

基于迁移学习仿真 SAR 图像的目标识别研究

崔亚楠¹, 吴建平^{1,2,3}, 朱辰龙¹, 闫相如¹

(1. 云南大学 信息学院, 云南 昆明 650504;

2. 云南省电子计算中心, 云南 昆明 650223;

3. 云南省高校数字媒体技术重点实验室, 云南 昆明 650223)

摘要:合成孔径雷达(SAR)图像的目标识别研究在军事、国防等领域具有特殊的应用价值。为了更高效、准确地识别 SAR 图像中的目标物,实验利用卷积神经网络对 SAR 图像进行训练,以获取良好的识别模型。但小样本集合的 SAR 图像存在识别效果差,易导致结果过拟合等问题。为此,研究并提出了一种基于卷积神经网络仿真 SAR 图像迁移学习的目标识别方法。通过选取数据量较大的仿真 SAR 图像数据集预训练 Inception-ResNet-v2 网络模型,得到相应的网络参数。结合迁移学习的方法,将预训练模型得到的网络参数迁移到目标模型上作为目标模型的初始化参数,使用 SAR 图像对目标模型进行识别训练,并同步进行参数优化和迭代训练。实验有效解决了 SAR 图像数据不足所产生的过拟合问题,并且模型识别的准确率得到提升。通过 MSTAR 数据集验证了该算法的有效性,识别的准确率达到 99.57%。

关键词:卷积神经网络;迁移学习;合成孔径雷达;仿真 SAR 图像;Inception-ResNet-v2

中图分类号:TP753

文献标识码:A

文章编号:1673-629X(2021)10-0043-06

doi:10.3969/j.issn.1673-629X.2021.10.008

Research on Target Recognition Based on CNN Simulated SAR Image Transfer Learning

CUI Ya-nan¹, WU Jian-ping^{1,2,3}, ZHU Chen-long¹, YAN Xiang-ru¹

(1. School of Information Science & Engineering, Yunnan University, Kunming 650504, China;

2. Yunnan Provincial Electronic Computing Center, Kunming 650223, China;

3. Digital Media Technology Key Laboratory of Universities and Colleges in Yunnan Province, Kunming 650223, China)

Abstract: The research of synthetic aperture radar image target recognition has special application value in military, national defense and other fields. In order to recognize targets in SAR images more efficiently and accurately, convolutional neural networks are used for SAR image training to obtain an excellent recognition model through experiments. However, SAR images with small sample sets have poor recognition effects, which may easily lead to problems such as over-fitting of results. To this end, a target recognition method based on convolutional neural network simulation SAR image transfer learning is researched and proposed. A simulation SAR image data set with a large amount of data is selected to pre-train the Inception-ResNet-v2 network model to obtain the corresponding network parameters. Combined with the transfer learning method, the network parameters obtained by the pre-training model are transferred to the target model as the initialization parameters of the target model, and the target model is identified and trained using SAR images, and parameter optimization and iterative training are performed simultaneously. The experiment effectively solves the problem of overfitting caused by insufficient SAR image data, and the accuracy of model recognition is improved. The effectiveness of the algorithm is verified through the MSTAR data set, and the recognition accuracy reaches 99.57%.

Key words: convolutional neural network; transfer learning; synthetic aperture radar; simulated SAR image; Inception-ResNet-v2

0 引言

合成孔径雷达(synthetic aperture radar, SAR)是一种多平台协同工作的主动微波成像雷达系统。相较于

可见光、红外等光学成像方式, SAR 具有全天候、全天时且不受天气、光照等外界条件限制的独特优势。近年来,已经被广泛运用到军事、工业、农业等诸多领域。

收稿日期:2020-11-10

修回日期:2021-03-16

基金项目:国家自然科学基金(61763049);云南省应用基础研究重点课题(2018FA032)

作者简介:崔亚楠(1997-),男,硕士研究生,研究方向为图像处理、AI技术;通信作者:吴建平(1965-),男,高级工程师,硕士,研究方向为多媒体、信息化技术。

