

# SAR图像方向性上下文协方差矩阵构建方法及地物分类应用

符婷, 陈思伟

国防科技大学 电子科学学院 电子信息系统复杂电磁环境效应国家重点实验室, 长沙 410073

**摘要:** 合成孔径雷达 (SAR) 是对地观测等领域的重要传感器, 得到了广泛应用。然而, 单通道 SAR 图像每个像元只包含一个复散射值, 有限的信息量在一定程度上限制了其应用性能。针对这一问题, 本文提出了一种 SAR 图像空间纹理信息表征方法: 方向性上下文协方差矩阵 (DCCM)。DCCM 通过提取邻域中不同方向上的散射强度变化来拓展利用图像上下文信息, 将单个像元从一个标量拓展为一组矩阵, 从而极大提升了像元信息容量, 实现了信息增广。在此基础上提取的 DCCM 纹理特征能够更完备地表征地物空间纹理特性, 有望应用于地物分类等领域。本文将 DCCM 纹理特征分别与传统分类器和卷积神经网络结合, 构建了基于方向性上下文协方差矩阵的 SAR 图像地物分类方法。利用 AIRSAR 和 UAVSAR 数据开展的对比实验表明, 相比基于灰度共生矩阵、Gabor 滤波和多级局部模式直方图 3 种典型纹理特征的分类方法, 本文方法结合传统分类器时对总体分类精度提升达到 7% 以上, 结合卷积神经网络时也展现出了优异的分类性能以及更好的稳健性。

**关键词:** SAR 图像, 表征, 方向性上下文协方差矩阵, 空间纹理, 地物分类

**中图分类号:** TP753/P2

**引用格式:** 符婷, 陈思伟. 2024. SAR 图像方向性上下文协方差矩阵构建方法及地物分类应用. 遥感学报, 28(3): 730-746

**Fu T and Chen S W. 2024. SAR image directional context covariance matrix: Construction and its application in terrain classification. National Remote Sensing Bulletin, 28(3): 730-746 [DOI: 10.11834/jrs.20231482]**

## 1 引言

合成孔径雷达 SAR (Synthetic Aperture Radar) 是一种高分辨率二维成像雷达, 具有独特的全天时全天候的工作能力, 是重要的遥感对地观测手段。随着传感器分辨率逐步提高, SAR 图像能够展现越来越丰富的地物细节, 为其判读与解译奠定了基础。地物分类是 SAR 应用的重要研究方向, 在地图制图、环境监测以及军事侦察等领域有着广阔应用需求。尽管当前许多传感器具备了多极化、多波段的测量模式, 但在实际工作中, 由于其大幅宽、低成本等优势, 单极化、单波段的 SAR 图像依然应用广泛, 并且有大量过往积累的数据待发掘利用。如何更好地发挥此类单通道 SAR 数据的应用价值, 是值得研究的课题。

地物分类是遥感领域重要的基础性应用。然

而, 单通道 SAR 图像有限的信息量限制了其分类性能。本文将以此为背景, 探究单通道 SAR 图像的信息维度拓展, 以提升其应用潜能。传统的单通道 SAR 图像分类大致可分为两种途径: 基于像元散射信息及其统计分布的方法和基于图像空间纹理信息的方法 (Guan 等, 2019)。统计建模方法的关键在于找到一种适用于各类 SAR 场景的分布模型 (Guan 等, 2019), 常用分布模型有多元复高斯分布 (Kong 等, 1988)、复 Wishart 分布 (Lee 等, 1994a)、Weibull 分布 (Oliver, 1993)、K 分布 (Lee 等, 1994b) 和  $G^0$  分布 (Freitas 等, 2005)。此类方法在中低分辨率图像上得到了广泛应用 (Gao, 2010)。提取纹理信息是改善单通道 SAR 图像分类精度的另一种思路, 通过挖掘目标像元局部的空间信息来增加信息量, 进一步提升可分性。SAR 图像处理中常用的纹理特征有灰度共生矩阵 GLCM

收稿日期: 2021-07-19; 预印本: 2022-02-27

基金项目: 国家自然科学基金(编号: 62122091, 61771480); 湖南省杰青基金项目(编号: 2020JJ2034); 湖湘青年英才项目(编号: 2019RS2025)

第一作者简介: 符婷, 研究方向为极化雷达成像与解译。E-mail: futing@nudt.edu.cn

通信作者简介: 陈思伟, 研究方向为极化雷达成像与识别、机器学习、电子对抗。E-mail: chenswnudt@163.com

(Gray-Level Co-occurrence Matrix) (Haralick等, 1973)、分形模型 (Pentland, 1984)、马尔可夫随机场 MRF (Markov Random Field) (Chellappa 和 Chatterjee, 1985)、Gabor滤波器 (Jain和Farrokhnia, 1991; Lee, 1996) 等。Ulaby等 (1986) 将 GLCM 的一、二阶统计量用于 SAR 强度图像分类, 此后基于 GLCM 的方法在 SAR 图像分析中得到了广泛应用 (程雪姣等, 2014; Liu等, 2015; 李强等, 2018)。Clausi (2001) 对比了 GLCM、Gabor 滤波和 MRF 这 3 种纹理特征用于 SAR 图像海冰分类的效果, 指出 GLCM 结合 MRF 能够进一步提高分类精度。Dekker (2003) 则分析了直方图测度、小波能量、分形维度、间隙度和半变异函数等纹理特征在城市区域的分类能力。局部二值模式 LBP (Local Binary Pattern) (Ojala等, 1996, 2002) 及其改进方法成为了 21 世纪初期主要的局部纹理描述子之一 (Liu等, 2017)。在其基础上针对 SAR 图像提出的方法有多级局部模式直方图 MLPH (Multilevel Local Pattern Histogram) (Dai等, 2011) 和多尺度局部 Fisher 模式 MLFP (Multiscale Local Fisher Pattern) (Zhao等, 2021)。近年来, 基于纹理的 SAR 图像分类研究多是将上述常用纹理特征进行结合或改进 (Dai等, 2011; Aytakin等, 2013; Cheng等, 2015; 王璐等, 2015; Guan等, 2019)。此外, 还有一些基于稀疏表征 (Bi等, 2022)、属性剖面 (Attribute Profiles) (He等, 2017; Tombak等, 2019) 等的新方法。

除了传统分类方法, 近年来基于深度学习的 SAR 图像分类方法不断涌现, 并展现出优异的性能。Geng等 (2015) 将深度卷积自编码器用于 SAR 图像特征提取与分类。Zhao等 (2017) 联合集成学习方法与深度置信网络从图像中提取高层次特征并用于地物分类。Zhang等 (2017) 针对 SAR 图像的复数特性提出了复数卷积神经网络 CNN (Convolutional Neural Network), 并通过实验证明其相对实数网络性能更好。Wu等 (2021) 将注意力机制加入 CNN 以获得更加鲁棒的上下文特征。深度学习类方法一般需要大量标记样本用以训练网络, 然而 SAR 数据的标记样本往往相对有限。对此, 一些学者积极探索小样本下的深度学习方法。Qin等 (2017) 使用玻尔兹曼机来解决分类中的小样本问题。Wu等 (2018) 提出了一种迁移学习框架将预训练模型用于 SAR 图像分类。此

外, 深度学习作为一种端到端的方法, 有时缺乏可解释性, 为光学图像提出的模型也未必适合 SAR 图像。因此, 发展结合机理的深度学习方法也是一种改进思路。Jiao和Liu (2016) 根据极化协方差矩阵和相干矩阵的 Wishart 分布特性, 将 Wishart 距离引入深度堆叠网络并取得了较好的分类结果。Geng等 (2017) 先提取了 GLCM、Gabor 和梯度直方图等特征, 再输入一个深度收缩神经网络进行学习和分类。Chen和Tao (2018) 通过提取极化特征提升了 CNN 的分类精度。上述工作说明, 结合专家知识或手工提取特征的深度学习方法有助于进一步提升 SAR 图像分类性能。

单通道 SAR 图像每个像元只包含一个复散射值, 信息量较为有限, 也无法通过通道间运算提取特征。因此, 利用邻近地物的空间相关性, 从图像上提取纹理信息, 是扩充像元信息量、增强地物辨识性能的重要途径。现有的纹理特征已经在 SAR 图像分类中取得了广泛应用, 但同时也还面临着一些挑战。一方面, SAR 图像的动态范围通常较大, 一些提取流程中包含量化操作的特征, 如 GLCM, 可能受到局部强散射点的影响而丢失暗部纹理细节。另一方面, 以 Gabor 滤波器组为代表的一些方法, 设置参数较多、特征维度较高。为了寻找最优的参数组合, 手工调参的工作量较大。而且高维度的特征容易使分类器陷入“维数灾难”。基于上述背景, 寻找一种更适合 SAR 图像特性、能够高效提取 SAR 图像空间信息的纹理特征, 是进一步提升 SAR 图像解译水平的关键。

近来, Chen (2020) 提出了上下文协方差矩阵 CCM (Context Covariant Matrix)。CCM 能够较好地提取利用 SAR 图像上下文信息。结合矩阵相似性检验, CCM 在 SAR 图像相干斑滤波中取得了成功应用。在该工作的启发下, 本文提出了一种 SAR 图像空间纹理表征方法——方向性上下文协方差矩阵 DCCM (Directional Context Covariant Matrix), 并在此基础上发展出了基于 DCCM 纹理特征的 SAR 图像分类方法。本文分别结合传统分类器和 CNN, 在 AIRSAR 数据和 UAVSAR 数据上开展了地物分类实验, 验证了所提方法的有效性。

## 2 方向性上下文协方差矩阵(DCCM)

对于高分辨率 SAR 图像而言, 面状地物内部会呈现出更多的异质细节 (如农田的田垄、水面

的波纹), 而不是某种均质特性。这一方面给从统计特性识别地物带来困难, 一方面又提供了新的信息——空间纹理。纹理是一种重要的视觉特征, 通常指图像中反复出现的局部模式及其排列规则 (Tuceryan 和 Jain, 1993), 也可以理解为邻近像元间的空间相关性。基于该思路, DCCM 在原有的散射信息上拓展利用了空间纹理信息, 实现了单通道 SAR 图像像元信息增广。

以目标像元为中心取一个大小为  $(2n+1) \times (2n+1)$  的矩形邻域 ( $n=1, 2, \dots$ ), 可以将邻域像元按照其相对于目标像元的方向对称地划分为若干个区域。以四方向划分为例, 如图 1 所示, 绿色、蓝色、黄色和橙色方块分别代表 4 个方向 ( $0^\circ$ 、 $45^\circ$ 、 $90^\circ$  和  $135^\circ$ ) 的邻域像元。在各区域内计算该方向上的平均纹理特性, 将所有方向上的平均纹理特性组合即得到该目标像元的完整纹理特征。这种区域内部平均有利于得到更稳定的特征, 然而过度平均将损失细节从而对纹理没有足够的分辨力, 因此需要考虑划分方向的数目。兼顾稳定性和鉴别力, 通常将方向数目设为 4。

