

利用 CNN 的海上目标探测背景分类方法

徐雅楠, 刘宁波, 丁昊, 关 键, 黄 勇

(海军航空大学信息融合研究所, 山东烟台 264001)

摘 要: 该文主要研究基于卷积神经网络(Convolutional Neural Networks, CNN)的海上目标探测背景分类方法. 以 CNN 中的经典网络 LeNet 为例, 基于 IPIX 雷达实测数据集, 进行控制变量的模型训练, 对分类准确率、训练速度、一维信号的二维特征图变化等进行分析, 基于实测数据集验证了利用 CNN 在一维雷达回波信号中进行海杂波与噪声分类的可行性, 并同步分析了数据预处理、单个样本序列长度、网络结构参数等影响因素对分类准确率的影响, 并针对典型探测场景分类进行了验证. 结果表明, LeNet 卷积神经网络在海上探测背景区分方面, 具有很高的分类准确率, 并且数据预处理方式、单个样本序列长度对结果影响显著, 而网络结构参数有一定的调节区间, 在此区间内调整, 影响不显著, 所提方法在顺/逆浪向、高/低海况条件下杂波分类与杂噪分类方面具有很高的准确率.

关键词: 卷积神经网络; 海杂波; 探测背景; 分类

中图分类号: TN957.51

文献标识码: A

文章编号: 0372-2112 (2019)12-2505-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2019.12.008

Background Classification Method for Marine Target Detection Based on CNN

XU Ya-nan, LIU Ning-bo, DING Hao, GUAN Jian, HUANG Yong

(Information Fusion Institute, Naval Aviation University, Yantai, Shandong 264001, China)

Abstract: In this paper, the background classification method of marine target detection based on convolutional neural network (CNN) is mainly studied. Taking LeNet as an example, based on the IPIX measured data set, the model training through controlling variables is carried out. The feasibility of using CNN in the classification of sea clutter and noise in one dimensional radar echo signal is studied, and the influence of factors such as data preprocessing, single sample sequence length and network structure parameters on classification accuracy is analyzed synchronously, and verified for the typical detection scene classification. The application results of measured data show that the proposed method has high accuracy in clutter classification and noise classification under the conditions of forward/reverse direction and high/low sea conditions.

Key words: convolution neural network; sea clutter; detection background; classification

1 引言

海杂波建模与海杂波中的目标检测问题, 一直是国内外研究的热点和难点问题, 描述海杂波的统计特征量主要有幅度特性、频谱特性和时/空相关特性等^[1-3]. 然而, 由于海洋环境复杂, 海杂波呈现非高斯、非线性和非平稳特性, 实际海杂波常常偏离假设的统计分布模型, 使得恒虚警检测器性能严重下降^[2,3], 其次, 回波信杂比低以及复杂非均匀背景, 使得目标检测难度大, 检测方法的参数选择面临两难问题, 面对不同应用场景, 无法实时感知当前探测背景并调整信号处理方法加以应对, 严重影响目标检测的准确性. 根据检测机理的不同, 可将雷达目标检测器分为利用数据的

一阶(幅度)或二阶(功率、功率谱)统计特征基于似然比检验的能量检测器^[4]和特征检测器^[5,6], 后者的泛化性更好, 适用于多种复杂的探测场景. 特征检测器是将目标检测问题转化为分类问题, 即, 判断回波是否属于背景所在的类, 而基于特征提取的深度学习检测方法具备传统特征检测器的优点, 还具有更好的鲁棒性. CFAR 方法大都基于距离维幅度数据, 而实际上, 雷达接收机接收到的数据包括距离维、脉冲维、方位维、扫描间(帧间)、多普勒等多维度数据. 通过多维数据的选择来进行海杂波的抑制与目标检测, 可降低虚警, 提高检测概率, 充分利用变换域处理带来的信杂比改善和分形参数估计简单便捷的特点. 深度学习方法作为一

收稿日期: 2018-09-27; 修回日期: 2019-03-21; 责任编辑: 梅志强

基金项目: 国家自然科学基金(No. 61871392, No. 61531020, No. 61871391); 中国博士后科学基金(No. 2017M620862)

种可利用多域联合处理的特征检测器,具备传统 CFAR 检测方法所不具备的优势.

机器学习方法,在杂波分类^[7]及海杂波抑制^[8-10]方面的成功应用,为采用深度学习方法进行海上目标探测背景分类提供了理论基础,和基于机器学习的识别方法相比,深度学习方法对复杂探测背景有更好的适应性和更高的准确率.针对海杂波中目标检测这一应用场景,深度学习方法的运用的相关研究很少,其中大多为输入形式为图像,网络结构为 CNN 的有关研究^[8,9].经过处理以图像形式表达的回波信号,虽然更适合人观察理解,但是也难免会破坏一些回波信号本身的纹理等适合用深度学习网络结构提取和理解的特征.本文采用一维信号作为输入,可保留更多的可提取特征.

本文采用卷积神经网络中的 LeNet^[11],将网络输入由二维图像调整为二维回波信号,结合信号处理、调整网络结构和网络参数,提取得到一维海杂波信号及其多普勒谱域的隐含空间特征,进行目标探测背景——海杂波与噪声的分类,实现迎/顺风向杂波区域、噪声区域、高/低海况的判断,以期进行精细化杂波抑制和提高目标检测性能.

