

文章编号: 1007-4619(2005)05-0555-09

结合多分类器的遥感数据专题分类方法研究

柏延臣¹, 王劲峰²

(1. 清华大学 环境科学与工程系, 北京 100084; 2 中国科学院 地理科学与资源研究所, 北京 100101)

摘 要: 采用标准的多分类器结合方法进行遥感图像的分类研究。首先介绍了标准的多分类器结合的算法, 然后以 Landsat TM 多光谱遥感数据的土地覆被分类为例, 分别给出了抽象级上相同训练特征的多分类器结合、抽象级上不同训练特征的多分类器结合和测量级上的多分类器结合进行土地覆被分类的方法, 并进行了实例研究。参与分类器结合的单个分类器包括最大似然分类器, 最小距离分类器, 马氏距离分类器, K-NN 分类器, 多层感知器神经网络分类器。分类器的分类精度用总体精度、用户精度、生产者精度、kappa 系数和条件 kappa 系数评价。结果表明, 每一种多分类器结合的分类方法都能够比较显著地提高总体分类精度。文章最后对不同多分类器结合方式的优缺点进行了分析。

关键词: 遥感图像分类; 多分类器结合; 精度评价

中图分类号: TP751.1 **文献标识码:** A

1 引 言

区域到全球尺度的土地利用、土地覆被等专题类别信息及其变化的提取是遥感数据最广泛的应用领域。这些专题类别信息一般通过对多光谱遥感数据进行计算机自动分类实现。目前最常用的遥感图像分类器包括最大似然分类器, 最小距离分类器, 马氏距离分类器, 平行六面体分类器, K-NN 分类器和神经网络分类器等^[1, 2]。但是, 在实际应用中, 对于特定的遥感数据, 不同的分类器的分类精度不同, 而且同一个分类器对不同类别的分类精度也不同。一些科学家对各种分类器在遥感数据分类中的应用进行了比较研究^[3-6], 其基本结论是: 没有哪一个分类器是“万灵丹 (panacea)”^[7]。这是因为, 遥感数据分类的精度决定于分类过程的各个环节, 包括分类特征选择和提取、适当的数据先验知识以及合适的分类方法等。例如, 神经网络分类结果与神经网络结构的选择有很大关系, 而 K-NN 分类器的表现则与合适的 K 值的选择有关。但是, 真实地表的遥感数据是复杂的, 同一景遥感数据中不同类别数据的

统计分布特征也是不同的, 因此同样的分类方法下, 不同类别的分类精度差别很大, 而且这种差别随不同的分类方法而不同。常常出现一些分类器对一部分类别的分类精度高, 而另一些分类器对另一部分类别分类精度高。从这个意义上说, 不同的分类器之间可能有一定的互补性。当前关于遥感数据分类的研究大部分集中在发展新的分类器, 而很少强调利用现有分类器之间的互补性, 通过适当的方法将现有的各种分类算法结合起来以提高分类精度^[6]。

近年来, 多分类器结合的思想以及关于多分类器结合方法的研究在模式识别领域逐渐兴起, 并应用于信号处理^[8], 手写体的自动识别^[9]和指纹识别^[10]等多个领域。多分类器的结合已经成为模式识别领域的一个研究热点^[11], 并且在遥感图像分类领域也逐渐得到应用。如, Pinz 等提出了一种简单的结合神经网络和最大似然分类进行多光谱遥感数据分类的方法^[12]。Wilkinson 等提出了一种将神经网络分类器和统计分类器结合进行遥感图像分类的方法^[13]。Roli 等用多种方法将统计分类器和神经网络分类器结合用于遥感图像分类, 指出通过多分类器结合可以在较简单的分类器“设计”下得到满

收稿日期: 2004-03-30; 修订日期: 2004-07-05

基金项目: 国家自然科学基金 (40301033)、中国博士后科学基金 (2003033111) 和国家 863 项目 (001AA135151) 共同资助。

作者简介: 柏延臣 (1972-), 男, 甘肃景泰县人, 博士, 副教授。1996 年毕业于兰州大学地理学专业, 1999 年于中国科学院兰州冰川冻土研究所 (现中国科学院寒区旱区环境与工程研究所) 获理学硕士学位, 2002 年获中国科学院地理科学与资源研究所地图学与地理信息系统专业博士学位; 2002-2004 年在清华大学环境科学与工程系做博士后研究。从事遥感和 GIS 基础和应用研究, 发表论文 20 余篇, 出版专著 1 部。

意的分类精度^[6]。Gincinto等通过将多个神经网络分类器结合进行遥感图像软分类^[7]；Kumer等利用一种层次多分类器系统进行多光谱遥感数据分类^[14]；Benediktsson等将多分类器系统用于多源遥感数据分类^[15]；Burzzone等结合参数和非参数分类器进行非监督的土地覆盖图更新^[16]；Wan等通过结合多个自组织图神经网络进行遥感数据分类^[17]。

