

样本自适应多特征加权的高分辨率遥感图像分类

常 纯 李士进 万定生 冯 钧

(河海大学计算机与信息学院 南京 210098)

摘要 高分辨率遥感影像能够提供丰富的地物细节,但各种地物空间分布复杂,同类目标呈现出较大的光谱异质性,给传统模式识别分类器带来极大的挑战。提出了一种样本自适应多特征加权的遥感图像分类方法。常见的多特征组合分类器未能充分利用各种特征之间的局部相关性,提出通过分析测试样本局部特征相关性,探究各个特征在不同样本的分类中所占权重的不同,据此对不同分类器进行自适应加权。在一个大型遥感图像数据库上的实验结果表明,不同特征在遥感图像中对不同样本的分类作用是不同的,样本自适应特征加权法将平均分类精度从78.3%提高到90%。

关键词 遥感图像分类, 自适应加权, 特征组合, 多分类器

中图法分类号 TP391.4 文献标识码 A

Sample-specific Multiple Features Weighting-based High-resolution Remote Sensing Image Classification

CHANG Chun LI Shi-jin WAN Ding-sheng FENG Jun

(College of Computer and Information, Hohai University, Nanjing 210098, China)

Abstract High-resolution remote sensing image can provide rich feature details. However, a variety of terrain has complex spatial distribution, and spectral heterogeneity of similar landcovers appears largely, which bring great challenge to traditional pattern recognition classifier. For this purpose, this paper put forward a novel multi-classifier combination method for remote sensing image classification based on adaptive weights adjustment for different query samples. Previous multiple features combination classifiers fail to make full use of local correlation among them, with a unifying weight for all the samples. This paper explored different weights of each feature in classification on different test samples, according to different local distributions. The experimental results on a large remote sensing image database show that different features in remote sensing image classification of different samples have different effects, and the sample-specific multiple features weighting-based method presented in this paper enhances the average classification accuracy from 78.3% to 90%.

Keywords Remote sensing image classification, Adaptive weighting, Features combination, Multiple classifiers

随着遥感科学的发展和技术应用的深入,遥感研究正在由定性向定量转变。传统的基于像元的遥感图像分类主要借助统计模式识别理论和方法,在技术和应用上已经很成熟。但是单纯依靠像元光谱统计信息对遥感影像进行分类有很大的局限性,不但精度低,而且会产生大量的数据冗余^[1]。高分辨率遥感影像能够提供丰富的地物细节,但各种地物空间分布复杂,同类物体呈现出很大的光谱异质性,基于像元的分类技术容易造成较多的错分、漏分现象,从而导致分类精度较低^[2]。

近年来,研究者发现对于高分辨率遥感图像中的目标,不同特征的作用各不相同,彼此存在互补的现象^[3]。综合考虑图像的纹理特征、光谱特征和形状信息等多种特征信息的遥感影像解译技术已经得到了广泛的研究和应用,提高了遥感信息提取的精度和可靠性。在已提出的很多方法中,常见的包括投票表决法、最大概率类别法和模糊积分判别法^[4]等。

然而这些方法没有考虑到遥感目标的多样性,不能充分利用样本空间的局部特征相关性信息,因而分类精度差强人意。

针对以上问题,本文提出一种样本自适应多特征加权的高分辨率遥感图像分类方法。该方法先通过提取出分类目标的视觉词袋特征、颜色特征和纹理特征,针对不同样本在最近邻空间特征分布情况不同而确定各个特征的权重,并根据每种特征的分类结果进行多分类器自适应综合,最终获得多特征融合后的分类结果。该方法能够充分发挥各特征对不同样本的优势,使特征融合结果更佳。在具有2100幅图像的大型遥感图像分类公共测试数据集上的实验结果表明,本文方法极大地提高了分类精度。

