模型采用多次卷积和拼接操作，兼顾了地物的纹理特征和光谱信息。

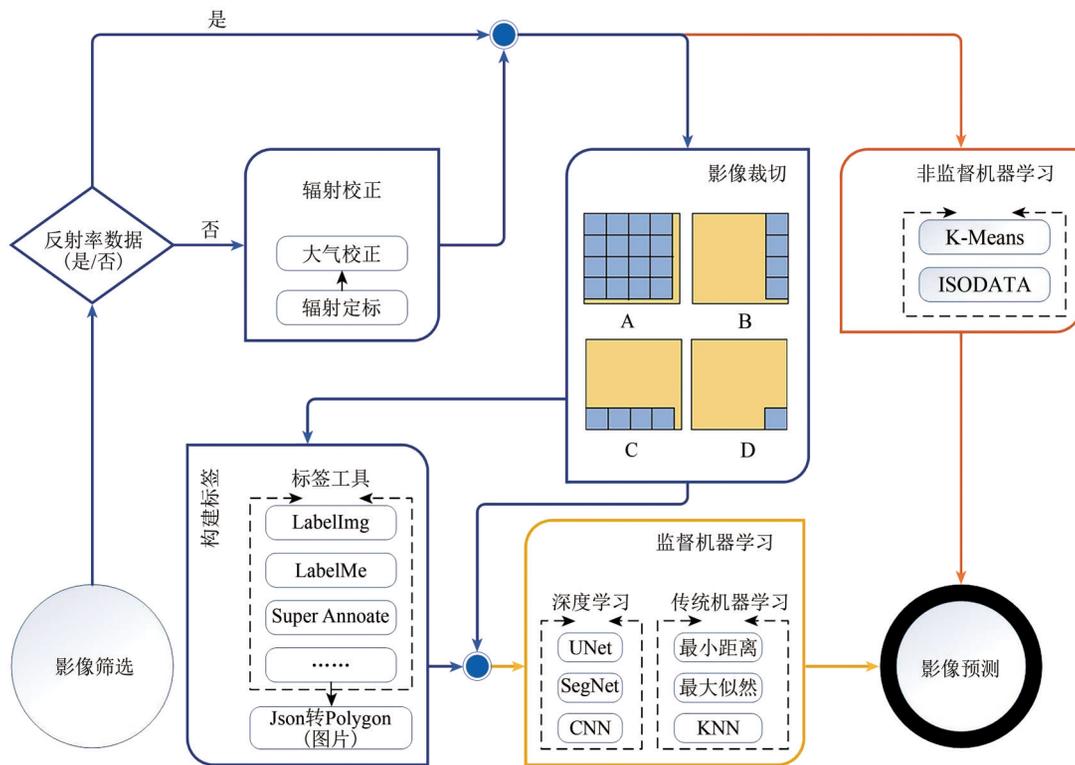


图3 水体提取技术路线
Fig. 3 Technology route of water extraction

训练过程中 Pixel-based CNN 模型精度高达 99.90%。在 3 景影像中选取了水体和非水体验证点数量各 164 个，验证精度为 92.07%，Kappa 系数 0.84。对比传统 NDWI、MNDWI 阈值法以及 UNet、DNN 等深度学习方法，Pixel-based CNN 拥有最高的精度。Pixel-based CNN 模型提取的河流连续性高，减少了阴影被误分为水的情况。

3.2.2 遥感影像土地覆盖复合要素分类

Gong 等 (2013) 利用 Landsat 数据通过监督分类算法获得了 30 m 空间分辨率的全球地表覆盖分

类结果。光谱特征作为土地覆盖分类的主要特征，在全球人工选取 91433 个训练样本，分别采用随机森林、决策树、最大似然以及支持向量机四种机器学习方法进行分类。全球土地覆盖分类的总体工作流程如图 5 所示。它包括数据预处理、训练和测试样本收集、使用时空邻域场景的局部训练样本逐场景进行图像分类，以及最终的精度评估。

通过人工选取的 38664 个样本，验证得到支持向量机方法的分类精度最高，总体精度为 64.89%，其次依次为随机森林 (59.8%)、决策树 (57.9%) 和

最大似然 (53.9%)。在此基础上, Gong 等 (2019) 依托 Google Earth Engine 和 Sentinel-2 影像数据研制了全球 10 m 分辨率的土地覆盖产品。

