

卷积神经网络在SAR遥感海冰分类中的应用可行性分析

崔艳荣¹, 邹斌^{1,2,3}, 韩震¹, 石立坚^{2,3}, 刘森²

(1.上海海洋大学海洋科学学院,上海 201306;2.国家卫星海洋应用中心,北京 100081;3.国家海洋局空间海洋遥感与应用研究重点实验室,北京 100081)

摘要: 分别介绍了卫星遥感海冰监测、分类的传统方法,以及卷积神经网络在遥感影像分类识别中的应用成果。尝试将在图像识别、语言检测等方面取得成功的卷积神经网络算法应用在海冰图像分类中,利用其能够应对非线性、网络结构简单、可并行运算等能力去解决海冰数据分类问题。

关键词: 卫星遥感;海冰分类;应用;卷积神经网络;深度学习

中图分类号: P731.15 **文献标识码:** A **文章编号:** 1003-0239(2019)05-0077-09

1 引言

海冰是指海洋中所有冰的总称,包括来自大陆的淡水冰(冰川和河冰)和由海水直接冻结而成的咸水冰,一般多指后者。海冰占全球海洋面积的5%~8%,是极地海域和某些高纬度区域最突出的海洋灾害。我国北部海域纬度偏高,每年都会有结冰现象出现;另外也会有黄河口附近的河冰流入海洋。在中国历史上,曾多次出现造成了航运中断、钻井平台塌陷,船舶受损等严重海冰灾害的严重冰情。可见,海冰监测工作是非常必要的。

海冰监测,主要任务为利用海冰图像构造表明不同类型海冰的地理分布位图,包括反演海冰类型、测算海冰面积、描述海冰最大边缘线、计算海冰密集度等一系列工作。而海冰图像分类是海冰监测的前提,即将所有的图像像素按照特征分别标记为不同海冰类型。把得到的海冰类型分类结果与实际地理数据相结合,计算出不同类型海冰的像素数量,可得出海冰面积;然后连接向海一侧最外缘的像素点,可得到海冰外缘线信息;将单位网格内海冰所占的面积除以该网格内海域总面积,即为海冰的密集度信息。因此,海冰的密集度、海冰面积、

海冰最大边缘线等信息都是由海冰分类识别衍生而来的^[1]。

传统的监测手段有海监船、海监飞机、沿岸海洋观测站、人工实地调查等。20世纪90年代以来,遥感技术迅猛发展,使得愈来愈多的遥感数据影像被应用于海冰监测与预防,合成孔径雷达(Synthetic Aperture Radar, SAR)因其独特的成像方式和异于其他图像的独特优势受到国内外遥感研究者的广泛关注和应用。SAR根据载体可大体分为机载SAR和星载SAR,以侧视方式成像,同时包含距离向和方位向信息。侧视SAR成像原理示意图如图1^[2]。

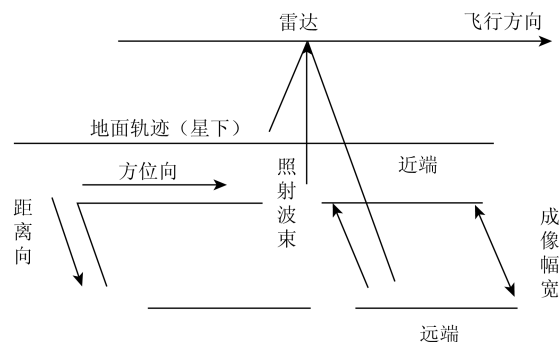


图1 侧视SAR成像原理示意图

收稿日期: 2018-11-29; 修回日期: 2019-01-17。

基金项目: 国家重点研发计划(2018YFC1407200; 2018YFC1407206)。

作者简介: 崔艳荣(1994-),女,硕士在读,主要从事深度学习在卫星遥感海冰解译中的应用研究。E-mail: 1278260805@qq.com

邹斌(1969-),男,研究员,硕士,主要从事卫星遥感海洋应用研究。E-mail: zoubin@mail.nsoas.org.cn

距离向分辨率取决于主动发射的脉冲宽度,宽度越窄,距离分辨率越高,通常情况下会尽可能缩短脉冲发射时间来提高距离向分辨率;方位向分辨率取决于雷达天线孔径的尺寸,并与孔径的尺寸成正比^[3],在实际操作中,天线尺寸太大不仅成本高,操作也不便,而是通过小天线合成虚拟的大孔径天线来达到提高方位分辨率的目的,合成孔径雷达也因此得名。

