

基于模型微调与 AM-Softmax 的极化 SAR 图像分类

赵明钧¹, 程英蕾¹, 秦先祥¹, 王 鹏¹, 文 沛², 张碧秀³

(1. 空军工程大学信息与导航学院, 西安, 710077;

2. 93575 部队, 河北承德, 067000; 3. 93897 部队, 西安, 710077)

摘 要 针对极化 SAR 图像分类中卷积神经网络(CNN)方法训练时间长、收敛速度慢, 原始 Softmax 函数无法对极化 SAR 图像的类内差异有效应对的问题, 提出一种基于模型微调与加性边际 Softmax(AM-Softmax)的极化 SAR 图像分类方法。该方法通过预训练网络的整体微调, 来改进 CNN 模型的效率和分类准确率, 然后以 AM-Softmax 替代 Softmax, 以解决 SAR 图像中类内变化较大的问题, 进一步提升分类精度。实验表明该方法具有快收敛的优势并且能够较好解决极化 SAR 图像类内差异较大的问题, 模型的分类总体精度达到 96% 以上。

关键词 极化 SAR 图像分类; 模型迁移; 加性边际 Softmax

DOI 10.3969/j.issn.2097-1915.2022.05.006

中图分类号 TP391 **文献标志码** A **文章编号** 2097-1915(2022)05-0036-08

A Polarimetric SAR Image Classification Based on Model Fine-Tuning and AM-Softmax

ZHAO Mingjun¹, CHENG Yinglei¹, QIN Xianxiang¹, WANG Peng¹, WEN Pei², ZHANG Bixiu³

(1. Information and Navigation School, Air Force Engineering University, Xi'an 710077, China;

2. Unit 93575, Chengde 067000, Hebei, China; 3. Unit 93897, Xi'an 710077, China)

Abstract Aimed at the problems that the convolutional neural network (CNN) method in polarimetric SAR image classification is long in training time, and slow at convergence speed, and the original Softmax function cannot effectively deal with the intra-class differences of polarimetric SAR images, a model based on fine-tuning and adding a polarimetric SAR image classification method is proposed by Additive Margin Softmax (AM-Softmax). This method improves the efficiency and classification accuracy of the CNN model through the overall fine-tuning of the pre-trained network, and then replaces the Softmax with AM-Softmax to solve the problem of large intra-class variation in SAR images and further improve the classification accuracy. The experiments show that this method is fast on convergence and deal with the problems of large variation in polarization SAR images within a class, and the overall classification accuracy of the model reaches above 96%.

Key words polarimetric SAR image classification; model transfer; additive margin Softmax

收稿日期: 2022-02-22

基金项目: 国家自然科学基金(61773396); 陕西省自然科学基金(2022JM-157)

作者简介: 赵明钧(1998—), 男, 黑龙江宁安人, 硕士生, 研究方向为极化 SAR 图像解译。E-mail: 1412796593@qq.com

引用格式: 赵明钧, 程英蕾, 秦先祥, 等. 基于模型微调与 AM-Softmax 的极化 SAR 图像分类[J]. 空军工程大学学报, 2022, 23(5): 36-43.
ZHAO Mingjun, CHENG Yinglei, QIN Xianxiang, et al. A Polarimetric SAR Image Classification Based on Model Fine-Tuning and AM-Softmax[J]. Journal of Air Force Engineering University, 2022, 23(5): 36-43.

极化合成孔径雷达(synthetic aperture radar, SAR)图像分类既可作为极化 SAR 图像解译的输出,也可作为其他解译手段的重要支撑,被广泛应用于民用、军事领域^[1]。从极化 SAR 图像分类的一般步骤来看,主要有特征提取、表示分类器的设计和优化两个主要步骤^[2]。其中针对第一个步骤,传统方法一般基于极化目标分解,对散射特性进行建模和解释,存在特征表示能力弱、特征选择过程复杂等问题。近年来,基于深度学习的方法已经从单通道 SAR 图像发展到极化 SAR 图像^[3]。具体方法有卷积神经网络^[4](convolutional neural network, CNN)、全卷积网络^[5]、深度自编码器^[6]、深度置信网络^[7]等。深度学习可学习图像的高层次语义特征,具有传统方法不具备的优势。其中以 CNN 为代表已成为目前极化 SAR 图像分类中效果最好、最常用的方法。但 CNN 方法也存在一定的弊端,最突出的就是其复杂的计算过程和由此所需的大量训练时间^[8]。基于此许多学者研究模型迁移的方法以减少深度 CNN 的训练时间、加快网络收敛。该方法以预训练网络提取深度特征,再设计相应分类器,构建迁移分类模型^[9-14]。预训练网络作特征提取器可以避免繁复的手工特征提取,加入微调可取得比原网络更好的效果。研究表明深度 CNN 所提取特征具有更丰富的表现力、更强的泛化性能,这有利于处理具有类内差异的遥感数据集^[15]。相应分类器的设计可与深度特征相配合,取得比传统特征更好的分类效果。

