

实现云图的预分割结果分别如图 2(b)、图 2(d)所示;通过分析 FCN 预分割结果,证明了 FCN 32s 结果如图 2(b)所示的非云(黑色)区域一定是云图中的一部分“非云”区域,FCN 8s 结果如图 2(d)所示的云(白色)区域一定是云图中的一部分“云”区域,余下的不确定的区域(如图 2(e)中的灰色区域所示)通过卷积神经网络 CNN 来确定,需要选取超像素区域中的关键像素来代表超像素区域的特征,关键像素的特征通过图 4 所示的 CNN 网络来判断是“云”或者是“非云”,即可知道不确定的超像素区域是“云”还是“非云”区域。




Fig.4 The framework of CNN

图 4 CNN 网络框架

1.1 超像素聚类分析

为了提高云图特征的学习效率同时保持像素特征的局部一致性,本文采用均值漂移(mean-shift)^[18,19]方法对云图中的像素进行聚类分析,使得后续的云图分割操作以超像素为基本单位,减小以像素为单元的计算复杂度。

均值漂移的超像素预处理是基于特征空间的聚类而实现的。均值漂移算法的输入是一个五维空间,包括二维的 (x,y) 物理坐标和三维的 (l,u,v) 颜色坐标,是一种基于高斯核函数核密度估计的无参数统计迭代方法。具体算法是,首先计算出当前像素点的偏移均值,将该点移动到此偏移均值,然后以此为新的起始点,继续移动直至收敛。偏移均值之后分配标签到每一个像素,相同标签的像素具有相同的视觉特征,所以一个超像素中的每一个像素都是相似的,如纹理性、颜色强度等特征相似。如图 2(c)所示,超像素预处理之后能够很好地保持云图局部一致性,可以避免云图像边界附近有歧义像素点的误分割。

1.2 FCN预分割

本文用全卷积神经网络 FCN 来实现云图的预分割,采用的 FCN 结构框架如图 3 所示,FCN 网络是对卷积神经网络 CNN(如图 4 所示)在分割领域的一个延伸,是一种图像语义分割,对一张图片上的所有像素点进行分割。CNN 都是对整张图片进行分类,而 FCN 是对一张图片中的每个像素进行分类,可以达到对图片特定部分的分类,比较适合分割。

1.2.1 FCN 网络介绍

CNN 在卷积层之后使用全连接层得到固定长度的特征向量进行分类,所不同的是,FCN 可以接受任意尺寸的输入图像,然后通过反卷积对最后一个卷积层的特征图进行上采样,使它恢复到输入图像相同的尺寸,从而对每个像素都进行预测,同时保留了原始输入图像的空间信息,最后在与输入图像等大小的特征图上对每个像素进行分类,逐像素地分类计算损失,相当于每个像素对应一个训练样本。

FCN 将 CNN 中的全连接层转化成卷积层,以图 4 中基于 Alexnet^[20,21]微调的 CNN 网络为例。该 CNN 网络有 5 个卷积层,还有两个全连接层 F1、F2 分别对应长度为 4 096 的向量,以及全连接层 F3 对应长度为 2 的向量,分别表示 2 个不同类别(云或者是非云)的概率。图 3 所示的 FCN 将这 3 个全连接层转换为卷积层,卷积核的大小分别为 $(4096,1,1)$ 、 $(4096,1,1)$ 、 $(2,1,1)$ 。FCN 输入的图像可以是任意大小,本文中毫米波雷达云图像数据集中云图的大小是 719×490 ,在 FCN 网络的第 1 层 pooling(pool1)之后变为原图大小的 $1/2$,第 2 层 pooling(pool2)后变为原图大小的 $1/4$,第 3 层后变为原图大小的 $1/8$,第 4 层变为原图大小的 $1/16$,第 5 层变为原图大小的 $1/32$ 。FCN 32s 网络是直接对 $1/32$ 尺寸的特征图进行上采样操作,但是这样的操作还原的

图片仅仅是 conv5 中的卷积核中的特征.直接上采样 32 步长带来的精度问题使之不能很好地还原图像中的细节特征,所以把 conv4 中的卷积核对上一次上采样之后的图进行反卷积补充细节,最后把 conv3 中的卷积核对刚才上采样之后的图像进行再次反卷积补充细节,最后就完成了整个图像的还原,这就是上采样 8 步长,也就是 FCN 8s 网络.

