

文章编号: 2096-1618(2024)01-0043-07

一种基于深度卷积神经网络的电磁干扰识别与抑制方法

王家珉¹, 李田家², 顾桃峰³, 张玉琴¹, 全晶¹, 王海江¹

(1. 成都信息工程大学电子工程学院, 四川 成都 610225; 2. 新疆和田地区气象局, 新疆 和田 848000; 3. 广州市突发事件预警信息发布中心, 广州 511430)

摘要:随着无线电通信技术的发展,人工无线电对气象雷达的电磁干扰(EMI)明显增加,对雷达数据的质量产生严重影响。目前,关于检测和抑制电磁干扰的研究大多是基于雷达的初级产品。从雷达接收机前端的I/Q数据出发,提出使用深度卷积神经网络来识别和抑制电磁干扰的方法。设计一种残差结构的全卷积网络,并且选择UNet和DeepLab V3+共同进行识别效果的对比,在识别之后使用线性插值方法对电磁干扰进行抑制。结果显示,3种模型都能有效地识别电磁干扰,并且在识别的准确率和召回率上各有优劣。在对识别结果进行抑制后,使得雷达数据质量都得到明显的提高。

关键词:深度神经网络;语义分割;电磁干扰;质量控制

中图分类号:TN959.4

文献标志码:A

doi:10.16836/j.cnki.jcuit.2024.01.008

0 引言

近年来,随着无线通信技术的发展,使通信频段的覆盖范围变广,用于无线通信的基站和电子设备数量增加,导致人工无线电对天气雷达的电磁干扰显著增加。Vaccarone等^[1]提出因电信系统的某些频段与C波段(4~8 GHz)天气雷达的工作频段重合,对雷达数据的质量造成严重影响。并且在S波段(2~4 GHz)也因无线通信行业对其中某些波段进行利用,形成电磁干扰对雷达产生影响。

电磁干扰对天气雷达的数据质量影响日益加重,因此对电磁干扰的识别和消除成为天气雷达质量控制的一项重要工作。Cho^[3]提出通过频谱检测异常增量达到抑制干扰的目的;Jiapeng Yin等^[4]提出移动双光谱线性去极化比(MDsLDR)滤波器用于减轻天气雷达中窄带混乱,包括电磁干扰;V Lakshmanan等^[5]从雷达回波上出发,通过神经网络对反射率、速度、速度谱宽等数据的处理得到非天气回波的特征进而识别和处理。

而雷达接收机的信号处理端中的I/Q数据中也包含散射粒子的静态和运动信息,因此对I/Q数据进行处理也会影响到回波数据的质量。但目前在I/Q数据上对电磁干扰的识别和抑制方法较为简单,通常是使用单脉冲异常检测滤波器对电磁干扰进行检测,然后把已经标记的脉冲用相邻脉冲值^[5]的插值结果替换^[6]。但是在I/Q数据中,电磁干扰可能只存在于一个脉冲上,也可能以相似的特征不断重复存在于多个连续的脉冲上,即有部分电磁干扰具有空间特征。原

有的方法均是在单独的脉冲上进行识别,对于识别具有二维特征的电磁干扰没有优势,所以使用有能力识别空间信息的算法识别电磁干扰相较于仅从单个脉冲上进行识别的模型更加有效。

受在计算机视觉上应用深度卷积神经网络(DCNN)的启发,将着重研究使用DCNN对I/Q数据中的电磁干扰和其他信号进行语义分割的可行性,并在分割的基础上进行抑制。

1 相关工作

目前已经证明以端到端的DCNN对于目标检测与图像分类已取得非常好的效果,因为有卷积-池化的过程。该过程能够通过训练有效捕获图像中空间信息和深度信息,比如经典的卷积神经网络VGG^[7], AlexNet^[8]等,它们都能够很好地完成图像分类和目标识别的工作。这是因为它们的结构普遍是在网络的前几层采用卷积-池化的操作,最终输出的分类器是一个向量,所以不得不把最终通过卷积-池化得到的特征进一步转化为一维的全连接层。这种方式不利于在I/Q数据上判断具体的某个距离库上存在电磁干扰,因为从卷积转化到全连接过程中会损失空间信息,对于需要获取空间信息的电磁干扰识别工作则失去了意义。

