

# 基于深度学习合成孔径雷达目标识别的研究

韩文文 韩宇

中国人民解放军78100部队 四川成都 610000

**摘要:** 随着科技技术的发展, 图像处理的方法越来越多, 深度学习技术已经占据图像处理的主流, 尤其是在图像识别领域。本文介绍了合成孔径雷达成像的基本原理及其图像特征, 重点将深度学习技术引入到合成孔径雷达的图像识别中, 包括数据预处理、数据增强、确定卷积神经网络的卷积核大小、激活函数的选择等等, 为图像识别的特征提取提出一种可能的流程了方向。

**关键词:** 图像识别; 特征提取; 深度学习技术

## Research on target recognition of synthetic Aperture Radar based on deep learning

Wenwen Han, Yu Han

78100 troops of the Chinese people's Liberation Army 610000 Chengdu, Sichuan

**Abstract:** With the development of science and technology, there are more and more image processing methods. Deep learning technology has occupied the mainstream of image processing, especially in the field of image recognition. This paper introduces the basic principle of SAR imaging and its image features and focuses on the introduction of deep learning technology into SAR image recognition, including data preprocessing, data enhancement, and determining the size of the convolution kernel of the convolution neural network, the selection of activation function and so on. It puts forward a possible process for feature extraction of image recognition.

**Keywords:** image recognition, feature extraction, deep learning technology

### 一、前言

合成孔径雷达(SAR)是一种全天候、对天气(包括下雨、起雾、云雾遮挡)要求十分低的一类雷达, 是一种主动式的(主动给发射电磁波并接收回波)高精度的成像雷达。由于其具备传统光学成像所不具备的性质, 合成孔径雷达被广泛应用于军事情报探测、军事地图测绘、飞机与导弹的高航、水质和水文的检测、森林火灾与重大灾害的监测、制备覆盖率的探查、考古研究等领域。随着合成孔径雷达的技术发展, 其成像质量也越来越好, 图像分辨率也越来越高, 但是对于合成孔径雷达图像的自动识别技术来说发展还是比较缓慢的。合成孔径雷达图像处理技术经历了(1)人工判断过程。该过程工作人员根据雷达图像中目标的大小、形状、阴影、灰度信息等要素来判断图像中的类别, 对人眼的依赖程度较高, 局限性较大、准确率也比较低。(2)计算机图像处理技术。该过程首先要通过特征提取算子来对图像进

行特征提取, 然后通过分类器对其取的特征进行识别。这种识别方法对于不同图像的特征提取算子的选择是个难题, 在不同背景下、不同距离下的目标识别起来也比较困难。(3)人工智能方法。近几年, 深度学习技术较为火爆, 在图像领域(包括图像目标识别、目标的检测以及目标的定位等)表现的非常出色, 在基于深度学习的人脸识别中识别率可达到99%以上, 若将深度学习技术应用于合成孔径雷达图像识别领域是很有意义的。

本文的研究对象就是将深度学习方法应用于合成孔径雷达目标识别问题上, 重点分析SAR目标成像原理以及使用深度学习方法中深度卷积网络处理雷达图像的过程。

### 二、合成孔径雷达成像原理及目标识别的步骤

#### 1. 合成孔径雷达成像原理

合成孔径雷达一般搭载在飞机上, 利用飞机的不断移动合成更大的孔径, 其走过的距离可认为是有效天线

孔径。工作过程：向目标处发射电磁波，然后接收反射回来的电磁波，并对接收到的雷达回波数据进行处理，接着运用距离多普勒算法进行成像，最终获得目标的散射特性分布和目标的二维灰度图像。

