基于深度神经网络的 SAR 建筑目标三维重建方法

陈健堃^{1,2,3,5†}, 彭凌霄^{1,2,4,5†}, 仇晓兰^{1,2,4,5*}, 丁赤飏^{1,4,5}, 吴一戎⁵

1. 中国科学院微波成像技术国家级重点实验室, 北京 100190

2. 中国科学院空间信息处理与应用系统技术重点实验室, 北京 100190

3. 中国科学院大学, 北京 100049

4. 中国科学院电子学研究所苏州研究院空间信息智能处理系统研究室, 苏州 215000

5. 中国科学院空天信息研究院, 北京 100094

* 通信作者. E-mail: xlqiu@mail.ie.ac.cn

† 同等贡献

收稿日期: 2019-05-14; 修回日期: 2019-07-20; 接受日期: 2019-08-13; 网络出版日期: 2019-12-16

国家自然科学基金 (批准号: 61725105) 资助项目

摘要 建筑物三维重建在城市规划、灾害监测、智慧城市等领域有重要应用, 是计算机视觉、摄影测量、遥感等领域研究的重要课题. 由于 SAR 成像机理的特殊性和复杂性, 基于 SAR 图像的建筑物三维重建难度很大, 现有方法的适用性和自动化程度都亟待提升. 本文构建了基于深度学习与雷达成像机理结合的 SAR 图像建筑物检测及三维重建整体框架, 并提出了基于耦合等效复数卷积神经网络的 SAR 图像建筑侧立面检测方法, 基于 RaySAR 的建模仿真及点云生成方法, 以及基于 3D 生成网络的 SAR 建筑物三维重建方法, 利用 TerraSAR-X 与 GF-3 高分辨率 SAR 图像进行实验, 得到了较好的三维重建结果. 本文方法为 SAR 图像目标三维重建提供了新的技术途径, 是 SAR 目标三维重建的有益尝试.

关键词 SAR, 深度学习, 语义分割, 点云生成, 建筑物检测, 三维重建

1 引言

建筑物三维重建是获取建筑物三维结构信息的重要手段, 在智慧城市、灾害监测、通信设施建设等领域具有重要应用价值, 社会经济价值日益突出. 航空航天遥感对地观测具有高分辨率宽幅的优势, 因此利用遥感手段进行建筑物提取和三维重建一直都是建筑物三维重建的研究重点之一. 在众多可用于三维重建的遥感数据源中, 合成孔径雷达 (synthetic aperture radar, SAR) 作为一种主动式微波遥感设备, 除了具有大幅宽、高分辨率的优点外, 还具有全天时、全天候、多波段、多极化, 以及可变视角等

引用格式: 陈健堃, 彭凌霄, 仇晓兰, 等. 基于深度神经网络的 SAR 建筑目标三维重建方法. 中国科学: 信息科学, 2019, 49: 1606–1625, doi: 10.1360/SSI-2019-0100
Chen J K, Peng L X, Qiu X L, et al. A 3D building reconstruction method for SAR images based on deep neural network (in Chinese). Sci Sin Inform, 2019, 49: 1606–1625, doi: 10.1360/SSI-2019-0100

特殊优势,具有重要的军事和民用价值.近年来,随着机载、星载 SAR 技术的不断成熟,获取的 SAR 图像分辨率大幅提高.在高分辨率 SAR 图像中,建筑物在图像上表现出的空间结构信息更加丰富,为建筑物提取和三维重建提供了重要的信息来源.

在基于高分辨率 SAR 图像的建筑目标提取和三维重建领域,国内外学者已有初步的研究.意大利帕维亚大学 (Università degli Studi di PAVIA) 的 Gamba 等^[1]从干涉 SAR 测量提供的三维地形高程数据出发,基于图像分割方法,采用最佳拟合平面实现三维数据的局部逼近,对干涉雷达数据地形图进行自洽划分,恢复建筑物的占地面积、高度、位置,以及简单的三维模型.澳大利亚的 Bolter^[2]对建筑物所表现出的 SAR 图像的阴影以及叠掩区域进行了深入的分析,开发了基于倾斜阴影边界的自动重建算法,利用 0.3 m 高分辨率 SAR 图像进行了实验验证,对独栋矩形建筑得到了较好的结果.国防科技大学的 Zhao 等^[3]提出基于 SAR 建筑物特征及环境背景上下文信息的 SAR 图像建筑物提取方法,对于长方体规则结构且高度较低的建筑具有较高的检测率和较低的误报率.中国科学院电子学研究所 Fu 等^[4]提出了一种基于分布密度函数差异的仿真图像迭代匹配方法,仿真 SAR 图像后向散射系数用来划分建筑物不同的散射区域,通过计算特征区域之间的分布密度函数差异,以取得最大匹配度值的仿真图像对应的检验高度作为建筑物的反演高度.复旦大学 Xu 等^[5]提出了一种基于多角度 SAR 图像进行建筑物三维重建的方法,首先将建筑建模为长方体,采用 CFAR 检测和 Hough 变换进行平行边缘线检测,提出用一组概率密度函数来描述目标图像及多角度图像的相干性,然后用最大似然估计进行建筑三维重建,并定义了一个混合优先级准则来评估重建结果的可靠性,在 1.5 m 分辨率测试图像上取得了较好的结果.然而,目前上述方法的普适性较差,通常只适用于长方体结构的建筑,难以处理复杂结构.

