

一种基于压缩感知理论的纹理分类方法^{*}

吴迪

(湖南工程学院 电气信息学院, 湖南 湘潭 411004)

摘要: 针对传统纹理分类方法计算复杂的问题, 基于 bag-of-words 模型提出了一种简单、新奇的纹理分类方法。在特征提取阶段, 使用 NSCT 滤波器对局部图像块进行映射投影, 然后通过观测矩阵提取其随机测量值特征; 在纹理分类阶段, 直接将随机特征嵌入到 bag-of-words 环境, 并直接在压缩域内进行学习和分类。利用纹理图像的稀疏性, 提出的特征提取方法简单, 并且在性能和复杂度上都优于传统特征提取方法。最后使用 CURET 数据库进行数值实验, 并与 patch、patch-MRF、MR8、LBP 四种最经典的方法进行比对。结果表明, 该方法在分类精度以及实时性上有重要的改进。

关键词: 稀疏表示; 压缩感知; 词袋模型; 纹理分类

中图分类号: TP391

文献标志码: A

文章编号: 1001-3695(2016)01-0291-05

doi:10.3969/j.issn.1001-3695.2016.01.067

Texture classification method based on theory of compressed sensing

Wu Di

(College of Electrical & Information Engineering, Hunan Institute of Engineering, Xiangtan Hunan 411004, China)

Abstract: According to the theories of sparse representation and compressed sensing, this paper presented a simple, novel approach for texture classification based on bag-of-words model. At the feature extraction stage, it extracted a small set of random features from local image patches. It embedded the random features into a bag-of-words model to perform texture classification; thus, carried out learning and classification in a compressed domain, yet by leveraging the sparse nature of texture images, our approach outperformed traditional feature extraction methods which involved careful design and complex steps. It conducted extensive experiments on the CURET databases. Results show that our approach leads to significant improvements in classification accuracy and instantaneity.

Key words: sparse representation; compressed sensing; bag-of-words model; texture classification

0 引言

自然图像中纹理无处不在, 它们是组成各种图像分析应用 (如图像分割、图像检索等) 的重要视觉线索。纹理特征是一种不依赖于颜色或亮度, 而反映图像中同质现象的视觉特征, 它是物体表面共有的内在特性。纹理特征包含了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^[1]。

纹理分类是计算机视觉和图像处理的基本问题, 在医学图像分析、遥感、目标识别、基于内容的图像检索中扮演了重要的角色。所以对于纹理分类的研究一直都是比较活跃的主题。当然, 纹理分类也是一个具有挑战性的工作, 其中困难主要集中在特征提取方面。在具体提取过程中, 人们总是先寻找更多能够反映纹理特性的测量值, 然后再通过各种变换或分析从中提取有效的特征量用于纹理表示和描述^[2], 如灰度共现直方图、灰度行程直方图、Markov 随机场模型、金字塔滤波器、Gabor、小波、局部二进制模式 (LBP)^[3]、灰度 Aura 直方图等。这些方法的目的是从局部图像块中选择出有限的纹理特征子集, 用来进行纹理分类。

大多数特征提取方法集中于局部纹理信息的提取, 以所给定像素周围的灰度模型为特征。然而, 纹理也可以以代表局部模型之间关系的全局模型为特征。近来词袋图像 (bag-of-words, BoW) 表示模型^[4] 受到越来越多地关注, 基于 bag-of-words 图像表示模型方法步骤一般为: a) 提取图像局部特征; b) 量化图像局部特征, 构建视觉关键词典; c) 将图像表示为若干视觉关键词组成的集合。这种图像表示模型将二维图像信息映射成视觉关键词集合, 既保存了图像的局部特征又有效压缩了图像的描述, 使得自然语言处理的各种技术与方法能够有效应用于模式识别领域。在纹理分析中引入 bag-of-words 图像表示模型, 则在进行局部纹理信息 (基元构成的局部图像块特征) 编码的同时也可以进行全局纹理信息 (对无序的直方图表示的基元重复频率进行统计) 的编码。

