

多光谱和 SAR 遥感图像融合分类的特征选取*

于秀兰 钱国蕙 贾晓光

(哈尔滨工业大学电子与通信工程系, 黑龙江, 哈尔滨, 150001)

摘要 针对多光谱和 SAR 遥感图像特征层融合分类的特征选取问题, 以 Landsat 卫星的 TM 图像和 JERS-1 卫星的 SAR 图像融合分类为例, 给出了一种基于 Rough Set 理论的最佳分类特征选取方法

关键词 Rough Set 理论, 多光谱和 SAR 遥感图像, 融合分类, 特征选取

CHARACTER SELECTION OF MULTI-SPECTRAL AND SAR REMOTE SENSING IMAGE FUSION CLASSIFICATION*

YU Xiu-Lan QIAN Guo-Hui JIA Xiao-Guang

(Department of Electronic & Communication Engineering,

Harbin Institute of Technology, Harbin, Heilongjiang 150001, China)

Abstract A best-classification character selection method based on Rough Set theory was presented with an example of fusion classification of Landsat TM and JERS-1 SAR images in this paper focusing on the character selection of the multi-spectral and SAR remote sensing images fusion classification

Key words Rough Set theory, multi-spectral and SAR remote sensing image, fusion classification, character selection

引言

多光谱和 SAR 遥感图像融合分类可以提高某些地物的分类精度, 其研究已成为国内外研究的热点^[1]. 多光谱和 SAR 遥感图像特征层融合分类一般采用模式识别技术中的分类器设计方法, 但是由于特征维数的加大增加了分类的计算消耗, 并且某些特征的加入可能会使分类精度降低, 因此有必要研究融合分类特征选取问题

特征选取包括特征选择和特征提取两类方法. 特征选择的最简单方法是利用专家的知识 and 经验, 严格方法是在给定约束条件下通过数学方法进行筛选, 这些约束条件形成各种准则函数. 实际应用中这些准则复杂而繁琐, 遥感图像分类特征选择主要还是通过分类实验进行, 如 Soiberg^[2]等人对 SAR 图像多纹理特征分类及 Sylbic^[3]等人对机载多光谱和多频率 SAR 数据进行无监督分类都是通过分类实验比较选择特征. 这样完全依靠分类实验选取特征计算量太大, 实用性差. 特征提取方法包括主成分分

析、判别式分析, 决策边界特征提取和 Benedikts-son^[4]等人提出的神经网络模型方法, 这些方法的缺点也是计算量大, 并且分类的精度也不高. 因此在多传感器遥感图像的特征层融合分类中常常选取很多特征用于分类, 如 Soiberg^[5]等人对 Landsat 卫星 TM 和 ERS 卫星的 SAR 图像的融合分类及 Mather^[7]等人利用 Landsat 卫星的 TM 和 SIR-A 的 SAR 图像对苏丹红海地区的岩石判别时, 都是选取尽可能多的特征, 全部用于分类, 目前文献中还没有给出一种简单实用的特征选取方法

本文尝试了应用粗集理论 (Rough Set) 对 Landsat 卫星的 TM 和 JERS-1 卫星的 SAR 图像融合分类进行特征选取, 实验结果表明了该方法选取的特征的有效性

1 Rough Set (RS) 理论的一些基本概念

RS 理论是 80 年代初波兰数学家 Z Pawlak^[6-9]提出的一个分析数据的数学理论, 现已广泛地应用于机器学习、知识获取、决策分析和过

* 国防基金(编号: Y96-01)资助项目
稿件收到日期 2000-12-09, 修改稿收到日期 2000-04-08

* The project supported by the National Defense Funds of China
Received 2000-12-09, revised 2000-04-08

程控制等研究领域,成为人工智能领域中一个新的研究热点。在RS理论中,“知识”被认为是一种根据特征属性将现实/抽象对象进行分类的能力。集合的划分依赖于所掌握的关于论域(研究对象的全体称为论域 U)的知识,是相对的。论域 U 被一族等价关系 R 分割成互不相交的子集 $E_i(i=1,2,\dots,n)$,称 E_i 为基本等效类。

设集合 $X \subseteq U$, R 是定义在 U 上的等价关系,则 X 相对于 R 的粗糙定义为

$$\alpha_R(X) = \frac{\text{card}(R_*(X))}{\text{card}(R^*(X))} \quad (1)$$

式(1)中, card 为求集合成员个数的函数; $R_*(X)$ 为 X 关于 R 的下逼近,是由那些根据现有知识判定在 U 中肯定属于 X 的对象所组成的最大集合; $R^*(X)$ 为 X 关于 R 的上逼近,是那些 U 中可能属于 X 的对象所组成的最小集合。

