

基于深度卷积神经网络的弹道目标微动分类

李江¹, 冯存前^{1,2✉}, 王义哲¹, 许旭光¹

(1. 空军工程大学防空反导学院, 西安, 710051; 2. 信息感知技术协同创新中心, 西安, 710077)

摘要 针对传统弹道目标微动分类缺乏智能性及噪声条件下分类性能差的问题,利用深度学习的高维特征泛化学习能力,提出一种将深度卷积神经网络用于弹道目标微动分类的方法。首先,在建立弹道目标微动模型的基础上,分析3种微动形式下的微多普勒表示,并生成雷达回波信号的时频图,作为训练、验证及测试的数据集;然后,运用深度卷积神经网络中的迁移学习对 AlexNet 和 GoogLeNet 进行再训练;最后,利用训练后的网络实现3种微动形式下的目标分类,并研究信噪比对分类性能的影响。仿真结果表明,与传统的微动目标分类方法相比,该方法不仅智能化程度高,而且在低信噪比条件下分类准确性更强。

关键词 弹道目标;微多普勒;卷积神经网络;时频分析;目标分类

DOI 10.3969/j.issn.1009-3516.2019.04.015

中图分类号 TN957 **文献标志码** A **文章编号** 1009-3516(2019)04-0097-08

Micro-Motion Classification of Ballistic Targets Based on Deep Convolutional Neural Network

LI Jiang¹, FENG Cunqian^{1,2✉}, WANG Yizhe¹, XU Xuguang¹

(1. Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China;

2. Collaborative Innovation Center of Information Sensing and Understanding, Xi'an 710077, China)

Abstract: Aimed at the problems that the traditional ballistic targets micro-motion classification is lack of intelligence and the classification performance is poor under noise conditions, by using the high-dimensional feature generalization learning ability of deep learning, a method of using deep convolution neural network for ballistic target micro-motion classification is proposed. Firstly, based on the establishment of the ballistic target micro-motion model, the micro-Doppler representations of the three micro-motion forms are analyzed, and the time-frequency map of the radar echo signals is generated as the data set for training, verification and testing; The transfer learning in deep convolution neural network is used to retrain AlexNet and GoogLeNet. Finally, the target network classification in three micro-motion forms is realized by using the trained network, and the influence of signal-to-noise ratio on classification performance is studied. The simulation results show that compared with the traditional micro-motion target classification method, the method is not only high in intelligence, but also is good in classification accuracy under low SNR conditions, and is guidable in the classification of ballistic targets.

收稿日期: 2019-04-07

基金项目: 国家自然科学基金(61701528)

作者简介: 李江(1995—),男,湖南郴州人,硕士生,主要从事目标探测与识别研究。E-mail:103106505@qq.com

通信作者: 冯存前(1975—),男,陕西西安人,教授,主要从事目标探测与识别研究。E-mail:fengcunqian@sina.com

引用格式: 李江, 冯存前, 王义哲, 等. 基于深度卷积神经网络的弹道目标微动分类[J]. 空军工程大学学报(自然科学版), 2019, 20(4): 97-104. LI Jiang, FENG Cunqian, WANG Yizhe, et al. Micro-Motion Classification of Ballistic Targets Based on Deep Convolutional Neural Network[J]. Journal of Air Force Engineering University (Natural Science Edition), 2019, 20(4): 97-104.

Key words: ballistic target; micro-Doppler; convolution neural network; time-frequency analysis; target classification

弹道目标识别与分类技术的发展对于战略预警与反导作战至关重要。随着多弹头分导及诱饵技术的不断进步^[1-2],基于传统的特征识别技术效率大幅下降,急需一种不依赖于目标参数的细节特征识别方法。自 2000 年 V. C. Chen 将微动运用到雷达目标识别领域,一种基于微动特征的有效新途径开始得到应用^[3]。常见弹道目标的微动形式有旋转、进动及章动等,不同微动形式的主要差异在于目标的瞬时速度及回波频谱,据此可作为弹道目标识别的有效依据^[4]。对弹道目标微动形式进行准确的分类是有效识别目标并获取参数的前提,但由于弹道目标微动特征的调频周期规律性不强,导致存在检测、提取和识别难的问题^[5],需研究智能化处理方法。

