

基于 DenseNet 的机载雷达动目标检测

李贵锋, 童宁宁, 冯为可, 刘成梁

(空军工程大学防空反导学院, 西安, 710051)

摘要 针对传统机载雷达运动目标检测方法所需训练距离单元较多的问题, 将运动目标检测问题转化为多分类问题。首先, 基于少量训练距离单元数据构建分类所需的训练数据集; 然后, 基于卷积神经网络 DenseNet 构建多类分类器; 最后, 利用训练后的分类器提取雷达空时回波数据特征, 进行目标检测和参数估计。仿真结果表明: 基于 DenseNet 的机载雷达动目标检测方法能够有效检测目标, 估计目标的距离、多普勒频率等参数。相比传统空时自适应处理方法, 该方法能够显著减少所需训练距离单元数量; 相比现有基于分类的目标检测方法, 该方法能够有效提高目标检测和参数估计的准确度。

关键词 机载雷达; 运动目标检测; 分类; 卷积神经网络

DOI 10.3969/j.issn.1009-3516.2021.02.013

中图分类号 TP391.4 **文献标志码** A **文章编号** 1009-3516(2021)02-0083-08

Airborne Radar Moving Target Detection Based on DenseNet

LI Guifeng, TONG Ningning, FENG Weike, LIU Chengliang

(Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China)

Abstract Aimed at the problem that conventional moving target detection methods for airborne radar always need many training range samples, there is an adaptation, i. e. transforming the target detection problem into a multi-classification problem. Firstly, the training dataset is constructed based on a small amount of training range samples, and then, a multi-class classifier is constructed based on DenseNet. Finally, the trained classifier is utilized for extracting the characteristics of the received space-time data for target detection and parameter estimation. The simulation results show that the DenseNet-based airborne radar moving target detection method proposed can detect the target effectively, and estimate its distance, Doppler frequency, and other parameters. Compared with the conventional space time adaptive processing method, the proposed method can significantly reduce the number of needed training range samples. Compared with the existing target detection method based on classification, the proposed method can improve the accuracy of target detection and parameter estimation effectively.

Key words airborne radar; moving target detection; classification; convolution neural networks

雷达探测技术因其全天时、全天候的工作能力, 已经成为探测地/海面和低空运动目标的重要手段。

由于地基雷达容易受到遮蔽效应和低空盲区的影响, 利用机载雷达对地/海面和低空运动目标进行探

收稿日期: 2020-10-12

基金项目: 国家自然科学基金(62001507)

作者简介: 李贵锋(1997—), 男, 河南南阳人, 硕士生, 研究方向: 目标探测与识别。E-mail: 18192077937@163.com

引用格式: 李贵锋, 童宁宁, 冯为可, 等. 基于 DenseNet 的机载雷达动目标检测[J]. 空军工程大学学报(自然科学版), 2021, 22(2): 83-90.
LI Guifeng, TONG Ningning, FENG Weike, et al. Airborne Radar Moving Target Detection Based on DenseNet[J]. Journal of Air Force Engineering University (Natural Science Edition), 2021, 22(2): 83-90.

勒频率; $f_T^i = d \cos \varphi_T \cos \theta_T / \lambda$ 为目标空间频率; λ 为波长; θ_T, φ_T 和 v_T 分别为目标方位角、俯仰角和速度; $x_{m,n}^{0,C}$ 表示接收信号中的杂波分量; α_i 为第 i 个杂波单元反射系数; $f_i^v = 2V \cos \varphi_i \cos \theta_i / \lambda f_r$ 和 $f_i^s = d \cos \varphi_i \cos \theta_i / \lambda$ 为第 i 个杂波单元的归一化多普勒频率和空间频率, θ_i 和 φ_i 分别为其对应的方位角和俯仰角; $\xi_{m,n}^0$ 表示接收信号中的噪声分量。

对应 M 个脉冲和 N 个阵元的待测距离单元空时回波信号可以由一个大小为 $MN \times 1$ 的向量 \mathbf{x}_0 表示, 即:

$$\mathbf{x}_0 = \alpha_T \mathbf{s}_T^{t,s} + \sum_{i=1}^{N_c} \alpha_i \mathbf{s}_i^{t,s} + \boldsymbol{\xi}_0 = \mathbf{x}_{T,0} + \mathbf{x}_{C,0} + \boldsymbol{\xi}_0 \quad (2)$$

