# 基于深度卷积神经网络的气象雷达噪声图像语义分割方法

杨宏宇* 王峰岩
(中国民航大学计算机科学与技术学院 天津 300300)

**摘 要**：针对新一代多普勒气象雷达的散射回波图像受非降雨等噪声回波干扰导致精细化短时气象预报准确度降低的问题，该文提出一种基于深度卷积神经网络(DCNN)的气象雷达噪声图像语义分割方法。首先，设计一种深度卷积神经网络模型(DCNNM)，利用MJDATA数据集的训练集数据进行训练，通过前向传播过程提取特征，将图像高维全局语义信息与局部特征细节融合；然后，利用训练误差值反向传播迭代更新网络参数，实现模型的收敛效果最优化；最后，通过该模型对气象雷达图像数据进行分割处理。实验结果表明，该文方法对气象雷达图像的去噪效果较好，与光流法、全卷积网络(FCN)等方法相比，该文方法对气象雷达图像中真实回波和噪声回波的识别准确率高，图像的像素精度较高。

**关键词**：气象雷达；深度学习；图像语义分割；图像去噪；卷积神经网络
**中图分类号**：TN957.52 **文献标识码**：A **文章编号**：1009-5896(2019)10-2373-09
**DOI**: 10.11999/JEIT190098

# Meteorological Radar Noise Image Semantic Segmentation Method Based on Deep Convolutional Neural Network

YANG Hongyun WANG Fengyan
(*College of Computer Science and Technology, Civil Aviation University of China, Tianjin* 300300, *China*)

**Abstract**: Considering the problem that the scattering echo image of the new generation Doppler meteorological radar is reduced by the noise echoes such as non-rainfall, the accuracy of the refined short-term weather forecast is reduced. A method for semantic segmentation of meteorological radar noise image based on Deep Convolutional Neural Network(DCNN) is proposed. Firstly, a Deep Convolutional Neural Network Model (DCNNM) is designed. The training set data of the MJDATA data set are used for training, and the feature is extracted by the forward propagation process, and the high-dimensional global semantic information of the image is merged with the local feature details. Then, the network parameters are updated by using the training error value back propagation iteration to optimize the convergence effect of the model. Finally, the meteorological radar image data are segmented by the model. The experimental results show that the proposed method has better denoising effect on meteorological radar images, and compared with the optical flow method and the Fully Convolutional Networks (FCN), the method has high recognition accuracy for meteorological radar image real echo and noise echo, and the image pixel precision is high.

**Key words**: Meteorological radar; Deep learning; Image semantic segmentation; Image denoising; Convolutional Neural Network(CNN)

## 1 引言

依靠多普勒效应[1]和降水粒子对雷达发射电磁波的散射回波，新一代的多普勒气象雷达是探测降雨信息的主要设备。由于地物回波等假回波因素的干扰造成气象雷达回波图像噪声增加，导致精细化短时气象预报的误差率上升。

目前，国内外针对雷达图像去噪问题的研究取得了一定成果，文献[2]使用复杂不可分离过采样重叠变换(Complex NonSeparable Oversampled Lapped Transform, CNSOLT)作为稀疏表示对雷达图像去噪处理，并结合CNSOLT和一种复值信号修改的迭代收缩/阈值算法(Iterative Shrinkage/Thresholding Algorithm, ISTA)，提出一种图像恢

收稿日期：2019-02-17；改回日期：2019-06-04；网络出版：2019-06-10
*通信作者： 杨宏宇 yhyxlx@hotmail.com
基金项目：国家自然科学基金(U1833107)，国家科技重大专项(2012ZX03002002)
Foundation Items: The National Natural Science Foundation of China (U1833107), The National Science and Technology Major Project (2012ZX03002002)

复方法。文献[3]提出一种基于非下采样Contourlet变换的自适应图像去噪算法，有效去除了图像中的高斯白噪声，提高了峰值信噪比并可保留图像边缘细节。文献[4]使用基于2维离散小波变换域的定向平滑滤波器对图像去噪，利用Kohonen自组织映射网络(Self-Organizing Map, SOM)对去噪后的图像进行去模糊处理。文献[5]将小波分析和变分推理进行结合，在分别消除图像的低频噪声和高频噪声后，利用小波逆变换获取去噪后的图像。

通过对上述成果的研究和分析，可以发现：

(1) 采用稀疏表示、非下采样Contourlet变换方法进行雷达图像去噪时，无法将图像的高频特征与低频关键特征进行全局量化组合以达到更好的去噪效果。

(2) 采用小波变换方法可以对雷达图像按照不同的小波公式和分解层数进行分解处理，然后将图像的低频区域的关键特征与高频区域的噪声特征进行小波量化组合，但在实际应用中，如何合理选取高频区域和对应层级的阈值是一大难点，这直接影响了小波去噪的准确率。

随着大数据和深度学习技术逐步趋于成熟，很多深度学习模型被应用于图像去噪中。文献[6]基于多尺度残差学习(Multi-scale Residual Learning, MRL)和Dropout正则化方法，提出一种基于卷积神经网络的航空图像去噪识别模型，该模型在一定程度上提高了图像去噪性能，但时间复杂度较高。文献[7]提出一种基于改进全卷积神经网络(Improved Full Convolutional Neural Network, IFCNN)模型的噪声图像语义分割算法，获得了较好图像分割效果，但处理对象只是空间复杂度较低的噪声图像，且网络模型对图像特征的提取能力有限。