相比而言,光学图像三维重建发展迅速,已具有较好的普适性.有学者将深度学习引入基于单幅 RGB 图像的三维重建研究并提出很多新的方法. Pontes 等^[6]通过卷积自编码器对输入图像提取特征,经轻量化网络得到图像类型,在预构建的三维模型库中寻找对应模型并进行模型变换和子模型线性累加,实验验证其对几类虚拟图像和真实图像具有一定的重建能力. Kurenkov 等^[7]应用类似的思路,首先从模型库中选取相似模型,借助 DeformNet 同时提取二维图像和三维模型特征,经三维反编码器输出偏移向量对初始模型进行修正,对真实图像具有较好的重建能力. Kniaz 等^[8]应用生成对抗网络对光学图像中建筑物进行重建,生成器将 U-Net 反编码层中的 2D 卷积核改进成 3D 卷积核同时保留跨层连接,合理结合二维图像与 3D 模型特征以实现二维图像输入三维模型输出的功能. Mandikal 等^[9]提出了 3D-LMNet,训练过程分为两个阶段,第 1 阶段采用三维编码解码网络,设计倒角距离为损失函数,训练过程不断优化编码器以建立三维模型与二维特征空间的映射关系.第 2 阶段则输入二维图像,经编码网络得到其在二维空间映射,并使之与从真值模型到二维空间映射特征不断逼近,从而学习由二维图像到三维模型的映射关系,同时在网络中添加多样化生成模型功能,实验验证了其具有比 PSGN^[10] 更好的三维重建能力.上述方法依赖于图像与对应模型训练集的建立.对于光学图像而言,建立训练集相对容易;然而对于 SAR 而言,复杂目标的三维成像 SAR 系统仍是国际研究前沿,尚未到达可以大规模推广应用的阶段,且复杂目标 SAR 图像仿真也具有很高挑战,为此, SAR 图像及对应三维模型库的建立具有很大的难度.此外,由于 SAR 成像机制与光学成像机制在电磁波频段、成像原理、成像几何等方面具有很大的差异, SAR 图像特征与光学图像特征存在显著不同,目标在 SAR 图像中常呈现为散射点的分布,往往不能完整体现目标的连续结构,且散射特性存在角度的敏感性.因此,目前尚未有借鉴上述光学图像三维重建新方法进行 SAR 图像三维重建的研究.

综上所述,由于 SAR 成像机理的特殊性和复杂性,高分辨率 SAR 图像三维重建依然存在很大的挑战.受鉴于深度学习方法在单幅光学图像三维重建中的优异表现,本文提出了基于深度学习进行

图 1 基于深度神经网络的 SAR 图像建筑目标三维重建总体框架

Figure 1 Overall framework of 3D building reconstruction for SAR images based on deep neural network

SAR 三维重建的总体技术框架, 通过适用于 SAR 图像的神经网络及学习训练, SAR 三维目标快速仿真, 并结合 SAR 成像几何物理模型提取绝对尺寸信息, 进行 SAR 目标的自动三维重建.

本文结构如下: 第 2 节介绍了基于深度神经网络的 SAR 建筑目标三维重建的整体框架, 第 3 节提出了基于耦合等效复数卷积网络的 SAR 图像建筑侧立面分割方法, 第 4 节介绍了基于 RaySAR 的快速仿真与图像 - 点云数据集构建方法, 第 5 节介绍了 3D 生成网络结合 SAR 成像几何的三维重建方法, 第 6 节给出了实验及结果分析, 第 7 节总结全文并指出后续研究方向.

2 基于深度神经网络的 SAR 建筑目标三维重建总体框架

本文提出的基于深度神经网络的 SAR 目标三维重建方法总体框架. 如图 1 所示, 通过人工标注构建 SAR 建筑物提取的标注数据集, 同时构建适用于 SAR 图像建筑物提取的深度学习神经网络, 本文提出了耦合等效的深度复数图像分割网络 (CV-SegNet), 通过训练使其具备了较好的 SAR 图像建筑物提取能力. 然后, 开展 SAR 目标图像高相似度快速仿真方法研究, 提出基于 RaySAR 仿真获得 SAR 图像 - 目标三维点云对数据集的方法. 接着, 基于国际上最近提出的 PointOutNet^[10] 网络结构, 构建了 SAR 图像 - 三维点云生成网络并提出改进方法, 利用仿真数据集对网络进行训练. 最后, 将 CV-SegNet 的建筑提取结果输入三维重建网络得到三维点云重建结果, 并进一步利用 SAR 成像几何, 通过建筑侧立面的顶底斜距差和入射角信息, 获得建筑物高度信息, 用于修正三维点云尺寸, 从而完成目标三维重建. 本文后面 3 节分别对该总体框架的建筑物分割、目标仿真、目标三维重建 3 个部分进行详细叙述.

3 基于耦合等效复数网络的 SAR 图像建筑物分割

卷积神经网络 (convolutional neural network, CNN) 是近年发展起来并引起广泛重视的一种网络, 其在图像处理方面已表现出非常卓越的能力. 20 世纪科学家们发现了视觉神经的几个特点: 视神经具有局部感受野, 一整张图的识别由多个局部识别点构成; 不同神经元对不同形状有识别能力, 且视神经具有叠加能力, 高层复杂的图案可以由低层简单线条组成. 之后人们发现经过卷积的操作, 可以很好地反映视神经处理计算的过程. 由此, LeCun 等于 1989 年^[11] 提出应用于图像分类的卷积神经网络, 并于 1998 年^[12] 构建了更加完备的卷积神经网络 LeNet-5, 成功应用于手写数字的识别问题中. 随后不断涌现出各类卷积神经网络, 诸如 2012 年的 AlexNet^[13], 2013 年的 ZFNet^[14], 2014 年的 VGGNet^[15] 和 2015 年的 ResNet^[16] 等, 在人像识别、手势识别等领域及 ImageNet 大规模视觉识别竞赛中表现出优异的成绩.

图像的语义分割是将输入图像中的每个像素分配一个语义类别, 以得到像素化的密集分类结果. 传统的 SAR 图像分割方法主要包括基于图像灰度分布模型的统计类方法和基于图像纹理分析的方法, 依赖于建立待分割区域的先验分布模型和相应的模型参数. 2014 年 Long 等^[17] 使用全卷积神经网络对自然图像进行端到端的分割, 取得了图像语义分割的重大突破. 基于卷积神经网络的 SAR 图像分割也受到了国内外研究者的重视. 然而, 由于 SAR 图像的特殊性, 适用于光学图像的分割网络很难直接有效地用于 SAR 图像. 为此, 研究者们从网络输入、网络结构等方面进行了改进. 清华大学的 Duan 等^[18] 提出应用于 SAR 图像语义分割的多尺度卷积神经网络, 在噪声消除阶段构造了一个稀疏表示损失函数以获得清晰的 SAR 图像作为网络输入, 采用多尺度卷积方法学习不同尺度的深度特征并进行特征级联, 实验验证了该方法在人工混合 SAR 图像与真实 SAR 图像上均具有较好的分割效果. 复旦大学的 Xu 等^[19] 提出了复数卷积神经网络, 实现像素级别的全极化 SAR 图像地物分类, Flevoland 数据集下 15 类地物平均分类精度达到了 95%. 但是上述研究均使用浅层 CNN 网络结构, 较难适用于大规模 SAR 图像训练与学习.

