

基于多特征和支持向量机的风景图像分类^①

周云蕾¹, 郭洁畅², 朱 蓉¹, 林青青¹, 金小菲¹

¹(嘉兴学院 数理与信息工程学院, 嘉兴 314001)

²(杭州电子科技大学 数字媒体与艺术设计学院, 杭州 310018)

摘要: 本文提出了一种基于多特征和支持向量机的风景图像分类方法. 首先, 通过深入分析风景图像在视觉内容上的显著特点, 利用融合颜色、纹理和形状等多种特征的方式来描述图像; 其次, 采用一种加权主成分方法对提取的高维图像特征进行有效降维; 最后, 运用基于支持向量机的分类器对图像进行分类. 经试验验证, 本文中提出的方法对风景图像有较好的分类效果.

关键词: 图像分类; 特征提取; 多特征; 加权主成分分析; 支持向量机

Landscape Image Classification Based on Multi-Feature Extraction and SVM Classifier

ZHOU Yun-Lei¹, GUO Jie-Chang², ZHU Rong¹, LIN Qing-Qing¹, JIN Xiao-Fei¹

¹(College of Mathematics Physics and Information Engineering, Jiaxing University, Jiaxing 314001, China)

²(School of Media and Design, Hangzhou Dianzi University, Hangzhou 310018, China)

Abstract: This paper mainly proposed a classification method based on multi features and support vector machine. Firstly, by analyzing the features of landscape image in the visual content, the image is described by means of fusion color, texture and shape features. Secondly, a weighted principal component method is used to reduce the features of high dimensional image. Finally, the experimental results show that the method proposed in this paper has a good classification effect on landscape images.

Key words: image classification; feature extraction; multi features; weighted principal component analysis(WPCA); support vector machine(SVM)

在科学技术不断创新和发展的今天, 信息的承载和表达方式越来越多, 如文本、音频、图像和视频等, 都是人们日常生活中获取和传递信息的媒介手段. 然而心理学研究表明, 人类利用视觉获取的信息大约占总信息获取量的 83%^[1]. 因此说明图像这一媒介, 是人们获取信息的主要来源. 随着互联网技术的不断发展, 虽然图像信息借助网络平台实现了广泛传播, 但同时也带来了图像数据堆积的问题. 如何通过有效的分类, 从而在海量图像数据中快速、准确地找到目标信息, 是当前图像处理领域的主要研究内容之一.

由于目前网络图像中, 风景图像是传播最为广泛的类别之一, 并且由于其所包含的信息内容丰富, 图

像构成复杂等原因, 使得难以对风景图像实现准确率较高的分类^[2]. 除此之外, 虽然传统图像检索方法对风景图像分类在一定程度上是有效的, 但是仅仅通过这些局部特征难以进一步反映风景图像的高层语义^[3], 因而对于局部特征相似但整体内容差别较大的风景图像难以获得较好的分类效果. Lipson P, Grimson E, Sinha P 在 1997 年通过手工方式对某几类风景图像的色彩与空间建立了 Configural Template 的描述^[4]. Das^[5]则根据先验知识, 使用图的结点代表图像的主要颜色等, 利用属性图方法来描述风景图像.

相较于上文所提到的一些传统图像分类方法所存在的复杂且效率低等问题, 基于内容的图像检索(Content Based Image Retrieval, CBIR)则需要很少、甚

① 基金项目:浙江省自然科学基金项目(LY15F020039);浙江省大学生科技创新活动暨新苗人才计划(2015R417026)

收稿时间:2015-09-01;收到修改稿时间:2015-11-02

至不需要人工力量参与到图像的分类过程中,同时,它还可以有效的提高图像分类的自动化程度,这使得 CBIR 系统日益成为了现有图像分类系统的主流技术来源^[6]. CBIR 往往需要对图像所具有的不同特征进行融合,实现基于多特征的图像分类.图像的多特征内容包括图像的颜色、形状、纹理和语意等特征^[7].对这些特征进行综合提取和分析有助于对图像的整体内容进行学习和理解.此外,基于多特征的图像分类研究成果可应用于多种研究领域,如图像搜索引擎、网络版权保护、敏感图像的识别与过滤、面向特定图像的数据挖掘等,具有一定的现实意义.