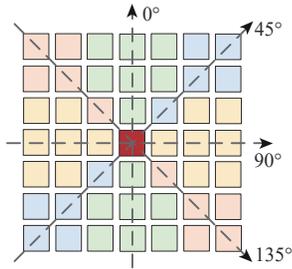


图 1 四方向 DCCM 示意图

Fig. 1 Illustration of four-directional DCCM

构造 DCCM 的第一步是提取上下文散射矢量。上下文散射矢量是由目标像元及关于其对称的两个邻域像元组成的向量。以  $3 \times 3$  邻域为例, 如图 2 所示, 红色的目标像元及其 8 个邻域像元一共可以构成如下 4 个上下文散射矢量。

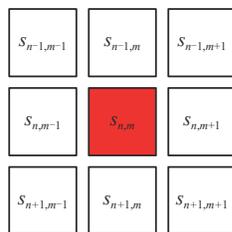


图 2 上下文散射矢量构建示意图

Fig. 2 Construction of context scattering vectors

$$\begin{aligned} \mathbf{k}_1 &= [s_{n-1,m-1} \quad s_{n,m} \quad s_{n+1,m+1}]^T \\ \mathbf{k}_2 &= [s_{n-1,m} \quad s_{n,m} \quad s_{n+1,m}]^T \\ \mathbf{k}_3 &= [s_{n-1,m+1} \quad s_{n,m} \quad s_{n+1,m-1}]^T \\ \mathbf{k}_4 &= [s_{n,m+1} \quad s_{n,m} \quad s_{n,m-1}]^T \end{aligned} \quad (1)$$

式中,  $s_{n,m}$  表示位于图像第  $n$  行、第  $m$  列的像元复散射值, 上标 “T” 表示转置。类似地, 对于大小为  $(2n+1) \times (2n+1)$  的邻域, 一共可以得到  $\frac{1}{2}(2n+1)^2 - 1$  个上下文散射矢量。

根据构建上下文散射矢量的邻域像元相对中心像元的方向, 可以将其分为不同方向的上下文散射矢量  $\mathbf{k}_i^d$  ( $d=0^\circ, 45^\circ, 90^\circ, 135^\circ$ )。例如图 1 中, 由绿色邻域像元构成的即为  $0^\circ$  方向的上下文散射矢量, 它们反映了该方向上的地物后向散射变化。利用  $d$  方向的上下文散射矢量, 可以得到  $d$  方向的 DCCM

$$\mathbf{C}^d = \frac{1}{N^d} \sum_{i=1}^{N^d} \mathbf{k}_i^d \mathbf{k}_i^{dH} \quad (2)$$

式中,  $N^d$  表示  $d$  方向上下文散射矢量的数目, 如图 1 中邻域大小为  $7 \times 7$  时,  $N^d = 7$ 。

将  $d$  方向上下文散射矢量记为  $\mathbf{k}_i^d = [s_1 \quad s_2 \quad s_3]^T$ , 令  $c_{pq}^d$  代表  $\mathbf{C}^d$  中第  $p$  行第  $q$  列的元素, 则  $c_{22}^d = c_{22} = s_2 s_2^* = |s_2|^2$  表示目标像元的强度, 而  $c_{11}^d = \langle s_1 s_1^* \rangle = \langle |s_1|^2 \rangle$  和  $c_{33}^d = \langle s_3 s_3^* \rangle = \langle |s_3|^2 \rangle$  分别表示  $d$  方向上两侧邻域像素的平均强度。其中, 上标 “\*” 表示共轭,  $\langle \cdot \rangle$  表示集合平均。显然,  $\mathbf{C}^d$  是一个 Hermite 矩阵 (若输入为 SAR 幅度/强度图像则  $\mathbf{C}^d$  为实对称矩阵)。于是有  $c_{12}^d = c_{21}^{d*} = \langle s_1 s_2^* \rangle$  表示目标像元与上半部分邻域像元的平均相关,  $c_{23}^d = c_{32}^{d*} = \langle s_2 s_3^* \rangle$  表示目标像元下半部分邻域像元的平均相关,  $c_{31}^d = c_{13}^{d*} = \langle s_1 s_3^* \rangle$  表示上下两部分邻域像元之间的平均相关。总的来说, DCCM 表征方式结合了像素强度和上下文信息, 其主对角线上的元素表示像素平均强度, 而非对角元素则反映了像素间的相关关系。

四方向 DCCM 可将目标像元从单个复数值拓展成为了  $\mathbf{C}^{0^\circ}$ 、 $\mathbf{C}^{45^\circ}$ 、 $\mathbf{C}^{90^\circ}$  和  $\mathbf{C}^{135^\circ}$  等 4 个矩阵, 每个矩阵包含了该方向上的纹理特性。DCCM 的方向数目可以根据实际需要进行调整。从理论上讲, 划分的方向越多, 能够捕获的纹理细节就越丰富。不难发现, CCM (Chen, 2020) 相当于一方向的 DCCM, 所以它能够表征的上下文信息较为有限。

一方面, DCCM将像元在邻域中所处的位置划分地更为细致, 相对于原始CCM加入了更多的方向信息, 有利于表征更复杂的空间纹理; 另一方面, 这种划分方式只区分邻域像元相对于中心像元的方向, 而不区分邻域像元相对中心像元的距离远近, 所以具有一定的尺度不变性。

### 3 基于DCCM纹理特征的SAR图像地物分类方法

#### 3.1 DCCM纹理特征提取

在DCCM表征中, 每个协方差矩阵 $\mathbf{C}^d$ 都是Hermite矩阵, 其中元素关于主对角线呈共轭对称关系, 所以这里只考虑矩阵上三角的元素。 $\mathbf{C}^d$ 中包含两类值: 对应散射强度的主对角线元素以及对应像素间相关的非对角元素。其中, 非对角元素的相关值事实上是由邻域内像元的强度值相乘后取平均得到的, 受到强度值大小的影响, 无法直观反映像素间的相关性。因此, 对相关值进行归一化:

$$\begin{aligned} c'_{12} &= \frac{c_{12}^d}{\sqrt{c_{11}^d c_{22}^d}} = \frac{\langle s_1 s_2 \rangle}{\sqrt{\langle |s_1|^2 \rangle \langle |s_2|^2 \rangle}} \\ c'_{13} &= \frac{c_{13}^d}{\sqrt{c_{11}^d c_{33}^d}} = \frac{\langle s_1 s_3 \rangle}{\sqrt{\langle |s_1|^2 \rangle \langle |s_3|^2 \rangle}} \\ c'_{23} &= \frac{c_{23}^d}{\sqrt{c_{22}^d c_{33}^d}} = \frac{\langle s_2 s_3 \rangle}{\sqrt{\langle |s_2|^2 \rangle \langle |s_3|^2 \rangle}} \end{aligned} \quad (3)$$

式中,  $c_{pq}^d$ 代表 $\mathbf{C}^d$ 中第 $p$ 行第 $q$ 列的元素。归一化后的相关值取值范围为 $[0, 1]$ , 它仅反映像素间的相关程度, 而与像素强度大小无关, 能够更好地反映图像局部纹理变化。另一方面, 归一化操作减少了 $\mathbf{C}^d$ 中强度值元素和相关值元素的信息冗余, 提升了特征空间中各维度的独立性, 更有利于地物的辨识。

对于直接从SAR数据计算得到的DCCM, 存在一些极端值使得整体动态范围较大, 而大部分值集中在一个相对较小的区间内, 造成长拖尾的分布形态。这种分布下的图像主体部分对比度不足, 不利于纹理提取。分析发现, DCCM中的强度值元素取值集中在0附近, 而归一化相关值集中在1附近。为了增大图像主体部分对比度, 使得被压缩的纹理细节得以展现, 考虑对大部分元素值所

在的区间进行展宽。利用对数函数的性质, 进行如下变换

$$\begin{cases} c''_{\text{intensity}} = \log_{10}(c_{\text{intensity}}) \\ c''_{\text{correlation}} = \log_{10}(1 - c'_{\text{correlation}}) \end{cases} \quad (4)$$

式中,  $c_{\text{intensity}}$ 代表强度值元素( $c_{11}, c_{22}, c_{33}$ ),  $c'_{\text{correlation}}$ 代表归一化相关值元素( $c'_{12}, c'_{13}, c'_{23}$ )。经过对数变换, DCCM中的极端值将被压缩, 图像主体部分对比度得到增强, 使原先处于暗处的纹理细节凸显出来。

经过归一化处理和对数变换后, 将DCCM中4个协方差矩阵的上三角元素取出, 构成1个特征向量。注意到, 每个 $\mathbf{C}^d$ 中的 $c_{22}$ 都是一样的, 为中心像元的强度。因此, 去除3个重复的 $c_{22}$ 后, 可以得到21维的DCCM纹理特征, 特征各维度的含义如表1所示。

表1 DCCM纹理特征元素  
Table 1 Elements of DCCM texture feature

维度	含义
$f_1$	$c_{22}$
$f_2-f_5$	$c_{11}^0, c_{11}^{45^\circ}, c_{11}^{90^\circ}, c_{11}^{135^\circ}$
$f_6-f_9$	$c_{12}^0, c_{12}^{45^\circ}, c_{12}^{90^\circ}, c_{12}^{135^\circ}$
$f_{10}-f_{13}$	$c_{13}^0, c_{13}^{45^\circ}, c_{13}^{90^\circ}, c_{13}^{135^\circ}$
$f_{14}-f_{17}$	$c_{23}^0, c_{23}^{45^\circ}, c_{23}^{90^\circ}, c_{23}^{135^\circ}$
$f_{18}-f_{21}$	$c_{33}^0, c_{33}^{45^\circ}, c_{33}^{90^\circ}, c_{33}^{135^\circ}$

提取DCCM纹理特征的总体流程如图3所示。类似地, 采用不同大小的邻域窗口, 可以构建各种尺度的DCCM, 以适用于不同粗细的空间纹理和不同大小的地物。DCCM窗口通常应该大于等于5, 具体要根据图像分辨率和图上地物的尺度, 结合实验选取。与Gabor滤波、LBP等需要手动选择多个参数的方法相比, 计算DCCM纹理特征只需事先确定好邻域窗口大小, 没有复杂的调参处理, 在实际应用中具有一定优势。

#### 3.2 SAR图像地物分类方法构建

基于DCCM纹理特征, 本文提出了一种SAR图像地物分类方法。该方法通过结合强度信息和纹理信息, 拓展单个像素信息容量, 进而提升SAR图像分类性能。首先, 对输入的SAR图像进行相干斑滤波, 以减少相干斑噪声对纹理提取的影响。其次, 依据图像分辨率以及地物形态和尺度选择邻域窗口大小, 并遍历全图计算DCCM。对

于地物内部相对均匀、成片状分布的农作物、水体等场景通常可选择较大的窗口，而包含独立建筑物和道路等细碎或狭长地物的城市场景则需要较小的窗口，以避免窗口内混入过多不同类别像素。然后，对得到的DCCM进行相关值归一化处理以及对数变换。前者能够减少各维度特征之间的