1.2.2 FCN 网络训练

本文所用的 FCN 云图分割网络是通过微调 Long 等人^[17]提出的 FCN 网络而得到的,微调网络也就是在现有初始化的模型参数的基础上通过比较少量的图片就可以实现模型训练,而不需要几万张、几十万张大量的图片重新训练一个新的网络.本文输入 FCN 网络的是云原图像 719×490,不需要任何裁剪等处理.从云图数据库中随机选取 1 000 张图像作为训练集,随机选取 350 张图片作为测试集.在 FCN 模型的训练过程中需要引入监督信号,也就是标签,标签的制作是基于 Photoshop 等画图软件手工将云图像中“云”和“非云”区域用黑白颜色区分,然后将其转化成 719×490 的二值矩阵(“云”部分用 1 表示,“非云”部分用 0 表示).训练过程中批次大小设为 1,即每迭代 1 次处理 1 张云图,FCN 32s 的初始学习率为 0.001,FCN 8s 的初始学习率为 10^{-13} ,而且是每迭代 1 000 次,学习率下降 10 倍.随着迭代次数的增加,网络的损失率趋于稳定的时候可以停止训练.最后,FCN 32s 网络迭代到 7 000 次时测试集准确率达到最高 95.38%,FCN 8s 网络迭代到 15 000 次时测试集准确率达到最高 92.21%.

Table 1 The FNR、FPR evaluation of FCN 32s、FCN 8s segmentation results

表 1 FCN 32s、FCN 8s 预测结果的 FNR 和 FPR 评价

方法	假负率 FNR(%)	假正率 FPR(%)
FCN 8s	24.166	0
FCN 32s	0	9.997

1.2.3 FCN 实现预分割

在语义分割中,我们需要输出与输入图像尺寸相同的分割图片,因此需要对特征图进行上采样.为了得到和输入图像尺寸完全相同的特征图,直接将全卷积后的结果进行反卷积,得到的结果往往比较粗糙.如图 3 所示,1/32 尺寸的特征图直接进行 32 步长的上采样,这样的操作还原的图片仅仅是 conv5 中卷积所得到的特征.所以得到的分割结果是如图 2(b)所示的 FCN 32s 粗分割结果,可以看出,FCN 32s 结果的云图没有轮廓信息,丢失了很多的细节信息.

考虑到直接上采样 32 步长不能够很好地还原图像特征,因此,与 Long 等人^[17]的思想相同,继续向前迭代,将 conv4 的特征与 conv5 层上采样 2 个步长的结果进行融合来实现细节补充.同理,对刚才上采样之后的结果进行再次反卷积,与 conv3 层的特征进行融合,整个过程相当于插值过程,最后将融合后的特征上采样 8 步长完成了整个图像的还原.FCN 8s 云图分割结果如图 2(d)所示.通过比较 FCN 32s 以及 FCN 8s 的结果可以看出,FCN 8s 与 FCN 32s 相比,更能学到细节信息,FCN 8s 粗分割结果的轮廓比 FCN 32s 更清晰,但同时也可以看出,FCN 8s 的结果也处于“欠学习”状态,精度还远远不够.分析原因,首先是 FCN 直接上采样本来就是一种比较粗糙的分割方法,再加上本文研究的毫米波雷达云图中杂波等因素的影响,使得即使是结合了上下文语义的 FCN 云图,分割效果还是不够理想.但是,结合 FCN 32s 和 FCN 8s 的结果,综合得到的信息是:FCN 32s 在预测非云区域(如图 2(b)中黑色所示)比较准确,FCN 8s 在预测云区域(如图 2(d)白色所示)比较准确.这一结论由表 1 的 FCN 32s、FCN 8s 预测结果的 FNR 和 FPR 评价可以证明,这是测试集中 200 张云图的平均值.我们以“云”区域为正类,“非云”区域为负类,通过预分割结果与标签的比较,假正率 FNR 和假负率 FPR 的结果见表 1.由表 1 可以看出,FCN 8s 预分割结果的假正率 FPR 为 0,FCN 32s 预分割结果的假负率 FNR 为 0.这意味着,FCN 8s 预测为“云”的一定是“云”,FCN 32s 预测为“非云”的一定是“非云”.基于上述这一结论,本文统计第 i 个超像素区域的像素总数为 N_i ,记超像素 i 在 FCN 8s 中的白色像素总数为 Y_i ,在 FCN 32s 中的黑色像素总数为 X_i ,既不属于 FCN 8s 中的白色像素也不属于 FCN 32s 黑色像素(即像素在 FCN 8s 中是黑色的,在 FCN 32s 中是白色的),总数记为 U_i .比较 X_i 、 Y_i 、 U_i ,若 $X_i = \max\{X_i, Y_i, U_i\}$,则该超像素区域的属性就确定为“非云”;若 $Y_i = \max\{X_i, Y_i, U_i\}$,则该超像素区域的属性

就确定为“云”;而其他情况(比如 $U_i = \max\{X_i, Y_i, U_i\}$ 或 $X_i = Y_i$ 等情况)下的超像素区域(如图 2(e)的灰色区域所示)根据 FCN 是无法确定的。

