



基于散射图卷积网络的 PolSAR 影像地物分类

刘旭^{1,2,3}, 李玲玲^{1,2,3*}, 刘芳^{1,2,3}, 杨淑媛^{1,2,3}, 侯彪^{1,2,3}, 焦李成^{1,2,3*}

1. 西安电子科技大学人工智能学院, 西安 710071

2. 智能感知与图像理解教育部重点实验室, 西安 710071

3. 智能感知与计算国际联合研究中心, 西安 710071

* 通信作者. E-mail: linglingxidian@gmail.com, lchjiao@mail.xidian.edu.cn

收稿日期: 2021-04-25; 修回日期: 2021-07-07; 接受日期: 2021-08-16; 网络出版日期: 2022-10-10

国家自然科学基金 (批准号: U1701267, 62006177, 61871310, 61902298, 61573267, 61906150)、中国博士后基金 (批准号: 2019M663641, 2017M613081) 和中央高校基本科研业务费专项资金 (批准号: XJS201903, XJS201901, JBF201905) 资助

摘要 本文针对极化合成孔径雷达 (polarimetric synthetic aperture radar, PolSAR) 图像解译中特征提取不足与目标分类困难的问题, 进行了深入的研究, 提出了一种基于散射图卷积网络的 PolSAR 影像分类方法. 在特征提取方面, 本文给出了极化散射编码的一维表现形式; 同时, 考虑目标散射的特性和像素间的复杂关系, 结合图论理论, 提出了一种新的散射机制的图表示模型, 来刻画复杂的极化散射机理; 最后, 将这种新的散射建模方法和图卷积网络结合, 提出了 PolSAR 图像分类的新方法, 从而更加高效、高精度地完成分类任务. 实验结果表明, 在 5 幅公开的 PolSAR 图像上 (PolSF 数据集), 本文提出的算法具有良好的分类性能.

关键词 散射, 特征表示, 图卷积网络, 极化 SAR 图像, 地物分类

1 引言

近年来, 国内外对地观测技术取得了飞速发展, 并在各行各业得到了广泛应用. 学者们围绕国家需求和目标, 突破关键共性技术或重大工程, 努力实现以科技发展的局部跃升带动生产力的跨越发展, 并填补国家战略空白^[1~4]. 高分三号卫星是我国首颗分辨率达到 1 m 的 C 频段多极化合成孔径雷达卫星, 是高分专项“天眼工程”中唯一一颗“雷达星”, 与“高分家族”的其他几颗光学遥感卫星相比, 最大的特点是有全天时、全天候的成像能力, 无论白天或黑夜、晴空或雷雨多云, 都可以随时对地成像. 目前, 极化 SAR (synthetic aperture radar) 在农业 (作物分类、土壤水分提取和作物评估)、海洋学 (地表水流和风场恢复)、林业 (森林监测、分类和树高估计)、灾难监测 (漏油检测、灾难评估) 和军事 (船舶检测、目标识别/分类) 等领域有着广泛的应用^[5~9].

引用格式: 刘旭, 李玲玲, 刘芳, 等. 基于散射图卷积网络的 PolSAR 影像地物分类. 中国科学: 信息科学, 2022, 52: 1900–1914, doi: 10.1360/SSI-2021-0126
Liu X, Li L L, Liu F, et al. Scattering graph convolutional network-based PolSAR image classification (in Chinese). Sci Sin Inform, 2022, 52: 1900–1914, doi: 10.1360/SSI-2021-0126

极化 SAR 是一种主动式微波遥感成像雷达,用微波设备来探测、接收被观测物体在微波波段的电磁辐射和散射信息,以识别远距离物体的技术.微波遥感雷达可以穿透大气云层,对天气条件等外界干扰不敏感;同时能够穿透植被,从而探测位于地表下的目标;获取的微波图像有明显的立体感,能提供可见光和红外遥感成像以外的信息^[10~13].

极化 SAR 拥有上述诸多优点,然而获取图像数据之后,解译获取信息是至关重要的一个环节,也是从事极化 SAR 图像解译的学者们长期研究的方向.与光学遥感图像不同的是,极化 SAR 图像成像机制比较复杂,包括数据的编解码与存储方式、物体的散射特性、天线发射信号和接收信号的方式、成像的斑点噪声等,这都是解译所面临的难点问题.解决这些问题,将会给极化 SAR 图像数据解译带来巨大的便利^[14,15].

深度学习由于其强大的学习能力,以深度卷积神经网络为代表的系列算法,在图像处理领域表现出了出色的性能^[16].如何利用深度学习算法解决极化 SAR 图像分类的问题也成为了一个研究热点.Zhou 等^[17]提出了一种基于深度卷积神经网络的极化 SAR 图像分类方法.该方法将极化相干矩阵形式的多视极化 SAR 数据归一化的 6 维实特征向量,送入 4 层卷积网络,得到分类结果.Gao 等^[18]提出了一种基于双分支深度卷积神经网络的极化 SAR 图像分类方法.该方法建立在两个分支的深度卷积神经网络上,将这两个分支的提取的特征通过全连接层组合起来.然后,利用 Softmax 分类器对这些特征进行分类.Chen 等^[19]提出了一种基于极化特征驱动的深度卷积神经网络来解决极化 SAR 图像分类的问题,核心思想是结合目标散射机理和极化特征挖掘的专家知识,利用旋转域的经典旋转不变极化特征和隐藏的极化特征来驱动所提出的模型,以此来辅助深度卷积网络训练分类器,提高最终的分类性能.Jiao 等^[20]以深度堆栈自编码网络为基础,结合极化 SAR 数据的 Wishart 分布,提出了一种极化 SAR 图像分类的新方法.该方法通过特殊的线性变化,快速求得 Wishart 距离,再结合隐层网络,提出 Wishart 网络,将其不断堆叠,形成深度 Wishart 网络.Zhang 等^[21]提出了一种复值卷积神经网络,用于解决极化 SAR 图像的分类任务.将卷积神经网络的输入层、输出层、卷积层、激活函数和汇聚层等单元扩展到复数域.此外,针对网络训练,推导了基于随机梯度下降的复杂反向传播算法.Bi 等^[22]提出了一种基于主动深度学习的极化 SAR 图像分类方法,旨在利用主动学习的思想来精调训练好的卷积神经网络,从而利用更少的样本完成分类任务,最后采用马尔可夫 (Markov) 随机场来增强结果的平滑线.Liu 等^[23]提出了一种基于极化卷积网络的极化 SAR 图像分类方法,给出了一种新的数据表示方法,即极化散射编码,并结合全卷积网络,实现了分类任务.由此可以看出,关于极化 SAR 图像散射特性的研究,一直属于领域内的热点问题,研究者针对复杂的散射特性,进行了深入的研究和探索.

图卷积神经网络的出现给复杂数据的解译提供了新的思路,并成功应用于诸多非欧几里得结构数据的场景^[24~27].卷积神经网络面向的是具有欧几里得结构的数据,不适用非欧几里得结构的数据,图卷积网络恰恰可以做到这一点.图 (graph) 是一种数据格式,它可以用于表示社交网络、通信网络、蛋白质分子网络等.图中的节点表示网络中的个体,边表示个体之间的连接关系.许多机器学习任务例如社团发现、链路预测等都需要用到图结构数据,因此图卷积神经网络的出现为这些问题的解决提供了新的思路.图上的神经网络,最早由 Joan Bruna 于 2014 年提出^[25],分别从空间和谱域两个角度去构造模型.图卷积神经网络,由 Kpif 等于 2017 年提出^[26],它为图 (graph) 结构数据的处理提供了一个崭新的思路,将深度学习中常用于图像的卷积神经网络应用到图数据上.图卷积神经网络是卷积神经网络和谱图理论的结合和扩充.另外,图卷积神经网络为描述图上不同节点之间的内在关系提供了一种有效的方法.

