

基于卷积神经网络的高分辨率雷达目标识别

何松华¹, 张润民^{1†}, 欧建平², 张军²

(1.湖南大学 信息科学与工程学院, 湖南 长沙 410082;

2.国防科技大学 ATR 实验室, 湖南 长沙 410073)

摘要:提出一种基于卷积神经网络(Convolution Neural Network, CNN)的高分辨率雷达目标识别方法. 首先针对小样本应用于深度 CNN 时训练过程中损失函数值收敛速度慢的问题, 利用结合批归一化算法的改进 CNN 网络对高分辨距离像(High Resolution Range Profile, HRRP)进行自动特征提取; 再利用支持向量机(Support Vector Machine, SVM)对距离像特征进行分类. 使用军事车辆高保真电磁仿真数据对提出的方法进行验证, 识别结果证明了该方法的有效性.

关键词:高分辨距离像; 雷达目标识别; 卷积神经网络; 批归一化; 支持向量机

中图分类号: TN957.51

文献标志码: A

High Resolution Radar Target Recognition Based on Convolution Neural Network

HE Songhua¹, ZHANG Runmin^{1†}, OU Jianping², ZHANG Jun²

(1.College of Computer Science and Electronic Engineering, Hunan University, Changsha 410082, China;

2.ATR Laboratory, National University of Defense Technology, Changsha 410073, China)

Abstract: A new method of high resolution radar target recognition based on Convolution Neural Network (CNN) was presented. To solve the problem of slow convergence of loss function values during the training process when small samples are applied to the deep CNN, High Resolution Range Profile (HRRP) features were firstly extracted by using the improved CNN combined with the Batch Normalization (BN) algorithm, and then classified by using a Support Vector Machine (SVM). The experimental results using high-fidelity electromagnetic simulation data of military vehicles validate the effectiveness of the proposed method.

Key words: High Resolution Range Profile (HRRP); radar target recognition; Convolution Neural Network (CNN); Batch Normalization (BN); Support Vector Machine (SVM)

* 收稿日期: 2018-07-21

基金项目: 国家自然科学基金资助项目(61471370), National Natural Science Foundation of China(61471370)

作者简介: 何松华(1964—), 男, 湖南武冈人, 湖南大学教授

† 通讯联系人, E-mail: rmz381@hnu.edu.cn

高分辨距离像(HRRP)是用宽带雷达信号获取的目标散射点回波在雷达射线上投影的向量和,它提供了目标散射点沿距离方向的分布情况,是目标重要的结构特征.HRRP具有分辨率稳定、易于获取与实现和成像周期短等特点,因而基于HRRP的目标识别成为国内外的研究热点^[1-2].

传统的HRRP目标识别方法有基于距离像特征抽取的识别、基于距离像模板的匹配识别和基于三维散射中心模型的识别等.特征抽取是从距离像上提取反映不同目标差异的、并在一定姿态角范围内具有稳定特征,目标识别所需的存储量和匹配运算量较少,单稳定特征提取较难,特征抽取后的分类器设计复杂.模板匹配法是将实时获取的目标距离像或其特征与预先获取并存储的已知目标的不同姿态的距离像或其特征模板进行匹配,通过合理范围内的全姿态匹配以适应一维距离像对目标姿态的敏感性,优点是识别率较高,但模板存储量以及姿态匹配运算量大.第三种方法是通过高保真电磁仿真计算、超分辨谱估计和三维散射中心提取等方法事先建立并存储目标的全姿态三维散射中心分布模型,并通过模型来预测目标在合理姿态范围内的目标距离像或其特征,与实时获取的目标距离像或其特征进行匹配,由于不需存储不同姿态的距离像或特征模板,存储量显著降低,但需要的姿态搜索、特征预测和匹配识别所需的运算量依然较大.

文献中经常使用的特征提取方法有平移不变特征、变换特征和结构特征等.上述算法都需要基于相关领域的深层知识经验来提取特征,因而导致了较大的不确定性.近年来深度神经网络方法在图像识别领域取得了很大成功^[3-4].主要模型有深度置信网络(Deep Belief Network, DBN)^[5]、栈式降噪自动编码器(Stacked Denoising Autoencoders, SDA)^[6]和卷积神经网络(CNN)^[7]等.

CNN作为一种监督学习算法,去除了传统目标识别中复杂的特征提取和数据重建过程,利用多个非线性隐层,将输入的复杂分层特征表示出来.卷积层的权值共享减少了网络的训练参数、降低了模型的复杂度.池化操作大大减少了网络的神经元数,使得网络对平移、旋转等变换具有鲁棒性.

