基于目标分解的极化 SAR 图像 SVM 监督分类*

张 祥[a,b], 邓喀中[a,b], 范洪冬[a,b], 赵 慧[a,b]
(中国矿业大学 a. 国土环境与灾害监测国家测绘局重点实验室; b. 江苏省资源环境信息工程重点实验室, 江苏 徐州 221116)

摘 要: 鉴于使用单一特征无法获得令人满意的分类效果以及 SVM 在小训练样本时具有良好的分类性能,提出了基于多种目标分解方法和 SVM 的极化 SAR 图像分类方法。首先对原始极化 SAR 图像使用多种目标分解方法进行处理,得到相应的分量信息,然后在极化 SAR 图像特征提取的基础上将 SVM 应用于极化 SAR 图像分类。通过选取不同的特征信息作为支持向量机的输入,比较其对分类性能的影响,得到最优的用于分类的特征信息组合,其中将相干分解和非相干分解的信息同时用做分类特征能够获得较好的分类效果。利用 NASA/JPL 实验室 AIRSAR 系统获取的全极化 SAR 数据进行实验处理,与 Wishart 监督分类进行对比,验证了将目标分解信息用做分类特征的有效性,同时与 Wishart/H/α 和模糊 C-均值 H/α 分类方法进行对比,得到提出的方法具有良好的分类性能。

关键词: 极化合成孔径雷达; 图像分类; 目标分解; 支持向量机; Wishart 迭代; 模糊 C-均值
中图分类号: TP391 **文献标志码**: A **文章编号**: 1001-3695(2013)01-0295-04
doi:10.3969/j.issn.1001-3695.2013.01.076

PolSAR SVM supervised classification method combining with polarimetric target decomposition

ZHANG Xiang[a,b], DENG Ka-zhong[a,b], FAN Hong-dong[a,b], ZHAO Hui[a,b]
(*a. Key Laboratory for Land Environment & Disaster Monitoring of SBSM, b. Jiangsu Key Laboratory of Resources & Environmental Information Engineering, China University of Mining & Technology, Xuzhou Jiangsu* 221116, *China*)

Abstract: Because the single feature cannot obtain the satisfactory classification result, and the SVM has the good classification performance with small training sample, this paper proposed a novel method based on the several target decomposition methods and PolSAR classification method based on SVM. First, it decomposed the original PolSAR image into corresponding component information by various target decomposition methods. Then in the basis of feature extraction, it applied the SVM to the PolSAR image classification. By choosing different feature information as the SVM input data and comparing the classification results, the optimal feature information combination could be obtained. Using the NASA/JPL laboratory AIRSAR system data as the experiment data, this paper made a comparison between the proposed method and the Wishart supervised classification to test the performance of the proposed method. The result verifies the proposed method is effective. And then, the paper carried out a further investigation on the comparison among the proposed method, Wishart/H/α method and fuzzy C-means H/α method, it indicates that the proposed method has good classification performance.

Key words: polarimetric synthetic aperture radar(PolSAR); image classification; target decomposition; support vector machine(SVM); Wishart iteration; fuzzy C-means

0 引言

全极化合成孔径雷达(PolSAR)提供了传统单极化 SAR 无法比拟的更多信息量,因此正确有效地提取极化信息已成为遥感数据处理的一个重要研究方向。针对极化特征的提取,学者们提出了多种极化 SAR 图像的目标分解方法,将其应用在分类中取得了较好的效果。支持向量机[1]是 Vapink 根据统计学理论于 1995 年前后提出的机器学习算法。它以最小结构风险代替了传统的最小经验风险,在模型的复杂性与学习能力之间寻求一种平衡,尽量提高泛化能力,即使由小样本得到的解,仍能保证较小的误差。求解的是一个二次型寻优问题,从理论上得到的将是全局最优解,并且其拓扑结构由支持向量决定,避免了神经网络方法中的过学习、维数灾难、局部极值以及网络拓扑结构设定的任意性等问题。

收稿日期: 2012-06-06; **修回日期**: 2012-07-25 **基金项目**: 国家自然科学基金资助项目(41071273);高等学校博士学科点专项科研基金资助项目(20090095110002);中央高校基本科研业务费专项资金资助项目(2010QNA21);江苏省博士后科研资助计划项目(1101109C);江苏高校优势学科建设工程资助项目(PAPD,SA1102)

作者简介:张祥(1987-),男,山西左云人,硕士研究生,主要研究方向为遥感图像处理(zhangxiangcumt@126.com);邓喀中(1957-),男,四川资中人,教授,博导,博士,主要研究方向为三下采煤、变形监测及控制、雷达数据处理等.