近年来,随着深度学习方法的迅速发展,其在处理目标分类问题上已经成为一种高效的智能方法,相比于传统的利用支持矢量机分类器^[6]、微多普勒频率差^[7-8]及微多普勒阈值识别^[9]来实现微动分类的方法,具有良好泛化能力的深度学习,通过挖掘更高维度的抽象特征,实现高准确性的智能化分类。目前深度学习在相应领域的研究有基于密集深度分离卷积的 SAR 图像水域分割算法^[10]及基于深度学习的复杂背景雷达图像多目标检测^[11]等,此外在人体姿态识别^[12]、高分辨距离成像^[13]和海上微动目标检测与分类^[14]等领域也有应用。深度学习中常用的模型为卷积神经网络(CNN)^[15],可以直接输入原始图像,且特征提取过程中也不需人为干预^[16],可实现高精度分类。除此之外,还包括循环神经网络(RNN)^[17]及深度置信网络(DBN)。深度学习在图像处理上优势明显,而时频图可对微动特性的时变性进行有效分析,两者结合亦可实现微动形式的智能分类。

本文提出了一种基于 CNN 的弹道目标微动形式的分类方法,用 CNN 对不同运动状态目标对应的雷达回波时频图进行分类。

第 1 步,建立锥柱弹道目标模型,对旋转、进动和章动 3 种微动形式进行数学分析,并得到相应的微多普勒表达式;第 2 步,分别介绍 AlexNet 和 GoogLeNet 两种网络模型,通过设置雷达信号、目标结构及微动参数,仿真雷达回波得到时频图,并利用时频图构建的数据集对 CNN 进行再训练;第 3 步,利用训练后的网络实现目标 3 种微动形式的分类,并对 2 种 CNN 模型的性能进行比较,同时列举其他深度学习网络模型;最后,研究信噪比对分

类性能的影响,并分析不同信噪比条件下 2 种模型与传统分类方法的分类性能。

1 锥柱目标微动特性分析

1.1 不同散射中心的建模

空间典型弹道目标模型主要有锥体、锥柱及锥柱裙目标等,根据文献^[6]分析结果,本文采用更为贴近实际电磁计算结果的滑动等效散射点模型,以典型锥柱目标为例,建立如图 1 所示的目标模型。以锥柱质心 O 为坐标原点,锥柱轴为 Z 轴, Y 轴与 Z 轴垂直, X 轴垂直于 OYZ 面且满足右手螺旋定则,从而建立雷达坐标系 $OXYZ$ 。与 Z 轴夹角为 θ 的锥柱轴,在 OXY 面的投影与 X 轴夹角为 φ ,雷达视线 η 与 OXY 面共面,且 η 与 Z 轴的夹角为 α ,有:

$$\boldsymbol{\eta} = [0, \sin\alpha, \cos\alpha] \quad (1)$$

锥柱目标在高频电磁波照射下的散射主要有锥顶 A ,不连续圆环处的滑动等效散射点 B 、 C 及底部边缘滑动等效散射点 D ,下面进行这 4 个点的理论轨迹分析^[18]。




图 1 锥柱目标模型

记锥柱质心 O 到锥顶 A 的距离为 l_{OA} ,对应矢量表示为:

$$\mathbf{r}_{OA} = l_{OA} [\cos\varphi\sin\theta, \sin\varphi\sin\theta, \cos\theta] \quad (2)$$

其在雷达视线上的投影为:

$$l_A = \mathbf{r}_{OA} \cdot \boldsymbol{\eta} \quad (3)$$

从而锥顶 A 对应的微多普勒频移为

$$f_A = \frac{2}{\lambda} \frac{dl_A}{dt} \quad (4)$$

下面分析不连续圆环处滑动等效散射点 B 、 C 的多普勒频移。在图 1 所示的 $OXYZ$ 坐标系内,锥柱轴 OA 与雷达视线 η 所构成平面的单位法向量为:

$$\mathbf{n}_1 = \frac{\boldsymbol{\eta} \times \mathbf{OA}}{|\boldsymbol{\eta} \times \mathbf{OA}|} \quad (5)$$

散射中心 B 、 C 位于平面 π_1 和平面 π_2 的交线

处,且由几何分析知平面 π_1 和平面 π_2 表达式如下:

OA 与 η 所构成的平面 π_1 的方程可表示为:

$$\mathbf{n}_1 \cdot \mathbf{r}_1 = 0 \quad (6)$$

锥柱结合部分所在平面方程 π_2 可表示为:

$$\mathbf{OA} \cdot \mathbf{r}_1 = l_1 \quad (7)$$

锥柱结合部中心 O_1 到 B、C 的单位方向矢量为:

$$\mathbf{n}_2 = \frac{\mathbf{OA} \times \mathbf{n}_1}{|\mathbf{OA} \times \mathbf{n}_1|} \quad (8)$$

那么散射点 B(C) 对应的矢量表示为:

$$\mathbf{r}_{OB(C)} = \mathbf{OO}_1 \pm \mathbf{n}_2 \cdot \mathbf{r} \quad (9)$$

$\mathbf{r}$ 、 $\mathbf{r}_1$ 分别为底面半径、面 π_1 上的矢量, l_1 为坐标原点 O 到平面 π_2 的距离。

散射点 B(C) 在雷达视线上的投影为:

$$l_{B(C)} = \mathbf{r}_{OB(C)} \cdot \boldsymbol{\eta} \quad (10)$$

则散射点 B(C) 对应的微多普勒频移为:

$$f_{B(C)} = \frac{2}{\lambda} \frac{dl_{B(C)}}{dt} \quad (11)$$

散射点 D 的微多普勒形式也如式(11)所示,具体可参考文献[19]。

1.2 不同微动形式的微多普勒分析

典型弹道目标的微动形式包括旋转、进动及章动3种,不同微动形式下散射中心将产生相应的微多普勒频率,下面分别进行分析。

对于锥柱目标旋转模型,锥旋角 φ 及章动角 θ 均恒定不变。此时,弹头圆锥部母线上的散射点(除锥顶)在微多普勒频移上表现为不同初相的 $\sin$ 函数,但锥顶无微动;而旋转对于滑动等效散射点而言不会引起其位置的变化,使得瞬时频率变化幅度较小,所以在微多普勒频谱中表现为一条幅值为0的谱线^[6,9]。

对于锥柱目标进动模型,章动角 θ 为常数,锥旋角 φ 随时间的变化而变化,即:

$$\varphi = 2\pi f_\varphi t + \varphi_0 \quad (12)$$

式中: f_φ 为锥旋角频率; φ_0 为初始锥旋角。

对于锥柱目标章动模型,锥旋角 φ 及章动角 θ 均随时间的变化而变化,即:

$$\varphi = 2\pi f_\varphi t + \varphi_0 \quad (13)$$

$$\theta = \theta_0 \sin 2\pi f_\theta t + \theta_1 \quad (14)$$

式中: f_θ 为摆动角频率; θ_1 为初始摆动角。

将不同微动形式下锥旋角 φ 及章动角 θ 的表达式(12)~(14)代入式(11)中,得到对应的强散射中心理论微多普勒分布,根据式(3)和(10),可以得到观测距离的时间函数,从而模拟微动目标的雷达回波。

2 卷积神经网络建模

利用 CNN 对由时频图构成的数据集进行特征学

习并实现分类,可选用都采用 RGB 三色通道的 AlexNet 网络及 GoogLeNet 网络进行训练、测试及验证。AlexNet 网络首次在 CNN 中成功应用了 ReLU 作为激活函数、Dropout 避免过拟合、LRN 创建局部竞争机制等^[20]; GoogLeNet 网络主要创新在于它的网中网结构 Inception,使其在与 AlexNet 网络相同计算量的条件下能提取更多的特征,进而优化训练结果,且通过高效的扩充网络深度和宽度,提升 Inception Module 准确率的同时避免过拟合。

AlexNet 网络传感像素为 227×227 , 网络结构如图2,注意到5个卷积层中仅有 Conv1、Conv2 及 Conv5 在其后有最大池化层, Conv1、Conv2 由1个子层和1个 LRN 组成,而 Conv5 层是最有效的特征提取层^[21],最后还有3个全连接层。每个卷积层和全连接层后面都应用 ReLU 激活函数:

$$f(x) = \max(0; x) \quad (15)$$

GoogLeNet 网络传感像素为 224×224 , 网络结构图见图3,其中有4个分支:第1分支对输入进行 1×1 的卷积;第2和第3分支类似,都使用了双重卷积;第4分支则是 3×3 最大池化与 1×1 卷积的组合。




图2 Alexnet 结构网络图

3 基于 CNN 的弹道目标微动分类

3.1 算法流程

算法流程共3个步骤,具体步骤如下:

1) 数据预处理,为恢复所传送的信息必须对模拟雷达回波进行解调,再通过脉冲压缩获得高分辨率;

2) 利用短时傅里叶变化将解调和脉冲压缩后的雷达回波信号转化为二维时频图构建数据集,并对两种网络模型进行预训练;




图3 GoogLeNet 网络结构图

3)将训练好的网络用于数据集中时频图的验证和测试,得到分类过程图及分类混淆矩阵图,实现目标分类。

3.2 数据集构建

用于模型训练的数据是模拟雷达信号,雷达载频 10 GHz,观察时间 5 s,脉冲重复频率 1 000 Hz。3 种微动采用相同的结构参数 $l_{OA}=1.25\text{ m}$, $OO_1=0.35\text{ m}$, $r=0.25\text{ m}$ 。

为方便比对分类效果,微动参数设置与文献[9]一致:①旋转时,初始锥旋角 $\varphi_0=0^\circ\sim 360^\circ$,章动角 $\theta_0=4^\circ\sim 20^\circ$,雷达视线角 $\alpha=105^\circ\sim 150^\circ$;②进动时,初始锥旋角 $\varphi_0=0^\circ$,章动角 $\theta_0=4^\circ\sim 20^\circ$,雷达视线角 $\alpha=105^\circ\sim 150^\circ$,锥旋角频率 $f_\varphi=0.82\sim 1.2\text{ Hz}$;③章动时,初始锥旋角 $\varphi_0=0^\circ$,章动角 $\theta_0=4^\circ\sim 20^\circ$,雷达视线角 $\alpha=105^\circ\sim 150^\circ$,锥旋角频率 $f_\varphi=0.8\sim 1.2\text{ Hz}$,章动角摆动幅度 $\theta_2=10^\circ$,章动角摆动频率 $f_\theta=1\sim 1.5\text{ Hz}$ 。具体设置见表 1,表中‘—’表示不需要此参数,然后根据微动信号模型对回波进行仿真。

表1 微动参数设置

微动参数	旋转	进动	章动
$\alpha/(\text{^\circ})$	105 : 5 : 150	105 : 5 : 150	105 : 5 : 150
$\theta_0/(\text{^\circ})$	4 : 4 : 20	4 : 4 : 20	4 : 4 : 20
$\varphi_0/(\text{^\circ})$	18 : 18 : 360	0	0
f_φ/Hz	—	0.82 : 0.02 : 1.2	0.84 : 0.04 : 1.2
$\theta_2/(\text{^\circ})$	—	—	10
f_θ/Hz	—	—	1 : 0.5 : 1.5

数据分为训练、验证和测试集。图 4~5 分别是理想条件和信噪比为 0 dB 条件下,数据集中 3 种微动形式的时频图,其中亮色部分为不同微动形式下滑动等效散射点的时变多普勒频移。目标训练集包括理想条件及 10 种不同信噪比情况下共 30 000 张图片,每种情况 3 000 张,其中 3 种微动形式各 1 000 张。从生成的时频图中,对 3 种微动形式分别随机抽选图像构建数据集,并按照 50%、25%、25% 的比例依次分配给训练、验证及测试 3 个部分。




图4 理想条件下数据集示例




图5 信噪比 0 dB 条件下数据集示例

3.3 CNN 模型训练

本文利用迁移学习中的预训练模型方法,对 AlexNet 网络和 GoogLeNet 网络进行再训练,通过时频图分类实现微动形式分类。AlexNet 网络和 GoogLeNet 网络都通过训练 100 多万幅图像,学会了丰富的图像特征表示,并可对 1 000 个图像对象进行高精度的分类。相比于使用从零开始随机初始化权重训练网络的方法,迁移学习中的预训练模型方法仅需要在目标数据集中的输入-输出对上选择性地进行调整,后者显然更具方便性和高效性。

本文使用 Visio 进行画图,Matlab 进行仿真。根据训练过程中损失值的收敛条件,采用动量随机梯度下降法训练网络,经过多次仿真实验后,设置最大历元数为 2,每次迭代使用 64 个观察值的小批量处理,初始学习率设置为 0.000 1,验证频率为 3,同时增加最后一个可学习层的速率因子,使得新图层中的学习速度比迁移前的图层学习速度更快。本文采用 CPU 计算,如若采用 GPU 或者配置更高的计算机进行计算,会使得计算速度更快。

