

DOI:10.13203/j.whugis20180172



文章编号:1671-8860(2018)12-1861-11

# 遥感大数据时代与智能信息提取

张 兵<sup>1, 2</sup>

1 中国科学院遥感与数字地球研究所,北京,100094

2 中国科学院大学,北京,101408

**摘 要:**近年来,天地一体化对地观测系统与智能计算技术的快速发展为遥感科技进步甚至变革提供了难得的机遇。遥感信息技术在历经 20 世纪 60~80 年代以统计数学模型为核心的数字信号处理时代、从 90 年代至今以遥感信息物理量化为标志的定量遥感时代之后,现在正逐渐进入一个以数据模型驱动、大数据智能分析为特征的遥感大数据时代。在总结遥感信息技术历史发展脉络的基础上,阐述了遥感大数据的内涵和智能信息提取的时代特点,并从遥感大数据的理念出发,论述了面向对象的遥感知识库构建,分析了融合遥感知识和深度学习算法的大数据智能信息提取策略。通过典型实例,介绍了以深度学习为代表的智能算法在遥感大数据目标检测、精细分类、参数反演等方面的发展现状与趋势,并讨论了深度学习在遥感大数据时代的智能信息提取方面的应用潜力。

**关键词:**遥感;大数据;深度学习;智能信息提取;神经网络

**中图分类号:**P237

**文献标志码:**A

## 1 遥感大数据是遥感信息科技发展的新阶段

现代遥感技术起源于 20 世纪 60 年代,以数字化和多谱段成像为特征,区别于以胶片为主要信息载体的传统航空摄影测量技术,它主要通过获取地物电磁波辐射信息并构建其数理模型的方式描述地物特征<sup>[1-2]</sup>。在整个 60~80 年代,即便是在传感器谱段设置中遵循了一定的地物电磁波谱特性准则,但是基于精确的图像物理量纲,尤其是与地学过程模型的深入耦合研究还是比较少见的。遥感图像处理算法更多偏重于图像灰度拉伸和增强等相对变换,其分类、参数提取等也多是基于真值与图像 DN(digital number)值之间的统计建模,诸如 Lyzenga<sup>[3]</sup>、Strahler<sup>[4]</sup>等一批统计学专家将传统统计学方法用于遥感图像分析建模,为遥感图像的统计学建模发展奠定了基础,开启了遥感图像的数字信号处理时代。

由于遥感的成像条件极易受大气、地形等外在因素的影响,统计模型始终受到样本代表性和模型通用性等问题的困扰。20 世纪 90 年代,基于先验知识和物理模型的定量遥感方法将遥感信

息与地表目标参数联系起来,定量地反演或推算相关地学目标参数<sup>[5]</sup>。遥感信息科技自此进入了一个以遥感信息物理量化为特征的定量遥感时代,尤其是从 2000 年开始美国地球观测系统(earth observation system, EOS)卫星开始提供 MODIS 全球定量遥感产品为其标志性事件。融合物理学知识的定量遥感数据产品和定量遥感反演模型是这个时代最典型的特征,比如,遥感图像大气校正方法愈加完善,植被叶片反射率模型 PROSPECT<sup>[6]</sup>和植被冠层二向反射模型 SAIL<sup>[7]</sup>等一些地物辐射传输模型也逐渐走向成熟和实用。定量遥感相对于统计遥感建模大大提高了人类利用遥感技术认知地物本质特征的能力。

近年来,随着航空航天科技的飞速发展,从微纳卫星到星座组网以及未来的智能遥感卫星系统<sup>[8]</sup>、从无人机到平流层飞艇、从地面观测台站到无线传感网,形成了天地一体化的空间信息网络,它们为人类提供了超高维度和超高频次的地球观测数据,且不同成像方式、不同波段、不同分辨率、不同观测尺度和维度的对地观测数据及其辅助定标与验证数据都呈爆发式增长。这些海量、多源、异构数据的快速增长不仅带动了遥感数据分析方

收稿日期:2018-05-15

项目资助:中国科学院战略性先导科技专项(XDA19080302)。

作者简介:张兵,博士,研究员,主要从事高光谱遥感与遥感大数据研究。zb@radi.ac.cn

法和技术的快速发展,也改变了人类利用遥感数据认知世界的方式。天地一体化的遥感观测能力与智能计算技术的突飞猛进为遥感科技发展打开了一扇崭新的大门。如果说从现代遥感诞生的20世纪60~80年代是一个以数学统计建模为核心的数字信号处理时代,从90年代至今是一个以遥感信息物理量化为标志的定量遥感时代,那么随着大数据技术的发展,未来遥感信息技术将逐渐进入一个以智能信息提取为特征的遥感大数据时代。

2007年1月,图领奖得主、著名的计算机科学家吉姆·格雷在“科学方法的一次革命”演讲中提出了科学研究的第四类范式:数据密集型科学发现,也就是现在我们所称的大数据(big data),这是继传统的实验范式、理论范式、仿真范式之外,人类认知领域的一种全新方式。牛顿力学和相对论分别是实验范式和理论范式成功应用的两个经典案例;仿真范式是先提出可能的理论,再搜集相应的数据,最后通过计算机仿真进行理论验证;而大数据或称大数据技术是先有了大量的已知数据,然后通过计算得出之前未知的知识和规律。所以,大数据是一种包含了数据处理行为的全新的科学发现和信息挖掘手段,它既包含数据本身,也包括方法论,两者缺一不可。

如前所述,天地一体化的空间信息网络为人类提供了无处不在的多层次、多角度、多波段、多维度、多时相的遥感观测及其辅助数据,在数据层面上已经体现了体量巨大(Volume)、种类繁多(Variety)、动态多变(Velocity)、冗余模糊(Veracity)和高价值(Value)的5V特征<sup>[1]</sup>。在方法论层面上,遥感大数据是针对传统遥感数据处理和信息提取方式的一种变革,它以多源遥感数据为主综合其他多源辅助数据,运用大数据思维与手段,聚焦于更高价值的信息和知识规律的发现。相对遥感数字信号处理时代的统计模型和定量遥感时代的物理模型,遥感大数据时代的信息提取和知识发现是以数据模型为驱动,其本质是以大样本为基础,通过机器学习等智能方法自动学习地物对象的遥感化本征参数特征,进而实现对信息的智能化提取和知识挖掘。

