

文章编号: 2095-4980(2019)01-0105-07

基于时频图深度学习的雷达动目标检测与分类

牟效乾¹, 陈小龙^{*1}, 苏宁远¹, 关 键¹, 陈唯实²

(1. 海军航空大学, 山东 烟台 264001; 2. 中国民航科学技术研究院, 北京 100028)

摘 要: 雷达动目标检测技术一直是雷达信号处理领域中的关键技术, 而传统的雷达动目标检测技术仅适用于匀速运动目标, 检测性能有限。针对该问题提出一种基于卷积神经网络(CNN)时频图处理的雷达动目标检测方法, 通过从雷达动目标回波中提取多普勒频移信息, 然后利用短时傅里叶变换转换为时频图, 输入卷积神经网络, 进行深度特征学习, 进而实现检测和分类的目的。仿真数据验证表明, 所提方法能够有效检测和区分匀速、匀变速运动以及微动目标, 稳健性高, 与传统动目标检测方法相比具有显著优势。

关键词: 雷达动目标检测; 目标分类; 深度学习; 卷积神经网络; 时频图

中图分类号: TN959

文献标志码: A

doi: 10.11805/TKYDA201901.0105

Radar detection and classification of moving target using deep convolutional neural networks on time-frequency graphs

MOU Xiaoqian¹, CHEN Xiaolong^{*1}, SU Ningyuan¹, GUAN Jian¹, CHEN Weishi²

(1. Naval Aviation University, Yantai Shandong 264001, China;

2. China Academy of Civil Aviation Science and Technology, Beijing 100028, China)

Abstract: Radar moving target detection technology is always a key technology in the field of radar signal processing. The traditional radar moving target detection technology is only suitable for uniformly moving targets, and the detection performance is limited. This paper proposes a radar Moving Target Detection(MTD) method based on Convolutional Neural Network(CNN) time-frequency processing. It extracts the Doppler shift information from the radar moving target echo, and then transforms it into time-frequency graph with short-time Fourier transform. After inputting the time-frequency graph into the CNN, the characteristic learning is performed to achieve the purpose of detection and classification. Simulation shows that this method is superior to traditional moving target detection methods.

Keywords: radar moving target detection; target classification; deep learning; Convolutional Neural Network; time-frequency graph

动目标检测和分类是雷达信号处理的重要分支, 对于目标的搜索、监视、跟踪和识别起着至关重要的作用, 在国防战略安全和日常生活中应用广泛。可靠和稳健的动目标检测和分类技术的难点主要体现在目标回波微弱、目标运动类型复杂多样、机动导致多普勒时变等^[1]。雷达在探测动目标时不仅受到目标机动性的影响, 还受杂波和噪声等干扰, 在实际的复杂背景下检测难度大^[2]。传统的动目标检测(MTD)先进行多普勒信息的提取, 然后通过多普勒滤波器组来区分运动目标和杂波, 并估计目标运动参数, 实现目标检测。然而, MTD 基于傅里叶变换实现, 决定其对于匀速运动目标性能最优, 对于变速和机动目标, 频谱发散, 能量难以积累, 对于不同运动类型的多分量信号处理也捉襟见肘^[3]。因其检测性能较差、虚警概率高、分类识别概率低, 亟需发展新的处理方法。

近年来, 随着人工智能的兴起与蓬勃发展, 深度学习在智能信号处理领域得到了越来越广泛的研究与应用^[4], 卷积神经网络(CNN)^[5]在图像识别、目标检测^[6]方面具有巨大优势, 相比于传统目标检测的特征提取方法^[7](例如

收稿日期: 2018-02-09; 修回日期: 2018-04-22

基金项目: 国家自然科学基金资助项目(61871391; U1633122; 61871392; 61531020); 国防科技基金资助项目(2102024); 山东省高校科技发展计划资助项目(J17KB139); 中国科协“青年人才托举工程”专项经费资助项目(YESS20160115)