CNN架构的研究不断取得突破性进展.Karen Simonyan提出的VGGNet模型包含了16~19个权重值,整个网络一致使用了3*3的卷积核和2*2的汇聚层,显示出网络深度对算法性能的提高具有关键作用^[8].He提出的残差网络(ResNet)结构采用了

独特的跳跃链接,多次使用批归一化,在ImageNet数据集上构建了152层网络,虽然其深度是VGGNet深度的8倍,但仍具有较低的复杂度^[9].CNN在高距离分辨雷达目标识别领域已经有了很多成功应用.Jarmo基于多基地雷达系统,将CNN应用于飞机目标识别^[10].Osman设计了有效的CNN模型,自动提取了舰船目标距离像特征,实现了军事和民用车辆的识别^[11].

就目前国内外研究现状而言,地面车辆目标的HRRP识别研究不多.因此本文将CNN应用于军事车辆的HRRP目标识别领域,减少了特征选择的人工步骤.CNN以往在处理小数据集时,往往由于网络模型复杂、数据源所提供的特征有限等因素,会导致训练过程损失函数收敛过慢问题.本文针对该情况,借鉴了VGGNet网络特点,将批归一化算法^[12]引入改进的CNN网络,从而对距离像进行特征提取.为进一步提高目标分类能力,将Softmax分类器替换为支持向量机^[13].基于车辆目标高保真电磁仿真数据的识别实验表明,本文方法具有更高的识别率,验证了其有效性.

1 信号模型

理论分析表明,光学区雷达目标的电磁散射可以用目标的局部散射源表示,称这些局部散射源为散射中心.散射中心是光学区雷达目标的重要特征,可利用散射中心模型对光学区雷达目标的散射特性进行准确建模.在不发生散射中心超距离单元走动(Motion Through Range Cells, MTRC)的转角区间内,距离单元内散射中心数目保持不变,反射强度也几乎恒定.设距离单元分辨率为 Δr ,目标横向长度设为 L_x ,则散射中心不产生MTRC的转角区间为

$$\Delta\theta < \frac{\Delta r}{L_x} \quad (1)$$

当采用亚米级分辨率雷达对地面目标观测时,根据经验, $\Delta\theta$ 一般为 $3^\circ\sim 5^\circ$ 左右,假设雷达在目标运动过程中接收到 N 次回波,且不产生MTRC.设第 m 个距离单元内第 t 个散射中心在第 n ($n=1, 2, \dots, N$)次回波相对于目标质心的径向位移差为 $\Delta r_m(n)$

$$x_m(n) = \sum_{t=1}^{T_m} a_{mt} \exp \left\{ -j \left[\frac{4\pi}{\lambda} \Delta r_m(n) - \phi_{mt} \right] \right\} \sum_{t=1}^{T_m} a_{mt} e^{j\psi_{mt}(n)} \quad (2)$$

式中: T_m 为第 m ($m=1, 2, \dots, M$)个距离单元内散射中心总个数; a_{mt} 是距离单元电磁回波中常数项的乘

积,即为第 m 个距离单元内第 t 个散射中心回波的反射系数; ϕ_m 表示初始相位; λ 表示波长. 因复数距离像的相位对目标姿态和距离变动很敏感,且不确定性较大,在匹配识别中难以利用,所以在实验中通常采用实数 HRRP,则第 n 次回波幅度定义为:

$$X = [|x_1(n)|, |x_2(n)|, \dots, |x_M(n)|]^T \quad (3)$$

由于雷达到目标距离、天线增益、雷达接收机增益等雷达系统参数的差异,不同目标与雷达的距离像具有不同的幅度尺度标准,即便是同一目标的 HRRP,观测条件不同,其幅度也存在很大差异,称为 HRRP 的强度敏感性. 解决此类敏感性,通常采用舍弃距离像的强度信息而只利用形状信息. 具体处理方法为在一定测度准则下对 X 做强度归一化处理,然后输入到 CNN 模型分类器,本文采用 L_2 范数归一化. 训练时采用距离像序列,测试时采用单幅距离像,使得识别模型不仅适应目标姿态变化,而且适应目标距离像在非严格远场条件且相对运动过程中的起伏.

2 卷积神经网络

CNN 通常由输入层、卷积层、汇聚层、全连接层和输出层组成. 其中卷积层和汇聚层称为隐含层. CNN 的权值共享结构使其更接近生物神经网络,网络性能可以通过改变网络的深度和广度来调整. CNN 能有效减少网络连接和权值参数,因而有效降低了网络模型的学习复杂度,相比于大规模神经元连接的全连接网络更容易训练.

