

## 基于卷积神经网络的海上微动目标检测与分类方法

苏宁远 陈小龙\* 关键 牟效乾 刘宁波  
(海军航空大学 烟台 264001)

**摘 要:** 该文利用深度学习的高维特征泛化学习能力, 将卷积神经网络(CNN)用于海上目标微多普勒的检测和分类。首先, 在海面微动目标模型的基础上, 在实测海杂波背景中分别构建4种类型微动信号的2维时频图, 并作为训练和测试数据集; 然后, 分别采用LeNet, AlexNet和GoogLeNet 3种CNN模型进行二元检测和多种微动类型分类, 并进行比较, 研究信杂比对检测和分类性能的影响。最后, 与传统的支持向量机方法进行比较, 结果表明, 所提方法能够智能学习微动特征, 具有更好的检测和分类性能, 可为杂波背景下的雷达微动目标检测和识别提供新的技术途径。

**关键词:** 微多普勒; 雷达目标检测; 深度学习; 卷积神经网络(CNN); 海杂波; 时频分析

中图分类号: TN957.51

文献标识码: A

文章编号: 2095-283X(2018)05-0565-10

DOI: 10.12000/JR18077

**引用格式:** 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. DOI: 10.12000/JR18077.

**Reference format:** Su Ningyuan, Chen Xiaolong, Guan Jian, *et al.*. Detection and classification of maritime target with micro-motion based on CNNs[J]. *Journal of Radars*, 2018, 7(5): 565-574. DOI: 10.12000/JR18077.

## Detection and Classification of Maritime Target with Micro-motion Based on CNNs

Su Ningyuan Chen Xiaolong Guan Jian Mou Xiaoqian Liu Ningbo  
(Naval Aviation University, Yantai 264001, China)

**Abstract:** In this paper, Convolutional Neural Networks (CNN) are used to detect and classify micro-Doppler effects of maritime targets by using generalized learning ability for high-dimensional features. Based on the micro-motion model of maritime targets, two-dimensional time-frequency maps of four types of micro-motion signals are constructed in the measured sea clutter background. These maps were used as training and test datasets. Furthermore, three types of CNN models, *i.e.*, LeNet, AlexNet, and GoogleNet, are used in binary detection and multiple micro-motion classifications. The effects of signal-to-noise ratio on detection and classification performance are also studied. Compared with the traditional support vector machine method, the proposed method can learn the micro-motion features intelligently, and has performed better in detection and classification. Thus, this study can provide a new technical approach for radar target detection and recognition under a cluttered background.

**Key words:** Micro-Doppler; Radar target detection; Deep learning; Convolutional Neural Network (CNN); Sea Clutter; Time-frequency analysis

收稿日期: 2018-09-14; 改回日期: 2018-10-16; 网络出版: 2018-10-30

\*通信作者: 陈小龙 cxlxl1209@163.com

基金项目: 国家自然科学基金(61871391, 61501487, 61871392, U1633122, 61471382, 61531020); 国防科技基金(2102024); 山东省高校科技发展计划(J17KB139); “泰山学者”和中国科协“青年人才托举工程”(YESS20160115)专项经费

Foundation Items: The National Natural Science Foundation of China (61871391, 61501487, 61871392, U1633122, 61471382, 61531020), National Defense Science Foundation (2102024), Scientific Research Development of Shandong (J17KB139), Special Funds of Taishan Scholars of Shandong and Young Elite Scientist Sponsorship Program of CAST (YESS20160115)

## 1 引言

海面目标的检测与分类在军事和民用等领域有广泛应用, 雷达是海上目标探测和监视的重要手段, 但受复杂海洋环境产生的海杂波以及海面目标类型多样化的影响, 可靠和稳健的海上目标检测和分类始终是需要研究的关键技术之一<sup>[1]</sup>。目前海面目标的检测与识别的难点主要在于海杂波抑制、目标高分辨特征提取、复杂特征分类等。传统的检测方法通常基于统计理论, 将海杂波视为随机过程, 但由于目标和杂波模型的多样化趋势, 该方法在复杂背景下难以实现高性能检测<sup>[2]</sup>。微多普勒技术的发展为目标检测与分类提供了有效途径<sup>[3]</sup>, 研究表明海面目标也具有微动特性, 主要表现为目标速度的变化和受海浪影响发生的横滚、俯仰、偏航等姿态变化, 这些变化信息均表现为目标或散射点瞬时速度的变化<sup>[2,4]</sup>, 可反映目标的运动状态, 为海上目标的检测和识别提供更多的有效信息。然而海面目标微动特征并不具有较为规律的调频周期特性, 其时变性, 存在检测、提取和识别难的问题<sup>[5]</sup>, 亟需发展和研究智能化方法和手段。

近年来迅速发展的深度学习方法是一种高效的智能处理方法, 相比于传统的支持向量机<sup>[6]</sup>(Support Vector Machine, SVM)更适合挖掘更高维度的抽象特征<sup>[7]</sup>, 具有良好的泛化能力, 并且在雷达领域开始得到应用。例如基于深度学习的SAR图像检测方法可用于地面物体的识别, 基于深度学习和多普勒雷达的人体姿态识别方法已用于手势指令识别<sup>[8]</sup>、步态识别、异常姿态(如跌落、溺水)检测等领域。此外, 在高分辨距离像、微多普勒谱图和距离多普勒谱图等识别中也有非常好的应用前景<sup>[9]</sup>。目前常用的深度学习模型包括卷积神经网络(Convolutional Neural Network, CNN)、循环神经网络(Recurrent Neural Network, RNN<sup>[10]</sup>)、深度置信网络(Deep Belief Network, DBN<sup>[11]</sup>)等。其中CNN是在计算机视觉中最常用的算法, 该方法不仅可以实现高精度的分类, 而且可直接输入原始图像, 在特征提取过程中也不需人为干预<sup>[12]</sup>。在文献<sup>[13]</sup>中提出的对于地面不同装甲目标的识别准确率已达到99.13%。由于微动特性具有时变性, 时频图是一种有效的分析工具。因此, 将深度学习用于海面目标的检测和分类既可以充分利用目标微动信息, 又可以发挥深度学习方法在图像处理上的优势, 实现目标微动信号的智能化提取和识别。