由于截至目前几乎没有针对多普勒气象雷达噪声图像语义分割的研究，因此上述各类针对噪声图像的处理的方法为本文研究内容的顺利开展提供了可供参考的实践解决方案。为此，本文将气象雷达图像去噪问题转化为图像语义分割[8,9]任务，应用深度学习技术进行气象雷达噪声图像语义分割，采用多通道跨层聚合的网络结构设计方式，设计一种深度卷积神网络模型(Deep Convolutional Neural Network Model, DCNNM)，本模型将多次池化操作后的结果分别单独保留，然后再各自进行卷积、反卷积处理并将各层数据累加求和，通过Crop操作将求和后数据与原始数据对齐。通过该网络进行模型训练可将图像的高层全局信息与底层局部信息有效结合，并可提升精细化图像分割效果。利用该网络在手工标注气象雷达噪声图像数据集MJDATA上进行的模型训练和测试实验结果表明，本文模型对真实回波和噪声回波识别准确率较高。

## 2 气象雷达图像的语义分割

由于地形，气候，硬件设备等多方面因素影响，气象雷达图像中噪声类型多种多样，图1展示了6类常见的回波噪声。

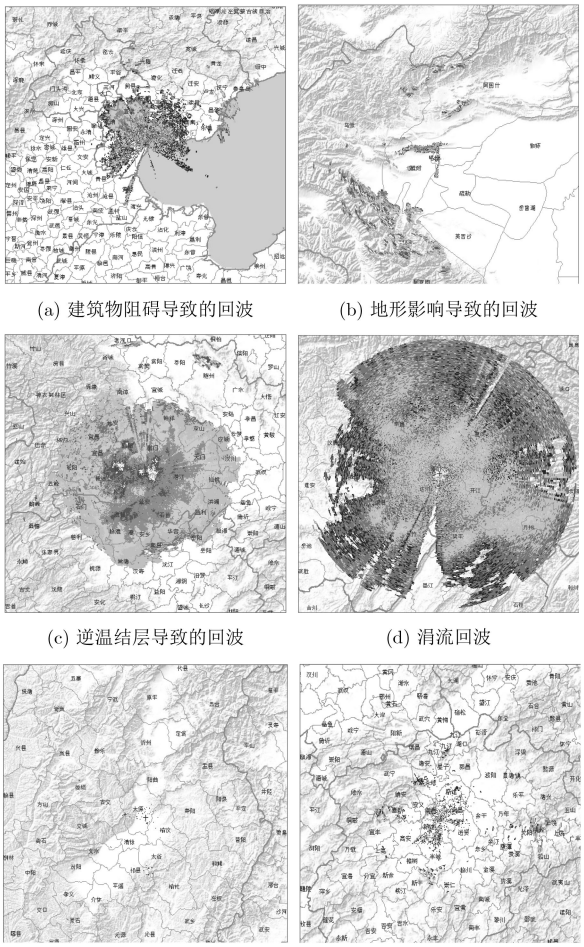

(a) 建筑物阻碍导致的回波 (b) 地形影响导致的回波

(c) 逆温结层导致的回波 (d) 涓流回波

(e) 低空昆虫导致的回波 (f)形态学噪声导致的回波

图 1 气象雷达噪声回波图

其中，图1(a)和图1(b)作为非降雨回波数据被包含在本文的MJDATA数据集中，其样本占有量较少。图1(c)、图1(d)、图1(e)和图1(f)4类噪声回波(包含降雨信息)的形状、高度和强度信息如表1所示。

表1中4类噪声回波的形状、高度和强度(dBz)会根据季节、地区和温度等自然因素在各自特定取值范围内发生变化。

气象雷达图像语义分割是针对气象雷达图像上的回波信息进行类别解析，其本质是根据像素特征将数字图像细分为互不重叠区域的过程。它是实现气象雷达图像去噪的基础，也是精细化短时预报等

表 1　4类噪声回波的特征描述

| 噪声回波 | 形状 | 高度(km) | 强度(dBz) |
|---|---|---|---|
| 逆温层回波 | 分布比较均匀的块状回波，范围较大，边缘清晰 | 5～6 | 10～30 |
| 涓流回波 | 分布比较均匀的半圆形回波，范围较大，边缘清晰 | 6～7 | 5～15 |
| 低空昆虫回波 | 分布不均匀的点状回波，范围小，比较分散 | 2～3 | 0～10 |
| 形态学噪声回波 | 分布不均匀的点状或片状回波，范围较小，比较分散 | 3～4 | 5～20 |

前沿应用的前提技术积累。短时预报能够准确地为用户反馈附近降雨信息的前提是能够获取完整、干净的气象雷达降雨基数据，否则就会产生预报误差。因此只有快速、准确地对气象雷达基数据进行回波识别并去噪，才能进行信息推送、覆盖计算等任务。

