

基于加权合成核与三重 Markov 场的极化 SAR 图像分类方法

宋婉莹, 李明, 张鹏, 吴艳, 贾璐, 刘高峰

(西安电子科技大学雷达信号处理国家重点实验室, 陕西西安 710071)

摘要: 马尔可夫随机场(Markov Random Field, MRF)广泛用于处理遥感图像的分类问题,然而 MRF 在构建极化合成孔径雷达(Synthetic Aperture Radar, SAR)图像模型时未考虑其非平稳特性且对初始分类较为敏感,为此本文提出了一种基于加权合成核与三重马尔可夫随机场(Triplet Markov Field, TMF)的极化 SAR 图像分类方法.该方法依据训练样本在特征空间上的距离,提出了加权合成核函数权重系数的自适应确定方法以提高初始分类的精度和普适性;为充分考虑极化 SAR 图像的非平稳统计特性,利用 TMF 对极化 SAR 图像进行统计建模以实现贝叶斯分类.实验结果表明,与基于 MRF 的极化 SAR 图像分类方法相比,本文所提方法可获得更高的分类精度和更平滑的同质区域分类结果,而且本文方法能更好地保持图像边缘信息.

关键词: 极化合成孔径雷达; 图像分类; 加权合成核; 三重马尔可夫随机场; 支持向量机

中图分类号: TN957.52 **文献标识码:** A **文章编号:** 0372-2112 (2016)03-0520-07

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

DOI: 10.3969/j.issn.0372-2112.2016.03.004

A Classification Method of PolSAR Image Based on Weighted Composite Kernel and Triplet Markov Field

SONG Wan-ying, LI Ming, ZHANG Peng, WU Yan, JIA Lu, LIU Gao-feng

(National Laboratory of Radar Signal Processing, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract: Markov random field (MRF) is widely applied to remote sensing images classification. However, the MRF-based classification method does not take the nonstationarity properties of images into account when it models polarimetric synthetic aperture radar (PolSAR) images, and is sensitive to the initial classification. Therefore, this paper proposes a classification method of PolSAR image based on the weighted composite kernel and the triplet Markov field (TMF). Based on the distances between the features of training samples, we compute the kernel weights of the weighted composite kernel for improving the accuracy and popularity of the initial classification. Then, taking the nonstationarity properties of PolSAR images into consideration, the TMF is introduced to model the statistics of real PolSAR images to realize the Bayesian classification. Experiments indicate that the proposed method can obtain higher classification accuracy and smoother homogeneous areas than the MRF-based PolSAR image classification method. Moreover, the proposed method can get more accurate edge location.

Key words: polarimetric synthetic aperture radar (PolSAR); image classification; weight composite kernel; Triplet Markov Field (TMF); support vector machine (SVM).

1 引言

图像分类是极化合成孔径雷达(Synthetic Aperture Radar, SAR)图像解译的重要内容之一,已广泛用于民用领域和军事领域^[1,2],比如,在地表覆盖测绘方面,可利用极化 SAR 图像分类研究城市发展变迁,农作物生

长状况和分布情况,地质分布和矿产分布情况等.在海洋研究和地球变化研究方面也有重要的应用.而极化 SAR 图像分类方法^[3-5]一直是该领域前沿研究的热点,其中利用马尔可夫随机场(Markov Random Field, MRF)^[6]实现极化 SAR 图像分类是重要的技术手段之

收稿日期:2014-07-15;修回日期:2015-02-10;责任编辑:覃怀银

基金项目:国家自然科学基金(No. 61271297, No. 61272281, No. 61301284);博士学科点科研专项基金(No. 20110203110001);国家部委预研基金(No. 9140A07020913DZ01001, No. 9140C010205140C01004)

一,该类方法^[7-9]通过贝叶斯理论与 MRF 构建关于分类的后验概率,依据最大后验概率(Maximum A Posterior, MAP)准则^[6]实现分类.基于 MRF 的极化 SAR 图像分类方法主要包含两个步骤:初始分类与 MAP 分类,其中 MAP 分类依赖于初始分类,初始分类精度越高,MAP 分类精度也相应地越高^[6],目前初始分类主要通过 Wishart 分类^[8]与支持向量机(Support Vector Machine, SVM)实现^[9].为了提高基于 MRF 的极化 SAR 图像分类方法的性能,有必要同时提高初始分类与 MAP 分类的精度.