Jonathan Long等^[9]提出全卷积网络(FCN),将卷积网络中原有的全连接层转换为卷积层。相较于经典的卷积神经网络,由全连接层组成DCNN避免了在卷积层到全连接层的转换过程中损失特征图的二维信息,全卷积网络的出现开辟了语义分割的新方向。然

而,Chen 等^[10]认为在卷积神经网络中,需要不断通过卷积-池化来提取特征,其中池化的目的就是增加感受野,但会导致分辨率的降低。因此不断重复卷积-池化的过程,会导致信号的下采样、信息会不可避免地损失,对于分类任务来说没有任何影响,但是对于语义分割工作下采样过程限制了定位的精度,难以捕捉目标的精细特征。所以,Chen 等^[11]提出通过空洞卷积法来改进卷积-池化的过程。空洞卷积在原有卷积核的基础上进行隔行和隔列的扩张,在原有卷积计算量相同的基础上扩大了卷积核的覆盖面积以增加感受野,且保持像素的相对空间位置不变。当多个带有不同扩张率空洞卷积核叠加时,不同的感受野就会带来多尺度信息。这些观点对于电磁干扰的识别任务非常重要,另外在识别之后,本文还对电磁干扰进行抑制,以达到质量控制的目的。

2 方法

2.1 回波参数估计

在 I/Q 数据中包含散射粒子的静态和运动的信息,然而对 DCNN 进行训练的数据选用的是功率数据,所以首先需要将 I/Q 数据进行回波参数估计,得到功率谱数据后再进行下一步的工作。本文采用的方法是脉冲对处理算法(PPP),相较于 FFT 算法,PPP 算法的速度更快,且对计算机硬件的要求更低。另外,设一个脉冲上采样点数为 N ,第 n 个距离库为 $x_N(n)$,则通过零延迟自相关函数可以得信号的功率谱密度^[12]:

$$r(0) = \frac{1}{N} \sum_{n=0}^{N-1} x_N^*(n) x_N(n) \quad (1)$$

2.2 在 I/Q 数据中进行语义分割工作

电磁干扰识别模型的建立像全卷积网络一样需要设计一个编码器,先对回波参数估计后的 I/Q 数据进行多次卷积与池化的操作。该过程用于提取信号中电磁干扰和其他信号的特征;再设计一个解码器,进行上采样的工作(反卷积或者是插值),将编码器得到的特征图以一定方式进行扩充,使解码器输出尺寸与输入相同。最终通过 softmax 层输出预测的结果。

ResNet 在计算机视觉工作中取得的巨大成功^[13],所以本文借鉴残差结构,将其应用在全卷积网络中作为编码器,用于加深网络深度,进行下采样工作。在解码器中,结合 UNet 的结构传递提取完毕的特征图^[14]进行上采样,上采样的方式是对特征图进行多次反卷积,当达到和输入相同尺寸后再经过 softmax 层输出得到结果。

与此同时,讨论另外两种现有的语义分割网络结构 UNet 和 Deeplab V3+在电磁干扰识别工作中的可用性。其中,Deeplab V3+为编码器-解码器结构^[15],与 UNet^[15]和本文所采用残差结构的网络有所不同。首先 Deeplab V3+使用的主干网络为 Xception^[16]。相较于前者,参数量更少,模型更加轻量,深度更深。而编码器中采用的是空洞空间卷积池化金字塔模块(ASPP)提取特征。基本结构就是通过选取多种不同扩张率的空洞卷积对目标同时进行采样,再将采样结果进行堆叠,这样就结合了多尺度信息。与此同时对每个采样过程都加入 Batch Normalization 的操作对数据归一化。使用这种结构提取特征代替卷积-池化的过程能够有效保留大部分信息^[18],可能对于细小的电磁干扰更具有优势。在解码器中,Deeplab V3+直接将特征图经过 softmax 层输出,再进行双线性插值得到和输入相同尺寸的结果。

2.3 评估模型

本文主要对比的评估结果是 Precision 和 Recall。其中 Precision 相比于 Recall 更加重要。因为如果把存在电磁干扰的距离库预测为正常回波的距离库,那么不会进行抑制处理,虽然不能改进数据质量,但是也不会影响后续产品的生成;若把正常回波的距离库预测为存在电磁干扰的距离库,那么把正常回波进行抑制,会对最终产品中某些重要气象回波的识别造成严重影响。

