

基于多尺度注意力机制的PolSAR深度学习超分辨率模型

林镠鹏¹, 李杰², 沈焕锋^{1,3}

1. 武汉大学 资源与环境科学学院, 武汉 430079;

2. 武汉大学 测绘学院, 武汉 430079;

3. 湖北珞珈实验室, 武汉 430079

摘要: 全极化合成孔径雷达影像 (PolSAR) 可提供丰富的极化信息, 但成像系统限制使其空间分辨率受到制约。为解决此问题, 本文基于深度学习框架, 提出一种基于多尺度注意力机制的超分辨率重建网络 (MS-PSRN), 通过对低分辨率PolSAR影像进行分辨率增强, 生成高分辨率的PolSAR影像。在该模型框架下, 采用多尺度注意力模块对不同尺度下的地物目标进行特征提取; 提出联合式与分离式两种内嵌方式, 在模型中嵌入通道注意力与空间注意力, 利用注意力机制的权值重校准特性, 增强PolSAR影像的极化信息与空间信息; 引入残差信息蒸馏机制, 提取判别性特征并对模型参数进行压缩; 提出自适应损失函数对网络训练过程进行约束以提升模型的数值拟合能力以及边缘信息保持能力。最后, 采用RADARSAT-2卫星的模拟数据与真实数据两个数据集对提出的方法进行验证。空间信息实验结果表明本文方法在目视结果与定量指标中均优于对比算法, 具有更高的空间纹理细节重建精度与较低的重建误差; 极化信息保持测试表明, 本文方法可在提升空间分辨率的同时, 有效保持PolSAR影像的极化信息。

关键词: 遥感, 全极化合成孔径雷达, 超分辨率重建, 深度学习, 遥感, 多尺度, 注意力机制

中图分类号: TP75/P2

引用格式: 林镠鹏, 李杰, 沈焕锋. 2024. 基于多尺度注意力机制的PolSAR深度学习超分辨率模型. 遥感学报, 28(9): 2362-2371

Lin L P, Li J and Shen H F. 2024. PolSAR image deep learning super-resolution model based on multiscale attention mechanism. National Remote Sensing Bulletin, 28(9): 2362-2371 [DOI: 10.11834/jrs.20233002]

1 引言

全极化合成孔径雷达成像系统可通过多种极化方式 (HH, HV, VH, VV) 获得单一场景中地物的多种极化散射信息, 其获取的PolSAR影像在舰船识别 (Wang 和 Liu, 2015; Zhang 等, 2019)、建筑物灾后检测 (Shi 等, 2015; Zhao 等, 2013)、土地利用分类 (Qi 等, 2012) 等多个领域中得到广泛应用。相比单极化 SAR 影像, PolSAR 影像能提供更为丰富的极化信息。然而, 受信号带宽和天线尺寸等系统限制, 部分 SAR 成像系统为获取多种极化信息, 不可避免需要降低影像空间分辨率。而空间分辨率的降低导致 PolSAR 影像在精细化应

用中受限。因此, 利用影像处理技术增强 PolSAR 影像分辨率十分必要。

近年来, 超分辨率重建技术 (超分) 已广泛应用于光学影像与单极化 SAR 影像的空间分辨率增强 (范冲 等, 2009; 贺智和贺丹, 2020), 但目前为止, 针对全极化 SAR 影像的研究则相对较少。2006年, Suwa 和 Iwamoto (2007) 提出二维极化带宽外推法 (2D-PBWE), 利用二维极化线性预测模型扩展距离向与方位向的极化频率带宽以提升分辨率。2008年, Zou 等 (2008) 在极化分解的基础上提出一种四象元超分辨率方法, 通过对中心像素与邻近像素加权, 得到增强的子像素值。该方法仅考虑中心像素与邻近像素的关系, 重建结

收稿日期: 2023-01-03; 预印本: 2023-03-14

基金项目: 湖北珞珈实验室开放基金 (编号: 220100041); 国家自然科学基金 (编号: 62071341, 42301417)

第一作者简介: 林镠鹏, 研究方向为影像质量改善、数据融合等。E-mail: linliupeng@whu.edu.cn

通信作者简介: 沈焕锋, 研究方向为资源环境遥感、多源数据融合、地学智能等。E-mail: shenhf@whu.edu.cn

果中存在明显格网效应。基于极化空间相关性的超分辨率方法 (SRPSC) (Zhang等, 2011), 通过引入子像素空间相关性改进像素加权方式, 有效缓解格网效应, 但该方法依赖于极化分解, 不同极化分解方法下的重建结果精度差异较大。此外, 谱分析技术 (Pastina等, 2001)、凸集投影算法 (Chen和Yang, 2007) 等方法也相继应用于PolSAR影像超分任务中。

现有的算法采用多为逐通道处理再融合的方式, 未充分考虑极化通道间的关系。研究表明, 在PolSAR影像超分重建过程中引入多通道极化信息能得到更稳健的结果 (Pastina等, 2001)。但PolSAR影像通道间关系较为复杂, 简单线性关系模型难以准确刻画通道间内在关系。机器学习作为一种广泛应用于遥感影像处理的技术, 其强大的非线性关系拟合能力已被应用于PolSAR影像超分重建中。Lin等 (2019) 利用卷积神经网络 (CNN) 对PolSAR影像进行多通道全极化SAR影像超分重建 (MSSR), 并通过残差补偿降低卷积神经网络超分引入的伪痕, 提升了PolSAR影像的分辨率。在此基础上, Shen等 (2020) 考虑PolSAR影像的数值特性以及数据结构, 提出了全极化SAR影像超分网络框架 (PSSR), 利用混合卷积等模块提取极化信息, 并使用残差结构等深度神经网络

$$\mathbf{T}_3 = \frac{1}{2} \begin{bmatrix} \langle |S_{HH} + S_{VV}|^2 \rangle & \langle (S_{HH} + S_{VV})(S_{HH} - S_{VV})^* \rangle & 2\langle (S_{HH} + S_{VV})S_{HV}^* \rangle \\ \langle (S_{HH} - S_{VV})(S_{HH} + S_{VV})^* \rangle & \langle |S_{HH} - S_{VV}|^2 \rangle & 2\langle (S_{HH} - S_{VV})S_{HV}^* \rangle \\ 2\langle S_{HV}(S_{HH} + S_{VV})^* \rangle & 2\langle S_{HV}(S_{HH} - S_{VV})^* \rangle & 4\langle |S_{HV}|^2 \rangle \end{bmatrix} \quad (2)$$

式中, *表示共轭运算, $\langle \cdot \rangle$ 表示空间统计均值。在 \mathbf{T}_3 矩阵中, 对角线上的元素为实数, 非对角线上的元素为复数, 且处于对称位置上的非对角线上的元素两两互为共轭复数。

