

SAR 影像极化特征的混合高斯模型与分类

李珞茹, 徐新*, 董浩, 桂容, 谢欣芳

武汉大学电子信息学院, 湖北 武汉 430072

摘要 针对高分辨率极化合成孔径雷达(SAR)影像中极化特征呈现尖峰拖尾等复杂多样的统计特点,采用混合高斯模型(GMM)对极化特征进行建模,提出了一种约束距离的混合多元高斯分布的参数估计算法。该参数估计算法在贪婪期望最大算法框架下设计约束距离函数,自动估计混合分量的个数和模型参数,进而在贝叶斯框架下实现极化 SAR 影像的地物分类。对 Radarsat-2 旧金山等地区三组影像数据的分类结果表明:相比于经典的分类算法,所提 GMM 分类算法的总体精度提高了 7%~10%,且对样本数目的依赖性更小,在城区和耕地区域等异质区域可以得到精度更高的分类结果。

关键词 遥感; 混合高斯模型; 统计分布; 合成孔径雷达; 参数估计

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/AOS201939.0128002

Gaussian Mixture Model and Classification of Polarimetric Features for SAR Images

Li Luoru, Xu Xin*, Dong Hao, Gui Rong, Xie Xinfang

School of Electronic Information, Wuhan University, Wuhan, Hubei 430072, China

Abstract Aiming at the various statistical characteristics such as peak tailing presented in the high-resolution synthetic aperture radar (SAR) images, we model the polarimetric features according to the Gaussian mixture model (GMM) and come up with a constrained distance estimation algorithm for the parameters of multivariate Gaussian mixture distribution. Under the framework of greedy expectation maximum algorithm, a constraint distance function is designed and the number of mixed components and model parameters are automatically estimated in this parameter estimation algorithm. Consequently the classification of polarimetric SAR images is realized under the Bayesian framework. The classification results of three groups of image data from Radarsat-2 in San Francisco and other places indicate that the proposed GMM classification algorithm possesses an overall accuracy higher by 7%-10% comparing with those by the classical classification algorithms. Moreover, its dependence on sample number is small. The more accurate classification results can be obtained in heterogeneous regions such as urban and farmland.

Key words remote sensing; Gaussian mixture model; statistical distribution; synthetic aperture radar; parameter estimation

OCIS codes 280.6730; 100.2960; 110.1650; 280.4750

1 引 言

极化合成孔径雷达(SAR)影像包含详细的地物覆盖信息,是进行地理监测的重要数据源。场景分类是极化 SAR 影像解译的重要内容,主要有基于统计模型分类方法、基于散射机制分析的分类方法和联合多极化特征的机器学习分类方法。由于相干成像机制^[1],极化 SAR 数据具有统计随机

性,因此统计建模是极化 SAR 处理和解译的重点。随着影像分辨率的不断提高,复高斯分布^[2]和复 Wishart 分布等^[3]不足以表征异质区域的统计特性,因此,研究人员进一步提出了 K_p 分布、 G_p 分布^[2]、KummerU 分布^[4]以及混合模型。这些极化 SAR 统计模型的分布形式逐渐变得过于复杂且不实用。而从原始数据中提取极化特征来反映地物目标的散射机制,也同样具有统计特性。有人采用

收稿日期: 2018-06-12; 修回日期: 2018-08-05; 录用日期: 2018-08-23

基金项目: 国家重点研发计划(2016YFB0502601)、高分辨率对地观测重大专项技术与开发(03-Y20A10-9001-15/16)

* E-mail: xinxu@whu.edu.cn

Weibull 分布^[5]、Log-normal 分布^[6] 等来描述 SAR 影像的单通道数据。Lee 等^[7] 推导了复相关系数幅度和相位的理论分布; Lopez-Martinez 等^[8] 从协方差矩阵出发, 推导了特征值的理论分布形式。这些极化特征的统计特性更加复杂多样, 相应的统计模型一般没有可以解析的表达式。针对城区、耕地等异质性明显的区域, 极化特征的统计分布逐渐表现出偏峰重尾, 有的甚至出现多峰特性。鉴于此, 研究人员引入了有限混合模型(FMM)^[9], 如混合广义极值分布(GEV)^[10]、混合 gamma 分布^[11] 等, 用于分析部分极化特征的统计特性。混合分布对 SAR 图像的建模更为精准, 但计算成本也更高。随着模型越来越复杂, 参数的估计难度也越来越大, 一些分布能描述指定的极化特征, 但却不能描述其他的极化特征。因此, 混合高斯分布被应用到特征值的分析上, 用以结合纹理特征实现分类^[12]。

然而, 混合高斯分布中混合分量个数如何选择的问题一直难以解决^[13]。传统方法使用惩罚似然形式, 如赤池信息量准则(AIC)^[14], 来考察信息准则, 但计算代价大。有些学者则通过删减或合并算法得到最终的混合模型的分量^[13], 但依然难以设定起点和终止条件。