SAR独特的成像方式使得SAR图像类似于灰度图像,没有光学图像的色彩和逼真,但同时也具备以下特点:(1)全天时、全天候和强穿透能力。其发射的主动脉冲可以不受昼夜、天气的影响,能够穿透云雾和尘埃;(2)图像亮、暗差异明显。由于不同的地物对微波的散射特性差异悬殊,使得回波的强度也不同,体现在图像上的亮度也会有很大差别,如SAR图像上的建筑物因反射较强呈现很亮的颜色,而水体因吸收或镜面反射,导致回波较弱,在图像上几乎呈现黑色;(3)图像存在阴影。当微波无法找到地物背部时,会产生阴影,虽然阴影会对图像分类带来误差,但丰富的阴影信息对SAR图像处理也会带来帮助,如计算地物高度;(4)出现透视收缩。当对高山成像时,由于峰顶距离传感器较近,山腰和山底会被遮住,这种现象称为叠掩。另外,由于山体倾斜,SAR成像图像会比实际成像图像短,即透视收缩^[4]。

SAR独特的成像方式使得获取的图像也具有多种模式。其实传感器获取的原始SAR数据是二维数据,要经处理后变成单视复数据或多视复数据才能呈现为图像,极化图像由单视复数据或多视复数据衍生而来,根据脉冲发射和接收的方式又可分为单极化和多极化。脉冲的发射和接收分别由水平和垂直两种方式,如果传感器发射和接收微波的方式都是水平方式,则成为HH单极化;同理,都为垂直方向,则为VV单极化;若发射方式为水平,接收方式为垂直,则为HV双极化;反之,则为VH双极化。如果发射和接收的方式两两完全组合,即为全极化^[3]。所以,根据微波发射和接收方式的不同组合,SAR数据可分为单极化、双极化和全极化3种模式。

丰富的遥感海冰数据源提高了海冰监测的全面性和时效性的同时,也给图像分析和特征提取带来了巨大挑战。卷积神经网络(Convolutional Neural

Networks, CNN)是提取数字图像特征的一种方法,把图像作为直接输入,通过选择合理的卷积核,对图像进行相关的变换,不仅大大降低了图像的预处理工作量,还能够更好的根据图像特征进行图像分类,提高识别准确率。另外,卷积神经网络的理论和模型的引入,其应对目标非线性混合的优势^[5],对海冰图像分类中存在的冰水混合,不同冰型混合等难以区分的问题也具有重要意义和价值。

2 国内外SAR遥感海冰分类的研究进展

海冰分类一般按照世界气象组织(World Meteorological Organization, WMO)的分类标准(WMO, 1985)进行定义,按照其形成过程和发展阶段,分为初生冰、尼罗冰、饼冰、初期冰、一年冰和老年冰6大类。许多国家和机构的海冰监测技术已经非常高,如加拿大海冰管理中心(Canadian ice service, CIS)、美国国家海冰中心(National Ice Center, NIC),以及德国、丹麦、芬兰、瑞典、和挪威的各种政府和商业海冰研究中心。

国外学者对SAR海冰影像分类方法的研究已相对成熟。机器学习方法的提出在SAR影像分类中扮演重要的角色,SAR图像海冰分类主要包括监督分类(训练样本)和非监督分类(无训练样本),其中监督分类的代表算法为灰度共生矩阵(Gray-Level Co-occurrence Matrix, GLCM)和支持向量机(Support Vector Machine, SVM)的联合分类^[6],通过将多种纹理信息、灰度色调特征输入到分类器中,获得不同海冰类型的概率密度函数来解决不同类别海冰后向散射系数重叠的问题。非监督分类的代表算法是脉冲耦合神经网络(Pulse Coupled Neural Network, PCNN)算法,2014年Karvonen等^[7]利用单层神经网络输入,设置中间隐含层信息,用最大响应值作为海冰类别的判译标准。为了提高海冰分类精度,上下文特征包括海冰的纹理特征,浮冰形状等已经得到了相应的关注与研究。Clausi等^[8]结合色调和纹理特征实现RADARSAT-1海冰像素级分类。进一步的研究表明,K均值聚类方法可以提高海冰类别和开阔水域的区分性。但是这类方法只适合平滑冰,在形变或者粗糙表面不适用,