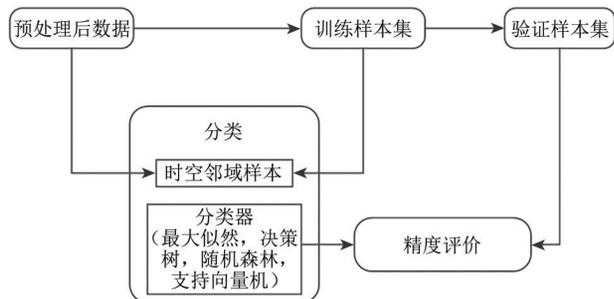


图4 土地覆盖分类技术路线

Fig. 4 Workflow of landcover classification

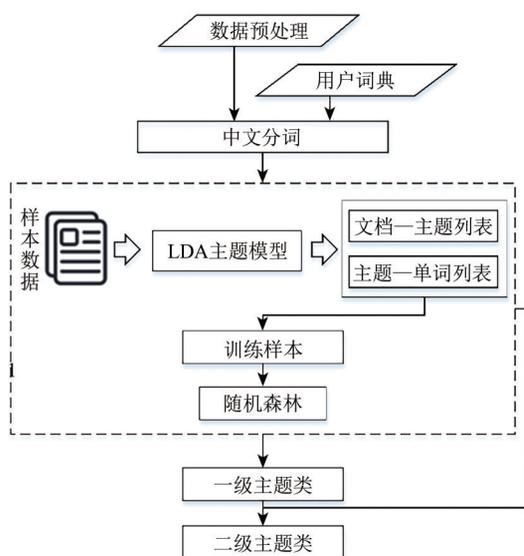


图5 主题抽取与情感分类框架

Fig. 5 Topic extraction and sentiment classification framework

Chen 等 (2015) 选取多源的遥感影像数据作为数据源, 包括 Landsat TM、ETM+ 以及环境卫星 (HJ-1)。收集了格式、精度、分辨率各异的多源土地覆盖数据、DEM 数据、地形数据、生态区数据以及地理知识背景, 并和影像数据整合。采取基于“像元—对象—知识”的 POK (Pixel-Object-Knowledge) 分类方法生产了全球 2000 年和 2010 年的土地覆盖数据产品, 总体精度超过 80%。

3.2.3 社交媒体文本分类

以微博社交媒体文本数据中的新冠疫情 (COVID-19) 公众话题提取为例分析网络文本分类。通过新浪微博数据中心官方 API, 以“冠状病毒”和“肺炎”为关键词, 获取自 2020 年 1 月 9 日

0 点至 12 月 9 日 24 点的微博文本。微博信息包括用户名、用户 ID、微博文本、地理位置、发布时间等属性字段。为消除噪声并提高分词效率, 须对原始数据进行文本过滤。使用 Python 正则表达式对原始社交媒体文本进行过滤, 去除干扰信息 (例如 http 链接、标点符号)、停用词、无意义文本、重复的文本。对原始数据清洗预处理后, 得到有效微博文本 6946196 条, 其中带地理坐标且位于中国区域内有 328241 条。

案例研究基于潜在狄利克雷分配 LDA (Latent Dirichlet Allocation) 主题模型和随机森林算法构建主题抽取与分类框架, 从新冠肺炎相关的社交媒体文本中分层获取公众情感话题 (王卷乐等, 2020)。首先使用 Python 中文分词工具“jieba”进行切词处理, 该步骤是将句子切分成一个个单独的词的过程。之后使用 LDA 主题模型进行主题抽取, 生成各文本的主题概率分布以及各主题的单词概率分布。最后将已标注主题的样本数据作为随机森林算法的训练样本, 基于 Python 中的“Scikit-learn”库, 对整个数据集进行分类。

分类生成以下 7 个一级话题: “疫情通报”“疫情科普”“官方应对”“个人应对”“观点情绪”“求助信息”“捐助信息”。之后对“个人应对”“观点情绪”和“求助信息”主题的文本数据应用上述步骤, 得到细粒度的二级分类。包括“恐惧担忧”“质疑政府/媒体”“谴责恶习”“客观评论”“科学防疫”“祈福祝愿”“呼吁救助”“复工意愿”“居家防护”“家庭宣传”“就医求助”“物资求助”和“其他”等 13 个二级话题。通过计算准确率、召回率和 F1 值, 一级话题类的准确率和 F1 值分别为 83% 和 82%, 二级话题类的准确率和 F1 值分别为 78% 和 76%。

4 讨论

4.1 机器学习方法在不同地理对象分类中的共性与差异

在机器学习领域, 分类任务主要有监督分类和非监督分类两类方法。监督分类是一种提前标注类别, 利用数据和标注标签训练分类器的方法。监督分类中通过大量标签数据的参与, 可以有效获取、构造地理要素的特征使其易于分类。非监督分类不提前进行数据标记, 可以在缺少标签的

情况下依靠数据的统计特征建立决策规则完成分类。非监督分类通常是通过聚类实现，将特征空间内分布较近的数据归为同一类别，分布较远的则为其他类别。在特征明显、类间差异较大的情况下，非监督分类是一种高效的方式。但在地理对象复杂多样时，非监督分类往往难以胜任。