所以下一小节考虑将 CNN 与 FCN 结合,对于 FCN 无法预测的少数超像素区域需要通过 CNN 预测分类云或者是非云,第 1.3 节将详细介绍 CNN 预测分类过程。

1.3 CNN优化分割

CNN 网络对本分割方法的贡献是补充预测 FCN 网络无法判断(或者是判断不准确)的少数超像素区域的云分类。本文为了减少计算量,选取超像素区域中的关键像素来表达超像素区域的特征,只需要通过 CNN 判断关键像素的特征,就可确定其所在超像素区域是“云”还是“非云”。

1.3.1 CNN 网络介绍及模型训练

本文采用的 CNN 结构如图 4 所示,该网络是通过 AlexNet 网络^[20,21]微调而得到的,由 5 个卷积层、3 个全连接层组成,并且只给卷积层 C1、卷积层 C2 和卷积层 C5 加入了 pooling 层。F1~F3 是全连接层,相当于在 5 层卷积层的基础上再加上一个 3 层的全连接神经网络分类器。需要注意的一点是,我们将 AlexNet 中 F3 的神经元个数由 1 000 调为 2,原因是为了实现“云”和“非云”的 2 分类。

在训练和测试 CNN 网络阶段,为了保证在采集训练集图像时,能够采集到整张云图的每一个像素点,我们对云图 719×490 的 4 个边界分别延伸 28 个像素,使图像变为 775×546。在延伸后的图像中,以任意像素点为中心,以 57 为边长裁剪出 57×57 的图像子块。CNN 网络从 10 张云图中随机选取了 900 个 57×57 的图像子块来训练,随机选取 300 个 57×57 的图像子块来测试。与 FCN 相同,在训练 CNN 网络时需要监督信号的输入,也就是所谓的标签。标签的制作过程本文是利用 Photoshop 等画图软件手工地将云图像中“云”和“非云”区域用黑白颜色区分,并转化为 txt 文件,设置成列表的形式(每个像素点是“云”还是“非云”用 0 或 1 表示),用于监督 CNN 网络的训练。在训练过程中,批次大小设为 64,即每迭代 1 次处理 64 个图像子块,学习率初始值为 0.01,且每迭代 200 次学习率下降 10 倍。最后迭代 2 000 次时模型的准确率达到最高 97.26%。

1.3.2 CNN 网络优化分割

用 CNN 网络辅助 FCN 网络实现分割的具体做法是:首先将每一个待 CNN 处理的超像素转化为一个一维的向量,由于超像素具有良好的特征保持特性,在一个超像素中的像素有相似的视觉特征、颜色、纹理和强度等,所以可以在一个超像素中选取 n (n 为奇数)个关键的像素点来代替表示该超像素的特性,这里,我们将这种方法简称为 SP-CNN。关键像素点的选取可以采用等间隔或者是随机取点两种方式,在此过程中,为了避免选取的关键像素点落到超像素的边界(因为当关键像素点落到“云”和“非云”超像素的边界时既可以表达“云”也可以表达“非云”属性),本文指出需要对每一个超像素进行腐蚀处理之后再选取关键像素点。具体的腐蚀处理如下所示:

$$K(I) = \{b/L_b \subset I\} \quad (1)$$

其中, I 表示待腐蚀的超像素, L 表示的是结构元素,如公式(2)所示,把结构元素 L 平移 b 后得到 L_b ,若 L_b 包含于 I ,我们记下这个 b 点,所有满足上述条件的 b 点组成的集合称作 I 被 L 腐蚀的结果。也就是说,用结构元素 L 扫描超像素 I 中的每一个像素,用结构元素与其覆盖的二值图像做“与”操作,如果都为 1,结果图像中的该像素为 1,否则为 0,也就是说,会使原来的图像缩小一圈。

$$\begin{pmatrix} 0 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 0 \end{pmatrix} \quad (2)$$

接下来,以上述选取的 n 个关键像素点为中心,裁剪出 57×57 的正方形子块,输入到第 1.3.1 节训练好的 CNN 网络中来学习该关键像素点的特征(云或者是非云)。最后对 n 个关键像素点的特征属性进行投票处理,如果大于或等于 $(n+1)/2$ 个关键像素点被 CNN 判断为“云”,则该超像素所在的区域是“云”区域,如果大于或者等于 $(n+1)/2$ 个关键像素点被 CNN 判断为“非云”,则该超像素所在的区域是“非云”区域。

2 实验对比及结果评价

本节主要介绍 FCN-CNN 云图分割算法在毫米波雷达云图像数据集中的实验结果,为了评价 FCN-CNN 云图分割算法的性能,我们进行了一系列关于 FCN-CNN 主要组成模块的实验分析,包括:(1) 基于 CNN 的云图分割^[15](MR-CNN);(2) 基于超像素聚类的 CNN(SP-CNN)云图分割;(3) 基于 FCN 的云图分割;(4) 基于超像素聚类的 FCN(SP-FCN)云图分割;(5) 本文的基于超像素的 FCN-CNN 云图分割方法.最后,我们采用图像像素的预测标签与真实标签之间的像素准确度、云图分割结果与真实标记之间的交并比(intersection-over-union,简称 IoU)以及测试集中平均的每张云图的分割时间作为本文的评价方法和准则.

