

基于混合型复数域卷积神经网络的三维转动舰船目标识别

张 云, 化青龙, 姜义成, 徐 丹

(哈尔滨工业大学电子与信息工程学院, 黑龙江哈尔滨 150001)

摘 要: 在较高海情下, 由于舰船目标处于随机摆动的非平稳运动状态, 常规合成孔径雷达 (Synthetic Aperture Radar, SAR) 成像处理会使得目标散焦、方位模糊, 从而导致三维转动舰船目标识别准确率低. 本文提出一种混合型复数域卷积神经网络 (Mix-type Complex-Valued Convolutional Neural Network, Mix-CV-CNN), 并推导 Mix-CV-CNN 前向传播与反向传播算法. 三维转动舰船目标经过 SAR 成像处理后存在剩余相位信息, Mix-CV-CNN 能充分利用 SAR 复数域图像的幅度和相位信息, 在不进行目标重聚焦的情况下, 较好完成 SAR 复杂运动舰船目标的识别. 实验表明, Mix-CV-CNN 相较于具有相同自由度的实数域卷积神经网络 (Real-Valued Convolutional Neural Network, RV-CNN) 识别性能有所提高, 实测数据识别平均准确率提高 3.85%.

关键词: 合成孔径雷达; 复数域卷积神经网络; 三维转动; 目标散焦; 舰船目标识别; 混合型复数域卷积神经网络

中图分类号: TP751

文献标识码: A

文章编号: 0372-2112(2022)05-1042-08

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

DOI: 10.12263/DZXB.20211255

Recognition of 3D Rotating Ship Based on Mix-CV-CNN

ZHANG Yun, HUA Qing-long, JIANG Yi-cheng, XU Dan

(School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin, Heilongjiang 150001, China)

Abstract: Because the ship targets are in a non-stationary motion state of random swing, conventional synthetic aperture radar (SAR) imaging processing will make the targets defocused and azimuth blurred, resulting in the recognition accuracy of three-dimensional rotating ship. This paper proposes a mixed-type complex-valued convolutional neural network (Mix-CV-CNN) and derives the Mix-CV-CNN forward propagation and backpropagation algorithms. The three-dimensional rotating target has residual phase information after SAR imaging processing. The Mix-CV-CNN could make full use of the amplitude and phase information of the complex SAR image and could better complete the recognition of SAR three-dimensional rotating targets without target refocusing. The experimental results show that Mix-CV-CNN has improved recognition performance compared with the real-valued convolutional neural network (RV-CNN) with the same degree of freedom. The average accuracy is increased by 3.85%.

Key words: synthetic aperture radar (SAR); complex-valued convolutional neural network (CV-CNN); three-dimensional rotation; target defocus; ship target classification; mix-type complex-valued convolutional neural network (Mix-CV-CNN)

1 引言

星载合成孔径雷达 (Synthetic Aperture Radar, SAR) 具有全天候、全天时、高分辨观测优势, 已成为对海监视不可或缺的手段^[1]. 在中高海情下, 航行中的舰船在海浪作用下存在三维摆动和平动分量. 非平稳运动动

量使得 SAR 回波近似为多分量多项式相位信号, SAR 成像处理后存在剩余多普勒相位, 导致成像结果呈现不同程度的散焦现象, 进而给舰船识别带来困难^[2]. 三维转动舰船目标成像处理主要用 SAR/ISAR 混合成像方式获得重聚焦图像, 进而进行特征提取与目标识别^[3]. 非合作舰船目标受到本身运动与海浪作用的随

机摆动复合作用,使得 SAR/ISAR 成像处理复杂. 同时在大场景 SAR 图像中,存在多目标交叠、强目标淹没弱目标等问题,导致实测运动舰船的识别率不高. 传统舰船识别方法主要对 SAR 静止舰船图像或聚焦后的清晰图像进行识别,较少考虑舰船随机摆动特性、平动特性导致图像模糊之后的识别问题.

随着深度学习的快速发展^[4],卷积神经网络(Convolutional Neural Network, CNN)在 SAR 图像处理领域展现出应用优势. 国内一些学者已经研究了 CNN 在 SAR 舰船检测领域的应用^[5,6]. 张晓玲等^[5]提出一种基于深度分离卷积神经网络的 SAR 舰船检测方法 SAR-ShipNet-20,该方法能够实现高速和高精度的舰船检测. SAR 回波本质是电磁波与成像场景相互作用的电磁相干叠加, SAR 图像本身是带有相位信息的复数数据^[7]. 但是以上研究通常仅考虑 SAR 图像的幅度信息,而忽略了与目标复杂运动特性有关的相位信息. 徐丰等^[8]将复数域卷积神经网络(Complex-Valued Convolutional Neural Network, CV-CNN)引入极化 SAR 地物识别, CV-CNN 相对于实数域卷积神经网络(Real-Valued Convolutional Neural Network, RV-CNN)具有明显识别优势,一些研究学者开始将 SAR 成像机理、目标回波特性与深度学习结合,并提出基于数据和模型联合驱动下的识别方法.