为了提高初始分类精度,本文引入了加权合成核^[10].加权合成核是单个特征核函数的加权和,其中核函数权重系数一般是由经验选定的,使算法缺乏普适性,本文通过训练样本在特征空间上的距离提出了核函数权重系数的自适应确定方法,所构建的加权合成核能提高初始分类精度,且提高了算法普适性.三重 Markov 场(Triplet Markov Field, TMF)^[11,12]是一种最近提出的随机场理论,是 MRF 的推广.文献[16]指出,极化 SAR 图像在空间纹理结构中的差异和极化散射机制上的差异都会使同一目标极化数据的统计分布存在差异,这种差异可以由极化数据的非平稳特性描述.文献[11]研究表明,TMF 相比于 MRF 能更准确地描述真实的图像,利用 TMF 构建的极化数据统计分布精度更高,MAP 分类也能获得更好的分类结果.因此,本文将 TMF 引入到极化 SAR 图像分类中,以提高极化 SAR 图像的 MAP 分类精度.

2 利用加权合成核的初始分类

核函数^[13]是模式识别领域中实现分类的一种有效

表 1 极化 SAR 图像特征

序号	极化散射特征	备注
1-3	P_v, P_d, P_s	P_v, P_d, P_s 分别为由极化目标分解 ^[14,15] 得到的体散射功率、二面角散射功率、面散射功率
4-9	$T_{11}, T_{12} , T_{13} , T_{22}, T_{23} , T_{33}$	T_{ij} 是相干矩阵 $T^{[1]}$ 的第 i 行第 j 列的元素
10-13	$\lambda_1, \lambda_2, \lambda_3, \text{SPAN}$	$\lambda_k, k=1, 2, 3$ 是协方差矩阵 $C^{[1]}$ 的特征值, SPAN 为 C 对角线元素和(总功率)
14-16	H, α, A	H, α, A 为 Cloude 分解 ^[1] 的极化散射特征,其中 H 为散射熵, α 为平均散射角, A 为反熵

设极化 SAR 图像的地物类别集合 $\Omega = \{1, 2, \dots, M\}$, M 为地物类别的个数.本文采用“一对一分类策略”^[13]与“多数投票原则”^[13]实现 M 个地物类别的 SVM 分类.设 $l, m \in \Omega$, 针对 l, m 两个地物类别的 SVM 分类,当核函数 $K^i(x_i, y_i)$ ($\forall i=1, 2, \dots, N$) 用高斯径向基核表示时,相应的加权合成核可表示为:

$$\begin{aligned} K_{lm}^c(\mathbf{x}, \mathbf{y}) &= \sum_{i=1}^N \mu_{lm}^i K^i(x_i, y_i) \\ &= \sum_{i=1}^N \mu_{lm}^i \exp(-|x_i - y_i|^2 / \delta) \end{aligned} \quad (3)$$

工具,它被用于计算 SVM 中高维特征空间内积,能避免特征空间从低维到高维的复杂转换,解决维数灾难等问题,且区分地物类别能力强的核函数有助于提高 SVM 的分类精度^[9,10].常用核函数包括:线性核、多项式核、高斯径向基核等,其中最广泛使用的是高斯径向基核,它的定义式为:

$$K^i(\mathbf{x}, \mathbf{y}) = \exp(-\|\mathbf{x} - \mathbf{y}\|^2 / \delta) \quad (1)$$

其中, \mathbf{x}, \mathbf{y} 分别表示两个样本的多维特征向量, δ 是高斯径向基核参数.

加权合成核^[10]是由单个特征的核函数的加权和构成的,如式(2)所示:

$$K^c(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^N \mu^i K^i(x_i, y_i) \quad (2)$$

其中, $\mathbf{x} = (x_1, x_2, \dots, x_N)^T$, $\mathbf{y} = (y_1, y_2, \dots, y_N)^T$, x_i, y_i 分别表示 \mathbf{x}, \mathbf{y} 的第 i 个特征, $K^i(x_i, y_i)$ 为第 i 个特征的核函数, μ^i 为 $K^i(x_i, y_i)$ 的权重系数, N 为 \mathbf{x}, \mathbf{y} 的维数.