式中: $\mathbf{x}_{T,0}, \mathbf{x}_{C,0}$ 和 $\boldsymbol{\xi}_0$ 分别表示目标向量、杂波向量和噪声向量; $\mathbf{s}_T^{t,s} = \mathbf{s}_T^t \otimes \mathbf{s}_T^s$ 表示目标的空时导向矢量, $\mathbf{s}_T^t = [1, \dots, e^{j2\pi(M-1)f_T^t}]^T$ 和 $\mathbf{s}_T^s = [1, \dots, e^{j2\pi(N-1)f_T^s}]^T$ 分别表示其时域导向矢量和空域导向矢量, $\mathbf{s}_i^{t,s} = \mathbf{s}_i^t \otimes \mathbf{s}_i^s$ 表示第 i 个杂波单元的空时导向矢量; $\mathbf{s}_i^t = [1, \dots, e^{j2\pi(M-1)f_i^t}]^T$ 和 $\mathbf{s}_i^s = [1, \dots, e^{j2\pi(N-1)f_i^s}]^T$ 分别表示其时域导向矢量和空域导向矢量, \otimes 表示克罗内克积。

假设各个杂波单元之间相互独立, 则杂波协方差矩阵 (clutter covariance matrix, CCM) 表示为:

$$\mathbf{R}_C = E[\mathbf{x}_{C,0} \mathbf{x}_{C,0}^H] = \sum_{i=1}^{N_c} E(|\alpha_i|^2) (\mathbf{s}_i^{t,s})^H \quad (3)$$

此外, 假设噪声与杂波不相关, 且服从均值为 0、协方差矩阵为 $\mathbf{R}_N = \sigma^2 \mathbf{I}_{MN}$ 的复高斯分布, 则杂波加噪声协方差矩阵 (clutter plus noise covariance matrix, CNCM) 可以表示为:

$$\mathbf{R}_I = \mathbf{R}_C + \sigma^2 \mathbf{I}_{MN} \quad (4)$$

式中: σ^2 为噪声功率; \mathbf{I}_{MN} 为大小为 $MN \times MN$ 的单元矩阵。

杂波环境下运动目标检测的目的即从式 (2) 中检测到目标回波信号 $\mathbf{x}_{T,0}$ 的存在, 可基于 STAP 方法实现。STAP 通过计算回波信号向量 \mathbf{x}_0 的线性组合使输出信号的信杂噪比 (signal to clutter plus noise ratio, SCNR) 最大, 而最佳加权系数 \mathbf{w}_0 , 即空时权值矢量, 可以通过最小化 CNCM 同时保持目标响应不变的方式进行优化求解, 表示为:

$$\min \mathbf{w}^H \mathbf{R}_I \mathbf{w}, \text{ s. t. } \mathbf{w}^H \mathbf{s}_T^{t,s} = 1 \quad (5)$$

式 (5) 的解为:

$$\mathbf{w}_0 = \mathbf{R}_I^{-1} \mathbf{s}_T^{t,s} / [(\mathbf{s}_T^{t,s})^H \mathbf{R}_I^{-1} \mathbf{s}_T^{t,s}] \quad (6)$$

2 所提算法

2.1 算法原理

在实际应用中, 待测距离单元的 CNCM 和目标

空时导向矢量往往是未知的。对于 CNCM 未知的问题, 若存在与待测距离单元杂波独立同分布且不包含目标的训练距离单元, 则待测距离单元的 CNCM 可通过采样矩阵求逆 (sample matrix inversion, SMI) 方法估计得到, 表示为:

$$\tilde{\mathbf{R}}_I = \sum_{l=1}^L \mathbf{x}_l \mathbf{x}_l^H / L \quad (7)$$

式中: $l=1, 2, \dots, L, \mathbf{x}_l$ 为第 l 个训练距离单元的回波信号向量。然而, 若要求输出 SCNR 的损失不大于 3 dB, 则 SMI 方法至少需要 $L=2MN-3$ 个独立同分布的训练距离单元来估计 CNCM, 这在实际非均匀杂波环境中是不现实的。

对于目标空时导向矢量未知的问题, 可以利用搜索多普勒频率和空间频率的方法进行处理: 首先, 给定多普勒频率和空间频率, 基于式 (6) 计算空时权值矢量; 接着, 对待测距离单元的回波信号进行加权处理, 得到滤波输出结果, 即 $y = \mathbf{w}_0^H \mathbf{x}_0$; 然后, 遍历所有感兴趣的距离单元, 得到每个距离单元的输出结果, 并利用恒虚警率 (constant false alarm rate, CFAR) 检测器进行检测; 最后, 遍历一定范围内的多普勒频率和空间频率, 输出目标最终检测结果, 包括目标的距离、多普勒频率和空间频率。