目前，主流的图像语义分割网络模型包括全卷积神经网络(Fully Convolutional Neural Networks, FCNN), RefineNet, ShelfNet, DeepLab v1, DeepLab v2, DeepLab v3和Mask R-CNN等，这些方法在进行图像语义分割任务时可以对某一类特定物体或者人物头像直接进行分类标记，其应用对象多为空间复杂度相对较低的人物场景图像。而气象雷达图像具有特殊性，图像中每一个像素点对应的空间距离可能达到2～3 km，且由于气象雷达站数量众多(全国范围内超过170个基站)，每个基站受覆盖范围、地理位置和地形等因素影响会产生大量不同类型的真实回波和噪声回波。因此一般的图像处理方法已经不能很好地满足任务需求。本文在利用图像语义分割技术对气象雷达图像进行去噪处理时，通过深度卷积神经网络来完成对图像中每一个像素点的分类，这样由识别结果组成的图像就是一张全局像素标记图，可达到精细化图像分割的目的。

## 3　多通道跨层聚合深度卷积神经网络

### 3.1　网络结构

本文设计的多通道跨层聚合深度卷积神网络模型如图2所示，本模型主要由5个特征提取结构和跨层聚合模块构成。

在网络的前端设计中，受AlexNet网络[10]特征提取结构设计方式的启发，模型前端的5个特征提取结构设计方式与其相似。不同的是，AlexNet网络中的每一个特征提取结构只包含1个卷积层，采用的是7×7与5×5的大卷积核，大卷积核虽然能够提高对数据的感知区域，但同时也带来了参数冗余，特征爆炸等问题。而本文网络的5个特征提取结构中的所有卷积核均使用3×3的小型化结构，且每个特征提取结构包含2～3个卷积层；采用该种设计方式主要有两方面原因：

(1) AlexNet网络中的7×7全卷积核，可以被分解为3个3×3微卷积核作层序叠加，这样做可有效减少网络中的参数数量。因为7×7卷积核有49个参数，而3个3×3微卷积核只有27个参数，参数量接近减少到原来的1/2，可有效降低模型过拟合的风险，同时也可以提高训练速度。

(2) 深度学习的特征感知从本质上来说是一种线性关系到非线性关系的映射，这种映射由激活函

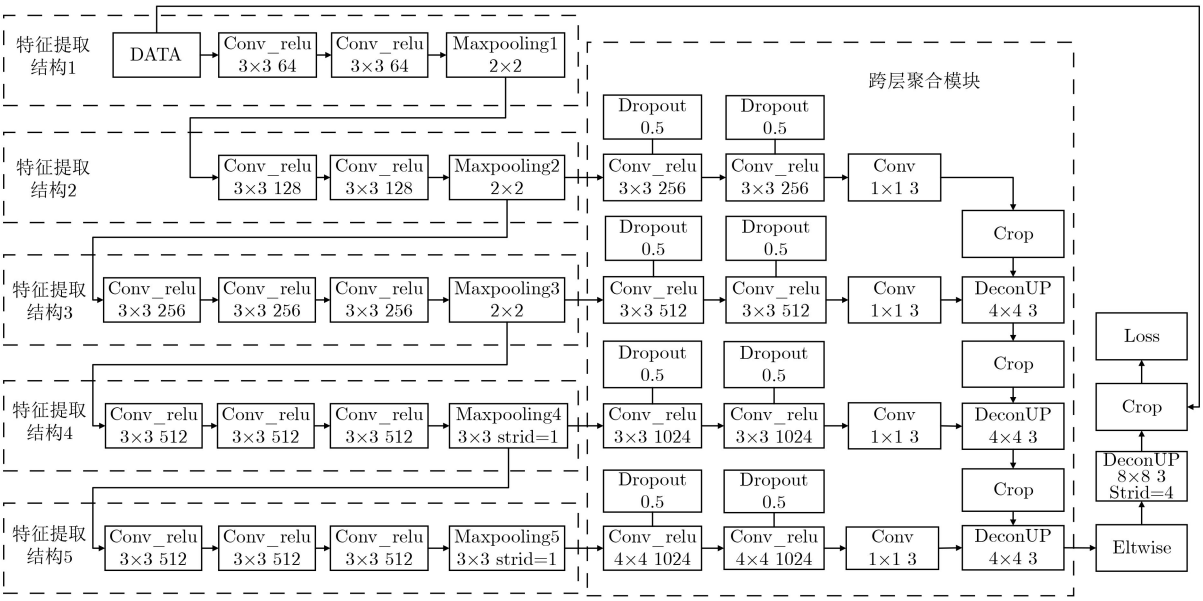


图 2 DCNNM的网络结构

数来完成。本文在使用多层小卷积核进行特征感知时，每一个卷积层后面都连接了一个ReLu激活层，这样做可以在使用更少的参数情况下感知到与AlexNet网络同样大小的视野区域，同时也能够抽取到更多的非线性关系。

在跨层聚合结构，将每次池化后的结果保存，然后进行单独的卷积训练，再使用反卷积技术将各层数据对齐同一维度后进行累加求和，最后统计模型训练损失值。同时为了避免DCNNM在训练过程中出现过拟合现象，使用Dropout[11]方法来稀疏神经元个数。