特别是霜花和降雪情况。Yu等^[9]利用CIS提供的SAR数据将主要的海冰类别作为研究对象,以迭代的形式通过区域生长的方法生成语义类别标记。为了实现语义特征判别,一种策略是加入了冰间水道的形状特征,另一个是为了识别多年浮冰的椭圆形测度。他们将分割和分类统一在贝叶斯框架实现最优化问题。为了描述多个超像素块之间的关系,IRGS方法利用最大后验概率描述领域之间的语义关系。Ochilov等^[10]提出的马尔科夫随机场(Markov Random Field, MRF)在海冰分割海冰分类中也得到了广泛的应用。MRF利用标签场来构建空间上下文信息,通过概率推理和优化过程获得海冰分类的分类结果。条件随机场(Conditional Random Field, CRF)既能够模拟观测场的空间语境信息,又能构造标签场的空间语境信息,直接定义后验概率服从Gibbs分布,并通过最大化后验概率的优化方法,获得较高精度的海冰分类结果。Wang等^[11]提出CNN-SFCRF算法,将CRF与CNN结合来计算海冰密集度,先用CNN来计算海冰密集度,然后用CRF构造上下文关系模型优化海冰密集度的计算结果。

国内使用SAR数据进行海冰监测得研究虽然较晚,但也取得了较好的成果。1995年1月国家海洋环境预报中心与加拿大遥感中心合作进行了中加海洋海冰监测项目,第一次对辽东湾海区ERS-1和JERS-1的SAR海冰数据进行实时接收,得到SAR海冰图像分类方法。刘建强等^[12]利用加拿大RADARSAT卫星获取ScanSAR WideA和WideB两种模式数据,监测并研究我国渤海海冰冰情,提供了重要的海冰解译方法与参考依据。朱婷婷等^[13]利用南极普里兹湾(Pydzy Bay)和阿德雷洼地(Adelie Depression)的RADARSAT-2双极化SAR数据,将统计分布特征、纹理特征、极化比和密集度等完备特征纳入CRF模型,研究过分割块的条件随机场CRF标签推理进程,在过分割块基础上利用上下文的语义推理过程,获得高精度的海冰分类结果。并且文中作者对比基于SVM的海冰分类,提出SVM-CRF算法,将多特征集合作为观测数据引入CRF框架,利用SVM分类标签作为类别先验优化分类结果,精度验证高于其他算法,并在不同训练样本、大场景和小场景海冰分类中分别对比验证了该算法相对于其他算法的优势。金亚秋等^[14]使用防卫气象

卫星(Defense Meteorological Satellite Program, DMSP)的被动微波成像辐射计(SSM/I)和RADARSAT主动微波SAR数据,对渤海区域进行了主动和被动的组合研究,指出可以用高分辨率RADARSAT SAR数据对渤海海冰物理特征进行分类和识别。纪永刚等^[15-16]利用ENVISAT ASAR双极化影像,结合同步TM数据,对辽东湾海域不同冰型的电磁特性响应进行分析,并提出PCNN算法用于海冰识别,海冰分类,以及冰型区分。张晰等^[17]基于单极化SAR影像,定量分析了GLCM参数对辽东湾海冰纹理特征的影响,确定了GLCM参数和纹理特征,用神经网络得到了最终的结果。于波等^[18]在研究辽东湾海冰检测分类研究中,采用SAR海冰的多极化影像进行解译研究,结合同步的ENVISAT ASAR、CBERS-02和BRADARSAT-2数据,定量比较分析了多极化影像上不同冰型的纹理特征量,根据凝聚层次聚类的思想,筛选出适应多极化海冰SAR影像自动分类的纹理特征量,设计出多极化遥感海冰图像分类方法。张盼等^[19]在研究ScanSAR海冰影像识别解译中,在支持向量机中引入空间语境信息,提出MRF-SVM分类系统,使得ScanSAR海冰图像的解译精度得到了有效提高。