利用目标分解得到的信息和性能良好的分类器可以获得较好的分类效果[2~4],Qi 等人[5]在 2012 年提出了一种综合利用极化分解、极化干涉,面向对象分析和决策树算法的极化 SAR 图像分类方法,通过挖掘极化 SAR 图像中的大量信息验证各个组分的有效性,获得了很好的分类效果。本文提出基于目标分解的极化 SAR 图像 SVM 监督分类方法。

1 目标分解

目标分解(target decomposition)是极化 SAR 数据分析中的一种重要方法,其主要思想在于把数据与目标的物理特性联系起来,根据测量数据对目标结构进行物理描述和刻画。具体来说,目标分解是把一个随机媒质散射问题的各种矩阵表现形式(散射矩阵、Mueller 矩阵、协方差矩阵、相干矩阵等)描述为独立成分之和,并把每一种成分与相应的物理机制联系起来[6]。

1970 年荷兰学者 Huynen[7]在其具有开创性的博士论文《雷达目标唯象理论》中最早提出了目标分解理论。自 20 世纪 80 年代后期以来,在众多学者的不懈努力之下,目标分解理论蓬勃发展,各种新的分解方法层出不穷,逐渐形成了较为完整的理论体系。

目标极化信息提取主要基于协方差矩阵和相干矩阵。目标的极化散射特性可通过 2 × 2 的极化散射矩阵来表示,用下标 h 和 v 来表示一组天线收发极化状态,散射矩阵可表示为

$$S=\begin{bmatrix} s_{hh} & s_{hv} \\ s_{vh} & s_{vv} \end{bmatrix} \tag{1}$$

在满足互易定理的情况下,将目标的散射矩阵矢量化可以得到目标的散射矢量为

$$k_c=[s_{hh} \quad \sqrt{2}s_{hv} \quad s_{vv}]^{\mathrm{T}} \tag{2}$$

由目标散射矢量得到对应的协方差矩阵为

$$C=k_c\times k_c^{\mathrm{H}}=\begin{bmatrix} |s_{hh}|^2 & \sqrt{2}s_{hh}s_{hv}^* & s_{hh}s_{vv}^* \\ \sqrt{2}s_{hv}s_{hh}^* & 2|s_{hv}|^2 & \sqrt{2}s_{hv}s_{vv}^* \\ s_{vv}s_{hh}^* & \sqrt{2}s_{vv}s_{hv}^* & |s_{vv}|^2 \end{bmatrix} \tag{3}$$

其中:H 表示共轭转置,* 表示共轭。

散射矩阵还可以在 Pauli 分解的基础上进行矢量化得到目标的特征矢量为

$$k_T=\frac{1}{\sqrt{2}}[s_{hh}+s_{vv} \quad s_{hh}-s_{vv} \quad 2s_{hv}]^{\mathrm{T}} \tag{4}$$

对应的目标相关矩阵为

$$T=k_T\times k_T^{\mathrm{H}}=$$

$$\frac{1}{2}\begin{bmatrix} |s_{hh}+s_{vv}|^2 & (s_{hh}+s_{vv})(s_{hh}-s_{vv})^* & 2(s_{hh}+s_{vv})s_{hv}^* \\ (s_{hh}-s_{vv})(s_{hh}+s_{vv})^* & |s_{hh}-s_{vv}|^2 & 2(s_{hh}-s_{vv})s_{hv}^* \\ 2(s_{hh}+s_{vv})^*s_{hv} & 2s_{hv}(s_{hh}-s_{vv})^* & 4|s_{hv}|^2 \end{bmatrix} \tag{5}$$

根据对所处理目标的判断与理解不同,目标分解方法可分为相干分解和非相干分解两类,这两类方法是分别基于“确定性目标”和“分布式目标”提出的。确定性目标是当以全极化单色波照射时,其在给定观测条件下的电磁散射特性可以由一个极化散射矩阵进行表征的目标,即该目标具有稳态性;分布式目标是指散射特性是时变的或者本身由一组独立的子散射体所组成的目标,即该目标具有起伏性。

相干分解是把极化测量目标的原始散射矩阵用多个基本散射体的散射矩阵加权和来表示。基本散射体就是在空间任意维上的尺度远小于雷达分辨率的散射体,包括平板、球体、二面角、三面角等,携带了雷达照射目标返回的极化信息,并通过极化散射矩阵来表征,由于没有考虑到目标散射可能存在的随机性,适用于确定性目标分解。

