

## 基于聚类识别的极化SAR图像分类

魏志强<sup>\*①</sup> 毕海霞<sup>②</sup>

<sup>①</sup>(西安电子工程研究所 西安 710100)

<sup>②</sup>(西安交通大学电子与信息工程学院 西安 710049)

**摘要:** 该文提出一种基于判别式聚类框架的非监督极化SAR图像分类算法, 利用判别式监督分类技术实现非监督聚类。为实现该算法, 定义了一个结合softmax回归模型和马尔科夫随机场光滑性约束的能量函数。该模型中, 像素类标和分类器均为需要优化的未知变量。该算法从基于 $H/\bar{\alpha}$ 目标极化分解和 $K$ -Wishart极化统计分布而产生的初始化类标开始, 交替迭代优化分类器和类标的能量函数, 从而实现对分类器和类标的求解。真实极化SAR数据上的实验结果证明了该算法的有效性和先进性。

**关键词:** 极化SAR图像分类; 判别式聚类; 马尔科夫随机场; softmax回归模型

中图分类号: TP75

文献标识码: A

文章编号: 1009-5896(2018)12-2795-09

DOI: 10.11999/JEIT180229

## PolSAR Image Classification Based on Discriminative Clustering

WEI Zhiqiang<sup>①</sup> BI Haixia<sup>②</sup>

<sup>①</sup>(Xi'an Electronic Engineering Research Institute, Xi'an 710100, China)

<sup>②</sup>(School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** This paper presents a novel unsupervised image classification method for Polarimetric Synthetic Aperture Radar (PolSAR) data. The proposed method is based on a discriminative clustering framework that explicitly relies on a discriminative supervised classification technique to perform unsupervised clustering. To implement this idea, an energy function is designed for unsupervised PolSAR image classification by combining a supervised Softmax Regression (SR) model with a Markov Random Field (MRF) smoothness constraint. In this model, both the pixelwise class labels and classifiers are taken as unknown variables to be optimized. Starting from the initialized class labels generated by Cloude-Pottier decomposition and  $K$ -Wishart distribution hypothesis, the classifiers and class labels are iteratively optimized by alternately minimizing the energy function with respect to them. Finally, the optimized class labels are taken as the classification result, and the classifiers for different classes are also derived as a side effect. This approach is applied to real PolSAR benchmark data. Extensive experiments justify that the proposed approach can effectively classify the PolSAR image in an unsupervised way and produce higher accuracies than the compared state-of-the-art methods.

**Key words:** Polarimetric Synthetic Aperture Radar (PolSAR) image classification; Discriminative clustering; Markov Random Field (MRF); Softmax Regression (SR) model

### 1 引言

极化SAR的成功应用与极化SAR图像解译技术的发展密切相关, 而图像分类是极化SAR图像解译过程中最重要的环节之一。从是否使用监督信息的角度区分, 极化SAR图像分类算法可分为监督极化SAR图像分类算法<sup>[1-6]</sup>和非监督极化SAR图像分类算法<sup>[7-13]</sup>。

监督极化SAR图像分类方法利用预先选定的有

标记训练集训练分类器, 然后将学习到的分类器应用于测试集上, 从而确定每个像素的类别归属。多种监督学习算法, 如贝叶斯分类算法<sup>[1]</sup>, 神经网络技术<sup>[2]</sup>, 支持向量机<sup>[3]</sup>和深度学习<sup>[4,5]</sup>等被应用于极化SAR图像分类中。监督极化SAR图像分类算法的性能总体上优于无监督极化SAR图像分类算法。然而, 监督分类算法的性能在很大程度上依赖于有标记训练集, 而其真实标记数据需要由专业的标记人员进行标记, 耗时耗力。另外, 在很多情况下, 训练集的选择需要人工参与, 训练集的一致性和完整性无法得到保证。这些因素使得监督分类算法不自

动、不可控。

无监督极化SAR图像分类算法旨在不利用任何标记信息的情况下,为数据进行类标分配。该类算法或基于不同的目标分解理论,如 $H/\alpha$ 分解<sup>[7]</sup>、Freeman分解<sup>[8]</sup>、四分量分解<sup>[9]</sup>和去取向理论<sup>[10]</sup>,或基于不同的极化SAR数据统计理论,如Wishart分布<sup>[7]</sup>和 $K$ -Wishart分布<sup>[11]</sup>。无监督极化SAR图像分类算法不依赖于标记数据,执行速度快,自动性强,并且其分类结果在物理上是可解释的。但是,其分类性能的提升对无监督算法的设计提出了很高的要求。因此,设计一种有效的无监督极化SAR图像分类算法仍然是一项非常具有挑战性的任务。