本文提出了一个适合于 SAR 复数形式数据学习的耦合等效复数网络, 并命名为 CV-SegNet, 其能够有效利用 SAR 复数据所蕴藏的丰富信息, 尤其有助于极化 SAR 数据等相位具有重要物理意义的数据的处理, 并且经验证, 其对于高分辨率 SAR 图像中建筑目标分割具有良好的效果.

3.1 耦合等效复数图像语义分割网络设计

原始的 SAR 图像是一幅复数图像, 尤其是极化、干涉等多通道 SAR 图像, 其相位中也蕴含有信息. 为了充分利用 SAR 复数图像的特性, 本文设计了 CV-SegNet, 其主要特点是能够将复数数据作为输入, 并在卷积过程中实现实数通道与虚数通道的等效复数耦合运算, 以更准确地提取图像特征. 考虑到复数网络参数量巨大以及复数误差反传算法的复杂性, 本文用上述等效复数运算语义分割网络代替全复数运算语义分割网络, 网络框架如图 2 所示.

CV-SegNet 将复数数据作为输入, 同时对各层传递了相位信息. 利用复数卷积耦合计算的方法, 对输入图像进行学习, 卷积结果经过非线性激励函数 ReLU 后生成特征图. 卷积层的输出作为池化层的输入, 进行下采样特征图的同时保留最大值坐标索引, 从而减少网络参数, 有助于维持网络的学习深度. 反池化层利用之前保留的索引, 在进行特征图高分辨率恢复后, 同样利用复数卷积计算的方法进行学习. 最后, 得到的等同于原始输入图像大小的节点输出值经 Softmax 层进行归一化后获得像素级别的分类概率.

图 2 SAR 图像目标检测的深度复数语义分割网络框架

Figure 2 Architecture of complex valued deep semantic segmentation network for target detection in SAR images

图 3 基于耦合计算方法的复数卷积层

Figure 3 Complex valued convolution layer based on coupling calculation method

3.1.1 基于复数卷积耦合计算方法的卷积层

从原始 SAR 数据的复数形式出发, 模拟复数卷积的基本算法, 提出虚拟的“实部”与“虚部”两个卷积核, 并实现卷积核共享与耦合计算, 输出经复数卷积后的实部与虚部的特征图. 如图 3 所示, 实部特征图 I 和虚部特征图 Q 分别与实部卷积核 I 和虚部卷积核 Q 进行计算, 将得到的 4 个特征图重新耦合成两张特征图, 即 II 与 QQ 相减得到下一层的特征图 I , IQ 与 QI 相加得到下一层的特征图

图 4 基于复数数据学习的池化层与反池化层

Figure 4 Pooling and up-pooling layer based on complex valued data learning

Q. 上述理论可由式 (1) 表述, 其中 $O_i^{(n)}$ 是第 n 层的输入特征图, $V_j^{(n+1)}$ 是第 $n+1$ 层的输出特征图, $\omega_{ji}^{(n+1)}$ 与 $b_i^{(n+1)}$ 分别是两层间的权重链接系数和偏置值.

$$\begin{aligned}
 V_j^{(n+1)} &= \sum_i \omega_{ji}^{(n+1)} \otimes O_i^{(n)} + b_i^{(n+1)} \\
 &= \sum_i \left[R(\omega_{ji}^{(n+1)}) \cdot R(O_i^{(n)}) - I(\omega_{ji}^{(n+1)}) \cdot I(O_i^{(n)}) \right] \\
 &\quad + j \cdot \sum_i \left[R(\omega_{ji}^{(n+1)}) \cdot I(O_i^{(n)}) + I(\omega_{ji}^{(n+1)}) \cdot R(O_i^{(n)}) \right] + b_i^{(n+1)}. \quad (1)
 \end{aligned}$$

3.1.2 基于复数数据学习的池化层与反池化层

池化层由卷积层得到的特征图作为输入, 将实部通道与虚部通道数据合成计算取模后并记录最大值位置索引, 由该位置索引分别对实部特征图与虚部特征图进行下采样, 以达到缩小特征图与简化网络负担的目的. 每个下采样层中存储的最大值位置索引为相应特征图的上采样过程提供位置信息. 反池化层中先将输入的特征图放大两倍, 然后将下采样过程中最大值所在位置坐标值激活, 其他值设置为零. 池化层与反池化层原理如图 4 所示.

3.1.3 损失函数

语义分割网络中最后一个卷积层输出所有类别的特征 (logits), 并在其后添加一个 Softmax 层. Softmax 层将 logits 值标准化到 0~1 之间, 并将其记作每一个像素在所有类别最大的概率. 引入交叉熵 (cross-entropy, CEH) 来对真实样本分布 $p(x)$ 和预测模型分布 $q(x)$ 的差异进行度量, 损失 (LOSS)

图 5 基于 SAR 图像目标检测的深度复数语义分割网络参数设定
Figure 5 Configuration of CV-SegNet for target detection in SAR images

为计算的所有样本中所有像素点的交叉熵之和. 对于建筑物侧立面分割的二分类问题, 可表述为式 (3), 其中 y 为独热编码后的真实标签、 $h_{\theta}(x)$ 为预测模型分布. M 为当前批次的样本数.

$$\text{CEH}(p, q) = - \sum_{x \in X} p(x) \log(q(x)), \quad (2)$$

$$\text{LOSS} = - \frac{1}{M} \sum_m \sum_i \left[y_m^{(i)} \log h_{\theta}(x_m^{(i)}) + (1 - y_m^{(i)}) \log(1 - h_{\theta}(x_m^{(i)})) \right]. \quad (3)$$

3.2 网络参数配置

本文基于 SegNet^[20] 提出的 CV-SegNet 核心分割引擎包含一个编码网络, 一个对应的解码网络, 并跟随着一个像素级别的分类层, 编码网络的架构在拓扑上与 VGG16 网络中的 13 个卷积层相同^[20]. 如图 5 所示, 编码网络中, 基于复数卷积耦合计算方法的卷积层与 BN 层以及非线性激活函数 ReLU 封装成为整体, 形成功能复数域拓展后的卷积层 (CV-convolution layer). 卷积层中卷积核的滑动步长 (stride) 全部取 1, 并在输入特征图的周围补零. 上述每个卷积层的后面接有应用于复数数据学习的池化层, 采用 Maxpooling 的方式, 下采样窗口大小 (pooling size) 为 2×2 , 滑动步长 (stride) 为 2. 解码网络内部设置与编码网络相类似, 逐步将高层特征图恢复到输入特征图大小. Softmax 非线性函数作