*通信作者: 陈小龙 email: cxlxl1209@163.com

尺度不变特征变换(Scale-Invariant Feature Transform, SIFT))和特征分类方法(例如支持向量机(Support Vector Machine, SVM)),卷积神经网络的特征学习更丰富,表达能力更强^[8]。卷积神经网络能够通过卷积核对图像的卷积自动提取图像特征^[9],从而实现良好的目标识别功能,并获得较高的检测成功率^[10]。1989年加拿大多伦多大学 Yann LeCun 等提出卷积神经网络,2012年 Hinton 改进了网络的训练方式后,卷积神经网络在图像目标检测方面得到了巨大突破和广泛应用^[11]。在雷达领域,卷积神经网络的研究主要集中在合成孔径雷达(Synthetic Aperture Radar, SAR)、逆合成孔径雷达(Inverse SAR, ISAR)以及光学图像处理等方面^[12-13]。2016年田壮壮等提出基于卷积神经网络的 SAR 图像目标识别^[14];2017年王思雨等提出基于卷积神经网络的高分辨力 SAR 图像飞机目标检测算法^[15],是一种飞机目标检测的新模式。但上述研究都是基于 SAR 雷达成像研究,对于雷达的体制有着一定的限制。考虑到动目标回波可建模为调频信号,因此可以使用时频分析方法进行有效分析,转化为时频二维图后即可采用深度学习网络进行图像处理,从而完成动目标的检测与分类。

本文提出基于卷积神经网络时频图处理的动目标检测技术,首先对目标进行回波信号调制和脉冲压缩处理,提取目标多普勒频移信息,然后通过短时傅里叶变换(Short-Time Fourier Transform, STFT)后转化为时频图,输入到卷积神经网络,利用其强大的图像识别功能进行检测。通过该方法可以识别匀速运动、匀变速、微动目标,相比传统检测方法 MTD 和分类方法 SVM,在检测和分类性能以及稳健性等方面具有明显优势。

1 雷达机动目标回波及时频图的构建

1.1 动目标多普勒信息的提取

假设雷达发射线性调频信号:

$$s_T(t) = \text{rect}\left(\frac{t}{T_p}\right) e^{j2\pi\left(f_c t + \frac{1}{2} u t^2\right)} \quad (1)$$

式中: $\text{rect}\left(\frac{t}{T_p}\right) = \begin{cases} 1, & \frac{t}{T_p} \leq 1 \\ 0, & \text{其他} \end{cases}$ 为矩形信号; f_c 为载波频率; T_p 为脉冲宽度; $u = \frac{B}{T_p}$ 为调制频率, B 为带宽。则在 t

时刻雷达接收到的信号为:

$$s_r(t) = \sigma_r \text{rect}\left(\frac{t-\tau}{T_p}\right) e^{j2\pi\left[f_c(t-\tau) + \frac{1}{2} u(t-\tau)^2\right]} \quad (2)$$

式中: σ_r 为目标的雷达散射截面积; 时间延迟为 $\tau = \frac{2r_s(t_m)}{c}$, c 为光速, $r_s(t_m)$ 为目标与雷达之间的距离, t_m 为在相参处理间隔内脉冲到脉冲间的慢时间。将 $r_s(t_m)$ 用泰勒级数展开为时间的多项式函数为:

$$r_s(t_m) = r_0 - v t_m - \frac{1}{2!} v \dot{t}_m^2 - \frac{1}{3!} v \ddot{t}_m^3 - \dots, t_m \in \left[-\frac{T_n}{2}, \frac{T_n}{2}\right] \quad (3)$$

式中: v 是目标速度; T_n 为相参积累时间。

对于匀变速运动目标,本文仅保留上式的前3项作为雷达与目标距离的二次近似,则:

$$r_s(t_m) = r_0 - v_0 t_m - \frac{a_s t_m^2}{2} \quad (4)$$

式中: v_0 为目标的初速度; a_s 为目标加速度。

采用发射信号作为参考信号,对回波信号经过解调和脉冲压缩后得到:

$$s_p(t, t_m) = A_r \text{sinc}[B(t-\tau)] e^{-j2\pi f_c \tau} \quad (5)$$

式中 A_r 为回波信号幅度。将 $\tau = \frac{2r_s(t_m)}{c}$ 代入式(5)中,对相位求取时间导数,得到匀变速运动目标的瞬时频率:

$$f_1 = -\frac{2}{\lambda} \frac{d\left(r_0 - v_0 t_m - \frac{a_s t_m^2}{2}\right)}{dt_m} = \frac{2}{\lambda} (v_0 + a_s t_m) \quad (6)$$