1 多特征提取

图像特征具有一定的复杂性及多样性,故本文中提出的基于多特征和支持向量机的风景图像分类研究方法中主要选取了图像颜色、形状和纹理这三种特征作为多特征的研究基础.下面,本文将分别针对这三类特征的提取方法进行简要说明.

1.1 颜色特征提取

作为风景图像的主要特征之一,颜色特征是描述一幅图像最简便而有效的特征^[8],并且通过利用颜色直方图所具有的统计特征,可以实现对图像颜色特征的直观描述.在视觉上具有一定相似度的彩色图像因为其颜色分布相似,所以往往能够得到相似的颜色直方图,这一特点可以说明颜色直方图与彩色图像之间存在着一定的对应关系.因此,本文将这种关系应用到风景图像分类中,使用颜色直方图及其统计特征作为风景图像的颜色特征.

常见的颜色直方图有统计直方图 (statistic histogram)和累加直方图(accumulative histogram). 本文利用图像特征的统计直方图来对风景图像进行刻画.如式(1)所示,颜色特征的统计直方图的函数是一维离散的,而其图形表示是二维的.

$$H(x) = \frac{n_x}{M}, x = 0,1,\dots,K-1 \quad (1)$$

其中, x 是图像的特征取值, K 是特征取值总数, n_x 是图像中具有特征值为 x 的像素个数, M 是图像像素个数^[9].

1.2 形状特征提取

因为对于某些风景图像来说,颜色信息并不能成为区分两类风景图像的有效特征,如图 1 所示,草原和山脉的主要颜色都是绿色,这两幅图像在颜色的比

例及分布上具有极高的相似性,如果只考虑图像的颜色特征将难以实现对这两种风景图像的有效分类.但其形状特征则有明显的区别,这时基于颜色特征的分类方法将无法实现图像分类的需求,从而考虑引入图像的形状特征作为这类在颜色上具有极高相似度的图像的分类依据.形状特征是图像的核心特征,该特征不受图像颜色变化的影响,即颜色改变不会引起图像形状特征的变化,这使得形状特征成为图像各种特征中一种稳定的特征.

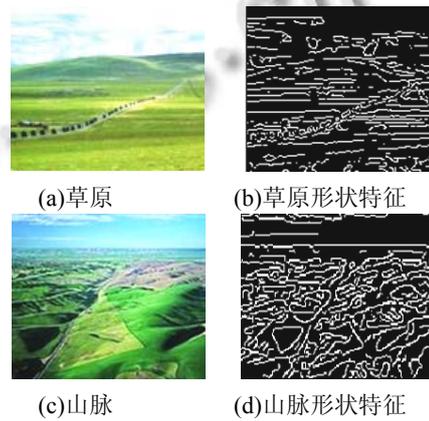


图 1 草原、山脉及其形状对比图

对图像的形状特征进行提取需要先对目标图像进行边缘检测,接着对其提取形状特征,或直接对图像寻找合适的矢量特型^[10].

Canny 边缘检测算子作为 edge 函数中最强的边缘检测算子,具有低误码率、高定位精度以及抑制虚假边缘等优点,因此本文使用 Canny 算子对图像进行边缘检测.

在对风景图像进行边缘检测后就可以获得风景图像的 Hu 不变矩的七个特征值,从而提取图像的形状特征. Hu M.K.^[11]提出了可以利用代数不变矩理论的方法来构造七个不变矩的观点,通常这七个不变矩称为 Hu 不变矩.如下式(2)所示^[12].

$$\begin{aligned} \phi_1 &= \eta_{20} + \eta_{02} \\ \phi_2 &= (\eta_{20} + \eta_{02})^2 + 4\eta_{11}^2 \\ \phi_3 &= (\eta_{30} + 3\eta_{12})^2 + (\eta_{03} + 3\eta_{21})^2 \\ \phi_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{03} + \eta_{21})^2 \\ \phi_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} - \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{03} + \eta_{21})^2] + (3\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{03} + \eta_{21})^2] \end{aligned}$$

$$\begin{aligned} \phi_6 &= (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{03} + \eta_{21})^2] + \\ & 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{03} + \eta_{21}) \\ \phi_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{03} + \eta_{21})^2] \\ & + (3\eta_{12} + \eta_{30})[3(\eta_{30} + \eta_{12})^2 - (\eta_{03} + \eta_{21})^2] \end{aligned} \quad (2)$$

1.3 纹理特征提取

纹理特征是图像除颜色特征及形状特征之外的另一重要特征. 纹理特征对图像所包含的目标物体的表面性质进行了相应的刻画, 并且通常具有周期性.

