

## 基于FCNN和ICAE的SAR图像目标识别方法

喻玲娟<sup>\*①②</sup> 王亚东<sup>①</sup> 谢晓春<sup>③</sup> 林 贇<sup>②</sup> 洪 文<sup>②</sup>

<sup>①</sup>(江西理工大学信息工程学院 赣州 341000)

<sup>②</sup>(中国科学院电子学研究所 北京 100190)

<sup>③</sup>(赣南师范大学物理与电子信息学院 赣州 341000)

**摘 要:** 近年来, 基于卷积神经网络(Convolutional Neural Network, CNN)的合成孔径雷达(Synthetic Aperture Radar, SAR)图像目标识别得到深入研究。全卷积神经网络(Fully Convolutional Neural Network, FCNN)是CNN结构上的改进, 它比CNN能获得更高的识别率, 但在训练过程中仍需要大量的带标签训练样本。该文提出一种基于FCNN和改进的卷积自编码器(Improved Convolutional Auto-Encoder, ICAE)的SAR图像目标识别方法, 即先用ICAE无监督训练方式获得的编码器网络参数初始化FCNN的部分参数, 后用带标签训练样本对FCNN进行训练。基于MSTAR数据集的十类目标分类实验结果表明, 在不扩充带标签训练样本的情况下, 该方法不仅能获得98.14%的平均正确识别率, 而且具有较强的抗噪声能力。

**关键词:** 合成孔径雷达; 自动目标识别; 全卷积神经网络; 卷积自编码器; 改进的卷积自编码器

**中图分类号:** TN957.5

**文献标识码:** A

**文章编号:** 2095-283X(2018)05-0622-10

**DOI:** 10.12000/JR18066

**引用格式:** 喻玲娟, 王亚东, 谢晓春, 等. 基于FCNN和ICAE的SAR图像目标识别方法[J]. 雷达学报, 2018, 7(5): 622–631. DOI: 10.12000/JR18066.

**Reference format:** Yu Lingjuan, Wang Yadong, Xie Xiaochun, *et al.* SAR ATR based on FCNN and ICAE[J]. *Journal of Radars*, 2018, 7(5): 622–631. DOI: 10.12000/JR18066.

## SAR ATR Based on FCNN and ICAE

Yu Lingjuan<sup>\*①②</sup> Wang Yadong<sup>①</sup> Xie Xiaochun<sup>③</sup> Lin Yun<sup>②</sup> Hong Wen<sup>②</sup>

<sup>①</sup>(School of Information Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China)

<sup>②</sup>(Institute of Electronics, Chinese Academy of Sciences, Beijing 100190, China)

<sup>③</sup>(School of Physics and Electronic Information, Gannan Normal University, Ganzhou 341000, China)

**Abstract:** In recent years, Synthetic Aperture Radar (SAR) image target recognition based on the Convolutional Neural Network (CNN) has attracted a significant amount of attention. Fully CNN (FCNN) is a structural improvement of the CNN, which features a higher recognition rate than CNN, but it still requires a large number of labeled data in the training process. This study aims to propose a method of SAR image target recognition based on FCNN and Improved Convolutional Auto-Encoder (ICAE), where several parameters of FCNN are initialized by the parameters of the ICAE encoder. These parameters are obtained in the unsupervised training mode. Then, the FCNN is trained by the labeled training samples. The experimental results on 10 kinds of target classification based on the MSTAR datasets show that this method cannot only achieve an average of 98.14% correct recognition rate but also feature a strong anti-noise capability when the labeled training samples are unexpanded.

收稿日期: 2018-08-31; 改回日期: 2018-10-20; 网络出版: 2018-10-31

\*通信作者: 喻玲娟 lingjuanyusmile@163.com

基金项目: 国家自然科学基金(61431018, 61501210, 61571421), 江西省自然科学基金(20161BAB202054), 江西省教育厅科技项目(GJJ150684, GJJ170825)

Foundation Items: The National Natural Science Foundation of China (61431018, 61501210, 61571421), The Natural Science Foundation of Jiangxi Province (20161BAB202054), The Science and Technology Project of Jiangxi Provincial Education Department (GJJ150684, GJJ170825)

**Key words:** Synthetic Aperture Radar (SAR); Automatic target recognition; Fully Convolutional Neural Network (FCNN); Convolutional Auto-Encoder (CAE); Improved Convolutional Auto-Encoder (ICAE)

## 1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)自动目标识别(Automatic Target Recognition, ATR)在军事和民用领域中具有十分重要的意义。近年来,基于卷积神经网络(Convolutional Neural Network, CNN)的SAR-ATR方法已得到深入研究,并取得了较好的识别结果<sup>[1-5]</sup>。与传统的SAR-ATR方法相同, MSTAR是验证方法有效性的常用数据集之一。文献<sup>[6-8]</sup>直接利用CNN实现该数据集的SAR目标识别。Chen等人在CNN结构基础上,利用卷积层替代全连接层,并通过扩充带标签的训练样本,获得了高达99%的识别率<sup>[2]</sup>。Wagner提出了一种利用CNN提取SAR图像特征和SVM目标分类相结合的方法<sup>[9]</sup>,并通过仿射变换和弹性畸变扩充训练样本,进一步提高了算法的鲁棒性<sup>[1]</sup>。Furukawa等人分析了训练样本扩充后, CNN具有更好的平移不变性,并采用18层Resnet模型获得了高达99.6%的识别率<sup>[4]</sup>。Pei等人利用多视方法扩充SAR图像,并构建一种多视深度学习框架,以提高目标的识别率<sup>[10]</sup>。由此可见,扩充带标签的训练样本,能够获得比扩充前更高的识别率。