基于以上分析,本文提出一种新的无监督极化SAR图像分类算法。该算法基于判别式聚类框架,巧妙地利用判别式监督分类进行无监督聚类。为实现该思想,本文定义了一个能量函数,该函数结合了监督softmax回归模型和类标光滑性约束。在该模型中,像素类标和分类器均为需要优化的未知变量。模型的初始化类标基于 $H/\alpha$ 分解和 $K$ -Wishart极化统计分布而产生。模型优化由该初始化类标开始,迭代优化能量函数。在每轮迭代中,交替优化softmax分类器和类标的能量函数,从而更新分类器和类标。最终,优化得到的类标即为分类结果,同时也得到了针对不同类别的分类器。

## 2 算法及其优化

### 2.1 本文算法概述

对于一幅有 $N$ 个像素的极化SAR图像,每个像素的输入为相干矩阵 $\mathbf{T}$ ,可从中可提取得到一个高维的特征向量。该算法旨在为每个像素 $i(i \in \{1, 2, \dots, N\})$ 标注类别 $y_i(y_i \in \{1, 2, \dots, K\})$ ,其中, $K$ 为图像所包含的类别数。定义 $\mathbf{X} = \{x_i\}$ 和 $\mathbf{Y} = \{y_i\}$ 。

以AIRSAR Flevoland为例,图1给出了本文算法的概率图,该算法由3个步骤组成。

(1) 特征提取:通过在相干矩阵 $\mathbf{T}$ 上执行数学变换和目标极化分解提取特征向量 $\mathbf{X}$ ;

(2) 初始化:产生一个初始化类标图,用作下一步骤的输入;

(3) 判别式聚类:执行迭代优化算法对基于判别式聚类的模型进行优化,改善分类结果。

### 2.2 基于判别式聚类的模型

本文方法基于像素特征为极化SAR图像预测像素类标。基于判别式聚类思想<sup>[14,15]</sup>,本文定义了一个损失函数如式(1),通过最小化该损失函数得到类标 $\mathbf{Y}$ 和分类器 $\mathbf{W}$ 。




图1 基于判别式的PolSAR图像分类方法流程

$$E(\mathbf{Y}, \mathbf{W}|\mathbf{X}) = E_c(\mathbf{Y}, \mathbf{W}|\mathbf{X}) + E_s(\mathbf{Y}, \mathbf{W}|\mathbf{X}) \quad (1)$$

其中, $E_c(\mathbf{Y}, \mathbf{W}|\mathbf{X})$ 为判别式聚类项, $E_s(\mathbf{Y}, \mathbf{W}|\mathbf{X})$ 为类标光滑项。

(1) 判别式聚类项:判别式聚类项 $E_c(\mathbf{Y}, \mathbf{W}|\mathbf{X})$ 符合正则化的softmax损失函数定义,如式(2)所示。

$$E_c(\mathbf{Y}, \mathbf{W}|\mathbf{X}) = L(\mathbf{Y}, \mathbf{W}|\mathbf{X}) + R(\mathbf{W}) \quad (2)$$

其中, $L(\mathbf{Y}, \mathbf{W}|\mathbf{X})$ 为softmax损失函数, $R(\mathbf{W})$ 为正则化项。Softmax损失函数定义为交叉熵损失:

$$L(\mathbf{Y}, \mathbf{W}|\mathbf{X}) = -\frac{1}{N_j} \sum_{i=1}^N \sum_{j=1}^K \frac{N}{K} \text{sgn}\{y_i = j\} \cdot \lg \frac{\exp(\mathbf{W}_j^T x_i)}{\sum_{l=1}^K \exp(\mathbf{W}_l^T x_i)} \quad (3)$$

其中, $\mathbf{W} = [\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_K]^T$ , $\mathbf{W}_i$ 为第 $i$ 个类别的分类器参数向量, $\text{sgn}\{y_i = j\}$ 为符号函数, $y_i = j$ 时,其值为1,否则等于0。不同于经典的softmax损失函数,本算法在损失函数中增加了参数 $N_j$ ,定义为类标 $j$ 对应的像素数目。增加该参数的目的是减少由于不同类别的像素数量的差异而引起的样本失衡。Softmax损失函数测量分类器 $\mathbf{W}$ 的预测和目标类标之间的一致性。其中,分类器和目标类标均作为待学习的变量。

为了防止由数据噪声和异常值引起的可能的过拟合,在交叉熵损失后引入正则化项 $R(\mathbf{W})$ 。本文采用 $L_2$ 范数正则项,其定义如式(4):

$$R(\mathbf{W}) = \alpha_c \sum_{i=1}^K \sum_{j=1}^M \mathbf{W}_{ij}^2 \quad (4)$$

其中,  $\alpha_c$  为正则项参数,  $M$  是向量维数。在本文中,  $\alpha_c$  固定取  $5 \times 10^{-5}$ 。

(2) 类标光滑项: 类标光滑项  $E_s(\mathbf{Y}, \mathbf{W}|\mathbf{X})$  用于约束相邻像素间具有相似的类标。定义如式(5):

$$E_s = \alpha_s \sum_{i=1}^N \sum_{j \in N(i)} S_{ij} \quad (5)$$

其中,  $\alpha_s$  为类标光滑项因子,  $N(i)$  为像素  $i$  的邻域像素集。  $S_{ij}$  定义如式(6):