智能信息提取是遥感大数据方法的明显特征和必然要求。多源异构海量遥感数据不仅对计算能力提出了更高的要求,而且对数据处理方法本身也提出了新要求,传统处理方法无法满足遥感大数据的处理精度和效率<sup>[9]</sup>。为满足日益增长的用户需求,智能化信息提取方法应运而生。支持

向量机<sup>[10]</sup>以及Boosting<sup>[11]</sup>等方法,根据少量样本数据通过训练学习自动构建信息提取模型,可以在小范围内得到很好的应用,自20世纪90年代发展以来迅速成为遥感智能信息提取的主流算法。然而这类算法由于其少量样本数据构建,模型参数容量有限,所以模型泛化能力较弱,被称为浅层机器学习。2006年深度学习算法的突破<sup>[12]</sup>将机器学习算法推向高潮。Krizhevsky等人建立的AlexNet是第一个具有现代意义的卷积神经网络,在ILSVRC 2012图像分析竞赛中获得了远远高于传统方法的成绩,展示了以基于深度学习为代表的人工智能算法在处理大数据方面的优势<sup>[13]</sup>。近年来,深度学习网络模型不断完善,在图像识别和信息提取方面取得突破性进展,在很多任务上的精度已然超过人工识别精度。

深度学习在计算机视觉领域的巨大成功为遥感大数据信息智能提取提供了重要机遇<sup>[14]</sup>,近年来,大量学者尝试将针对RGB三波段真彩色自然图像的神经网络引入遥感图像领域,在遥感图像分类<sup>[15-16]</sup>和目标探测<sup>[17-18]</sup>等方面的应用效果远优于传统算法。即便如此,遥感图像数据由于其产生方式、获取条件、数据信息和应用等诸多方面都相对常规自然图像具有非常明显的独特性,使得现有基于数码照片设计的深度学习算法仍旧无法深入挖掘遥感图像蕴含的辐射、光谱及地理化参数等信息。此外,遥感图像观测尺度大、场景复杂,现有网络模型对遥感图像的理解和特征提取还存在明显不足。因此,基于对地球观测信息的理解 and 应用需求,研究融合遥感数据特征与深度学习等智能信息提取算法,构建适用于遥感大数据的模型、方法与系统工具,是解决遥感大数据时代信息提取与知识挖掘的必由之路。

## 2 遥感大数据知识库构建和深度学习网络开发

遥感大数据时代的信息提取是以数据驱动下的信息分析模型为主要特征,深度学习是目前适用于这种需求的最优算法。深度学习在计算机视觉领域的巨大成功是建立在ImageNet<sup>[19]</sup>等海量图像样本库、众多神经网络模型,以及基于图形处理器(graphic processing unit, GPU)的快速计算能力基础上的。针对遥感数据的特殊性,融合遥感数据特征的样本库构建和深度学习网络开发是将深度学习成功应用到遥感领域的关键。

## 2.1 面向对象的遥感知识库构建

遥感大数据时代信息提取最突出的表现是以数据驱动模型来代替基于统计或物理知识模型,数据本身发挥着决定性作用<sup>[19-21]</sup>。以深度学习为代表的机器学习算法本质上是采用监督学习的方式,通过大量样本数据来学习目标本质特征,并据此对未知数据进行预测判别。因此,具有属性标记的样本数据是其取得成功的决定性因素之一<sup>[22-23]</sup>。计算机视觉领域经过多年的发展已经构建了以 ImageNet 为代表的众多自然图像样本库。在遥感领域,研究者们已经构建了一些用于目标探测<sup>[20, 24-26]</sup>和图像分类<sup>[27-31]</sup>的标记样本库。这些样本库在一定程度上支持了机器学习算法在遥感领域的发展。

与地面拍摄的小场景自然影像相比,遥感图像具有大场景成像、尺度效应明显、观测角度差异大、空间位置特征突出、电磁波特性差异大,以及所有地物都具有明确地理学环境背景等特点。地表场景的复杂性、成像条件与成像载荷类型的多样性给遥感图像样本数据库的建立带来了挑战。遥感大场景成像的特点也决定了遥感图像内会包含分布复杂的多种地物类型,同一类地物在不同成像条件下的特征可能存在部分差异,并且具有十分明显的尺度效应;不同光照条件、大气参数都会对遥感图像特征产生影响,在不同季节、不同纬度的光照条件下,同一地物在同一传感器获取的数据中可能表现出具有极大差异性的光谱辐射特征,同一地物由于天气条件的不同,成像特征也会产生明显变化;另一方面,卫星、飞机、飞艇等不同平台搭载的传感器在波段设置、空间分辨率、信噪比、成像角度等方面的参数也千差万别,传感器在轨服役期间的成像性能也通常会随着时间的推移而下降。

遥感图像的复杂性和遥感应用的多样性要求遥感图像样本库相对自然图像样本库具有更多的属性。遥感图像包含了丰富的地表自然属性和社会属性,从应用的角度来看,除了对单一地物目标信息的提取,很多情况下是对多种图像目标综合体的提取。例如,“机场”这一目标实际是包括飞机、跑道、航站楼、廊桥等多种目标的组合体,而且当我们从遥感图像提取机场信息时也非常关注图像获取时间等信息。计算机视觉领域中只记录自然图像及其类别属性信息的样本库,显然已无法满足基于深度学习在遥感图像信息提取和应用两方面的需求,应该发展记录目标对象或地类的样本标记数据、图像元数据及其地理学属性、背景和