1 特征提取

图像特征在模式分类中具有极其重要的作用,本文利用图像的视觉词袋模型、颜色直方图和Gabor纹理特征对遥感

到稿日期:2013-05-20 返修日期:2013-08-10 本文受国家自然科学基金(61170200, 61370091)资助。

常 纯(1989—),女,硕士生,主要研究方向为遥感图像分析;李士进(1973—),男,博士,教授,主要研究方向为模式识别与计算机视觉, E-mail: lishijin@hhu.edu.cn(通信作者)。

图像进行分类。

1.1 视觉词袋特征

视觉词袋(bag-of-visual-words)是目前比较流行的基于表现属性的图像表示方法,在物体识别、人体行为分析等计算机视觉问题中得到广泛应用。该方法源于文本信息检索领域的词袋模型(bag-of-words)^[4]。本文的视觉码本的创建过程可分为以下两个步骤:

(1) 提取图像的局部 SIFT (Scale Invariant Feature Transform) 特征^[5],采用 k 均值聚类算法对局部特征集合进行聚类,每一个聚类中心对应于一个视觉单词,所有的视觉单词组成视觉码本(visual codebook)。

(2) 对于一幅给定图像的局部特征,采用硬分配方法将其匹配到最近的视觉单词,统计词频形成图像表示,在此基础上将这幅图像表示成视觉单词出现频率的直方图^[6]。

1.2 颜色直方图

颜色直方图是许多图像检索系统广泛采用的一种全局特征,具有特征提取和相似度计算简便的优点^[7]。本文的直方图特征提取基于 HSL 色彩空间,相对于 RGB 色彩空间,其更符合人眼的视觉感知特性。具体提取方法如下:

对于图像中的每一个像素,将其 H, L, S 分量分别量化为 8 等份,这样 HSL 直方图就有 512 个间隔(bin)。然后统计所有像素的直方图,最后再进行归一化,以消除图像大小变化的影响。

1.3 纹理特征

纹理特征是一种不依赖于颜色或亮度的反映图像中同质现象的视觉特征。纹理特征包含物体表面结构组织排列的重要信息以及它们与周围环境的联系。基于统计信息的纹理特征提取是对图像中颜色及强度的空间分布信息进行统计得到相关纹理信息。Gabor 变换的优异性使 Gabor 小波在图像纹理分析中得到了广泛的使用^[8]。具体提取方法如下:

使用 5 个尺度、6 个方向的 Gabor 滤波器对原始图像进行 Gabor 变换,可以形成 30 幅图像纹理表示,再计算这 30 幅图像的均值和方差,从而得到一个 60 维的特征向量。

2 多特征组合方法

2.1 常见特征组合方法

国内外多数学者使用一种算法或者规则将多个分类器进行组合,提高了分类精度。具有代表性的几种组合方法有多数投票法、加权综合法、完全一致法、最大概率类别法、模糊积分融合法等^[9,13-15]。

(1) 多数投票法。多数投票法属于典型的抽象级分类器融合方法,其基本思想是当各子分类器输出结果不完全一致时,可以通过投票的方式来决定类别的归属问题。多数投票法基于群体的判断优于个体的判断假设,简单、准确且易操作,其判决条件比较苛刻,结果的可靠性较高,但会使判决率降低,而且没有考虑各分类器本身特性。

(2) 加权综合法。加权综合规则下的分类精度明显高于多数投票规则下的分类精度。因为加权求和规则本身就是针对多数票规则一人一票的缺点提出的,在确定各个分类器的权重时,采用该成员分类器独立分类的总体精度作为其衡量

值,但是关于权重的定量没有考虑到特征的局部特点,即样本的多样性,不能合理地衡量成员分类器分类能力的值。如果能确定更合理的权重,那么加权求和规则下的组合精度将更高^[10]。

(3) 完全一致法。完全一致法要求很严格,只有在各个分类器输出一致的情况下才输出结果,否则拒识^[11]。因此,在分类器分类不一致的情况下,该方法不能给出很好的分类效果,不仅没有考虑到单个特征对分类的作用,而且没有合理结合样本的多样性,导致分类精度很低。