极化 SAR 图像由于其成像机制,存在不同类别地物散射特征相似、相同类别地物散射特征不同的情况^[16]。这导致了一些地物类别类内差异大(如城市区域)、一些类别类间差异小(如水体、道路),给细粒度的极化 SAR 图像分类问题造成一定的困难。并且在极化 SAR 图像分类领域, CNN 方法一般以像素邻域图像块作为输入,因此不免存在单一样本包含多类地物的情况。由于 CNN 主要基于 Softmax 函数,虽然能够优化类间差异,但并不要求类内紧致与类间分开,在某些类内差别较大的情况下,难以取得较好的分类效果。

本文针对 CNN 方法的上述缺陷,提出一种基于模型迁移与 AM-Softmax 的极化 SAR 图像分类方法,首先 ImageNet 上预训练的 CNN,考虑到极化 SAR 图像与光学图像具有一定差异,在整体迁移网络上进行微调,使迁移模型在新的目标域数据中提取适合于新任务的深度特征。其次以 AM-Softmax 函数^[17]取代 CNN 常用的 Softmax 分类函数,以应对极化 SAR 图像分类任务中类内差异较大的情况。

1 本文方法

为解决极化 SAR 图像分类中, CNN 方法训练时间长、收敛速度慢,以及 Softmax 函数无法对类内差别较大的极化 SAR 数据有效区分的问题。本文提出一种基于模型微调与 AM-Softmax 的极化 SAR 图像分类方法。首先利用在 ImageNet 上预训练的 VGG-16^[18] 网络作特征提取。最后为缓解类内差异较大带来的错分问题,以 AM-Softmax 作为整体分类模型的分损失函数。整体模型分类过程分为预处理、特征提取、分类器设计、分类结果的输出 4 部分,方法示意如图 1 所示。

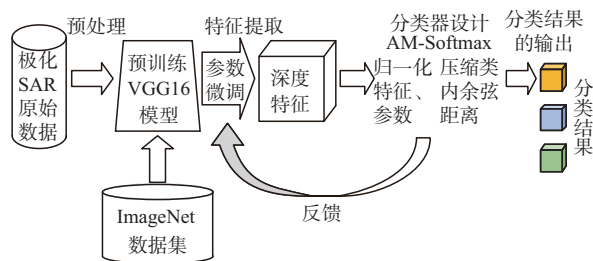


图 1 本文方法示意图

1.1 预处理

在数据预处理方面,为减少相干斑影响,对实验数据均采用加权最小二乘滤波处理^[19]。本文以 20 像素×20 像素的图像块尺寸作为预训练网络输入,并采用双线性插值方法,将图像块尺寸扩充至 40 像素×40 像素。

对于极化 SAR 图像每个像素点可以用相干矩阵的 9 维向量表示:

$$\mathbf{V} = (T_{11}, T_{22}, T_{33}, \text{real}(T_{12}), \text{imag}(T_{12}), \text{real}(T_{13}), \text{imag}(T_{13}), \text{real}(T_{23}), \text{imag}(T_{23})) \quad (1)$$

式中: T_{ij} 为相干矩阵元素; $\text{real}(\cdot)$ 和 $\text{imag}(\cdot)$ 分别为求实部和虚部操作。

由式(1)可知,整幅极化 SAR 图像有 9 个通道。预训练模型要求输入为 3 个通道的归一化数据,本文首先对原始极化 SAR 数据归一化,然后采用主成分分析^[20]法实现数据降维,将排名前 3 的主成分构成的归一化数据作为深度迁移网络的输入。

1.2 深度特征提取

预训练的 CNN 已被证明可提取深度特征的特征提取器^[21],这一过程主要依赖于卷积和池化操作。本文采用在整体特征提取部分微调的方式构建深度迁移网络。深度网络模型如图 2 所示。

根据图 2,深度迁移网络的特征提取部分包括输入层、卷积层、池化层等共 13 层。通过预训练部分整体的参数微调可使深度网络更关注极化 SAR

图像上的分类任务。网络参数迁移使深度网络所提取的特征泛化性能更好,从而有助于应对新数据集上的类内差异。此外,迁移网络无须从头开始训练,大大提高了网络训练效率。



图2 预训练特征提取网络结构图

1.3 分类器设计

Softmax 是深度学习模型常用的分类函数,它与其他分类方法相比可以直接输出分类的概率,具有简单方便的特点^[22]。但 Softmax 并不要求类内紧凑和类间分离,给类内差异较大的分类任务造成了一定的困难^[23]。