为了在不扩充带标签训练样本的情况下获得较高的识别率,文献<sup>[11-14]</sup>提出了一些基于CNN的改进方法。其中,自编码器(Auto-Encoder, AE)和CNN相结合的方法较为简单、有效。Chen等人提出先用无监督稀疏AE训练卷积核,再用带标签的训练样本经过卷积和池化后得到一系列特征图,最后用这些特征图训练Softmax分类器。该方法获得三分类目标和十分类目标的识别率分别为90.1%和84.7%<sup>[12]</sup>。Housseini等人提出一种结合CNN和卷积自编码器(Convolutional Auto-Encoder, CAE)的方法,该方法能够用比CNN更少的卷积层和每层更少的卷积核,获得与CNN相接近的识别率,从而在保证识别率的同时,有效减少运算时间<sup>[13]</sup>。

本文在CNN和CAE相结合的基础上,提出一种基于全卷积神经网络(Fully Convolutional Neural Network, FCNN)和改进的卷积自编码器(Improved Convolutional Auto-Encoder, ICAE)的识别方法。其中, FCNN是CNN结构上的改进<sup>[15]</sup>, ICAE是按照FCNN结构对CAE的编码器改进得到。由于FCNN能够获得比CNN更高的识别率,而ICA E是一种无监督训练方式,且具有一定的抗噪声能力,因此,该方法不仅能在带标签训练样本不

扩充的情况下获得较高的识别率,而且具有较强的抗噪声能力。MSTAR实验结果验证了该方法的有效性。

## 2 FCNN和CAE的基本理论

### 2.1 FCNN

传统的CNN由一系列交替的卷积层和池化层,再加上若干全连接层构成。FCNN与CNN相比,结构的改进之处包括:①步长为 $s$ ( $s$ 为大于1的正整数)的卷积层替代池化层,能够避免池化运算带来的信息损失;②卷积层替代全连接层,不仅能减少网络参数的运算量,而且能够防止过拟合。因此,FCNN的结构主要包括卷积层和步长为 $s$ 的卷积层。

#### (1) 卷积层

假定 $l$ 表示第 $l$ 层,  $A$ 表示输出特征图,  $H$ 和 $W$ 分别表示特征图的高和宽,  $N$ 表示输出特征图的通道总数,  $K$ 表示卷积核,  $K_1 \times K_2$ 表示卷积核尺寸,则 $H^l$ 和 $W^l$ 分别表示第 $l$ 层输出特征图的高和宽,  $N^l$ 表示第 $l$ 层输出特征图的总通道数,  $K_1^l \times K_2^l$ 表示第 $l$ 层卷积核尺寸,  $A_n^l(x, y)$  ( $n = 0, 1, 2, \dots, N^l - 1; x = 0, 1, \dots, H^l - 1; y = 0, 1, \dots, W^l - 1$ )表示第 $l$ 层中第 $n$ 通道输出特征图在像素单元 $(x, y)$ 处的值,  $K_{n'n'}^l(i, j)$  ( $n' = 0, 1, 2, \dots, N^{l-1} - 1; i = 0, 1, \dots, K_1^l - 1; j = 0, 1, \dots, K_2^l - 1$ )表示第 $l$ 层中连接第 $n'$ 通道输入和第 $n$ 通道输出的卷积核在 $(i, j)$ 处的值。

第 $l$ 层卷积输出特征图可由该层的输入特征图(即第 $l-1$ 层的输出特征图)与卷积核计算如下:

$$A_n^l(x, y) = f \left( \sum_{n'=0}^{N^{l-1}-1} \sum_{i=0}^{K_1^l-1} \sum_{j=0}^{K_2^l-1} K_{n'n'}^l(i, j) \cdot A_{n'}^{l-1}(x+i, y+j) + b_n^l \right) \quad (1)$$

其中,  $b_n^l$ 表示第 $l$ 层中第 $n$ 通道的偏置,  $f(\cdot)$ 表示激活函数。

输出特征图的高 $H^l$ 和宽 $W^l$ 计算如下:

$$H^l = H^{l-1} - K_1^l + 2p + 1 \quad (2)$$

$$W^l = W^{l-1} - K_2^l + 2p + 1 \quad (3)$$

其中,  $p$ 为卷积前对输入特征图补零的长度。

#### (2) 步长为 $s$ 的卷积层

考虑上述第 $l$ 层卷积之后的步长为 $s$ 的卷积层,输入为第 $l$ 层的卷积输出 $A^l$ ,与第 $l$ 层卷积相类似,其卷积输出 $A_n^{l+1}$ 为:

$$A_n^{l+1}(x, y) = f \left( \sum_{n'=0}^{N^{l+1}-1} \sum_{i=0}^{K_1^{l+1}-1} \sum_{j=0}^{K_2^{l+1}-1} K_{nn'}^{l+1}(i, j) \cdot A_{n'}^l(xs + i, ys + j) + b_n^{l+1} \right) \quad (4)$$

