深度学习在生态资源研究领域的应用: 理论、方法 和挑战

郭庆华^{1,2*}, 金时超^{1,2†}, 李敏³, 杨秋丽^{1,2}, 徐可心^{1,2}, 巨袁臻⁴, 张菁^{1,2}, 宣晶³, 刘瑾¹,
苏艳军¹, 许强⁴, 刘瑜⁵

1. 中国科学院植物研究所植被与环境变化国家重点实验室, 北京 100093;
2. 中国科学院大学, 北京 100049;
3. 中国科学院植物研究所系统与进化植物学国家重点实验室, 北京 100093;
4. 成都理工大学地质灾害防治与地质环境保护国家重点实验室, 成都 610059;
5. 北京大学地球与空间科学学院遥感与地理信息系统研究所, 北京 100871

* 通讯作者, E-mail: qguo@ibcas.ac.cn

† 共同第一作者

收稿日期: 2019-09-03; 收修改稿日期: 2020-01-05; 接受日期: 2020-02-11; 网络版发表日期: 2020-04-02

中国科学院战略性先导科技专项A类项目(批准号: XDA19050401)和国家自然科学基金项目(批准号: 31971575和41871332)资助

摘要 生态资源是人类生存发展和自我实现的重要物质基础, 对其进行深入全面的研究和理解关系到人类社会的可持续发展. 随着观测技术的进步, 长时间、跨尺度、海量异构多源数据的获取能力得到了显著提升, 生态资源研究进入了数据驱动的新时代. 传统的统计学习和机器学习算法在海量数据面前存在饱和问题. 深度学习作为高维非线性复杂特征自动提取的新手段, 对海量数据具有不饱和性, 正成为学界和工业界数据处理的新引擎. 为推动深度学习在生态资源领域的应用, 文章首先介绍了深度学习的理论与生态资源研究的联系, 以及常用工具和数据集. 其次, 通过物种识别、作物育种和植被制图三个案例介绍了深度学习在分类识别、检测定位、语义分割和实例分割任务中的具体实践, 以及图神经网络在生态资源领域中典型的空间离散点数据上的应用场景. 最后, 综合大数据时代下生态资源数据的特点和深度学习的发展现状, 总结了深度学习在生态资源领域发展的挑战和机遇. 希望通过不同学科之间的交叉和人才培养, 能够促进生态资源领域数据的标准化和共享化, 提升算法的普适性和解释性, 并借助于硬件的发展最终实现应用的丰富化和智能化.

关键词 生态资源, 深度学习, 神经网络, 大数据, 理论与工具, 应用与挑战

1 引言

生态资源也叫生态环境资源, 是自然资源的重要

组成部分, 指一切被生物和人类利用的物质、能量和信息的总和(Black等, 1990; Ehrlich和Ehrlich, 1970).

生态资源在生态系统中提供了维护系统动态平衡的核

中文引用格式: 郭庆华, 金时超, 李敏, 杨秋丽, 徐可心, 巨袁臻, 张菁, 宣晶, 刘瑾, 苏艳军, 许强, 刘瑜. 2020. 深度学习在生态资源研究领域的应用: 理论、方法
和挑战. 中国科学: 地球科学, 50(10): 1354–1373, doi: 10.1360/SSTe-2019-0201

英文引用格式: Guo Q, Jin S, Li M, Yang Q, Xu K, Ju Y, Zhang J, Xuan J, Liu J, Su Y, Xu Q, Liu Y. 2020. Application of deep learning in ecological resource
research: Theories, methods, and challenges. Science China Earth Sciences, 63(10): 1457–1474, <https://doi.org/10.1007/s11430-019-9584-9>

心作用(Scott等, 1998). 对生态资源进行深入的探索和研究, 有助于充分发挥其经济、生态和社会效益, 促进生态文明建设、美丽中国建设和人类社会可持续发展.

在20世纪90年代全球信息化建设和21世纪以来物联网和云计算的促进下, 人类进入了大数据时代(李德仁, 1999, 2016). 根据国际数据公司(IDC)发布的数据统计白皮书《IDC: 2025年中国将拥有全球最大的数据圈》, 全球数据量在2025年预计达到175ZB. 生态资源作为地球大数据的重要组成部分, 也随着观测手段的进步进入了数据爆发增长的新阶段. 除了生态资源综合考察站点(如中国政府在全国范围内布置了40万个地面采样点用于定时调查森林资源)(吴炳方等, 2018), 大量的环境变化和生物多样性监测网络也在各国政府和国际组织的支持下得到了蓬勃的发展, 如国际长期生态学研究网络(International Long Term Ecological Research Network, ILTER)、全球生物多样性观测网络(The Group on Earth Observations Biodiversity Observation Network, GEO BON)和全球生物多样性信息网络(Global Biodiversity Information Facility, GBIF)(马克平等, 2018). 近年来, 各国政府在本国范围内启动了一系列大数据工程, 如美国国家科学基金斥资4.34亿美元的“霓虹计划(The National Ecological Observatory Network, NEON)”, 旨在全美范围内布设1.5万个传感器, 收集500多种生物地球化学参数. 中国科学院战略性先导科技专项A类项目支持下的地球大数据科学工程“广目”, 致力于构建包含资源、环境、生物、生态等多个领域的大数据云服务共享平台, 探索大数据驱动下科学研究的新范式和新发现. 此外, 公众科学时代智能终端众源数据的上传和卫星遥感时代多源遥感数据的实时下载使得生态资源领域已然进入大数据时代.

生态资源大数据作为大数据的一种, 同样具备数据量大(volume)、类型繁多(variety)、价值高(value)、速度快(velocity)等特点(郭华东, 2014, 2018; 翟明国等, 2018). 海量数据的积累推动了生态资源研究从传统的模型驱动走向数据驱动的“数据密集型科学”研究新范式(McCallen等, 2019), 促进了多尺度、多要素和多过程的理论发现. 同时, 多源(元)异构、时空耦合、地理关联、高维复杂和低信噪比的大数据给数据处理和信息挖掘带来了巨大的挑战. 相比于其他领域, 生态资源

研究侧重空间尺度(分子、个体、种群、群落、生态系统和生物圈)和时间尺度(进化、演替、生长发育等)的格局、过程、变化和应用, 因此更强调对研究对象进行分类检测和动态分析以进行时空尺度推绎. 目前, 生态资源研究的方法主要有简单统计学习、传统机器学习 and 不同层次神经网络模型.

传统的统计学习方法主要是基于数据的概率分布, 以推理为基础, 解释性强但效率低, 适合小数据集(图1). 机器学习作为统计学习向人工智能发展的中间产物, 是以数据为基础、“学习”为重点, 适合于非线性复杂任务(Olden等, 2008; Recknagel, 2001; Thessen, 2016). 因此, 机器学习很长一段时间内成为了生态资源数据挖掘的重要途径(Cutler等, 2007; Jordan和Mitchell, 2015; Karpatne等, 2018; Olden等, 2008; Park和Chon, 2007; Recknagel, 2001; Thessen, 2016). 如Guo等(2005)利用支持向量机(support vector machine, SVM)预测了美国加州橡树突发死亡的分布, Yang等(2018)利用人工神经网络的方法结合地面调查和MODIS(moderate resolution imaging spectroradiometer)遥感数据预测了中国三江源地区的草地地上生物量, Jin等(2018a)利用随机森林(random forest, RF)对不同植被类型条件下的树高进行了估算和模型评价. 但是传统的机器学习算法需要人为定义特征, 且性能随着数据的增加会出现“平台期”(图1), 无法满足日益增长的数据处理需求. 深度学习作为机器学习的一个新兴分支, 通过建立模拟人脑进行分析学习的神经网络(Bengio等, 2013), 以“大数据”为驱动, 以“最小化预测误差”为目标, 已经被证明在海量、高维和复杂数据处理上具有最先进的性能(Hinton等, 2006; LeCun等, 2015). 相比于机器学习, 一方面, 深度学习具备自动学习提取特征的能力, 对于解决生态资源大数据多源异构、特征难以定义的问题带来了新的手段; 另一方面, 深度学习在大数据驱动下通过深层次网络能够实现比浅层神经网络和机器学习以及简单统计方法提取更丰富的空间层次的特征(Ba和Caruana, 2014), 兼顾了生态资源研究中的空间尺度问题; 同时深度循环神经网络等模型(Connor等, 1994)充分考虑了时间效应, 兼顾了生态资源研究中的时间尺度效应. 此外, 深度学习对于大数据具有不饱和性和精度高等特点(图1), 能够满足日益增长的生态资源大数据的处理需求. 因此, 深度学习正在逐步革新传统的生态资源研究(Bro-

图1 简单统计学习、传统机器学习和不同层次神经网络模型能力与数据量之间的相对关系

drick等, 2019; Handan-Nader和Ho, 2019; Huang等, 2018; Reichstein等, 2019; Singh等, 2018).

为了促进深度学习在生态资源领域的发展和应用, 本文综述了深度学习技术的起源与发展、基本网络结构、与生态资源研究的关系和主要任务以及常用数据集和工具, 分析了深度学习技术的优势及应用潜力, 介绍了深度学习在物种识别、作物育种和植被制图三个案例中的具体实践. 最后总结了当下发展的挑战和机遇.

2 深度学习简介

2.1 深度学习起源与发展

深度学习的概念最早源于美国心理学家Warren McCulloch和数学家Walter Pitts于1943年通过对生物神经元的结构和工作原理进行数学抽象和简化构建的一个基于神经网络的数学模型——MCP模型(McCulloch和Pitts, 1943). 受突触可塑性原理(赫布定律)的启发, 美国科学家Frank Rosenblatt在20世纪50年代发现了一种类似于人类学习过程的算法, 并于1958年正式提出由两层神经元组成的神经网络——感知机(Perceptron)(Rosenblatt, 1960). 感知机是当时首个可以学习的人工神经网络, 它的出现迎来了神经网络发展的

第一次高潮(图2). 但是, 单层感知机模型只能处理线性可分问题, 对于简单的异或问题都无法解决(Minsky和Papert, 1969), 这使得神经网络的发展很快进入“冰河时期”(“AI winter”). 直到1986年, Rumelhart等(1986)提出了反向传播(Backpropagation, BP)算法, 解决了非线性分类问题和多层感知机(Multilayer Perceptron, MLP)所需要的复杂计算量问题, 使得神经网络进入了第二次发展高潮. 1998年, Yann LeCun提出了LeNet5模型应用于手写数字识别, 并正式提出了一种新的神经网络——卷积神经网络(Convolutional Neural Network, CNN), 成为目前深度学习常用模型之一(LeCun等, 1998). 但当时的硬件条件无法支持CNN大量的运算, 其优势完全被同样能解决非线性问题且高效泛化的SVM取代, 因此受到了第二次重大冲击.