2.1 基于超像素聚类的 CNN 云图分割(SP-CNN)

本节在超像素聚类的基础上利用第 1.3.1 节中介绍的 CNN 来实现云图的分割,这里简称为 SP-CNN.我们以超像素作为基本的研究对象,而不是每一个像素,这样可以保证局部一致性,同时用超像素中的关键像素点的特征代表超像素区域的特征,这样可以降低数据的计算量,其中,关键像素点的特征通过 CNN 提取.

为了验证 SP-CNN 在云分割中的能力,我们将 200 张云图作为测试数据集.首先将待分割的云图进行超像素聚类预处理,其次,在超像素中等间隔地选取 n 个关键像素点,接着,以关键像素点为中心裁剪出 57×57 的图像子块,最后,将 57×57 图像子块输入到第 1.3.1 节中训练好的 CNN 网络来学习关键像素点的特征, n 个关键像素的特征投票结果就是超像素所在区域的特征.在实验过程中,我们对关键像素($n=1,3,5,7$)的均匀选取和随机采样做了对比实验,如第 1.3.2 节中所述,在选取关键像素点之前对超像素进行腐蚀处理,这样就会导致部分超像素中像素的总个数不足 7.所以,表 2 比较了针对等间隔采样和随机选取 $n=1,3,5$ 个关键像素点的结果,这是 5 次实验的平均结果,包括平均准确率和每张图的分割时间.本文在 Windows PC 上生成超像素结果,平均每张云图的运行时间是 3.12s,在 Nvidia Tesla K40C GPU 上 CNN 预测一个关键像素点的特征的时间是 0.04s,所以,以 $n=5$ 为例,云图分割平均每张图耗时 33.12s.表 2 所示结果显示,等间隔采样 5 个关键像素点时,分割平均准确率可达 99.543%,分割时间是 33.12s,这个分割效果优于其他方案.所以在接下来的实验中,我们会采取等间隔采样 5 个关键像素点的方案.

Table 2 Performance of SP-CNN with uniform and random pixel selection evaluated by accuracy and time costs
表 2 SP-CNN 过程中随机与等间隔选取关键点的性能比较

	随机选取关键点			等间隔选取关键点		
	$n=1$	$n=3$	$n=5$	$n=1$	$n=3$	$n=5$
准确度(%)	99.171±0.027	99.422±0.011	99.433±0.003	98.821±0.047	99.476±0.002	99.543±0.003
时间	9.12	21.12	33.12	9.12	21.12	33.12

2.2 基于超像素聚类的 FCN-CNN 云图分割

由第 1.2 节介绍可知,FCN 更适合语义分割,但是分割结果粗糙.通过第 1.2.3 节,我们可以分析到的结论是,FCN 32s 在预测非云区域(黑色)时比较准确,FCN 8s 在预测云区域(白色)时比较准确.至于 FCN 预测不到的区域,我们可以利用 SP-CNN 的思想进一步分析.

假设云图在超像素处理之后,云图中的像素被聚类成 k 个超像素.统计第 $i(1 \leq i \leq k)$ 个超像素区域的像素总数 N_i ,记超像素 i 在 FCN 8s 中被预测为“云”(白色)的像素总数为 Y_i ,在 FCN 32s 中被预测为“非云”(黑色)的像素总数为 X_i ,其中,既不属于 FCN 8s 中的“云”(白色)像素也不属于 FCN 32s 中的“非云”(黑色)像素(也就是像素在 FCN 8s 中被预测为“非云”而在 FCN 32s 中被预测为“云”)的总数记为 U_i .

(1) 基于超像素聚类的 FCN 8s-CNN 云图分割:统计第 $i(1 \leq i \leq k)$ 个超像素区域的像素总数 N_i ,记云图在 FCN 8s 网络中被预测为“云”(白色)的像素总数为 Y_i ,如果 $Y_i \geq \frac{1}{2}N_i$,则此超像素区域就属于“云”,否则,这个超像素用第 2.1 节中的 SP-CNN 来判断.