2.4 制作数据集

数据集的制作过程分为两个部分。首先通过程序自动化批量处理,主要步骤是单位转换,标准化,边缘增强,生成可视化标签。在自动化批量处理结束后还需人工制作标签。

因为回波参数估计得到原始功率数据数值跨度很大,需要将原始功率数据 P_{source} 单位转化为 dB。单位转换后的数据 P 作为网络的输入并且辅助制作标签时功率可视化:

$$P = 10 \lg P_{\text{source}} \quad (2)$$

在标准化步骤中,将功率数据 P 标准化到 0 ~ 255。这一步骤是将功率谱数据转化为灰度图像,灰度图像仅用于数据的可视化,方便人工订正以及制作训练数据的标签。

$$P_{\text{norm}} = (P - P_{\text{max}}) / (P_{\text{max}} - P_{\text{min}}) \times 255 \quad (3)$$

其中 P_{max} 是功率谱数据 P 中的最大值, P_{min} 是 P 中的最小值。

边缘增强的目的是使存在电磁干扰的距离库更加清晰。 G_x 和 G_y 分别是存在回波的距离库和不存在回波的距离库的水平方向和垂直方向上的边缘,通过用

检测水平和垂直边缘的 Sobel 算子对归一化后的功率谱数据卷积得到的。计算过程^[18]如下:

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \times P_{\text{norm}} \quad (4)$$

$$G_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \times P_{\text{norm}} \quad (5)$$

水平方向和垂直方向的边缘可合并为 G ; 最后将边缘 G 与归一化功率谱数据 P_{norm} 相结合得到边缘增强后的数据 P_{process} :

$$G = \sqrt{G_x^2 + G_y^2} \quad (6)$$

$$P_{\text{process}} = G + P_{\text{norm}} \quad (7)$$

提取边缘后,进行二值化。用于二值化的阈值是通过手动调节的,而阈值保留电磁干扰特征的同时又去除大部分的底噪。通过二值化后,即可将电磁干扰和其他天气回波从背景中分离出来。

自动化批量处理数据后,人工识别电磁干扰和天气回波。在二值化结果的帮助下,可以直接将边缘增强后的功率数据 P_{process} 的灰度值改变为训练标签。将有存在电磁干扰的距离库的位置灰度值设为 1,表示是“电磁干扰”;将有天气回波和背景的距离库的位置灰度值设为 0,表示是“其他信号”。训练集与测试集的划分比例为 8:2。

2.5 抑制电磁干扰

在模型预测后抑制电磁干扰,根据模型预测得到的结果命名为 P_{predicte} ,可看作正常回波与电磁干扰的具体位置分布,在相同距离下的各脉冲之间遍历 P_{predicte} ,当读取到预测结果为电磁干扰的标签时,在该位置标记为 N1,并且继续往下遍历,当读取到正常回波标签时该位置上标记为 N2,那么 N1 ~ (N2-1) 的距离库则存在电磁干扰,需要对其进行插值和替换。在 I/Q 数据中分别读取与 N1 相同位置的距离库的值为 V1, N2 位置的值为 V2,进行线性插值,最后在 I/Q 数据中将 N1 ~ (N2-1) 的距离库设为插值结果,则完成了各脉冲之间同一个距离上的电磁干扰的抑制。不断地对所有距离遍历 P_{predicte} 重复插值,完成功率数据中电磁干扰的抑制。