2006年, Hinton在*Science*等期刊上发表论文, 提出了“深度信念网络”(Hinton等, 2006; Hinton和Salakhutdinov, 2006), 并赋予多层神经网络相关的学习方法一个新名词——“深度学习”. 随着图形处理单元(Graphic Processing Unit, GPU)等硬件的发展以及大数据的积累, 深度学习理论和算法迎来了第三次高潮, 出现了如AlexNet(Krizhevsky等, 2012)、GoogLeNet(Szegedy等, 2015)、ResNet(He K等, 2016)、基于区域的卷积神经网络(Girshick, 2015; Girshick等, 2016; He等, 2017; Ren等, 2015)、循环神经网络(Recurrent Neural Network, RNN)(Hochreiter和Schmidhuber, 1997; Mandic和Chambers, 2001)、生成对抗网络(Generative Adversarial Net, GAN)(Goodfellow等, 2014)、强化学习(Tang等, 2017)和图神经网络(Graph Neural Networks, GNN)(Zhang Z等, 2018; Zhou等, 2018)等算法, 实现了在特定任务上超越传统算法甚至在分类识别领域超越人类的效果(Silver等, 2017; Tang等, 2017; Zhang等, 2017).

2.2 深度学习网络的基本结构与生态资源大数据的联系

深度学习网络结构主要由输入层、输出层以及介于两层之间的大量的隐藏层组成. 每一层包含有不同数量的神经元, 上一层的神经元通过卷积、激活和池化等操作提取特征映射到下一层神经元, 最后输出分类或者回归的结果(Schmidhuber, 2015). 卷积操作指的是利用核函数(卷积核)对输入数据进行区间积分得

图2 深度学习的起源与发展

到线性特征。激活是指对卷积得到的特征进行非线性变化,提升模型在复杂问题上的拟合能力,常见的激活函数有双曲正切函数、Sigmoid函数和ReLU函数等。池化是对局部特征进行聚合的操作(如最大值池化和平均值池化),能够增强特征提取的稳健性,减少网络的参数,加快模型的收敛(Boureau等, 2010a, 2010b)。在输出层,目前主要有全连接输出和全卷积输出两种形式,以分类任务为例,全连接输出层将隐藏层提取的特征图降维到1维,再经过全连接和softmax等函数的非线性映射,得到每一类输出的概率,并利用one-hot编码的方法输出预测的对象类别(如手写数字识别)。相比之下,全卷积层利用卷积操作代替全连接操作,实现对象内部每个基本单元(如像素)预测类别的输出。输出的类别通过交叉熵函数(回归问题用均方根

误差)计算与真实值的误差,利用反向传播更新模型结构中的参数,减小网络输出与目标之间的差距,实现模型的训练(LeCun等, 2015; Rumelhart等, 1986)。

结合生态资源领域的特点,深度学习网络的基本结构框架如图3所示。生态资源领域的数据形式主要有一维的声音和文本数据(如鸟声、文献记载),二维的图像和视频数据(如植物标本照片和卫星影像),三维的空间离散点数据(如包含经纬度和海拔记录的植被调查点)。针对一维时序数据,常用的深度学习结构有处理时间序列的RNN系列模型(如Long Short-Term Memory, LSTM)(Hochreiter和Schmidhuber, 1997; Man-dic和Chambers, 2001)。针对二维图像数据,主流的结构是CNN系列(Krizhevsky等, 2012; LeCun, 2015)。针对三维的空间数据,最近兴起的图神经网络(GNN)或

将成为一种主流方式(Zhang Z等, 2018; Zhou等, 2018). RNN、CNN和GNN的基本结构都由输入层、隐藏层和输出层组成, 其主要差异在于隐藏层和卷积操作各有特色. 最常用的CNN系列的模型主要是利用在图像上, 通过一定窗口大小的卷积核沿着输入图像从左上角往右下角以一定的步长前进, 在每个窗口位置进行卷积操作和池化操作从而完成整张图片不同空间尺度的特征提取. RNN系列的模型相比于CNN新增有记忆功能的单元, 通过将上一隐藏层的输出结合当前时刻网络的状态一并传递给下一时刻, 实现不同时间尺度信息的提取. GNN主要面向非欧式空间数据的处理, 其隐藏层特征提取主要有空域卷积和频域卷积两类方法, 空域卷积主要通过图采样和聚合的方法实现图上消息传递和状态更新, 频域卷积通过图的傅里叶变化将空间域的特征提取转化为频率域的逐点乘积(Yan等, 2019). 隐藏层的特征经过全连接层或者全卷积层将特征转化为目标输出, 输出的特征由于包括不同空间尺度和时间尺度的信息, 因此在生态学领域主要用于5类任务, (1) 分类识别: 输出一个类别的标签值, 如鸟声分类; (2) 检测定位: 确定目标在数据中的位置, 如图像中个体的检测; (3) 语义分割: 对数据中不同类别

目标进行区分, 但是同类目标不同个体之间不加以区分; (4) 实例分割: 对数据中不同类别目标进行区分, 且同类目标不同个体之间加以区分; (5) 回归预测: 通过对训练集的学习使得模型在接受新输入时的输出值与目标值差异最小, 回归问题的输出是连续值(图3).

2.3 深度学习在生态资源中的主要任务

为了深入了解深度学习在生态资源领域的应用, 本文通过在ISI Web of Science数据库以主题(“deep learning”)和主题(“biology” OR “earth science” OR “ecological resource”)对2000年以来深度学习在生态资源领域的发文量进行检索. 检索结果发现, 深度学习在生态资源领域的研究正处于迅速增长阶段, 尤其是近十年来出现指数增长的趋势; 从文献的发表国家来看, 美国和中国学者在全球处于引领地位; 在前十名的国家中, 发达国家居多, 发展中国家只有中国(图4). 检索得到的4505篇中英文文章涵盖了生态资源领域的动物、植物、微生物等研究对象, 涉及了多尺度、多源数据的算法和应用研究, 包括了分类识别、检测定位、语义分割、实例分割和回归预测等主要任务, 表明深度学习作为一种大数据分析的新工具在生

图3 深度学习网络基本结构及其在生态资源中的应用

图 4 ISI Web of Science检索的深度学习在生态资源领域发量随时间变化趋势(a)与研究热点国家分布图(b)

态资源大时代发挥了越来越重要的作用。

在分类识别方面(Barré等, 2017; Carranza-Rojas等, 2017; Knight等, 2017; Norouzzadeh等, 2018; Rzanny等, 2017; Younis等, 2018), 卷积神经网络和循环神经网络是生态资源研究中的主流模型。在植物分类中(Lee等, 2015, 2016), Barré等(2017)基于CNN构建了实地拍照叶片的植物物种分类模型, 在185种叶片上的Top5分类精度的平均值为97.8%。Mohanty等(2016)利用深度学习的方法实现了基于图像的38种植物病害的分类。Carranza-Rojas等(2017)用卷积神经网络和迁移神经网络实现了基于标本图片的上千个物种的分类。除了利用CNN对单张图像进行分类之外, Taghavi Namin等(2018)利用LSTM对CNN提取的时间序列图像的特征进行表型和基因型的分类。在动物分类方面, Norouzzadeh等(2018)利用深度学习的方法基于相机陷阱获取的图像数据自动识别动物的类别并统计其数量, 实现了动物种群的监测。同时, 动物发出的声音也被作为一种重要数据源, 用于根据声音进行物种识别并对动物生物多样性进行监测(Knight等, 2017; Potamitis, 2015, 2016; Salamon等, 2017)。此外, 深度学习在分类识别中的应用还广见于遥感图像分类(Cheng等, 2018; Hamida等, 2018; Kussul等, 2017; Pan等, 2017; Qi等, 2016; Zhong等, 2017; Zou等, 2015)和生物学图像的分类(如蛋白质亚细胞的分类)(Pärnamaa和Parts, 2017)。

在检测定位方面(Pathak等, 2018; Pound等, 2017b), 深度学习经历了从逐像素分类和图像块分类

等间接方式到目前的区域建议框直接定位方式的转变。Pound等(2017b)用逐像素回归的方式对每个像素属于对象的概率进行了预测, 从而间接实现了小麦穗的定位; 与此同时, Pound等(2017a)通过对图像分块扫描进行分类预测从而确定目标类别的位置, 实现了小麦穗和叶尖等关键部位的检测定位。Li等(2017)以图像块的分类的方式实现了油棕榈树的检测和计数。但是, 图像块的方法存在速度慢、滑动步长难以确定的不足。相比之下, Weinstein等(2019)采用了RetinaNet直接在图像上基于候选框分类和回归实现了树冠的检测, 速度和精度都得到了提升, 这主要得益于类似的单阶段(Liu W等, 2016; Redmon等, 2016; Ross和Dollár, 2017)和双阶段(Girshick, 2015; Girshick等, 2014; He等, 2017; Ren等, 2015)目标检测算法的出现。此外, 深度学习在动物监测(Kellenberger等, 2018)、云检测(Shi等, 2016)和病害检测(Mohanty等, 2016)等方面也发挥着重要作用。