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

其中,  $v_i$  为像素  $i$  的特征向量, 一般选择为在图像边缘处急剧变化的特征。在本文中,  $v_i$  选择为 Pauli 矩阵成分的组合。  $\sigma$  为两个相邻像素  $i$  和像素  $j$  的特征间的平均均方距离。类标光滑项函数倾向于使得相邻像素具有相同的类标, 并促使类标边界与强边界对齐。如果相邻像素  $i$  和  $j$  处于一个平坦区域, 式(6)中指数项数值较大, 因此, 最小化  $S_{ij}$  则强烈地约束  $y_i$  和  $y_j$  取相同的值。但若相邻像素跨越强边界, 则指数项数值相对较小(甚至接近 0), 因此, 在优化过程中, 相邻像素  $i$  和  $j$  的类标差异是允许的。

(3) 最终的损失函数: 总结以上公式, 最终的综合损失函数定义如下:

$$E(\mathbf{Y}, \mathbf{W}|\mathbf{X}) = -\frac{1}{N_j} \sum_{i=1}^N \sum_{j=1}^K \frac{N}{K} \text{sgn}\{y_i = j\} \cdot \lg \frac{\exp(\mathbf{W}_j^T x_i)}{\sum_{l=1}^K \exp(\mathbf{W}_l^T x_i)} + \alpha_c \sum_{i=1}^N \sum_{j=1}^M \mathbf{W}_{ij}^2 + \alpha_s \sum_{i=1}^N \sum_{j \in N(i)} |y_i - y_j| \exp\left(-\frac{\|v_i - v_j\|_2^2}{2\sigma}\right) \quad (7)$$

其中, 分类器参数矩阵  $\mathbf{W}$  和类标  $\mathbf{Y}$  均为需要优化的变量。

尽管损失函数  $E(\mathbf{Y}, \mathbf{W}|\mathbf{X})$  遵循 softmax 回归模型的公式, 但它们实质上是不同的。在 softmax 分类算法中, 类标  $\mathbf{Y}$  为常量, 即训练集中的标注。而在判别式聚类算法中,  $\mathbf{Y}$  为需要优化的变量之一。本文方法通过判别式聚类的思想解决了非监督分类问题, 这恰好体现了判别式聚类算法的本质。

### 2.3 模型优化

通过最小化式(7)中的损失函数, 可得到分类器  $\mathbf{W}$  和类标  $\mathbf{Y}$ 。此优化问题可分解为两个子问题, 并通过迭代交替优化这两个子问题, 得到最终

的分类器  $\mathbf{W}$  和类标  $\mathbf{Y}$ 。作为优化算法的输入, 初始化类标  $\mathbf{Y}$  需预先产生。在每轮迭代中, 首先进行子问题1的求解, 基于当前的类标学习分类器; 然后, 进行子问题2的求解, 利用最新的分类器更新类标。

(1) 子问题1: 基于固定  $\mathbf{Y}$  求解  $\mathbf{W}$ : 子问题1的目的即基于当前类标估计  $\mathbf{Y}$  学习分类器  $\mathbf{W}$ 。类标估计  $\mathbf{Y}$  作为固定变量存在。在第  $t$  个迭代中, 对于  $t=1$  的情况, 当前类标估计  $\mathbf{Y}$  取值为初始化类标; 对于  $t>1$  的情况, 当前类标估计  $\mathbf{Y}$  取值为  $t-1$  轮迭代的类标估计。

在子问题1中, 由于类标估计  $\mathbf{Y}$  为常数, 式(7)中的损失函数可重写式(8):

$$E(\mathbf{W}|\mathbf{X}, \mathbf{Y}) = -\frac{1}{N_j} \sum_{i=1}^N \sum_{j=1}^K \frac{N}{K} \text{sgn}\{y_i = j\} \cdot \lg \frac{\exp(\mathbf{W}_j^T x_i)}{\sum_{l=1}^K \exp(\mathbf{W}_l^T x_i)} + \alpha_c \sum_{i=1}^N \sum_{j=1}^M \mathbf{W}_{ij}^2 \quad (8)$$

本文采用 L-BFGS<sup>[16]</sup> 迭代优化算法最小化上述 softmax 回归损失函数。

(2) 子问题2: 基于固定  $\mathbf{W}$  求解  $\mathbf{Y}$ : 子问题2旨在基于子问题1中更新得到的分类器  $\mathbf{W}$  预测像素类标  $\mathbf{Y}$ 。子问题2的求解过程中考虑了类标的光滑性约束。