RS理论使用决策表描述论域中的对象。决策表是一个二维表格,每一行描述一个对象(也称实例),每一列描述对象的一种属性。通过对决策表进行约简实现分类规则的自动提取。约简的步骤通常为:

(1) 删除相同的实例; (2) 删除表中多余的列(条件属性): 逐一去除各条件属性,看是否影响分类,如不影响分类,则去除该条件属性。这样,通过删除多余实例和多余属性,来得到RS理论分类规则。

2 多光谱和 SAR 遥感图像分类决策表建立、约简和最优特征选取

2.1 实验图像及分类采集的特征

以哈尔滨市附近某地区的1997年6月14日 Landsat 卫星的 TM 图像(见图1)和1997年4月



图1 TM 345 波段彩色合成灰度图
Fig. 1 Color-composition gray image of band TM 345

29日的 JERS-1 的 SAR 图像(见图2)融合分类应用为例: 实验图像配准后像素分辨率为12.5m, 图像大小为512×512像素。地物的真实类别结合实地考察获取(两时相图像地物类型没有变化)。该地区主要包含旱田、特殊旱田类作物-小麦、盐碱地、居民点和荒草地。学习样本和检验样本数见表1。

表1 学习样本和检验样本数

Table 1 Pixel numbers of learning and test samples					
样本	旱田	小麦	盐碱地	居民点	荒草地
学习样本数	830	893	848	846	841
检验样本数	5906	3839	8395	7614	3820

特征层融合分类时, TM 选取6个空间分辨率相同的光谱特征,分别为 T_1-T_6 ; SAR 图像的特征,根据文献[3],并通过实验比较,选取由灰度共生矩阵(参数为5×5窗口、灰度等级为8,方向为0度,距离为1个像素)提取的集群熵(T_7)、对比度(T_8)、相关(T_9)、能量(T_{10})、熵(T_{11})和局部平稳(T_{12})6个纹理特征,为了约简方便,将所有特征线拉伸到0~255。

2.2 遥感图像融合分类决策表的建立

直接利用学习样本作为多传感器遥感图像RS理论中的决策表的实例来得到约简是很困难的: 因为遥感图像分类时,为了表征各类样本的统计特性,通常选取的学习样本数量较大,这样会使决策表过于庞大,约简困难;而减少学习样本的数量,又会造成决策表中的实例不能完全表征遥感图像特征的统计特性,会得出不当的约简。

考虑到遥感图像中某一类别的地物的各个特征一般都服从一定空间分布,并且基本上都是在某一均



图2 TM 345 与 SAR 合成灰度图(ISH 合成)
Fig. 2 TM 345 and SAR composition gray image (ISH)

值附近波动, 可以看成是正态或近似正态分布, 即

$$p(t|c) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp[-\frac{1}{2\sigma^2}(t-\mu)^2], \quad (2)$$

式(2)中, μ, σ 分别为 c 类地物的特征 t 的均值和标准方差 如果对于样本空间的全部样本只考虑这一个特征, 并且将该特征轴分为两个子集 ($-\infty, \mu-2\sigma$) ($\mu+2\sigma, +\infty$) 和 $[\mu-2\sigma, \mu+2\sigma]$, 前一个子集对应非 c 类地物, 后一个子集对应 c 类地物, 则根据概率知识, $[\mu-2\sigma, \mu+2\sigma]$ 子集包含了全部 c 类地物的 97.7%, 即

$$P(\mu-2\sigma \leq t \leq \mu+2\sigma) = 97.7\%, \quad (3)$$

采用 $\pm 3\sigma$ 虽然概率为 99.9%, 但会使 c 类地物与其它类地物灰度重叠区加大, 获取约简困难; 因此对于决策属性 c , $[\mu-2\sigma, \mu+2\sigma]$ 这一范围的条件属性被近似认为包含了所有这一决策类的条件属性 这样得到实验图像分类决策表(见表 2). 为约简计算方

便, 对表 2 中值下限直接取整数, 上限加 1 后取整数

2.3 决策表的约简

对决策表进行约简时, 分别以各条件属性的上下限为门限, 对全图像进行分类 在 $\pm 2\sigma$ 条件下, 每一条件属性将得到小于等于 8 个等价关系, 找出最优等价关系的分类(这里的最优等价关系分类的含义为分类后各子集中重叠越少越好). 对上述决策表中, 可得到特征 $T_1 \sim T_{12}$ 的各个条件属性对论域的分类的最优等价关系(见表 3). 表 3 中用阿拉伯数字 1~5 代替 $T_1 \sim T_5$