混合高斯分布的优势在于: 1) 混合模型分布灵

活, 不受极化特征多样性和异质区域中复杂统计特性的限制; 2) 多元高斯分布能拟合多元数据, 可以对多特征进行联合分析; 3) 与其他模型相比, 由简单的多元高斯分布得到的混合模型的计算成本较低。鉴于此, 本文采用混合高斯分布来描述 SAR 影像极化特征的统计特性, 并设计了一种参数估计算法, 用以得到模型参数, 然后在贝叶斯框架下实现对极化 SAR 的分类。之后, 对 SAR 影像的极化特征进行分析, 并进行分类实验, 对所提算法进行理论证明和实验验证。结果表明: 基于混合高斯模型(GMM)的算法能更有效地解译极化 SAR 影像, 在异质性明显的耕地和城区区域能更好地描述极化特征分布。

2 实验数据

本实验采用三组数据, 均来自 Radarsat-2 获取的 C 波段数据, 如图 1~3 所示。美国旧金山地区极化 SAR 数据的大小为 1200 pixel×1600 pixel, 包含水域、林地和城区三类地物; 荷兰弗兰福德地区极化 SAR 数据的大小为 1200 pixel×1400 pixel, 包含水域、林地、耕地和城区 4 类地物; 加拿大温哥华地区极化 SAR 数据的大小为 1600 pixel×2600 pixel, 包含水域、林地、耕地、城区 4 类地物。根据 Google Earth 进行标注, 以便取样和计算分类精度。

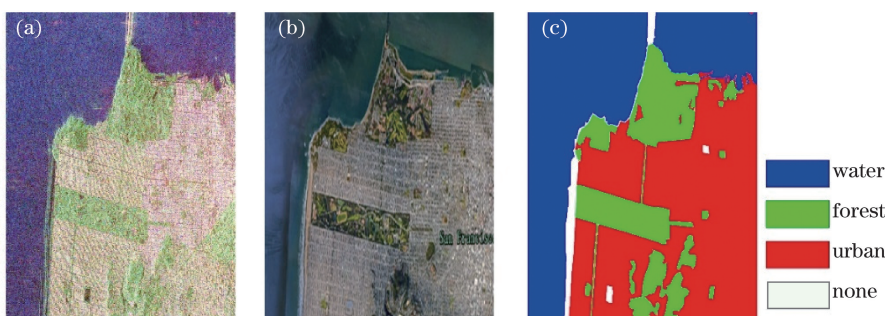


图 1 旧金山地区 Radarsat-2 极化 SAR 影像。(a) Pauli 伪彩图; (b) 对应的地图; (c) 标注图

Fig. 1 Polarimetric SAR images from Radarsat-2 in San Francisco. (a) Pauli pseudo color image;

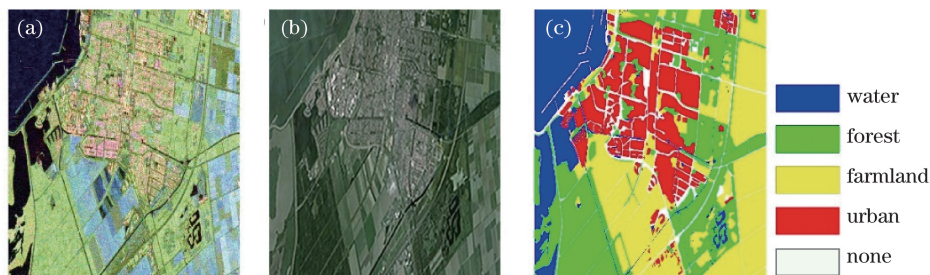


图 2 弗兰福德地区 Radarsat-2 极化 SAR 影像。(a) Pauli 伪彩图; (b) 对应的地图; (c) 标注图

Fig. 2 Polarimetric SAR images from Radarsat-2 in Flevoland. (a) Pauli pseudo color image; (b) corresponding map; (c) ground truth




图 3 温哥华地区 Radarsat-2 极化 SAR 影像。(a) Pauli 伪彩图;(b)对应的地图;(c)标注图
Fig. 3 Polarimetric SAR images from Radarsat-2 in Vancouver. (a) Pauli pseudo color image;
(b) corresponding map; (c) ground truth

有研究表明,一些极化特征具有较强的目标识别能力^[15-17],故而本实验中使用如下极化特征: 1) 极化相关系数,如极化通道相关系数和圆极化相关系数等;2) Cloude-Pottier 分解特征组(散射熵 H 、散射角 α 、各向异性度 A);3) Freeman 分解特征组(表面散射 FP_s 、二面散射 FP_d 、体散射 FP_v);4) Yamaguchi 分解特征组(表面散射 YP_s 、二面散射 YP_d 、体散射 YP_v 、螺旋散射 YP_h)。

3 极化特征统计特性分析

以弗兰福德地区数据在 Yamaguchi 四分量分解下得到的极化特征为例,分析其统计特性。实验前对特征进行了归一化处理。选择 4 种常用于描述极化 SAR 数据的分布(γ 分布、Log-normal 分布、K 分布和 GMM 分布)进行对比,如图 4 所示。