冗余信息，后者能提升图像主体部分的对比度，让纹理细节更好地展现出来。基于变换后的DCCM，提取21维的DCCM纹理特征向量，选取一定比例的标记样本作为训练集，输入分类器中进行训练。最后用训练好的分类器对图像进行分类，得到分类结果。所提方法的总体流程如图4所示。

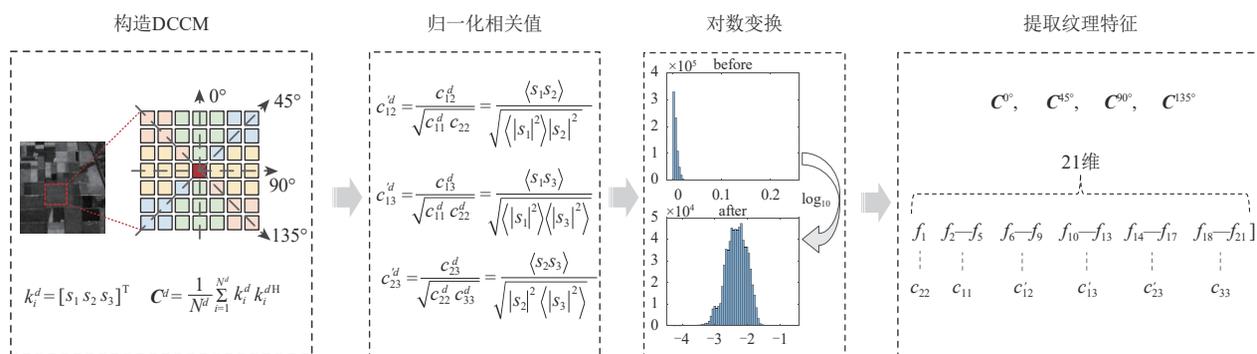


图3 DCCM纹理特征提取方法

Fig. 3 Framework of DCCM texture feature extraction

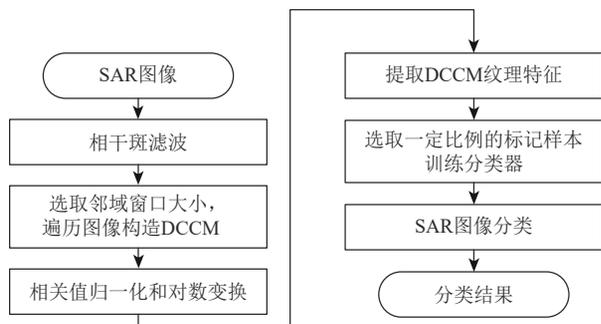


图4 SAR图像分类流程

Fig. 4 SAR image classification scheme

## 4 实验结果与分析

### 4.1 实验设置

本节选择基于GLCM、Gabor滤波、MLPH以及CCM纹理特征的分类方法（下文分别简称GLCM方法、Gabor方法、MLPH方法和CCM方法）作为对比方法开展地物分类实验。其中，GLCM和Gabor滤波是常用的纹理特征，在光学和SAR图像处理领域都取得了广泛的应用。而MLPH是近年来基于LBP方法针对高分辨率SAR图像提出的纹理特征，并且在文献（Dai等，2011）中表现出优于前面二者的性能。GLCM采用量化为32个灰度级的SAR幅度图像计算，设置4个方向、两种步长。从GLCM中提取对比度、相关、能量和同质性这4种不相关的统计量（Ulaby等，1986），构成32维

的特征向量。Gabor滤波器采用了5种尺度、8个方向，得到40维的特征向量，其参数设置和实现参考李建萍等（2010）和Haghighat等（2013）所著的文献。MLPH参照原始文献（Dai等，2011）提供的方法及参数实现，其特征向量为75维。另外，CCM方法也在实验中作为对比方法，以验证加入方位信息是对像元信息容量的进一步增广，能够改善SAR图像分类性能。

在分类器选择方面，本节采用两种经典的机器学习分类器：决策树DT（Decision Tree）和支持向量机SVM（Support Vector Machine）。其中，SVM采用径向基核函数，其超参数采用网格寻优方法确定。在预处理阶段采用SimiTest滤波（Chen等，2012）对SAR图像进行相干斑抑制。实验中，取已知样本的10%作为训练集，其余样本作为测试集，用总体精度OA（Overall Accuracy）和Kappa系数来定量评估实验结果。为了排除不同训练样本的干扰，每组实验随机选取训练集，重复五次，取五次实验的平均分类精度和Kappa系数。此外，邻域窗口大小均设置为25×25。

### 4.2 AIRSAR数据集地物分类实验

实验数据一是来自NASA/JPL AIRSAR于1989年获得的荷兰Flevoland地区L波段数据，大小为750×1024。该区域的主要地物为农作物，共分为15类，包括茎豆、豌豆、森林、苜蓿、小麦1、甜

菜、土豆、裸地、草地、油菜籽、大麦、小麦 2、小麦 3、水域和建筑物。利用数据的 HH 极化和 VV 极化分别开展对比实验。AIRSAR 数据如图 5 所示, 其真值如图 6 所示。

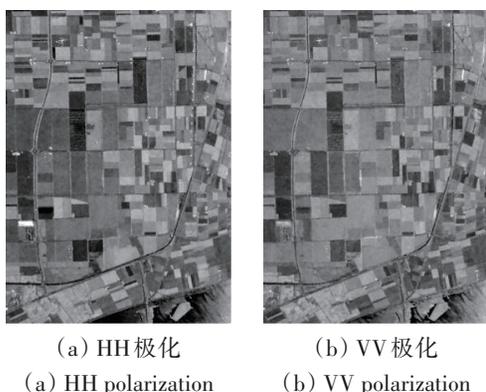


图 5 AIRSAR 数据图像

Fig. 5 SAR images of AIRSAR dataset

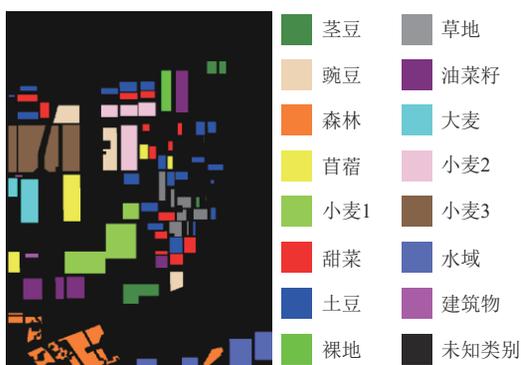


图 6 AIRSAR 数据真值

Fig. 6 Ground truth of AIRSAR dataset

在 10% 的训练率下, 对 HH 极化数据的地物分类精度和 Kappa 系数如表 2 所示, 分类结果如图 7 所示。从总体分类精度上看, 基于 DCCM 纹理特征的分类方法 (下文简称 DCCM 方法) 取得了最高的总体分类精度和 Kappa 系数, 并显著高于其他方法。对 DT 分类器, DCCM 方法取得了 77.69% 的总体精度。基于 CCM 纹理特征的分类方法和基于 Gabor 滤波特征的分类方法 (下文分别简称为 CCM 方法和 Gabor 方法) 总体精度分别为 69.45% 和 65.13%。而基于 GLCM 纹理特征的分类方法和基于 MLPH 纹理特征的分类方法 (下文分别简称为 GLCM 方法和 MLPH 方法) 分类精度均不足 60%。对 SVM 分类器, 5 种方法的分类精度都有所提升。其中, DCCM 方法的总体分类精度达到了 96.51%, 而其他方法的总体精度都不到 85%。可以看出,

相比其他方法, DCCM 方法显著提升了该数据的分类性能。这反映出 DCCM 纹理特征能够有效结合 SAR 图像的强度和纹理信息, 进而增强了地物的可分性。相比于 CCM 方法, DCCM 方法的分类精度有明显提高, 证实了加入方向性能够更精细地提取 SAR 图像纹理, 有利于地物的辨识。此外, 在 DT 分类器上, Gabor 方法对建筑物的分类精度 (98.29%) 略高于 DCCM 方法 (97.71%)。结合分类结果图分析, 该差异主要来源于夹在大麦和小麦 3 之间的一小块建筑物, 可能是由于窗口相对较大使 DCCM 方法受到了邻近地物的干扰。

从分类结果图上看, DT 分类器的分类结果普遍不太理想。MLPH 方法和 GLCM 方法的结果图上遍布着细碎的误分像素点, 整体正确率较低。Gabor 方法、CCM 方法和 DCCM 方法的结果稍好一些。SVM 分类器的分类结果整体有所改善。其中, DCCM 方法的对大部分地物的分类效果都很好, 只对油菜籽、草地和水域等地物出现了零星的错误。值得注意的是, GLCM 方法虽然总体精度还不错, 但其错误分类的像素散布在各个地物块中, 从视觉上看并不太理想。这可能表明 GLCM 方法对图像的空间信息利用不足。相比之下, Gabor 方法和 DCCM 方法更倾向于在地物交界处出现错误, 而地物块内部相对完整。可以发现, CCM 方法在油菜籽等地物中出现了大面积的误分, 而这一情况在 DCCM 方法中得到了明显改善, 说明加入方向性信息能够提升地物辨识能力。总的来说, DCCM 方法正确率更高, 并且得到了更加平滑完整的结果图, 证实了 DCCM 纹理特征能够有效结合像素强度和空间纹理信息, 实现地物分类性能的提升。

对 VV 极化数据的地物分类精度和 Kappa 系数如表 3 所示, 对应的分类结果如图 8 所示。VV 极化数据的总体分类精度普遍低于 HH 极化。DCCM 方法依然取得了最高的总体精度和 Kappa 系数, 在 DT 和 SVM 分类器上的分类精度分别达到了 73.97% 和 95.22%, 超出其他 4 种方法 10% 以上。在 DT 分类器上, MLPH 方法和 GLCM 方法的总体精度均不足 50%, 而 Gabor 方法和 CCM 方法的精度分别达到 61.33% 和 63.48%。在 SVM 分类器上, GLCM 方法的分类精度有大幅提升, 达到了 82.65%。Gabor 方法的总体精度也达到了 81.65%, 而另外两种方法精度均不足 80%。值得注意的是, CCM 方法在 VV 极化上的分类精度相比 HH 极化大幅降低, 而

DCCM方法依旧保持了较好的性能。可见方向性信息特征的鲁棒性,从而在不同极化的数据上能取得相对稳定的分类性能。

表2 AIRSAR数据HH极化地物分类精度和Kappa系数

Table 2 Classification accuracy and Kappa coefficient of HH polarization in AIRSAR dataset