其输出特征图的高 $H^{l+1}$ 和宽 $W^{l+1}$ 计算如下:

$$H^{l+1} = \left\lfloor \frac{H^l - K_1^{l+1} + 2p}{s} \right\rfloor + 1 \quad (5)$$

$$W^{l+1} = \left\lfloor \frac{W^l - K_2^{l+1} + 2p}{s} \right\rfloor + 1 \quad (6)$$

其中,  $\lfloor \cdot \rfloor$ 表示向下取整。

## 2.2 CAE

传统的AE包括编码器和解码器两部分<sup>[16-18]</sup>, 编码器从输入信号中提取特征, 解码器则利用提取的特征重构原信号。在重构信号逐渐逼近输入信号的过程中, 实现编码和解码网络参数的训练, 因此, AE是一种无监督训练方式。由于AE的编码和解码网络都采用全连接方式, 若加深AE的深度, 将导致网络参数量多、容易过拟合等问题。CAE是一种利用CNN改进AE的网络<sup>[19]</sup>, 仍然包括编码器和解码器两部分。其中, 编码器由卷积层和池化层构成, 解码器则由反池化层和反卷积层构成, 该结构更适用于图像的编码和重构。又由于AE具有一定的抗噪声能力<sup>[20]</sup>, 因此, CAE编码器可用于带噪声的图像目标特征提取。

考虑一个简单的CAE, 编码器只包含1个卷积层和1个池化层, 解码器包含1个反池化层和1个反卷积层, 如图1所示。输入图像 $X$ 经过编码器后得到特征图 $Y$ , 再经过解码器后得到重构图像 $\tilde{X}$ 。在使 $\tilde{X}$ 与 $X$ 的误差最小的过程中, 利用误差的后向传播<sup>[21]</sup>完成CAE的参数训练。编码和解码的详细过程如下:

### (1) 编码

假设输入图像的高和宽分别为 $H$ 和 $W$ , 卷积核为 $K$ , 其大小为 $K_1 \times K_2$ , 则经过编码得到的特征图 $Y$ 为:

$$Y = \text{Pooling}(f(KX + B)) \quad (7)$$

其中,  $f(\cdot)$ 表示激活函数,  $\text{Pooling}(\cdot)$ 表示池化,  $B$ 表示偏置。

编码器中卷积后, 特征图的高和宽分别按照式(2)和式(3)计算。

### (2) 解码

假设反卷积核为 $\hat{K}$ , 其大小为 $K'_1 \times K'_2$ , 则解码重构图像 $\tilde{X}$ 为:

$$\tilde{X} = f(\hat{K} \times \text{Unpooling}(Y) + C) \quad (8)$$

其中,  $\text{Unpooling}(\cdot)$ 表示反池化,  $C$ 表示偏置。

解码器中反卷积通常用卷积的转置来实现, 反卷积后特征图的高和宽仍然分别按照式(2)和式(3)计算。

## 3 基于FCNN和ICAIE的SAR图像目标识别方法

本文针对MSTAR数据集, 按照FCNN结构改进CAE, 提出一种基于FCNN和ICAIE的SAR图像目标识别方法, 其结构及流程如图2所示。

算法实现的具体步骤如下:

(1) 定义FCNN结构包括4个交替的卷积层和步长 $s$ 为2的卷积层, 以及1个卷积层和Softmax分类器。

(2) 按照FCNN结构设计ICAIE的编码器结构, 即用步长为2的卷积层替代CAE编码器的池化层。因此, ICAIE的编码器包括4个交替的卷积层和步长 $s$ 为2的卷积层, ICAIE的解码器包括4个交替的反池化层和反卷积层。