在无噪声干扰的理想条件下,训练和测试结果见表 2。在预训练时间上,AlexNet 网络明显比 GoogLeNet 网络更短,即预训练速度更快,此优势也是一些特定问题选择 AlexNet 网络的重要原因;在验证和测试的准确性上,2 种网络模型总的识别率都达到了 98.67% 以上,这是一个相当可观的分类准确性。由于所处理的分类种类少、训练集不够庞大及参数设置等因素的影响,可能使得在处理这类问题时网络结构相对简单的 AlexNet 网络准确性比 GoogLeNet 网络更高。

表2 训练及测试

模网络型	AlexNet	GoogLeNet
训练总时间/s	400	1 015
验证准确性/%	99.60	99.20
测试准确性/%	99.60	98.67

4 仿真结果及分析

4.1 分类性能及分析

理想条件下 2 种网络的测试结果由混淆矩阵图给出,见图 6。AlexNet 网络模型的目标分类概率为 99.60%,GoogLeNet 网络模型的目标分类概率不低于 98.67%。通过分析发现,2 类模型测试结果有一定的相似性:①旋转的判断率最高,都是 100%,这是因为旋转锥柱目标散射源散射位置和散射强度恒定,时频图为一 条直线,相比于进动和章动的曲线时频图而言特征明显;②主要的误判在于将章动误判为进动,这可能是因为在部分设置的参数下,存在遮挡效应而使得生成的时频图存在部分缺失或者锥顶散射源产生的微多普勒频率较小导致部分章动时频图与进动相似,进而产生分类混淆。




图 6 混淆矩阵图

4.2 不同网络类型比较

本文还可利用深度学习中的其他网络进行分类,如 VGG-16、VGG-19 及 ResNet 等网络,与 AlexNet 网络和 GoogLeNet 网络相比,这些网络结构更为复杂,训练时间相应更长,但分类的准确性更高,适合处理分类种类多、精确度要求高的分类问题,图 7 对不同网络相对速度和准确率进行了比较,因而针对不同分类问题可结合分类要求选择合适的网络。





图 7 不同网络的相对速度-准确率

例如:与 VGG-19 相比,如图 8 所示,给出了 3 种网络对理想数据集训练的精度图。其中网络参数如下:MaxEpochs 为 2, MiniBatchSize 为 15, InitialLearnRate 为 0.000 1, ValidationFrequency 为 3,且采用 GPU 计算。AlexNet、GoogLeNet、VGG-19 的训练精度依次为:99.60%、98.53%、99.87%,训练时间依次为:439 s、636 s、2 457 s。虽然 AlexNet 网络和 GoogLeNet 网络的分类精度相对较差,但网络训练时间则明显更短,也是这 2 种网络的突出优势,同时从训练后的验证结果来看,在分类数据集不是很庞大时,分类的准确性也可以达到比较理想的情况。因此,在分类时应根据不同的需求选择合适的网络模型,在本文所分析的问题中,AlexNet 和 GoogLeNet 更为合适。






图 8 预训练结果图

4.3 信噪比对不同分类方法的性能影响

对 AlexNet 网络和 GoogLeNet 网络在不同信噪比时训练后的测试结果进行研究。由于随机抽样的随机性,为保证实验结果的可信度,在每种信噪比条件下重复 5 次迁移学习并取其平均值作为最后的测试结果,图 9~10 分别给出 2 种网络模型在不同信噪比时 3 种微动模型分类结果。同时为研究本方法的有效性,将与文献[6]中支持矢量机分类器及文献[9]中利用微多普勒阈值识别的分类方法相比较,仿真结果见图 11。




图 9 AlexNet 分类性能




图 10 GoogLeNet 分类性能




图 11 目标分类性能

分析图 9~10 知,基于 CNN 的分类方法中:

- 1) 旋转弹头的识别率一直时最高的;
- 2) 随着信噪比的减低,主要误判在章动和进动之间;
- 3) 在低信噪比时,仍然具有很可观的识别率,如 $\text{SNR}=0\text{dB}$ 时,3 种识别率都在 95% 左右。

分析图 11 可知:

- 1) 在信噪比较大时,3 种分类方式准确性都很高,分类准确性随着信噪比的降低而下降,但 AlexNet 网络和 GoogLeNet 网络变化更小;