其他关联大数据信息的遥感知识库。

面向对象的遥感知识库是以单一地物或者地物组合体为关注对象,既记录单一地物,又记录其特征性的存在背景和关联数据,不仅为深度神经网络提供基础图像及对应的属性类别、位置信息,还提供了地物对象的物理和社会特征等辅助信息。以建筑物遥感知识库为例,遥感图像中有多个建筑物目标,在知识库中,每个图像的元数据记录了该图像获取的传感器名称、波段设置、空间分辨率、成像时间、成像条件、信噪比等信息;每个建筑物目标的样本标记数据记录了该建筑物的属性类别(如居住建筑、公共建筑、工业建筑、农业建筑等)、位置信息(相对坐标或地理坐标);物理属性记录了该建筑物的高度、屋顶材料的光谱曲线、特殊纹理形状等信息;社会属性记录了该建筑物的社会功能,如学校、医院、体育馆、交通设施等;地理学背景等信息记录该建筑物在图像中的邻域地物及其关系信息,如学校建筑和体育馆的周边一般有运动场等信息;其他关联大数据信息包括与该建筑物相关的、可以辅助信息提取与分析的数据,如该建筑物的街景图片,定位于该建筑物的社交媒体数据等。这就是一种基于遥感大数据理念的面向对象的遥感知识库构建。

面向对象的遥感知识库不仅能够满足基于深度学习系统的遥感大数据信息提取标记样本需求,而且也为人工智能方法与传统物理模型的融合研究以及遥感信息产品的应用分析建立了丰富的知识储备。

## 2.2 融合遥感特征的深度学习网络开发

尽管深度学习已经在传统计算机视觉领域取得了突飞猛进的发展,但是在遥感领域中深度学习的研究才刚刚起步,大量工作仅仅是从传统计算机视觉领域中迁移过来的,还没有形成符合遥感数据特点的专用深度学习网络模型。探讨遥感数据特点,开发适用于遥感大数据信息挖掘特点的深度学习网络模型是促进深度学习在遥感领域应用的关键。

1998年,Lecun等<sup>[32]</sup>总结完善了经典卷积神经网络在手写体数字识别中的应用;2012年,Hinton 研究组开发的 AlexNet 网络一举夺得 ImageNet 图像识别比赛冠军<sup>[13]</sup>,深度学习在自然语言、语音识别、自然图像处理等多个领域取得了突破性的进展,这些巨大成功主要得益于深度学习模型与海量样本数据接近完美的统一。现有的深度学习网络模型主要是针对真彩色自然图像,大多不支持多波段的遥感数据格式,而且在图



但是,深度学习算法和神经网络系统已经被广泛迁移到遥感数据分析中,并在大区域的目标检测、图像分类、参数提取等方面取得了很大进步,彰显了深度学习算法在遥感领域的巨大优势和应用潜力。本文在分析总结深度学习在遥感信息应用的基础上,用一些典型案例来分析深度学习在遥感信息智能提取方面的优势和潜力。

### 3.1 大区域典型目标快速检测

进入遥感大数据时代,随着空间和时间分辨率的不断提高,遥感图像的复杂度和数据量呈几何级数增加,在大场景中进行目标自动检测越来越需要更加智能的算法。以深度学习为代表的智能算法在计算机视觉领域已经取得了突破性进展,针对自然图像目标检测算法主要分为两种方式,一种是基于候选区域的目标检测算法,如 R-CNN<sup>[34]</sup>、Fast R-CNN<sup>[35]</sup>、Faster R-CNN<sup>[36]</sup>以及 SPP-Net<sup>[37]</sup>等,这类方法由于需要通过滑动窗口来产生预选窗口,计算量比较大,且无法达到实时的目标检测。另外一种是基于回归方法的目标检测算法,如 YOLO<sup>[38]</sup>、YOLO2<sup>[39]</sup>和 SSD<sup>[33]</sup>等,这类方法使用了回归的思想来确定图像中目标边框以及类别,大大提高了目标检测速度。这些算法在对自然图像的目标检测中取得了甚至超过人类识别能力的巨大成功,为遥感领域应用奠定了良好基础。

遥感图像场景和目标复杂性使得深度学习在遥感领域中的应用遇到诸多挑战,在过去几年里,遥感学者在针对自然图像目标检测算法的基础上做了不同尝试和改进。Chen 等将深度卷积神经网络的各个卷积层分成几个平行的分支层,在保证相同结构参数的同时,减少了全连接层,增加了模型对复杂遥感图像的训练效率<sup>[38]</sup>;通过将深度神经网络最后固定感受野的卷积层转化成不同感受野的卷积层,每层应用不同尺寸的最大池化层,从而获取目标不同尺度下的特征,提高检测精度<sup>[39]</sup>。Jiang 等利用基于图论的超像素分割方法提取一系列图像块,然后训练深度卷积神经网络对图像块进行二分类来判断是否为车辆<sup>[40]</sup>。Zhang 等使用修正过的椭圆和线性检测器挑选出候选图片,然后计算图片的梯度直方图特征获取局部形状信息,利用预训练卷积神经网络模型获取图片特征,最后根据支持向量机对特征进行分类来识别油罐<sup>[41]</sup>。Tang 等利用小波压缩挑选舰船候选照片,然后使用深度卷积神经网络提取高层特征,最后使用极限学习机判断该特征是否属于舰船<sup>[42]</sup>。Zhu 等<sup>[26]</sup>和 Cheng 等<sup>[43]</sup>在 AlexNet

模型之前对训练样本进行了旋转增强操作,提高了神经网络模型对目标的旋转不变性,在一定程度上增加了样本的多样性,但是数据增强只是提高模型泛化能力的一种方式,对于模型性能和精度的提高并没有本质的影响。Radovic 等<sup>[44]</sup>和 Chen 等<sup>[45]</sup>通过迁移学习使用计算机领域成熟的目标检测算法检测飞机,该方法在一定试验区内效果很好,但由于训练样本单一、数量少,无法泛化应用于大范围的目标检测。

