

机器学习在遥感影像分类中的应用

高昂,唐世浩*,肖萌,郑伟

国家卫星气象中心,北京 100081

摘要 概述了机器学习的主要方法及其在遥感影像的主要应用方向,涵盖环境生态遥感中机器学习技术的研究、应用情况及近年来的新进展。通过使用深度学习对FY-3C气象卫星资料进行积雪检测的应用实例,说明深度学习模型可以利用大数据的优势不断提高检测精度,在某些指标中取得了更优于传统机器学习的精度,可解决传统机器学习难以解决的一些问题,从而带动遥感应用模式的创新。

关键词 机器学习;遥感影像分类;深度学习

机器学习是人工智能(artificial intelligence, AI)研究发展到一定阶段的必然产物,蓬勃发展于20世纪90年代,是AI中最受欢迎和最成功的子领域^[1]。它建立在概率统计的基础上,是计算机学科和统计学的交叉学科。初期,机器学习的研究几乎完全局限于人工智能领域。近年来,机器学习成为一种支持技术,逐渐进入了计算机学科的不同领域,甚至其他学科领域,解决不同领域甚至不同学科对机器学习的需求。目前,分类问题求解是大多数的应用研究领域。机器学习有利于计算机从海量的数据信息中提取有用知识,更好地指导各种应用中的信息处理和决策^[2]。

随着遥感仪器性能的不断发展和我们所能获取的遥感图像不仅数量激增,而且光谱特征维数进一步增加。然而,人工标定遥感图像费时费力,因此有必要利用机器学习对图像进行自动处理方法。遥感图像分类是遥感图像信息处理中最基本的问题之一。其分类技术是遥感应用系统中的关键技术。遥感图像分类方法的精度直接影响到遥感的应用发展。为提高遥感图像自动分类的速度和精度,研究人员不断探索新的方法。遥感影像数据的分类实质上是一类特殊的空间数据的数据处理和模式识别问题,通常情况下,与数据处理、模式识别相应的思想和方法都可以应用于遥感影像数据的

收稿日期:2020-10-25;修回日期:2021-04-20

基金项目:国家重点研发计划重点专项(2018YFC1506500)

作者简介:高昂,博士,研究方向为机器学习,电子信箱:gaoang@cma.gov.cn;唐世浩(通信作者),研究员,研究方向为卫星遥感生态环境与灾害监测评估应用,电子信箱:tangshihao937966@cma.cn

引用格式:高昂,唐世浩,肖萌,等.机器学习在遥感影像分类中的应用[J].科技导报,2021,39(15):67-74;doi:10.3981/j.issn.1000-7857.2021.15.007

分类。许多机器学习技术被广泛地应用于遥感影像的分类中^[3-4]。

1 机器学习算法的类型

机器学习技术包含的众多算法与模型可根据不同标准进行归类,一种广泛使用的分类方法是根据训练过程中得到的监督数量和类型,将其分为监督学习、非监督学习、半监督学习和强化学习^[5]。

监督和非监督的区别在于:使用监督算法,需要训练数据集包含输入样本及其对应的输出值(也被称为样本标签),输出值在训练模型时可用于监督调整模型精度,使模型逐步学习到输入输出之间的关系;而在使用无监督算法,只使用一个包含巨大数据量的样本数据集,依靠聚类算法基于数据间的关系将数据分为不同类别。半监督学习介于监督和非监督学习之间,使用大量缺乏输出的样本和少量已标记的样本,可有效减少获得标记样本的成本并获得精度较为可靠的模型。强化学习略有不同,在强化学习中,设置了一个决策反馈环境,算法在该环境中做出决策并立即得到环境反馈结果,算法根据反馈评估自己的决策效果并不断改进决策能力。

1.1 随机森林

随机森林(random forest, RF)算法作为一种基于分类和回归决策树的机器学习算法^[6],在遥感图像分类领域得到了国内外学者的广泛关注^[7-9]。特征变量的选择对 RF 算法的分类精度有重要影响。文献[10]将光谱、形状和纹理特征作为 RF 算法的特征变量,有效地提高了整体分类精度。文献[11]将 GETIS 统计量作为特征变量加入到 RF 分类模型中,提高了 RF 算法的分类性能。文献[12]提出结合矩距指数、光谱特征和地形特征对帕米尔高原植被覆盖进行分类。目前,对于不同类型的遥感图像,RF 算法中特征变量的选取还没有通用的方法,因此在 RF 分类算法中特征变量的选择上还有很大的改进空间。

