

# 基于小样本学习的 SAR 图像识别

汪航<sup>1</sup> 陈晓<sup>2</sup> 田晟兆<sup>1</sup> 陈端兵<sup>1,3</sup>

1 电子科技大学大数据研究中心 成都 611731

2 陆军参谋部信息保障室 北京 100042

3 电子科技大学数字文化与传媒研究中心 成都 611731

(cnwanghhh@163.com)



**摘要** 深度学习已成为图像识别领域的一个研究热点。与传统图像识别方法不同,深度学习从大量数据中自动学习特征,并且具有强大的自学习能力和高效的特征表达能力。但在小样本条件下,传统的深度学习方法如卷积神经网络难以学习到有效的特征,造成图像识别的准确率较低。因此,提出一种新的小样本条件下的图像识别算法用于解决 SAR 图像的分类识别。该算法以卷积神经网络为基础,结合自编码器,形成深度卷积自编码网络结构。首先对图像进行预处理,使用 2D Gabor 滤波增强图像,在此基础上对模型进行训练,最后构建图像分类模型。该算法设计的网络结构能自动学习并提取小样本图像中的有效特征,进而提高识别准确率。在 MSTAR 数据集的 10 类目标分类中,选择训练集数据中 10% 的样本作为新的训练数据,其余数据为验证数据,并且,测试数据在卷积神经网络中的识别准确率为 76.38%,而在提出的卷积自编码结构中的识别准确率达到了 88.09%。实验结果表明,提出的算法在小样本图像识别中比卷积神经网络模型更加有效。

**关键词:** 小样本学习;深度学习;卷积神经网络;自编码器

**中图分类号** TP301.6

## SAR Image Recognition Based on Few-shot Learning

WANG Hang<sup>1</sup>, CHEN Xiao<sup>2</sup>, TIAN Sheng-zhao<sup>1</sup> and CHEN Duan-bing<sup>1,3</sup>

1 Big Data Research Center, University of Electronic Science and Technology of China, Chengdu 611731, China

2 Information Assurance Office of Army Staff, Beijing 100042, China

3 Center for Digitized Culture and Media, University of Electronic Science and Technology of China, Chengdu 611731, China

**Abstract** Deep learning has become a research hotspot in the field of image recognition. Different from traditional image recognition methods, deep learning is to automatically learn features from a large amount data and has a strong ability of feature learning and representation. However, under the condition of small samples, the traditional deep learning methods such as convolutional neural network are difficult to learn effective features, resulting in low image recognition accuracy. Thus, a new image recognition algorithm under small samples was proposed to solve the classification and recognition of SAR images. On the basis of convolutional neural network, it combines convolution operation with autoencoder to form a deep convolutional autoencoder network structure. The algorithm firstly preprocesses the image and enhances the image using 2D Gabor filter, and then trains the model, finally, constructs the image classification model. The proposed model can automatically learn and extract effective features from small sample images, and improve the recognition accuracy. On 10 categories of target classification of MSTAR data set, 10% samples from the training data were selected as new training data, the rest were valid data, and the recognition accuracy of the test data in the convolutional neural network is 76.38%, while that in the proposed convolutional autoencoder is 88.09%. Experimental results show that the proposed algorithm is more effective than convolutional neural network in small sample image recognition.

**Keywords** Few-shot learning, Deep learning, Convolutional neural network, Autoencoder

## 1 引言

近年来,随着研究的不断深入,深度学习在图像识别、音频处理、工业生产线优化等领域被广泛应用,已成为科研领域的研究热点。与传统方法相比,深度学习能从大量数据中自动学习特征,并具有很强的特征表达能力。在图像识别领域,

许多科研人员利用大规模带标签的数据,通过深度卷积神经网络训练了识别性能优异的模型。但在医疗、军事等领域,由于保密机制、数据获取成本高等原因,深度学习面临一个新的问题——小样本,即由于标签注释成本太高而缺少足够的带标签数据。小样本问题主要体现在两个方面:1)虽然数据量足够,但缺少数据对应的标签,即在大量数据中只有少部分数

到稿日期:2019-04-25 返修日期:2019-07-26 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61673085,61433014);国家重点研发计划(2017YFC1601005)

This work was supported by the National Natural Science Foundation of China (61673085,61433014) and National Key Research and Development Project (2017YFC1601005).