(3) 将MSTAR的训练样本作为ICAIE的输入图像, 经过编码器得到提取的特征图像, 再经过解码

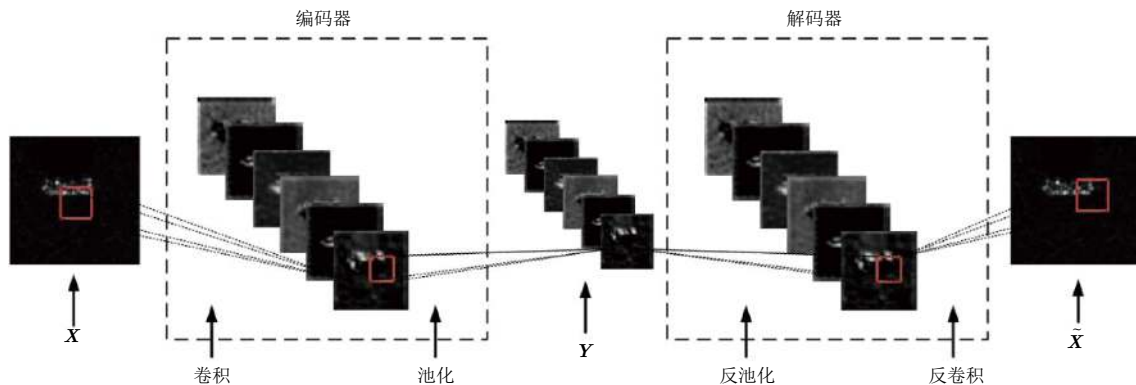


图 1 CAE结构示意图

Fig. 1 The structure of CAE




图2 基于FCNN和ICAE的识别方法

Fig. 2 The recognition method based on FCNN and ICAE

器重构图像。在使重构图像与输入图像的误差最小的过程中，利用误差的后向传播完成ICAE的参数训练。

(4) 将训练好的ICAE编码器参数初始化FCNN中相应层的参数。

(5) 将MSTAR的带标签训练样本输入FCNN，在使目标输出类别与标签一致的过程中，利用误差的后向传播完成FCNN参数训练。

(6) 将MSTAR测试样本输入已训练好的FCNN网络，完成分类输出。

有关FCNN和ICAE的结构及前向传播流程进一步介绍如下。

### 3.1 FCNN

图2中已定义FCNN包括4个交替的卷积层和步长为2的卷积层、1个卷积层和Softmax分类器，图3进一步给出包含每层卷积核通道数和卷积核尺寸的结构及前向传播流程。前4个交替的卷积层和步长为2的卷积层所采用的卷积核尺寸均为 $3 \times 3$ ，通道数分别为16, 32, 64, 128，每层卷积之后都需要经过Selu非线性激活函数<sup>[22]</sup>，以避免训练过程中产生梯度爆炸或者梯度消失问题。最后一个卷积层的尺寸为 $4 \times 4$ ，通道数为10，卷积之后经过Softmax分类器分类。此外，前两个卷积层和步长为2的卷积层在卷积前需要对输入的图像或特征图补零，后两个步长为2的卷积层在卷积前需要对特征图补零，而后3个卷积层在卷积前无需补零。

FCNN识别SAR图像的具体过程如下：

(1) 输入1幅 $88 \times 88$ 的SAR图像，卷积前对图像周围补零，经过16个卷积核的卷积后，根据式(2)和式(3) (式中 $p = 1$ )可知，输出为16幅 $88 \times 88$ 的特征图。

(2) 16幅 $88 \times 88$ 的特征图卷积前周围先补零，经过16个步长为2的卷积核的卷积后，根据式(5)和式(6) (式中 $p = 1$ )可知，输出为16幅 $44 \times 44$ 的特征图。

(3) 与步骤(1)类似，16幅 $44 \times 44$ 的特征图卷积前先补零，经过32个卷积核的卷积后，输出为32幅 $44 \times 44$ 的特征图。

(4) 与步骤(2)类似，32幅 $44 \times 44$ 的特征图卷积前先补零，经过32个步长为2的卷积核的卷积后，输出为32幅 $22 \times 22$ 的特征图。

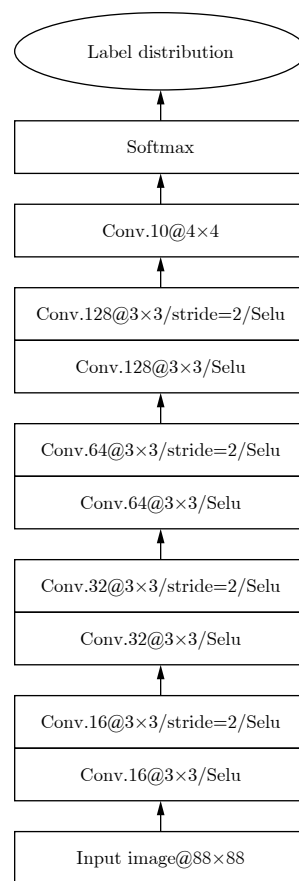


图3 FCNN的结构和前向传播

Fig. 3 The structure and forward propagation of FCNN

(5)  $32$ 幅 $22 \times 22$ 的特征图卷积前无需补零，经过64个卷积核的卷积后，根据式(2)和式(3) (式中 $p = 0$ )可知，输出为128幅 $20 \times 20$ 的特征图。

(6) 64幅 $20 \times 20$ 的特征图卷积前先补零，经过64个步长为2的卷积核的卷积后，根据式(5)和式(6) (式中 $p = 1$ )可知，输出为64幅 $10 \times 10$ 的特征图。

(7) 与步骤(5)类似，64幅 $10 \times 10$ 的特征图卷积前无需补零，经过128个卷积核的卷积后，输出为128幅 $8 \times 8$ 的特征图。

(8) 与步骤(6)类似，128幅 $8 \times 8$ 的特征图卷积前先补零，经过128个步长为2的卷积核的卷积后，输出为128幅 $4 \times 4$ 的特征图。

(9) 128幅 $4 \times 4$ 的特征图卷积前无需补零, 经过10个 $4 \times 4$ 卷积核的卷积后, 根据式(2)和式(3) (式中 $p = 0$ )可知, 输出为10个数值。

(10) 将10个数值输入Softmax分类器得到目标的所属类别。

为了使目标输出的所属类别与标签一致, 需要不断调整各层卷积核权重和偏置参数, 从而完成FCNN的网络参数训练。

### 3.2 ICAE

图2中, ICAE的编码器结构与FCNN前4个交替的卷积层和步长 $s$ 为2的卷积层相同, 因此, 其各层的卷积通道数和尺寸, 以及输入输出图像尺寸, 也与FCNN对应层相同。图4是包含了各层输入输出图像尺寸的ICAE结构和前向传播流程, 显然, 编码器部分的输入输出图像尺寸, 与第3.1节中FCNN对应层的计算结果相一致。