最近,图卷积网络在遥感图像像素级分类任务中也取得了不错的结果^[28~36],Wan 等^[28]提出了

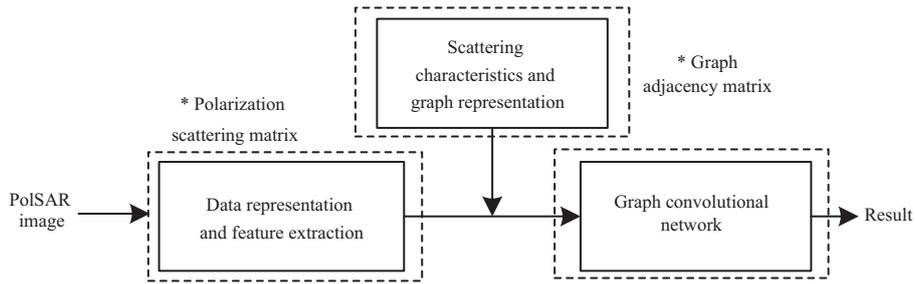


图 1 散射图卷积网络的极化 SAR 图像分类框架

Figure 1 PolSAR image classification framework based on the scatter graph convolutional network

一个新的上下文感知动态图卷积网络用于高光谱图像分类. 为了获取长距离的上下文关系, 他们通过学习像素到区域的分配来超越常规的图像网格, 并进一步编码区域之间的上下文关系, 从而可以通过连续的图卷积将原本远离二维空间的区域连接起来. Cheng 等^[34]提出了一种基于超像素的图卷积网络的 PolSAR 图像分类方法 (MSSP-GCN). 该方法采用超像素作为图形节点, 充分利用超像素的特性极大地减少了超像素的边界信息的计算成本, 从而应用在大尺度 PolSAR 图像分类中. 可看出利用图卷积网络解决图像像素级分类任务的主要研究思路是如何构造节点特征和图结构信息.

综上, 本文针对具有全天候全天时极化 SAR 图像分类中的关键问题, 考虑极化 SAR 图像数据的目标散射原理, 借鉴深度学习、图网络等有效的图像处理方法, 探索极化 SAR 图像分类的新方法.

本论文的特色和创新, 主要表现在以下:

- 提出了一种基于散射图卷积网络的极化 SAR 图像分类方法;
- 提出了一种新的散射机制的图表示模型, 来表示极化散射机理;
- 将散射特性建模与图卷积网络结合, 来进行网络建模;
- 在数据集 PolSF 上验证了算法的有效性.

2 散射图卷积网络

本文提出的散射图卷积网络 (scattering graph convolutional network, SGCN) 算法整体框架如图 1 所示. 围绕极化 SAR 图像分类任务, 从“极化 SAR 数据表示与特征提取”、“散射特性与图表示”、“图卷积网络分类模型”这 3 方面进行介绍.

2.1 极化 SAR 数据表示与特征提取

极化 SAR 图像的成像模式是一种主动的方式, 通过发射电磁波, 经过地物散射回来的回波信号, 完成成像的过程. 根据电磁波的极化特性, 极化 SAR 通过发射和接收的模式, 获取水平 (H) 和垂直 (V) 这两种正交的极化电磁波, 来捕获目标物体的完整特性. 通常情况下, 极化 SAR 的发射天线和接收天线都可以设置成水平和垂直两种方向, 最终可以得到 4 个独立的回波 (HH, HV, VH, VV). 其中, HH 表示水平发射和水平接收, VV 表示垂直发射和垂直接收, HV 表示水平发射和垂直接收, VH 表示垂直发射和水平接收.

对于极化 SAR 图像中每个像素点的信息, 可以将其表示成一个 2×2 的复数矩阵形式, 这个矩阵

被称为极化散射矩阵 S , 如下所示:

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

直观地, 这里给出一般的假设, 分别以 $a \sim h$ 赋值极化散射矩阵 S , 各元素赋值情况如下:

$$\begin{aligned} S_{HH} &= a + bi, \\ S_{HV} &= c + di, \\ S_{VH} &= e + fi, \\ S_{VV} &= g + hi, \end{aligned} \quad (2)$$

其中 i 表示复数单元, S_{HH} , S_{HV} , S_{VH} , S_{VV} 表示不同的回波信号.

本文的特征提取方法是基于极化散射编码^[23], 如下所示:

$$\varphi(S) = \varphi \left(\begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \right) = \varphi \left(\begin{bmatrix} a + bi & c + di \\ e + fi & g + hi \end{bmatrix} \right) = \begin{bmatrix} a & b & 0 & 0 \\ 0 & 0 & |c| & |d| \\ e & 0 & 0 & h \\ 0 & |f| & |g| & 0 \end{bmatrix}. \quad (3)$$

对于图网络来说, 每个节点的特征需要的是一个一维的向量, 而对于每个像素点, 我们的极化散射编码的最终形式是一个 4×4 的矩阵, 自然地想法是将其拉成一列. 同时, 从式 (3) 可以看出, 极化散射编码中一半的元素为 '0', 考虑到如果删掉 '0' 元素进行列处理, 则存在幅度位置出现相位值的情况. 所以我们直接拉成一列, 得到 16 维的列向量, 如下所示:

$$\tilde{\varphi}(S) = \tilde{\varphi} \left(\begin{bmatrix} a + bi & c + di \\ e + fi & g + hi \end{bmatrix} \right) = [a, b, 0, 0, 0, 0, |c|, |d|, e, 0, 0, h, 0, |f|, |g|, 0], \quad (4)$$

式中元素 '0' 用来补位, 从而能使有值位置的元素代表其特性.

2.2 散射特性的图建模与表示

极化 SAR 数据的散射特性是指天线发射出去的信号经过不同材质的物体散射回不同强度的回波信号的现象. 根据不同的物体, 散射现象大概分为单次散射、偶次散射和体散射等. 其中, 球状体和平面体很直观地表明了单次散射机制, 电磁波发射到这种物体上, 都会直接被散射回去. 偶次散射是指电磁波经过两次反射之后朝着原路返回的现象. 前两种现象的反射强度都比较强. 第 3 种体散射是指空间方向随机分布的偶极子或者短细棒, 例如树枝和植被区域, 这种物体可以用体散射来表述, 电磁波照射到这种物体上经过多次反射, 只有部分能量传播回来被雷达接收.

对于雷达来说, 发射信号是已知的, 面对不同的散射体, 会得到不同的返回信号, 这些信号也包含多种散射体的回波叠加, 相对比较复杂. 如何对各种不同的散射体进行建模, 是一个巨大的挑战.