3 实验流程

3.1 数据的切割

本文使用的 I/Q 数据较大,由于计算机显存限制,无法直接将数据带入训练和预测,所以需要将 I/Q 数

据与其对应的标签进行切割。切割数据的大小为 512 个脉冲×512 个距离库,切割方式下如下。

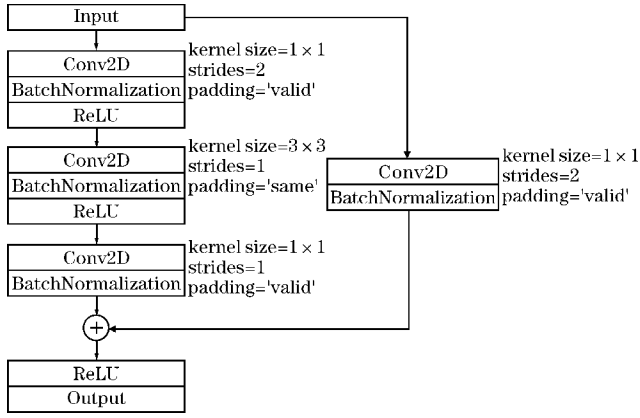
设原有的功率谱数据一个脉冲中有 w 个距离库,共有 h 个脉冲,那么功率谱数据的尺寸则为 $w \times h$,在切割后得到的数据尺寸可设为 $w_{\text{cut}} \times h_{\text{cut}}$ 。相应地,模型的输入和输出尺寸也应为 $w_{\text{cut}} \times h_{\text{cut}}$ 。所以需要将功率谱数据先取 h_{cut} 个脉冲,按照 w_{cut} 个距离库的长度进行切割;切割完毕后,再向下平移 h_{cut} 个脉冲重复切割流程,并且在切割的过程中需要记录切割的顺序。另外,在切割时可能存在 w 或 h 不是 w_{cut} 或 h_{cut} 的整数倍情况,会得到部分切割数据的距离库数或脉冲数不到 w_{cut} 和 h_{cut} 情况。因此,在模型训练过程中,当数据大小与 $w_{\text{cut}} \times h_{\text{cut}}$ 不匹配时,功率谱数据和标签将被插值,其大小将被扩大到训练前的 $w_{\text{cut}} \times h_{\text{cut}}$ 。在模型预测工作中,当输入尺寸与 $w_{\text{cut}} \times h_{\text{cut}}$ 不一致时,仍按前面的步骤对输入数据进行尺寸扩展,但需要将模型的预测结果压缩到原始输入数据尺寸的大小。将模型的预测结果按记录顺序拼接后,得到的最终预测结果与原始功率谱数据的大小相同。

另外,不同的切割尺寸也会影响模型的识别精度。虽然每个脉冲存在的电磁干扰的尺寸不大,但每个脉冲存在气象回波的距离库是连续的,数量也很大。当切割得到的数据尺寸小于天气回波的尺寸时,DCNN 模型就无法学习到真正的天气回波特征,从而影响精度。因此,切割数据中的宽度 w_{cut} 的大小必须远远大于每个单独脉冲中带有天气回波的距离库的数量。

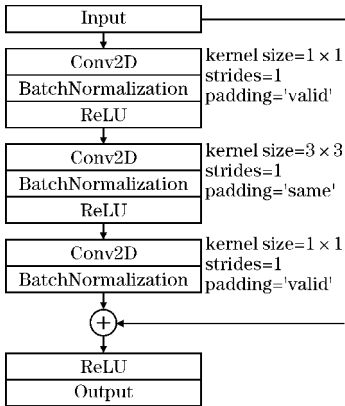
3.2 模型结构

本文将着重描述利用 ResNet50 的残差结构改造全卷积网络,用于语义分割存在电磁干扰的距离库的过程。

下采样过程的主要特点是能够将网络表层特征数据直接跳跃连接到深层,能够有效解决 DCNN 过深导致的梯度消失问题,提高准确率。主要分为 5 个阶段,每个阶段都可以看作由两个模块构成,分别是 Conv Block 和 Identity Block。两个模块的结构如图 1 所示,Conv Block 能够改变输入的维度。首先通过 1×1 的卷积核压缩模块输入的通道数,通过 3×3 的卷积核改变模块输入尺寸。再通过 1×1 的卷积核改变模块输出的输出通道数。另外输入还要通过 3×3 的卷积核得到残差边与输出堆叠。而 Identity Block 用于加深网络。通过 1×1 的卷积核压缩模块输入的通道数,随后通过 3×3 的卷积核进行卷积,但 padding 方式为 same,所以保持卷积之后的特征图尺寸不变。再通过 1×1 的卷积核改变输出通道数进行输出,另外输入还要直接与输出再进行结合。