Softmax 将输入矢量从 N 维空间映射到类别并返回概率形式的分类结果,Softmax 一般使用交叉熵损失函数:

$$L = \frac{1}{N} \sum_i L_i = -\frac{1}{N} \sum_i \log \left(\frac{e^{f_i}}{\sum_j e^{f_j}} \right) \quad (2)$$

式中: L_i 代表第 i 类的损失; N 代表类别数; f_i 代表最终全连接层输出的第 i 个分量。由于 f 是由该层参数矩阵 \mathbf{W} 与输入向量相乘所得,所以可表示为:

$$L_i = -\log \left(\frac{e^{\|\mathbf{W}_i\| \|x_i\| \cos(\theta_i)}}{\sum_j e^{\|\mathbf{W}_j\| \|x_i\| \cos(\theta_j)}} \right) \quad (3)$$

式中: x_i 代表最终全连接层输入向量 \mathbf{x} 的第 i 个分量; $f_i = \mathbf{W}_i^T \times x_i$, f_i 也被称为第 i 类样本的目标逻辑; θ_i 代表第 i 个类别输入向量与参数矩阵之间的夹角。Softmax 函数在处理二分类问题时的决策函数是:

$$\|\mathbf{W}_1\| \|\mathbf{x}\| \cos(\theta_1) > \|\mathbf{W}_2\| \|\mathbf{x}\| \cos(\theta_2) \quad (4)$$

Softmax 决策函数在处理分类问题时主要根据目标逻辑。当 $f_1 > f_2$ 即判定为第 1 类,反之则判定为第 2 类,在两类之间并没有类间距离的要求也并没有限制类内紧致。因此在处理类内间距较大甚至超过类间间距的问题时,效果会变差^[23]。基于 Softmax 函数的上述缺陷,在人脸识别领域出现了针对 Softmax 的改进函数,文献[23]提出 L-Softmax,通过在参数 \mathbf{W} 与 x 之间增加一个约束变量 m ,从而使分类条件更加苛刻,使得学习到的特征之间具有更大的角度可分离性。在此之后,文献[24]提出了一种 A-Softmax 损失函数,A-Softmax 对原本的 Softmax 损失函数进行了限制,将 $\|\mathbf{W}_i\|$ 设置为 1(即对参数矩阵进行了归一化),并且将偏置设置为 0。

在 L-Softmax 和 A-Softmax 的基础上,文献[17]提出了一种更简便、更适合于深度网络前后向传播的 AM-Softmax 函数,其优异性能已在人脸识别任务中得到了验证。AM-Softmax 借鉴了 L-Softmax 和 A-Softmax 引入约束变量 m 的思想,在类间施加加性边际约束。其在 A-Softmax 参数矩阵归一化和偏置设置为 0 的基础上,对特征也进行归一化。在这种限制下每个类别的目标逻辑只与 $\cos(\theta)$ 有关,AM-Softmax 损失函数可以写为:

$$L_{\text{AMS}} = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s(\cos\theta_i - m)}}{e^{s(\cos\theta_i - m)} + \sum_{j=1, j \neq i}^c e^{s \cos \langle \theta_j \rangle}} \quad (5)$$

式中: $c = N - 1$,超参数 s 用来缩放余弦值;超参数 m 用来控制类间间隔。由式(5)可知,AM-Softmax 损失函数在正向传播过程中只需要计算 $\cos(\theta) - m$,若将 $\cos(\theta)$ 视为未知量,则反向传播过程中的梯度始终为 1,大大方便了神经网络的前后向传播计算。根据 AM-Softmax 的损失函数可推导出其决策边界,以二分类为例在类 1 决策边界处有:

$$\begin{cases} \cos(\mathbf{W}_1, P_1) - m = \cos(\mathbf{W}_2, P_1) \\ \cos(\mathbf{W}_1, P_1) - m = \cos(\mathbf{W}_1, P_2) \end{cases} \quad (6)$$

式中:其中 \mathbf{W}_1 为类 1 的边界向量; P_1 为类别 1 的决策边界;以二分类为例 AM-Softmax 与 Softmax 决策边界的对比如图 3 所示。

由图 3 可知,AM-Softmax 是以决策区域替代决策边界,通过在对每一类别各设置一个决策边界形成一块可移动的固定区域,将两类样本特征向边缘处挤压,从而使不同类别之间的距离加大,相同类别之间更加紧凑,一定程度上克服了 Softmax 类间无间隔、类内不紧致的缺点。

