

引用格式:张泽宇,刘畅. 基于极化分解和膨胀卷积的极化 SAR 地物分类[J]. 微电子学与计算机,2020,37(12):70-76.
[ZHANG Z Y, LIU C. Terrain classification of Pol-SAR based on dilated convolution and polarization decomposition [J]. Microelectronics & Computer,2020,37(12):70-76.]

基于极化分解和膨胀卷积的极化 SAR 地物分类

张泽宇^{1,2,3},刘 畅^{1,2,3}

(1 中国科学院 空天信息创新研究院,北京 100190;2 中国科学院大学,北京 100049;

3 中国科学院 电子学研究所,北京 100190)

摘 要: 针对基于深度学习的极化 SAR 地物分类中存在的标注数据少且未能利用 SAR 极化分解特征的问题,提出了一种基于极化分解和膨胀卷积的极化 SAR 地物分类方法. 在低采样率下训练基于像素分类的卷积神经网络(CNN),将其卷积层参数迁移到同结构的膨胀卷积网络(DCNN),解决了膨胀卷积网络训练数据不足的问题;然后将反应地物散射特性的极化分解特征与包含高维空间语义信息的膨胀卷积特征图进行联合,使用联合特征构建随机森林(RF)进行分类. 实验表明,特征图和极化分解的联合特征能够实现更为精确的分类,且由于引入膨胀卷积和随机森林,算法具有很高的实时性.

关键词: Pol-SAR; 膨胀卷积; 极化分解; 地物分类

中图分类号: TP753

文献标识码: A

文章编号: 1000—7180(2020)12—0070—07

Terrain classification of Pol-SAR based on dilated convolution and polarization decomposition

ZHANG Ze-yu^{1,2,3},LIU Chang^{1,2,3}

(1 Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100190, China;

2 University of Chinese Academy of Sciences, Beijing 100049, China;

3 Institute of Electronics, Chinese Academy of Sciences, Beijing 100190)

Abstract: In order to solve the problems of the lack of labeling data and the failure to make use of the polarization decomposition feature of SAR in Pol-SAR terrain classification methods based on deep learning, a polarimetric SAR terrain classification method based on dilated convolution and polarization decomposition is proposed. The convolutional neural network (CNN) based on pixel classification was trained at low sampling rate, and its convolutional layer parameters were transferred to the expansive convolutional network (DCNN) with the same structure, thus solving the problem of insufficient training data of the expansive convolutional network. Then the polarization decomposition feature reflecting the scattering characteristics of ground objects is combined with the expansive convolution feature map containing the high-dimensional spatial semantic information, and the random forest (RF) is constructed by using the joint feature for classification. Experiments show that the alliance of polarization decomposition features and feature maps can achieve more accurate classification, and the algorithm has high real-time performance due to the dilated convolution and random forest.

Key words: Pol-SAR; dilated CNN; polarization decomposition; terrain classification

1 引言

极化合成孔径雷达(Polarimetric Synthetic Aperture Radar, Pol-SAR)地物分类是 SAR 的关键应用之一,传统的极化 SAR 地物分类方法分为特征提取和分类器训练两步^[1]. 而极化 SAR 特征提取以极化目标分解为主,其目的是在合理的物理约束模型下去解译地物的散射机制^[2],如 Freeman-Durden^[3]分解将散射分解为模拟水域和粗糙地面的表面散射、模拟森林树冠的体散射以及模拟建筑物的二面角散射,Yamaguchi^[4]分解改进了 Freeman-Durden 的体散射模型并且新增了模拟复杂建筑等极不均匀物体的螺旋散射. 极化分解能够直接反应介质表面的粗糙度、介电常数以及密度等本质特征,对于特定地物类型具有较高的区分度,如文献^[5]结合多种极化特征能够对海岸带植被进行较好的分类,文献^[6]利用极化特征和纹理特征能够完整获取水陆边界. 但是,传统分类方法一般是基于像素进行分类,受 SAR 成像固有的相干斑噪声的影响较大,对于多类型地物分类场景表现不佳. 而卷积神经网络(Convolutional Neural Network, CNN)^[7]能够自动抽象出高维特征,充分利用像素的空间语义信息来减弱噪声影响,卷积神经网络分为基于像素训练的网络和端到端网络两种,基于像素训练的 CNN 网络尽管能够在较少的数据上得到充分的训练,但存在很多重复计算,效率很低^[7],而端到端神经网络(包含全卷积(FCN, Full Convolutional Neural Network)^[8]和膨胀卷积(Dilated CNN)^[9])能够实现全图的直接像素映射,效率较高,其中膨胀卷积能够在特征图不减小的前提下增大感受野,避免 FCN 的下采样操作,保留更多的细节信息. 但是端到端网络需要大量训练数据,在当前极化 SAR 标注数据稀缺的前提下难以直接训练一个泛化能力良好的膨胀卷积网络,同时现有网络均未能有效结合极化分解特征^{[10][11]}.