由表 3 可以得出: T_1, T_2, T_3 为重复特征; T_5 亦为重复特征, 且分类效果差于 T_1, T_{12} 和 T_3 , 则对于分类 $\{C_1, C_2, C_5\}$ 和 $\{C_3, C_4, C_5\}$, T_1, T_2, T_3 任选其一即可; 特征 $T_6 \sim T_{12}$ 为重复特征, 任选其一即可; T_4 为分类必须特征; T_7 对分类不是必须的

表 2 多传感器遥感图像分类决策表

Table 2 The decision table of multi-sensor remote sensing image classification

类别	T_1	T_2	T_3	T_4	T_5	T_6	T_7	T_8	T_9	T_{10}	T_{11}	T_{12}
C_1	35- 65	42- 68	53- 79	69- 101	119- 144	130- 150	216- 249	2- 24	78- 167	24- 125	104- 202	132- 212
C_2	34- 60	42- 62	52- 73	69- 95	110- 136	121- 144	132- 228	76- 197	16- 86	1- 17	13- 60	22- 109
C_3	79- 247	83- 249	83- 246	124- 239	136- 238	129- 241	172- 258	0- 37	18- 169	6- 111	66- 198	104- 214
C_4	68- 141	74- 141	84- 152	93- 159	131- 185	130- 196	59- 199	24- 199	0- 57	0- 32	14- 98	33- 137
C_5	38- 89	48- 96	38- 96	127- 166	103- 164	86- 149	196- 258	2- 26	51- 176	18- 122	98- 199	132- 207

表 3 $T_1 \sim T_{12}$ 的最优等价关系分类

Table 3 The best classification of $T_1 \sim T_{12}$ equivalence relations

特征	T_1	T_2	T_3	T_4	T_5	T_6
门限	65, 68	68, 74	79, 83	101	136	
小于门限集合	1, 2, 5	1, 2, 5	1, 2, 5	1, 2, 4	1, 2, 4, 5	最优等价关系分类
大于门限集合	3, 4, 5	3, 4, 5	3, 4, 5	3, 4, 5	1, 3, 4, 5	
特征	T_8	T_9	T_{10}	T_{11}	T_{12}	
门限	199, 216	37, 75	57, 78	17, 18	60, 65	98
小于门限集合	2, 3, 4, 5	1, 3, 4, 5	2, 3, 4, 5	2, 3, 4	2, 4	2, 3, 4
大于门限集合	1, 2, 3, 5	2, 4	1, 2, 3, 5	1, 3, 4, 5	1, 3, 4, 5	1, 3, 5




图 3 分类决策树

Fig. 3 Classification decision tree

因此条件属性 $T_1 \sim T_{12}$ 分类时,有多种约简,约简使分类特征由原来的 12 个减少到 3 个.

2.4 最优特征的选取

为选择最优特征,需用粗糙度来衡量等价关系:对论域 U 的子集 X ,等价关系 R_1 和 R_2 都将 U 分成 X 和 \bar{X} ,且 $X \cup \bar{X} = U$,如果集合 X 相对于等价关系 R_1 和 R_2 粗糙度分别为 $\alpha_{R_1}(X)$ 和 $\alpha_{R_2}(X)$,若

$$\alpha_{R_1}(X) < \alpha_{R_2}(X), \quad (4)$$

则当将论域 U 分成集合 X 和集合 \bar{X} 时,等价关系 R_1 的分类精度高于等价关系 R_2 . 这就是进行最优特征选取所遵循的粗集原理

将特征 $T_1 \sim T_{12}$ 利用决策树方法进行分类时,结合决策表得到全体样本组成的论域的分类树状结构(见图 3). 图 3 中 $\odot 1 \sim \odot 5$ 是一种为了讨论方便而使用的记号表示,每一个记号表示一个分类子过程. $\odot 1$ 和 $\odot 5$ 的分类过程决定特征 $T_1 \sim T_3$ 的选择, $\odot 2 \sim \odot 4$ 的分类过程决定特征 $T_7 \sim T_{12}$ 的选择.

