

# 基于深度卷积神经网络的图上半监督极化 SAR 图像分类算法

魏志强<sup>1</sup>, 毕海霞<sup>2</sup>, 刘 霞<sup>3</sup>

(1. 西安电子工程研究所, 陕西西安 710100; 2. 西安交通大学电子与信息工程学院, 陕西西安 710049;  
3. 西安理工大学应用数学系, 陕西西安 713300)

**摘 要:** 为实现在只有少量标记数据情况下的高质量图像分类, 本文提出了一种基于深度卷积神经网络的图上半监督极化 SAR 图像分类算法. 该算法将极化 SAR 图像建模为无向图, 并基于该无向图, 定义了包含半监督项, 卷积神经网络项和类标光滑项的能量函数. 算法所采用的卷积神经网络提取抽象的数据驱动的极化特征. 半监督项约束了有标记像素的类标在分类过程中保持不变. 类标光滑项约束了像素间类标的光滑性. 基于对 PauliRGB 图像进行超像素分割而产生的初始化类标图, 交替迭代优化所定义的能量函数直至其收敛. 在两幅真实极化 SAR 图像上的实验结果表明, 该算法达到了优异的分类效果, 其性能优于当前已有算法.

**关键词:** 极化 SAR 图像分类; 半监督; 卷积神经网络; 图模型

**中图分类号:** TP753; TP183

**文献标识码:** A

**文章编号:** 0372-2112 (2020)01-0066-09

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2020.01.008

## A Graph-Based Semi-Supervised PolSAR Image Classification Method Using Deep Convolutional Neural Networks

WEI Zhi-qiang<sup>1</sup>, BI Hai-xia<sup>2</sup>, LIU Xia<sup>3</sup>

(1. Xi'an Electronic Engineering Research Institute, Xi'an, Shaanxi 710100, China;  
2. School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an, Shaanxi 710049, China;  
3. Department of Applied Mathematics, Xi'an University of Technology, Xi'an, Shaanxi 713300, China)

**Abstract:** To realize high quality image classification with few labeled data, a graph-based semi-supervised PolSAR image classification method using deep neural networks is proposed in this paper. The PolSAR image is modeled as a graph, based on which we design an energy function which incorporates a semi-supervision term, a convolutional neural network (CNN) term and a pairwise smoothness term. CNN is responsible for extracting discriminative polarimetric features. The semi-supervision term enforces that class information of labeled pixels keep fixed during the classification. The pairwise smoothness term enforces class label smoothness. Started from an initialized class label map generated using superpixel segmentation of polarimetric PauliRGB image, the proposed method iteratively optimizes the energy function until the model converges. Experimental results conducted on two benchmark PolSAR images show that our approach effectively improves the classification accuracy with limited numbers of labeled pixels.

**Key words:** polarimetric synthetic aperture radar (PolSAR) image classification; semi-supervised method; convolutional neural network (CNN); graph model

### 1 引言

极化合成孔径雷达(极化 SAR)图像分类是极化 SAR 发展和应用的一个重要环节. 根据在图像分类中

是否使用有标记数据, 图像分类算法可分为监督算法、无监督算法和半监督算法.

监督算法利用有标记像素训练分类器, 并将其用于其余像素的标记预测. 多种经典的监督算法<sup>[1-3]</sup>被用

于极化 SAR 图像分类中. 近年来, 人们将深度学习技术<sup>[4-6]</sup>引入极化 SAR 图像分类中, 获得了优异的结果. 该算法可达到较高的分类准确率, 但其强烈依赖于大量的有标记数据.

无监督算法不使用有标记数据实现图像分类. 它通常基于目标分解理论<sup>[7,8]</sup>生成初始类标图. 然后根据极化统计分布<sup>[9,10]</sup>, 对初始类标图进行迭代更新<sup>[11]</sup>. 该算法简单、执行速度快, 但分类准确率往往不高.

半监督分类算法同时利用有标记和无标记数据进行图像分类, 以提升算法的分类性能和泛化能力. 该算法可基于更少的信息标记成本得到更高的准确率, 近年来发展迅速<sup>[12]</sup>.

图上半监督方法是一种典型的半监督学习方法. 其在建立图模型时, 在图像上构建一张由顶点和边组成的图, 顶点对应图像的像素, 边代表像素间的相似度. 分类过程中, 类标信息由有标记像素沿边传播至未标记像素. 近几年, 该算法取得了较好的分类效果<sup>[13,14]</sup>. 但是, 如何挖掘更具代表性的极化特征并实现图上类标的有效传播, 仍是一项有挑战性的任务.

本文提出一种半监督极化 SAR 图像分类方法, 将图上半监督分类算法和深度卷积神经网络融合于极化 SAR 图像分类框架中. 实验结果证明了该算法相较于其它分类算法的优势.

## 2 分类算法

### 2.1 模型概述

给定一幅  $N$  个像素的极化 SAR 图像, 每个像素的输入为  $3 \times 3$  复数相干矩阵  $T$ . 将原始特征数据定义为  $\mathbf{X} \in \mathbf{R}^{D_1 \times D_2 \times D_3}$ , 其中  $D_1$  和  $D_2$  为图像的高度和宽度,  $D_3$  为特征向量维度, 总像素数目  $N = D_1 \times D_2$ . 定义有标记像素集为  $\mathbf{L} = \{(x_1, t_1), (x_2, t_2), \dots, (x_n, t_n)\}$ , 其中,  $n \ll N$ , 为训练样本的数目,  $t_i \in \{1, 2, \dots, K\}$ ,  $x_i \in S_{\text{sup}}$ ,  $K$  为图像类别数,  $S_{\text{sup}}$  为标记像素集. 算法旨在为每个像素  $i$  ( $i \in \{1, \dots, N\}$ ) 分配类标  $y_i$ . 定义  $\mathbf{Y} = \{y_i\}$  代表图像中所有像素的类标集合.