模式识别领域发展了许多种多分类器结合的方法。根据单个分类器输出类型,可以将分类器结合方法分为抽象级的结合(Abstract Level),排序级的结合(Ranked Level)和测量级的结合(Measurement Level)三大类^[18],每一类中又有多种结合方法。Xu等提出了不同输出级别上的各种结合方法,被称为多分类器结合的标准方法^[9],在各种模式识别的应用领域广泛应用,但目前尚未见到标准的多分类器结合方法在遥感数据分类中的应用研究。本文首先介绍标准的多分类器结合方法,然后以TM图像的土地覆被分类为例,使用不同方式进行多分类器结合的分类试验,并与单个分类器的分类精度进行比较以评价多分类器结合的分类效果。最后对多分类器结合方法在遥感数据分类中的应用进行讨论。

2 标准的多分类器结合方法

假设一个遥感图像分类问题涉及 M 个类别: $C_1 \cup C_2 \cup \dots \cup C_i \dots \cup C_M$ 。每一个类别 $C_i, \forall i \in \Delta = \{1, 2, \dots, M\}$ 代表一种特定类别。以模式识别中的术语,每一类别代表一种特定的模式,而每一种模式用一个特征矢量 X 描述。分类器的输出信息可以分为 3 个级别^[9]:

抽象级 分类器输出一个类别标示(Label)。在抽象级上分类器的结合可以理解为:给定 K 个分类器 $\epsilon_k (k=1, \dots, K)$, 每个分类器对输入模式 X 赋予一个类别 i , 即: $\epsilon_k(X) = i$ 。这时分类器的结合问题就是用这些单个的分类器结合成一个分类器 E , 使 $E(X) = j \in \Delta \cup \{M+1\}$, 其中 $j=M+1$ 代表分类器无法判断 j 的类别, 赋予未分类类别。

排序级 分类器将像元可能的类别排列成一个序列: $L_k \subseteq \Delta$, 最前面的类别为像元最可能的类别。这时的分类器结合问题就是将单个分类器 $\epsilon(X) = L_k, k=1, \dots, K$ 结合为一个分类器 $E(X) = m, m \in \Delta \cup \{M+1\}$;

测量级 分类器输出一系列测量值(如后验概率)说明像元属于各类别的程度。对于输入模式 X ,

每个分类器输出一个矢量 $M_\epsilon(k) = [P_k(1), \dots, P_k(M)]^T$, 其中 $P_k(i)$ 表示分类器 ϵ_k 认为模式 X 属于类别 i 的程度。这时分类器结合问题就是利用单个的分类器 $\epsilon(X) = M_\epsilon(k), k=1, \dots, K$, 建立一个分类器 $E(X) = j \in \Delta \cup \{M+1\}$ 。

由于常用于遥感图像分类的分类器的输出要么是抽象级,要么是测量级,因此对遥感图像分类来说,多分类器的结合一般在抽象级和测量级上进行。

2.1 抽象级的多分类器结合——投票法

抽象级的分类器结合是最常见的分类器结合方式,因为任何分类器都有抽象级的输出,因此抽象级的多分类器结合可以将任何分类器的输出融合形成新的分类决策。在抽象级的分类器结合过程中,要解决的主要问题是分类器的输出结果之间的不一致。抽象级分类器结合方法一般用投票法(Voting)^[6,9],其基本思想是通过投票的方式决定分类器输出结果不一致时的模式类别确定问题。投票规则源于一种假设:群体的判断优于个体的判断^[19]。其中多数投票规则(Majority Voting Rule)以半数以上的分类器一致分类的类别作为待分类模式的最终类别;保守投票规则(Conservative Voting Rule)认为只有当所有的分类器的输出结果完全一致时,确定该输出结果为最终分类类别,否则,判定为“未知类别”,即:

$$T_k(X \in C_i) = \begin{cases} 1, & \text{当 } \epsilon_k = i, i \in \Delta \text{ 时} \\ 0, & \text{其它} \end{cases} \quad (1)$$

更一般的投票决策规则表达为(Xu等, 1992):

$$E(X) = \begin{cases} j & \text{当 } T_E(X \in C_j) = \max_{i \in \Delta} T_E(X \in C_i) \geq \alpha \times K \text{ 时} \\ M+1, & \text{其它} \end{cases} \quad (2)$$

其中 $T_E(X \in C_i) = \sum_{k=1}^K T_k(X \in C_i), i=1, \dots, M; 0 < \alpha < 1.0$ 。

显然,多数投票规则是式(2)在 $\alpha=0.5$ 时的特例;而保守投票规则是式(2)在 $\alpha=1.0$ 时的特例。然而,式(2)只考虑“使得票最多者当选且票数足够多”,但没有考虑有两个类别同时赢得最多票数的情形,或者得票数第一的类别和票数第二的类别票数十分接近的情形。在这种情况下,即使赢得最多票数的类别的票数很多,但由于另一个类别赢得的票数也接近,因此最终的分类决策是不可靠的。这个问题可以通过比较多数投票规则(comparative majority voting rule)解决:

$$E(X) = \begin{cases} j & \text{当 } T_E(X \in C_j) = \max_i, \max_i - \max_x \geq \alpha \times K \text{ 时} \\ M + 1, & \text{其它} \end{cases} \quad (3)$$