2 卷积神经网络

卷积神经网络一般由全连接层(输入和输出层)、卷积层、池化层(下采样层)组成,其训练过程可划分为前向传播过程(FP)和反向传播过程(BP).在 CNN 应用方面,一个成功的示例是 Y. LE-Cun 等^[11]于 1995 年提出的 LeNet-5 系统,在 MNIST 上识别率在 90% 以上,已用于银行的手写支票识别,近年来,出现了 AlexNet^[12]、VGGNet^[13]、GoogLeNet^[14]、NIN^[15]、ResNet^[16]、RCNN^[17]等,不仅有更高的识别率,而且降低了网络计算开销.下面将介绍卷积神经网络的基本原理和 LeNet-5 的基本网络结构.

2.1 卷积神经网络的基本原理

CNN 最早由 Y. LE-Cun 等^[11]提出,其通过组合局部感受野、权值共享和空间或时间上的子采样将 BP 算法^[18]成功用于训练深度网络的结构,具有平移不变性和线性不变性.从结构上讲,CNN 具有输入层、隐藏层(卷积层和池化层)、输出层;从本质上讲,和其他 BP 网络相同,都是通过梯度下降算法来达到目标函数最小值;从过程上讲,包括前向传播和反向传播的过程.

2.2 LeNet 基本结构

LeNet 的基本结构示意图如图 1 所示,以长度为 1×400 的序列为例绘制,图中所使用参数是实验采用的一组参数.

将 LeNet 应用于一维雷达回波序列,必须要对经典




图1 LeNet基本结构示意图

的网络结构参数进行修改,以输入是 1×400 的序列为例,经过网络结构中的 reshape 过程,变为 20×20 的矩阵,需要重新计算所需的网络结构参数. C1、C3 为卷积层,卷积核尺寸均为 1×4 ,分别具有 16 个和 32 个卷积核,采用了全 0 填充,这就决定了其不改变输出尺寸,只改变深度(分别为 16、32). S2、S4 为下采样层,步长均为 2,因此使输出尺寸缩小一半,分别为 10×10 和 5×5 .最后通过全连接层 F6(输入为 $5 \times 5 \times 32 = 800$,输出为 512),O7(输入 512,输出为类别数 2)得到网络输出.

3 构建数据集

3.1 实测数据简介

本文训练采用的是 1998 年 IPIX 雷达海杂波数据^[19,20],由加拿大 McMaster 大学利用 X 波段的 IPIX 雷达开展对海探测得到的,数据采集时雷达天线工作模式为驻留模式,观察目标为漂浮于海面的金属网缠绕的泡塑球体.本数据集包含 HH、VV、HV、VH 四种极化方式,同一个训练集与检测集采用极化方式相同的同极化数据,信杂比(SCR)约为 0~9dB.具体情况见表 1.

表 1 IPIX 数据说明

相关信息	38 号数据	84 号数据
采集日期	1998/02/04 22:40:24	1998/02/03 16:58:36
采集地点	Grimsby	Grimsby
工作频率	9.39GHz	9.39GHz
脉冲发射频率	1000Hz	1000Hz
不模糊速度	7.9872 (m/s)	7.9872 (m/s)
距离范围	3021 ~ 3444 (m)	3000 ~ 3989 (m)
方位角范围	359.7858°	342.2955°
极化方式	HH, VV, HV, VH	HH, VV, HV, VH
擦地角	0.32°	0.32°
雷达高度	20m	20m
波束宽度	0.9°	0.9°
天线增益	45.7dB	45.7dB
距离单元个数	28	34
脉冲数目	60000 个	60000 个

数据中包含高杂噪比(约为 8.5dB)的多普勒频移为正的海杂波数据,高杂噪比(约为 7.4dB)的多普勒频移为负的海杂波数据,低杂噪比(约为 1.8dB)的海杂波数据,接近噪声的数据,其时域和频域幅度分别如图 2 (a)~图 2 (d)所示.按照需求选择数据构建不同的数据集,可以达到不同的训练效果,实现不同的实验目的.

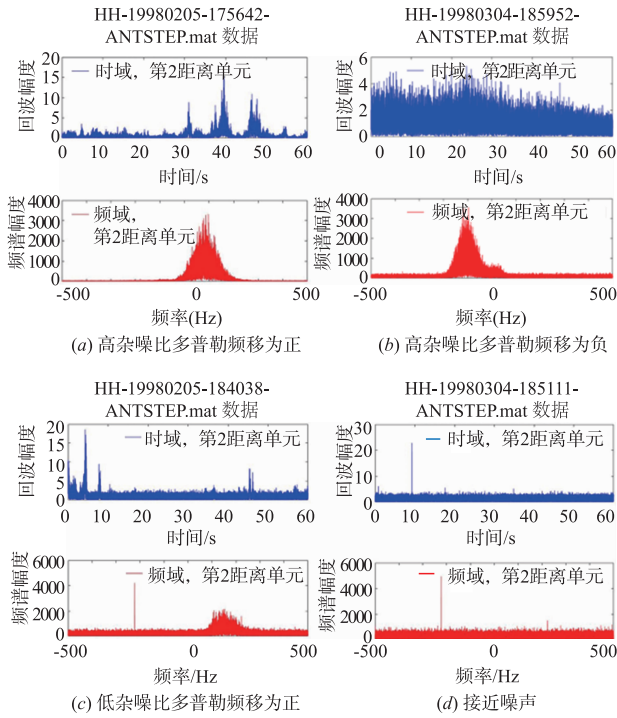


图2 海杂波数据类型示例

3.2 训练集、测试集与验证集构建

深度学习需要大量的数据来进行模型训练,通过梯度下降算法训练模型达到收敛.为了确保训练的准确性和可行性,需要指向同一目标的训练集(training set)用于确定拟合曲线的参数,验证集(validation set)用于模型选择,测试集(test set)用于测试已完成训练模型的精确度.当数据样本量在 10^4 量级以下时,一般将训练集和测试集按 7:3 比例划分;若有验证集,则按 6:2:2 比例划分;若是数据量很大(例如超过 10^5 量级),则可将训练集、验证集、测试集比例调整为 98:1:1.图 3 给出了基于实测数据集利用反向传播算法训练神经网络的流程图.