两类地理要素分类在机器学习方法的使用中存在明显的共性和差异。共性包括：(1) 流程通用性。遥感分类和文本分类的流程总体一致，其本质上是将信息数字化，选取易于分类的特征信息，构建分类器，完成分类并促进其普适应用；(2) 方法相通性。遥感影像分类和网络文本分类在很多情况下是可以相互借鉴的。常用于计算机视觉的 CNN 也可用于 NLP 文本分类，常用于文本处理的 Transformer 在近两年开始在图像分类、语义分割、目标检测等领域广泛应用。差异包括：(1) 数据处理侧重点不同。文本分类重在分词与词向量的构建，影像分类重在获取目标对象的光谱、纹理以及波段指数等特征信息；(2) 方法针对性。影像数据和文本数据存在自身特点。影像本身以数字信号存储，数值的大小与地物的信息息息相关。文本信息虽然也以数字编码形式存储于计算机中，但是编码的大小难以反映不同文字之间的关联性及其含义。在分类过程中，遥感影像分类重点关注特征波段的纹理特征信息，例如以 CNN 为基础的 GoogLeNet, VGG, ResNet 等骨架神经网络常用于影像分类的任务中。而文本分类则需要考虑数据的向量化和文本的语序问题，因此向量化的 word2vec、LDA 等模型以及 RNN、LSTM 等网络常用于文本分类任务。

在以上共性与差异认识的基础上，不同地理对象分类方法之间可相互借鉴。多源异构的文本数据和遥感影像数据的结合可以促进多模态的地理对象分类的发展。文本词语的特征相似性度量可以在影像分类的特征选择中发挥作用，高精度的 POI 数据可以为遥感影像变化检测 (Zhu 等, 2022b)、遥感影像地物分类服务 (Zhu 等, 2021)；遥感影像的时空变化信息也可以反过来为文本提取和分类提供补充信息。网络大数据文本信息和遥感影像的结合，在多模态数据融合、分类体系构建和样本/语料库辅助分类 3 个方面具有前景。(1) 遥感分类可融合多模态数据 (例如 POI 数据、街景数据、GPS、光学、红外、微波等) 来提高分

类的精细度和精确度，文本分类亦可使用多源要素与文本数据的结合辅助进行分类。例如，高精度的 POI 数据、文献统计数据可为遥感数据的监督分类提供辅助样本；地理要素中的文本分类可在现有语料基础上结合地理、自然、人文知识辅助实现高精度分类与应用。(2) 遥感分类目前已经建立了多种可推广、认可度高的分类体系，使得分类结果可以被广泛应用。有些分类体系是针对全球尺度的，并且形成可更新、对比的长时序数据产品，例如全球土地覆盖数据产品 (Gong 等, 2013, 2019; Chen 等, 2015)。相比于遥感分类，文本分类目前缺乏通用的技术模式，因此可充分借鉴遥感分类的进展构建适用于不同事件的自然语言标准分词体系。(3) 遥感分类目前已经发展了多个样本库用于机器学习算法进行分类与学习，构建多尺度、多数据来源、统一分类体系的样本库可促进遥感数据分类的快速发展。自然语言处理工作中高质量语料的参与是预处理和模型训练的前提条件。发展覆盖多类型地理要素的多语言语料文本库，可推动地理要素文本分类的快速应用和发展。

4.2 人工智能在地理对象分类中的潜力挖掘

遥感影像分类发展至今，从数据的采集、加工和一致性处理和分类过程来看，已实现了多样的分类体系、方法和工具。机器学习方法可为影像分类的全过程提供智力支持，并不断有新的机器学习算法加入。用于分类的多源数据也趋向于同化，不同轨道的主被动地球观测数据、分布式的地面站点观测数据、泛在的社交媒体数据都被用于支持遥感影像分类以求获得更高的时空精度 (Estes 等, 2016; Li 等, 2017)。尽管文本数据与遥感数据在获取、存储、表达方式存在差异，但其在研究的地理对象上是存在联系的，因此针对特定的目标对象分类可以将二者结合开展研究。例如，社交媒体数据、兴趣点数据可以提供适合于精准监测地理环境的实时信息，特别是在与智慧城市、灾害应急和环境变化相关的各种应用中 (Chi 等, 2017; Eismann 等, 2009; Gamba, 2013; Huang 等, 2020; Shapiro, 2006)。

地理要素分类与人工智能的结合具有很大潜力。随着大数据的发展，多源异构数据的挖掘利用，联合文本和影像/图像的多模态学习可以为地

理对象研究提供新的方向和思路,推动构建“自然—人文—信息”的三元世界(俞肇元等,2022)。另一方面,深度学习是一个“黑匣子”,其以数据驱动为主来完成任务,但是这种方法存在难以解释、过度依赖样本数据等问题,忽略了地理知识方面的信息。随着大数据、网络化和信息化的快速发展,遥感、地信等技术越发趋向于技术发展,而忽略了地理学上的联系(李新等,2022)。传统知识驱动以专家的知识、经验和推理为前提,其解释性强,具有较强的稳定性,但是存在复杂问题难以用经验解决的情况。因此,知识驱动与数据驱动相结合是后深度学习时代发展的一大趋势(Reichstein等,2019),地球科学领域知识和深度学习方法的集成融合有望成为未来推进遥感信息提取的主流趋势(Ge等,2022;陈旻等,2021)。数据引领信息挖掘经验知识,知识指导方法合理使用数据。

