

基于旋转变换的农作物区双极化 SAR 散射特征 提取与分类研究

韩文涛¹, 王明续¹, 陈抒录², 高晗³, 汪长城⁴, 朱建军⁴

1. 湘潭大学 土木工程学院, 湘潭 411105

2. 湘潭市勘测设计院, 湘潭 411105

3. 中国石油大学 海洋与空间信息学院, 青岛 266580

4. 中南大学 地球科学与信息物理学院, 长沙 410083

摘要: 极化 SAR (合成孔径雷达) 凭借其全天时、全天候的优势, 在作物分类中具有重要作用。目前, 基于机器学习方法构建极化分解特征与作物之间的关联是实现极化 SAR 分类的重要途径。然而, 现有双极化分解方法常依赖于固定的散射模型, 仅能获取离散的散射特征, 限制了对作物复杂散射信息的细致表征。为此, 本文提出一种基于旋转变换的双极化 SAR 散射特征提取方法, 该方法利用表征双极化空间的两个极化参数构建旋转矢量, 观测矩阵在旋转矢量上的连续投影可获得海量连续散射特征, 从而更全面地反映不同作物的散射特性, 增强类间差异性。本文选取中国甘肃省金昌市与美国加利福尼亚州两个农田实验区进行实验。实验结果显示, 与现有双极化分解方法相比, 在金昌实验区, 新方法分类精度达 96.10%, 较 C_2 矩阵、Stokes 分解和 Cloude 分解分别提升 4.73%, 2.23%和 2.83%; 在加利福尼亚实验区, 分类精度为 93.01%, 较上述方法分别提升 5.07%, 3.19%和 3.13%, 证明本文方法在不同农业场景下均具有稳定的分类性能提升。

关键词: 双极化 SAR; 连续散射特征; 农作物分类; 旋转变换

中图分类号: P237/P2

引用格式:

[DOI:]

收稿日期: ; 预印本:

基金项目: 国家自然科学基金(编号: 42501462); 湖南省自然科学基金(编号: 2025JJ60236); 湖南省教育厅优秀青年基金(编号: 25B0158)

第一作者简介: 韩文涛, 男, 博士, 研究方向为 SAR 模型分解与应用研究。E-mail: xtuhwt@xtu.edu.cn

合成孔径雷达 (Synthetic Aperture Radar, SAR) 是一种通过微波波段探测并获取地面观测信息的遥感技术 (吴一戎, 2013)。相较于光学成像技术, SAR 具备全天时、全天候工作的能力, 已成为对地观测领域的重要工具。在 SAR 成像基础上引入极化测量, 利用不同极化通道之间的幅度与相位差异, 可更精细地反演作物特性 (韩文涛 等, 2025)。全极化 SAR 系统可获得 HH、HV、VV、VH 四种极化信号 (Lee 和 Pottier, 2009), 获取全面的散射信息, 但其幅宽相对较窄、空间分辨率相对较低 (史磊 等, 2025; 曹卓岳, 2022)。单极化系统虽具有较宽的幅宽和较高的分辨率, 但极化信息有限, 不利于高精度分类 (吴永辉 等, 2008)。相比之下, 双极化模式在兼顾幅宽和分辨率的同时, 能够保留相对丰富的极化信息, 因此在农作物分类等应用中展现出显著潜力 (孙维东 等, 2025; 李煜 等, 2024)。

在 SAR 作物分类的监督学习框架中, 通常采用特征驱动的分类范式 (Zhang 等, 2011; 陈晋 等, 2025)。首先通过目标分解等技术从原始 SAR 数据中提取反映作物差异的特征, 再将这些特征作为输入, 利用机器学习算法学习不同作物类别在特征空间中的分布模式, 从而建立从散射特征到作物类别的映射关系, 实现对整个观测场景的作物分类 (徐丰 等, 2017; Krizhevsky 等, 2012; Xiang 等, 2022; Yu 等, 2024)。因此, 如何从 SAR 数据中提取丰富、具有区分能力的散射特征, 成为提升分类精度的关键 (沈明辉, 2020; 张腊梅, 2010)。在这一过程中, 目标分解技术发挥着核心作用, 它能够将观测矩阵分解为具有明确物理意义的散射成分, 从而为分类模型提供可解释的特征输入 (Yang 等, 2006; 陈启浩 等, 2014; Chen 等, 2014)。

目前, 极化 SAR 分解方法的研究已取得长足发展, 学者们相继提出各种目标分解方法, 常用的方法有相干分解 (Huynen 等, 1970; Li 等, 2012) 和非相干分解方法 (Freeman 等, 1998; Li 等, 2020)。相干分解的研究对象是确定的目标, 其散射回波必然是相干的, 不受外界环境或目标变动造成的干扰。然而, 这类分解往往忽视相干斑噪声的影响, 难以应对随时空变化的分布式观测目标。多数情况下自然界中的作物是呈分布式的, 因此非相干分解方法在这类情景下关注度更高 (王婷婷, 2024)。经典的非相干分解方法有 Freeman-Durden 三分量分解 (Freeman 和 Durden, 1998)、Yamaguchi 四分量分解 (Yamaguchi 等, 2005) 和 Freeman 二分量分解 (Freeman, 2007)。

上述分解方法主要针对全极化矩阵设计, 难以直接应用于双极化数据的散射特征提取。为此学者们基于双极化数据提出了一系列分解方法。Cloude 将针对全极化矩阵的特征值分解进行降维变化并应用于双极化矩阵。该方法已成为现有双极化数据解译和作物分类的主流手段, 然而其存在物理意义不明确的问题, 其应用前景受到相应制约 (Cloude, 2007; Cloude 和 Pottier, 1997)。对于 Cloude 双极化分解, α 和 δ 参数分别从振幅与相位两个维度, 协同描述了作物的几何结构与空间分布特征。其中, α 反映极化通道的振幅比值, 可定量表征作物从