类别	DT					SVM				
	MLPH	Gabor	GLCM	CCM	DCCM	MLPH	Gabor	GLCM	CCM	DCCM
茎豆	33.84	45.54	40.62	50.37	60.61	75.46	83.76	88.46	72.94	97.18
豌豆	40.01	55.52	37.86	62.90	72.69	78.22	82.43	83.99	76.17	95.81
森林	63.17	69.33	62.60	70.31	79.52	83.96	81.31	92.85	82.27	97.98
苜蓿	41.20	49.91	45.20	59.88	68.02	89.89	81.42	80.94	73.06	95.03
小麦1	51.26	73.63	48.32	77.89	84.48	80.83	90.47	82.71	84.66	98.35
甜菜	43.23	61.16	38.00	71.99	78.66	69.09	84.64	76.48	83.93	97.66
土豆	59.23	76.44	55.48	75.78	82.48	76.22	86.73	81.36	81.78	96.82
裸地	48.38	57.74	53.91	61.32	73.03	94.69	92.25	92.70	74.35	97.38
草地	59.45	50.76	51.82	63.78	71.53	74.39	71.54	82.29	75.92	91.42
油菜籽	40.17	50.24	45.77	46.35	61.95	75.58	75.49	80.88	65.45	94.72
大麦	62.50	74.86	51.31	82.12	88.86	90.80	92.97	86.69	85.73	95.94
小麦2	42.96	53.96	42.42	62.36	69.98	84.49	78.93	80.91	71.76	94.22
小麦3	61.74	79.78	53.24	83.33	89.01	84.59	90.62	75.66	83.92	96.90
水域	51.44	72.56	77.42	73.29	82.39	84.97	95.86	94.79	83.89	98.51
建筑物	85.43	98.29	81.44	96.01	97.71	91.86	93.75	99.95	97.36	100.00
OA	51.29	65.13	50.69	69.45	77.69	80.65	84.98	83.03	79.64	96.51
Kappa	46.83	61.94	46.16	66.65	75.65	78.85	83.59	81.43	77.74	96.19

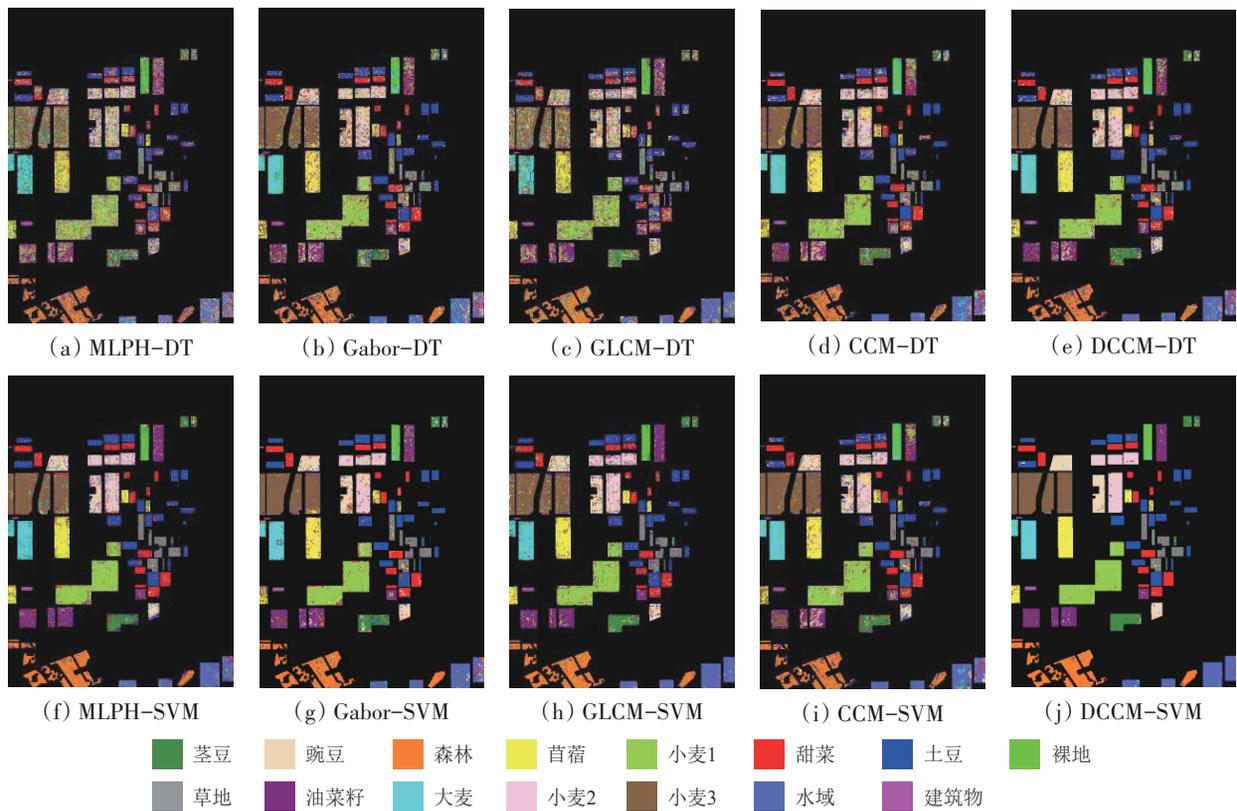


图7 AIRSAR数据HH极化分类结果图

Fig. 7 Classification results of HH polarization in AIRSAR dataset

表3 AIRSAR 数据 VV 极化地物分类精度和 Kappa 系数

Table 3 Classification accuracy and Kappa coefficient of VV polarization in AIRSAR dataset

类别	DT					SVM				
	MLPH	Gabor	GLCM	CCM	DCCM	MLPH	Gabor	GLCM	CCM	DCCM
茎豆	26.73	32.67	31.60	37.26	52.30	90.16	80.36	85.69	57.52	92.89
豌豆	34.05	54.45	37.85	58.77	71.60	74.79	82.18	84.37	69.08	95.61
森林	60.73	65.60	65.70	62.19	77.42	77.95	75.62	94.17	72.77	96.51
苜蓿	58.04	68.63	45.06	75.23	83.79	90.27	88.57	83.86	81.09	97.51
小麦1	43.14	63.45	47.69	64.04	72.90	75.86	77.84	82.76	72.61	94.55
甜菜	40.26	48.41	39.69	56.52	65.78	74.43	77.85	73.95	72.98	94.80
土豆	47.55	60.33	48.16	56.27	68.38	66.41	79.58	75.28	67.73	93.07
裸地	40.00	54.79	54.10	60.44	73.58	93.75	88.93	94.18	72.86	97.25
草地	58.06	57.88	57.42	64.81	76.17	78.42	74.40	79.89	74.49	92.93
油菜籽	37.12	50.03	43.85	51.75	63.28	76.16	75.14	79.07	62.77	92.32
大麦	61.15	78.17	48.90	84.07	91.34	94.55	94.85	84.43	88.82	98.88
小麦2	37.41	51.73	38.73	54.58	66.32	79.62	74.44	81.82	65.56	93.62
小麦3	56.46	80.36	51.86	85.88	88.91	80.43	90.53	79.44	87.24	96.83
水域	42.71	64.16	73.15	57.10	72.66	77.26	94.13	94.43	75.27	97.70
建筑物	34.54	71.44	74.37	51.14	68.40	90.05	97.24	98.76	65.82	97.82
OA	46.90	61.33	49.15	63.48	73.97	78.09	81.65	82.65	73.78	95.22
Kappa	42.04	57.80	44.49	60.13	71.58	76.02	79.93	81.03	71.35	94.78

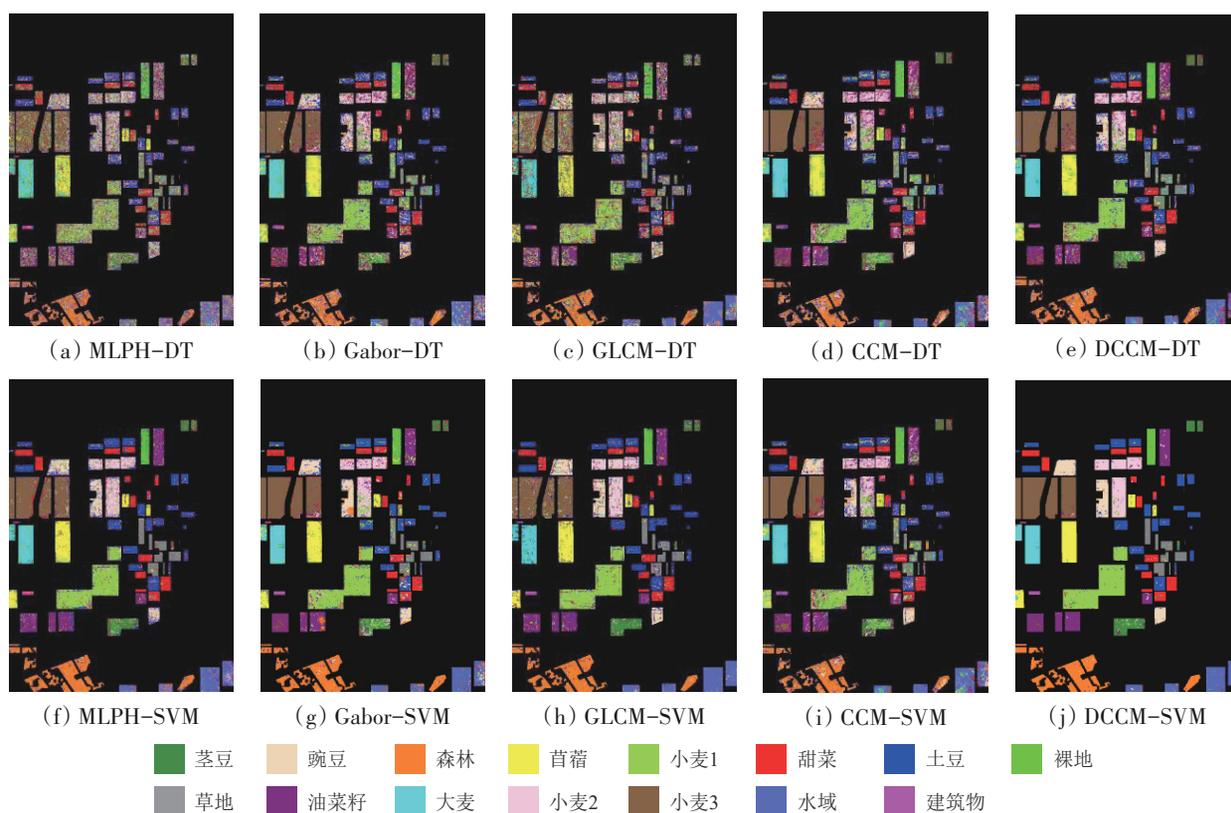


图8 AIRSAR 数据 VV 极化分类结果图

Fig.8 Classification results of VV polarization in AIRSAR dataset

从 VV 极化数据的分类结果图上看, 可以得到与 HH 极化类似的结论。可以看到, GLCM 方法的

分类结果图容易存在噪声的现象在此处更加显著。在 SVM 分类器上, GLCM 方法没有出现大面积错

误, 但几乎每块地物上都散布着零星的误分像素, 该现象在小麦 3 上尤为明显。相比之下, 总体精度更低的 Gabor 方法和 MLPH 方法则更多是在地物边缘出现错误, 分类结果的完整性更好。这可能反映了 GLCM 纹理特征有时并不适应 SAR 图像特性, 因此没能很好地提取图上空间信息。对比其他方法, DCCM 方法取得了很好的分类结果, 分类错误较少, 并且地物完整性得到了较大提升。