5 结 论

自然要素和人文要素是地理大数据的两大组成。大数据时代下,自然要素和人文要素分类信息的提取都需要地理对象分类方法的支持。随着人工智能技术的引入,二者在分类方法上都在广泛使用机器学习和深度学习等新方法。本文回顾了地理要素分类以及人工智能发展的历程,通过对比自然和人文两类地理要素在分类流程、方法、应用方面的异同,并列出了遥感影像单一要素、复合要素提取技术和社交媒体话题分类3个案例,探讨了地理对象分类合而不同的特点。研究发现遥感影像和网络文本两类地理要素在机器学习分类方法上可相互借鉴,进一步丰富了对人工智能和大数据支持下的地理对象分类方法认识。随着大数据技术和人工智能算法的发展,两类地理要素间的协同分类发展、知识驱动分类、多模态分类研究等是未来地理要素分类可深入的研究方向。

参考文献(References)

Adams J B, Sabol D E, Kapos V, Filho R A, Roberts D A, Smith M O and Gillespie A R. 1995. Classification of multispectral images based on fractions of endmembers: application to land-cover change in the Brazilian Amazon. *Remote Sensing of Environ-*

ment, 52(2): 137-154 [DOI: 10.1016/0034-4257(94)00098-8]

Alajlan N, Bazi Y, Melgani F and Yager R R. 2012. Fusion of supervised and unsupervised learning for improved classification of hyperspectral images. *Information Sciences*, 217: 39-55 [DOI: 10.1016/j.ins.2012.06.031]

Bahdanau D, Cho K and Bengio Y. 2016. Neural machine translation by jointly learning to align and translate. arXiv: 1409.0473 [DOI: 10.48550/arXiv.1409.0473]

Blaschke T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1): 2-16 [DOI: 10.1016/j.isprsjprs.2009.06.004]

Breiman L. 1984. *Classification and Regression Trees*. New York: Routledge [DOI: 10.1201/9781315139470]

Breiman L. 1996. Bagging predictors. *Machine Learning*, 24(2): 123-140 [DOI: 10.1007/BF00058655]

Breiman L. 2001. Random forests. *Machine Learning*, 45(1): 5-32 [DOI: 10.1023/A:1010933404324]

Chen J, Chen J, Liao A P, Cao X, Chen L J, Chen X H, He C Y, Han G, Peng S, Lu M, Zhang W W, Tong X H and Mills J. 2015. Global land cover mapping at 30 m resolution: a POK-based operational approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103: 7-27 [DOI: 10.1016/j.isprsjprs.2014.09.002]

Chen M, Lv G N, Zhou C H, Lin H, Ma Z Y, Yue S S, Wen Y N, Zhang F Y, Wang J, Zhu Z Y, Xu K and He Y Q. 2021. Geographic modeling and simulation systems for geographic research in the new era: some thoughts on their development and construction. *Science China Earth Sciences*, 64(8): 1207-1223 (陈旻, 闰国年, 周成虎, 林琤, 马载阳, 乐松山, 温永宁, 张丰源, 王进, 朱之一, 许凯, 何元庆. 2021. 面向新时代地理学特征研究的地理建模与模拟系统发展及构建思考. *中国科学: 地球科学*, 51(10): 1664-1680) [DOI: 10.1360/SSTe-2020-0264]

Chi M M, Sun Z Y, Qin Y Q, Shen J S and Benediktsson J A. 2017. A novel methodology to label urban remote sensing images based on location-based social media photos. *Proceedings of the IEEE*, 105(10): 1926-1936 [DOI: 10.1109/JPROC.2017.2730585]

Cortes C and Vapnik V. 1995. Support-vector networks. *Machine Learning*, 20(3): 273-297 [DOI: 10.1007/BF00994018]

Cover T and Hart P. 1967. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1): 21-27 [DOI: 10.1109/TIT.1967.1053964]

Du P J, Xia J S, Xue C H, Tan K, Su H J and Bao R. 2016. Review of hyperspectral remote sensing image classification. *Journal of Remote Sensing*, 20(2): 236-256 (杜培军, 夏俊士, 薛朝辉, 谭琨, 苏红军, 鲍蕊. 2016. 高光谱遥感影像分类研究进展. *遥感学报*, 20(2): 236-256) [DOI: 10.11834/jrs.20165022]

Eisenecker U W. 1995. AI: the tumultuous history of the search for artificial intelligence. *AI Communications*, 8(1): 45-47 [DOI: 10.3233/AIC-1995-8108]

Eismann M T, Stocker A D and Nasrabadi N M. 2009. Automated hyperspectral cueing for civilian search and rescue. *Proceedings of*