2.2 样本自适应多特征加权的遥感图像分类

Domeniconi 等人^[12]发现分类器的性能与训练个体的局部特征分布有关,他们提出一种局部自适应距离度量的最近邻分类方法(Locally Adaptive Metric Nearest-Neighbor Classification),试验结果表明,该方法可以提高最近邻分类器的正确率。针对以往遥感图像特征融合分类方法没有考虑到样本的多样性及特征的本身特性的不足,本文借鉴文献[12]的特征加权方法,提出了一种样本自适应多分类器组合的高分辨率遥感图像分类方法。该方法根据样本在不同特征空间最近邻的类后验概率分布计算出各个特征对分类贡献的权重,然后利用不同特征的权重对该样本的多特征分类结果进行融合。

具体权重确定过程如下:设 X_0 为待测试图像,根据最近邻方法,利用欧氏距离搜索 X_0 的一幅最近邻图像 X ,令 $P(j|X)$ 为 X 的类条件概率, J 为图像的类别总数,则

$$D(X, X_0) = \sum_{j=1}^J \frac{[P(j|X) - P(j|X_0)]}{P(j|X_0)} \quad (1)$$

$D(X, X_0)$ 衡量了图像 X 与图像 X_0 基于不同类条件概率的距离。 $D(X, X_0)$ 越小表明测试图像 X_0 的分类错误率越接近于其最近邻图像 X 的渐近错误率。式(1)计算了真实后验概率与其估计值之间的距离。如果利用 X_0 的每维特征估计 $P(j|X)$ 的均值,那么, $D(X, X_0)$ 衡量了该特征预测 $P(j|X)$ 的相关性(relevance)。

基于上述讨论, $P(j|X)$ 是一个关于 X 的函数。 $P(j|X)$ 的条件期望用 $\bar{P}(j|x_i=z)$ 表示,设 x_i 为样本图像 X 的 i 维特征向量,那么 $\bar{P}(j|x_i=z) = E[P(j|X)|x_i=z] = \int P(j|X)p(X|x_i=z)dx$,其中 $p(X|x_i=z)$ 是输入变量的条件概率密度。令

$$r_i(Z) = \sum_{j=1}^J \frac{[P(j|Z) - \bar{P}(j|x_i=z_i)]^2}{\bar{P}(j|x_i=z_i)} \quad (2)$$

式(2)表示特征 i 在 $x_i=z_i$ 处预测 $P(j|Z)$ 的能力, $\bar{P}(j|x_i=z_i)$ 越接近于 $P(j|Z)$,表明特征 i 携带了更多预测局部 Z 的类后验概率的信息,从而特征 i 对分类的作用越大。利用基于欧氏距离的最近邻方法搜索出测试图像在训练样本中的 K 个最近邻图像,定义测试图像 X_0 的特征相关性度量:

$$\bar{r}_i(X_0) = \frac{1}{K} \sum_{z \in N(X_0)} r_i(z) \quad (3)$$

式中, $N(X_0)$ 表示图像 X_0 在训练样本中的 K 个最近邻,式(3)描述了特征 i 对未知样本图像在最近邻空间的分类作用的平均值。根据式(3), \bar{r}_i 作为局部相关性测量,衡量了基于特征 i 对于 X_0 的一个局部最近邻样本中类后验概率的平均

水平。 \bar{r}_i 越小,表明特征 i 在测试图像 X_0 的邻域内的类后验概率越大。令 q 表示不同特征的数目,通过式(4)来确定各种特征的权重:

$$w_i(X_0) = \frac{\exp(c \frac{1}{\bar{r}_i(X_0)})}{\sum_{l=1}^q \exp(c \frac{1}{\bar{r}_l(X_0)})} \quad (4)$$

式中, c 是用来选择 \bar{r}_i 对 w_i 影响大小的参数。当 $c=0$, $w_i=\frac{1}{q}$ 时,将不考虑 \bar{r}_i 的作用;反之,当 c 很大时, \bar{r}_i 将对 w_i 产生指数级的影响。指数级的权重对局部特征相关性的变化更加敏感,并且能更好地提高分类性能。