在语义分割方面(Douarre等, 2016), 深度学习也经历了从间接的像素和图像块分类到直接语义分类的过程。Douarre等(2016)采用逐像素分类的思想利用迁移学习对X光断层扫描图像中的土壤和植物根系进行了语义分割, 这类方法效率相对较低; 另一种间接的语义分割方法是先将图像分割成斑块, 在对每个斑块进行分类的划分(Zhang C等, 2018), 但存在斑块划分不准确和误差累积传递的不足。随着全卷积神经网络(Fully convolutional network, FCN)的提出, 类似于Unet结构(Ronneberger等, 2015)的全卷积神经网络可以实现端到端的语义分割, 效率大大提升。如Wurm等(2019)利用FCN网络对卫星影像中的平民窟进行了语义分割。此外, 语义分割在遥感影像的分类(Chai等, 2019; Jepsen等, 2019; Kemker等, 2018; Li等, 2019; Volpi和Tuia, 2018; Wieland等, 2019)、点云分类(Fang和Lafarge, 2019; Qi等, 2016, 2017; Sun等, 2018; Yao等, 2019; Zhang R等, 2018)、城市规划(Griffiths和Boehm, 2019; Guo等, 2018)等遥感数据处理和应用中取得了当下最先进的效果。

在实例分割方面, 深度学习应用到生态资源的研究相对较少。Romera-Paredes和Torr(2016)基于FCN和LSTM的方法对拟南芥的每个叶片实现了分割和计数。目前实例分割主要是对激光雷达等获取的三维空间数据进行精细分割(Liu和Furukawa, 2019; Wang W等,

2018; Wang Y等, 2019; Yi等, 2018), 且往往通过联合训练的方式与语义分割同时进行(De Brabandere等, 2017; Liang等, 2019; Pham等, 2019; Wang X等, 2019), 以提升不同任务的效果。

在回归预测方面, 深度学习在生态资源领域的研究也比较少, 主要由于深度学习尤其是卷积神经网络的主要优势(空间维度的关联性)对于回归问题的改进远不及对于分类问题的改进。当前有一些研究利用分类思想进行回归, 如Dobrescu等(2017)基于分类的思想对莲座植物的叶片进行了叶片数量的回归预测, 从而实现了叶片的自动计数。此外, 还有少量研究利用RNN对时间序列的浮游植物的生物量进行回归预测(Jeong等, 2008)。

尽管深度学习目前已经在生态资源领域取得了广泛应用, 但是当前的研究主要集中在监督学习方面, 且以CNN和RNN的应用最为广泛(Christin等, 2018; Taghavi Namin等, 2018)。GNN作为一种新兴的数据处理模型, 在非欧氏数据处理中具有显著优势, 但是当前应用还比较少。此外, 深度学习中的半监督学习(Han等, 2017; Weinstein等, 2019)、无监督学习和强化学习方法在生态学中的应用也比较缺乏, 其主要限制因素在于2.2节中提到的数据集和工具等。

2.4 深度学习常用数据集和工具

深度学习作为一门数据驱动的科学, 其核心是海

量的数据。在计算机视觉领域, 主流的数据集有MNIST、MS-COCO和Open Images等。相比之下, 应用于生态资源领域研究的深度学习数据集相对来说数据量更小、类别更少, 主要有涉及各类动植物分类、检测以及生态场景分类的数据集(表1)。

海量的数据集解决了深度学习的输入, 而神经网络模型的搭建、算法的实现依赖于一些主流的深度学习工具, 如TensorFlow(<https://www.tensorflow.org/>)、Pytorch(<https://pytorch.org/>)、Caffe(<http://caffe.berkeleyvision.org/>)、Torch(<http://torch.ch/>)、Keras(<https://keras.io/>)、MxNet(<http://mxnet.incubator.apache.org/>)、CNTK(<https://www.microsoft.com/en-us/cognitive-toolkit/>)、Theano(<http://deeplearning.net/software/theano/>)、PaddlePaddle(<http://www.paddlepaddle.org/>)等。这些工具的主要开发语言和调用接口丰富多样, 但几乎都支持CPU(Central Processing Unit)、GPU(Graphics Processing Unit)以及不同操作平台的使用, 部分还支持TPU(Tensor Processing Unit)的使用(表2)。

除了数据的积累和模型的创新, 一个日益完整的深度学习计算生态还需要硬件的支持。GPU提供的强大的浮点计算性能大幅提高了深度学习两大关键活动(分类和卷积)的性能, 成为大数据时代深度学习挖掘的加速引擎。在相同的精度下, GPU相比于传统的CPU拥有更快的速度和更小的功耗。数据、算法和算

表 1 深度学习在生态资源领域的常用公开数据集

数据库	发布者	数据量	数据描述	下载链接
Caltech-UCSD Birds-200-2011	California Institute of Technology	11788	200种鸟类, 每张照片标记有目标位置边框。样本与ImageNet数据库有重叠。	http://www.vision.caltech.edu/visipedia/CUB-200-2011.html
Labeled Fishes in the Wild	National Marine Fisheries Service	4000+	包含鱼类、无脊椎动物和河床的图片, 其中鱼类的位置用外接矩形框进行了标记	https://swfscdata.nmfs.noaa.gov/labeled-fishes-in-the-wild/
Oxford Flower Dataset	University of Oxford	9549	一个包含17类鲜花、每类80张的数据集和一个包含102类鲜花、每类40到258张的数据集	http://www.robots.ox.ac.uk/~vgg/data/flowers/
UCI Folio Leaf	University of California, Irvine	637	32类树叶、每类20张	https://archive.ics.uci.edu/ml/datasets/Folio
WHU-RS19 Data Set	武汉大学	950	包含19类场景图像	http://www.esience.cn/people/yangwen/WHU-RS19.html
UC Merced Land-Use Data Set	University of California, Merced	2100	包含21类场景图像	http://weegee.vision.ucmerced.edu/datasets/landuse.html
UCF Google Street View	University of Central Florida	62058	包含精确的GPS坐标和拍摄方向, 每一处地点包括4个方位和1个仰视图像	http://crv.ucf.edu/data/GMCP_Geolocalization/

表 2 深度学习常见工具对比

工具名称	TensorFlow	Pytorch	Caffe	Torch	Keras	MXNet	CNTK	Theano	PaddlePaddle
主要开发语言	C++, CUDA	Python	C++	C, Lua	Python	C++	C++	Python	Python
主要调用接口	Python, C/C++, Java, Go, R, Julia	Python, C++	MATLAB, Python	Lua, LuaJIT, C, C++/OpenCL	Python, R	C++, Python, Julia, Matlab, JavaScript, Go, R, Scala, Perl	C++, Python	Python	Python
运行方式	CPU, GPU, TPU	CPU, GPU, TPU	CPU, GPU	CPU, GPU	CPU, GPU, TPU	CPU, GPU	CPU, GPU	CPU, GPU	CPU, GPU
操作平台	Linux, macOS, Windows, Android	Linux, macOS, Windows	Linux, macOS, Windows	Linux, macOS, Windows, Android, iOS	Linux, macOS, Windows	Linux, macOS, Windows, AWS, Android, iOS	Linux, macOS, Windows	Linux, macOS, Windows	Linux, macOS, Windows

力的共同发展, 奠定了深度学习在生态资源领域应用的基础。

3 深度学习的应用

生态资源数据的多样性和特殊性经过深度学习在不同时空尺度进行信息挖掘后给诸多学科的发展带来了新突破(2.3节)。本节选取了在物种识别领域的经典应用案例, 旨在介绍深度学习超越领域分类专家的判别能力背后的主要技术点; 在作物表型领域, 展示了深度学习在分类识别、目标检测、语义分割、实例分割和回归预测的应用细节和精度效率; 最后以植被制图为例, 分析了图神经网络对生态资源领域空间离散点数据的潜在应用。

3.1 深度学习在物种识别中的应用

人类依靠视觉识别物种的本质就是做图像识别。计算机和深度学习技术的发展使得机器具备相似的能力。深度学习在识别物种方面的研究起步较早, 在植物、动物和标本识别中均取得了超越传统分类器的效果(Barré等, 2017; Carranza-Rojas等, 2017; Yalcin等, 2016)。

深度学习物种识别的基础是海量的物种图像信息。为了提升物种识别的能力, 需要数据库中包含丰富的物种类别且每种类别具有足够的样本数量, 如中国植物图像库(Plant Photo Bank of China, PPBC, <http://ppbc.iplant.cn/>)截至2019年10月已经收录各类植物图片493科5048属33249种5256659幅, 又如中国自然标本馆(Chinese Field Herbarium, CFH, <http://www.cfh.ac.cn>)截至2019年

10月共收录各类植物图片1220万张, 其中经专家鉴定的照片有857万张, 包含坐标的照片有250万张。

基于中国植物图像库的数据集, 我们采用TensorFlow框架搭建了植物物种识别分类网络, 该网络综合吸收了目前CNN在分类中的多项技巧, 包括非对称卷积网络(Asymmetric Convolution)、通道卷积(Inception)、残差网络(ResNet)、模块熔接(Deep fusion)(Zhao等, 2016)。最终, 该模型可识别约3000属5000余种植物, 前五种(Top5)的准确率高达80%以上, Top5的召回率高达96%, F 值大于0.44, 已经大大超过了普通植物分类学家能够识别的物种数(图5)。基于此模型, 我们主导开发了“花伴侣”APP, 并且通过微信公众号及拍照识花网站(<http://stu.iplant.cn>)对外提供识别引擎服务。

除了植物实景照片的识别, 通过迁移学习的方法将分类模型应用于腊叶标本、树皮、种子等对象的分类, 充分整合植物各部位、各器官信息, 有望实现植物物种的更精准鉴定。未来, 除了识别肉眼可见的物体外, 深度学习在微体的识别上也有着广阔的前景和潜力, 如花粉识别(Martin和Harvey, 2017)。

3.2 深度学习在作物育种中的应用

人口增长和人均消费水平的提高给粮食安全带来了空前的压力(Monfreda等, 2008; Ramankutty等, 2008)。发展作物育种技术、培育高产优质品种, 对于保障国家粮食安全具有重大意义。当前, 作物育种已经实现了由传统杂交育种走向基因组学和表型组学的时代, 主要问题已经由数据获取转变为数据分析。深度学习作为复杂特征提取的利器, 在当代作物表型育种中扮演着重要的角色。