原始数据在 CNN 中的计算过程是前向传播的,即前一层的输出是当前层的输入. 设 CNN 模型输入的原始数据为 X , 本文用 K_i 表示网络的第 i 层特征图,且 $K_0 = X$. 此处先假设 K_i 是卷积层,则第 i 层输出特征图为:

$$K_i = f(K_{i-1} * W_i + b_i) \quad (4)$$

式中: W_i 表示第 i 层卷积核的权值向量;“*”表示卷积核与第 $i-1$ 层特征图的卷积操作,其输出结果与第 i 层的偏置项 b_i 相加,最后通过非线性激活函数 f 的映射得到第 i 层特征图 K_i . 卷积层计算了所有神经元的输出. 卷积层中的每一个神经元都与输入层中的局部区域连接,每个神经元都计算本身与输入层相连的区域与自身权重的内积. 卷积层用于提取输入特征,对于图像数据而言,如第一层卷积能提取

边缘、线条等低级特征,越深的卷积层越能提取更深层次的特征.

一般情况下,在连续的卷积层之间插入一个汇聚层. 假设 K_i 是汇聚层,则有:

$$K_i = \text{downsampling}(K_{i-1}) \quad (5)$$

汇聚层的功能就是按照一定规则对特征图进行下采样,逐步降低数据的空间尺寸,减少网络参数数量和计算资源的耗费,有效控制过拟合.

经过多个卷积层和汇聚层的交替传播,最后通过全连接层对提取的特征进行分类. 全连接层作用是将学到的分布式特征表示映射到标记空间,得到输入 K_0 隶属于不同类别的概率矢量 Y ,即:

$$Y(i) = P(L = l_i | K_0; (W, b)) \quad (6)$$

式中: l_i 表示第 i 个标签类别. CNN 模型实质上是将原始矩阵 K_0 经过多层数据变换或降维,映射到一个新的特征表达 Y 的过程.

3 卷积神经网络的改进

3.1 引入批归一化

本文借鉴了 VGGNet 架构的特点,又根据所用小数据训练样本的特点,提出一种新的 CNN 模型架构. 由于本文模型借鉴了 VGGNet 网络的大深度模型,当靠前的层参数变化时,每层的输入分布在训练过程也会变化. 这只有通过较低的学习率和繁琐的参数初始化来减慢训练速度,导致了训练具有饱和和非线性的模型变得异常困难. 此现象称为内部协变量移位.

在训练过程中,随着网络加深,深度神经网络中的激活输入值在做非线性变换前,其分布会逐渐发生偏移,即其整体分布逐渐往非线性函数取值区间的上下端点逼近,从而导致后向传播时底层神经网络的梯度消失,进而造成网络训练速度变慢. 为了解决此类问题,本文将 Ioffe 提出的批归一化 (Batch Normalization, BN) 算法引入到改进的 CNN 中,通过一定的规范化算法,把每层神经网络的任意神经元激活输入值强制拉回标准正态分布,使输入值落入非线性函数的敏感区,使输入值小的变动就会导致损失函数较大变化,即增大梯度,加速收敛.

假设 CNN 网络中某一层输入数据集合为 $\{x_1, \dots, x_s\}$, 该批小样本数据的数量为 s , 引入 BN 算法对输入样本数据进行批归一化,输出数据集合设为

$\{y_1, \dots, y_s\}$, 算法主要步骤如下:

Step1. 计算输入激活数据集的期望:

$$E[x] = \frac{1}{s} \sum_{i=1}^s x_i \quad (7)$$

Step2. 计算输入激活数据集的方差:

$$\text{Var}[x] = \frac{1}{s} \sum_{i=1}^s (x_i - E[x])^2 \quad (8)$$

Step3. 对该批激活数据 x_i 进行批归一化得到 \hat{x}_i :

$$\hat{x}_i = \frac{x_i - E[x]}{\sqrt{\text{Var}[x] + \varepsilon}} \quad (9)$$

Step4. 引入两个网络可自动学习的参数 γ 和 β , 对 Step3 输出数据进行重构变换, 最后得到输出数据 y_i :

$$y_i = \gamma \hat{x}_i + \beta \quad (10)$$

式(9)中的 ε 加在分母上是为了防止除零错误, 目的是确保重构变换的数值稳定性, 一般取接近 0 的正数. 式(9)只相当于把非线性函数变成了线性函数, 即把每层的数据分布标准化, 但这种强制归一化会破坏网络中间层的固有分布, 为了解决由此带来的网络表达能力下降的问题, 保证非线性状态的学习, 引入了式(10)的重构变换对归一化值进行缩放和移位. 通过这个操作调整归一化值的标准正态分布, 在每个数据集上调整程度不同, 作用是把非线性函数值从中心的线性区往非线性区移动, 在具有较强的非线性表达能力的同时, 又避免太靠近线性区两端, 导致网络收敛速度太慢.