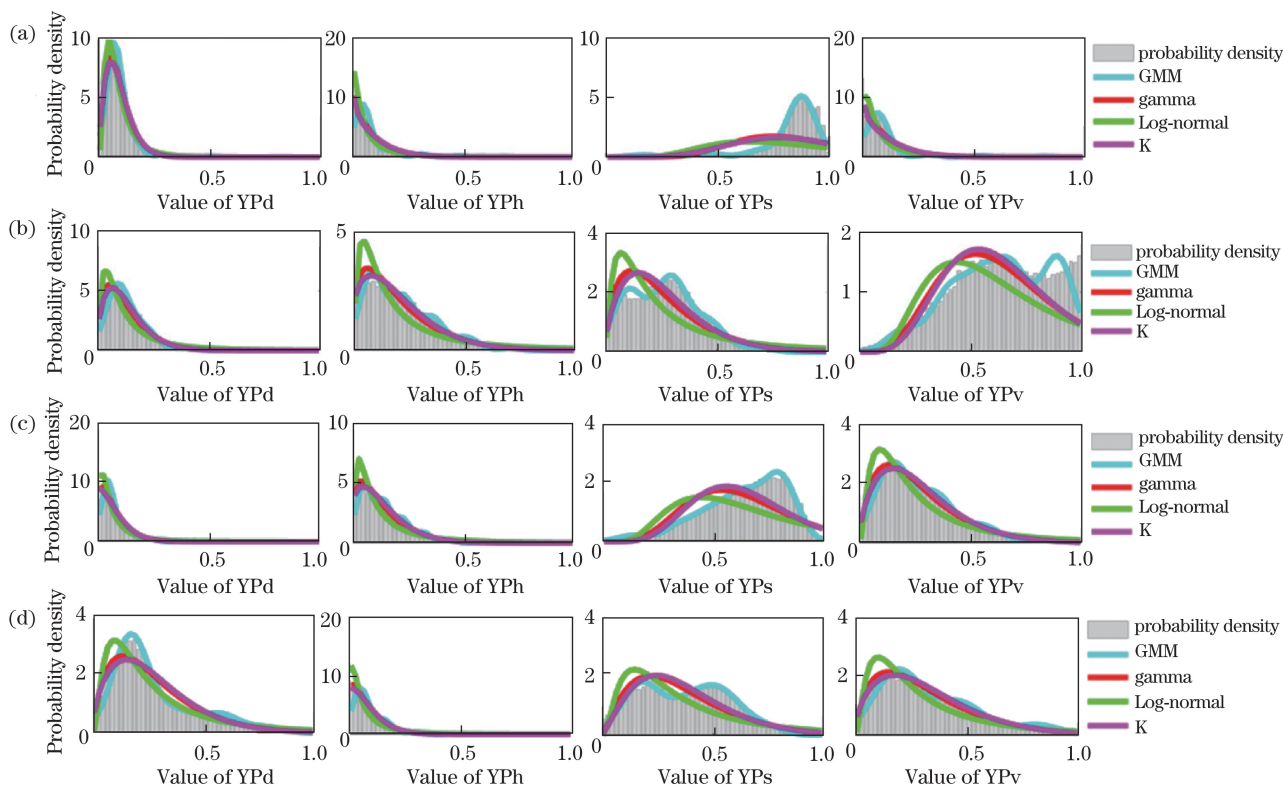


图 4 不同分布下各特征的拟合结果。(a)水域;(b)林地;(c)耕地;(d)城区
Fig. 4 Fitting results of each feature at different distributions. (a) Water; (b) forest; (c) farmland; (d) urban

观察数据与模型分布之间的吻合程度可以发现,对于左偏分布的极化 SAR 特征,如水域区域的二面散射,各分布均能较好地描述;对于右偏分布的

特征,如耕地区域的表面散射,GMM 的曲线最接近数据直方图,K 分布的拟合结果次之;对于尖峰分布的特征,如林地区域的二面散射,GMM 曲线的效果

最佳,其他较差;对于具有多峰特性的极化 SAR 特征,如城区区域的表面散射和林地区域的体散射,仅有 GMM 的拟合结果较好。根据实验可知,其他目标分解方法得到的极化特征也同样具有上述统计特性。从拟合情况来看,GMM 是一种较好的对极化 SAR 特征进行统计的模型。

通过计算 KS 距离来客观评价统计模型的建模能力,结果如表 1~2 所示。可以看出:K 分布在水域上的平均 KS 距离较大,不适合用于该区域的统计建模;gamma 分布和 Log-normal 分布在水域和城区上的 KS 距离均较大;GMM 分布在 4 类地物上的 KS 距离最小。这说明:GMM 是一种效果优异的统计模型,可用于极化 SAR 影像中不同地物类别的统计建模。

表 1 不同分布下的 KS 距离均值

Table 1 KS distance mean at different distributions

Distribution	Water	Forest	Farmland	Urban
Gamma	1.414	0.691	0.436	1.221
Log-normal	1.277	0.796	0.400	1.115
K	1.764	1.134	0.784	1.515
GMM	0.245	0.257	0.283	0.175

表 2 不同分布下的 KS 距离的最大值

Table 2 Maximum KS distance at different distributions

Distribution	Water	Forest	Farmland	Urban
Gamma	2.544	0.941	0.537	2.087
Log-normal	2.233	1.387	0.506	1.890
K	3.135	1.419	0.882	2.551
GMM	0.305	0.322	0.401	0.250

总体来说,与其他分布相比,GMM 更适用于极化 SAR 影像中不同地物类别的统计建模。下文将针对如何选择 GMM 混合分量的个数以及参数估计中存在的问题进行分析。