图5 物种分类网络模型核心技术图

作物表型育种的前提是获取单株作物的表型结构信息。尽管当前利用图像三维重建(如Structure-from-Motion, SFM)和激光雷达点云都能够获取作物的三维结构数据,但是如何从群体三维数据中分离出单株的作物(目标分类与检测定位)以及更加精细的茎叶个体(语义分割与实例分割)是一个技术瓶颈。传统的针对于森林场景的单木分割和枝叶分离算法对体积较小的作物精度低,且严重依赖人工定义的特征和阈值。近年来,深度学习方法在作物表型组学研究中取得了一系列的突破(Pound等, 2017b; Ubbens和Stavness, 2017)。但是,这些方法集中于解决基于图像数据的群体参数提取,对于精细水平的单株参数提取方法还十分缺乏,主要原因是缺乏有效的单株分割和茎叶分割算法。Jin等(2018b)提出的基于激光雷达和深度学习技术的单株玉米分割是在本领域的一个新的尝试,其主要思想是利用改进的基于区域卷积神经网络(Faster Region based Convolutional Neural Network, Faster R-CNN)进行田间玉米的定位,并将定位得到的种子点信息输入到区域增长算法中用于单株玉米的提取。Faster R-CNN模型主要包括4个部分:(1)卷积层:对输入的图像进行一系列的卷积、激活和池化运算得到高维度的特征图像,用于输入后续的区域建议网络 and 全连接的分层;(2)区域建议网络:利用高维度的特征图像生成建议区域;(3)兴趣区池化:利用区域建议网络生成的兴趣区域从卷积层得到的高维特征中提取感兴趣的特征;(4)分类和回归:感兴趣区的特征图被输入到全连接层判断其是属于前景目标还是背景类别,并进一步利用回归修正包围框位置从而获取精确的感兴趣区。Faster R-CNN网络经过训练之后能够实现目标的

识别(分类)和定位(回归),因此可以被用于许多基于种子点的区域增长算法以便提取单个目标对象。在此分割基础上,提取出单株玉米点云,进行三维体素化。体素化的点云可被三维卷积神经网络进行特征提取,输出语义级别的茎叶分类结果,进一步对特征图进行meanshift聚类(Comaniciu和Meer, 2002),得到实例分割的单个茎秆和叶片(Jin等, 2020)(图6)。上述地基激光雷达数据对玉米单株进行识别的精度高达90%,基于识别结果提取的株高与实测值的 R^2 大于0.90(Jin等, 2018b),基于识别单株进行茎叶语义和实例分割的精度也都高达0.90(Jin等, 2020)。除此之外,深度学习在作物目标对象分类识别和分割提取等方面被证明具有充分的优势,如Jin等(2017)利用无人机影像对小麦早期种植密度自动、快速估算时的偏差为9株/ m^2 ;从田间机器人获取的图像中自动提取的玉米的数量与实地测量的相关性高达0.88,自动提取的茎粗相对误差为2.77mm,而自动计数的效率和提取茎粗的效率分别时人工测量的30倍和270倍(Baweja等, 2018)。因此,经过深度学习提取得到的单株、茎秆和叶片实例,可以被用于高通量作物表型参数的提取,从而服务作物育种研究。

在作物育种领域,深度学习还被广泛应用于叶片计数(Aich和Stavness, 2017; Baweja等, 2018)、叶片分类(Grinblat等, 2016; Li等, 2016; Zhang和Huai, 2016)、花(穗)果识别(Madec等, 2019; Pound等, 2017b; Thi Thanh-Nhan等, 2017; Xiong等, 2017)和年龄估计等方面(Baweja等, 2018; Ubbens和Stavness, 2017)。未来,深度学习还会被广泛地应用于植物病虫害等胁迫(Ghosal等, 2018; Mohanty等, 2016; Ramcharan等, 2017;

图 6 利用Faster R-CNN模型对单株对象进行分类识别和回归定位并基于此利用VCNN实现茎叶语义分割和实例分割

Singh等, 2018; Wang等, 2017)和产量估计等(Rahmoonfar和Sheppard, 2017)研究。

3.3 深度学习在植被制图中的应用

植被图是生物多样性保护、生态研究和植被管理与恢复的重要信息来源(Lai等, 2016; Lenihan等, 2003)。随着气候变化和人类活动的影响, 植被类型处于动态变化过程中。及时、准确、高效地完成植被制图工作是科研和社会生产管理的迫切需求。由于地形等环境因素的复杂性, 大尺度植被制图依然是一项艰巨的任务。

公民科学和卫星遥感技术的进步为植被制图提供了海量的数据源, 加上计算能力和算法的不断发展, 目前大尺度植被分类的难点主要集中在以下3个方面: (1) 植被分类体系的确定; (2) 多源数据的标准化; (3) 非结构化数据的特征提取。深度学习的图神经网络为非结构化数据的特征提取提供了新手段。

以新一代中国植被图初步绘制方法为例, 通过搜集2018年全国分布的哨兵2影像, 经过辐射定标、大气校正、去云掩膜和全色锐化等处理之后, 对所有影像进行面向对象分割。面向对象分割之后的斑块的中心点经过空间聚类成为M组点的集合。每组点集通过最小生成树的方式生成一个包含N个节点和E条边的无向图, 记为 $G(N, E)$ 。每个节点包含的属性有节点对应的斑块范围内的地形变量、气候变量、物候指数变量和其他植被指数变量。节点对应的目标变量为斑块内地面实测植被类型Y。因此, 图神经网络的输入为无向图G和其对应的邻接矩阵A; 在隐藏层中, 图卷积运算是通过将图做傅里叶变化到频域进行逐元素相乘, 再将相乘结果经过傅里叶逆变换到空间域完成; 卷积运算的结果同样需要经过激活函数 δ 和池化操作实现非线性特征的提取, 多个隐藏层的特征提取如公式(1)所示; 输出层得到的是与输入层相同节点数量的矩阵, 矩阵的值为每个节点对应属于不同植被类型的概率(图7)。

$$H^L = \delta(W^{L-1}H^{L-1} + b^{L-1}), \quad (1)$$

式中, H^L 为第L层的特征表达, W^{L-1} 为第L-1层的权重参数矩阵, H^{L-1} 为第L-1层的特征表达, b^{L-1} 为第L-1层的偏置项。

上述图神经网络结构以空间分布的离散点数据为

输入, 是生态资源大数据时代最常见的一种数据形式。通过图神经网络结构将节点包含的丰富的环境特征信息转化为适合植被类型预测的深层非线性特征。在海量地面调查数据的监督学习下, 通过误差的反向传播最终实现基于空间离散点数据的植被类型预测模型。在此基础上, 通过提取不包含地面调查数据区域的环境特征信息, 可利用已经训练好的模型进行预测, 最终实现全国范围内植被制图。本文所述方法目前处于初步验证阶段, 图神经网络在生态资源大数据的应用目前也鲜有报道, 但是图神经网络效率和性能已经在激光雷达点云分类和城市建筑物格局分析等领域得到充分体现(Landrieu和Simonovsky, 2017; Wang Y等, 2018; Yan等, 2019)。

4 深度学习在生态资源中面临的挑战和机遇

伴随着GPU、TPU、ASIC(Application Specific Intergrated Circuits)和FPGA(Field-Programmable Gate Array)等芯片技术的发展, 硬件条件已经不是深度学习技术在大数据时代应用的主要瓶颈。同时, 更加深层和复杂的神经网络模型被学界和业界提出, 并在文本分类(Conneau等, 2016)、语音识别(Ravanelli, 2017)、图像分割(Sermanet等, 2013; Song和Xiao, 2016)、视频分析(Wang和Sng, 2015)和关系推理(Battaglia等, 2018)等领域都取得了前所未有的精度(LeCun等, 2015)。近年来, 滴滴、高德、阿里巴巴、商汤科技和华为等公司先后在地图测绘和土地利用识别等遥感图像智能分析方面引领了深度学习在行业的应用, 给传统的空间信息行业带来了巨大冲击。生态资源领域的工作者应当清楚地认识到深度学习在本领域的应用挑战并抓住新技术的机遇, 才能有效避免传统的生态资源研究被计算机等领域入侵的危机。如果说深度学习是一场发展浪潮, 目前在生态资源领域, 深度学习已经“淹没”了大部分传统的分类和识别任务(水体部分), 在物种分类、器官识别和土地覆盖分类等工作中远远超过了传统的方法。图8中距离水体很近的岸边所显示的诸如植被分类、地形插值、种群动态监测等应用则表示即将受深度学习冲击的领域。此外, 受深度学习浪潮冲击较小的领域主要位于距离浪潮较远的山体部分, 这些领域涉及到人文思想和规划设计, 如森

图 7 利用GNN模型对植被分布的离散点数据结合连续分布的遥感图像进行训练学习

林经理、生态规划和生态理论等. 在这些挑战面前, 我们需要解决的问题和能够抓住的机遇主要有以下三方面(图9).

(1) 数据的标准化和共享化. 当前, 监督学习是深度学习的主要形式, 而海量带有标记的数据则是监督学习的前提. 数据的数量和质量决定了模型的精度和稳定性(Marcus, 2018). 现阶段公布的很多公共数据集(如MINIST和COCO等)只能支持特定的任务. 针对解决实际问题的样本还很缺乏, 尤其是在生态资源研究领域. 基础研究对数据积累的意识不够强烈, 加上研

究条件和背景环境因素的复杂性, 使得生态资源数据的获取、传输、存储、标记和共享使用更加缺乏, 难以满足数量需求. 例如, 利用深度学习技术识别不同鸟类的叫声从而监测鸟类多样性时至少需要收集36小时鸟叫的音频记录才能保证深度学习算法比人耳辨别更有效(Christin等, 2018; Knight等, 2017; Potamitis, 2016). 利用卷积神经网络自动定位蜜蜂的活动位置时, 需要生成10000个带有标记的图像用于训练蜜蜂的定位模型(Wild等, 2018). 另一方面, 现阶段生态资源领域采集的数据往往集中在不同机构和不同专家的

图8 生态资源领域被深度学习浪潮带来冲击和颠覆的领域(水体与近水体部分)以及存在挑战和未来亟待解决的领域(山体部分)

个人数据库中,不同来源的数据由于采集者目的不同,标准不统一,难以满足质量需求.在数据共享方面,虽然已有TRY(Kattge等, 2011)和sPlot(Purschke等, 2015)等全球尺度的植物性状和样方调查数据库已经实现了较程度的开放共享,但是这些数据没有按照深度学习研究的标准组织成直接可用的数据集.对于其他生态资源领域的数据集共享问题则更为迫切.