ICAE的解码器包括4个交替的反池化层和反卷积层, 其中, 前两个反卷积层在反卷积前需对特征图的周围补两个零, 而后两个反卷积层在反卷积前需补一个零。其具体过程如下:

(1) 编码输出的128幅 $4 \times 4$ 的特征图作为解码器的输入, 经过反池化后, 输出为128幅 $8 \times 8$ 的特征图。

(2) 128幅 $8 \times 8$ 的特征图在反卷积前补零, 经过64个 $3 \times 3$ 反卷积核的反卷积后, 根据式(2)和式(3) (式中 $p = 2$ )可知, 输出为64幅 $10 \times 10$ 的特征图。

(3) 与步骤(1)类似, 64幅 $10 \times 10$ 的特征图, 经过反池化后, 输出为64幅 $20 \times 20$ 的特征图。

(4) 与步骤(2)类似, 64幅 $20 \times 20$ 的特征图在反卷积前补零, 经过32个 $3 \times 3$ 反卷积核的反卷积后, 输出为32幅 $22 \times 22$ 的特征图。

(5) 与步骤(1)类似, 32幅 $22 \times 22$ 的特征图, 经过反池化后, 输出为32幅 $44 \times 44$ 的特征图。

(6) 32幅 $44 \times 44$ 的特征图在反卷积前补零, 经过16个 $3 \times 3$ 反卷积核的反卷积后, 根据式(2)和式(3) (式中 $p = 1$ )可知, 输出为16幅 $44 \times 44$ 的特征图。

(7) 与步骤(1)类似, 16幅 $44 \times 44$ 的特征图, 经过反池化后, 输出为16幅 $88 \times 88$ 的特征图。

(8) 与步骤(6)类似, 16幅 $88 \times 88$ 的特征图在反卷积前补零, 经过1个 $3 \times 3$ 反卷积核的反卷积后, 最终输出为1幅 $88 \times 88$ 的图像。

为了使重构图像尽可能逼近输入图像, 需要不断调整编码器和解码器各层卷积核权重和偏置参数, 从而无监督地完成ICAE的网络参数训练。

## 4 实验结果及分析

本文采用MSTAR数据集进行十分类实验, 10类目标的光学图像及其SAR图像如图5所示。将下视角为 $17^\circ$ 的图像作为训练集, 下视角为 $15^\circ$ 的图像作为测试集。训练集和测试集包含的各类目标的型号、数量如表1所示, 共有2747个训练样本, 2425个测试样本。实验前先将所有目标的SAR图像截取其中心 $88 \times 88$ 大小的区域, 以作为训练和测试的原始输入图像。此外, 将所有样本进行标准化预处理, 即减去均值、除以标准差。

由于ICAE是CAE结构的改进, 因此, ICAE也具有一定的抗噪声能力。实验分别考虑不加噪声和加噪声两种情况。其中, 不加噪声情况, 进一步考虑数据集不扩充和扩充实验; 加噪声情况, 又进一步考虑加不同比例和不同功率的噪声实验。为验证本文所提方法的有效性, 采用基于CNN和CAE的方法、基于FCNN的方法, 以及基于CNN的方法进行对比。这3种方法所采用的FCNN, CNN和CAE的结构如表2所示。

网络训练前, 卷积核权重初始化方面, 基于FCNN和ICAE的方法中, 用训练好的ICAE编码器参数初始化FCNN对应层的参数; 基于CNN和CAE的方法中, 用训练好的CAE编码器参数初始化CNN对应层的参数; 4种方法中其余的卷积核权重均采用均值为0, 标准差为 $\sqrt{1/n}$  ( $n$ 为每一层输入的数量)的正态分布初始化。网络训练时, 4种方法的批处理块大小(batchsize)均为128, 并采用Adam算法<sup>[23]</sup>进行网络参数的更新, 初始学习率为0.01, 每当20次迭代内的损失函数不再降低, 学习率乘以0.1, 直到损失函数完全收敛。




图 4 ICAE的结构和前向传播

Fig. 4 The structure and forward propagation of ICAE




图 5 10类地面军事目标光学图像及其SAR图像

Fig. 5 Ten types of ground military targets: Optical images versus SAR images

表 1 训练样本和测试样本数量

Tab. 1 The number of training and testing images

型号	训练集		测试集	
	角度	数量	角度	数量
BMP-2	17°	233	15°	195
BTR-70	17°	233	15°	196
BTR-60	17°	256	15°	195
BRDM-2	17°	298	15°	274
T-72	17°	232	15°	196
T-62	17°	299	15°	273
2S1	17°	299	15°	274
D7	17°	299	15°	274
ZIL-131	17°	299	15°	274
ZSU-234	17°	299	15°	274

#### 4.1 不加噪声实验

**4.1.1 数据集不扩充** 数据集不扩充时，包括2747个训练样本和2425个测试样本。按照第3节阐述的实现步骤，采用基于FCNN和ICAIE的方法进行10类目标识别，得到的混淆矩阵如表3所示。进一步地，其余3种方法得到的各类目标的正确识别率和平均正确识别率如表4所示。实验结果表明，在

训练样本没有扩充的情况下，基于FCNN和ICAIE的方法的平均正确识别率能够达到98.14%，比基于CAE和CNN的方法提高了1.03%，比基于FCNN的方法提高了1.56%，比基于CNN的方法提高了2.43%。