令 $a_s = 0$ 可得匀速目标的瞬时频率:

$$f_2 = \frac{2v_0}{\lambda} \quad (7)$$

对于微动目标,雷达与目标的距离 $r_s(t_m)$ 如下^[16]:

$$r_s(t_m) = r_0 - A \sin(\omega t_m + \varphi) \quad (8)$$

式中: A, ω, φ 分别表示微动目标的正弦振动幅度、角频率和相位。解调和脉压后得到微动目标的瞬时频率为:

$$f_3 = -\frac{2}{\lambda} \frac{d(r_0 - A \sin(\omega t_m + \varphi))}{dt_m} = \frac{2A\omega \cos(\omega t_m + \varphi)}{\lambda} \quad (9)$$

1.2 多普勒频移信息到视频图的转换

由上面分析的动目标模型可知, 回波具有时变特性和一定的非平稳性, 因此宜采用时频分析的方法分析。常用的有 STFT 以及二次型的 Wigner-Ville 分布(Wigner-Ville Distribution, WVD), 其中 WVD 虽然具有较高的分辨力, 但在进行多信号分析时会出现难以避免的交叉项, 因而选用多信号分析时不会出现交叉项的 STFT 进行时频分析^[17]。通过短时傅里叶变换将提取的多普勒频移信息转换为二维信息, 然后转换为时频图。

$$\text{STFT}(t, f) = \int_{-\infty}^{+\infty} [s_p(t)g^*(u-t)]e^{-j2\pi fu} du \quad (10)$$

式中: $s_p(t)$ 为调制和脉压后的目标回波信息; $g(t)$ 为汉宁窗。

2 CNN 和机动目标检测方法

2.1 CNN 的基本理论模型

卷积神经网络由卷积层、池化层和全连接层组成。卷积层是卷积神经网络的核心, 通过卷积核(滤波器)来提取图像的特征; 池化层实际上是降采样, 减少运算量和数据维度; 利用全连接层可以将池化层转化为一个向量。

卷积神经网络训练的优越性在于它可以利用输出值与真实值的误差进行反向传播, 从而调整权值系数优化卷积神经网络, 进一步提高正向传播的精确度。

用损失函数来表示输出值与真实值的误差, 建立损失函数:

$$E^n = \frac{1}{2} \sum_{k=1}^C (t_k^n - X_k^n)^2 \quad (11)$$

式中: E^n 为第 n 个样本的误差; C 为样本类别数; t_k^n 为第 n 个样本真实值的第 k 维; X_k^n 为第 n 个样本输出值的第 k 维。则总误差:

$$E^N = \frac{1}{2} \sum_{n=1}^N \sum_{k=1}^C (t_k^n - X_k^n)^2 \quad (12)$$

式中 N 为样本数。

目标函数是求得损失函数的最小值, 从而使得卷积神经网络模型最优化, 即 $\min E^N$ 。

2.2 基于卷积神经网络的机动目标检测与分类

2.2.1 卷积神经网络的选择

首先是卷积神经网络的选取, 一个好的卷积神经网络对于目标检测与分类的精确度与速度起着至关重要的作用。经典的卷积神经网络模型有 LeNet, AlexNet, GoogleNet, VGG, Deep Residual Learning。这 5 类网络的层数如表 1 所示。这里的总层数包括卷积层和全连接层, 不包含池化层和激活层。可以看出, 上述 5 个网络的总层数依次递增, 总层数越多识别准确率越高, 效果越好, 但是也存在以下 3 个主要问题:

1) 网络层数越多, 参数也越多, 在训练数据集有限的情况下, 模型容易过拟合;

2) 网络层数越多, 运算量越大, 训练较慢;