从目前深度学习在遥感领域的目标检测效果来看,通过迁移计算机视觉领域针对 RGB 三波段自然图像的目标检测模型,结合遥感图像特征加以改进优化,能够取得相对传统算法更加理想的效果。但从对遥感数据的适用程度和应用效果来看,遥感特征与深度学习神经网络算法的融合仍然处于起步阶段,而遥感知识样本库的不足则是限制深度学习神经网络在遥感目标检测中深入应用的另外一个关键因素。

笔者团队基于面向对象的遥感知识库和融合遥感大数据特征的深度学习网络,利用 1.19 m 分辨率遥感影像实现了全国室外运动场(包括田径场、足球场和篮球场)的提取。由于全国范围内运动场的多样性、自然场景的复杂性以及图像本身的巨大差异,导致看似简单的全国范围运动场提取变得极其复杂,不仅运动场自身差异很大,而且很多虚假目标容易被错误提取,比如带一圈小路的池塘、高速公路立交桥弯道、带小路的花坛等等都具有田径场局部或者全部特征。为了解决这些难题,本文从遥感数据准备、样本选择与制作、模型设计与训练等几个方面不断迭代,最终实现了超过 90% 的识别精度。在工程实施上,利用苍灵系统的工程化处理能力,将全国 960 万 km<sup>2</sup> 米级分辨率图像制作成了 2 014 万份 768×768 像素的图像切片,在 72 h 内完成了全国室外运动场的全自动提取。

### 3.2 遥感图像快速自动分类

遥感图像分类是遥感应用中的经典问题,传统基于像素的图像分类方法在分类精度和算法泛化能力方面都难以适用于大范围遥感图像的自动处理。深度学习在计算机视觉领域的成功为遥感大数据自动分类提供了新的技术方法,2015 年出现的全卷积神经网络(fully convolutional networks, FCN)是最具有标志性的图像分割模型,开启了深度学习在自然图像分割方面的应用<sup>[46]</sup>。随后 Chen 等提出了 DeepLab 网络,该网络引入了空洞卷积的思想及条件随机场(conditional

random field, CRF)后处理流程,大大提升了语义分割的精度<sup>[47]</sup>。Zhao等提出了PSPNet网络,该网络利用池化金字塔的思想,在不依赖任何后处理流程的情况下,进一步提升了语义分割的精度<sup>[48]</sup>。针对遥感数据的特殊性,一些研究人员开始尝试将自然图像语义分割网络模型迁移到遥感影像地物分类中来,探索将遥感的多波段辐射信息、光谱信息与空间纹理信息融合,力求达到最优的遥感信息深度挖掘和利用。

Hu等使用了只有5层网络的一维卷积神经网络对高光谱图像从像素的光谱维度进行高光谱影像分类,由于没有考虑像素之间的语义信息和影像空间纹理等信息,因此不能克服椒盐噪声<sup>[49]</sup>。Makantasis等构建了一个二维卷积神经网络,提取光谱与空间维度上的特征信息,然后使用多层感知机结构完成分类<sup>[50]</sup>。Kussul等使用一维与二维卷积神经网络分别提取一维光谱信息和二维空间纹理信息,由于没有将两种信息有机地融合起来,光谱维度上依旧是基于像素的分类,椒盐噪声依然明显<sup>[51]</sup>。为了避免过拟合问题,Zhao和Du提出了一种基于空谱特征提取的高光谱图像分类模型,该模型使用降维和深度学习算法分别对光谱特征及空间特征进行提取和融合,并基于融合后的特征进行训练和分类<sup>[52]</sup>。Santara等提出了一种端对端的波段自适应光谱与空间特征学习网络来解决维度灾难问题,这两种网络结构通过光谱降维方式在降低光谱维复杂度的同时也丢失很多光谱信息<sup>[53]</sup>。Chen等<sup>[47]</sup>和Li等<sup>[54]</sup>使用了三维卷积神经网络结构同时提取出空间特征信息以及光谱特征信息,但是这种网络模型结构的参数量非常多,由于遥感样本不足,容易出现模型过拟合与泛化能力弱的问题。Marcos等提出了一种包含两个分支的神经网络结构分别处理多光谱影像数据与数字表面模型(digital surface model, DSM)数据,然后融合两种特征信息实现分类,由于网络结构庞大且多源数据样本集较小,又缺乏遥感数据增强,出现了模型过拟合的问题<sup>[55]</sup>。

从当前的应用情况来看,基于深度学习的神经网络模型在遥感领域已经展示了其巨大的潜力,但仍需要针对遥感数据特点开发相应数据增强方法和能够充分利用遥感数据辐射传输理论、多(高)光谱信息以及多源信息的专用神经网络系统。为满足上述需求,苍灵系统以ResNet<sup>[56]</sup>和PSPNet<sup>[48]</sup>为原型,结合4波段遥感数据特点构建了一个60层、约310万参数的深度学习网络结构,网络系统完全兼容遥感数据格式,并开发了数

据增强模块以提高样本的多样性。图2是利用苍灵系统对广东省GF-2卫星图像(4波段1 m分辨率)的自动分类结果,地类包括建成区、道路、水体、耕地、林地、农业设施等类型,分类结果总体交并比(intersection over union, IoU)精度0.7187, F1-score 0.8044。从目视效果看,较好地保留了地物对象特性,很少有椒盐噪声,地类混淆错误也较少。分类结果误差主要发生在地物边界地区,产生这种误差的最主要原因是参与训练的人工解译真值与遥感图像具有一定偏差。这种偏差一方面来自所谓真值本身的误差(约15%左右),这些误差不仅会降低模型精度,而且也给精度评价带来很大不确定性;另一方面,训练真值和遥感图像在时相上也存在一定偏差,地物类型可能略有变化。广东全省自动分类实验一方面展示了苍灵系统全自动分类的高精度,另一方面也展示了基于深度学习的神经网络系统的分类效率,广东全省18万km<sup>2</sup>1 m分辨率图像自动分类利用1台8 GPU服务器仅需26 h。