目前国内外学者对SAR遥感海冰分类研究大多是基于图像纹理特征和空间上下文信息的,虽然也取得了相对较好的进展,但还存在一些问题尚待解决:(1)不同类别的海冰后向散射系数重叠,多数基于阈值分割的海冰分类方法精度不高,特别是对薄冰和季节性海冰的分类问题;(2)相同极化方式的影像虽然能够区分表面粗糙度差异的海冰类型,但对海浪条件也较为敏感,流冰区和碎冰区和的海水与碎冰难以区分;(3)交叉极化方式,能较好识别冰和水,但表面粗糙度差异的海冰却难以判别;(4)多极化方式下的SAR海冰遥感解译中,表面较粗糙的浮冰后向散射信号的强度较大,与周围海水的对比度较低,边界模糊,难以区分。

3 卷积神经网络在图像分类中的应用进展

3.1 卷积神经网络(CNN)的结构和算法原理

卷积神经网络是由多个模块组成的可训练结

构体。其中每一个模块由三个连续操作单元组成：卷积核,非线性转换层和池化层。一个CNN模型通常包含多个用于提取图像特征的学习模块和若干全连接层。在卷积过程中,首先输入一个样本矩阵 $X(S_x \times S_y \times S_z)$,经 K 个大小为 $C_x \times C_y \times S_z$ 的卷积核 C^k ,其中 $k=1, \dots, K$ 。每一个卷积核都会以步长 P 为间隔遍历矩阵,最后会得到 K 幅特征图,式(1)如下:

$$\begin{cases} h^k = (C^k \times x) + b & (k = 1, \dots, K) \\ M_x = \frac{S_x - C_x}{P} + 1 \\ M_y = \frac{S_y - C_y}{P} + 1 \end{cases} \quad (1)$$

式中: M_x 和 M_y 分别为卷积操作之后输出的特征图的维度。卷积核的尺寸和数量直接影响对图像特征的学习结果,卷积核的权值和偏置也会随着训练而改变。

CNN简易结构示意图如图2。图示包含了输入层、卷积层、采样层、全连接层和输出层,其实在卷积层和采样层(池化层)中间还有一个非线性函数操作层,通过激活函数对每一个特征单元进行非线性处理,实现了非线性目标可分类的目标。池化层的作用是对卷积层习得的特征求局部平均与二次提取,保留最佳特征,减小特征分辨率,避免网络过拟合问题。最后的全连接层结构与传统的全连接神经网络很相似,接收神经元要与输入层的每一个神经元连接,由此利用模型所提取到的所有特征去训练分类模型,其中第一层全连接层以卷积操作后的特征层(h^k)作为输入,将特征映射表示为一个向

量,并通过权矩阵 W 和偏置 b 变换到输出空间,式(2)如下:

$$h = f(W \times x) + b \quad (2)$$

式中: f 为激活函数; h 为网络学习后的输出结果。

3.2 CNN模型在结构上的改进

卷积神经网络在手写字符识别、语音检测和图像解译等领域表现突出。2012年卷积神经网络^[20]被第一次用于Image Net大规模视觉识别挑战赛(Image Net Large Scale Visual Recognition Challenge, ILSVRC)并一举得冠,之后卷积神经网络在各个领域颇受青睐,学者们针对不同的应用领域和研究目的,对卷积神经网络在结构上做出了相应改进和优化。其中ImageNet大赛中的模型为AlexNet,其网络参数示意图如图3所示^[20],该模型共有8层,5个卷积层和3个全连接层,每个卷积层包含激励函数以及局部响应归一化处理,最后加一个最大池化层进行降采样处理。设置第一层卷积核大小为 11×11 ,第二层为 5×5 ,后三层均为 3×3 ,卷积步长设置为4。

张帆等^[21]在利用卷积神经网络对农作物种植面积进行遥感估测中,针对其研究目的和数据对AlexNet模型进行了改进,提出改变5个卷积层的卷积核,分别为2个 3×3 大小和3个 2×2 大小,并提出在3个全连接层后加入dropout层,降低网络发生过拟合的几率。吕鸿蒙等^[22]针对阿尔茨海默病医学图像提出增强的Alex Net,通过增加网络的层数来