- the IEEE, 97(6): 1031-1055 [DOI: 10.1109/JPROC.2009.2013561]
- Estes L D, McRitchie D, Choi J, Debats S, Evans T, Guthe W, Luo D, Ragazzo G, Zempeni R and Caylor K K. 2016. A platform for crowdsourcing the creation of representative, accurate landcover maps. *Environmental Modelling and Software*, 80: 41-53 [DOI: 10.1016/j.envsoft.2016.01.011]
- Freund Y and Schapire R E. 1997. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55(1): 119-139 [DOI: 10.1006/jcss.1997.1504]
- Fu B J. 2017. Geography: from knowledge, science to decision making support. *Acta Geographica Sinica*, 72(11): 1923-1932 (傅伯杰. 2017. 地理学: 从知识、科学到决策. *地理学报*, 72(11): 1923-1932) [DOI: 10.11821/dlxb201711001]
- Fu B J, Leng S Y and Song C Q. 2015. The characteristics and tasks of geography in the new era. *Scientia Geographica Sinica*, 35(8): 939-945 (傅伯杰, 冷疏影, 宋长青. 2015. 新时期地理学的特征与任务. *地理科学*, 35(8): 939-945) [DOI: 10.13249/j.cnki.sgs.2015.08.001]
- Gamba P. 2013. Human settlements: a global challenge for EO data processing and interpretation. *Proceedings of the IEEE*, 101(3): 570-581 [DOI: 10.1109/JPROC.2012.2189089]
- Gao Y, Xiong J H, Wu H, Zhang Z H, Liu J B and Li X. 2022. Frontier hotspots and development directions of geographical science research: from a perspective of national natural science foundation application keywords in 2021. *Scientia Geographica Sinica*, 42(1): 15-30 (高阳, 熊巨华, 吴浩, 张中浩, 刘建宝, 李鑫. 2022. 2021年度自然科学基金申请书关键词透视地理科学研究前沿热点与发展方向. *地理科学*, 42(1): 15-30) [DOI: 10.13249/j.cnki.sgs.2022.01.002]
- Ge Y, Zhang X X, Atkinson P M, Stein A and Li L F. 2022. Geoscience-aware deep learning: a new paradigm for remote sensing. *Science of Remote Sensing*, 5: 100047 [DOI: 10.1016/j.srs.2022.100047]
- Gong P, Liu H, Zhang M N, Li C C, Wang J, Huang H B, Clinton N, Ji L Y, Li W Y, Bai Y Q, Chen B, Xu B, Zhu Z L, Yuan C, Ping Suen H, Guo J, Xu N, Li W J, Zhao Y Y, Yang J, Yu C Q, Wang X, Fu H H, Yu L, Dronova I, Hui F M, Cheng X, Shi X L, Xiao F J, Liu Q F and Song L C. 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(6): 370-373 [DOI: 10.1016/j.scib.2019.03.002]
- Gong P, Wang J, Yu L, Zhao Y C, Zhao Y Y, Liang L, Niu Z G, Huang X M, Fu H H, Liu S, Li C C, Li X Y, Fu W, Liu C X, Xu Y, Wang X Y, Cheng Q, Hu L Y, Yao W B, Zhang H, Zhu P, Zhao Z Y, Zhang H Y, Zheng Y M, Ji L Y, Zhang Y W, Chen H, Yan A, Guo J H, Yu L, Wang L, Liu X J, Shi T T, Zhu M H, Chen Y L, Yang G W, Tang P, Xu B, Giri C, Clinton N, Zhu Z L, Chen J and Chen J. 2013. Finer resolution observation and monitoring of global land cover: first mapping results with Landsat TM and ETM+ data. *International Journal of Remote Sensing*, 34(7): 2607-2654 [DOI: 10.1080/01431161.2012.748992]
- Hinton G E and Salakhutdinov R R. 2006. Reducing the dimensionality of data with neural networks. *Science*, 313(5786): 504-507 [DOI: 10.1126/science.1127647]
- Huang Z, Qi H J, Kang C G, Su Y L and Liu Y. 2020. An ensemble learning approach for urban land use mapping based on remote sensing imagery and social sensing data. *Remote Sensing*, 12(19): 3254 [DOI: 10.3390/rs12193254]
- Joachims T. 2002. Optimizing search engines using clickthrough data// *Proceedings of the Eighth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Edmonton: Association for Computing Machinery: 133-142 [DOI: 10.1145/775047.775067]
- Kim Y. 2014. Convolutional neural networks for sentence classification// *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha: Association for Computational Linguistics: 1746-1751 [DOI: 10.3115/v1/D14-1181]
- Lecun Y, Boser B, Denker J S, Henderson D, Howard R E, Hubbard W and Jackel L D. 1989. Back-propagation applied to handwritten zip code recognition. *Neural Computation*, 1(4): 541-551 [DOI: 10.1162/neco.1989.1.4.541]
- Legleiter C J, King T V, Carpenter K D, Hall N C, Mumford A C, Sloanecker T, Graham J L, Stengel V G, Simon N and Rosen B H. 2022. Spectral mixture analysis for surveillance of harmful algal blooms (SMASH): a field-, laboratory-, and satellite-based approach to identifying cyanobacteria genera from remotely sensed data. *Remote Sensing of Environment*, 279: 113089 [DOI: 10.1016/j.rse.2022.113089]
- Li J, Benediktsson J A, Zhang B, Yang T and Plaza A. 2017. Spatial technology and social media in remote sensing: a survey. *Proceedings of the IEEE*, 105(10): 1855-1864 [DOI: 10.1109/JPROC.2017.2729890]
- Li K, Wang J L and Yao J Y. 2021. Effectiveness of machine learning methods for water segmentation with ROI as the label: a case study of the Tuul River in Mongolia. *International Journal of Applied Earth Observation and Geoinformation*, 103: 102497 [DOI: 10.1016/j.jag.2021.102497]
- Li M, Zang S Y, Zhang B, Li S S and Wu C S. 2014. A review of remote sensing image classification techniques: the role of spatio-contextual information. *European Journal of Remote Sensing*, 47(1): 389-411 [DOI: 10.5721/EuJRS20144723]
- Li X, Zheng D H, Feng M and Chen F H. 2022. Information geography: the information revolution reshapes geography. *Science China Earth Sciences*, 65(2): 379-382 (李新, 郑东海, 冯敏, 陈发虎. 2022. 信息地理学: 信息革命重塑地理学. *中国科学: 地球科学*, 52(2): 370-373) [DOI: 10.1360/SSTe-2021-0184]
- Maron M E. 1961. Automatic indexing: an experimental inquiry. *Journal of the ACM*, 8(3): 404-417 [DOI: 10.1145/321075.321084]
- McCulloch W S and Pitts W. 1990. A logical calculus of the ideas im-