(2) 基于超像素聚类的 FCN 32s-CNN 云图分割:统计第 $i(1 \leq i \leq k)$ 个超像素区域的像素总数 N_i ,记云图在

FCN 32s 网络中被预测为“非云”(黑色)的像素总数为 X_i , 如果 $X_i \geq \frac{1}{2}N_i$, 则此超像素区域就属于“非云”, 否则同理, 这个超像素用第 2.1 节中 SP-CNN 的方法来判断.

(3) 基于超像素聚类的 FCN-CNN 云图分割: 比较 X_i 、 Y_i 、 U_i , 若 $X_i = \max\{X_i, Y_i, U_i\}$, 则该超像素区域的特征就确定为“非云”; 若 $Y_i = \max\{X_i, Y_i, U_i\}$, 则该超像素区域的特征就确定为“云”; 否则, 其他情况(比如 $U_i = \max\{X_i, Y_i, U_i\}$ 或 $X_i = Y_i$ 等)下的超像素区域都通过第 2.1 节的 SP-CNN 方法来判断.

本节中 FCN 32s 以及 FCN 8s 在测试集数据库上的分割都是基于第 1.2.2 节中训练好的 FCN 网络, 在 Nvidia Tesla K40C GPU 上, FCN 8s 实现云图分割的时间是平均每张 4.94s, FCN 32s 的分割时间是 4.23s, 与第 1.2 节中的分析相符, FCN 在分割领域与 CNN^[15]相比, 在速度上有很大的优势, 但是精度有所欠缺. 实验过程中, 针对同样的 200 张云图测试集, 我们对 SP-CNN、FCN 8s-CNN、FCN 32s-CNN 和 FCN-CNN 这几种方法进行定量评估. 由表 4 的结果可以看出, 从分割准确度来看, 差距并不是特别明显, 但在分割时间方面, 基于超像素引导下的 FCN-CNN 方法有很大的优势, 表 3 也可以证明这一点. 表 3 是对这 200 张测试云图中平均每张云图需要 CNN 网络处理的超像素个数进行统计, 可以看出, 时间差距上最根本的原因是 CNN 处理超像素的数量不同.

Table 3 Average superpixel number and time statistics of CNN processing

表 3 CNN 处理的平均超像素数量及时间统计

方法	SP-CNN	FCN 8s-CNN	FCN 32s-CNN	FCN-CNN
需要 CNN 处理的超像素(个)	150	84	103	38.47
CNN 处理所需时间(s)	30	16.8	20.6	7.69

Table 4 Performance evaluation of FCN-CNN compared with Threshold^[11]、MR-CNN^[15]、FCN 32s^[17]、FCN 8s^[17]、FCN 8s-CNN、FCN 32s-CNN and SP-CNN by accuracy, IoU and time cost for cloud segmentation

表 4 本文的云图分割 FCN-CNN 方法与其他方法的性能比较

方法	准确度(%)	交并比 IoU(%)	时间(s)
阈值 ^[11]	96.751±0.003	60.253±3.346	-
MR-CNN ^[15]	99.500±0.005	83.744±0.492	17.615
FCN 8s ^[17]	98.630±0.002	55.884±2.692	4.23
FCN 32s ^[17]	94.441±1.456	65.553±3.717	4.94
SP-CNN	99.543±0.003	80.132±0.512	33.12
FCN 8s-CNN	99.517±0.012	79.564±0.976	24.86
FCN 32s-CNN	99.543±0.004	80.782±0.785	27.95
FCN-CNN	99.564±0.003	81.235±0.506	19.98

2.3 图像分割评价

本文采用像素误差、交并比 IoU 以及分割所需时间的评价方法来衡量分割结果.

像素准确度是给定待测的分割标签 L 以及其真实的数据标签 L' , 则:

$$P_{pixel} = \|L - L'\|^2 \quad (3)$$

其中, $\|\cdot\|$ 代表汉明距离, 它反映了分割图片与原始标签的像素相似度. 按照这种方法, 本文所提 FCN-CNN 最后可以使云图的分割准确度达到 99.564%.

IoU 是分割结果 K 与分割标签图 K' 的重合程度. 即分割结果与分割标签图的交集比上它们的并集, 公式表示为

$$IoU = \frac{K \cap K'}{K \cup K'} \quad (4)$$

本文的 FCN-CNN 实现云图分割的交并比达到 81.235%. 结合表 4 分析, 在处理速度上, 平均分割一张图像只需 19.984s.

我们用相同的评价指标对阈值^[11]、MR-CNN^[15]、FCN 32s^[17]、FCN 8s^[17]、FCN 8s-CNN、FCN 32s-CNN 和 SP-CNN 方法进行衡量, 结果见表 4, 可以发现, 精度与 MR-CNN、SP-CNN 等相当, 但是速度相比于 MR-CNN 提高了 880 倍, 相比于 SP-CNN 提高了 1.657 倍, 可以看出, FCN-CNN 是一种高效的毫米波雷达云图分割方法.