随着 SAR 系统与成像技术的发展与完善, SAR 图像的应用得到广泛关注, 从而大量 SAR 图像目标的自动识别 (automatic target recognition, ATR) 成为学者们研究的热点问题。

国内外对 SAR 图像目标的自动识别进行了研究并提出了一些方法。早期对 SAR 图像目标识别的研究主要基于特征提取, 如文献[1]运用非负矩阵分解特征进行 SAR 图像目标识别; 文献[2]通过提取图像局部判别嵌入特征进行目标识别; 文献[3]基于电磁散射特征提取方法识别 SAR 图像目标。以上特征提取方法均会忽略掉图像的细节信息, 从而无法充分提取目标的特征, 导致目标识别效果不佳。深度学习^[4]的出现为 SAR 图像目标识别提供更多的可能。AlexNet^[5]、VGG^[6]、GoogleNet^[7]、ResNet^[8]等深度学习网络模型在 ImageNet 大赛中表现优越, 这些神经网络模型也逐渐引入到 SAR 图像目标识别研究中。

卷积神经网络 (CNN) 模型训练时往往需要大量的数据, 对于数据较少的 SAR 图像数据集在训练过程中大概率会出现过拟合, 从而导致模型鲁棒性差, 识别效果不佳。在以往的研究中, 文献[9]通过增强数据集获取更多 SAR 图像, 再对 CNN 模型进行训练, 最终达到了 96.42% 的识别率。文献[10]基于模型迁移, 引入超限学习机 (ELM) 对目标进行学习, 最终取得了 97.23% 的识别率。文献[11]提出一种 CMNet 网络模型, 通过增加卷积层个数减少图像相干斑噪声的影响, 并利用 Softmax 损失与中心损失共同监督网络训练提高模型的泛化能力, 最终获得了 99.30% 的识别率。

为了更有效地解决 SAR 图像样本不足的问题, 一些学者提出仿真 SAR 图像的概念, 如文献[12]基于一种射线追踪技术的 SAR 信号级仿真方法构建地面车辆目标 SAR 仿真场景物理模型, 得到相应的 SAR 仿真图像, 扩充了 SAR 图像数据。一定程度上能够解决 SAR 图像数据缺乏的问题。在此基础上, 文中提出基于卷积神经网络仿真 SAR 图像迁移学习的方法, 利用 SAR 仿真数据集^[13]预训练卷积神经网络至网络收敛, 得到相应的网络参数。再将预训练得到的网络参数迁移到目标网络对 SAR 图像数据进行训练。实验结果表明, 该算法优于传统机器学习方法, 获得了更好的识别效果, 进一步提高了 SAR 识别的实用价值。

1 相关理论和技术描述

1.1 卷积神经网络

卷积神经网络主要由卷积层、池化层、全连接层构成。卷积层和池化层在卷积神经网络中交替叠加出现, 组成了提取特征的部分。卷积神经网络相比其他神经网络, 其独特优势在于具有权值共享和局部感知

的特性, 很大程度上减少了网络参数, 降低了计算量。

(1) 卷积层。

卷积层中包含多种尺寸的卷积核, 作用是对图像的深层特征进行提取。其次利用激活函数对其进行非线性激活得到新的特征。具体计算过程如下:

$$Y_{i,j} = f\left(\sum_{l=0}^{N-1} \sum_{k=0}^{N-1} w_{l,k} x_{i+l,j+k} + W_b\right) \quad (1)$$

其中, $Y_{i,j}$ 是第 i 行, 第 j 列的特征输出值; N 为卷积核的大小; $w_{l,k}$ 为第 l 行, 第 k 列的权重; W_b 为偏置项; f 为激活函数。ReLU 函数相较于其他激活函数有更快的收敛速度且能够缓解梯度消失的问题, 因此文中选用 ReLU 函数作为非线性激活函数。其函数表达式为:

$$\text{ReLU}(x) = \max(x, 0) \quad (2)$$

(2) 池化层。

池化层分为平均池化 (average pooling) 和最大池化 (max pooling) 两种形式, 作用在于减少网络参数量, 防止过拟合, 使网络优化更加容易。