**4.1.2 数据集扩充** 采用随机采样方式<sup>[2]</sup>对带标签的训练样本进行数量扩充，即实验采用的训练样本数为2747乘以扩充倍数。图6为4种方法的平均正确识别率随其扩充倍数的变化情况。实验结果表明，基于FCNN和ICAIE的方法在训练集不扩充时，平均正确识别率为98.14%；基于CNN和CAE的方法在训练集扩充7倍后，平均正确识别率为98.08%；基于FCNN的方法在训练集扩充8倍后，平均正确识别率为98.1%；而基于CNN的方法在训练集扩充10倍后，平均正确识别率只有97.43%。因此，基于FCNN和ICAIE的方法能够在训练集不扩充的情况下获得较高的识别率。

#### 4.2 加噪声实验

**4.2.1 加不同比例的噪声** 数据集不扩充时，在测试样本中加入噪声，具体方法为将服从均匀分布的噪声随机取代测试样本的像素单元<sup>[24]</sup>。图7为添加不同比例噪声的SAR图像，图7(a)–图7(e)的噪声比例分别为1%、5%、10%、15%、20%。图8为4种方法的平均正确识别率随噪声比例变化的情况。实验结

表 2 FCNN, ICAE, CNN和CAE的网络结构

Tab. 2 The network structures of FCNN, ICAE, CNN and CAE

FCNN	ICAE	CNN	CAE
Conv.16@3×3	Conv.16@3×3	Conv.16@3×3	Conv.16@3×3
Conv.16@3×3/stride=2	Conv.16@3×3/stride=2	Maxpooling@2×2	Maxpooling@2×2
Conv.32@3×3	Conv.32@3×3	Conv.32@3×3	Conv.32@3×3
Conv.32@3×3/stride=2	Conv.32@3×3/stride=2	Maxpooling@2×2	Maxpooling@2×2
Conv.64@3×3	Conv.64@3×3	Conv.64@3×3	Conv.64@3×3
Conv.64@3×3/stride=2	Conv.64@3×3/stride=2	Maxpooling@2×2	Maxpooling@2×2
Conv.128@3×3	Conv.128@3×3	Conv.128@3×3	Conv.128@3×3
Conv.128@3×3/stride=2	Conv.128@3×3/stride=2	Maxpooling@2×2	Maxpooling@2×2
Conv.10@4×4	Unpooling@2×2	Conv.10@4×4	Unpooling@2×2
Softmax	Deconv.64@3×3	Softmax	Deconv.64@3×3
	Unpooling@2×2		Unpooling@2×2
	Deconv.32@3×3		Deconv.32@3×3
	Unpooling@2×2		Unpooling@2×2
	Deconv.16@3×3		Deconv.16@3×3
	Deconv.1@3×3		Deconv.1@3×3

表 3 基于FCNN和ICAE的识别结果

Tab. 3 The recognition results based on FCNN and ICAE

目标型号	识别结果										正确识别率 (%)
	2S1	BMP-2	BRDM-2	BTR-60	BTR-70	D7	T-62	T-72	ZIL-131	ZSU-234	
2S1	265	0	1	0	2	0	0	6	0	0	96.72
BMP-2	1	191	0	0	1	1	0	1	0	0	98.45
BRDM-2	0	0	270	3	0	0	0	0	1	0	98.54
BTR-60	0	0	2	186	0	0	1	0	2	4	95.38
BTR-70	3	0	0	0	193	0	0	0	0	0	98.47
D7	0	0	2	0	0	272	0	0	0	0	99.27
T-62	0	0	0	0	0	0	270	0	0	3	98.90
T-72	0	1	0	0	1	0	0	194	0	0	98.98
ZIL-131	0	0	0	0	0	1	2	0	270	1	98.54
ZSU-234	0	0	0	0	0	3	1	1	0	269	98.18
平均正确识别率(%)	98.14										

表 4 基于不同方法的实验结果对比

Tab. 4 The comparison of experimental results based on different methods

目标型号	识别率(%)			
	FCNN+ICAE	CNN+CAE	FCNN	CNN
2S1	96.72	95.99	94.16	96.72
BMP-2	97.95	97.44	96.41	94.36
BRDM-2	98.54	95.99	96.35	95.26
BTR-60	95.38	91.79	95.38	96.41
BTR-70	98.47	99.49	98.98	93.88
D7	99.27	96.35	98.54	97.81
T-62	98.90	97.07	90.84	93.41
T-72	98.98	98.98	98.47	97.96
ZIL-131	98.54	98.91	97.81	96.35
ZSU-234	98.18	98.91	99.64	94.89
平均正确识别率(%)	98.14	97.11	96.58	95.71

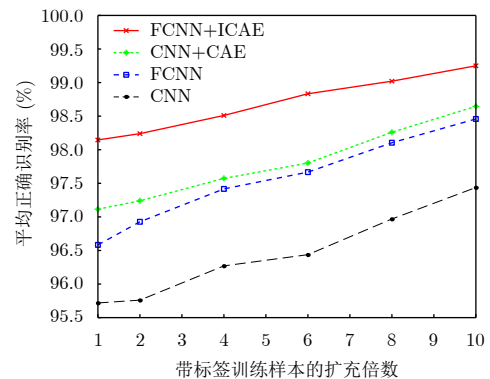


图 6 4种方法的平均正确识别率随带标签的训练样本扩充倍数的变化

Fig. 6 The average correct recognition rate of the four methods varies with the multiples of labeled training samples