通信作者:陈端兵(dbchen@uestc.edu.cn)

据带有标签;2)数据量本身较小。在小样本条件下,由于缺乏训练数据,很难用传统的深度学习网络得到理想的结果。

目前,卷积神经网络是小样本图像识别领域中主要的研究方法,许多学者以该结构为基础对模型进行扩展。Feng 等提出了自适应空间正则化边缘堆叠自编码器方法,用于解决高光谱小样本图像的分类问题<sup>[1]</sup>。Mocanu 等提出了混合变分自编码器,用于解决小样本中的 one-shot learning 问题<sup>[2]</sup>。Yang 等提出了高阶约束自编码器,用于解决遥感图像数量不足的问题<sup>[3]</sup>。Wang 等提出了基于预训练的堆叠去噪自编码器,用于解决回归预测问题<sup>[4]</sup>。

合成孔径雷达(Synthetic Aperture Radar, SAR)是一种主动的对地观测系统,能全天时、全天候对地实施观测,并具有一定的地表穿透能力。SAR 图像在灾害监测、环境监测、海洋检测、资源勘查、测绘和军事等方面具有得天独厚的优势。对于 SAR 图像目标识别,目前研究人员大多是基于大样本进行建模和研究,只有少数学者开展了小样本条件下 SAR 图像目标识别的研究<sup>[1-3]</sup>,并且与大样本数据相比,其识别准确率较低。针对这一问题,本文提出了一种新的算法——卷积自编码器算法。该方法以卷积神经网络为基础<sup>[5-7]</sup>,将卷积操作与自编码器<sup>[8-9]</sup>相结合,从而形成深度卷积自编码网络结构。该结构能自动学习并提取小样本图像中的有效特征,提高了识别准确率。

## 2 SAR 图像预处理方法


SAR 图像通常包含目标区域和背景杂波区域,如果对原始图像进行分类识别,背景杂波会一定程度地影响识别性能;SAR 是相干系统,斑点噪声是其固有特性。本文在利用 SAR 图像建立学习模型对目标进行识别之前,首先使用多尺度、多方向 2D Gabor<sup>[10-13]</sup>滤波器组对 SAR 图像进行预处理,以降低噪声的影响。

Gabor 滤波器不仅具有傅里叶变换的特点,而且能够反映图像信号的整体特征并对局部特征进行分析。二维 Gabor 小波变换能够提取图像上各尺度的纹理信息。二维 Gabor 小波核可表示为椭圆高斯包络和复平面波的乘积,具体定义为:

$$\psi_{u,v}(\mathbf{z}) = \frac{\|\mathbf{K}_{u,v}\|}{\sigma^2} e^{-\frac{\|\mathbf{K}_{u,v}\|^2 \|\mathbf{z}\|^2}{2\sigma^2}} (e^{i\mathbf{K}_{u,v}\cdot\mathbf{z}} - e^{-\frac{\sigma^2}{2}}) \quad (1)$$

其中, $\mathbf{z}=(x,y)$ 是位置变量, $u$ 为 Gabor 核的方向, $v$ 为 Gabor 核的尺度, $\|\cdot\|$ 为模运算, $\mathbf{K}_{u,v}=k_s e^{i\theta_d}$ 表示 Gabor 滤波器的尺度和方向, $k_s=k_{\max}/f^s$ , $k_{\max}=\pi/2$ 。本文取  $f=2$ ,滤波器的尺寸为 1717, $\sigma=\pi/4$ , $u$ 为 0~8, $v$ 为 0~5,即 5 个尺度、8 个方向,共 40 个滤波器实部取值图像。