(a) Conv Block 模块结构



(b) Identity Block 模块结构

图1 残差模块

将 ResNet50 的残差结构改进得到的电磁干扰语义分割网络结构如图2所示。网络的上采样过程借鉴 UNet 结构的思路,将每一次下采样得到的特征图都参与上采样的过程中。在编码器中,首先将输入进行 7×7 的卷积,改变输入尺度,保留特征图 Feat1。后续借助残差结构下采样的每一个阶段结束则得到对应的特征图,所以当编码器流程结束后总共会得到 5 张特征图:Feat1, Feat2, Feat3, Feat4, Feat5。在解码器中,首先将 Feat5 长宽各进行两倍的上采样,再与 Feat4 拼接。通过两次卷积改变通道数,得到的结果与 Feat5 一样长宽各进行两倍的上采样。再分别与 Feat3, Feat2, Feat1 以相同的步骤进行拼接和上采样。经过 5 次残差模块的下采样和上采样后,再通过 softmax 层进行输出得到预测结果。

3.3 学习率的调整

本文在 3 种模型中均采用动态调整学习率的方法,这种方法能够根据训练步长动态调整学习率的方法帮助模型在加快收敛的同时也能够跳出局部最优解。采用动态调整学习率的方法是 Cosine Annealing Warm Restarts^[19],该方法共分为 warm up 和 cosine annealing 两个阶段。每完成一次 epoch 则表示完成一次

步长,需要动态调整一次学习率,记录当前进行的步长为 S ,训练过程需要总步数设为 S_{total} 。

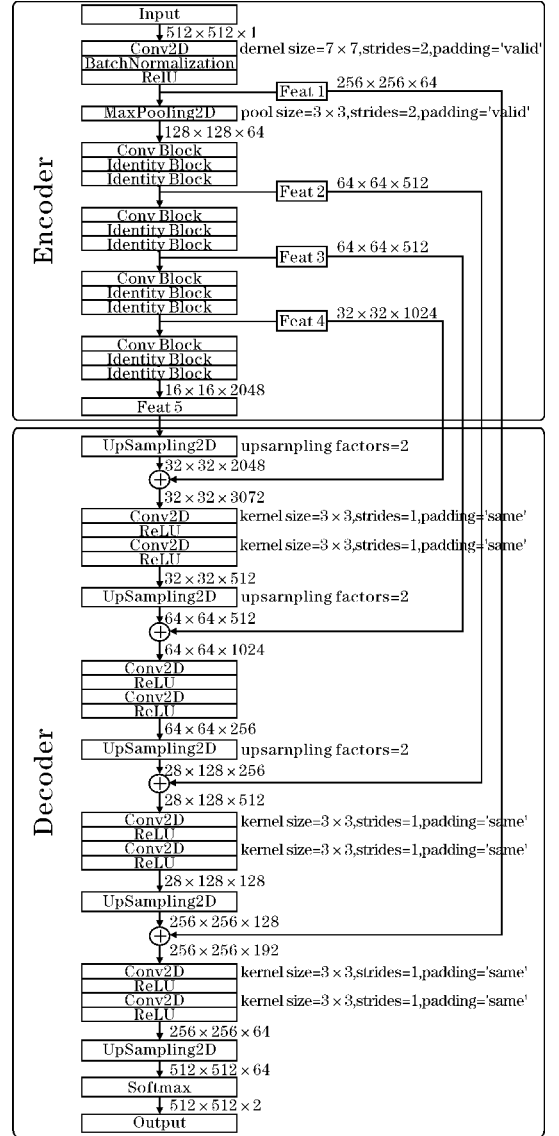


图2 采用残差结构的电磁干扰识别模型

Warm up 阶段是一个线性增长的过程,这一过程中学习率需要在固定步长 $S_{\text{warm_up}}$ 之内以一定的线性关系进行增长,设刚开始训练时学习率初始值为 lr_{init} ,最终期望得到学习率为 lr_{base} ,则:

$$lr_{\text{warm_up}} = [(lr_{\text{base}} - lr_{\text{init}}) / S_{\text{warm_up}}] \times S + lr_{\text{init}} \quad (8)$$