### 4.3 UAVSAR 数据集地物分类实验

实验数据二是机载 L 波段雷达 UAVSAR 于 2012 年获取的加拿大 Manitoba 地区数据, 大小为  $1011 \times 1325$ 。该区域有 7 类农作物, 包括燕麦、油菜籽、小麦、玉米、大豆、草料作物和阔叶林。该数据的 HH 和 VV 极化图像分别如图 9 (a) (b) 所示, 真值如图 10 所示。

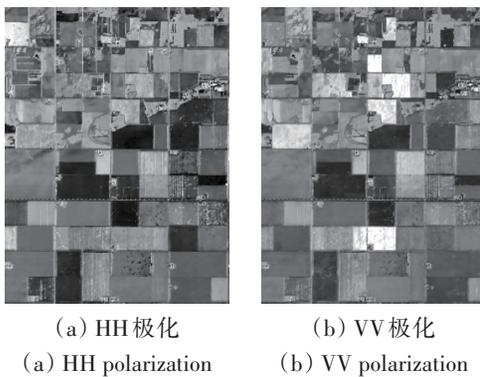


图 9 UAVSAR 数据图像

Fig. 9 SAR images of UARSAR dataset

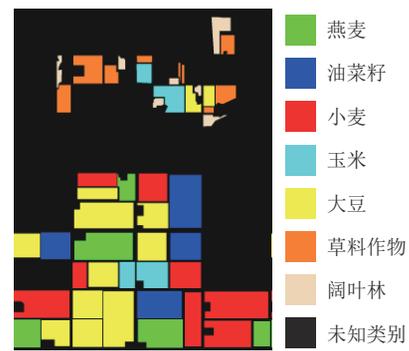


图 10 UAVSAR 数据真值

Fig. 10 Ground truth of UAVSAR dataset

对 HH 极化数据的地物分类精度和 Kappa 系数如表 4 所示, 对应的分类结果如图 11 所示。在 DT 分类器上, DCCM 方法的总体分类精度达到了 84.92%, CCM 方法达到了 77.66%, 而其他方法均不到 70%。在 SVM 分类器上, DCCM 方法的总体分类精度 (96.95%), 高出其他方法 7% 以上。GLCM 方法 (89.56%) 和 CCM 方法 (85.23%) 也取得了不错的分类精度。而在 AIRSAR 数据上表现较好的 Gabor 方法在此表现不佳, 总体精度仅为 79.96%。此外, MLPH 方法在两个分类器上分类效果都比较差, 总体精度均不到 60%。几种方法的 Kappa 系数高低与总体分类精度呈现出对应的关系。不难看出, 在对比方法性能出现波动的情况下, DCCM 方法依旧获得了较好的分类结果, 反映了 DCCM 纹理特征在这两景数据上均能有效挖掘图像上下文信息, 具有更好的稳健性。

表 4 UAVSAR 数据 HH 极化地物分类精度和 Kappa 系数

Table 4 Classification accuracy and Kappa coefficient of HH polarization in UAVSAR dataset

类别	DT					SVM				
	MLPH	Gabor	GLCM	CCM	DCCM	MLPH	Gabor	GLCM	CCM	DCCM
阔叶林	58.53	45.42	DT	61.17	70.42	74.68	74.48	91.17	77.74	98.36
草料作物	54.39	47.81	54.66	63.75	72.47	69.62	75.86	90.04	79.52	96.00
大豆	66.57	82.90	70.47	86.30	91.12	58.59	85.71	88.80	89.54	97.30
玉米	56.61	46.15	62.11	61.55	71.10	73.35	57.17	93.70	77.14	95.60
小麦	46.00	73.46	66.56	80.66	88.09	47.34	84.13	87.59	86.71	96.97
油菜籽	62.89	57.57	65.67	70.55	79.71	68.73	75.96	91.90	80.42	96.58
燕麦	51.18	74.22	60.49	79.81	87.93	58.29	81.09	89.90	85.92	97.33
OA	54.87	69.43	65.16	77.66	84.92	57.30	79.96	89.56	85.23	96.95
Kappa	42.94	61.69	56.26	71.97	81.09	45.25	74.80	86.87	81.42	96.17

结合分类结果图进行分析, 首先注意到 MLPH 方法大面积混淆了小麦、大豆和燕麦等地物, 因此其总体分类精度较低。与 AIRSAR 数据类似,

GLCM 方法在 SVM 分类器上取得了较高的分类精度, 其分类结果图上没有大面积的误分类, 但存在明显的、无关地物类别的噪声, 地物完整性较

差。这对于基于图像分类的后续应用，如地图制图、变化分析等都是不利的。在SVM分类器上，Gabor方法对玉米和油菜籽、小麦和燕麦等地物存在较多混淆，可能是由于这几种农作物的纹理和散射强度都比较相似。然而可以发现，DCCM方法

虽然也对这几类地物出现了错误分类，但相比Gabor方法有了明显改善，反映了DCCM在提取SAR图像上的细微纹理差异时更具优势。总的来说，DCCM方法取得了最佳的分类结果，其分类正确率更高，得到的地物完整性更好。

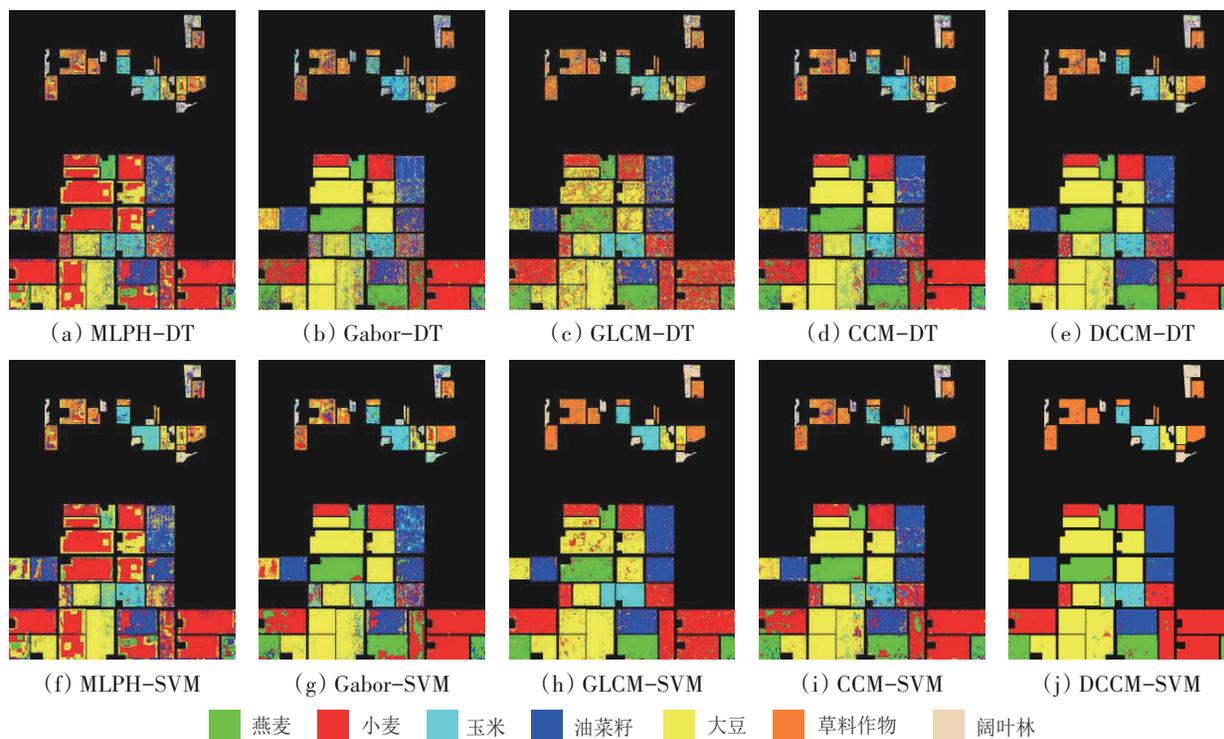


图 11 UAVSAR 数据 HH 极化分类结果图

Fig. 11 Classification results of HH polarization in UAVSAR dataset

对VV极化数据的地物分类精度和Kappa系数如表5所示，分类结果如图12所示，从中可以得到的结论与HH极化基本一致。DCCM方法在DT和SVM分类器上的总体分类精度分别达到了87.33%和97.40%，展现出优异的性能。相比其他方法，DCCM方法对总体精度提升达到7%以上。注意到，GLCM方法在SVM分类器上的总体精度已经达到了90%以上，但是其结果图上的噪声依旧显著（图12（h））。推测是GLCM纹理特征没能很好地利用SAR图像上像素之间的空间相关性，从而导致了较多噪声的出现。另外，相比CCM方法，DCCM方法对燕麦、小麦和油菜籽等地物的分类效果明显改善，再次证明了方向性信息对于更精细地刻画纹理、提升地物可分性的必要性。

结合AIRSAR数据和UAVSAR数据的实验结果，可以认为DCCM纹理特征能够较好地提取SAR图像上下文信息，提升地物的可辨识度。基

于DCCM纹理特征的分类方法在两景数据上均取得了最好的分类结果。该方法能够更好地适应SAR图像特性，显著减少了地物之间的混淆，提升了SAR图像地物分类性能。此外，相比其他方法，DCCM方法得到的分类结果图更加完整、平滑，对于后续应用更加有利。

#### 4.4 基于卷积神经网络的地物分类实验

近年来，越来越多的深度学习方法被引入SAR图像处理并得到成功应用。由于端到端的深度学习方法缺乏可解释性和可控性，有时未必能适应SAR图像特性，因此发展结合专家知识和机理的深度学习方法是提升其应用性能的一个重要途径。本节将所提方法结合CNN开展实验，以验证DCCM纹理特征与深度学习方法结合的可行性。

本节采用了1个基本的3层CNN（Chen和Tao，2018）进行地物分类实验，网络结构如图13所示。该网络包含3个卷积层、两个最大池化层和1个全

连接层。网络输入为 $15 \times 15 \times m$ 的特征图像，其中 $m$ 是特征维度。对于DCCM纹理特征而言， $m=21$ 。3个卷积层中，分别采用了30、60、120个大小为 $2 \times 2$ 的卷积核，卷积步长为1。每两个卷积层之间

设置了一个 $2 \times 2$ 的最大池化层，其步长为2。最后，对全连接层应用了Dropout正则化方法，然后通过Softmax函数输出网络预测的类别标签。

表5 UAVSAR数据VV极化地物分类精度

Table 5 Classification accuracy and Kappa coefficient of VV polarization in UAVSAR dataset