构建标准的数据体系、搭建众源的数据共享平台是大数据标准化和共享化的基础.目前,生态资源领域大数据主要来源有长时间和宽覆盖的卫星遥感数据(如Landsat、MODIS、Sentinel、高分、资源和环境系列等)、手机等智能终端(如花伴侣、形色和绿途等)获取的众源数据和大型数据网络设施平台(如全球生物多样性信息网络和世界自然保护联盟等)积累的台站数据.这些数据体量大、种类多、信息复杂,如国家标本资源平台(National Specimen Information Infrastructure, NSII, <http://www.nsii.org.cn>)拥有1400多万条标本记录,600多万条植物和昆虫的图像数据.对生态资源领域的

数据建立标准的数据体系,充分发挥众包平台对数据进行分类整理和人工标记,最终建立开放共享的数据平台是一项重要而影响深远的工作,如在中国科学院“地球大数据科学工程”项目支持下开发的“绿途”众源植被分布数据采集系统和共享平台用于植被制图等工作,正是对生态资源大数据研究范式的一种探索.

(2) 算法的普适性和解释性.深度学习自出现以来就朝着网络层数越来越深的方向发展.隐藏层的增加使得模型提取非线性特征的能力增强,但也导致模型的解释性降低,这是深度学习被称为黑盒的一个重要原因.生态资源研究关注过程和格局的成因和机理,隐藏层的不可解释性限制了深度学习在机理问题研究中的应用.虽然Shwartz-Ziv和Tishby(2017)把信息瓶颈(information bottleneck)理论应用于解释深度学习网络的不同层之间的状态变化,以及网络是如何实现数据压缩率和准确率的权衡过程,但是这种解释目前在大型神经网络中是否存在还未得到充分验证.

因此,结合领域知识,开发结合物理模型和深度学

图 9 深度学习在生态资源领域应用的挑战与机遇

习的组合型算法，增强模型普适性和解释性是算法领域的机遇。一方面，由于标注数据成本昂贵，因此发展半监督和自监督学习是当前深度学习的前沿之一。目前已有相关的研究工作，如生成对抗网络(Goodfellow等, 2014)、对偶学习(He D等, 2016)、强化学习(Chen等, 2018)及迁移学习(Bengio, 2012)等适用于小样本、转移性强的模型。同时，为了增强模型的普适性，在小样本学习的基础上，如果能够结合传统物理/数学模型的原理求解和深度学习的范例学习，发挥两者优势的新型算法不但能提升模型的泛化能力，还能促进模型的机理解释(Reichstein等, 2019; 徐宗本等, 2013)。另一方面，复杂的隐藏层也增加了模型解释的难度，如何将复杂模型的隐藏层可视化，如何解释数据和信息在深层神经网络中的变化也是未来应该被关注的一个重要方向(Shwartz-Ziv和Tishby, 2017)，如Wu等(2017)采用简单决策树正则化深度神经网络的方法提高了模型的可解释性。总之，充分利用地学背景环境信息和生态学图论关系等领域知识，考虑生态资源领域问题的特殊性(如时间和空间相关性)，结合深度学习模型与传统经验模型的优点(Gatta等, 2014; Liu等, 2017; Wolf, 2003)，推动模型的普适性和解释性发展，促进大数据背景下的机理推理是当前算法发展迫切需求和机遇。

(3) 应用的丰富化和智能化。随着生态资源领域进入大数据时代，深度学习算法和计算机硬件走向成熟，深度学习解决生态资源领域问题的研究势必会成为未

来的研究热点。但是，目前深度学习的方法没有被充分地应用于生态资源研究，主要解决了一些非机理性问题(Christin等, 2018; Marcus, 2018)，其主要原因在于生态学家和计算机科学家之间缺乏对数据标准和应用需求的交流和合作。有限的公开数据和不统一的数据格式，使得计算机科学家难以构建具有代表性的数据集，致使当前深度学习在生态资源领域研究任务中效果不佳。例如，深度学习能够很好地发现生物学数据中的批量差异，但却难以从正常差异中辨别相应的微小差异(Webb, 2018)；深度学习也难以通过识别远距离物种的声音，判定出感兴趣的特定物种(Christin等, 2018)。这类由于样本数量不足和质量不佳带来的问题需要具有专业背景的生态学家辅助计算机科学家解决，如通过传统的数据收集方法来获得更多高质量的样本数据，构建标准的公开数据集(Liu J等, 2016)。

促进多学科交叉和人才培养是实现丰富化和智能化应用的机遇。学科交叉在很大程度上依赖于人才培养和学科设置的改革。人才梯度完善、学科设置合理，深度学习技术就能不断丰富其智能化应用，促进多平台和多元传感器进行数据采集，结合数据融合、深度学习算法和生态学家的专业知识对数据进行评判、筛选，最终做出适当的决策管理。例如利用深度学习指导无人机重新播种，或者指导机器人去除一些入侵物种，这种全自动的管理方式将会大大减少人为活动对生态系统的干扰(Cantrell等, 2017; Christin等, 2018)。

生态资源领域已经进入大数据时代，而目前对于大数据的挖掘应用比较有限。构建公开可用的生态资源标准数据集是深度学习应用的前提，并且随着数据集的成熟和方法的进步，静态的目标识别将向动态发展。此外，随着深度学习模型在解释性方面的提升，以及图神经网络等新型网络在推理等领域的改进，结合生态资源数据的关联网络分析有望成为多尺度、多要素知识发现的新途径。对于深度学习算法本身的发展，有望更深入的结合交叉学科领域的知识(如物理模型)，从模型普适性和解释性方面突破，有望建立大数据驱动下数据密集型知识发现的新范式(郭华东等, 2016)。同时，如果深度学习算法能够充分学习人脑的思维推理，将会实现在生态资源的管理和规划等应用的一个重大突破。在深度学习发展的热潮和生态资源大数据背景下，生态资源大数据、大科学和大发现的新时代将会到来。

参考文献

- 郭华东. 2014. 大数据 大科学 大发现——大数据与科学发现国际研讨会综述. 中国科学院院刊, 29: 500–506
- 郭华东. 2018. 科学大数据——国家大数据战略的基石. 中国科学院院刊, 33: 768–773
- 郭华东, 陈润生, 徐志伟, 孙建军, 毕军, 王力哲, 骆健俊, 沈华伟, 顾东晓, 梁栋, Spiess H W, Lengauer T. 2016. 自然科学与人文科学大数据——第六届中德前沿探索圆桌会议综述. 中国科学院院刊, 31: 707–716
- 李德仁. 1999. 信息高速公路、空间数据基础设施与数字地球. 测绘学报, 28: 1–5
- 李德仁. 2016. 展望大数据时代的地球空间信息学. 测绘学报, 45: 379–384
- 马克平, 朱敏, 纪力强, 马俊才, 郭庆华, 欧阳志云. 2018. 中国生物多样性大数据平台建设. 中国科学院院刊, 33: 80–87
- 吴炳方, 张鑫, 曾红伟, 张淼, 田富有. 2018. 资源环境数据生成的大数据方法. 中国科学院院刊, 8: 1–8
- 徐宗本, 杨燕, 孙剑. 2013. 求解反问题的一个新方法: 模型求解与范例学习结合. 中国科学: 数学, 47: 1345–1354
- 翟明国, 杨树锋, 陈宁华, 陈汉林. 2018. 大数据时代: 地质学的挑战与机遇. 中国科学院院刊, 33: 825–831
- Aich S, Stavness I. 2017. Leaf counting with deep convolutional and deconvolutional networks. Proceedings of the 2017 IEEE International Conference on Computer Vision Workshops (ICCVW). 1: 22–29
- Ba J, Caruana R. 2014. Do deep nets really need to be deep? Adv Neural Information Proc Systems, 1: 2654–2662
- Barré P, Stöver B C, Müller K F, Steinhage V. 2017. LeafNet: A computer vision system for automatic plant species identification. Ecol Inf, 40: 50–56
- Battaglia P W, Hamrick J B, Bapst V, Sanchez-Gonzalez A, Zambaldi V, Malinowski M, Tacchetti A, Raposo D, Santoro A, Faulkner R. 2018. Relational inductive biases, deep learning, and graph networks. arXiv: 1806.01261
- Baweja H S, Parhar T, Mirbod O, Nuske S. 2018. StalkNet: A deep learning pipeline for high-throughput measurement of plant stalk count and stalk width. In: Hutter M, Siegwart R, eds. Field and Service Robotics. Springer Proceedings in Advanced Robotics, vol 5. Cham: Springer. 271–284
- Bengio Y. 2012. Deep Learning of representations for unsupervised and transfer learning. Proc ICML Workshop Unsupervised Transfer Learning, 1: 17–36
- Bengio Y, Courville A, Vincent P. 2013. Representation learning: A review and new perspectives. IEEE Trans Pattern Anal Mach Intell, 35: 1798–1828
- Black H C, Nolan J R, Connolly M J, Nolan-Haley J M. 1990. Black's Law Dictionary: Definitions of the Terms and Phrases of American and English Jurisprudence, Ancient and Modern. Minnesota: West Publishing Company
- Boureau Y L, Bach F, LeCun Y, Ponce J. 2010a. Learning mid-level features for recognition. San Francisco: IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2559–2566
- Boureau Y L, Ponce J, LeCun Y. 2010b. A theoretical analysis of feature pooling in visual recognition. Haifa: Proceedings of the 27th International Conference On Machine Learning (ICML-10). 111–118
- Brodrick P G, Davies A B, Asner G P. 2019. Uncovering ecological patterns with convolutional neural networks. Trends Ecol Evol, 34: 734–745
- Cantrell B, Martin L J, Ellis E C. 2017. Designing autonomy: Opportunities for new wildness in the anthropocene. Trends Ecol Evol, 32: 156–166
- Carranza-Rojas J, Goeau H, Bonnet P, Mata-Montero E, Joly A. 2017. Going deeper in the automated identification of Herbarium specimens. BMC Evol Biol, 17: 181–194
- Chai D, Newsam S, Zhang H K, Qiu Y, Huang J. 2019. Cloud and cloud shadow detection in Landsat imagery based on deep convolutional neural networks. Remote Sens Environ, 225: 307–316
- Chen Y, Zhang Q, Huang C, Mu L, Meng G, Wang X. 2018. Reinforced evolutionary neural architecture search. arXiv: 1808.00193
- Cheng G, Yang C, Yao X, Guo L, Han J. 2018. When Deep Learning meets metric learning: Remote sensing image scene classification via learning discriminative CNNs. IEEE Trans Geosci Remote Sens, 56: 2811–2821
- Christin S, Hervet E, Lecomte N. 2018. Applications for deep learning in ecology. bioRxiv, doi: 10.1101/334854
- Comaniciu D, Meer P. 2002. Mean shift: A robust approach toward feature space analysis. IEEE Trans Pattern Anal Machine Intell, 24: 603–619
- Conneau A, Schwenk H, Barrault L, LeCun Y. 2016. Very Deep convolutional networks for text classification. arXiv: 1606.01781
- Connor J T, Martin R D, Atlas L E. 1994. Recurrent neural networks and robust time series prediction. IEEE Trans Neural Netw, 5: 240–254
- Cutler D R, Edwards Jr. T C, Beard K H, Cutler A, Hess K T, Gibson J, Lawler J J. 2007. Random forests for classification in ecology. Ecology, 88: 2783–2792
- De Brabandere B, Neven D, Van Gool L. 2017. Semantic instance segmentation with a discriminative loss function. arXiv: 1708.02551