图7 加不同比例噪声的SAR图像

Fig. 7 SAR images with noise of different proportions

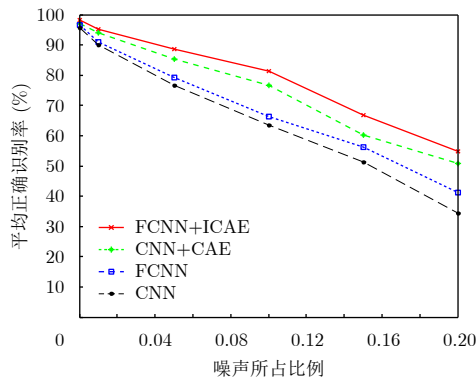


图8 4种方法的平均正确识别率随噪声所占比例的变化

Fig. 8 The average correct recognition rate of the four methods varies with the noise proportion

果表明，随着噪声比例的增加，基于FCNN和ICAE方法的抗噪声能力最强，其次为基于CNN和CAE的方法，再次是基于FCNN的方法，最后为基于CNN的方法。

**4.2.2 加不同功率的噪声** 数据集不扩充时，在测试样本中加入不同功率的高斯白噪声。定义SAR图像功率 $P_S$ 与干扰噪声功率 $P_N$ 的比值为信噪比(Signal-to-Noise Ratio, SNR)，即 $SNR = 10 \lg(P_S/P_N)$ 。显然，由于SAR图像中本身含有噪声，此处的SNR并非真实的SNR。图9为不同SNR的SAR图像，图9(a)–图9(e)的SNR分别为90 dB, 70 dB, 50 dB, 30 dB, 10 dB。图10为4种方法的平均正确




图9 不同信噪比的SAR图像

Fig. 9 SAR images with different SNR

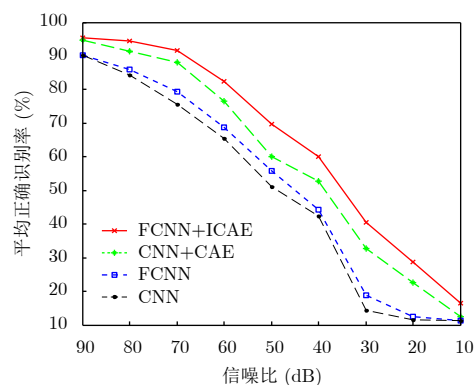


图10 4种方法的平均正确识别率随信噪比的变化

Fig. 10 The average correct recognition rate of the four methods varies with SNR

识别率随SNR变化的情况。实验结果表明，随着SNR的降低，基于FCNN和ICAE方法的抗噪声能力最强，其次为基于CNN和CAE的方法，再次是基于FCNN的方法，最后为基于CNN的方法。

### 5 结论

本文介绍了FCNN和CAE的结构，FCNN包含卷积层和步长为 $s$ 的卷积层，CAE包括由卷积层和池化层构成的编码器，以及由反池化层和反卷积层构成的解码器。针对MSTAR数据，按照FCNN结构对CAE编码器进行改进，提出了一种基于FCNN和ICAE的SAR目标识别方法。该方法先用ICAE无监督训练获得的编码器网络参数初始化FCNN的部



分参数, 后用原始带标签训练样本对FCNN进行训练。实验结果表明, 在带标签训练样本不扩充的情况下, 该方法比基于CAE和CNN、基于FCNN以及基于CNN的方法, 具有更高的识别率和更强的抗噪声能力。