相干分解的前提假设是目标的散射特性是确定性的或者非时变的,因而可以使用一些表征不同电磁散射特性的基本散射体来描述目标,目标的散射特性可由其中的某种散射体或几种散射体的组合来表征。基于此假设,相干分解通常将目标的散射矩阵分解为多个具有一定物理意义的散射矩阵,常见的相干分解包括 Pauli 分解[8]、Krogager 分解[9]和 Cameron 分解[10]等。

非相干分解引入了目标的多像素平均,将极化测量目标的平均散射矩阵表征为多个描述不同散射机理的散射矩阵组合。由于利用了目标的统计特性,因而更适用于分解分布式目标,并且通常散射波为部分极化态,对目标协方差矩阵和相干矩阵等进行非相干分解能够更加准确地解释目标的散射过程,并利于提取极化数据中包含的物理参数。

对于林地、城市等具有起伏性的复杂目标,每个像素的散射回波通常由多个散射体的散射信息混合叠加而成,由于相干斑噪声的存在,导致使用单个像素的散射矩阵很难准确描述对应地物目标的散射机理,同时没有有效利用各个极化通道之间的相关性信息。将统计描述(目标的平均散射矩阵)应用到这类分布式目标中,使用非相干目标分解来降低相干斑噪声的影响,并从统计角度描述目标的散射过程。常见的非相干分解包括 Huynen 分解[11]、Freeman 分解[12]和 Cloude 分解[13]等。

2 支持向量机

假定原始特征空间训练数据 $\{(x_1,y_1),\cdots,(x_l,y_l)\}$ $(x_i\in \mathrm{R}^n, y_i\in\{-1,1\}, i=1,2,\cdots,l)$ 可被超平面 $\langle\omega,x\rangle+b=0$ $(b\in \mathrm{R})$ 线性划分为两类,超平面必定满足 $y_i(\langle\omega,x_i\rangle+b)\geqslant 1$ $(i=1,2,\cdots,l)$,$\langle *,*\rangle$ 表示矢量内积。SVM 所求的最优超平面要使得分类间隔最大,这等价于求解二次规划问题:

$$\min_{\omega,b}\varphi(\omega)=\frac{1}{2}\langle\omega,\omega\rangle \tag{6}$$

$$\text{s.t.}\quad y_i(\langle\omega,x_i\rangle+b)\geqslant 1 \quad i=1,2,\cdots,l \tag{7}$$

基于最优分类超平面的判决函数为

$$f(x)=\mathrm{sgn}(\langle\omega^*,x\rangle+b^*)=\mathrm{sgn}(\sum_{i\in SV}y_ia_i^*\langle x_i,x\rangle+b^*) \tag{8}$$

其中,$a_i^*\geqslant 0$ 为上述二次规划问题的唯一解。

当原始特征空间中的训练数据线性不可分时,引入松弛变量 $\zeta_i\geqslant 0$ $(i=1,2,\cdots,l)$,使得允许存在错分样本,对应的优化问题为

$$\min_{\omega,b,\zeta}\varphi(\omega)=\frac{1}{2}\langle\omega,\omega\rangle+C\sum_{i=1}^{l}\zeta_i \tag{9}$$

$$\text{s.t.}\quad y_i(\langle \omega, x_i\rangle + b) \geqslant 1 - \zeta_i \quad \zeta_i \geqslant 0; i = 1,2,\cdots,l \tag{10}$$

其中:$C>0$ 为惩罚因子,用于控制对错分样本惩罚的程度。

注意到无论训练样本在原始特征空间中是否线性可分,求解其对应的优化问题以及最终得到的最优分类超平面都只需计算原始特征空间中样本之间的内积,而不需要知道原始特征空间到高维特征空间的非线性映射的具体形式。统计学习理论指出,满足 Mercer 定理的函数 $K(x,y)$ 可作为内积使用,且能以系数 $\eta_i>0$ 展开成 $K(x,y)=\sum_{i=1}^{\infty}\eta_i\psi_i(x)\psi_i(y)$,称之为核函数。引入核函数后,当样本在高维空间中不是线性可分时,可求得基于高维特征空间中广义最优分类超平面的决策函数为

$$f(x) = \mathrm{sgn}(k(\omega^*, x) + b^*) = \mathrm{sgn}(\sum_{i\in SV} y_i a_i^* K(x_i, x) + b^*) \tag{11}$$