由于分类器  $\mathbf{W}$  为常量, 公式(7)中的损失函数可重写为式(9):

$$E(\mathbf{Y}, \mathbf{W}|\mathbf{X}) = -\frac{1}{N_j} \sum_{i=1}^N \sum_{j=1}^K \frac{N}{K} \text{sgn}\{y_i = j\} \cdot \lg \frac{\exp(\mathbf{W}_j^T x_i)}{\sum_{l=1}^K \exp(\mathbf{W}_l^T x_i)} + \alpha_s \sum_{i=1}^N \sum_{j \in N(i)} |y_i - y_j| \exp\left(-\frac{\|v_i - v_j\|_2^2}{2\sigma}\right) \quad (9)$$

此类标分配问题在本质上是一个组合优化问题。在图像上建立无向图  $G = \langle v, \varepsilon \rangle$ , 其中,  $v$  为图像顶点集, 对应像素点;  $\varepsilon$  为无向边集, 对应像素间的邻居关系。定义类标变量  $y_i$  为每个顶点上的随机变量。则图上的类标  $\mathbf{Y}$  就构成了一个马尔科夫随机场(MRF),  $E(\mathbf{Y}, \mathbf{W}|\mathbf{X})$  为其上的能量函数。能量函数的第1项反映了一个像素被分配到不同类标的损失函数。一个像素属于某类别的概率越大, 该像素被分配为对应类别的可能性就越大。第2项约

束了相邻像素间的类标一致性。MRF标记问题为非确定性的NP-困难问题。本文采用了置信传播算法求解该问题。

(3) 更新 $N_j (j = 1, 2, \dots, K)$ : 子问题2对图像类标进行更新后, 每个类别的像素数目 $N_j$ 发生了改变。不同类别的像素数应相应更新, 并作为下一轮迭代的输入。

## 2.4 初始化

给定极化SAR图像逐个像素相干矩阵 $\mathbf{T}$ 后, 通过执行初始化步骤可产生初始类标估计, 作为后续迭代优化过程的输入。该初始化步骤基于 $H/\bar{\alpha}$ 目标分解理论<sup>[7]</sup>和 $K$ -Wishart极化统计分布<sup>[11]</sup>。首先, 运行 $H/\bar{\alpha}$ 目标极化分解产生图像像素类标的初始分割。然后, 执行基于 $K$ -Wishart极化统计分布的迭代最大似然分类, 对分类面进行更新。

其初始聚类中心设置为由 $H/\bar{\alpha}$ 目标极化分解产生的初始分割的聚类均值。然后, 计算每个像素到所有聚类均值的 $K$ -Wishart距离, 并将其分配到具有最小 $K$ -Wishart距离的聚类中。这样, 就得到了新的聚类中心。重复以上流程直至收敛。如果实际的地物类型数目小于8, 则需根据聚类中心间的 $K$ -Wishart距离进行合并流程。优先合并两个类间距离较小的类, 直至类标数目达到期望值。如果期望类别数目 $K$ 大于8, 则需对 $H - \bar{\alpha}$ 子空间进行更加精细的初始划分。在8个初始子空间的每一个子空间中均衡地增加 $n$ 条横线和 $n$ 条竖线, 将其划分为 $n^2$ 个区域,  $n$ 定义为离 $K/8$ 的平方根最近的向上取整的整数。基于该精细初始划分进行 $K$ -Wishart聚类迭代直至达到期望的类别数目。

## 3 极化特征

极化特征一般可分为两类。第1类为原始极化矩阵及其直接数学变换。第2类为从经典目标分解算法中所提取得到的特征。本文所使用的原始极化矩阵包括散射矩阵 $\mathbf{S}$ 、相干矩阵 $\mathbf{T}$ 和协方差矩阵

$\mathbf{C}$ , 所采用的极化目标分解方法包括Pauli分解、 $H/\bar{\alpha}$ 分解和Freeman分解。如表1所示, 本文共提取了58维特征。

(1) 3种不同极化方式下, 相干矩阵的强度和相位: (a) 水平和垂直线极化; (b)  $+45^\circ/-45^\circ$ 线极化; (c) 左右旋圆极化。

(2) 水平和垂直线极化,  $+45^\circ/-45^\circ$ 线极化和左右旋圆极化方式下, 不同极化通道的强度比。 $I_{pq}$ 代表 $p-q$ 极化方式下强度, 其中 $p$ 和 $q$ 属于下标集 $\{h, v, l, r, m, n\}$ , 分别代表水平线极化、垂直线极化、左旋圆极化、右旋圆极化、 $+45^\circ$ 线极化和 $-45^\circ$ 线极化。

(3) SPAN定义为:  $\text{SPAN} = I_{hh} + 2I_{hv} + I_{vv}$ 。SPAN代表了极化总功率, 是一个重要的极化SAR特征。

(4) 基于水平和垂直线极化,  $+45^\circ/-45^\circ$ 线极化和左右旋圆极化方式下的9个Pauli目标分解参数。对每种极化方式, 共有3个Pauli分解通道, 分别代表了奇次面散射, 偶次面散射和 $45^\circ$ 倾斜的2次散射。