3) 网络层数越多, 层梯度越往后穿越容易消失, 优化模型的难度增大。

由于本文研究的 4 种运动类型的时频图均基于线条和曲线, 简单卷积网络就可以识别图形的线条、边、角, 达到目的。因此本文不使用层数和参数过多的 GoogleNet, VGG, Deep Residual Learning, 而采用 LeNet 和 AlexNet。

选择样本量为 240 张时频图的数据集分别输入 LeNet 网络和 AlexNet 网络进行训练。训练结果见图 1 和图 2。其中, 增长曲线是识别准确率, 2 条下降曲线是损失函数曲线, 可以看出验证数据得到的损失函数曲线波动性弱于训练数据得到的损失函数曲线。显而易见, LeNet 网络的识别准确率高于 AlexNet 网络, 在迭代 30 次时, LeNet

表 1 经典卷积神经网络层数表

Table 1 Layer of classic Convolution Neural Network

network type	LeNet	AlexNet	VGG	GoogleNet	Deep Residual Learning
total layers	4	8	11-19	22	152

网络的识别准确率为 99.74%，AlexNet 网络为 95.09%，而且损失函数大大低于 AlexNet 网络，所以选用 LeNet 网络作为卷积神经网络模型。

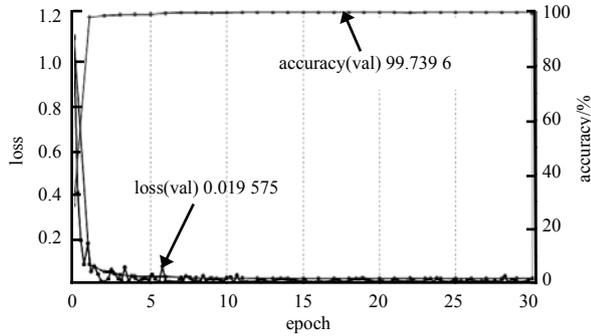


Fig.1 Training result chart of LeNet model
图 1 LeNet 模型训练结果图

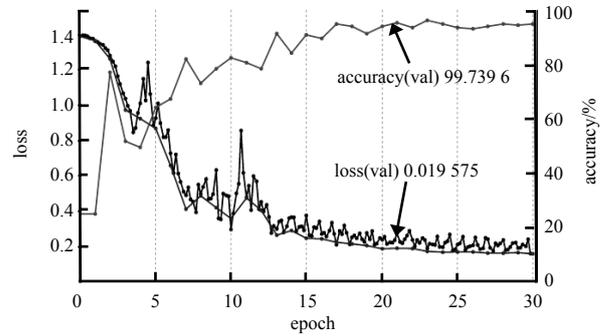


Fig.2 Training result chart of AlexNet model
图 2 AlexNet 模型训练结果图

2.2.2 检测和分类流程及参数的选取

算法流程图如图 3 所示,首先对仿真的动目标回波进行回波解调与匹配滤波,从而完成动目标多普勒信息的提取;然后,利用 STFT 对动目标多普勒信息进行时频分析,并构建时频图;最后将时频图输入卷积神经网络进行训练得到各类动目标的特征信息,通过迭代对网络的参数进行优化,从而完成动目标检测与分类。

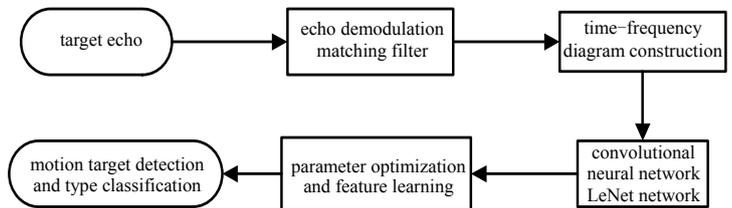


Fig.3 Model block diagram
图 3 模型结构框图

CNN 结构图如图 4 所示,输入图像像素大小为 128×128 ,然后卷积层使用大小为 5×5 的卷积核提取初步的线条、边角特征,然后通过池化层进行下采样降低运算量和数据维度,最后进入全连接层汇集特征信息最终分类并且得到训练的精确度和损失函数值。