本文提出了一种基于CNN的海面目标检测与运动类型分类方法, 用CNN对雷达回波的时频图进行分类, 实现目标、杂波的区分和不同运动状态

目标的分类。首先建立海面目标的运动模型, 再根据运动模型设置目标运动参数, 仿真获得目标回波信号并进行时频分析, 获得时频图。然后用时频图构建数据集, 对CNN进行训练和测试, 比较不同CNN模型目标检测与分类的性能, 并分析信杂比(Signal-to-Clutter Ratio, SCR)对模型性能的影响。并提出了适合工程化应用的研究方向。

## 2 海面微动目标信号建模与CNN模型构建

### 2.1 海面微动目标信号模型

目标回波的多普勒谱反映了目标瞬时速度的变化, 可以通过分析目标回波信号多普勒谱的特性对不同运动状态的目标进行分类。首先构建海面目标运动模型, 建立目标回波信号中参量与目标运动参数的关系, 然后通过设置目标运动参数得到仿真的动目标回波, 用于数据集的构建。

假设雷达和目标位于同一水平面内, 雷达发射线性调频(LFM)信号:

$$s_t(t) = \text{rect}\left(\frac{t}{T_p}\right) \exp\left\{j2\pi\left[f_c t + \frac{1}{2} k t^2\right]\right\} \quad (1)$$

式中,  $\text{rect}(u) = \begin{cases} 1, & |u| \leq 1/2 \\ 0, & |u| > 1/2 \end{cases}$ ,  $f_c$  是雷达载频,  $T_p$  为脉宽,  $k = B/T_p$  为调频率,  $B$  为带宽, 则  $t$  时刻雷达接收的信号表示为:

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

式中,  $\sigma_r$  为目标的散射截面积,  $\tau = 2r_s(t_m)/c$  为时间延迟,  $c$  代表光速,  $r_s(t_m)$  为雷达与目标的视线距离,  $t_m$  表示脉冲-脉冲间的慢时间。回波经过解调 and 脉冲压缩运算后, 式(2)改写为<sup>[14]</sup>:

$$s_{PC}(t, t_m) = A_r \text{sinc}\left[B(t - \tau)\right] \exp(-j2\pi f_c \tau) \quad (3)$$

#### (1) 海面非匀速平动目标信号模型

假设目标与雷达位于同一水平面内, 目标瞬时速度的方向与目标到雷达观测方向的夹角为 $\varphi$ , 目标的距离走动为时间的多项式函数, 经泰勒级数展开得到

$$r_s(t_m) = r_0 - vt_m - \frac{1}{2!} v' t_m^2 - \frac{1}{3!} v'' t_m^3 - \dots, \\ t_m \in [-T_n/2, T_n/2] \quad (4)$$

式中,  $v$  是目标径向速度,  $T_n$  为相参积累时间。仅保留式(4)的前4项作为观测距离的近似, 则式(4)改写为:

$$r_s(t_m) = r_0 - v_0 t_m - a t_m^2/2 - g t_m^3/6 \quad (5)$$

式中,  $r_0$ 为目标与雷达的距离,  $v_0$ ,  $a$ ,  $g$ 分别为目标初速度, 加速度和加速度变化率在观测方向上的分量。

## (2) 海面微动目标信号模型

海面微动目标雷达回波信号反映了散射点与雷达的位置变化情况, 建立微动目标信号模型即建立观测距离与目标运动参数、时间之间的关系式。散射点与雷达的距离可表示为目标自身转动角度的函数, 而转动角度则是时间和角速度的函数, 假设目标质心与雷达的相对位置不变, 目标微动类似简谐运动, 其运动角速度可用最大角速度和角速度变化周期描述。因此先建立观测距离和转动角度的几何关系模型, 然后通过目标运动参数写出角度随时间变化的表达式, 得到回波信号的时间函数。观测距离和转动角度的几何关系模型采用文献[14]中的3轴转动模型, 观测距离为:

$$r_s(t_m) = \sin \phi (a_{11}x + a_{12}y + a_{13}z) + \cos \phi (a_{21}x + a_{22}y + a_{23}z) \quad (6)$$

式中,  $\phi$ 为目标舰船左舷方向与观测方向的夹角,  $a_{ii}$ 为:

$$\begin{cases} a_{11} = \cos \theta_y \cos \theta_z \\ a_{12} = -\cos \theta_y \sin \theta_z \\ a_{13} = \sin \theta_y \\ a_{21} = \sin \theta_x \sin \theta_y \cos \theta_z + \cos \theta_x \sin \theta_z \\ a_{22} = -\sin \theta_x \sin \theta_y \sin \theta_z + \cos \theta_x \cos \theta_z \\ a_{23} = -\sin \theta_x \cos \theta_y \end{cases} \quad (7)$$

式中,  $\theta_x$ ,  $\theta_y$ ,  $\theta_z$ 为对应的旋转角度。假设目标在每个轴向上做简谐运动, 初相位为0, 则角速度的每个分量 $\omega_i(t_m)$ 分别为:

$$\omega_i(t_m) = \omega_{im} \cos \left( \frac{2\pi}{T_i} t_m \right) \quad (8)$$