### 3.2 前向传播特征提取

在DCNNM的前向传播过程中，每一层网络的参数经过随机生成的卷积核进行特征提取，输出的结果经过激活函数进行非线性映射生成特征结果图作为下一层网络的输入数据。卷积运算的过程如式(1)所示

$$x_j^l = \psi\left(\sum_{i\in M_j} x_i^{l-1} w_{ij}^l + b_i^l\right) \tag{1}$$

其中，$x_j^l$表示每一个卷积层经过一个卷积核的处理得到的结果，$l$代表网络层数，$j$代表卷积核序号。$w$表示网络权重，$b$为偏置，$\Psi$为激活函数，本文采用Relu激活函数，公式表示如式(2)。

$$\mathrm{Relu}(y) = \begin{cases} y, & y > 0 \\ 0, & y \le 0 \end{cases} \tag{2}$$

在本文所提网络结构中，每隔几个卷积层就会进行一次池化处理，每一个卷积核输出的特征图都会经过池化层的下采样操作进行特征筛选，池化层的计算过程可用式(3)表示

$$X_j^l = \psi\left(w_j^l \mathrm{down}\left(x_j^{l-1}\right) + b_j^l\right) \tag{3}$$

其中，down($x$)表示对矩阵元素$x$的下采样操作，池化操作和普通的神经元计算类似，也有其权值$w_j^l$和偏置$b_j^l$。

### 3.3 反向传播模型优化

为使模型训练达到理想的收敛效果，使用Softmax函数计算网络输出的预测标记图与实际样对网络参数迭本标记图的对比误差值，然后利用误差值进行反向传播代更新，以便网络能够快速获取最优的权重和偏置，使网络的输出$y(x)$能够拟合所有的训练输入$x$。为了量化模型拟合程度，定义一个代价函数

$$C(w,b) = \frac{1}{2n}\sum_{x=1}^{n}\left\|\boldsymbol{y}^{(x)} - \boldsymbol{a}\right\|^2 \tag{4}$$

其中，$C$为代价函数，$w$表示所有网络中权重的集合，$b$是所有的偏置，$n$是训练输入数据的个数，$\boldsymbol{a}$表示当输入为$x$时输出的向量。由式(4)可知，代价函数$C(w,b)$是非负的，因此如果优化算法能够找到合适的权重和偏置，使得$C(w,b)\approx 0$，那么，对于所有的训练输入$x$, $\boldsymbol{y}(x)$接近于输出$\boldsymbol{a}$时，模型就能收敛到最优状态，因此训练算法的目的就是最小化权重和偏置的代价函数$C(w,b)$。

梯度下降是一个求函数最小值的算法，它的思想是随机选取一个参数组合$(w,b)$，计算代价函数$C$，然后寻找下一个能让代价函数值下降最多的参数组合，持续此过程，直到找出一组最优的参数组合，以获取$C(w,b)$的全局最小值(global minimum)。利用梯度下降算法来寻找使代价方程取得最小值的权重$w_k$和$b_l$，定义如式(5)和式(6)进行参数更新

$$w \to w_k{}' \equiv w_k - \eta\frac{\partial C}{\partial w_k} \tag{5}$$

$$b \to b_l^{'} \equiv b_l - \eta\frac{\partial C}{\partial b_l} \tag{6}$$

其中，$\eta$为学习率，偏导数$\partial C/\theta w_k$和$\partial C/\theta b_l$表示任意权重和任意偏置的变化率。

## 4 数据集获取及数据预处理

### 4.1 数据采集及人工标注

本文DCNNM所用的训练和测试数据来自于手工标注的MJDATA数据集。该数据集主要抽取来自2016年5月—10月这个降水分布较多的时间段内的气象雷达数据，站点范围覆盖全国170多个气象雷达站，噪生样本的获取方式是抽取同一时段内5个不同时刻的雷达图像作为数据储备，例如在t, t+6, t+12, t+18, t+24和t+30, t+36, t+42, t+48, t+54两个时间段内每隔6 min抽取1张图像，分别连续抽取5张图像。同时为了使样本抽取的均匀性得到保证，本文从每个雷达基站抽取45张图像。由于受气象雷达站本身覆盖范围的影响，该数据集包含两种不同像素大小的图像，分别为477×477和509×509。

对气象雷达图像的标注规则和数据集的样本比例分配的设置规则如下：

首先，对气象雷达图像中的每一个像素进行手工标记，其中，图像的所有背景信息被标注为0，噪声被标注为128，真实回波(降雨信息)被标注为255，数据集共包含7473张人工标注图像。

其次，考虑到每个气象雷达站图像样本的特殊性，在从每个气象雷达站抽取样本数据时按照训练集和测试集4:1的比例进行筛选，最后总训练集中

包含6077张样本图像，总测试集中包含1396张样本图像，符合网络训练的数据分配标准。

手工对原始气象雷达回波进行标注后的效果如图3所示，其中，绿色部分为噪声，红色部分为真实回波。原始气象雷达回波图经过灰度映射后的效果如图4所示。为提高可视化效果，对两张图像均进行彩色映射。