类别	DT					SVM					/%
	MLPH	Gabor	GLCM	CCM	DCCM	MLPH	Gabor	GLCM	CCM	DCCM	
阔叶林	64.19	46.97	52.85	57.34	69.91	83.97	74.80	91.32	76.18	97.55	
草料作物	52.96	45.48	51.43	61.13	71.19	70.66	72.97	86.82	77.17	92.12	
大豆	68.22	76.43	72.01	82.49	88.96	68.97	80.26	89.71	87.59	96.95	
玉米	95.18	98.80	69.62	99.49	99.58	98.84	98.03	94.12	99.85	99.98	
小麦	53.08	76.22	67.02	82.99	89.88	53.78	83.81	88.49	87.60	98.07	
油菜籽	65.79	64.02	63.75	74.74	84.08	75.11	77.54	91.47	84.26	97.36	
燕麦	51.20	75.01	63.92	80.46	88.86	60.11	80.75	91.31	87.97	98.61	
OA	62.10	72.78	66.29	80.11	87.33	66.38	81.57	90.02	87.05	97.40	
Kappa	52.04	65.87	57.69	75.03	84.11	57.09	76.71	87.45	83.68	96.74	

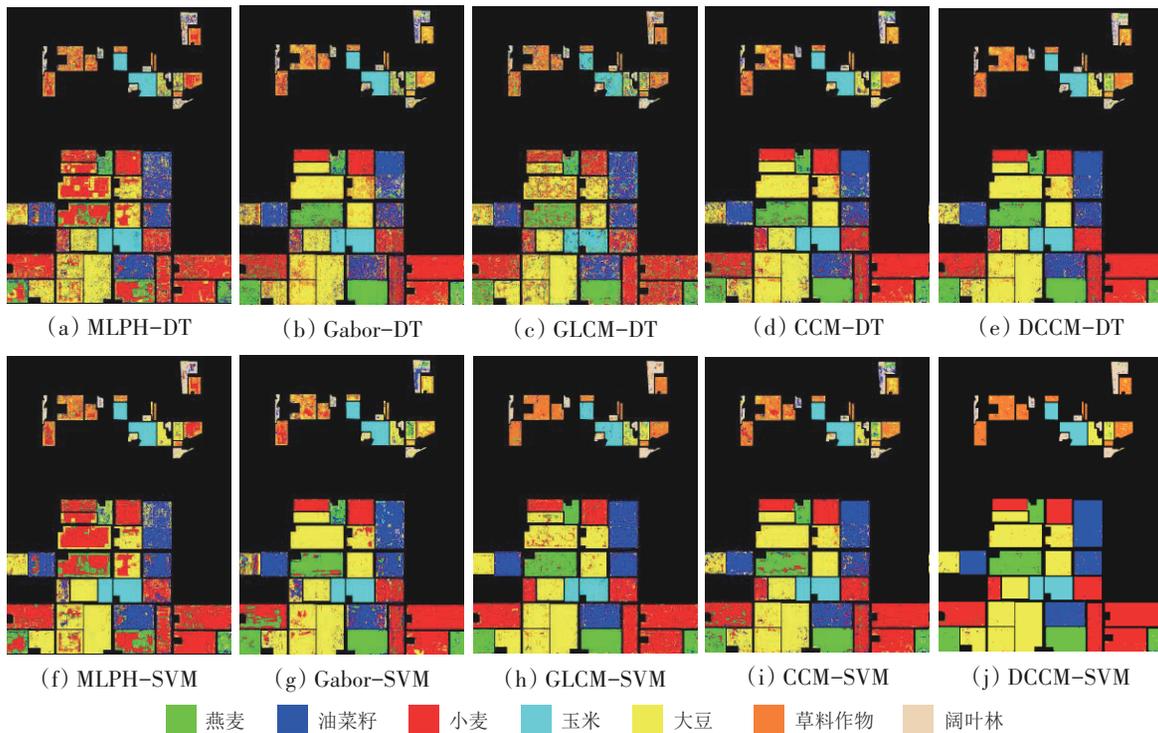


图12 UAVSAR数据VV极化分类结果图

Fig. 12 Classification results of VV polarization in UAVSAR dataset

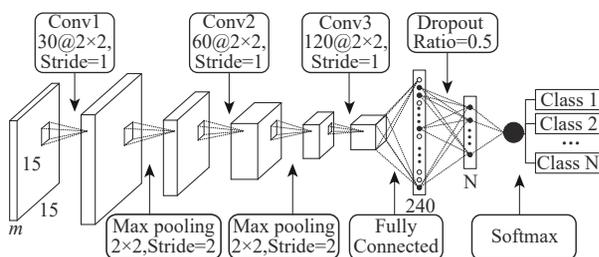


图13 CNN网络结构图

Fig. 13 CNN architecture

实验对比了基于原始数据的CNN以及基于纹理特征的CNN，前者属于端到端的深度学习方法，而后者是结合手工提取特征的深度学习方法。在基于纹理特征的CNN中，采用了5种纹理特征分别与CNN结合以对比不同纹理特征的性能，包括GLCM、Gabor滤波、CCM和DCCM纹理特征。为了与上一节实验中 $25 \times 25$ 的邻域窗口保持一致，这

里先从纹理特征图上取出  $25 \times 25 \times m$  的图像块, 然后缩放成  $15 \times 15 \times m$  作为网络输入。由于结合纹理特征的 CNN 在 10% 训练率下分类精度均可达到 99%, 性能差距不明显, 所以本节将训练率设置为 5%, 以便对比不同特征的分类性能。此外, 这里将结合 SVM 分类器的 DCCM 分类方法也加入对比, 以比较传统方法和深度学习方法的性能差异。实验中采用全图分类精度和 Kappa 系数作为评价指标。

AIRSAR 数据的分类精度和 Kappa 系数如表 6 所示。相比基于原始数据的 CNN (以下简称原始 CNN), 基于纹理特征的 CNN 在分类精度和 Kappa 系数上均有显著提升。其中, MLPH-CNN 取得了最佳的分类精度 (98.92% 和 98.78%), 略高于 DCCM-CNN (98.91% 和 98.62%)。这可能是由于 MLPH 是一种多尺度的特征, 对于不同尺度的地物或地物边缘能够更好地贴合。但这也导致了 MLPH 特征维度较高 (75 维), 需要更强大的分类器才能拟合, 因而没能在 4.2 节的传统分类器实验中取得很好的结果。相比之下, DCCM 特征维度 (21 维) 不及 MLPH 特征的三分之一, 但取得了与之相近的精度, 说明 DCCM 特征是简洁而高效的。GLCM-CNN 和 CCM-CNN 的分类精度比上述两种特征低了 1% 左右。而在传统分类器上表现较好的 Gabor 滤波纹理特征结合 CNN 后则表现没那么好, 在基于纹理的 CNN 中精度最低。此外注意到, 传统方法 DCCM-SVM 的分类精度 (92.78% 和 90.78%) 高于原始 CNN (89.96% 和 87.26%), 说明 SAR 数据直接结合 CNN 未必能取得超越传统方法的效果。因此, 结合手工提取特征是提升深度学习方法分类性能的有效途径。

表 6 AIRSAR 数据分类精度和 Kappa 系数  
Table 6 Classification accuracy and Kappa coefficient in AIRSAR dataset

方法	HH		VV	
	OA	Kappa	OA	Kappa
原始 CNN	89.96	89.03	87.26	86.07
MLPH-CNN	98.92	98.82	98.78	98.66
Gabor-CNN	96.52	96.20	97.38	97.14
GLCM-CNN	97.50	97.27	97.41	97.17
CCM-CNN	97.45	97.21	97.76	97.55
DCCM-CNN	98.91	98.81	98.62	98.50
DCCM-SVM	92.78	92.11	90.78	89.93

UAVSAR 数据的分类精度和 Kappa 系数如表 7 所示。由于 MLPH-CNN 在网络训练中无法收敛,

因此没有展示在表格中。结合 4.3 节中基于 MLPH 特征方法混淆了多类地物的情况, 可以推测是 MLPH 特征在该数据上无法提取出具有区分度的纹理信息。该数据上, DCCM-CNN 取得了最佳的分类精度 (99.43% 和 99.57%) 和 Kappa 系数, 相比原始 CNN 提升了 10% 以上。GLCM-CNN 也取得了较好的精度 (99% 和 98.83%), 略高于 CCM-CNN (98.03% 和 98.30%)。与 AIRSAR 数据类似, DCCM-SVM 也取得了比原始 CNN 更好的分类效果, 再次验证了结合知识和机理的重要性。

表 7 UAVSAR 数据分类精度和 Kappa 系数  
Table 7 Classification accuracy and Kappa coefficient in UAVSAR dataset

方法	HH		VV	
	OA	Kappa	OA	Kappa
原始 CNN	82.71	78.14	89.01	86.12
Gabor-CNN	97.38	96.72	92.31	90.34
GLCM-CNN	99.00	98.74	98.83	98.53
CCM-CNN	98.03	97.52	98.30	97.87
DCCM-CNN	99.43	99.29	99.57	99.46
DCCM-SVM	94.28	92.82	94.96	93.67

综上所述, 结合 DCCM 纹理特征的 CNN 能够有效提升 SAR 图像地物分类性能, 取得优异的分类结果。相比于传统分类器, CNN 固然性能更加强大, 但直接将原始数据输入 CNN 却未必是最好的选择。本节实验验证了结合手工提取的纹理特征可以进一步提升 CNN 的分类性能。在结合纹理特征的方法中, 虽然 MLPH-CNN 在 AIRSAR 数据上分类精度略高于 DCCM-CNN, 但 DCCM 方法整体表现更加稳健, 能在两景数据、3 种分类器上均取得较好的结果。MLPH 特征虽然能够提取多尺度纹理, 但由于特征维度过高等原因, 需要更强大的分类器才能发挥作用。并且 MLPH 方法在 UAVSAR 数据上表现不够稳健。而结合其他纹理特征的方法在分类精度和 Kappa 系数上都没能超越 DCCM 方法。尤其是在性能相对较弱的传统分类器上, DCCM 方法的优势更加显著, 说明 DCCM 特征是一种高效、稳健的 SAR 图像纹理特征。

## 5 分析与讨论

### 5.1 算法耗时分析

本文传统分类器实验在 MATLAB R2018b 上运行, 平台配置为 Intel Core i7-10750H CPU@2.60 GHz,

内存 16.0 GB。CNN 实验在 python3.6+Tensorflow1.13 上运行，CPU 配置为 Intel Xeon CPU E5-2699 v4@2.2 GHz，GPU 配置为 NVIDIA Quadro RTX5000。上文所用几种方法在特征提取和分类阶段的运算时间如表 8、表 9 所示。由于几种方法的 DT 分类时间都很短（1 s 以内），所以此处不作详细讨论。