在纹理分类中, 一方面尽管大量文献依赖数据的特征提取和降维, 但是对于什么纹理特征更好没有达成一致, 并且实践者在使用上也缺少指导方针; 另一方面, 为了避免通用降维技术的缺点, 如主成分分析 (PCA), 它比较依赖于数据的类型、固定分解的计算负担, 缺乏原始空间和投影空间的距离保证。所

收稿日期: 2014-12-03; **修回日期:** 2015-01-29 **基金项目:** 国家科技支撑计划项目 (1214ZGA008); 国家自然科学基金项目 (61263031); 湖南省重点学科建设项目 (081101); 重庆市教委自然科学基金资助项目 (KJ1400628); 湖南工程学院博士科研启动基金项目

作者简介: 吴迪 (1985-), 男, 湖南湘潭人, 讲师, 博士, 主要研究方向为多源信息融合及智能信息处理 (wudi6152007@163.com)。

以,为了追求计算更简单、信息损失更少的方法,本文引入基于压缩感知的随机映射(random projection, RP)理论。

随机映射(RP)^[5]指的是将点集合从高维空间投影到随机挑选的低维空间的技术。该技术主要用于组合优化、信息检索、人脸识别、机器学习等。其原始像素的对比分布、滤波器响应和随机特征如图 1 所示。其中纹理 1、纹理 2、纹理 3 分别为三张 Brodatz 纹理图像,图 1(a)(b)为原始像素值平面分布对比;(c)为两线性滤波器响应;(d)~(f)分别为对大小 9×9 、 15×15 、 25×25 的图像块进行随机映射对提取。




图 1 局部图像块随机投影

压缩感知(CS)理论的出现证明了 RP 在信号保留和降维上的强大能力。CS 理论表明,对于稀疏或可压缩信号来说,由极小数量非自适应测量值组成的随机投影可以捕捉绝大部分的信号凸显信息且能够完美重构。Baraniuk 等人^[6]发现 CS 和 Johnson Lindenstrauss (JL)定理(从高维特征空间映射到低维特征空间后数据点之间的距离基本保持不变,表明高维欧几里德空间的点集可以映射到维数为点集数目对数的空间)之间的基本联系(RP 为著名 Johnson Lindenstrauss (JL)定理提供了可行解),它在随机降维映射下稳定嵌入有限点集,即是说 RIP 可以被认为是 JL 定理的直接结果。由于稀疏表示和压缩感知可以通过一些冗余字典的少许基元进行线性组合来很好地逼近音频信号或者自然图像。CS 理论表明,就特征数而言,很小数量的随机特征就能包括足够保留潜在在局部纹理结构的信息,并能够正确地任何测试图像进行分类。

近年来,也有不少文献应用压缩感知理论来进行分类识别。文献[7]中利用 CS 投影观测来进行信号分类,文献[8]中利用随机测量值来执行各种图像的分类。当然,稀疏表示和 CS 在机器视觉和模式识别中最成功的应用之一为 SRC 算法进行人脸识别^[9],识别时将整个训练样本集作为基本字典,并且假设所有的分类样本位于线性子空间以至于可以将识别问题映射为找出测试图像的稀疏表示与训练图像的线性组合之间的区别。它的新奇之处在于直接将人脸图像本身作为字典而不需要学习。需要注意的是, SRC 算法是基于全局特征的,可是纹理分类主要依赖于像素和其邻近像素之间的关系; SCR 算法是基于重建的,而本文方法却想避免重建这计算复杂的

步骤。

所以根据以上理论,本文提出一种计算简单并且有效的纹理分类方法。首先简单选择随机特征集合然后嵌入 bag-of-words 分类环境,并在块压缩域内直接进行分类而无须对参数进行更进一步调制,并且数值实验表明该纹理分类方法优于目前经典的纹理分类方法。