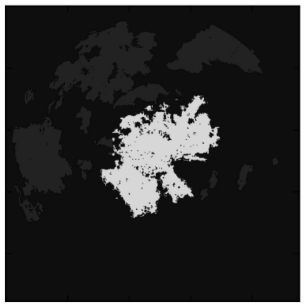

图 3 手工标注的气象雷达回波图

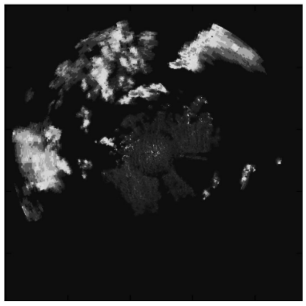

图 4 灰度映射后的气象雷达回波图

### 4.2 数据预处理

(1) 添加空间信息

由于气象雷达回波图像的空间复杂度较高，为了使DCNNM能够更好地感知气象雷达数据的空间坐标信息，增强其对不同特征之间关联信息的提取能力。本文对手工标注后的图像额外添加1维空间信息，通过实验验证了采用该处理方式后，DCNNM对噪声回波和真实回波的识别准确率分别提高了近3%。图5是添加空间信息后气象雷达图像的可视化效果。气象雷达图中的许多噪声样本都处于图像的中心位置，而气象雷达的扫描范围也是以中心为坐标基准。本文在每张图像的中心到边缘区域从0开始做序列递增，这样产生的图像就是由中心到边缘，数值不断变大的灰度图像，在此情况下，DCNNM可以更准确地感知真实回波在空间上的移动规律。

(2) 图像切割

在深度学习领域，数据集大小和网络参数数量是影响网络模型训练效果和收敛速度的两个关键因素。虽然本文使用的MJDATA数据集提供了超过

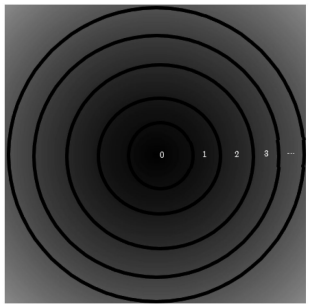


图 5 添加空间信息后图像的可视化结果

7000张的手工标注图像，但是对于DCNNM的训练任务来说，仍不能很好地满足需求。此外，MJDATA数据集中包含大小为477×477×3和509×509×3的图像，两者的参数训练量分别超过了$6.8\times10^5$和$7.7\times10^5$，这极大地增加了网络训练的复杂度，因此必须减少输入数据维度。传统的图像缩放[12,13]方式虽然能够解决这一问题，但气象雷达数据对空间信息的依赖性极强，对图像直接缩放会破坏其空间结构，损失大量原始噪声信息。相比较于图像缩放的方式，采用图像切割操作对图像中的真实回波与噪声回波的局部空间位置对应关系产生的影响更小。

利用(1)中处理好的MJDATA数据集，对气象雷达图像进行切割操作。将数据集中大小为477×477×3和509×509×3的图像集合统一切割成384×384×3大小的图像，切割操作主要包括以下两个步骤：

步骤 1　固定区域，随机切割。对MJDATA数据集中每张图像的20个384×384×3区域进行随机切割，将数据集扩充到原来的20倍；

步骤 2　图像筛选。经过步骤1的图像随机切割处理，数据集中会出现许多拥有较少或者几乎不存在真实回波与噪声回波信息的图像，这些图像对模型训练没有正向反馈作用，因此在经过筛选后，图像数量减少到步骤1的1/2，约为74730张。

## 5　实验与结果

### 5.1 实验环境和网络训练参数设置

本文算法的实现在Ubuntu16.04系统上进行，由深度学习库Caffe[14]实现，Caffe提供了完善的python接口供开发者使用，方便快捷。在模型训练时使用NVIDIA Tesla K40m GPU加速器进行并行计算加速，以提高模型运算效率。模型训练参数设置如表2所示。

此外，每进行10批次训练统计一次训练误差，每进行200批次测试统计一次测试误差。

### 5.2 评估标准

在对模型的去噪效果建立评估标准之前，基于

手工标注的结果与机器去噪后的标注结果建立了气象雷达图像去噪效果交叉验证取值表，如表3所示。

表 2 模型训练参数设置

| 训练参数 | 参数取值 |
|---|---|
| 网络学习率 | $10^{-8}$ |
| 权重衰减系数 | 0.001 |
| momentum系数 | 0.91 |
| 感知屏蔽数量 | 0.5 |
| 批处理大小 | 4 |
| 网络最大迭代次数 | 10000 |

表 3 气象雷达图像去噪效果交叉验证取值表

| 像素点 | 255 | 128 |
|---|---|---|
| 255 | A手工标注为降雨的像素点，并且机器去噪也标注为降雨的像素点 | B手工标注为噪声的像素点，但是机器去噪标注为降雨的像素点 |
| 128 | C手工标注为降雨的像素点，但是机器去噪标注为噪声的像素点 | D手工标注为噪声的像素点，并且机器去噪也标注为噪声的像素点 |

本文以DCNNM对真实回波识别准确率(True Echo Recognition ACCuracy, TERACC)和对噪声回波识别准确率(Noise Echo Recognition ACCuracy, NERACC)以及像素精度(Pixel Accuracy, PA)3类指标来评估图像的去噪效果。其中，