采用估计的方法对式(2)中的 $P(j|Z)$ 和 $\bar{P}(j|x_i=z_i)$ 赋值。设 $y_n \in \{1, \dots, J\}$, N 为 $N_1(Z)$ 邻域的大小(即样本 X_0 的最近邻样本个数),

$$\hat{Pr}(j|Z) = \frac{\sum_{n=1}^N 1(X_n \in N_1(z)) 1(y_n=j)}{\sum_{n=1}^N 1(X_n \in N_1(z))} \quad (5)$$

$\hat{Pr}(j|Z)$ 表示在局部邻域 $N_1(Z)$ 内, X 属于类别 j 的概率期望。同样, $\bar{P}(j|x_i=z_i)$ 用类似的方法估算:

$$\hat{Pr}(j|x_i=z_i) = \frac{\sum_{x_n \in N_2(z)} 1(|x_n - z_i| \leq \Delta_i) 1(y_n=j)}{\sum_{x_n \in N_2(z)} 1(|x_n - z_i| \leq \Delta_i)} \quad (6)$$

可以调整 Δ_i 的大小,从而基于特征 i 确定在 $N_1(Z)$ 和 $N_2(Z)$ 两个邻域内筛选掉的样本个数。 $\hat{Pr}(j|x_i=z_i)$ 表示在局部邻域 $N_2(Z)$ 内, 基于特征 i 判断 X 属于类别 j 的概率期望。

文献[12]利用上述过程为 KNN 分类器的每个特征维进行权重估计,而在遥感图像分类中,我们不能将不同属性的特征串接(feature concatenation)在一起进行距离的计算。一方面是因为不同类型的特征,其物理意义不同,将不同属性的特征串接得到的距离其物理意义并不明确;另一方面,遥感图像的训练样本较少,并且不同特征各自维数较高,串接到一起更加容易导致“维数灾难”(curse of dimensionality)。在假设各特征对分类均比较有效的前提下,本文分别首先利用各种特征训练多个分类器,然后采用上述过程确定各种特征的权重,最后进行样本自适应加权的多特征多分类器融合。算法具体步骤如下:

1. 训练过程。提取全局特征得到 BOVW 表示、HSL 颜色直方图表示和 Gabor 纹理表示。然后分别用支持向量机训练,得到 3 个不同的支持向量机分类器,分别记为 SVM1, SVM2, SVM3。

2. 测试:提取待测试图像的 BOVW 表示、颜色直方图特征以及 Gabor 纹理特征,将其分别采用 SVM1, SVM2, SVM3 进行分类,得到该图像属于不同类的 3 组预测概率,分别为 P_1, P_2, P_3 。

3. 计算测试图像在 3 种特征空间中各个特征的权重:

① 将 BOVW, HLS, Gabor 3 种特征的权值初始化为 1, 采用欧氏距离的最近邻方法来获取测试图像在训练样本中的不同 k 个最近邻样本图像,由于 3 种特征的物理意义各不相同,本文统计 3 种特征在训练样本空间中的平均距离作为归一化因子,对基于 3 种特征的欧氏距离分别进行归一化处理, k 取

K_1, K_2, K_3 , 此处 K_1, K_2 分别对应式(5)、式(6)中 $N_1(Z)$ 和 $N_2(Z)$ 的邻域大小, K_3 对应式(3)中的 $N(X_0)$ 大小;

② 计算 K_1 个最近邻样本属于各个类别的概率;

③ 对 K_2 个最近邻样本计算其基于每一种特征与待测样本的距离在 Δ_i 范围内(为了基于各种特征下的 Δ_i 一致,本文将该距离进行归一化)属于各个类别的概率;

④ 利用式(2)计算每一种特征对分类的作用大小;

⑤ 对 K_3 个最近邻样本计算每一个最近邻样本的每一个特征对分类的作用大小,统计 3 种特征对分类的作用大小的平均值,通过式(3)得出对于该测试图像的每一个特征的局部分类作用大小;