式中,  $T_i$ 分别为各个分量简谐运动的周期,  $\omega_{im}$ 分别为各个分量简谐运动的角速度最大值。则 $t$ 时刻目标3个方向上的转动角度分别为:

$$\theta_i(t_m) = \int_0^{t_m} \omega_i(\tau) d\tau \quad (9)$$

因此, 通过设置目标3个方向微动的最大角速度和角速度变化周期, 根据式(6)、式(7)、式(8)、式(9)可以得到观测距离的时间函数, 再根据式(3)即可仿真微动目标的雷达回波信号。

本文将匀变速, 变加速和两种不同运动参数的3轴转动作为重点研究对象, 其中匀变速运动多普勒谱如式(10)所示, 具有一次函数的特点。变加速运动多普勒谱如式(11)所示, 具有2次函数的特

点。微动目标多普勒谱如式(12)所示, 具有周期性特征。

$$f_{d1} = \frac{2}{\lambda} (v_0 + at_m) \quad (10)$$

$$f_{d2} = \frac{2}{\lambda} (v_0 + at_m + gt_m^2/2) \quad (11)$$

式中,  $\lambda$ 为波长, 微动目标多普勒谱具有周期性特征。在较短观测时间内,  $\sin \theta_i \approx \omega_i(t_m)t_m$ ,  $\cos \theta_i \approx 1$ , 当目标分别做横滚、偏航、俯仰运动时, 微动目标多普勒谱如式(12)、式(13)、式(14)所示:

$$f_{dx} = \frac{2}{\lambda} \frac{dr_s(t_m)}{dt_m} = \frac{2}{\lambda} \cos \phi \left[ -y\omega_{xm}^2 \cos^2 \left( \frac{2\pi}{T_x} t_m \right) t_m - z\omega_{xm} \cos \left( \frac{2\pi}{T_x} t_m \right) \right] \quad (12)$$

$$f_{dy} = \frac{2}{\lambda} \sin \phi \left[ -x\omega_{ym}^2 \cos^2 \left( \frac{2\pi}{T_y} t_m \right) t_m + z\omega_{ym} \cos \left( \frac{2\pi}{T_y} t_m \right) \right] \quad (13)$$

$$f_{dz} = \frac{2}{\lambda} \left\{ \sin \phi \left[ -x\omega_{zm}^2 \cos \left( \frac{2\pi}{T_z} t_m \right) t_m - y\omega_{zm} \cos \left( \frac{2\pi}{T_z} t_m \right) \right] + \cos \phi \left[ x\omega_{zm} \cos \left( \frac{2\pi}{T_z} t_m \right) - y\omega_{zm}^2 \cos \left( \frac{2\pi}{T_z} t_m \right) t_m \right] \right\} \quad (14)$$

两类微动目标中, 一类姿态转动角度大、周期短, 例如中小型舰船; 另一类转动幅度小、周期长, 例如大型舰船。两类目标微动特征差异主要体现在微多普勒的幅度和变化周期的不同, 详见3.2小节。

## 2.2 CNN网络模型介绍

CNN是计算机视觉中常见的算法, 尤其是在2维图像的处理领域有着广泛运用。由于本文所采用的数据集由2维时频图构成, 因此可利用CNN进行特征学习, 并用于检测和分类。CNN主要包括多个卷积层、池化层和全连接层, 最后用softmax分类作为输出层。本文选用LeNet, AlexNet和GoogLeNet网络进行训练和测试, LeNet是最早的卷积神经网络之一, 起初被用于进行手写数字识别; AlexNet则是LeNet的一种更深更宽的版本, 将LeNet思想扩展到了能学习到更复杂的对象与对象层次的神经网络上。GoogLeNet是一种“网络中的网络”, 其思想是在深度神经网络达到较高水平性能的同时减少其计算开销。这3种网络是CNN中常见且具有代表性的网络。

### (1) LeNet

LeNet网络共有7层, 结构如图1(a)所示, 包括两个卷积层, 两个全连接层和一个softmax输出层, 在每个卷积层后有一个池化层。其卷积层的卷积核大小为 $5 \times 5$ , 池化层选用最大池化函数降采样, 即对领域内特征点取最大。全连接层计算输入向量和权重向量之间的点积, 再加上一个偏置, 结果通过sigmoid函数输出。

$$S(x) = \frac{1}{1 + e^{-x}} \quad (15)$$

输出层采用径向基函数(Radial Basis Function, RBF)网络连接方式, RBF输出值越接近0, 则识别结果越接近第*i*类别。

$$y_i = \sum_j (x_j - w_{ij})^2 \quad (16)$$

### (2) AlexNet

AlexNet网络结构如图1(b)所示, 包括5个卷积层和3个全连接层, 前两个卷积层由1个子层和1个响应归一化层组成。每个层后面都跟了一个ReLU操作:

$$f(x) = \max(0, x) \quad (17)$$

并且第1、第2、第5个卷积层后面都有一个最大池化层。与LeNet相比, AlexNet通过使用局部响应归一化等多种方式避免过拟合。

### (3) GoogLeNet

GoogLeNet是一种通过加深网络模型深度和宽度构建的卷积神经网络模型, 其结构如图1(c)所示, 它由22个层组成, 有超过100个参数。它使用

RGB三色通道, 感应像素的大小为 $224 \times 224$ 。为了防止梯度消失, 它设置两个不同深度的损失函数以保证返回梯度。为了避免过拟合和加快收敛速度, 每个卷积操作后都进行ReLU(式(17))操作。此外它还通过使用inception模块来增加网络的宽度。

## 2.3 训练及测试方法

本文使用Python2.7, VS2013, CUDA7.5, cudnn5.1, caffe的环境架构, 并通过NVIDIA digits进行图像的图形化界面处理, 计算机配置为双E5处理器, 显卡为NVIDIA Quadro M2000, 内存24 GB。根据训练过程中loss值的收敛情况, 模型训练参数设置为: 迭代次数30, 参数求解算法采用随机梯度下降, 下降策略采用step down<sup>[15]</sup>, 初始学习率0.01, 步长33%, 变化率为0.1。以LeNet为例, 图2(a)和图2(c)分别为CNN的第1个卷积层和第2个卷积层的卷积核, 图2(b)和图2(d)分别为第1个卷积层和第2个卷积层的特征图。