图 1 为图上半监督深度卷积神经网络模型. 在图像上构建图, 监督信息为有标记像素施加类别约束, 使得其类别在分类过程中保持不变. CNN 向该图模型输出像素预测值. 图模型隐含的类标光滑性先验约束了类标传播中的空间一致性. 为此, 定义一个融合了监督信息、CNN 预测和类标光滑项的能量函数, 并设计优化算法求解该模型.

### 2.2 模型定义

在图像上建立了一张无向图  $\mathcal{G} = \langle \mathcal{V}, \mathcal{E} \rangle$ . 图像的顶点集  $\mathcal{V}$  对应像素, 包括有标记和无标记的像素, 类标  $y_i$  为每个节点  $v_i \in \mathcal{V}$  上的变量. 为求解该分类模型, 定义




图 1 图上半监督深度卷积神经网络模型

能量函数如下:

$$E(\mathbf{Y}, \Theta | \mathbf{X}, \mathbf{L}) = E_s(\mathbf{Y} | \mathbf{X}, \mathbf{L}) + E_c(F_\Theta | \mathbf{X}, \mathbf{Y}) + E_p(\mathbf{Y} | \mathbf{X}) \quad (1)$$

其中,  $F_\Theta$  为 CNN 在参数取值为  $\Theta$  时的非线性变换,  $\Theta$  为整个 CNN 的滤波器和偏置,  $E_s(\mathbf{Y} | \mathbf{X}, \mathbf{L})$  为半监督项,  $E_c(F_\Theta | \mathbf{X}, \mathbf{Y})$  为 CNN 项,  $E_p(\mathbf{Y} | \mathbf{X})$  为类标光滑项. 最小化该能量函数求解得到类标  $\mathbf{Y}$  和 CNN 参数  $\Theta$ .

#### (1) 半监督项

半监督项约束有标记像素的类别不变性, 其基于随机选择的有标记像素集  $\mathbf{L}$  定义如下:

$$E_s(\mathbf{Y} | \mathbf{X}, \mathbf{L}) = \sum_{i=1}^N \psi_i^{\text{SEMI}}(y_i | \mathbf{X}, \mathbf{L}) \quad (2)$$

其中,  $\psi_i^{\text{SEMI}}(y_i | \mathbf{X}, \mathbf{L})$  为半监督项, 定义如下:

$$\psi_i^{\text{SEMI}}(y_i) = \begin{cases} 0, & \text{if } x_i \in S_{\text{sup}} \text{ and } y_i = t_i \\ \infty, & \text{if } x_i \in S_{\text{sup}} \text{ and } y_i \neq t_i \\ -\log(1/K), & \text{otherwise} \end{cases} \quad (3)$$

对有标记像素  $x_i$ , 如果类标预测值  $y_i$  与真实类标  $t_i$  相同, 则半监督项值为 0, 否则值为无穷大. 对无标记像素, 所有类标的半监督项值设置为等对数概率值. 最小化该项意味着在类标传播过程中, 预测类标值倾向于取真实类标值.

#### (2) CNN 项

本文算法的 CNN 架构如图 2 所示. 包括一个输入层, 两组卷积层和池化层, 两个全连接层和一个 softmax 分类器连接至输出层. 在极化 SAR 图像分类任务中, 每个像素的输入  $x_i$  是一个由原始极化特征构成的三维数据块.

CNN 网络结构设置为: 每个像素输入到 CNN 的特征块大小为  $8 \times 8 \times 6$ . 第一个卷积层包含 20 个卷积核, 其大小为  $3 \times 3$ , 第二个卷积层包含 50 个卷积核, 其大小为  $2 \times 2$ . 两个最大池化层核大小为  $2 \times 2$ . 第一个全连接层包含




图2 CNN网络架构

500 个单元,第二个全连接层的单元数为图像类别数。

CNN 项的能量函数写作:

$$E_c(F_\Theta | \mathbf{X}, \mathbf{Y}) = - \sum_{i=1}^N \sum_{j=1}^K \mathbb{1}\{y_i = j\} \log P(y_i = j | F_\Theta) \quad (4)$$

其中,  $P(y_i = j | F_\Theta)$  标识了像素  $x_i$  取类标  $j$  的概率。

(3) 类标光滑项

类标光滑项  $E_p(\mathbf{Y} | \mathbf{X})$  强制约束相邻像素具有相似的类标,定义如下:

$$E_p(\mathbf{Y} | \mathbf{X}) = \alpha_p \sum_{i=1}^N \sum_{j \in \mathcal{N}(i)} \mathcal{S}_{ij} \quad (5)$$

其中,  $\alpha_p$  为类标光滑系数,  $\mathcal{N}(i)$  为像素  $i$  的邻域像素集.  $\mathcal{S}_{ij}$  定义如下:

$$\mathcal{S}_{ij} = |y_i - y_j| \exp\left(-\frac{\|v_i - v_j\|_2^2}{2\sigma}\right) \quad (6)$$