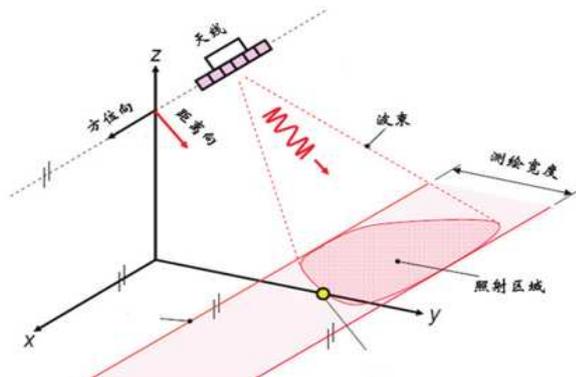


图1 合成孔径雷达成像原理图

雷达技术中角分辨率（在两坐标中为方位分辨率或称为横向距离分辨率）可用数学表达式：

$$\delta_x = \lambda R / D \quad (\text{rad}) \quad (\text{式1})$$

式中，D为天线孔径，R为斜距。

对于N个振源的线性阵列，此线性阵列的辐射方向图可定义为单个阵元辐射方向图和阵列因子的乘积。阵列因子是阵列里天线阵元均为全向阵元时的总辐射方向图。若忽略空间损失和阵元的方向图，则阵列的输出可表示为

$$V_R = \sum_N^{n=1} A_n \exp[-j(2\pi/\lambda)d]^2 \quad (\text{式2})$$

式中， $V_R$ 为阵列输出面的各阵元幅度的平方之和； $A_n$ 为第n个阵元的幅度；d为线性阵列阵元的间距；N为阵列中阵元的总数。因此，阵列的半功率点波瓣宽度为：

$$\theta_{0.5} = \lambda / L \quad (\text{式3})$$

式中，L为实际阵列的总长度。若阵列对目标的斜距为R，则其横向距离分辨力为

$$\delta_x = \lambda R / L (\text{rad}) \quad (\text{式4})$$

## 2. 雷达目标识别原理

雷达目标识别技术是利用雷达和计算机对遥远目标进行辨认的技术，对遥远目标进行探测和定位，测量与目标形体和表面物理特征有关的参数，进而对目标进行分类和识别。其基本原理是利用雷达回波中的幅度、相位、频谱和极化等目标特征信息，通过数学上的各种多维空间变换来估算目标的大小、形状、重量和表面层的物理特征参数，最后根据大量训练样本所确定的鉴别函数，在分类器中进行识别和判决。

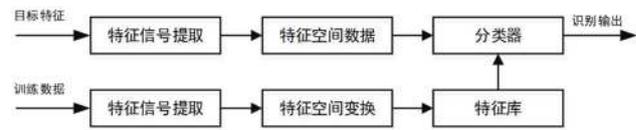


图2 雷达目标识别原理图

目标特征是雷达发射的电磁波与目标在传播空间相互产生的信息，载于散射回波之上，是雷达识别目标的主要信息来源。目前可用的雷达目标特征主要包括窄带RCS特征、运动特征、频谱特征、一维像、二维像、极化等特征。特征空间变换是采用各种优化的变换技术改善特征空间中原始特征的分布结构，去除冗余特征，压缩特征维数的技术。特征库是在训练实测数据基础上进行特征信号提取，再进行空间变换后而形成的标准特征模板库，常规雷达目标识别通常采用的是同特征库进行匹配的模式分类器。

## 三、图像处理深度学习算法流程

### 1. 基于深度学习方法的图像识别

目前基于深度学习方法对不同形式雷达数据进行处理的主流研究思路是基于生成各种不同雷达图像，利用深度学习网络对图像进行处理。其与常规雷达识别技术最主要的差异在于采用的特征不同。常规雷达识别主要借助专业技术人员的经验进行特征提取（提取的为物理特征）。深度学习的实质是通过构建很多隐层的机器学习模型和海量的训练数据，来学习更有用的特征，提升分类或预测的准确性，自动提取特征，减少了技术人员对专业知识的依赖程度。对于目标识别而言，其主要要求是要快速、简便、有效的对图像的特征进行提取，近年来，深度学习发展迅速，各种各样新的网络结构（卷积神经网络、自编码器、受限玻尔兹曼机等）和训练技巧（dropout、NB等）的出现，使得深度学习被用用到各个领域。我们这里选用卷积神经网络进行图像识别。

图像识别的主要步骤为：1. 获得原始数据；2. 数据的预处理；3. 数据的特征提取；4. 利用分类器进行分类。

### 2. 数据预处理

对原始图片进行降噪、数据增强。由于SAR雷达一般采用仰视方式工作，目标的图像非常大概率是和样本中的图像的角度不同，这里采用图片旋转的方法来进行数据增强，增加样本数量。图片旋转的转换公式为

$$\begin{cases} X_\alpha = X \cdot \cos\theta + Y \cdot \sin\theta \\ Y_\alpha = -X \cdot \sin\theta + Y \cdot \cos\theta \end{cases} \quad (\text{式5})$$