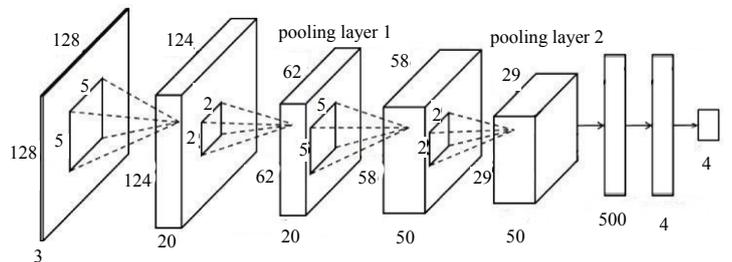


Fig.4 Structure diagram of CNN
图 4 卷积神经网络结构图

参数设置表、参数规模表如表 2 和表 3 所示。表 2 网络参数中迭代次数是对模型重复训练的次,决定着模型权重参数的优化程度。

表 2 网络参数表

Table2 Network parameters table

parameter	number of iterations	optimal parameter solving algorithm	initial learning rate	learning strategy	step size	gamma
value	30	SGD	0.01	step down	109	0.1

表 3 中,参数的规模决定着特征提取的精细度和训练的复杂度,参数越多,卷积神经网络提取特征越充分,同时运算量也大大增大,本文选用的 LeNet 网络不仅能保证特征提取的精细度,而且网络结构相对简单,参数规模不大,训练的复杂度小。

表 3 网络参数规模表

Table3 Network parameters scale table

primary layer name	convolution 1	convolution 2	fully connected layer 1	fully connected layer 2
network parameter scale	1 520	25 050	21 025 500	2 004

3 仿真分析与测试

3.1 仿真时频图数据集的构建

共构建 2 个数据集, 第一个数据集是 2 400 张像素为 128×128 的图片, 其中匀速、匀减速、匀加速、微动运动目标各 600 张; 第二个数据集是 240 张像素为 128×128 的图片, 其中匀速、匀减速、匀加速、微动运动目标各 60 张。仿真信号的多普勒频移数值在 100 Hz 到 10 kHz 之间, 回波信号加高斯噪声, 信噪比取-10~9 dB。

3.2 卷积神经网络模型的训练

本文创建了基于 VS2013, CUDA7.5, cudnn5.1, caffe, digits6.0 的 caffe 架构环境, 通过 digits 进行图像的图形化界面处理, 输入第一个数据集后建立的卷积神经网络模型结果如图 5 所示。本文设置参与训练的图片 75%用于训练, 25%用于验证。增长曲线是卷积神经网络验证的识别准确率曲线, 第 30 次迭代时准确率高达 99.796%, 波动性小的下降曲线是验证数据得到的损失函数值曲线, 损失函数值低至 0.000 01(损失值越小说明求解的目标函数越优)。