图5所示为FCN-CNN与其他方法在4张不同云图上的结果示例,从结果我们可以看出,阈值法^[11]的鲁棒性较差.由于云图噪音繁杂且不稳定,FCN 32s^[17]分割的云区域较为粗糙,丢失了大量的边界细节.相反地,FCN 8s^[17]虽然捕获了更多的云边界细节却丢失了云区域的主要信息.这是由于,FCN 32s 直接对最后一个卷积层的特征图进行 32 步长的上采样,所以无法捕获准确的边界信息,FCN 8s 通过融合前几层卷积层的特征,可以学习更多的细节信息,但是同时,由于云区域的噪声影响,使其丢失了云的部分主要区域.从图 5 的结果上来看,MR-CNN^[15]、FCN 8s-CNN^[17]、FCN 32s-CNN^[17]、SP-CNN 与本文的基于超像素的 FCN-CNN 方法相比在复杂的噪声影响下更鲁棒,但是基于超像素的 FCN-CNN 不仅能够更好地保持云图区域局部的一致性,还可以避免有边缘像素引起的歧义,而且其同时结合了超像素聚类、FCN 以及 CNN 的优点,使得分割精度和速度都优于其他方法.图 5 中,第 1 行所示为原图,第 2 行所示为超像素,第 3 行所示为标签,第 4 行所示为阈值,第 5 行所示为 MR-CNN,第 6 行所示为 FCN 8s,第 7 行所示为 FCN 32s,第 8 行所示为 SP-CNN,第 9 行所示为 FCN 8s-CNN,第 10 行所示为 FCN 32s-CNN,第 11 行所示为 FCN-CNN.

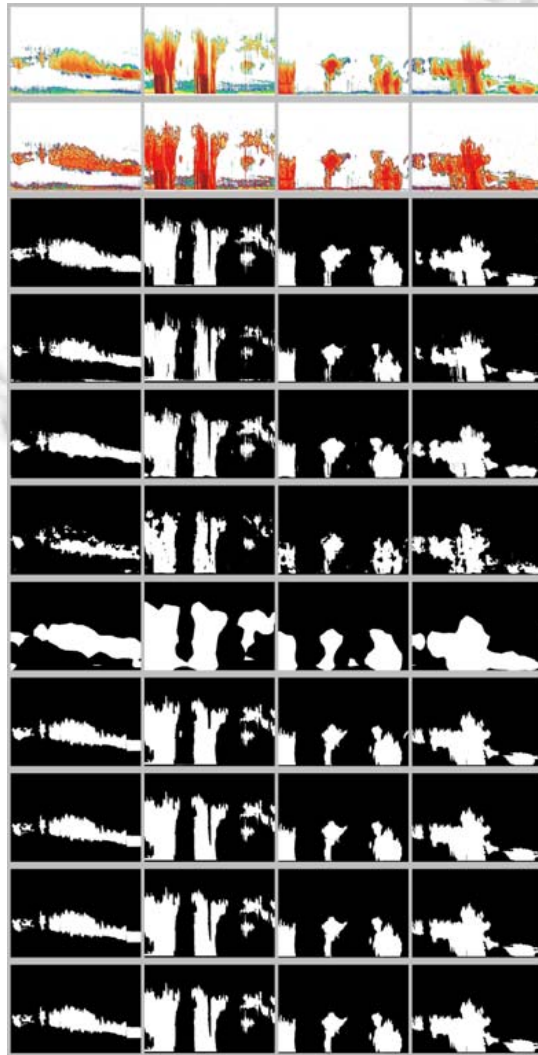


Fig.5 Cloud images segmentation results

图 5 云图分割结果

3 结 论

本文提出了一种高效的基于超像素聚类的 FCN-CNN 云图像分割方法.超像素预处理有效地保持了云图中云和非云区域的局部一致性,其中,在超像素区域进行腐蚀处理巧妙地避免了边缘像素引起的歧义.同时,本文将云图输入到不同步长的全卷积神经网络 FCN 32s 和 FCN 8s 中来实现云图的快速预分割,利用预分割结果确定部分“云”和“非云”区域,即根据 FCN 32s 预测的“非云”的区域一定为云图中的部分“非云”区域,由 FCN 8s 预测的“云”的区域一定为云图中的一部分“云”区域;余下的不确定的区域由 CNN 来进一步分析,在这个过程中,为了降低计算复杂度,我们选取超像素区域中的关键像素来表达超像素区域的特征,关键像素的特征通过 CNN 网络来判断是“云”或者是“非云”.本文通过多组实验的对比以及定量的评估分析证实了所提出的基于超像素聚类分析的 FCN-CNN 云图分割方法是有效的.值得注意的是,毫米波雷达扫描云层的时候生成云图像的时间间隔是 10min,而本文提出的基于超像素聚类的 FCN-CNN 方法在云图分割过程中平均每张云图只耗费不到 20s,这说明,该方法满足云图分割的实时性需求.综上所述,本文研究的基于超像素聚类的 FCN-CNN 云图分割方法有效地汲取了超像素、FCN 和 CNN 的优点,具有良好的云图分割能力,为高效的气象预测奠定了良好的基础.

