DOI: 10.12086/oee.2018.170432

基于随机卷积特征和集成超限 学习机的快速 SAR 目标识别

谷雨^{1*},徐英²

¹杭州电子科技大学通信信息传输与融合技术国防重点学科实验室,浙江杭州 310018; ²杭州电子科技大学生命信息与仪器工程学院,浙江杭州 310018

摘要:深度卷积神经网络在目标检测与识别等方面表现出了优异性能,但将其用于 SAR 目标识别时,较少的训练样本 和深度模型的优化设计是必须解决的两个问题。本文设计了一种结合二维随机卷积特征和集成超限学习机的 SAR 目标 识别算法。首先,随机生成具有不同宽度的二维卷积核,对输入图像进行卷积与池化操作,提取随机卷积特征向量。其次, 为提高分类器的泛化能力,并降低训练时间,基于集成学习思想对提取的卷积特征进行随机采样,然后采用超限学习机 训练基分类器。最后,通过投票表决法对基分类器的分类结果进行集成。采用 MSTAR 数据集进行了 SAR 目标识别实验, 实验结果表明,由于采用的超限学习机具有快速训练能力,训练时间降低了数十倍,在无需进行数据增强的情况下,分 类精度与采用数据增强和多层卷积神经网络的深度学习算法相当。提出的算法具有实现简单、需要调整参数少等优点, 采用集成学习思想提高了分类器的泛化能力。 关键词:深度学习;卷积特征;随机化;超限学习机;集成学习

中图分类号: TN957.52 文献标志码: A

引用格式:谷雨,徐英.基于随机卷积特征和集成超限学习机的快速 SAR 目标识别 [J]. 光电工程, 2018, 45(1): 170432

Fast SAR target recognition based on random convolution features and ensemble extreme learning machines

Gu Yu^{1*}, Xu Ying²

¹Fundamental Science on Communication Information Transmission and Fusion Technology Laboratory, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China;

²College of Life Information Science & Instrument Engineering, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China

Abstract: Deep convolution neural network has demonstrated excellent performance in target detection and recognition tasks. However, few training samples and optimization design of deep models are two main problems to be solved when applied to SAR target recognition. This paper proposes an algorithm for SAR target recognition by combination of two dimensional random convolution features and ensemble extreme learning machines. Firstly, two dimensional random convolution kernels with different widths are generated, and convolution and pooling operations are performed in input image to extract random convolution feature vectors. Secondly, random samplings based on ensemble learning theory are done for extracted feature vectors to improve generalization performance of classifier and reduce training time, and base classifiers are then trained by extreme learning machines (ELM).



Article

2018年,第45卷,第1期

收稿日期: 2017-08-21; 收到修改稿日期: 2017-11-24

基金项目: 国家自然科学基金 (61375011) 项目

作者简介:谷雨 (1982-),男,博士,副教授,主要研究方向是多源信息融合。E-mail: guyu@hdu.edu.cn

Finally, majority vote method is adopted to combine the classification results of base classifiers. SAR target recognition experiments based on MSTAR database were performed, and experimental results demonstrate that, training time has dropped by ten times due to fast training capability of ELM, and the proposed algorithm achieves comparable classification performance with deep-learning-based methods which use data augmentation and multiple convolution layers. The proposed algorithm has the advantages of easy implementation and fewer adjustable parameters, and improves classifier's generalization performance through adoption of ensemble learning ideas. **Keywords:** deep learning; convolution features; randomization; extreme learning machine; ensemble learning **Citation:** Gu Y, Xu Y. Fast SAR target recognition based on random convolution features and ensemble extreme learning machines[J]. *Opto-Electronic Engineering*, 2018, **45** (1): 170432

1 引 言

SAR(synthetic aperture radar) 图像自动目标识别是 SAR 图像解译的一个重要研究方向。SAR 图像目标识 别使用数据处理方法对目标进行分类与识别,其工作 过程为,首先在 SAR 图像中找出感兴趣区域,然后对 每一个感兴趣区域进行分类判断出类别^[1]。SAR 图像 目标识别在国民经济和国防建设中有着广泛的应用, 如海洋监测系统、军事目标识别、矿藏探测等。

特征提取和分类器设计是提高 SAR 图像识别精度 需考虑的两个关键要素^[1]。基于主成分分析^[2]等的特 征提取方法利用各种数学变换改善特征空间中原始特 征的分布,从而实现压缩特征维数、去除冗余特征的 目的。通过对图像进行分析与处理可提取峰值、纹理、 边缘等计算机视觉特征和电磁特征等用于 SAR 目标分 类^[34]。目前用于 SAR 目标识别的分类器主要包括基 于模板匹配的方法、基于支持向量机的方法^[5]、基于 集成学习的方法^[6] 和基于稀疏表示的方法^[79]等。