1 建立纹理稀疏模型

CS 的前提基础是信号必须具有稀疏性或者可压缩性。近年来,由于多尺度分析技术的迅猛发展,大多数的自然图像在多尺度域以内都是可压缩的。由于纹理图像大多具有稳定性和周期性,所以也普遍具有稀疏性。使用 CS 理论进行的关键主要是可以预先知道稀疏字典,其中,字典 Ψ 将基础系数向量 θ 映射到稀疏域 $p \approx \Psi \theta$ 。相反, Φ 为从稀疏域到测量值域的映射 $x = \Phi p$ 。所以如果能够直接在压缩域内进行分类的话则可以不进行重建操作也无须知道先验 Ψ 。

此外,大多数纹理分类的文献都以从图像块进行特征提取为基础,而对纹理所潜在的自由度数目知道得较少。文献[10]中,作者首先使用滤波器组减少图像块空间,并且使用局部线性嵌入算法^[11]将滤波器边界投影到各种低维,可以增加分类精度。

2 CS 观测降维

对于局部图像块来说,处理高维数据时降维是很重要的,因为降维可以减轻维数灾难和其他不希望的高维空间性质。最广泛的降维方法有阶乘方法(如 PCA),但是这类方法计算代价过于昂贵,不能保证能够很好地保留原始信号和投影之间的距离。在此本文在 NSCT 域内使用随机投影来降维:

$$\underline{x} = \Phi \underline{p} \quad (1)$$

理想状况下 $m \ll n$ 。明显看出, $\Phi \in \mathbb{R}^{m \times n}$, $m < n$ 由于 Φ 存在零空间所以丢失信息,说明了 $\underline{p}$ 和 $\underline{p} + \underline{z}$ ($\underline{z} \in N(\Phi)$) 之间存在不可分辨性。对特征提取器 Φ 识别的主要挑战是如何使 Φ 的零空间和系数信号 $\underline{p}$ 的低维子空间正交。

理想情况下 Φ 为信号保留的。它提供了稳定嵌入以近似保留所有信号对之间的距离。对于任意两图像块 $\underline{p}_1$ 和 $\underline{p}_2$ 来说,它们之间的距离被近似保留:

$$1 - \varepsilon \leq \frac{\|\Phi(\underline{p}_1 - \underline{p}_2)\|_2}{\|\underline{p}_1 - \underline{p}_2\|_2} \leq 1 + \varepsilon \quad (2)$$

其中: $\varepsilon > 0$ 。文献[12]中 CS 理论关键结果为 RIP, 上式也为 JL 定理的直接结果。所以可以直接使用 CS 来进行纹理分类。

定理 1 对于任何 $0 < \varepsilon < 1$ 以及任何正整数 d 。假设 m 为正整数,则得到

$$m \geq 4 \left(\frac{\varepsilon^2}{2} - \frac{\varepsilon^3}{3} \right)^{-1} \ln d \quad (3)$$

对于任何集合 D 中的每个对 $u, v \in D$ 存在利普希茨映射 $f: \mathbb{R}^{n \times 1} \rightarrow \mathbb{R}^{m \times 1}$:

$$(1 - \varepsilon) \|u - v\|^2 \leq \|f(u) - f(v)\|^2 \leq (1 + \varepsilon) \|u - v\|^2 \quad (4)$$

式(4)通过 $m \times n$ 的矩阵 Φ 可以满足将 f 当做是线性映射表示,其中 Φ 中元素为随机从确定的概率分布(如高斯分布)中获得。

此外,Baraniuk 等人^[16]使用简单的技术来验证以 CS 为基础的随机矩阵的 RIP,并且清楚阐述 RIP 可以认为是 JL 定理的结果。即是说,任何分布只要它能够满足 JL-嵌入则也能满足于 RIP 矩阵。