- manent in nervous activity. 1943. *Bulletin of Mathematical Biology*, 52(1/2): 99-115
- Mitchell T M. 1997. *Machine Learning*. New York: McGraw-Hill, Inc.
- Novikoff A B. 1962. Cytochemical staining methods for enzyme activities: their application to the rat parotid gland. *The Jewish Memorial Hospital bulletin*, 6-7: 70-93
- Quinlan J R. 1986. Induction of decision trees. *Machine Learning*, 1(1): 81-106 [DOI: 10.1007/BF00116251]
- Quinlan J R. 1993. *C4.5: Programs for Machine Learning*. San Francisco: Morgan Kaufmann Publishers, Inc.
- Reichstein M, Camps-Valls G, Stevens B, Jung M, Denzler J, Carvalhais N and Prabhat. 2019. Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743): 195-204 [DOI: 10.1038/s41586-019-0912-1]
- Ren W and Ge Y. 2011. Progress on sub-pixel mapping methods for remotely sensed images. *Remote Sensing Technology and Application*, 26(1): 33-44 (任武, 葛咏. 2011. 遥感影像亚像元制图方法研究进展综述. *遥感技术与应用*, 26(1): 33-44) [DOI: 10.11873/j.issn.1004-0323.2011.1.33]
- Rosenblatt F. 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6): 386-408 [DOI: 10.1037/h0042519]
- Rumelhart D E, Hinton G E and Williams R J. 1988. Learning internal representations by error propagation//Collins A and Smith E E, eds. *Readings in Cognitive Science*. San Mateo: Morgan Kaufmann, 399-421 [DOI: 10.1016/B978-1-4832-1446-7.50035-2]
- Salcedo-Sanz S, Ghamisi P, Piles M, Werner M, Cuadra L, Moreno-Martínez A, Izquierdo-Verdiguier E, Muñoz-Marí J, Mosavi A and Camps-Valls G. 2020. Machine learning information fusion in earth observation: a comprehensive review of methods, applications and data sources. *Information Fusion*, 63: 256-272 [DOI: 10.1016/j.inffus.2020.07.004]
- Schapire R E. 1990. The strength of weak learnability. *Machine Learning*, 5(2): 197-227 [DOI: 10.1007/BF00116037]
- Shapiro J M. 2006. Smart cities: quality of life, productivity, and the growth effects of human capital. *The Review of Economics and Statistics*, 88(2): 324-335 [DOI: 10.1162/rest.88.2.324]
- Socher R, Huval B, Manning C D and Ng A Y. 2012. Semantic compositionality through recursive matrix-vector spaces//Proceedings of the 2012 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning. Jeju Island: Association for Computational Linguistics: 1201-1211
- Socher R, Pennington J, Huang E H, Ng A Y and Manning C D. 2011. Semi-supervised recursive autoencoders for predicting sentiment distributions//Proceedings of the 2011 Conference on Empirical Methods in Natural Language Processing. Edinburgh: Association for Computational Linguistics: 151-161
- Socher R, Perelygin A, Wu J, Chuang J, Manning C D, Ng A and Potts C. 2013. Recursive deep models for semantic compositionality over a sentiment treebank//Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing. Seattle: Association for Computational Linguistics: 1631-1642
- Song Q. 2016. *Object-based Image Analysis with Machine Learning Algorithms for Cropping Pattern Mapping Using GF-1/WFV Imagery*. Beijing: Chinese Academy of Agricultural Sciences: 92 (宋茜. 2016. 基于GF-1/WFV和面向对象的农作物种植结构提取方法研究. 北京: 中国农业科学院: 92)
- Tai K S, Socher R and Manning C D. 2015. Improved semantic representations from tree-structured long short-term memory networks//Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). Beijing: Association for Computational Linguistics: 1556-1566 [DOI: 10.3115/v1/P15-1150]
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, Kaiser L and Polosukhin I. 2017. Attention is all you need. arXiv: 1706.03762 [DOI: 10.48550/arXiv.1706.03762]
- Walter V. 2004. Object-based classification of remote sensing data for change detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3/4): 225-238 [DOI: 10.1016/j.isprsjprs.2003.09.007]
- Wang F. 1990. Fuzzy supervised classification of remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 28(2): 194-201 [DOI: 10.1109/36.46698]
- Wang J L, Zhang M, Han X H, Wang X J and Zheng L. 2020. Spatio-temporal evolution and regional differences of the public opinion on the prevention and control of COVID-19 epidemic in China. *Acta Geographica Sinica*, 75(11): 2490-2504 (王卷乐, 张敏, 韩雪华, 王晓洁, 郑莉. 2020. COVID-19疫情防控中的中国公众舆情时空演变特征. *地理学报*, 75(11): 2490-2504) [DOI: 10.11821/dlxb202011016]
- Xu J, Ding Y X and Wang X L. 2007. Sentiment classification for Chinese news using machine learning methods. *Journal of Chinese Information Processing*, 21(6): 95-100 (徐军, 丁宇新, 王晓龙. 2007. 使用机器学习方法进行新闻的情感自动分类. *中文信息学报*, 21(6): 95-100) [DOI: 10.3969/j.issn.1003-0077.2007.06.013]
- Xu J B, Song J, Li B C, Liu D and Cao X S. 2021. Combining night time lights in prediction of poverty incidence at the county level. *Applied Geography*, 135: 102552 [DOI: 10.1016/j.apgeog.2021.102552]
- Yang Z C, Yang D Y, Dyer C, He X D, Smola A and Hovy E. 2016. Hierarchical attention networks for document classification//Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. San Diego: Association for Computational Linguistics: 1480-1489 [DOI: 10.18653/v1/N16-1174]
- Yu F H, Zhao D, Guo Z F, Jin Z Y, Guo S, Chen C L and Xu T Y. 2022. Characteristic analysis and decomposition of mixed pixels from UAV hyperspectral images in rice tillering stage. *Spectroscopy and Spectral Analysis*, 42(3): 947-953 (于丰华, 赵丹, 郭忠辉, 金忠煜, 郭爽, 陈春玲, 许童羽. 2022. 水稻分蘖期无人机高光谱影