针对上述两个问题,本文首先在低采样率下训练一个基于像素的 CNN 网络,将其卷积层参数迁移到一个相同结构的膨胀卷积网络,避免对端到端网络的直接训练;然后将包含高维语义信息的膨胀卷积特征图与反应地物散射机制的极化分解特征进行联合,构建随机森林(Random Forests, RF)^[12]进行分类. 基于 AIRSAR 和 E-SAR 平台的实测数据进行实验,验证了此融合特征能够实现更为精确快速的分类.

2 基于膨胀卷积和极化分解的分类算法

2.1 极化分解特征提取

考虑精度和计算量,本文采用了 Freeman 二分解^[3]、Freeman-Durden^[3]、Yamaguchi^[4]以及 Krogager^[13]分解,增加散射强度 span 和协方差矩阵值构成 22 维物理特征,如表 1.

表 1 特征类别

特征算法	特征描述
Freeman	二面角散射、体散射
Freeman-Durden	表面散射、二面角散射、体散射
Yamaguchi	表面散射、二面角散射、体散射、螺旋散射
Krogager	二面角散射,螺旋散射,球散射
Span	散射总功率
Cs	协方差矩阵[C]实部虚部展开

以 Yamaguchi^[4]分解为例,它把总的散射分为四个分量,其中表面散射模拟水域和粗糙地面,体散射模拟森林树冠,二面角散射模拟建筑物,螺旋散射模拟复杂建筑等极不均匀物体. 如公式(1).

$$T = YP_s \cdot T_{\text{surface}} + YP_v \cdot T_{\text{val}} + YP_d \cdot T_{\text{double}} + YP_c \cdot T_{\text{helix}}$$

(1)

图 1(a)、(b)分别表示 Oberpfaffenhofen 地区极化 SAR 数据 Yamaguchi 分解的二面角散射分量和螺旋散射分量. 图 1(a)中的二面角散射中深色部分能够很好的提取道路区域,图 1(b)的螺旋散射中高亮区域对于地物表面不规则的复杂城区和灌木区域有着很好的匹配度.



(a) Yamaguchi 二面角散射



(b) Yamaguchi 螺旋散射

图 1 Oberpfaffenhofen 地区极化分解图

2.2 膨胀卷积与参数迁移原理

在卷积网络中,特征图中的一个点对应的输入图像中的图像块大小被叫做该层的感受野(Receptive field)^[10],其计算公式如(2),其中 rf_K 为当前层感受野大小, rf_{K-1} 为上一层感受野大小, f_K 为当前层卷积核大小, s_i 为步长。

$$rf_K = rf_{K-1} + ((f_{K-1}) * \prod_{i=1}^{K-1} s_i) \quad (2)$$

膨胀卷积通过在卷积核中进行不同填充率的空洞填充来扩大感受野,图2表示当卷积核大小是 3×3 时,不同填充率的膨胀卷积核,其中图2(a)对应的填充率为0,可以看到,填充率为0的膨胀卷积核就是普通卷积核,其感受野为3;图2(b)对应的填充率为1,其具有 5×5 的感知范围;图2(c)对应的填充率为2,其感受野已经扩大至 7×7 。膨胀卷积无需下采样操作,能够在不降低特征图尺寸的前提下逐步扩大感受野,具有更强的细节保留能力和空间语义特征提取能力。