其中， $(X_\alpha, Y_\alpha)$ 和 $(X, Y)$ 分别是图片旋转后和

旋转前的坐标,  $\theta$  为旋转的角度。

### 3. 训练样本输入卷积神经网络进行训练

#### (1) 确定卷积神经网络模型

深度卷积网络训练的过程就是在学习如何自动进行特征选择, 它的每一个卷积层就是一个特征选择的过程, 输出就是特征图。本文网络模型采用 AlexNet 模型结构 (5 个卷积层, 3 个全连接层, 共计 6 亿 3 千万个连接, 6 千万个参数和 65 万个神经元)。

深度卷积的神经网络框架如下图:




图3 神经网络框架图

#### (2) 确定激活函数

常用的激活函数有 sigmoid 函数, tanh 函数, ReLU 函数, Leaky ReLU 函数等。

对于 sigmoid 函数, 其公式和其导数公式如下:

$$f(x) = \text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (\text{式6})$$

$$f'(x) = \frac{e^{-x}}{(1 + e^{-x})^2} = f(x)(1 - f(x))$$

通过观察 sigmoid 函数图可以发现, sigmoid 函数的取值范围在 0 和 1 之间, 并且越远离坐标原点, 函数值越接近 0 或者 1。对于其函数的导数, 可以发现 sigmoid 函数的导数在原点取得最大值 0.25, 然后向两边快速减少, 此时在网络较深时会造成梯度弥散。

对于双曲正切函数 tanh 函数, 其公式和导数公式如下:

$$f(x) = \text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (\text{式7})$$

$$f'(x) = 1 - \text{tanh}^2(x) = 1 - f^2(x)$$

通过观察 tanh 函数图可以发现, tanh 函数的取值范围是 -1 到 1 之间; tanh 函数的导数最大值可以取到 1, 这表示当遇到显著的特征时, tanh 函数能不断扩大特征效果, 但在特征不明显的环境下效果可能不会很好。

对于 ReLU 函数, 其公式和导数公式如下:

$$f(x) = \text{ReLU}(x) = \max(0, x)$$

$$f'(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (\text{式8})$$

其最大特点就是当  $x < 0$  时, 激励函数的输出为零, 也就是说当该神经元的输入小于零时该神经元表现为不激活状态, 且使用使用该函数会使得随机梯度下降收敛的快些。

对于 ReLU 的变体 Leaky Relu (带泄露整流线性单元), 其与 ReLU 函数唯一不同的地方是 Leaky ReLU 在  $x$  小于 0 时, 函数值不取零, 而是取  $ax$  (其中  $0 < a < 1$ ), 其作用是可以改善 ReLU 激活函数会将某些有用的输入未被激活的弊端, 其相关公式如下:

$$f(x) = \text{LReLU}(x) = \begin{cases} x, & x \geq 0 \\ ax, & x < 0 \end{cases}$$

$$f'(x) = \begin{cases} 1, & x \geq 0 \\ a, & x < 0 \end{cases} \quad (\text{式9})$$

对激活函数进行试验, 将其放入构造好了的神经网络中, 使用训练数据训练, 最后可得不同激活函数的识别率, 具体如下:

Sigmoid 函数的识别率为 0.756, tanh 函数的识别率为 0.874, ReLU 函数的识别率为 0.935, Leaky ReLU 函数的识别率为 0.927。经过计算建议选择 ReLU 函数作为合适 SAR 图像处理的激活函数。

#### (3) 确定卷积核尺寸

对于卷积神经网络而言, 卷积是非常重要的, 为了确定卷积核的大小, 提取出有用的特征图, 这里对  $3 \times 3$ ,  $5 \times 5$ ,  $7 \times 7$ ,  $9 \times 9$ ,  $11 \times 11$ ,  $13 \times 13$ ,  $15 \times 15$  的卷积核来进行训练, 以下为不同尺寸卷积核所对应的识别率, 其中  $3 \times 3$  为 0.943,  $5 \times 5$  为 0.951,  $7 \times 7$  为 0.948,  $9 \times 9$  为 0.957,  $11 \times 11$  为 0.939,  $13 \times 13$  为 0.941,  $15 \times 15$  为 0.938, 经对比建议选择  $9 \times 9$  的卷积核。