与光学图像不同, SAR 图像相位蕴含了目标的丰富信息. 近年来,一些学者利用 CV-CNN 开展 SAR 目标识别研究,复数域深度学习逐渐成为一个深度学习领域较受关注的分支,尤其在 SAR 目标识别上表现了优越性能. YU 等^[9]提出了复数域全卷积神经网络用于 SAR 目标分类,该网络隐藏层中只包含卷积层,避免了复杂的池化操作和过拟合. TAN 等^[10]利用复数域网络提取协方差/相干矩阵中包含的物理散射机制,提出了 CV-3D-CNN 网络进行 PolSAR 图像分类. SUNAGA 等^[11]提出了一种 CV-CNN 架构处理 InSAR 数据,并证明该 CV-CNN 可自适应地对斜坡和平原进行分类. GAO J 等^[12]通过数据驱动的方式,利用 CV-CNN 实现了对 SAR 舰船目标的重聚焦.

CV-CNN 在处理复数域数据具有一定优势,网络中的全部元素可扩展到复数域. 但激活函数在扩展过程中会出现不解析的问题. 文献[8]提出的实虚型复数域卷积神经网络(Real-Imaginary-type Complex-Valued Convolutional Neural Network, RI-CV-CNN)将复数分为实部和虚部分别激活处理,但该方法并不直接处理相位信息,不利于网络对舰船复杂运动信息的感知. 文献[11]将复数分为幅度和相位分别处理,但直接推导反向传播公式较为困难. 因此,本文提出一种混合型复数域卷积神经网络(Mix-type Complex-Valued Convolu-

tional Neural Network, Mix-CV-CNN),在卷积层将输入分为幅度和相位两部分,充分考虑 SAR 舰船复杂运动信息的感知识别,在全连接层和输出层设计了实虚型网络,进行误差反向传播公式的推导. 由于随机海浪使得舰船目标存在三维转动, Mix-CV-CNN 不需要对运动目标进行 SAR/ISAR 混合成像的重聚焦处理,即可解决三维转动目标识别问题,提高识别精度.

2 三维转动舰船目标成像分析

舰船在海上航行时,由于受风力、气压和重力等影响,会随着海浪起伏摆动,产生随机非平稳运动,并表现为三维转动:俯仰、侧摆和偏航. 三维转动使得舰船目标回波的多普勒相位时变,常规 SAR 成像处理后仍有多阶相位信息剩余,从而影响 SAR 成像质量. 舰船三维转动示意图如图 1 所示.




图 1 舰船三维转动示意图

从图 1 中可以得到,三维转动角速度分别为偏航角速度 ω_y 、俯仰角速度 ω_p 和侧摆角速度 ω_r . 由三维转动产生的舰船转动角度分别为偏航角 θ_y 、俯仰角 θ_p 和侧摆角 θ_r . 当舰船发生偏航、俯仰和侧摆时,多普勒频率可以分别表示为^[13]

$$f_{dy} = 2 \left\{ \left[x_p \cos \theta_y - y_p \sin \theta_y \right] \tilde{j} - \left[x_p \sin \theta_y + y_p \cos \theta_y \right] \tilde{i} \right\} \omega_y / \lambda \quad (1)$$

$$f_{dp} = 2 \left\{ \left[z_p \cos \theta_p + x_p \sin \theta_p \right] \tilde{i} + \left[z_p \sin \theta_p - x_p \cos \theta_p \right] \tilde{k} \right\} \omega_p / \lambda \quad (2)$$

$$f_{dr} = 2 \left\{ \left[y_p \cos \theta_r - z_p \sin \theta_r \right] \tilde{k} - \left[y_p \sin \theta_r + z_p \cos \theta_r \right] \tilde{j} \right\} \omega_r / \lambda \quad (3)$$

式(1)~(3)中, (x_p, y_p, z_p) 为舰船一散射点的坐标, $(\tilde{i}, \tilde{j}, \tilde{k})$ 为坐标单位, λ 为入射波波长.

由式(1)~(3)可得,舰船三维转动分量引起目标回波多普勒频率变化,进而导致 SAR 图像模糊散焦,仿真成像结果如图 2 所示,图 2(a)~(d)为点目标仿真结果,图 2(e)~(h)为第 800 距离单元方位剖面图,不同转动分量均会引起目标像散焦.