通过特定的图像处理技术能够将图像的纹理特征抽取出来, 通过这一操作可以取得纹理的定量或定性描述, 这一过程被称为纹理分析^[13], 其在遥感图像分析领域应用十分广泛, 因为颜色和形状相近的风景图像会呈现出不同的纹理特征.

对于应用图像纹理特征来进行图像分类的方法, 其纹理特征提取方法的选择和分类器的设计是决定分类正确率高低的关键. 文献[14]提出在对纹理特征进行提取的过程中可以使用 Gabor 滤波器, 并采用 PCA 方法对提取的特征进行选择, 最后采用 SVM 进行纹理图像分类^[14]. 其中 Gabor 小波变换的算法在文献[15]中给出了利用 MATLAB 编程语言原理式. 在进行实验后发现, 使用 Gabor 小波变换会导致维度过高, 而使用双树复小波的维数仅为 36 维^[15], 所以本文使用双树复变换作为图像的纹理特征, 具体的算法流程图如图 2 所示.

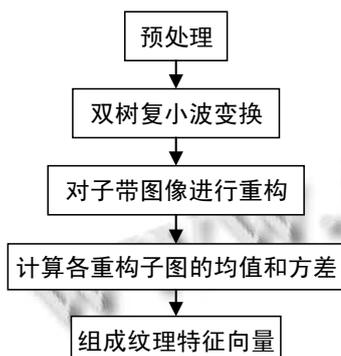


图 2 双树复小波变换算法流程

2 特征优化

上文涉及到对风景类图像综合特征的提取, 包括对作为颜色特征的颜色直方图、作为形状特征的 Hu 不变矩以及作为纹理特征的小波变换的三类特征. 通常情况下, 特征数目的增加在帮助图像内容描述准确性提高的同时, 也为所提取的特征带来了数据处理上

困难的增加. 在图像处理过程中, 每增加一个特征就会使得描述图像的向量维度增加, 从而使得特征数据的维数过高. 这样不仅不能保证分类准确率的提高, 甚至可能会导致某种程度上处理效率的下降. 这是因为在描述图像的问题中, 并不是每一个特征都能够对图像分类的预测作出贡献, 部分特征对风景图像而言可能是低效特征, 无关特征. 这样一来不仅会增加分类系统的实现难度, 还会影响到图像分类的准确性.

对于多特征带来的数据处理难度增加的问题, 文献[16]提出了一种基于特征加权的自动图像分类方法: 该方法考虑到图像特征对分类系统的贡献不同, 分别为特征赋予不同的权重. 一开始, 将根据特征分布的离散程度来判断特征所应该获得的权重, 为高度相关的特征增加权重, 以肯定该特征在图像分类中所起到的作用, 进而防止弱相关或不相关的特征支配后续标注算法, 从而提高图像的整体分类效果^[16].

此外, 文献[17]也提出了一种以特征加权为基础的图像分类方法: 以特征的稳定性为依据, 对各特征的重要程度进行判断, 从而给予各个特征不同的权重, 然后借助支持向量机(SVM)实现图像分类^[17].

基于以上两种特征加权的处理方法, 考虑到风景图像中颜色、形状和纹理特征在图像整体特征表达上所占比重存在一定差异, 结合颜色对于风景图像的表达具有突出贡献等因素, 本文对于多特征的处理提出以下方法:

首先通过色彩对风景图像进行大致的分类, 其次再通过形状和纹理特征对上一步中粗分类的图像进一步分类. 在特征优化基础上, 运用支持向量机对风景图像进行分类相信会获得较好的实验结果.

下面, 本文将从主成分分析及加权主成分分析两个方面来介绍特征优化方法.