本文首先利用实测数据验证利用 LeNet 区分一维杂波和噪声序列的可行性,然后再通过控制变量的参数调整,通过达到收敛所需的训练步骤和分类准确率,分析参数改变对分类效果的影响.针对不同实验目的,需要挑选不同类型的数据构建数据集,为了保证训练效果,各个类别数据的数据量需保持在同一个量级,并且整个样本中各类样本的数据分布均匀.具体构建数

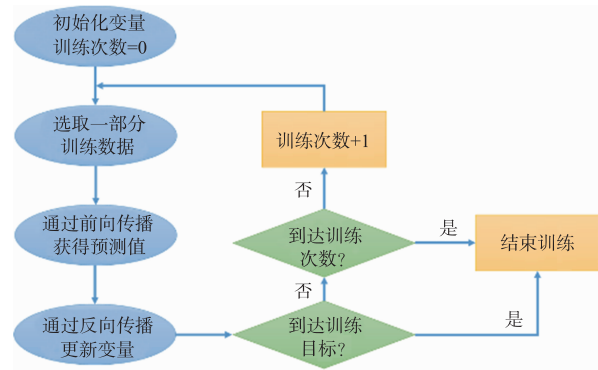


图3 利用反向传播算法训练神经网络的流程图

据集的流程如图 4 所示.

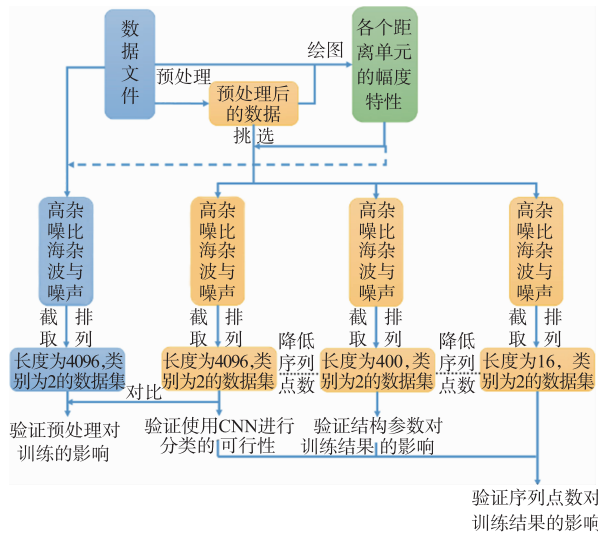


图4 构建数据集的流程图

先通过观察每个数据文件各个距离单元时间-距离单元-幅度图和频率-距离单元-幅度图,和可能存在目标的距离单元的时间-幅度图和频率-幅度图,记录各类数据所在的距离单元.将同类数据所在的各个距离单元包含的采样点拼接起来,按实验预设序列点数进行截取,形成一个宽度为设定的序列点数 n ,长度是拼接得到的序列总长所能截取的段数 m 的矩阵.按 one-hot 标签的规则在矩阵插入二进制标签,以 3 类数据且对应标签是噪声为 001,正多普勒频移海杂波为 010,负多普勒频移海杂波为 100 为例,在每行的第 $n+1$ 列、 $n+2$ 列、 $n+3$ 列分别插入相应的 0 或 1.再把各个类别长度为 m ,宽度为 $n+3$ 的矩阵拼接起来,得到 $3m \times (n+3)$ 的矩阵,其中的数据按类别成块排布.为了提高训练的质量,将矩阵随机按行打乱.取出每行后 3 列这个 $3m \times 3$ 的矩阵作为标签矩阵,取出每行前 n 列这个 $3m \times n$ 的矩阵作为数据矩阵.实际训练时,只要在编写的网络结构中,按照按行号相同为准则读取数据矩阵和标签矩

阵中的数据便可以保证训练数据和标签一一对应. 在第 4 节中, 根据实验目的, 我们采取不同预设长度、不同预处理方式的各类数据构成训练集.

4 基于实测数据集的验证与分析

4.1 CNN 训练与参数影响分析

4.1.1 利用 LeNet 进一维信号分类的可行性验证

能够通过 CNN 进行特征提取的前提条件是数据样本要符合局部性假设和权值共享假设, 这是由于 CNN 本身的结构特点决定的. 输入的雷达回波序列相邻序列点之间具有一定联系的, 而且邻近序列点之间的联系比距离远的序列点强, 因此符合局部性假设; 虽然相同时刻不同距离单元、相同距离单元不同时刻回波的多普勒谱的幅度特征、多普勒频移都各不相同, 但是都具有相似的纹理特征, 在序列某段区域提取的特征可能在另一个区域同样适用, 因此符合权值共享假设, 具备进行实验验证使用 CNN 进行特征提取和分类的可行性的理论基础. LeNet 作为一种简单的 CNN, 包含两层全连接层, 会将分布式特征映射到样本标记空间, 大大减少了特征位置对分类的影响, 其结构决定了其要将输入的一维雷达回波信号的点重排成一个 $n \times n$ 二维矩阵, 重排过程会改变部分空间特征, 需实验验证能否影响分类. 需将卷积运算的步长和卷积核的尺寸都设为 $1 \times n$ (即纵轴方向尺度为 1) 的, 防止引入纵轴方向的卷积运算带来的无用特征. 本小节为防止数据质量对可行性验证造成影响, 采用经过预处理的、幅度区分明显的海杂波数据和噪声数据构成训练集进行训练, 而为了验证分类方法的鲁棒性, 均采用训练集数据量 20% 左右的区分度不明显的样本数据构成测试集和验证集进行验证. 以单个样本序列为 1×400 为例, 得到的样本数据矩阵及对应标签分别如表 2 和表 3 所示, 由于样本集是 7500×400 的, 表中仅展示部分值, 其中标签和样本向量按行一一对应 (其中 01 表示噪声类, 10 表示海杂波类). 需说明的是, 本文结果都是以在 Spyder 和 Pycharm 为 IDE, 在 Tensorflow 框架下, 采用 Python 3.5 语言实现 LeNet 的条件下得出的.