通过上述分析可知, 基于 STAP 的运动目标检测方法可以视为一种多次二分类方法。构造二分类器, STAP 方法需要大量的独立同分布训练距离单元估计 CNCM 和较高的复杂度计算 CNCM 的逆矩阵得到空时权值矢量。针对上述问题, 可直接将运动目标检测问题转化为一种多分类问题: 首先, 对于给定的待测距离单元回波信号向量, 基于训练距离单元构建数据集, 利用相应方法提取目标的特征, 构造多类分类器, 得到目标的多普勒频率和空间频率类别; 然后, 遍历所有感兴趣距离单元, 得到目标的距离类别。

从另一角度看, 对于具有不同多普勒频率和空间频率的目标, 雷达接收到的空时回波数据本身将具有不同的特征。通过构建合适的多类分类器, 可以直接提取空时回波数据的特征, 并对其进行分类, 输出每一类对应的概率, 根据概率最大值所对应的类即可判断目标的有无及其对应的多普勒频率和空间频率。上述过程可以表示为:

$$\mathbf{p} = \gamma(\mathbf{X}^0) \quad (8)$$

式中: \mathbf{X}^0 为输入多类分类器的待测距离单元空时回波数据; $\gamma(\cdot)$ 为代表多类分类器的非线性函数; \mathbf{p} 为分类器输出的概率矢量, 其最大值位置对应目标所在的类。

基于上述原理和 DenseNet 在特征提取方面的

优异性能,本文提出了基于 DenseNet 构造多类分类器对运动目标进行检测的方法,如图 2 所示。

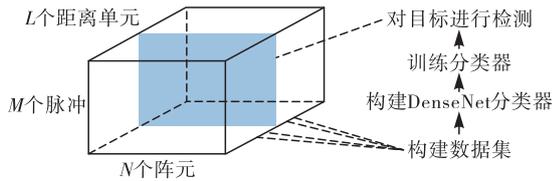


图 2 基于 DenseNet 的运动目标检测方法

2.2 数据集构建

对分类器进行训练以获得期望的性能需要充足的数据,本文通过使用少量训练距离单元与具有不同多普勒频率/空间频率且幅度/相位随机变化的运动目标相加的方式来构建训练数据集,具体实现方式描述如下。

对于任意待测距离单元,在其两侧各选取仅含杂波和噪声的 $L/2$ 个距离单元作为训练距离单元。其中,为避免目标距离向扩展带来的不利影响,设置保护距离单元,两侧保护距离单元的个数均为 $Q/2$ 。训练数据集共分为 $K+1$ 类,其中,第 0 类表示无目标,第 1~ K 类表示具有不同多普勒频率和空间频率的目标。当 $k=0$ 时,训练数据由训练距离单元空时回波数据加上微小扰动得到;当 $k=1,2,\dots,K$ 时,训练数据由训练距离单元空时回波数据加上建模得到的运动目标空时回波数据得到。因此,由第 l 个训练距离单元和第 k 类目标所构造的训练数据可表示为:

$$\mathbf{X}^{l,k,p} = \alpha_{l,k,p} e^{j\vartheta_{l,k,p}} e^{j2\pi[(m-1)f_k^t + (n-1)f_k^s]} + \mathbf{X}^l \quad (9)$$

式中: $p=1,2,\dots,P$, P 表示每类目标的复幅度个数;相位 $\vartheta_{l,k,p} \in [0, 2\pi]$ 服从随机均匀分布。当 $k=0$,即无运动目标时, $\alpha_{l,0,p} \in [\alpha_0^+, \alpha_0^-]$ 服从随机均匀分布,为微小扰动的幅度, f_0^t 和 f_0^s 满足 $f_0^t = (2V/f_r d) f_0^s$;当 $k \neq 0$,即存在运动目标时, $\alpha_{l,k,p} \in [\alpha^+, \alpha^-]$ 为运动目标的幅度,同样服从随机均匀分布, f_k^t 和 f_k^s 分别表示第 k 类运动目标的归一化多普勒频率和空间频率,满足 $f_k^t \neq (2V/f_r d) f_k^s$; \mathbf{X}^l 为第 l 个训练距离单元的空时回波数据。

由式(9)可知,训练数据集的总样本数为 l_{kp} ,每一类训练数据的样本数为 l_p 。对于 $M \times N$ 大小的矩阵 $\mathbf{X}^{l,k,p}$,将该矩阵的实部和虚部分 2 个通道进行存放,得到大小为 $M \times N \times 2$ 的三维矩阵,作为分类器的输入;对于不同类别的训练数据,分别设置长度为 K 的标签向量 \mathbf{y} ,其中,第 k 类训练数据所对应的标签向量 $\mathbf{y}^{l,k,p}$ 的第 k 个元素值为 1,其余均为 0。