2.1 主成分分析

主成分分析(Principal Component Analysis, PCA), 是一种常用的统计分析方法, 它的原理是把原本的多个变量, 通过数学分析和处理的方法, 划分为少数的几个综合指标. PCA 的实质就是在尽可能好地代表原始数据的前提下, 通过线性变换将高维空间中的样本数据投影到低维空间中^[18]. 而虽然目前可以用于降维的算法有许多, 如 PCA、ICA、LDA 以及 LLE 等, 但与其他算法不同的是, PCA 在去除图像的二阶相关性方面能使重构的图像与原图像相比具有方差小和峰值

信噪比高的特点^[19]。此外, PCA 在降维时因丢弃的某些特征而损失的信息可以通过低维空间中更加精确地映射得到补偿, 进而在低维空间中仍可得到和高维空间相近的识别率。基于 PCA 的这些优点, 并且考虑到风景图像中颜色、形状和纹理特征之间是具有一定的相关性的, 因此本文选用 PCA 对提取的多特征数据进行降维, 从而划分出风景图像的综合特征。

尽管 PCA 在数据降维处理上拥有较多优势, 但是需要确保 PCA 能够有效工作仍需满足待处理图像的主要特征能够在图像中大致相同的区域内。否则虽然此时 PCA 可以照常计算, 但降维后得到的样本矩阵用于分类所获得的正确分类的准确率将有所下降。由于本文实验中所涉及到的不同种类的风景图像在其类别范围内具有相似度较高的颜色、形状及纹理特征的分布, 因而 PCA 算法的这一缺点对本文实验结果的准确率影响较小。

PCA 的计算步骤如图 3 所示。

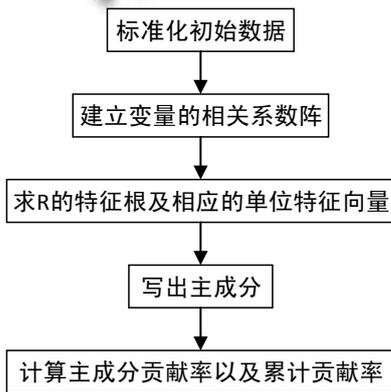


图 3 PCA 计算步骤

其中, 变量的相关系数如式(3)所示。

$$R = (r_{ij})_{p \times p}$$

$$r_{ij} = \frac{\sum_{k=1}^n (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j)}{\sqrt{\sum_{k=1}^n (x_{ki} - \bar{x}_i)^2 \sum_{k=1}^n (x_{kj} - \bar{x}_j)^2}} \quad (3)$$

R 的特征根需要满足 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p > 0$ 的条件, 并分别对应了: a_1, a_2, \dots, a_p 。如式(4)所示。

$$a_1 = \begin{bmatrix} a_{11} \\ a_{21} \\ \dots \\ a_{p1} \end{bmatrix}, a_2 = \begin{bmatrix} a_{12} \\ a_{22} \\ \dots \\ a_{p2} \end{bmatrix}, \dots, a_p = \begin{bmatrix} a_{1p} \\ a_{2p} \\ \dots \\ a_{pp} \end{bmatrix} \quad (4)$$

根据上述可以写出主成分, 如式(5):

$$F_i = a_{1i}X_1 + a_{2i}X_2 + \dots + a_{pi}X_p, \quad i=1,2,\dots,p \quad (5)$$

一般将累计贡献率达 85%到 95%之间的特征值 $\lambda_1, \lambda_2, \dots, \lambda_m$ 所对应的向量作为第 1、第 2、...、第 m 个主成分。贡献率计算公式如式 2-4, 累计贡献率计算公式如式(7)。

$$\frac{\lambda_i}{\sum_{k=1}^p \lambda_k} \quad (i=1,2,\dots,p) \quad (6)$$

$$\frac{\sum_{k=1}^i \lambda_k}{\sum_{k=1}^p \lambda_k} \quad (i=1,2,\dots,p) \quad (7)$$

图 4 显示了对所提取的 50 幅日出日落图像的纹理特征使用 PCA 进行降维的结果图。可以看出, 原本纹理特征需要 36 维特征向量来进行表达, 现在仅需 5 维特征向量其贡献率就能达到 97%以上, 这说明使用 PCA 降维的方法是切实可行的。