由于目标区域和背景杂波区域具有显著的方向性,因此将得到的 40 个滤波器实部取值图像叠加,能有效抑制背景杂波的斑点噪声,从而增强目标区域。增强目标区域后,对图像进行切割,选择中心目标图像。图像的预处理结果如图 1 所示。



(a) 原图

(b) 预处理后的结果

图 1 SAR 图像的预处理结果

Fig. 1 Preprocessing results of SAR image

## 3 模型与方法

### 3.1 模型的基本思路

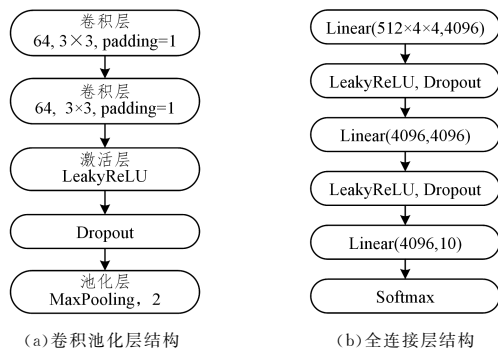
首先以 VGG11<sup>[14]</sup>模型结构为基础,构造一个新的卷积神经网络模型,并通过交叉验证的思想训练小样本数据,调整模型参数,得到小样本条件下最优的卷积神经网络模型。在卷积自编码器模型中,编码器部分的结构与卷积神经网络的结构相同,解码器部分的结构在编码器结构的基础上进行反操作,通过对小样本数据进行训练,保留编码器部分的结构和权重;在此结构后增加全连接层,并进行训练,最终得到卷积自编码器分类模型。其中采用的分类器为多分类回归模型 Softmax。

### 3.2 卷积神经网络

在深度学习中,卷积神经网络(Convolutional Neural Network, CNN)是一类深度神经网络,常用于分析视觉图像。卷积神经网络以特征图作为输入,其层次结构包括数据输入层(Input Layer)、卷积层(Convolution Layer)、激活层(Activation Layer)、池化层(Pooling Layer)和全连接层(Fully Connected Layer)。

本文的卷积神经网络结构包括 1 个输入层、4 个卷积池化层和 1 个全连接层。每个卷积池化层的具体结构为每 2 层卷积层后连接 1 层激活层;激活层后为 Dropout 层,用于防止过拟合;最后是 1 层池化层。全连接层分为 3 层线性层;第 1 层为降维层(即将卷积操作后的特征图进行降维),第 2 层为保留层(保留降维层后的特征图个数),第 3 层为分类层。在最后一层后加入分类器,形成分类神经网络。

卷积神经网络结构中的第 1 层到第 4 层卷积池化层中的卷积层输出通道数量(也可看作卷积核的数量或输出的特征数)依次为 64, 128, 256, 512, 使用 LeakyReLU 作为激活函数,如图 2(a)所示,全连接层也采用激活函数 LeakyReLU,最后使用 Softmax 分类器进行分类,如图 2(b)所示。



(a) 卷积池化层结构

(b) 全连接层结构

图 2 卷积池化层和全连接层

Fig. 2 Convolution pooling layer and fully connected layer

其中,卷积池化层从第 1 层到第 4 层输出的特征图大小分别为 3232, 1616, 88, 44, 全连接层第 1 层到第 3 层的输出特征数为 8192, 4096, 10。

#### 3.2.1 输入层

在输入层中对原始图像进行简单的预处理,包括取均值、归一化等。本文在输入层采取的预处理为归一化,将图像像素归一化到 0~1 之间,以加快训练网络的收敛速度和训练速度。

