

# 基于支撑向量机和超像素的极化 SAR 图像分类

韩景红, 王海江, 冉元波, 杨建华  
(成都信息工程大学电子工程学院, 四川 成都 610225)

**摘要:**针对极化 SAR 图像的分类方法多集中在像素级, 这些方法不仅运算量大, 而且分类效果较差, 提出一种利用支撑向量机和超像素分割相结合的方法对极化合成孔径雷达(PolSAR)系统图像分类。首先, 利用 SLIC 算法对 Pauli 分解后的极化 SAR 图像进行超像素分割。然后, 利用预处理后的数据得到高维的极化特征空间, 并利用监督局部线性嵌入(SLLE)算法对高维极化特征进行降维, 减少特征空间的冗余信息, 提取主要信息。最后, 以超像素为处理单元, 获得每个超像素内的特征, 利用支撑向量机(SVM)对超像素块进行分类, 获得初始类别分类结果, 之后, 使用 Wishart 分类器再次分类。实验结果表明所提的方法较基于像素点分类的方法能够得到更好的分类效果。

**关键词:**极化 SAR; 降维; 支撑向量机; 超像素; 分类

**中图分类号:** TN957.52

**文献标志码:** A

**doi:** 10.16836/j.cnki.jcuit.2018.04.004

## 0 引言

极化合成孔径雷达(Pol synthetic aperture radar, PolSAR)是一种主动的微波遥感成像雷达, 它通过接收地物反射的不同极化状态的回波, 得到地物目标的散射特性<sup>[1]</sup>。PolSAR 的成像原理与常规的光学遥感成像原理有本质区别, PolSAR 数据不仅与常见的光学图像表现特征不同, 包含的信息也不同。根据极化 SAR 得到的散射特性可以进行极化 SAR 图像的分类。

PolSAR 图像分类方法分为基于统计模型的和基于极化目标分解的方法<sup>[2]</sup>。基于统计模型的方法运用了统计建模和 Bayes 理论<sup>[3]</sup>, 统计模型是否正确建立决定了该分类方法的准确率。基于极化目标分解的方法不需要知道数据的概率分布也能实现对极化 SAR 图像的分类<sup>[4]</sup>, 比较经典的有:  $H/\alpha$ 、 $H/A/\alpha$  分解<sup>[5]</sup>、Pauli 分解<sup>[6]</sup>、Krogager 分解<sup>[7]</sup>等。

还有从其他角度对 PolSAR 图像进行分类的方法: 根据是否提前选取带有类别标签的训练样本, 可以将 PolSAR 目标分类方法分为有监督分类<sup>[8-10]</sup>和无监督分类<sup>[11-13]</sup>。有监督分类需要选取有标签的训练样本并根据样本的特征来处理未标记的 PolSAR 图像数据。对于无监督分类, 需要的先验知识则是对于地物后向散射特性的经验信息与模型描述。PolSAR 有监督分类中运用最普遍的是基于统计分布的 Bayes 分布和 Wishart 分布。Kong 等提出的基于复高斯分布的最大似然法是 PolSAR 分类使用 Bayes 的雏形。由于相干

斑的影响, 后来 Lee 等又提出了基于 Wishart 分布的多视 ML 分类, 后续的很多研究都是基于上面的分类模型进行的。无监督分类的整个过程中, 没有分类样本参与, 比较常见的算法有 K-Means 和 ISODATA 等。目前, 利用机器学习对 PolSAR 图像进行分类的方法成为主流方法, 例如: 神经网络和模糊聚类结合分类<sup>[14]</sup>、主成分分析和神经网络结合分类<sup>[15]</sup>、支撑向量机分类<sup>[16]</sup>等。

利用上述方法对 PolSAR 图像的分类更多的是基于像素点的分类, 由于存在相干斑噪声的影响, 因此基于像素点的分类效果比较差。结合像素之间的空间信息进行分类能够增加分类结果的鲁棒性。就上述问题提出了一种结合超像素的分类方法, 在分类过程中能够利用像素之间的空间信息, 分类效果更好。

## 1 分类特征选择及降维

### 1.1 分类特征选择

根据 PolSAR 的原始数据可以得到 PolSAR 图像每一个像素点的散射矩阵:

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

两个目标散射矢量分别为:

$$K_L = (s_{hh} \quad s_{hv} \quad s_{vv})^T \quad (2)$$

$$K_P = \frac{1}{\sqrt{2}} (s_{hh} + s_{vv} \quad s_{hh} - s_{vv} \quad 2s_{hv})^T \quad (3)$$

可以得到极化协方差矩阵  $C$  和极化相干矩阵  $T$ :

$$\mathbf{C} = [\mathbf{K}_L \mathbf{K}_L^H] \quad (4)$$

$$\mathbf{T} = [\mathbf{K}_p \mathbf{K}_p^H] \quad (5)$$

根据文献[17]提出改进的 sigma 滤波器对 Pol-SAR 数据滤波,再结合极化协方差矩阵  $\mathbf{C}$  和极化相干矩阵  $\mathbf{T}$  可以得到文中需要的特征参数。特征参数如表 1 所示,共 27 维。表 1 中,前 11 个极化特征是进行简单的算术运算而提取的极化参数,其优点是计算简单,能反映一部分极化信息。后 16 个极化特征参数是极化目标分解后的极化参数,这些极化参数可以表征目标的散射信息和几何结构信息<sup>[18]</sup>。

表 1 27 个特征参量

特征描述	特征参量
极化总功率	$ s_{hh} ^2 + 2 s_{hv} ^2 +  s_{vv} ^2$
HH-VV 相关系数的振幅	$\left  \frac{\langle s_{hh}s_{vv}^* \rangle}{\sqrt{ s_{hh} ^2  s_{vv} ^2}} \right $
HV/VV 通道比/dB	$10\lg\left(\frac{ s_{hv} ^2}{ s_{vv} ^2}\right)$
共极化比/dB	$10\lg\left(\frac{ s_{vv} ^2}{ s_{hh} ^2}\right)$
交叉极化比/dB	$10\lg\left(\frac{ s_{hv} ^2}{ s_{hh} ^2}\right)$
HH 通道后向散射系数	$\langle s_{hh}s_{hh}^* \rangle$
VV 通道后向散射系数	$\langle s_{vv}s_{vv}^* \rangle$
HV 通道后向散射系数	$\langle s_{hv}s_{hv}^* \rangle$
HH-VV 相位	$\arg(\langle s_{hh}s_{vv}^* \rangle)$
HH-HV 相位	$\arg(\langle s_{hh}s_{hv}^* \rangle)$
HV-VV 相位	$\arg(\langle s_{hv}s_{vv}^* \rangle)$
pauli 分解	$ a ^2,  b ^2,  c ^2$
Yamaguchi 分解	$f_h, f_s, f_d, f_v$
Cloud 分解	$H, \partial, A$
Krogager 分解(SDH)	$k_s, k_d, k_h$
Freeman-Durden 分解	$P_s, P_d, P_v$

## 1.2 监督局部线性嵌入算法

监督局部线性嵌入(SLLE)算法可以分为 3 步:

第 1 步,通过距离度量得到每个数据点的  $k$  个近邻点。通过距离公式可得到某数据点最近的  $k$  个数据点,并将这  $k$  个数据点视为该数据点的  $k$  个近邻点,该距离公式为

$$D' = D + \alpha \max(D) \Delta \quad (6)$$

其中  $D'$  是计算后的距离; $D$  是两点间的欧式距离; $\Delta$  的取值与类别有关,当两个数据点是同一类别时, $\Delta$  取

0,否则取 1; $\alpha \in [0,1]$  是控制监督程度的参数,它是一个经验值。

第 2 步,通过最小化重构损失来计算权重。损失函数定义为

$$\min \mathcal{E}(\mathbf{W}) = \sum_{i=1}^N \left| x_i - \sum_{j=1}^k \mathbf{w}_j^i x_{ij} \right|^2 \quad (7)$$

其中  $x_{ij}(j=1,2,\dots,k)$  是  $x_i$  的  $k$  个近邻点, $\mathbf{w}_j^i$  是  $x_i$  与  $x_{ij}$  之间的权重,约束条件为:  $\sum_{j=1}^k \mathbf{w}_j^i = 1$ 。构造一个矩阵  $\mathbf{Q}^i$  用来求矩阵  $\mathbf{W}$ , $\mathbf{Q}^i$  的表达式为

$$\mathbf{Q}_{jm}^i = (x_i - x_{ij})^T (x_i - x_{im}) \quad (8)$$

结合  $\sum_{j=1}^k \mathbf{w}_j^i = 1$ , 并利用拉格朗日乘子法,可以重构出最佳的权重向量:

$$\mathbf{w}_j^i = \frac{\sum_{m=1}^k (\mathbf{Q}^i)^{-1}_{jm}}{\sum_{p=1}^k \sum_{q=1}^k (\mathbf{Q}^i)^{-1}_{pq}} \quad (9)$$