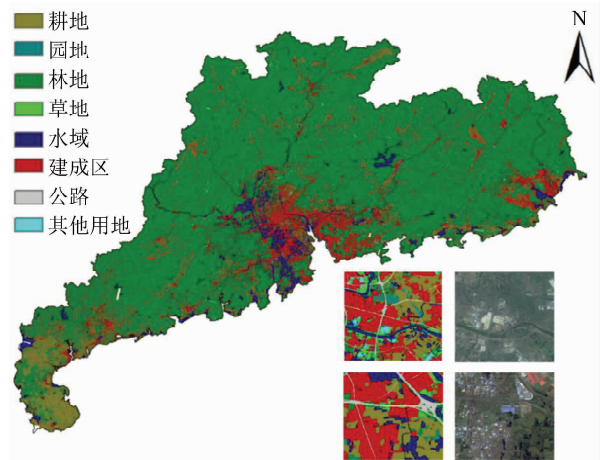


图2 广东省土地利用自动分类结果

Fig. 2 Automatic Classification Result of Land Use in Guangdong Province

### 3.3 遥感大数据驱动的地表参数反演

根据遥感成像机理与陆表过程,基于先验知识和物理模型反演地物理化参数是当前定量遥感的主流方法。由于先验知识的局限性、模型的非精确表达与近似以及观测数据的不完备、不精确等原因,导致了定量遥感的病态反演问题<sup>[57]</sup>。参与定量反演的遥感数据需要经过复杂的辐射定标、大气校正、辐射归一化、几何校正等处理,这些环节不仅大大增加参数反演的复杂度与不确定性,而且每个环节都会引入新的误差。进入遥感大数据时代,随着遥感及辅助数据量的急剧增加以及大数据分析方法的快速发展,利用机器学习、

主成分变换 (principal components analysis, PCA) 等数据驱动的遥感参数反演方法,不仅可以回避经典辐射传输模型的模拟近似误差,还可以实现高效率的地表参数反演<sup>[58]</sup>。如 Verrelst 等发现,高斯过程回归等机器学习方法和神经网络方法能够替代 SCOPE、DART (discrete anisotropic radiative transfer) 和 FLIGHT 等一维和三维植被辐射传输或场景模拟方法,得到高精度的植被冠层反射率光谱和叶绿素荧光发射光谱<sup>[59]</sup>。Gómez-Dans 等发现高斯过程仿真方法能够替代 PROSAIL 和 SEMIDISCRETE 等连续或离散冠层辐射传输模型,精确模拟冠层反射率光谱,并提供高精度的叶面积指数、叶绿素含量、叶片含水量等反演结果<sup>[60]</sup>。Liu 等提出了基于 PCA 数据驱动的叶片光学特性重构新方法和叶片生化参数反演模型,光谱重构精度比 PROSPECT 等物理模型模拟方法高 3~10 倍,且叶片生化参数反演精度优于传统植被指数方法和辐射传输物理反演方法<sup>[61]</sup>。

近年来,基于深度学习的 end-to-end 参数提取方法也开始应用到对地表参数的定量反演中。如 Wang 等利用卷积神经网络建模海冰图像与海冰密度的关系,并将其应用于海冰密度估计,结果表明深度学习算法估计结果与专业人员人工解译结果之间的差异小于 10%<sup>[62]</sup>。Yu 等利用堆栈自编码算法提取图像特征,并采用全连接神经网络 (feed-forward neural networks, FNN) 模型对图像特征与氮素浓度相关性进行建模,实验结果验证了 SAE-FNN 模型在遥感参数反演中的有效性<sup>[63]</sup>。虽然当前基于深度学习的遥感参数反演应用较少,但是这种从数据直接到参数的 end-to-end 的方法克服了遥感数据定量处理的繁琐过程,彰显了遥感大数据驱动的数据模型在参数反演方面的巨大优势和潜力。在遥感大数据时代,之所以能够避开传统繁琐的定量转换过程而利用深度学习等智能算法直接实现 end-to-end 的参数提取,一方面是天地一体化对地观测能力的提升为参数反演提供了充足的数据样本,另外一方面是以深度学习为代表的智能计算技术提供了有力的工具。基于深度学习的神经网络拥有多达上百层的网络结构和上千万的参数容量,而且具有完全通过数据自主学习特征参数的能力。因此,利用“大样本数据集+完备参数刻画能力”的数据模型来代替传统的“小样本数据集+先验知识约束”的物理模型,这种改变也必将是遥感大数据时代地表参数遥感反演的一种变革。

黑臭水体是由于水体遭受严重有机污染导致

厌氧生物降解过程生成硫化氢、氨、硫醇等发臭物质,同时形成黑色物质,使水体发生黑臭。利用遥感数据反演黑臭水体,往往需要高精度辐射定标与大气校正等定量处理过程,准确反演水体光谱反射率,再根据先验知识建立黑臭水体反演模型和图像指数<sup>[64]</sup>。为了对比验证基于物理模型的定量反演和基于深度学习的识别结果,利用苍灵系统对北京市建成区的黑臭水体进行识别,对北京市建成区 GF-2 卫星图像 (4 波段 1 m 分辨率) 的黑臭水体进行提取,覆盖面积大约为 1 400 km<sup>2</sup>,提取结果的总体精度大约为 85%。图 3 是基于定量反演模型和基于深度学习模型的北京市黑臭水体分布图 and 对比图,其中红色为两种方法同时提取的区域,绿色和黄色分别为定量遥感和深度学习单独提取的区域。从结果来看,利用深度学习的方式也同样能达到定量遥感反演相当的精度,而且可以预计,随着知识样本库的增加和算法的改进,基于深度学习的精度将有很大的提升空间。