图2 感受野视图

并且膨胀卷积不会增加卷积核参数量,填充的孔洞在训练过程中不更新。

作为一种端到端网络,膨胀卷积网络的训练以区域块作为输入对象,如 64×64 、 128×128 等,一个区域块对应一个训练样本,对于 1000×1000 的数据集,只有几百个样本,并且这些样本还要区分训练和测试集,故现有样本数据难以支持训练泛化能力良好的膨胀卷积网络。而基于像素训练的样本以像素为单位,提取像素周边小块区域作为网络输入,对于 1000×1000 的数据集共有 10^6 个样本,能够支撑网络进行充分的训练且只需要很少的标注数据。鉴于此,在相同感知野的条件下将充分训练的基于像素训练的卷积网络的卷积层参数迁移到同等结构和感知野的膨胀卷积网络的卷积层中。网络结构与迁移原理如图3所示。

其中CNN为普通卷积网络,DCNN为膨胀卷积网络,Conv1为普通卷积,D-conv2为填充率为1的膨胀卷积,为使两者相同层的感受野对应,DCNN网络的Pooling步长为2。对膨胀卷积计算感受野时




图3 感受野视图

等效为卷积核扩大,由公式(2)计算可得,图3中CNN和DCNN各层的感受野均为1、2、4、8,故两者的卷积核提取的是相同感知范围的语义特征,因此可以将CNN的卷积层参数迁移到膨胀卷积DCNN,使得膨胀卷积提取到和普通卷积相同感知野内的相同语义特征。

2.3 DCNN-RF-F 算法

算法完整流程如图4所示,先在小样本条件下训练基于像素的CNN,然后将其卷积层参数迁移到膨胀卷积网络,避免直接训练膨胀卷积网络;将完整图像输入膨胀卷积网络,得到和输入图像同尺寸的特征图;同时对输入图像进行极化分解得到其极化分解特征;然后将膨胀卷积特征图和极化分解特征图叠加得到联合特征图,将其送入随机森林进行分类。算法命名为(Dilated CNN Random forest Feature, DCNN-RF-F)。

3 分类实验

3.1 实验基本设置

在AIRSAR平台的Flevoland-Netherlands地区和E-SAR平台的Oberpfaffenhofen地区极化SAR数据上进行实验。

硬件设备上,本实验平台所用计算机配置是Intel(R)Xeon(R) CPU X5650 @ 2.67GHz,内存为12GB,GPU为NVIDIA GEFORCE GTX 1070Ti,显存为8G。采用Tensorflow深度学习框架。编程语言采用Python3.6和C++11。

共设五组对比实验:利用表1特征构建多特征随机森林和多特征XGBoost^[14]以及多分类支持向量机(Support Vector Machine, SVM)^[15]作为传统




图 4 DCNN-RF-F 分类算法

分类方法的代表,方法分别命名为 F22-RF、F22-XGB 以及 F22-SVM;CNN 是经典的基于像素分类的方法;同时为验证极化分解特征能够提高准确率,将膨胀卷积提取的特征图单独训练随机森林,方法命名为 (Dilated CNN Random Forests, DCNN-RF).

网络基本结构由三个卷积层组成,如图 5 所示.




图 5 网络结构图

采用协方差矩阵 $\mathbf{C}$ 作为网络的输入,如式(3):

$$\mathbf{C} = \begin{bmatrix} \langle |S_{HH}|^2 \rangle & \sqrt{2} \langle S_{HH} S_{HV}^* \rangle & \langle S_{HH} S_{VV}^* \rangle \\ \sqrt{2} \langle S_{HV} S_{HH}^* \rangle & 2 \langle |S_{HV}|^2 \rangle & \sqrt{2} \langle S_{HV} S_{VV}^* \rangle \\ \langle S_{VV} S_{HH}^* \rangle & \sqrt{2} \langle S_{VV} S_{HV}^* \rangle & \langle |S_{VV}|^2 \rangle \end{bmatrix} \quad (3)$$

式中, S_{HH} 和 S_{VV} 项包含了同极化通道功率,而 S_{HV} 和 S_{VH} 项则包含了交叉极化通道回波功率.由互易定理^[2],单波段极化 SAR 输入为如下 9 维实数向量.