图2 CNN基本结构




图3 Alex Net 参数示意图




图4 Sigmoid/Tanh 函数和 Relu 函数

对特征进行更精确的提取,实现分类结果的精度提升。对于传统的二次代价函数,使用梯度下降法(Gradient descent)^[23]对权值参数进行调整时,随着在网络中逐层传播,残差值变得越来越小,引发梯度消失现象,致使底层网络难以进行有效训练;而用交叉熵代价函数去代替二次代价函数可以使权值和偏置值的调整与激活函数的梯度无关;通常情况下线性表达能力较差的神经网络会引入激活函数,以此注入非线性因素,使数据非线性可分;或者通过把数据进行稀疏表达,提高数据处理效率,传统神经网络中最常用的两个激活函数为 Sigmoid 系(见图 4a,摘自 AlexNet 的论文 Deep Sparse Rectifier Neural Networks), Logistic-Sigmoid 和 Tanh-Sigmoid。对比图 4 的激活函数,以收敛目标是 0 为例,对于 Tanh-Sigmoid 函数,越接近目标,梯度越大,收敛速度越快,容易出现学习速率过快而找不到最低点的现象;而 RELU 激活函数,其梯度不随着权值的调整而

发生变化,避免了“梯度消失”现象的出现。

袁文翠等^[24]提出用 RELU 激活函数(见图 4b)所示^[23]来代替 Sigmoid 系函数,解决了“梯度消失”问题,通过优化代价函数和激活函数来提高模型精准度,并利用 Tensor board 实现模型可视化。Jaderberg 等^[25]采用新的可学习模块—空间变换网络(Spatial Transformer Networks, STNs),使 CNN 受数据空间多样性的影响问题得到解决,该模块分为 3 个部分:本地化网络(localisation network)、网格生成器(grid generator)及采样器(sampler)。空间变换网络(STNs)可以直接放到输入层,也可以在卷积层或者其它层的后面插入,无需对原 CNN 模型的内部结构做出改变,它能够根据分类或者其它任务自适应地将数据进行空间变换和对齐(包括平移、缩放、旋转以及其它几何变换等),实现 CNN 模型具有平移不变性、缩小不变性,旋转不变性等,提高分类的准确度。

如上,目前多数对卷积神经网络的研究,都是在文献^[20]提出的网络上进行结构上的改进,如改变局部感受野的大小^[26]、优化目标函数和激活函数、增加网络的深度^[20]等。另外,鉴于卷积神经网络的参数需要大规模的标签数据去训练,当训练数据数目较少时,卷积神经网络的优势得不到体现。为此,提出了在大规模数据集 Image Net 上预训练 CNN 模型再进行参数微调的思路。文献^[27-29]研究表明,在 Image Net 上预训练的 CNN 模型泛化能力较强,用于 SUN-397 和 PASCAL VOC 等数据集的图像分类效果较好。文献^[30-31]使用预训练好的 CNN 模型,对遥感图像进行了有效分类。在图像检索领域,文献^[32-33]将 Image Net 上预训练的 CNN 模型用于 Oxford、Holidays 和 UK Bench 等数据集中,模型特殊的隐层结构提取出更深层的特征,在图像检索中显著提高了性能。

3.3 CNN 模型在训练方法上的改进

在 CNN 模型的训练阶段,传统意义上说,对神经网络进行有监督训练是行不通的,但是卷积神经网络却是一个特例。它可以通过 BP 算法通过正向传播信息和误差反向传播来进行有监督训练。并且在网络学习训练之前,首先要对网络中的权重和偏置进行初始化,一般采用不同的小随机数来设定初始化值。“小随机数”一方面避免了在网络训练中因权值过大而提前进入饱和状态;另一方面确保了网络的泛化能力。“不同”的初始化值,为了保证网络能够进行正常的训练和学习,因为相同的初始化值会使网络失去学习能力。然而在实际的应用中,由于标记样本的缺乏,使得有监督训练难以进行,这使得 CNN 在实际应用中受到了一定的阻碍。事实上,卷积神经网络既可以有监督训练也可以进行无监督训练。鉴于 CNN 模型在图像识别、模式识别中的优势和特性,为了解决样本缺失的问题,很多学者在训练方法上做出了尝试和努力。如 Dong 等^[34]先利用稀疏滤波对 CNN 进行无监督训练,再把训练好的模型用于交通工具的识别,其中稀疏算法避免了训练过程中的过拟合现象。来年, Dong 等^[35]又尝试半监督训练 CNN 模型,首先通过稀疏滤波对模型进行预训练,然后用少量样本对模型进行参数微调,最后把该模型用于 BIT-Vehicle 数