⑥ 利用每一特征的局部分类作用大小,根据式(4)来计算每一特征的权重。

4. 将第 2 步输出的各个特征预测概率 P_1, P_2, P_3 与对应的权重相乘求和,取最大值所对应的类别作为多特征融合的最终分类结果。

3 实验结果与分析

3.1 实验数据

本文采用的图像数据集是国际上大型的遥感图像分类公共测试数据集^[16],共有 21 类,每类包括 100 幅图像,均为 QuickBird 高分辨率遥感图像,大小为 256 * 256。这些图像从 United States Geological Survey(USGS) 处下载的,包括美国各个州的多种场景:如农田,机场,棒球内场,海滨,建筑物,灌木丛,稠密居民区,森林,高速公路,高尔夫球场,海港,十字路口,中等稠密居民区,活动房区,立交桥,停车场,河流,跑道,稀疏居民区,储油罐和网球场等。这些图像反映了每类场景的不同表示形式,具有很好的代表性。在下面分类实验中,如无特别说明,我们从每一类中取出 80 幅图像作为训练样本,20 幅图像作为测试样本。

各个特征具体参数如下:词袋模型中,码本(codebook)个数为 1000;颜色直方图特征向量维数为 512;对于 Gabor 纹理特征,尺度数为 5,方向数为 6,向量维数为 60。

本文算法中有 5 个可调参数: K_1 :式(5)中在 $N_1(Z)$ 邻域内的最近邻图像数目; K_2 :对于式(6)中 K_3 个最近邻图像的每一个 $N_2(Z)$ 邻域内的最近邻图像数目; K_3 :待测样本图像的最近邻图像数目; Δ_i :确定在 $N_2(Z)$ 邻域内而基于单个特征距离范围内最近邻的阈值; c :式(4)中的指数加权因子。

实验中, $N=1680$ 个训练图像, $q=3$ 种特征, $J=21$ 类。在确定待测图像的 k 个最近邻时, k 的 3 个不同取值 K_1 从一定范围内(3, 5, 7, 9, 11, 13, 15, 17, 19, 21, 23, 25)搜索, K_2, K_3 在总体训练样本的 10% 到 40% 搜索, c 的值在 1 到 20 范围内变化, Δ_i 的值从 0.5 向 1.5 转移。通过对训练集实验结果的比较,最终确定 K_1 的值为 9, K_2 和 K_3 的值在 15% 的总体样本时,即 K_2 的值为 252, K_3 的值为 252, c 的值为 18, Δ_i 的值为 1 时,分类结果最佳。

3.2 本文方法结果

采用本文样本自适应融合算法的分类结果的统计见图 1。从图 1 可以看出,每一类的分类精度都要比单一特征的最大分类精度高,这充分说明对每一个样本图像,各个特征之间

存在互补性。采用样本自适应多特征加权的方法可以根据图像的局部特点自适应选择各个特征的权重,进而对其结果进行融合。从图像的总体平均分类精度上看,达到了90%,比单一特征分类精度的最高值78.3%高出近12个百分点。良好的分类精度证明了本文算法比较有效。




图1 单一特征与本文方法的各类分类精度和总的平均分类精度

3.3 与其他方法比较

图2给出了加权综合法、多数投票法和完全一致法3种分类器组合方法以及本文的方法在测试集上的实验结果。其中,加权综合法计算每种特征所对应分类器的总体精度,将其作为权重值,然后分别求出待测图像的每种特征所对应的类概率值,并乘以其权重。最后将相同类的概率值相加,并以最大概率作为最终的类别输出。多数投票法计算每种特征所对应的类别标签输出,只有存在至少两个输出标签相同时才给出识别结果,否则拒识。完全一致法要求更严格,只有在3个分类器输出一致的情况下才输出结果,否则拒识。通过比较实验结果,可以发现:加权综合法的分类精度为88.1%,最接近本文算法的结果,但是该方法具有“过拟合”的风险,对所有测试样本都采用同一组权重系数;而本文方法充分利用不同样本特征的局部相关性,自适应调整特征的权重,很好地避免了这一问题。多数投票法和完全一致法的分类精度明显低于本文方法,分别只有81.43%和52.86%。