高分辨率PolSAR影像 $\mathbf{T}_x \in \mathbb{R}^{H \times W \times C}$ 受系统限制, 退化为低分辨率PolSAR影像 $\mathbf{T}_y \in \mathbb{R}^{h \times w \times C}$ 。其中, \mathbf{T}_x 与 \mathbf{T}_y 是由 \mathbf{T}_3 构成的三维矩阵。 H 、 W 、 C 分别表示高分辨率PolSAR影像的高度、宽度与通道数。 h 与 w 分别表示低分辨率PolSAR影像的高度、宽度。 $r_a = H/h$ 和 $r_r = W/w$ 分别表示高分辨率PolSAR影像与低分辨率PolSAR影像在方位向与距离向上的空间分辨率比率。PolSAR影像退化过程可表示为

$$\mathbf{T}_y = f_d(\mathbf{T}_x) \quad (3)$$

式中, $f_d(\cdot)$ 表示降采样算子。

模块, 有效提升PolSAR影像空间分辨率。然而, 该方法仅从单一尺度下进行重建, 对于不同尺度下的地物信息差异考虑不足。此外, 现有深度学习PolSAR影像超分方法对极化信息的利用尚不充分。

本文针对上述多尺度信息与极化信息利用不充分的问题, 构建了一种多尺度超分辨率重建框架与模型。通过内嵌注意力机制, 增强神经网络模型对空间信息与极化信息的特征提取能力; 通过引入信息蒸馏机制, 在降低参数量的同时, 提取判别性特征; 通过建立自适应损失函数增强对数值信息与边缘信息的一致性约束, 提升模型数值拟合能力与边缘信息保持能力。

2 研究方法

2.1 PolSAR数据组织形式

对于单基PolSAR成像系统, 根据不同的回波信号发射与接收方式, 在目标上发生的散射过程可表示为 2×2 复数后向散射矩阵 \mathbf{S}_2 的形式:

$$\mathbf{S}_2 = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \quad (1)$$

式中, S_{HH} 与 S_{VV} 表示共极化通道, S_{HV} 与 S_{VH} 表示交叉极化通道。在忽略成像系统噪声且满足互易性条件的情况下, 后向散射矩阵 \mathbf{S}_2 可通过Pauli基转化为相干矩阵 \mathbf{T}_3 的形式:

2.2 基于多尺度注意力机制的超分辨率重建框架

如图1所示, 基于多尺度注意力机制的PolSAR超分辨率框架主要包括: (1) 采用复数特征提取模块 (Shen等, 2020) 与转置卷积 (Zeiler等, 2010) 进行PolSAR影像分组特征提取与特征上采样处理。(2) 构建三级架构的多尺度网络模型以充分提取多尺度特征信息; 提出联合式与分离式两种注意力内嵌方式, 在多尺度网络模型中嵌入空间注意力与通道注意力, 分别对空间信息与极化信息进行重校准; 利用密集连接块增强模型特征提取能力, 提升特征重用性。(3) 引入残差信息蒸馏模块提取判别性特征, 并降低模型参数量。(4) 建立自适应损失函数约束模型训练过程。各模块详细信息如下所述。

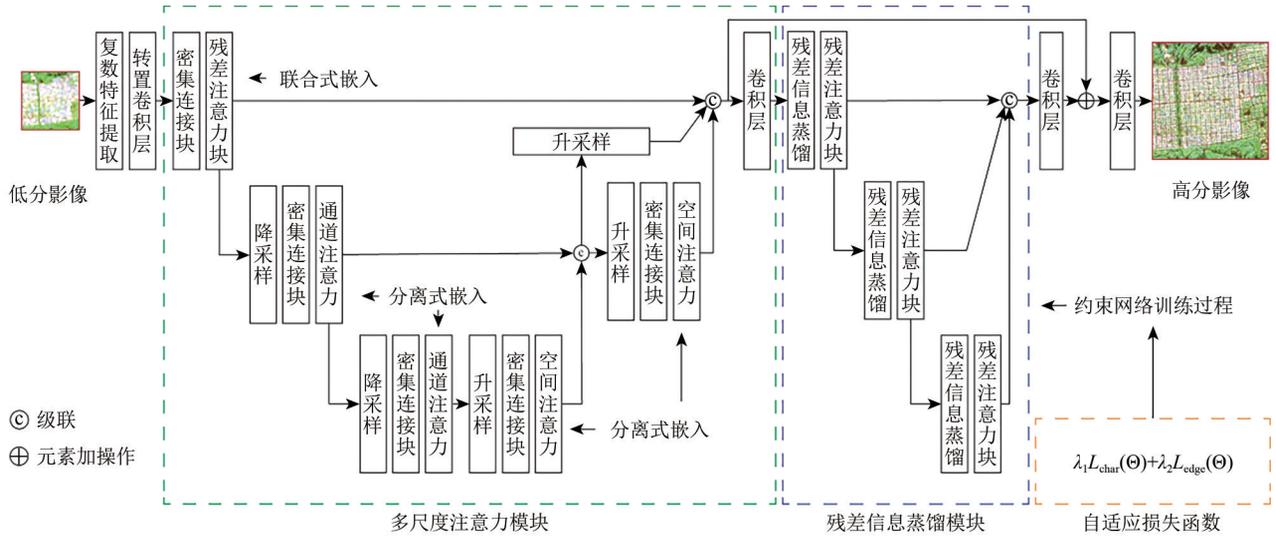


图1 超分辨率网络总体框架

Fig. 1 Super-resolution network framework

2.3 多尺度注意力模块

注意力机制作为一种特征映射重校准技术，广泛应用于计算机视觉任务中，包括超分重建 (Zhang 等, 2018a)、影像分类 (Wang 等, 2017)、语义分割 (Fu 等, 2019) 等。为提升模型的空间信息增强能力与极化信息保持能力，本文在多尺度模型中嵌入空间注意力模块与通道注意力模块。

如图2所示，空间注意力模块包含两个卷积层，第1个卷积层用于提取特征映射信息，第2个则用于进行特征映射降维处理。初始输入特征映射经卷积层处理，对其进行归一化后可得二维空间注意力权重。通过对初始输入特征映射与空间注意力权重进行元素乘操作，得到空间注意力加权的特征映射。空间注意力可表示为

$$F_s = F_i \otimes \sigma(W_s^2 \circ \delta(W_s^1 \circ F_i + b_s^1) + b_s^2) \quad (4)$$