## 3 基于CNN的海上微动目标检测和分类

### 3.1 算法流程

主要包括4个步骤: (1)数据预处理; (2)数据集构建和模型训练; (3)目标检测; (4)目标分类, 算法流程如图3所示。首先对雷达回波进行解调和脉冲压缩。然后采用短时傅里叶变换(Short-time Fourier Transform, STFT)将回波转换为2维时频图, 得到不同运动类型的时频图作为训练集和测试集中的样本。第2步进行目标检测, 用训练集训练3个不同的目标检测模型, 并使用测试集对3个模型分别进行测试, 选取检测概率最高的一个模型, 分

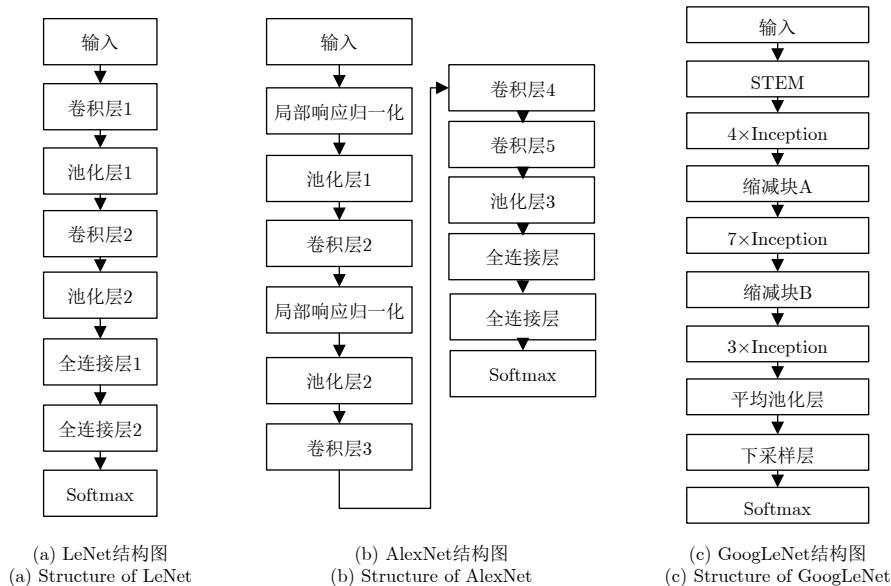


图 1 本文采用的3种CNN网络结构

Fig. 1 Structure of three CNNs used in this paper

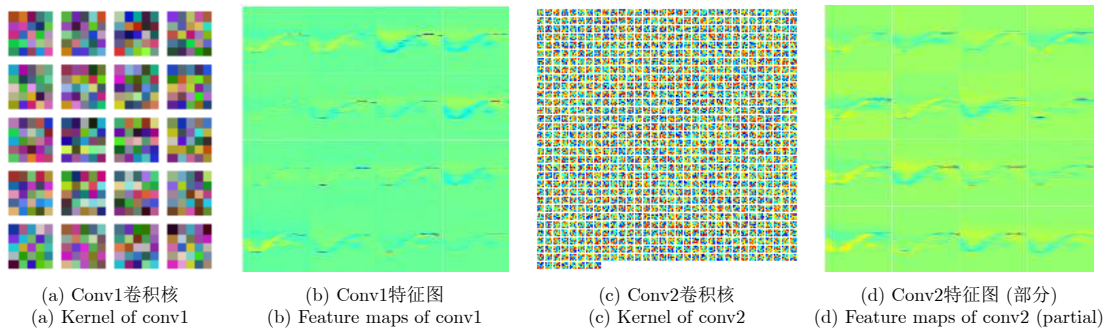


图 2 CNN中各卷积层的数据特征(以LeNet为例)

Fig. 2 Data characteristics of each convolution layer in CNN (e.g., LeNet)

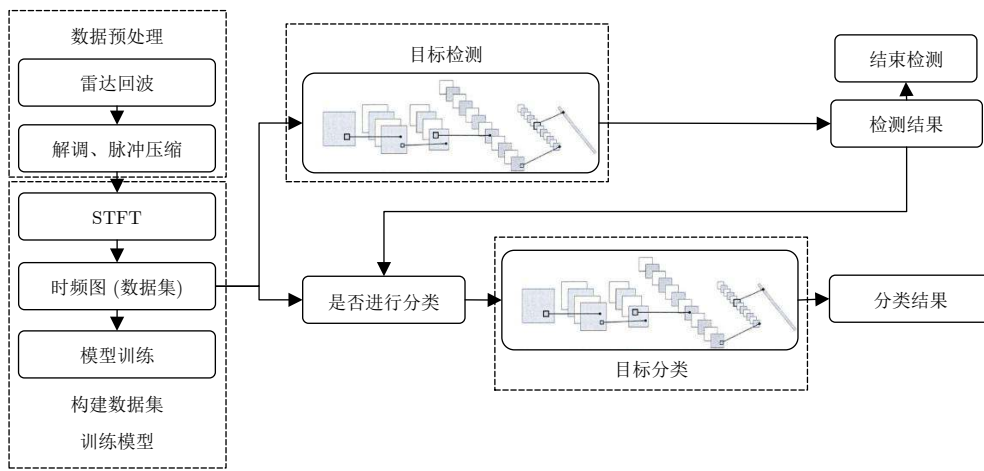


图 3 所提方法处理流程图

Fig. 3 Processing flow diagram of the proposed method

析SCR对模型检测性能的影响，并对错误检测的样本进行重点研究。若结果为杂波则重新测试其他数据，若结果为目标，则用目标分类模型对该数据进行进一步的分类，从而实现海面目标的检测与分类。其中目标检测通过CNN网络二元分类，区分目标和杂波样本，实现目标检测功能。目标分类模型实现对4种不同运动状态的目标进行分类。