用于解码网络中第 13 个卷积层的输出解点. 网络的输入图像大小为 $256 \times 256 \times 3$, 前两个卷积层选取了 64 个大小为 $3 \times 3 \times 3$ 的卷积核, 输出 64 个 $256 \times 256 \times 3$ 的特征图, 经过第 1 个池化层后, 特征图大小变为 $128 \times 128 \times 3$. 第 1 个池化层的输出送入第 3 个卷积层, 它包含 128 个大小为 $3 \times 3 \times 3$ 的卷积核, 输出 128 个 $128 \times 128 \times 3$ 的特征图, 经过第 2 个池化层后特征图大小变为 $64 \times 64 \times 3$. 以此类推, 经过第 5 个池化层后得到 512 个大小为 $8 \times 8 \times 3$ 的最高层特征图. 特征图经解码网络的卷积和反池化操作后, 在第 13 个卷积层中输出 2 张大小为 $256 \times 256 \times 3$ 的特征图, 以保证每个像素对应 2 个输出节点, 每个节点的输出值经过 Softmax 归一化后为一个类别的预测概率.

4 基于 RaySAR 仿真的 SAR 图像 – 三维点云数据集构建方法

深度神经网络的训练需要大量的数据支持, 针对 SAR 图像数据尤其对应的三维结构数据严重缺乏的困境, 本文采用 SAR 图像高效仿真方法, 构建一个虚拟的 SAR 图像 – 三维点云数据集, 并通过神经网络进行仿真参数的回归预测, 提高仿真相似度.

4.1 三维目标的 SAR 图像仿真

面向目标三维模型的 SAR 图像仿真技术是一项各国都非常重视的关键技术, 著名的 SAR 仿真软件美国 Xpatch 对华禁运、意大利 ARESYS 公司的 GSS 软件价格高昂且仿真能力有限, 我国东南大学、北京无线电测量研究所 207 所等单位经过多年积累也开发了自主知识产权的 SAR 目标电磁仿真软件, 其仿真目的主要在于获得目标高精度 RCS 等量化目标特性. 本文的 SAR 目标图像仿真, 并不需要在 RCS 方面的高精度, 而拟得到在图像结构、散射中心分布方面具有与真实图像较好相似度的仿真结果. 为此, 本文采用了 DLR 于 2016 年开源的 RaySAR 仿真软件. RaySAR 依赖于 POV-Ray 提供的射线追踪功能, 利用物理光学法计算模拟信号的散射强度和三维位置即方位向位置、斜距向位置以及高程, 最后进行仿真图像构建, 其仿真结果能够保证在几何方面的准确性, 同时可以通过合理设置目标镜面反射系数 (specular)、漫反射系数 (diffuse)、粗糙度 (roughness)、多次散射衰减系数 (reflection) 等物理参数的初始值, 获得较高的图像相似度.

为了提高参数设置的准确性以提升仿真结果相似度, 作者前期工作^[21]提出了一种人工智能辅助电磁计算的目标仿真方法, 通过设计合理的神经网络结构和损失函数, 实现了实际观测样本信息向 SAR 目标仿真系统的馈入, 可利用实际获取的 SAR 图像回归预测更加合理的仿真参数. 同时, 为了提高仿真速度, 本文对 RaySAR 进行了 GPU 加速和参数输入方式的批量化改造, 实现了大规模仿真样本的快速生成. 在设置最高散射次数为 5100 万条射线的条件下, 生成 480×320 尺寸仿真图像耗时约为 3 s.

为构建一个面向建筑物三维重建的相对充分的数据集, 本文基于 GoogleEarth 公开模型集, 选择了苏州、上海、北京、广州等地 60 个建筑模型. 这些建筑模型涵盖了民用住宅、工业建筑、商用建筑等不同类型, 建筑形状包括了比较规则的多边形棱柱, 也包含了一些不规则的弧状建筑, 如长方体、圆柱、塔状、棱台、锥形等. 为了尽可能模拟不同材质、不同地面背景、不同噪声等情况下的图像, 本文对每个建筑模型进行仿真时采用了三组典型的镜面反射系数、漫反射系数等仿真参数. 由于对于实际 SAR 图像而言, 入射角准确可知, 为此本文仿真时 SAR 入射角恒定设为 25° , 对每个建筑模型以 20° 方位角为间隔进行仿真, 共仿真得到了 3240 个目标图像样本. 图 6 给出 4 种典型建筑在两组不同方位角下的仿真结果.

图 6 两组不同方位角下典型建筑的 SAR 图像仿真结果

Figure 6 Two groups of SAR image simulation results of typical buildings in different azimuth angles

4.2 SAR 仿真图像对应的三维点云生成

RaySAR 仿真软件在仿真获得 SAR 图像时, 输入的三维模型为 obj 格式, 该格式很难进行数学表达, 从而难以直接作为三维生成网络的输出. 为了获得便于计算和使用的三维数据格式, 本文选用较为常用的三维点云格式, 其具有数学表达形式简单、存储空间小、易于网络学习的特点, 且在传统的 SAR 三维成像 (例如阵列 SAR, TomoSAR 等) 中, 通常也采用点云作为主要的三维表达形式.

本文尝试了从真值模型直接获得仿真图像对应三维点云的方法. 借助 Point Cloud Library 开源库将收集到的三维建筑 obj 模型进行下采样, 均匀构建三维体素栅格, 以每个体素栅格内的重心点位置坐标来代表三维点云的坐标, 最后输出恒定数量的点集, 本文中的建筑模型均以 2048 个点来表示. 该方法能够保证点云结构具有较好的完整性, 不因 SAR 图像存在阴影等而缺失, 可以用于检验三维生成网络在结构生成方面的能力, 最大程度上从真实 SAR 图像建筑目标恢复其完整的空间三维结构. 采用该方法得到的不同目标模型的仿真图像和点云如图 7 所示.