式中， F_s 表示空间注意力输出特征映射， F_i 表示输入特征映射， \otimes 表示元素乘算子， \circ 表示卷积操作。 W_s^1 与 W_s^2 分别表示两个卷积层的权重项， b_s^1 与 b_s^2 分别表示两个卷积层的偏置项。 $\delta(\cdot)$ 与 $\sigma(\cdot)$ 分别表示 PReLU 激活函数与 Sigmoid 激活函数，其中 PReLU 激活函数用于提升模型非线性拟合能力，Sigmoid 函数用于对权重进行归一化。

为保持各极化通道在超分重建前后的极化信息一致性，本文引入通道注意力模块，从通道向对特征映射进行重校准。如图2所示，通道注意力模块包含两个全连接层，用于进行通道向权重提取。初始输入特征映射经全连接层处理后，使用

Sigmoid 函数进行归一化，得到通道注意力权重。通过对初始输入特征映射与通道注意力权重进行元素乘处理，得到通道注意力加权的特征映射。区别于常规通道注意力，考虑到 PolSAR 影像具有较宽的数值动态范围以及相对复杂的数据分布，本文移除全局池化操作以避免出现数值异常问题。

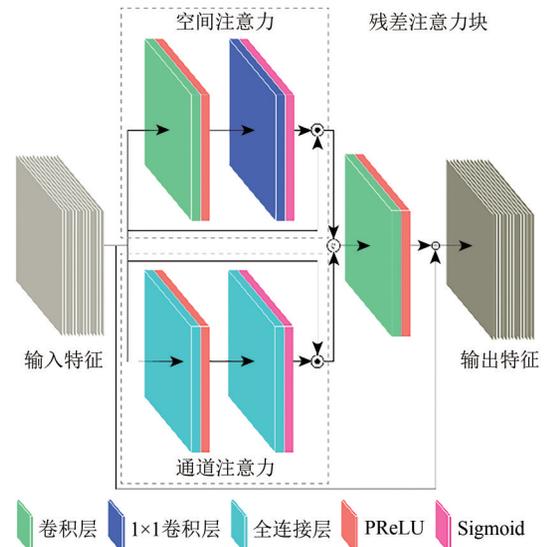


图2 残差注意力块

Fig. 2 Residual attention blocks

在多尺度注意力模块中，通道注意力可表示为

$$F_c = F_i \otimes \sigma(W_c^2 \circ \delta(W_c^1 \circ F_i + b_c^1) + b_c^2) \quad (5)$$

式中， F_c 表示通道注意力输出特征映射， W_c^1 与 W_c^2 分别表示两个全连接层的权重， b_c^1 与 b_c^2 表示两个全连接层的偏置项。

如图2所示，本文采用级联处理整合空间注意力与通道注意力加权后的特征映射，并利用残差结构实现特征重用，残差注意力块可表示为

$$F_f = F_i \oplus \delta \left(W_f \circ (f_c(F_s, F_c)) + b_f \right) \quad (6)$$

式中， F_f 表示注意力机制融合模块输出特征映射， \oplus 表示元素加算子。 W_f 和 b_f 分别表示权重与偏置项， $f_c(\cdot)$ 表示特征级联处理。在多尺度注意力模块中，引入密集连接块以深度提取影像特征。密集连接块(Zhang等, 2018b)是一种通过多个跳跃链接实现不同层次信息流传递的结构。在多尺度注意力模块进行升/降采样时，伴随特征映射尺寸与通道数变化(图1)。在降采样过程中，特征映射的尺寸变小，通道数增加，通道向信息量增加，为了有效提取通道向信息，本文嵌入通道注意力模块。在升采样过程中，特征通道数减少，尺寸变大，空间向信息增加，本文则嵌入空间注意力模块以提取丰富的空间细节信息。通过此种分离式嵌入能够有效适应通道向与空间向的信息量变化。而在对原始尺度特征映射进行处理时，尺度未发生变化，采用联合式嵌入，以均衡提取极化信息与空间信息。

2.4 残差信息蒸馏模块

深度学习模型的发展伴随着模型参数量增大、复杂度增高的问题，使得对计算力的需求增大。信息蒸馏作为一种将有限的计算资源用于处理判别性特征的资源分配方案，常用于降低模型计算量并提取重要特征。信息蒸馏是一种将特征映射分离重构的机制(Liu等, 2020)，其将特征映射分离成两部分，一部分直接保留，另一部分被进一步处理，最后将直接保留的与进一步处理的特征映射进行合并。该机制可在提取判别性特征的同时，压缩模型参数，实现模型的轻量化表达。本文的残差信息蒸馏模块由3个残差信息蒸馏单元与3个残差注意力块构成。

在残差蒸馏模块中，首先进行残差信息蒸馏单元处理，再使用残差注意力块对特征映射进行重校准(图1)。经过3次残差信息蒸馏单元与残差注意力块处理后，可获得不同层次下的关键特征，通过对不同层次下特征映射的级联与重组，生成高分辨率PolSAR影像。

残差信息蒸馏单元进行了3次分离(图3)。经过分离处理，一部分特征映射经过卷积层与

PReLU处理后，直接用于后续特征级联，另一部分则继续进行分离处理。通过级联处理合并4种不同层次下的特征映射，使用卷积层对合并特征映射进行进一步处理，实现对不同层次下重要特征的提取。

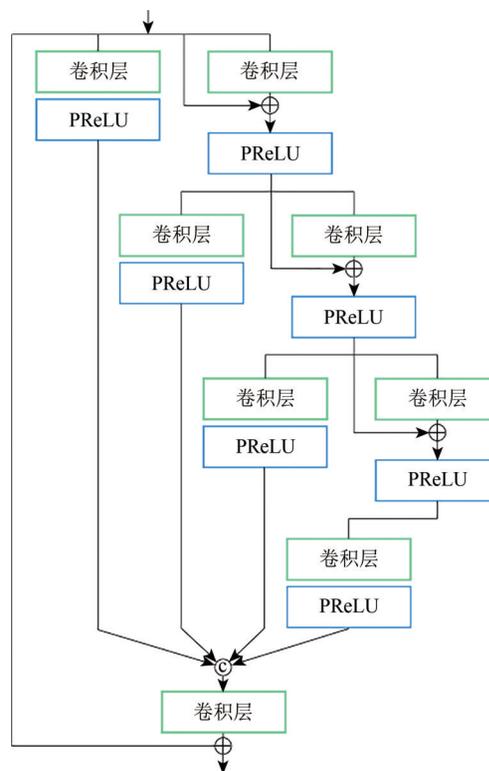


图3 残差信息蒸馏单元

Fig. 3 Residual information distillation unit

2.5 自适应损失函数

本文采用自适应权重的Charbonnier损失函数和边缘损失函数(Zamir等, 2021)作为损失函数，可定义为

$$L_i(\Theta) = \lambda_1 L_c(\Theta) + \lambda_2 L_e(\Theta) \quad (7)$$

式中， $L_i(\cdot)$ 表示自适应损失函数， $L_c(\cdot)$ 表示Charbonnier损失函数， $L_e(\cdot)$ 表示边缘损失函数。 Θ 为神经网络参数。 λ_1 和 λ_2 为正则化参数，用于调整两个损失函数的权重，二者由式(8)自适应确定， $f_i(\cdot)$ 表示数值提取算子。

$$\lambda_1 = \frac{f_i(L_c)}{f_i(L_c) + f_i(L_e)}, \lambda_2 = \frac{f_i(L_e)}{f_i(L_c) + f_i(L_e)} \quad (8)$$