本文引入图网络来描述极化 SAR 数据复杂的散射特性. 将多种散射体的回波叠加和图网络中的节点汇聚结合起来, 进行建模. 图 2 给出了利用图网络解决极化 SAR 图像数据表示与分类的动机, 图 2(a) 列出了极化 SAR 成像散射的一个示意图, 虽然极化 SAR 图像数据从格式看是欧几里得空间下的栅格数据, 但是其每个点的散射信号却是复杂的、无序的、甚至是随机的. 图 2(b) 展示了图网络的基本连接单元. 通过对比图 2(a) 和 (b) 中的结构, 可以看出, 图 2(a) 中节点的散射信息的分布和图 2(b)

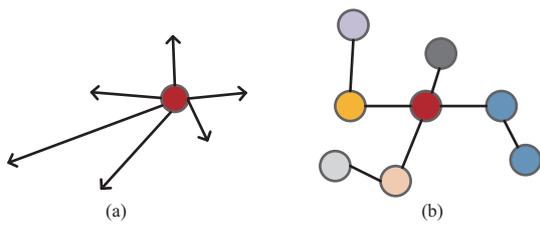


图 2 (网络版彩图) (a) 散射特性与 (b) 图网络对比示意

Figure 2 (Color online) Comparison between (a) the scattering characteristics and (b) graph network

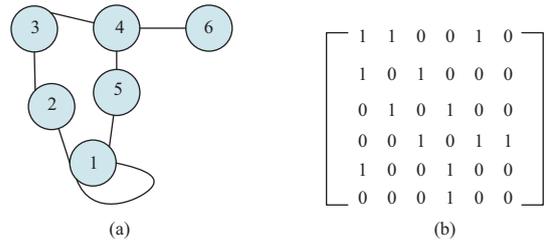


图 3 (网络版彩图) (a) 图节点关系与 (b) 邻接矩阵
Figure 3 (Color online) (a) Pixel relation and (b) adjacency matrix

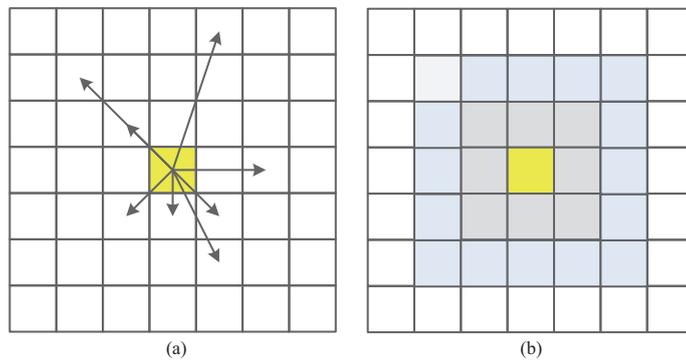


图 4 (网络版彩图) 像素散射建模示意

Figure 4 (Color online) Scattering characteristic modeling. (a) Single point scattering; (b) single point pixel relationship

中节点间的连接结构极其相似. 受此启发, 如何将两者进行结合建模是本论文研究的关键, 这个关键结合点在于邻接矩阵的构造, 下面就这个问题进行讨论.

在图网络中, 图的定义为 $G = (V, E)$, V 表示顶点, E 表示边. 为了刻画 V 和 E , 包括两个部分: 节点 V 的特征 X 和图结构 (邻接矩阵 A). $X \in \mathbb{R}^{N \times C}$, N 表示样本个数, C 表示特征的维数或者通道数. $A \in \mathbb{R}^{N \times N}$ 表示 N 个节点之间的关系. 图 3 给出了一个示例, 图 3(a) 表示一个具有 6 节点的图结构, 节点 1 除了和节点 2 和 5 相连接外, 还和自己有连接, 这个称为自环. 图 3(b) 表示与图 3(a) 相对应的邻接矩阵, 可以看出, 6 个节点就对应一个 6×6 的矩阵, 表示节点之间的对应关系, 有连接的节点对应位置设为 1, 反之为 0.

目标散射特性的建模核心在邻接矩阵 A 的构造上, 即中心节点和周围邻近节点的关系. 图 4 给出了一个像素的散射建模的思路, 第一, 非规则邻接点特性, 从图 4(a) 中可以看出, 中心像素点的邻接点是比较杂乱的、无序的, 这也符合散射机理. 第二, 规则邻接点建模, 如图 4(b) 所示, 以黄色的中心像素点作为研究对象, 它的邻接点就是其 k 邻域的像素点. 关于规则邻接点建模, 可以选取 k 邻域作为研究对象, k 是超参数. 在图 4(b) 中, 以 5×5 的图像块为例, 共 25 个像素点, 其中一个中心像素和 24 邻域信息, 这样就可以构建一个 25×25 的邻接矩阵 A . 下面公式给出其构造方式:

$$A_{i,j} = \exp(-\|x_i - x_j\|^2/\delta), \tag{5}$$

其中, x_i, x_j 表示对应位置的像素值或者特征值, δ 是表示距离因子的超参数, 以中心像素为参考, 邻

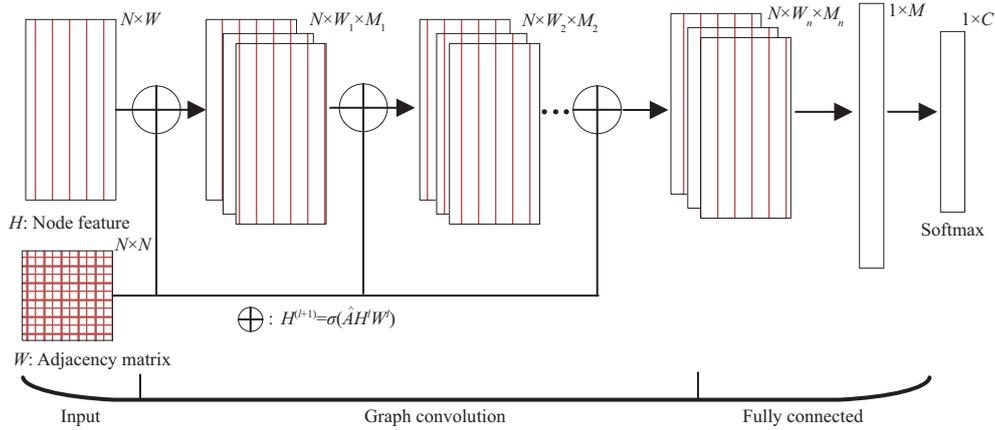


图 5 (网络版彩图) 图卷积网络
Figure 5 (Color online) Graph convolutional network

近的第 1 层对应的值是 1, 第 2 层是 1/2, 第 3 层是 1/3, 以此类推, 第 n 层是 $1/n$. 此邻接矩阵对应的图像特征是一个 $5 \times 5 \times 16$ 的图像块, 可转换为 25×16 的输入.

2.3 图卷积网络

在图像处理中, 卷积的概念很直观, 因为图像是栅格格式的, 像素点的排列顺序也有明确的位置关系. 然而在抽象的图结构数据中, 没有这些性质, 没有空间上的位置关系, 也就难以通过卷积的方式进行计算. 图卷积网络 (graph convolutional network, GCN) 的核心思想是利用边的信息对节点信息进行聚合从而生成新的节点表示. 通过在图结构上进行推导和优化的方式来研究图神经网络. 图神经网络需要解决的难点是, 如何根据相邻节点特征和边的信息对当前节点特征进行更新, 从而对图数据进行节点分类、图分类、边预测等^[26]. 在图上, 不但可以处理非欧几里得空间的数据, 亦可处理欧几里得空间数据, 那是因为从广义上来讲, 任何数据在赋范空间内都可以建立拓扑关联.