(3) 全连接层。

全连接层作为卷积神经网络的“分类器”, 其每个节点与上一层所有节点完全连接, 将经过卷积层和池化层所得到的全部特征汇总, 最终输出的节点数即为目标识别的类别数。

1.2 迁移学习

迁移学习是在两个领域具有一定相关性的条件下, 用其中一个领域学习到的知识解决另一个领域存在的问题的方法^[14]。迁移学习分为基于实例迁移学习、基于特征迁移学习、基于模型迁移学习和基于关系迁移学习四大类别。传统机器学习在训练一个好的网络模型时需要训练大量数据进行学习, 对于一些数据较少的样本往往训练效果不佳。迁移学习能有效解决小样本数据的学习问题, 提升卷积神经网络对小样本数据目标分类识别的准确率。

在迁移学习中, 被学习的领域称为源域 (source domain), 待解决问题的领域称为目标域 (target domain), 公式如下:

$$D(s) = \{x_s, P(x_s)\} \quad (3)$$

$$D(t) = \{x_t, P(x_t)\} \quad (4)$$

其中, $D(s)$ 为源域; $D(t)$ 为目标域; x_s 为源域的特征空间; x_t 为目标域的特征空间; $P(x_s)$ 是与 x_s 对应的边际概率分布; $P(x_t)$ 是与 x_t 对应的边际概率分布。

1.3 仿真 SAR 图像模型介绍

生成仿真 SAR 目标图像过程: 首先, 利用 Ulaby 方法结合粗糙面散射理论建立 SAR 车辆目标仿真场景模型, 再利用蒙特卡罗 (Monte Carlo) 方法获取雷达与目标以及地面环境的空间几何关系, 进一步通过随

机散射法等获取地面的粗糙特性。随后,利用射线弹跳法、等效边缘流法等建立目标、地面场景的电磁散射模型。最后,基于电磁散射模型与场景模型计算 SAR 目标的扫频数据,通过时频变换与成像算法得到仿真 SAR 目标图像。不同方位角的部分仿真 SAR 图像如图 1 所示。




图 1 部分仿真 SAR 图像

2 基于迁移学习的 SAR 目标图像识别方法

2.1 图像预处理

遥感雷达图像具有较大的相干斑点噪声,一定程度上影响了网络性能的提升。文中采用一种增强的 Lee 滤波算法^[15]先对 MSTAR 数据集中的图像进行滤波去噪,减少噪声在神经网络模型训练中产生的影响,有效提高了网络性能。

2.2 Inception-ResNet-v2

随着卷积神经网络在图像识别领域的深入发展,对网络性能有更高的要求。前期扩充网络的深度与高度的作法,出现了网络过拟合、计算量大等问题。而 Inception 网络模型有效缓解了该问题。Inception v1 网络^[7]通过稀疏矩阵聚类成相对密集的子矩阵的方法提高网络计算性能。Inception v2 网络^[16]在输入时增加了 batch_normal,使网络训练收敛得更快。Inception v3 网络^[16]利用多个小卷积核串联取代较大卷积核的方式,改善了网络的非线性,减小了网络过拟合的概率。Inception v4 网络与 Inception v3 网络相比具有更统一的简化架构。Inception v4 网络与 Inception-ResNet-v2 网络结构相似,不同点在于 Inception-ResNet-v2 网络结合了残差网络的思想可以

将网络深度增加^[17]。

Inception-ResNet-v2 网络结合了残差网络思想,在增加神经网络深度的同时降低了梯度消失的问题,该网络性能最佳。因此,文中采用 Inception-ResNet-v2 网络作为训练模型,将原始模型的 Dropout rate 改为 0.5,最后利用 Adam 算法对模型进行优化,其采用的网络架构如图 2 所示。