3.2 引入支持向量机分类

CNN 架构从本质上说, 卷积层、汇聚层和激活函数层的作用是将原始数据映射到隐层特征空间, 其中卷积层用以提取输入数据的局部特征, 它生成的每个特征图都是对输入数据的局部特征的某个角度的描述. 而全连接层负责将学到的分布式特征表示映射到标记样本空间, 关键功能是维度变换, 把高维数据降到低维, 全连接层的每个和特征图相同尺寸的卷积核从一个特定角度对这些特征图进行组合, 用以后续的分类. CNN 最后的输出层一般采用 Softmax 函数, 其通过全连接方式将多个神经元的输出, 映射到 (0, 1) 区间的概率, 输出每一个分类的概率. 该方法能与反向传播过程有效结合. 逻辑回归的损失函数源于全局数据的概率模型, Softmax 又基于回归原则, 为逻辑回归的多分类特例. 因此, Softmax 分类考虑全局样本的同时, 其分类超平面将会受到

每个样本的干扰, 导致非线性分类效果一般.

而支持向量机 (SVM) 基于结构代价最小化准则, 核心思想为通过预先指定的非线性变换将输入矢量映射至另外的高维特征空间, 在此空间构造最优分类超平面. SVM 的性能主要受支持向量的影响, 当支持向量机改变非支持向量样本时, 并不会引起决策面的变化, 因而其非线性分类性能优良. 已经有研究表明在人工神经网络架构中, 使用 SVM 做分类能获得比 Softmax 更优异的性能^[14-15]. 由于本实验数据源属于小样本, 在原始数据经过归一化预处理且 CNN 基本模型相对复杂的情况下, 采用 SVM 代替 Softmax 做分类, 预期可以提高最终识别准确率^[16]. 因此本文采用 SVM 代替 Softmax 用作 CNN 模型的分类型器, 隐含层输出的高维特征, 经过全连接层后, 被平铺成一维数据, 再输入 SVM 分类器进行类别判定.

4 实验结果

4.1 实验数据源

为了验证本文所提出的目标识别系统的有效性, 采用了高频电磁计算软件获取的 4 类车辆目标的宽带电磁散射数据, 对这些数据做逆傅里叶变换 (IFFT) 处理, 可得到目标的距离像. 该 4 类雷达目标电磁仿真数据是基于东南大学毫米波国家重点实验室研发的 NESC 高频电磁散射仿真软件计算而得^[17-18]. 仿真数据库中的 4 类地面车辆目标分别为装甲运输车、重型运输车、重型卡车和厢式卡车, 目标 CAD 模型及其在典型姿态下的距离像如图 1 所示.

基于 CAD 模型, 将表 1 中预设的电磁参数输入上述电磁计算系统得到 4 类目标全方位观测角度下的多极化电磁散射数据. 图 1 中各类目标模型右边图像为各个目标在同一观测角度、HH 极化方式下的归一化高分辨距离像示意图, 为简洁起见图中 HRRP 只展示出 64 个非零距离单元. 由图可见, 各目标距离像的幅度、峰值位置等差异较大, 此类差异信息就构成了基于 HRRP 进行目标分类的基础.

表 1 电磁散射计算参数

Tab.1 The calculation parameters of electromagnetic scattering

带宽 /MHz	中心频率 /GHz	方位角 /($^{\circ}$)	俯仰角 /($^{\circ}$)	频率采样 个数	极化 方式
500	100	0-360	27, 30	128	HH

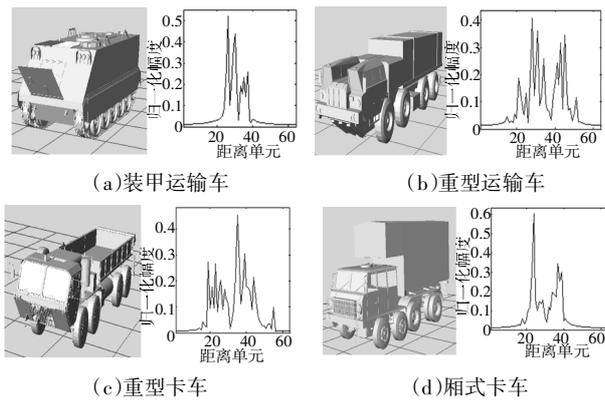


图 1 4 类地面目标 CAD 模型及其典型 HRRP 示意图
Fig.1 The CAD models and its typical HRRP diagram of 4 kinds of ground targets

对目标的同一个观测角度下的步进频率回波信号进行 IFFT 合成一维距离像. 为了消除距离像的强度敏感性^[9], 在训练前可对每幅距离像独立进行 l_2 归一化. 由于电磁仿真数据是类转台数据, 不必平移对准.