表 2 样本数据

样本	1	2	3	399	400
1	7.1249	26.7899	8.5794	19.1833	36.832
2	26.165	24.6549	10.9913	34.2123	47.711
.....
7499	30.005	15.1558	22.4217	32.596	33.404
7500	38.568	22.5201	11.8415	32.7949	25.953

表 3 样本对应标签

样本	第一位	第二位
1	0	1
2	0	1
3	0	1
4	1	0
.....
7499	0	1
7500	0	1

LeNet 各层网络结构能够提取到区分度显著的特征, 是保证分类准确率的关键. 卷积层和池化层提取的各类别二维特征图之间具备显著的区分度以及各类别自身具备丰富的特征, 又是得到较高最终分类准确率的前提. 图 5(a) 与 (b) 分别为点数为 400 和 4096 的噪声信号的二维特征图, 图 5(c) 和 (d) 分别为点数为 400 和 4096 点的海杂波序列的二维特征图, 可见, 噪声信号能量分布分散而海杂波信号能量分布集中, 集中区域与背景交界处有明显的边缘, 不同类别信号的二维图特征区分明显且序列长度越长, 二维图形显示越精细 (分辨率越高).


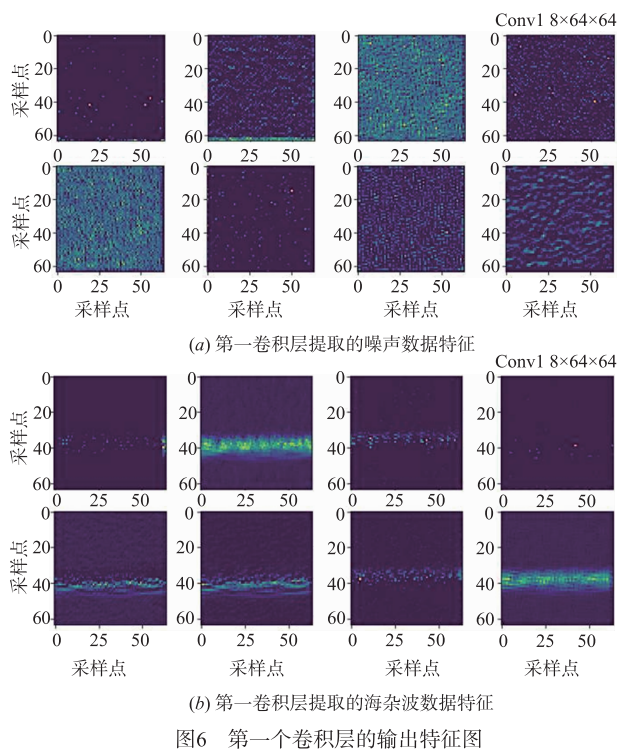


图 5 输入第一个卷积层的噪声与海杂波样本

输入卷积层的一个批尺寸 (batchsize) 为一个四维数据切片, 形如 $[4, 64, 64, 1]$ (第一至四维分别是批尺寸大小、单个样本序列重排后的长度、单个样本序列重排后的宽度、RGB 通道数). 经过第一层卷积后, 8 个卷积核分别提取特征矩阵, 维数均为 64×64 , 如图

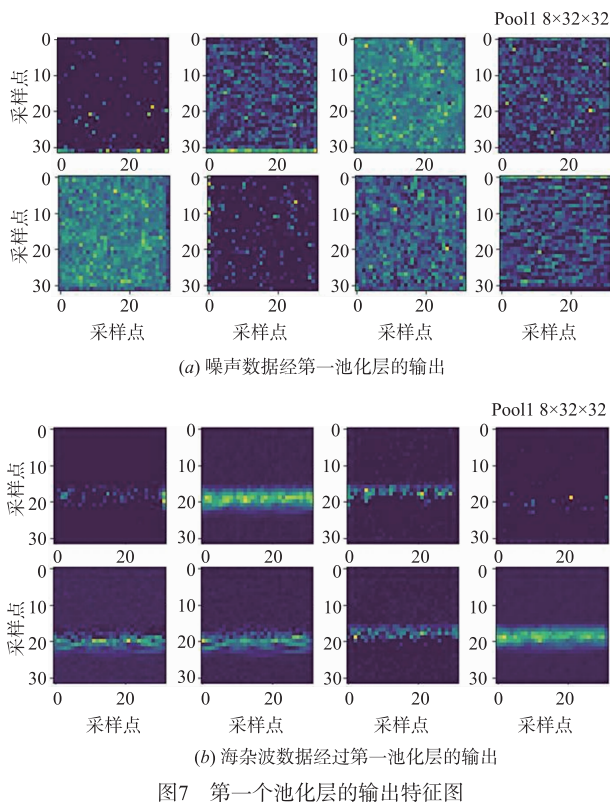
6 所示,其中图 6(a)是第一卷积层提取的噪声数据的特征.由于噪声信号能量分散,没有与背景区分明显的能量集中区域;由于随机初始化卷积核的值不同,卷积核提取的边缘特征强弱有高低之分.图 6(b)是第一卷积层提取的海杂波数据的特征,由于海杂波信号能量集中,不论初始化值强弱,卷积核提取的边缘特征都相对集中,且与背景噪声区域交界处边缘清晰,两种类别数据的差距显著,足够保证分类的准确率.