极化目标分解^[1,14,15]是分析目标极化散射机制最重要的手段,依据极化目标分解方法(Freeman 分解, Yamaguchi-Sato 分解和 Cloude 分解),不同地物类别所具有的极化散射特征是有差异的,这为极化 SAR 图像分类提供了理论依据.为了充分利用极化 SAR 图像信息,本文选取多个极化散射特征,如表 1 所示,并引入加权合成核,依据各个地物类别极化散射特征间的主次关系来融合核函数.文献[10]指出:通过合理确定核函数权重系数,加权合成核能获得更好的分类结果,因此核函数权重系数的计算是一个值得研究的问题,下面,本文将给出核函数权重系数的自适应确定方法的具体过程.

为方便比较,本文将式(1)的高斯径向基核称为“传统核函数”,式(3)中由高斯径向基核构造的加权合成核简称为“加权合成核”,参数 δ 都设为 1.

在极化 SAR 图像第 i 个特征对应的一维特征空间中,类别 l 与 m 的训练样本之间距离越大,说明该特征区分类别 l, m 的能力越强,该特征的核函数 $K^i(x_i, y_i)$ 区分类别 l, m 的能力也越强,反之越弱.因此,类别 l 与 m 训练样本之间的距离可以用于度量核函数 $K^i(x_i, y_i)$ 区分类别 l, m 的能力,当距离越大时,核函数 $K^i(x_i, y_i)$ 区分类别 l, m 的能力越强,应赋予较大的权重系数,反

之赋予较小的权重系数,从而提高加权合成核 $K_{lm}^c(\mathbf{x}, \mathbf{y})$ 区分类别 l, m 的能力. 类别 l, m 的训练样本在特征 i 的一维特征空间中的距离为:

$$d_{lm}^i = \frac{1}{N_{T_l} N_{T_m}} \left| \sum_{p \in T_l, q \in T_m} x_i^p - x_i^q \right|, i = 1, 2, \dots, N \quad (4)$$

其中, T_l 与 T_m 分别表示类别 l 与 m 的训练样本集, N_{T_l} 与 N_{T_m} 分别为 T_l 与 T_m 的样本个数, p 与 q 分别为 T_l 与 T_m 的训练样本, x_i^p 与 x_i^q 分别为 p 与 q 的第 i 个特征. 其中, 类别 l 的 x_i^p 始终为被减数, 类别 m 的 x_i^q 始终为减数; 特征 i 进行了归一化处理.

若类别 l 与 m 的训练样本在特征 i 的一维特征空

间上的差异较大, 则 $x_i^p - x_i^q$ 出现同号的情况会较多且 $|x_i^p - x_i^q|$ 会较大, 此时 d_{lm}^i 会较大; 反之若差异较小, 则 $x_i^p - x_i^q$ 出现异号的情况会较多且 $|x_i^p - x_i^q|$ 会较小, 此时 d_{lm}^i 会较小. 将式(4)的距离归一化后作为权重系数 μ_{lm}^i , 如式(5)所示.

$$\mu_{lm}^i = d_{lm}^i / \sum_{j=1}^N d_{lm}^j, i = 1, 2, \dots, N \quad (5)$$

式(3)的加权合成核结合 SVM 可将极化 SAR 图像的像素点划分为类别 l 或 m , 利用加权合成核的初始分类如图 1 所示.




图1 利用加权合成核的初始分类

3 利用 TMF 的 MAP 分类

文献[11]指出真实图像往往是非平稳的, 非平稳图像由多个平稳态组成, 不同平稳态的统计特性存在一定的差异. TMF^[11,12] 通过添加一个辅助场来区别同一类目标的不同平稳态, 并采用不同参数的 MRF 来描述不同平稳态, 相比于 MRF, TMF 能更准确地描述真实图像. 与单极化 SAR 数据不同, 在分析极化目标散射机制中, 基于 Pauli 分解研究表明同一类目标由于尺寸、方位角等因素的不同在极化散射机制上存在较大差异^[16], 散射机制的差异意味着同一类目标极化数据的统计分布也存在着差异, 而这种差异性可由极化数据的非平稳特性描述. 因此, 本文将引入 TMF 对极化 SAR 图像进行统计建模以实现贝叶斯分类.