3　基于目标分解的极化 SAR 图像分类

3.1　分类特征选取

分类特征的选取和分类器的使用是图像分类技术的关键所在。鉴于使用单一特征无法获得令人满意的分类效果,本文选用多种目标分解方法的分量用做分类特征信息,利用各种目标分解方法充分挖掘和提取极化 SAR 图像中包含的丰富信息,从而充分发挥极化 SAR 数据信息丰富的优点。在各种目标分解方法特征信息组合的基础上应用 SVM 进行极化 SAR 图像分类。

采用 Cloude、Huynen、Freeman、Krogager 目标分解方法对极化 SAR 图像进行处理,得到相应的分解信息,通过组合不同的极化信息完成分类特征的选取。五种特征组合如表 1 所示。

表 1　分类特征组合

组合	分解特征信息	组合	分解特征信息
1	Cloude & Freeman	4	Cloude & Freeman & Krogager
2	Freeman & Krogager	5	Cloude & Freeman & Huynen
3	Cloude & Huynen & Krogager		

3.2　分类过程

分类过程可以表述为:首先选取训练样本,然后选定分类特征组合,交叉验证优化 SVM 参数,最后进行分类处理,得到分类结果和相应的混淆矩阵。分类处理流程如图 1 所示。

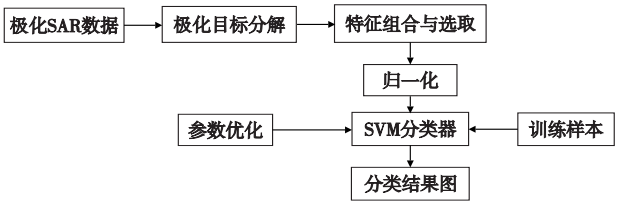

图1　SVM监督分类流程

4　分类实验

监督分类样本的选取对分类具有一定的影响,本文监督分类过程均采用同一组训练样本,并根据实地勘测信息和高分辨率光学遥感信息进行判读,选取了较理想的训练样本。选择径向基核函数进行 SVM 分类实验:利用交叉验证方法优化 SVM 径向基核函数的两个参数:惩罚因子和核函数宽度系数。

分别以表 1 列出的五组特征信息作为 SVM 的输入进行分类处理。图 2 ~ 6 分别给出五种特征组合 SVM 监督分类结果,图 7 为 Wishart 监督分类得到的结果。表 2 ~ 7 分别为五种特征组合 SVM 监督分类混淆矩阵和 Wishart 监督分类混淆矩阵。

表 2　Cloude & Freeman 特征组合 SVM 分类混淆矩阵

	C1	C2	C3	C4	C5	C6	C7	C8	C9
C1	93.85	0.03	0	0.24	0.08	0.03	0	3.53	2.25
C2	0	80.98	8.72	2.54	0.22	0.22	7.31	0	0
C3	0	12.4	78.81	0.96	0.04	0.84	6.9	0	0.04
C4	0.07	1.4	0.2	77.5	1.19	8.36	2.45	0.13	8.7
C5	0.12	0.31	0.17	8.47	78.79	5.18	1.9	0.78	4.27
C6	0.09	0.22	0.09	5.12	4.96	75.96	0.93	0.04	12.59
C7	0	6.82	4.36	4.54	2.12	2.68	77.1	0.09	2.25
C8	2.65	0	0	0.06	0.11	0	0	95.66	1.51
C9	0.67	0.51	0.16	4.94	4.94	1.17	0.31	1.53	85.78