经过池化(下采样)后,得到的输出特征图如图 7 所示.本文采用的采样方式是取区域内四个采样点的最大值加以保留(maxpooling),会进一步减少卷积层权值参数误差,保留更多的纹理信息,强化边缘.图 7(a)为池化后噪声数据,不论 8 个卷积核初始化的值如何,能量高的噪声采样点被加以强调,但仍分布均匀,图 7(b)为池化后海杂波数据,海杂波能量集中区域与背景噪声区域的边缘被进一步强调,类似图像处理的“锐化”作用,可见,特征图纹理依然清晰,主要特征都予以保留,还强化了用以分类的边缘特征,两类数据的特征图区分更加明显.

训练结果表明,在单个样本序列为 4096 时,经过 7500 次训练,准确率可达到 100%.这表明,利用 CNN 网络(本文以 LeNet 为例,其他如 AlexNet、VGGNet 等网络也有类似结果)进行一维杂噪信号分类,不仅具有可行性,还具有高的分类准确率.

在对海雷达探测场景中,距雷达较近的区域海杂



波强,随着距离逐步增加,海杂波逐步减弱,直至噪声占主导地位,所以通过对探测场景中杂波和噪声进行分类,可以为对海雷达的杂波区域和噪声区域进行自动划分奠定基础,为后续目标检测方法选取以及门限设置提供指导.

4.1.2 输入数据样本对训练结果影响分析

本小节主要分析输入数据样本杂噪比高低、序列长度和预处理对训练结果的影响.除 4.1.1 小节中所述将海杂波回波序列直接输入(或进行简单的归一化)之外,还有将海杂波重构到其他特征域再输入的方式.除本小节使用傅里叶变换(FFT)重构到多普勒谱特征空间外,还有通过短时傅里叶变换、平滑伪 WVD 变换(SPWVD)、分数阶傅里叶变换(FRFT)等方式将其处理到时频域,以提高各类数据在该特征域的可分性.只要能够在同一个特征空间域内使得海杂波与目标具有区分度更大的特征,这种预处理方式就是可行的.在控制序列长度和网络结构参数的条件下,输入经过 FFT 变换的多普勒谱和回波时间幅度序列.构建的数据集结构和 4.1 节中相同,不采用预处理直接输入时域波形时,单个数据样本序列长度为 400 的情况下,无法收敛,不能完成训练与分类,但如果提高序列长度至 4096 时,分类准确率可达到 75.4%;经 FFT 后,训练 500 次时,分类准确率已经达到了 75%,2000 次后收敛,达到 100%,具体结果如表 4 所示.

表 4 1×400 时预处理与否训练结果

预处理	训练 500 次		训练 1000 次		训练 2000 次	
	损失	准确率	损失	准确率	损失	准确率
是	0.1637	0.75	0.1406	0.75	5.037×10^{-6}	1
否	0.7077	0.5	0.5685	0.75	0.7092	0.75

可见,数据预处理对 LeNet 的分类准确率影响较大.虽然不经过预处理的数据样本,在单个序列长度足够长的情况下,经过一定的参数调整,也能保证一定的分类准确率.当参数在最适宜范围内,再提高分类准确率,需采用适当的预处理手段提高输入的不同类别信号在特征空间的区分度.

为了更直观地看出预处理与否对训练结果的影响,对长度为 4096 点的数据样本进行相同点数的 FFT 变换,再经过归一化(减均值除以均值)等预处理操作,绘制输入第一个卷积层的单个 4096 点未经预处理的样本与经过预处理处理的特征图进行对比,如图 8 所示,由图 8 (a)、(c)对比可知,经过预处理的两种类别数据区分明显,由图 8 (b)、(d)对比可知没有经过预处理的样本数据,纹理特征区分不明显,从而降低分类准确率.




图 8 预处理前后输入的纹理特征

单个样本序列长度对分类准确率也存在较大影响,在满足可以重排成 n 维方阵的前提下,改变每个回波样本的序列长度,在从 4096 点降至 16 点降维过程中,选取了几个有代表性的点数 16 (4×4)、64 (8×8)、……、2704 (52×52)、3600 (60×60)、4096 (64×64) 进行测试,得出了单样本序列长度与分类准确率的关系,如

表 5 所示.

表 5 序列点数长短与检测准确率的关系

点数	训练 1000 次		达到收敛所需步数	最终准确率
	损失	准确率		
16	0.707674	0.5	4500	0.75
64	0.282509	0.75	2400	1
144	0.39498	0.75	2000	1
256	0.163722	0.75	1600	1
400	0.140643	0.75	1200	1
576	0.0968458	0.8	1150	1
1024	0.0709154	0.85	1000	1
1600	0.1139498	0.8	950	1
2304	0.0692352	0.9	900	1
2704	0.0652134	0.9	850	1
3600	0.0600302	1	800	1
4096	0.0000503657	1	600	1

可见,单样本序列长度越长,其训练到 1000 步时的损失函数值 loss 越低,准确率越高;达到收敛所需的训练步数越少,最终分类准确率越高.另外,通过大量数据验证表明,在保证训练步数足够多的前提下,序列长度不低于 64 时,均可达到很高的分类准确率,而长度为 16 点可作为能否区分海杂波与噪声的临界值.在序列长度满足上述条件的前提下,当杂噪比高于 1.5dB 时,使用 LeNet 可将海杂波与噪声稳定地区分开,随着杂噪比逐步降低,分类准确率也会逐步降低.