基于海量大数据与深度学习技术学习得到的特 征在很多场景下优于人工设计的特征,目前已在人

脸识别、自然语言处理等方面取得了性能的极大提 升。自 Hinton 等^[10] 提出用于深度信任网络训练的有 效算法以来、学者提出了多种有效的深度学习模型 与算法。目前基于卷积神经网络(convolution neural network, CNN)的深度模型已经应用于 SAR 图像目 标识别^[11-12],实验结果表明,通过对模型结构进行优 化设计,能够提高 SAR 目标识别的精度。虽然能够 取得较高的识别精度,但是基于深度卷积神经网络的 SAR 目标识别方法需解决以下难题:1) 受目标方位角 和平台俯视角等因素影响,构建较完备的 SAR 图像训 练集十分困难。目前通常采用数据增强手段产生虚拟 训练样本^[11-12]: 2) 虽然已经提出了许多有效的用于目 标识别的 CNN 模型结构,但是主要用于可见光图像 的分类, 而 SAR 图像中存在较强的相干斑噪声^[11];3) 需要较长的时间训练深度模型参数,同时容易出现过 拟合现象。文献 [13] 研究表明,采用随机生成的卷积 核对图像进行滤波,通过合理地设计分类器,提取的 特征也能够取得优异的分类效果。



图 1 基于随机卷积特征和集成超限学习机的 SAR 目标识别算法流程图

Fig. 1 Flowchart of SAR target recognition algorithm based on random convolution features and ensemble extreme learning machines

为提高 SAR 图像目标识别的识别率,并提高识 别算法的速度,提出了一种融合随机卷积特征和集成 超限学习机^[13-14]的 SAR 图像目标识别方法。采用二 维随机卷积核对原图像进行滤波,从而实现特征提 取,由于卷积核为随机生成,无需要通过大量样本训 练得到。超限学习机是具有单个隐层的前馈神经网 络,具可调参数少和快速学习等优点,通过集成学习 思想能够提高分类器的泛化能力,从而满足了 SAR 图像目标识别准确率和实时性两方面的要求。实验验 证了提出算法的有效性。

2 基于随机卷积特征和集成超限学 习机的 SAR 目标识别算法

如图 1 所示,提出的基于随机卷积特征和集成超 限学习机的 SAR 目标识别算法首先对输入图像进行 裁剪与缩放,获得目标切片图像;然后采用随机生成 的多个具有不同宽度的卷积核对目标切片图像进行 滤波与池化操作,实现随机卷积特征提取;为提高分 类器的泛化能力,基于集成学习思想^[15],先对提取 的随机卷积特征向量进行抽样,然后采用超限学习机 进行分类器训练,最后采用投票表决获得目标的真实 类别。

2.1 二维随机卷积特征

采用深度卷积神经网络设计 SAR 目标识别模型时, 需要解决训练样本构建、深度模型结构设计、优化算 法和超参数选择等几个方面^[16-17]。由于采用随机生成 的卷积核对图像进行滤波与池化,提取的特征提取也 具有较强的分辨能力,考虑到 SAR 图像具有较强的相 干斑噪声,本文提取 SAR 目标特征时,随机生成一定 数量具有不同宽度的二维卷积核,采用这些卷积核对 SAR 图像目标切片进行滤波,基于滤波后的图像生成 特征向量。

根据 SAR 图像中目标的分辨率,设定二维卷积 核的宽度范围集合为Ω,首先随机选择卷积核的宽度, 然后根据式 (1) 生成 *N* 个二维卷积核 *Kernel*:

$$Kernel_m(i,j) = 2 \times rand() - 1, \tag{1}$$

式中: *i*, *j* 分别表示二维卷积核的行列坐标, *m*=1,…, *N* 表示二维卷积核的索引, *rand*() 产生位于区间 [0, 1] 均匀分布的随机数。

采用生成的二维卷积核 Kernel_{m=1}, ..., N 对目标切片

图像 I_n 进行滤波, 如式 (2) 所示:

$$F_n^m = Kernel_m * padding(I_n), \tag{2}$$

式中: I_n 为输入目标切片图像,分辨率为 $W \times W$, F_n^m 表示计算得到的二维卷积特征, *Kernel_m* 为第 *m* 个卷 积核, * 表示卷积操作, *padding*(I_n) 表示根据卷积核 的宽度对 I_n 边缘用 0 进行填充,使得 F_n^m 与 I_n 的大小 保持一致。

为使获得的二维随机卷积特征对目标平移具有 一定的不变性,采用均方池化操作进行特征变换^[13], 如式 (3) 所示:

$$P_n^m(i,j) = \sqrt{\sum_{p=i}^{i+r-1} \sum_{q=j}^{j+r-1} F_n^m(p,q)^2} , \qquad (3)$$