其中,  $v_i$  为在像素  $i$  上的特征向量,要求它在图像边缘处变化剧烈,  $v_i$  即取值为 Pauli 极化分解加权系数的组合.  $\sigma$  为两个邻域像素  $i$  和  $j$  之间的特征均方差距离. 类标光滑项使得相邻像素具有相同的类标,并鼓励类标边界与图像边界对齐. 若像素  $i$  和  $j$  均位于平坦区域,则式(6)中的指数项数值比较大,因此,最小化  $\mathcal{S}_{ij}$  强烈约束  $y_i$  和  $y_j$  取值相同. 但对跨越边界的邻域像素,该指数项数值较小,甚至接近于 0,因此,在优化过程中,允许邻域像素  $i$  和  $j$  存在类标差异。

(4) 总能量函数讨论

综上所述,总能量函数形式如下:

$$\begin{aligned} E(\mathbf{Y}, F_\Theta | \mathbf{X}, \mathbf{L}) &= \underbrace{\sum_{i=1}^N \psi_i^{\text{semi}}(y_i | \mathbf{X}, \mathbf{L})}_{\text{半监督项}} \\ &\quad - \underbrace{\sum_{i=1}^N \sum_{j=1}^K \mathbb{1}\{y_i = j\} \log P(y_i = j | F_\Theta)}_{\text{CNN项}} \\ &\quad + \underbrace{\alpha_p \sum_{i=1}^N \sum_{j \in \mathcal{N}(i)} |y_i - y_j| \exp\left(-\frac{\|v_i - v_j\|_2^2}{2\sigma_m}\right)}_{\text{类标光滑项}} \quad (7) \end{aligned}$$

半监督项用于约束有标记像素固定取其真实类标值. CNN 项用于学习判别式特征,并在有标记像素的引导下进行类标预测. 类标光滑项约束预测类标图的光滑性,以及类标边界与图像边界的一致性. 该能量函数的类标  $\mathbf{Y}$  和 CNN 网络  $F_\Theta$  均为未知量,其中类标  $\mathbf{Y}$  为离散变量,  $F_\Theta$  的参数  $\Theta$  为连续变量。

## 2.3 模型优化算法

为求解式(7)中的未知变量,设计一个交替迭代优化算法. 首先,基于固定类标  $\mathbf{Y}$  学习  $F_\Theta$  的网络参数  $\Theta$  (CNN 学习子问题),然后基于固定  $F_\Theta$  学习类标  $\mathbf{Y}$  (类标传播子问题). 这两个子问题相互依赖:

(i) 当类标  $\mathbf{Y}$  固定时,优化算法学习 CNN;

(ii) 当  $F_\Theta$  固定时,优化算法基于监督信息、CNN 预测和类标光滑约束将类标传播至未标记像素。

(1) CNN 学习子问题

该子问题旨在基于当前类标  $\mathbf{Y}$  学习一个 CNN 网络. 学习过程中类标  $\mathbf{Y}$  保持不变. 迭代数  $t = 1$  时,当前类标取 PauliRGB 图像超像素分割初始化类标;  $t > 1$  时,当前类标取  $t - 1$  轮迭代的估计类标. 由于类标  $\mathbf{Y}$  为固定变量,式(7)可重写为:

$$E(F_\Theta | \mathbf{X}, \mathbf{Y}) = - \sum_{i=1}^N \sum_{j=1}^K \mathbb{1}\{y_i = j\} \log P(y_i = j | F_\Theta) \quad (8)$$

优化式(8)函数得到  $F_\Theta$  的网络参数  $\Theta$ . 式(8)函数采用随机梯度下降(Stochastic Gradient Descent, SGD)算法优化求解. 在第  $t$  个迭代中, CNN 参数  $\Theta$  按如下公式进行更新:

$$\Theta_{t+1} = \Theta_t - \tau \frac{\partial E(F_\Theta | \mathbf{X}, \mathbf{Y})}{\partial \Theta} \quad (9)$$

其中,  $\tau$  为学习率. 基于优化后的 CNN 参数  $\Theta$ . 本文使用开源代码 MatConvNet<sup>①</sup> 对 CNN 进行训练。

(2) 类标传播子问题

本子问题旨在基于当前 CNN 网络  $F_\Theta$  预测类标  $\mathbf{Y}$ . 图中像素由重新训练的 CNN 网络  $F_\Theta$  对其进行标记,并由类标光滑项约束进行平滑操作. 由于 CNN 参数  $\Theta$  为固定值,式(7)可重写为:

$$\begin{aligned} E(\mathbf{Y} | \mathbf{X}, \mathbf{L}, F_\Theta) &= \sum_{i=1}^N \psi_i^{\text{semi}}(y_i | \mathbf{X}, \mathbf{L}) \\ &\quad - \sum_{i=1}^N \sum_{j=1}^K \mathbb{1}\{y_i = j\} \log P(y_i = j | F_\Theta) \\ &\quad + \alpha_p \sum_{i=1}^N \sum_{j \in \mathcal{N}(i)} |y_i - y_j| \exp\left(-\frac{\|v_i - v_j\|_2^2}{2\sigma_m}\right) \quad (10) \end{aligned}$$

该类标分配问题是一个组合优化问题,可看作一个标准的 MRF<sup>[15,16]</sup>. 图上的类标  $\mathbf{Y}$  组成了一个 MRF,式(10)为其能量函数. MRF 标注是 NP-hard 问题,本文采用置信传播算法<sup>[17]</sup> 对 MRF 进行优化求解。

## 2.4 原始极化特征

如表 1 所示,六维的实极化特征向量作为算法的输入,记作 RF -  $i, i = 1, \dots, 6$ . 这些特征均从二阶  $3 \times 3$  极化

① <http://www.vlfeat.org/matconvnet/>

复相干矩阵  $T$  提取<sup>[4]</sup>. RF-1 为总极化功率 SPAN ( $SPAN = T_{11} + T_{22} + T_{33}$ ) 的对数形式. RF-2 和 RF-3 分别为  $T_{22}$  和  $T_{33}$  功率与总极化功率的比值. RF-4 至 RF-6 是交叉极化项  $T_{12}$ 、 $T_{13}$  和  $T_{23}$  的相对相关系数, 定义为交叉极化项功率与其对应的两个同极化项功率乘积平方根的比值. RF-2 至 RF-6 特征均归一化至  $[0, 1]$ .