- 像混合像元特征分析与分解. 光谱学与光谱分析, 42(3): 947-953 [DOI: 10.3964/j.issn.1000-0593(2022)03-0947-07]
- Yu Q, Gong P, Clinton N, Biging G, Kelly M and Schirokauer D. 2006. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering and Remote Sensing*, 72(7): 799-811 [DOI: 10.14358/PERS.72.7.799]
- Yu Z Y, Yuan L W, Wu M G, Zhou L C, Luo W, Zhang X Y and Lv G N. 2022. Classification and description of geographic information from the perspective of geography. *Journal of Geo-information Science*, 24(1): 17-24 (俞肇元, 袁林旺, 吴明光, 周良辰, 罗文, 张雪英, 闫国年. 2022. 地理学视角下地理信息的分类与描述. *地球信息科学学报*, 24(1): 17-24) [DOI: 10.12082/dqxxkx.2022.210817]
- Zhang G X, Cao Z X and Gu Y J. 2005. A hybrid classifier based on rough set theory and support vector machines//Second International Conference on Fuzzy Systems and Knowledge Discovery. Changsha: Springer: 1287-1296 [DOI: 10.1007/11539506_162]
- Zhao D P, Gu H Y and Jia Y. 2016. Comparison of machine learning method in object-based image classification. *Science of Surveying and Mapping*, 41(10): 181-186 (赵丹平, 顾海燕, 贾莹. 2016. 机器学习法在面向对象影像分类中的对比分析. *测绘科学*, 41(10): 181-186) [DOI: 10.16251/j.cnki.1009-2307.2016.10.036]
- Zheng Z H, Wu W B, Chen X, Hu R X, Liu X and Wang P. 2018. A traffic sensing and analyzing system using social media data. *Acta Automatica Sinica*, 44(4): 656-666 (郑治豪, 吴文兵, 陈鑫, 胡荣鑫, 柳鑫, 王璞. 2018. 基于社交媒体大数据的交通感知分析系统. *自动化学报*, 44(4): 656-666) [DOI: 10.16383/j.aas.2017.c160537]
- Zhu Q Q, Guo X, Deng W H, Shi S N, Guan Q F, Zhong Y F, Zhang L P and Li D R. 2022b. Land-Use/Land-Cover change detection based on a Siamese global learning framework for high spatial resolution remote sensing imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 184: 63-78 [DOI: 10.1016/j.isprsjprs.2021.12.005]
- Zhu Q Q, Lei Y, Sun X L, Guan Q F, Zhong Y F, Zhang L P and Li D R. 2022a. Knowledge-guided land pattern depiction for urban land use mapping: a case study of Chinese cities. *Remote Sensing of Environment*, 272: 112916 [DOI: 10.1016/j.rse.2022.112916]
- Zhu Q Q, Zhang Y N, Wang L Z, Zhong Y F, Guan Q F, Lu X Y, Zhang L P and Li D R. 2021. A Global Context-aware and Batch-independent Network for road extraction from VHR satellite imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 175: 353-365 [DOI: 10.1016/j.isprsjprs.2021.03.016]