2.3 分类器构建

在数据集构建完成后,需要构建分类器来提取数据特征完成分类任务。DenseNet 作为近年来新

提出的一种卷积神经网络,能够充分利用各层提取到的特征,相比 AlexNet 具有更优的性能,其结构如图 3 所示,包括初始化层、密集连接层、过渡层和分类层等。

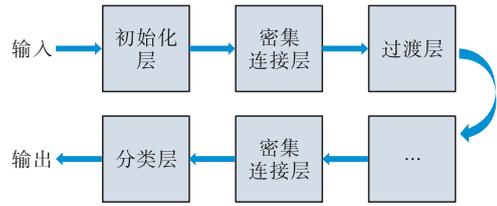


图 3 DenseNet 结构图

初始化层对输入图片进行数据初始化,由一次卷积操作和一次池化操作组成,使输入图片的特征图大小减半、数量增多。需要注意的是,对运动目标信号进行检测时,如果空时回波数据尺寸较小,就可以选择舍弃初始化层中的池化层,避免特征图过早变小导致无法充分挖掘利用特征。

密集连接层使用多个特征图大小相同的卷积模块对输入的特征图进行深层次的特征提取。其中,卷积模块是批量归一化(batch normalization, BN)、线性整流函数(rectified linear unit, ReLU)和卷积 3 种操作的组合,可以看成是一个非线性转换函数 κ 。BN 对数据进行规范化使其满足标准正态分布,同时也减少了整个训练集梯度的计算时间;ReLU 取代之前的 Sigmoid、Tanh 等激活函数,使梯度下降和误差反向传播更加高效,也避免了梯度消失的问题;卷积操作用于对经过 BN 和 ReLU 处理过的数据进行特征提取。密集连接层将前面所有卷积模块与后面的卷积模块建立连接,保留不同层次的特征一起向后传播。第 $j+1$ 个卷积模块的输入是前面 j 个卷积模块的输出层的并集,可以表示为 $c_{j+1} = \kappa([c_1, c_2, \dots, c_j])$ 。值得注意的是,使用 DenseNet 构建分类器时要根据输入特征图的大小选择合适数量的密集连接层及每个密集连接层中的卷积模块,确保高分类精度的同时做到高效率,没有冗余。

过渡层位于 2 个密集连接层之间,对前面密集连接层得到的特征图进行降维处理,包括卷积操作和平均池化操作。卷积操作用于减少特征图的数量;若前一个密集连接层输出 ζ_d 个特征图,经过过渡层中的卷积操作之后会生成 $\epsilon \zeta_d$ 个输出特征图,其中 ϵ 表示压缩系数;平均池化操作可用于减小特征图大小。

分类层对前面学到的特征进行分类,映射到标签所在空间。首先,分类层对最后一个密集连接层得到的特征图进行全局平均池化操作,对数据进行降维来融合前面学到的特征。然后,使用 Softmax 函数对全局平均池化得到的结果进行归一化,得到

输入数据属于每一类的概率向量。

3 仿真试验

3.1 仿真条件

本节用仿真试验来验证本文方法在机载雷达运动目标检测中的有效性,仿真参数为:载机高度 $H=3\text{ km}$,速度 $V=250\text{ m/s}$,ULA 阵元间距 $d=0.25\text{ m}$,相干脉冲数 $M=16$,阵元个数 $N=14$,脉冲重复频率 $f_r=2\ 000\text{ Hz}$,载波波长 0.5 m 。假设噪声为均值为 0、方差为 1 的复高斯信号, $N_c=181$ 个杂波单元在方位 $[0, \pi]$ 之间均匀分布,且幅度服从复高斯分布,杂噪比设为 40 dB 。本文共仿真 501 个距离单元的空时回波数据,距离为 $6\sim 31\text{ km}$,其中,目标所在距离单元的距离为 18.5 km ,目标的归一化多普勒频率为 -0.25 ,方位角为 45° ,信噪比为 30 dB 。

为简便起见,本文假设目标的空间频率 f_r 为已知,在此基础上构建数据集,对目标进行检测,并估计其距离和多普勒频率。构建训练数据集的参数如表 1 所示,其中,目标的类别个数为 $K+1=M+1$,且当 $k=0$ 时, $f_k^0=(2V/f_r d)f_r^0$;当 $k=1,2,\dots,M$ 时, $f_k^0=-1/2+(k-1)/M$ 。