#### 3.2.2 卷积层

卷积层是卷积神经网络中最重要的层次,用于提取特征。卷积层中有两个关键操作:局部关联和窗口滑动。局部关联

指将每个神经元看作一个滤波器(filter),也称卷积核(kernel);窗口滑动是指滤波器对局部数据进行运算。

在卷积层中,计算输入图像的区域和滤波器的权重矩阵之间的点积,并将结果作为该层的输出。滤波器将滑过整个图像,重复相同的点积运算。

### 3.2.3 激活层

卷积神经网络中的激活层实质上是一个非线性函数,即把卷积层的输出结果做非线性映射。一般选择修正线性单元(Rectified Linear Unit, ReLU)函数,其公式为:

$$f(x) = \max(0, x) \quad (2)$$

该函数能够解决梯度消失的问题,加快训练速度。但如果一个非常大的梯度流过一个 ReLU 神经元,更新参数后,该神经元不会有任何激活,即出现“死亡”现象。因此本文采用激活函数 LeakyReLU,它为所有的负值赋予一个非零斜率,其公式为:

$$y_i = \begin{cases} x_i, & x_i \geq 0 \\ a_i x_i, & x_i < 0 \end{cases} \quad (3)$$

其中,  $a_i$  是  $(1, +\infty)$  内的固定参数。当不激活时, LeakyReLU 仍然会有非零值输出,从而获得一个小梯度,避免 ReLU 可能出现的神元“死亡”现象。

### 3.2.4 池化层

池化层主要用于降低特征维数并压缩数据和参数的量,以减小过拟合,同时提高模型的容错性;也负责在图像压缩时去掉无关紧要的信息,保留最能够表达图像特征的信息。

目前有两种广泛使用的池化操作:平均池化(Average-pooling)和最大池化(Maxpooling)。本文模型采用最大池化,滤波器大小为 2。

### 3.2.5 全连接层

在卷积神经网络中,将最后一层卷积层的输出展平,并将当前层的每个节点与下一层的另一个节点连接起来。全连接层主要对特征进行重新拟合,以减少特征信息的丢失,最后使用 Softmax 函数进行分类。

## 3.3 卷积自编码器

### 3.3.1 自动编码器

在无监督学习中,自编码器是一类典型的无监督神经网络,其目的是基于输入的无标签数据  $X$ ,通过训练得到数据的一个降维特征表达,即隐藏层  $H$ 。在图像识别中,可以通过隐藏层  $H$  提取图像特征,并将这种更为抽象的特征作为后续全连接层的输入,以更好地表达输入图像,这在分类任务上具有重要的意义。

原始自编码器的结构很简单,包括输入层、隐藏层、输出层。其中,隐藏层的维度远小于输入层;输出层的输出用于重构输入层的输入,使输入和输出之间的误差最小。因此自编码器分为两个部分:前一部分为编码器(Encoder),将输入压缩为特征;后一部分为解码器(Decoder),将特征还原为输入。

### 3.3.2 卷积自动编码器

普通的自编码器中,编码器和解码器中层与层之间的连接方式为全连接,编码器在进行训练时,参数十分复杂,并且训练时间长。

卷积自编码器利用了传统自编码器的无监督学习方式,并结合了卷积神经网络中的卷积和池化操作来实现特征提取。与传统自编码器相比,其训练速度更快,重构误差更低。

本文卷积自编码器中的编码器部分的网络结构与卷积神经网络中卷积池化部分的结构相同。首先通过编码器部分构造出对应的解码器部分,在训练结束后,保留编码器部分的结构和权重,在编码器后加上与卷积神经网络结构中相同的全连接层来进行图像分类识别。卷积自编码器的具体结构如图 3 所示,图 3(a)左侧表示编码器部分,右侧表示解码器部分,每一层输出的特征图大小在箭头上进行标识。图 3(a)中 Encoder1 的结构如图 2(a)所示,解码器的部分结构如图 3(b)所示,因为编码器中卷积部分是先进行卷积操作后进行池化操作,所以对对应解码器部分为先进行反池化操作再进行反卷积操作,其中反卷积层的输出通道数(也称为反卷积核的数量或输出的特征数)从 Decoder1 到 Decoder4 分别为 512, 256, 128, 64, 并且使用 LeakyReLU 作为激活函数。