表 1 本文算法所使用的原始极化特征

标识	描述
RF-1 = $10 \log_{10}(SPAN)$	分贝形式的极化总功率
RF-2 = $T_{22}/SPAN$	功率 $T_{22}$ 与总极化功率比值
RF-3 = $T_{33}/SPAN$	功率 $T_{33}$ 与总极化功率比值
RF-4 = $ T_{12}  / \sqrt{T_{11} \cdot T_{22}}$	$T_{12}$ 的相对相关系数
RF-5 = $ T_{13}  / \sqrt{T_{11} \cdot T_{33}}$	$T_{13}$ 的相对相关系数
RF-6 = $ T_{23}  / \sqrt{T_{22} \cdot T_{33}}$	$T_{23}$ 的相对相关系数

## 2.5 模型初始化

极化 SAR 图像具有空间一致性, 即相邻的像素倾向于属于同一地物种类<sup>[11]</sup>. 基于此先验, 本文设计一种基于超像素分割的初始化算法. 首先对 PauliRGB 图像执行简单线性迭代聚类算法<sup>[18]</sup> (Simple Linear Iterative Cluster, SLIC) 得到超像素分割图. 如果某个超像素包含有标记像素, 则其内部所有像素均初始化为同样的类标, 并加入训练像素集. 最终得到了一个扩展训练像素集, 用作本文优化算法的输入.

## 2.6 算法流程图

图 3 为本文算法的流程图. 首先, 执行精细 Lee 滤波算法<sup>[19]</sup> 减少散斑噪声, 然后提取原始极化特征, 并生成超像素分割初始化类标图. 最后, 交替迭代优化图上半监督深度卷积神经网络模型, 求解得到分类结果和 CNN 参数.

## 3 实验结果及分析

### 3.1 实验数据和参数设置

使用两个真实极化 SAR 数据对本文算法验证. 第一个数据为 NASA/JPL AIRSAR 获取的荷兰 Flevoland 地区图像, 大小为  $750 \times 1024$ . 该数据的 PauliRGB 图像、真实类标及色码如图 4(a) 和图 4(b) 所示. 第二个数据为 NASA/JPL AIRSAR 获取的旧金山地区的数据, 其大小为  $900 \times 1024$ . 该图像没有真实标记, 本文采用与文献[4]同样的类标设置, 即图像共包含 5 类地物. 有标记像素和测试像素在图 4(c) 中标识.

算法参数设置为: 学习率  $\tau$  和动量参数分别为 0.001 和 0.9, 批大小为 100, 类标光滑系数设置为 5. 选择 1% 的有标记像素作为算法的输入.

### 3.2 算法有效性验证

CNN 学习 (CNN Learning, CL)、类标传播 (Label Propagation, LP)、迭代优化算法以及超像素分割初始化

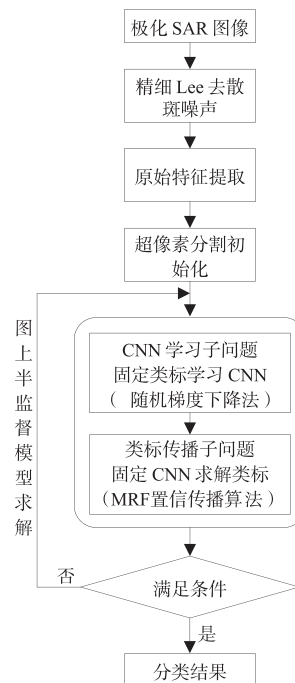


图 3 本文算法流程图

是本算法中的四个关键要素. 为验证其有效性, 分别对是否采用超像素分割初始化, 经过一轮 CL 后、或一轮 CL + LP 后, 以及三轮 CL + LP 后的类标结果进行比较.

以 Flevoland 地区数据为例, 图 5 和表 2 为分类结果和数值结果. 不采用超像素分割作为初始化的组称作随机采样组, 采用超像素分割作为初始化的组称作超像素分割组.

表 2 算法有效性分析总分类准确率/%

对象/类别	初始化	一轮 CL	一轮 CL + LP	三轮 CL + LP
随机采样组	100	84.43	87.47	88.34
超像素分割组	98.03	<b>95.22</b>	<b>97.12</b>	<b>98.82</b>

随机采样组的初始输入及结果如图 5(a1) ~ (a4) 所示. 图 5(a2) 为经过一轮 CL 后的分类结果, 可以发现大量误分类像素, 如图中黑色椭圆和红色矩形所标识的区域. 这是由于随机采样组的训练样本过少, 使得 CNN 网络无法有效分辨出这些地表类别.