4 混合高斯模型的参数估计算法

4.1 混合高斯模型

混合高斯模型由多个多元高斯分布线性加权叠加而成,对于多元变量 \mathbf{x} ,其概率密度函数为

$$f(\mathbf{x}) = \sum_{k=1}^K \pi_k f_{k(\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}(\mathbf{x}), \quad (1)$$

式中: $f_{k(\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}(\mathbf{x})$ 为第 k 个分量的概率密度函数; π_k 、 $\boldsymbol{\mu}_k$ 和 $\boldsymbol{\Sigma}_k$ 分别为 GMM 中第 k 个分量的权重系数、均值向量和协方差矩阵。权重系数 π_k 满足归一化条件,即 $\sum_{k=1}^K \pi_k = 1$,其中 $0 < \pi_k \leq 1$ 。

一般情况下,对混合高斯模型进行参数估计时,需要提前设定混合分量的个数 K ,然后通过期望最大化(EM)算法实现。EM 算法对初值的过度依赖使其易于陷入局部最大值,且需要设定混合分量的个数。因此,这里设计了约束距离的参数估计算法,用来实现混合高斯分布的参数估计。

4.2 约束距离的参数估计算法

借鉴贪婪 EM 算法^[18]的思想,本课题组提出一种新的混合高斯模型参数估计算法,即:从一个分量出发,交替插入新分量作为新的初始值,运行 EM 算法,直至满足收敛准则。通过提出的约束距离函数对当前的拟合结果进行分析,从而确定收敛的阈值。在参数估计过程中,将一个新的分量 $N(\mathbf{x} | \boldsymbol{\mu}_{M+1}, \boldsymbol{\Sigma}_{M+1})$ 加入到含有 M 个分量的混合模型 $h_M(\mathbf{x})$ 中,得到新的模型

$$h_{M+1}(\mathbf{x}) = (1 - \alpha)h_M(\mathbf{x}) + \alpha N(\mathbf{x} | \boldsymbol{\mu}_{M+1}, \boldsymbol{\Sigma}_{M+1}), \quad (2)$$

式中: $\alpha \in (0, 1)$ 。 α 和 $N(\mathbf{x} | \boldsymbol{\mu}_{M+1}, \boldsymbol{\Sigma}_{M+1})$ 均随机生成。继而提出约束距离函数,其表达式为

$$\Psi = d_{KS}(1 + \lambda), \quad (3)$$

式中: d_{KS} 为 KS 距离,用于计算模型的拟合精度,判断统计模型是否适用。当 d_{KS} 过大时,认为拟合得到的分布模型不能与原数据匹配。 λ 为分量个数的约束项,其定义为

$$\lambda = \left(\lg \frac{1}{\prod_{k=1}^K \pi_k} \right) / k = - \left(\sum_{k=1}^K \lg \pi_k \right) / k. \quad (4)$$

当混合分量的个数足够多时,能平滑任何分布,但待求参数的个数和耗时也会增加,极易产生过拟合,因此需要对分量的个数进行约束。理论上,当分量的个数达到需要的拟合结果时,新的分量权重应为 0。然而由于随机噪声的存在,势必会产生比重不为 0 但幅度极小的分量,若对受噪声影响的数据进行拟合,就会发生过拟合。基于“过拟合所产生的新的分量的比重会远小于前几个分量”这一思路,定义了分量个数的约束项。当过拟合时,会产生比重 π_{k+1} 远小于 1 的第 $k+1$ 个分量,这时 λ 会增加 $-\lg \pi_{k+1}$, λ 随着比重 π_{k+1} 的减小呈指数增大。当发生过拟合时(即 M 过大时), λ 会迅速增大;当欠拟合时,模型的经验分布与样本的累积分布匹配得不好, d_{KS} 也会增大。当通过选择最小的距离 Ψ 值来确定混合分量的个数时,过大和过小的 k 值都会被惩罚掉,从而估计出正确的混合分量的个数。由此可知, Ψ 是一个关于 k 的不严格的下凹函数,其

最小值处对应的 k 值即为混合模型的分量个数。

4.3 算法流程

在贪婪 EM 算法框架下,约束距离的参数估计算法可以自动估计模型混合分量的个数,同时完成参数估计。具体流程如图 5 所示,可总结为:1)记混合分量的个数 $k=1$,此时分量约束项 $\lambda=0$,直接计

算得到高斯模型 f ,通过 f 计算出 d_{KS} ,得到约束距离函数 Ψ ;2)随机生成高斯分量 ϕ 与其对应的权重 α ,令模型 $f'=\alpha\phi+(1-\alpha)f$,将其作为初始值代入 EM 算法中进行计算,直至收敛;3)计算新的约束距离函数 Ψ' ,当 $\Psi'>\Psi$ 时,输出混合分量的个数为 k 。否则重复第二步。




图 5 约束距离估计算法流程

Fig. 5 Flow chart of constrained distance estimation algorithm

4.4 算法有效性分析

对约束距离的参数估计算法进行性能分析。以弗兰福德地区的圆极化系数 x 为例,列出不同混合分量个数下的 KS 距离值、约束距离函数损失值和约束距离项,如图 6 所示。这组数据在 $k=5$ 时取得了最小的约束距离损失值,在 $k=8$ 时取得了最小的 KS 距离。在图 7 中列出了 k 值分别为 1、5、8 时的拟合结果。