(5) 参数 $p_s, p_d, p_v$ 和 $\alpha_L$ 为Freeman分解参数。其中 $p_s, p_d$ 和 $p_v$ 分别代表了面散射, 2次散射和体散射的能量,  $\alpha_L$ 为形状参数。

(6) 通过 $H/\bar{\alpha}$ 分解提取得到的8个参数, 其中 $H$ 代表目标的随机程度;  $\bar{\alpha}$ 代表目标的平均散射体制;  $A$ 为各向异性度;  $\beta$ 为目标取向角。其他4个参数为 $H$ 和 $A$ 的数学组合。

以上特征中, (1)~(3)中的特征属于第1类, 即极化矩阵及其数学变换; (4)~(6)中的特征属于第2类, 即目标分解特征。

## 4 实验

### 4.1 实验数据及设置

如图2所示, 本文采用两幅真实极化SAR图像进行实验。第1幅图像为荷兰Flevoland地区的C波

表1 本文算法所使用的特征

| 极化特征分类     | 标识                                                                                                                                                                                                              | 物理描述                                               |
|------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------|
| 极化矩阵及其数学变换 | $\mathbf{T}_{ij}(i, j = 1, 2, 3, i \leq j)$                                                                                                                                                                     | 水平垂直线极化方式下的相干矩阵元素(模值与幅角)                           |
|            | $\text{Lin}45 \mathbf{T}_{ij}(i, j = 1, 2, 3, i \leq j)$                                                                                                                                                        | $+45^\circ/-45^\circ$ 线极化方式下的相干矩阵元素(模值与幅角)         |
|            | $\text{Cir}45 \mathbf{T}_{ij}(i, j = 1, 2, 3, i \leq j)$                                                                                                                                                        | 左右旋圆极化方式下的相干矩阵元素(模值与幅角)                            |
|            | $\frac{I_{hv}}{I_{hh}}, \frac{I_{lv}}{I_{vv}}, \frac{I_{lh}}{I_{vv}}, \frac{I_{lr}}{I_{lr}}, \frac{I_{ll}}{I_{lr}}, \frac{I_{ll}}{I_{lr}}, \frac{I_{mm}}{I_{mm}}, \frac{I_{mm}}{I_{mm}}, \frac{I_{mm}}{I_{mm}}$ | 水平垂直线极化, $+45^\circ/-45^\circ$ 线极化以及左右旋圆极化方式下的强度比值 |
| 目标分解特征     | SPAN                                                                                                                                                                                                            | 极化总功率                                              |
|            | Pauli矩阵分解                                                                                                                                                                                                       | Pauli分解参数                                          |
|            | $P_s, P_d, P_v, \alpha_L$                                                                                                                                                                                       | Freeman分解参数                                        |
|            | $\bar{\alpha}, H, A, \beta, (1-H)(1-A), (1-H)A, H(1-A), HA$                                                                                                                                                     | $H/\bar{\alpha}$ 分解参数                              |

段全极化数据,由NASA/JPL的AIRSAR于1989年8月16日获取,如图2(a)所示。该图像大小为 $300 \times 270$ ,其在斜距方向的分辨率为6.6 m,在水平方向的分辨率为12.1 m。其真实类标及色码分别如图3(a)所示。此极化SAR图像共有7类地表,包括空地、大麦、苜蓿、豌豆、土豆、甜菜和小麦。第2幅图像为德国Oberpfaffenhofen地区E-SAR的L波段全极化数据,如图2(b)所示。该图像大小为 $800 \times 700$ ,分辨率为2 m。其真实类标和色码如图3(b)所示。该图像共有4类地表,分别为:森林,郊区,道路和开阔地。

本文实验部分首先进行参数分析,然后通过与已有算法进行比较验证本文算法的有效性。这些算法包括:Wishart MRF算法<sup>[17]</sup>,  $H/\bar{\alpha}$ -Wishart算法<sup>[18]</sup>,功率熵和同极化率方法<sup>[19]</sup>,Wishart TMF方法<sup>[20]</sup>和Freeman Wishart算法<sup>[21]</sup>。


#### 4.2 参数分析

在本文算法中, $\alpha_s$ 及迭代次数会影响最终的分类结果。 $\alpha_s$ 决定了类标平滑性约束的强度。较大的 $\alpha_s$ 值意味着类标平滑项在优化过程中发挥了更重要的作用,从而倾向于产生更光滑的分类结果。判别