1.2 支持向量机

支持向量机是建立在统计学习的 VC 维理论和

结构风险最小化基础上的机器学习方法^[13]。它根据有限的样本信息,在使样本误差最小的同时,使模型泛化误差的上界最小。支持向量机由于在文本分类任务中显示出卓越性能^[14],很快成为机器学习的主流技术,并在 2000 年前后直接掀起了统计学习(statistical learning)^[15-16]的高潮。但从总体上看,支持向量机在高光谱遥感图像分类中的应用研究尚处于起步阶段,仅有个别成功的案例^[17-18]。

1.3 神经网络

神经网络(artificial neural network, ANN)^[19]是一种模仿大脑神经网络处理信息方式的机器学习算法。神经网络包含输入层(input layer),隐藏层(hidden layer),输出层(output layer),每层由一个或多个“神经节点”组成,每个节点代表一种数据处理方法,层与层的节点的通过权重连接,数据输入后通过层层传递完成复杂的非线性计算过程。神经网络以最少的输入集“学习”不同的图像模式。它们也被称为黑盒算法,因为通常很难弄清楚神经网络是如何计算输出的。神经网络在遥感上的第一个应用于 1988 年完成^[20]。它提供了一种准确的方法来对土地覆盖和地球物理特征进行分类,而不必依赖于统计假设或程序。近年来,神经网络在技术上取得较大突破,人们设计出了隐藏层更多、神经节点间关系更为复杂的神经网络,这类神经网络的算法精度已经可以达到甚至超过人眼识别精度^[21-25],被广泛应用于包括遥感图像识别在内的各类机器视觉领域^[26-27]。而以此类神经网络结构为核心的机器学习方法,也被称为深度学习。

1.4 深度学习网络

深度学习网络^[28]就是深层的人工神经网络,理论上说参数越多的模型复杂度越高、增加隐层数目能完成更复杂的学习任务。但一般情形下,复杂模型的训练效率低,易陷入过度拟合。而随着云计算、大数据时代的到来,计算能力的大幅提高可缓解训练的低效性,训练数据的大幅增加则可降低过拟合的风险,因此,以深度学习为代表的复杂模型开始受到关注。

经典深度学习以卷积神经网络(convolutional neural networks, CNN)^[23,29]为代表的模型在图像分类中取得了巨大的成就。但是CNN的分类算法在进行卷积和池化过程中丢失了图像信息(比如分辨率和位置),所以无法提取出物体的具体轮廓,也无法指出每个像素具体属于哪个类别。而大气环境遥感监测要求精确识别出气象要素的轮廓,并给出像元级的分类,这就使得CNN分类算法无法直接应用于遥感影像的信息提取。

语义分割网络是深度学习的一个分支,与经典深度学习网络对整幅图像进行分类标记不同,语义分割模型是将输入图像中的每个像素分配一个语义类别,以得到像素化的密集分类。随着深度学习技术在计算机视觉领域的开疆拓土,图像分类、物体识别和语义分割任务等都获得了重大突破^[30-31]。尤其是针对图像分割问题,UNet网络^[32]取得了不错的效果,一个改进的UNet网络由编码结构和解码结构组成(图1),包含6种运算单元。




图1 改进的UNet网络结构

1) 卷积。输入向量在卷积层和滤波层之间进行卷积运算。假设 $x_{i,j,k}^n$ 表示特征矩阵 $x_{i,j,k}$ 中的第 n 个节点,其对应的过滤器权重为 $w_{i,j,k}$, b^n 表示第 n 个输出值对应的偏置项参数,那么 $x_{i,j,k}^n$ 的卷积值 $g(n)$ 为

$$g(n) = \sum_{i=1}^H \sum_{j=1}^W \sum_{k=1}^C w_{i,j,k} x_{i,j,k}^n + b^n$$

式中, H 、 W 、 C 分别表示卷积核的长、宽、数量。

2) 激活函数。卷积层和滤波层一般通过激活函数连接^[34],而修正线性单元(rectified linear unit, ReLU)激活在深度卷积神经网络中被广泛采用。有文献[35]提出了扩展型指数线性单元激活函数(scaled exponential linear unit, SELU),可以进行自归一化,有效克服梯度消失等问题。其公式为

$$f(x) = \lambda \begin{cases} \alpha(ex - 1), & x < 0 \\ x, & x \geq 0 \end{cases}$$