图 2 为纹理块基于随机测量值重建的例子,重建算法为 CoSaMP。当随机测量值数目增加到足够大时,原始稀疏纹理被完美重构。




图 2 基于测量值的稀疏信号重建


由于在实际应用中信号不可避免地会遇到噪声的干扰,所以式(1)应该修正为:

$$\underline{x} = \Phi \underline{p} + \underline{v} \quad (5)$$

其中: $\underline{v} \in \mathbb{R}^{m \times 1}$ 为与 $\underline{p}$ 无关的噪声项。则可以根据噪声污染的压缩测量值使用伴随欧几里德距离测量的单一最近邻分类器对 $\underline{p}$ 进行分类。如图 3(a) 所示,基础模型为 100 正弦曲线集合为

$$\{p_k(t)\}_{k=1}^{100} = \{\cos(\omega_k t)\}_{k=1}^{100} \quad (6)$$

图 3(b) 为分类精度百分比随测量值数量 m 变化的函数表示。



(b) 为在无噪和有噪情况下测量值数目与分类精度之间的函数关系

图 3 随机特征进行稀疏分类

3 Bag-of-words 聚类

类比于一篇文档中的若干文本单词,bag-of-words 模型认为一幅图像由若干视觉单词组成,提取图片中的若干局部特征并将其转换为视觉单词,根据视觉单词与视觉词汇表的关系生成一幅图像的视觉直方图,视觉单词直方图表述一幅图像的特征,可以有效实现物体的识别分类,其分类框图如图 4 所示。




图 4 bag-of-words 模型分类

设 $p \in \mathbb{R}^{n \times 1}$ 为尺寸大小为 $\sqrt{n} \times \sqrt{n}$ 的局部图像块内像素,假设在图像块空间存在一真实的联合概率分布密度 $f(\underline{p})$,则认为该纹理为均值纹理, $f(\underline{p})$ 为平稳。在提取特征时希望保留包含于局部图像块中的局部纹理信息以及表示纹理之间重复关系的全局纹理。而事实证明,基于基元的方法可以有效地进行局部—全局表示。基元的方法通过使用 K-均值将特征空间自适应分块为簇来训练。如果输入的数据集表示为 $\chi = \{\underline{x}_1, \dots, \underline{x}_\chi\}$, $\underline{x}_i \in \mathbb{R}^{m \times 1}$, 则输出的基元集合为 $W = \{\underline{\omega}_1, \dots, \underline{\omega}_K\}$, $\underline{\omega}_i \in \mathbb{R}^{m \times 1}$ 。聚类解的质量通过平均量化误差来测量,定义为 $Q(\chi, W)$:

$$Q(\chi, W) = \frac{1}{|\chi|} \sum_{j=1}^{|\chi|} \min_{k \leq K} \|\underline{x}_j - \underline{\omega}_k\|_2^2 \quad (7)$$

因此,根据 CS 随机映射与 bag-of-words 模型的互补性,本文提出直接在压缩域进行分类:

$$\chi = \{\underline{x} = \Phi \underline{p} \mid \underline{p} \in D\} \quad (8)$$

其中: $\Phi = [\varphi_{i,j}] \in \mathbb{R}^{m \times n}$ 为高斯随机测量矩阵,其元素 $\varphi_{i,j}$ 为独立、零均值、方差为 1 的高斯随机变量。

4 分类主要步骤

本文主通过提取局部图像块来进行纹理的局部几何研究。首先,在图像块特征提取阶段,于一 N -像素图像 I 中每个像素点位置 (i, j) 周围提取尺寸大小为 $\sqrt{n} \times \sqrt{n}$ 的图像块 $\{p_{i,j}\}_{i,j}$ (图像边缘像素除外)。形式上,该线性运算符从图像 I 中提取所有图像块并表示如下:

$$\Xi: I \rightarrow \{p_{i,j}\}, i, j \in (\frac{\sqrt{n}}{2}, \sqrt{N} - \frac{\sqrt{n}}{2}) \quad (9)$$

每个图像块 p_i 被看做尺寸 n 的向量处理。为了让标记简单,本文使用一个指标 i 代替图像块的两个指标 i, j 。假如有 C 个不同的纹理类,每类有 S 个样本,设第 c 类样本可以表示为 $\{I_{c,s}\}_{s=1}^S, D = \{\{I_{c,s}\}_{s=1}^S\}_{c=1}^C$ 表示整个纹理数据集。通过式(9)从图像 $I_{c,s}$ 中提取尺寸大小为 $\sqrt{n} \times \sqrt{n}$ 的图像块 $\{p_{c,s,i}\}_i$ 。