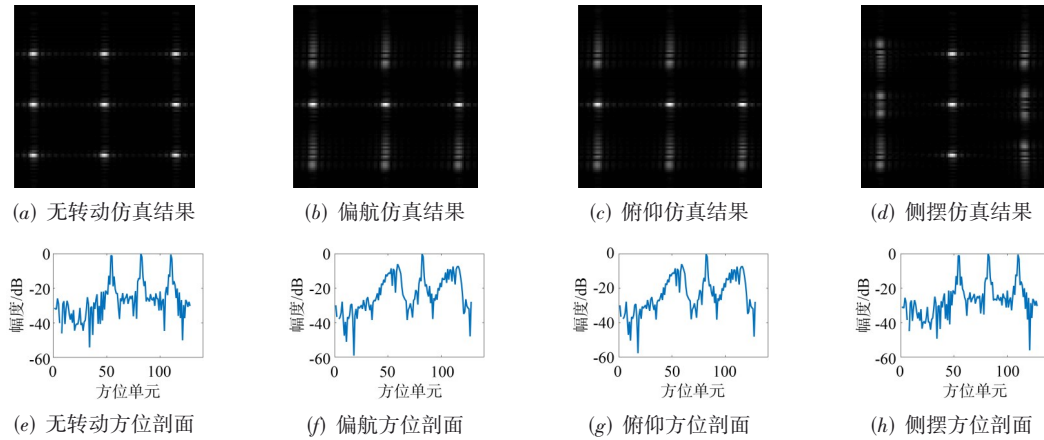


图2 SAR点目标三维转动仿真示例

3 基于 Mix-CV-CNN 的 SAR 舰船识别算法

本文构建了一种混合型卷积神经网络,该网络结合幅相型与实虚型卷积神经网络的优点,在卷积层使用幅相型激活函数,在全连接层与输出层使用实虚型激活函数^[14],在一定程度上解决了幅相型神经网络反向传播过程较为复杂的难题,并提升了 SAR 三维转动舰船目标的识别性能。

3.1 Mix-CV-CNN 算法原理

Mix-CV-CNN 由输入层、卷积层、池化层、全连接层和输出层组成, Mix-CV-CNN 的所有元素均为复数. 本小节介绍 Mix-CV-CNN 的前向传播与反向传播算法。

3.1.1 Mix-CV-CNN 前向传播算法

(1) 卷积层前向传播

第 l 个卷积层的输出 \mathbf{a}^l 可以表述为:前一层的输出 \mathbf{a}^{l-1} 经过卷积核 \mathbf{W}^l 的卷积运算,得到中间参量 \mathbf{z}^l ,再经过幅相型激活函数 $\sigma_{A-P}(\cdot)$ ^[15] 激活,得 \mathbf{a}^l ,即

$$\mathbf{a}^l = \sigma_{A-P}(\mathbf{z}^l) = \sigma(|\mathbf{z}^l|) \exp(j \cdot \arg(\mathbf{z}^l)) \quad (4)$$

$$\mathbf{z}^l = \mathbf{a}^{l-1} * \mathbf{W}^l \quad (5)$$

式中, $|z|$ 与 $\arg(z)$ 分别代表复变量 z 的幅度与相位, $\sigma(\cdot)$ 为实数域激活函数,如 sigmoid^[16]、ReLU^[17] 等, j 是虚数单位, $*$ 表示卷积操作。

(2) 池化层前向传播

除了卷积层,深度学习网络也常用池化层缩减模型的大小,提高计算速度,同时增强所提取特征的鲁棒性. 池化层的操作相当于下采样,并减小特征图尺寸. 本文采取平均值池化,即选取池化窗口内平均值作为池化层输出. 池化层前向传播过程为:前一层的输出 \mathbf{a}^{l-1} 经过平均值池化,得到池化层输出 \mathbf{a}^l ,即

$$\mathbf{a}^l = \text{ave}(\text{Re}(\mathbf{a}^{l-1})) + j \cdot \text{ave}(\text{Im}(\mathbf{a}^{l-1})) \quad (6)$$

式中, $\text{Re}(z)$ 与 $\text{Im}(z)$ 分别代表 z 的实部与虚部, $\text{ave}(\cdot)$ 表示平均值池化操作。

(3) 全连接层前向传播

全连接层中的每个神经元都与前一层中的所有神经元相连,在整个网络中起到分类器的作用. 如果 L 表述为输出层,则输出层的输出 \mathbf{a}^L 可以表述为:全连接层的输出 \mathbf{a}^{L-1} 经过连接权重 \mathbf{W}^L 的矩阵相乘运算,得到中间参量 \mathbf{z}^L ,再经过实虚型激活函数 $\sigma_{R-I}(\cdot)$ 激活,得到输出层的输出 \mathbf{a}^L . 即

$$\mathbf{a}^L = \sigma_{R-I}(\mathbf{z}^L) = \sigma(\text{Re}(\mathbf{z}^L)) + j \cdot \sigma(\text{Im}(\mathbf{z}^L)) \quad (7)$$

$$\mathbf{z}^L = \mathbf{W}^L \mathbf{a}^{L-1} \quad (8)$$

输出层采用独热编码,对应真值位置为 $1 + 1j$,其他位置为 0. 计算输出向量中每个元素幅度,幅度最大元素的位置编号即为输出类别。

3.1.2 Mix-CV-CNN 反向传播算法

Mix-CV-CNN 有监督训练的实质是优化权重和偏差,使得网络输出与训练数据的期望输出或给定标签相匹配. 在多特征提取阶段之后,网络输出和目标之间仍然存在误差,该误差可以描述为损失函数. 因此,网络参数通过优化算法进行训练,并将反向传播中的损失函数最小化。