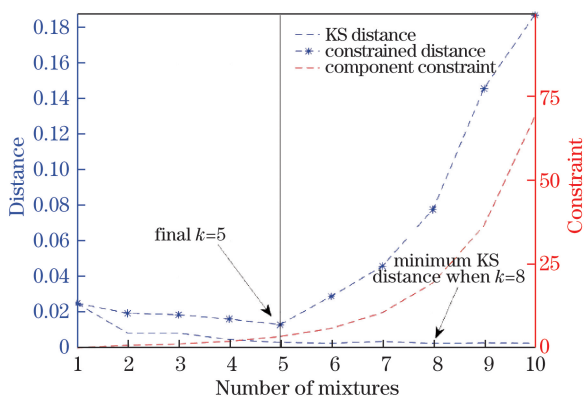


图 6 不同参数下的距离函数

Fig. 6 Distance function at different parameters

从 KS 距离来看,随着混合分量个数增加,KS 距离值逐渐减小并趋近于 0。直接观察图 6 可知:当 $k=5$ 时,KS 距离几乎已经接近最小值,但是从数值上来看,KS 距离值还在继续减小,直至 $k=8$;而从约束距离函数值来看,其受 KS 距离的影响较大,会随着 KS 距离的减小而减小;KS 距离逐渐减小至最小值后,KS 距离趋于稳定,损失值受约束距离项的影响越来越大,最终急速增长。观察约束距离损失值可以看出,约束距离损失值随着混合分量个数的增加而增大,由此判断模型出现了过拟合。

从拟合的结果来看:当 $k=1$ 时,单分量的高斯模




图 7 不同参数下的拟合结果。(a) $k=1$; (b) $k=5$; (c) $k=8$

Fig. 7 Fitting results at different parameters.

(a) $k=1$; (b) $k=5$; (c) $k=8$

型无法描述极化特征的偏峰与重尾问题;当 $k=5$ 时,混合高斯模型已经可以较好地拟合极化特征的分布;当 $k=8$ 时,混合高斯模型的拟合结果相对于 $k=5$ 时的优化效果不明显,但计算成本却大大增加了。

综上所述,根据约束距离函数可以选择出符合数据分布且计算成本更低的 k 值。

4.5 极化 SAR 分类流程

基于 GMM 的统计模型对极化 SAR 数据进行分类,流程如图 8 所示。在进行分类前,数据均通过窗口为 5 的 Boxcar 滤波器进行滤波处理,然后进行极化分解得到极化特征,之后再选择训练样本进行 GMM 模型的参数估计,最后通过建立的 GMM 模型并结合最大后验算法 (MAP) 对数据进行分类。分类后通过马尔科夫随机场模型 (MRF)^[19-20] 计算每个像素点属于每个类别的概率与其邻域的关系,并结合邻域之间的依赖关系重新计算其概率分布,

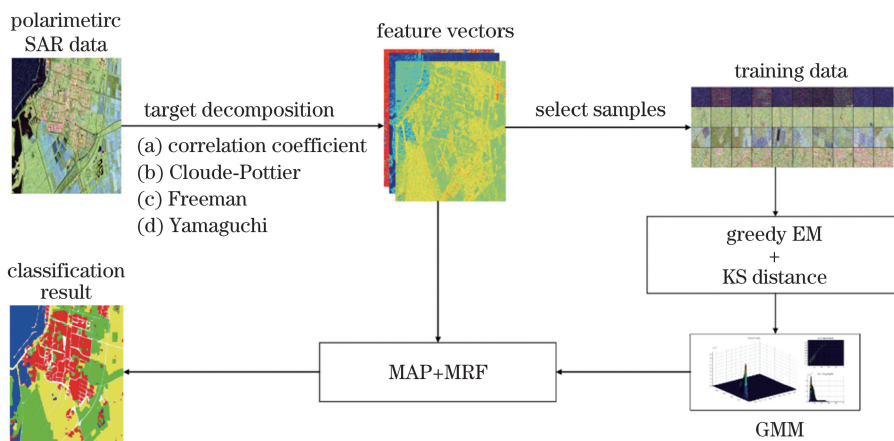


图 8 基于 GMM 模型的极化 SAR 图像分类算法流程

Fig. 8 Flow chart of polarimetric SAR image classification algorithm based on GMM model

从而完成实验结果的后处理。

5 分类结果与分析

首先,选用极化相关系数为极化特征,将基于混合高斯分布的分类算法(GMM)应用于极化 SAR 的地物分类,并将分类结果与 K 近邻(KNN)、支持

向量机(SVM)、随机森林(RF)、基于 Wishart 分布的分类方法(WHRT)得到的分类结果进行对比。数据均通过窗口为 5 的 Boxcar 滤波器进行滤波,然后从每个类别中随机选择 1%作为样本,估计模型参数或训练分类器,最后完成分类实验。实验参数保持不变。分类图如图 9~11 所示,分类精度见表 3。




图 9 旧金山地区的极化 SAR 分类结果。(a) KNN; (b) SVM; (c) RF; (d) WHRT; (e) GMM

Fig. 9 Polarimetric SAR classification results in San Francisco. (a) KNN; (b) SVM; (c) RF; (d) WHRT; (e) GMM