真实回波识别准确率：TERACC=A/(A+B)

噪声回波识别准确率：NERACC=D/(C+D)

像素精度：PA=A+D/(A+B+C+D)

### 5.3 实验设计

为验证本文网络模型设计的合理性和有效性，设置了3组对比实验，具体设置如下：

**实验1** 在MJDATA数据集的数据量达到5000张图像时，利用DCNNM进行模型训练得到一个网络模型Model1，然后通过该模型进行了测试实验，最后根据测试结果计算各评价指标值。

**实验2** 在MJDATA数据集的数据量达到5000张图像时，使用传统的光流法[15]、全卷积网络(Fully Convolutional Networks, FCN)[16]和光流法+FCN3种方法，分别进行模型训练和样本测试，并根据测试结果分别计算各评价指标值，然后进行对比分析。

**实验3** 在MJDATA数据集的数据量达到7473张图像时，使用DCNNM进行模型训练得到一个网络模型Model2，并使用该模型进行测试实验；然后分别使用DeepLab v3[17], ShelfNet[18]和Mask R-CNN[19]3类网络模型分别进行训练和测试，最后根据这4类模型的测试结果计算各评估指标值并进行对比分析。

### 5.4 实验结果

通过对5.3节中实验1与实验2测试结果进行统计，4类方法的评估指标结果如表4所示。

表 4 4类模型测试效果对比(%)

| 数据集 | 方法 | TERACC | NERACC | PA |
|---|---|---|---|---|
| MJDATA (5000) | 光流法 | 88.21 | 59.03 | 73.39 |
| | FCN | 91.68 | 79.61 | 85.43 |
| | 光流法+FCN | 92.60 | 73.91 | 78.17 |
| | Model1 | 93.65 | 81.65 | 96.75 |

由表4可知，当MJDATA数据集的数据量为5000时，Model1对真实回波、噪声回波的识别准确率和像素精度明显优于其它3类方法，这表明将DCNNM应用于气象雷达图像语义分割任务中是一种切实可行的方案，且实验效果良好。

MJDATA(5000)数据集在后期不断增加新的纯噪声样本和多噪声样本，数据量扩充到7473张图像。如表5所示，显示了4类模型在MJDATA(7473)数据集上测试后的评估指标值。

表 5 4类模型测试效果对比(%)

| 数据集 | 方法 | TERACC | NERACC | PA |
|---|---|---|---|---|
| MJDATA (7473) | DeepLab v3 | 88.57 | 81.65 | 91.75 |
| | ShelfNet | 86.92 | 84.34 | 90.51 |
| | Mask R-CNN | 89.66 | 85.20 | 93.63 |
| | Model2 | 90.40 | 84.36 | 92.79 |

通过对表4和表5中Model1和Model2的测试结果分析可知，在扩充了样本训练量后，随着数据量的增加，Model2在MJDATA(7473)数据集上对真实回波识别的准确率与像素精度低于Model1在MJDATA(5000)上测试的评估值，但是对噪声回波的识别准确率高于后者，这可能是由于在后期添加的数据样本中，大量的纯噪声样本和多噪声样本影响了测试模型对真实样本和噪声样本的识别效果。

由表5的测试结果可知，Model2对真实回波的识别准确率高于其它3类模型，对噪声回波的识别准确率和像素精度略低于Mask R-CNN，但高于DeepLab v3和ShelfNet，这说明本文方法在进行气象雷达图像语义分割任务时拥有较好的处理效果，这主要是因为本文的DCNNM采用独特的网络结构设计方式，虽然网络结构较为复杂，网络深度较深(卷积层数达到25层)，但能够对MJDATA数据集中拥有高维复杂空间结构特征的图像进行有效的特

征提取；而DeepLab v3, ShelfNet和Mask R-CNN3类模型由于网络深度较浅，且其应用对象是空间复杂度较低的图像，所以相比之下本文方法对气象雷达图像拥有更好的语义分分割效果。

图6显示了在同一数据集MJDATA(7473)上，各类方法在完成训练和测试过程后实际运行时间的对比结果。

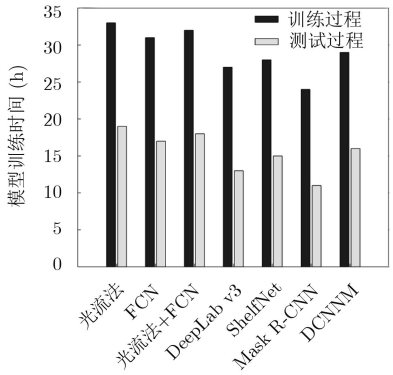


图 6 各类模型训练和测试时间的对比结果

由图6可知，DCNNM相比较于传统的光流法、FCN和光流法+FCN3类方法的训练和测试时间更短；与主流的DeepLab v3, ShelfNet和Mask R-CNN3类方法相比，训练和测试时间更长，这是因为DCNNM虽然采用了小卷积核，减少了参数训练量，但网络层数较多，特征提取过程较为详细，所以在时间效率上不占优势，但图像语义分割效果相比较于其它方法具有明显优势。