设 S 为极化 SAR 图像所有像素点的集合. $X = \{X_s, s \in S\}$, $Y = \{Y_s, s \in S\}$, $U = \{U_s, s \in S\}$, 表示定义在 S 上的三个随机场, 其中 X 为标记场, Y 为观测场, U 为辅助场. $X_s \in \Omega = \{1, 2, \dots, M\}$ 为像素点 s 的类别. Y_s 为像素点 s 的观测数据, 对于极化 SAR 图像, Y_s 为协方差矩阵 C_s . U_s 为像素点 s 的平稳态, 不失一般性^[11], 本文假定极化 SAR 图像存在两个平稳态, 分别用 $U_s = a$ 与 $U_s = b$ 表示, $A = (a, b)$. 设 (X, U, Y) 具有 Markov 性^[11], 那么 (X, U, Y) 称为 TMF. 马尔可夫场 (X, U) 的分布由式(6)的势能函数定义^[11,12]:

$$W(x, u | \theta) = \sum_{(s,t) \in C_H} \alpha_H^1 (1 - 2\delta(x_s, x_t)) - \sum_{(s,t) \in C_V} (\alpha_{aH}^2 \delta^*(u_s, u_t, a) + \alpha_{bH}^2 \delta^*(u_s, u_t, b)) (1 - \delta(x_s, x_t)) + \sum_{(s,t) \in C_V} \alpha_V^1 (1 - 2\delta(x_s, x_t)) - \sum_{(s,t) \in C_V} (\alpha_{aV}^2 \delta^*(u_s, u_t, a) + \alpha_{bV}^2 \delta^*(u_s, u_t, b)) (1 - \delta(x_s, x_t)) \quad (6)$$

其中, C_H 和 C_V 分别表示邻域系统的水平和垂直基团; $\{\alpha_H^1, \alpha_{aH}^2, \alpha_{bH}^2, \alpha_V^1, \alpha_{aV}^2, \alpha_{bV}^2\}$ 称为定义势能函数的 TMF 模型参数; 当 $x_s = x_t$ 时, $\delta(x_s, x_t) = 1$, 否则 $\delta(x_s, x_t) = 0$; 当 $u_s = u_t = a$ 时, $\delta^*(u_s, u_t, a) = 1$, 否则 $\delta^*(u_s, u_t, a) = 0$, $\delta^*(u_s, u_t, b)$ 的计算类似于 $\delta^*(u_s, u_t, a)$.

基于 Hammersley-Clifford 理论, TMF 模型的联合先验概率分布可定义^[11]为:

$$P(x, u | \theta) = \frac{1}{Z_{xu}(\theta)} \exp(-W(x, u | \theta)) \quad (7)$$

其中, $Z_{xu}(\theta) = \sum_{x \in \Omega} \sum_{u \in A} \exp(-W(x, u | \theta))$ 为 TMF 模型的分布函数.

假定 Y 关于 (X, U) 的条件分布满足统计独立条件^[11], 由 Y_s 服从 Wishart 分布^[1], 可得似然概率 $P(y | x, u)$ 的表达式为:

$$P(y | x, u) = \prod_{s \in S} P(y_s | x_s, u_s) \quad (8a)$$

$$P(y_s | x_s, u_s) = \frac{n^m |C_s|^{n-q} \exp(-n \text{Tr}((Z_{x_s, u_s})^{-1} C_s))}{K(n, q) |Z_{x_s, u_s}|^n} \quad (8b)$$

其中, C_s 为像素点 s 的协方差矩阵, n 为视数, q 为 C_s 的行数, Z_{x_s, u_s} 为协方差矩阵的平均值, 其计算公式为:

$$Z_{x,u} = \frac{1}{N_T} \sum_{t \in T_s} C_t, T_s = \{t | x_t = x_s \text{ and } u_t = u_s, t \in S\} \quad (9)$$

其中, T_s 表示与像素点 s 属于相同类别与相同平稳态的像素点集合, N_T 为 T_s 的像素点个数.