在式(9)中,可能存在  $\mathbf{Q}^i$  是奇异矩阵的问题,因此需要把  $\mathbf{Q}^i$  变为

$$\mathbf{Q}^i = \mathbf{Q}^i + r\mathbf{I} \quad (10)$$

其中, $r$  是一个正则化参数, $\mathbf{I}$  是一个  $k \times k$  的单位矩阵。

第 3 步,将高维度的数据点映射到低维度中。映射后的损失函数为

$$\min \mathcal{E}(Y) = \sum_{i=1}^N \left| y_i - \sum_{j=1}^k \mathbf{w}_j^i y_{ij} \right|^2 \quad (11)$$

其中, $\mathcal{E}(Y)$  是损失函数, $y_i$  是  $x_i$  的低维表示, $y_{ij}(j=1,2,\dots,k)$  是  $y_i$  的  $k$  个近邻点,约束条件为

$$\sum_{i=1}^N y_i = 1, \frac{1}{N} \sum_{i=1}^N y_i y_i^T = \mathbf{I} \quad (12)$$

其中, $\mathbf{I}$  是一个  $m \times m$  的单位矩阵,利用稀疏矩阵的特性,可以重新定义损失函数:

$$\min \mathcal{E}(Y) = \sum_{i=1}^N \sum_{j=1}^N \mathbf{M}_{ij} \mathbf{y}_i^T \mathbf{y}_j \quad (13)$$

其中  $\mathbf{M}$  是一个  $N \times N$  的对称矩阵,其表达式为:

$$\mathbf{M} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W}) \quad (14)$$

最终结果需要满足最小化损失函数值,因此  $Y$  的取值为  $\mathbf{M}$  的最小  $m$  个非零特征值所对应的特征向量。

## 2 分类算法

### 2.1 支撑向量机

支撑向量机的作用就是利用超平面把各类别划分开。支撑向量机理论是由 Vapnik 和 Cortes 在 1995 提出用于解决模式识别问题的方法,当时的 SVM 属于一种线性的分类模型,而后 Boser、Guyon 和 Vapnik 等又引入核函数,提出非线性支撑向量机。支撑向量机是

基于 VC 维理论和结构风险最小化原理而构建的一种监督学习模型,主要用于数据回归分析和分类。SVM 比一般的学习机拥有更好的泛化和推广能力。

假设线性可分的样本集  $(x_i, y_i), i = 1, 2, \dots, n$ ,  $x \in \mathbb{R}^d, y \in \{+1, -1\}$ 。  $d$  维空间中的线性判别函数:  $g(x) = wx + b$ , 分类面方程为:  $wx + b = 0$ 。对样本进行归一化,使所有样本都满足  $|g(x)| \geq 1$ , 即离分类面最近的样本满足  $|g(x)| = 1$ , 这样分类间隔就等于  $\|w\|/2$ 。因此当满足  $\|w\|$  (或  $\|w\|^2$ ) 最小并且  $y_i(w x_i + b) - 1 \geq 0, i = 1, 2, \dots, n$  时的分类面就是最优分类面。

求最优分类面问题可以转化为如下约束优化问题

$$\min \varphi(w, b) = \frac{1}{2} \|w\|^2 \quad (15)$$

$$\text{st. } y_i(x_i \cdot w + b) - 1 \geq 0 \quad i = 1, 2, \dots, l \quad (16)$$

所以得到最优分类函数为

$$f(x) = \text{sgn}\{w^* \cdot x + b^*\} = \text{sgn}\left\{\sum_{i=1}^k a_i^* y_i (x_i \cdot x) + b^*\right\} \quad (17)$$

其中  $a^*, b^*$  为确定划分超平面的参数。

在线性不可分的情况下,可以在约束条件上增加一个松弛项  $\xi_i \geq 0$  成为

$$\text{st. } y_i(x_i \cdot w + b) - 1 + \xi_i \geq 0 \quad i = 1, 2, \dots, l \quad (18)$$