式中，Charbonnier损失函数主要用于约束重建影像的数值信息一致性，可定义为

$$L_c(\Theta) = \frac{1}{N} \sum_{i=1}^N \sqrt{\| \rho^i - f_n(T_y^i) \|^2 + \varepsilon^2} \quad (9)$$

式中, N 表示训练影像对 $\{T_x^i, T_y^i\}_{i=1}^N$ 的数量, $\rho^i = T_x^i - T_u^i$ 表示低分辨率 PolSAR 影像 T_y^i 的上采样结果 T_u^i 与高分辨率 PolSAR 影像 T_x^i 之间的残差, $f_n(\cdot)$ 表示残差卷积神经网络的输出。 ε 为常数项, 在本文中设置为 10^{-3} 。

在自适应损失函数中, 边缘损失函数主要用于保持重建影像的结构信息一致性, 可定义为

$$L_c(\Theta) = \frac{1}{N} \sum_{i=1}^N \sqrt{\|\Delta(\rho^i) - \Delta(f_n(T_y^i))\|^2 + \varepsilon^2} \quad (10)$$

式中, $\Delta(\cdot)$ 表示拉普拉斯算子, 用于提取边缘信息。

3 实验与分析

3.1 实验数据与参数设置

利用 3 个 RADARSAT-2 (RS-2) 数据集进行实验。其中训练数据集信息如表 1 所示, 测试数据

表 2 测试数据集信息

Table 2 Test dataset information

测试数据集	卫星	波段	区域	分辨率/m	尺寸	模式
模拟实验	RS-2	C	温哥华区域	16	3800×1000×9	低分全极化
				8	7600×2000×9	高分全极化
真实实验	RS-2	C	魁北克区域	16	1024×854×9	标准全极化
				8	2048×1708×9	精细全极化

测试数据包括两个数据集, 其中模拟实验数据集使用 RS-2 精细模式下获取的温哥华区域数据作为高分辨率 PolSAR 影像, 通过 PolSARpro v5.0 进行最邻近插值处理获得低分辨率 PolSAR 影像, 在测试时以模拟低分辨率作为待处理目标影像, 将原始高分辨率影像作为参考影像。真实实验数据集则将 RS-2 精细模式下获取的魁北克区域高分辨率 PolSAR 影像作为参考影像, 将标准模式下获取的低分辨率 PolSAR 影像作为待处理目标影像。

在实验中, 训练数据与测试数据均使用 PolSARpro v5.0 进行了 Sigma 辐射校正, 采用非局部均值滤波进行去相干斑处理。真实实验所使用的精细模式数据与标准模式数据进行了配准处理。

在残差信息蒸馏模块中, 蒸馏率设置为 50%, 即每次分离后, 直接保留的特征占比为全部特征的 50%。本文所有模块均采用 Kaiming 正态分布 (He 等, 2015) 对模型参数进行初始化处理。ADAM 方法 (Kingma 和 Ba, 2017) 用于更新模型参数。本文提出的模型共训练 100 周期, 初始学习率为

集信息如表 2 所示。本实验使用旧金山区域数据对模型进行训练, 使用温哥华区域数据进行模拟实验与消融实验, 使用魁北克区域数据进行真实实验与极化信息保持测试。

表 1 训练数据集信息

Table 1 Train dataset information

卫星	波段	区域	分辨率/m	尺寸	模式
RS-2	C	旧金山	8	6800×2400×9	高分全极化
RS-2	C	旧金山	8	5200×2400×9	高分全极化

训练数据使用了两景 RS-2 精细模式下获取的数据集, 标称分辨率为 8 m。通过 PolSARpro v5.0 降采样处理得到分辨率为 16 m 的低分辨率 PolSAR 影像, 并将其与高分辨率影像进行配对处理。其中, 低分辨率 PolSAR 影像块大小为 20×20, 高分辨率 PolSAR 影像块大小为 40×40, 影像块之间的重叠率为 50%, 训练数据共使用了 71104 个高低分影像对。

10^{-4} , 学习率每隔 10 周期下降一半。

3.2 空间信息提升对比实验

为了验证本文方法在空间信息重建方面的有效性, 本文从模拟实验与真实实验两方面进行验证。模拟实验是对原始高分辨率 PolSAR 影像的降分辨率影像进行超分辨率重建, 并以原始高分辨率影像为参考进行定量指标计算。真实实验对标准模式下的低分辨率 PolSAR 影像进行超分辨率重建, 以精细模式获取的高分辨率 PolSAR 影像为参考进行定量评价。

模拟实验包括一景 RS-2 卫星获取的温哥华区域精细模式高分辨率 PolSAR 影像, 以及一景利用该高分辨率 PolSAR 影像经过两倍降采样得到的低分辨率 PolSAR 影像。如表 3 所示, 本文对极化相干矩阵进行 Pauli 分解, 获得与物理散射机制相关联的奇次散射分量 $|P_1|^2 = \frac{1}{2} \langle |S_{hh} + S_{vv}|^2 \rangle$ 、偶次散射分量 $|P_2|^2 = \frac{1}{2} \langle |S_{hh} - S_{vv}|^2 \rangle$ 、体散射分量

$|P_3|^2 = 2\langle |S_{HV}|^2 \rangle$ ，并对3个分量进行定量评价。本文方法相比现有的算法，在PSNR有一定程度的提高。同时，相比现有的算法，本文方法具有更低的MAE。

表3 不同方法下的模拟实验定量评价指标

Table 3 Quantitative evaluation results of simulation experiments by using different method

定量指标	双三次内插	SRPSC	MSSR	PSSR	MS-PSRN
PSNR ($ P_1 ^2$)	43.692	43.296	44.674	44.382	<u>44.486</u>
PSNR ($ P_2 ^2$)	44.668	44.260	45.309	<u>45.459</u>	45.482
PSNR ($ P_3 ^2$)	53.539	53.229	<u>54.746</u>	54.712	55.129
PSNR 均值	47.300	46.928	<u>48.243</u>	48.184	48.366
MAE ($ P_1 ^2$)	0.448	0.440	0.395	0.415	<u>0.402</u>
MAE ($ P_2 ^2$)	0.149	<u>0.142</u>	0.164	<u>0.142</u>	0.124
MAE ($ P_3 ^2$)	0.048	<u>0.045</u>	0.059	0.059	0.040
MAE 均值	0.215	0.209	0.206	0.206	0.189