表 1 训练数据集参数

参数	数值
K	16
Q	18
L	8
P	101
$[\alpha_0^+, \alpha_0^-]$	$[0, 10]\text{ dB}$
$[\alpha^+, \alpha^-]$	$[30, 40]\text{ dB}$

本文基于 DenseNet 构建的多类分类器由 1 个初始化层、3 个密集连接层、2 个过渡层、1 个全局平均池化层、1 个全连接层和 1 个最终分类层组成,网络模型如图 4 所示,各层参数如表 2 所示。可知,本文所构建的多类分类器的网络参数共为 55 199 个,相比文献[14]基于 AlexNet 构建的多类分类器,参数量减少了约 88%。

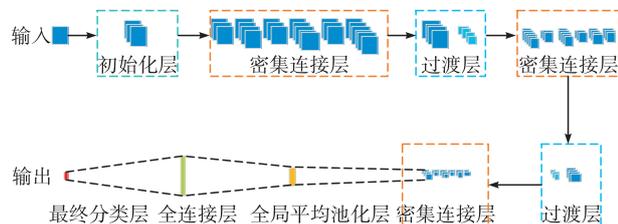


图 4 所提分类器网络结构

表 2 本文构建的多类分类器各层参数

Layer Name	Stride	Parameters	Output Shape
Input		0	(16,14,2)
Conv1	1	3 264	(16,14,64)
Conv2	1	4 616	(16,14,8)
Concatenate1		0	(16,14,72)
Conv3	1	5 192	(16,14,8)
Concatenate2		0	(16,14,80)
Conv4	1	5 768	(16,14,8)
Concatenate3		0	(16,14,88)
Conv5	1	3 916	(16,14,44)
AveragePooling1	2	0	(8,7,44)
Conv6	1	3 176	(8,7,8)
Concatenate4		0	(8,7,52)
Conv7	1	3 752	(8,7,8)
Concatenate5		0	(8,7,60)
Conv8	1	4 328	(8,7,8)
Concatenate6		0	(8,7,68)
Conv9	1	2 346	(8,7,34)
AveragePooling2	2	0	(4,3,34)
Conv10		2 456	(4,3,8)
Concatenate7		0	(4,3,42)
Conv11	1	3 032	(4,3,8)
Concatenate8		0	(4,3,50)
Conv12	1	3 608	(4,3,8)
Concatenate9		0	(4,3,58)
GlobalAveragePooling		0	58
Dense		7 552	128
Output		2 193	17

3.2 分类器训练与测试

在训练分类器时,批尺寸和训练次数会影响到分类器最终的内部权重,进而使预测结果产生差异。因而,本文设置 101 和 16 两种尺寸和不同的训练次数,来对不同的分类器进行训练并对比最终的效果。

自适应时刻估计(adaptive moment estimation, Adam)优化器是一种有效的随机优化方法,可通过对第一和第二梯度的估计来计算不同参数的自适应性学习率,并且只需要很小的内存^[19],因而能够快速收敛并找到参数更新中正确的目标方向。因此,本文选用 Adam 优化器对所提出的分类器进行训练。

从图 5 可见,本文所提出的基于 DenseNet 的分类器在两种不同批尺寸条件下的分类准确率均高于文献[14]所提出的基于 AlexNet 的分类器。

本文按照构建训练数据集的方式生成测试数据

集,对分类器进行测试,各类目标数量均为 100 个,所得分类混淆矩阵如图 6~7 所示。其中,对角线上的数字表示预测值与真实值相符,即测试数据集中每类目标正确分类的数量;对角线以外的数字表示预测值与真实值不相符,即测试数据集中每类目标错误分类的数量。由图可知,在不同批尺寸的条件,文献[14]基于 AlexNet 提出的分类器测试结果相差较大,随着批尺寸的下降,错误分类的数量从 24 降为 13;而本文基于 DenseNet 的分类器测试结果相差较小,错误分类的数量稳定在 5 左右。由此可得,本文分类器错误率低,识别精度高,更加稳定。