关于图上的卷积操作, 主要从谱图理论出发, 利用拉普拉斯 (Laplace) 变换、傅里叶 (Fourier) 变换等工具, 通过卷积的一般形式进行推导、展开和近似, 从而得到离散的图卷积模型. 关于推导这里不占用篇幅. 下面直接考虑多层的图卷积网络, 最终得出的传播规则可以表示为

$$H^{(l+1)} = \sigma(\tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}H^lW^l), \quad (6)$$

其中 $H^{(l+1)} \in \mathbb{R}^{N \times D}$ 表示第 $l+1$ 层的特征, N 是样本个数, D 是特征维数. $H^{(l)}$ 表示第 l 层的特征. 通常 $H^0 = X$ 表示模型的输入. σ 是激活函数, 通常可以采用 ReLU, Sigmoid 等. W^l 是第 l 层可学习的权重. $\tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}$ 表示图中节点的位置关系及其规范化表达式, 通常表示成 $\hat{A} = \tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}$, $\tilde{A} = A + I_N$, I_N 表示单位矩阵. \tilde{D} 是度矩阵, 其中 $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$, 表示每行元素相加赋值到对角元素的位置上. 在模型训练过程中 \hat{A} 是一个常数矩阵. 所以传播规则式 (6) 可以简写为

$$H^{(l+1)} = \sigma(\hat{A}H^lW^l). \quad (7)$$

下面以一个图卷积网络的模型架构为例进行介绍, 包含输入层、图卷积层、全连接和一个输出层, 结构如图 5 所示, 表达式如下:

$$Z = f(X, A) = \text{softmax}(\hat{A}\text{ReLU}(\hat{A}\text{ReLU}(\hat{A}H^0W^0)W^1)W^2), \quad (8)$$

其中 W^0, W^1 和 W^2 是可学习的权重参数, $H^0 = X$, 激活函数 $\text{ReLU}(x) = \max(0, x)$ 分类器

$$\begin{aligned} \text{softmax}(x_i) &= \frac{1}{Z} \exp(x_i), \\ Z &= \sum_i \exp(x_i). \end{aligned} \quad (9)$$

网络的损失函数采用交叉熵损失, 定义如下:

$$\mathcal{L} = - \sum_{n \in \mathcal{Y}_L} \sum_{f=1}^F Y_{nf} \ln Z_{nf}, \quad (10)$$

其中 \mathcal{Y}_L 代表有标记的样本. F 代表最后特征图的通道数, 与分类的类别数保持一致. n 和 f 分别表示样本索引和通道索引. 最后, 可以通过最小化交叉熵损失来优化网络参数, 整个网络采用随机梯度优化算法来进行优化和求解.

2.4 基于散射图卷积网络的 PolSAR 图像分类

极化 SAR 图像分类是一种像素级的分类任务, 是指通过算法判断和确定图像中每一个像素点位置的地物类别.

接下来, 给出基于散射图卷积网络的极化 SAR 图像分类算法流程, 见算法 1. 分为 8 个步骤: (1) 对原始的极化散射矩阵进行极化散射编码, 得到 S_I , 这一步是将原始的复数矩阵进行了实数化, 便于后续模型的操作; (2) 极化散射矩阵是一个二维的实数矩阵, 将其转换成一维的特征向量 X , 来满足图网络的输入需求, 作为节点特征; (3) 考虑数据的散射特性, 进行节点散射建模, 构造邻接矩阵 A ; (4) 综合前面三点, 将极化 SAR 图像数据, 转换成一维特征向量, 同时得到邻接矩阵, 共同作为图卷积网络的输入; (5) 通过图卷积网络得到最后一层的输出的特征, 送入 Softmax 分类器进行分类; (6) 设置学习率、动量衰减参数、迭代次数等参数, 采用随机梯度下降法对网络进行优化; (7) 网络训练完成, 保存模型参数; (8) 利用训练好的参数, 在测试集上验证算法的性能, 输出分类结果.

Algorithm 1 Scatter graph convolutional network

Input: Polarimetric SAR image.

Output: Classification results.

- 1: Encodes the polarization scattering matrix to obtain S_I ;
 - 2: Unidimensional processing S_I gets X , as a node feature;
 - 3: The scattering characteristics of the node are modeled to obtain the adjacency matrix A ;
 - 4: Input X and A into the graph convolutional network;
 - 5: Inputs the last layer of features into the Softmax classifier;
 - 6: Updated 4 and 5 by the random gradient descent method;
 - 7: Meets the stop conditions and the training is completed;
 - 8: Output classification results.
-

3 实验结果及分析

本节主要验证所提出算法的性能, 主要分为 4 个部分进行介绍, 包括实验数据、实验设置、评价指标, 以及结果分析.

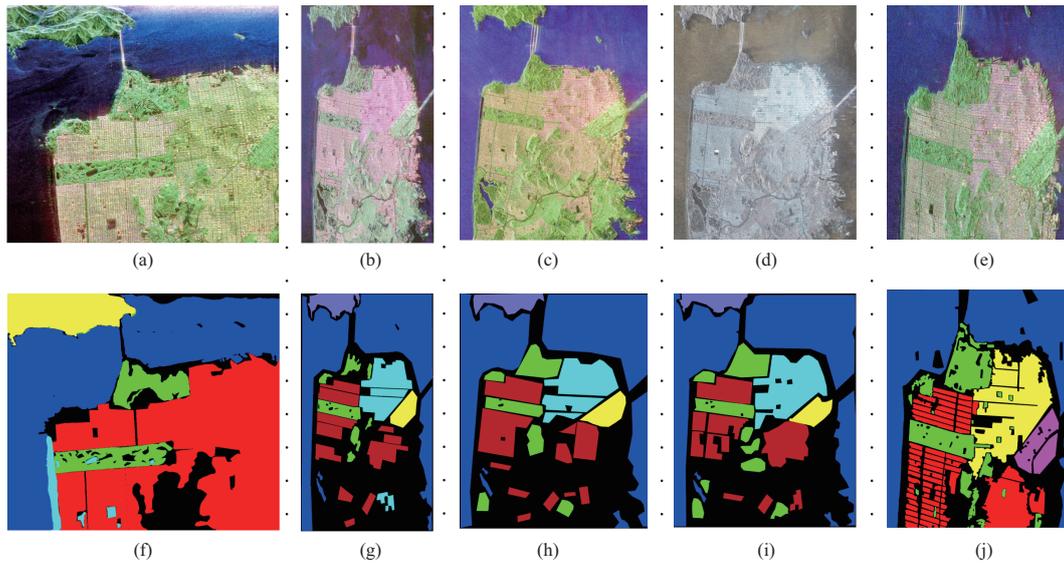


图 6 (网络版彩图) PolSF 数据集可视化. (a)–(e) 是不同传感器下的旧金山地区图像, 包括 SF-AIRSAR, SF-ALOS2, SF-GF3, SF-RISAT 和 SF-RS. (f)–(j) 分别是对应的标记图

Figure 6 (Color online) PolSF dataset visualization. (a)–(e) are the images of San Francisco area under different sensors, including SF-AIRSAR, SF-ALOS2, SF-GF3, SF-RISAT, and SF-RS. (f)–(j) are corresponding ground truth respectively

表 1 PolSF 数据集介绍

Table 1 PolSF dataset

Name	Time	Resolution (m)	Size	Class	Polarization	Country	Band
SF-AIRSAR	1989.08	10	1024 × 900	5	Full	USA	P
SF-ALOS2	2015.03	18	2784 × 5056	6	Full	Japan	L
SF-GF3	2018.08	8	2304 × 2912	6	Full	China	C
SF-RISAT	2016.08	2.33	4928 × 6391	6	Dual	India	X
SF-RS2	2008.04	8	1380 × 1800	5	Full	Canada	C

3.1 实验数据

本文采用的实验数据集是 PolSF^[27], 该数据集¹⁾²⁾ 包括 5 幅美国旧金山地区的极化 SAR 数据, 这 5 幅图像分别来自不同的卫星和不同的时间. 数据集的伪彩图和标记图可视化见图 6, 数据集的成像时间、分辨率、像素大小、类别和成像类型、卫星信息等信息, 见表 1.