3) 池化。池化操作可以汇合低层特征信息,缩减计算数据量,扩大高层滤波器的感受野。给定大小为 $H \times W \times C$ 的特征矩阵 x ,采用大小为 $F \times F$ 的池化核(不填充池化,unpadded pooling),且池化步长 S ,则最大池化操作的输出为

$$F_{i,j} = \max(G_{i,j})$$

式中, $G_{i,j}$ 表示 x 中大小为 $F \times F$ 的池化区域; $i=1, 2, \dots, \left\lfloor \frac{H-F+1}{S} \right\rfloor$; $j=1, 2, \dots, \left\lfloor \frac{W-F+1}{S} \right\rfloor$ 。

4) 特征融合。将低层特征向量与相应高层特征向量拼接为新的张量,就能够融合高层的语义信息和低层的局部特征信息,从而实现准确而又精细的语义特征提取。在本文提出的网络中,将每次上采样输出的特征图,与下采样部分输出的相同尺度的特征图进行通道串联。

5) 转置卷积。转置卷积相当于正常卷积的反向传播,具体步骤如下:

(1) 给定步长 s ,沿着步长的方向,在输入特征图中每个元素后面补 $s-1$ 个0,得到扩充后的特征图 x 。

(2) 按照卷积padding规则^[35],计算填充0的位置 L 及个数,将 L 上下和左右各自颠倒一下,再对 x 整体补0,得到 x' 。

(3) 将卷积核反转,即上下左右方向进行逆序操作。

(4) 以 x' 作为输入,进行步长为 S 的卷积操作。

6) Softmax。将多个神经元的输出值映射到0与1之间,可作为多分类预测的概率描述。给定输出层第*i*个神经元的输出值 Z_i ,则 Z_i 的概率值 S_i 为

$$S_i = \frac{\exp(Z_i)}{\sum_{j=1}^N \exp(Z_j)}$$

式中, N 为输出层的神经元个数,亦即分类数。

2 机器学习在遥感影像分类中的应用

2.1 云检测

云是影响气候变化的重要因素,它直接影响着地球系统的辐射收支。要实现气象气候产品的高精度遥感反演,首先必须进行云检测,以确定每个像元是“有云”还是“晴空”。云的地基检测长期依赖气象观测员目视判断,因而云的卫星遥感观测也备受关注。现有遥感影像云检测方法主要基于特征提取的模式识别检测方法,并综合利用各种方法优化云检测的效果^[36]。云像素的自动提取技术大多采用多特征(单通道或通道组合)阈值的思想^[37-38],用固定阈值判断像元是否被云污染。但是考虑到大气运动的复杂性,针对不同纬度地区以及不同天气条件下的云影像,使用固定阈值的检测效果并不好。为了解决这个问题,Alan等^[39]利用遥感图像直方图变化情况动态获取云地分离的阈值,在此基础上,许多算法针对不同卫星改进了动态阈值的提取方法^[40-42]。我国风云二号气象卫星(FY-2)的云检测产品^[43-45]基于动态阈值算法,采用滑动窗口和嵌套窗口的方法,一定程度上提高了云检测的精度,但是这类云检测算法需要大量的人工解释和阈值参数调整,算法的精度通常受限于仪器的通道和空间分辨率。

FY-2的云检测产品是许多定量产品反演所需要的重要输入数据,其质量对定量产品的反演精度有重要的影响。云在时间和空间上都具有极大不

确定性,导致卫星云图的特征不断变化^[46],对云检测造成了较大的干扰。一些研究^[47-48]表明,与高分卫星的云覆盖率以及地面人工观测的结果相比,FY-2云检测的误差较大,而且在太阳耀斑处云边界轮廓不连续,存在将云误判识为冰雪、雾霾以及沙尘的问题。FY-2云检测的误差极大地限制了云的自动化观测水平,不可避免地影响后续业务化产品的精度^[49]。因此,提高云检测的精度对卫星遥感信息定量提取以及产品真值检验具有重要意义。