图 5(b1) ~ (b4) 为超像素分割组初始化及分类的结果. 比较图 5(b2) 与图 5(a2) 可以看出, 采用超像素分割作为初始化输入进行 CNN 学习后, 许多在图 5(a2) 中被误分类的像素得到了校正. 这恰好验证了超像素分割以及 CNN 学习对分类准确率的提升. 比较图 5(b3) 与图 5(b1) ~ (b2) 可得, 执行过半监督图上类标传播的分类图呈现出了更清晰的边界, 且孤立像素大大减少, 显示了类标光滑性约束的平滑效果.

为验证迭代优化算法的有效性, 对该数据进行了三轮 CL + LP 迭代优化. 从图 5(b4) 及其黑色椭圆形标

注的区域可观测出,优化后的分类结果与真实类标吻

合度更好,且空间一致性更佳.

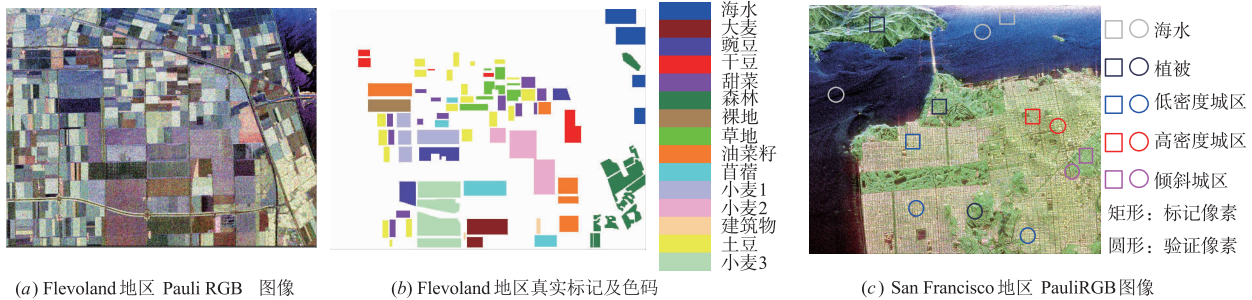


图4 San Francisco地区实验数据及标记和测试像素




图5 算法有效性验证结果

(a1)~(a4)随机采样组: (a1)训练样本; (a2)一轮CL结果; (a3)一轮CL+LP结果; (a4)三轮CL+LP结果  
(b1)~(b4)超像素分割组: (b1)超像素分割结果; (b2)一轮CL结果; (b3)一轮CL+LP结果; (b4)三轮CL+LP结果

表2为两组实验的总分类准确率.结果显示,超像素分割组相较于随机采样组的“一轮CL”、“三轮CL+LP”的分类准确率分别增加了10.79%、9.65%和10.48%.在超像素分割组中,“一轮CL+LP”和“三轮CL+LP”相较于“一轮CL”的分类准确率增加了1.90%和3.60%.以上结果证明了CNN学习、类标传播、迭代优化算法以及超像素分割初始化的有效性.

### 3.3 算法比较分析

#### (1) Flevoland地区数据的实验结果

比较本文算法与其它8种典型算法,包括SVM算法<sup>[2]</sup>、Wishart算法<sup>[9]</sup>、Wishart-Bernoulli限制玻尔兹曼机算法(WBRBM)<sup>[5]</sup>、Wishart-深度置信网络算法(WDBN)<sup>[5]</sup>、Wishart-深度堆栈网络算法(WDSN)<sup>[6]</sup>、卷积神经网络算法(CNN)<sup>[4]</sup>、半监督空间图算法(SSA)<sup>[13]</sup>和带邻域约束的半监督特征提取算法(SNC)<sup>[14]</sup>.图6和表3为分类结果和分类准确率值.

从图6(a)可以看出,SVM算法的误分类比较严重,尤其是在图像的上部和左侧部分.图6(b)为

Wishart算法的分类结果,图中裸地和水被严重混淆(由红色矩形标识).此外,油菜籽和小麦1两个类别也存在分类混淆问题(由黑色椭圆标识).图6(c)和图6(e)为WBRBM和WDSN算法的分类结果.两个类标图中均有许多误分类像素.许多油菜籽类别的像素被分类为小麦1类别,反之亦然(由黑色椭圆标识).同时,图像中存在内部像素不连续的问题(由黑色矩形标识).

图6(f)为CNN算法的分类结果.其结果比前述各种算法更加清晰,但是,草地类别过度影响了整图的分,许多不属于草地类别的像素被归为草地类别,例如,黑色矩形标识的区域应被分类为苜蓿.图6(g)和图6(h)为SSA和SNC算法的分类结果.文献[13,14]中没有给出整图的类标,只给出了有真实标记的像素的类标.结果显示,草地、森林、油菜籽和小麦1类别的分类混淆比较严重.图6(d)和图6(i)为WDBN算法和本文算法的分类结果,其分类性能相较其它算法大为提升,分类图像更加干净,空间连接度更优.