据库中验证可行性和精度,分类效果较好。

综上所述, CNN 模型已经被广泛应用于各领域的图像处理,包括卫星遥感图像,其泛化能力和迁移能力较强,基于不同研究目的的改进模型均达到实验要求,模型结构可塑性较强。但目前少有用海冰图像分类中,而针对遥感海冰图像分类中,冰水混合以及不同冰型混合等非线性混合问题,卷积神经网络的每一个神经元接受局部输入,可通过非线性的操作实现待分类目标的非线性可分。另外尤其在结冰初期,冰、水温度相近,且形态特征模糊,新冰区常被识别为含有少量冰的水。而 CNN 模型的隐层结构可以提取出更深层、更抽象的特征,检测出遥感图像中新冰和水之间细微的差别,从而更加准确的判别新冰与水。

3.4 CNN 模型在 SAR 遥感海冰图像分类中的应用进展及可行性分析

尽管图像的色、形、位特征是数据图像分类的重要指标^[36],而 SAR 图像与光学成像机制不同, SAR 图像中海冰类型的形、位特征较弱,目前只能依靠纹理特征和颜色特征来分类,增加了应用卷积神经网络对 SAR 海冰图像分类的困难性,但是很多基于 CNN 模型的 SAR 海冰图像分类仍旧取得了较好的效果。Wang 等^[11]在 2016 年首次将卷积神经网络应用于海冰密集度评测中,其精度与海冰分析员手绘图相比,绝对平均误差不超过 10%;Chen 等^[37]在使用改进深度卷积神经网络进行 SAR 海冰图像分类中,其平均准确率达 99%;2017 年, Wang 等^[38]进一步的研究发现, CNN 网络模型相对于多层感知机 (MLP40),具有识别地物特征之间细微差别的能力,能够更准确的识别出新冰;李金鑫等^[39]使用 CNN 网络模型进行 SAR 图像分类时,对比了图像切片尺寸的大小对分类结果的影响,指出切片和滑动步长要与图像整体尺寸和分辨率相适宜,同时验证了卷积神经网络应用在 SAR 图像上的分类高效性;黄冬梅等^[36]将 CNN 模型用于海冰密集度评估和海冰分类实验中,也指出海冰训练样本尺寸对分类结果影响显著,并在该实验中确定 16×16 像素为最佳分类尺寸,该实验模型的总体分类准确率达到 93% 以上, Kappa 系数 0.8 以上。可见,卷积神经网络模型用于 SAR 海冰图像分类具有较大潜力,且相比现

有的海冰解译图的制作流程和信量,基于卷积神经网络模型的SAR海冰图像分类可以提供更加详细的海冰地理分布信息,并且减小时间和资源成本。

综上所述,目前关于卷积神经网络在遥感图像上应用的研究已经有了很多研究成果,用于遥感海冰图像解译的研究也在进行,并取得可观进展,为深度学习框架下的CNN模型在海冰图像分类的应用研究提供了技术支持。

4 总结与展望

综上所述,现有的基于纹理特征和空间信息场的遥感海冰图像分类方法虽已取得可观的进展,但仍存在许多尚未解决的问题,如冰、水非线性混合问题。在过去几年里,深度学习在模式识别和图像识别等方面表现出色,其框架下的卷积神经网络得到最深入的研究。其通过隐层结构提取深层的特征,检测出地物细微差别的能力,和其能够应对非线性、网络结构简单、可并行运算等能力对解决遥感海冰图像冰水混合、不同冰型混合问题和提高海冰图像分类准确率具有重要价值。

卷积神经网络在图像分类中的优势大致分为5个方面:

(1)CNN能够直接将遥感图像的原始像素作为输入,不需要对图像先通过算法提取特征,减轻了图像数据预处理的大量、重复的繁琐工作,避免了复杂的特征工程;

(2)隐层结构可以提取出更深层、更抽象的特征,检测出海冰图像上不同冰型之间、冰水之间细微的差别;