本文提出的分类器等同于 Patch^[14] 方法,除此之外,使用来源于 $\underline{p}$ 的随机测量值 $\underline{x} = \Phi \underline{p}$ 代替 $\underline{p}$ 作为分类特征,其中 Φ 中的元素由独立零均值、方差为 1 的正态分布采样而来。压缩域为

$$\chi = \{\underline{x} = \Phi \underline{p} \mid \underline{p} \in D\} \quad (10)$$

其为图像块域的压缩表示,其中图像块域表示为

$$D = \{\underline{p} \mid \underline{p} \in \mathbb{R}^{n \times 1}\} \quad (11)$$

主要分类步骤如下:

a) 被压缩的基元字典学习阶段,在压缩域 χ 内直接进行普通的被压缩基元字典 W 学习,对于每个纹理类来说,通过 k -均值来进行 K 基元的学习。此时,通过连接每个纹理类的 K 个基元组成普通的压缩字典 W ,且字典的尺寸大小为 $W = CK$ 。

b) 基元直方图学习阶段,对每个训练样本 $I_{c,s}$ 进行压缩基元直方图 $h_{c,s}$ 学习,并通过式 9 中每个提取的图像块用 W 中最近的基元进行标记。每个纹理类由模型集合表示为 $H_c =$

$\{h_{c,s}\}_{s \in \mathcal{S}}$

c) 分类阶段,由步骤 b) 计算出所给图像的直方图 h_{new} , 使用最近邻分类器对 h_{new} 进行分类,并用 χ^2 统计对两直方图之间的距离进行测量:

$$\chi^2(h_1, h_2) = \frac{1}{2} \sum_{k=1}^{CK} \frac{[h_1(k) - h_2(k)]^2}{h_1(k) + h_2(k)} \quad (12)$$

5 实验分析

5.1 对比方法

Patch 方法^[13]:该方法基于 $\sqrt{n} \times \sqrt{n}$ 尺寸的局部块,且训练和测试都在图像块域内进行。

Patch-MRF^[13]:使用二维直方图表示纹理图像,一维表示量化为二进制的块中心像素,另一维表示图像块中心像素除外的学习基元。文献[14]中中心像素的二进制数最大为 200,基元字典的尺寸为 $61 \times 40 = 2440$,则最终导致极高的维数 $2440 \times 200 = 48800$ 。

MR8^[13]:如图 5 所示,38 个滤波器中的 8 个滤波器进行响应,使用复杂各向异性高斯滤波器方法来计算 MR8 响应。




图 5 获得 MR8 滤波器响应的原始滤波器组

(其中杆干过滤器为 3 尺度和 6 方向,然后加上高斯滤波器和 LoG 滤波器)

LBP^[14]:LBP 基元字典具有旋转不变性和一致性,在不同尺度被定义为 $\text{LBP}_{8,1}^{\text{riu2}}$ 、 $\text{LBP}_{8,1+16,2'}^{\text{riu2}}$ 、 $\text{LBP}_{8,1+16,2+24,3'}^{\text{riu2}}$ 、 $\text{LBP}_{8,1+16,2+24,3+24,4'}^{\text{riu2}}$ 。文献[15]中最新提出 $\text{LBP}_{8,1+16,2+24,3+24,4+24,5'}^{\text{riu2}}$ 。在本文中,将这 5 个尺度的 LBP 基元分别简单定义为 1-尺度, ..., 5-尺度。