(1) 全连接层反向传播

令 \mathbf{a}^L 为网络输出, \mathbf{h} 为期望输出,则总的分类误差 J 可以表示为

$$J = \frac{1}{2} \|\mathbf{a}^L - \mathbf{h}\|^2 \quad (9)$$

定义输出层误差项为

$$\delta^L = \frac{\partial J}{\partial \text{Re}(\mathbf{a}^L)} \frac{\partial \text{Re}(\mathbf{a}^L)}{\partial \text{Re}(\mathbf{z}^L)} + \frac{\partial J}{\partial \text{Im}(\mathbf{a}^L)} \frac{\partial \text{Im}(\mathbf{a}^L)}{\partial \text{Re}(\mathbf{z}^L)} + j \frac{\partial J}{\partial \text{Re}(\mathbf{a}^L)} \frac{\partial \text{Re}(\mathbf{a}^L)}{\partial \text{Im}(\mathbf{z}^L)} + j \frac{\partial J}{\partial \text{Im}(\mathbf{a}^L)} \frac{\partial \text{Im}(\mathbf{a}^L)}{\partial \text{Im}(\mathbf{z}^L)} \quad (10)$$

由式(9)可知,式(10)的第二、三项为零,因此式(10)可简化为

$$\begin{aligned} \delta^L &= \text{Re}(\mathbf{a}^L - \mathbf{h})\sigma'(\text{Re}(\mathbf{z}^L)) \\ &+ j \cdot \text{Im}(\mathbf{a}^L - \mathbf{h})\sigma'(\text{Im}(\mathbf{z}^L)) \end{aligned} \quad (11)$$

式中 $\sigma'(\cdot)$ 为 $\sigma(\cdot)$ 的导数.

通过式(12)与(13)完成全连接层的权值更新.

$$\frac{\partial J}{\partial \mathbf{W}^L} = \delta^L (\mathbf{a}^{L-1})^H \quad (12)$$

$$\mathbf{W}^L \leftarrow \mathbf{W}^L + \alpha \frac{\partial J}{\partial \mathbf{W}^L} \quad (13)$$

式中 $(\cdot)^H$ 代表取共轭转置.

(2) 池化层反向传播

在池化层中并没有需要学习的参数,但是仍然需要计算池化层的误差项,以便在反向传播中获得较低层的误差项.若第 l 层是池化层,该层误差项 δ^l 与后接卷积层的误差项 δ^{l+1} 及权重 \mathbf{W}^{l+1} 有关,池化层误差项 δ^l 为

$$\begin{aligned} \text{Re}(\delta^l) &= \text{Re}(\delta^{l+1}) * \text{rot}(\text{Re}(\mathbf{W}^{l+1})) \\ &+ \text{Im}(\delta^{l+1}) * \text{rot}(\text{Im}(\mathbf{W}^{l+1})) \end{aligned} \quad (14)$$

$$\begin{aligned} \text{Im}(\delta^l) &= -\text{Re}(\delta^{l+1}) * \text{rot}(\text{Im}(\mathbf{W}^{l+1})) \\ &+ \text{Im}(\delta^{l+1}) * \text{rot}(\text{Re}(\mathbf{W}^{l+1})) \end{aligned} \quad (15)$$

式中 $\text{rot}(\cdot)$ 代表矩阵旋转 180 度.

(3) 卷积层反向传播

Mix-CV-CNN 在卷积层使用幅相型激活函数,采用全连接层误差项公式推导方式,通过求取卷积层误差项的实部和虚部完成误差反向传播.

若第 l 层是卷积层,该层误差项 δ^l 与后接池化层的误差项 δ^{l+1} 以及池化因子 β 有关.为了保持误差项尺寸相同,需要将 δ^{l+1} 进行上采样,上采样过程表示为 $\text{up}(\delta^{l+1})$. 则 J 对该卷积层输出 \mathbf{a}^l 的偏导为

$$\frac{\partial J}{\partial \text{Re}(\mathbf{a}^l)} = \beta (\text{Re}(\text{up}(\delta^{l+1})) + \text{Im}(\text{up}(\delta^{l+1}))) \quad (16)$$

$$\frac{\partial J}{\partial \text{Im}(\mathbf{a}^l)} = \beta (-\text{Re}(\text{up}(\delta^{l+1})) + \text{Im}(\text{up}(\delta^{l+1}))) \quad (17)$$