$$\text{features} = [C_{11}, C_{12_im}, C_{12_re}, C_{13_im}, C_{13_re}, C_{22}, C_{23_im}, C_{23_re}, C_{33}] \quad (4)$$

采用交叉熵(Cross-Entropy, CE)^[7] 作为损失函数,引入目标检测中的焦点损失(Focal Loss)^[10] 以解决样本不均衡和收敛难度不同的问题.焦点损

失公式如下:

$$\text{Focal Loss}(\hat{p}) = \sum_{i=1}^c -\alpha (p_i - \hat{p}_i)^\gamma \log(\hat{p}_i) = -\alpha (1 - \hat{p}_i)^\gamma \log(\hat{p}_i) \quad (5)$$

3.2 评价指标

为了比较本文算法的有效性,使用像素精度(Pixel Accuracy, PA),频权交互比(Frequency Weighted Intersection over Union, FWIoU),Kappa 系数作为精度测量标准.记 P_{ij} 为第 i 类地物被分类为第 j 类的数量.那么:

像素精度 PA 表示标记正确的像素占总数的比例,如式(6)所示.

$$PA = \frac{\sum_{i=1}^k P_{ii}}{\sum_{i=1}^k \sum_{j=1}^k P_{ij}} \quad (6)$$

FWIoU 是语义分割的标准度量,其能够最好的衡量预测分类和真实标签的重合程度,值越大分类效果越好.如(7) 所示^[7].

$$FWIoU = \frac{\sum_{i=0}^k P_{ij}}{\sum_{i=0}^k \sum_{j=0}^k P_{ij}} \sum_{i=0}^k \left(\frac{P_{ij}}{\sum_{i=0}^k P_{ij} + \sum_{j=0}^k P_{ji} - P_{ii}} \right) \quad (7)$$

Kappa 为一致性检验指标,基于混淆矩阵来计算,值越大分类一致性越好,其公式如(8) 所示^[7].

$$Kappa =$$

$$\frac{\sum_{i=1}^k P_{ii} \times \sum_{i=1}^k \sum_{j=1}^k P_{ij} - \sum_{i=1}^k (\sum_{j=1}^k P_{ij} \sum_{j=1}^k P_{ji})}{(\sum_{i=1}^k \sum_{j=1}^k P_{ij})^2 - \sum_{i=1}^k (\sum_{j=1}^k P_{ij} \sum_{j=1}^k P_{ji})} \quad (8)$$

3.3 实验结果

3.3.1 Oberpfaffenhofen 地区实验

本数据是来源于 E-SAR 平台的 L 波段数据, 包含表面不规则的城区和灌木丛, 以及相对规则的耕地和道路区域. 尺寸为 1300×1200 , 其伪彩色图和标注信息如图 6(a)、(b) 所示. 数据总的采样率约 1%, 训练集和验证集的比例为 9:1.




图 6 Oberpfaffenhofen 极化 SAR 数据

上述六种算法在该数据集上的效果如表 2 所示. 分类时间包含了特征提取过程和分类过程两个阶段的时间.

表 2 Oberpfaffenhofen 地区实验结果表(%)

算法/指标	灌木	耕地	城区	道路
F22-RF	83.78	90.17	77.16	80.56
F22-XGB	84.18	89.35	75.76	80.13
F22-SVM	82.88	89.78	68.03	74.54
CNN	89.60	92.65	90.51	58.52
DCNN-RF	91.27	89.90	88.91	85.21
DCNN-RF-F	91.57	91.28	89.15	86.29

算法/指标	PA	Kappa	FWIoU	Time(s)
F22-RF	85.06	73.52	74.91	18.22
F22-XGB	84.43	72.17	74.03	15.62
F22-SVM	82.16	66.15	70.72	617
CNN	88.53	80.09	79.39	422
DCNN-RF	89.51	82.84	81.62	13.59
DCNN-RF-F	90.45	84.42	83.04	26.49

根据表 2, 随机森林在传统方法中取得了最高的 PA 、 $Kappa$ 以及 $FWIoU$, 分别为 85.06%、73.52% 和 74.91%. XGBoost 速度最快, 并且由于