其中 $0 < \alpha < 1.0$, $\max_i = \max_{X \in \Delta} T_E(X \in C_j)$; $\max_x = \max_{X \in \Delta - \{j\}} T_E(X \in C_j)$ 。

2.2 测量级的多分类器结合——Bayesian 平均方法

许多分类器 (Bayesian 和 MLP 神经网络分类器) 在分类过程中输出一个模式 X 属于类别 C_i 的后验概率。一个简单的分类器结合规则就是平均各分类器的后验概率估计, 然后根据平均的后验概率, 确定待分类模式的最终类别。

假定对于分类器 ϵ , 它将模式 X 划分为各类别的后验概率测量为 $P_k(X \in C_i | X)$, $i=1, \dots, M$, $k=1, \dots, K$, Bayesian 平均结合规则表示为:

$$P_E(X \in C_i) = \frac{1}{K} \sum_{k=1}^K P_k(X \in C_i), \quad i=1, \dots, M \quad (4)$$

最终的分类决策为:

$$E(X) = \begin{cases} j & \text{当 } P_E(X \in C_j) = \max_{i \in \Delta} P_E(X \in C_i) \text{ 时} \\ M + 1, & \text{其它} \end{cases} \quad (5)$$

Bayesian 平均方法中需要分类过程中输出待分类模式属于每个类别的后验概率, 而只有 Bayesian 分类器在分类过程中产生后验概率。而在各种距离分类器中, 某一像元的所属类别是根据该像元的光谱矢量与各类别平均光谱矢量的欧氏距离或马氏距离做出的。在分类器结合过程中, 我们当然希望将各种不同的分类器结合, 但这种结合的前提是: 在测量级的分类器结合过程中, 不同分类器输出的测量必须在同一个量级, 它们之间应该具有可比性。因此, 需要将距离分类器的光谱矢量距离测量转换为满足概率论三个公理的, 与概率矢量可比的“概率”。这个转换可以通过公式 (6) 实现:

$$P_k(X \in C_i | X) = \frac{1/d_k(C_i | X)}{\sum_{i=1}^M 1/d_k(C_i | X)} \quad (6)$$

其中, $d_k(C_i | X)$ 表示第 k 个分类器中模式 X 与类别 C_i 的光谱矢量距离。经过式 (6) 转换后, 就可以将多种分类器通过 Bayesian 平均方法结合。

3 多分类器结合方法进行遥感数据分类的实验

通过多分类器结合的方法提高分类精度的程度

依赖于各分类器分类表现的独立性, 当分类器用独立的特征集训练或用独立的训练数据训练时, 分类器之间被认为是独立的^[9]。可以预见, 当用多源遥感数据进行分类或用完全不同的特征 (如光谱特征和各种纹理特征) 参与训练分类器时, 分类器具有很高的独立性; 对于一般的多光谱数据而言 (如 Landsat TM 数据), 如何通过不同波段结合, 既保证单个分类器一定的分类精度, 又使各种波段结合方式下的特征具有较高独立性, 并不是一个容易的事。

我们利用美国 Lanier 湖区的 Landsat TM 数据土地覆盖分类为例, 比较抽象级的多分类器结合方法和测量级的多分类器结合方法。图 1 是试验数据的标准假彩色合成图像。图像中的土地覆被类型包括城镇、裸地、农地、草地、水体、针叶林、阔叶林、云和云的阴影。




图 1 试验区 Landsat TM 标准假彩色合成图像 (R: 4, G: 3, B: 2)
Fig 1 Composite standard false color imagery of Landsat TM (R: 4, G: 3, B: 2)

分类过程中的训练样本是根据已有的结合地面调查和目视判断做出的土地覆被图, 用层次随机采样方法选取的。分类器的精度评价采用基于误差矩阵的评价方法, 精度评价指标包括总体精度, 用户精度, 生产者精度, kappa 系数和条件 kappa 系数^[20]。精度评价中地面参考数据的选取根据已有的土地覆被图以层次随机采样方式选取。单个分类器的分类结果与精度评价结果如图 2 和表 1。可以看出, 虽然各分类器的总体精度差别不大, 但对各个类别的分类精度差别很大, 特别是农地与草地、针叶林与阔叶林, 以及城镇与裸地、裸地与云的区分方面。无论是生产者精度, 用户精度还是条件 kappa 系数, 每个分类器对不同类别的分类精度差别都很大。每一类别分类精度最高的分类器也各不相同。