- 2) 当信噪比为 0 dB 时,传统分类法的分类准确性不足 60%,而通过时频分析和迁移学习,深度学习模型的目标分类准确性仍在 96% 以上,具有明显优势;

- 3) 在信噪比为 -5 dB 时,传统分类法的分类准确性只有不到 55%,而深度学习模型的目标分类准确性仍比较高,保持在 90% 左右;

- 4) 随着信噪比的下降,由于噪声对时频图的干扰,导致目标微动特征减弱,模型本身的参数对分类准确性的影响加大,致使目标分类准确性迅速下降,失去参考价值。

仿真结果表明,基于深度学习的分类方法比传统分类方法准确性更高,且信噪比对分类性能的影响更小,具有更好的鲁棒性。同时基于深度学习的分类方法特征提取过程中也不需人为干预,具有智能性。

5 结语

本文提出了一种基于深度卷积神经网络的弹道目标微动分类方法,根据不同微动形式下的微动表达式,模拟雷达信号产生时频图并用于数据集的训

练、验证及测试,将 AlexNet 和 GoogLeNet 2 种模型用于弹道目标微动分类,并研究信噪比对分类性能的影响。2 种模型迁移学习后的仿真分类结果表明,基于卷积神经网络的深度学习分类方法,可实现对雷达信号产生的不同微动形式下的时频图进行分类,且相比于传统的分类方法,具有较高程度的智能性和在低信噪比时更高的精确性,这也为弹道目标的微动分类提供了一种新的思路。

参考文献(References):

- [1] Cohort 311-1210/Team LCS. Missile Defense in the 21st Century Acquisition Environment: Exploring a BMD Capable LCS Mission Package[R]. Monterey, CA:Naval Postgraduate School, 2013: 1-8.
- [2] JOHSON S B. Technical and Institutional Factors in the Emergence of Project Management[J]. International Journal of Project Management, 2013, 31(5): 670-681.
- [3] CHEN V C. Analysis of Radar Micro-Doppler Signature with Time-Frequency Transform[C] //Proceedings of the IEEE Workshop on Statistical Signal and Array Processing. Pocono Manor, PA:IEEE, 2000: 463-466.
- [4] 陈小龙, 关键, 何友. 微多普勒理论在海面目标检测中的应用及展望[J]. 雷达学报, 2013, 2(1): 123-134.
CHEN X L, GUAN J, HE Y. Applications and Prospect of Micro- Motion Theory in the Detection of Sea Surface Target[J]. Journal of Radars, 2013, 2(1): 123-134. (in Chinese)
- [5] CHEN X L, GUAN J, LI X Y, et al. Effective Coherent Integration Method for Marine Target with Micro-motion via Phase Differentiation and Radon-Lv's Distribution[J]. IET Radar, Sonar& Navigation, 2015, 9(9):1284-1295.
- [6] 韩勋, 杜兰, 刘宏伟, 等. 基于时频分布的空间锥体目标微动形式分类[J]. 系统工程与电子技术, 2013, 35(4): 684-691.
HAN X, DU L, LIU H W, et al. Classification of Micro Motion Form of Space Cone Shaped Objects Based on Time-Frequency Distribution[J]. Systems Engineering and Electronics, 2013, 35(4):684-691. (in Chinese)
- [7] 关永胜, 左群声, 刘宏伟, 等. 空间锥体目标微动特性分析与识别方法[J]. 西安电子科技大学学报, 2011, 38(2):105-111.
GUANG Y S, ZUO Q S, LIU H W, et al. Micro-Motion Characteristic Analysis and Recognition of Cone-Shaped Targets [J]. Journal of Xidian University, 2011, 38(2):105-111. (in Chinese)
- [8] 关永胜, 左群声, 刘宏伟. 基于微多普勒特征的空间锥体目标识别[J]. 电波科学学报, 2011, 26(2): 209-215, 412.
GUAN Y S, ZUO Q S, LIU H W. Micro-Doppler Signature Based Cone-Shaped Target Recognition[J]. Chinese Journal of Radio Science 2011, 26(2): 209-215, 412. (in Chinese)
- [9] 束长勇, 张生俊, 黄沛霖, 等. 基于微多普勒的空间锥体目标微动分类[J]. 北京航空航天大学学报, 2017, 43(7):1387-1394.
SHU C Y, ZHANG S J, HUANG P L, et al. Micro-Motion Classification of Spatial Cone Target Based on Micro-Doppler[J]. Journal of Beijing University of Aeronautics and Astronautics, 2017, 43(7): 1387-1394. (in Chinese)
- [10] 张金松, 邢孟道, 孙光才. 一种基于密集深度分离卷积的 SAR 图像水域分割算法[J]. 雷达学报, 2019, 8(3): 400-411.
ZHANG J S, XING M D, SUN G C. A Water Segmentation Algorithm for SAR Image Based on Dense Depthwise Separable Convolution[J]. Journal of Radars, 2019, 8(3):400-411. (in Chinese)
- [11] 周龙, 韦素媛, 崔忠马, 等. 基于深度学习的复杂背景雷达图像多目标检测[J]. 系统工程与电子技术, 2019, 41(6):1258-1264.
ZHOU L, WEI S Y, CUI Z M, et al. Multi-Objective Detection of Complex Background Radar Image Based on Deep Learning[J]. Systems Engineering and Electronics, 2019, 41(6):1258-1264. (in Chinese)
- [12] 张儒鹏, 于亚新, 张康, 等. 基于 OI-LSTM 神经网络结构的人类动作识别模型研究[J]. 计算机科学与探索, 2018, 12(12):1926-1939.
ZHANG R P, YU Y X, ZHANG K, et al. Research on Human Action Recognition Model Based on OI-LSTM Neural Network Structure[J]. Journal of Frontiers of Computer Science and Technology, 2018, 12(12): 1926-1939. (in Chinese)
- [13] 王俊, 郑彤, 雷鹏, 等. 深度学习在雷达中的研究综述[J]. 雷达学报, 2018, 7(4):395-411.
WANG J, ZHENG T, LEI P, et al. Study on Deep Learning in Radar[J]. Journal of Radars, 2018, 7(4): 395-411. (in Chinese)