表3显示,本文算法的总分类准确率相较其它算

法分别高 12.95%、13.78%、13.30%、1.25%、6.14%、6.36%、11.24% 和 14.18%。WDBN 算法的分类准确率低于本文算法 1.25%。但需要注意的是,WDBN 算法使用

了 5% 的真实标记像素作为训练样本,而本文算法只使用了 1% 的真实标记像素。

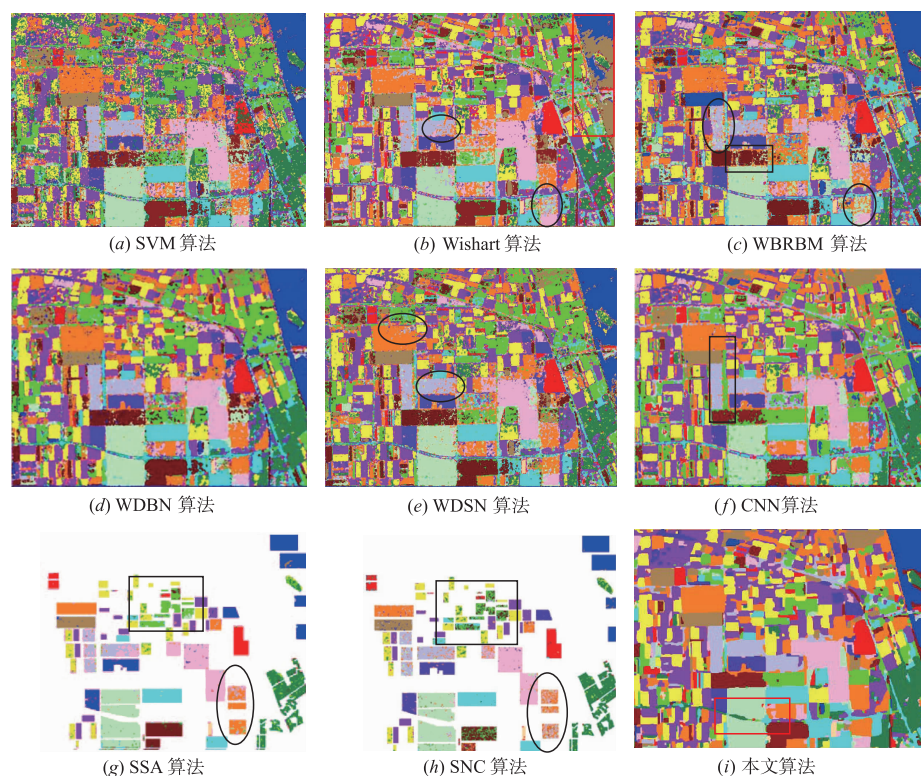


图6 Flevoland地区数据不同算法的分类结果

表3 不同算法在 Flevoland 地区图像上的分类准确率/%

对象/类别	海水	大麦	豌豆	干豆	甜菜	森林	裸地	草地
SVM	97.82	97.17	78.94	63.55	90.91	93.82	96.58	87.59
Wishart	51.75	95.26	96.28	95.08	95.13	87.91	99.20	72.46
WBRBM	99.71	98.16	96.46	91.30	94.44	89.71	0.14	36.97
WDBN	99.90	<b>99.49</b>	98.68	96.71	98.14	96.45	97.34	<b>95.39</b>
WDSN	98.88	97.05	96.81	96.00	96.22	90.85	99.26	90.13
CNN	98.88	96.90	88.89	92.58	89.74	93.95	99.94	79.20
SSA	92.63	96.23	93.01	94.14	94.17	86.44	96.19	65.25
SNC	96.79	64.45	91.83	92.35	96.66	90.44	92.11	50.54
本文算法	<b>100.00</b>	<b>99.68</b>	<b>99.12</b>	<b>99.07</b>	<b>99.76</b>	<b>98.81</b>	<b>100.00</b>	<b>90.72</b>
对象/类别	油菜籽	苜蓿	小麦1	小麦2	建筑物	土豆	小麦3	总 CA
SVM	81.28	96.04	90.79	81.15	0.43	53.97	95.48	85.87
Wishart	74.84	92.93	86.22	82.72	83.40	87.75	88.64	85.04
WBRBM	72.48	<b>98.49</b>	91.67	69.31	76.68	89.92	96.99	85.52
WDBN	95.90	98.47	<b>97.67</b>	<b>94.79</b>	<b>88.56</b>	98.08	98.55	97.57
WDSN	86.18	96.05	93.22	81.20	84.12	87.63	95.79	92.68
CNN	93.10	92.21	93.62	91.82	87.18	87.24	94.46	92.46
SSA	80.88	90.19	90.74	76.96	78.25	87.71	90.98	87.58
SNC	69.19	92.78	83.83	71.62	73.63	85.53	89.33	84.64
本文算法	<b>99.26</b>	<b>99.72</b>	<b>99.10</b>	<b>99.65</b>	<b>98.31</b>	<b>98.83</b>	<b>99.50</b>	<b>98.82</b>

## (2) San Francisco 地区数据的实验结果

图 7 和表 4 分别为 SVM 算法、Wishart 算法、本文算法和 CNN 算法对 San Francisco 地区数据的分类结果和分类准确率值. 这里没有比较用于 Flevoland 地区数据的其它几种算法, 因为对应的原文没有将其用于该数据.