References:

- [1] Martínez-Chico M, Batlles FJ, Bosch JL. Cloud classification in a Mediterranean location using radiation data and sky images. *Energy*, 2011,36(7):4055–4062. [doi: 10.1016/j.energy.2011.04.043]
- [2] Long CN, Sabburg JM, Calbó J, Pagès D. Retrieving cloud characteristics from ground-based daytime color all-sky images. *Journal of Atmospheric & Oceanic Technology*, 2006,23(5):633–652. [doi: 10.1175/JTECH1875.1]
- [3] Shields JE, Johnson RW, Karr ME, Wertz JL. Automated day/night whole sky imagers for field assessment of cloud cover distributions and radiance distributions. In: *Proc. of the 10th Symp. on Meteorological Observations and Instrumentation*. 1998. [http://xueshu.baidu.com/s?wd=paperuri:\(c7eaa7569237eec16316553da79c38bd\)&filter=sc_long_sign&sc_ks_para=q%3DAutomated+day%2Fnight+whole+sky+imagers+for+field+assessment+of+cloud+cover+distributions+and+radiance+distributions&tn=SE_baiduxueshu_c1gjeupa&ie=utf-8&sc_us=11998081953391704638](http://xueshu.baidu.com/s?wd=paperuri:(c7eaa7569237eec16316553da79c38bd)&filter=sc_long_sign&sc_ks_para=q%3DAutomated+day%2Fnight+whole+sky+imagers+for+field+assessment+of+cloud+cover+distributions+and+radiance+distributions&tn=SE_baiduxueshu_c1gjeupa&ie=utf-8&sc_us=11998081953391704638)
- [4] Shields JE, Karr ME, Johnson RW, Burden AR. Day/Night whole sky imagers for 24-h cloud and sky assessment: History and overview. *Applied Optics*, 2013,52(8):1605–1616. [doi: 10.1364/AO.52.001605]
- [5] Long C, Slater D, Tooman T. Total sky imager model 880 status and testing results. Office of Scientific & Technical Information Technical Reports, 2001. <https://xs.glgoo.net/scholar?hl=zh-CN&q=Total+sky+imager+model+880+status+and+testing+results&btnG=&lr=>
- [6] Shaw JA, Thurairajah B. Short-Term arctic cloud statistics at NSA from the infrared cloud imager. 2003. https://www.researchgate.net/publication/228878636_Short-term_arctic_cloud_statistics_at_NSA_from_the_infrared_cloud_imager
- [7] Racette P, Adler RF, Wang JR, Gasiewski AJ, Jakson DM, Zacharias DS. An airborne millimeter-wave imaging radiometer for cloud, precipitation, and atmospheric water vapor studies. *Journal of Atmospheric & Oceanic Technology*, 1992,13(3):1426–1428. [doi: 10.1175/1520-0426(1996)013<0610:AAMWIR>2.0.CO;2]
- [8] Kreuter A, Zangerl M, Schwarzmann M, Blumthaler M. All-Sky imaging: A simple, versatile system for atmospheric research. *Change*, 2009,48(6):1091–1097. [doi: 10.1364/AO.48.001091]
- [9] Mantelli Neto SL, Von Wangenheim A, Pereira EB, Comunello E. The use of euclidean geometric distance on RGB color space for the classification of sky and cloud patterns. *Journal of Atmospheric & Oceanic Technology*, 2010,27(9):1504–1517. [doi: 10.1175/2010JTECHA1353.1]
- [10] Souzaecher MP, Pereira EB, Bins LS, Andrade MAR. A simple method for the assessment of the cloud cover state in high-latitude regions by a ground-based digital camera. *Journal of Atmospheric & Oceanic Technology*, 2006,23(3):437. [doi: 10.1175/JTECH1833.1]
- [11] Yang J, Lü WT, Ma Y, Yao W. An automatic ground-based cloud detection method based on adaptive threshold. *Journal of Applied Meteorological Science*, 2009,20(6):713–721 (in Chinese with English abstract).
- [12] Liu S, Zhang L, Zhang Z, Wang C, Xiao B. Automatic cloud detection for all-sky images using superpixel segmentation. *IEEE Geoscience & Remote Sensing Letters*, 2015,12(2):354–358. [doi: 10.1109/LGRS.2014.2341291]