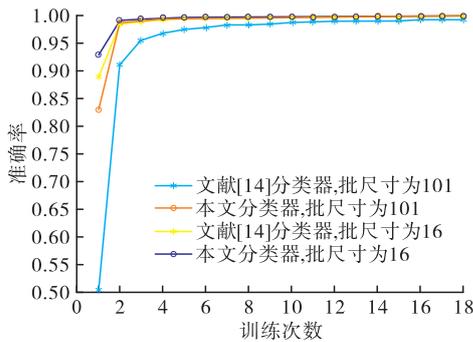


图 5 不同批尺寸时分类准确率随训练次数的变化曲线

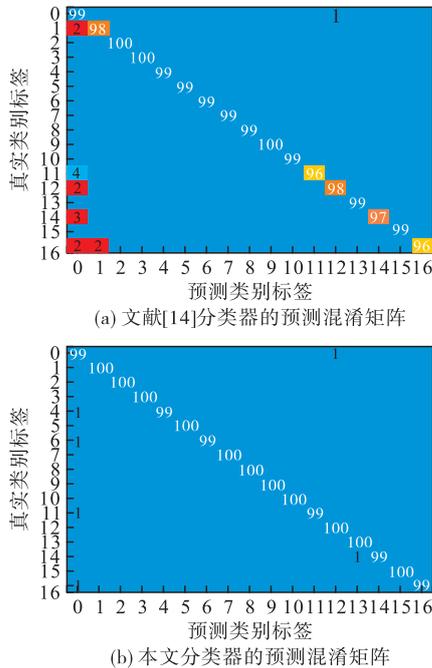
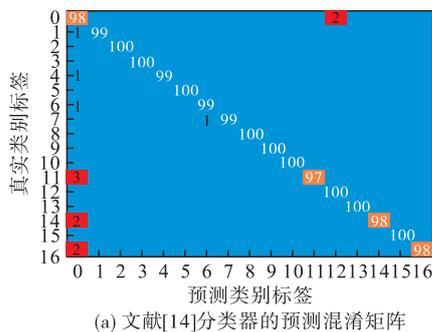


图 6 批尺寸为 101 时得到的分类混淆矩阵



(a) 文献[14]分类器的预测混淆矩阵

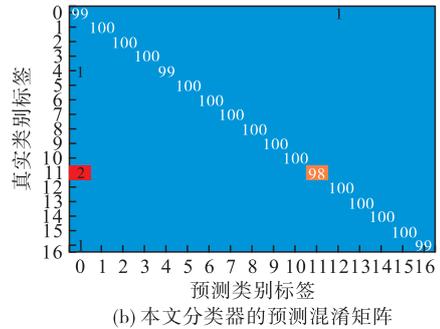


图 7 批尺寸为 16 时得到的分类混淆矩阵

接着,为了验证分类器的稳健性,即分类器在测试环境改变时的性能,使用不同于训练集的信杂比(signal to clutter ratio, SCR)来构建测试数据集,并根据实际对运动目标的时域导向矢量进行修改。

考虑到实际情况中天线接收到的回波在各个脉冲间的幅相变化,构建测试集时将运动目标的时域导向矢量修改为:

$$\tilde{s}_T = [1, \dots, e^{j2\pi(M-1)f_T^i}]^T \odot \mathbf{a}_T \odot \mathbf{b}_T \quad (10)$$

式中: \odot 表示哈达玛积, $\mathbf{a}_T = [a_0, a_1, \dots, a_{M-1}]^T$, $\mathbf{b}_T = [e^{j\beta_0}, e^{j\beta_1}, \dots, e^{j\beta_{M-1}}]^T$, a_M 在 $[0.9, 1.1]$ 之间均匀分布, β_M 在 $[-5^\circ, 5^\circ]$ 之间均匀分布。

对于批尺寸为 16 时训练得到的分类器,设置以 5 的步长逐步减小 SCR 构建测试集,进行 30 次实验得到的分类准确率如图 8 所示。

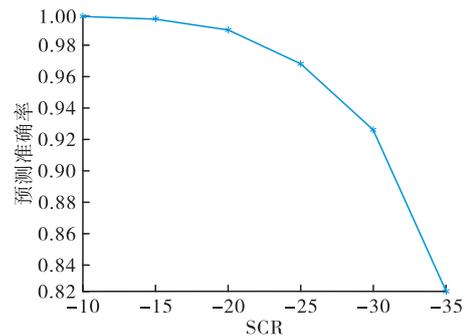


图 8 不同信杂比时本文分类器的预测准确率曲线

由图 8 可以看出,在 SCR 由 -10 dB 降为 -25 dB 的过程中,分类器的预测准确率缓慢下降;当 SCR 继续降低时,分类器预测准确率快速衰减。当 SCR 为 -30 dB 时的预测准确率为 92.59%,此时预测混淆矩阵如图 9 所示,各个类别均有误判现象产生,其中对应 $k=12, f_d=0.1875$ 的目标准确率仅为 37%。这是由于目标的空域归一化频率为 0.1910,与杂波较为接近,在 SCR 较小时,目标和杂波时难以区分,此时分类器失效。