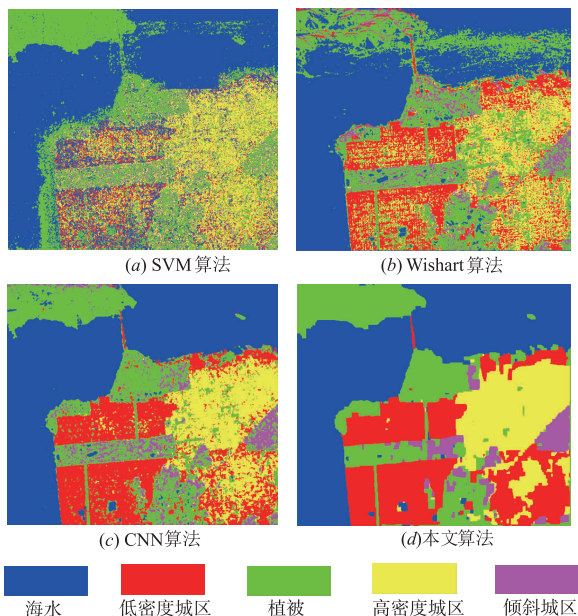


图 7 San Francisco 地区数据不同算法的分类结果

图 7(a) 显示, SVM 算法对低密度城区、高密度城区和倾斜城区分类混淆严重, 且图像右中部的倾斜城区无法被分辨出来. 图 7(b) 显示, Wishart 算法对低密度城区、高密度城区和植被类别分类混淆. 图 7(c) 和图 7(d) 为 CNN 算法和本文算法的分类结果. 两者在图像右下侧区域的分类差别巨大. CNN 算法将其分类为高密度城区, 而本文算法将其分类为低密度城区. 参考该地区光学图像及该区域的 SAR 图像<sup>[10]</sup> 可知, 该区域分类为低密度城区是更合理的. 表 4 显示, 本文算法的总分类准确率比其它算法分别高 46.79%、30.44% 和 7.31%.

表 4 不同算法在 Flevoland 地区图像上的分类准确率/%

对象/类别	海水	植被	高密度城区	低密度城区	倾斜城区	总分类准确率
SVM	86.74	58.67	25.61	60.44	13.67	51.08
Wishart	94.94	89.22	46.28	40.11	60.22	67.43
CNN	<b>100.00</b>	84.67	79.22	83.44	88.78	90.56
本文算法	<b>100.00</b>	<b>92.31</b>	<b>96.69</b>	<b>99.22</b>	<b>97.67</b>	<b>97.87</b>

### 3.4 算法参数分析

#### (1) 类标光滑性参数和迭代次数

$\alpha_p$  决定了类标光滑性约束的强度, 较大的  $\alpha_p$  意味着更光滑的分类结果. 优化迭代可提高分类准确率, 但

迭代次数越多, 消耗计算时间和资源越大, 且过多的迭代会导致细节的丢失.

图 8 为 5 个典型  $\alpha_p$  值执行 1 到 5 轮优化迭代后的分类结果. 结果显示, 较小的  $\alpha_p$  值 (取值 0.1) 总分类准确率值远差于较大的  $\alpha_p$  值, 并且收敛于一个较差的总分类准确率值. 随着  $\alpha_p$  变大 (取值 3), 算法对散斑噪声的抑制增强, 总分类准确率在第一轮显著提升. 分析发现, 经三轮迭代后能量函数即可达到收敛的状态, 后续迭代的提升可忽略不计. 因此, 选取  $\alpha_p \geq 3$ , 以迭代数 3 作为迭代的终止条件.




图 8 类标光滑性系数及迭代数目选取分析

为了确定  $\alpha_p$  取值, 图 9 给出了 Flevoland 地区数据不同  $\alpha_p$  值经三轮迭代后的类标图. 图 9(a) 为  $\alpha_p = 3$  的分类结果, 存在一些散斑块和孤立的像素点. 图 9(c) 为  $\alpha_p = 10$  的分类结果. 优化后整图更加平滑, 然而, 图像中有些细节被减弱甚至消失. 为在空间一致性和细节保持达到平衡, 在试验中选取  $\alpha_p = 5$ .




图 9 不同值  $\alpha_p$  在三轮迭代优化后的类标图

#### (2) 批尺寸

CNN 中的批尺寸决定能量函数的下降方向和网络的收敛性. 选择 5 个不同的批尺寸 (10、50、100、200 和 1000) 进行实验, 其总分类准确率如表 5 所示. 结果显示, 批尺寸为 100 时得到最高的分类准确率, 因此, 将批尺寸默认为 100.

#### (3) 网络深度

通过减增全连接层的数目测试网络深度对系统性能的影响. 表 6 为网络深度分别取 5、6、7 和 8 时的实验.

表 5 不同批尺寸下的分类准确率/%

批尺寸	10	50	100	200	1000
总分类准确率	94.47	97.08	<b>98.82</b>	96.98	95.91

表 6 不同网络深度下的分类准确率/%

网络深度	5	6	7	8
总分类准确率	97.56	<b>98.82</b>	96.59	95.72

结果显示,网络深度的增加并不会使结果一直变好,这是由深度神经网络中的梯度消失问题引起的.实验中,网络深度设置为 6 时,实验结果最优.因此,将网络深度默认设置为 6.

#### (4) 核尺寸

表 7 不同卷积核大小下的分类准确率/%

核大小	1	3	5	7
输入块大小	6	8	10	12
总分类准确率	97.32	<b>98.82</b>	97.08	96.33

为评估核尺寸对网络性能的影响,将第二个卷积层的核尺寸固定为 2,修改第一个卷积层的核尺寸.表 7 为不同核尺寸下的总分类准确率值.可以看出,核尺寸为 3 时,得到最高的分类准确率,因此,核尺寸默认设置为 3.

## 4 结论

本文提出一个基于卷积神经网络的半监督极化 SAR 图像分类模型.主要贡献是其将半监督算法、深度卷积神经网络和类标光滑性约束结合于统一的框架中.为此,设计一个能量函数,以 PauliRGB 超像素分割初始化分类结果作为起始,迭代优化该能量函数.在每个迭代中,首先执行 CNN 学习和预测,以提取数据驱动的极化特征表示,并为分类模型提供类标预测;然后,基于图模型执行类标传播.更新后的类标进一步对 CNN 进行调整.执行迭代优化算法直至能量函数收敛.将本文算法用于两幅真实极化 SAR 图像,实验仅使用 1% 的有标记像素作为输入.实验结果与比较表明,本文算法具有更高的分类准确率和更优的空间一致性.