则卷积层误差项为

$$\begin{aligned} \text{Re}(\delta^l) &= \frac{\partial J}{\partial \text{Re}(\mathbf{a}^l)} \frac{\partial \text{Re}(\mathbf{a}^l)}{\partial \text{Re}(\mathbf{z}^l)} + \frac{\partial J}{\partial \text{Im}(\mathbf{a}^l)} \frac{\partial \text{Im}(\mathbf{a}^l)}{\partial \text{Re}(\mathbf{z}^l)} \\ &= \frac{\partial J}{\partial \text{Re}(\mathbf{a}^l)} \left(\sigma'(|\mathbf{z}^l|) \cos(\arg(\mathbf{z}^l)) \frac{\text{Re}(\mathbf{z}^l)}{|\mathbf{z}^l|} + \text{Im}(\mathbf{a}^l) \frac{\text{Im}(\mathbf{z}^l)}{|\mathbf{z}^l|^2} \right) \\ &+ \frac{\partial J}{\partial \text{Im}(\mathbf{a}^l)} \left(\sigma'(|\mathbf{z}^l|) \sin(\arg(\mathbf{z}^l)) \frac{\text{Re}(\mathbf{z}^l)}{|\mathbf{z}^l|} + \text{Re}(\mathbf{a}^l) \frac{\text{Im}(\mathbf{z}^l)}{|\mathbf{z}^l|^2} \right) \end{aligned} \quad (18)$$

$$\begin{aligned} \text{Im}(\delta^l) &= \frac{\partial J}{\partial \text{Re}(\mathbf{a}^l)} \frac{\partial \text{Re}(\mathbf{a}^l)}{\partial \text{Im}(\mathbf{z}^l)} + \frac{\partial J}{\partial \text{Im}(\mathbf{a}^l)} \frac{\partial \text{Im}(\mathbf{a}^l)}{\partial \text{Im}(\mathbf{z}^l)} \\ &= \frac{\partial J}{\partial \text{Re}(\mathbf{a}^l)} \left(\sigma'(|\mathbf{z}^l|) \cos(\arg(\mathbf{z}^l)) \frac{\text{Im}(\mathbf{z}^l)}{|\mathbf{z}^l|} - \text{Im}(\mathbf{a}^l) \frac{\text{Re}(\mathbf{z}^l)}{|\mathbf{z}^l|^2} \right) \\ &+ \frac{\partial J}{\partial \text{Im}(\mathbf{a}^l)} \left(\sigma'(|\mathbf{z}^l|) \sin(\arg(\mathbf{z}^l)) \frac{\text{Im}(\mathbf{z}^l)}{|\mathbf{z}^l|} + \text{Re}(\mathbf{a}^l) \frac{\text{Re}(\mathbf{z}^l)}{|\mathbf{z}^l|^2} \right) \end{aligned} \quad (19)$$

通过式(20)与(21)完成卷积层权值更新.

$$\frac{\partial J}{\partial \mathbf{W}^l} = \overline{\mathbf{a}^{l-1}} * \delta^l \quad (20)$$

$$\mathbf{W}^l \leftarrow \mathbf{W}^l + \alpha \frac{\partial J}{\partial \mathbf{W}^l} \quad (21)$$

式中 $\overline{(\cdot)}$ 代表取共轭.

3.2 算法描述

在舰船三维转动条件下,SAR 回波数据经过常规 SAR 成像算法的距离向与方位向压缩后,仍有多阶相位信息剩余,使得三维转动目标不能很好地聚焦成像.本文所提的基于 Mix-CV-CNN 的 SAR 舰船识别算法利用复数域网络相位信息提取与处理能力,提高对模糊散焦 SAR 三维转动舰船目标的识别效果.识别算法示意图如图 3 所示.

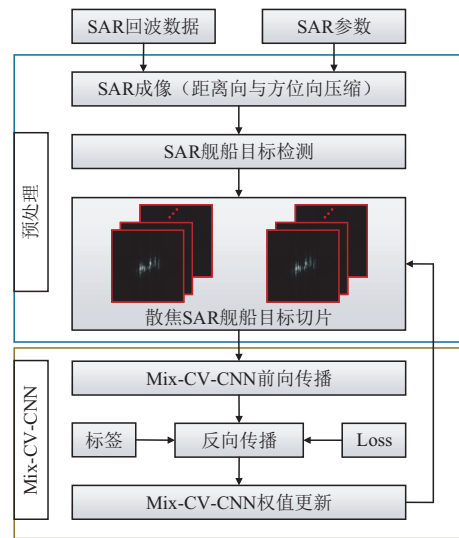


图 3 SAR 舰船识别算法示意图

首先,通过 SAR 成像处理构造 SAR 三维转动舰船目标训练集与测试集;然后,利用训练集训练 Mix-CV-CNN,通过 Mix-CV-CNN 自学习并提取样本的深层本质特征;最后,通过全连接层与输出层,实现对 SAR 三维转动舰船目标的识别.

步骤如算法 1 所示:

算法 1 基于 Mix-CV-CNN 的 SAR 舰船识别算法

输入: SAR 舰船目标训练集与测试集

输出: Mix-CV-CNN 模型与舰船类别

1. 根据式(4)~(8),从训练集中随机选取部分样本与对应标签,输入到 Mix-CV-CNN 中进行前向传播,得到网络输出 a^l ;
2. 根据式(9)~(11)、式(14)~(19),由 a^l 与标签 h ,利用 Mix-CV-CNN 反向传播算法,计算各层误差项 δ^l ;
3. 根据式(12)、(13)、(20)、(21),由各层输出 a^l 与误差项 δ^l 更新权值;
4. 按照设定的训练批次与迭代次数,循环步骤 1~3,完成训练;
5. 将测试样本输入到训练好的 Mix-CV-CNN 进行前向传播,得到输出 a^l ,实现 SAR 三维转动舰船目标的识别.