在网络结构确定的前提下,数据预处理、单样本序列长度、网络结构参数(批尺寸、卷积核尺寸、步长等)对分类准确率均有影响.数据预处理与否,即样本集中各类别数据的特征复杂度与区分度,对结果影响最为明显.在其他条件相同的前提下,仅进行 FFT 处理,可将准确率提高 20% 以上(详见表 4).单样本序列长度的影响次之,随着输入序列量级变化,在相同训练步数情况下,对分类准确率的影响在 10% 左右,数据越短、杂噪比越低,需要的训练步数越多,耗费时间越多.实际上,选取杂噪比高的数据、进行预处理和增加序列点数,都是在提高输入样本的特征丰富度,即纹理复杂程度;增加点数相当于提高分辨率,而进行预处理和选取杂噪比高的数据则是在分辨率相同情况下,提高不同类别数据间的特征区分度.

4.1.3 网络结构参数对训练结果影响分析

采用控制变量的训练方法,在输入均为单个样本序列长度为 400 的低杂噪比海杂波数据和噪声数据的条件下,保持其他参数不变,只改变一个参数进行多次训练,得出批尺寸(batchsize)、卷积核尺寸(kernel size)、步长

(stride)、第一层卷积核数(conv1)、第二层卷积核数(conv2)、隐含节点数等参数对训练速度(用同一步数下的准确率和损失来衡量)和模型分类准确率(达到收敛时的准确率)的影响.分析过程流程框图如图9所示.




图9 网络结构参数对训练结果影响分析流程框图

具体参数对训练结果影响如表6所示,由于涉及参数众多,这里以批尺寸为例说明.

表6 具体参数对训练结果影响

参数调整		训练 1000 步的结果		达到收敛所需步数	最终准确率
		损失	准确率		
批尺寸	8	0.14064	0.75	1200	1
卷积核	4 * 4				
步长	[1,1,1,1]				
conv1	1,4				
conv2	4,8				
批尺寸	4	0.03419	0.90	1100	1
卷积核	4 * 4				
步长	[1,1,1,1]				
conv1	1,4				
conv2	4,8				

网络结构参数对分类结果的影响较小.批尺寸主要影响了训练所需时间,而对准确率影响较小;卷积核尺寸在4 * 4时效果最佳,在满足网络结构内在要求(可被重排成n * n单样本序列的n能被4整除等)情况下调整,对结果影响10%以内;步长需是1 * n维的,最长不宜超过卷积核尺寸,即在2至5之间为宜(序列长度特别长时,可放宽到10左右);第二层卷积核数(conv2)最好为第一层卷积核数(conv1)的2倍左右,其太少不能提取到足够多的特征,太大则会造成运算量大幅提高、过拟合可能性增大,在网络输入为一维雷达回波的情况下,卷积核数随着单样本序列的长度增加而增加,使得经过两个卷积层后,连接数与序列长度在同一量级,在适当范围内调整,对准确率的影响不超过10%;隐含节点数与卷积核数的选取规则基本一致,也应随单样本序列长度的增加而增加,但由于提高其数量会增大计算量,所以选取范围应控制在128至1024之间,不宜过高.

4.2 典型探测场景分类验证

4.2.1 顺浪向与逆浪向的划分

为满足精细化的海上目标探测要求,在区分海杂波和噪声基础上,再进行顺浪向/逆浪向海杂波以及噪声信号的三分类验证.对海雷达探测海面时,往往需扫描一个圆形或扇形区域海面,其间雷达视线方向与海浪运动方向夹角在0°~180°间变化,180°对应于雷达迎浪向探测海面,海杂波多普勒频率为正,0°对应于雷达顺浪向探测海面,海杂波多普勒频率为负,且二者能量差异较大.本节采用此类具有明确标记且具有一定区分度的回波数据验证所提方法.实测数据处理结果如表7所示(表中显示的杂噪比约为1.8dB的海杂波与噪声数据处理结果).通过多组数据验证表明,无论是表中所示低杂噪比还是高杂噪比的回波数据,均有较高的分类准确率.

表7 顺/逆浪向海杂波、噪声三分类

训练结果	训练 500 次		训练 1000 次		训练 2000 次	
	损失	准确率	损失	准确率	损失	准确率
400	0.1637	0.75	0.1406	0.75	5.04 * 10 ⁻⁶	1
1600	0.0733	0.75	0.0991	0.75	0.0014	1
4096	0.0512	1	0.0035	1		

此外,在杂噪比和纹理特征丰富程度相同的情况下,相比于杂波与噪声区域分类,CNN达到可以准确区分正负多普勒频移海杂波,需更多的数据样本,并需更多的训练步数达到收敛.

4.2.2 高/低海况的区分

海况亦称海面状况、海情,是指在海洋水文观测中,由气象条件、风浪和涌浪等引起的海面外貌特征.在风力作用下,根据海面状况、波峰的形状及其破裂程度和浪花泡沫出现的多少等,把海况共分为10级.由于当前还没有完整获取各级海况的雷达数据,且已获取数据由于辅助信息记录不充分,也难以准确判断海况等级,仅有高低海况的粗略判断(认为3级以下海况为较低海况,4级以上海况为较高海况).基于此,本节采用高/低海况数据进行所提方法的分类准确度验证,数据处理结果如表8所示.