### 参考文献

[1] KONG J A, SWARTZ A A, YUEH H A, et al. Identification of terrain cover using the optimum polarimetric classifier[J]. *Journal of Electromagnetic Waves & Applications*, 1988, 2(2): 171 - 194.

[2] LARDEUX C, FRISON P L, TISON C, et al. Support vector machine for multifrequency sar polarimetric data classification[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2009, 47(12): 4143 - 4152.

[3] YUAN Zhengwu, CHEN Ran, CHEN Cuiping, et al. Object-based classification method for PolSAR images with improved scattering powers and contextual features[J]. *Chinese Journal of Electronics*, 2017, 26(4): 803 - 809.

[4] Zhou Y, Wang H, Xu F, Jin Y Q. Polarimetric SAR image classification using deep convolutional neural networks[J]. *IEEE Geoscience & Remote Sensing Letters*, 2016, 13(12): 1935 - 1939.

[5] LIU F, JIAO L, HOU B, et al. POL-SAR image classification based on Wishart DBN and local spatial information[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2016, 54(6): 3292 - 3308.

[6] JIAO L, LIU F. Wishart deep stacking network for fast POLSAR image classification[J]. *IEEE Transactions on Image Processing*, 2016, 25(7): 3273 - 3286.

[7] 谈璐璐, 杨汝良, 商建. 利用 Shannon 熵参数的极化干涉 SAR 图像非监督分类[J]. *电子学报*, 2010, 38(10): 2264 - 2267.

TAN Lu-lu, YANG Ru-liang, SHANG Jian. Unsupervised PolInSAR image classification with Shannon entropy parameters[J]. *Acta Electronica Sinica*, 2010, 38(10): 2264 - 2267. (in Chinese)

[8] 曹芳, 洪文, 吴一戎. 基于 Cloude-Pottier 目标分解和聚合的层次聚类算法的全极化 SAR 数据的非监督分类算法研究[J]. *电子学报*, 2008, 36(3): 543 - 546.

CAO Fang, HONG Wen, WU Yi-rong. An unsupervised classification for fully polarimetric SAR data using Cloude-Pottier decomposition and agglomerative hierarchical clustering algorithm[J]. *Acta Electronica Sinica*, 2008, 36(3): 543 - 546. (in Chinese)

[9] LEE J S, GRUNES M R, AINSWORTH T L, et al. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 1999, 37(5): 2249 - 2258.

[10] DOULGERIS A P. An automatic U-distribution and Markov random field segmentation algorithm for PolSAR images[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2015, 53(4): 1819 - 1827.

[11] WU Y, JI K, YU W, et al. Region-based classification of polarimetric SAR images using Wishart MRF[J]. *IEEE Geoscience & Remote Sensing Letters*, 2008, 5(4): 668 - 672.

[12] CULP M, MICHAELIDIS G. Graph-based semisupervised learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2008, 30(1): 174 - 179.

[13] LIU H, WANG Y, YANG S, et al. Large polarimetric SAR data semi-supervised classification with spatial-anchor graph[J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2016, 9(4):

- 1439 – 1458.
- [14] LIU H, ZHU D, YANG S, et al. Semisupervised feature extraction with neighborhood constraints for polarimetric SAR classification[J]. IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing, 2016, 9 (7): 3001 – 3015.
- [15] BI H, SUN J, XU Z. Unsupervised PolSAR image classification using discriminative clustering[J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 55 (6): 3531 – 3544.
- [16] 宋婉莹, 李明, 张鹏, 等. 基于加权合成核与三重 Markov 场的极化 SAR 图像分类方法[J]. 电子学报, 2016, 44 (3): 520 – 526.  
SONG Wan-ying, LI Ming, ZHANG Peng, et al. A classification method of PolSAR image based on weighted composite kernel and triplet Markov field[J]. Acta Electronica Sinica, 2016, 44 (3): 520 – 526. (in Chinese)
- [17] TAPPEN M F, FREEMAN W T. Comparison of graph cuts with belief propagation for stereo, using identical MRF parameters[A]. Proceedings of IEEE International Conference on Computer Vision[C]. Nice: IEEE, 2003. 900 – 906.
- [18] ACHANTA R, SHAJI A, SMITH K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34 (11): 2274 – 2282.
- [19] LEE J S, GRUNES M R, GRANDI G D. Polarimetric SAR speckle filtering and its implication for classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 1999, 37 (5): 2363 – 2373.

#### 作者简介



**魏志强** 男, 1974 年 12 月出生, 安徽利辛人. 毕业于复旦大学获博士学位, 现为西安电子科技大学研究所研究员, 主要研究方向为雷达系统工程、太赫兹技术、SAR 图像处理.  
E-mail: zqwei@fudan.edu.cn



**毕海霞 (通信作者)** 女, 1982 年 11 月出生, 山东桓台人. 毕业于西安交通大学获博士学位, 主要研究方向为图像处理、机器学习、大数据和通信技术.  
E-mail: bhxwzq@163.com



**刘霞** 女, 1984 年 1 月出生, 陕西榆林人. 2015 年毕业于西安交通大学获博士学位, 现为西安理工大学讲师. 主要研究方向为机器学习、学习理论、非线性泛函分析.  
E-mail: liuxia1232007@163.com