#### (4) 确定代价函数

无论是卷积神经网络还是传统的机器学习关键都训练一个优秀且稳定的模型。要训练一个模型, 就要知道模型的输出与真实数据有多大的区别并且要进行修正, 代价函数就是用来衡量模型输出与真实值的偏差。

本文采用交叉熵作为损失函数, 描述深度卷积网络的实际输出与期望输出之间的距离。当交叉熵值越小, 网络的输出效果就越好。对于合成孔径雷达图像来说, 因为是对输入进行分类, 所以网络最后输出的为一个概率分布 (网络最后通过 softmax 函数)。

其交叉熵可表示为:

$$H(p, q) = -\sum_x p(x) \log(q(x)) \quad (\text{式10})$$

其中,  $p$  为期望输出的概率分布,  $q$  为实际输出的概率分布。

#### (5) 确定优化算法

根据代价函数, 确定优化算法来减少偏差。一般来说梯度下降法是解决神经网络化的通用算法, 由于梯度

下降法自身的一些不足之处和学习率这个超参数的难以设置导致梯度下降法在深度卷积网络中效果很差，为了避免学习率这个难以把握的超参数大的设定，需要选用一种合适的算法。这里选用两种算法进行比较，确定适合的算法。

第一种是AdaGrad算法，它是在梯度下降法的基础上衍生的，和梯度下降法的区别在于它的学习率不是恒定的。Adagrad的核心想法就是，如果一个参数的梯度一直都非常大，那么其对应的学习率就变小一点，防止震荡，而一个参数的梯度一直都非常小，那么这个参数的学习率就变大一点，使得其能够更快地更新，其公式表示为

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{G + \epsilon}} g_t \quad (式11)$$

其中  $\eta$  为预先设定的全局学习率， $G$ 是梯度取平方累加后的开发， $g$ 是梯度， $\epsilon$  为平滑参数，其作用是为了避免分母为零的情况。

第二种是Adam算法，它是在梯度下降法的基础上结合了一个加速梯度下降算法而形成的，因Adam算法在处理大规模数据优化时非常高效，所以Adam算法在深度学习领域非常流行。

对这两种算法进行实验，其分辨率如下：AdaGard算法为0.945，Adam算法为0.958。最终选择Adam算法。

#### (6) 具体实现

卷积层输出特征图大小的计算公式如下：

$$N = (W - F + 2P) / S + 1 \quad (式12)$$

其中， $W * W$ 为输入图像的大小， $F * F$ 为卷积核大小，

$S$ 为步长， $P$ 为Padding的像素个数。

采用tensorflow系统进行卷积图的计算，这里我们使用“SAME”模式：

确定输出的特征尺寸：

$$w_{out} = \frac{w_{in} + 2 * padding - F}{stride} + 1 \quad (式13)$$

$w_{in}$ 和 $w_{out}$ 分别为网络层输入和输出的特征图尺寸， $F$ 是卷积核的大小， $stride$ 为步长， $padding$ 是补零圈数。

#### (7) 进行平均池化层

采用大小为 $3 * 3$ ，步长为 $2 * 2$ 进行平均池化，完成第一个卷积模块，获得输出矩阵。如此往复进行剩余的卷积模块，从而获取最终训练样本。

#### 四、结束语

合成孔径雷达应用范围较广，本文重点研究内容是将深度学习引入到合成孔径雷达图像处理中，试验了不同卷积核尺寸、不同激活函数、不同优化算法等对网络模型识别率的影响，最后找出最优体条件，为提高雷达识别率提供一种方法。

#### 参考文献：

- [1]于娜.基于合成孔径雷达图像处理的舰船目标检测与优化[J].舰船科学技术 Vol.41.No.10A Oct, 2019.
- [2]皮亦鸣, 杨建宇.合成孔径雷达成像原理[M].成都: 电子科技大学出版社, 2007.
- [3]张平.雷达图像处理与目标录取关键技术的研究[D].大连海事大学.
- [4]H.Maitre.合成孔径雷达图像处理[M].北京: 电子工业出版社, 2013.