3.2 实验设置

在实验中, 主要包括对比算法和所提出算法的参数设置. 本文采用的对比算法有堆叠自编码网络 (SAE)^[23]、卷积神经网络 (CNN)^[19]、卷积自编码网络 (CAE)^[37]、多尺度超像素图卷积网络 (MSSP-GCN)^[34]. 为了对比的公平性, 本文的对比算法和所提出的算法均设置了 9 层的网络, 结构为 $[I; 128; 256; 256; 256; 128; 64; 64; C]$, 其中 I 为输入 X 的维度, 实验中选取的图像大小为 31×31 , C 为对应图像的类别个数. 在模型训练中, 每类的训练样本个数均随机选取 1024 个, 剩下的标记样本作为测试

1) <https://github.com/liuxuvip/PolSF>.

2) <https://gitee.com/liuxu-vip/PolSF>.

表 2 SF-AIRSAR 数据上的分类结果
Table 2 Classification accuracy on SF-AIRSAR

Method	Mountain	Water	Urban	Vegetation	Bare soil	OA	AA	Kappa
SAE	0.7048	0.9642	0.9981	0.9986	0.6677	0.9567	0.8667	0.9337
CNN	0.6609	0.9715	0.9978	0.9967	0.6876	0.9579	0.8629	0.9353
CAE	0.6140	0.9640	0.9980	0.9962	0.7182	0.9593	0.8581	0.9374
MSSP-GCN	0.6320	0.9680	0.9950	0.9908	0.723	0.9618	0.8618	0.9432
SGCN	0.7454	0.9767	0.9974	0.9966	0.7488	0.9684	0.8930	0.9512

样本. 在训练阶段, 网络权重参数使用的初始化方法是 Xavier, 动量是 0.9, 学习率是 0.01, 训练的批大小是 64. 本文实验中使用的操作系统为 Ubuntu16.04, 深度学习框架为 Pytorch, 程序接口是 Python. 使用的图形工作站硬件是 64 G RAM 和 GeForce GTX TITAN X GPU.

3.3 评价指标

算法性能的评价指标分类是总体精度 (overall accuracy, OA)、平均精度 (average accuracy, AA) 和卡帕系数 (kappa coefficient, Kappa). 首先介绍总体精度 OA:

$$OA = \frac{M}{N}, \quad (11)$$

其中 M 是分类的样本个数, N 是总样本的个数. 下面是平均精度:

$$AA = \frac{1}{C} \sum_{i=1}^C \frac{M_i}{N_i}, \quad (12)$$

其中 C 是类别数, i 是类别索引, M_i 是第 i 类的分类数目, N_i 是第 i 类的所有样本个数.

$$Kappa = \frac{OA - P}{1 - P}, \quad P = \frac{1}{N^2} \sum_{i=1}^C \bar{Z}(i, :) * \bar{Z}(:, i), \quad (13)$$

其中 Z 是混淆矩阵, $\bar{Z}(i, :)$ 是其第 i 行元素之和, $\bar{Z}(:, i)$ 是其第 i 列元素之和. N 是测试样本的个数.

3.4 实验结果

下面给出了本文所提出算法和对比较算法在 PolSF 数据集上的分类结果. 见表 2~6 和图 7, 图 7 第 1~5 行分别是 SF-AIRSAR, SF-ALOS2, SF-GF3, SF-RISAT, SF-RS 的结果, 第 1~5 列分别表示 SAE, CNN, CAE, MSSP-GCN, SGCN 的结果.

3.4.1 SF-AIRSAR 数据实验结果

本实验数据是美国的机载合成孔径雷达 AIRSAR 于 1989 年拍摄于旧金山海湾区的全极化 SAR 图像. 空间分辨率是 10 m, 图像大小是 1024×900 , 标记了 5 个类别地物, 分别是山地、水、城市、植被、裸土. 未标记的地物标记为黑色. 实验结果见表 2 和图 7(a)~(e). 从表 2 可以看出, 本文所提出的算法整体准确率 OA 达到了 96.84%, 高于其他对比方法. 在这幅图像中, 山地和裸土这两类相对较难分, 分类准确率较低, 仅 60%~70% 之间, 本文所提出的算法相对对比算法提升了 4~8 个百分点. 第 2 类水的分类准确率也达到了最高 97.67%, 比 SAE 和 CAE 高 1.2 个百分点, 比 MSSP-GCN 和 CNN 高 0.6 个百分点. 第 3 和 4 类, 即城市和植被分类结果较好, 均达到了 99% 以上. 分类结果的可视化

表 3 SF-ALOS2 数据上的分类结果

Table 3 Classification accuracy on SF-ALOS2

Method	Mountain	Water	Vegetation	High-Density	Low-Density	Developed	OA	AA	Kappa
SAE	0.8991	0.9999	0.8734	0.9368	0.9862	0.7150	0.9644	0.9017	0.9419
CNN	0.8884	1.0000	0.8523	0.9420	0.9975	0.8122	0.9693	0.9154	0.9498
CAE	0.9263	1.0000	0.8559	0.9413	0.9986	0.8210	0.9716	0.9239	0.9535
MSSP-GCN	0.9128	1.0000	0.8726	0.9408	0.9932	0.8765	0.9733	0.9327	0.9582
SGCN	0.9044	1.0000	0.9027	0.9405	0.9965	0.9233	0.9770	0.9446	0.9623

表 4 SF-GF3 数据上的分类结果

Table 4 Classification accuracy on SF-GF3

Method	Mountain	Water	Vegetation	High-Density	Low-Density	Developed	OA	AA	Kappa
SAE	0.6282	0.9997	0.8913	0.9776	0.9710	0.8285	0.9595	0.8827	0.9365
CNN	0.6076	0.9999	0.9270	0.9947	0.9962	0.8001	0.9630	0.8876	0.9420
CAE	0.7312	0.9999	0.9150	0.9887	0.9779	0.9895	0.9755	0.9337	0.9616
MSSP-GCN	0.7219	0.9999	0.9355	0.9854	0.9788	0.9802	0.9758	0.9336	0.9622
SGCN	0.7107	0.9999	0.9807	0.9862	0.9993	0.9760	0.9808	0.9421	0.9698

见图 7(a)~(e), 可以看出图 7(e) 更接近真实地物标记图, 分类结果图中的噪声相对较少, 也表示本文提出的算法具有较好的分类性能.