联合分布 (X, U, Y) 为马尔可夫分布, 其分布可定义^[11] 为:

$$P(x, u, y) = \frac{1}{Z_{xu}(\theta)} \exp(-W(x, u | \theta) + \sum_{s \in S} \log(P(y_s | x_s, u_s))) \quad (10)$$

根据贝叶斯公式^[6], 可得后验概率分布 $P(x, u | y)$:

$$P(x, u | y) \propto \frac{1}{Z_{xu}(\theta)} \exp(-W(x, u | \theta) + \sum_{s \in S} \log(P(y_s | x_s, u_s))) \quad (11)$$

由于分布函数 $Z_{xu}(\theta)$ 难以计算, 常采用 ICM 方法^[6] 来近似实现 MAP 分类, ICM 方法依据单个像素点 s 的条件概率 $P(x_s, u_s | y_s, x_N, u_N)$ 来实现分类, 其表达式为:

$$P(x_s, u_s | y_s, x_N, u_N) \propto \exp(-W_s(x_s, u_s | \theta))$$

$$+ \log P(y_s | x_s, u_s) \quad (12)$$

其中, $P(y_s | x_s, u_s)$ 如式(8b)所示, $W_s(x_s, u_s | \theta)$ 为单个像素点 s 的势能函数, 表达式为:

$$W_s(x_s, u_s | \theta) = \sum_{t \in N_H} \alpha_H^1 (1 - 2\delta(x_s, x_t)) - \sum_{t \in N_H} (\alpha_{aH}^2 \delta^*(u_s, u_t, a) + \alpha_{bH}^2 \delta^*(u_s, u_t, b)) (1 - \delta(x_s, x_t)) + \sum_{t \in N_V} \alpha_V^1 (1 - 2\delta(x_s, x_t)) - \sum_{t \in N_V} (\alpha_{aV}^2 \delta^*(u_s, u_t, a) + \alpha_{bV}^2 \delta^*(u_s, u_t, b)) (1 - \delta(x_s, x_t)) \quad (13)$$

由式(12)可知, $P(x_s, u_s | y_s, x_N, u_N)$ 正比于能量函数 $E_s = -W_s(x_s, u_s | \theta) + \log P(y_s | x_s, u_s)$, 根据 ICM 方法, 只需极大化 E_s , 即可估计像素点 s 的 x_s 与 u_s , 如式(14)所示. 利用 TMF 的 MAP 分类如图 2 所示.

$$(x_s, u_s) = \arg \max_{x_s \in \Omega, u_s \in A} \{-W_s(x_s, u_s | \theta) + \log P(y_s | x_s, u_s)\} \quad (14)$$




图2 利用TMF的MAP分类

4 实验结果及分析

本文方法的分类性能通过实测极化 SAR 图像分类实验来测试, 实验所用图像是 NASA/JPL 实验室 AIR-SAR 系统获取的 L 波段 San Francisco 地区的 4 视极化图像, 分辨率为 10m, 图像大小为 700×900 像素, 主要包含建筑物、植被、海洋与裸地四种地物类别.

图 3(a) 是 San Francisco 图像的 Pauli 分解图, 其中 1~4 方框所圈区域分别表示建筑物、植被、海洋、裸地的训练样本. 图 3(b) 是本文方法的分类结果. 图 3(c)~3(e) 分别是由 Wishart 分类、传统核函数与加权合成核实现的初始分类结果. 图 3(f)~3(h) 是 MRF 的 MAP 分类结果, 初始分类分别通过 Wishart 分类、传统核函数、加权合成核来实现. 表 2 是 San Francisco 图像在不同分类方法下的分类精度. 通过对比分析图 3(c)~3(e) 及表 2 可知, 加权合成核的初始分类结果优于 Wishart 分类与传统核函数的初始分类结果, 说明加权合成核能提高初始分类的精度. 通过对比分析图 3(f)~3(h) 及表 2 可知, 加权合成核 + MRF 的分类性能优于 Wishart 分类 + MRF 与传统核函数 + MRF 的分类性能, 说明初始分类精度的提高有助于提高 MAP 分类精度. 通过对比图 3(h) 与 3(b) 可知, TMF 的 MAP 分类能

更好地提高同质区域分类结果的平滑性且能更好地保持边缘信息, 再结合表 2 可知, TMF 的 MAP 分类性能优于 MRF 的 MAP 分类性能. 通过对比分析图 3(b) 与 3(f)、3(g) 及表 2 可知, 本文所提出的分类方法性能优于现有的基于 MRF 的分类方法^[8,9] 性能, 分别高出 8.79%、9.63%.