将目标改为求  $\frac{1}{2} \|w\|^2 + C(\sum_{i=1}^n \xi_i)$  最小,  $C > 0$  是一个常数。

在最优分类面中采用适当的核函数  $K(x_i, x_j)$  就可以实现某一非线性变换后的线性分类,而计算难度却没有增加。相应的分类函数也变为

$$f(x) = \text{sgn}\left\{\sum_{i=1}^k a_i^* y_i K(x_i \cdot x) + b^*\right\} \quad (19)$$

几种常用的核函数:线性核函数、多项式核函数、RBF 核函数、sigmoid 核函数。RBF 核函数是一种局部性强的核函数,能够实现非线性映射,并且 RBF 核函数需要确定的参数较少,函数复杂程度较低,因此大多数情况下优先使用高斯核函数。所以使用的 SVM 选用 RBF 核函数。

## 2.2 Wishart 分类

由于公式(4)、(5)满足复 Wishart 分布,所以可以根据每个像素点的相干矩阵对 PolSAR 图像分类,分类依据是 Wishart 距离:

$$D(T_i, T_j) = \ln |T_i| + \text{tr}(T_i^{-1} T_j) \quad (20)$$

其中  $T_i$  和  $T_j$  分别为  $i$  点和  $j$  点的相干矩阵。

具体分类步骤如下:

步骤 1 为每一类提供一个初始的相干矩阵  $T_m^k$ ,

$T_m^k$  为第  $m$  类自身相干矩阵的均值 ( $k = 0$ )。

步骤 2 用 Wishart 距离衡量  $T_i$  与  $T_m^k$  的距离,得到  $D(T_i, T_m^k)$ ,将  $i$  点归为最小  $D(T_i, T_m^k)$  时的  $m$  类。

步骤 3 用步骤 2 中的分类结果重新计算,得到  $T_m^{k+1}$ 。

步骤 4 回到步骤 2,继续迭代,直到规定的终止条件。

## 2.3 分类流程

提出的分类算法流程如下:

(1)数据预处理。读取 PolSAR 图像数据,并利用改进的 sigma 滤波器对相干矩阵进行滤波。

(2)提取极化特征。通过相干矩阵与散射矩阵,得到极化目标分解的散射机制、振幅等特征。

(3)SVM 分类、降维。提取各类别 5% 的训练样本,对 PolSAR 图像分类。利用 SLLE 算法并结合分类后的标签对高维特征进行降维处理。

(4)超像素分割。对 PolSAR 图像进行 Pauli 分解,得到伪彩色图像,然后利用 SLIC 算法进行超像素分割。

(5)提取超像素特征。提取超像素块内所有像素点的特征的均值作为此超像素块的特征。

(6)超像素分类。以超像素块为分类单元,利用 SVM 分类器分类。分类后的结果再以超像素块内所有像素点的相干矩阵的均值为特征,使用 Wishart 分类器迭代修正。

分类流程图如图 1 所示。

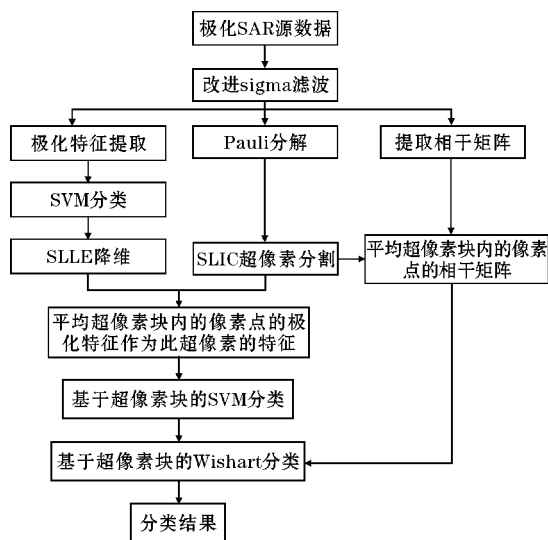


图1 分类流程图

## 3 仿真实验与分析

使用的数据是 L 波段全极化 SAR 数据,该数据是 1992 年 AIRSAR 系统在荷兰 Flevoland 地区获取的,选

取其中大小为  $223 \times 252$  的实验区域。该数据能够在 <https://earth.esa.int/web/polsarpro/home> 上下载,仿真工具为 Matlab2013b。在基于像素点和超像素的分类中,选择每个类别中 5% 的数据作为训练集,整个数据作为测试集,然后利用 SVM 对数据进行分类。利用 5 折交