表 8 AIRSAR 数据上的运算时间

Table 8 Computing time on AIRSAR dataset

方法	特征提取	SVM	CNN
MLPH	460	53	3765
Gabor	2	21	2544
GLCM	738	27	2193
CCM	177	8	2385
DCCM	250	10	2344

表 9 UAVSAR 数据上的运算时间

Table 9 Computing time on UAVSAR dataset

方法	特征提取	SVM	CNN
MLPH	705	251	/
Gabor	4	194	5463
GLCM	1435	214	5659
CCM	312	122	4084
DCCM	460	130	5463

结合两表分析可以发现，在特征提取阶段，Gabor 方法用时最短（小于 5 s）。其次，速度较快的是 CCM 方法（177 s 和 312 s）。由于加入了方向信息，DCCM 方法的运算耗时（250 s 和 460 s）相对 CCM 有所增加。MLPH 方法和 GLCM 方法耗时最长，MLPH 方法耗时约为 DCCM 方法的 1.5 到 2 倍，而 GLCM 方法耗时达到了将近 3 倍。分类阶段的运算时间主要与特征向量维度和分类器有关，表中给出的分类时间为分类器训练与分类的时间总和。在 SVM 分类器上，CCM 方法和 DCCM 方法是耗时最短的。GLCM 方法和 Gabor 方法分类耗时约为 DCCM 方法的 1.5 倍，而 MLPH 方法由于特征维度最高而耗时最长。CNN 上的运算时间由于受服务器状态影响较大，没有呈现出特别明确的规律。但仍然可以发现，MLPH 方法由于特征维度显著高于其他方法，所需的训练和分类时间更长。

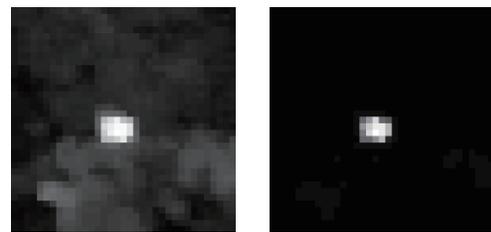
结合前面的分类结果，可以看出 Gabor 方法特征提取速度很快，但得到的纹理特征有时候缺乏足够的鉴别力，分类性能一般。GLCM 方法在

UAVSAR 数据上分类精度较高，但特征提取和分类都较为耗时。DCCM 方法在运算耗时上相比 MLPH 方法和 GLCM 方法有一定的优势，并且在两景数据上均取得了较好的分类精度。由此可见，DCCM 方法较好地平衡了运算效率和分类性能。

## 5.2 SAR 图像量化对纹理提取的影响

相比普通光学图像，SAR 图像通常呈现出更大的动态范围。有时候这种动态范围主要来源于二面角等结构或金属材质的物体，它们在成像场景中占比很小却强度很大，造成图像上大部分区域都显得很暗且对比度不足。这对于面状地物的纹理提取不利，特别是以 GLCM 为代表的一部分纹理特征，它们的运算过程包含量化操作，即需要将输入图像的像素值划分为一定的灰度级数。强散射点的存在可能会使本就对比度不足的暗区域被划入很少的灰度级中，从而丢失了其中的纹理信息。相比之下，DCCM 可以直接针对浮点型数据进行计算，在动态范围较大的场景不容易丢失信息，在 SAR 图像上下文信息提取中更有优势。

图 14 (a) 展示了一个存在强散射点的森林区域 SAR 图像切片，从图中可以观察到暗部包含许多树冠的纹理细节。图 14 (b) 则是将其量化为 16 个灰度级（GLCM 计算中的典型取值）后的图像，对比发现大部分的树冠纹理都丢失了，只剩下强散射点本身。



(a) 量化前 (b) 量化后  
(a) Before quantization (b) After quantization

图 14 SAR 图像切片量化前后对比

Fig. 14 A slice of SAR image before and after quantization

为了定量分析几种纹理特征在大动态范围场景下的性能，选取了两个包含强散射点的 SAR 图像切片进行分析。所选切片如图 15 所示，两个切片对应的地物分别为油菜籽和豌豆。这里通过两种地物在不同特征空间中的类间距离与类内距离之比来反映特征对地物的区分度，该比值越大，

说明地物可分性越好。其中,为了消除特征各维度的尺度和分布不一致的问题,用马氏距离来衡量特征空间中样本之间的距离。此外,为了避免强散射点本身对距离计算的影响,对整个切片提取特征后,切除包含强散射点的部分再计算距离,得到的结果如表 10 所示。从表中可以看到, DCCM 和 Gabor 滤波这两种提取过程不需要量化的纹理特征取得了较高的类间一类内距离比。其中, DCCM 特征呈现出最优的地物区分性能。而 GLCM 特征和 MLPH 特征的一类内距离比则相对较低,验证了量化操作对大动态范围下的纹理提取有着一定影响。

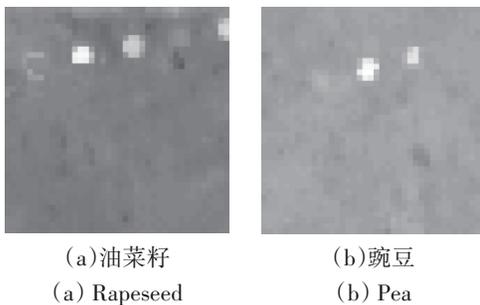


图 15 包含强散射点的 SAR 图像切片

Fig. 15 Slices of SAR images with strong scattering points

表 10 含强散射点切片的类间一类内距离比

Table 10 The ratio of inter-class distance to inner-class distance of slices with strong scattering points

距离	特征			
	DCCM	GLCM	Gabor	MLPH
类内	2.93	12.86	5.10	56.08
类间	3.59	13.57	5.65	57.03
类间/类内	1.22	1.06	1.11	1.02

### 5.3 DCCM 的高维拓展

上述的 DCCM 构造方式是针对单通道 SAR 图像提出的,但同样可以推广到多通道 SAR 情形。以全极化 SAR 图像为例,将各极化通道上构造的上下文散射矢量进行拼接

$$\mathbf{k}_i = [s_{HH}^1 \ s_{HH}^2 \ s_{HH}^3 \ s_{HV}^1 \ s_{HV}^2 \ s_{HV}^3 \ s_{VH}^1 \ s_{VH}^2 \ s_{VH}^3 \ s_{VV}^1 \ s_{VV}^2 \ s_{VV}^3]^T \quad (5)$$

式中,下标表示极化通道,上标表示空间位置。比如  $s_{HH}^1$  表示 HH 极化构造的上下文散射矢量的第一个值。于是可以得到全极化 DCCM

$$\mathbf{C}_{Pol}^d = \frac{1}{N^d} \sum_{i=1}^{N^d} \mathbf{k}_i^d \mathbf{k}_i^{dH} \quad (6)$$

全极化 DCCM 不仅包含了空间维度的上下文

信息,也包含了不同极化通道之间的相关信息。因此,全极化 DCCM 进一步拓展了信息容量。不难发现, DCCM 中协方差矩阵的维度仅与原图像的通道数有关。比如单极化 SAR 图像中, DCCM 为一组  $3 \times 3$  的协方差矩阵。而对于双极化和全极化图像, DCCM 则分别对应  $6 \times 6$  和  $9 \times 9$  的协方差矩阵。矩阵的主对角元素含义仍然是对应区域像素的平均强度,而非对角元素表示不同空间位置、不同极化的像素之间的相关。

## 6 结论

单通道 SAR 图像蕴含着巨大的应用潜力,但像元中有限的信息量却限制了其应用性能。对此,本文结合空间纹理信息对单通道 SAR 图像进行信息维度拓展,提出了方向性上下文协方差矩阵。本文主要创新点包括:(1)提出了 DCCM,将单个像元拓展为一组矩阵,增加了像元信息量,拓宽了信息维度。通过提取邻域中不同方向上的散射强度变化, DCCM 能够精细地表征图像局部上下文信息。此外, DCCM 可以兼容复数浮点型数据而无需量化操作,对于动态范围较大的 SAR 图像具有更好的适应性。(2)提取了 DCCM 纹理特征。该特征通过对数变换改善了由于 SAR 数据分布不均衡导致的纹理对比度不足的问题。并且 DCCM 特征维度较低,无需复杂的调参处理。在此基础上,构建了一种 SAR 图像分类方法。该方法既可结合传统分类器,又可结合深度学习方法,具有较好的实用性。

分别结合传统分类器和 CNN,本文在 AIRSAR 和 UAVSAR 数据上开展了对比实验。结果表明,在传统分类器上,所提方法的分类性能显著优于基于 GLCM、Gabor 滤波和 MLPH 的分类方法,总体精度提升达到 7% 以上。结合 CNN 的实验中, DCCM 方法也展现出了优异的分类性能和较好的稳健性。未来的工作中,我们将考虑结合多极化、多时相的 SAR 数据,探究 DCCM 在多通道 SAR 图像上的特性,进一步挖掘其应用潜能。

### 参考文献 (References)

- Aytekin Ö, Koc M and Ulusoy İ. 2013. Local primitive pattern for the classification of SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 51(4): 2431-2441 [DOI: 10.1109/TGRS.