稀疏到茂密的变化； δ 表征通道间的极化相位差，对冠层的空间分布与各向异性敏感。两者的协同应用，为区分不同散射特性的作物提供了特征支撑。此外，Cloude 分解最初并未给出 $H - \alpha$ 平面的明确分割标准。针对这一问题，Ji 和 Wu（2015）提出了改进的双极化公式，系统分析了不同双极化组合对散射机制提取能力的影响，并通过实验确定了双极化 $H - \alpha$ 平面的最优分界线。对于基于模型的双极化分解，2022 年，Mascolo 提出了基于 Stokes 矩阵的分解方法，其将观测数据分解为极化部分和非极化部分，分别对应地表散射和体散射，这是对双极化分解的重要补充（Mascolo 等，2022）。

然而上述分解方法局限于特定模型来解译 SAR 信号，只能得到特定且离散的散射特征，这些散射特征在探索具有复杂空间分布的作物场景时，难以保持稳定的分类精度（陈思伟 等，2017；Han 等，2023）。鉴于此，本文提出一种基于旋转变换的 SAR 散射特征提取方法，通过旋转矢量驱动回波信号在极化空间中进行连续变换，从而获得包含更丰富作物信息的连续散射特征，增强不同作物之间的可分性，提升分类精度。

2 实验区及数据介绍

本文选取中国甘肃省金昌市和美国加利福尼亚州的农作物区进行实验。金昌地区主要种植的作物包括春小麦、油菜、玉米、洋葱、苜蓿和娃娃菜；美国加利福尼亚州索拉诺县则以向日葵、冬小麦、苜蓿、番茄、三叶草、杏仁和核桃为主要种植作物。两地作物结构差异明显，金昌以耐旱型粮食作物和蔬菜为主；加利福尼亚州则侧重于高价值经济作物和果树，依托地中海气候下的灌溉农业体系。选择不同气候、不同作物类型和不同数据来源的研究区交叉对比，为验证旋转变换方法的跨气候、跨作物适用性提供了典型样本。本文选取欧洲 Sentinel-1 卫星数据作为实验数据。该卫星搭载 C 波段传感器，具有全天时、全天候的观测能力。金昌实验区影像的成像日期为 2018 年 6 月 19 日；加利福尼亚实验区影像的成像日期为 2024 年 7 月 23 日。

2.1 金昌实验区

金昌市实验区位于永昌县，地理位置为东经 102° 、北纬 38° 。所选实验区包含两个区域，这两个区域被同一景影像覆盖，同时参与分类。但二者在海拔和气候条件具有显著差异性，且间距较远，为了便于分析，本文将这两个区域分开展示。金昌农田区不同作物的像素总数量如表 1 所示。对于图 1 的背景区域，其中包含了农业区和城区。金昌实验区的验证数据来源于实地测量，受野外调查条件限制，测量范围有限，因此部分农业区未纳入分类与验证范畴。金昌 A 和 B 区域面积分别约为 700 km^2 和 200 km^2 。为准确获取地面真实分类图，前期已开展了实地样地调查实验。在识别作物类型时，首先调查作物的关键形态特征，再结合农学专家知识中关于作物不同物候期的形态特征，二者交叉对比，识别同样地作物的类别。A 区域小麦的播种日期要晚于 B 区域小麦的播种日期，这是因为海拔差异，A 区域在过冬后的气温上升要比 B 区域气温上升更晚更慢。此外，A 区域小麦的生长周期仅有 120 天，比 B 区域小麦的生长周期要少 40 天。




图 1 甘肃省金昌农田实验区概况

Fig.1 Overview of farmland experimental areas in Jinchang, Gansu

表 1 金昌农田区不同作物的像素总数量

Table 1 Total number of pixels for different crops in Jinchang farmland areas

实验区	地物类型	像素总数量
金昌	小麦（A 区域）	66406
	油菜	25084
	小麦（B 区域）	72362
	玉米	19276
	洋葱	11516
	苜蓿	38562
	娃娃菜	36367
	裸土	43512

2.2 加利福尼亚州实验区

加利福尼亚州实验区地处加州中央谷地的核心农业带，地理位置为西经 122 度，北纬 39 度。实验区水热条件优越，气候条件温和，是典型的地中海气候。同时，土壤肥沃且地势平坦有利于大面积机械化种植。该数据集是一种年度更新，覆盖美国本土 48 个州的针对特定作物的土地覆盖数据集，空间分辨率为 10m。如图 2 所示，加利福尼亚州实验区面积约为 700 km²，背景区域主要为农业区，地面验证数据来源于美国农业部国家农业统计局。该研究区包含 68 种地物类型，剔除非农作物后，选取占比最多的 8 种作物作为分类对象，作物生长周期如图 3 所示，其余地物均予以掩膜处理，不同作物的像素总数量如表 2 所示。




图 2 美国加利福尼亚州农田实验区概况

Fig.2 Overview of farmland experimental areas in California, USA




图 3 美国加利福尼亚州农田实验区作物常规播种与收获日期

Fig.3 Conventional planting and harvesting dates of crops in farmland experimental areas in California, USA

表 2 加利福尼亚农田区不同作物的像素总数量

Table 2 Total number of pixels for different crops in the California farmland area

实验区	地物类型	像素总数量
加利福尼亚	玉米	124500
	向日葵	124538
	冬小麦	111677
	苜蓿	296783
	番茄	277461
	三叶草	308884
	杏仁	351611
	核桃	114104

3 基于旋转变换的双极化 SAR 散射特征提取

双极化 SAR 系统采用单极化发射与双极化接收模式，通过发射单一极化状态的电磁波，同步接收作物散射波的水平和垂直极化分量（Lee 和 Pottier，2009）。通过矢量化双极化信号，将散射矢量与其共轭转置相乘，最后进行集合平均处理可得到双极化协方差矩阵：

$$\mathbf{C}_2 = \begin{pmatrix} E_{HH}E_{HH}^* & E_{HH}E_{HV}^* \\ E_{HV}E_{HH}^* & E_{HV}E_{HV}^* \end{pmatrix} \quad (1)$$

双极化协方差矩阵蕴含了作物几何物理属性，在进行分类前，有必要从矩阵中提取出能反映不同作物散射差异的特征。2007 年，Cloude 提出了双极化 SAR 特征值分解方法。该方法的核心在于不依赖于特定的统计分布假设，从而避免了多变量模型物理约束带来的局限性（Cloude，2007）。另一方面，从物理模型的角度，Mascolo 提出了一种基于 Stokes 矢量的广义模型分解方法。该方法结合了波极化理论，将 Stokes 矢量分解为部分极化波和完全极化波两个分量，分别对应体散射和地表散射过程（Mascolo 等，2022）。