图 2 Inception-ResNet-v2 网络总体架构

其中,Inception-ResNet-v2 网络结构又由 Stem 模块、Inception-ResNet-A 模块、Reduction-A 模块、Inception-ResNet-B 模块、Reduction-B 模块、Inception-ResNet-C 模块等组成。

2.2.1 Dropout 的设计

对于参数量大,训练样本少的神经网络训练时很容易产生过拟合,Dropout 的提出有效解决了这一问题。Dropout 在训练网络时会随机丢弃部分神经元,从而达到减少网络参数、提升模型鲁棒性的目的,同时,有效缓解过拟合对网络的影响。文中模型中 Dropout rate 设置为 0.5。

2.2.2 Softmax 分类器设计

Softmax 函数是基于多项逻辑损失的组合,常用于图像等多分类问题来表示类别之间的概率分布,其基本原理是将输入映射为 0 到 1 之间的实数,实现分类向量的归一化。Softmax 分类器的目的是实现估计分类概率和真实分布之间交叉熵的最小化。

交叉熵函数表达式为:

$$H(p, q) = - \sum_x p(x) \log(q(x)) \quad (5)$$

其中, p 表示真实分布, q 表示估计分布。

Softmax 函数表达式为:

$$H(z_i) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (6)$$

其中, i 表示第 i 类别, k 表示总的类别数, $H(z_i)$ 表示第 i 类别的概率。

2.3 迁移学习算法设计与实现

文中基于迁移学习实现 Inception-ResNet-v2 网络模型的预训练、训练以及优化等, 迁移模型如图 3 所示。算法的具体实现过程如下:

(1) 将仿真 SAR 数据集中的七类图像作为源域识别任务, 仿真 SAR 数据集作为源域训练样本。对 Inception-ResNet-v2 模型进行预训练, 得到预训练模型参数。

(2) 构建与源域模型相同的目标域模型。

(3) 将 MSTAR 数据集中的十类图像作为目标域识别任务, MSTAR 数据集作为目标域的训练样本。将上述预训练模型中的参数作为目标域模型的初始化参数对目标域模型进行训练。

(4) 采用 Adam 算法优化网络。

(5) 最终通过 Softmax 分类器实现目标的分类。

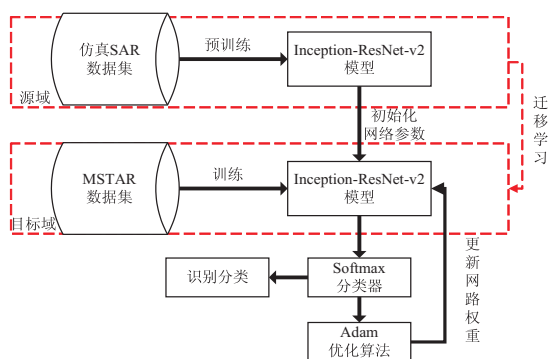


图 3 SAR 迁移学习的模型

3 实验结果与分析

实验在 tensorflow1.10+keras2.2.2 框架下实现神经网络的搭建。实验环境配置: win10 操作系统、i7-8750h 处理器、GTX1060 显卡、16 G 内存。

3.1 实验数据集

文中选用 SAR 仿真数据集作为预训练模型的数据集。该数据集包含三种不同场景下的七类 SAR 仿真图像, 每类图像由七个不同方向角下仿真获取, 总计 21 168 张仿真图像。

为验证文中算法的有效性, 实验选用 MSTAR 数据集作为实测数据集。MSTAR 数据集包含了 2S1、BMP2、BRDM2、BTR60 等十类目标图像, 其中十类目标的光学图像与其对应的 SAR 图像如图 4 所示。文中选用常用的 17° 方位角下的 2 746 张 SAR 图像与 15° 方位角下的 2 426 张 SAR 图像作为训练及测试样本。将两个方位角下的同类目标图像混合, 并按照 6:4 的比例随机在每类中抽取 60% 作为训练集, 剩余的 40% 作为测试集, 具体如表 1 所示。