5 基于 3D 生成网络的 SAR 图像三维重建

利用单幅图像进行目标或场景的三维重构是近期计算机视觉、深度学习领域中的研究热点之一, 目前针对光学自然图像, 已有多个三维模型的公共数据集供研究人员使用, 如 PASCAL 3D+^[22], Shapnet^[23], ModelNet^[24] 以及 IKEA Dataset^[25] 等, 并已经涌现了一批研究成果. Wu 等^[24] 提出将目标三维结构表示为三维体素上的概率分布, 利用深度卷积置信网络 (convolutional deep belief network, CDBN) 基于深度图恢复目标三维结构, 同时建立大型三维数据库 ModelNet. Choy 等^[26] 提出 3D-R2N2 网络, 基于二维卷积编码器对于输入的二维图像提取特征向量, 基于三维 LSTM 解码器重构目标三维模型. Wang 等^[27] 提出由图像直接生成三维网格, 网络结构分为一个二维卷积编码器和三维解码器 GCN (graph convolutional network). 上述研究主要基于光学自然图像, 目前基于深度学习等方法的遥感图像三维重建研究仍处于起步阶段, 而将上述方法用于 SAR 图像的三维重建则尚未见报道.

本文结合上述利用单幅图像进行三维重建方面的最新进展, 对深度学习在 SAR 图像三维重建中的可行性进行了初步探索, 参考文献 [10] 构建了相应的网络结构模型 SAR Point Generation Net (SARPGN), 用于直接从 SAR 图像生成无序点云数据. 如图 8 所示, 网络结构分为编码器和解码器, 编码器用于提取 SAR 图像特征, 将高维特征逐层压缩至低维特征并去除图像中的冗余信息, 解码器用

图 7 基于模型生成的点云和仿真图像

Figure 7 Point clouds and simulation images generated based on models

于将图像中的低维特征逐层重构, 最后在输出层得到三维点云. 本文以一个三维张量 $\langle H, W, C \rangle$ 表示每层网络输出特征图的尺寸, 其中 $\langle H \rangle$ 代表特征图的高度, $\langle W \rangle$ 代表特征图的宽度, $\langle C \rangle$ 代表特征图的深度. 在卷积与反卷积的过程中, 多次使用跳跃连接, 融合不同深度的 SAR 图像特征图以提高神经网络在不同尺度下多特征的学习能力. 本文同样借鉴文献 [10] 的思想, 设计出二重编码解码结构, 该结构可以更好地融合局部与全局三维信息, 增加了预测点云的空间连续性, 从而提高对光滑表面的表达能力. 为了更好地考虑三维物体的几何特征, 解码器分为两个分支, 全连接层分支和反卷积层分支. 其中, 全连接层分支输出一个大小为 1024×3 的预测矩阵, 存储 1024 个预测点的三维坐标, 反卷积层分支输出一张大小为 $32 \times 32 \times 3$ 的特征图, 特征图中每个像素点的 3 通道深度对应存储一个预测点的三维坐标, 最后, 两分支预测出的点云共同组成共计包含 2048 个点的输出点集.

在损失函数设计方面, 使用推土机距离 (earth move distance) 来作为预测点云 S_1 和真值点云 S_2 的度量. 该方法可以有效度量比较完全不同的概率分布, 最大限度地增强了两个分布样本之间的差异, 如式 (4) 所示. 其中 $\phi(x)$ 为 S_1 到 S_2 的双射.

$$D_{\text{EMD}}(S_1, S_2) = \min_{\phi: S_1 \rightarrow S_2} \sum_{x \in S_1} \|x - \phi(x)\|_2. \quad (4)$$

为使预测点云分布均匀以增加模型的可表达性和鲁棒性, 本文引入排斥损失函数 (repulsion loss)

图 8 SAR point generation (SARPGN) 网络结构
Figure 8 Structure of SAR point generation network (SARPGN)

来进一步优化网络训练过程, 如式 (5) 所示.

$$L_{\text{rep}}(S_1, S_2) = \sum_{i=0}^N \sum_{i' \in K(i)} \eta(\|x_{i'} - x_i\|) \omega(\|x_{i'} - x_i\|), \quad x_{i'} \in S_1, x_i \in S_2, \quad (5)$$

其中 $N = 2048$, $K(i)$ 是 x_i 的 K 个近邻点, 排斥项 $\eta(r) = -r$ 使得近邻点具有更大的损失, 快速衰减函数 $\omega(r) = e^{-r^2/h^2}$ 约束只有 x_i 的 K 个近邻点才受到惩罚.

利用上述公式, 本文分别设计两种损失函数, 记为 loss1 和 loss2 , 分别对神经网络进行训练, 描述如式 (6) 和 (7). 其中权值 $\lambda = 0.93$, $\mu = 0.07$.

$$\text{loss1} = D_{\text{EMD}}(S_1, S_2), \quad (6)$$

$$\text{loss2} = \lambda D_{\text{EMD}}(S_1, S_2) + \mu L_{\text{rep}}(S_1, S_2). \quad (7)$$

采用 4.2 小节仿真数据集中 70% 的图像 - 点云数据对网络进行训练, 其余 30% 作为测试集进行测试, 重建结果如图 9 所示, 初步验证了 SARPGN 的三维重建能力.

然而, 上述三维点云生成结果只能获得归一化的建筑物相对尺寸结构, 无法获得建筑物的绝对大小. 为此, 本文基于第 3 小节建筑物侧立面分割, 通过分割结果中上部线条和底部线条的距离向间隔 $\text{Pixel}_{\text{Interval}}$ 、距离向分辨率 Pixel_Y 及成像入射角 θ , 由式 (8) 计算得到建筑物的高度 h , 并利用该高度, 对三维点云进行尺寸缩放, 从而得到最终的三维重建结果.

$$h = \frac{\text{Pixel}_{\text{Interval}} \cdot \text{Pixel}_Y}{\cos \theta}. \quad (8)$$

图 9 SARPGN 在初始测试集下的部分结果
Figure 9 Results of SARPGN on its initial test set

图 10 (a) 苏州和 (b) 香港地区的 SAR 图像
Figure 10 SAR images of (a) Suzhou and (b) Hong Kong

6 实验分析

6.1 实验数据集及预处理

训练数据为由 TerraSAR-X 获取的苏州地区的 HH 单极化 SAR 图像. 获取时间为 2015 年 6 月 24 日, 近距入射角为 34.890° , 远距入射角为 35.430° , 方位向像元分辨率为 0.230 m, 距离向像元分辨率为 1.021 m. 图 10(a) 为经整体量化处理显示的苏州地区 HH 极化 SAR 图像, 该地区包含典型建筑物群, 应用于建筑物高亮度侧立面特征区域的训练及测试. 重建区域为 GF-3 号获取的香港区域的 VV 单极化 SAR 图像, 获取时间为 2016 年 8 月 15 日, 近距入射角为 41.946° , 远距入射角为 42.553° , 如图 10(b) 所示.