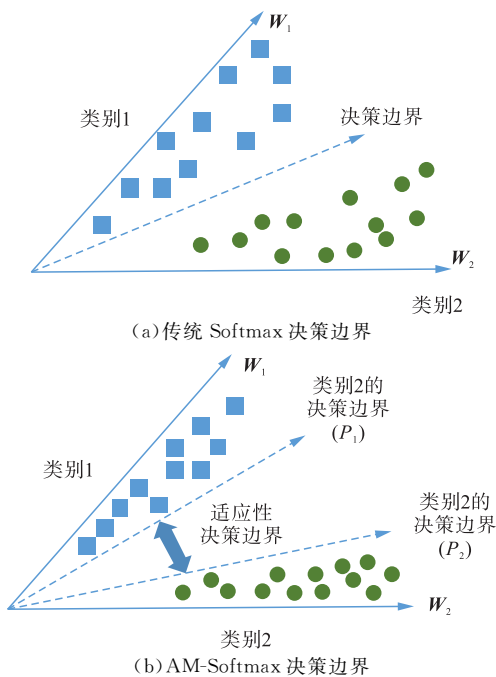


图 3 AM-Softmax 与 Softmax 决策边界对比图


1.4 分类结果的处理

分类模型完成训练后,本文采用逐像素赋予标签的方法,首先将原始图像作预处理得到采样像素点的领域图像块,最后输入至训练好的模型中预测,将预测标签依次赋予给中心点,得到分类结果。为保证图像边界处能够取到足够大小的样本且图像块大小恰好被图像整体的大小整除,本文对整幅极化 SAR 图像进行了零填充。

2 实验设计与结果分析

2.1 实验环境及数据集

为验证本文方法有效性,以深度学习框架 Tensorflow 为实验环境, Tensorflow 为 GPU 2.6.0 版本。实验运行环境为:CPU 配置 11th Gen Intel(R) Core(TM) i5-11260H 2.60Hz、GPU 配置 GeForce RTX 3060 6GB。选取 2 组数据集实验,分别是由机载 SAR 系统拍摄的德国 OberPfaffenhofen 地区的 L 波段数据(数据集 1),以及由美国机载合成孔径雷达(AIRSAR)系统获得的荷兰 Flevoland 地区 L 波段数据(数据集 2)。数据集 1 图像大小为 1 300 像素×1 200 像素,数据集 2 图像大小为 750 像素×1 024 像素。2 组数据的 PauliRGB 图像见图 4。




(a)OberPfaffenhofen 数据 (b)Flevoland 数据

图 4 实验数据


2.2 AM-Softmax 超参数确定

AM-Softmax 中超参数 s 用来缩放余弦值, m 用来控制类间间隔,二者取值影响了 AM-Softmax 的分类性能。为取得两超参数的较优值,取每类 1% 数量标记样本作为训练集,按照 1.4 节所述方法划分测试集,以总体精度为指标,根据文献[17]将 s 设置为 20、30,以 0.5 为步长变化 m (0.1 到 0.9 之间),进行实验,结果折线图如图 5 所示:

根据图 5,在两数据集上各自选择总体精度最高的一组参数即数据集 1 上选择 $s=30, m=0.8$,数据集 2 上选择 $s=30, m=0.25$ 作为本次实验 AM-Softmax 损失函数的超参数。



(a)数据集 1 超参数测试结果



(b)数据集 2 超参数测试结果

图 5 AMSoftmax 参数测试结果图

2.3 预训练网络的选择

为兼顾预训练网络特征提取的有效性和分类结果的准确性,选取 Keras 中 VGG16、ResNet50^[25] 和 MobileNet^[26] 3 种预训练网络进行试验,由于 CNN 的全连接层限制了图像输入尺寸大小^[27],因此去除 3 种网络的全连接层。表 1 为 3 种网络模型的参数对照表。

表 1 预训练模型参数对照

模型	尺寸	层数	大小/MB
VGG16	224×224	23	56.1
ResNet50	224×224	50	90.3
MobileNet	224×224	88	16.4

每一类选取 1% 的标记样本作为训练集,由于一些类别标记样本数量较少,所以设置每一类所取样本至少为 50 个,样本标记情况表如表 2、3 所示。

分类函数(AM-Softmax)、超参数设置保持不变,变换输入尺寸和预训练网络模型,划分训练集和验证集比例为 4 : 1,3 种模型在验证集上的准确率如表 4~5 所示。