### 3.2 训练数据集的构建

模型训练和测试所用的数据包括仿真目标信号和实测海杂波。首先设置4种微动目标及其运动参数，如表1所示。再根据海面微动目标信号模型得

到仿真的目标回波信号，设置雷达工作在X波段(8 GHz)。选取IPIX数据中纯海杂波单元中的数据作为海杂波训练集，并按照一定的SCR仿真微动目标信号，

$$\begin{cases} P_c = \frac{1}{l_c} \sum |clu_i|^2 \\ P_s = P_c 10^{\frac{SCR}{10}} \\ sig = P_s s(t) \end{cases} \quad (18)$$

式中， $P_c$ 为杂波功率， $l_c$ 为杂波信号长度， $clu$ 为选取的实测杂波信号， $P_s$ 为目标信号功率， $sig$ 为待仿

表 1 微动参数设置

Tab. 1 Configuration of micro-motion parameters

运动类型	初速度 (m/s)	加速度 (m/s <sup>2</sup> )	急动度 (m/s <sup>3</sup> )	采样点数	运动类型	角速度	微动周期(s)	采样点数
匀加速	[5, 15]	[-16, 16]	-	2 <sup>11</sup> Hz, 0.50 s	微动 I <sup>[16]</sup>	$ \bar{\omega}_{xm}  = [0.34, 0.42]$ rad/s	$T_x = 26.4$	2 <sup>8</sup> Hz, 8 s
						$ \bar{\omega}_{ym}  = [0.15, 0.17]$ rad/s	$T_y = 11.2$	
						$ \bar{\omega}_{zm}  = [0.07, 0.09]$ rad/s	$T_z = 33.0$	
非匀变速	[50, 300]	[-160, 160]	[-160, 160]	2 <sup>14</sup> Hz, 0.25 s	微动 II <sup>[16]</sup>	$ \bar{\omega}_{xm}  = [0.61, 0.65]$ rad/s	$T_x = 12.2$	2 <sup>10</sup> Hz, 8 s
						$ \bar{\omega}_{ym}  = [0.95, 1.07]$ rad/s	$T_y = 6.7$	
						$ \bar{\omega}_{zm}  = [0.52, 0.56]$ rad/s	$T_z = 14.2$	

真的目标信号,  $s(t)$ 为微动信号波形。需要说明的是本文所示SCR均为脉压后时域SCR, 同时在保证不发生多普勒模糊的情况下, 采用不同的采样点数以保证具有明显的微动特征。

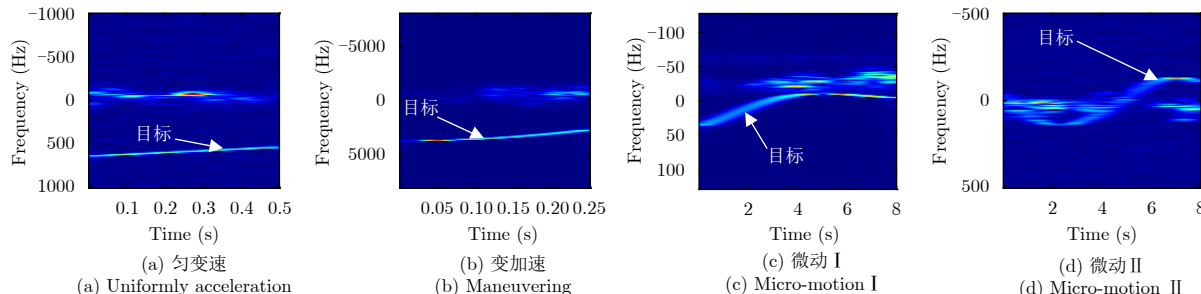


图 4 数据集示例

Fig. 4 Examples of datasets

### 3.3 CNN模型训练

目标检测模型训练集包括12900张图片, 分为杂波和目标两类。其中杂波信号时频图7500张, 目标信号时频图5400张(包括18种SCR, 每种SCR下仿真图像有300张, 每种SCR下的时频图又包括4种运动目标类型, 每一类目标75张)。目标分类模型训练集包括5016张图片, 分为匀变速、变加速、微动 I 和微动 II 4类。其中匀变速目标信号时频图1392张, 变加速目标信号时频图1704张, 微动 I 和微动 II 目标信号时频图各960张。不同模型训练时长如表2所示。

## 4 仿真结果及分析

### 4.1 不同模型目标检测性能比较

目标检测仿真测试集包括4300张图片, 分为杂

波和目标两类。其中杂波信号时频图2500张, 目标信号时频图1800张(包括18种SCR, 每种SCR下仿真图像有100张, 每种SCR下的时频图又包括4种运动目标类型, 每一类目标25张)。用该测试集对3个目标检测模型进行测试, 测试结果如表3所示。

表3中测试结果显示, LeNet模型检测概率最高, 而AlexNet模型可以达到更低的虚警概率。其中错判样本主要包括以下4类: 部分信号中杂波多普勒谱较宽, 甚至近似高斯分布, 易发生漏警和虚警, 如图5(a)所示。低速目标多普勒谱与杂波谱重叠, 易造成漏警, 如图5(b)所示。低SCR情况下漏警概率也会明显升高, 如图5(c)所示。还有部分杂波特性与目标相似, 如图5(d)所示, 图中为杂波多普勒谱, 但是具有与目标类似的特征。造成虚警。

表 2 CNN模型训练时长

Tab. 2 Training time of CNN models

模型	目标检测模型			目标分类模型		
	LeNet	AlexNet	GoogLeNet	LeNet	AlexNet	GoogLeNet
训练用时(min)	68.00	37.52	175.00	27.92	38.40	54.43