4 实验结果与分析

4.1 数据集

4.1.1 仿真数据集

仿真数据由基于 3D 模型与射线追踪法的 SAR 成像方法得到,图像为未进行运动补偿和重聚焦处理的原始成像结果. 仿真参数:轨道高度 755 km、斜视角 0° 、下视角 42.3° 、雷达平台速度 7568 m/s、载频 5.4 GHz、脉冲重复频率为 1178 Hz. 仿真数据集包含五类目标,分别为阿利伯克级驱逐舰、黑天鹅级护卫舰、不来梅级护卫舰、日向级驱逐舰、罗津级护卫舰. 仿真不同姿态、信噪比、三维转动角速度的样本数据 11520 个. SAR 三维转动舰船目标仿真示例如图 4 所示.



图 4 五类 SAR 三维转动舰船目标仿真示例 (a) 五类舰船目标光学图像; (b) 3D 模型; (c) 静止状态; (d) 三维转动状态

4.1.2 实测数据集

基于船舶自动识别系统数据对七景高分三 SAR 数据进行标注,再结合部分 OpenSAR^[18]数据集,构建 SAR 实测数据集,包含货船、油船、其他船三类目标等样本数据 2000 个,示例如图 5 所示.

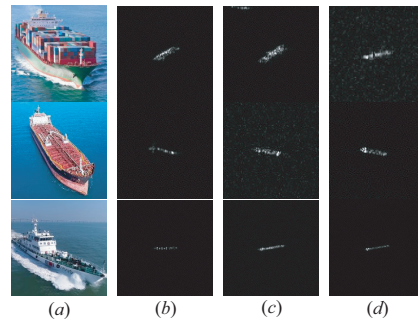


图 5 三类 SAR 舰船目标实测示例 (a) 光学图像; (b)~(d) SAR 实测图像

4.2 网络架构

Mix-CV-CNN 架构如图 6 所示. 除了输入输出层外,它还包括五个卷积层,三个平均池化层和两个全连接层. Mix-CV-CNN 的自由度是同类 RV-CNN 的两倍. 为了公平对比,实验所用 RV-CNN 架构具有与 Mix-CV-CNN 相同的自由度,其二维输入数据由 SAR 复图像的实部和虚部组成.

4.3 模型训练

网络训练优化方法采用 CvAdam 算法^[19],共训练 1000 批次,每批次 32 个样本,学习率为 0.0001. 卷积层与全连接层中包含的实数域激活函数为 ReLU. 输出层包含的实数域激活函数为 sigmoid. 训练曲线分别如图 7 所示. 在相同条件下, Mix-CV-CNN 的收敛速度快于 RI-CV-CNN 与 RV-CNN,体现了 Mix-CV-CNN 的优越性.

4.4 识别结果

4.4.1 仿真数据识别结果

仿真识别结果如表 1 所示. Mix-CV-CNN 识别混淆矩阵如表 2 所示. 由表 1、表 2 可得, RV-CNN 中仅有三类目标的准确率超过 85%,其中罗津级的准确率仅有 75.67%. 采用复数域深度学习网络可以有效提高存在三维转动分量的目标识别能力, RI-CV-CNN 中各类目标准确率均超过了 90%. VGG16^[20]和 ResNet18^[21]均有两类目标的准确率低于 90%. Mix-CV-CNN 对目标识别的准确率均超过了 RV-CNN 和 RI-CV-CNN,尤其是第五类目标的准确率比 RV-CNN 高出 21.65%. Mix-CV-CNN 的平均准确率达到最高的 97.46%,体现了 Mix-CV-CNN 相对于 RI-CV-CNN、RV-CNN 及其他经典骨干网络的性能优势.

算法运算效率方面,在 Intel(R) i7-6700 CPU 与 GeForce RTX 1080 显卡的环境中,训练 1000 批次,每批次训练 32 个样本. 运算效率统计如表 3 所示.