道路区域的散射特征明显, 两者均在道路区域取得了较高的精度, SVM 精度最差且耗时最多. DCNN-RF 方法的 PA 、 $Kappa$ 以及 $FWIoU$ 分别超出 CNN 0.98%、2.75% 和 2.23%, 且分类速度提高 31 倍, 说明随机森林分类器能够更好的解析 CNN 提取的特征. DCNN-RF-F 方法通过融合极化分解特征和 CNN 特征图取得了最佳的 PA 、 $Kappa$ 以及 $FWIoU$, 分别为 90.45%、84.42% 以及 83.04%, 耗时相比 DCNN-RF 增加了 12.9 s, 主要增加在极化特征的提取上, 但分类时间仍远小于 CNN.

图 7 列出了 F22-RF、CNN、DCNN-RF 以及 DCNN-RF-F 四种方法的分类结果图. 四种方法均能实现整体连贯的分类, 但受相干斑噪声影响, F22-RF 的结果图中存在较多的孔洞, 分类连续性较差. CNN 方法分类结果损失了较多的道路区域, DCNN-RF-F 通过融合对道路区分明显的极化分解特征在道路区域达到了最高的精度, 且整体分类精度最高, 分类结果最为平滑.




图 7 Oberpfaffenhofen 地区分类结果图

3.3.2 Flevoland-Netherlands 地区实验

Flevoland-Netherlands 极化 SAR 数据是 SAR 分类领域广泛使用的分类数据, 包含 L, P, C 三个波段的 Pol-SAR 数据, 共有 14 种农作物以及道路和建筑 2 种人造目标. 大小是 1079×1024 , 图 8(a) 表示 L 波段的 Pauli 伪彩图, 图 8(b) 表示对应的标注区域. 黑

色区域是未标注部分,不参与训练和测试.数据总体采样率是 2%,训练集和验证集的比例为 9:1.




图 8 Flevoland-Netherlands 地区极化 SAR 数据

算法效果如表 3 所示.随机森林在传统方法中取得了最高的精度和最快的速度,SVM 相比于 RF 和 XGBoost 对土豆、菜籽、水果以及燕麦的区分精度较高,但是对建筑等其它多种地物的效果较差,并且其耗时为 RF 的 13 倍.DCNN-RF 方法的 PA 、 $Kappa$ 以及 $FWIoU$ 较 CNN 分别下降了 0.33%、0.38%和 0.58%,但分类速度提高 19 倍.DCNN-RF-F 经过反应散射特征的极化分解特征和包含更多高维语义信息的膨胀卷积特征图的融合,其 PA 、 $Kappa$ 以及 $FWIoU$ 相比 CNN 上升了 0.67%、0.78%和 1.24%,并且 DCNN-RF-F 在草地、甜菜、建筑等多达 12 种地物种取得了最佳精度,耗时相比 DCNN-RF 增加了 27 s,增加量相比于数据 1 和 2 的增加值较多,这是因为本数据是三波段极化 SAR 数据,每个波段都要分别提取特征.

表 3 Flevoland-Netherlands 实验结果表(%)

算法/指标	草地	亚麻	土豆	小麦	菜籽	甜菜	青稞	豌豆	玉米	大豆
F22-RF	95.85	98.66	98.08	98.56	99.69	98.20	98.78	97.11	96.31	98.53
F22-XGB	92.58	98.19	98.41	98.41	99.53	97.22	98.66	96.26	94.16	98.58
F22-SVM	81.28	88.23	98.88	89.11	99.70	86.82	92.89	76.10	67.49	71.94
CNN	95.18	99.88	98.92	99.41	99.77	97.93	99.23	97.73	98.00	95.66
DCNN-RF	95.70	99.78	98.90	99.26	99.78	97.53	98.96	98.91	95.44	98.58
DCNN-RF-F	97.68	99.81	99.04	99.40	99.88	99.38	99.37	99.76	98.87	98.94