5.2 实验设置

5.2.1 数据库

实验在 CURET 纹理数据库(图 6)的基础上进行纹理分类测试。数据库包括 $N=200 \times 200$ 像素的 61 类纹理图像。每个纹理类给出各种不同观测与照度的相同材质图像,总共有 $61 \times 92 = 5612$ 张,它的主要缺点是同样的纹理数不多,一般的分类方法很难研究出其类内变化,然而本文分类方法可以轻松找出相同功率谱下的内类变化,所以很适合用于本文的分类验证。本文将数据库随机分成训练集和测试集两个集合,其划分包括两种情况^[16]:

a) T46:每类 92 张图片,训练集和测试集分别均匀地设置为 2806 (61×46) 训练样本和 2806 (61×46) 测试样本的模式。

b) T23:每类 92 张图片,不均匀划分训练集和测试集,其中训练集设置为 1403 (61×23),测试集设置为 4209 (61×69) 的模式。

设置两种模式能更好地研究不同算子的性质。一般情况下在有综合训练样本时设置 T46,在只有部分训练样本集时设置 T23。




图 6 CURET 纹理

5.2.2 正则化

根据提取的 RP 向量,本文使用 Weber's law 标准化:

韦伯定律(Weber's law)^[13]:

$$x \leftarrow x \left[\frac{\log(1 + \frac{\|x\|_2}{0.03})}{\|x\|_2} \right] \quad (13)$$

5.2.3 RP 参数选择

RP 分类器有三个参数:a) RP 维数 m ($m \leq n$);b) 每类的基元 K 数目;c) 图像块尺寸 n 。

m 值在分类时的影响如图 7 所示。从结果可以看出,分类精度在初期增加很快,然后在很大的一个范围基本上保持水平,最后在 m 值很大时有所下降。在 m 值很大时精度降低说明了高维聚类会增加分类难度,所以本文方法反对 Patch 方法中的高维分类。图 8 显示了每类压缩基元 K 值相对于分类精度的影响,可以看出, K 值应该充分大以满足表示空间的分块具有意义。图 9 为图像块尺寸 ($\sqrt{n} \times \sqrt{n}$) 以及映射维数对分类精度的影响。可以很清楚地看出,在尺寸很小的时候,其准确率随维数的增加快速增加,并随尺寸的增加变化越来越缓慢。




图 7 分类精度与 CS 维数之间的函数关系
($K=12$, 块尺寸为 10×10)




图 8 每类压缩基元 K 数目与分类精度之间关系
(尺寸为 13×13 , 维数大小 m 为 40)

5.3 结果对比

将本文方法与前面提到的四种方法使用 CURET 纹理进行试验对比。为了使对比更有意义,本文使用与参考文献同样的实验参数设置。

Varma 与 Zisserman 的研究中使用六个滤波器组对基于基元的纹理分类,纹理数据库为 CURET 纹理。得出的结论为具有旋转不变性、多尺度、最大响应的 MR8 滤波器产生了优于其他方法的结果。在文献[13]中采用的 Patch 方法甚至优于 MR8 滤波器组。

对于计算代价来说,结果如表1所示。其中, T 为K-均值迭代数目(一般 $T \geq 50$); G 为中心像素的量化二进制数; S_1 与 S_2 分别为每类的训练与测试样本数目; N_l 为每个样本的像素数; N_0 为学习的基元每类的像素数目;对于 CURET 纹理来说, $C=61, S=92, S_1=S_2=46, N_l=200 \times 200, N_0=S_l N_l, G=200$ 。

表1 各算法的计算复杂度对比

方 法	特征提取	K-均值聚类	直方图	分类(1NN)
RP(本文)	$C \cdot S \cdot nmN_1$	$C \cdot T \cdot O(mKN_0)$	$C \cdot S \cdot mCKN_1$	$2(C \cdot S_1) \cdot (C \cdot S_2) \cdot CK$
Patch	-	$C \cdot T \cdot O(nKN_0)$	$C \cdot S \cdot nCKN_1$	$2(C \cdot S_1) \cdot (C \cdot S_2) \cdot CK$
Patch-MRF	-	$C \cdot T \cdot O((n-1)KN_0)$	$(n-1)CKN_1$	$2(C \cdot S_1) \cdot (C \cdot S_2) \cdot GCK$

从表1可以看出,Patch 和 RP 方法之间,很明显相对复杂度由相对维数 m 和 n 分别确定,而就 Patch 模式来说,分类计算复杂度主要受因子 G 的影响, G 为中心像素的量化二进制数。