实验中选取在 HH 极化方式下的目标电磁散射回波作为基础数据集, 在不同俯仰角下进行电磁计算, 27°俯仰角下的观测数据作为训练集, 30°下的作为测试集, 每个目标的训练和测试集各有 14 400 个样本.

4.2 网络模型

实验中用于 4 类仿真目标 HRRP 识别的系统模型如图 2 所示, 该模型借鉴了 VGGNet 架构, 根据所采用数据集的特点, 提出并采用了一种新的 CNN 模型架构. 该网络包含了 8 个卷积层, 所有卷积层都采用步长为 1 进行 3*1 的卷积. 汇聚层都采用步长为 2 进行 2*1 的最大值汇聚. 本实验采用 Keras 深度学习的框架, 采用 Theano 作为后端进行张量操作.

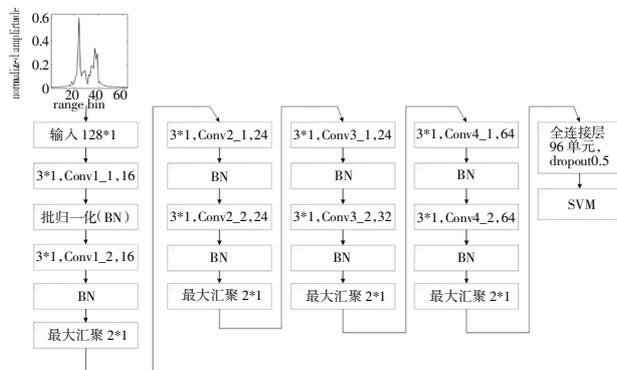


图 2 提出的卷积神经网络架构

Fig.2 The proposed convolutional neural network architecture

整个网络有 4 大隐含层, 每段内有 2 个卷积层, 且每层卷积核数量一样, BN 操作置于激活函数 ReLu 之前. 网络随层数递增过程中, 汇聚操作逐步忽略局部信息, 特征图的维度随着每个汇聚操作缩小一半, 特征图维度依次变化为: 128, 64, 32, 16, 8. 但是深度随着 4 个隐含层依次递增: 16, 24, 32, 64. 最小批尺寸为 32, 训练次数为 150 次, 初始学习率为 0.000 1, 动量为 0.9.

4.3 4 类仿真数据实验结果

4.3.1 BN 算法性能实验

图 3 和图 4 分别展示了当采用本文提出的基本 CNN 网络结构时, 不结合 BN 算法和结合 BN 算法的训练集和验证集的损失函数变化曲线. 其中深色

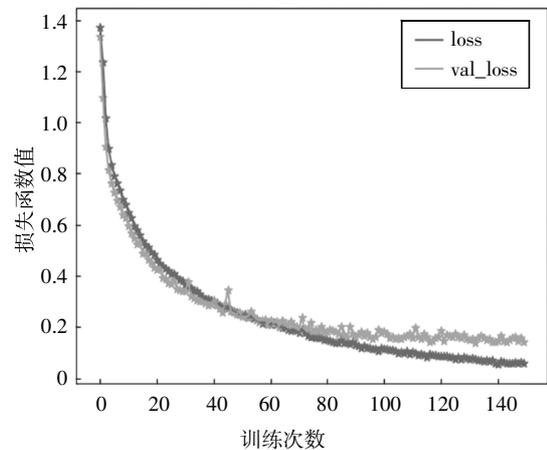


图 3 一般 CNN(未加 BN)的训练集和验证集损失函数随训练次数变化曲线

Fig.3 The loss function values curve with epochs of general CNN (without BN) in training set and validation set