SAR 的单视复数图像动态范围很大, 为了便于网络学习, 本文首先对图像进行了量化调整处理, 采用对小范围 SAR 进行负指数变换操作, 我们将大小为 $m \times n$ 的切片数据记作 S_{ij} , 其中 $i = 1, 2, \dots, m$, $j = 1, 2, \dots, n$. 预处理具体过程如式 (9)~(12).

首先对每一个切片计算像素值均值 S_{ave} :

$$S_{ave} = \frac{1}{mn} \sum_{ij} |S_{ij}|. \quad (9)$$

引入负指数量化因子 k :

$$k = \frac{\sqrt{2} \times \ln 2}{\sqrt{(1 + \ln 2)S_{\text{ave}}}}. \quad (10)$$

对原始切片数据 S_{ij} , 按式 (6) 进行负指数量化, 像素值范围标准化到 $[0, 1]$, 标准化切片数据记为 N'_{ij} :

$$N'_{ij} = 1 - \exp(-k \cdot |S_{ij}|). \quad (11)$$

将标准化切片数据像素值范围扩充到 $[0, 255]$, 最终得到经负指数量化后的切片数据 S'_{ij} :

$$S'_{ij} = 255N'_{ij}. \quad (12)$$

基于上述地区原始 SAR 幅度图像数据构建了实数图像和复数图像两个数据集, 其中实数数据集是经预处理后直接应用于实数语义分割网络的幅度图像, 采用滑窗式均匀切片的方法对整幅 SAR 图像进行切割. 切片总数为 10000 张, 其中 7246 张作为训练集, 剩余 2754 张作为测试集, 切片大小为 256×256 . 而对于复数语义分割网络, 原始 SAR 复数形式数据的实部和虚部分别经上述相同的方式量化后重新拼接成复数, 为保证其物理意义, 需要将式 (12) 的扩大系数 255 更改为 $255/\sqrt{2}$.

6.2 实验环境

本文中基于 SAR 复数形式数据认知学习的语义分割网络与 3D 点云生成网络的训练和测试过程的实验平台参数为 Windows Server 2008 64 位操作系统, Intel(R) Xeon(R) CPU E5-2683 2.00 GHz, 2 颗, GPU 为 NVIDIA Tesla P100, 4 颗, 采用 Tensorflow 第三方开源库来实现. 在实验中, 语义分割网络训练过程采用自适应学习率优化算法 (adaptive moment estimation, Adam), 加权指数衰减 (batch norm decay) 的值设为 0.95, 采用 Step 学习策略, 其中学习率 (learning rate) 设置为 0.0001, 批处理大小 (batch size) 设置为 16, 这些参数可以帮助本文的网络框架取得更好的效果.

6.3 实验结果与分析

6.3.1 基于复数语义分割网络的 SAR 建筑物分割

本文主要研究在高分辨率 SAR 图像中, 分别应用实数语义分割网络和等效复数语义分割网络, 并将这两种网络分别命名为 RV-SegNet 和 CV-SegNet, 提取单个建筑物的高亮度侧立面区域, 并进行对比分析. 实数语义分割网络的输入为经过 6.1 小节所述的预处理后的 SAR 幅度图像, 网络结构中为传统的实数卷积层和上下采样层. 等效的复数语义分割网络的输入为经相同预处理方式后的 SAR 复数数据, 结合基于复数卷积耦合计算方法的卷积层, 基于复数数据学习的池化层与反池化层, 完成对 SAR 图像建筑物特征区域的分割. 在苏州地区数据集下进行实验验证, 测试集下检测结果如图 11 和 12 所示. 实验中, 实数语义分割网络与复数语义分割网络分别在迭代次数为 7×10^4 和 1×10^5 时收敛, 网络所展示出的性能指标如图 13 及表 1 所示.

语义分割架构应用于建筑物高亮度侧立面特征区域的检测性能较好, 图像中绝大多数可判读的目标区域被标记成为红色. 相比于仅适用于幅度实数数据作为输入的传统语义分割网络, 基于耦合等效复数网络使用 SAR 图像原始复数数据作为输入, 并结合复数卷积改进的算法, 检测性能上有一定的提升, 主要表现在检测区域结果的精细化和语义的规则化. 实验中传统实数语义分割网络的准确率维持在 0.996, 复数语义分割网络的准确率小幅提升至 0.998. 在召回率和 F1 值方面, 复数语义分割网络较之传统实数语义分割网络均有约 2% 的提高. 这也意味着, 本文提出的基于 SAR 复数形式数据认知学习的语义分割网络更加适用于 SAR 图像的解译.

图 11 基于复数语义分割网络的 SAR 图像中建筑物侧立面检测结果. (a) SAR 图像; (b) 预测标签; (c) SAR 图像与预测标签融合的检测结果

Figure 11 Results of building facade detection in SAR images based on CV-SegNet. (a) SAR images; (b) prediction tags; (c) detection results of fusion of SAR images and prediction tags

图 12 SAR 图像中建筑物侧立面检测结果对比. (a) 原始 SAR 幅度图像; (b) RV-SegNet 提取结果; (c) CV-SegNet 提取结果.

Figure 12 Comparison of results of building facade detection in SAR images. (a) Original amplitude SAR images; (b) extraction results of RV-SegNet; (c) extraction results of CV-SegNet.

图 13 语义分割网络在 SAR 图像建筑物侧立面检测任务中的性能指标对比. (a) 准确率; (b) 召回率; (c) F1 值. 每排的左图为使用 RV-SegNet 的实验结果, 右图为使用 CV-SegNet 的实验结果, 图中橙色曲线为训练集下结果, 蓝色曲线为测试集下结果.

Figure 13 Comparisons of semantic segmentation network performance of building facade detection in SAR images. (a) Overall accuracy; (b) recall; (c) F1 value. The left pictures show the performance of RV-SegNet, and the right pictures show the performance of CV-SegNet. The orange curves in the figures are the results on training set, and the blue curves are the results on test set.