表 2 San Francisco 图像的分类精度 (%)

地物类别	Wishart 初始分类	传统核函数初始分类	加权合成核初始分类	Wishart 分类 + MRF	传统核函数 + MRF	加权合成核 + MRF	本文方法
建筑物	77.12	72.56	81.11	81.23	76.48	85.17	90.58
植被	80.52	81.16	83.81	82.45	83.19	88.97	90.86
海洋	82.98	83.51	86.34	85.63	85.76	90.13	92.34
裸地	72.46	73.78	84.93	78.21	78.73	88.56	88.91
整体	78.27	77.75	84.05	81.88	81.04	88.21	90.67

为了进一步说明本文方法的有效性, 我们用同样的方法, 对 AIRSAR 系统获取的 Flevoland 地区的 4 视全极化 SAR 数据进行分类, 该实验数据大小为 377×273 像素, 距离向分辨率为 6.60m, 方位向分辨率为 12.10m, 图 4 是 Flevoland 图像在不同方法下的分类结果, 其中图 4(b) 是本文方法的分类结果, 表 3 是 Flevoland 图像在不同方法下的分类精度. 从图 4 的视觉评价

与表3的定量结果分析可知,加权合成核的初始分类效果优于 Wishart 分类和传统核函数的初始分类,且 TMF 的 MAP 分类效果优于 MRF 的 MAP 分类,加权合

成核 + TMF 的分类效果优于传统核函数 + MRF,说明本文提出的极化 SAR 图像分类方法性能优于基于 MRF 的分类方法^[8,9]性能。

表3 Flevoland 图像的分类精度 (%)

分类方法	裸地	大麦	苜蓿	豌豆	马铃薯	油菜籽	甜菜	小麦	整体
Wishart 初始分类	96.86	84.98	89.02	80.23	90.25	55.14	69.88	70.45	79.60
传统核函数初始分类	97.52	87.26	88.96	80.87	92.57	57.42	78.93	76.15	82.46
加权合成核初始分类	98.67	89.78	89.15	86.76	94.37	71.89	81.51	82.67	86.85
传统核函数 + MRF	98.73	87.39	92.94	90.29	94.91	90.56	85.04	86.59	90.81
加权合成核 + MRF	99.14	89.91	93.16	91.68	95.48	92.67	87.34	88.59	92.25
本文方法	99.67	96.62	95.86	94.87	96.31	94.19	92.75	94.85	95.64