当 $S > S_{\text{warm_up}}$ 时则可视作 warm up 阶段结束,进入 cosine annealing 阶段。本文设定该阶段的最小学习率为 lr_{init} ,最大学习率为 lr_{base} ,并且在训练过程中保持不变,因此可将该阶段简化:


$$lr_{\text{cosine_annealing}} = lr_{\text{init}} + \frac{1}{2} \times (lr_{\text{init}} - lr_{\text{base}}) \times [1 + \cos(\frac{S - S_{\text{warm_up}}}{S_{\text{total}} - S_{\text{warm_up}}} \times \pi)] \quad (9)$$

本文中,3 种模型均保持一致的动态学习率参数,取 $lr_{\text{init}} = 0.00001$, $lr_{\text{base}} = 0.1$, warm up 过程的步数 $S_{\text{warm_up}} = 3$ 。

4 结果

4.1 电磁干扰识别评估结果

表 1 展示的是 UNet,采用残差结构的语义分割网络以及 DeepLab V3+对于电磁干扰识别的评估结果。可以看出 UNet 以及采用残差结构的电磁干扰语义分割网络的 Precision 较高,相较于 DeepLab V3+可以比较精确地定位存在电磁干扰的距离库。而前两者的 Recall 不如 DeepLab V3+,表明这 3 种模型中 DeepLab V3+能够预测得到的存在电磁干扰的距离库最为全面。然而,对识别电磁干扰,Precision 的重要性更高,所以在电磁干扰识别工作上 UNet 和采用残差结构的电磁干扰语义分割网络效果更好。




(a) 原始数据

(b) UNet 的分割结果

表 1 模型评估结果		单位:%	
Network Name	Precision	Recall	
UNet	89.00	74.17	
采用残差结构的语义分割网络	87.54	77.60	
DeepLab V3+	65.31	85.43	


4.2 脉冲间电磁干扰的抑制效果对比

图 3 抽取的是在各个 I/Q 数据中拥有电磁干扰较为严重的脉冲的识别与抑制效果,从图 3 可以看出: UNet 的预测结果边缘更加锐利和精确,DeepLab V3+相较于 UNet 能够识别更多特征不明显的电磁干扰,但是所预测的边缘模糊和不精确,存在大量的误识别。采用残差结构的语义分割网络的预测得到的边缘精确度界于两者之间。



(c) 残差结构的语义分割网络的分割结果

(d) DeepLab V3+ 的分割结果



(e) UNet识别后的抑制结果


(f) 残差结构的语义分割网络识别后的抑制结果

(g) DeepLab V3+识别后的抑制结果

图 3 3 个模型的识别和抑制结果


对于抑制结果,边缘更加模糊的 Deeplab V3+相较于能够预测更加精确边缘的前者,虽然存在大量的误识别,但是抑制之后的效果可能会更好。原因是边缘模糊带来的是插值范围更大,此时对范围较为广泛且强度较强的

电磁干扰抑制效果更好。但是,边缘的预测不精确可能对抑制带来潜在问题,会把具有电磁干扰的距离库作为插值需要的参数带入计算,对抑制效果产生劣化,反而加重电磁干扰带来的影响,如图 4(g) 的黑框所示。