然而，上述方法通常基于固定的散射模型进行特征提取，这一局限易导致作物散射信息不能被充分获取，难以满足复杂场景下精细化分类的需求（陈思伟 等，2017；Han 等，2023）。为克服固定视角带来的局限性，本文提出一种面向双极化数据的极化空间旋转变换方法，以期挖掘常规散射模型下难以被探索的作物属性。

首先，由两个极化参数构成的特征矢量 $\mathbf{u}$ 可以表示为（Cloude，2007）：

$$\mathbf{u} = \begin{pmatrix} \cos \alpha \\ \sin \alpha e^{j\delta} \end{pmatrix} \quad (2)$$

其中， α 和 δ 分别为极化散射角和极化相位角， α 值的大小由同极化和交叉极化通道的相对幅度决定，取值范围为 $[0, \pi/2]$ ； δ 值的大小则由相对相位决定，变化范围为 $[-\pi, \pi]$ 。 α 和 δ 共同构成了极化庞格莱球（Cloude，2007）。由于双极化数据缺少一种同极化观测，现有的面向全极化数据的散射特征提取方法难以直接应用于双极化数据。

接着，将双极化 SAR 观测矩阵投影到不断旋转变换的特征矢量上：

$$P(\alpha, \delta) = \mathbf{u}^{*T} \begin{pmatrix} C_{11} & C_{12} \\ C_{12}^* & C_{22} \end{pmatrix} \mathbf{u} \quad (3)$$

其中，上标*和T分别表示共轭和转置， C_{ij} 为双极化协方差矩阵 $\mathbf{C}_2$ 的第 (i, j) 个元素， P 为散射能量。通过旋转矩阵驱动 $\mathbf{C}_2$ 在极化空间中旋转变换，可得到海量连续的散射特征。例如，当 $\alpha = 0^\circ$ 时， $P(\alpha, \delta) = HH$ ； $\alpha = 90^\circ, \delta = 0^\circ$ 时， $P(\alpha, \delta) = HV$ 。有趣的是， $P(\alpha, \delta)$ 对 α 求偏导，并令偏导数等于 0 的过程等价于 Cloude 特征值分解。这说明旋转变换方法可以挖掘现有散射模型所对应的散射特征。这得益于旋转变换方法未固定散射模型形式，散射模型可以无约束的自由变换。

随后，采用三维图像的形式展示上述连续散射特征。如图 4 所示，横坐标和纵坐标分别为两个变化的极化参数，纵坐标为于极化参数相对应的散射能量。




图 4 连续散射特征的三维可视化图

Fig.4 3D Visualization of continuous scattering characteristics

由上图可知，旋转变换方法将两个极化通道的观测生动的展示为三维图像。然而，上述三维图像难以直接用于作物分类，为此有必要基于三维图像进一步定义特征参数。本文对双极化能量 $P(\alpha, \delta)$ 进行统计分析，提取以下特征：

(1) 最大能量值

$$P_{\max} = \max_{\alpha, \delta} P(\alpha, \delta) \quad (4)$$

该特征为三维图像中能量的最值，如图 4 中的黑色圆点所示，其对应作物主导结构所产生的散射强度。裸地和冠层不发达区域的最大能量值低，高大农作物区则较大。

(2) 总功率

$$Span = P(\alpha = 0^\circ) + P(\alpha = 90^\circ, \delta = 0^\circ) = HH + HV \quad (5)$$

该特征表征了 2 个通道的总后向散射强度，如图 4 中的 2 个灰色圆点所示。总能量与作物结构和分布密切相关。此外，作物的湿度也会显著影响总能量，湿度越大总能量也越大。

(3) 极化对比度

$$Contrast = \frac{P_{\max} - P_{\min}}{P_{\max} + P_{\min}} \quad (6)$$

该特征表示散射能量的最大变化量，其值越接近 1，表征作物去极化程度越弱；值越接近 0，表征作物去极化程度越高。

(4) 偏度

$$Skew = \frac{|E[(P(\alpha, \delta) - \mu)^3]|}{\sigma^3} \quad (7)$$

该特征描述能量分布的不对称性，通过一系列能量（图 4 中的红线）计算得出。红线通过最大能量，并垂

153 直于 y-z 轴平面。偏度越大，表示能量分布越向一侧倾斜，作物的各向异性越明显。偏度越低，表征作物各向异
154 性较低，例如裸地。不同于上述三个特征，偏度是传统分解方法难以挖掘的散射特征，由一系列连续散射能量
155 计算得来。

156 (5) 平滑度

157
$$Smooth = \frac{1}{std(\Delta P(\alpha, \delta))} \quad (8)$$

158 $std(\Delta P(\alpha, \delta))$ 是相邻角度功率差分的标准差，同样通过一系列能量（图 4 中的红线）计算得出。该特征表征
159 散射体对极化方式的敏感程度， $std(\Delta P)$ 越大，平滑度越小，散射体产生的后向散射强度对极化方式的变化越敏
160 感。这一参数与偏度参数一致，均只能被连续散射模型所挖掘。

161 4 散射特征对作物的可区分性分析

162 基于第 3 节提出的极化空间旋转变换方法，可以提取一系列表征不同作物差异的特征参数，其中连续散射
163 特征参数是现有传统分解模型难以提取的，这里深入分析这些参数对作物的可区分性。