由图10可以看出,本文提出的方法优于所有方法,清楚地说明 RP 矩阵保留了局部图像块中的凸显信息,并且能够很好地在压缩块空间进行分类。相比较 Patch 方法来说,本文方法无论是在分类精度还是在特征空间维数上都更优,并且在存储空间和计算复杂度上也有一定的改进。




图9 尺寸 $(\sqrt{n} \times \sqrt{n})$ 图像块以及映射维数与分类精度之间的关系




图10 各种方法对 CURET 纹理的分类结果

4 结束语

本文提出一种将纹理表示为局部纹理块的随机测量值的一压缩集合,即原始局部图像块中大约原始图像块三分之一的维数空间保留了凸显信息,其他增加的特征数对分类性能只产生很少量的改进,并在纹理分类精度以及计算复杂度上优于其他几种经典的纹理分类方法。本文提出的 RP 方法与以前的纹理分类有以下显著的区别:

a) 本文方法证明了随机特征用来纹理分类的有效性并且证明了在压缩图像块域进行纹理分类的有效性。

b) 本文提出方法能够达到 Patch 方法的高精分类性能且能够在其低维特征空间预选滤波器组。

c) 随机特征可以无纹理图像的先验信息,免除了对信号在某基(过完备)中的稀疏性假设,而传统的纹理特征提取方法需要对所研究的纹理进行很强的假设。

本文的实验分析证明了本文方法的有效性。

参考文献:

- [1] 钟桦,杨晓鸣,焦李成. 基于多分辨共生矩阵的纹理图像分类[J]. 计算机研究与发展, 2011, 48(11):59-68.
- [2] 陈洋,王润生. 结合 Gabor 滤波器和 ICA 技术的纹理分类方法[J]. 电子学报, 2007, 35(2):128-132.
- [3] Ojala T, Pietikainen M, Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. IEEE Trans Pattern Analysis and Machine Intelligence, 2002, 24(7):971-987.
- [4] Zhang J, Marszalek M, Lazebnik S, et al. Local features and kernels for classification of texture and object categories: a comprehensive study[J]. International Journal of Computer Vision, 2007, 73(2):213-238.
- [5] Dasgupta S, Gupta A. An elementary proof of a theorem of Johnson and Lindenstrauss [J]. Random Structures and Algorithms, 2003, 22(1):60-65.
- [6] Baraniuk R G, Davenport M, DeVore R A, et al. A simple proof of the restricted isometry property for random matrices[J]. Constructive Approximation, 2008, 28(3):253-263.
- [7] Widynski N, Mignotte M. A multiscale particle filter frame-work for contour detection[J]. IEEE Trans on PatternAnalysis and Machine Intelligence, 2014, 36(10):1922-1935.
- [8] Huang Zengxi, Liu Yiguang, Li Xuwei, et al. An adaptive bimodal recognition framework using sparse coding for face and ear[J]. Pattern Recognition Letters, 2014, 53:69-76.
- [9] Wright J, Yang A, Ganesh A, et al. Robust face recognition via sparse representation [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(2):210-217.
- [10] Levina E. Statistical issues in texture analysis[D]. Berkeley: University of California, 2002.
- [11] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290:2323-2326.
- [12] Cande's E J, Tao T. Decoding by linear programming [J]. IEEE Trans on Information Theory, 2005, 51(12):4203-4215.
- [13] Varma M, Zisserman A. A statistical approach to texture classification from single images[J]. International Journal of Computer Vision, 2005, 62(1):61-81.
- [14] Liao S, Law M W K, Chung A C S. Dominant local binary patterns for texture classification[J]. IEEE Trans on Image Processing, 2009, 18(5):1107-1118.
- [15] Pietikainen M, Nurmela T, Maenpaa T, et al. View-based recognition of real-world textures[J]. Pattern Recognition, 2004, 37(2):313-323.
- [16] Kokare M, Biswas P K, Chatterji B N. Rotation-invariant texture image retrieval using rotated complex wavelet filters[J]. IEEE Trans on Systems, Man and Cybernetics: Part B, 2006, 36(6):1273-1282.