与传统机器学习需要依赖人工提取特征不同,深度学习可自动提取影像特征,并具有可迁移的特点,为FY-2历史资料再处理提供了新的思路。近年来深度学习技术已开始用于分辨率较高、光谱通道较多的卫星遥感数据的云检测。文献[50]提出了基于全卷积神经网络的深度学习方法,文献[51]结合超像素和卷积神经网络对高分辨率遥感影像进行云检测,文献[52]利用卷积神经网络提取影像特征,然后将影像特征输入支持向量机分类器进行分类,获得云检测结果。研究中发现了冰雪误识别、太阳耀斑处云边界轮廓不连续、雾霾以及沙尘误识别但却不明原因等问题。

2.2 积雪检测

20世纪90年代,以数学家Vapnik为代表的学派经过多年研究,发展了一套统计学习理论和以它为基础的支持向量机算法^[53]。这套新算法既能处理非线性数据,又能有效地限制过拟合,被认为是目前针对小样本分类和回归等问题的最佳算法,在文字识别、语音识别等方面应用已卓有成效^[21],并开始应用于卫星遥感领域。有学者^[54]利用深度神经网络进行积雪检测,与阈值法相比,效果较好,且具有时间和空间上的灵活性。本文分别使用VGG网络^[24]作为编码器的语义分割网络,以及UNet++^[55]分割网络,基于FY-3C数据进行积雪检测,用平均准确率、平均精度、召回率以及平均交并比等评价指标进行了不同样本数的评价(图2、图3)。