式聚类算法中的迭代次数也会对预测准确率产生影响。并且,参数 $\alpha_s$ 和迭代数目是互相影响的。因此,本文将综合分析这两个参数对分类结果的影响。

选取了5个典型的 $\alpha_s$ 值(0.1, 0.2, 0.5, 1和2),对分别执行1~5次判别式聚类迭代的实验结果进行分析。图4分别给出了Flevoland地区和Oberpfaffenhofen地区在不同 $\alpha_s$ 和迭代数下的总分类准确率。迭代次数0的总分类准确率对应初始化类标。从图4可以看出,在第1轮迭代后,总分类准确率显著提高。当 $\alpha_s$ 取较大值(例如:1.0),迭代次数取2或3时,可得到稳定且较高的总分类准确率。然而,随着迭代次数的持续增加,总分类准确率提高减缓,甚至略有降低。这是因为,对于小的 $\alpha_s$ 值(比如0.1),其类标平滑效果相对较弱,无法校正由于散斑效应引起的像素误分类;而对于大的 $\alpha_s$ 值(比如2.0),多轮强的MRF优化会使得那些小且窄的区域由于连续的类标光滑操作而逐渐消失。

综合考虑分类准确率以及迭代间的稳定性, $\alpha_s$ 取1.0和2.0之间的值,迭代数目取2或3是比较合理的。本文中后续对两幅真实极化SAR图像进行实验时, $\alpha_s$ 取为1.0,迭代次数取3。




(a) Flevoland 地区




(b) Oberpfaffenhofen 地区

图2 本文所使用的两幅原始极化SAR图像



(a) Flevoland 地区的真实地物标注



(b) Oberpfaffenhofen 地区的真实地物标注

图3 两幅极化SAR图像的真实地物标注

### 4.3 与其他算法比较

**4.3.1 Flevoland地区数据实验结果** 图5给出了Flevoland地区采用本文算法和其他5种算法的分类结果。表2给出了这6种算法的分类准确率。从图5(a)  $H/\bar{\alpha}$ -Wishart分类器的结果中可以观测出,许多像素被误分类了。比如,许多小麦类别的像素被分类为苜蓿(见图5(a)白色长方形所标识)。并且,不同类间的边界非常模糊,不清晰。Wishart MRF算法在分类阶段采用了MRF优化算法,将空间连接性考虑在内。与图5(a)相较,图5(b)中误分类的像素减少了,像素的空间连接性更强,边界更加清晰了。Freeman Wishart分类器以及功率熵共极化率分类器的分类结果中有分类混淆的现象。从

图5(c)和图5(d)可以看出,两幅图像右下侧区域的分类结果被严重污染了。类别为甜菜的像素被误分类为苜蓿。并且,两幅图像中散布着误分类散斑噪声。相较于图5(a)—5(d),图5(e)所示的Wishart TMF分类结果的视觉效果更好。然而,在结果中仍然存在一些孤立的像素块,尤其是在图像的右下侧部分。

本文方法利用监督softmax回归和丰富的特征进行非监督分类,因此,在初始化类标图中很多被误分类的像素在迭代优化过程中被逐渐校正。本文方法中所引入的由MRF模型建模的光滑项约束使得分类结果更加光滑。因此,与其他5种算法相较,本文算法得到了更好的分类性能,误分类率




图4 光滑系数和迭代次数对分类结果的影响




图5 使用不同方法对Flevoland地区分类结果

低，且视觉效果更好。本文方法的总分类准确率比其他方法分别提高了 13.46%，7.23%，8.89%，10.75%和3.19%。

**4.3.2 Oberpfaffenhofen地区数据实验结果** 图6给出了本文方法和其他3种算法( $H/\bar{\alpha}$  - Wishart分类器, Wishart MRF分类器和Freeman Wishart分类器)在Oberpfaffenhofen地区数据的分类结果。表3列出了这些方法的分类准确率结果。由于原文献<sup>[17]</sup>和文献<sup>[18]</sup>没有在该数据上进行实验，因此，无法对功率熵和共极化率和Wishart TMF两种算法进行比较。

图6(a)给出的是 $H/\bar{\alpha}$  - Wishart算法的分类结果。从图中可以看出，图像中存在大量误分类像素点。比如，在黑色长方形标注的区域，许多森林类别的像素被误分类为郊区和道路。在玫红色长方形标注的区域内部，许多开阔地类别的像素点被分类为道路类别。这是由于 $H/\bar{\alpha}$  - Wishart分类器基于 $H/\bar{\alpha}$ 分解及Wishart分布进行无监督聚类。森林和郊区，以及开阔地和道路在随机性和散射体制上比

较接近，且Wishart分布只适用于匀质区域的图像分类，无法很好地建模非匀质区域的情况。因此，对于相近散射机制的地物无法正确区分。并且，图像下侧的道路变得不可见了。除此以外，整个图像布满了散斑点，视觉效果很差。从图6(b)可以看出，Wishart MRF算法大大改善了图6(a)中的散斑问题，并且在图像右上区域的道路变得更加光滑和清晰。但是，误分类问题仍然比较严重。Freeman Wishart算法的分类结果如图6(c)所示。由于道路和开阔地的散射机制比较接近，这两类的像素在很大程度上被混淆了，并且整个图像中道路类别的像素基本上看不到。对于郊区区域，只有部分具有最强偶次散射功率的区域被分类为郊区类别，其他一些像素被误分类为森林类别。本文方法的分类结果如图6(d)所示。与其他3种算法的结果相比，由于本文算法采用了判别式聚类算法及MRF优化，其误分类率更低，分类结果更加光滑。本文算法的总分类准确率比其他方法分别高17.82%，14.99%和8.90%。