图 10 弗兰福德地区的极化 SAR 分类结果。(a) KNN; (b) SVM; (c) RF; (d) WHRT; (e) GMM

Fig. 10 Polarimetric SAR classification results in Flevoland. (a) KNN; (b) SVM; (c) RF; (d) WHRT; (e) GMM

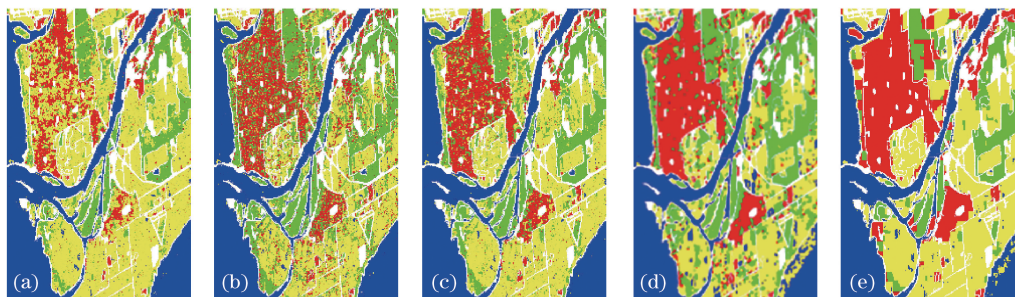


图 11 温哥华地区的极化 SAR 分类结果。(a) KNN; (b) SVM; (c) RF; (d) WHRT; (e) GMM

Fig. 11 Polarimetric SAR classification results in Vancouver. (a) KNN; (b) SVM; (c) RF; (d) WHRT; (e) GMM

表 3 极化 SAR 分类实验的精度

Table 3 Experimental accuracy in classification of polarimetric SAR

%

Place	Algorithm	Water	Forest	Farmland	Urban	Overall	Kappa
San Francisco	KNN	99.82	98.28	-	69.17	94.34	91.16
	SVM	99.68	96.70	-	78.26	95.03	91.61
	RF	99.78	98.24	-	79.73	95.97	92.76
	WHRT	99.42	95.44	-	73.01	93.01	89.24
	GMM	99.50	98.98	-	95.84	96.90	93.23
Flevoland	KNN	86.77	91.10	75.29	74.91	83.85	76.23
	SVM	82.47	90.42	72.88	75.29	82.71	75.15
	RF	85.98	86.03	73.69	75.88	83.01	76.60
	WHRT	85.60	86.96	72.05	72.19	80.89	72.37
	GMM	87.69	85.81	92.70	88.19	89.70	82.11
Vancouver	KNN	99.28	87.15	73.88	48.19	81.02	66.77
	SVM	99.18	84.72	63.20	66.10	80.57	65.45
	RF	99.28	86.86	79.56	72.52	84.16	69.35
	WHRT	99.21	88.72	66.49	86.21	80.21	66.22
	GMM	99.66	86.88	80.08	96.71	89.97	74.22

从分类精度来看,在对旧金山地区和温哥华地区的分类实验中,水域的分类精度较高,基本稳定在99%以上;在对弗兰福德地区的分类实验中,林地地区的分类精度相对较高。在KNN的分类结果中,水域这类单一散射地物的极化特征分布较为集中,分类效果较好,但其他地物,如城区和耕地区域的分类效果则略差。SVM分类器是二值分类器,可能会对一种类别的识别效果极好,但对其他类别的识别效果则较差,复杂度也较高。随机森林算法严重依赖于训练样本,提取信息的能力较强。对比前两组实验可知,随机森林算法在旧金山地区取得了更好的分类结果,在弗兰福德和温哥华地区的水域和城区区域也取得了不错的结果。基于Wishart分布的分类方法适用于表征均匀区域的特性,因此在水域区域能得到较好的分类结果,在耕地、林地等区域的结果则不佳。通过对比分析分类结果可知,基于GMM的分类算法得到的分类结果更好。旧金山地区不同地物之间的区别较大,易于辨别,各实验都能达到93%以上的分类精度。从分类结果图来看,在基于GMM的分类算法得到的结果中,边缘和纹理更加清晰,小图斑和噪点更少,将林地误分为城区的概率也更小,分类效果更优。弗兰福德地区最难区分区域是城区区域,基于GMM的分类算法对城区区域的分类效果要强于其余4种分类器。对于温哥华地区的极化SAR数据,也是基于GMM的算法的分类效果最好。

使用不同的特征组对弗兰福德地区的数据进行分类实验,以验证基于GMM的分类算法对不同极化特征的普适性。实验中选取的极化特征组有:1) Cloude-Pottier分解得到的特征;2) Freeman三分量分解得到的特征;3) Yamaguchi四分量分解得到的特征。由于已在第一组实验中将极化相关系数选为特征进行分类实验,所以这里不再重复实验。实验结果如表4所示。