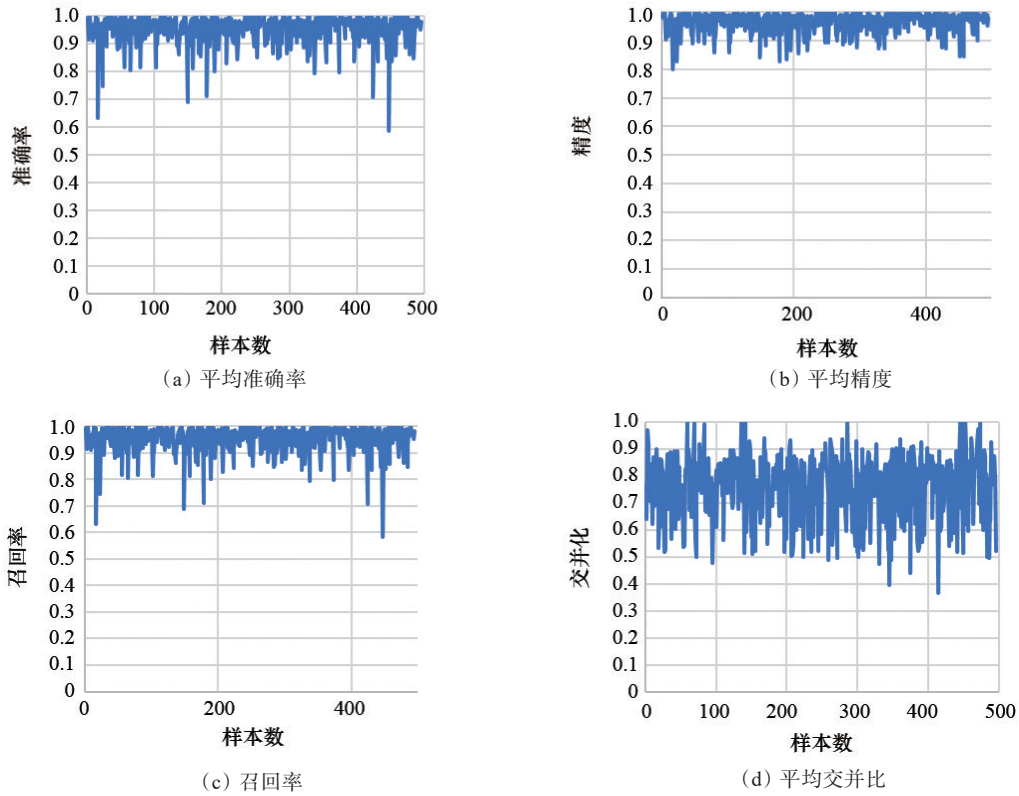


图 2 基于VGG网络的积雪检测评估

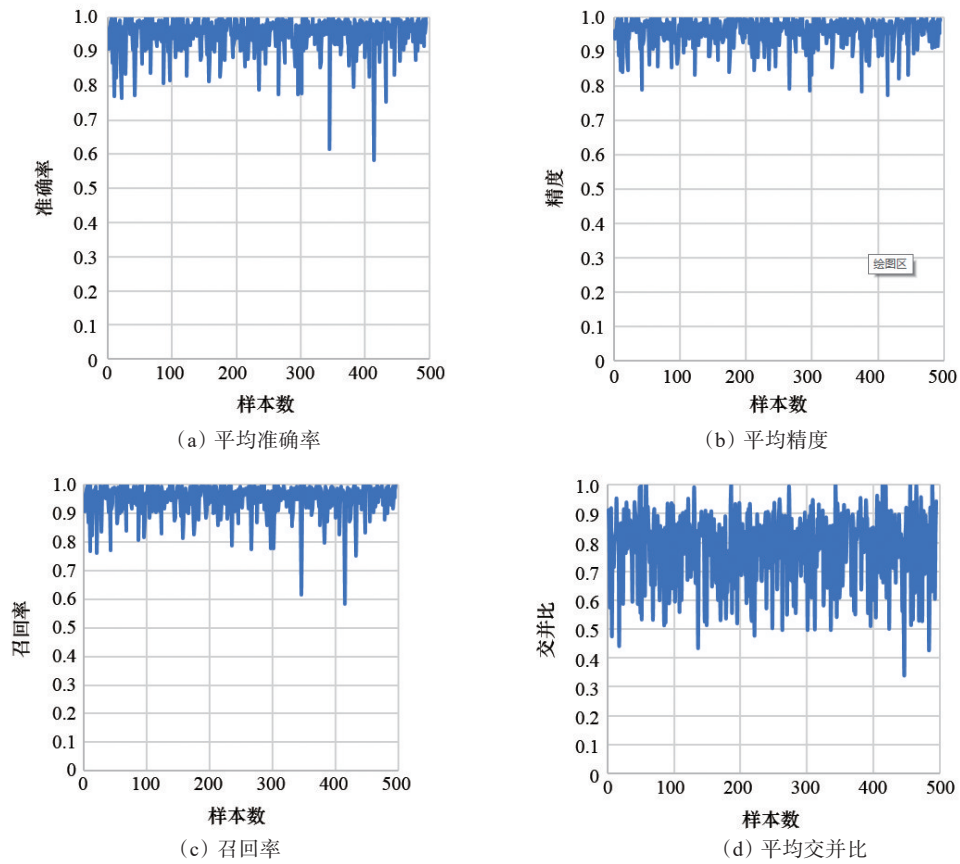


图 3 基于UNet++网络的积雪检测评估

3 结论

系统概述了机器学习的主要方法及其在遥感影像的主要应用方向,有针对性地涵盖了环境生态遥感中机器学习技术的研究及应用情况,并介绍了近年来最新的研究进展。

以卫星遥感应用中的积雪检测为例,使用主流深度学习模型对FY-3C卫星资料进行检测,结果可以看出,深度学习模型可以利用大数据的优势不断提高检测精度,甚至在某些指标中取得了更优于传统机器学习的精度,且可解决传统机器学习难以解决的一些问题,如遥感应用中的全自动化积雪检测问题等。因此,在未来的生态遥感应用中需要熟悉机器学习在所涉及各类问题上的适用情况,并及时掌握科技前沿技术,可以最大程度地受益于每一次信息技术的革命性突破,以机器学习特别是深度学习技术带动遥感应用模式的创新,更好地迎接现代卫星气象发展的新挑战与新机遇。

参考文献(References)