由表 3 可得, Mix-CV-CNN 耗时是 RV-CNN 的 3 倍,而与 RI-CV-CNN 差异较小, Mix-CV-CNN 在全连接层和输出层使用实虚型激活函数,有利于并行化计算. 相比

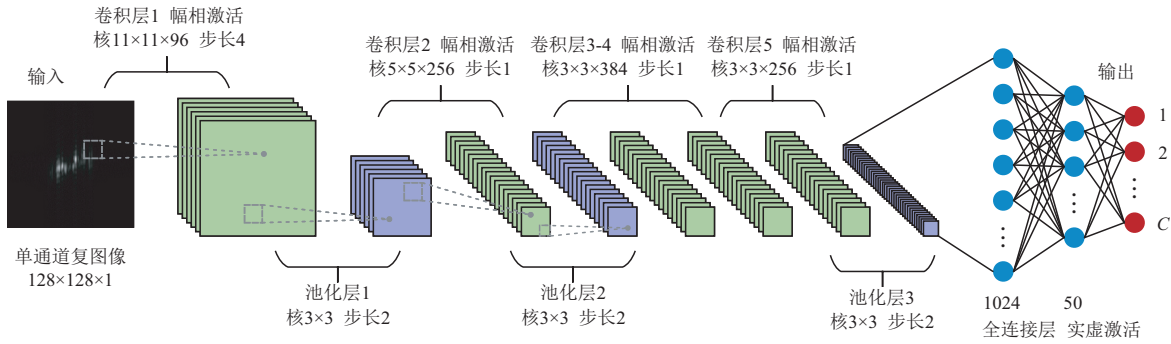


图6 Mix-CV-CNN网络架构




图7 损失函数收敛曲线

表1 仿真数据识别测试结果(%)

类别	Mix-CV-CNN	RI-CV-CNN	RV-CNN	VGG16	ResNet18
阿利伯克级	99.36	96.21	95.31	99.92	99.14
黑天鹅级	97.76	92.49	80.76	95.52	88.36
不来梅级	96.43	91.33	80.35	88.61	78.12
日向级	96.54	95.29	93.90	94.51	96.74
罗津级	97.32	94.24	75.67	85.49	96.42
平均准确率	97.46	93.91	85.45	92.81	91.76

表2 Mix-CV-CNN仿真数据识别混淆矩阵(%)

	1	2	3	4	5
1	99.36	0	0	0.64	0
2	0	97.76	0.22	0	2.01
3	0	0	96.43	0	3.57
4	0.41	0	3.05	96.54	0
5	1.56	0.67	0.45	0	97.32

于实数运算,复数运算更为复杂,使得Mix-CV-CNN训练速度较慢。ResNet18的参数量为11.51 M,原生VGG16的参数量约为138 M,本实验将VGG16全连接层的神经元个数设置为1024,VGG16的参数量下降为24.15 M。相较于经典骨干网络VGG16和ResNet18,本文所提的Mix-CV-CNN在参数量及运算效率上是具有明显优势的。

表3 运算效率统计

算法	总耗时(s)	每批次耗时(s)	参数量(M)
Mix-CV-CNN	62	0.06	9.65
RI-CV-CNN	59	0.06	9.65
RV-CNN	21	0.02	4.83
VGG16	141	0.14	24.15
ResNet18	139	0.14	11.51

4.4.2 实测数据识别结果

实测数据集包含货船、油船、其他船等,每一类别所包含的实测目标样本情况较为复杂多样。实测数据识别结果如表4所示。Mix-CV-CNN识别混淆矩阵如表5所示。

由表4、表5可得,VGG16中仅有一类目标的准确率超过了90%。RV-CNN中仅有一类目标的准确率超过了95%,且油船的准确率低于85%。RI-CV-CNN与

表4 实测数据识别测试结果(%)

类别	Mix-CV-CNN	RI-CV-CNN	RV-CNN	VGG16	ResNet18
货船	97.14	93.56	94.29	93.54	91.93
油船	98.08	94.17	84.62	89.36	97.87
其他船	93.10	95.44	96.55	86.27	94.11
平均准确率	96.09	94.39	92.24	89.72	94.63

ResNet18 中三类目标准确率均超过了 90%。Mix-CV-CNN 中货船、油船两类目标的准确率超过了 95%，仅其他船一类目标的准确率低于 95%，但也达到了 93.10%，平均准确率达到了最高的 96.09%，体现了 Mix-CV-CNN 在卷积层使用幅相型激活函数并利于网络对 SAR 舰船目标复杂运动信息进行感知处理的优势。

表 5 Mix-CV-CNN 实测数据识别测试结果 (%)

	货船	油船	其他船
货船	97.14	0	2.86
油船	1.92	98.08	0
其他船	0	6.90	93.10

5 结论

本文针对 SAR 三维转动目标的复数域信息特征，将复数域卷积神经网络应用于 SAR 舰船目标识别。在设计网络构架时考虑目标相位信息的深度挖掘，结合现有幅相型与实虚型复数域卷积神经网络的优点，提出了混合型复数域卷积神经网络，并推导了前向传播与反向传播模型，给出算法实现流程。实验验证了 Mix-CV-CNN 可在未进行目标重聚焦的情况下，较好地实现三维转动舰船目标的识别。相较于 RV-CNN、RI-CV-CNN 及其他经典骨干网络 VGG16 和 ResNet18，所提 Mix-CV-CNN 可显著提高识别精度。