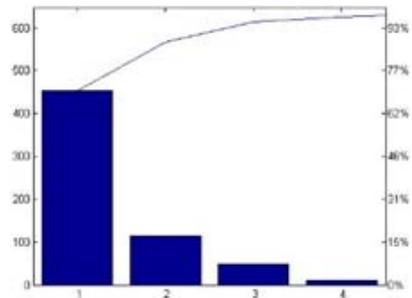


图 4 日出日落图像纹理特征的 PCA

2.2 加权主成分分析

在风景图像分类的过程中, 从一幅风景图像中提取出来的颜色、形状以及纹理特征, 在图像分类过程中各自发挥着不同的作用。如颜色特征就与风景图像的分类相关性较高, 而纹理特征相关性较低。但纹理特征又是可以区分类似草原和森林这类风景图像的关键特征。所以如何合理地构造特征空间, 并分别给这些特征赋予不同的权重显得十分重要。

考虑到特征加权和 PCA 都能有效的降低图像特征维度, 并且比较符合风景图像分类的要求, 本文将采用结合特征加权和 PCA 来处理提取出的三类特征。

根据上述分析, 运用 PCA 进行综合特征提取时, 结合文献[20]提出的一种特征加权融合算法, 将提取出的颜色、形状、纹理特征分别进行 PCA 特征提取得到主成分, 然后将主成分对应的特征进行加权融合,

将融合后的图像特征作为分类器的输入数据^[20]。设主成分有 x 个, C_i 为特征, $0 < i < x$ 。采用不同的权重融合后的综合特征, 得到式(8):

$$X = w_1 C_1 + w_2 C_2 + \dots + w_x C_x \quad (8)$$

令 x 个权重之和为 1。因为颜色特征在风景图像分类中的贡献较大所以在进行权重融合时应给颜色特征较大权重, 其次是形状和纹理特征。

3 SVM的参数及选择

对风景图像的多特征进行提取和加权融合及分析之后, 要完整实现风景图像的分类还需对风景图像进行分类学习。在这一过程中, 分类器的选择及其参数设置具有决定性作用。

3.1 核函数的选择

设存在着一个映射 $\varphi: x \rightarrow \varphi(x)$, 该映射使 $k(x, x') = k(\varphi(x), \varphi(x'))$ 。其中 $k(x, x')$ 就是所谓的核函数, 它是输入空间与特征空间之间的映射。Vapnik 和他的同伴研究发现^[21], 误差惩罚因子 C 及核函数及其参数的选择将成为影响 SVM 性能的关键性因素。常用的核函数有诸如高斯径向基核 (Gaussian RBF)、多项式核 (Polynomial) 以及 Sigmoid 核等。当前, 高斯径向基核 RBF 的应用最为普及, 因此本文将 RBF 核作为核函数, 从而使用 SVM 分类器对提取的风景图像的综合特征进行分类。

3.2 松弛变量和惩罚因子的选择

将所用的 SVM 分类器的核函数确定为 RBF 核之后, 需要对 RBF 核本身的参数 σ 及惩罚因子 C 进行相应的优化, 进而得到适合的核参数。

RBF 核的自身参数 σ 表示径向基函数的宽度, 它是负指数函数, σ 的指数值如果取小一些, 那么就可以敏感地感觉到指数因受函数影响引起的变化。另外, 从一定程度来说, 核参数的选择也受训练数据量大小的影响。当前对核参数进行抉择的较为常用的方法是: 首先, 将最优分类器找出来; 然后, 再将其余样本集分布特点相互对比, 从而找出它们之间的能够成立的对应关系; 最后, 根据上述步骤来确定分类器的类型和参数, 这点可以根据训练样本的一些先验知识来完成。

4 基于多特征和支持向量机的图像分类系统的分析与实现

4.1 实验图像库说明

本实验图像库中风景图像来自百度图片搜索引擎, 选取了风景类图像中具有代表性的日出日落、海滩及梯田三类图像, 最终得到了一个由 200 幅日出日落图像、200 幅海滩图像及 200 幅梯田图像共计 600 幅风景图像所组成的实验图像库, 并选取了该图像库中每类图像的 50 幅图像共计 150 幅图像组成本次实验的训练集, 同时将剩余的 450 幅图像组成本次实验的测试集。

4.2 算法流程

基于多特征和支持向量机的风景图像分类算法的流程是:

① 特征提取算法流程

对每类图像的训练库中的图像进行颜色、形状和纹理特征的提取。特征提取流程图如图 5 所示。

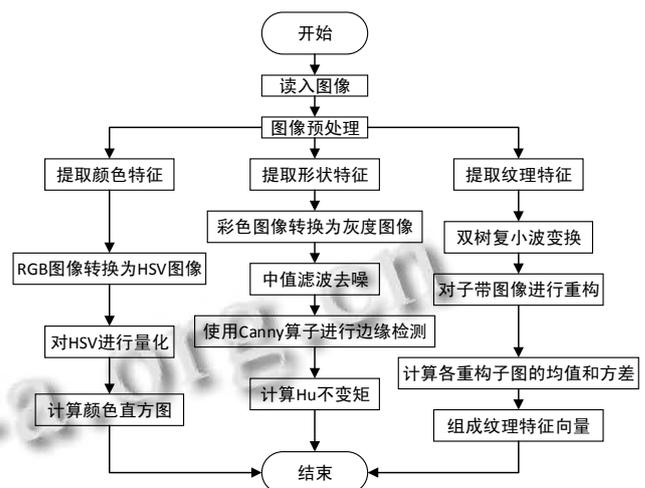


图 5 特征提取算法流程图

② 特征优化算法流程

使用多特征对图像进行分类将会导致 SVM 分类器的输入向量维数较大。并且这些特征中包含着大量的冗余信息。每类风景图像具有不同的特点, 每种特征对每类风景图像的重要性不同。因此本系统采用 PCA 将提取的每个特征的主成分找出, 并根据每类风景图像特点赋予每种特征不同权重。特征优化流程图如图 6 所示。



图 6 特征优化算法流程图

③ 总算法流程

本系统算法的总流程图如图 7 所示。

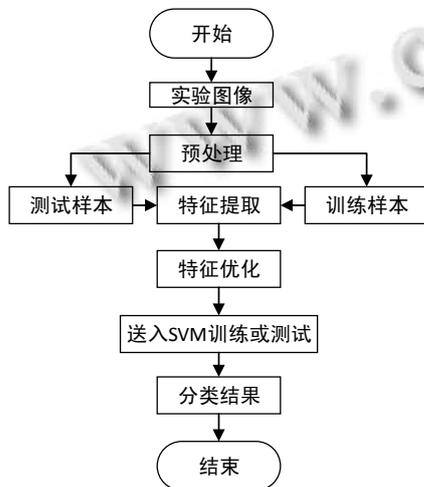


图 7 总算法流程图

5 实验分析

表 1 单特征图像分类方法与多特征图像分类方法的性能对比

| 分类方法 | 分类准确率(%) | | | 平均分类准确率(%) |
|---------------|----------|--------|--------|------------|
| | N = 20 | N = 30 | N = 50 | |
| 颜色直方图+SVM | 77.58 | 83.42 | 89.61 | 83.54 |
| 颜色直方图+PCA+SVM | 74.36 | 78.52 | 86.34 | 79.74 |
| 多特征+SVM | 81.29 | 86.58 | 90.27 | 86.05 |
| 多特征+PCA+SVM | 80.26 | 86.49 | 91.78 | 86.18 |

由于本次实验所选取的三类风景图像在颜色特征上区别最为明显，故本次实验选取了颜色直方图作为

单特征分类方法的代表与本文所提出的基于多特征的分类方法进行比较分析。观察表 5-1 中所统计的四种分类方法在训练样本(N)数目取不同值的情况下的分类准确率及平均分类准确率可以发现，颜色直方图作为区分本次实验三类图像最为突出的特征，在结合使用 SVM 后这一分类方法得到了较好的分类结果。但是对该方法使用 PCA 降维后在本次实验中虽然提升了分类速度，但却降低了分类的准确率。说明在本实验中对数据降维后在一定程度上降低了原数据间的差异性，从而导致分类准确率下降。

相对于单特征的颜色直方图+SVM 分类方法来说，多特征+SVM 的分类方法在一定程度上提升了分类的准确性，这说明对于在某些仅仅根据单一特征而难以区分的风景图像来说，基于多特征的分类方法能降低因特征的单一而带来的分类误差。其中，虽然在 N 较小的情况下，使用了 PCA 对数据进行降维的基于多特征的分类方法并没有很好的提升分类准确率，但随着 N 的增大，这一分类方法对于分类准确率的提升效果也逐渐增大。说明这一分类方法不仅加快分类速度的同时还提高了分类准确率，从整体上提升了原算法的性能。