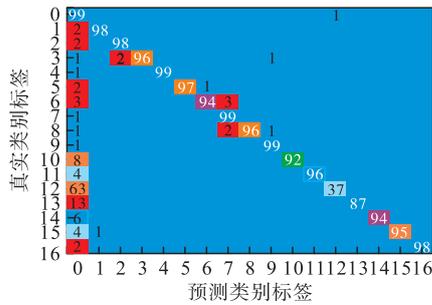
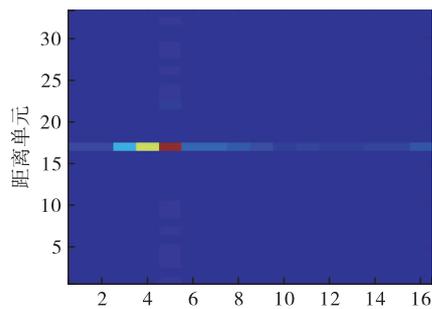


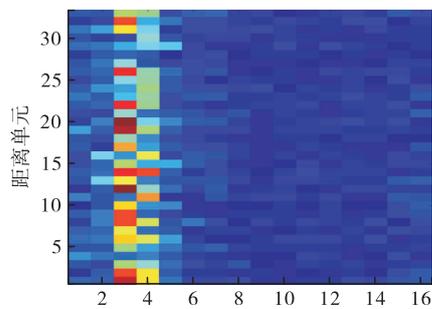
图 9 SCR = -30 dB 时预测混淆矩阵

3.3 动目标检测

分别使用传统 STAP 方法和基于分类的方法对目标所在的距离单元及其两侧各 16 个距离单元共 33 个距离单元的空时回波数据进行处理,检测运动目标并估计其参数。其中,利用传统 STAP 方法进行目标检测时分为 2 种情况:训练距离单元充足 ($L=2MN=448$) 和训练距离单元不足 ($L=8$),结果如图 10 所示,其中,横坐标类别 $k(k=1, 2, \dots, M)$ 对应归一化多普勒频率 $f_k^a = -1/2 + (k-1)/M$ 。由图 10 可以看出,当训练距离单元充足时,传统 STAP 算法可以有效检测目标,对应的类别为第 5 类,即目标归一化多普勒频率为 -0.25 ;然而,当训练距离单元不足时,传统 STAP 算法无法有效检测目标。



(a) 训练距离单元充足 ($L=448$)

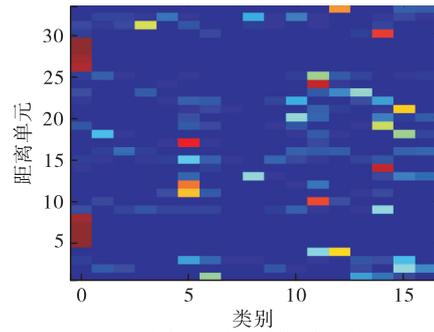


(b) 训练距离单元不足 ($L=8$)

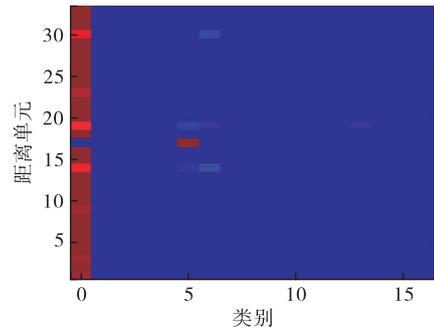
图 10 训练距离单元数量对 STAP 检测结果的影响

对于基于分类的运动目标检测方法(即本文方法和文献[14]方法),基于 $L=8$ 个训练距离单元,采用不同的批尺寸参数对所构建的多类分类器进行训练,并将 33 个距离单元空时回波数据输入到训练