图 6 是学习率曲线, 学习率值越小, 表明梯度下降的步长越小, 精确度越高。当迭代次数在第 20 次以后时, 学习率接近零, 说明此时精确度极高。

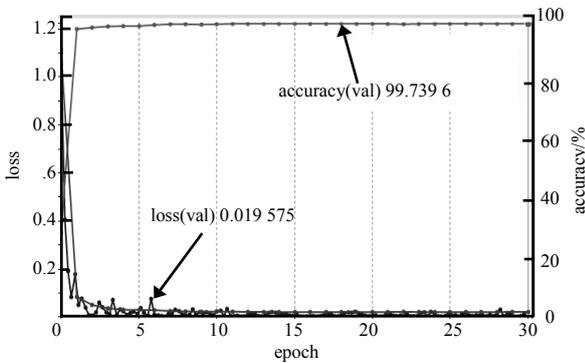


Fig.5 Training result chart
图 5 训练结果图

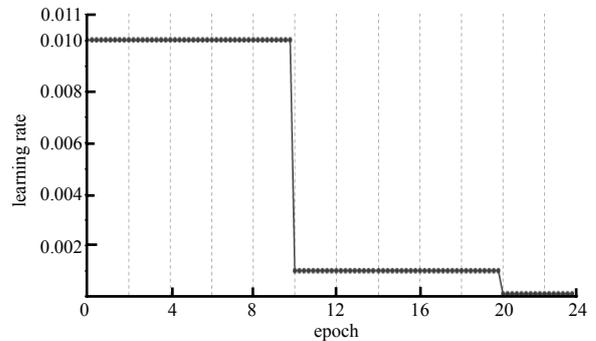


Fig.6 Learning rate
图 6 学习率结果图

3.3 不同运动类型目标检测和分类结果

雷达目标检测为回波信号的二元假设检验, 即噪声背景中的目标以及纯噪声无目标, 因此, 可将二元分类近似为目标的检测过程, 从而验证噪声背景下的检测性能。首先以 240 张 128×128 像素的仿真时频图图像作为数据集对模型进行训练, 其中每类运动目标的时频图各 60 张。对于每一类运动目标, 分别用信噪比为-10~4 dB 的该类目标时频图进行测试, 将二元分类概率记作检测性能。每类运动目标检测概率随信噪比变化的结果见图 7。

为了研究测试集数量对检测概率的影响, 使用 2 400 张 128×128 像素的仿真时频图图像作为数据集对模型进行训练, 其中每类运动目标的时频图各 600 张。对于每一类运动目标, 仍然分别用信噪比为-10~4 dB 的该类目标时频图进行测试, 测试结果即为检测概率。每类运动目标检测概率随信噪比变化的结果见图 8。

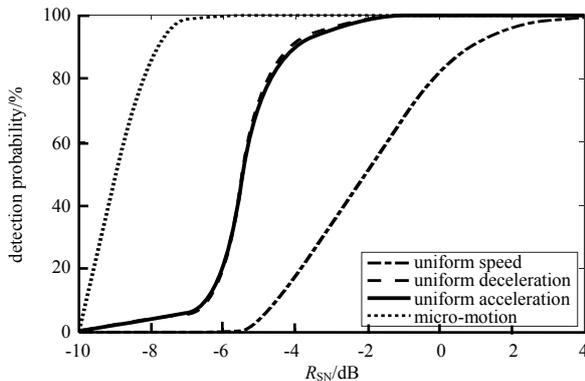


Fig.7 Curves of moving target detection results with SNR (training sample size is 240)
图 7 运动目标检测结果随 SNR 变化曲线(训练样本量 240)

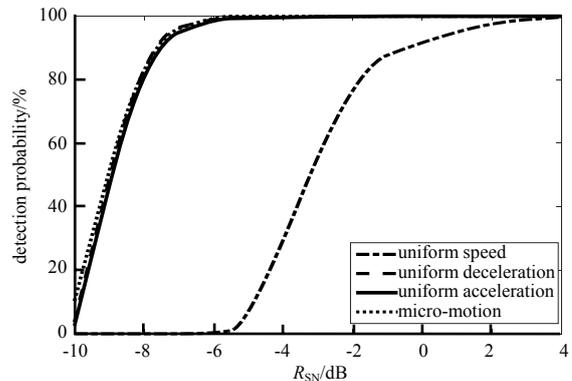


Fig.8 Curves of moving target detection results with SNR (training sample size is 2 400)
图 8 运动目标检测结果随 SNR 变化曲线(训练样本量 2 400)

从上图可以看出,匀速运动目标相对来说不易检测,其检测概率随信噪比的增加而增加,这是因为匀速运动目标的多普勒频移时频图是一条水平直线,对于卷积核来说提取特征不是很明显,也很容易被噪声掩盖。匀加速、匀减速、非匀速运动目标的检测概率相当高且准确,受信噪比影响不大。随着样本数量的增加,网络在同一信噪比下对匀速运动的检测概率也得到了提高。网络对于微动目标的检测性能良好,受信噪比影响最小。因此,利用深度卷积神经网络更适合处理复杂运动类型的目标。