图 4 十类目标光学图像与其对应的 SAR 图像

表 1 实测 SAR 数据

图像	2S1	BMP2	BRDM2	BTR70	BTR60	D7	T62	T72	ZIL131	ZSU23
17°	299	232	298	233	256	299	299	232	299	299
15°	274	196	274	196	195	274	273	196	274	274
训练集	344	257	343	257	271	344	343	257	344	344
测试集	229	172	229	172	180	229	229	171	229	229

3.2 实验结果

输入图片的大小为 224×224; 学习率值为 0.000 1; batchsize 值为 12; dropout 值为 0.5; 迭代 7 770 次, 通过实验结果数据分析, 在迭代到 6 475 次时准确率达到了最高。

十类 SAR 目标图像的识别结果如表 2 的混淆矩阵所示, 其中 BTR70 装甲车、D7 推土机、T72 坦克、ZIL131 卡车识别率达到 100%。BMP2 坦克识别率最低, 但准确率也达到了 98.84%。最终在测试集上的平均识别率为 99.57%。

表 2 十类 SAR 目标图像识别结果

类别	2S1	BMP2	BRDM2	BTR70	BTR60	D7	T62	T72	ZIL131	ZSU23	识别率/%
2S1	227	0	0	0	0	0	1	1	0	0	99.13
BMP2	0	170	0	1	0	0	0	1	0	0	98.84

续表 2

类别	2S1	BMP2	BRDM2	BTR70	BTR60	D7	T62	T72	ZIL131	ZSU23	识别率/%
BRDM2	0	0	228	0	1	0	0	0	0	0	99.56
BTR70	0	0	0	172	0	0	0	0	0	0	100
BTR60	0	1	0	0	179	0	0	0	0	0	99.44
D7	0	0	0	0	0	229	0	0	0	0	100
T62	0	0	0	0	0	0	227	2	0	0	99.13
T72	0	0	0	0	0	0	0	171	0	0	100
ZIL131	0	0	0	0	0	0	0	0	229	0	100
ZSU23	0	0	0	0	0	1	0	0	0	228	99.56
平均识别率											99.57

3.3 对比实验分析

对比实验一:

在该实验中,不对网络进行预训练。直接用 17° 方位角下 SAR 目标的训练集对网络进行训练,网络参数随机初始化,学习率、batchsize、dropout 等值与文中实验保持不变。最终在 15° 方位角下 SAR 目标的测试集识别率仅达到 91.64%。

用小样本数据集直接对神经网络进行训练,得到局部最优解的概率较大,训练出来的网络鲁棒性较差,不能充分提取图像更多的细节特征,所以识别的准确率较低。

对比实验二:

选用 ImageNet 数据集取代 SAR 仿真数据集对网络预训练,并保留预训练网络的相关参数。将预训练得到的参数作为目标模型的初始化参数,再用 17° 方位角下 SAR 目标的训练集对网络进一步训练至收敛。学习率、batchsize、dropout 等值保持不变。最终在 15° 方位角下 SAR 目标的测试集识别率达到了 97.47%,仍低于文中提出的方法。

与 ImageNet 数据集图像相比,仿真 SAR 图像的特征与目标 SAR 图像特征相似度更高,所以仿真 SAR 图像训练的模型具有更好的泛化能力。




图 5 准确率对比

文中方法与两个对比实验的 SAR 识别准确率以及训练误差对比如图 5 和图 6 所示。总共训练 30 轮,

其中每轮训练大约为 259 次,共计训练 7 770 次。




图 6 训练误差对比

不同的 SAR 图像目标识别研究方法与文中识别方法的对比结果如表 3 所示。

表 3 不同方法的网络模型性能对比

来源	方法	识别率/%
对比实验一	不做预训练处理	91.64
对比实验二	ImageNet 数据集预训练	97.47
文献[9]	增强数据集	96.42
文献[10]	CNN+ELM	97.23
文献[11]	CMNet 模型	99.30
文中方法	迁移仿真 SAR 模型	99.57