注：加粗表示最优结果，下划线表示次优结果。

为了进行直观的比较，选取密集建成区与植被区域两种典型地物进行目视评价。如图4与图5

所示，双三次内插方法与SRPSC方法在密集建成区以及植被区域均出现明显的格网效应，地物边缘呈锯齿状。3种基于深度学习的方法没有出现明显格网效应，但MSSR与PSSR方法在密集建成区存在色彩畸变的现象，本文方法在重建出细节信息的同时，具有更少的人造伪痕。

真实实验包括一景RS-2卫星获取的魁北克区域精细模式高分辨率PolSAR影像，以及一景相同区域标准模式下获取的低分辨率PolSAR影像。如表4所示，本文方法在所有定量指标评价中均优于现有算法，说明本文方法在真实场景的重建中能够重建出更多的纹理细节，同时具有更小的重建误差。如图6—图8所示，选取了密集建成区、植被以及强散射点3种典型地物进行目视评价。双三次内插以及SRPSC方法对于真实场景的重建存在格网效应的问题，对强散射点的重建中，该现象更为明显。MSSR方法在3种典型区域重建中均存在一定的过平滑效应。PSSR方法对于植被的重建效果较好，但对密集建成区的重建则存在色彩畸变。相比现有算法，本文方法具有更多的细节信息，色彩的保真度更高。

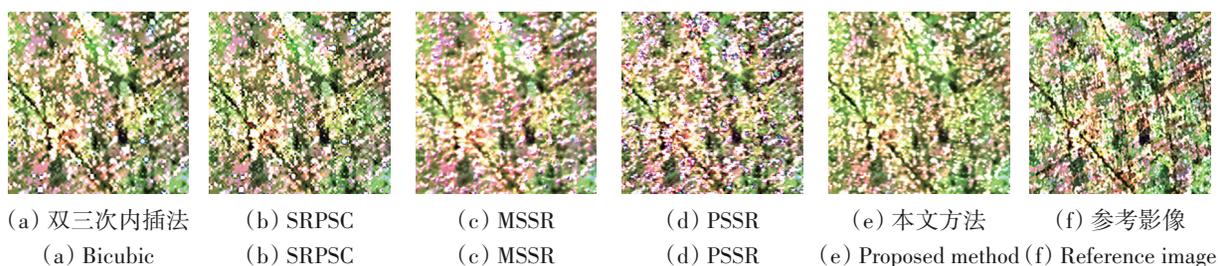


图4 不同方法模拟实验结果(密集建成区)

Fig. 4 Simulated experiments results by using different methods (Densely built-up area)

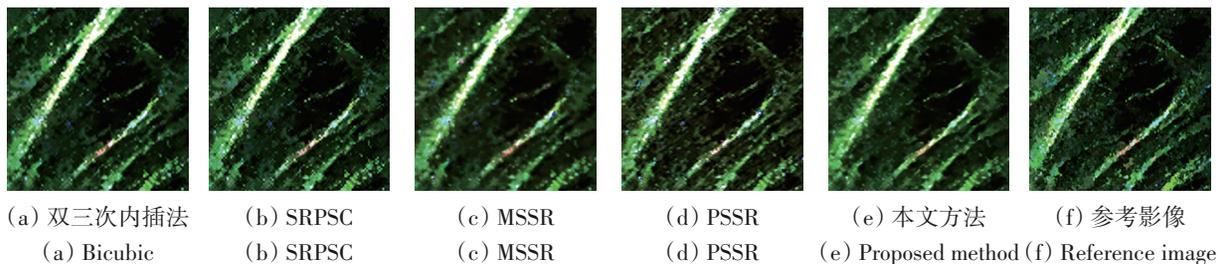


图5 不同方法模拟实验结果(植被区域)

Fig. 5 Simulated experiments results by using different methods (Vegetation area)

3.3 极化信息保持测试

为了验证不同地物覆盖类型在超分辨率重建后的散射信息保真度，本文对超分辨率重建结果进行了极化分解实验，并与相应的原始高分辨率

PolSAR影像的分解结果进行比较。在极化分解实验中，采用Yamaguchi极化分解方法(Yamaguchi等, 2005)对PolSAR影像进行处理，获得奇次散射、偶次散射与体散射分量。其中，奇次散射分量

表征粗糙表面的散射机制, 偶次散射主要表征人造建筑的散射机制, 体散射则主要表征植被等地物的散射机制。在图9(a)与图9(d)中, 高值主要分布在码头等具有较大粗糙表面的地表覆盖中, 符合奇次散射的特性。在图9(b)与图9(e)中, 高值则主要分布在城市建成区中, 城市建成区存在大量垂直于地面的建筑物, 偶次散射分量

值较高。在图9(c)与图9(f)中, 体散射分量则普遍较低, 高值较少, 出现该现象的原因在于, 魁北克区域地表覆盖以建筑为主, 大型植被较少, 因而体散射较低。由图9所示, 本文方法的分解结果与精细模式下的分解结果在3个分量的数值分布基本保持一致。

表4 不同方法下的真实实验定量评价结果

Table 4 Quantitative evaluation results of real experiments by using different method

定量指标	双三次内插	SRPSC	MSSR	PSSR	MS-PSRN
PSNR ($ P_1 ^2$)	50.770	50.744	50.903	<u>51.716</u>	51.930
PSNR ($ P_2 ^2$)	49.951	50.212	50.268	<u>50.762</u>	52.279
PSNR ($ P_3 ^2$)	50.345	50.600	<u>54.276</u>	54.167	54.289
PSNR 均值	50.355	50.519	51.815	<u>52.215</u>	52.833
MAE ($ P_1 ^2$)	0.095	<u>0.083</u>	0.125	0.099	0.070
MAE ($ P_2 ^2$)	0.103	<u>0.086</u>	0.137	0.106	0.074
MAE ($ P_3 ^2$)	0.152	0.129	0.095	<u>0.084</u>	0.076
MAE 均值	0.117	0.099	0.119	<u>0.096</u>	0.073