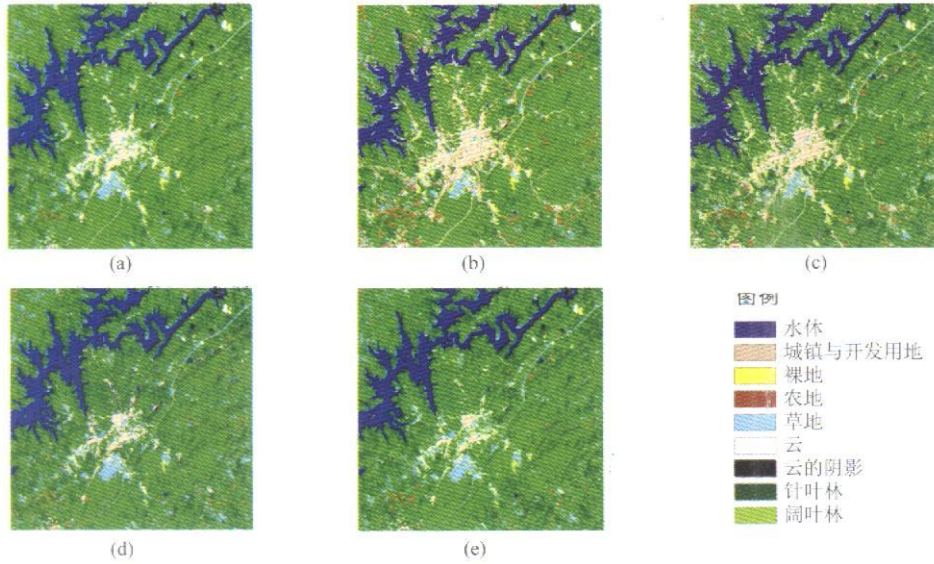


图 2 单个分类器的分类结果

(a) 多层感知神经网络分类器; (b) 最大似然分类器; (c) K-NN 分类器; (d) 马氏距离分类器; (e) 最小距离分类器

Fig 2 Classified maps by different classifiers

(a) Multiple layer perceptron classifier; (b) Maximum likelihood classifier; (c) K-NN classifier; (d) Mahalanobis classifier; (e) Minimum distance classifier

表 1 单个分类器的分类精度

(a) 各分类器的生产者精度; (b) 各分类器的用户精度; (c) 各分类器的条件 kappa 系数; (d) 各分类器的总体分类精度和 kappa 系数

Table 1 Classification accuracy by every individual classifier

(a) Producer's accuracy; (b) User's accuracy; (c) Conditional kappa coefficient; (d) Overall accuracy and kappa coefficient

(a)

生产者精度 /%	MLP	K-NN	M inD	M ad	MLC	最优分类器
水体	89.02	89.02	85.37	90.24	89.02	M ad
城镇	84.29	98.57	51.43	65.71	94.29	K-NN
裸地	45.95	64.86	54.05	40.54	62.16	K-NN
农地	61.84	76.32	68.42	63.16	80.26	MLC
草地	62.92	38.20	61.80	66.29	43.82	M ad
云	77.50	67.50	52.50	65.00	97.50	MLC
阴影	100.00	81.82	81.82	95.45	95.45	MLP
针叶林	56.35	60.32	72.22	64.29	54.76	M inD
阔叶林	85.44	77.85	83.54	81.65	77.22	MLP

(b)

用户精度 /%	MLP	K-NN	M inD	M ad	MLC	最优分类器
水体	97.33	89.02	92.11	93.67	93.59	MLP
城镇	67.82	48.25	73.47	63.89	58.93	M inD
裸地	80.95	85.71	60.61	93.75	92.00	M ad
农地	95.92	80.56	88.14	73.85	61.00	MLP
草地	84.85	89.47	71.43	75.64	92.86	MLC
云	81.58	93.10	72.41	76.47	90.70	K-NN
阴影	84.62	94.74	78.26	63.64	91.30	K-NN
针叶林	78.02	80.00	73.39	80.20	88.46	MLC
阔叶林	54.66	63.40	57.39	58.11	61.62	K-NN

(c)

kappa 系数	MLP	K-NN	M inD	M ad	MLC	最优分类器
水体	0.9698	0.8757	0.9106	0.9283	0.9274	MLP
城镇	0.6424	0.4250	0.7052	0.5988	0.5437	M inD
裸地	0.7989	0.8492	0.5841	0.9340	0.9155	M ad
农地	0.9542	0.7819	0.8669	0.7066	0.5625	MLP
草地	0.8264	0.8794	0.6727	0.7209	0.9182	MLC
云	0.8046	0.9269	0.7074	0.7504	0.9013	K-NN
阴影	0.8412	0.9457	0.7756	0.6246	0.9102	K-NN
针叶林	0.7320	0.7561	0.6755	0.7585	0.8593	MLC
阔叶林	0.4144	0.5273	0.4497	0.4590	0.5043	K-NN

(d)

	MLP	K-NN	M inD	M ad	MLC
总体精度 /%	73.00	71.71	70.71	71.29	73.29
kappa 系数	0.6811	0.6694	0.6535	0.6619	0.6885