以分类模型在验证集上的准确率作为分类模型特征提取能力的评价指标。由表 4~5 可知,3 种预训练模型在不断增加输入图像尺寸的情况下,准确率都得到提高。其中 ResNet50、MobileNet 模型提升较为明显,而 VGG16 模型因为网络的层数较少,对于小尺寸图像具有较好适应度。因此本文选择预训练 VGG16 模型及 40 像素×40 像素的输入尺寸对所提方法进行验证。

表 2 数据集 1 样本标注情况表

样本类别	标注像素个数
建筑区	328 051
森林	246 673
裸地	736 894

表 3 数据集 2 样本标注情况表

类别	标注像素个数
豇豆	6 103
豌豆	9 111
森林	14 944
苜蓿	9 477
小麦 1	17 283
甜菜	10 050
土豆	15 292
裸地	3 078
草地	6 269
油菜	12 690
大麦	7 156
小麦 2	10 591
水	21 300
小麦 3	13 476
建筑物	476

表 4 数据集 1 模型准确率表 单位: %

模型	40 像素× 40 像素	50 像素× 50 像素	100 像素× 100 像素
	VGG16	96.92	97.06
ResNet50	40.43	70.44	89.32
MobileNet	25.3	35.28	85.19


表 5 数据集 2 模型准确率表 单位: %

模型	40 像素× 40 像素	50 像素× 50 像素	100 像素× 100 像素
	VGG16	96.51	97.27
ResNet50	56.21	56.41	94.30
MobileNet	25.23	57.08	89.40


2.4 方法效率比较

为了验证所提方法与传统 CNN 方法相比具有

效率上的优势,将本文方法(方法 1)与 VGG16 网络方法(方法 2)在数据集 1 上进行比较,为保证两种方法损失计算一致,以 AM-Softmax 替代 VGG16 的 Softmax,并保持两种方法超参数设置、样本集设置(均为 1%与 2.3 节一致)、训练集和验证集比例(4:1)、训练次数保持一致(epochs 均为 5),对比结果如图 6 所示:



(a)方法 1、2 在数据集 1 上损失



(b)方法 1、2 在数据集 1 上的准确率

图 6 方法 1 与方法 2 对比图

由图 6 可知,本文方法在初始训练轮次,具有 75.4%的准确率,方法 2 在初始训练轮次仅为 12.3%,在 5 次训练中本文方法已经基本稳定在 97%左右,方法 1 仍然处在优化阶段,且精度为 87.57%。使用早停策略将方法 1 训练至大致收敛,方法 1 与方法 2 训练时间对比如表 5 所示:

由表 6 可知,在训练次数超过 20 次后,方法 2 基本收敛且精度稳定在 93%左右。虽然每轮的训练时间两种方法相差不大,但本文方法仅经过 5 次训练就基本收敛,根据收敛轮次可以得出,本文方法相较于传统 VGGNet 方法节约了大约 60s 的训练时间。

表 6 方法 1 与方法 2 训练时间对比表

方法	训练次数				
	5	10	15	20	25
方法 1/%	96.92	97.02	96.95	96.15	94.02
方法 2/%	87.57	90.26	92.18	93.24	91.18
方法 1 时间/s	35	50	67	83	103
方法 2 时间/s	39	58	79	95	119

2.5 方法准确率比较

为了验证本文方法在准确率上的优势,以 1.4 节

方法划分测试集,将本文方法(方法 1)与 VGG16+Softmax 方法(方法 2)、预训练 VGG16 微调+Softmax 方法(方法 3)、文献[14]所提方法(方法 4:预训练 VGG16 参数复制+Softmax 多层感知机)在两个数据集上进行分类预测准确率比较。在方法比较实验中,训练样本均取 1%(与 2.3 节一致),将所有方法训练到收敛。方法 1、方法 2、方法 3 与方法 4 分类结果如图 7 所示。方法 1、方法 2、方法 3 与方法 4 在两数据集上的分类精度如表 7~8 所示。

由图 7 可知,本文方法在整体结果上取得较好的区域一致性,并在城区等类内差异较大区域错分像素明显少于其它几种方法;方法 3 结果好于本文方法外的其他两种方法,迁移部分的整体微调可以获得在新数据集上优势更明显的深度特征。

由表 7~8 可知,在 2 个数据集上,本文方法均获得 96% 以上的总体分类精度,优于其他几种方法。方法 3 较方法 4 总体精度提升明显,表明预训练网络的参数整体微调可以使迁移模型更关注于新的分类任务;方法 3 相较于方法 2 在两数据集上准确率提高了 3% 左右,表明深度迁移网络在预训练部分整体微调取得比参数随机初始化方法(方法 2)更好的效果。对比方法 1 与方法 3,二者在总体分类精度上相差不大,方法 1 略优于方法 3。但在某些类别上(建筑区、建筑物等)的分类,AM-Softmax 函数明显优于 Softmax 函数。说明 AM-Softmax 与迁移网络特征提取相配合,可以缓解由类内差异导致的错分。