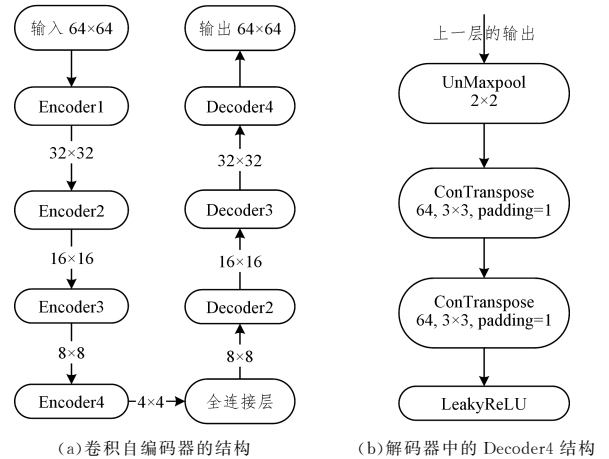


图 3 卷积自编码器

Fig. 3 Convolutional autoencoder

## 4 实验和分析

### 4.1 实验数据

实验数据采用美国国防高级研究计划局(DARPA)和美国空军研究实验室(AFRL)支持的 MSTAR 计划所公布的实测 SAR 地面静止目标数据。采集该数据的传感器为高分辨率聚束式合成孔径雷达。选择俯仰角为  $17^\circ$  的数据作为训练集,  $15^\circ$  的数据作为测试集。数据集中共有 10 种类型的数据,训练集共有 2747 张 SAR 图像,测试集有 2426 张 SAR 图像,图像大小为  $128 \times 128$ ,  $158 \times 158$ ,  $178 \times 178$ ,  $192 \times 192$ 。具体数据情况如表 1 所列。

表 1 实验数据的统计结果

Table 1 Statistics of experimental data

类别	训练集数量	测试集数量
2S1	299	274
BMP2(SN_9566)	232	196
BRDM_2	298	274
BTR70(SN-C71)	233	196
BTR_60	256	195
D7	299	274
T62	299	273
T72(SN_132)	232	196
ZIL131	299	274
ZSU_23_4	299	274
ALL	2746	2426

为了研究小样本条件下 SAR 图像识别算法的性能,对上述训练集数据进行随机划分,即对表 1 中每类数据按照 1:9

的比例随机划分,将 10% 的数据作为新的训练集,90% 的数据作为验证集,并使用新的训练集对上述模型进行训练。

## 4.2 实验结果分析

基于上述实验数据,选择划分好的 10% 的数据作为训练集,分别在卷积神经网络模型和本文提出的卷积自编码模型上进行训练,使用的深度学习框架为 PyTorch。

### 4.2.1 卷积神经网络

卷积神经网络模型如图 2 所示。训练次数为 400,优化器选择 Adam,学习率设置为 0.0001,损失函数为多分类交叉熵损失函数。训练结果如图 4 所示。




图 4 卷积神经网络的训练结果

Fig. 4 Training results of convolutional neural network

从图 4 可知,当训练次数少于 170 时,卷积神经网络模型一直都在学习 SAR 图像的特征;在 170 次后,训练集和验证集的损失开始逐渐下降;当训练次数为 220 左右时,验证集的损失开始出现波动,而训练集的损失依然在下降,这时出现了过拟合现象。经过分析可知,由于训练集数据过少,对于卷积神经网络模型而言,学习到的特征很少,随着训练次数的增多,损失逐渐增大,从而出现过拟合。因此,卷积神经网络模型并不适用于小样本图像识别。