其中: *i*, *j* = 1, …, *W*+1-*r*, *r* 为池化操作进行的区域 宽度。

将经过池化操作后的二维卷积特征 P_n^m 拉伸成列 向量,此列向量的维数为 $[(W+1-r)^2 1]$,并将这 N 个 特征向量按照顺序连接成一个维数更大的特征向量f, 该特征向量的维数为 $[N \times (W+1-r)^2 1]$ 。

2.2 基于集成超限学习机的分类器训练

集成学习算法通过合并一组基分类器来提高分 类器的性能^[15],由于提取的二维随机卷积特征具有 较高的维数,拟对提取的特征向量进行随机抽样以达 到降维目的,然后采用超限学习机训练得到基分类 器,最后通过投票表决来确定目标类别。

2.2.1 基于随机抽样的特征选择

设待训练的分类器数目为 *C*,对于第 *k* 个分类器 而言,根据提取的特征向量维数,基于式 (4) 和式 (5) 生成特征索引。

$$index = floor(linspace(1, N \times (W + 1 - r)^2, N + 1)), \quad (4)$$
$$Clasind_k(i) = randi(index[i], index(i + 1),$$

$$floor((W+1-r)^2/C))$$
 , (5)

其中: *linspace*(*x*, *y*, *n*) 表示生成元素个数为*n* 的等差数列, *x* 为起点, *y* 为终点。*floor*() 表示向下取整, *randi*(*x*, *y*, *n*) 表示随机生成 *n* 个位于区间 [*x*, *y*] 均匀分布的整数向量。*Clasind*_k(*i*) 表示第*k* 个分类器对应的特征索引, *i* 的取值范围为 1,…, *N*。

采用式 (4) 和式 (5) 相当于采用随机抽样的方式 对每个卷积核提取的二维卷积特征进行特征选择,一 方面起到了降维的目的,另一方面是期望通过随机方 式获得目标的可能有效特征组合。

2.2.2 基于超限学习机的基分类器训练

超限学习机 (extreme learning machine, ELM) 为 具有单个隐层的前馈神经网络,通过对输入层与隐层 间的权重进行随机化处理,提高了分类与回归等任务 的泛化能力^[14]。ELM 算法已经成功应用于高光谱图 像分类,并取得了较高的分类精度^[18]。超限学习机 的分类模型为^[14]

$$f_{L}(x) = \sum_{i=1}^{L} \beta_{i} h_{i}(x) = h(x)\beta , \qquad (6)$$

其中: $h_i(x) = G(a_i, b_i, x)$ 为隐层输出响应值,G为 隐层可采用的激活函数, $x = R^d$,为d维输入特征 向量, $a_i = R^d$,为输入层和隐层间的随机连接权重, $b_i = R$,为偏移值,L为隐层节点个数, β 为输出权 重向量。设训练样本数目为M,目标类别数目为B, ELM 优化的目标函数可表示为^[14]

$$\min_{\alpha_{1}=p\mid \forall M} \lambda \left\| \boldsymbol{H} \boldsymbol{\beta} - \boldsymbol{T} \right\|_{p}^{\delta_{1}} + \left\| \boldsymbol{\beta} \right\|_{q}^{\delta_{2}}, \tag{7}$$

式中: $\delta_1 > 0, \delta_2 > 0, p, q = 0, 1, 2 \cdots, +\infty$, λ 为正则化参数, *H* 为隐层节点输出的随机矩阵, *T* 为目标类别向量, 如式 (8) 所示:

$$\boldsymbol{T} = \begin{bmatrix} \boldsymbol{t}_{1}^{1} \\ \vdots \\ \boldsymbol{t}_{M}^{T} \end{bmatrix} = \begin{bmatrix} \boldsymbol{t}_{11} & \cdots & \boldsymbol{t}_{1B} \\ \vdots & \vdots & \vdots \\ \boldsymbol{t}_{M1} & \vdots & \boldsymbol{t}_{MB} \end{bmatrix} \circ$$
(8)

当 δ₁=2, δ₂=2, *p*=2, *q*=2 时,式 (7) 具有闭环解, 具体如式 (9) 和式 (10) 所示:

$$\boldsymbol{\beta} = \boldsymbol{H}^{\mathrm{T}} \left(\frac{I}{\lambda} + \boldsymbol{H} \boldsymbol{H}^{\mathrm{T}} \right)^{-1} \boldsymbol{T} \quad , \quad M \leq L \; , \qquad (9)$$

$$\boldsymbol{\beta} = \left(\frac{\boldsymbol{I}}{\boldsymbol{\lambda}} + \boldsymbol{H}^{\mathrm{T}}\boldsymbol{H}\right)^{-1}\boldsymbol{H}^{\mathrm{T}}\boldsymbol{T} \quad , \quad M > L \; , \qquad (10)$$