3.4 与传统方法比较

为进一步检验卷积神经网络的性能,与传统的动目标检测方法 MTD 和传统的分类方法 SVM^[18]进行对比研究。通过时频图+CNN 与时频图+SVM 两种检测分类方法与本文中卷积神经网络时频图检测与分类方法的对比可以验证本文方法的优劣。运动目标回波多普勒频移数值在 100 Hz 到 10 kHz 之间,信噪比分别取 -2 dB, 0 dB, 4 dB。

从表 4 可以看出,本文的 CNN 检测与分类方法与传统的检测与分类方法 SVM 相比,在相同信噪比下,检测同一类型的运动目标的概率远远高于后者,在低信噪比下尤为明显,高信噪比下检测精确度非常高。其中匀速运动的检测相比其他 3 类运动类型而言检测概率低,特别是在低信噪比下,但是 CNN 检测与分类方法的性能可以随着信噪比的提高而显著提升,有着较好的检测能力。由此可见,基于卷积神经网络时频图处理的动目标检测技术性能优于传统的 SVM 分类方法。

表 4 性能对比(%)
Table4 Performance comparison(%)

algorithm	$R_{SN}=-2$ dB				$R_{SN}=0$ dB				$R_{SN}=4$ dB			
	uniform speed	uniform acceleration	uniform deceleration	micro-motion	uniform speed	uniform acceleration	uniform deceleration	micro-motion	uniform speed	uniform acceleration	uniform deceleration	micro-motion
time-frequency graph+CNN	5	85	80	100	55	95	95	100	100	100	100	100
time-frequency graph+SVM	10	25	20	100	45	35	40	100	75	80	80	100

4 结论

本文将深度学习中的卷积神经网络用于雷达机动目标检测,通过将目标信息转换为时频图信息输入卷积神经网络,很好地实现了雷达匀速、匀加速、微动目标的检测和分类,在很大程度上弥补了传统的检测方法 MTD 和分类方法 SVM 的缺陷,提高了检测和分类性能,为雷达信号的智能化处理提供了新的研究思路。后续将深入研究和比较不同深度神经网络应用在雷达动目标检测的优缺点,验证实测目标回波数据,将所提算法工程化应用。

参考文献:

- [1] 陈小龙,关键,黄勇,等. 雷达低可观测动目标精细化处理及应用[J]. 科技导报, 2017,35(20):19-27. (CHEN Xiaolong, GUAN Jian, HUANG Yong, et al. Radar refined processing and its applications for low-observable moving target[J]. Science & Technology Review, 2017,35(20):19-27.)
- [2] 陈唯实,李敬. 雷达探鸟技术发展与应用综述[J]. 现代雷达, 2017,39(2):7-17. (CHEN Weishi, LI Jing. Survey of development and application of radar bird exploration technology[J]. Modern Radar, 2017,39(2):7-17.)
- [3] ZHAO M M, ZHANG Q, LUO Y, et al. Micromotion feature extraction and distinguishing of space group targets[J]. IEEE Geoscience & Remote Sensing Letters, 2017,14(2):174-178.
- [4] 李岩,高梅国,崔双洋. 认知雷达对抗中的未知雷达状态识别方法[J]. 太赫兹科学与电子信息学报, 2018,16(2):233-238. (LI Yan, GAO Meiguo, CUI Shuangyang. Unknown radar state recognition method in cognitive radar confrontation[J]. Journal of Terahertz Science and Electronic Information Technology, 2018,16(2):233-238.)
- [5] 李旭冬,叶茂,李涛. 基于卷积神经网络的目标检测研究综述[J]. 计算机应用研究, 2017,34(10):1-7. (LI Xudong, YE Mao, LI Tao. Research on target detection based on convolutional neural networks[J]. Application Research of Computers, 2017,34(10):1-7.)
- [6] PAPAGEORGIOU C P, OREN M, POGGIO T. A general framework for object detection[C]// 6th International Conference on Computer Vision. India:IEEE, 1998:555-562.
- [7] 庞存锁. 高速、加速运动目标检测及雷达目标微动特征提取算法研究[D]. 北京:北京理工大学, 2014. (PANG Cunsuo.