- 2012.2210428]
- Bi H X, Yao J, Wei Z Q, Hong D F and Chanussot J. 2022. PolSAR image classification based on robust low-rank feature extraction and Markov random field. *IEEE Geoscience and Remote Sensing Letters*, 19: 4005205 [DOI: 10.1109/LGRS.2020.3034700]
- Chellappa R and Chatterjee S. 1985. Classification of textures using Gaussian Markov random fields. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 33(4): 959-963 [DOI: 10.1109/TASSP.1985.1164641]
- Chen S W. 2020. SAR image speckle filtering with context covariance matrix formulation and similarity test. *IEEE Transactions on Image Processing*, 29: 6641-6654 [DOI: 10.1109/TIP.2020.2992883]
- Chen S W and Tao C S. 2018. PolSAR image classification using polarimetric-feature-driven deep convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, 15(4): 627-631 [DOI: 10.1109/LGRS.2018.2799877]
- Chen S W, Wang X S and Sato M. 2012. PolInSAR complex coherence estimation based on covariance matrix similarity test. *IEEE Transactions on Geoscience and Remote Sensing*, 50(11): 4699-4710 [DOI: 10.1109/TGRS.2012.2192937]
- Cheng J, Ji Y Q and Liu H J. 2015. Segmentation-based PolSAR image classification using visual features: RHLBP and color features. *Remote Sensing*, 7(5): 6079-6106 [DOI: 10.3390/rs70506079]
- Cheng X J, Xu J, Liu Q Q and Lu J. 2014. Extraction and evaluation of texture features in SAR images for urban land cover classification. *Geomatics and Spatial Information Technology*, 37(4): 47-50 (程雪姣, 徐佳, 刘庆群, 陆吉. 2014. 面向城市地物分类的 SAR 图像纹理特征提取与分析. *测绘与空间地理信息*, 37(4): 47-50) [DOI: 10.3969/j.issn.1672-5867.2014.04.012]
- Clausi D A. 2001. Comparison and fusion of co-occurrence, Gabor and MRF texture features for classification of SAR sea-ice imagery. *Atmosphere-Ocean*, 39(3): 183-194 [DOI: 10.1080/07055900.2001.9649675]
- Dai D X, Yang W and Sun H. 2011. Multilevel local pattern histogram for SAR image classification. *IEEE Geoscience and Remote Sensing Letters*, 8(2): 225-229 [DOI: 10.1109/LGRS.2010.2058997]
- Dekker R J. 2003. Texture analysis and classification of ERS SAR images for map updating of urban areas in the Netherlands. *IEEE Transactions on Geoscience and Remote Sensing*, 41(9): 1950-1958 [DOI: 10.1109/TGRS.2003.814628]
- Freitas C C, Frery A C and Correia A H. 2005. The polarimetric G distribution for SAR data analysis. *Environmetrics*, 16(1): 13-31 [DOI: 10.1002/env.658]
- Gao G. 2010. Statistical modeling of SAR images: a survey. *Sensors*, 10(1): 775-795 [DOI: 10.3390/s100100775]
- Geng J, Fan J C, Wang H Y, Ma X R, Li B M and Chen F L. 2015. High-resolution SAR image classification via deep convolutional autoencoders. *IEEE Geoscience and Remote Sensing Letters*, 12(11): 2351-2355 [DOI: 10.1109/LGRS.2015.2478256]
- Geng J, Wang H Y, Fan J C and Ma X R. 2017. Deep supervised and contractive neural network for SAR image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(4): 2442-2459 [DOI: 10.1109/TGRS.2016.2645226]
- Guan D D, Xiang D L, Tang X A, Wang L and Kuang G Y. 2019. Covariance of textural features: a new feature descriptor for SAR image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(10): 3932-3942 [DOI: 10.1109/JSTARS.2019.2944943]
- Haghighat M, Zonouz S and Abdel-Mottaleb M. 2013. Identification using encrypted biometrics. //15th International Conference on Computer Analysis of Images and Patterns. York: Springer, 440-448 [DOI: 10.1007/978-3-642-40246-3\_55]
- Haralick R M, Shanmugam K and Dinstein I. 1973. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6): 610-621 [DOI: 10.1109/TSMC.1973.4309314]
- He C, Liu X L, Kang C Y, Chen D and Liao M S. 2017. Attribute learning for SAR image classification. *ISPRS International Journal of Geo-Information*, 6(4): 111 [DOI: 10.3390/ijgi6040111]
- Jain A K and Farrokhnia F. 1991. Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, 24(12): 1167-1186 [DOI: 10.1016/0031-3203(91)90143-S]
- Jiao L C and Liu F. 2016. Wishart deep stacking network for fast POL-SAR image classification. *IEEE Transactions on Image Processing*, 25(7): 3273-3286 [DOI: 10.1109/TIP.2016.2567069]
- Kong J A, Swartz A A, Yueh H A, Novak L M and Shin R T. 1988. Identification of terrain cover using the optimum polarimetric classifier. *Journal of Electromagnetic Waves and Applications*, 2(2): 171-194 [DOI: 10.1163/156939387X00324]
- Lee J S, Grunes M R and Kwok R. 1994a. Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution. *International Journal of Remote Sensing*, 15(11): 2299-2311 [DOI: 10.1080/01431169408954244]
- Lee J S, Schuler D L, Lang R H and Ranson K J. 1994b. K-distribution for multi-look processed polarimetric SAR imagery//Proceedings of IGARSS '94-1994 IEEE International Geoscience and Remote Sensing Symposium. Pasadena: IEEE: 2179-2181 [DOI: 10.1109/IGARSS.1994.399685]
- Lee T S. 1996. Image representation using 2D Gabor wavelets. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(10): 959-971 [DOI: 10.1109/34.541406]
- Liu H Y, Guo H D and Zhang L. 2015. SVM-based sea ice classification using textural features and concentration from RADARSAT-2 dual-pol ScanSAR data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(4): 1601-1613 [DOI: 10.1109/JSTARS.2014.2365215]
- Liu L, Fieguth P, Guo Y L, Wang X G and Pietikäinen M. 2017. Local binary features for texture classification: taxonomy and experi-

- mental study. *Pattern Recognition*, 62: 135-160 [DOI: 10.1016/j.patcog.2016.08.032]
- Ojala T, Pietikäinen M and Harwood D. 1996. A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1): 51-59 [DOI: 10.1016/0031-3203(95)00067-4]
- Ojala T, Pietikainen M and Maenpaa T. 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7): 971-987 [DOI: 10.1109/TPAMI.2002.1017623]
- Oliver C J. 1993. Optimum texture estimators for SAR clutter. *Journal of Physics D: Applied Physics*, 26(11): 1824-1835 [DOI: 10.1088/0022-3727/26/11/002]
- Pentland A P. 1984. Fractal-based description of natural scenes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-6(6): 661-674 [DOI: 10.1109/TPAMI.1984.4767591]
- Qin F C, Guo J M and Sun W D. 2017. Object-oriented ensemble classification for polarimetric SAR Imagery using restricted Boltzmann machines. *Remote Sensing Letters*, 8(3): 204-213 [DOI: 10.1080/2150704X.2016.1258128]
- Tombak A, Türkmenli İ, Aptoula E and Kayabol K. 2019. Pixel-based classification of SAR images using feature attribute profiles. *IEEE Geoscience and Remote Sensing Letters*, 16(4): 564-567 [DOI: 10.1109/LGRS.2018.2879880]
- Li J P, Fu L Q and Han Y. 2010. Parameter design of Gabor filters for feature extraction. *Optics and Optoelectronic Technology*, 8(3): 79-83 (李建萍, 付丽琴, 韩焱. 2010. 用于特征提取的 Gabor 滤波器参数设计. *光学与光电技术*, 8(3): 79-83) [DOI: 10.3969/j.issn.1672-3392.2010.03.020]
- Li Q, Zhang J F, Gong L X, Xue T F and Jiang H B. 2018. Extraction of earthquake-collapsed buildings based on correlation change detection of multi-texture features in SAR images. *Journal of Remote Sensing*, 22(S1): 128-138 (李强, 张景发, 龚丽霞, 薛腾飞, 蒋洪波. 2018. SAR 图像纹理特征相关变化检测的震害建筑物提取. *遥感学报*, 22(S1): 128-138) [DOI: 10.11834/jrs.20187185]
- Tuceryan M and Jain A K. 1993. *Texture analysis/Handbook of Pattern Recognition and Computer Vision*. Toh Tuck Link: World Scientific: 235-276 [DOI: 10.1142/9789814343138\_0010]
- Ulaby F T, Kouyate F, Brisco B and Williams T H L. 1986. Textural information in SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, GE-24(2): 235-245 [DOI: 10.1109/TGRS.1986.289643]
- Wang L, Zhang F, Li W, Xie X M and Hu W. 2015. A method of SAR target recognition based on Gabor filter and local texture feature extraction. *Journal of Radars*, 4(6): 658-665 (王璐, 张帆, 李伟, 谢晓明, 胡伟. 2015. 基于 Gabor 滤波器和局部纹理特征提取的 SAR 目标识别算法. *雷达学报*, 4(6): 658-665) [DOI: 10.12000/JR15076]
- Wu W J, Li H L, Zhang L, Li X W and Guo H D. 2018. High-resolution PolSAR scene classification with pretrained deep convnets and manifold polarimetric parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 56(10): 6159-6168 [DOI: 10.1109/TGRS.2018.2833156]
- Wu Z T, Hou B and Jiao L C. 2021. Multiscale CNN with autoencoder regularization joint contextual attention network for SAR image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 59(2): 1200-1213 [DOI: 10.1109/TGRS.2020.3004911]
- Zhang Z M, Wang H P, Xu F and Jin Y Q. 2017. Complex-valued convolutional neural network and its application in polarimetric SAR image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(12): 7177-7188 [DOI: 10.1109/TGRS.2017.2743222]
- Zhao Z Q, Jia M and Wang L. 2021. High-resolution SAR image classification via multiscale local Fisher patterns. *IEEE Transactions on Geoscience and Remote Sensing*, 59(12): 10161-10178 [DOI: 10.1109/TGRS.2020.3039847]
- Zhao Z Q, Jiao L C, Zhao J Q, Gu J and Zhao J. 2017. Discriminant deep belief network for high-resolution SAR image classification. *Pattern Recognition*, 61: 686-701 [DOI: 10.1016/j.patcog.2016.05.028]

## SAR image directional context covariance matrix: Construction and its application in terrain classification

FU Ting, CHEN Siwei

*State Key Laboratory of Complex Electromagnetic Environment Effects on Electronics and Information System,  
National University of Defense Technology, Changsha 410073, China*

**Abstract:** Synthetic Aperture Radar (SAR) is a kind of high-resolution imaging sensor, which is able to work under nearly all weather and illumination conditions. SAR plays an important role in earth observation. For single-band, single-polarization SAR image, however, there's only one complex scalar in each pixel. So that the information contained in such single-channel SAR image could be quite limited, which

limits its performance in various applications. Since terrain classification is one of the typical tasks in SAR image interpretation, this paper takes it as an example to demonstrate the problem and gives our solution. To address the above problem, this paper proposes a representation for the spatial information on SAR image—the Directional Context Covariance Matrix (DCCM). DCCM obtains the variance of pixel intensity in several orientations inside the neighborhood in order to make use of the context information. During such process, the target pixel is extended from a complex scalar to a group of matrices, so that its information content is increased. Besides, the matrix form also enables some of the advanced matrix algorithms to be applied to single-channel SAR image. On the basis of it, the DCCM texture feature is derived, which can better represent the texture properties on SAR image and shows better discriminability for different land covers. Then, the texture feature is combined with two traditional classifiers as well as the Convolutional Neural Network (CNN), respectively. Thereafter, a SAR image classification scheme is established. To illustrate the performance of proposed method, terrain classification experiments are carried out on AIRSAR and UAVSAR datasets. Methods based on three commonly used texture features, the gray level co-occurrence matrix (GLCM), Gabor filters and Multilevel Local Pattern Histogram (MLPH) are taken into comparison. On traditional classifiers, the overall classification accuracies are increased by 7% on both datasets. While combining with CNN, the overall accuracies and kappa coefficients are significantly improved with DCCM texture feature than the original SAR data. The proposed feature also shows nice efficiency and better robustness when compared to other texture features. The experiment results indicate that DCCM is an effective representation that is suitable for SAR image. DCCM is efficient, robust and easy-to-use. The proposed DCCM based classification method can improve the classification performance of single-channel SAR image by increasing the pixel information content. Beyond that, DCCM could be a promising method for many other SAR image interpretation tasks.

**Key words:** SAR image, representation, directional context covariance matrix, texture, terrain classification

**Supported by** National Natural Science Foundation of China (No.62122091, 61771480); Natural Science Foundation of Hunan Province (No.2020JJ2034); Science and Technology Planning Project of Hunan Province (No. 2019RS2025)