此外，本次实验结果仍然存在一定误差的主要原因有：

- 1) 尽管已经提取了图像的多种特征，但在特征提取过程必然会丢失部分图像信息从而影响分类准确率；
- 2) 分类器具有模糊性，并且在 SVM 分类器的核参数的选取具有一定主观性；
- 3) 本实验在选取实验图像时由于图像来源与训练样本与测试样本数量设置的限制等因素对实验结果的准确性也会造成一定程度上的影响。

6 结语

随着互联网技术的不断发展及多媒体领域相关技术的日益成熟，快速、准确的图像分类技术的应用将越来越广泛。而风景图像作为互联网图像中所占比重较大的一类图像，其自身具有颜色、形状及纹理等特征突出的优势，通过对这些特征进行综合提取与分析，将获得较好的学习效果，从而提升风景图像分类的速度与准确率。本文研究的基于多特征和支持向量机的风景图像分类方法通过对风景图像进行多特征提取与

分析处理并利用支持向量机方法最终获得了基于风景类图像较好的分类效果。

参考文献

- 1 王惠锋,孙正兴,王箭.语义图像检索研究进展.计算机研究与发展,2002,39(5):513-522.
- 2 侯玉婷.基于 SVM-KN 的特征自适应加权自然图像分类研究[硕士学位论文].西安:西北大学,2014.
- 3 王小玲,刘念祖,谢康林.基于语义的风景图像检索.计算机工程与设计,2008,29(16):4271-4274.
- 4 Lipson P, Grimson E, Sinha P. Configuration based scene classification and image indexing. Proc. of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 1997. 1007-1013.
- 5 Das M, Riseman E, Draper B. FOCUS: Searching for multi-colored objects in a diverse image database. Computer Vision and Image Understanding, 2004, 94(1-3): 168-192.
- 6 朱蓉.基于语义 WEB 图像分类研究[博士学位论文].杭州:浙江大学,2011.
- 7 王文慧.基于内容的图像检索技术研究[博士学位论文].长沙:国防科学技术大学,2001.
- 8 王娟,孔兵,贾巧丽.基于颜色特征的图像检索技术.计算机系统应用,2011,20(7):160-164.
- 9 Gonzalez RC, Woods RE, Eddins SL. 数字图像处理的 MATLAB 实现.北京:清华大学出版社,2013:35-42.
- 10 陈宏.基于形状特征的图像检索[硕士学位论文].西安:西安电子科技大学,2010.
- 11 Hu MK. Visual pattern recognition by moment invariants. IEEE Trans. on Information Theory, 1962, (2): 179-187.
- 12 张伟,何金国.Hu 不变矩的构造与推广.计算机应用,2010,30(9):2449-2452.
- 13 孙艳霞.纹理分析在遥感图像识别中的应用[硕士学位论文].乌鲁木齐:新疆大学, 2005.
- 14 孙娅斌.基于支持向量机的纹理图像分类算法.计算机仿真,2012,29(5):286-290.
- 15 唐银凤,黄志明,黄荣娟,姜佳欣,卢昕.基于多特征提取和 SVM 分类器的纹理图像分类.计算机应用与软件, 2011,28(6):22-28.
- 16 王科平,张志刚.基于特征加权的自动图像分类方法.微型电脑应用,2014,30(1):13-17.
- 17 杜娟,孙君顶.基于特征加权和支撑向量机的图像分类研究.激光与红外,2013,43(3):314-316.
- 18 张铮,徐超,任淑霞,韩海玲编著.数字图像处理与机器视觉:VisualC++与 Matlab 实现.北京:人民邮电出版社,2014: 442-456.
- 19 罗斌,顾伟,吕皖丽,等.基于主分量分析的矢量量化数字水印算法.计算机工程,2010,36(2):167-169.
- 20 赵焕利,王玉德,张学志等.小波变换和特征加权融合的人脸识别.中国图象图形学报,2012,17(12):1522-1527.
- 21 Cortes C, Vapnik V. Support-vector networks. Machine Learning, 1995, 20: 273-295.