(a) 原始数据

(b) UNet 的分割结果



(c) 残差结构的语义分割网络的分割结果

(d) DeepLab V3+ 的分割结果



(e) UNet识别后的抑制结果

(f) 残差结构的语义分割网络识别后的抑制结果

(g) DeepLab V3+识别后的抑制结果

图 4 存在问题的识别和抑制结果

4.3 产品对比

反射率、速度谱宽和多普勒速度的产品中,电磁干

扰存在的距离库的位置相同,所以本文采用反射率产品进行抑制效果的对比,如图5所示。

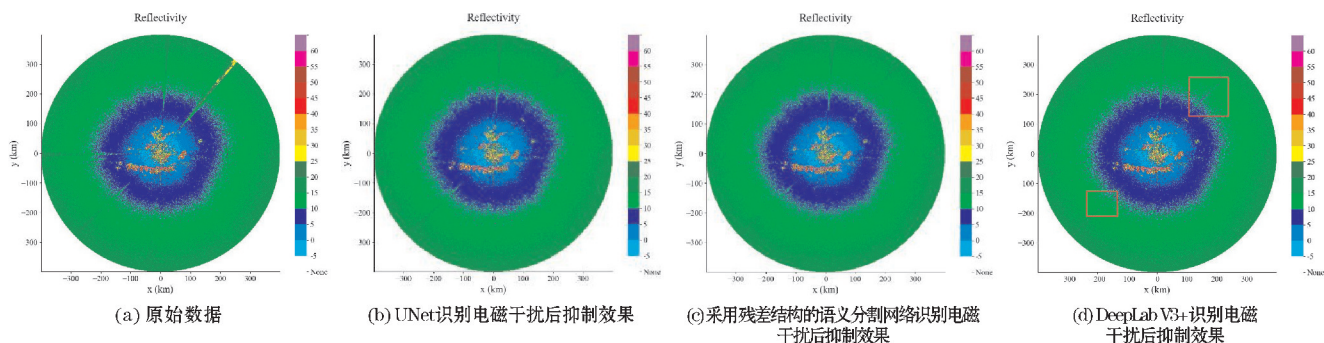


图5 3个模型的反射率产品对比

通过反射率 PPI 图像可以看出,不同模型的识别与抑制过后所生成的产品都能明显减弱电磁干扰带来的影响,且三者之间的变化不大。值得注意的是图5(b)中230~240度的电磁干扰没有抑制,而图5(c)中230~240度和30~45度出现由于抑制插值位置的不准确而产品劣化的迹象(如红色框)。

3种模型中DeepLab V3+的网络深度最深,根据对脉冲的抑制效果对比,可以推断出随着网络的加深,对于某些特征不明显的电磁干扰特征更容易识别,但是会损失边缘的精度。本文推测大部分电磁干扰的特征较为简单,在神经网络的浅层其实就已经捕获。但随着网络的深度增加,在网络特征传递过程中又会丢失部分浅层捕获到的电磁干扰特征信息。UNet结构保留每一次下采样的特征直接传递给解码器,而DeepLab V3+是当空洞卷积的流程都结束之后才开始传递特征到解码器。所以UNet和采用残差结构的电磁干扰语义分割网络的预测结果相较于DeepLab V3+更加精确。对于识别电磁干扰这一类仅识别简单特征的工作来说,将浅层特征直接传递到解码器进行上采样相较于DeepLab V3+采用ASPP再进行传递特征到解码器保留空间信息更加有效,因此识别的边缘更加精确,在一定程度上能够避免定位不精确所造成的在插值过程中劣化数据。

5 结束语

设计一种采用残差结构的语义分割网络识别电磁干扰,并且还结合UNet,DeepLab V3+两种模型用于探讨不同结构模型对电磁干扰识别的影响。首先对I/Q数据进行回波参数估计,得到功率谱基数据,进而在功率数据上进行主要的工作。接下来制作训练模型的数据集,将功率数据归一化,再进行可视化,通过边缘增强和二值化的方式方便人工订正,得到区分电磁干扰和背景的标签数据;将功率数据和标签进行切割之后分别采用3种语义分割网络进行训练,通过再训练过

程中不断调整最终完成3种预测模型的建立。在模型对具有电磁干扰距离库的位置完成预测后,通过线性插值完成电磁干扰的抑制。

在评估结果中,UNet对电磁干扰识别的精确度是89.00%,采用残差结构的电磁干扰语义分割网络精确度是87.54%,DeepLab V3+的精确度是65.31%。虽然DeepLab V3+对电磁干扰的识别精确度在三者中最低,但是它相较于前两者能捕获更多特征不明显的电磁干扰。这几种网络的结构各不相同,通过实验证明具有能够直接传递浅层特征进行上采样的结构网络对于电磁干扰的识别工作更加有效。对识别到存在电磁干扰的距离库线性插值后,无论是对I/Q数据中脉冲的抑制效果还是对产品生成后的效果进行对比,三者对电磁干扰的抑制均能够起到明显的作用。因此在I/Q数据中使用深度卷积神经网络对存在电磁干扰的距离库进行语义分割并且加以抑制是有效的。

致谢:感谢广州市科技计划资助项目(202206010016)对本文的资助

参考文献:

- [1] Vaccarone M, Chandrasekar C V, Bechini R. Survey on Electromagnetic Interference in Weather Radars in Northwestern Italy [J]. *Environments*, 2019, 6(12): 126.
- [2] Saltikoff E, Cho J Y N, Tristant P. The Threat to Weather Radars by Wireless Technology [J]. *Bulletin of the American Meteorological Society*, 2016, 97(7): 1159-1167.
- [3] Cho J Y N. Signal Processing Algorithms for the Terminal Doppler Weather Radar: Build 2 [J]. *Signal Processing Algorithms for the Terminal Doppler*, 2010: 89.
- [4] Yin J, Unal C M H, Russchenberg H W J. Narrow-Band Clutter Mitigation in Spectral Polarimetric Weather Radar [J]. *IEEE Transactions on Geoscience*

- and Remote Sensing, 2017, 55(8):4655–4667.
- [5] Lakshmanan V, Hondl K, Stumpf G. Quality control of weather radar data using texture features and a neural network [C]. Preprints, 31st Radar Conference, 2003:522–525.
- [6] Cho J Y N. A New Radio Frequency Interference Filter for Weather Radars [J]. Journal of Atmospheric and Oceanic Technology, 2017, 34(7):1393–1406.
- [7] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition [C]. International Conference on Learning Representations. Computational and Biological Learning Society, 2015.
- [8] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6):84–90.
- [9] Long J, Shelhamer E, Darrell T. Fully Convolutional Networks for Semantic Segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4):640–651.
- [10] Chen L C, Papandreou G, Kokkinos I. Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs [J]. Computer Science, 2014(4):357–361.
- [11] Chen L C, Papandreou G, Kokkinos I. 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.
- [12] Nishiguchi K, Kobayashi M. Improved algorithm for estimating pulse repetition intervals [J]. IEEE Transactions on Aerospace and Electronic Systems, 2000, 36(2):407–421.
- [13] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition [J]. computer vision and pattern recognition, 2016:770–778.
- [14] Ronneberger O. U-Net Convolutional Networks for Biomedical Image Segmentation [J]. Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS, 2017, 9351:234–241.
- [15] Chen L C, Zhu Y, Papandreou G, et al. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation [C]. European Conference on Computer Vision. Springer, Cham, 2018.
- [16] Chollet F. Xception: Deep learning with depthwise separable convolutions [J]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2017:1251–1258.
- [17] Chen L C, Papandreou G, Schroff F. Rethinking Atrous Convolution for Semantic Image Segmentation [J]. Computer Vision and Pattern Recognition, 2017:801–818.
- [18] Kanopoulos N, Vasanthavada N, Baker R L. Design of an image edge detection filter using the Sobel operator [J]. IEEE Journal of Solid-State Circuits, 1988, 23(2):358–367.
- [19] Loshchilov I, Hutter F. SGDR: Stochastic Gradient Descent with Warm Restarts [J]. ICLR, 2016(9):17.

A Method of Electromagnetic Interference Identification and Suppression based on Deep Convolutional Neural Network

WANG Jiamin¹, LI Tianjia², GU Taofeng³, ZHANG Yuqin¹, QUAN Jing¹, WANG Haijiang¹

(1. College of Electronic Engineering, Chengdu University of Information Technology, Chengdu 610225, China; 2. Xinjiang Hotan Prefecture Meteorological Bureau, Hotan 848000, China; 3. Guangzhou Emergency Warning Information Release Center, Guangzhou 511430)

Abstract: In recent years, the development of radio communication technology has significantly increased Electromagnetic interference (EMI) from artificial radio, which has a detrimental impact on the quality of weather radar data. Current research on detecting and suppressing EMI mostly focuses on the primary radar products. This paper proposes a method to identify and suppress EMI using deep convolutional neural networks applied to the I/Q data of the front end of radar receivers. Specifically, this paper designed a fully convolutional network with residual structure. As well as UNet and DeepLab V3+ were selected to compare the identification effect together, following which a linear interpolation method is used to suppress the electromagnetic interference. The results show that all three models can effectively identify EMI, and each has its advantages and disadvantages in the accuracy and recall rate. Suppressing EMI based on the identification significantly improves the quality of radar data.

Keywords: DCNN; semantic segmentation; electromagnetic interference; quality control.