164 4.1 金昌实验区

165 如图 5 和图 6 所示，在能量最大值方面，娃娃菜区域展现出最突出的响应，油菜区域次之；六月成像期间，
166 进入成熟期的娃娃菜与油菜凭借其宽大叶片和茂密冠层结构产生强烈的表面散射与体散射贡献，使该特征能区
167 分这两类作物。总能量特征进一步强化了作物间的区分能力，呈现出从娃娃菜、油菜、苜蓿到裸土的梯度递减
168 趋势，系统反映了植被覆盖度与生物量对总后向散射强度的影响。在对比度特征中，小麦区域的极化对比度值
169 处于中等水平，其去极化程度明显高于多数作物，该特征揭示小麦高大结构引发的多重散射机制。对于偏度特
170 征，油菜区域明显偏低的偏度值反映出油菜冠层散射能量分布的对称特性，与其它作物形成明显对比。平滑度
171 特征方面，玉米呈现的低平滑度表明其散射特性对极化方式变化极为敏感，这主要源于玉米直立茎秆结构带来
172 的显著方位性散射效应。综上，通过旋转变换提取的散射特征能系统捕捉不同作物的结构特性与散射机制差异。




图 5 金昌 A 实验区的真实分类图和散射特征参数分布图

Fig.5 Ground truth classification map and distribution maps of scattering parameters for the Jinchang A experimental area





图 6 金昌 B 实验区的真实分类图和散射特征参数分布图

Fig.6 Ground truth classification map and distribution maps of scattering parameters for the Jinchang B experimental area

为了进一步挖掘新方法中散射特征对作物的区分能力，在图 5 和图 6 中选择 T1 和 T2 两个区域进行放大分析。如图 7 所示，对于 T1 区域，Stokes 分解和 Cloude 分解中的 α_g 和 α 均无法区分小麦和油菜，这两个区域的 α_g 和 α 均较大或较小。 C_{11} 对这两个区域的区分能力有些许提高，小麦区域的 C_{11} 值略低于油菜区域。对比上述特征，旋转变换方法中的偏度可区分两种作物，小麦区域的偏度值显著大于油菜区域。对于 T2 区域， C_{11} 和两种分解模型中的参数均无法区分小麦、玉米和洋葱，三个区域的值呈现高度的同质性。然而，对于旋转变换方法中的对比度特征，玉米区值最高，小麦区次之，洋葱区最低，有效的识别了三种不同的作物。

185 进一步分析不同作物的类内一致性，可以发现作物在不同特征视野下，类内一致性存在差异。Stokes 分解
 186 导出的 α_g 展现了最高的类内一致性，其在不同地块间取值平稳，受噪声与局部差异影响较小。然而，这种稳定
 187 性是以牺牲类间差异为代价的。 α_g 在不同作物类别间的数值波动微弱，导致特征空间中各类别高度重叠，难以
 188 形成有效的决策边界。相比之下，新方法中的偏度特征对作物冠层结构变化较为敏感，在不同作物间呈现出显
 189 著的数值梯度。但是，它在强化类间差异的同时，也同步放大了同类作物内部环境因素差异导致的散射随机性，
 190 导致其类内一致性在所有特征中处于较低水平。



191
 192 图 7 T1 和 T2 区域真实分类图和散射特征参数值放大图

193 Fig.7 Enlarged views of the ground truth map and the distribution of parameter values for the T1 and T2 areas

194 4.2 加利福尼亚实验区

195 如图 8 所示，对于加利福尼亚实验区，不同作物同样呈现出明显的区分性。在最大值特征视角下，向日葵
 196 与苜蓿具有较好的可区分性，其中苜蓿处于收割期的中期，散射能量最大值较低；向日葵刚开始收割，其高大
 197 植株与密实冠层结构，表现出较高的散射能量最大值。在总能量特征视角下，向日葵和苜蓿的总能量两级分化，
 198 有助于进一步将二者从观测场景中区分出来；此外，杏仁区域在该特征中呈现独特的中等取值，这与其较为均
 199 匀的树冠结构相关，使其能有效与其他作物区别。在对比度特征中，冬小麦的数值最为突出，反映了收割期后
 200 期的冬小麦地块产生的散射贡献极化程度较高。在偏度特征下，三叶草表现出明显高于其他区域的数值，偏度
 201 越大表明散射能量分布越不均衡。在平滑度特征方面，不同作物对极化方式的敏感程度存在显著差异，依次表
 202 现为冬小麦、苜蓿、三叶草、番茄、向日葵；平滑度数值越小，表明作物散射响应随极化状态变化越强烈，进一
 203 步揭示了不同作物结构对极化方式敏感性的系统性差异。




图 8 加利福尼亚实验区的真实分类图和散射特征参数分布图

Fig.8 Ground truth map and distribution maps of scattering parameters for the California experimental area

进一步选取图 8 中的 T3 和 T4 两个区域进行放大分析。如图 9 所示，对于 T3 区域，Stokes 和 Cloude 分解中的参数能识别冬小麦区域，冬小麦区域的 α_g 和 α 明显低于其他区域。然而，这两个参数无法有效区分核桃和番茄。另一方面， C_{11} 对三种作物的识别能力均不足，三种作物的 C_{11} 均未呈现可区分的差异。对于旋转变换方法中的平滑度，冬小麦区域最大，玉米区域次之，番茄区域最低，有能力将这三种作物区分开。在 T4 区域，Stokes 和 Cloude 分解中的参数在不同作物区存在相互矛盾和混乱，难以区分四种作物。最大值和 C_{11} 值的视角下，四种作物的区分度较强，尤其对于旋转变换方法中的最大值，呈现从向日葵、番茄、杏仁、苜蓿依次降低的梯度变化，有利于作物分类。

通过对不同特征视野下作物类内一致性的深入分析，可以发现不仅同类作物之间的特征一致性较弱，即使在同一地块内部，特征分布也呈现出较高的离散性。这一现象可能源于局部环境异质性对极化响应的调制作用。土壤水分分布不均、微地形起伏、植被种植密度时疏时密等因素叠加在一起，掩盖了作物本身的极化散射共性。这些干扰因素反映在特征空间中，使原本应一致的像素点之间出现了明显差异。




图 9 T3 和 T4 区域真实分类图和散射特征参数分布放大图

Fig.9 Enlarged views of the ground truth map and the distribution of parameter values for the T3 and T4 regions