图7是对两个相邻气象雷达基站(分别是北京大兴站与河北沧州站)的原始回波图像进行灰度处理

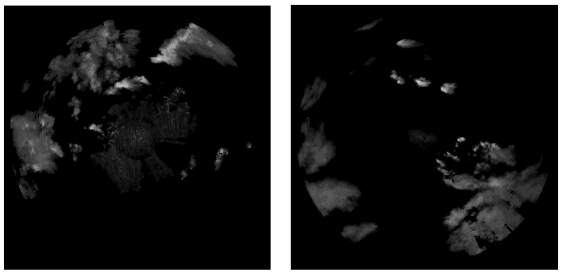

图 7 经过灰度处理的气象雷达图

后的效果图，其处理目的是为了使DCNNM更好地适应图像的像素灰度变化。

图8显示了本文方法与DeepLab v3, ShelfNet和Mask R-CNN3类方法在MJDATA(7473)数据集上测试后的语义分割效果对比图。

由图7和图8处理前后的对比效果可知，原始气象雷达噪声图像经过DCNNM处理后，真实回波区域与噪声回波区域被精细化分割，达到了良好的图像去噪效果。与其它3类方法相比，本文方法的语义分割效果最好，对不同灰度区域不存在误分割的情形。

## 6　结束语

为了解决多普勒气象雷达图像噪声对精细化短时气象预报准确率产生的消极影响，本文以图像语义分割技术为基础，将深度学习技术应用到气象雷达图像去噪任务中，提出一种基于深度卷积神经网络的气象雷达噪声图像语义分割方法。本文的DCNNM采用了多通道跨层聚合的网络结构设计方式，在进行特征提取任务时，DCNNM可以将图像中的高维特征信息与低维特征信息进行融合，在保

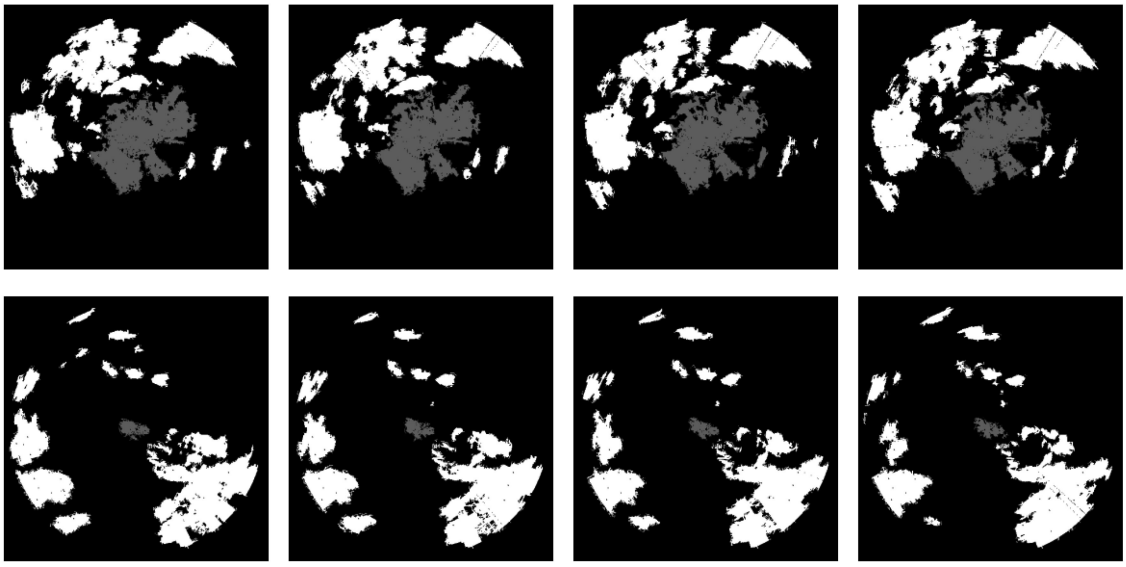

(a) 基于本文方法　(b) 基于DeepLabv3　(c) 基于ShelfNet　(d) Mask R-CNN

图 8 气象雷达图像语义分割效果对比

留高维全局语义信息的情况下也不会损失局部的特征细节，有效提升了图像语义分割的准确度。在手工标注的MJDATA数据集上对该算法进行训练和测试，获得了较好的实验效果，证明了深度学习应用于气象雷达图像去噪任务中的技术可行性和有效性。

未来，对基于深度卷积神经网络的气象雷达噪声图像语义分割方法的优化研究重点包括以下两方面：(1)对DCNNM网络结构进行优化，例如增加网络层数，修改连接方式等方法，在此基础上改进算法。(2)增加数据样本，通过训练增强DCNNM的适应范围，提升模型的泛化能力。

## 参 考 文 献


[1] 杨植宗. 多普勒效应与多普勒雷达[J]. 物理通报, 2003(2): 47–48. doi: 10.3969/j.issn.0509-4038.2003.02.027.
YANG Zhizong. Doppler effect and Doppler radar[J]. *Physics Bulletin*, 2003(2): 47–48. doi: 10.3969/j.issn.0509-4038.2003.02.027.