结合图 3、表 1、表 2、表 3,可以看出: (1) 在过程 1 中, T_1, T_2, T_3 等价,但在过程 $\odot 5$ 中,要将 $\{C_3\}$ 和 $\{C_5\}$ 分开;由表 2: 特征 T_1, T_2, T_3 在这两个类别的取值区间分别具有 10, 13 和 13 个像素的重叠区;并且各条件属性的标准方差非常接近,如果假设论域为 $\{C_3, C_5\}$,集合 $X = \{C_3\}$, X 相对于特征 T_1, T_2 和 T_3 的三个等价关系 R_1, R_2, R_3 的粗糙度分别为 $\alpha_{R_1}(X), \alpha_{R_2}(X), \alpha_{R_3}(X)$, 则必有 $\alpha_{R_1}(X) < \alpha_{R_2}(X)$, 且 $\alpha_{R_1}(X) < \alpha_{R_3}(X)$, 因此,特征 $T_1 \sim T_3$ 中, T_1 为最优特征; (2) 在过程 $\odot 2$ 中,由表 3 可以看出特征 T_7 和 T_9 的最优等价关系分类不能够直接区分 C_1 和

C_2 , 因此 T_7 和 T_9 不是最优特征; (3) 在过程 $\odot 3$ 中,由表 3 可看出只有特征 T_{11} 可以直接将 $\{C_3, C_4, C_5\}$ 分成 $\{C_3, C_4\}$ 和 $\{C_3, C_5\}$ 而不具有重叠区,初步断定: T_{11} 为最佳分类特征; (4) 在过程 $\odot 4$ 中,要将 $\{C_3\}$ 和 $\{C_4\}$ 分开,从表 2 中可以算出,特征 $T_7 \sim T_{12}$ 在这两个类别的取值区间分别具有 27, 13, 39, 27, 33, 33 个像素的重叠区;在论域为 $\{C_3, C_4\}$, 集合 $X = \{C_3\}$ 的情况下, X 相对于特征 $T_7 \sim T_{12}$ 的等价关系 $R_7 \sim R_{12}$ 的粗糙度分别为 $\alpha_{R_7}(X) \sim \alpha_{R_{12}}(X)$, 其中 $\alpha_{R_8}(X)$ 为最小. 但是在 T_8 和 T_{11} 之间,由于 $\odot 4$ 为 $\odot 3$ 的子过程, $\odot 3$ 过程的分类精度还将影响 $\odot 4$ 过程的分类精度,因此,综合考虑,确定 T_{11} 为 $T_7 \sim T_{12}$ 中的最佳分类特征.

对于本文的多传感器图像, T_1, T_4, T_{11} 为分类的最优特征集.

3 分类实验验证

我们采用 Bayes 分类器进行了两组分类实验验证.

实验 1: (1) 验证了本实验图像中特征选择 T_1, T_4, T_{11} 三个特征可以达到文中 12 个特征的分类精度,并且加入其它特征不会显著提高分类精度; (2) 验证了多传感器遥感图像分类精度比单传感器遥感图像分类精度有很大提高; (3) 验证 T_1, T_4, T_{11} 为最少分类特征,减少任一个都会极大降低某类地物的分类精度. 实验结果见表 4. 由表 4 可见, TM 和 SAR 多传感器遥感图像的分类精度比单传感器遥感图像的分类精度提高近 10%; 并且利用特征 T_1, T_4, T_{11} 可得到很高的分类精度,加入其它特征分类精度提高不超过 0.8%, 去掉 T_1, T_4, T_{11} 中任何一个特

表 4 T_1, T_4, T_{11} 与其它多特征分类精度比较 (%)

Table 4 Comparison of classified accuracy between T_1, T_4 and T_{11} and other multi-characters (%)

特征 类别	$T_1, T_4,$ T_{11}	$T_1 \sim T_6$	$T_1, T_4,$ T_8, T_{11}	$T_1, T_4,$ $T_8, T_9,$ T_{11}	$T_1, T_3,$ $T_4, T_8,$ T_9, T_{11}	全部 12 个 特征	T_1, T_4	$T_1,$ T_{11}	$T_4,$ T_{11}
	C_1	99.07	64.98	99.02	99.17	99.20	99.14	48.61	90.62
C_2	99.32	80.59	99.53	99.48	98.62	98.62	74.24	99.69	97.24
C_3	94.34	92.64	93.10	95.64	95.80	95.88	83.29	92.20	68.25
C_4	97.26	91.80	97.39	97.62	98.40	98.33	88.71	95.71	90.25
C_5	91.36	92.09	90.76	93.38	93.77	93.17	89.24	67.17	84.27
检验样本全体	96.30	85.27	95.92	97.06	97.26	97.17	77.35	90.53	85.84