5 分类结果与分析

随机森林是一种集成学习算法，由多个决策树组成，广泛用于分类、回归等任务。其核心思想是通过构建大量相互独立的决策树，并将它们的预测结果进行集成，从而提升模型的准确性和鲁棒性（王树兰 等，2025）。此外，随机森林在对 SAR 影像进行作物分类时，每一个决策树相互独立决策且都由随机特征和随机样本构成，可以避免数据过拟合，因此本文采用随机森林作为分类器。在样本选取阶段采用分层随机采样策略（Aires 等，2025），针对不同作物类别样本数量存在的不平衡问题，分层采样能够保证每一类作物在训练集和测试集中均保持相同的分布比例，即严格按照 50%:50%的比例划分训练集和测试集。模型基于 MATLAB 的树袋装算法实现，决策树数量为 300 棵，最小叶子节点大小为 5，节点分裂准则采用偏差减少，每棵树在分裂时考虑全部特征。分类方法所采用的散射特征参数如表 3 所示，分别为 C_2 矩阵元素、Cloude 分解、Stokes 分解和旋转方法得到的散射特征。

表 3 双极化 SAR 数据的四组分类特征


Table 3 Four sets of classification features of dual-polarization SAR data

分解方法	C_2 极化矩阵	特征值分解	Stokes 分解	新方法
散射特征参数	C_{11} C_{12} C_{22}	H	m_p m_v α_g δ	最大值
		A		总能量
		α		对比度
		λ_1		偏度
		λ_2		平滑度

5.1 金昌实验区

图 10 展示了金昌 A 区域基于不同方法的农作物分类结果。目视效果上，基于旋转变换方法的分类结果整

235 体表现最优，不同类别之间相互错分现象较少。细节上，对于苜蓿区域，除旋转变换方法外，其他三种方法均
236 在不同程度上将部分苜蓿像元错误地划分为小麦。本文提出的方法通过构建极化参数空间中的连续投影，能提
237 取如偏度、平滑度等反映散射能量分布的连续散射特征。这些特征对作物冠层结构的细微差异更为敏感，能捕
238 捉苜蓿与小麦在散射响应上的区别，从而实现对二者的区分。此外，旋转变换方法在区分娃娃菜与油菜两类作
239 物上也表现出更高的准确性，错分明显减少。



240


241

242

图 10 金昌 A 区域基于不同方法的作物分类结果和错分图

Fig.10 Crop classification results and misclassification maps for the Jinchang A experimental area

243 图 11 展示了金昌 B 区域的分类结果。总体而言，四种方法对于小麦与裸土这两类作物均表现出良好的识别
244 能力，分类结果均质，反映了这些作物在基础极化特征上具有较好的可分性。然而，对于结构复杂的玉米与洋
245 葱作物，现有方法均表现出明显的局限性。具体而言，现有方法的分类结果中，玉米区域被无规律地错分为包
246 括小麦、油菜在内的多种作物。此现象在基于 Cloude 分解的分类结果中尤为显著，其分类图斑呈现出较高的类
247 别混乱。类似地，洋葱区域在现有方法的分类结果中也存在大面积误判。本文方法在玉米与洋葱的分类上均取
248 得了提升。



249

250

251

图 11 金昌 B 区域基于不同方法的作物分类结果和错分图

Fig.11 Crop classification results and misclassification maps for the Jinchang B experimental area

252 表 4 列出了金昌 A 和 B 实验区基于不同特征参数的定量分类精度。在总体分类精度上，本文方法分类精度
253 达到 96.10%，较 C_2 矩阵、Stokes 分解和 Cloude 分解分别提升了 4.73%、2.23%和 2.83%。Kappa 系数亦呈现相
254 同趋势，新方法为 0.9536，优于其他方法。从各类别生产者精度分析，在区分难度较高的作物类别上，新方法
255 的优势更为显著。在玉米分类中，新方法精度（84.76%）较次优方法（Stokes 分解，79.48%）提升超过 5%；在
256 洋葱分类中，新方法精度（86.17%）较次优的 C_2 矩阵（78.72%）提升超过 7%；对于易与小麦混淆的苜蓿，新方
257 法精度（92.57%）亦明显高于其他方法（83.58%-84.10%）。

258 表 4 基于不同特征参数的金昌区域定量分类结果

259 Table 4 Quantitative classification results of the Jinchang area based on different parameters

	小麦(A 区域)	油菜	小麦(B 区域)	玉米	洋葱	苜蓿	娃娃菜	裸土	总体精度	Kappa
新方法	97.84%	90.85%	98.64%	84.76%	86.17%	92.57%	99.74%	99.99%	96.10%	0.9536
C_2 矩阵	96.70%	84.37%	97.19%	77.22%	78.72%	83.58%	99.18%	99.73%	91.37%	0.9108
Stokes 分解	97.86%	87.63%	97.73%	79.48%	78.67%	83.76%	99.16%	99.87%	93.87%	0.9268
Cloude 分解	95.67%	88.17%	97.23%	79.17%	76.25%	84.10%	99.20%	99.86%	93.27%	0.9197

260 5.2 加利福尼亚实验区

261 图 12 呈现了美国加利福尼亚农业区在四种方法下的分类结果。基于旋转变换方法的分类图表现出更高的空
262 间连贯性。对于传统方法，其分类结果中普遍存在空间破碎化现象，尤其在玉米种植区表现出显著的类别混淆。
263 这揭示了传统方法在特征表征能力上的局限性，基于固定散射模型或矩阵元素提取的离散特征集，难以全面描
264 述复杂三维结构作物的完整散射响应。这种表征能力的不足直接导致分类决策边界模糊，在空间上表现为类内
265 异质性高、类间混淆明显。值得注意的是，旋转变换方法在玉米区域取得的分类改善，与第 4 节中的散射特征
266 分析相互验证，进一步证实了连续特征提取策略在提升复杂农业场景分类精度方面的有效性。

267 进一步分析加利福尼亚区域的农作物定量分类结果，如表 5 所示。实验数据表明，本文方法在总体精度上
268 达到了 93.01%，相较于 C_2 矩阵、Stokes 分解及 Cloude 分解分别提升了 5.07%、3.19%和 3.13%。同时，其 Kappa
269 系数也达到最高的 0.9174，优于传统方法。在各类别的纵向对比中，传统方法在向日葵、苜蓿及核桃等作物上
270 表现出较大的精度波动，而新方法在所有 8 类作物中均保持了较高的分类精度。这种在不同作物类别间的高度
271 稳健性，进一步验证了旋转变换特征在处理复杂农业场景时，能够提供较传统离散特征更具普适性的散射特征
272 支撑。