对卷积神经网络进行测试时,若输入图像为图 1(b) 所示的预处理后的图像,则第 1 层卷积池化层的某个输出特征图和第 2 层卷积池化层的某个输出特征图如图 5 所示。可以看出,前两层卷积池化层能更好地提取图像的轮廓特征;而后两层卷积池化层为具体的细节部分,在此不做描述。




图 5 卷积神经网络卷积池化层的输出特征图

Fig. 5 Convolution pooling layer output feature map of convolutional neural network

在测试集中进行测试时,卷积神经网络模型的平均准确率为 76.38%,相对较低,并且各个类的识别准确率也相对较低。

### 4.2.2 卷积自编码

卷积自编码模型如图 3 所示。其训练方法分为两步:预训练和微调。

预训练阶段:使用自编码器模型进行训练,训练次数为 400,使自编码器的输出结果与原始输入之间的损失达到最小,在此选择均方差损失函数。图 6 给出了一幅图像与卷积自编码器输出图像的对比结果。其中输入图像为图 1(b) 预

处理后的图像,输出图像如图 6(b) 所示,损失为 0.000914。




图 6 卷积自编码器的输入图像与输出图像

Fig. 6 Input image and output image of convolutional autoencoder

微调阶段:将预训练好的自编码器模型中的编码器部分的结构和权重保留,即保留图 3(a) 中左半部的编码器部分,去掉解码器部分,随后在编码器后加入与卷积神经网络模型中相同的全连接层,形成卷积自编码器分类模型。该模型与卷积神经网络模型完全相同,并使用小样本数据对新构建的模型进行训练分类。选择多分类交叉熵损失函数,优化器为 Adam,学习率为 0.0001,训练次数为 60。微调阶段的训练结果如图 7 所示。




图 7 卷积自编码器微调阶段的训练结果

Fig. 7 Training results of convolutional autoencoder in fine-tuning

从图 7 可知,经过预训练阶段后,尽管训练的早期准确率较低,但是随着训练次数的增加,准确率快速上升,而卷积神经网络模型需要训练很多次才能够有显著提升。同时,在预训练阶段,自编码器模型训练 400 次后,其编码部分就能有效提取 SAR 图像特征;在微调阶段,利用编码器的结构和权重可以有效提高模型识别准确率,训练 10 次左右准确率就已经达到最优,并且不会出现过拟合现象。

微调阶段中使用的卷积自编码器分类模型实际上与卷积神经网络模型相同,当输入图像为图 1(b) 所示的预处理图片时,第 1 层卷积池化层输出的某个特征图和第 2 层卷积池化层输出的某个特征图如图 8 所示。与卷积神经网络提取出的特征图(如图 5 所示)相比,其更具有抽象性,能够更有效地描述图像边缘和轮廓特征。




图 8 卷积自编码器分类模型中卷积池化层的输出特征图

Fig. 8 Convolution pooling layer output feature map of convolutional autoencoder

在测试集中进行测试时,卷积自编码器分类模型的平均准确率为 88.09%,相比卷积神经网络模型有了大幅度的提升。卷积神经网络模型与卷积自编码模型的识别准确率对比如表 2 所列。

表 2 卷积神经网络模型与卷积自编码模型的识别准确率对比  
Table 2 Accuracy comparison between convolutional neural network model and convolutional autoencoder model

类别	(单位:%)	
	卷积神经网络	卷积自编码
2S1	78.10	91.24
BMP2(SN_9566)	46.94	56.12
BRDM_2	69.34	91.24
BTR70(SN-C71)	58.46	83.08
BTR_60	80.61	89.29
D7	90.88	98.54
T62	79.85	86.45
T72(SN_132)	86.22	86.74
ZIL131	75.18	89.05
ZSU_23_4	88.69	98.54
平均	76.38	88.09