算法/指标	水果	洋葱	燕麦	苜蓿	建筑	道路	PA	Kappa	FWIoU	Time(s)
F22-RF	98.07	94.37	97.27	99.68	76.48	81.06	96.38	95.80	93.33	39
F22-XGB	97.60	92.38	92.70	99.25	80.01	79.72	95.85	95.18	92.53	61
F22-SVM	98.21	7.43	98.04	96.81	57.06	63.76	88.10	85.79	80.21	518
CNN	99.18	99.27	100	99.93	84.19	88.69	97.63	97.26	95.50	312
DCNN-RF	98.87	99.63	100	99.82	83.30	86.43	97.30	96.88	94.92	16.64
DCNN-RF-F	98.93	99.55	100	99.98	85.67	91.11	98.30	98.04	96.74	43.64

4 结束语

极化目标分解从物理原理出发,能够通过简单的计算提取散射特征,在一些极化 SAR 图像地物分类的针对性应用中,如建筑物检测、森林面积监测等,能够有效地提升模型的分类精度.本文通过联合反应地物散射特性的极化分解特征和包含精细高维空间语义信息的膨胀卷积特征图实现了精确的极化 SAR 地物分类,使用膨胀卷积极大提高了推理速度,并且通过参数迁移解决了膨胀卷积网络训练数据不足的问题.实现了在小样本条件下准确快速的

极化 SAR 地物分类.

参考文献:

[1] ZHANG L, ZOU B, ZHANG J, et al. Classification of polarimetric SAR image based on support vector machine using multiple-component scattering model and texture features [J]. EURASIP Journal on Advances in Signal Processing, 2009, 2010: 1-9.

[2] DONG J. Statistical analysis of polarization SAR image features and research on classification algorithm [D]. Wuhan :Wuhan University , 2018.

[3] FREEMAN A, DURDEN S L. A three-component

- scattering model for polarimetric SAR data[J]. IEEE Transactions on Geoscience and Remote Sensing, 1998, 36(3):963-973.
- [4] YAMAGUCHI Y, MORIYAMA T, ISHIDO M, et al. Four-component scatteriSng model for polarimetric SAR image decomposition[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43 (8): 1699-1706.
- [5] VAN B S, COMBER A, LAMB A. Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data[J]. Remote Sensing of Environment, 2014, 149:118-129.
- [6] DENG Y, ZHANG H, WANG C, et al. Object-oriented polarization SAR water extraction method combining texture and polarization decomposition [J]. Remote sensing technology and application, 2016, 31(4): 714-723.
- [7] ZHANG J Q. Research on polarization SAR ground object classification based on deep learning [D]. Beijing :Chinese academy of surveying and mapping , 2018.
- [8] ZHANG Z, WANG H, XU F, et al. Complex-valued convolutional neural network and its application in polarimetric SAR image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55 (12):7177-7188.
- [9] GU Y F. Research on semantic segmentation algorithm based on grouped dilated convolution and cascade network [D]. Harbin: Harbin Institute of Technology, 2018.
- [10] YE Q W, WU X F. Design of objective loss function to suppress inefficient learning in end-to-end deep image segmentation network [J]. Microelectronics & Computer, 2019, 36(9):38-43.
- [11] CHEN S W, TAO C S. PolSAR image classification using polarimetric-feature-driven deep convolutional neural network[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(4):627-631.
- [12] LI C L, TIE Y, QI L. Multi-feature speech emotion recognition based on random forest classification optimization[J]. Microelectronics & Computer, 2019, 36 (1):70-73.
- [13] KROGAGER E. New decomposition of the radar target scattering matrix [J]. IET Electronics Letters, 1990, 26(18):1525-1526.
- [14] YE D, LI Z, WANG Y J. Research on behavior recognition method based on SPLDA dimensionality reduction and XGBoost classifier [J]. Microelectronics & Computer, 2019, 36(6):35-39.
- [15] SHEN Y L, SONG J, WAN Z C. SVM feature selection and parameter optimization based on improved firework algorithm [J]. Microelectronics & Computer, 2018, 35(1):21-25.

作者简介:

张泽宇 男, (1994-), 硕士研究生. 研究方向为 SAR 遥感图像处理技术. E-mail: zhangzeyu0901@163. com

刘畅 男, (1978-), 研究员, 博士生导师. 研究方向为 SAR 系统及其相关 SAR 成像处理技术.