[2] NAGAYAMA S, MURAMATSU S, YAMADA H, *et al*. Millimeter wave radar image denoising with complex nonseparable oversampled lapped transform[C]. 2017 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC), Kuala Lumpur, Malaysia, 2017: 1824–1829. doi: 10.1109/apsipa.2017.8282330.

[3] WU Peng, XU Hongling, and XIE Pengcheng. Research on ground penetrating radar image denoising using nonsubsampled contourlet transform and adaptive threshold algorithm[J]. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 2016, 9(5): 219–228. doi: 10.14257/ijsip.2016.9.5.19.

[4] MASTRIANI M. Denoising based on wavelets and deblurring via self-organizing map for Synthetic Aperture Radar images[J]. *International Scholarly and Scientific Research & Innovation*, 2008, 2(9): 2073–2082.

[5] 王俊, 杨成龙. 结合小波分析和变分原理的雷达图像去噪模型[J]. 指挥控制与仿真, 2017, 39(5): 41–44. doi: 10.3969/j.issn.1673-3819.2017.05.009.
WANG Jun and YANG Chenglong. Radar image denoising model based on wavelet analysis and variation principle[J]. *Command Control & Simulation*, 2017, 39(5): 41–44. doi: 10.3969/j.issn.1673-3819.2017.05.009.

[6] CHEN Chong and XU Zengbo. Aerial-image denoising based on convolutional neural network with multi-scale residual learning approach[J]. *Information*, 2018, 9(7): 169. doi: 10.3390/info9070169.

[7] 董晓亚, 赵晓丽, 张嘉祺. 一种改进的噪声图像语义分割方法[J]. 光电子·激光, 2017, 28(12): 1372–1377. doi: 10.16136/j.joel.2017.12.0103.
DONG Xiaoya, ZHAO Xiaoli, and ZHANG Jiaqi. An improved semantic segmentation method for noisy image[J]. *Journal of Optoelectronics·Laser*, 2017, 28(12): 1372–1377. doi: 10.16136/j.joel.2017.12.0103.

[8] CHEN L C, PAPANDREOU G, KOKKINOS I, *et al*. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834–848. doi: 10.1109/TPAMI.2017.2699184.

[9] CHEN L C, PAPANDREOU G, KOKKINOS I, *et al*. Semantic image segmentation with deep convolutional nets and fully connected CRFs[C]. International Conference on Learning Representations, San Diego, USA, 2015.

[10] KRIZHEVSKY A, SUTSKEVER I, and HINTON G E. ImageNet classification with deep convolutional neural networks[C]. The 25th International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2012: 1097–1105. doi: 10.1145/3065386.

[11] ACHILLE A and SOATTO S. Information dropout: Learning optimal representations through noisy computation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(12): 2897–2905. doi: 10.1109/TPAMI.2017.2784440.

[12] 郭正红, 张俊华, 郭晓鹏, 等. 结合视觉显著图的Seam Carving图像缩放方法[J]. 云南大学学报: 自然科学版, 2018, 40(2): 222–227.
GUO Zhenghong, ZHANG Junhua, GUO Xiaopeng, *et al*. Seam Carving image scaling method with visual significant graph[J]. *Journal of Yunnan University: Natural Sciences Edition*, 2018, 40(2): 222–227.

[13] 岳鑫, 肖晨. 基于奇异值分解和双三次插值的图像缩放算法改进[J]. 西安邮电大学学报, 2018, 23(4): 72–77. doi: 10.13682/j.issn.2095-6533.2018.04.012.
YUE Xin and XIAO Chen. Improvement of image scaling algorithm based on singular value decomposition and bicubic interpolation[J]. *Journal of Xi'an University of Posts and Telecommunications*, 2018, 23(4): 72–77. doi: 10.13682/j.issn.2095-6533.2018.04.012.

[14] KOMAR M, YAKOBCHUK P, GOLOVKO V, *et al*. Deep neural network for image recognition based on the Caffe framework[C]. The Second IEEE International Conference on Data Stream Mining & Processing (DSMP), Lviv, Ukraine, 2018: 102–106. doi: 10.1109/DSMP.2018.8478621.

[15] DOSOVITSKIY A, FISCHER P, ILG E, *et al*. FlowNet: Learning optical flow with convolutional networks[C]. IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015: 2758–2766. doi: 10.1109/ICCV.

2015.316.

[16] LONG J, SHELHAMER E, and DARRELL T. Fully convolutional networks for semantic segmentation[C]. The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, USA, 2015: 3431–3440. doi: 10.1109/CVPR.2015.7298965.

[17] CHEN L C, PAPANDREOU G, SCHROFF F, *et al.* Rethinking atrous convolution for semantic image segmentation[EB/OL]. https://arxiv.org/abs/1706.05587, 2017.

[18] ZHUANG Juntang and YANG Junlin. ShelfNet for real-time semantic segmentation[EB/OL]. https://arxiv.org/abs/1811.11254v1, 2018.

[19] HE Kaiming, GKIOXARI G, DOLLÁR P, *et al.* Mask R-CNN[C]. 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2017: 2980–2988. doi: 10.1109/ICCV.2017.322.

杨宏宇：男，1969年生，博士，教授，研究方向为网络信息安全、图像处理.

王峰岩：男，1993年生，硕士生，研究方向为网络信息安全、图像处理.