叉验证的方法得到 SVM 的最优参数,SVM 采用 RBF 核函数,核参数的范围是  $[2^{-8}, 2^8]$ ,惩罚参数的范围是  $[2^{-8}, 2^8]$ 。为了验证基于超像素分类的优势,进行了基于像素点分类的对比实验。实验结果如图 2 所示。

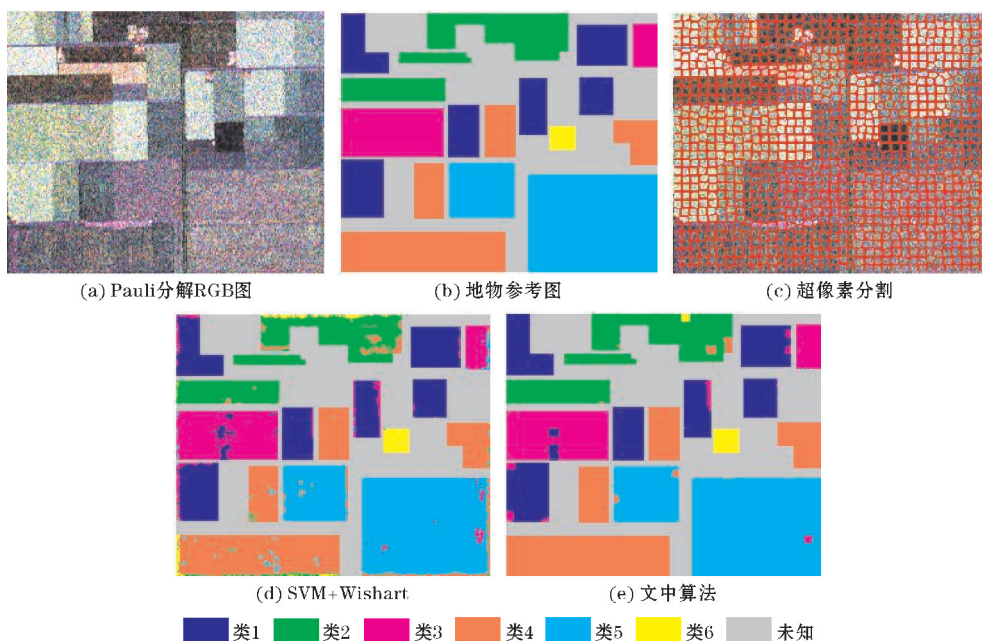


图2 Flevoland 地区实验结果

从分类效果上看,图 2(d)是基于像素级的分类,受相干斑噪声影响较大,各类中存在多个像素级的孤立点,影响图像解译,总体精度为 91.31%。图 2(e)是基于超像素的分类,相干斑的影响明显减少,噪声点较少,分类效果更加均匀,总体精度为 95.27%,有利于进一步的研究。从数据处理量来看,超像素能够降低处理单元的数量,降低运算量。文中数据在基于像素点分类时需要处理上万个像素点 ( $223 \times 252$ ),而基于超像素分类只需要处理 1061 个超像素块。

## 4 结束语

针对 PolSAR 图像基于像素级的分类存在缺陷,提出一种利用 SVM 与超像素相结合的方法对 PolSAR 图像分类。相较于像素级的分类方法,该方法结合了像素点之间的信息和空间信息进行分类,且运算量明显减少。首先,介绍了 PolSAR 图像常用的 SVM 分类器以及提取的高维极化特征。然后,运用监督局部线性嵌入算法对高维极化特征降维,得到低维特征空间。接着,以每个超像素内像素点的特征均值作为 SVM 分类时的特征对超像素进行分类。最后,以各类别的相干矩阵的均值作为特征,利用 Wishart 对分类后错分的类别进行迭代修正,并仿真得到了结果。通过与基于