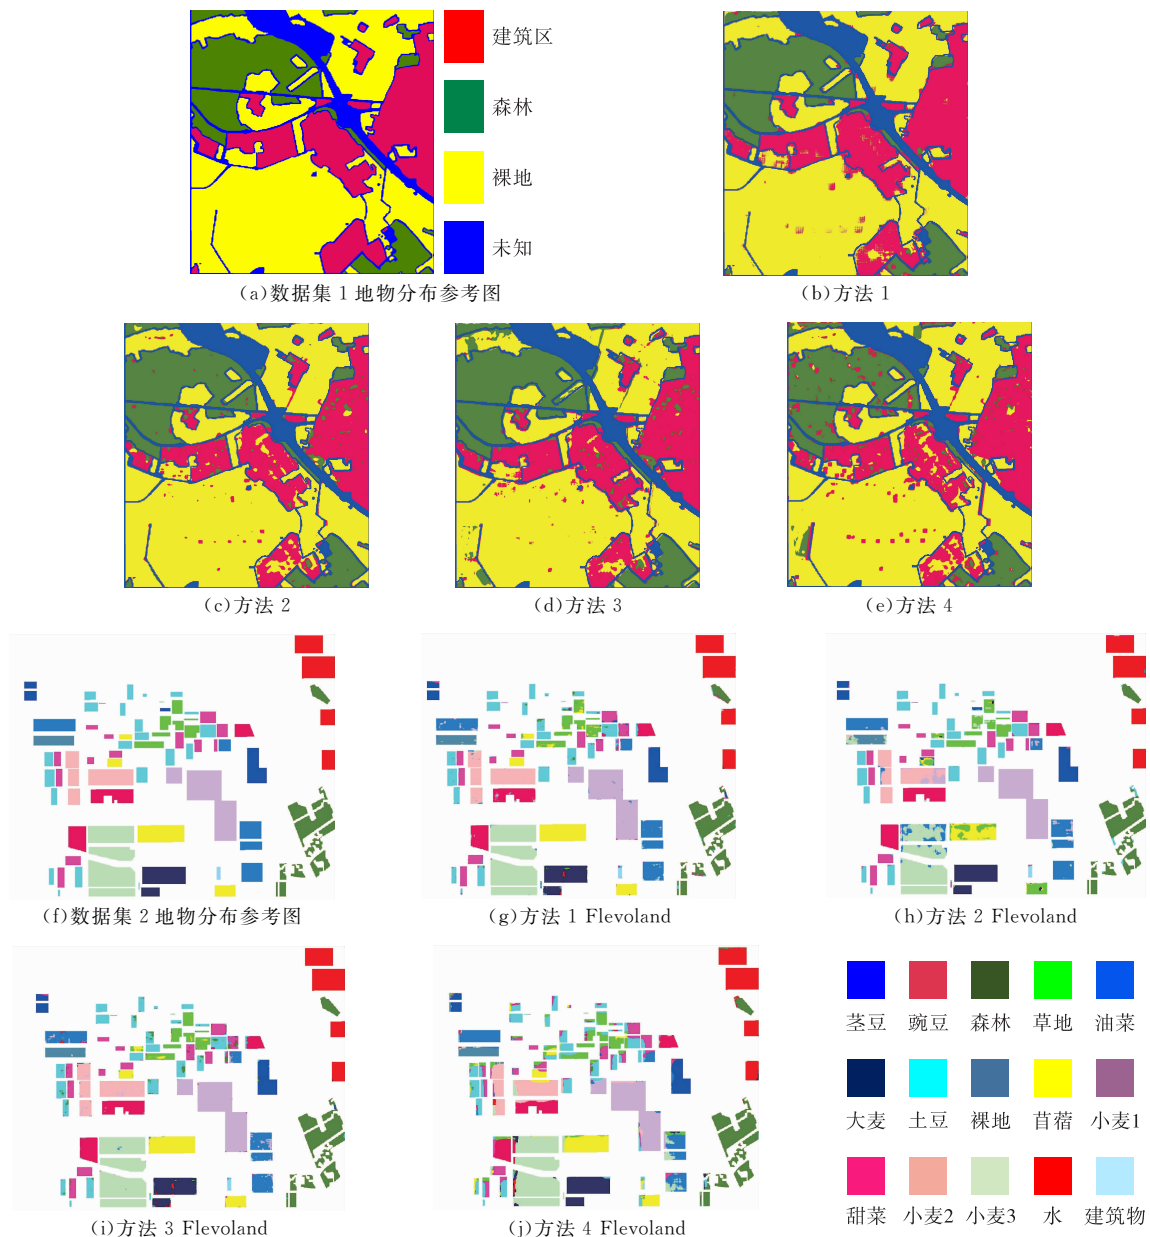


图 7 4 种方法分类结果图

表 7 数据集 1 方法精度对比 单位: %

数据	方法 1	方法 2	方法 3	方法 4
建筑区	95.93	85.60	86.46	85.74
森林	96.32	93.13	98.27	90.44
裸地	96.43	95.42	97.98	95.16
总体分类精度	96.29	92.61	95.15	91.92

表 8 数据集 2 方法精度对比 单位: %

数据	方法 1	方法 2	方法 3	方法 4
豇豆	93.65	97	92.08	83.18
豌豆	94.84	99.63	97.12	84.78
森林	96.07	97.12	99.03	96.00
苜蓿	99.18	54.61	96.48	85.68
小麦 1	98.81	99.99	99.41	92.21
甜菜	94.61	98.67	91.22	63.93
土豆	89.54	99.26	92.30	74.05
裸地	97.40	72.61	99.02	87.91
草地	83.44	87.54	90.15	76.02
油菜	94.14	92.61	88.17	72.88
水	99.66	89.39	99.52	93.35
小麦 2	97.49	81.79	92.97	85.17
小麦 3	99.21	96.92	99.87	98.50
大麦	94.84	99.42	92.83	90.72
建筑物	83.16	76.68	72.89	34.87
总体分类精度	96.39	92.04	95.52	85.76

2.6 分类函数比较

为进一步验证本文方法能缓解类内差异导致的错分问题,选取城区加拿大 radarsat-2 星载极化 SAR 系统拍摄的美国 San Francisco 地区的 C 波段数据(数据集 3)进行分类函数比较实验,其地物分布图如图 8 所示。

在本次实验中,每一类选取 1 000 个样本,选择本文方法和方法 3 进行实验,保持两种方法的超参数设置不变,分类结果如图 9 所示。




图 8 San Francisco 3 类地物分布图



图 9 AM-Softmax 与 Softmax 分类结果对比图

分类精度如表 9 所示:

表 9 AM-Softmax 与 Softmax 分类精度对比表 单位: %