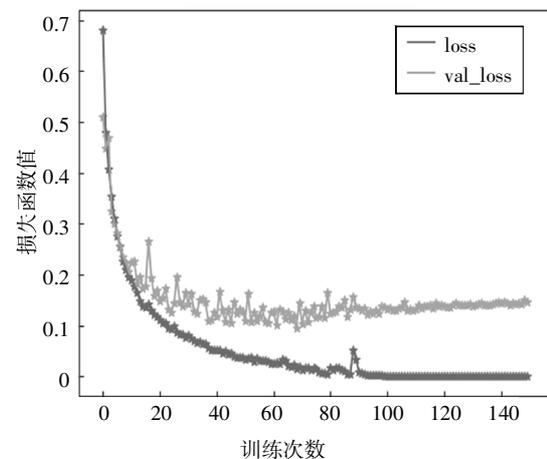


图 4 结合 BN 算法的 CNN 训练集和验证集的损失函数随训练次数的变化曲线

Fig.4 The loss function values curve with epochs of proposed CNN (with BN) in training set and validation set

线代表训练集指标变化,浅色线代表验证集指标变化.在训练终止时,损失值越小,表明该网络预测值与真实值差别越小.由图3和图4看出,结合BN算法的网络在训练阶段的损失值比一般CNN网络的损失值更小,特别是在训练初期,前者的损失函数下降更快,说明了BN算法可以加速网络收敛.

导致上述现象的原因有两点.第一,由于模型建立的过程是在假设数据之间独立同分布的基础上的,实际训练时都是用历史数据产生模型,再使用该模型预测测试数据,但是由于HRRP的姿态敏感性,导致每幅距离像之间强相关性,数据独立同分布的假设往往不成立.第二,训练样本太小,训练数据无法对整个数据分布进行估计的时候,采用的大深度网络进行了过度训练,比如不太重要的距离像的随机波动信息也被当作某种概念,被模型自动学习了,而这些随机波动并不适用于新数据,从而导致模型泛化性能变差.而采用BN算法的网络,通过强制将层间的激活输入值进行规范化,最大程度满足了数据独立同分布的假设,因而加快了收敛速度.

表2和表3分别列出了当采用本文提出的基本CNN架构时,记录的不结合BN算法和结合BN算法的训练集部分迭代次数的损失函数值.从中可以看出,对于本实验的小样本数据源,在整个训练过程中,同等实验条件下,未采用BN算法的CNN架构,在第140次迭代时,损失值为0.0534,从该观测点往后才最终收敛于0.0357.而采用BN算法的CNN架构在迭代到第90次时,损失函数值就降到了0.0293,从该观测点往后,损失函数值趋于稳定,最终150次时,收敛于0.0112.其收敛速度明显优于未加BN算法的情况.结果再次验证了,当处理小样本数据时,采用BN算法的CNN架构可以有效解决训练过程中损失函数收敛速度慢的问题.

表2 未加BN的CNN训练集部分迭代次数的损失函数值

Tab.2 The loss function value of the partial iteration number of the training set of the general CNN (without BN)

迭代次数	损失值	迭代次数	损失值	迭代次数	损失值
10	0.589 1	60	0.219 8	110	0.129 1
20	0.487 8	70	0.193 5	120	0.117 3
30	0.392 3	80	0.182 9	130	0.099 5
40	0.315 6	90	0.174 6	140	0.053 4
50	0.283 2	100	0.131 0	150	0.035 7

表3 结合BN的CNN训练集部分迭代次数的损失函数值
Tab.3 The loss function value of the partial iteration number of the CNN training set combined with BN

迭代次数	损失值	迭代次数	损失值	迭代次数	损失值
10	0.162 5	60	0.042 6	110	0.014 3
20	0.113 9	70	0.038 2	120	0.012 9
30	0.079 6	80	0.034 8	130	0.012 0
40	0.067 2	90	0.029 3	140	0.011 6
50	0.048 7	100	0.017 9	150	0.011 2

4.3.2 基于Softmax与SVM的CNN对比实验

为表述方便,将4类目标分别记为Tgt1~Tgt4.将训练数据输入图2的目标识别系统,在没有观测噪声的条件下进行识别测试.结合BN算法的CNN分别采用Softmax和SVM分类结果如表4和表5所示,混淆概率矩阵中的列值表示测试数据的真实目标类别,行值表示预测目标类别.