后的分类器中,检测目标,估计其参数,所得结果如图 11 和图 12 所示。

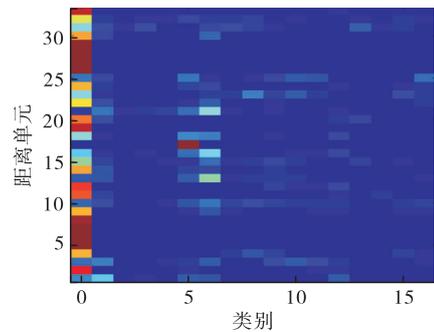


(a) 文献[14]方法目标检测结果

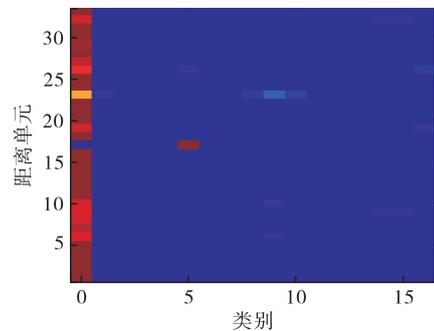


(b) 本文方法目标检测结果

图 11 批尺寸为 101 时两种方法的目标检测结果



(a) 文献[14]方法目标检测结果



(b) 本文方法目标检测结果

图 12 批尺寸为 16 时两种方法的目标检测结果

从图中可以看出,在批尺寸为 101 时,文献[14]方法无法有效检测运动目标;当批尺寸为 16 时,文献[14]方法能够检测运动目标,但性能有待进一步提高。相比之下,本文方法在这两种批尺寸时均能有效检测运动目标,目标所在距离单元为第 17 个距离单元,目标类别为 5(即多普勒频率等于 -0.25),

性能较文献[14]方法有较大提升,这验证了本文方法的有效性和优越性。

4 结语

为了减少机载雷达运动目标检测所需训练距离单元的数量,提高现有基于分类的运动目标检测方法的性能,本文基于 DenseNet 构建了分类器,对雷达接收到的空时回波数据进行处理,提取特征进行分类来实现运动目标的检测和参数估计。仿真结果表明该方法与传统 STAP 方法相比,可以减少所需训练距离单元的数量;与现有基于 AlexNet 的目标检测方法相比,能获得更加可靠、准确的目标检测结果。

参考文献

- [1] MELVIN W L. Space-Time Adaptive Processing for Radar[J]. Academic Press Library in Signal Processing, 2014, 2: 595-665.
- [2] FENG W K, ZHANG Y S, HE X Y. ClutterRank Estimation for Reduce-Dimension Space-Time Adaptive Processing MIMO Radar[J]. IEEE Sensors Journal, 2016, 17(2): 238-239.
- [3] FA R, DE LAMARE R C, WANG L. Reduced-Rank STAP Schemes for Airborne Radar Based on Switched Joint Interpolation, Decimation and Filtering Algorithm[J]. IEEE Transactions on Signal Processing, 2010, 58(8): 4182-4194.
- [4] CRISTALLINI D, BURGER W. A Robust Direct Data Domain Approach for STAP[J]. IEEE Transactions on Signal Processing, 2011, 60(3): 1283-1294.
- [5] BIDON S, BESSON O, TOURNERET J, et al. Knowledge-Aided STAP in Heterogeneous Clutter Using a Hierarchical Bayesian Algorithm[J]. IEEE Transactions on Aerospace and Electronic Systems, 2011, 47(3): 1863-1879.
- [6] FENG W K, GUO Y D, ZHANG Y S, et al. Airborne Radar Space Time Adaptive Processing Based on Atomic Norm Minimization[J]. Signal Processing, 2018, 148(7): 31-40.
- [7] WEN C, TAO M L, PENG J Y, et al. Clutter Suppression for Airborne FDA-MIMO Radar Using Multi-Waveform Adaptive Processing and Auxiliary Channel STAP[J]. Signal Processing, 2019, 154(1): 280-293.
- [8] KHATIB A E, ASSALEH K, MIR H. Learning-Based Space-Time Adaptive Processing[C]//2013 1st International Conference on Communications, Signal Processing and Their Applications, ICCSPA 2013. Budapest, Hungary: IEEE, 2013: 1-4.
- [9] KHATIB A E, ASSALEH K, MIR H. Space-Time Adaptive Processing Using Pattern Classification[J]. IEEE Transactions on Signal Processing, 2015, 63(3): 766-779.
- [10] 闵丛丛. 基于学习的空时自适应处理方法研究[D]. 成都: 电子科技大学, 2017.
- [11] 杜兰, 王兆成, 王燕, 等. 复杂场景下单通道 SAR 目标检测及鉴别研究进展综述[J]. 雷达学报, 2020, 9(1): 34-54.
- [12] 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.
- [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.
- [14] LIU Z, XU X Q, YANG J Y, et al. Moving Target Indication Using Deep Convolutional Neural Network[J]. IEEE Access, 2018(6): 65651-65660.
- [15] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet Classification with Deep Convolutional Neural Networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [16] SZEGEDY C, LIU W, JIA Y Q, et al. Going Deeper with Convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA: IEEE, 2015: 1-9.
- [17] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 770-778.
- [18] HUANG G, LIU Z, MAATEN L V D, et al. Densely Connected Convolutional Networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 2261-2269.
- [19] KINGMA D, BA J. Adam: A Method for Stochastic Optimization[C]//2015 3rd International Conference on Learning Representations. San Diego, USA: [s. n.], 2015: 1412.

(编辑:徐敏)