其中 I 为单位矩阵。

将所有训练样本提取得到的特征向量按列进行 排列构成特征矩阵 *F*,训练第 *k* 个基分类器时,根据 式 (5)得到的特征索引生成特征子矩阵 *F_k*,然后采用 超限学习机训练得到弱分类器。由于已经通过随机化 生成二维卷积核,并对输入图像进行卷积核池化操 作以实现特征提取,采用 ELM 算法进行分类器训练 时,设定 $H=F_k^{T}$,根据训练样本标签确定 *T*,利用式 (9) 或式 (10)求取输出层权重向量 $\beta_k^{[13]}$ 。

2.2.3 基于投票表决的分类器集成与目标识别

对测试图像提取特征向量,对特征向量进行随机 抽样生成新的特征向量,利用训练得到的分类器进行 目标类别预测,并对所有分类器结果进行投票表决, 确定目标的类别。具体步骤如下:

对于一个测试样本,设提取的特征向量为f,根

据第 k 个分类器所对应的特征索引 $Clasind_k$ 对特征 f进行采样得到降维后的特征 f_k ,利用式 (11) 求解得到 一个 1 × B 的向量,向量中的每个值代表属于某一类 别的概率,通过式 (12) 求得最大位置处的索引即为 目标的类别 $Label_k$ 。

$$v_k = f_k^{\mathrm{T}} * \beta_k \quad , \tag{11}$$

$$[\sim, Label_k] = \max(v_k) \quad \circ \tag{12}$$

根据 Bagging 算法思想^[19],对所有 C 个分类器的结果进行投票表决,从而确定目标的最终估计类别,如式 (13) 所示。

 $Label = MajorityVote(Label_k)_{k=1\cdots C} \quad (13)$

3 实验结果分析

为验证提出算法的有效性,采用 MSTAR 数据集 来测试算法的性能。MSTAR 数据集^[20] 中的 SAR 图 像是通过 HH 极化、0.3 m×0.3 m 分辨率、X 波段的 SAR 传感器采集到的,包括混合目标在内总计 10 类 目标。采用的训练样本数和测试样本数分别如表1所 示,其中训练样本的俯视角为17°,测试样本的俯视 角为 15°, 部分型号目标的 SAR 图像及相应可见光 图像如图 2 所示。进行目标识别前,首先对原始 SAR 图像进行预处理,通过滤波算法降低相干斑噪声影 响,并提取 SAR 目标切片图像。核宽为 3×3 的采用 均值滤波算法对输入 SAR 图像进行滤波, 以图像平 面二维中心点为坐标原点,提取尺寸大小为 64×64 的目标区域图像,将其进行尺度缩放,使图像分辨率 降低为 32 × 32, 除以 255.0, 使得图像灰度等级位于 区间 [0,1]。对于不同操作条件下 MSTAR 数据集中 的目标进行识别,评价指标选择总体分类精度 (overall accuracy, OA) 和平均分类精度 (average accuracy, AA)。

3.1 算法参数分析与选择

提出的算法主要参数包括:卷积核个数 N,卷积 核宽度集合 Ω ,集成分类器的个数 C和正则化系数 λ 。 根据文献 [13] 的研究结果,当卷积核的个数超过一 定数目时,分类精度趋于稳定。考虑分类精度和算法 实时性的相互影响,设定用于特征提取的二维卷积核 个数 N= 48。

采用超限学习机训练分类器时,由于正则化系数 λ 对分类器的泛化能力影响较大,首先设定 *N*=48, *C*= 8, **Ω** = [3 5 7 9 11 13],采用文献 [12] 的配置,即 无变形目标情况,分析正则化参数 λ 对分类精度的影 响。由式 (2) 可知, λ 越大,则目标函数中分类错误 带来的损失越大,故在保证训练精度的前提下,适当 减小 λ 值,能提高分类器的泛化能力。从表 2 可以看 出, λ = 0.01 时目标分类精度最高, λ 逐渐增大时,分 类精度呈下降趋势,故在后面的实验中取 λ = 0.01。

根据集成学习理论,当采用多个弱分类器合成强 分类器时,能够提高分类器的泛化能力。从表 3 中可 以看出,提取二维卷积特征时虽然卷积核为随机生 成,但是由于采用了具有不同宽度的卷积核对输入图 像进行滤波,能够捕捉到目标不同尺度的特征,因 此在不进行特征随机抽样的情况下(*C*=1)训练集成 分类器,总体分类精度达到了 95.71%。当采用更多 分类器进行投票表决时,总体分类精度有一定提高, 达到了 97.53%,这说明通过特征随机抽样的方式, 在一定概率下能够获得利于目标分类识别的有效特 征组合,通过多分类器集成的方式能够保证 SAR 目标 识别的泛化能力。当分类器数目为 8 时,取得最高的 总体分类精度,故后续实验中设定分类器数目 *C*= 8。