- Dobrescu A, Valerio Giuffrida M, Tsaftaris S A. 2017. Leveraging multiple datasets for deep leaf counting. *Proc IEEE Inter Conference Computer Vision*, 1: 2072–2079
- Douarre C, Schielein R, Frindel C, Gerth S, Rousseau D. 2016. Deep Learning based root-soil segmentation from X-ray tomography. *bioRxiv*, doi: 10.1101/071662
- Ehrlich P R, Ehrlich A H. 1970. *Population, Resources, Environment. Issues in San Francisco*: Freeman and Company
- Fang H, Lafarge F. 2019. Pyramid scene parsing network in 3D: Improving semantic segmentation of point clouds with multi-scale contextual information. *ISPRS J Photogramm Remote Sens*, 154: 246–258
- Gatta C, Romero A, Veijer J V D. 2014. Unrolling loopy top-down semantic feedback in convolutional deep networks. *Computer Vision and Pattern Recognition Workshops*, 1: 504–511
- Ghosal S, Blystone D, Singh A K, Ganapathysubramanian B, Singh A, Sarkar S. 2018. An explainable deep machine vision framework for plant stress phenotyping. *Proc Natl Acad Sci USA*, 115: 4613–4618
- Girshick R. 2015. Fast R-CNN. *Proceedings of the IEEE International Conference On Computer Vision*, 1: 1440–1448
- Girshick R, Donahue J, Darrell T, Malik J. 2014. Rich feature hierarchies for accurate object detection and semantic segmentation. *Proc IEEE Conference Computer Vision and Pattern Recognition*, 1: 580–587
- Girshick R, Donahue J, Darrell T, Malik J. 2016. Region-based convolutional networks for accurate object detection and segmentation. *IEEE Trans Pattern Anal Mach Intell*, 38: 142–158
- Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, Courville A, Bengio Y. 2014. Generative adversarial nets. *Adv Neural Information Processing Systems*, 1: 2672–2680
- Griffiths D, Boehm J. 2019. Improving public data for building segmentation from Convolutional Neural Networks (CNNs) for fused airborne lidar and image data using active contours. *ISPRS J Photogramm Remote Sens*, 154: 70–83
- Grinblat G L, Uzal L C, Larese M G, Granitto P M. 2016. Deep learning for plant identification using vein morphological patterns. *Comput Electron Agr*, 127: 418–424
- Guo Q H, Kelly M, Graham C H. 2005. Support vector machines for predicting distribution of sudden oak death in California. *Ecol Model*, 182: 75–90
- Guo Z, Shengoku H, Wu G, Chen Q, Yuan W, Shi X, Shao X, Xu Y, Shibasaki R. 2018. Semantic segmentation for urban planning maps based on U-Net. *IGARSS 2018–2018 IEEE Inter Geosci Remote Sensing Symposium*, 1: 6187–6190
- Hamida A B, Benoit A, Lambert P, Ben Amar C. 2018. 3-D Deep Learning approach for remote sensing image classification. *IEEE Trans Geosci Remote Sens*, 56: 4420–4434
- Han W, Feng R, Wang L, Cheng Y. 2017. A semi-supervised generative framework with Deep Learning features for high-resolution remote sensing image scene classification. *ISPRS J Photogramm Remote Sens*, 145: 23–43
- Handan-Nader C, Ho D E. 2019. Deep learning to map concentrated animal feeding operations. *Nat Sustain*, 2: 298–306
- He D, Xia Y, Qin T, Wang L, Yu N, Liu T, Ma W Y. 2016. Dual learning for machine translation. *Adv Neural Information Proc Systems*, 1: 820–828
- He K, Gkioxari G, Dollár P, Girshick R. 2017. Mask R-CNN. *Proc IEEE Inter Conference Computer Vision*, 1: 2961–2969
- He K, Zhang X, Ren S, Sun J. 2016. Deep residual learning for image recognition. *Proc IEEE Conference Computer Vision Pattern Recognition*, 1: 770–778
- Hinton G E, Osindero S, Teh Y W. 2006. A fast learning algorithm for deep belief nets. *Neural Comput*, 18: 1527–1554
- Hinton G E, Salakhutdinov R R. 2006. Reducing the dimensionality of data with neural networks. *Science*, 313: 504–507
- Hochreiter S, Schmidhuber J. 1997. Long short-term memory. *Neural Comput*, 9: 1735–1780
- Huang B, Zhao B, Song Y. 2018. Urban land-use mapping using a deep convolutional neural network with high spatial resolution multi-spectral remote sensing imagery. *Remote Sens Environ*, 214: 73–86
- Jeong K S, Kim D K, Jung J M, Kim M C, Joo G J. 2008. Non-linear autoregressive modelling by Temporal Recurrent Neural Networks for the prediction of freshwater phytoplankton dynamics. *Ecol Model*, 211: 292–300
- Jeppesen J H, Jacobsen R H, Inceoglu F, Toftegaard T S. 2019. A cloud detection algorithm for satellite imagery based on deep learning. *Remote Sens Environ*, 229: 247–259
- Jin S, Su Y, Gao S, Hu T, Liu J, Guo Q. 2018a. The transferability of random forest in canopy height estimation from multi-source remote sensing data. *Remote Sens*, 10: 1183–1203
- Jin S, Su Y, Gao S, Wu F, Hu T, Liu J, Li W, Wang D, Chen S, Jiang Y, Pang S, Guo Q. 2018b. Deep learning: Individual maize segmentation from terrestrial Lidar data using Faster R-CNN and regional growth algorithms. *Front Plant Sci*, 9: 866–875
- Jin S, Su Y, Gao S, Wu F, Ma Q, Xu K, Ma Q, Hu T, Liu J, Pang S, Guan H, Zhang J, Guo Q. 2020. Separating the structural components of maize for field phenotyping using terrestrial Lidar data and deep convolutional neural networks. *IEEE Trans Geosci Remote Sens*, 58: 2644–2658
- Jin X, Liu S, Baret F, Hemerlé M, Comar A. 2017. Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sens Environ*, 198: 105–114