3.1 抽象级的投票多分类器结合实验

在抽象级的投票方法进行多分类器结合分类时,参数 α 的选取对分类精度有很大影响。 α 越大,分类精度越高,但同时分类的拒绝率也越高,即更多的像元被判别为未知像元。为便于比较,我们在投票决策过程中强制将每个像元分类到已知类别,也就是说,不设定 α ,而将像元分类为票数最多的类别。

参与分类器结合的各分类器包括最大似然分类器 (MLC),最小距离分类器 (MinD)、K-NN 分类器,马氏距离分类器 (MaD)和多层感知器神经网络分类器 (MLP)。

3.1.1 相同特征集训练的多分类器抽象级结合

相同特征集训练的多分类器抽象级结合方式如图 3。

图 3 中 B1, B2, ..., B5 表示 Landsat TM 多光谱遥感数据中的波段 1 至波段 5。图 4(a)是由图 3 所示的分类器结合方式,用相同的特征训练各分类器,用投票法进行抽象级的分类器结合生成的分类结果。图 4 中的图例和图 2 中相同。表 2 是用相同特征训练的分类器在抽象级结合后的分类精度。与表 1 中的结果比较可以看出,将多分类器结合后,对

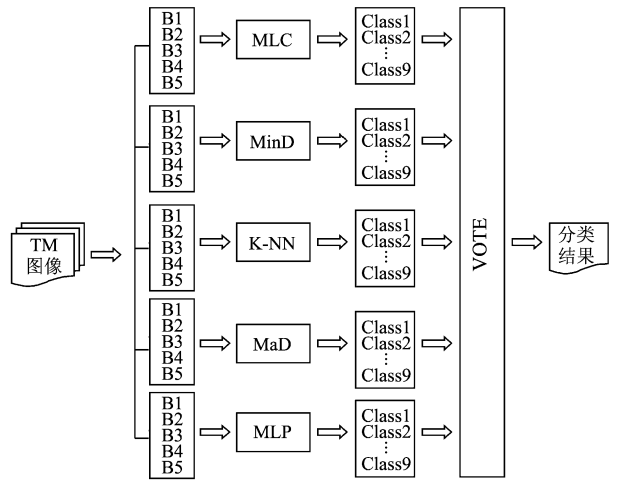


图 3 相同特征集的抽象级多分类器结合示意图

Fig 3 Multi-Classifier combination at abstract level with different training features

于单个类别的分类精度,无论是生产者精度、用户精度还是条件 kappa 系数,都不会高于单个分类器分类精度中的最高精度,但多分类器结合后的总体分类精度和 kappa 系数都高于任何单个分类器的总体分类精度和 kappa 系数。总体精度比单个分类器提高 6%—9%, kappa 系数提高 7%—10%。

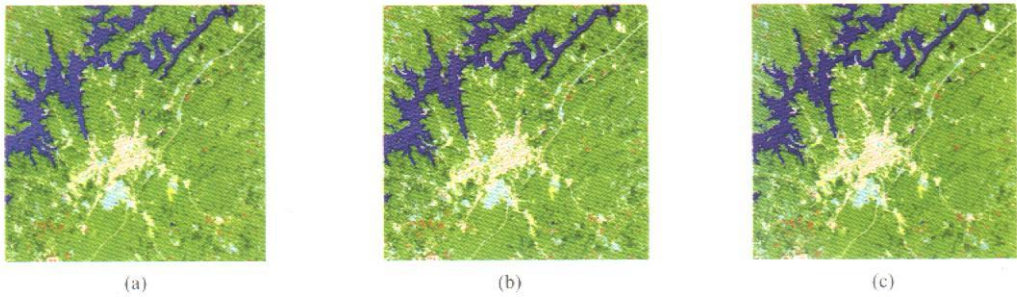


图 4 不同多分类器结合分类方法的分类结果

(a)相同特征训练的抽象级多分类器分类结果;(b)不同特征训练的抽象级多分类器分类结果;(c)测量级的多分类器分类结果

Fig 4 The results of the classification experiments by combining multiple classifiers in different ways at different levels

(a) Combination of multiple classifiers at the abstract level using same training features

(b) Combination of multiple classifiers at the abstract level using different training features

(c) Combination of multiple classifiers at the measurement level

表 2 相同特征训练的多分类器抽象级结合分类结果精度评价

Table 2 Classification accuracy of combined classifiers at abstract level with same training feature

	水体	城镇	裸地	农地	草地	云	阴影	针叶林	阔叶林
生产者精度	0.89	0.929	0.54	0.829	0.685	0.8	0.955	0.698	0.842
用户精度	0.948	0.722	0.923	0.863	0.924	0.889	0.875	0.815	0.665
kappa 系数	0.941	0.691	0.919	0.846	0.913	0.882	0.871	0.774	0.567