表4 基于Softmax的CNN识别结果

Tab.4 The recognition results of CNN based on Softmax

	Tgt1	Tgt2	Tgt3	Tgt4
Tgt1	0.952 6	0.020 4	0	0.027 0
Tgt2	0.029 6	0.879 7	0.020 4	0.070 3
Tgt3	0	0	1	0
Tgt4	0.006 2	0.006 7	0	0.987 1

表5 基于SVM的CNN识别结果

Tab.5 The recognition results of CNN based on SVM

	Tgt1	Tgt2	Tgt3	Tgt4
Tgt1	0.968 6	0.010 3	0	0.021 1
Tgt2	0.026 7	0.891 7	0.018 9	0.062 7
Tgt3	0	0	1	0
Tgt4	0.001 2	0.000 5	0	0.998 3

由表4和表5可看出基于SVM的CNN识别系统对于4类目标的识别率要高于基于Softmax的CNN.而且通过实验得出,用Softmax做分类时的平均识别率为0.9540,当用SVM做分类时,平均识别率提高到了0.9645.具体原因是当CNN模型提取的特征生效后,原始的线性不可分数据趋于线性可分,

此时 SVM 仅利用部分支持向量样本的分类原则优势就凸显了.该结果证明了在训练样本不大情况下, CNN 采用 SVM 做分类可以增强 HRRP 目标识别性能.

4.3.3 本文方法与其他分类方法对比实验

为进一步验证本文所提出的网络结构的有效性,在相同的实验条件下,将本文方法与 SVM、最大相关匹配法(Maximum Correlation Criterion-Template Matching Method, MCC-TMM)^[20]、贝叶斯压缩感知(Bayesian Compressive Sensing, BCS)^[21]和联合稀疏表示分类方法(Joint Sparse Representation, JSR)^[22]进行对比,对比实验结果如表 6 所示.从表 6 可以看出本文方法明显优于 SVM、MCC-TMM、BCS 和 JSR 等方法,再次验证了本文所提的目标识别模型确实能增强 HRRP 目标识别性能.

表 6 其他算法实验结果

Tab.6 The experimental results of other algorithms

方法	平均识别率
SVCA+SVM ^[23]	0.942 4
MCC-TMM ^[23]	0.928 1
BCS ^[24]	0.927 6
JSR ^[25]	0.914 9
CNN(基于 Softmax)	0.954 0
本文方法	0.964 5

5 结 论

针对 HRR 雷达目标识别问题,本文提出了一种基于卷积神经网络的目标识别方法.首先基于小数据集的特点,将批归一化算法引入 CNN 网络模型.其次,针对基于 Softmax 分类的 CNN 模型非线性分类效果有限的问题,本文将 Softmax 分类器替换为支持向量机,并利用 4 类军事车辆目标的高保真电磁仿真数据对所提方法进行验证.在不需要人工提取距离像特征的情况下,本文方法在 4 类目标实验中,平均识别率达到了 96.45%.并且利用本文网络架构处理小数据集时,加快了损失函数曲线的收敛速度.实验证明本文方法的有效性,并说明了卷积神经网络应用在高距离分辨率雷达目标识别领域有一定前景.

但是目前对雷达目标识别来说,往往无法获得完备目标数据集,如待测目标为敌军车辆目标.而且受限于数据获取的条件,很难获取足够多的训练样本,因此距离像识别可看成典型的小样本识别问题.另外,数据来源差异也不容忽略,比如训练数据来源于电磁仿真或暗室缩比模型测量,而测试数据是真实场景数据.上述因素都会影响 HRRP 识别的稳健性,故深入研究稳健的目标识别算法将是下一步的工作重点.

参考文献

- [1] 杜兰. 雷达高分辨距离像目标识别方法研究[D]. 西安:西安电子科技大学电子工程学院, 2007:3—9.
DU L. Research on target recognition method for radar high resolution range profile[D]. Xi'an: School of Electronic Engineering, Xi-dian University, 2007:3—9. (In Chinese)
- [2] 何松华, 肖怀铁, 孙文峰, 等. 高距离分辨率极化雷达目标匹配识别研究[J]. 电子学报, 1999, 27(3):110—112.
HE S H, XIAO H T, SUN W F, et al. A study of high range resolution polarization radar target recognition by using matched correlators[J]. Acta Electronica Sinica, 1999, 27(3):110—112. (In Chinese)
- [3] 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.
TIAN Z Z, ZHAN R H, HU J M, et al. SAR ATR based on convolutional neural network [J]. Journal of Radars, 2016, 5(3):320—325. (In Chinese)
- [4] 宋青松, 张超, 田正鑫, 等. 基于多尺度卷积神经网络的交通标志识别 [J]. 湖南大学学报(自然科学版), 2018, 45(8):131—137.
SONG Q S, ZHANG C, TIAN Z X, et al. Traffic sign recognition based on multi-scale convolutional neural network [J]. Journal of Hunan University (Natural Sciences), 2018, 45(8):131—137. (In Chinese)
- [5] HINTON G E, OSINDER S, THE Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7):1527—1554.
- [6] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion[J]. The Journal of Machine Learning Research, 2010, 11:3371—3408.
- [7] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11):2278—2324.
- [8] KAREN S, ANDREW Z. Very deep convolution net-works for