3.4.2 SF-ALOS2 数据实验结果

该实验数据是日本的星载合成孔径雷达 ALOS2 于 2015 年拍摄于旧金山海湾区的全极化 SAR 图像. 空间分辨率是 18 m, 图像大小是 2784×5056 , 标记了 6 个类别地物, 分别是山地、水、植被、高密度城市、低密度城市、开发区. 未标记的地物标记为黑色. 实验结果见表 3 和图 7(f)~(j). 实验的量化指标见表 3, 总体的, 本文所提出的算法达到了 97.70% 的总体分类精度, 高于其他算法. 从每个类别分析, 所有算法对水这一类几乎都判断对了. 特别是在较难分辨的开发区这一类, 对比算法 SAE, CNN, CAE, MSSP-GCN 分别是 71.50%, 81.22%, 82.10% 和 87.65%. 本文所提出的算法 SGCN 达到了 92.33%, 高于对比算法近 10 个百分点. 从图 7(f)~(j) 对比可以看出, 本文算法的开发区分类结果, 相对比较清晰、均匀. 对于第 3 类植被, 本文算法也提高了 3~5 个百分点. 其他类别和对比算法基本持平, 分类准确率的 3 个指标均是最高.

3.4.3 SF-GF3 数据实验结果

该实验数据是中国的星载合成孔径雷达高分 3 号于 2018 年拍摄于旧金山海湾区的全极化 SAR 图像. 空间分辨率是 8 m, 图像大小是 2304×2912 , 标记了 6 个类别地物, 分别是山地、水、植被、高密度城市、低密度城市、开发区. 未标记的地物标记为黑色. 实验结果见表 4 和图 7(k)~(o). 从表 4 的分类指标可以看出, 本文提出算法的总体精度达到了 98.08%, Kappa 系数也达到了 96.98%. 从第 1 类山地的分类结果, 可以看出本文算法比 SAE 和 CNN 高出了近 10 个百分点. 从第 6 类开发区的分类结果, 可以看出 SGCN 比 SAE 和 CAE 分别提高了 15 和 17 个百分点, 对比图 7(l), (m) 和 (o) 可以看出. 特别地, 第 3 类植被的分类结果提升比较明显, 本文提出的算法的准确率是 98.07%, 相对 3 个对比算法提高了 7~9 个百分点. 对应的结果优势也可以从图 7(k)~(o) 看出.

表 5 SF-RISAT 数据上的分类结果
Table 5 Classification accuracy on SF-RISAT

Method	Mountain	Water	Vegetation	High-Density	Low-Density	Developed	OA	AA	Kappa
SAE	0.5810	0.9964	0.8393	0.9807	0.9814	0.4564	0.9255	0.8059	0.8866
CNN	0.6624	0.9940	0.8332	0.9396	0.9988	0.4682	0.9289	0.8160	0.8913
CAE	0.6248	0.9986	0.7792	0.9344	0.9918	0.7480	0.9375	0.8461	0.9048
MSSP-GCN	0.6288	0.9973	0.8124	0.9412	0.9903	0.6752	0.9401	0.8409	0.9113
SGCN	0.6440	0.9967	0.8400	0.9571	0.9893	0.6562	0.9440	0.8472	0.9144

表 6 SF-RS2 数据上的分类结果
Table 6 Classification accuracy on SF-RS2

Method	Water	Vegetation	High-Density	Low-Density	Developed	OA	AA	Kappa
SAE	0.9997	0.9579	0.9640	0.9683	0.8915	0.9772	0.9563	0.9673
CNN	0.9987	0.9591	0.9491	0.9829	0.9624	0.9796	0.9705	0.9707
CAE	1.0000	0.9934	0.9816	0.9915	0.8383	0.9856	0.9610	0.9793
MSSP-GCN	1.0000	0.9872	0.9834	0.9871	0.9266	0.9877	0.9769	0.9801
SGCN	0.9999	0.9896	0.9875	0.9883	0.9581	0.9924	0.9847	0.9891

3.4.4 SF-RISAT 数据实验结果

该实验数据是印度的星载合成孔径雷达 RISAT 于 2016 年拍摄于旧金山海湾区的双极化 SAR 图像, 特别注意的是本文中关于双极化 SAR 数据, 未成像而缺失的信息, 在散射矩阵中设置为 0. 空间分辨率是 2.33 m, 图像大小是 4928 × 6391, 标记了 6 个类别地物, 分别是山地、水、植被、高密度城市、低密度城市、开发区. 未标记的地物标记为黑色. 实验结果见表 5 和图 7(p)~(t). 从表 5 的分类指标可以看出, 本文所提出的算法在分类指标中, 总体分类精度、平均分类精度和 Kappa 系数都得到了最高, 分别是 94.4%, 84.72%, 91.44%. 其中比较难分辨的类别都取得不错的结果, 例如第 6 类, 即开发区. SGCN 在开发区这类的结果比 SAE 和 CNN 高出 20 个百分点. 从图 7(q)~(t) 也可以对比看出, 开发区这类地物明显在图 7(t) 增多. 其他类别涨幅在 -5~5 个百分点之间波动, 本文算法整体优于对比算法.

3.4.5 SF-RS2 数据实验结果

该实验数据是加拿大的星载合成孔径雷达 RADARSAT2, 2008 年拍摄于旧金山海湾区的全极化 SAR 图像. 空间分辨率是 8 m, 图像大小是 1380 × 1800, 标记了 5 个类别地物, 分别是水、植被、高密度城市、低密度城市、开发区. 未标记的地物标记为黑色. 实验结果见表 6 和图 7(u)~(y). 这幅图像的分类结果相对都较好, 从表 6 可以看出, 对比算法和本文提出的算法都高于 95.00%. SGCN 得到了 99.24% 的总体准确率, 在开发区这类地物中取得了较为明显的提升, 比 SAE 和 CAE 分别高出了 6 和 12 个百分点, 比 MSSP-GCN 高了 3 个百分点. 对比图 7(u)~(y), 可以看出, 开发区的分类结果比较平滑, 没有杂点, 边界比较清晰.

综上, 在 PolSAR 数据集中的 5 幅 PolSAR 数据的实验结果可以看出, 本文所提出的算法 SGCN 取得了较好的分类结果, 结果的整体分类精度、平均分类精度和 Kappa 系数都有所提升. 特别地, 在一些较难识别的类别中也表现得较为明显, 充分展示了本文算法的性能. 另外, 通过对比算法进行分析,