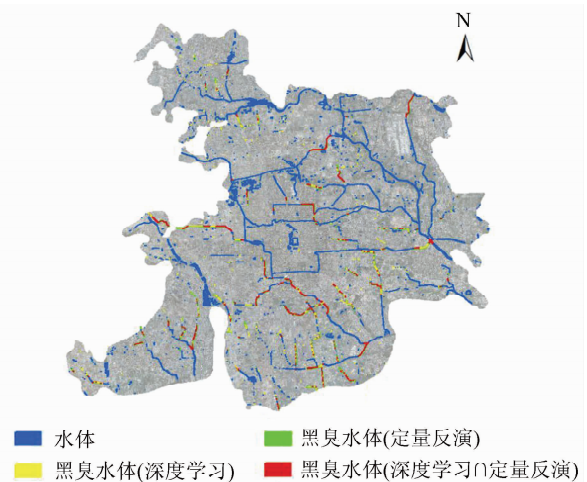


图 3 北京市建成区基于定量遥感反演和深度学习的黑臭水体提取结果对比

Fig. 3 Comparison of Quantitative Retrieval and Deep Learning Approaches in Labeling Black and Odorous Water Bodies for Buildup Area in Beijing

## 4 结语与展望

遥感大数据为人们提供了新的信息挖掘和科学发现手段,但也面临不同类型和结构的数据整合、海量数据的高效能计算、智能算法的遥感适用性、数据准确性与结果验证等一系列挑战。遥感大数据的信息提取是以数据驱动下的智能模型为主要特征,深度学习是目前满足这种需求的最优算法。现阶段针对 RGB 三波段真彩色图像建立

的样本库和深度学习神经网络在普适性方面存在明显不足。传统的仅标记图像类型与位置的样本库要扩展到包括遥感图像元数据信息、样本目标的图像属性、物理属性、地理学属性、社会属性等在内的知识样本库；而针对遥感图像的深度学习神经网络开发则需要从多源遥感数据支持、基于遥感成像机理的数据增强以及融合遥感影像特征的网络设计等方面入手，同时还要考虑全球及区域应用的大规模计算需求。

深度学习等人工智能理论与方法在计算机视觉领域取得巨大成就，近年来也被广泛应用在遥感领域，在大范围目标自动快速检测、复杂场景精细分类、地表参数快速识别等方面展示了巨大优势和发展潜力，为遥感大数据的智能信息提取带来前所未有的发展契机。

遥感大数据是遥感信息科技发展的新阶段，遥感图像信息提取已经由传统的统计学分析、定量遥感建模分析逐渐向数据驱动的智能分析转变。当然，在可预见的一定时期内，3种方式仍会并行发展，但是以智能分析为标志的遥感大数据时代即将到来，它无疑将给现有的遥感应用模式带来一场深刻变革。

### 参 考 文 献

- [1] Zhang Bing. Current Status and Future Prospects of Remote Sensing[J]. *Bulletin of Chinese Academy of Sciences*, 2017, 32(7): 774-784 (张兵. 当代遥感科技发展的现状与未来展望[J]. 中国科学院院刊, 2017, 32(7): 774-784)
- [2] Li Deren, Shen Xin, Ma Hongchao, et al. Commercial Operation of China's High-Resolution Earth Observation System is Imperative[J]. *Geomatics and Information Science of Wuhan University*, 2014, 39(4): 386-390 (李德仁, 沈欣, 马洪超, 等. 我国高分辨率对地观测系统的商业化运营势在必行[J]. 武汉大学学报·信息科学版, 2014, 39(4): 386-390)
- [3] Lyzenga D R. Passive Remote Sensing Techniques for Mapping Water Depth and Bottom Features[J]. *Applied Optics*, 1978, 17(3): 379-383
- [4] Strahler A H. The Use of Prior Probabilities in Maximum Likelihood Classification of Remotely Sensed Data[J]. *Remote Sensing of Environment*, 1980, 10(2): 135-163
- [5] Li Xiaowen. Retrospect, Prospect and Innovation in Quantitative Remote Sensing[J]. *Journal of Henan University (Natural Sciences)*, 2005, 35(4): 49-58 (李小文. 定量遥感的发展与创新[J]. 河南大学学报(自然科学版), 2005, 35(4): 49-58)
- [6] Miller J, Hare E W, Wu J. Quantitative Characterization of the Vegetation Red Edge Reflectance 1. An Inverted-Gaussian Reflectance Model[J]. *International Journal of Remote Sensing*, 1990, 11(10): 1 755-1 773
- [7] Goward S N, Huemmrich K F. Vegetation Canopy PAR Absorptance and the Normalized Difference Vegetation Index: An Assessment Using the SAIL Model[J]. *Remote Sensing of Environment*, 1992, 39(2): 119-140
- [8] Zhang Bing. Intelligent Remote Sensing Satellite System[J]. *Journal of Remote Sensing*, 2011, 15(3): 415-431(张兵. 智能遥感卫星系统[J]. 遥感学报, 2011, 15(3): 415-431)
- [9] Ma Y, Wu H, Wang L, et al. Remote Sensing Big Data Computing: Challenges and Opportunities[J]. *Future Generation Computer Systems*, 2015, 51: 47-60
- [10] Li Fenling, Chang Qingrui, Liu Jiaqi, et al. SVM Classification with Multi-texture Data of ZY-1 02C HR Image[J]. *Geomatics and Information Science of Wuhan University*, 2016, 41(4): 455-462(李粉玲, 常庆瑞, 刘佳岐, 等. 基于多纹理和支持向量机的ZY-1 02C星HR数据分类[J]. 武汉大学学报·信息科学版, 2016, 41(4): 455-462)
- [11] Freund Y, Schapire R E. A Decision-Theoretic Generalization of On-line Learning and an Application to Boosting[J]. *Journal of Computer and System Sciences*, 1997, 55(1): 119-139
- [12] Hinton G E, Osindero S, Teh Y W. A Fast Learning Algorithm for Deep Belief Nets[J]. *Neural Computation*, 2006, 18(7): 1 527-1 554
- [13] Krizhevsky A, Sutskever I, Hinton G E. ImageNet Classification with Deep Convolutional Neural Networks[J]. *Advances in Neural Information Processing Systems*, 2012, 25(2): 1 097-1 105
- [14] Wang S, Quan D, Liang X, et al. A Deep Learning Framework for Remote Sensing Image Registration [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, <https://doi.org/10.1016/j.isprsjprs.2017.12.012>
- [15] Guidici D, Clark M L. One-Dimensional Convolutional Neural Network Land-cover Classification of Multi-seasonal Hyperspectral Imagery in the San Francisco Bay Area, California[J]. *Remote Sensing*, 2017, 9(6): 629
- [16] Wang H, Wang Y, Zhang Q, et al. Gated Convolutional Neural Network for Semantic Segmentation in High-Resolution Images [J]. *Remote Sensing*, 2017, 9(5): 446