总体精度:80%, 总体 kappa 系数:0.7654

3.1.2 不同特征集训练的多分类器抽象级结合

在多分类器结合过程中,一般总希望参与结合的各分类器之间具有独立性。理论上,对于两个类别分类的情况,假设有奇数个分类器且分类精度相同,则将这奇数个分类器在抽象级结合后总的分类精度服从一个二项式分布,分类器越多,分类精度越高。这时当单个分类器精度高于 50% 时,单个分类器之间独立可得到更高的结合后的分类精度^[21]。实验研究表明相互不独立的多分类器结合仍然可以显著提高分类精度^[21]。

分类器之间的独立性一般是指由独立的特征训练的分类器。因此分类器的独立性的评价常常是对分类器训练特征之间独立性的评价。对于多光谱遥感数据分类来说,不同的波段组合形成不同的训练特征,因此希望不同的波段组合形成的特征之间具有独立性。

我们利用不同的组合分别对最大似然分类器、最小距离分类器、多层感知器神经网络、马氏距离分类器和 K-NN 分类器进行训练。训练特征的波段组

合为 2, 3, 4; 3, 4, 5; 4, 5, 7; 三种组合方式。每个分类器分类结果通过投票决策方法结合得到最后的分类结果。不同特征集训练的多分类器抽象级结合分类过程与相同特征集训练的多分类器过程类似。分类结果如图 4(b)。

表 3 为不同特征集训练的多分类器抽象级结合分类结果的精度统计。与表 2 中相同特征集训练的多分类器抽象级结合分类结果精度对比可以发现,两者的分类精度非常接近,后者的分类精度并没有高于前者,相反略低于前者。造成这种情况的原因大概有两方面:一是 TM 图像各波段之间具有较高的相关性,不同的特征(波段组合)如 2, 3, 4, 与 3, 4, 5; 3, 4, 5 与 4, 5, 7 之间也有较高的相关性,因此各特征之间的独立性不高;二是为了使各分类器训练特征不同而使各特征的波段数减少,导致某些单个分类器的分类精度降低,因此结合后的总体分类精度虽然高于单个分类器,但并不比用相同特征训练的多分类器结合后的分类精度高。

表 3 不同特征训练的多分类器抽象级结合分类结果精度评价

Table 3 Classification accuracy of combined classifiers at abstract level with different training features

	水体	城镇	裸地	农地	草地	云	阴影	针叶林	阔叶林
生产者精度	0.939	0.929	0.595	0.776	0.629	0.825	0.864	0.659	0.848
用户精度	0.939	0.692	0.846	0.819	0.903	0.868	0.95	0.846	0.72
kappa 系数	0.931	0.657	0.838	0.798	0.889	0.86	0.9481	0.812	0.639

总体精度: 79.7%, 总体 kappa 系数: 0.7631

3.2 测量级的多分类器结合实验

除了抽象级的多分类器结合外,测量级的多分类器结合也是多分类器结合的常用方式。测量级的分类器结合方式是根据分类器各输出的一系列说明像元属于各类别的程度测量值(如后验概率),以一定方式结合各分类器,用结合后的测量值作为判别像元类别的依据。很显然,分类器在分类过程中输出的代表像元属于各类别程度的测量值,包括后验概率估计,距离测量等,实际上是各分类器分类的不确定性度量。因此,测量级的多分类器结合可以理解为以各单个分类器不确定性为基础的多分类器结合。

本实验中,我们分别用 TM 遥感数据的 1, 2, 3, 4, 5 波段对最大似然分类器、多层感知器神经网络、

最小距离、马氏距离 4 个分类器进行训练并分类。最小距离和马氏距离分类器输出的距离像元到各类别中心的距离测量通过式(6)转换为“概率测量”。各分类器的测量值按照式(4)中的 Bayesian 平均方法结合并以式(5)确定最终的分类结果。

图 5 给出了用 Bayesian 平均方法进行测量级多分类器结合的过程示意图。图 4(c)为用测量级的多分类器结合方法分类的 Lanier 湖区土地覆被图。表 4 为 Bayesian 平均法测量级多分类器结合分类结果精度统计。可以看出,测量级的多分类器结合的总体分类精度比单个分类器的总体分类精度提高约 4%—9%, kappa 系数提高 5%—8%; 和抽象级的多分类器结合分类精度比较(表 2, 表 3),测量级的多分类器结合的分类精度略低于抽象级结合的分类精度。