注: 加粗表示最优结果, 下划线表示次优结果。

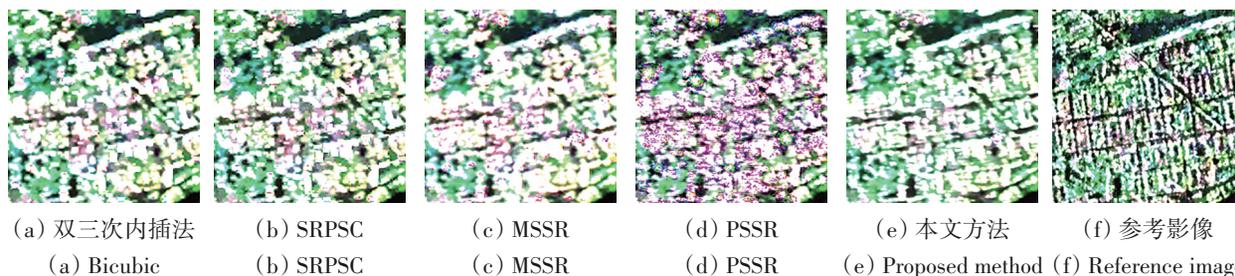


图6 不同方法真实实验结果(密集建成区)

Fig. 6 Real experiments results by using different methods (Densely built-up area)

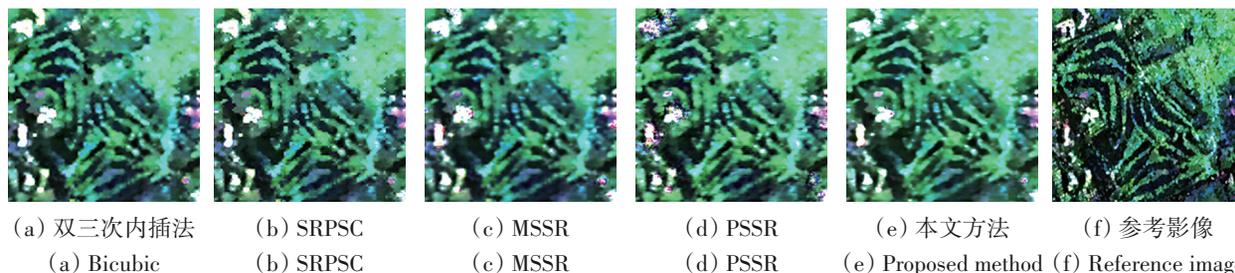


图7 不同方法真实实验结果(植被区域)

Fig. 7 Real experiments results by using different methods (Vegetation area)

本文对超分辨率重建结果的极化分解结果与原始高分辨率影像的极化分解结果进行相关系数与平均绝对误差计算。如表5所示, 本文提出方法的分解结果相比其他算法具有更高的相关系数与

更低的平均绝对误差, 说明本文方法相比其他算法在极化信息上更接近原始高分辨率影像, 且具有更低的重建误差, 能有效保持影像的极化信息。

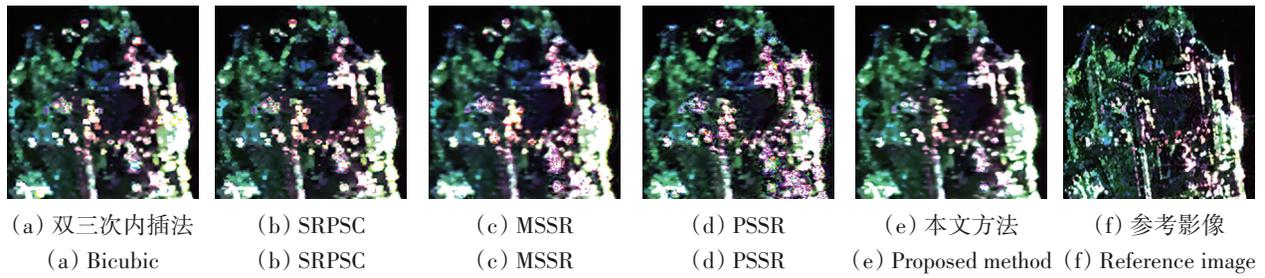


图8 不同方法真实实验结果(强散射点)

Fig. 8 Real experiments results by using different methods (Strong scattering points)