- [17] Xu Z, Xu X, Wang L, et al. Deformable ConvNet with Aspect Ratio Constrained NMS for Object Detection in Remote Sensing Imagery[J]. *Remote Sensing*, 2017, 9(12):1 312
- [18] Zou Z, Shi Z. Random Access Memories: A New Paradigm for Target Detection in High Resolution Aerial Remote Sensing Images[J]. *IEEE Transactions on Image Processing*, 2018, 27(3): 1 100-1 111
- [19] Deng J, Dong W, Socher R, et al. ImageNet: A Large-Scale Hierarchical Image Database[C]. IEEE Conference on Computer Vision and Pattern Recognition, Miami, USA, 2009
- [20] Xia G S, Bai X, Ding J, et al. DOTA: A Large-Scale Dataset for Object Detection in Aerial Images [OL]. <https://arxiv.org/abs/1711.10398v2>, 2017
- [21] You Q Z, Luo J B, Jin H L, et al. Building a Large Scale Dataset for Image Emotion Recognition: The Fine Print and the Benchmark[C]. Thirtieth AAAI Conference on Artificial Intelligence, Phoenix, USA, 2016
- [22] John E B, Derek T A, Chee S C. A Comprehensive Survey of Deep Learning in Remote Sensing: Theories, Tools and Challenges for the Community[J]. *Journal of Applied Remote Sensing*, 2017, 11(4): 042609
- [23] Karalas K, Tsagkatakis G, Zervakis M, et al. Deep Learning for Multi-label Land Cover Classification [C]. SPIE Remote Sensing, Toulouse, France, 2015
- [24] Liu Z, Wang H, Weng L, et al. Ship Rotated Bounding Box Space for Ship Extraction from High-Resolution Optical Satellite Images with Complex Backgrounds [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 13(8):1 074-1 078
- [25] Razakarivony S, Jurie F. Vehicle Detection in Aerial Imagery: A Small Target Detection Benchmark[J]. *Journal of Visual Communication and Image Representation*, 2015, 34:187-203
- [26] Zhu H, Chen X, Dai W, et al. Orientation Robust Object Detection in Aerial Images Using Deep Convolutional Neural Network[C]. IEEE International Conference on Image Processing, Quebec, Canada, 2015
- [27] Yang Y, Newsam S. Bag-of-Visual-Words and Spatial Extensions for Land-use Classification[C]. International Conference on Advances in Geographic Information Systems, San Jose, California, 2010
- [28] Zou Q, Ni L, Zhang T, et al. Deep Learning Based Feature Selection for Remote Sensing Scene Classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(11):2 321-2 325
- [29] Xia G S, Yang W, Delon J, et al. Structural High-Resolution Satellite Image Indexing[C]. ISPRS TC VII Symposium—100 Years ISPRS, Vienna, Austria, 2010
- [30] Campos-Taberner M, Romero-Soriano A, Gatta C, et al. Processing of Extremely High-Resolution LiDAR and RGB Data: Outcome of the 2015 IEEE GRSS Data Fusion Contest-Part A: 2-D Contest [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(12):5 547-5 559
- [31] Cramer M. The DGPF-Test on Digital Airborne Camera Evaluation—Overview and Test Design[J]. *Photogrammetry-Foregrounding-Geoinformation*, 2010, 2 010(2):73-82
- [32] Lecun Y, Bottou L, Bengio Y, et al. Gradient-Based Learning Applied to Document Recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2 278-2 324
- [33] Liu W, Anguelov D, Erhan D, et al. SSD: Single Shot MultiBox Detector [C]. European Conference on Computer Vision, Springer, Cham, 2016
- [34] Girshick R. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, Columbus, USA, 2014
- [35] Girshick R. Fast R-CNN [C]. IEEE International Conference on Computer Vision, Santiago, Chile, 2015
- [36] Ren S, He K, Girshick R. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1 137-1 149
- [37] He K, Zhang X, Ren S, et al. Pyramid Pooling in Deep Convolutional Networks for Visual Recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1 904-1 916
- [38] Chen X, Xiang S, Liu C, et al. Vehicle Detection in Satellite Images by Parallel Deep Convolutional Neural Networks [C]. Asian Conference on Pattern Recognition, Naha, Japan, 2013
- [39] Chen X, Xiang S, Liu C. Vehicle Detection in Satellite Images by Hybrid Deep Convolutional Neural Networks [J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(10): 1 797-1 801
- [40] Jiang Q, Cao L, Cheng M, et al. Deep Neural Networks-based Vehicle Detection in Satellite Images [C]. International Symposium on Bioelectronics and