与文献 [13] 不同,本文提出算法采用了具有不同宽度的卷积核提取随机卷积特征,从表4可以看出,采用宽度为3的卷积核比采用宽度为9的卷积核的总体分类精度低5.19%,这说明对于 SAR 目标而言,采用较大的卷积核宽度更利于提取目标的局部特征信息,当卷积核宽度为9时取得最高的分类精度。本文考虑不同卷积核宽度提取的目标特征尺度不同,为保证分类器的泛化能力,设定卷积核宽度集合为 $\Omega = [3, 5, 7, 9, 11, 13],采用随机抽样的方式,首先确定卷积核的宽度,然后再根据选定的卷积核宽度根据一定的概率分布生成随机的卷积核。$

表 1 MSTAR 数据集描述 Table 1 Description of MSTAR database

日标米刑	201		D7	TEO	ZIL	7011024	DTDCO		BMP2		BTR70		T72	
日你天空	231	DRDIVIZ	DI	102	131	230234	DIROU	SN9563	SN9566	SNC21	SNC71d	SN132	SN812	SNS7
训练样本数	299	298	299	299	299	299	256	233	/	1	233	232	/	/
测试样本数	274	274	274	273	274	274	195	195	196	196	196	196	195	191



图 2 MSTAR 数据集中部分型号目标 SAR 图像及对应可见光图像

Fig. 2 SAR images and their corresponding visible images of partial types of targets in MSTAR database

表 2 正则化系数 λ 对分类精度的影响

Table 2 Influence of regularization parameter λ on classification performance

表 3 集成分类器数目对分类精度的影响 Table 3 Influence of number of ensemble classifiers on classification performance

λ	AA/%	OA/%	分类器数目	AA/%	OA/%
0.01	97.53	97.44	1	96.08	95.71
0.1	97 49	97 28	2	97.52	97.32
4	05.00	00.00	4	97.66	97.53
1	95.32	90.68	6	97.64	97.48
10	91.30	90.17	8	97.62	97.53
100	88.99	88.29	10	97.49	97.48

Table 4 Influence of convolution kernel width on classification performance

宽度	AA/%	OA/%
3	92.06	92.58
5	96.82	96.82
7	97.63	97.61
9	97.91	97.77
11	97.78	97.69
13	97.73	97.57

3.2 实验结果分析与比较

在标准操作条件下 (standard operating condition, SOC) 对 10 类混合目标进行分类,由于卷积核为随 机生成,共进行了 5 次蒙特卡洛模拟分类实验,最 优的分类精度如表 5 和表 6 所示。表 5 和表 6 的区别 主要在于采用的测试样本不同,从表 1 中可以看出, BMP2 和 T72 存在 3 个不同的型号,即变形目标情况。 文献 [12] 中训练样本和测试样本的型号相同,而文献 [11] 中采用 BMP2 和 T72 的一个型号作为训练样本, 测试样本采用了所有 3 个型号的样本。从表 5 和表 6 的分类结果可以看出,由于存在变形目标情况,故后 一种情况的分类精度略低。

分类实验采用如下 PC 机硬件配置: CPU 为 Intel(R) Core(TM) i5-3230M @2.6 GHz,内存为 12 GB, 显卡为 NVIDIA NVS5400M,2 G 独立显存;采用的 Matlab 版本为 Matlab 2017a。基于上述配置利用本文 算法实现一次分类识别过程总计需要约 15 min,主 要过程包括图像读入、卷积特征提取、分类器训练与 测试,其中卷积特征提取未采用 GPU 加速。表7 为 本文算法与文献 [11] 和文献 [12] 算法的性能对比。 从表7 中可以看出,提出算法的平均分类精度优于文 献 [11] 算法的性能,当采用文献 [12] 的训练条件时,

表 5 10 类目标分类混淆矩阵 (文献 [12] 配置) Table 5 Confusion matrix for classification of target with ten classes (Ref[12]'s configuration)

	2S1	BRDM2	D7	T62	ZIL131	ZSU234	BTR60	BMP2	BTR70	T72	No.	正确率 /%
2S1	266	0	0	3	0	0	1	1	2	1	274	97.08
BRDM2	0	252	0	0	6	0	1	0	12	3	274	91.97
D7	1	1	272	0	0	0	0	0	0	0	274	99.27
T62	1	0	0	268	0	0	0	0	2	2	273	98.17
ZIL131	0	0	0	0	273	1	0	0	0	0	274	99.64
ZSU234	0	0	3	1	0	269	0	0	0	1	274	98.18
BTR60	0	2	0	2	1	0	190	0	0	0	195	97.44
BMP2	0	0	0	0	0	0	0	189	3	4	195	96.43
BTR70	0	0	0	0	0	0	0	0	196	0	196	100
T72	0	0	0	0	0	0	0	3	1	192	196	97.96
AA												97.61
OA												97.57

表 6 10 类目标分类混淆矩阵 (文献 [11] 配置) Table 6 Confusion matrix for classification of target with ten classes (Ref[11]'s configuration)