- [1] 周志华. 机器学习[M]. 清华大学出版社, 2016.
- [2] Mjolsness E, DeCoste D. Machine learning for science: State of the art and future prospects[J]. *Science*, 2001, 293(5537): 2051-2055.
- [3] 刘颖. 基于半监督集成支持向量机的土地覆盖遥感分类方法研究[D]. 中国科学院研究生院(东北地理与农业生态研究所), 2013.
- [4] 杨晨. 基于机器学习的土地覆盖遥感信息提取方法研究[D]. 吉林大学, 2010.
- [5] Géron A. Hands-on machine learning with scikit-learn, keras, and tensorflow: Concepts, tools, and techniques to build intelligent systems[M]. O'Reilly Media, 2019.
- [6] Breiman L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5-32.
- [7] 刘毅, 杜培军, 郑辉, et al. 基于随机森林的国产小卫星遥感影像分类研究[J]. *测绘科学*, 2012, 37(4): 194-196.
- [8] Lowe B, Kulkarni A. Multispectral image analysis using random forest[J]. 2015.
- [9] Rodriguez-Galiano VF, Ghimire B, Rogan J, et al. An assessment of the effectiveness of a random forest classifier for land-cover classification[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2012, 67: 93-104.
- [10] 刘海娟. 基于RF模型的高分辨率遥感影像分类评价[J]. *南京林业大学学报:自然科学版*, 2015, (39): 99-103.
- [11] Ghimire B, Rogan J, Miller J. Contextual land-cover classification: Incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic[J]. *Remote Sensing Letters*, 2010, 1(1): 45-54.
- [12] Salas EAL, Boykin KG, Valdez R. Multispectral and texture feature application in image-object analysis of summer vegetation in Eastern Tajikistan Pamirs[J]. *Remote Sensing*, 2016, 8(1): 78.
- [13] Cortes C, Vapnik V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273-297.
- [14] Joachims T. Text categorization with support vector machines: Learning with many relevant features[C]. Dortmund Germany: Springer, 1998: 137-142.
- [15] Vapnik V. The nature of statistical learning theory[M]. Springer Science & Business Media, 2013.
- [16] Vapnik VN. An overview of statistical learning theory[J]. *IEEE transactions on neural networks*, 1999, 10(5): 988-999.
- [17] 卢伟, 文鸿雁, 李淑. 基于SVM的遥感影像空间特征提取和分类研究[J]. *山西建筑*, 2009, 35(5): 10-12.
- [18] 张耀波, 张迁. 基于SVM的遥感影像的分类[J]. *地理空间信息*, 2005, (4): 24-26.
- [19] Kohonen T. Adaptive, associative, and self-organizing functions in neural computing[J]. *Applied optics*, 1987, 26(23): 4910-4918.
- [20] Kanellopoulos I, Wilkinson GG. Strategies and best practice for neural network image classification[J]. *International Journal of Remote Sensing*, 1997, 18(4): 711-725.
- [21] 陈岩, 李洋洋, 余乐, 等. 基于卷积神经网络的手写体数字识别系统[J]. *微电子学与计算机*, 2018, 35(2): 71-74.
- [22] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2012, 25: 1097-1105.
- [23] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [24] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. 2014, arXiv: 14091556.