表 3 不同模型目标检测结果

Tab. 3 Results of target detection of different models

模型	LeNet	AlexNet	GoogLeNet
虚警概率	1.24%	0.04%	0.24%
检测概率	92.28%	84.44%	90.94%
仿真时间(min)	41.92	57.15	43.77

### 4.2 信杂比对目标检测性能的影响

信杂比对目标检测性能影响仿真中, 每个SCR下测试集包括910张图片, 分为杂波和目标两

类。其中杂波信号时频图100张, 目标信号时频图810张(其中微动 II 时频图像210张, 其他3类时频图像各200张)。选用检测概率最高的LeNet检测模型, 进行不同SCR下的目标检测仿真, 将仿真结果用检测概率-信杂比折线图表示, 如图6(a)所示。在SCR不低于-10 dB时检测概率稳定在95%以上; 低于-10 dB时检测概率随SCR降低而下降, -20 dB时检测概率降至90%, 当SCR低至-30 dB时检测概率降至80%。随后再使用大量杂波样本对模型进行测试, 测得该模型虚警概率约为0.029。

### 4.3 不同模型目标分类性能比较

目标分类仿真测试集包括1672张图片, 分为匀变速、变加速、微动 I 和微动 II 4类。其中匀变速目标信号时频图464张, 变加速目标信号时频图568张, 微动 I 和微动 II 目标信号时频图各320张。

用该测试集分别测试3个目标分类模型, 结果如图7所示。

3个模型仿真时间差异不大(LeNet, AlexNet和GoogLeNet分别为31.08 min, 32.25 min和30.65 min), 通过比较3个模型对同一测试集分类结果, 发现3个




图5 错判示例图

Fig. 5 Examples of wrong judgment

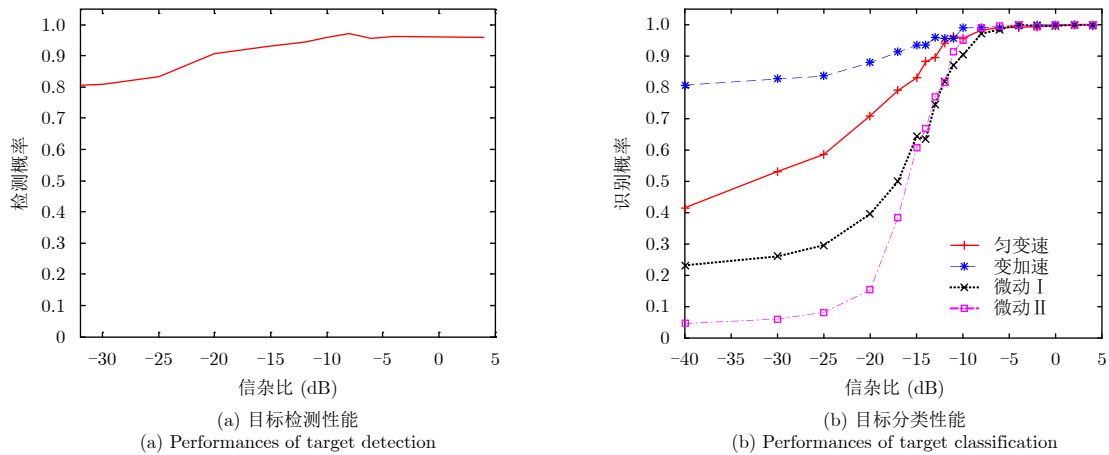


图6 不同信杂比下目标检测分类性能

Fig. 6 Performances of target classification under different SCRs

	匀变速	变加速	微动 I	微动 II		匀变速	变加速	微动 I	微动 II		匀变速	变加速	微动 I	微动 II
匀变速	99.35%	0.65%	0.00%	0.00%	匀变速	100.00%	0.00%	0.00%	0.00%	匀变速	100.00%	0.00%	0.00%	0.00%
变加速	0.00%	99.65%	0.18%	0.18%	变加速	36.80%	59.51%	3.34%	0.35%	变加速	14.61%	80.11%	4.75%	0.53%
微动 I	0.31%	0.94%	98.75%	0.00%	微动 I	20.31%	0.94%	78.75%	0.00%	微动 I	18.75%	0.31%	80.63%	0.31%
微动 II	0.00%	0.00%	0.00%	100.00%	微动 II	0.00%	0.00%	17.81%	82.19%	微动 II	0.00%	0.00%	13.12%	86.88%
	99.66%	101.24%	98.93%	100.18%		157.11%	60.45%	99.90%	82.54%		133.36%	80.42%	98.50%	87.72%

(a) LeNet混淆矩阵  
(a) Confusion matrix of LeNet

(b) AlexNet混淆矩阵  
(b) Confusion matrix of AlexNet

(c) GoogLeNet混淆矩阵  
(c) Confusion matrix of GoogLeNet

图7 不同模型目标分类结果

Fig. 7 Results of target classification via different models

模型在检测性能上有明显差异。其中LeNet可以实现最高的识别概率，总识别概率达到99.46%，且每种目标识别概率均不低于98.75%。AlexNet和GoogLeNet总识别概率分别为78.77%和87.02%，通过分析其分类结果发现，这两类模型分类测试时误判情况有一定相似性，主要误判来自于以下几类：变加速目标被识别为匀变速目标、微动 I 类别目标被识别为匀变速、微动 II 类别目标被识别为微动 I 类别。

#### 4.4 信杂比对目标分类性能的影响

SCR对目标检测性能影响仿真中，每个SCR下测试集包括1760张图片，分为匀变速、变加速、微动 I 和微动 II 4类。其中匀变速目标信号时频图348张，变加速目标信号时频图852张，微动 I 和微动 II 目标信号时频图各280张。选取LeNet目标分类模型对不同SCR下的测试集进行仿真，结果如图6(b)所示。从图中可以看出，当SCR不低于-4 dB时，各类目标的识别概率较高，且几乎不受SCR变化影响。当SCR低于-4 dB时，识别概率随SCR下降而降低，