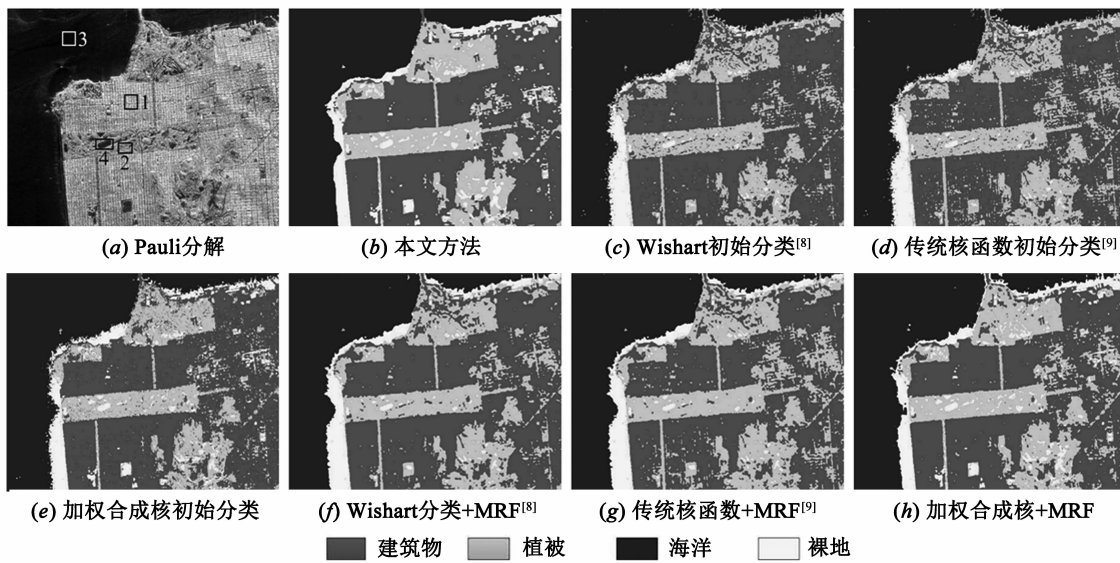


图3 San Francisco 图像的分类结果

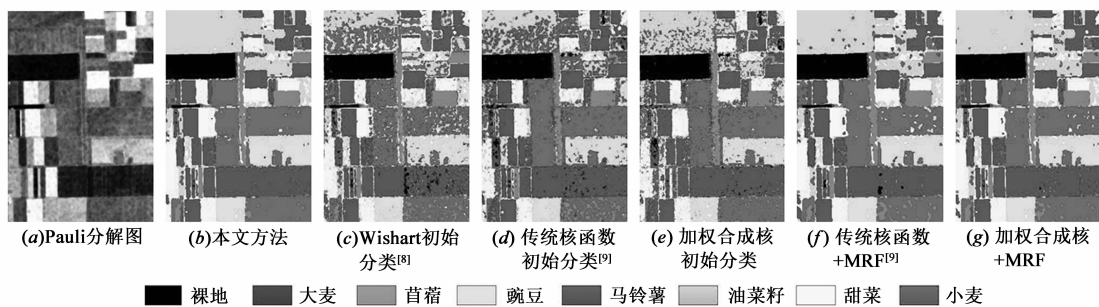


图4 Flevoland 图像的分类结果

实验中加权合成核的核函数权重系数是通过图3(a)的训练样本计算得到,为了测试加权合成核区分地物类别的能力,现选取不同于图3(a)训练样本的测试样本,如图5所示,其中1~4方框所圈区域分别表示建筑物、植被、海洋、裸地的测试样本。同类样本核函数与异类样本核函数之间的比值^[10]用于度量核函数区分地物类别的能力,如式(15)所示:

$$\Lambda_{lm} = \frac{\frac{1}{N_{R_l}^2} \sum_{i,j \in R_l} K(\mathbf{x}_i, \mathbf{x}_j) + \frac{1}{N_{R_m}^2} \sum_{i,j \in R_m} K(\mathbf{y}_i, \mathbf{y}_j)}{\frac{2}{N_{R_l} N_{R_m}} \sum_{i \in R_l, j \in R_m} K(\mathbf{x}_i, \mathbf{y}_j)} \quad (15)$$

其中, R_l 与 R_m 分别是类别 l 与 m 的测试样本集, N_{R_l} 与 N_{R_m} 分别为 R_l 与 R_m 的样本个数, $\mathbf{x}_i, \mathbf{x}_j$ 为属于类别 l 的样本 i 与 j 的多维特征向量, $\mathbf{y}_i, \mathbf{y}_j$ 为属于类别 m 的样本 i 与 j 的多维特征向量, $K(\mathbf{x}_i, \mathbf{x}_j)$ 与 $K(\mathbf{y}_i, \mathbf{y}_j)$ 为同类样本

核函数, $K(x_i, y_j)$ 为异类样本核函数, Λ_{lm} 表示核函数区分类别 l 与 m 的能力, Λ_{lm} 越大, 区分能力越强, 反之越弱.

四种地物类别建筑物、植被、海洋、裸地分别标记为类别 1~4, 对应的测试样本集 $T_1 \sim T_4$ 分别如图 5 的方框区域所示, 表 4 为能力度量 Λ_{lm} 的测试结果. 从表 4 可知, 对于四种地物类别中的任意两个, 加权合成核区分这两种地物类别的能力都高于传统核函数, 该实验结果验证了: 通过训练样本在特征空间上的距离来确定核函数的权重系数, 所构建的加权合成核能有效区分地物类别.




图5 测试加权合成核区分地物类别能力的样本

表 4 传统核函数与加权合成核区分地物类别的能力

核函数	建筑物:类别 1;植被:类别 2;海洋:类别 3;裸地:类别 4					
	Λ_{12}	Λ_{13}	Λ_{14}	Λ_{23}	Λ_{24}	Λ_{34}
传统核函数	2.10	4.56	1.86	5.91	2.99	4.74
加权合成核	2.98	6.23	2.78	7.00	3.48	5.29

5 结论

本文提出了一种基于加权合成核与三重 Markov 场的极化 SAR 图像分类方法. 首先加权合成核被引入到了初始分类中, 依据训练样本在特征空间上的距离, 提出了加权合成核中核函数权重系数的自适应确定方法, 实验验证了所构建的加权合成核能提高初始分类的精度, 能有效区分地物类别, 且增强了算法的普适性. 其次, 为了充分考虑极化 SAR 图像的非平稳统计特性, 将 TMF 引入到极化 SAR 图像的 MAP 分类中, 构建了基于 TMF 的极化 SAR 图像 MAP 分类, 实验验证了基于 TMF 的 MAP 分类精度高于 MRF 的 MAP 分类精度, 且本文所提出方法的性能优于现有的基于 MRF 的极化 SAR 图像分类方法性能.