4 结束语

提出了一种基于卷积神经网络仿真 SAR 图像迁移学习的目标识别方法,能有效缓解现存 SAR 数据集较小带来的问题;使用 Inception-ResNet-v2 网络并融合 Inception-v4 网络的特征与残差网络的思路,在提高识别准确率的同时能够缓解梯度消失问题。还通过仿真 SAR 目标图像对 Inception-ResNet-v2 网络预训练,得到网络参数。将预训练获得的网络参数作为目标网络的初始化参数进行迁移学习,并利用 SAR 目标图像对网络进一步训练并更新权重等参数直至网络收敛。最终在测试集上获得了 99.57% 的识别率。该方

法一定程度上避免了小样本数据集在网络训练过程中容易陷入局部最优解的问题,在实测 SAR 图像集上对其有效性进行了验证。

在现代太空立体化战争中,高效、准确地识别出对方地面投入战场的或后方的军备 SAR 图像极为重要。文中方法可为 SAR 图像目标的识别研究和进一步应用提供参考。

参考文献:

- [1] HUAN Ruohong, PAN Yun, MAO Keji. SAR image target recognition based on NMF feature extraction and Bayesian decision fusion[C]//2010 second IITA international conference on geoscience and remote sensing. Qingdao: IEEE, 2010:496-499.
- [2] PEI Jifang, HUANG Yulin, LIU Xian, et al. Neighborhood virtual points discriminant embedding for synthetic aperture radar automatic target recognition[J]. Optical Engineering, 2013, 52(3):036201-1-036201-11.
- [3] 计科峰,张静克,邢相薇,等. 基于电磁散射特性的高分辨 SAR 图像地面车辆目标特征提取[C]//第十届全国信息获取与处理学术会议论文集. 沈阳:中国仪器仪表学会, 2012:108-113.
- [4] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7):1527-1554.
- [5] KRIZHEVSKY A, SUTSKEVER I, HINTON G. 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.
- [6] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv:1409.1556, 2014.
- [7] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]//2015 IEEE conference on computer vision and pattern recognition (CVPR). Boston, MA: IEEE, 2015:1-9.
- [8] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//IEEE conference on computer vision & pattern recognition. Las Vegas, NV: IEEE, 2016:770-778.
- [9] 陈欣,陈明逊. 基于增强数据集卷积神经网络的 SAR 目标识别方法[J]. 重庆理工大学学报:自然科学版, 2020, 34(1):86-93.
- [10] 刘晨,曲长文,周强,等. 基于卷积神经网络迁移学习的 SAR 图像目标分类[J]. 现代雷达, 2018, 40(3):38-42.
- [11] 胡显,姚群力,侯冰倩,等. 基于卷积神经网络的合成孔径雷达图像目标识别[J]. 科学技术与工程, 2019, 19(21):228-232.
- [12] 董纯柱,胡利平,朱国庆,等. 地面车辆目标高质量 SAR 图像快速仿真方法[J]. 雷达学报, 2015, 4(3):351-360.
- [13] ANDERS K, ADILI A, JØRGEN D. Synthetic SAR image generation using sensor, terrain and target models[C]//Eusar: European conference on synthetic aperture radar. Hamburg, Germany: VDE Press, 2016:405-409.
- [14] PAN S J, YANG Qiang. A survey on transfer learning[J]. IEEE Transactions on Knowledge & Data Engineering, 2010, 22(10):1345-1359.
- [15] 李文辉. 基于深度学习的 SAR 图像目标识别[D]. 成都:电子科技大学, 2018.
- [16] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//IEEE conference on computer vision & pattern recognition. Las Vegas: IEEE, 2016:2818-2826.
- [17] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning[C]//Proceedings of the thirty-first AAAI conference on artificial intelligence. San Francisco, California, USA: AAAI Press, 2017:4278-4284.