图2 完全一致法、加权综合法、多数投票法与本文方法的各类分类精度和总的平均分类精度

本文的多特征融合分类方法在整体上提高了分类性能。通过分析测试图像样本邻域特征分布,可以更加有针对性地确定各种特征的权重,利用特征在训练图像样本中的统计信息来获得特征之间的关系,并对单一特征分类结果进行自适应融合,有助于纠正一些易错的分类,部分解决了低层特征与高层语义之间的“语义鸿沟”问题,从而使高分辨率遥感图像分类更加有效、可靠。

结束语 本文采用基于支持向量机的多特征融合对高分辨率遥感图像进行分类,提出了一种样本自适应多特征加权的方法。该方法能够针对不同测试样本图像自适应地选择不同的特征权重,发挥各特征在不同样本和不同局部特征空间的

分类优势,提高了分类准确率,最终从整体上提高了分类性能。与当前流行的几种融合方法进行比较,在一个大型遥感图像公共测试数据集上进行了对比实验,证明了本文方法的优越性。

本文由于对每个测试样本都要在不同特征空间计算其最近邻,算法时间复杂度较高。如何提高计算效率是今后需要进一步改善的方向之一。

参 考 文 献

- [1] 彭正林,毛先成,刘文毅,等.基于多分类器组合的遥感影像分类方法研究[J].国土资源遥感,2011,89(2):19-25
- [2] 王彦杰.基于显著局部特征的视觉物体表示方法[D].北京:北京理工大学,2010
- [3] 张春霞,张讲社.选择性集成学习算法综述[J].计算机学报,2011,34(8):1399-1410
- [4] 陈海林,吴秀清,胡俊华.基于局部特征空间相关核的图像目标分类[J].光电子工程,2009,36(3):33-38
- [5] 孙灏,杜培军,赵卫常.基于多分类器组合的高分辨率遥感影像目标识别[J].地理与地理信息科学,2009,25(1):32-35
- [6] 陈忠.高分辨率遥感图像分类技术研究[D].北京:中国科学院研究生院,2006
- [7] Lowe D G. Distinctive Image Features from Scale-Invariant Keypoints[J]. International Journal of Computer Vision, 2004, 60(2):91-100
- [8] Mallat S. A Theory of Multi Resolution Signal Decomposition: the Wavelet Representation[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 1989, 11(7):674-693
- [9] Zhou Z H. Ensemble Methods: Foundations and Algorithms [M]. Boca Raton, FL: Chapman & Hall/CRC, 2012
- [10] 刘小芳.基于核理论的遥感图像分类方法研究[D].成都:电子科技大学,2011
- [11] 张文博,姬红兵,王磊.一种自适应权值的多特征融合分类方法[J].系统工程与电子技术,2013(4):1133-1137
- [12] Domeniconi C, Peng Jing, Gunopoulos D. Locally Adaptive Metric Nearest-Neighbor Classification[J]. IEEE Trans. Pattern Anal. Mach. Intell., 2002, 24(9):1281-1285
- [13] 肖海军,洪帆,张昭理,等.基于融合分类和支持向量机的入侵检测研究[J].计算机仿真,2008,25(4):130-132
- [14] Li Shi-jin, Tao Jia, Wan Ding-sheng, et al. Content-based remote sensing image retrieval using co-training of multiple classifiers [J]. Journal of Remote Sensing, 2010, 14(3):493-506
- [15] Benediktsson J A, Chanussot J, Fauvel M. Multiple classifier systems in remote sensing: from basics to recent developments [C]//Haindl M, Kittler J, Roli F, eds. Proceedings of the 7th international conference on Multiple classifier systems (MCS'07). Berlin, Heidelberg: Springer-Verlag, 2007:501-512
- [16] Yang Yi, Shawn N. Spatial pyramid co-occurrence for image classification[C]//IEEE International Conference on Computer Vision. 2011:1465-1472