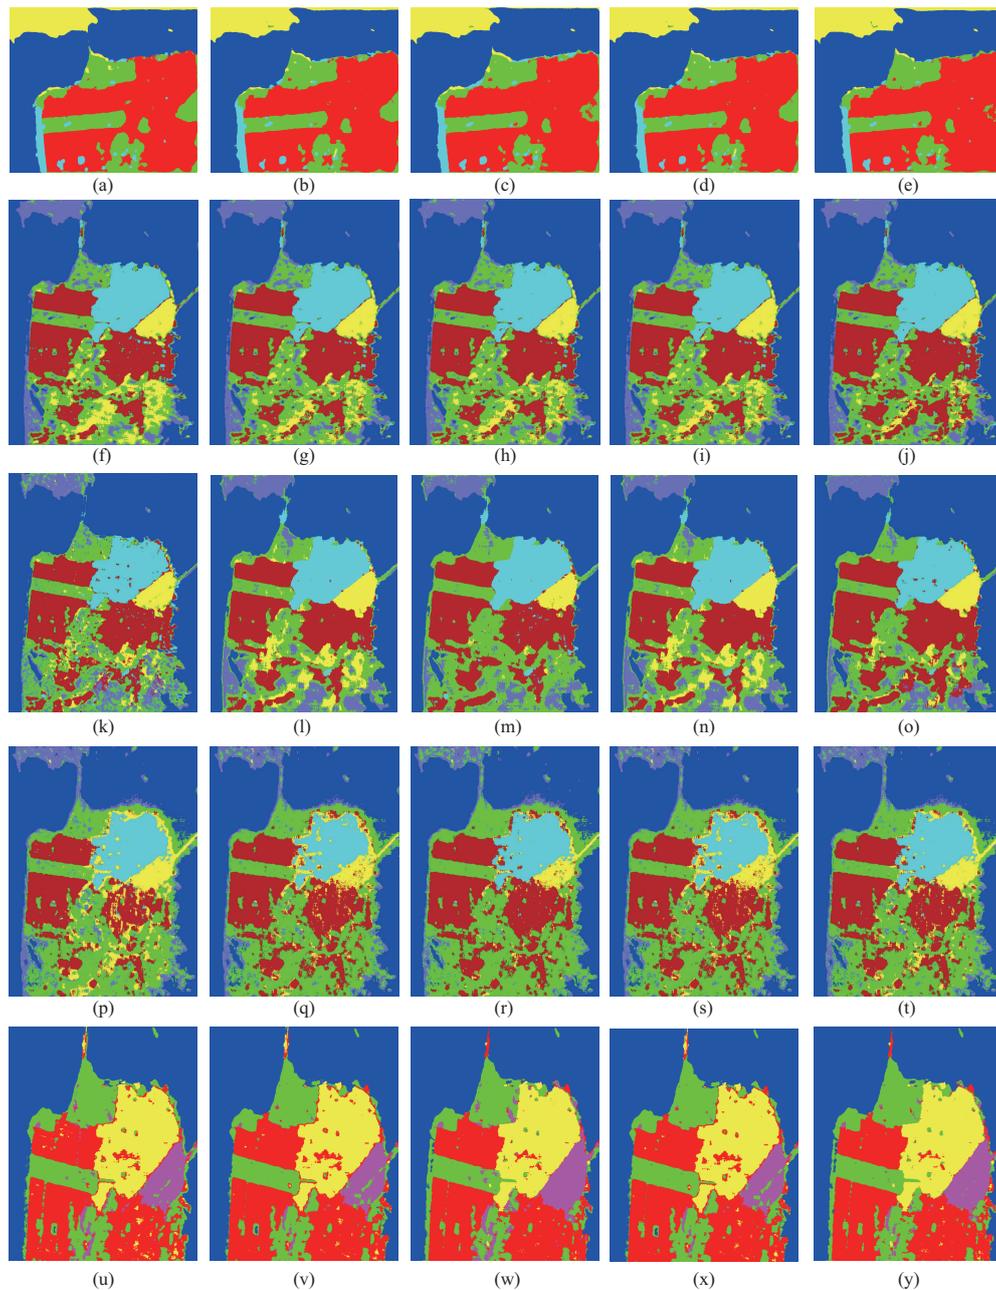


图 7 (网络版彩图) 实验分类结果图. 第 1~5 行分别代表数据 SF-AIRSAR, SF-ALOS2, SF-GF3, SF-RISAT 和 SF-RS. 第 1~5 列分别代表方法 SAE, CNN, CAE, MSSP-GCN 和 SGCN

Figure 7 (Color online) Classification results. The first to fifth rows represent data SF-AIRSAR, SF-ALOS2, SF-GF3, SF-RISAT, and SF-RS, respectively. The first to fifth columns represent methods SAE, CNN, CAE, MSSP-GCN, and SGCN, respectively

可以看出, 所提算法性能的提升主要是因为图卷积网络提取了更加有效的特征. 实验设置中, 我们和对比算法使用了相同的参数、分类器, 区别就在于图卷积网络的设计. 归结原因是图卷积网络更能够挖掘像素间的散射关系, 从而进行有效的表征, 从而增加其识别率. 关于算法的效率, 如表 7 所示, 从

表 7 计算时间
Table 7 Computation times

Method	SF-AIRSAR		SF-ALOS2		SF-GF3		SF-RISAT		SF-RS2	
	Train (s)	Test (s)								
SAE	300	55	312	120	322	88	325	130	300	60
CNN	348	75	322	115	320	92	300	125	283	80
CAE	321	40	315	117	315	95	323	128	325	52
MSSP-GCN	318	43	317	105	321	91	318	131	308	48
SGCN	308	42	315	104	317	96	321	132	311	47

训练时间来看, 各个算法的时间相差不多, 主要原因是本文中, 训练样本选取是一致, 即对于所有图像, 每个类别的数目是固定. 从测试时间可以看出, 图像尺寸的大小与测试时间的长短是一致的.

4 结论

本论文针对极化 SAR 图像地物分类的问题, 以极化散射矩阵为研究对象, 探索数据成像机理, 构造数据散射编码函数, 利用数据的散射特性, 借助图网络与卷积神经网络的表征和学习能力, 构建基于散射图卷积网络的极化 SAR 图像分类模型, 从而探索出极化 SAR 图像分类的新理论与新方法. 实验结果表明, 本文提出的算法可以有效地挖掘数据的特征, 从而高效完成极化 SAR 图像分类的任务. 在未来的工作中, 将更加深入地研究极化散射特性的建模.

参考文献

- Zhou M F, Wang X L. Object detection models of remote sensing images using deep neural networks with weakly supervised training method. *Sci Sin Inform*, 2018, 48: 1022–1034 [周明非, 汪西莉. 弱监督深层神经网络遥感图像目标检测模型. *中国科学: 信息科学*, 2018, 48: 1022–1034]
- Xu F, Hu C, Li J. Introduction to the topic of deep learning in remote sensing image processing. *Sci Sin Inform*, 2020, 50: 619–620 [徐丰, 胡程, 李军. 遥感图像处理中的深度学习专题简介. *中国科学: 信息科学*, 2020, 50: 619–620]
- Fang S, Yao Z J, Cao F Y. Spatio-temporal method of satellite image fusion based on linear model. *J Image Graph*, 2020, 25: 579–592 [方帅, 姚振稷, 曹风云. 线性模型的遥感图像时空融合. *中国图象图形学报*, 2020, 25: 579–592]
- Liu X. Deep fusion network learning for multi-source remote sensing image classification. Dissertation for Ph.D. Degree. Xi'an: Xidian University, 2019 [刘旭. 基于深度融合网络学习的多源遥感图像分类. 博士学位论文. 西安: 西安电子科技大学, 2019]
- Avouac J P, Meng L S, Wei S J, et al. Lower edge of locked Main Himalayan Thrust unzipped by the 2015 Gorkha earthquake. *Nat Geosci*, 2015, 8: 708–711
- Reiche J, Lucas R, Mitchell A L, et al. Combining satellite data for better tropical forest monitoring. *Nat Clim Change*, 2016, 6: 120–122
- Xu F, Wang H P, Jin Y Q. Deep learning as applied in SAR target recognition and terrain classification. *J Radar*, 2017, 6: 136–148 [徐丰, 王海鹏, 金亚秋. 深度学习在 SAR 目标识别与地物分类中的应用. *雷达学报*, 2017, 6: 136–148]
- Zhang Z M, Wang H P, Xu F, et al. Complex-valued convolutional neural network and its application in polarimetric SAR image classification. *IEEE Trans Geosci Remote Sens*, 2017, 55: 7177–7188
- Lyu Y, Kang T N, Pan Q, et al. UAV sense and avoidance: concepts, technologies, and systems. *Sci Sin Inform*, 2019, 49: 520–537 [吕洋, 康童娜, 潘泉, 等. 无人机感知与规避: 概念, 技术与系统. *中国科学: 信息科学*, 2019, 49: 520–537]