### 参 考 文 献

- [1] 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).
- [2] Chen S Z, Wang H P, Xu F, *et al.* Target classification using the deep convolutional networks for SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 4806–4817. DOI: [10.1109/TGRS.2016.2551720](https://doi.org/10.1109/TGRS.2016.2551720).
- [3] Zhang Z M, Wang H P, 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. DOI: [10.1109/TGRS.2017.2743222](https://doi.org/10.1109/TGRS.2017.2743222).
- [4] Furukawa H. Deep learning for target classification from SAR imagery: Data augmentation and translation invariance[J]. *IEICE Technical Report*, 2017, 117(182): 13–17.
- [5] 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 Haipeng, and Jin Yaqiu. 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).
- [6] Morgan D A E. Deep convolutional neural networks for ATR from SAR imagery[C]. Proceedings of SPIE 9475, Algorithms for Synthetic Aperture Radar Imagery XXII, Baltimore, Maryland, United States, 2015: 94750F.
- [7] Profeta A, Rodriguez A, and Clouse H S. Convolutional neural networks for synthetic aperture radar classification[C]. Proceedings of SPIE 9843, Algorithms for Synthetic Aperture Radar Imagery XXIII, Baltimore, Maryland, United States, 2016: 98430M.
- [8] Wilmanski M, Kreucher C, and Lauer J. Modern approaches in deep learning for SAR ATR[C]. Proceedings of SPIE 9843, Algorithms for Synthetic Aperture Radar Imagery XXIII, Baltimore, Maryland, United States, 2016: 98430N.
- [9] Wagner S. Combination of convolutional feature extraction and support vector machines for radar ATR[C]. Proceedings of the 17th International Conference on Information Fusion, Salamanca, Spain, 2014: 1–6.
- [10] Pei J F, Huang Y L, Huo W B, *et al.* SAR automatic target recognition based on multiview deep learning framework[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(4): 2196–2210. DOI: [10.1109/TGRS.2017.2776357](https://doi.org/10.1109/TGRS.2017.2776357).
- [11] Lin Z, Ji K F, Kang M, *et al.* Deep convolutional highway unit network for SAR target classification with limited labeled training data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(7): 1091–1095. DOI: [10.1109/LGRS.2017.2698213](https://doi.org/10.1109/LGRS.2017.2698213).
- [12] Chen S Z and Wang H P. SAR target recognition based on deep learning[C]. Proceedings of 2014 International Conference on Data Science and Advanced Analytics, Shanghai, China, 2015: 541–547.
- [13] El Housseini A, Toumi A, and Khenchaf A. Deep learning for target recognition from SAR images[C]. Proceedings of 2017 Seminar on Detection Systems Architectures and Technologies, Algiers, Algeria, 2017: 1–5.
- [14] 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 Zhuangzhuang, Zhan Ronghui, Hu Jiemin, *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).
- [15] Springenberg J T, Dosovitskiy A, Brox T, *et al.* Striving for simplicity: The all convolutional net[OL]. arXiv preprint arXiv:1412.6806, 2015.
- [16] Hinton G E and Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504–507. DOI: [10.1126/science.1127647](https://doi.org/10.1126/science.1127647).
- [17] 康妙, 计科峰, 冷祥光, 等. 基于栈式自编码器特征融合的SAR图像车辆目标识别[J]. *雷达学报*, 2017, 6(2): 167–176. DOI: [10.12000/JR16112](https://doi.org/10.12000/JR16112).  
Kang Miao, Ji Kefeng, Leng Xiangguang, *et al.* SAR target recognition with feature fusion based on stacked autoencoder[J]. *Journal of Radars*, 2017, 6(2): 167–176. DOI: [10.12000/JR16112](https://doi.org/10.12000/JR16112).
- [18] 赵飞翔, 刘永祥, 霍凯. 基于栈式降噪稀疏自动编码器的雷达目标识别方法[J]. *雷达学报*, 2017, 6(2): 149–156. DOI: [10.12000/JR16151](https://doi.org/10.12000/JR16151).  
Zhao Feixiang, Liu Yongxiang, and Huo Kai. Radar target recognition based on stacked denoising sparse autoencoder[J]. *Journal of Radars*, 2017, 6(2): 149–156. DOI: [10.12000/JR16151](https://doi.org/10.12000/JR16151).
- [19] Masci J, Meier U, Cireřan D, *et al.* Stacked convolutional auto-encoders for hierarchical feature extraction[C]. Proceedings of the 21st International Conference on Artificial Neural Networks on Artificial Neural Networks and Machine Learning – ICANN 2011, Espoo, Finland, 2011: 52–59.
- [20] Vincent P, Larochelle H, Bengio Y, *et al.* Extracting and

composing robust features with denoising autoencoders[C]. Proceedings of the 25th International Conference on Machine Learning, Helsinki, Finland, 2008: 1096–1103.

- [21] Rumelhart D E, Hinton G E, and Williams R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533–536. DOI: [10.1038/323533a0](https://doi.org/10.1038/323533a0).
- [22] Klambauer G, Unterthiner T, Mayr A, *et al.* Self-normalizing neural networks[C]. Proceedings of the 31st

Neural Information Processing Systems, Long Beach, CA, United States, 2017: 972–981.

- [23] Kingma D P and Ba J L. Adam: A method for stochastic optimization[OL]. arXiv preprint arXiv:1412.6980, 2015.
- [24] Dong G G, Wang N, and Kuang G Y. Sparse representation of monogenic signal: With application to target recognition in SAR images[J]. *IEEE Signal Processing Letters*, 2014, 21(8): 952–956. DOI: [10.1109/LSP.2014.2321565](https://doi.org/10.1109/LSP.2014.2321565).

### 作者简介



喻玲娟(1982–), 女, 籍贯江西, 博士, 江西理工大学副教授, 硕士生导师, 中国科学院电子学研究所博士后, 研究方向为合成孔径雷达信号处理。  
E-mail: lingjuanyusmile@163.com



王亚东(1993–), 男, 籍贯江苏, 江西理工大学在读硕士研究生, 研究方向为合成孔径雷达自动目标识别。  
E-mail: wangyadong183@163.com



谢晓春(1975–), 男, 籍贯江西, 博士, 赣南师范大学副教授, 硕士生导师, 研究方向为合成孔径雷达信号处理。  
E-mail: xiexiaochun@gnnu.cn

林 赟(1983–), 女, 籍贯浙江, 博士, 中国科学院电子学研究所副研究员, 硕士生导师, 研究方向为合成孔径雷达3维成像技术、多角度SAR成像基础理论与方法研究。  
E-mail: ylin@mail.ie.ac.cn

洪 文(1968–), 女, 籍贯陕西, 博士, 中国科学院电子学研究所研究员, 博士生导师, 主要研究方向为合成孔径雷达成像与系统及其应用、极化/干涉合成孔径雷达数据处理及应用、3维微波成像新概念新体制新方法等。  
E-mail: whong@mail.ie.ac.cn