Cloude-Pottier分解通过特征值的熵、极化角和各向异性来表征相对散射强度的大小,进而解译极化SAR数据。Freeman分解得到的3个特征分别为表面散射、二面散射和体散射,直接对散射功率进行描述。Yamaguchi分解相对于Freeman分解增加了螺旋散射分量,因此对建筑物的区分能力大大增强。水域区域的散射为单一的表面散射,易于区分。林地区域是连成一片的二面散射,比较容易区分。城区区域和耕地区域的组成往往比较复杂,耕地区域混合了不同种类的农作物,而城区区域则包含高楼、公园、广场等混合区域,散射特性不一致,容易混淆,实验结果也印证了这一点。在组成复杂的异质区域,基于GMM的分类算法明显取得了最高的精度,在基于三组极化特征的实验上均可以看到其分类效果。在耕地区域,需要区分的对象为不同种类的农作物,基于Cloude-Pottier分解和Yamaguchi分解的精度仅低于随机森林的分类结果,基于Freeman分解的精度为89.77%,是最高的。在城区

表 4 弗兰福德地区不同特征的极化 SAR 分类实验精度

Table 4 Experimental accuracy in classification of polarimetric SAR under different features in Flevoland %

%

Feature sets	Algorithm	Water	Forest	Farmland	Urban	Overall	Kappa
Cloude-Pottier decomposition	KNN	82.73	95.54	74.59	15.59	69.87	61.74
	SVM	77.40	92.23	79.83	15.67	69.73	61.63
	RF	84.07	94.87	83.04	33.84	77.79	68.75
	GMM	88.00	76.48	82.67	82.42	79.86	70.58
Freeman decomposition	KNN	92.56	90.39	87.51	37.41	78.87	70.70
	SVM	70.20	89.51	77.13	34.24	75.38	69.22
	RF	93.01	86.06	88.88	51.15	81.00	71.58
	GMM	94.53	67.57	89.77	85.03	82.35	72.78
Yamaguchi decomposition	KNN	86.61	89.05	69.76	70.43	80.09	70.78
	SVM	89.31	88.31	67.78	65.60	75.89	68.65
	RF	86.38	87.68	77.03	72.00	80.69	71.31
	GMM	87.58	84.50	70.71	92.95	82.23	72.61

区域,三组实验均取得了最高的分类精度:82.42%、85.03%和 92.95%,高于其他分类方法至少 20%。Yamaguchi 分解的特征组对城区区域的区分能力更强,但 GMM 分类精度仍高于其他三组实验。

由此可得,极化特征对分类结果有一定的影响,但不论是基于哪一组极化特征,GMM 都能获得更好的分类结果,而且在复杂的地形区域上更具有明显的优势。

最后,以 50 个点为间隔,进行训练样本数目的分析。数据取自弗兰福德地区,极化特征为极化相关系数特征组。实验采用了三种常用的分布(K 分布、gamma 分布、Log-normal 分布)与 GMM 进行对比分析,如图 12 所示:在训练样本的数目从 50 增加到 200 的过程,平均分类精度缓慢提高;当训练样本数目超过 200 以后,分类精度的变化不明显,趋于稳定。在实验中选取 200 个样本进行训练,这是因

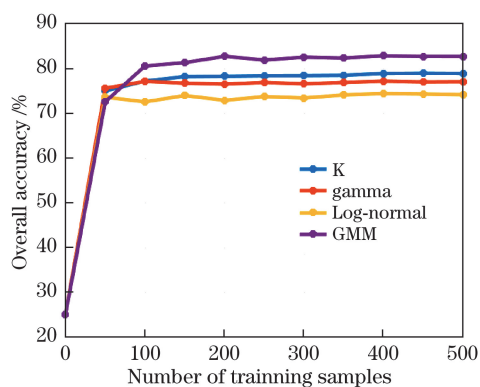


图 12 分类精度与训练样本数目的关系

Fig. 12 Overall accuracy vs. number of training samples

为一方面能够保证分类的精度,另一方面也可以避免过拟合现象,减小计算量。

通过实验发现,基于统计的分类算法对训练样本数目的要求很低,200 个训练样本在实验数据中所占的比例不到 0.03%。由此可以判断,基于统计模型的分类算法对训练样本数目的依赖性极低,能在更少的训练样本下得到更好的分类结果。需要说明的是,虽然基于统计的分类算法在低训练样本数下可以保证分类的精度,但为了方便与对比实验的分类结果进行比较,在上面的实验中依然选择每一类的 1%作为训练样本。

综合实验结果来看,基于 GMM 的分类方法对几种地物类型都能得到较好的分类结果,尤其是对散射复杂且易发生漫散射的城区和耕地区域都得到了最高的分类精度,对各地区的数据进行分类的精度都高于其他分类器。可以认为,基于 GMM 的分类算法更能有效描述极化 SAR 影像中的极化特征,对不易解译的城区区域和耕地区域也能更好地描述,且对训练样本数目的依赖性极低,在避免过拟合的同时,能在训练样本少的情况下得到更好的分类结果。

6 结 论

本课题组提出了一种准确估计 GMM 参数的算法,设计了约束距离函数,在贪婪 EM 算法框架下自动估计混合分量的个数和模型参数,并将该算法应用到极化 SAR 影像的分类上。该算法不仅可以自动获取混合分量的个数,且计算成本低。对极

化特征拟合的评价验证了所提算法的有效性,通过实验验证了贝叶斯框架下的统计模型对训练样本的依赖性低,且分类结果更优异,能在训练样本少的情况下得到更好的分类结果,分类结果图像中的边缘和纹理更为清晰,小图斑和噪点更少。最后进行了极化 SAR 影像的分类实验,该实验对散射复杂的城区和耕地区域能得到最高的分类精度,对各地区的数据进行分类的精度都高于其他分类器,区域间的误分率也很低。实验结果表明,基于 GMM 的分类算法能有效描述极化 SAR 影像的极化特征,符合 SAR 影像的极化特征在异质区域上的分布特性,对于不易解译的城区和耕地区域能更有效地描述其地物特性。