- Jordan M I, Mitchell T M. 2015. Machine learning: Trends, perspectives, and prospects. *Science*, 349: 255–260
- Karpatne A, Ebert-Uphoff I, Ravela S, Babaie H A, Kumar V. 2018. Machine learning for the geosciences: Challenges and opportunities. *IEEE Trans Knowl Data Eng*, 31: 1544–1554
- Kattge J, Diaz S, Lavorel S, Prentice I C, Leadley P, Bönsch G, Garnier E, Westoby M, Reich P B, Wright I J, Cornelissen J H C, Violle C, Harrison S P, Van BODEGOM P M, Reichstein M, Enquist B J, Soudzilovskaia N A, Ackerly D D, Anand M, Atkin O, Bahn M, Baker T R, Baldocchi D, Bekker R, Blanco C C, Blonder B, Bond W J, Bradstock R, Bunker D E, Casanoves F, Cavender-bares J, Chambers J Q, Chapin Iii F S, Chave J, Coomes D, Cornwell W K, Craine J M, Dobrin B H, Duarte L, Durka W, Elser J, Esser G, Estiarte M, Fagan W F, Fang J, Fernández-méndez F, Fidelis A, Finegan B, Flores O, Ford H, Frank D, Freschet G T, Fyllas N M, Gallagher R V, Green W A, Gutierrez A G, Hickler T, Higgins S I, Hodgson J G, Jalili A, Jansen S, Joly C A, Kerkhoff A J, Kirkup D, Kitajima K, Kleyer M, Klotz S, Knops J M H, Kramer K, Kühn I, Kurokawa H, Laughlin D, Lee T D, Leishman M, Lens F, Lenz T, Lewis S L, Lloyd J, Llusià J, Louault F, Ma S, Mahecha M D, Manning P, Massad T, Medlyn B E, Messier J, Moles A T, Müller S C, Nadrowski K, Naeem S, Niinemets Ü, Nöllert S, Nüske A, Ogaya R, Oleksyn J, Onipchenko V G, Onoda Y, Ordoñez J, Overbeck G, Ozinga W A, Patiño S, Paula S, Pausas J G, Peñuelas J, Phillips O L, Pillar V, Poorter H, Poorter L, Poschold P, Prinzing A, Proulx R, Rammig A, Reinsch S, Reu B, Sack L, Salgado-negret B, Sardans J, Shiodera S, Shipley B, Siefert A, Sosinski E, Soussana J F, Swaine E, Swenson N, Thompson K, Thornton P, Waldram M, Weiher E, White M, White S, Wright S J, Yguel B, Zaehle S, Zanne A E, Wirth C. 2011. TRY—A global database of plant traits. *Glob Change Biol*, 17: 2905–2935
- Kellenberger B, Marcos D, Tuia D. 2018. Detecting mammals in UAV images: Best practices to address a substantially imbalanced dataset with Deep Learning. *Remote Sens Environ*, 216: 139–153
- Kemker R, Salvaggio C, Kanan C. 2018. Algorithms for semantic segmentation of multispectral remote sensing imagery using Deep Learning. *ISPRS J Photogramm Remote Sens*, 145: 60–77
- Knight E C, Hannah K C, Foley G J, Scott C D, Brigham R M, Bayne E. 2017. Recommendations for acoustic recognizer performance assessment with application to five common automated signal recognition programs. *Avian Conserv Ecol*, 12: 14–42
- Krizhevsky A, Sutskever I, Hinton G E. 2012. Imagenet classification with deep convolutional neural networks. *Adv Neural Information Processing Systems*, 1: 1097–1105
- Kussul N, Lavreniuk M, Skakun S, Shelestov A. 2017. Deep Learning classification of land cover and crop types using remote sensing data. *IEEE Geosci Remote Sens Lett*, 14: 778–782
- Lai L, Huang X, Yang H, Chuai X, Zhang M, Zhong T, Chen Z, Chen Y, Wang X, Thompson J R. 2016. Carbon emissions from land-use change and management in China between 1990 and 2010. *Sci Adv*, 2: e1601063
- Landrieu L, Simonovsky M. 2017. Large-scale point cloud semantic segmentation with superpoint graphs. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 4558–4567
- LeCun Y. 2015. LeNet-5, convolutional neural networks. URL: <http://yann.lecun.com/exdb/lenet>: 20
- LeCun Y, Bengio Y, Hinton G. 2015. Deep Learning. *Nature*, 521: 436–444
- LeCun Y, Bottou L, Bengio Y, Haffner P. 1998. Gradient-based learning applied to document recognition. *Proc IEEE*, 86: 2278–2324
- Lee S H, Chan C S, Wilkin P, Remagnino P. 2015. Deep-plant: Plant identification with convolutional neural networks. *IEEE Inter Conference Image Processing (ICIP)*, 1: 452–456
- Lee S H, Chang Y L, Chan C S, Remagnino P. 2016. Plant identification system based on a convolutional neural network for the lifeCLEF 2016 plant classification task. *CLEF (Working Notes)*. 502–510
- Lenihan J M, Drapek R, Bachelet D, Neilson R P. 2003. Climate change effects on vegetation distribution, carbon, and fire in California. *Ecol Appl*, 13: 1667–1681
- Li J X, Zhang D X, Zhang J J, Zhang J, Xun L N, Yan Q, Desteche Publicat I. 2016. Plant leaf recognition based on small datasets using deep learning algorithm. *2016 International Conference on Computer Science and Information Security (Csis 2016)*. 351–355
- Li W, Fu H, Yu L, Cracknell A. 2017. Deep Learning based oil palm tree detection and counting for high-resolution remote sensing images. *Remote Sens*, 9: 22–34
- Li Z, Shen H, Cheng Q, Liu Y, You S, He Z. 2019. Deep Learning based cloud detection for medium and high resolution remote sensing images of different sensors. *ISPRS J Photogramm Remote Sens*, 150: 197–212
- Liang Z, Yang M, Wang C. 2019. 3D graph embedding learning with a structure-aware loss function for point cloud semantic instance segmentation. *arXiv*: 1902.05247
- Liu C, Furukawa Y. 2019. MASC: Multi-scale affinity with sparse convolution for 3D instance segmentation. *arXiv*: 1902.04478
- Liu J, Li J, Li W, Wu J. 2016. Rethinking big data: A review on the data quality and usage issues. *ISPRS J Photogramm Remote Sens*, 115: 134–142
- Liu R, Fan X, Cheng S, Wang X, Luo Z. 2017. Proximal alternating direction network: A globally converged deep unrolling framework.

- Thirty-Second AAAI Conference on Artificial Intelligence. 1: 1–8
- Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu C Y, Berg A C. 2016. SSD: Single shot multibox detector. *European Conference On Computer Vision*. 21–37
- Madec S, Jin X, Lu H, De Solan B, Liu S, Duyme F, Heritier E, Baret F. 2019. Ear density estimation from high resolution RGB imagery using Deep Learning technique. *Agric For Meteorol*, 264: 225–234
- Mandic D P, Chambers J. 2001. *Recurrent Neural Networks for Prediction: Learning Algorithms, Architectures and Stability*. New Jersey: John Wiley & Sons, Inc
- Marcus G. 2018. Deep learning: A critical appraisal. arXiv: 1801.00631
- Martin A C, Harvey W J. 2017. The Global Pollen Project: A new tool for pollen identification and the dissemination of physical reference collections. *Methods Ecol Evol*, 8: 892–897
- McCallen E, Knott J, Nunez-Mir G, Taylor B, Jo I, Fei S. 2019. Trends in ecology: Shifts in ecological research themes over the past four decades. *Front Ecol Environ*, 17: 109–116
- McCulloch W S, Pitts W. 1943. A logical calculus of the ideas immanent in nervous activity. *Bull Math Biophys*, 5: 115–133
- Minsky M L, Papert S. 1969. *Perceptrons: An Introduction to Computational Geometry*. Cambridge: The MIT Press
- Mohanty S P, Hughes D P, Salathé M. 2016. Using Deep Learning for image-based plant disease detection. *Front Plant Sci*, 7: 1419–1428
- Monfreda C, Ramankutty N, Foley J A. 2008. Farming the planet: 2. Geographic distribution of crop areas, yields, physiological types, and net primary production in the year 2000. *Glob Biogeochem Cycle*, 22: GB1022
- Norouzzadeh M S, Nguyen A, Kosmala M, Swanson A, Palmer M S, Packer C, Clune J. 2018. Automatically identifying, counting, and describing wild animals in camera-trap images with Deep Learning. *Proc Natl Acad Sci USA*, 115: E5716–E5725
- Olden J D, Lawler J J, Poff N L R. 2008. Machine learning methods without tears: A primer for ecologists. *Q Rev Biol*, 83: 171–193
- Pan B, Shi Z, Xu X. 2017. MugNet: Deep Learning for hyperspectral image classification using limited samples. *ISPRS J Photogramm Remote Sens*, 145: 108–119
- Park Y S, Chon T S. 2007. Biologically-inspired machine learning implemented to ecological informatics. *Ecol Model*, 203: 1–7
- Pärnamäa T, Parts L. 2017. Accurate classification of protein subcellular localization from high-throughput microscopy images using deep learning. *G3-Genes Genom Genet*, 7: 1385–1392
- Pathak A R, Pandey M, Rautaray S. 2018. Application of deep learning for object detection. *Procedia Comput Sci*, 132: 1706–1717
- Pham Q H, Nguyen D T, Hua B S, Roig G, Yeung S K. 2019. JSIS3D: Joint semantic-instance segmentation of 3D point clouds with multi-task pointwise networks and multi-value conditional random fields. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 8827–8836
- Potamitis I. 2015. Unsupervised dictionary extraction of bird vocalisations and new tools on assessing and visualising bird activity. *Ecol Inf*, 26: 6–17
- Potamitis I. 2016. Deep Learning for detection of bird vocalisations. arXiv: 1609.08408
- Pound M P, Atkinson J A, Townsend A J, Wilson M H, Griffiths M, Jackson A S, Bulat A, Tzimiropoulos G, Wells D M, Murchie E H, Pridmore T P, French A P. 2017a. Deep machine learning provides state-of-the-art performance in image-based plant phenotyping. *Gigascience*, 6: 83–92
- Pound M P, Atkinson J A, Wells D M, Pridmore T P, French A P. 2017b. Deep Learning for multi-task plant phenotyping. *Proc IEEE Conference Computer Vision Pattern Recognition*, 1: 2055–2063
- Purschke O, Dengler J, Bruehlheide H, Hennekens S, Jandt U, Chytrý M, Jansen F, Jiménez-Alfaro B, Kattge J, Lenoir J. 2015. sPlot—The new global vegetation-plot database for addressing trait-environment relationships across the world's biomes. In: Mucina L, Price J N, Kalwij J M, eds. *Biodiversity and Vegetation: Patterns, Processes, Conservation*. 90
- Qi C R, Su H, Mo K, Guibas L J. 2016. Pointnet: Deep Learning on point sets for 3D classification and segmentation. arXiv: 1612.00593
- Qi C R, Yi L, Su H, Guibas L J. 2017. PointNet++: Deep hierarchical feature learning on point sets in a metric space. In: *Advances in Neural Information Processing Systems*. 5099–5108
- Rahmehoonfar M, Sheppard C. 2017. Real-time yield estimation based on Deep Learning. *SPIE Commercial+ Scientific Sensing and Imaging*. 1: 10218: 09–15
- Ramankutty N, Evan A T, Monfreda C, Foley J A. 2008. Farming the planet: 1. Geographic distribution of global agricultural lands in the year 2000. *Glob Biogeochem Cycle*, 22: GB1003
- Ramcharan A, Baranowski K, McCloskey P, Ahmed B, Legg J, Hughes D P. 2017. Deep Learning for image-based cassava disease detection. *Front Plant Sci*, 8: 1852–1858
- Ravanelli M. 2017. Deep Learning for distant speech recognition. arXiv: 1712.06086
- Recknagel F. 2001. Applications of machine learning to ecological modelling. *Ecol Model*, 146: 303–310
- Redmon J, Divvala S, Girshick R, Farhadi A. 2016. You only look once: Unified, real-time object detection. *Proc IEEE Conference Computer Vision and Pattern Recognition*, 1: 779–788
- Reichstein M, Camps-Valls G, Stevens B, Jung M, Denzler J, Carvalhais N, Prabhat N. 2019. Deep learning and process