且在SCR低于-8 dB、高于-25 dB时，这一变化更加明显。其中两种微动目标的识别概率受SCR影响最明显，而变加速运动在SCR低至-40 dB时仍有超过80%的识别概率。这一差别主要由样本特征随SCR降低而减弱造成，由于训练集中变加速样本比例较高会导致目标特征弱的样本被判为变加速类型。随SCR降低，时频图中目标特征减弱，识别概率更多受模型自身参数影响，识别结果的参考价值下降。此外，考虑到时频图计算时的积累增益，也对低SCR的检测和识别性能有较大的贡献作用。

#### 4.5 与现有方法比较

采用支持向量机(Support Vector Machine, SVM)的方法对回波信号的时频图进行目标检测和分类，以比较本文方法与传统方法的性能。SVM是一种基于结构风险最小化准则，通过构建超平面进行分类的算法，其仿真结果如表4所示。SVM单次检测时虚警概率为0.2207。相比于传统SVM分类方法，基于CNN的海面目标检测与分类方法具有更高的检测、识别概率和更低的虚警概率。

表 4 基于CNN和SVM的海面目标检测与分类结果比较

Tab. 4 Comparison of maritime targets detection and classification results based on CNN and SVM

分类方法	虚警概率	检测概率(%)				识别概率(SCR=-4 dB)(%)			
		SCR=4 dB	SCR=-4 dB	SCR=-12 dB	SCR=-20 dB	匀变速	变加速	微动 I	微动 II
CNN	0.0290	95.80	96.30	94.11	90.62	100.00	100.00	99.65	100.00
SVM	0.2207	80.52	79.90	77.81	77.31	84.30	84.46	73.56	94.25

通过以上仿真，得出如下结论：(1)通过时频分析和深度学习的方法可以实现对海面目标的检测，在SCR不低于-20 dB的情况下检测概率超过90%。(2)在完成目标检测之后，通过时频分析和深度学习的方法可以对海面目标进行分类，且在SCR不低于-6 dB时性能稳定，在SCR不低于-10 dB时，各类目标的识别概率均不低于90%，随着SCR继续降低，目标多普勒谱受杂波干扰明显，进而影响特征提取，导致目标识别概率下降明显。影响目标识别性能的主要因素除SCR外还包括杂波特性、目标运动类型和目标速度。(3)本文提到的3种深度学习模型对雷达回波信号的处理效率相当，但是在检测和分类的准确率上，LeNet模型优势较大。(4)基于深度学习的分类方法在目标检测和分类中性能优于SVM等传统分类方法，但是前者性能受SCR影响较大。

## 5 结论

本文提出了一种基于CNN的海面微动目标检

测与分类方法。在这一方法中，利用CNN模型对雷达回波信号的时频图进行分类。文中使用仿真雷达回波信号进行CNN训练和测试，用于海面目标的检测与分类。检测和分类结果体现了CNN在雷达信号时频图像处理应用中目标微动特征提取识别的高精度智能化优势。与传统SVM分类方法相比，基于CNN的方法在检测和识别概率上更具有优势，也为雷达海上动目标检测和分类提供了新的思路。下一步，将针对虚警概率高，在杂波多普勒较宽、低SCR或目标速度较低的情况下检测分类性能弱等问题，开展预处理方法、判决准则、仿真流程优化和使用实测数据测试性能等研究，以验证和提高所提方法在对实际海上目标检测和分类性能。

#### 参 考 文 献

- [1] Darzikolaei M A, Ebrahimzade A, and Gholami E. Classification of radar clutters with artificial neural network[C]. Proceedings of the 2nd International Conference on Knowledge-Based Engineering and Innovation, Tehran, Iran, 2015: 577-581.