(3)CNN应对非线性的优势可解决不同冰型混合、冰水混合的场景;

(4)CNN权值共享特性可以极大地简化数据量;

(5)池化层的存在筛选出最为有价值的信息,解决了数据特征冗余问题。

下一步要进行的具体研究工作计划:

(1)由于在小规模数据集中难以体现CNN模型的优势,为解决样本缺乏问题,先利用预训练好的模型(如AlexNet模型,它是在大规模数据集

ImageNet上训练出来的网络,泛化能力较强,能够较好的迁移到海冰遥感图像中),再选取少量海冰样本进行参数微调,来提高分类精度;

(2)根据渤海海冰与极地海冰的各自特异性,确定适应的CNN结构参数,包括层数,卷积核大小,学习率等;

(3)希望可以构建相对规模的遥感海冰图像数据集,训练完备所用的CNN模型以外,为以后其他模型在海冰影像分类上的应用提供样本数据支持,更好的为我国海冰监测和预防服务。

参考文献:

- [1] 张晰. 极化SAR渤海海冰厚度探测研究[D]. 青岛: 中国海洋大学, 2011.
- [2] 吴良斌. SAR图像处理与目标识别[M]. 北京: 航空工业出版社, 2013.
- [3] Maitre H. 合成孔径雷达图像处理[M]. 孙洪, 译. 北京: 电子工业出版社, 2013.
- [4] 胡雪丽. 基于支持向量机的SAR图像增强与分类[D]. 西安: 西安科技大学, 2008.
- [5] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- [6] 刘惠颖, 郭华东, 张露. 基于HJ-1C SAR数据的辽东湾海冰分类[J]. 国土资源遥感, 2014, 26(3): 125-129.
- [7] Karvonen J. Baltic sea ice concentration estimation based on C-band dual-polarized SAR data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(9): 5558-5566.
- [8] Clausi D A, Yue B. Comparing cooccurrence probabilities and Markov random fields for texture analysis of SAR sea ice imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(1): 215-228.
- [9] Yu Q Y, Clausi D A. SAR sea-ice image analysis based on iterative region growing using semantics[J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(12): 3919-3931.
- [10] Ochilov S, Clausi D A. Operational SAR sea-ice image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(11): 4397-4408.
- [11] Wang L, Wong A, Scott K A, et al. Sea ice concentration estimation from satellite SAR imagery using convolutional neural network and stochastic fully connected conditional random field[Z]. 2015.
- [12] 刘建强, 吴奎桥, 黄润恒. Radarsat卫星渤海海冰监测研究[J]. 海洋预报, 1999, 16(3): 62-70.
- [13] 朱婷婷. 南北极典型场景SAR海冰解译研究[D]. 武汉: 武汉大学, 2017.
- [14] 金亚秋, 陈轶, 张巍, 等. 雷达卫星SAR与防卫气象卫星SSM/I