- [25] Yang F, Jin L, Yang W, et al. Handwritten/printed receipt classification using attention-based convolutional neural network[C]. IEEE, 2016: 384-389.
- [26] 郑益勤, 杨晓峰, 李紫薇. 深度学习的静止卫星图像海上强对流云团识别[J]. 遥感学报, 2020, 24(1): 97-106.
- [27] Chen Y, Lin Z, Zhao X, et al. Deep learning-based classification of hyperspectral data[J]. IEEE Journal of Selected topics in applied earth observations and remote sensing, 2014, 7(6): 2094-2107.
- [28] Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [29] LeCun Y, Bengio Y. Convolutional networks for images, speech, and time series[J]. The Handbook of Brain Theory and Neural Networks, 1995, 3361(10): 1995.
- [30] Badrinarayanan V, Kendall A, Cipolla R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.
- [31] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]. 2015: 3431-3440.
- [32] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, 2015: 234-241.
- [33] Lee C-Y, Gallagher P, Tu Z. Generalizing pooling functions in CNNs: Mixed, gated, and tree[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 863-875.
- [34] Klambauer G, Unterthiner T, Mayr A, et al. Self-normalizing neural networks[C]. 31st Conference on Neural Information Processing Systems (NIPS 2017): Long Beach, CA, USA, 2017: 972-981.
- [35] 李金洪. 深度学习之TensorFlow: 入门、原理与进阶实战[M]. 北京: 机械工业出版社, 2018.
- [36] 李爱勤, 王环东, 王静怡, 等. 高分辨率遥感影像中云和似云目标的自动区分[J]. 测绘通报, 2017, (6): 31-35.
- [37] Rossow WB, Garder LC. Cloud detection using satellite measurements of infrared and visible radiances for ISCP[J]. Journal of Climate, 1993, 6(12): 2341-2369.
- [38] Taylor VR, Stowe LL. Reflectance characteristics of uniform earth and cloud surfaces derived from NIMBUS-7 ERB[J]. Journal of Geophysical Research: Atmospheres, 1984, 89(D4): 4987-4996.
- [39] Di Vittorio A V, Emery W J. An automated, dynamic threshold cloud-masking algorithm for daytime AVHRR images over land[J]. IEEE Transactions on Geoscience and Remote Sensing, 2002, 40(8): 1682-1694.
- [40] 武艳, 银燕, 师春香, 等. 基于动态阈值法的NOAA系列卫星云检测结果检验[J]. 高原气象, 2012, 31(3): 745-751.
- [41] Dybbroe A, Karlsson K-G, Thoss A. NWCSAF AVHRR cloud detection and analysis using dynamic thresholds and radiative transfer modeling. part I: Algorithm description[J]. Journal of Applied Meteorology and Climatology, 2005, 44(1): 39-54.
- [42] Poli G, Adembri G, Gherardelli M, et al. Dynamic threshold cloud detection algorithm improvement for AVHRR and SEVIRI images[C]// 2010 IEEE International Geoscience and Remote Sensing Symposium. Honolulu, HI, USA, IEEE, 2010: 4146-4149.
- [43] 刘健. 中国区域云特性分析及在FY-2云检测中的应用[J]. 应用气象学报, 2009, 20(6): 673-681.
- [44] 刘健. FY-2云检测中动态阈值提取技术改进方法研究[J]. 红外与毫米波学报, 2010, 29(4): 288-292.
- [45] 刘希, 许健民, 杜秉玉. 用双通道动态阈值对GMS-5图像进行自动云检测[J]. 应用气象学报, 2005, (4): 434-444.
- [46] 杨铁利, 何全军. MODIS数据的云检测处理[J]. 鞍山科技大学学报, 2006, (2): 162-166.
- [47] 李娅, 郭建侠, 曹云昌, 等. FY-2G云量产品与地面观测云量对比分析[J]. 高原气象, 2018, 37(2): 514-523.
- [48] 裔传祥, 辛晓洲, 胡继超, 等. 基于GF-4数据分析低分辨率卫星云检测尺度误差对下行辐射计算的影响[J]. 地球科学进展, 2018, 33(4): 425-434.
- [49] 刘炼焯, 兰明才, 朱歆炜, 等. FY-2G卫星两种云订正产品在湖南的对比分析[J]. 暴雨灾害, 2017, 36(2): 164-170.
- [50] 瞿建华, 鄢俊洁, 薛娟, 等. 基于深度学习的FY3D/MERSI和EOS/MODIS云检测模型研究[J]. 气象与环境学报, 2019, 35(3): 87-93.
- [51] 徐启恒, 黄滢冰, 陈洋. 结合超像素和卷积神经网络的国产高分辨率遥感影像云检测方法[J]. 测绘通报, 2019, (1): 50-55.
- [52] 陈洋, 范荣双, 王竞雪, 等. 基于深度学习的资源三号卫星遥感影像云检测方法[J]. 光学学报, 2018, 38(1): 362-367.
- [53] Burges C J. A tutorial on support vector machines for pattern recognition[J]. Data Mining and Knowledge Discovery, 1998, 2(2): 121-167.
- [54] 康晓光, 孙龙祥. 基于人工神经网络的云自动检测算法[J]. 解放军理工大学自然科学版, 2005, (5): 102-106.

- [55] Zhou Z, Siddiquee MMR, Tajbakhsh N, et al. Unet++: A nested u-net architecture for medical image segmentation[M]//Deep learning in medical image analysis and multimodal learning for clinical decision support. Springer, 2018: 3-11.

Application of machine learning in remote sensing image classification

GAO Ang, TANG Shihao*, XIAO Meng, ZHENG Wei

National Satellite Meteorological Center, Beijing 100081, China

Abstract This paper summarizes the main methods of machine learning and its main application direction in remote sensing image. It covers the research and application of machine learning technology in environmental ecological remote sensing, and the new progress in recent years. Through the application of deep learning to snow detection of FY-3C meteorological satellite data, it is shown that the deep learning model can improve the detection accuracy by means of big data advantages, and has achieved better precision than traditional machine learning in some indexes, thus solving some problems that are difficult to solve using traditional machine learning method, and driving the innovation of remote sensing application mode.

Keywords machine learning; remote sensing image classification; deep learning ●



(责任编辑 祝叶华)