方法	城区	海洋	植被	总体精度
方法 1	99.07	99.91	90.69	98.20
方法 3	89.57	99.17	91.26	94.32

由图 9 可知,本文方法分类结果较好且在红色城区部分的分类明显好于方法 3。根据表 8, AM-Softmax 与 Softmax 在类内差别较小区域(林地和海洋区域),分类性能较为接近。在类内差异较大的区域(城区部分),AM-Softmax 相较于 Softmax 的优势较为明显。Softmax 擅长优化类间差异,不擅长优化类内差异,AM-Softmax 通过加性间隔的设置使深度迁移网络所提取的深度特征类内特征紧致、类间特征分离,在类内差别较大的极化 SAR 图像分类任务中,表现出超越 Softmax 的良好性能。

3 结语

本文针对卷积神经网络方法训练效率低且对类内差异不能有效应对的问题,提出一种基于模型微调与 AM-Softmax 的极化 SAR 图像分类方法。以模型迁移获得效率上的优势并提取深度特征,并结合 AM-Softmax 损失函数从而优化深度特征的类内距与类间距,提升迁移网络在类内变化较大情况下的分类效果。

虽然本文方法取得较好的效果,但特征提取部分网络的参数的微调,较一般模型微调方法大大增加需计算的参数,造成一定的计算负担。本文方法可以快速收敛,但也极易因为参数设置不合理导致整体分类模型过拟合。下一步的研究工作将从源域与目标域之间的相似关系入手,在更小样本条件下以更小的计算代价完成迁移模型分类。

参考文献

- [1] YANG W, ZHANG X, CHEN L, et al. Semantic Segmentation of Polarimetric SAR Imagery Using Conditional Random Fields[C]//2010 IEEE International Geoscience and Remote Sensing Symposium. Honolulu, HI, USA: IEEE, 2010: 1593-1596.
- [2] 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.
- [3] MULLISSA A G, PERSELLO C, REICHE J. Despeckling Polarimetric SAR Data Using a Multi-