表 1 语义分割网络在 SAR 图像建筑物侧立面检测任务中的性能指标对比

Table 1 Comparisons of semantic segmentation network performance of building facade detection in SAR images

Item	RV-SegNet	CV-SegNet
Overall accuracy	0.996	0.998
Recall	0.900	0.920
F1 value	0.920	0.940

6.3.2 基于点云生成网络的 SAR 典型建筑物三维模型重建

为了验证三维重建方法对于实际 SAR 图像的有效性, 本文对香港地区 Harbourfront landmark, International Finance Centre, Laguna City, Hyatt Regency, Empire Centre, Hopewell Centre 共计 6 个典型建筑物进行了三维重建并在图中给予编号标注, 重建目标涵盖了建筑物的常见类型, 如近似立方

图 14 香港地区典型建筑的三维模型

Figure 14 3D models of typical buildings in Hong Kong area. (a) Harbourfront landmark; (b) International Finance Centre; (c) Laguna City; (d) Hyatt Regency; (e) Empire Centre; (f) Hopewell Centre.

体、扁平长方体、圆柱体及塔状结构. 由 Google Warehouse 开源模型库获取的三维模型如图 14 所示.

实验基于 RV-SegNet 与 CV-SegNet 对 SAR 图像建筑目标进行分割, 并对分割结果分别用两种损失函数计算的 SARPGN 生成三维点云模型, 结合分割图像与入射角信息计算建筑物高度对三维点云进行尺寸缩放, 从而得到包含尺寸信息的三维重建结果, 如图 15 所示.

为分别分析 CV-SegNet 与 SARPGN 对 SAR 建筑物三维重建的提升效果, 本文使用倒角距离 (chamfer distance) 作为预测点云与真值模型的相似性度量, 如式 (13) 所示, 其中, 预测点云为 S_1 , 真值点云为 S_2 , 相似性度量结果如表 2 所示.

$$d_{CD}(S_1, S_2) = \sum_{x_{i'} \in S_1} \min_{x_i \in S_2} \|x_{i'} - x_i\|_2^2 + \sum_{x_i \in S_2} \min_{x_{i'} \in S_1} \|x_i - x_{i'}\|_2^2. \quad (13)$$

从重建结果可以看出, SARPGN 对于其他地区实际图像也具备一定的适应能力, 可以重建出建筑目标的基本三维结构, 验证了本文基于深度神经网络的 SAR 三维重建方法的可行性. CV-SegNet 对 SAR 图像建筑物侧立面的提取能力优于 RV-SegNet, 同时改进的 SARPGN(loss2) 针对 SAR 图像的三维模型生成能力较 SARPGN(loss1) 也有所提升.

7 结语

本文提出了基于深度神经网络的 SAR 目标三维重建方法, 首先提出耦合等效复数语义分割网络, 将基于复数卷积耦合计算方法的卷积层贯穿于整个端到端的神经网络框架中, 实现对 SAR 复数图像的有效处理, 完成 SAR 图像建筑物侧立面检测. 然后基于 RaySAR 仿真 SAR 图像及对应的三维点云形成训练数据集, 对提出的 SAR 三维点云生成网络进行训练. 最后将建筑检测结果输入生成网络, 完成 SAR 典型建筑物三维模型重建. 采用 TerraSAR-X 与 GF-3 号高分辨率图像进行了 SAR 三维重建

图 15 SAR 图像典型建筑物侧立面提取结果及三维点云重建结果

Figure 15 Facade extraction and 3D point cloud reconstruction results of typical buildings from SAR images

表 2 SAR 图像建筑物三维重建模型相似性度量结果对比

Table 2 Similarity comparisons of 3D building reconstruction models from SAR images

Building number	Chamfer distance d_{CD}			
	SARPGN(loss1)		SARPGN(loss2)	
	RV-SegNet	CV-SegNet	RV-SegNet	CV-SegNet
1	0.6597	0.6590	0.6526	0.5739
2	0.7327	0.7025	0.3488	0.3061
3	0.9799	0.9059	1.0051	0.9280
4	0.5032	0.4391	0.4894	0.4141
5	1.0797	1.0683	1.0363	1.0243
6	0.5970	0.5286	0.4756	0.4634
Average	0.7587	0.7172	0.6680	0.6183

的全链路实验, 结果验证了方法的初步可行性, 为 SAR 目标三维重建提供了新的技术途径. 后续研究将进一步改善 SAR 图像建筑目标自动提取的方法, 提高 SAR 目标仿真能力, 研究仿真模型和数据集的合理构建方法, 并针对 SAR 图像特点改进三维生成网络, 同时提高三维结构信息提取的精度.

参考文献

- Gamba P, Houshmand B, Saccani M. Detection and extraction of buildings from interferometric SAR data. *IEEE Trans Geosci Remote Sens*, 2000, 38: 611–617
- Bolter R. Reconstruction of man-made objects from high resolution SAR images. In: *Proceedings of 2000 IEEE Aerospace Conference*, 2000. 287–292
- Zhao L J, Zhou X G, Kuang G Y. Building detection from urban SAR image using building characteristics and contextual information. *EURASIP J Adv Signal Process*, 2013, 2013: 56
- Fu X Y, You H J, Fu K. 3-D reconstruction of building from single high-resolution SAR image. *J Infrared Millim Waves*, 2012, 31: 569–576 [傅兴玉, 尤红建, 付琨. 单幅高分辨率 SAR 图像建筑三维模型重构. *红外与毫米波学报*, 2012, 31: 569–576]
- Xu F, Jin Y Q. Automatic reconstruction of building objects from multiaspect meter-resolution SAR images. *IEEE Trans Geosci Remote Sens*, 2007, 45: 2336–2353
- Pontes J K, Kong C, Sridharan S, et al. Image2mesh: a learning framework for single image 3D reconstruction. In: *Proceedings of Asian Conference on Computer Vision*. Berlin: Springer, 2018. 365–381
- Kurenkov A, Ji J, Garg A, et al. Deformnet: free-form deformation network for 3D shape reconstruction from a single image. In: *Proceedings of IEEE Winter Conference on Applications of Computer Vision*, 2018. 858–866
- Kniaz V V, Remondino F, Knyaz V A. Generative adversarial networks for single photo 3D reconstruction. *Int Arch Photogramm Remote Sens Spatial Inf Sci*, 2019, 42-2/W9: 403–408
- Mandikal P, Murthy N, Agarwal M, et al. 3DLMNet: latent embedding matching for accurate and diverse 3D point cloud reconstruction from a single image. 2018. ArXiv: 1807.07796
- Fan H Q, Su H, Guibas L J. A point set generation network for 3d object reconstruction from a single image. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017. 605–613
- LeCun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition. *Neural Comput*, 1989, 1: 541–551
- Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition. *Proc IEEE*, 1998, 86: 2278–2324
- Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks. In: *Proceedings of Advances in Neural Information Processing Systems*. 2012. 1097–1105
- Zeiler M D, Fergus R. Visualizing and understanding convolutional networks. In: *Proceedings of European Conference*