Development and prospects of machine learning methods in geographic elements classification

WANG Juanle^{1,3,5}, LI Kai^{1,2}, YAN Xinrong^{1,3}, ZHENG Li^{1,4}, HAN Xuehua^{1,3}

1. State Key Laboratory of Resources and Environmental Information System, Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, China;
2. College of Geoscience and Surveying Engineering, China University of Mining & Technology (Beijing), Beijing 100083, China;
3. University of Chinese Academy of Sciences, Beijing 100049, China;
4. Institute of Disaster Prevention, Sanhe 065201, China;
5. Jiangsu Center for Collaborative Innovation in Geographical Information Resource Development and Application, Nanjing 210023, China

Abstract: Geographic objects typically include both physical and human elements. The big data produced by remote sensing and the ubiquitous social media data provide rich sources for the feature classification of these two types of objects. The extraction of physical objects based on remote sensing classification and the extraction and classification of social media information based on web text are the current mainstream methods of extracting geographic objects. The former is supported by image processing technology, whereas the latter is achieved using natural language processing technology. With the application of artificial intelligence classification methods such as machine learning, the classification characteristics of these two types of elements are becoming increasingly common. Using the evolution of machine learning methods as a medium, in this study, we compared the remote sensing classification of single- and multiple-element physical geographic elements and the natural language processing classification of web text elements. Since the 1940s, the development of machine learning methods has experienced five stages, namely, germination, development, bottleneck, recovery, and outbreak. Machine learning and related information classification methods have become the current focus of researchers. We described the principle applied by machine learning methods for geographic element classification and divided the classification process of geographic elements into data acquisition, data preprocessing, feature construction or model training, and accuracy evaluation. We observed many similarities between physical-element-oriented remote sensing classification and human-element-oriented text classification in terms of their process and model. However, text and remote sensing classifications also differ in their data and tasks. By using single objects, compound object classification, and microblog social media topic classification extraction as three examples for remote sensing classification, we further examined the

process of completing different geographic element classification tasks. We then built a pixel-based CNN model to classify the water bodies in the Tuul River region of Mongolia. Land cover classification mainly adopts random forest, decision tree, maximum likelihood, support vector machine, and pixel-object-knowledge methods to map the global land cover. Social media classification uses latent Dirichlet allocation and a random forest algorithm to classify the public sentiment on COVID-19 topics in microblogs. From the discussion, we noted similarities and differences in the use of machine learning methods for classifying the two types of geographical elements. Remote sensing and text classification are generally consistent, while remote sensing image classification and web-based text classification can learn from each other in many cases. The differences between these methods lie in their focuses on data processing and targeting. Specifically, text classification focuses on word separation and word vector construction, whereas image classification focuses on obtaining feature information, such as the spectrum, textures, and band indices of the target objects. The combination of geographic element classification and artificial intelligence has considerable potential. With the development of big data and the mining and use of multisource heterogeneous data, the multimodal learning of joint text and images can provide new directions and ideas for geographic object research. The integrated fusion of geoscience-domain knowledge and deep learning methods is expected to become a mainstream approach for advancing remote sensing information extraction in the future. The mutual reference among classification methods for remote sensing and social media big data can expand the applications of the intelligent classification of physical and human geographic elements.

Key words: geographic elements classification, physical geography elements, human geography elements, machine learning, remote sensing classification, web text classification, natural language processing

Supported by Strategic Priority Research Program (Class A) of the Chinese Academy of Sciences (No. XDA19040501); Construction Project of the China Knowledge Center for Engineering Sciences and Technology (No. CKCEST-2022-1-41)