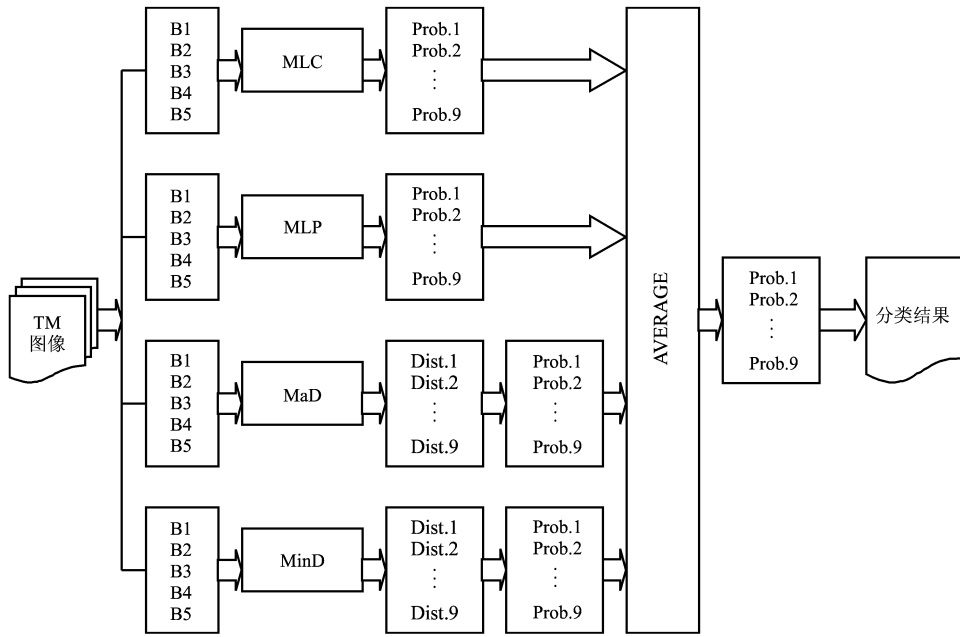


图 5 Bayesian平均法进行测量级多分类器结合示意图

Fig 5 The Bayesian average combination procedures at measurement level

表 4 Bayesian平均法进行测量级多分类器结合的分类结果精度评价

Table 4 Accuracy of combined classifiers by Bayesian average at measurement level

	水体	城镇	裸地	农地	草地	云	阴影	针叶林	阔叶林
生产者精度	0.927	0.9	0.59	0.816	0.584	0.95	0.955	0.627	0.829
用户精度	0.938	0.677	0.957	0.785	0.912	0.864	0.913	0.868	0.627
kappa系数	0.93	0.642	0.954	0.759	0.9	0.855	0.91	0.839	0.518

总体精度: 77.7%, 总体 kappa系数: 0.7386

4 结论与讨论

本文将标准的多分类器结合方法引入到遥感图像分类中,以 Landsat TM 图像土地覆被分类为例,分别进行了抽象级上相同训练特征的多分类器结合分类、抽象级上不同训练特征的多分类器结合分类和测量级上的多分类器结合分类试验,并比较了这些多分类器结合分类结果与单个分类器分类结果的精度。研究表明,抽象级的多分类器结合与测量级的多分类器结合方法都能比较显著提高遥感数据的总体分类精度,但通过多分类器结合后,单个类别的分类精度不一定高于单个分类器对单个类别的分类精度。不同训练特征的多分类器结合分类精度并不高于相同训练特征的多分类器结合分类精度,说明采用不同的波段组合方式并没有真正增强分类器之间的独立性。

在本文的试验研究中,测量级的结合方法并不比抽象级的结合方法精度高。造成这种现象的可能原因有两点:(1)由于测量级的结合是通过各单个分类器的后验概率平均实现的,因此即使少数分类器的拙劣表现也对这个分类结果有显著影响。相反,抽象级的结合是通过投票方式进行的,少数表现比较差的分类器在投票过程中属于少数,并不影响最终的分类精度;(2)测量级的多分类器结合中各分类器是用同样的波段组合进行分类的,这意味着各分类器之间缺少独立性。在多分类器结合过程中如何检验分类器之间的独立性将是多分类器结合研究中下一步的研究重点之一。

虽然本文中不同的多分类器结合方法都能在一定程度上提高遥感数据的分类精度,但不同结合方法各有优缺点。抽象级多分类器结合方法的优点在于对参与结合的分类器的特性没有要求。由于结合实在最终的分类结果基础上进行,因此任何分类器,

包括专家系统分类器、语义分类器等都可以参与抽象级的多分类器结合。但是对与抽象级的分类器结合,为保证投票决策过程中不发生两个或多个类别“得票”相等的局面,必须要求有奇数个分类器参与分类器结合。相反,测量级的多分类器结合方法的缺点在于参与分类器结合的各分类器在分类过程必须能够如后验概率矢量的不确定性的度量,因此象平行六面体分类、专家系统分类器以及各种语义分类器等不能参与测量级的多分类器结合。但测量级的分类器结合对参与结合的分类器的个数没有要求。因为测量多级分类器系统最终的分类决策根据像元属于各类别的程度的测量,而不是将像元分类为某一类别的分类器的个数进行的。

参 考 文 献 (References)