**结束语** 本文在对 SAR 图像进行 2D Gabor 滤波预处理的基础上,采用卷积自编码方法替代传统的卷积神经网络方法。通过实验对比分析可知,卷积自编码器的识别效果优于卷积神经网络,尤其是在每一类中,卷积自编码器的准确率相比于卷积神经网络有了较大的提升。但是对于个别类如 BMP2(SN\_9566)来说,不管是卷积自编码器还是卷积神经网络,其识别率均相对较低,这可能是由于图像本身的问题。

总体而言,本文提出的卷积自编码方法的准确率高、鲁棒性强,并且能够避免过拟合问题,提高了小样本图像识别的准确率;该方法亦可以应用到除 SAR 图像领域外的其他图像识别问题中。

对未来工作的展望:

- 1)在卷积自编码的基础上进行扩展,使用卷积变分自编码方法替代卷积自编码;
- 2)使用不同的预处理方法对图像进行预处理,并与未经过预处理的识别结果进行比较;
- 3)尝试以 DenseNet 网络为基础来构造卷积自编码器模型;
- 4)利用本文数据和本文卷积自编码器的思想对 C-way K-shot 进行研究;
- 5)迁移学习方法与自编码器方法的结合。

## 参考文献

- [1] FENG J, LIU L, CAO X, et al. Marginal Stacked Autoencoder With Adaptively-Spatial Regularization for Hyperspectral Image Classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(9): 3297-3311.
- [2] MOCANU C, MOCANU E. One-Shot Learning using Mixture of Variational Autoencoders: a Generalization Learning approach [C]// Proceedings of the 17th International Conference on Autonomous Agents and MultiAgent Systems. Stockholm, Swe-

den, 2018: 2016-2018.

- [3] YANG Q, SUN F. Small sample learning with high order contractive auto-encoders and application in SAR images [J]. Science China Information Sciences, 2018, 61(9): 271-273.
- [4] WANG X, MU S, SHI A, et al. A Stacked Denoising Autoencoder Based on Supervised Pre-training [C]// Smart Innovations in Communication and Computational Sciences. Singapore: Springer, 2019: 139-146.
- [5] WANG H, CHEN S, XU F, et al. Application of deep-learning algorithms to MSTAR data [C]// 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Milan, 2015: 3743-3745.
- [6] ZAIED S, TOUMI A, KHENCHAF A. Target classification using convolutional deep learning and auto-encoder models [C]// 2018 4th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP). Sousse, 2018: 1-6.
- [7] ZHAO F. SAR Image Target Recognition Based on Deep Learning Network [D]. Xi'an: Xidian University, 2017.
- [8] JIA Z, GUANGCHANG D, FENG C, et al. A Deep Learning Fusion Recognition Method Based On SAR Image Data [J]. Procedia Computer Science, 2019, 147: 533-541.
- [9] CHEN Y, MENG H, WEN X, et al. Classification methods of a small sample target object in the sky based on the higher layer visualizing feature and transfer learning deep networks [J]. EURASIP Journal on Wireless Communications and Networking, 2018, 2018(1): 127.
- [10] LADES M, VORBRUGGEN J C, BUHMANN J. Distortion invariant object recognition in the dynamic link architecture [J]. IEEE Transaction on Computer, 1993, 42(3): 300-311.
- [11] JONES J P, PALMER L A. An evaluation of the two-dimensional Gabor filter model of simple receptive fields in cat striate cortex [J]. Journal of Neurophysiology, 1987, 58(6): 1233-1258.
- [12] MOU H. Face Recognition Method Based on Gabor Features [D]. Wuhan: South-Central University for Nationalities, 2013.
- [13] NI W, YAN W, WU J, et al. 2D Gabor Filter Enhancing and Adaptive Thresholding for MSTAR Image [J]. Opto-Electronic Engineering, 2013, 40(3): 87-93.
- [14] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition [J]. arXiv: 14096.



**WANG Hang**, born in 1997, postgraduate. His main research interests include big data and cloud computing.



**CHEN Duan-bing**, born in 1971, professor. His main research interests include big data mining, complex network, information spreading and recommending.