- [2] 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. DOI: [10.3724/SP.J.1300.2013.20102](https://doi.org/10.3724/SP.J.1300.2013.20102).
- Chen Xiao-long, Guan Jian, and He You. Applications and prospect of micro-motion theory in the detection of sea surface target[J]. *Journal of Radars*, 2013, 2(1): 123–134. DOI: [10.3724/SP.J.1300.2013.20102](https://doi.org/10.3724/SP.J.1300.2013.20102).
- [3] 罗迎, 张群, 王国正, 等. 基于复图像OMP分解的宽带雷达微动特征提取方法[J]. 雷达学报, 2012, 1(4): 361–369. DOI: [10.3724/SP.J.1300.2012.20065](https://doi.org/10.3724/SP.J.1300.2012.20065).
- Luo Ying, Zhang Qun, Wang Guo-zheng, *et al.*. Micro-motion signature extraction method for wideband radar based on complex image OMP decomposition[J]. *Journal of Radars*, 2012, 1(4): 361–369. DOI: [10.3724/SP.J.1300.2012.20065](https://doi.org/10.3724/SP.J.1300.2012.20065).
- [4] Chen X L, Guan J, Bao Z H, *et al.*. Detection and extraction of target with micromotion in spiky sea clutter via short-time fractional Fourier transform[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(2): 1002–1018. DOI: [10.1109/TGRS.2013.2246574](https://doi.org/10.1109/TGRS.2013.2246574).
- [5] Chen X L, Guan J, Li X Y, *et al.*. Effective coherent integration method for marine target with micromotion via phase differentiation and radon-Lv's distribution[J]. *IET Radar, Sonar & Navigation*, 2015, 9(9): 1284–1295. DOI: [10.1049/iet-rsn.2015.0100](https://doi.org/10.1049/iet-rsn.2015.0100).
- [6] Wagner S A. SAR ATR by a combination of convolutional neural network and support vector machines[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2016, 52(6): 2861–2872. DOI: [10.1109/TAES.2016.160061](https://doi.org/10.1109/TAES.2016.160061).
- [7] 田壮壮, 占荣辉, 胡杰民, 等. 基于卷积神经网络的SAR图像目标识别研究[J]. 雷达学报, 2016, 5(3): 320–325. DOI: [10.12000/JR16037](https://doi.org/10.12000/JR16037).
- Tian Zhuang-zhuang, Zhan Rong-hui, Hu Jie-min, *et al.*. SAR ATR based on convolutional neural network[J]. *Journal of Radars*, 2016, 5(3): 320–325. DOI: [10.12000/JR16037](https://doi.org/10.12000/JR16037).
- [8] Kim Y and Toomajian B. Hand gesture recognition using micro-Doppler signatures with convolutional neural network[J]. *IEEE Access*, 2016, 4: 7125–7130. DOI: [10.1109/ACCESS.2016.2617282](https://doi.org/10.1109/ACCESS.2016.2617282).
- [9] 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. DOI: [10.12000/JR18040](https://doi.org/10.12000/JR18040).
- Wang Jun, Zheng Tong, Lei Peng, *et al.*. Survey of study on deep learning in radar[J]. *Journal of Radars*, 2018, 7(4): 395–411. DOI: [10.12000/JR18040](https://doi.org/10.12000/JR18040).
- [10] 徐彬, 陈渤, 刘宏伟, 等. 基于注意循环神经网络模型的雷达高分辨率距离像目标识别[J]. 电子与信息学报, 2016, 38(12): 2988–2995. DOI: [10.11999/JEIT161034](https://doi.org/10.11999/JEIT161034).
- Xu Bin, Chen Bo, Liu Hong-wei, *et al.*. Attention-based recurrent neural network model for radar high-resolution range profile target recognition[J]. *Journal of Electronics & Information Technology*, 2016, 38(12): 2988–2995. DOI: [10.11999/JEIT161034](https://doi.org/10.11999/JEIT161034).
- [11] 王星, 周一鹏, 周冬青, 等. 基于深度置信网络和双谱对角切片的低截获概率雷达信号识别[J]. 电子与信息学报, 2016, 38(11): 2972–2976. DOI: [10.11999/JEIT160031](https://doi.org/10.11999/JEIT160031).
- Wang Xing, Zhou Yi-peng, Zhou Dong-qing, *et al.*. Research on low probability of intercept radar signal recognition using deep belief network and bispectra diagonal slice[J]. *Journal of Electronics & Information Technology*, 2016, 38(11): 2972–2976. DOI: [10.11999/JEIT160031](https://doi.org/10.11999/JEIT160031).
- [12] 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. DOI: [10.12000/JR17075](https://doi.org/10.12000/JR17075).
- Xu Zhen, Wang Robert, Li Ning, *et al.*. A novel approach to change detection in SAR images with CNN classification[J]. *Journal of Radars*, 2017, 6(5): 483–491. DOI: [10.12000/JR17075](https://doi.org/10.12000/JR17075).
- [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): 136–148. DOI: [10.12000/JR16130](https://doi.org/10.12000/JR16130).
- Xu Feng, Wang Hai-peng, and Jin Ya-qiu. Deep learning as applied in SAR target recognition and terrain classification[J]. *Journal of Radars*, 2017, 6(2): 136–148. DOI: [10.12000/JR16130](https://doi.org/10.12000/JR16130).
- [14] 陈小龙, 董云龙, 李秀友, 等. 海面刚体目标微动特征建模及特性分析[J]. 雷达学报, 2015, 4(6): 630–638. DOI: [10.12000/JR15079](https://doi.org/10.12000/JR15079).
- Chen Xiao-long, Dong Yun-long, Li Xiu-you, *et al.*. Modeling of micromotion and analysis of properties of rigid marine targets[J]. *Journal of Radars*, 2015, 4(6): 630–638. DOI: [10.12000/JR15079](https://doi.org/10.12000/JR15079).
- [15] Prusa J D and Khoshgoftaar T M. Improving deep neural network design with new text data representations[J]. *Journal of Big Data*, 2017, 4: 7. DOI: [10.1186/s40537-017-0065-8](https://doi.org/10.1186/s40537-017-0065-8).
- [16] 高建军. 多径和海浪波干扰下的舰船ISAR成像及横向定标[D]. [博士论文], 哈尔滨工业大学, 2010.
- Gao Jian-jun. ISAR ship imaging and cross-range scaling with multipath and sea clutter interference[D]. [Ph.D. dissertation], Harbin Institute of Technology, 2010.

### 作者简介



苏宁远(1995-), 男, 山东烟台人, 硕士在读。主要研究方向为智能雷达信号处理、目标检测。

E-mail: 965291799@qq.com



牟效乾(1995-), 男, 山东烟台人, 硕士在读。研究领域包括智能雷达信号处理、动目标检测等。

E-mail: 1012226010@qq.com



陈小龙(1985-), 男, 山东烟台人, 博士, 讲师。研究领域包括雷达动目标检测、海杂波抑制、雷达信号精细化处理等。入选中国科协“青年人才托举工程”, 获中国电子学会优秀博士学位论文奖, 第十九届中国专利优秀奖, 中国电子学会科技进步三等奖。

E-mail: cxlxl1209@163.com



刘宁波(1983-), 男, 山东烟台人, 博士, 讲师, 研究方向为雷达信号处理、海杂波抑制与目标智能检测。

E-mail: lnb198300@163.com



关 键(1968-), 男, 辽宁锦州人, 教授, 博士生导师。主要研究方向为包括雷达目标检测与跟踪、侦察图像处理和信息融合。获国家科技进步二等奖1项、军队科技进步一等奖2项, 山东省技术发明一等奖1项; “百千万人才工程”国家级人选, 入选教育部新世纪优秀人才支持计划。

E-mail: guanjian\_68@163.com