图 12 加利福尼亚区域基于不同方法的作物分类结果和错分图

Fig.12 Crop classification results and misclassification maps for the California area

表 5 基于不同特征参数的加利福尼亚区域定量分类结果

Table 5 Quantitative classification results of California area based on different parameters

	玉米	向日葵	冬小麦	苜蓿	番茄	三叶草	杏仁	核桃	总体精度	Kappa
新方法	90.38%	89.06%	96.84%	93.05%	97.11%	93.85%	94.96%	78.11%	93.01%	0.9174
C_2 矩阵	82.48%	78.31%	92.73%	86.27%	91.80%	88.69%	94.98%	70.92%	87.94%	0.8570
Stokes 分解	87.16%	78.03%	98.31%	88.25%	97.40%	92.65%	94.92%	59.49%	89.82%	0.8792
Cloude 分解	88.05%	82.51%	94.04%	87.67%	92.12%	90.21%	94.96%	79.64%	89.88%	0.8802

横向对比金昌和加州实验区的分类结果，加州地区的分类精度基本低于金昌地区，这可能是由作物结构复杂性和物候期特征差异共同决定的。加州地区属于地中海气候，作物类型涵盖果树以及形态复杂的作物。果树具有茂密冠层，其散射机制包含多重散射过程，易导致果树与高秆作物的散射特征重叠。相比之下，金昌地区地处温带大陆性气候区，地物包括小麦、娃娃菜和裸土，其散射特征主要由地表散射和体散射主导，不同作物间的几何形态差异在极化特征中相较显著，类间可分性相对较强。因此，在类似观测条件下，加州地区的作物分类精度低于金昌地区。

6 结论

针对现有分解方法因依赖固定散射模型而难以充分表征复杂作物散射特性的问题，本文提出了一种基于旋

286 转变换的连续特征提取方法。通过在甘肃省金昌市与美国加利福尼亚州两个典型农业区开展实验与对比分析，
287 证明方法的有效性：

288 (1) 该方法通过构建旋转矩阵实现散射模型在极化空间的连续变化，将离散的双极化观测展示为连续的能
289 量响应分布，从而提取出更丰富的散射特征。实验结果表明，相较于传统模型，新方法能够更充分地挖掘双极
290 化数据中蕴含的作物几何物理信息。

291 (2) 与传统极化分解方法相比，新方法在多种农业场景下均表现出显著且稳定的分类性能提升。在金昌实
292 验区，新方法的总体分类精度达到 96.10%；在加利福尼亚实验区，其精度为 93.01%。两地实验结果一致验证了
293 该方法在不同种植结构、气候条件下的有效性和鲁棒性。

294 (3) 本文研究主要基于单时相、单波段双极化 SAR 数据，尚未充分考虑农作物精细结构特征的提取，也
295 未探究作物在全生长周期内的动态演变规律。针对上述不足，未来工作将重点从以下两方面展开。一是引入多
296 波段 SAR 数据，融合 C、L、X 等不同波段对作物冠层的穿透能力差异，构建多波段旋转变化特征体系，以更
297 全面地刻画作物结构并提升作物分类精度；二是引入长时序 SAR 观测，挖掘散射特征随作物生长进程的演化轨
298 迹，揭示关键物候期的特征变化规律，为作物精细分类提供支撑。

299 (4) 针对地物类型单一的简单场景，传统分解方法所提取的离散特征已具备足够的类间区分度。相比之下，
300 新方法通过旋转变换导出的连续分布特征可能会产生平滑效应，从而掩盖原本显著的判别性规律。此外，针对
301 散射机制高度相似的异类作物，旋转变换提取的高维特征空间可能过度放大非同类作物间的共有特征，导致特
302 征分布呈现出高度的同质化。在上述两种情况下，新方法可能加剧不同作物间的特征混淆，限制了作物的分类
303 精度。

304 参考文献(References)

- 305 Aires U R V, Martins V S, Ferreira L B, Huang Y, Heintzman L and Ouyang Y. 2025. Impact of sampling techniques on crop type mapping
306 using multi-temporal composites from Harmonized Landsat-Sentinel images. *Computers and Electronics in Agriculture*, 237(Part B):
307 110676 [DOI:10.1016/j.compag.2025.110676]
- 308 Cao Z Y. 2022. Polarization information reconstruction based on deep learning. Beijing: Beijing University of Chemical Technology (曹卓岳.
309 2022. 基于深度学习的极化信息重建. 北京: 北京化工大学)
- 310 Chen J, Liu T Y, Shi Q, Dong J W and Chen Y. 2025. Early-season crop classification: recent developments and prospects. *National Remote*
311 *Sensing Bulletin*, 29(6): 1890-1900 (陈晋, 刘天禹, 石茜, 董金玮, 陈洋. 2025. 遥感农作物早期分类研究现状与展望. 遥感学报,
312 29(6): 1890-1900) [DOI:10.11834/jrs.20255017]
- 313 Chen Q H, Liu X G and Chen Q. 2014. An integrated multi-feature segmentation method for fully polarimetric SAR images. *Geomatics and*
314 *Information Science of Wuhan University*, 39(12): 1419-1424 (陈启浩, 刘修国, 陈奇. 2014. 一种综合多特征的全极化 SAR 图像分
315 割方法. 武汉大学学报(信息科学版), 39(12): 1419-1424) [DOI:10.13203/j.whugis20130469]
- 316 Chen S W, Li Y Z, Wang X S and Xiao S P. 2017. Polarimetric SAR target scattering interpretation in rotation domain: theory and application.