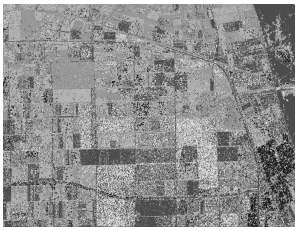

图2　Cloude & Freeman特征组合SVM分类

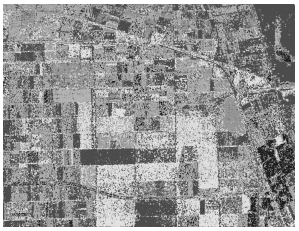

图3　Freeman & Krogager特征组合SVM分类

表 3　Freeman & Krogager 特征组合 SVM 分类混淆矩阵

	C1	C2	C3	C4	C5	C6	C7	C8	C9
C1	89.8	0.02	0	0.32	0.08	0	0	9.71	0.08
C2	0	92.32	2.01	0.89	0.52	0	4.25	0	0
C3	0	5.89	84.38	0.58	0.19	0.17	8.7	0	0.06
C4	0.01	0.67	0.06	83.3	8.89	6.11	0.41	0	0.55
C5	0.14	1.21	0.15	6.5	88.73	0.85	0.5	0.01	1.91
C6	0	0	0.02	6.88	1.41	86.66	0.02	0	5.01
C7	0	2.55	4.95	1.65	3.31	2.36	82.4	0	2.82
C8	3.63	0	0	0	0	0	0	94.95	1.43
C9	0	0	0.04	1.21	1.65	5.79	0	0.86	90.44

表 4　Cloude & Huynen & Krogager 特征组合 SVM 分类混淆矩阵

	C1	C2	C3	C4	C5	C6	C7	C8	C9
C1	98.26	0	0	0.27	0.06	0.08	0	1.14	0.19
C2	0	95.97	2.31	0.3	0	0.07	1.34	0	0
C3	0	4.22	86.28	0.15	0.28	0.02	9.1	0	0
C4	0	0.18	0.12	82.44	8.82	7.74	0.26	0	0.44
C5	0.03	0.81	0.2	8.65	83.16	5.91	0.54	0.03	0.68
C6	0.02	0	0.04	5.39	10.39	82.3	0	0.04	1.81
C7	0	2.13	3.83	0.57	5.33	2.99	84.4	0.03	0.69
C8	0.8	0	0	0	0	0	0	98.43	0.77
C9	0.39	0.04	0.2	0.82	1.57	8.97	0	0.9	87.11

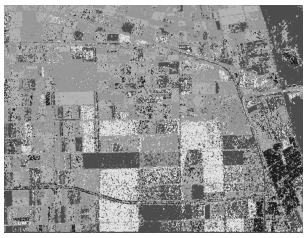

图4　Cloude & Huynen & Krogager特征组合SVM分类

图5　Cloude & Freeman & Krogager特征组合SVM分类

表 5 Cloude & Freeman & Krogager 特征组合 SVM 分类混淆矩阵

	C1	C2	C3	C4	C5	C6	C7	C8	C9
C1	97.71	0.02	0	0.27	0.06	0	0	1.77	0.17
C2	0	96.2	1.86	0.22	0.15	0	1.57	0	0
C3	0	5.42	88.97	0.43	0.11	0.11	4.97	0	0
C4	0	0.49	0.18	88.9	2.72	6.95	0.43	0	0.33
C5	0.04	0.93	0.17	8.23	85.56	2.79	0.65	0.03	1.61
C6	0.02	0	0.04	5.09	6.95	85.44	0.04	0	2.41
C7	0	3.17	4.72	1.29	2.12	1.92	83.99	0	2.8
C8	1.91	0	0	0	0	0	0	97.2	0.88
C9	0.2	0	0.16	0.94	2.66	6.93	0.04	0.94	88.13

表 6 Cloude & Freeman & Huynen 特征组合 SVM 分类混淆矩阵

	C1	C2	C3	C4	C5	C6	C7	C8	C9
C1	95.76	0.02	0	0.22	0.05	0.13	0	2.53	1.3
C2	0	87.4	6.41	0.6	0.6	0.07	4.92	0	0
C3	0	7.52	83.82	0.3	0.45	0.09	7.8	0	0.02
C4	0	0.59	0.13	86.19	6.17	5.69	0.45	0	0.78
C5	0.1	0.76	0.23	6.03	85.04	6.13	0.9	0.02	0.8
C6	0.09	0.09	0	6.9	5.41	83.9	0.04	0.09	3.48
C7	0	4.44	5.66	1.36	4.1	2.68	81.17	0.02	0.57
C8	2.23	0	0	0	0	0.03	0	96.89	0.86
C9	0.55	0	0	2.35	1.49	7.27	0.04	1.37	86.93