表 2 不同方法在Flevoland地区数据上的分类准确率(%)

| 方法/类别                      | 空地            | 大麦            | 苜蓿           | 豌豆           | 土豆           | 甜菜           | 小麦           | 总分类准确率 |
|----------------------------|---------------|---------------|--------------|--------------|--------------|--------------|--------------|--------|
| $H/\bar{\alpha}$ - Wishart | 99.94         | 86.60         | 84.63        | 88.50        | 81.44        | 84.00        | 82.48        | 85.59  |
| Wishart MRF                | <b>100.00</b> | 86.21         | 93.27        | 94.24        | 85.55        | 89.54        | 92.55        | 91.82  |
| Freeman Wishart            | 98.26         | 87.97         | 83.38        | 93.22        | 98.13        | 92.20        | 84.53        | 90.16  |
| 功率熵和共极化率                   | 99.44         | 89.85         | 75.22        | 85.92        | 85.79        | 91.01        | 87.89        | 88.30  |
| Wishart TMF                | 99.81         | 97.60         | 86.10        | <b>98.27</b> | 90.00        | 95.86        | 97.33        | 95.86  |
| 本文算法                       | <b>100.00</b> | <b>100.00</b> | <b>95.07</b> | 98.21        | <b>98.57</b> | <b>98.63</b> | <b>99.93</b> | 99.05  |




图 6 使用不同方法对Oberpfaffenhofen地区的分类结果

表 3 本文方法在Oberpfaffenhofen地区数据上的分类准确率(%)

| 对象/类别                      | 森林           | 道路           | 郊区           | 开阔地          | 总分类准确率       |
|----------------------------|--------------|--------------|--------------|--------------|--------------|
| $H/\bar{\alpha}$ - Wishart | 65.21        | 41.80        | 51.51        | 76.01        | 64.43        |
| Wishart MRF                | 74.43        | 55.52        | 42.28        | 72.93        | 67.26        |
| Freeman Wishart            | <b>97.71</b> | 18.13        | 16.80        | <b>87.85</b> | 73.35        |
| 本文算法                       | 93.65        | <b>64.70</b> | <b>60.78</b> | 84.41        | <b>82.25</b> |

## 5 结束语

本文提出了一种基于判别式聚类的非监督分类方法,利用了监督学习技术完成非监督聚类,并在能量函数模型中综合考虑了空间上下文信息。本算法以基于 $H/\alpha$ 极化目标分解理论和 $K$ -Wishart极化统计分布生成分类结果作为初始化输入,通过求解softmax回归问题和MRF组合优化问题,迭代交替更新分类器和像素类标,直至满足迭代终止条件。两幅真实极化SAR图像上的实验证明,与其他几种已有算法相比,本文算法可获得更高的分类准确率和更好的空间一致性。特征提取和优化是极化SAR图像分类中非常重要的研究课题,它对分类准确率、时间复杂度和内存消耗均存在非常重要的影响。本文没有聚焦于特征设计。但受到深度学习模型的学习能力的启发,我们计划在将来的研究工作中基于深度学习技术学习更加有效的极化特征。