Journal of Radars, 6(5): 442-455 (陈思伟, 李永祯, 王雪松, 肖顺平. 2017. 极化 SAR 目标散射旋转域解译理论与应用. 雷达学报, 6(5): 442-455) [DOI:10.12000/JR17033]

Chen S W, Wang X S, Xiao S P and Sato M. 2014. General polarimetric model-based decomposition for coherency matrix. IEEE Transactions on Geoscience and Remote Sensing, 52(3): 1843-1855 [DOI:10.1109/TGRS.2013.2255615]

Cloude S R. 2007. The dual polarization entropy/alpha decomposition: a PALSAR case study. Science and Applications of SAR Polarimetry and Polarimetric Interferometry. Frascati: European Space Agency: 2

Cloude S R and Pottier E. 1997. An entropy based classification scheme for land applications of polarimetric SAR. IEEE Transactions on Geoscience and Remote Sensing, 35(1): 68-78 [DOI:10.1109/36.551935]

Freeman A. 2007. Fitting a two-component scattering model to polarimetric SAR data from forests. IEEE Transactions on Geoscience and Remote Sensing, 45(8): 2583-2592 [DOI:10.1109/TGRS.2007.897929]

Freeman A and Durden S L. 1998. A three-component scattering model for polarimetric SAR data. IEEE Transactions on Geoscience and Remote Sensing, 36(3): 963-973 [DOI:10.1109/36.673687]

Han W T, Fu H Q, Zhu J J, Zhang S R, Xie Q H and Hu J. 2023. A polarimetric projection-based scattering characteristics extraction tool and its application to PolSAR image classification. ISPRS Journal of Photogrammetry and Remote Sensing, 202: 314-333 [DOI:10.1016/j.isprsjprs.2023.05.031]

Han W T, Zhou C, Zhu J J, Fu H Q, Xie Q H, Hu J, Wang C C and Gao H. 2025. Research progress and prospects of polarimetric SAR decomposition. Geomatics and Information Science of Wuhan University, 50(8): 1498-1516 (韩文涛, 周瑾, 朱建军, 付海强, 解清华, 胡俊, 汪长城, 高晗. 2025. 极化 SAR 分解研究进展与展望. 武汉大学学报(信息科学版), 50(8): 1498-1516) [DOI:10.13203/j.whugis.20230388]

Huynen J R. 1970. Phenomenological theory of radar targets. Delft: Delft University of Technology

Ji K F and Wu Y R. 2015. Scattering mechanism extraction by a modified Cloude-Pottier decomposition for dual polarization SAR. Remote Sensing, 7(6): 7447-7470 [DOI:10.3390/rs70607447]

Krizhevsky A, Sutskever I and Hinton G. 2012. ImageNet classification with deep convolutional neural networks. In: Proceedings of the 25th International Conference on Neural Information Processing Systems. Lake Tahoe, Nevada: ACM

Lee J S and Pottier E. 2009. Polarimetric radar imaging: from basics to applications. Boca Raton: CRC Press

Li D, Zhang Y and Liang L. 2020. A mathematical extension to the general four-component scattering power decomposition with unitary transformation of coherency matrix. IEEE Transactions on Geoscience and Remote Sensing, 58(11): 7772-7789 [DOI:10.1109/TGRS.2020.2983758]

Li H Z, Wang C, Zhang H and Liu L. 2012. A unified three-component scattering model for polarimetric coherent target decomposition. International Journal of Remote Sensing, 33(9): 2868-2891 [DOI:10.1080/01431161.2011.622728]

Li Y, Yang J F, Zhang H S, Li G and Chen J. 2024. Review of the studies on remote sensing classification based on polarimetric Synthetic Aperture Radar. National Remote Sensing Bulletin, 28(8): 1835-1853 (李煜, 杨静飞, 张鸿生, 李刚, 陈杰. 2024. 极化合成孔径雷达遥感地物分类研究进展. 遥感学报, 28(8): 1835-1853) [DOI:10.11834/jrs.20242346]

Mascolo L, Cloude S R and Lopez-Sanchez J M. 2022. Model-based decomposition of dual-pol SAR data: application to Sentinel-1. IEEE Transactions on Geoscience and Remote Sensing, 60: 5220119 [DOI:10.1109/TGRS.2021.3137588]

Shen M H. 2020. Research on coastal zone land cover classification method based on multi-temporal remote sensing. Qingdao: China University of Petroleum (East China) (沈明辉. 2020. 基于多时相遥感的海岸带地物分类方法研究. 青岛: 中国石油大学(华东))

Shi L, Sun W D, Yang L, Yang J, Zhao L L, Li P X and Liu Y B. 2025. Evaluation of radiometric and polarimetric errors in the LT-1A satellite data based on tropical forests in the Amazon. Journal of Radars, 14(2): 405-423 (史磊, 孙维东, 杨乐, 杨杰, 赵伶俐, 李平湘, 刘亚波. 2025. LT-1A 卫星全极化 SAR 辐射与极化系统误差稳定性分析:以热带雨林场景为例. 雷达学报(中英文), 14(2): 405-423)

357 [DOI:10.12000/JR24102]

358 Sun W D, Du X L, Yang J, Shi L, Li M Y, Zhao L L and Hu C. 2025. Reconstruction of full-polarimetric SAR data based on dual-polarimetric
359 observations from the LT-1 Satellite. *National Remote Sensing Bulletin*, 29(11): 3109-3123 (孙维东, 杜欣玲, 杨杰, 史磊, 黎旻懿, 赵
360 伶俐, 胡成. 2025. 基于陆探一号卫星双极化观测的全极化 SAR 数据重构. *遥感学报*, 29(11): 3109-3123)
361 [DOI:10.11834/jrs.20254327]

362 Wang S L, Qiu Y, Zhao C B, Zou J X and Wang C F. 2025. eDPRF: Efficient differentially private random forest training algorithm. *Journal of*
363 *Software*, 36(7): 2929-2946 (王树兰, 邱瑶, 赵陈斌, 邹家须, 王彩芬. 2025. eDPRF: 高效的差分隐私随机森林训练算法. *软件学*
364 *报*, 36(7): 2929-2946) [DOI:10.13328/j.cnki.jos.007332]

365 Wang T T. 2024. Research on polarimetric SAR target decomposition method based on scattering matrix optimization. Xi'an: Xidian University
366 (王婷婷. 2024. 基于散射矩阵优化的极化 SAR 目标分解方法研究. 西安: 西安电子科技大学)

367 Wu Y H, Ji K F and Yu W X. 2008. Comparison of classification performance of full-, dual- and single-polarization SAR images using SVM.
368 *Journal of Remote Sensing*, (1): 46-53 (吴永辉, 计科峰, 郁文贤. 2008. 利用 SVM 的全极化、双极化与单极化 SAR 图像分类性能
369 的比较. *遥感学报*, (1): 46-53) [DOI:10.11834/jrs.20080107.]