表8 高/低海况数据的分类结果

点数	训练 500 次		训练 1000 次		训练 2000 次	
	损失	准确率	损失	准确率	损失	准确率
400	0.0329	0.75	8.0466	0.5	8.32427	0.5
1600	2.1089	0.75	15.7875	0.5	2.267 * 10 ⁻⁴	1
4096	3.6206	0.75	0.0012	1		

网络训练过程中,当第一层卷积核数(conv1)为8,第二层卷积核数(conv2)为16,隐含节点数为512时,纹理特征较丰富,达到收敛的速度较快,所需数据量较少,其他参数对分类准确率影响的结论与4.1.3节中一致,此处不赘述.由于高/低海况下的海杂波具有较为接近的纹理特征,特征差异不如噪声与海杂波明显,因此,网络训练过程中损失函数下降速度较慢,且起伏较大.当序列长度小于400时,达到高的分类准确率需很大数据量(训练4000次以上准确率才可接近1).若需在序列长度较小的情况下达到高的分类准确率,则需要使用可获得更多细节信息的预处理方法和网络结构.

4.3 目标探测中的相关应用

使用CNN进行探测背景的分类,目的不仅仅是探测背景的分类本身,最终目的还是为了优化传统方法实现海杂波中的目标分类检测.在信杂比高的情况下,不管目标落在杂波谱内(图10(a))还是杂波谱外(图10(b)),区分度都很高;当信杂比较低时,目标位于杂波谱外或与杂波谱仅部分重叠(图10(c)),频域的识别率仍然较高,在序列长度为400点以上时,数据集充足的情况下准确率在95%以上.海面漂浮弱目标的回波信号在频域和时域都容易完全淹没于杂波中,如图10(d)所示,仅从肉眼观察,很难根据几何特征上区分出来.

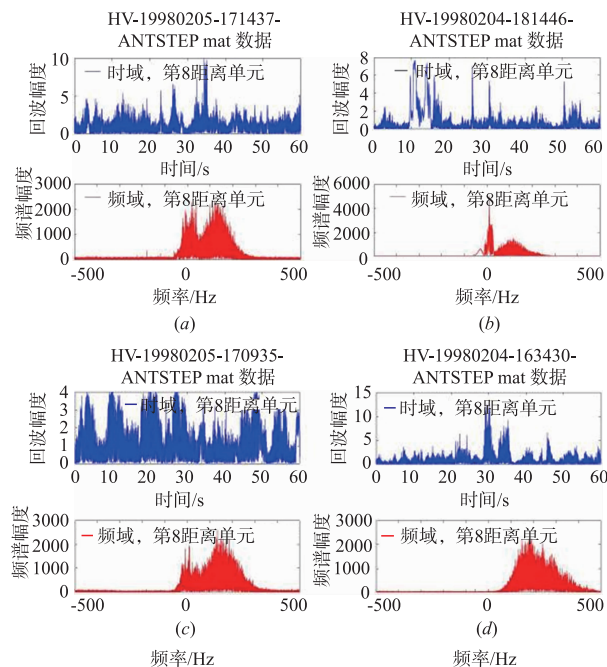


图10 频域各类杂波中的目标信号

由此引出两个问题.其一是,虽然两种目标的频谱与杂波重叠,但这些目标也是探测的重点,直接用深度学习方法进行海杂波中目标检测的方法不应当被抛弃,所以考虑通过多种重构到不同维度特征空间的预

处理方式,寻找使得这类目标在该域与海杂波区分明显的预处理方法,此方向研究正在开展;其二是,与传统神经网络相比,深度学习方法的泛化性、准确率和计算量如何,是否具有良好的应用价值.基于此,对卷积神经网络(CNN)和传统的支持向量机(SVM)及基于RBF函数的全连接网络的计算速度、准确率等方面进行了对比,如表9所示,采用的训练集是信杂比7dB左右,其频谱如图10(c)所示.

表9 与传统神经网络的性能对比

网络结构	准确率/损失	训练速度	所需数据量
CNN	99.8%/9.1897 * 10 ⁻³	62.3s	1584
SVM	95.7%/6.358 * 10 ⁻²	34.6s	585
RBF-NN	90.9%/1.3735 * 10 ⁻¹	38.9s	762

通过对比可以发现,由于输入的是各类数据的雷达回波序列本身而非特征向量,SVM网络和基于RBF的全连接网络训练速度上并没有比LeNet网络具有太多的优势,但所需的数据量大大降低.在实验选用的各类数据样本的分类问题上,准确率相当.在信杂比更低的目标检测中,LeNet检测准确率为75.4%时,SVM和RBF网络要落后10%以上,接近随机划分的准确率,因此深度学习方法的泛化性能较好.如果选用合适的预处理方式,和更高级的网络结构,有直接应用于海杂波中目标检测的潜力.本文所提方法也可以通过辨识探测背景,再结合各种传统检测方法的适用场景,选择性能最佳的检测方法,提取和筛选出一系列能够区分海杂波单元与目标单元的差异特征,以便有效分离目标和海杂波的回波特征,辅助特征域目标检测方法设计.