- understanding for data-driven Earth system science. *Nature*, 566: 195–204
- Ren S, He K, Girshick R, Sun J. 2015. Faster R-CNN: Towards real-time object detection with region proposal networks. *Adv Neural Information Processing Systems*, 1: 91–99
- Romera-Paredes B, Torr P H S. 2016. Recurrent instance segmentation. *European Conference on Computer Vision*. 1: 312–329. In: Leibe B, Matas J, Sebe N, Welling M, eds. *Computer Vision—ECCV 2016*. Lecture Notes in Computer Science, vol 9910. Cham: Springer
- Ronneberger O, Fischer P, Brox T. 2015. U-Net: Convolutional networks for biomedical image segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. 234–241
- Rosenblatt F. 1960. Perceptron simulation experiments. *Proc IRE*, 48: 301–309
- Ross T Y L P G, Dollár G K H P. 2017. Focal loss for dense object detection. *Proc IEEE Conference Computer Vision Pattern Recognition*, 1: 2980–2988
- Rumelhart D E, Hinton G E, Williams R J. 1986. Learning representations by back-propagating errors. *Nature*, 323: 533–536
- Rzanny M, Seeland M, Wäldchen J, Mäder P. 2017. Acquiring and preprocessing leaf images for automated plant identification: Understanding the tradeoff between effort and information gain. *Plant Methods*, 13: 97–107
- Salamon J, Bello J P, Farnsworth A, Kelling S. 2017. Fusing shallow and Deep Learning for bioacoustic bird species classification. 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 141–145
- Schmidhuber J. 2015. Deep Learning in neural networks: An overview. *Neural Networks*, 61: 85–117
- Scott M J, Bilyard G R, Link S O, Ulibarri C A, Westerdahl H E, Ricci P F, Seely H E. 1998. Valuation of ecological resources and functions. *Environ Manage*, 22: 49–68
- Sermanet P, Eigen D, Zhang X, Mathieu M, Fergus R, LeCun Y. 2013. Overfeat: Integrated recognition, localization and detection using convolutional networks. arXiv: 1312.6229
- Shi M, Xie F, Zi Y, Yin J. 2016. Cloud detection of remote sensing images by Deep Learning. *Geoscience and Remote Sensing Symposium (IGARSS)*, 2016 IEEE International. 701–704
- Shwartz-Ziv R, Tishby N. 2017. Opening the black box of deep neural networks via information. arXiv: 1703.00810
- Silver D, Schrittwieser J, Simonyan K, Antonoglou I, Huang A, Guez A, Hubert T, Baker L, Lai M, Bolton A, Chen Y, Lillicrap T, Hui F, Sifre L, van den Driessche G, Graepel T, Hassabis D. 2017. Mastering the game of Go without human knowledge. *Nature*, 550: 354–359
- Singh A K, Ganapathysubramanian B, Sarkar S, Singh A. 2018. Deep Learning for plant stress phenotyping: Trends and future perspectives. *Trends Plant Sci*, 23: 883–898
- Song S, Xiao J. 2016. Deep sliding shapes for amodal 3D object detection in RGB-D images. *Proc IEEE Conference on Computer Vision and Pattern Recognition*, 1: 808–816
- Sun Y, Zhang X, Xin Q, Huang J. 2018. Developing a multi-filter convolutional neural network for semantic segmentation using high-resolution aerial imagery and LiDAR data. *ISPRS J Photogramm Remote Sens*, 143: 3–14
- Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A. 2015. Going deeper with convolutions. *Proc IEEE Conference Computer Vision and Pattern Recognition*, 1: 1–9
- Taghavi Namin S, Esmailzadeh M, Najafi M, Brown T B, Borevitz J O. 2018. Deep phenotyping: Deep Learning for temporal phenotype/genotype classification. *Plant Methods*, 14: 66–79
- Tang Z T, Shao K, Zhao D B, Zhu Y H. 2017. Recent progress of deep reinforcement learning: From AlphaGo to AlphaGo Zero. *IET Control Theory Appl*, 34: 1529–1546
- Thessen A. 2016. Adoption of machine learning techniques in ecology and earth science. *One Ecosystem*, 1: 8621–8658
- Thi Thanh-Nhan N, Thi-Lan L, Hai V, Huy-Hoang N, Van-Sam H. 2017. A combination of Deep Learning and hand-designed feature for plant identification based on leaf and flower images. *Asian Conference on Intelligent Information and Database Systems*. Cham: Springer. 223–233
- Ubbens J R, Stavness I. 2017. Deep plant phenomics: A Deep Learning platform for complex plant phenotyping tasks. *Front Plant Sci*, 8: 1
- Volpi M, Tuia D. 2018. Deep multi-task learning for a geographically-regularized semantic segmentation of aerial images. *ISPRS J Photogramm Remote Sens*, 144: 48–60
- Wang G, Sun Y, Wang J. 2017. Automatic image-based plant disease severity estimation using deep learning. *Comput Intel Neurosci*, 1: 1–8
- Wang L, Sng D. 2015. Deep Learning algorithms with applications to video analytics for a smart city: A survey. arXiv: 1512.03131
- Wang W, Yu R, Huang Q, Neumann U. 2018. SGPN: Similarity group proposal network for 3D point cloud instance segmentation. *Proc IEEE Conf Computer Vision Pattern Recognition*, 1: 2569–2578
- Wang X, Liu S, Shen X, Shen C, Jia J. 2019. Associatively segmenting instances and semantics in point clouds. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 4096–4105
- Wang Y, Sun Y, Liu Z, Sarma S E, Bronstein M M, Solomon J M. 2018. Dynamic graph CNN for learning on point clouds. *ACM Trans*

- Graph (TOG), 38: 1–12
- Wang Y, Yu Y, Liu M. 2019. PointIT: A fast tracking framework based on 3D instance segmentation. *arXiv*: 1902.06379
- Webb S. 2018. Deep learning for biology. *Nature*, 554: 555–557
- Weinstein B G, Marconi S, Bohlman S, Zare A, White E. 2019. Individual tree-crown detection in RGB imagery using semi-supervised Deep Learning neural networks. *Remote Sens*, 11: 1309–1321
- Wieland M, Li Y, Martinis S. 2019. Multi-sensor cloud and cloud shadow segmentation with a convolutional neural network. *Remote Sens Environ*, 230: 111203–111214
- Wild B, Sixt L, Landgraf T. 2018. Automatic localization and decoding of honeybee markers using deep convolutional neural networks. *arXiv*: 1802.04557
- Wolf M. 2003. Method for unrolling two-deep loops with convex bounds and imperfectly nested code, and for unrolling arbitrarily deep nests with constant bounds and imperfectly nested code: U.S. Patent 6567976. 2003-5-20
- Wu M, Hughes M C, Parbhoo S, Zazzi M, Roth V, Doshi-Velez F. 2017. Beyond sparsity: Tree regularization of deep models for interpretability. In: Thirty-Second AAAI Conference on Artificial Intelligence. 2018
- Wurm M, Stark T, Zhu X X, Weigand M, Taubenböck H. 2019. Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks. *ISPRS J Photogram Remote Sens*, 150: 59–69
- Xiong X, Duan L, Liu L, Tu H, Yang P, Wu D, Chen G, Xiong L, Yang W, Liu Q. 2017. Panicle-SEG: A robust image segmentation method for rice panicles in the field based on Deep Learning and superpixel optimization. *Plant Methods*, 13: 104–118
- Yalcin H, Razavi S, IEEE. 2016. Plant classification using convolutional neural networks. 2016 Fifth International Conference on Agro-Geoinformatics. 233–237
- Yan X, Ai T, Yang M, Yin H. 2019. A graph convolutional neural network for classification of building patterns using spatial vector data. *ISPRS J Photogram*, 150: 259–273
- Yang S, Feng Q, Liang T, Liu B, Zhang W, Xie H. 2018. Modeling grassland above-ground biomass based on artificial neural network and remote sensing in the Three-River Headwaters Region. *Remote Sens Environ*, 204: 448–455
- Yao X, Guo J, Hu J, Cao Q. 2019. Using Deep learning in semantic classification for point cloud data. *IEEE Access*, 7: 37121–37130
- Yi L, Zhao W, Wang H, Sung M, Guibas L. 2018. Gspn: Generative shape proposal network for 3D instance segmentation in point cloud. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 3947–3956
- Younis S, Weiland C, Hoehndorf R, Dressler S, Hickler T, Seeger B, Schmidt M. 2018. Taxon and trait recognition from digitized herbarium specimens using deep convolutional neural networks. *Bot Lett*, 165: 377–383
- Zhang C, Sargent I, Pan X, Li H, Gardiner A, Hare J, Atkinson P M. 2018. An object-based convolutional neural network (OCNN) for urban land use classification. *Remote Sens Environ*, 216: 57–70
- Zhang R, Li G, Li M, Wang L. 2018. Fusion of images and point clouds for the semantic segmentation of large-scale 3D scenes based on Deep Learning. *ISPRS J Photogram Remote Sens*, 143: 85–96
- Zhang S, Huai Y. 2016. Leaf image recognition based on layered convolutions neural network Deep Learning. *J Beijing Forest Univ*, 38: 108–115
- Zhang X, Luo H, Fan X, Xiang W, Sun Y, Xiao Q, Jiang W, Zhang C, Sun J. 2017. AlignedReID: Surpassing human-level performance in person re-identification. *arXiv*: 1711.08184
- Zhang Z, Cui P, Zhu W. 2018. Deep Learning on graphs: A survey. *arXiv*: 1812.04202
- Zhao L, Wang J, Li X, Tu Z, Zeng W. 2016. On the connection of deep fusion to ensembling. *arXiv*: 1611.07718
- Zhong Z, Li J, Luo Z, Chapman M. 2017. Spectral-Spatial residual network for hyperspectral image classification: A 3-D deep learning framework. *IEEE Trans Geosci Remote Sens*, 56: 847–858
- Zhou J, Cui G, Zhang Z, Yang C, Sun M. 2018. Graph neural networks: A Review of methods and applications. *arXiv*: 1812.08434
- Zou Q, Ni L, Zhang T, Wang Q. 2015. Deep Learning based feature selection for remote sensing scene classification. *IEEE Geosci Remote Sens Lett*, 12: 2321–2325

(责任编辑: 岳天祥)