- [13] Buch KAJ, Sun CH. Cloud classification using whole-sky imager data. In: Proc. of the 9th Symp. on Meteorological Observations & Instrumentation. 1995,16(3):353–358. [http://xueshu.baidu.com/s?wd=paperuri%3A\(9cebe35398fab368b4f3d5382a8e4d6b\)&filter=sc_long_sign&tn=SE_baiduxueshu_c1gjeupa&ie=utf-8&sc_ks_para=q%3DCloud%20classification%20using%20whole-sky%20imager%20data](http://xueshu.baidu.com/s?wd=paperuri%3A(9cebe35398fab368b4f3d5382a8e4d6b)&filter=sc_long_sign&tn=SE_baiduxueshu_c1gjeupa&ie=utf-8&sc_ks_para=q%3DCloud%20classification%20using%20whole-sky%20imager%20data)
- [14] Taravat A, Frate FD, Cornaro C, Vergari S. Neural networks and support vector machine algorithms for automatic cloud classification of whole-sky ground-based images. IEEE Geoscience & Remote Sensing Letters, 2015,12(3):666–670. [doi: 10.1109/LGRS.2014.2356616]
- [15] Zhang JN, Wu LF, He JY. Millimeter-Wave cloud image segmentation based on multi-resolution convolutional neural network. In: Proc. of the National Conf. on Multimedia Technology. 2016 (in Chinese with English abstract). [hppt://hhme.cs.tsinghua.edu.cn](http://hhme.cs.tsinghua.edu.cn)
- [16] Wu Z, Huang Y, Yu Y, Wang L, Tan T. Early hierarchical contexts learned by convolutional networks for image segmentation. In: Proc. of the Int'l Conf. on Pattern Recognition. IEEE, 2014. 1538–1543. [doi: 10.1109/ICPR.2014.273]
- [17] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation. In: Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition. 2015. 3431–3440. [doi: 10.1109/CVPR.2015.7298965]
- [18] Comaniciu D, Meer P. Mean shift: A robust approach toward feature space analysis. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2002,24(5):603–619. [doi: 10.1109/34.1000236]
- [19] Tao W, Jin H, Zhang Y. Color image segmentation based on mean shift and normalized cuts. IEEE Trans. on Systems, Man, and Cybernetics, Part B (Cybernetics), 2007,37(5):1382–1389. [doi: 10.1109/TSMCB.2007.902249]
- [20] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. In: Proc. of the Int'l Conf. on Neural Information Processing Systems. Curran Associates Inc., 2012. 1097–1105. [http://xueshu.baidu.com/s?wd=paperuri:\(bfd67dfdf8cea0c47038f63e91b9df1\)&filter=sc_long_sign&sc_ks_para=q%3DImageNet+classification+with+deep+convolutional+neural+networks&tn=SE_baiduxueshu_c1gjeupa&ie=utf-8&sc_us=7479570315911023847](http://xueshu.baidu.com/s?wd=paperuri:(bfd67dfdf8cea0c47038f63e91b9df1)&filter=sc_long_sign&sc_ks_para=q%3DImageNet+classification+with+deep+convolutional+neural+networks&tn=SE_baiduxueshu_c1gjeupa&ie=utf-8&sc_us=7479570315911023847)
- [21] Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma J, Huang ZH, Andrej K, Aditya K, Michael B, Alexander C, Li FF. ImageNet large scale visual recognition challenge. Int'l Journal of Computer Vision, 2014,115(3):211–252.

附中文参考文献:

- [11] 杨俊,吕伟涛,马颖,姚雯,李清勇.基于自适应阈值的地基云自动检测方法.应用气象学报,2009,20(6):713–721.
- [15] 张加楠,毋立芳,贺娇瑜.基于多分辨率卷积神经网络的毫米波雷达云图像分割.见:第 25 届全国多媒体技术学术会议.2016. [hppt://hhme.cs.tsinghua.edu.cn](http://hhme.cs.tsinghua.edu.cn)



毋立芳(1970—),女,山西临猗人,博士,教授,博士生导师,CCF 专业会员,主要研究领域为计算机视觉.



邹蕴真(1995—),女,本科生,主要研究领域为深度学习,图像分割.



贺娇瑜(1993—),女,硕士,主要研究领域为计算机视觉.



赵铁松(1984—),男,博士,教授,博士生导师,CCF 专业会员,主要研究领域为图像处理,多媒体通信.



简萌(1987—),女,博士,讲师,CCF 专业会员,主要研究领域为计算机视觉.