- 对渤海海冰的观测研究[J]. 地球物理学报, 2001, 44(2): 163-170.
- [15] 纪永刚, 张杰, 孟俊敏. 辽东湾海冰类型 SAR 响应分析[J]. 遥感技术与应用, 2007, 22(2): 195-199.
- [16] 纪永刚, 张杰, 孟俊敏, 等. 基于 PCNN 的海冰 SAR 图像分类系统[J]. 高技术通讯, 2008, 18(2): 190-195.
- [17] 张晰, 张杰, 纪永刚. 基于纹理特征分析的辽东湾 SAR 影像海冰检测[J]. 海洋科学进展, 2008, 26(3): 386-393.
- [18] 于波. 辽东湾海冰多极化 SAR 影像解译分析与分类算法研究[D]. 青岛: 中国海洋大学, 2009.
- [19] 张盼. 基于 ScanSAR 海冰图像的冰水解译[D]. 合肥: 合肥工业大学, 2016.
- [20] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. Lake Tahoe, Nevada: Curran Associates Inc., 2012: 1097-1105.
- [21] 焦计晗, 张帆, 张良. 基于改进 AlexNet 模型的油菜种植面积遥感估测[J]. 计算机测量与控制, 2018, 26(2): 186-189.
- [22] 吕鸿蒙, 赵地, 迟学斌. 基于增强 AlexNet 的深度学习阿尔茨海默病的早期诊断[J]. 计算机科学, 2017, 44(S1): 50-60.
- [23] Yarotsky D. Error bounds for approximations with deep ReLU networks[J]. Neural Networks, 2017, 94: 103-114.
- [24] 袁文翠, 孔雪. 基于 TensorFlow 深度学习框架的卷积神经网络研究[J]. 微型电脑应用, 2018, 34(2): 29-32.
- [25] Jaderberg M, Simonyan K, Zisserman A, et al. Spatial transformer networks[J]. arXiv: 1506.02025, 2015.
- [26] Zeiler M D, Fergus R. Visualizing and understanding convolutional networks[C]//Proceedings of the 13th European Conference on Computer Vision. Zurich, Switzerland: Springer, 2014: 818-833.
- [27] Donahue J, Jia Y Q, Vinyals O, et al. DeCAF: a deep convolutional activation feature for generic visual recognition[C]//Proceedings of the 31st International Conference on International Conference on Machine Learning. Beijing, China: JMLR. org, 2014: I-647-I-655.
- [28] Oquab M, Bottou L, Laptev I, et al. Learning and transferring mid-level image representations using convolutional neural networks[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA: IEEE, 2014: 1717-1724.
- [29] Chatfield K, Simonyan K, Vedaldi A, et al. Return of the devil in the details: delving deep into convolutional nets[J]. arXiv: 1405.3531, 2014.
- [30] Penatti O A B, Nogueira K, dos Santos J A. Do deep features generalize from everyday objects to remote sensing and aerial scenes domains? [C]//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops. Boston, MA, USA: IEEE, 2015: 44-51.
- [31] Hu F, Xia G S, Hu J W, et al. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery[J]. Remote Sensing, 2015, 7(11): 14680-14707.
- [32] Ng J Y H, Yang F, Davis L S. Exploiting local features from deep networks for image retrieval[C]//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops. Boston, MA, USA: IEEE, 2015: 53-61.
- [33] Babenko A, Slesarev A, Chigorin A, et al. Neural codes for image retrieval[C]//Proceedings of the 13th European Conference on Computer Vision. Zurich, Switzerland: Springer, 2014: 584-599.
- [34] Dong Z, Pei M T, He Y, et al. Vehicle type classification using unsupervised convolutional neural network[C]//Proceedings of the 22nd International Conference on Pattern Recognition. Stockholm, Sweden: IEEE, 2014: 172-177.
- [35] Dong Z, Wu Y W, Pei M T, et al. Vehicle type classification using a semisupervised convolutional neural network[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(4): 2247-2256.
- [36] 黄冬梅, 李明慧, 宋巍, 等. 卷积神经网络和深度置信网络在 SAR 影像冰水分类的性能评估[J]. 中国图象图形学报, 2018, 23(11): 1720-1732.
- [37] Chen S Z, Wang H P, Xu F, et al. Target classification using the deep convolutional networks for SAR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(8): 4806-4817.
- [38] Wang L, Scott K A, Clausi D A. Sea ice concentration estimation during freeze-up from SAR imagery using a convolutional neural network[J]. Remote Sensing, 2017, 9(5): 408.
- [39] 李金鑫. 基于卷积神经网络的 SAR 图像分类[M]. 长春: 吉林大学, 2018.

Feasibility analysis of convolutional neural networks in remote sensing sea ice classification

CUI Yan-rong¹, ZOU Bin^{1,2}, HAN Zhen¹, SHI Li-jian², LIU Sen²

(1.College of Marine Science, Shanghai Ocean University, Shanghai 201306, China; 2 .National Satellite Ocean Application Service, Beijing 10081 China; 3. Key Laboratory of Space Ocean Remote Sensing and Application, State Oceanic Administration, Beijing 100081 China)

Abstract: This paper analyzes the traditional methods of sea ice monitoring and classification based on satellite remote sensing, and the application results of convolutional neural network in remote sensing image classification and recognition. Moreover, the convolutional neural networks algorithm, which has been successfully used in image recognition and language detection, is applied to the classification of sea ice images, and to solve the issues of sea ice data classification based on its simple network structure, capability in coping with nonlinearity and parallel computing.

Key words: satellite remote sensing; sea ice classification; application; convolutional neural networks; deep learning