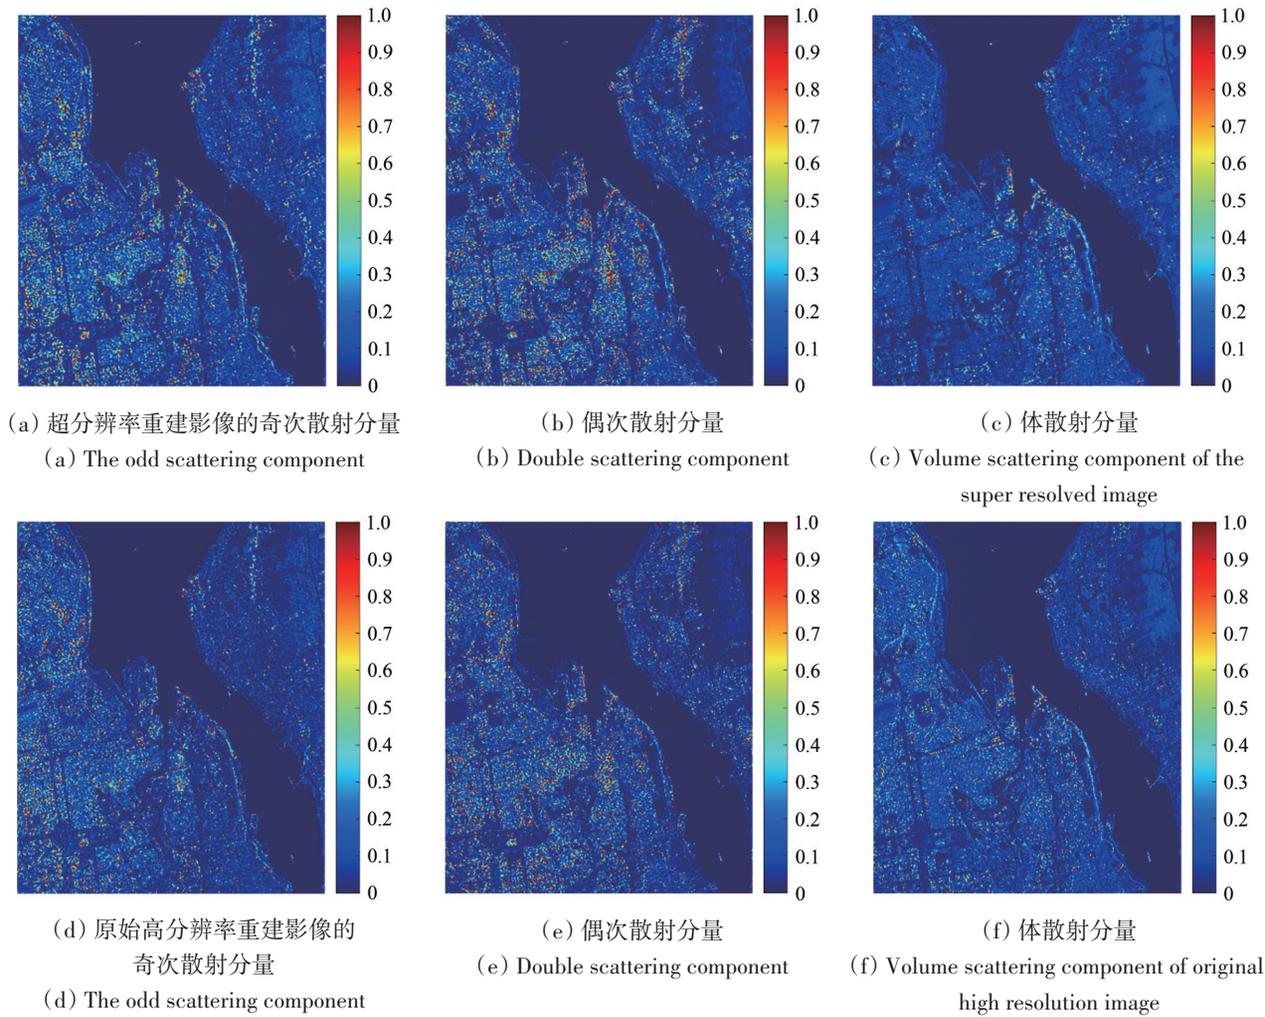


图9 极化分解结果

Fig. 9 Polarization decomposition results

表5 极化信息定量评价结果

Table 5 Quantitative evaluation results of polarimetric information

定量指标	双三次内插	SRPSC	MSSR	PSSR	MS-PSRN
CC (Odd)	0.8056	0.8079	0.8108	<u>0.8143</u>	0.8267
CC (Dbl)	0.7977	0.7986	0.7950	<u>0.8007</u>	0.8131
CC (Vol)	0.7177	<u>0.7108</u>	0.6447	0.6080	0.6704
MAE (Odd)	0.0970	<u>0.0962</u>	0.1010	0.1039	0.0925
MAE (Dbl)	0.1371	<u>0.1353</u>	0.1463	0.1377	0.1290
MAE (Vol)	0.0440	<u>0.0438</u>	0.0467	0.0490	0.0438

注: Odd表示奇次散射, Dbl表示偶次散射, Vol表示体散射。加粗表示最优结果, 下划线表示次优结果。

3.4 消融实验

为了验证各模块的有效性, 本文进行了模块消融实验, 包括多尺度模块、注意力模块、残差信息蒸馏模块、Charbonnier 损失函数、边缘损失函数等 5 个模块。

如表 6 所示, 在消融实验中, 移除相应模块后的模型精度均有一定程度下降, 本文提出的完整模型在全部定量指标中均为最优, 说明本文提出的各个模块均能有效提升 PolSAR 影像分辨率增强精度。

表 6 消融实验定量评价结果

Table 6 Quantitative evaluation results of ablation experiments

定量指标	WM	WA	WR	WC	WE	All
PSNR ($ P_1 ^2$)	44.102	44.007	44.223	43.916	<u>44.468</u>	44.486
PSNR ($ P_2 ^2$)	45.140	<u>45.435</u>	45.361	45.370	45.423	45.482
PSNR ($ P_3 ^2$)	54.804	54.562	54.599	54.700	<u>54.870</u>	55.129
PSNR 均值	48.015	48.001	48.061	47.995	<u>48.254</u>	48.366

注: WM 表示移除多尺度模块, WA 表示移除注意力模块, WR 表示移除残差信息蒸馏模块, WC 表示移除 Charbonnier 损失函数, WE 表示移除边缘损失函数, All 表示完整模型。加粗表示最优结果, 下划线表示次优结果。

4 结论

为提升 PolSAR 影像的空间分辨率, 本文提出了内嵌注意力机制的多尺度 PolSAR 影像超分辨率神经网络模型, 在多尺度残差网络框架以分离式与联合式嵌入注意力机制, 有效提取地物目标多尺度信息并增强模型空间一极化信息刻画能力。在此基础上, 结合特征蒸馏机制, 提取关键特征并降低网络参数量, 并采用结合数值一致性约束与边缘一致性约束的自适应损失函数对网络训练进行有效约束。空间信息实验表明, 本文方法能有效重建空间细节并降低人造伪痕, 在定量指标上明显优于对比方法, 具有更高的精度以及更低的重建误差。极化分解实验表明, 本文方法能有效保持影像的极化信息。如何集成多维多源互补信息, 实现全极化 SAR 影像分辨率增强, 是未来亟待进一步深入研究的方向。

参考文献 (References)

Chen J and Yang J. 2007. Super-resolution of polarimetric SAR images for ship detection//2007 International Symposium on Microwave,

Antenna, Propagation and EMC Technologies for Wireless Communications. Hangzhou: IEEE: 1499-1502 [DOI: 10.1109/MAPE.2007.4393565]

Fan C, Gong J Y, Zhu J J and Liao M S. 2009. Super-resolution reconstruction of ALOS-PRISM remote sensing images. Journal of Remote Sensing (in Chinese), 13(1): 75-82 (范冲, 龚健雅, 朱建军, 廖明生. 2009. ALOS-PRISM 遥感影像超分辨率重建. 遥感学报, 13(1): 75-82) [DOI: 10.11834/jrs.20090110]

Fu J, Liu J, Tian H J, Li Y, Bao Y J, Fang Z W and Lu H Q. 2019. Dual attention network for scene segmentation//Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE: 3141-3149 [DOI: 10.1109/CVPR.2019.00326]

He K M, Zhang X Y, Ren S Q and Sun J. 2015. Delving deep into rectifiers: surpassing human-level performance on imagenet classification//Proceedings of the 2015 IEEE International Conference on Computer Vision. Santiago: IEEE: 1026-1034 [DOI: 10.1109/ICCV.2015.123]

He Z and He D. 2020. Deep learning-based super-resolution for GF-4 satellite imagery. Journal of Remote Sensing (in Chinese), 24(12): 1500-1510 (贺智, 贺丹. 2020. 基于深度学习的高分四号卫星图像超分辨率重建. 遥感学报, 24(12): 1500-1510) [DOI: 10.11834/jrs.20208397]

Kingma D P and Ba J. 2017. Adam: a method for stochastic optimization. arXiv preprint arXiv:1412.6980

Lin L P, Li J, Yuan Q Q and Shen H F. 2019. Polarimetric SAR image super-resolution VIA deep convolutional neural network//IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama: IEEE: 3205-3208 [DOI: 10.1109/IGARSS.2019.8898160]

Liu J, Tang J and Wu G S. 2020. Residual feature distillation network for lightweight image super-resolution//European Conference on Computer Vision. Glasgow: Springer: 41-55 [DOI: 10.1007/978-3-030-67070-2_2]