- [14] 苏宁远,陈小龙,关键,等. 基于卷积神经网络的海上微动目标检测与分类方法[J]. 雷达学报,2018,7(5): 565-574.
- SU N Y, CHEN X L, GUAN J, et al. Detection and Classification of Maritime Target with Micro-motion Based on CNNs [J]. Journal of Radars, 2018, 7(5): 565-574. (in Chinese)
- [15] 谭咏梅,刘姝雯,吕学强. 基于 CNN 与双向 LSTM 的中文文本蕴含识别方法[J]. 中文信息学报,2018,32(7):11-19.
- TAN Y M, LIU S W, LV X Q. CNN and BiLSTM Based Chinese Textual Entailment Recognition [J]. Journal of Chinese Information Processing, 2018, 32(7):11-19. (in Chinese)
- [16] 徐真,王宇,李宁,等. 一种基于 CNN 的 SAR 图像变化检测方法[J]. 雷达学报,2017,6(5):483-491.
- XU Z, WANG Y, LI N, et al. A Novel Approach to Change Detection in SAR Images with CNN Classification[J]. Journal of Radars, 2017, 6(5): 483-491. (in Chinese)
- [17] ELMAN J L. Finding structure in time[J]. Cognitive Science, 1990, 14 (2) : 179-211.
- [18] 黄培康,殷红成,许小剑. 雷达目标特性[M]. 北京:电子工业出版社,2005:86-92.
- HUANG P K, YIN H C, XU X J. Radar Target Character [M]. Beijing:Publishing House of Electronic Industry, 2005:86-92. (in Chinese)
- [19] 马梁. 弹道中段目标微动特性及综合识别方法[D]. 长沙:国防科学技术大学,2011.
- MA L. The Micro-Motion Characteristic and Combining Classification of Ballistic Target[D]. Changsha: National University of Defense Science and Technology, 2011. (in Chinese)
- [20] WANG Y Z, FENG C Q, ZHANG Y S. Classification of Space Targets with Micro-Motion Based on Deep CNN [C] //2019 IEEE 2nd International Conference on Electronic Information and Communication Technology, Harbin:IEEE, 2019:557-561.
- [21] 胡涛,李卫华,秦先祥,等. 基于深度 CRF 模型的图像语义分割方法[J]. 空军工程大学学报(自然科学版), 2018,19(5):52-57.
- HU T, LI W H, QIN X X, et al. An Image Semantic Segmentation Based on Deep CRF Model[J]. Journal of Air Force Engineering University (Natural Science Edition), 2018, 19(5):52-57. (in Chinese)

(编辑:徐敏)