- 10 Chen S W, Tao C S. PolSAR image classification using polarimetric-feature-driven deep convolutional neural network. *IEEE Geosci Remote Sens Lett*, 2018, 15: 627–631
- 11 Guo Y W, Jiao L C, Wang S R, et al. Fuzzy superpixels for polarimetric SAR images classification. *IEEE Trans Fuzzy Syst*, 2018, 26: 2846–2860
- 12 Liu F, Jiao L C, Tang X. Task-oriented GAN for PolSAR image classification and clustering. *IEEE Trans Neural Netw Learn Syst*, 2019, 30: 2707–2719
- 13 Wang X S, Chen S W. Polarimetric synthetic aperture radar interpretation and recognition: advances and perspectives. *J Radar*, 2020, 9: 259–276 [王雪松, 陈思伟. 合成孔径雷达极化成像解译识别技术的进展与展望. *雷达学报*, 2020, 9: 259–276]
- 14 Zhang X R, Yu X Y, Tang X, et al. PolSAR image classification method based on Markov discriminant spectral clustering. *J Radar*, 2019, 8: 425–435 [张向荣, 于心源, 唐旭, 等. 基于马尔科夫判别谱聚类的极化 SAR 图像分类方法. *雷达学报*, 2019, 8: 425–435]
- 15 Krogager E. New decomposition of the radar target scattering matrix. *Electron Lett*, 1990, 26: 1525–1527
- 16 LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521: 436–444
- 17 Zhou Y, Wang H P, Xu F, et al. Polarimetric SAR image classification using deep convolutional neural networks. *IEEE Geosci Remote Sens Lett*, 2016, 13: 1935–1939
- 18 Gao F, Huang T, Wang J, et al. Dual-branch deep convolution neural network for polarimetric SAR image classification. *Appl Sci*, 2017, 7: 447
- 19 Chen S W, Tao C S. PolSAR image classification using polarimetric-feature-driven deep convolutional neural network. *IEEE Geosci Remote Sens Lett*, 2018, 15: 627–631
- 20 Jiao L C, Liu F. Wishart deep stacking network for fast POLSAR image classification. *IEEE Trans Image Process*, 2016, 25: 3273–3286
- 21 Zhang Z M, Wang H P, Xu F, et al. Complex-valued convolutional neural network and its application in polarimetric SAR image classification. *IEEE Trans Geosci Remote Sens*, 2017, 55: 7177–7188
- 22 Bi H X, Xu F, Wei Z Q, et al. An active deep learning approach for minimally supervised PolSAR image classification. In: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium*, 2019. 9378–9395
- 23 Liu X, Jiao L C, Tang X, et al. Polarimetric convolutional network for PolSAR image classification. *IEEE Trans Geosci Remote Sens*, 2019, 57: 3040–3054
- 24 Bruna J, Zaremba W, Szlam A, et al. Spectral networks and locally connected networks on graphs. 2014. ArXiv:1312.6203
- 25 Zhao L, Peng X, Tian Y, et al. Semantic graph convolutional networks for 3D human pose regression. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, 2019. 3425–3435
- 26 Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks. In: *Proceedings of the 5th International Conference on Learning Representations*, 2017
- 27 Liu X, Jiao L C, Liu F. PolSF: PolSAR image dataset on San Francisco. 2019. ArXiv:1912.07259
- 28 Wan S, Gong C, Zhong P, et al. Hyperspectral image classification with context-aware dynamic graph convolutional network. *IEEE Trans Geosci Remote Sens*, 2021, 59: 597–612
- 29 Cai Y M, Zhang Z J, Cai Z H, et al. Graph convolutional subspace clustering: a robust subspace clustering framework for hyperspectral image. *IEEE Trans Geosci Remote Sens*, 2021, 59: 4191–4202
- 30 Wan S, Pan S R, Zhong P, et al. Dual interactive graph convolutional networks for hyperspectral image classification. *IEEE Trans Geosci Remote Sens*, 2021. doi: 10.1109/TGRS.2021.3075223
- 31 Bai J, Ding B X, Xiao Z, et al. Hyperspectral image classification based on deep attention graph convolutional network. *IEEE Trans Geosci Remote Sens*, 2021. doi: 10.1109/TGRS.2021.3066485
- 32 Ding Y, Guo Y Y, Chong Y W, et al. Global consistent graph convolutional network for hyperspectral image classification. *IEEE Trans Instrum Meas*, 2021, 70: 1–16
- 33 Hong D, Gao L, Yao J, et al. Graph convolutional networks for hyperspectral image classification. *IEEE Trans Geosci Remote Sens*, 2021, 59: 5966–5978
- 34 Cheng J D, Zhang F, Xiang D L, et al. PolSAR image classification with multiscale superpixel-based graph convolutional network. *IEEE Trans Geosci Remote Sens*, 2021. doi: 10.1109/TGRS.2021.3079438
- 35 Liu H Y, Zhu T W, Shang F H, et al. Deep fuzzy graph convolutional networks for PolSAR imagery pixelwise

- classification. *IEEE J Sel Top Appl Earth Observation Remote Sens*, 2021, 14: 504–514
- 36 Ren S J, Zhou F. Semi-supervised classification for PolSAR data with multi-scale evolving weighted graph convolutional network. *IEEE J Sel Top Appl Earth Observation Remote Sens*, 2021, 14: 2911–2927
- 37 Xie W, Jiao L C, Hou B, et al. POLSAR image classification via wishart-AE model or wishart-CAE model. *IEEE J Sel Top Appl Earth Observations Remote Sens*, 2017, 10: 3604–3615

Scattering graph convolutional network-based PolSAR image classification

Xu LIU^{1,2,3}, Lingling LI^{1,2,3*}, Fang LIU^{1,2,3}, Shuyuan YANG^{1,2,3}, Biao HOU^{1,2,3} & Licheng JIAO^{1,2,3*}

1. *School of Artificial Intelligence, Xidian University, Xi'an 710071, China;*

2. *Key Laboratory of Intelligent Perception and Image Understanding of the Ministry of Education of China, Xi'an 710071, China;*

3. *International Research Center of Intelligent Perception and Computation, Xi'an 710071, China*

* Corresponding author. E-mail: linglingxidian@gmail.com, lchjiao@mail.xidian.edu.cn

Abstract In this paper, we address the problem of insufficient feature extraction and the difficulty in interpreting the polarimetric synthetic aperture radar (PolSAR) images with all-day and all-weather capability and propose a novel scattering graph convolution network for PolSAR image classification. In terms of feature extraction, this paper presents a one-dimensional representation of polarimetric scattering coding. Simultaneously, considering the target scattering characteristics and the complex relationship among pixels, combined with the graph theory, a novel graph representation model of scattering mechanism is proposed to describe the complex polarization scattering mechanism. Finally, a polarimetric SAR image classification model based on the scatter graph convolution network is proposed to improve the decoding and classification of the PolSAR data. The experimental results regarding the five images of the PolSF dataset demonstrate that the proposed algorithm exhibits superior performance.

Keywords scattering, feature representation, graph convolutional network, PolSAR image, classification