参 考 文 献

- [1] Goodman J W. Some fundamental properties of speckle[J]. Journal of the Optical Society of America, 1976, 66(11): 1145-1150.
- [2] Deng XP, López-Martínez C, Chen J S, *et al.* Statistical modeling of polarimetric SAR data: a survey and challenges[J]. Remote Sensing, 2017, 9(4): 348.
- [3] Cloude S R, Pottier E. An entropy based classification scheme for land applications of polarimetric SAR[J]. IEEE Transactions on Geoscience and Remote Sensing, 1997, 35(1): 68-78.
- [4] Harant O, Bombrun L, Gay M, *et al.* Segmentation and classification of polarimetric SAR data based on the KummerU distribution[C]. Proceedings of the Fourth International Workshop on Science and Applications of SAR Polarimetry and Polarimetric Interferometry (POLINSAR), 2009: 668.
- [5] Fay F A, Clarke J, Peters R S. Weibull distribution applied to sea clutter[C]. IEE Proceedings of Conference on Radar, 1977: 101-104.
- [6] Trunk G V, George S F. Detection of targets in non-Gaussian sea clutter[J]. IEEE Transactions on Aerospace and Electronic Systems, 1970, 6(5): 620-628.
- [7] Lee J S, Hoppel K W, Mango S A, *et al.* Intensity and phase statistics of multilook polarimetric and interferometric SAR imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 1994, 32(5): 1017-1028.
- [8] Lopez-Martinez C, Pottier E, Cloude S R. Statistical assessment of eigenvector-based target decomposition theorems in radar polarimetry[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(9): 2058-2074.
- [9] Doulgeris A P, Akbari V, Eltoft T. Automatic PolSAR segmentation with the u-distribution and Markov random fields[C]. 9th European Conference on Synthetic Aperture Radar, 2012: 183-186.
- [10] She X Q, Qiu X L, Lei B, *et al.* A classification method based on polarimetric entropy and GEV mixture model for intertidal area of PolSAR image[J]. Journal of Radars, 2017, 6(5): 554-563. 折小强, 仇晓兰, 雷斌, 等. 一种极化熵结合混合 GEV 模型的全极化 SAR 潮间带区域地物分类方法[J]. 雷达学报, 2017, 6(5): 554-563.
- [11] Li H C, Hong W, Wu Y R, *et al.* On the empirical-statistical modeling of SAR images with generalized gamma distribution[J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(3): 386-397.
- [12] Gou S P, Qiao X, Zhang X R, *et al.* Eigenvalue analysis-based approach for POL-SAR image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(2): 805-818.
- [13] Zhang D M, Fu M S, Guo H, *et al.* Automatic estimation algorithm of component number of mixture model based on penalized distance[J]. Journal of South China University of Technology (Natural Science Edition), 2009, 37(10): 101-107. 张大明, 符茂胜, 郭慧, 等. 基于惩罚距离的混合模型分量数自动估计算法[J]. 华南理工大学学报(自然科学版), 2009, 37(10): 101-107.
- [14] Akaike H. A new look at the statistical model identification[J]. IEEE Transactions on Automatic Control, 1974, 19(6): 716-723.
- [15] Wan J H, Zang J X, Liu S W. Fusion and classification of SAR and optical image with consideration of polarization characteristics[J]. Acta Optica Sinica, 2017, 37(6): 0628001. 万剑华, 臧金霞, 刘善伟. 顾及极化特征的 SAR 与光学影像融合与分类[J]. 光学学报, 2017, 37(6): 0628001.
- [16] Xie X F, Xu X, Dong H, *et al.* A semi-supervised dimension reduction method for polarimetric SAR image classification[J]. Acta Optica Sinica, 2018, 38(4): 0428001. 谢欣芳, 徐新, 董浩, 等. 一种极化 SAR 影像分类中的半监督降维方法[J]. 光学学报, 2018, 38(4): 0428001.
- [17] Ye Z, Bai L, Nian Y J. Hyperspectral image classification algorithm based on Gabor feature and locality-preserving dimensionality reduction[J]. Acta Optica Sinica, 2016, 36(10): 1028003. 叶珍, 白麟, 粘永健. 基于 Gabor 特征与局部保护降维的高光谱图像分类算法[J]. 光学学报, 2016, 36(10): 1028003.
- [18] Xie F C. Mixed hidden variable model and greedy EM

- algorithm[D]. Nanjing: Southeast University, 2003.
- 解锋昌. 混合隐藏变量模型和贪婪 EM 算法[D]. 南京: 东南大学, 2003.
- [19] Peng Y J, Chen J Y, Xu X, *et al.* SAR images statistical modeling and classification based on the mixture of alpha-stable distributions[J]. *Remote Sensing*, 2013, 5(5): 2145-2163.
- [20] Dong H, Xu X, Sui H G, *et al.* Copula-based joint statistical model for polarimetric features and its application in PolSAR image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(10): 5777-5789.