Bioinformatics, Beijing, China, 2015

- [41] Zhang F, Du B, Zhang L, et al. Weakly Supervised Learning Based on Coupled Convolutional Neural Networks for Aircraft Detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(9): 5 553-5 563
- [42] Tang J, Deng C, Huang G, et al. Compressed-Domain Ship Detection on Spaceborne Optical Image Using Deep Neural Network and Extreme Learning Machine[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(3): 1 174-1 185
- [43] Cheng G, Zhou P, Han J. Learning Rotation-Invariant Convolutional Neural Networks for Object Detection in VHR Optical Remote Sensing Images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(12): 7 405-7 415
- [44] Radovic M, Adarkwa O, Wang Q. Object Recognition in Aerial Images Using Convolutional Neural Networks[J]. *Journal of Imaging*, 2017, 3(2): 21
- [45] Chen Z, Zhang T, Ouyang C. End-to-End Airplane Detection Using Transfer Learning in Remote Sensing Images[J]. *Remote Sensing*, 2018, 10(1): 139
- [46] Long J, Evan S, Trevor D. Fully Convolutional Networks for Semantic Segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, Boston, United States, 2015
- [47] Chen L, Papandreou G, Kokkinos I, et al. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848
- [48] Zhao H, Shi J, Qi X, et al. Pyramid Scene Parsing Network[C]. IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 2017
- [49] Hu W, Huang Y, Wei L, et al. Deep Convolutional Neural Networks for Hyperspectral Image Classification [J]. *Journal of Sensors*, 2015, 2 015 (2) :1-12
- [50] Makantasis K, Karantzas K, Doulamis A, et al. Deep Supervised Learning for Hyperspectral Data Classification Through Convolutional Neural Networks[C]. IEEE International Geoscience and Remote Sensing Symposium, Milan, Italy, 2015
- [51] Kussul N, Lavreniuk M, Skakun S, et al. Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(5): 778-782
- [52] Zhao W, Du S. Spectral-Spatial Feature Extraction for Hyperspectral Image Classification: A Dimension Reduction and Deep Learning Approach[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 4 544-4 554
- [53] Santara A, Mani K, Hatwar P, et al. Bass Net: Band-Adaptive Spectral-Spatial Feature Learning Neural Network for Hyperspectral Image Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(9): 5 293-5 301
- [54] Li Y, Zhang H, Shen Q. Spectral-Spatial Classification of Hyperspectral Imagery with 3D Convolutional Neural Network[J]. *Remote Sensing*, 2016, 18(7): 1 527-1 554
- [55] Marcos D, Hamid R, Tuia D. Geospatial Correspondence for Multimodal Registration[C]. IEEE International Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016
- [56] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016
- [57] Li Xiaowen, Wang Jindi, Hu Baoxin, et al. Role of Prior Knowledge in Remote Sensing Inversion[J]. *Science in China (Series D)*, 1998, 28(1): 67-73 (李小文, 王锦地, 胡宝新, 等. 先验知识在遥感反演中的作用[J]. *中国科学(D辑)*, 1998, 28(1): 67-73)
- [58] Liu L, Tang H, Caccetta P, et al. Mapping Afforestation and Deforestation from 1974 to 2012 Using Landsat Time-Series Stacks in Yulin District, a Key Region of the Three-North Shelter Region, China [J]. *Environmental Monitoring and Assessment*, 2013, 185(12): 9 949-9 965
- [59] Verrelst J, Caicedo J P R, Muñoz-Mari J, et al. SCOPE-Based Emulators for Fast Generation of Synthetic Canopy Reflectance and Sun-Induced Fluorescence Spectra[J]. *Remote Sensing*, 2017, 9(9): 927
- [60] Gómez-Dans J L, Lewis P E, Disney M. Efficient Emulation of Radiative Transfer Codes Using Gaussian Processes and Application to Land Surface Parameter Inferences[J]. *Remote Sensing*, 2016, 8(2): 119
- [61] Liu L, Song B, Zhang S, et al. A Novel Principal Component Analysis Method for the Reconstruction of Leaf Reflectance Spectra and Retrieval of Leaf Biochemical Contents[J]. *Remote Sensing*, 2017, 9(11): 1 113
- [62] Wang L, Scott K A, Xu L, et al. Sea Ice Concentration Estimation During Melt from Dual-Pol SAR Scenes Using Deep Convolutional Neural Networks: A Case Study[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 4 524-4 533
- [63] Yu X, Lu H, Liu Q. Role of Prior Knowledge in Remote Sensing Inversion[J]. *Chemometrics and Intel-*

*ligent Laboratory Systems*, 2018, 172: 188-193

- [64] Shen Qian, Zhu Li, Cao Hongye. Remote Sensing Monitoring and Screening for Urban Black and Odorous Water Body: A Review[J]. *Chinese Journal*

*of Applied Ecology*, 2017, 28(10): 3 433-3 439

(申茜, 朱利, 曹红业. 城市黑臭水体遥感监测与筛查研究进展[J]. *应用生态学报*, 2017, 28(10): 3 433-3 439)

## Remotely Sensed Big Data Era and Intelligent Information Extraction

ZHANG Bing<sup>1,2</sup>

1 Institute of Remote Sensing and Digital Earth, Chinese Academy of Sciences, Beijing 100094, China

2 University of Chinese Academy of Sciences, Beijing 101408, China

**Abstract:** In recent years, the rapid development of the earth observation capability and the intelligent computing technology has provided opportunities for the advancement and even revolution of remote sensing information technology. Remote sensing data processing technology has experienced the Digital Signal Processing Era from 60s to 80s of last century, which utilizes the Statistical Model as the core, and the Quantitative Remote Sensing Era from 90s marked by the Physical Model. Recently, it is developing towards Remotely Sensed Big Data Era which relies on Data Model by data-driven intelligent analysis. This paper summarizes the history of remote sensing information technology and presents the concept of remotely sensed big data and the characteristics of intelligent information extraction era. Firstly, from the view of remotely sensed big data, this paper discusses the construction of object-based remote sensing knowledge dataset and analyzes the data-driven intelligent information extraction strategy combined the knowledge of remote sensing and deep learning algorithm. Then the current status and development of intelligent algorithms represented by deep learning are introduced by typical applications on object detection, fine classification and parameter inversion based on remote sensing data. Consequently, the application potential of deep learning on intelligent information extraction in Remotely Sensed Big Data Era is discussed.

**Key words:** remotely sensed; big data; deep learning; intelligent information extraction; neural network

**Author:** ZHANG Bing, PhD, professor, specializes in the research of hyperspectral remote sensing and remotely sensed big data.  
E-mail: zb@radi.ac.cn

**Foundation support:** The Strategic Priority Research Program of the Chinese Academy of Sciences, No. XDA19080302.