- large-scale image recognition [C]//International Conference on Learning Representations (ICLR). San Diego, 2015, arXiv:1409.1556.
- [9] HE K, ZHANG X, REN S, *et al.* Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770—778.
- [10] JARMO L, VISA K. Deep learning for HRRP-based target recognition in multistatic radar systems [C]//IEEE Radar Conference. Philadelphia: IEEE, 2016: 1—6.
- [11] OSMAN K, OKAN M Y, MEHMET Z K, *et al.* Convolutional neural networks-based ship target recognition using high resolution range profiles [C]//18th International Radar Symposium. Prague: IEEE, 2017: 1—6.
- [12] SERGEY I, CHRISTIAN S. Batchnormalization: accelerating deep network training by reducing internal covariate shift [C]//Proceedings of the 32nd International Conference on Machine Learning (ICML). Lille, 2015: 448—456. arXiv:1502.03167.
- [13] CORTES C, VAPNIK V. Support-vector networks [J]. *Machine Learning*, 1995, 20(3): 273—297.
- [14] DARMATASIA, MOHAMAD I F. Handwriting recognition on form document using convolutional neural network and support vector machines (CNN-SVM) [C]//5th International Conference on Information and Communication Technology (ICoICT). Melaka: IEEE, 2017: 1—6.
- [15] ALALSHEKMUBARAK A, SMITH L S. A novel approach combining recurrent neural network and support vector machines for time series classification [C]//9th International Conference on Innovations in Information Technology. Abu Dhabi: IEEE, 2013: 42—47.
- [16] ABIEN F A. An architecture combining convolutional neural network (CNN) and support vector machine (SVM) for image classification [astro-ph.CO] Adamson University, Manila, 2017. arXiv preprint arXiv:1712.03541.
- [17] 吕志清, 安翔, 洪伟. 电磁散射的拉格朗日乘子区域分解算法 [J]. *电子学报*, 2007, 35(6): 1069—1073.
- LÜ Z Q, AN X, HONG W. Domain decomposition method with Lagrange multipliers for the analysis of electromagnetic scattering [J]. *Acta Electronica Sinica*, 2007, 35(6): 1069—1073. (In Chinese)
- [18] 殷晓星, 王群, 洪伟. 目标雷达散射截面的高频适用条件 [J]. *现代雷达*, 2007, 29(1): 6—8.
- YIN X X, WANG Q, HONG W. Restriction condition of radar cross section of objects in high frequency [J]. *Modern Radar*, 2007, 29(1): 6—8. (In Chinese)
- [19] 袁莉. 基于高分辨距离像的雷达目标识别方法研究 [D]. 西安: 西安电子科技大学电子工程学院, 2007: 7—8.
- YUAN L. Research on radar target recognition method based on high resolution range profile [D]. Xi'an: School of Electronic Engineering, Xidian University, 2007: 7—8. (In Chinese)
- [20] ZYWECK A, BOGNER R E. Radar target classification of commercial aircraft [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1996, 32(2): 598—606.
- [21] JI S, YA X, CARIN L. Bayesian compressive sensing [J]. *IEEE Transactions on Signal Processing*, 2008, 56(6): 2346—2356.
- [22] SHEKHAR S, VISHAL M P, NASSER M N, *et al.* Joint sparse representation for robust multimodal biometrics recognition [J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 2013, 35: 1—14.
- [23] 刘盛启. 基于高分辨距离像的特征提取与识别增强技术 [D]. 长沙: 国防科技大学 ATR 实验室, 2016: 33—44.
- LIU S Q. Research on feature extraction and recognition performance enhancement algorithms based on high range resolution profile [D]. Changsha: ATR Laboratory, National University of Defense Technology, 2016: 33—44. (In Chinese)
- [24] LIU S Q, ZHAN R H, ZHAI Q L, *et al.* Multi-view radar target recognition based on Bayesian compressive sensing [J]. *Journal of Electro-magnetic Waves and Applications*, 2015, 687(14): 3704—3708.
- [25] LIU S Q, ZHAN R H, ZHAI Q L, *et al.* Full-polarization HRRP recognition based on joint sparse representation [C]//IEEE Radar Conference. Johannesburg: IEEE, 2015: 333—338.