- [1] Schowengerdt R A. Remote Sensing Models and Methods for Image processing[M]. 2nd Edition. Academic Press 1997.
- [2] Richards J A. Remote Sensing Digital Image Analysis[M]. 2nd Edition. Springer-Verlag 1998.
- [3] Benediktsson J A, Swain P H, Ersoy O K. Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data [J]. IEEE Transactions on Geoscience and Remote Sensing. 1990, **28**: 540— 552.
- [4] Bischof H, Schneider W, Pinz A J. Multispectral Classification of Landsat Images Using Neural Networks [J]. IEEE Transactions on Geosciences and Remote Sensing. 1992, **30**(3): 482— 490.
- [5] Roli F, Sarpico S B, Vemazza G. Neural Networks for Classification of Remotely Sensed Images [A]. Chen C H (Editor). Fuzzy Logic and Neural Network Handbook [C], McGraw Hill 1996.
- [6] Roli F, Giacinto G, Vemazza G. Comparison and Combination of Statistical and Neural Network Algorithms for Remote Sensing Image Classification [A]. Kanellopoulos W ilkinson G, Roli F, et al. Neurocomputation in Remote Sensing Data Analysis [C], Springer 1997.
- [7] Giacinto G, Roli F. Ensembles of Neural Networks for Soft Classification of Remote Sensing Images [C]. Proceeding of the European Symposium on Intelligent Techniques [C], 1997.
- [8] Ghosh J, Tumer K, Beck S, et al. Integration of Neural Classifiers for Passive Sonar Signals [C]. Leondes DSP Theory and Applications [C]. Academic Press 1995.
- [9] Xu L, Krzyzak A, Suen C Y. Methods of Combining Multiple Classifiers and Their Applications to Handwriting Recognition [J]. IEEE Transaction on Systems Man, and Cybernetics 1992, **22**(3): 418— 435.
- [10] Cappelli R, Maio D, Maltoni D. Combining Fingerprint Classifiers [A]. Kittler Roli Multiple Classifier Systems [C], Springer 2000.
- [11] Kittler J, Roli F. Multiple Classifier Systems [M]. Springer 2000.
- [12] Pinz A, Bartl R. Information Fusion in Image Understanding Landsat Classification and Ocular Fundus Images [J]. Sensor Fusion. 1992, **1828**: 276— 287.
- [13] Wilkinson G G, Fierens F, Kanellopoulos I. Integration of Neural and Statistical Approaches in Spatial Data Classification [J]. Geographical Systems 1995, **2**: 1— 20.
- [14] Kumer S, Ghosh J, Crawford M. A Hierarchical Multiclassifier System for Hyperspectral Data Analysis [C]. 2000.
- [15] Benediktsson J A, Sveinsson J R. Consensus Based Classification of Multisource remote sensing data [A]. Kittler Roli Proceedings of First International Workshop on Multiple Classifier Systems. Springer 2000.
- [16] Burzzone L, Cossu R, Prieto D J. Combining Parametric and Nonparametric Classifiers for an Unsupervised Updating of Land Cover Maps [A]. Kittler Roli Proceedings of First International Workshop on Multiple Classifier Systems [C]. Springer 2000.
- [17] Wan W, Fraser D. A multiple SelfOrganizing Map Scheme for Remote Sensing Classification [A]. Kittler Roli Proceedings of First International Workshop on Multiple Classifier Systems [C]. Springer 2000.
- [18] Suen C Y, Lam L. Multiple Classifier Combination Methodologies for Different Output Levels [A]. Kittler Roli Proceedings of First International Workshop on Multiple Classifier Systems. Springer 2000.
- [19] Lam L. Classifier Combinations: Implementations and Theoretical Issues [A]. Kittler Roli Proceedings of First International Workshop on Multiple Classifier Systems [C], Springer 2000.
- [20] Congalton R G, Green K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices [M]. Lewis Publishers 1999.
- [21] Kuncheva L I, Whitaker C J, Shipp C A. Is Independence Good for Combining Classifiers? [A]. ICPR '2000 [C], 2000, 2: 168— 171.

Combining Multiple Classifiers for Thematic Classification of Remotely Sensed Data

BO Yan-chen¹, WANG Jin-feng²

(1. Department of Environmental Science and Engineering, Tsinghua University, Beijing 100084, China;

(2. Institute of Geographical Science and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, China)

Abstract Deriving thematic maps by classifying remotely sensed data was a major application fields of remote sensing techniques. The most often used classifiers in classification process of remotely sensed data include various statistical classifiers and artificial neural networks. Comparisons among these classifiers found no classifier as “panacea”. While most efforts were made to develop new classifiers for more accurate classification results, to fully exploit the potentials of the existing classifiers by combining multiple existing classifiers is an effective way in many fields of pattern recognition applications. In this paper, the standard multiple classifier combination method was used for land cover mapping using remotely sensed data. Landsat TM data in Lanier Lake was used as an experimental data. Land cover maps were derived by combining classifiers at abstract level with same training features, combining classifiers at abstract level with different training features and by combining classifiers at measurement level respectively. Classification accuracies of these maps were compared with those of classifiers combined. Results showed that for all classifiers combination methods, the classification accuracies were improved. Advantages and drawbacks of every method of classifiers combination were analyzed and further study in combining multiple classifiers for remotely sensed data classification was suggested.

Key words remotely sensed data classification; multiple classifier combination; accuracy assessment