- Detection of high-speed and accelerated moving targets and algorithms for extracting micro-motion features of radar targets[D]. Beijing:Beijing Institute of Technology, 2014.)
- [8] 周俊宇,赵艳明. 卷积神经网络在图像分类和目标检测应用综述[J]. 计算机工程与应用, 2017,53(13):34-41. (ZHOU Junyu,ZHAO Yanming. Overview of Convolutional Neural Networks in image classification and target detection applications[J]. Computer Engineering and Applications, 2017,53(13):34-41.)
- [9] 尹颢,闫磊. 基于深度卷积神经网络的图像目标检测[J]. 工业控制计算机, 2017,30(4):96-97. (YIN Xie,YAN Lei. Image target detection based on deep Convolutional Neural Network[J]. Industrial Control Computer, 2017,30(4):96-97.)
- [10] KRIZHEVSKY A,SUTSKEVER I,HINTON G E. Imagenet classification with deep Convolutional Neural Networks[J]. Advances in Neural Information Processing Systems, 2012,25(2):1097-1105.
- [11] 王震. 基于深度学习的快速目标检测技术研究[D]. 天津:天津理工大学, 2017. (WANG Zhen. Research on fast target detection technology based on deep learning[D]. Tianjin:Tianjin University of Technology, 2017.)
- [12] 宋光慧. 基于迁移学习与深度卷积特征的图像标注方法研究[D]. 杭州:浙江大学, 2017. (SONG Guanghui. Research on image marking methods based on migration learning and deep convolution features[D]. Hangzhou,China:Zhejiang University, 2017.)
- [13] 徐丰,王海鹏,金亚秋. 深度学习在 SAR 目标识别与地物分类中的应用[J]. 雷达学报, 2017,6(2):137-148. (XU Feng, WANG Haipeng,JIN Yaqiu. Application of deep learning in SAR target recognition and feature classification[J]. Journal of Radar, 2017,6(2):137-148.)
- [14] 田壮壮,占荣辉,胡杰民,等. 基于卷积神经网络的 SAR 图像识别研究[J]. 雷达学报, 2016,5(3):321-324. (TIAN Zhuang zhuang,ZHAN Ronghui,HU Jiemin,et al. Research on SAR image recognition based on Convolutional Neural Network[J]. Journal of Radar, 2016,5(3):321-324.)
- [15] 王思雨,高鑫,郑歆慰,等. 基于卷积神经网络的高分辨率 SAR 图像飞机目标检测方法[J]. 雷达学报, 2017,6(2):196-201. (WANG Siyu,GAO Xin,ZHENG Xinwei,et al. High resolution SAR image aircraft target detection method based on Convolutional Neural Network[J]. Journal of Radar, 2017,6(2):196-201.)
- [16] CHEN Xiaolong,GUAN Jian,BAO Zhonghua,et al. Detection and extraction of target with micro-motion in spiky sea clutter via short-time fractional Fourier transform[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014,52(2):1002-1018.
- [17] CHEN Xiaolong,GUAN Jian,LIU Ningbo,et al. Maneuvering target detection via Radon-fractional Fourier transform-based long-time coherent integration[J]. IEEE Transaction on Signal Processing, 2014,62(4):939-953.
- [18] 王月岭. 基于支持向量机与概率输出网络的深度学习[D]. 西安:西安理工大学, 2017. (WANG Yueling. Deep learning based on support vector machine and probability output network[D]. Xi'an:Xi'an University of Technology, 2017.)

作者简介:



牟效乾(1995-),男,山东省烟台市人,在读硕士研究生,主要研究方向为智能雷达信号处理、动目标检测等.email:1012226010@qq.com.

陈小龙(1985-),男,山东省烟台市人,博士,讲师,主要研究方向为雷达动目标检测、海杂波抑制、雷达信号精细化处理等.

苏宁远(1995-),男,山东省烟台市人,在读硕士研究生,主要研究方向为智能雷达信号处理,目标检测.

关 键(1968-),男,辽宁省锦州市人,教授,博士生导师,主要研究方向为雷达目标检测与跟踪、侦察图像处理和信息融合.

陈唯实(1982-),男,天津市人,博士,副研究员,主要研究方向为机场运行安全、雷达探鸟、低空空域监视等.