像素点的分类结果比较可以得出,所提分类算法不仅运算量明显减少,而且分类效果更加好,准确率较高。

## 参考文献:

- [1] 付姣,张永红,刘晓龙,等. 利用 Yamaguchi 分解保持地物散射特性的极化 SAR 分类[J]. 测绘科学,2014,39(3):81-84.
- [2] Lee J S, Pottier E. Polarimetric Radar Imaging: From Basics to Applications [J]. Francis Group Boca Raton Isbn,2009.
- [3] 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.
- [4] Van Zyl J J. Unsupervised classification of scattering behavior using radar polarimetry data [J]. IEEE Transactions on Geoscience & Remote Sensing,1989,27(1):36-45.
- [5] Cloude S R, Pottier E. An entropy based classification scheme for land applications of polarimetric SAR[J]. IEEE Transactions on Geoscience & Remote Sensing,1997,35(1):68-78.

- [6] Cloude S R, Pottier E. A review of target decomposition theorems in radar polarimetry [J]. IEEE Transactions on Geoscience & Remote Sensing, 1996, 34(2): 498–518.
- [7] Krogager E. New decomposition of the radar target scattering matrix [J]. Electronics Letters, 1990, 26(18): 1525–1527.
- [8] 任俊英, 苏彩霞, 曹永锋. 基于中间层特征的全极化 SAR 监督地物分类 [J]. 遥感技术与应用, 2014, 29(2): 330–337.
- [9] Pottier E, Saillard J. On radar polarization target decomposition theorems with application to target classification, by using neural network method [C]. Antennas and Propagation, 1991. Icap 91. Seventh International Conference on. IET, 2002, 1: 205–268.
- [10] Chen K S, Huang W P, Tsay D H, et al. Classification Of Multifrequency Polarimetric Sar Imagery Using A Dynamic Learning Neural Network [J]. Geoscience & Remote Sensing IEEE Transactions on, 1996, 34(3): 814–820.
- [11] 许斌. 基于复 Wishart 分布的极化 SAR 图像无监督分类 [J]. 信息技术, 2016, 40(11).
- [12] Doulgeris A P, Anfinson S N, Eltoft T. Classification With a Non-Gaussian Model for PolSAR Data [J]. IEEE Transactions on Geoscience & Remote Sensing, 2008, 46(10): 2999–3009.
- [13] Lin L Q, Song H, Huang P P, et al. Unsupervised classification of PolSAR data using large scale spectral clustering [C]. Geoscience and Remote Sensing Symposium. IEEE, 2014: 2814–2817.
- [14] Chen C T, Chen K S, Lee J S. The use of fully polarimetric information for the fuzzy neural classification of SAR images [J]. IEEE Transactions on Geoscience & Remote Sensing, 2003, 41(9): 2089–2100.
- [15] Khan K U, Yang J. Novel Features for Polarimetric SAR Image Classification by Neural Network [C]. International Conference on Neural Networks and Brain, 2005. Icn&b. IEEE, 2005: 165–170.
- [16] 李平, 徐新, 董浩, 等. 利用可分性指数的极化 SAR 图像特征选择与多层 SVM 分类 [J]. 计算机应用, 2018, 38(1): 132–136.
- [17] Lee J S, Wen J H, Ainsworth T L, et al. Improved Sigma Filter for Speckle Filtering of SAR Imagery [J]. IEEE Transactions on Geoscience & Remote Sensing, 2009, 47(1): 202–213.
- [18] Krogager E. New decomposition of the radar target scattering matrix [J]. Electronics Letters, 1990, 26(18): 1525–1527.

## PolSAR Image Classification based on SVM and Superpixel

HAN Jing-hong, WANG Hai-jiang, RAN Yuan-bo, YANG Jian-hua

(College of Electronic Engineering, Chengdu University of Information Technology, Chengdu 610225, China)

**Abstract:** The classification methods for PolSAR images are mostly concentrated at the pixel level. These methods not only have a large amount of computation, but also have a poor classification effect. A method based on SVM and superpixel segmentation for polarimetric SAR image classification is proposed. Firstly, the SLIC algorithm is used to segment the polarimetric SAR image after Pauli decomposition. Then, the preprocessed coherence matrix is used to obtain the high dimension polarimetric feature space, and the Supervised Local Linear Embedding (SLLLE) algorithm is used to reduce the dimension. Finally, superpixel blocks are classified by SVM, and the classification result after being classified by SVM algorithm is classified by the Wishart classifier again.

**Keywords:** polarimetric SAR; dimension reduction; SVM; superpixel; classification