- Stream Complex-Valued Fully Convolutional Network [J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19:1-5.
- [4] LI S, WANG H, XU F. General Purpose PolSAR Classifier with Convolutional Neural Network[C]//2018 China International SAR Symposium. Shanghai, China: IEEE, 2018: 1-4.
- [5] MULLISSA A G, PERSELLO C, STEIN A. PolSARNet: A Deep Fully Convolutional Network for Polarimetric SAR Image Classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(12): 5300-5309.
- [6] LIU G, LI Y, JIAO L, et al. Multiobjective Evolutionary Algorithm Assisted Stacked Autoencoder for PolSAR Image Classification[J]. *Swarm and Evolutionary Computation*, 2021, 60: 100794.
- [7] HOU B, LUO X, WANG S, et al. Polarimetric SAR Images Classification Using Deep Belief Networks with Learning Features[C]//2015 IEEE International Geoscience and Remote Sensing Symposium. Milan, Italy: IEEE, 2015: 2366-2369.
- [8] 黄洁, 姜志国, 张浩鹏, 等. 基于 CNN 的遥感图像舰船目标检测[J]. *北京航空航天大学学报*, 2017, 43(9): 1841-1849.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet Classification with Deep Convolutional Neural Networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [10] SHARIF R A, AZIZPOUR H, SULLIVAN J, et al. CNN Features off-the-Shelf: An Astounding Baseline for Recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. [S. l.]: IEEE, 2014: 806-813.
- [11] 余东行, 张保明, 赵传, 等. 联合 CNN 与集成学习的遥感影像场景分类[J]. *遥感学报*, 2020(6): 718-729.
- [12] 胡涛, 李卫华, 秦先祥. 基于多层深度特征融合的极化合成孔径雷达图像语义分割[J]. *中国激光*, 2019(2): 1-8.
- [13] 刘晨, 曲长文, 周强, 等. 基于 CNN 迁移学习的 SAR 图像目标分类[J]. *现代雷达*, 2018, 40(3): 38-42.
- [14] 任硕良, 索继东, 佟禹. 卷积神经网络结合迁移学习的 SAR 目标识别[J]. *电光与控制*, 2020, 27(10): 37-42.
- [15] ZHAO L, ZHANG W, TANG P. Analysis of the Inter-Dataset Representation Ability of Deep Features for High Spatial Resolution Remote Sensing Image Scene Classification[J]. *Multimedia Tools and Applications*, 2019, 78(8): 9667-9689.
- [16] 管冬冬. 高分辨率 SAR 图像地物分类技术研究[D]. 长沙: 国防科技大学, 2019.
- [17] WANG F, CHENG J, LIU W, et al. Additive Margin Softmax for Face Verification[J]. *IEEE Signal Processing Letters*, 2018, 25(7): 926-930.
- [18] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition [J]. *Computer Science*, 2014, 14(9): 1556-1570.
- [19] REN Y, YANG J, ZHAO L, et al. A Global Weighted Least-Squares Optimization Framework for Speckle Filtering of PolSAR Imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 57(3): 1265-1277.
- [20] SCHÖLKOPF B, RÄTSCH G. Kernel PCA and Denoising in Feature Spaces[J]. *Advances in Neural Information Processing Systems*, 2008, 11: 536-542.
- [21] MIDDELMANN W, EBERT A, THOENNESSEN U. Automatic Target Recognition in SAR Images Based on a SVM Classification Scheme[J]. *Adaptive & Natural Computing Algorithms*, 2007, 4432(102): 492-499.
- [22] 万磊, 佟鑫, 盛明伟, 等. Softmax 分类器深度学习图像分类方法应用综述[J]. *导航与控制*, 2019, 18(6): 1-11.
- [23] LIU W, WEN Y, YU Z, et al. Large-Margin Softmax Loss for Convolutional Neural Networks[C]//Proceedings of 33rd International Conference on Machine Learning. New York, City, NY, USA: [s. n.], 2016: 507-516.
- [24] LIU W, WEN Y, YU Z, et al. Sphreface: Deep Hypersphere Embedding for Face Recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu HI, USA: IEEE, 2017: 212-220.
- [25] HE K, ZHANG X, REN S, et al. Identity Mappings in Deep Residual Networks[C]//European Conference on Computer Vision. [S. l.]: Springer International Publishing, 2016: 630-645.
- [26] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications [EB/OL]. (2017-04-17) [2022-02-22]. <https://arxiv.org/abs/1704.04861>.
- [27] KRISHNA G S, PRAKASH N. Deep Learning for Efficient and Multi-Labelled Classification of Synthetic Aperture Radar Images[J]. *Evolving Systems*, 2021, 12(3): 741-754.