类别	2S1	BRDM2	D7	T62	ZIL131	ZSU234	BTR60	BMP2	BTR70	T72	No.	正确率 /%
2S1	267	0	0	4	0	0	0	2	1	0	274	97.45
BRDM2	3	256	2	0	3	0	0	1	6	3	274	93.43
D7	1	0	272	0	0	0	0	0	1	0	274	99.27
T62	0	0	0	270	0	0	0	0	0	3	273	98.90
ZIL131	0	0	0	0	271	0	0	1	1	1	274	98.91
ZSU234	0	0	2	2	0	270	0	0	0	0	274	98.54
BTR60	0	4	0	2	0	0	189	0	0	0	195	96.92
BMP2	0	0	0	0	0	0	0	525	23	39	587	89.44
BTR70	0	0	0	0	0	0	0	0	196	0	196	100
T72	0	0	0	0	0	0	0	21	9	552	582	94.85
AA												96.77
OA												95.79

表4 卷积核宽度对分类精度的影响

	总体分类 (不同训练		数据增强	训练时间 (包括特征提取)
文献 [11] 算法	93.16		需要	几小时 ~ 几天
文献 [12] 算法		99.13	需要	几小时 ~ 几天
本文算法	95.79	97.57	不需要	十几分钟

表 7 与基于深度卷积神经网络的 SAR 目标识别算法性能比较

Table 7 Comparison of target recognition performance between the proposed algorithm and deep-learning-based algorithm

本文算法的分类精度达到 97.57%, 略低于文献 [12] 算法的分类精度 99.13%。但是本文算法的训练时间 更短,同时由于采用了较少的卷积核,因而识别速度 也大大提高。提出的算法因不需要进行数据增强操 作,因而算法设计较基于深度卷积神经网络的识别算 法更适合较少样本情况下的目标分类问题,提出的算 法具有实现简单、可调参数少和训练速度快等优点。 当存在变形目标情况时,本文算法的分类精度略高于 文献 [11] 的分类精度,比较文献 [11] 和文献 [12] 设 计的深度神经网络结构可以看出, 文献 [11] 仅采用 了 3 × 3 的卷积核, 而文献 [12] 采用了更大宽度的卷 积核, 卷积核宽度包括 3×3 、 $5 \times 5 \times 6$ 年 6 年 , 这也 进一步验证了表 4 的结果, 即对于 SAR 图像目标识 别而言,由于具有较强的相干斑噪声,且目标分辨率 较低, 故应采用较大的卷积核提取目标的局部特征进 行分类。本文提出的算法借鉴了基于深度卷积神经网 络的 SAR 目标识别算法的设计思想,但是采用了随 机生成的具有不同宽度的卷积核,并采用随机抽样 方式进行特征降维,基于集成学习思想设计分类器, 虽然卷积核为随机生成,但是经过多次蒙特卡罗仿真 表明,提出的算法能够保证 SAR 目标识别精度。

除了上述标准操作条件下 (SOC)10 类混合目标 分类实验外,文献 [21] 给出了两种扩展操作条件 (EOC-1, EOC-2) 下的分类实验。在 EOC-1 情况下, 采用表 1 中 BMP2, BTR70, BRDM-2 和 T72 的四类 目标的训练样本训练得到分类器,然后对 T72 的 5 种不同型号的测试样本进行分类,测试样本型号、俯 视角和数目,如表 8 所示。EOC-1 分类实验主要测 试分类器对变形目标的分类能力。比较表 8 和表 5 的 分类结果可以看出,对 T72 的分类精度由 94.85% 下 降至 85.90%,其中型号 A64 的分类精度最低,低至 73.65%。

在 EOC-2 情况下,采用表 1 中 2S1, BRDM2,

T72 和 ZSU234 四类目标的训练样本训练分类器,测 试样本为俯视角为 30°时获得的目标样本图像,T72 采用的型号为 A64。EOC-2 分类实验主要测试分类器 在较大俯视角差异情况下的目标分类能力,实验结果 如表 9 所示。从表 9 中可以看出,除 T72 的 A64 型 号分类结果非常低以外,其他类型目标的分类结果均 较高。一个可能的原因是由原始的 SAR 回波数据生 成 SAR 幅值图像时,采用的对比度增强算法虽然对 大部分图像均能取得较好的可视效果,但是对于目标 分类识别而言不一定适合,故导致实验中采用的 T72 A64 目标与其它类型的目标区分度降低,导致分类效 果差。