5 结束语

本文将卷积神经网络应用于对海雷达目标探测背景(海杂波与噪声、顺/逆浪向海杂波、高/低海况海杂波)分类,以LeNet为例,验证了利用CNN进行分类的可行性,在基于实测数据进行一维雷达回波数据集构建、样本数据网络输入等方面,进行了较为深入的研究,从训练效果和实际应用两方面进行分析得到了相应的结论,并给出了分类准确率的主要影响因素及其对分类结果的影响程度,针对典型探测场景分类,通过大量实测数据分析,给出了网络参数调整的合理范围.最后,针对该方法在目标探测的应用上,通过实验与传统神经网络方法进行对比,结果表明,CNN不仅可以用于对精细化的海杂波类型乃至更为复杂的探测场景进行准确分类识别,智能选取与当前场景最为匹配的信号处理方法,还可以通过回波特征域重构等预处理方式结合更高级网络实现目标检测.

参考文献

- [1] 丁昊,董云龙,刘宁波,等. 海杂波特性认知研究进展与展望[J]. 雷达学报,2016,5(05):499-516
DING Hao, DONG Yun-long, LIU Ning-bo, et al. Overview and prospects of research on sea clutter property cognition [J]. Journal of Radars, 2016, 5(05):499-516. (in chinese)
- [2] 刘宁波,关键,王国庆,等. 基于海杂波 FRFT 谱多尺度 Hurst 指数的目标检测方法[J]. 电子学报,2013,41(9):1847-1853.
LIU Ning-Bo, GUAN Jian, WANG Guo-Qing, et al. Target detection within sea clutter based on multi-scale hurst exponent in frft domain [J]. Acta Electronica Sinica, 2013, 41(9):1847-1853. (in chinese)
- [3] 尹志盈,张玉石. 雷达海杂波统计特性建模研究[J]. 装备环境工程,2017,14(7):29-34.
YIN Zhi-Ying, ZHANG Yu-Shi. Radar sea clutter modeling of statistical characteristic [J]. Equipment Environmental Engineering, 2017, 14(7):29-34. (in chinese)
- [4] TUGNAIT J K. Two-channel tests for common non-Gaussian signal detection [J]. IEEE Proceedings of Radar and Signal Processing, 1993, 140(6):343-349.
- [5] POURNEJATIAN N M, NAYEBI M M. Fractal-multiresolution based detection of targets within sea clutter [J]. Electronics Letters, 2012, 48(6):345.
- [6] SHUI P L, LI D C, XU S W. Tri-feature-based detection of floating small targets in sea clutter [J]. IEEE Transactions on Aerospace and Electronic Systems, 2014, 50(2):1416-1430.
- [7] DARZIKOLAEI M A, EBRAHIMZADE A A, GHOLAMI E. Classification of radar clutters with artificial neural network [A]. International Conference on Knowledge-Based Engineering and Innovation [C]. Tehran: IEEE, 2015. 577-581.
- [8] VICEN-BUENO, RAÚL, CARRASCO-ÁLVAREZ, et al. Sea clutter reduction and target enhancement by neural networks in a marine radar system [J]. Sensors, 2009, 9(3):1913-1936.
- [9] CALLAGHAN D, BURGER J, MISHRA A K. A machine learning approach to radar sea clutter suppression [A]. Radar Conference [C]. Seattle: IEEE, 2017. 1222-1227.
- [10] SHI S N, SHUI P L. Sea-surface floating small target detection by one-class classifier in time-frequency feature space [J]. IEEE Transactions on Geoscience & Remote Sensing, 2018, 56(11):6395-6411.
- [11] LÉCUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [12] SIMONYAN K, VEDALDI A, ZISSERMAN A. Learning local feature descriptors using convex optimisation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(8):1573-1585.
- [13] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [A]. International Conference on Neural Information Processing Systems [C]. Lake Tahoe, Nevada, US: NIPS, 2012. 1097-1105.
- [14] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition [DB/OL]. <https://arxiv.org/pdf/1409.1556>. 2015-04-10/2018-09-25
- [15] Lin M, Chen Q, Yan S. Network In Network [DB/OL] <https://arxiv.org/abs/1312.4400>, 2014-03-04/2018-09-28
- [16] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [A]. Conference on Computer Vision and Pattern Recognition [C]. Las Vegas: IEEE Computer Society, 2016. 770-778.
- [17] GIRSHICK R, DONAHUE J, DARRELL T, et al. Region-based convolutional networks for accurate object detection and segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 38(1):142-158.
- [18] 刘彩红. BP 神经网络学习算法的研究 [D]. 重庆:重庆师范大学, 2008.
LIU Cai-hong. BP Neural Network Learning Algorithm [D]. Chongqing: Chongqing Normal University, 2008. (in chinese)
- [19] 王鹏. 极化 IPIX 雷达回波数据处理与分析 [D]. 黑龙江哈尔滨:哈尔滨工业大学, 2016.
WANG Peng. Research on SAR image classification and recognition based on machine learning [D]. Harbin, Heilongjiang: Harbin Institute of Technology, 2016. (in chinese)
- [20] Drosopoulos A. Description of the OHGR database [R]. Ottawa: Defence Research Establishment, 1994.

作者简介



徐雅楠 女,1995 年 10 月出生,山东威海人,2017 年进入海军海空大学航空预警学院. 现为在读硕士生. 主要研究方向为海杂波中目标检测的深度学习方法.

E-mail: yt_yananxu@163.com



刘宁波 男,1983 年出生,山东烟台人. 博士后在读,海军航空大学航空预警学院副教授,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



丁昊 男,1983 年出生,山东烟台人. 博士,讲师,主要研究方向为海杂波特性认知,雷达目标检测等. 入选中国科协“青年人才托举工程”.

E-Mail: hao3431@tom.com



关键 男,1968 年出生,辽宁锦州人,教授,博士生导师. 主要研究方向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