参考文献

- [1] ZHAO Y, ZHANG M, ZHAO Y, GENG X. A bistatic SAR image intensity model for the composite ship-ocean scene[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(8): 4250-4258.
- [2] LIU P, JIN Y. A study of ship rotation effects on SAR image[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(6): 3132-3144.
- [3] NEWAY M, BENITZ G R, BARRETT D J, et al. Detection and imaging of moving targets with LiMIT SAR data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(6): 3499-3510.
- [4] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Advances in neural information processing systems, 2012, 25: 1097-1105.
- [5] 张晓玲, 张天文, 师君, 等. 基于深度分离卷积神经网络的高速高精度 SAR 舰船检测[J]. 雷达学报, 2019, 8(6): 841-851.
ZHANG Xiao-ling, ZHANG Tian-wen, SHI Jun, et al. High-speed and High-accurate SAR ship detection based on a depthwise separable convolution neural network[J]. Journal of Radars, 2019, 8(6): 841-851. (in Chinese)
- [6] 杨龙, 苏娟, 李响. 基于深度卷积神经网络的 SAR 舰船目标检测[J]. 系统工程与电子技术, 2019, 41(09): 1990-1997.
YANG Long, SU Juan, LI Xiang. Ship detection in SAR images based on deep convolutional neural network[J]. Systems Engineering and Electronics, 2019, 41(09): 1990-1997. (in Chinese)
- [7] 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(01): 34-54.
DU Lan, WANG Zhao-cheng, WANG Yan, et al. Survey of research progress on target detection and discrimination of single-channel SAR images for complex scenes[J]. Journal of Radars, 2020, 9(01): 34-54. (in Chinese)
- [8] ZHANG Z, WANG H, XU F, et al. Complex-valued convolutional neural network and its application in polarimetric SAR image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(12): 7177-7188.
- [9] YU L, HU Y, XIE X, et al. Complex-valued full convolutional neural network for SAR target classification[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(10): 1752-1756.
- [10] TAN X, LI M, ZHANG P, et al. Complex-valued 3-D convolutional neural network for PolSAR image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(6): 1022-1026.
- [11] SUNAGA Y, NATSUAKI R, HIROSE A. Land form classification and similar land-shape discovery by using complex-valued convolutional neural networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(10): 7907-7917.
- [12] GAO J, DENG B, QIN Y, et al. Enhanced radar imaging using a complex-valued convolutional neural network[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(1): 35-39.
- [13] 蔡彦宁, 种劲松. 舰船目标三维转动 SAR 成像仿真研究[J]. 计算机仿真, 2011, 28(03): 287-291, 364.
CAI Yan-ning, ZHONG Jin-song. SAR imaging simulation for three-dimensional rotations of ship targets[J]. Computer Simulation, 2011, 28(03): 287-291, 364. (in Chinese)
- [14] KUROE Y, YOSHIDA M, MORI T. On activation functions for complex-valued neural networks-existence of energy functions[C]//Artificial Neural Networks and Neural Information Processing. Heidelberg, Berlin: Springer, 2003: 985-992.

- [15] HIROSE A. Complex-valued neural networks: theories and applications[M]. Singapore: World Scientific, 2003.
- [16] ILIEV A, KYURKCHIEV N, MARKOV S. On the approximation of the step function by some sigmoid functions[J]. Mathematics and Computers in Simulation, 2017, 133:223-234.
- [17] NAIR V, HINTON G E. Rectified linear units improve restricted Boltzmann machines[C]//27th International Conference on Machine Learning. Haifa, Israel: ICML, 2010: 1-8.
- [18] 项鹏, 郭炜炜, 张增辉, 等. 面向 SAR 解译的 OpenSAR 数据开放共享平台[J]. 信息技术, 2016, (09): 1-4,9. XIANG Peng, GUO Wei-wei, LI Zeng-hui, et al. An open platform of SAR database for SAR image interpretation[J]. Information Technology, 2016, (09): 1-4, 9. (in Chinese)
- [19] ZHANG Y, HUA Q, XU D, et al. A complex-valued convolutional neural network with different activation functions in polarimetric SAR image classification[C]// 2019 International Radar Conference. Toulon, France: IEEE, 2019: 1-4.
- [20] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. [2014]. <https://arxiv.org/abs/1409.1556>.
- [21] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, America: IEEE, 2016: 770-778.



姜义成(通讯作者) 男, 1964年11月出生, 出生于黑龙江省哈尔滨市. 现为哈尔滨工业大学教授、博士生导师. 主要研究方向为雷达信号处理.

E-mail: jiangyc@hit.edu.cn



徐丹 女, 1996年4月出生, 出生于黑龙江省七台河市. 主要研究方向为数据分析与智能图像处理.

E-mail: xudanhit@hit.edu.cn

作者简介



张云 女, 1975年11月出生, 出生于黑龙江省虎林市. 现为哈尔滨工业大学教授、博士生导师. 主要研究方向为雷达信号处理、SAR成像、机器学习和遥感模式分析.

E-mail: zhangyunhit@hit.edu.cn



化青龙 男, 1995年2月出生, 出生于安徽省阜阳市. 现为哈尔滨工业大学博士. 主要研究方向为雷达图像处理 and 深度学习网络框架.

E-mail: huaqinglong_hit@163.com