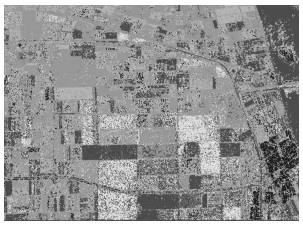

图6 Cloude & Freeman & Huynen 特征组合SVM分类

图7 Wishart监督分类

表 7 Wishart 监督分类混淆矩阵

	C1	C2	C3	C4	C5	C6	C7	C8	C9
C1	94.5	0.05	0	0.25	1.01	0	0.09	3.92	0.17
C2	0	63.24	6.64	4.85	4.77	0	20.51	0	0
C3	0	11.33	73.23	2.29	5.21	0.45	7.49	0	0
C4	0.2	0.79	0.03	72.34	7.33	10.17	6.57	0.11	2.46
C5	0.96	1.27	0.19	6.61	72.3	6.55	9.7	0.1	2.31
C6	0.33	0.26	0	9.57	9.92	66.06	6.68	1.67	5.51
C7	0.06	9.3	3.45	4.15	6.2	1.5	74.11	0.17	1.06
C8	21.64	0	0	0.14	0.54	0.97	1.2	72.37	3.14
C9	5.25	0.47	0	4.7	4.66	7.18	4.39	10.1	63.24

从定性和定量的角度对分类结果进行分析和比较，得到如下结论：

在相同的训练样本情况下，相比于 Wishart 监督分类，基于目标分解的极化 SAR 图像 SVM 监督分类方法能够获得更好的分类效果，验证了将目标分解信息用做分类特征的有效性。

不同特征集组合对分类结果有显著的影响，通过混淆矩阵的对比，将相干分解和非相干分解的特征分量同时用做分类特征时，获得了较理想的分类效果。说明单独的相干分解和非相干分解不能充分挖掘极化 SAR 图像中包含的丰富信息，将两者结合进行补充用于分类处理可以实现较好的效果。

此外，选用了两种典型的非监督分类方法作为对比实验，Wishart/H/α 分类和模糊 C-均值 H/α 分类，结果如图 8 所示。

与基于目标分解的极化 SAR 图像 SVM 监督分类相比，这两种方法混分和错分现象较严重，说明本文方法具有较强的实用性。

(a)Wishart/H/α 分类 (b)FCM/H/α 分类

图8 两种典型的非监督分类结果

5 结束语

通过实验结果对比和分析，得到本文提出的基于目标分解的极化 SAR 图像 SVM 监督分类方法能够实现较好的分类效果。同时选择不同极化目标分解的特征信息进行分类处理，得到不同特征组合对分类结果具有重要影响。根据不同特征信息组合得到的分类结果，分析得到将相干分解和非相干分解信息同时用做分类特征可以获得理想分类效果。

参考文献：

[1] VAPNIK V N. 统计学习理论[M]. 许建华，张学工，译. 北京：电子工业出版社，2004：364-384.

[2] 邹同元，杨文，代登信，等. 一种新的极化 SAR 图像非监督分类算法研究[J]. 武汉大学学报：信息科学版，2009，34(8)：910-913.

[3] 巫兆聪，欧阳群东，胡忠文. 应用分水岭变化与支持向量机的极化 SAR 图像分类[J]. 武汉大学学报：信息科学版，2012，37(1)：7-10.

[4] 张斌，马国锐，刘国英，等. 一种结合 Freeman 分解和散射熵的 MRF 多极化 SAR 影像分割算法[J]. 武汉大学学报：信息科学版，2011，36(9)：1064-1067.

[5] QI Zhi-xin, YEH A G O, LI Xia, *et al*. A novel algorithm for land use and land cover classification using RADAR-2 polarimetric SAR data[J]. Remote Sensing of Environment, 2012, 118(3): 21-39.

[6] CLOUDE S R, POTTIER E. A review of target decomposition theorems in radar polarimetry[J]. IEEE Trans on Geoscience and Remote Sensing, 1996, 34(2): 498-518.

[7] HUYNEN J R. Phenomenological theory of radar targets[D]. Netherlands: Technical University of Delft, 1970.

[8] CLOUDE S R. Group theory and polarization algebra[J]. Optic, 1986, 75(1): 26-36.

[9] KROGAGER E. A new decomposition of the radar target scattering matrix[J]. Electronics Letters, 1990, 26(18): 1525-1526.

[10] CAMERON W L, LEUNG L K. Feature motivated polarization scattering matrix decomposition[C]//Proc of IEEE International Radar Conference. 1990: 549-557.

[11] HUYNEN J R. Physical reality of radar target[C]//Proc of SPIE, vol 1748. 1992: 86-96.

[12] FREEMAN A, DURDEN S. A three-component scattering model for polarimetric SAR data[J]. IEEE Trans on Geoscience and Remote Sensing, 1998, 36(3): 963-973.

[13] CLOUDE S R, POTTIER E. Radar target decomposition theorems [J]. Electronics Letters, 1985, 21(1): 22-24.