参考文献

[1] LEE J S, POTTIER E. Polarimetric Radar Imaging from Basic to Application[M]. New York: CRC Press, 2011. 1-30, 160-175.

[2] VAN ZYL J J, KIM Y. Synthetic Aperture Radar Polarimetry[M]. California: Jet Propulsion Laboratory, 2011. 85-155.

[3] 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)

- [4] CHEN Q, KUANG G Y, LI J, et al. Unsupervised land cover/land use classification using PolSAR imagery based on scattering similarity[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(3): 1817-1825.
- [5] LIU B, HU H, WANG H Y, et al. Superpixel-based classification with an adaptive number of classes for polarimetric SAR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(2): 907-924.
- [6] LI S L. Markov Random Field Modeling in Image Analysis[M]. London: Springer-Verlag, 2009. 1-189.
- [7] 张斌, 杨然, 谢兴. 利用极化目标分解和 WMRF 的全极化 SAR 图像分类方法[J]. 武汉大学学报信息科学版, 2011, 36(3): 297-301.
- ZHANG Bin, YANG Ran, XIE Xing. Classification of fully polarimetric SAR image based on polarimetric target decomposition and Wishart Markov random field[J]. Geomatics and Information Science of Wuhan University, 2011, 36(3): 297-301. (in Chinese)
- [8] WU Y, JI K, et al. Region-based classification of polarimetric SAR images using Wishart MRF[J]. IEEE Geoscience and Remote Sensing Letter, 2008, 5(4): 668-672.
- [9] WU Z C, OUYANG Q D. SVM- and MRF-based method for contextual classification of polarimetric SAR images[A]. International Geoscience and Remote Sensing Symposium[C]. Canada, Vancouver: IEEE Computer Society, 2011. 818-821.
- [10] CAMPS-VALLS G, GÓMEZ-CHOVA L, et al. Kernel-based framework for multitemporal and multisource remote sensing data classification and change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(6): 1822-1835.
- [11] BENBOUDJEMA D, PIECZYNSKI W. Unsupervised statistical segmentation of nonstationary images using triplet Markov fields[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(8): 1367-1378.
- [12] BENBOUDJEMA D, TUPIN F, et al. Unsupervised segmentation of SAR images using triplet Markov fields and Fisher noise distributions[A]. International Geoscience and Remote Sensing Symposium[C]. Barcelona, Spain: IEEE Computer Society, 2007. 3891-3894.
- [13] LI G Q, WEN C Y, et al. Model-based online learning with kernels[J]. IEEE Transactions on Neural Networks

and Learning Systems, 2013, 24(3):356-369.

- [14] 刘高峰,李明,等. 一种改进的极化 SAR 自适应非负特征值分解[J]. 电子与信息学报, 2013, 35(6):1449-1455.

LIU Gao-feng, LI Ming, et al. An improved adaptive non-negative eigenvalue decomposition for polarimetric synthetic aperture radar[J]. Journal of Electronics & Information Technology, 2013, 35(6):1449-1455. (in Chinese)

- [15] LIU G F, LI M, et al. Fast solution to nonnegative eigenvalue decomposition for polarimetric SAR[J]. IET Electronics Letters, 2013, 49(6):419-420.

- [16] VAN ZYL J J. Unsupervised classification of scattering behavior using radar polarimetry data[J]. IEEE Transactions on Geoscience and Remote Sensing, 1989, 27(5):36-45.

作者简介



宋婉莹 女, 1988 年生于山东聊城. 现为西安电子科技大学雷达信号处理国家重点实验室博士研究生. 研究方向为极化 SAR 图像处理、多传感器信息融合等.

E-mail: wanyingsong@hotmail.com



李 明 (通信作者) 男, 1965 年生于河南南阳. 现为西安电子科技大学雷达信号处理国家重点实验室博士、教授、博士生导师. 研究方向为宽带信号实时处理与检测、多源信息融合及 SAR 图像理解等.

E-mail: liming@xidian.edu.cn