文献 [21] 给出了 SVM、Boosting 等几种典型分类 算法的分类结果,结合基于深度学习的 SAR 目标识别 结果,对本文算法共进行了 5 次蒙特卡洛模拟实验, 实验结果对比如表 10 所示。本文提出算法和文献 [21] 算法均采用了集成学习思想,从表 10 可以看出,提 出的算法性能和文献 [21] 提出的判别图模型结果相 近。但是本文算法的实现更简单,可调参数少,训练 速度高,对于常规目标和变形目标情况均能进行有效 识别。为验证 SAR 图像转换过程中对比度自动增强算 法对识别结果的影响,将采用原始 SAR 图像进行训 练和测试的算法记为 RCFEELM,采用不进行对比对 自动增强算法的 SAR 图像训练集和测试集的算法记为 RCFEELM-NEW,从表 10 中可以看出,在 EOC-1 和 EOC-2 两种情况下,目标平均分类精度均有大幅提升。

4 结 论

本文提出了一种融合随机卷积特征和集成超限 学习机的 SAR 目标识别方法,充分利用了具有不同 宽度的卷积核能够提取目标多尺度特征的特点,同时 采用集成学习思想,通过对特征进行重采样的方式训

类别	型号	俯视角 / °	数量	BMP2	BRDM2	T72	BTR70	正确率 /%
	S7	15,17	419	12	0	389	18	92.84
	A32	15,17	572	16	54	488	14	85.31
T72	A62	15,17	573	1	33	528	11	92.15
	A63	15,17	573	5	55	501	12	87.43
	A64	15,17	573	34	63	422	54	73.65
AA								86.28
OA								85.90

表 8 EOC-1 条件下分类混淆矩阵 Table 8 Confusion matrix for EOC-1

表 9 EOC-2 条件下分类混淆矩阵 Table 9 Confusion matrix for EOC-2

类别	数量	2S1	BRDM2	T72	ZSU234	正确率 /%
2S1	288	272	11	0	5	94.44
BRDM2	287	19	268	0	0	93.38
T72	288	65	54	153	16	53.13
ZSU234	288	4	6	1	277	96.18
AA						84.28
OA						84.27

表 10 不同分类算法的分类性能比较

Table 10 Comparison of average classification accuracies for different classification algorithms

算法	SOC/%	EOC-1/%	EOC-2/%
EMACH ^[21]	88	77	68
SVM ^[21]	90	81	75
AdaBoost ^[21]	92	82	78
CondGauss ^[21]	97	80	79
IGT ^[21]	95	85	80
A-ConvNets ^[12]	99.13	98.93	96.12
RCFEELM-NEW	93.00 ± 0.32	97.74 ± 0.53	91.75 ± 0.96
RCFEELM	94.97 ± 0.42	83.26 ± 2.98	81.95 ± 2.61

练若干弱分类器集合,有效地提高了 SAR 目标识别 的精度,提高了分类器的泛化能力。提出的算法避免 了应用深度卷积神经网络进行 SAR 目标识别时需要 进行样本扩充、模型优化设计和长时间训练等难题。 采用 MSTAR 数据集,在标准操作条件和多个扩展操 作条件下验证了提出算法的有效性。下一步的研究方 向采用多种互补特征,进一步提高算法的分类精度, 并对算法进行优化来提高实时性能。

参考文献

- El-darymli K, Gill E W, Mcguire P, et al. Automatic target recognition in synthetic aperture radar imagery: a state-of-the-art review[J]. *IEEE Access*, 2016, 4: 6014–6058.
- [2] Pei J F, Huang Y L, Huo W B, et al. SAR imagery feature extraction using 2DPCA-based two-dimensional neighborhood virtual points discriminant embedding[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, **9**(6): 2206–2214.

[3] Amoon M, Rezai-Rad G A. Automatic target recognition of syn-

thetic aperture radar (SAR) images based on optimal selection of Zernike moments features[J]. *IET Computer Vision*, 2014, **8**(2): 77–85.

- [4] Du P J, Samat A, Gamba P, *et al.* Polarimetric SAR image classification by boosted multiple-kernel extreme learning machines with polarimetric and spatial features[J]. *International Journal of Remote Sensing*, 2014, **35**(23): 7978–7990.
- [5] Zhao Q, Principe J C. Support vector machines for SAR automatic target recognition[J]. *IEEE Transactions on Aerospace* and Electronic Systems, 2001, **37**(2): 643–654.
- [6] Sun Y J, Liu Z P, Todorovis S, et al. Adaptive boosting for SAR automatic target recognition[J]. *IEEE Transactions on Aero*space and Electronic Systems, 2007, 43(1): 112–125.
- [7] Song S L, Xu B, Yang J. SAR target recognition via supervised discriminative dictionary learning and sparse representation of the SAR-HOG feature[J]. *Remote Sensing*, 2016, 8(8): 683.
- [8] Zhang H C, Nasrabadi N M, Zhang Y N, et al. Multi-view automatic target recognition using joint sparse representation[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2012, 48(3): 2481–2497.
- [9] Dong G G, Kuang G Y, Wang N, et al. SAR target recognition via joint sparse representation of monogenic signal[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(7): 3316–3328.
- [10] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, **313** (5786): 504–507.
- [11] Ding J, Chen B, Liu H W, et al. Convolutional neural network with data augmentation for SAR target recognition[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(3): 364–368.
- [12] 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.