## 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 and Applications*, 1988, 2(2): 171–194.
- [2] POTTIER E and SAILLARD J. On radar polarization target decomposition theorems with application to target classification by using network method[C]. Proceedings of the International Conference on Antennas and Propagation, York, UK, 1991, 1: 265–268.
- [3] FUKUDA S and HIROSAWA H. Support vector machine classification of land cover: Application to polarimetric SAR data[C]. Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium, Sydney, NSW, Australia, 2001, 1: 187–189. doi: [10.1109/IGARSS.2001.976097](https://doi.org/10.1109/IGARSS.2001.976097).
- [4] JIAO Licheng and LIU Fang. Wishart deep stacking network for fast PolSAR image classification[J]. *IEEE Transactions on Image Processing*, 2016, 25(7): 3273–3286. doi: [10.1109/TIP.2016.2567069](https://doi.org/10.1109/TIP.2016.2567069).
- [5] ZHOU Yu, WANG Haipeng, XU Feng, *et al.* Polarimetric SAR image classification using deep convolutional neural networks[J]. *IEEE Geoscience Remote Sensing Letters*, 2017, 13(12): 1935–1939. doi: [10.1109/LGRS.2016.2618840](https://doi.org/10.1109/LGRS.2016.2618840).
- [6] GAO Wei, YANG Jian, and MA Wenting. Land cover classification for polarimetric SAR images based on mixture models[J]. *Remote Sensing*, 2014, 6(5): 3770–3790. doi: [10.3390/rs6053770](https://doi.org/10.3390/rs6053770).
- [7] CLOUDE S R and POTTIER E. An entropy based classification scheme for land application of polarimetric SAR[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1997, 35(1): 68–78. doi: [10.1109/36.551935](https://doi.org/10.1109/36.551935).
- [8] FREEMAN A and DURDEN S L. A three-component scattering model for polarimetric SAR data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1998, 36(3): 963–973. doi: [10.1109/36.673687](https://doi.org/10.1109/36.673687).
- [9] YAMAGUCHI Y, MORIYAMA T, ISHIDO M, *et al.* Four-component scattering model for polarimetric SAR image decomposition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(8): 1699–1706. doi: [10.1109/TGRS.2005.852084](https://doi.org/10.1109/TGRS.2005.852084).
- [10] XU Feng and JIN Yaqiu. Deorientation theory of polarimetric scattering targets and application to terrain surface classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(10): 2351–2364. doi: [10.1109/TGRS.2005.855064](https://doi.org/10.1109/TGRS.2005.855064).
- [11] DOULEGERIS A P, ANFINSEN S N, and ELROFT T. Classification with a non-Gaussian model for PolSAR data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(10): 2999–3009. doi: [10.1109/TGRS.2008.923025](https://doi.org/10.1109/TGRS.2008.923025).
- [12] 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[J]. 雷达学报, 2017, 6(2): 136–148. doi: [10.12000/JR16130](https://doi.org/10.12000/JR16130).  
XU Feng, WANG Haipeng and JIN Yaqiu. Deep Learning as Applied in SAR Target Recognition and Terrain Classification[J]. *Journal of Radars*, 2017, 6(2): 136–148. doi: [10.12000/JR16130](https://doi.org/10.12000/JR16130).
- [13] 钟能, 杨文, 杨祥立, 等. 基于混合Wishart模型的极化SAR图像非监督分类[J]. 雷达学报, 2017, 6(2): 136–148. doi: [10.12000/JR16133](https://doi.org/10.12000/JR16133).  
ZHONG Neng, YANG Wen, YANG Xiangli, *et al.* Unsupervised Classification for Polarimetric Synthetic Aperture Radar Images Based on Wishart Mixture Models[J]. *Journal of Radars*, 2017, 6(2): 136–148. doi: [10.12000/JR16133](https://doi.org/10.12000/JR16133).
- [14] BACH F and HARCHAOU Z. DIFFRAC: A discriminative and flexible framework for clustering[C]. Proceedings of Conference and Workshop on Neural Information Processing Systems, Vancouver, British Columbia, Canada, 2007: 49–56.
- [15] SUN Jian and PONECE J. Learning discriminative part detectors for image classification and cosegmentation[C]. Proceedings of IEEE International Conference on Computer Vision, Sydney, NSW, Australia, 2013: 3400–3407.
- [16] ZHU Ciyou, BYRD R H, LU Peihuang, *et al.* L-BFGS-B: Fortran subroutines for large-scale bound-constrained optimization[J]. *ACM Transaction Mathematical Software*, 1997, 23(4): 550–560. doi: [10.1145/279232.279236](https://doi.org/10.1145/279232.279236).
- [17] WU Yonghui, JI Kefeng, YU Wenxian, *et al.* Region-based classification of polarimetric SAR images using Wishart

- MRF[J]. *IEEE Geoscience and Remote Sensing Letters*, 2008, 5(4): 668–672. doi: [10.1109/LGRS.2008.2002263](https://doi.org/10.1109/LGRS.2008.2002263).
- [18] 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 and Remote Sensing*, 1999, 37(5): 2249–2258. doi: [10.1109/36.789621](https://doi.org/10.1109/36.789621).
- [19] WANG Shuang, LIU Kun, PEI Jingjing, *et al.* Unsupervised classification of fully polarimetric SAR images based on scattering power entropy and copolarized ratio[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, 10(3): 622–626. doi: [10.1109/LGRS.2012.2216249](https://doi.org/10.1109/LGRS.2012.2216249).
- [20] LIU Gaofeng, LI Ming, WU Yan, *et al.* PolSAR image classification based on Wishart TMF with specific auxiliary field[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(7): 1230–1234. doi: [10.1109/LGRS.2013.2290066](https://doi.org/10.1109/LGRS.2013.2290066).
- [21] LEE J S, GRUNES M R, POTTIER E, *et al.* Unsupervised terrain classification preserving polarimetric scattering characteristics[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(4): 722–731. doi: [10.1109/TGRS.2003.819883](https://doi.org/10.1109/TGRS.2003.819883).
- 魏志强：男，1974年生，博士，研究员，研究方向为雷达系统工程、图像处理和太赫兹技术。
- 毕海霞：女，1982年生，博士，高级工程师，研究方向为机器学习、遥感图像处理、大数据处理和通信技术。