表 5 T_1, T_{11} 为最优分类特征验证 (%)

Table 5 Verification of T_1, T_{11} to be the best classification characters (%)

特征	1, 4, 7	1, 4, 8	1, 4, 9	1, 4, 10	1, 4, 11	1, 4, 12	2, 4, 7	2, 4, 8	2, 4, 9
检验样本全体	93.96	95.99	94.59	95.88	96.30	95.88	93.61	95.85	94.43
特征	2, 4, 10	2, 4, 11	2, 4, 12	3, 4, 7	3, 4, 8	3, 4, 9	3, 4, 10	3, 4, 11	3, 4, 12
检验样本全体	95.53	96.01	95.68	93.54	95.50	93.79	95.20	95.77	95.04



图 4 TM 分类图像

Fig. 4 Classified result with TM characters




图 5 RS 理论选取特征分类图像

Fig. 5 Classified result with RS-theory-selected character

征, 都会使某类别的地物分类精度显著降低, 说明这三个特征对分类是必不可少的

实验 2: 验证 $T_1 \sim T_3$ 为等价特征, 且 T_1 为最优特征; $T_7 \sim T_{12}$ 也为等价特征, 且 T_{11} 为最优特征 (见表 5)。选择 T_4 特征 $T_1 \sim T_3$ 任意一个特征和 $T_7 \sim T_{12}$ 任意一个特征时, 分类精度最大差异为 2.76%, 说明他们都可以作为决策表的约简; 并且以选择 T_1, T_4, T_{11} 特征分类精度最高, 说明 T_1 和 T_{11} 为最佳分类特征

对全图应用 TM 多光谱特征以及粗集理论提取的特征的 Bayes 分类器分类结果见图 4 和图 5。检验样本整体分类精度分别为 85.27% 和 96.30%。

说明 TM 和 SAR 融合可以显著提高分类精度; 融合分类特征提取可使用粗集理论方法, 并采用传统的 Bayes 分类器

4 结语

本文针对多光谱和 SAR 遥感图像特征层融合分类, 将粗集理论用于特征选取, 提出一种适用于遥感图像分类及特征选取的粗集决策表组成及约简方法, 得到分类的最小特征集合, 并给出应用粗集理论从最小特征集合中选择最佳特征的方法。分类实验验证了该最佳特征选取法的有效性

REFERENCES

[1] Pohl C. Multi-sensor image fusion in remote sensing: concepts, methods and applications, *Int. J. Remote Sensing*, 1998, **19**(5): 823—854

[2] Solberg A H S, Jain A K. Texture fusion and feature selection applied to SAR imagery, *IEEE Trans on Geoscience and Remote Sensing*, 1997, **35**(2): 475—479

[3] Sylvie Le Hegarat-Mascle, Isabelle Bouch, Vidal-Madjar D. Application of Dempster-Shafer evidence theory to unsupervised classification in multi-source remote sensing, *IEEE Trans on Geoscience and Remote Sensing*, 1997, **35**(4): 1018—1031

[4] Benediktsson J A, Sveinsson J R. Feature extraction for multi-source data classification with artificial neural networks, *Int. J. Remote Sensing*, 1997, **18**(4): 727—740

[5] Solberg A H S, Jain A K, Torfinn Taxt. Multi-source classification of remotely sensed data: fusion of Landsat TM and SAR images, *IEEE Trans on Geoscience and Remote Sensing*, 1994, **32**(4): 768—778

[6] Mather Paul M, Tso Brandt, Koch Magaly. An evaluation of Landsat TM spectral data and SAR-derived textural information for lithological discrimination in the Red Hills, Sudan, *Int. J. Remote Sensing*, 1998, **19**(4): 587—604

[7] WANG Jue, MAO Duo-Qian, ZHOD Yu-Jian. Summary of rough-set theory and its application, *Pattern Recognition and Artificial Intelligence* (王珏, 苗夺谦, 周育键 关于 RS 理论与应用的综述, 模式识别与人工智能), 1996, **9**(4): 337—343

[8] Pawlak Z, Slowinski R. Rough set approach to multi-attribute decision analysis, *European Journal of Operational Research*, 1994: 443—459

[9] CHEN Zun-De. Intelligent system of rough set combined with artificial neural network and its application, *Pattern Recognition and Artificial Intelligence* (陈遵德 RS 神经网络智能系统及其应用, 模式识别与人工智能), 1999, **12**(1): 1—5