Pastina D, Lombardo P, Farina A and Daddi P. 2001. Super-resolution of polarimetric SAR images of a ship//IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. IEEE 2001 International Geoscience and Remote Sensing Symposium (Cat. No. 01CH37217). Sydney: IEEE: 2343-2345 [DOI: 10.1109/IGARSS.2001.977996]

Qi Z X, Yeh A G O, Li X and Lin Z. 2012. A novel algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR data. Remote Sensing of Environment, 118: 21-39 [DOI: 10.1016/j.rse.2011.11.001]

Shen H F, Lin L P, Li J, Yuan Q Q and Zhao L L. 2020. A residual convolutional neural network for polarimetric SAR image super-resolution. ISPRS Journal of Photogrammetry and Remote Sensing, 161: 90-108 [DOI: 10.1016/j.isprsjprs.2020.01.006]

Shi L, Sun W D, Yang J, Li P X and Lu L J. 2015. Building collapse assessment by the use of postearthquake Chinese VHR airborne SAR. IEEE Geoscience and Remote Sensing Letters, 12(10): 2021-2025 [DOI: 10.1109/LGRS.2015.2443018]

Suwa K and Iwamoto M. 2007. A two-dimensional bandwidth extrapolation technique for polarimetric synthetic aperture radar images. IEEE Transactions on Geoscience and Remote Sensing, 45(1): 45-54 [DOI: 10.1109/TGRS.2006.885406]

Wang F, Jiang M Q, Qian C, Yang S, Li C, Zhang H G, Wang X G and Tang X O. 2017. Residual attention network for image classifica-

- tion//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE: 6450-6458 [DOI: 10.1109/CVPR.2017.683]
- Wang Y H and Liu H W. 2015. PolSAR ship detection based on super-pixel-level scattering mechanism distribution features. *IEEE Geoscience and Remote Sensing Letters*, 12(8): 1780-1784 [DOI: 10.1109/LGRS.2015.2425873]
- Yamaguchi Y, Moriyama T, Ishido M and Yamada H. 2005. Four-component scattering model for polarimetric SAR image decomposition. *IEEE Transactions on Geoscience and Remote Sensing*, 43(8): 1699-1706 [DOI: 10.1109/TGRS.2005.852084]
- Zamir S W, Arora A, Khan S, Hayat M, Khan F S, Yang M H and Shao L. 2021. Multi-stage progressive image restoration//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE: 14816-14826 [DOI: 10.1109/CVPR46437.2021.01458]
- Zeiler M D, Krishnan D, Taylor G W and Fergus R. 2010. Deconvolutional networks//2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Francisco: IEEE: 2528-2535 [DOI: 10.1109/CVPR.2010.5539957]
- Zhang L M, Zou B, Hao H J and Zhang Y. 2011. A novel super-resolution method of PolSAR images based on target decomposition and polarimetric spatial correlation. *International Journal of Remote Sensing*, 32(17): 4893-4913 [DOI: 10.1080/01431161.2010.492251]
- Zhang T, Jiang L F, Xiang D L, Ban Y F, Pei L and Xiong H L. 2019. Ship detection from PolSAR imagery using the ambiguity removal polarimetric notch filter. *ISPRS Journal of Photogrammetry and Remote Sensing*, 157: 41-58 [DOI: 10.1016/j.isprsjprs.2019.08.009]
- Zhang Y L, Li K P, Li K, Wang L C, Zhong B N and Fu Y. 2018a. Image super-resolution using very deep residual channel attention networks//Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich: Springer: 294-310 [DOI: 10.1007/978-3-030-01234-2_18]
- Zhang Y L, Tian Y P, Kong Y, Zhong B N and Fu Y. 2018b. Residual dense network for image super-resolution//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE: 2472-2481 [DOI: 10.1109/CVPR.2018.00262]
- Zhao L L, Yang J, Li P X, Zhang L P, Shi L and Lang F K. 2013. Damage assessment in urban areas using post-earthquake airborne PolSAR imagery. *International Journal of Remote Sensing*, 34(24): 8952-8966 [DOI: 10.1080/01431161.2013.860566]
- Zou B, Hao H J and Guo X J. 2008. Super-resolution of polarimetric SAR images based on target decomposition and polarimetric spatial correlation//IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium. Boston: IEEE: II-911-II-914 [DOI: 10.1109/IGARSS.2008.4779143]

PolSAR image deep learning super-resolution model based on multiscale attention mechanism

LIN Liupeng¹, LI Jie², SHEN Huanfeng^{1,3}

1. School of Resource and Environmental Sciences, Wuhan University, Wuhan 430079, China;

2. School of Geodesy and Geomatics, Wuhan University, Wuhan 430079, China;

3. Hubei Luojia Laboratory, Wuhan 430079, China

Abstract: Fully Polarimetric Synthetic Aperture Radar imagery (PolSAR) can provide rich polarimetric information; however, given the limitations of the system's signal bandwidth and the physical size of the antenna, the spatial resolution of the SAR imaging system is restricted while acquiring multiple polarization information. To solve this problem, on the basis of the deep learning framework, this study proposes a multiscale attention-based PolSAR super-resolution network (MS-PSRN), which performs super-resolution reconstruction on the low-resolution full-polarimetric SAR images to generate the fully polarimetric SAR images with high spatial resolution. Under this super-resolution reconstruction framework, this study uses a multiscale architecture to fully extract the feature information of objects at different scales. On this basis, the spatial attention mechanism and the channel attention mechanism are introduced to recalibrate the feature maps, which are used to enhance the reconstruction performance of spatial details and improve the ability to maintain polarization information, respectively. Two attention mechanism embedding methods, i.e., joint and separated, are proposed to cope with the spatial size and quantity changes of the feature maps processed by the encoder and decoder. This study introduces a residual information distillation mechanism, extracts discriminative features through feature distillation, and compresses model parameters at the same time. In addition, the adaptive loss function is proposed to constrain the network training process and improve the model's numerical fitting ability and edge information preservation ability. In this study, the proposed method is verified by two datasets, namely, the simulated data and the real data produced by RADARSAT-2 images. The experimental results of spatial information show that the proposed method is superior to the comparison algorithms in terms of visual results and quantitative indicators and has higher texture detail reconstruction accuracy and lower reconstruction error. The polarimetric information preservation test shows that the proposed method can effectively preserve the polarimetric information of PolSAR images while improving spatial resolution.

Key words: remote sensing, fully polarimetric synthetic aperture radar, super resolution, deep learning, remote sensing, multi-scale, attention mechanism

Supported by Open Fund of Hubei Luojia Laboratory (No. 220100041); National Natural Science Foundation of China (No. 62071341, 42301417)