370 Wu Y R. 2013. The concept of multidimensional synthetic aperture radar imaging. *Journal of Radars*, 2(2): 135-142 (吴一戎. 2013. 多维度合
371 成孔径雷达成像概念. *雷达学报*, 2(2): 135-142) [DOI:10.3724/SP.J.1300.2013.13047]

372 Xiang D L, Xie Y Z, Cheng J D, Xu Y H, Zhang H and Zheng Y P. 2022. Optical and SAR image registration based on feature decoupling
373 network. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1-13 [DOI:10.1109/TGRS.2022.3211858]

374 Xu F, Wang H P and Jin Y Q. 2017. Application of deep learning to SAR target recognition and terrain classification. *Journal of Radars*, 6(2):
375 136-148 (徐丰, 王海鹏, 金亚秋. 2017. 深度学习在 SAR 目标识别与地物分类中的应用. *雷达学报*, 6(2): 136-148)
376 [DOI:10.12000/JR16130]

377 Yamaguchi Y, Moriyama T, Ishido M and Yamada H. 2005. Four-component scattering model for polarimetric SAR image decomposition. *IEEE*
378 *Transactions on Geoscience and Remote Sensing*, 43(8): 1699-1706 [DOI:10.1109/TGRS.2005.852084]

379 Yang J, Xiong T and Peng Y N. 2006. Polarimetric SAR image classification by using generalized optimization of polarimetric contrast
380 enhancement. *International Journal of Remote Sensing*, 27(16): 3413-3424 [DOI:10.1080/01431160600589161]

381 Yu F H, Bai J C, Fang J Y, Guo S E, Zhu S F and Xu T Y. 2024. Integration of a parameter combination discriminator improves the accuracy
382 of chlorophyll inversion from spectral imaging of rice. *Agriculture Communications*, 2(3): 100055 [DOI:10.1016/j.agrcom.2024.100055]

383 Zhang B, Perrie W, Li X F and Pichel W G. 2011. Mapping sea surface oil slicks using RADARSAT-2 quad-polarization SAR image.
384 *Geophysical Research Letters*, 38: L10602 [DOI:10.1029/2011GL047013]

385 Zhang L M. 2010. Research on feature extraction and detection of man-made target using polarimetric SAR images. Harbin: Harbin Institute
386 of Technology (张腊梅. 2010. 极化 SAR 图像人造目标特征提取与检测方法研究. 哈尔滨: 哈尔滨工业大学)

Rotation-Transform-Based Scattering Characteristics Extraction and Classification in Agricultural Areas Using Dual-Polarization SAR Data

HAN Wentao¹, WANG Mingxu¹, CHEN Shulu², GAO Han³, WANG Changcheng⁴, ZHU Jianjun⁵

1. School of Civil Engineering, Xiangtan University, Xiangtan 411105, China;

2. Xiangtan Survey and Design Institute, Xiangtan 411105, China

3. College of Oceanography and Space Informatics, China University of Petroleum, Qingdao 266580, China

4. School of Geosciences and Info-Physics, Central South University, Changsha 410083, China

Abstract: Objective: In the field of polarimetric synthetic aperture radar (PolSAR) remote sensing, the capability to conduct all-weather, day-and-night observations makes it a pivotal tool for crop classification. Currently, establishing correlations between decomposition features and crop types via machine learning algorithms has become a mainstream approach. However, existing dual-polarimetric decomposition methodologies, such as Stokes or Cloude decompositions, are constrained by their reliance on predefined and fixed scattering models. These conventional approaches are limited to extracting discrete scattering features, which often fail to sufficiently characterize the geometric structures and scattering processes of complex agricultural vegetation, thereby hindering the achievement of higher classification accuracy. **Method:** To effectively address these issues, the paper proposes a rotation transformation methodology specifically designed for dual-polarimetric data. By using the polarimetric scattering angle α and the polarimetric phase angle δ , a dynamic and continuous rotation vector is constructed. This method projects the dual-polarization covariance matrix C_2 onto this vector, transforming static observations into a continuous power response distribution. Then, by utilizing α , δ , and the continuous scattering power P at these rotation vectors as coordinate axes, a three-dimensional polarimetric space is constructed. Within this visualization framework, the research generates corresponding three-dimensional power response surfaces for different crops. Based on this, a series of key scattering features like skewness and smoothness are extracted. These features capture subtle physical differences that conventional fixed decomposition models fail to detect, thereby enhancing classification robustness in complex agricultural scenes. **Result:** The efficacy of this approach was rigorously validated through comprehensive experiments in Jinchang, China, and California, USA. These two regions are characterized by distinct climatic conditions and diverse crop planting structures. Quantitative analysis demonstrates that the proposed method achieved an outstanding overall classification accuracy of 96.10% in the Jinchang study area, outperforming C_2 matrix, Stokes decomposition, and Cloude decomposition by 4.73%, 2.23%, and 2.83%, respectively. Similarly, in the California agricultural site, the method yielded a high

classification accuracy of 93.01%, providing performance improvements ranging from 3.13% to 5.07% over baseline methods. These results illustrate that the new method consistently delivers superior classification performance across different agricultural landscapes. **Conclusion:** By constructing a rotation matrix that allows the scattering model to vary continuously, the method transforms discrete dual-polarimetric observations into a continuous power response. This enables the mining of richer geometric and physical information than conventional models. Experimental results confirm that this approach achieves superior and stable classification accuracy across diverse agricultural landscapes. While the current study utilizes single-temporal, single-band data, future work will integrate multi-band SAR and long-term time-series observations. This will better capture phenological growth trajectories, ultimately enhancing ability to distinguish between structurally similar crops across different developmental stages.

Key words: Dual-polarization SAR, continuous scattering characteristics, crop classification, rotation transformation.

Supported by the National Natural Science Foundation of China [No. 42501462], Hunan Provincial Natural Science Foundation [No. 2025JJ60236], and Hunan Provincial Education Department [25B0158].