- on Computer Vision. Berlin: Springer, 2014. 818–833
- 15 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. 2014. ArXiv: 1409.1556
 - 16 He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016. 770–778
 - 17 Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015. 3431–3440
 - 18 Duan Y P, Tao X M, Han C Y, et al. Multi-scale convolutional neural network for SAR image semantic segmentation. In: Proceedings of IEEE Global Communications Conference, 2018. 1–6
 - 19 Xu F, Wang H P, Jin Y Q. Deep learning as applied in SAR target recognition and terrain classification. J Radars, 2017, 6: 136–148
 - 20 Badrinarayanan V, Kendall A, Cipolla R. Segnet: a deep convolutional encoder-decoder architecture for image segmentation. 2015. ArXiv: 1511.00561
 - 21 Niu S R, Qiu X L, Peng L X, et al. Parameter prediction method of SAR target simulation based on convolutional neural networks. In: Proceedings of European Conference on Synthetic Aperture Radar, 2018. 1–5
 - 22 Xiang Y, Mottaghi R, Savarese S. Beyond PASCAL: a benchmark for 3D object detection in the wild. In: Proceedings of the 2014 IEEE Winter Conference on Applications of Computer Vision. New York: IEEE, 2014. 75–82
 - 23 Chang A X, Funkhouser T, Guibas L, et al. Shapenet: an information-rich 3D model repository. 2015. ArXiv: 1512.03012
 - 24 Wu N Z, Song S, Khosla A, et al. 3D ShapeNets: a deep representation for volumetric shape modeling. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015. 1912–1920
 - 25 Lim J J, Pirsiavash H, Torralba A. Parsing Ikea objects: fine pose estimation. In: Proceedings of the IEEE International Conference on Computer Vision, 2013
 - 26 Choy C B, Xu D, Gwak J Y, et al. 3D-R2N2: a unified approach for single and multi-view 3D object reconstruction. In: Proceedings of European Conference on Computer Vision. Berlin: Springer, 2016. 628–644
 - 27 Wang N Y, Zhang Y D, Li Z W, et al. Pixel2Mesh: generating 3D mesh models from single RGB images. In: Proceedings of the European Conference on Computer Vision. Berlin: Springer, 2018. 55–71

A 3D building reconstruction method for SAR images based on deep neural network

Jiankun CHEN^{1,2,3,5†}, Lingxiao PENG^{1,2,4,5†}, Xiaolan QIU^{1,2,4,5*}, Chibiao DING^{1,4,5} & Yirong WU⁵

1. National Key Laboratory of Science and Technology on Microwave Imaging, Chinese Academy of Sciences, Beijing 100190, China;
2. The Key Laboratory of Technology in Geo-spatial Information Processing and Application System, Chinese Academy of Sciences, Beijing 100190, China;
3. University of Chinese Academy of Sciences, Beijing 100049, China;
4. Laboratory of Spatial Information Intelligent Processing System, Institute of Electronics, Chinese Academy of Sciences, Suzhou 215000, China;
5. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China

* Corresponding author. E-mail: xlqiu@mail.ie.ac.cn

† Equal contribution

Abstract Owing to its momentous applications in urban planning, disaster monitoring, smart cities and other fields, 3D building reconstruction is an important topic in many research areas such as computer vision, photogrammetry, and remote sensing. The particularity and complexity of the microwave scattering mechanism bring great challenges to the 3D building reconstruction of SAR images, and the applicability and automation of existing methods need to be improved. This study constructs the overall framework of building detection in SAR images and 3D reconstruction based on deep learning and radar imaging mechanism. It puts forward a method of using a coupled equivalent complex valued convolutional neural network for building facade detection in SAR images, a method for RaySAR-based modeling simulation and point cloud generation for 3D model training, and a method for a 3D generation network for 3D building reconstruction from SAR images. Experiments using TerraSAR-X and GF-3 high resolution SAR images are carried out, producing good 3D reconstruction results. The proposed method is a useful attempt for 3D target reconstruction of SAR images and represents a new technical approach.

Keywords SAR, deep learning, semantic segmentation, point cloud generation, building detection, 3D reconstruction

Jiankun CHEN was born in 1995. He received his B.S. degree in electronics from Jilin University, Changchun, China and Tomsk Polytechnic University, Tomsk, Russia, in 2017. Currently, he is a Ph.D. candidate at Aerospace Information Research Institute, Chinese Academy of Sciences, and the University of Chinese Academy of Sciences. His research interests include remote sensing applications and deep learning.

Lingxiao PENG was born in 1990. He received his M.S. degree in computer science from Nanjing University of Science and Technology, Nanjing, China, in 2016. He is currently a research associate at Suzhou Institute of the Institute of Electronics, Chinese Academy of Sciences. His research interests include SAR image processing and applications and computer vision.

Xiaolan QIU was born in 1982. She received her B.S. degree in electronic engineering and information science from the University of Science and Technology of China, Hefei, China, in 2004, and her Ph.D. degree in signal and information processing from the Graduate University of the Chinese Academy of Sciences, Beijing, China, in 2009. From 2009, she has been working at the Institute of Electronics, Chinese Academy of Sciences, Beijing. Her research interests include SAR imaging and geo-correction, SAR simulation, and SAR image interpretation.

Chibiao DING was born in 1969. He received his B.S. and Ph.D. degrees in electronics engineering from Beihang University, Beijing, China, in 1997. Since then, he has been working at the Institute of Electronics, Chinese Academy of Sciences, Beijing, where he is currently a research fellow and vice director. His main research interests include advanced synthetic aperture radar systems, signal processing technology, and information systems.