- [13] Huang G, Huang G B, Song S J, et al. Trends in extreme learning machines: a review[J]. Neural Networks, 2015, 61: 32–48.
- [14] Rokach L. Ensemble-based classifiers[J]. Artificial Intelligence Review, 2010, 33(1–2): 1–39.
- [15] Goodfellow I, Bengio Y, Courville A. Deep Learning[M]. Cambridge, USA: MIT Press, 2016.
- [16] Iamdola F N, Han S, Moskewica M W, et al. SqueezeNet: Alex-Net-level accuracy with 50x fewer parameters and < 0.5MB model size[EB/OL]. arXiv preprint: 1602.07360, 2016.
- [17] Huang G B, Bai Z, Kasun L L C, et al. Local receptive fields based extreme learning machine[J]. *IEEE Computational Intelli*gence Magazine, 2015, **10**(2): 18–29.
- [18] Li T, Zhang X J. Research of hyperspectral remote sensing image classification based on extreme learning machine[J]. Opto-Electronic Engineering, 2016, 43(11): 62–68. 李铁,张新君.极限学习机在高光谱遥感图像分类中的应用[J]. 光 电工程, 2016, 43(11): 62–68.
- [19] Breiman L. Bagging predictors[J]. *Machine Learning*, 1996, 24(2): 123–140.
- [20] Ni W P, Yan W D, Wu J Z, et al. 2D gabor filter enhancing and adaptive thresholding for MSTAR image[J]. Opto-Electronic Engineering, 2013, 40(3): 87–93.
 倪维平,严卫东,吴俊政,等. MSTAR 图像 2D Gabor 滤波增强 与自适应阈值分割 [J]. 光电工程, 2013, 40(3): 87–93.
- [21] Srinivas U, Monga V, Raj R G. SAR automatic target recognition using discriminative graphical models[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2014, **50**(1): 591–606.

Fast SAR target recognition based on random convolution features and ensemble extreme learning machines

Gu Yu 1* , Xu Ying 2

¹ Fundamental Science on Communication Information Transmission and Fusion Technology Laboratory, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China;

² College of Life Information Science & Iinstrument Engineering, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China



Flowchart of SAR target recognition algorithm based on random convolution features and ensemble extreme learning machines

Abstract: Deep convolution neural network has demonstrated excellent performance in target detection and recognition tasks, however, few training samples and optimization design of deep models are two main problems to be solved when applied to SAR target recognition. This paper proposes a fast SAR target recognition algorithm by combination of two dimensional random convolution features and ensemble extreme learning machines. Firstly, two dimensional random convolution features are extracted, where kernel widths are randomly selected from the kernel width set, and random kernels with different widths are generated based on uniform distribution. Convolution and square pooling operations are performed in the input image to extract random convolution features, and these features are transformed into vectors and combined to form a high-dimensional feature vector. Secondly, random sampling operations based on ensemble learning theory are adopted to perform dimensionality dimension to get a low-dimensional feature vector, and extreme learning machines (ELM), which has the advantages of fast training speed, few adjustable parameters, and good generalization performance, are used to train base classifiers. Finally, majority vote method is adopted to combine the classification results of base classifiers to predict the label of the targets. MSTAR database is used to perform SAR target recognition experiments to verify the performance of the proposed algorithm. The parameters which affect recognition performance greatly are firstly analyzed, including the number of the convolution kernel, the width of the convolution kernel, the number of base classifier, and regularization parameter. It can be concluded that, recognition performance with larger kernel width is higher than that with smaller kernel width, where convolution kernels with small width, such as 3×3 , is mostly often used in deep convolution models to perform visible image recognition. Extreme learning machine with small regularization coefficient can achieve good generalization capability and improve recognition performance. SAR target recognition experiments are done under standard operating condition and extended operating conditions, and experimental results demonstrate that, the overall recognition performances for ten-class targets with and without distorted configurations are 95.79% and 97.57%, respectively. Meanwhile, the training time has dropped by ten times due to fast training capability of ELM, and the proposed algorithm achieves comparable classification performance with deep-learning-based methods which use data augmentation and multiple convolution layers. Finally, the recognition performance compared with state-of-the-art classifiers are presented. The proposed algorithm has the advantages of easy implementation and fewer adjustable parameters, and improves classifier's generalization performance through adoption of ensemble learning ideas.

Citation: Gu Y, Xu Y. Fast SAR target recognition based on random convolution features and ensemble extreme learning machines[J]. *Opto-Electronic Engineering*, 2018, **45** (1): 170432

Supported by National Natural Science Foundation (61375011)

^{*}E-mail: guyu@hdu.edu.cn