

文章编号:1001-9081(2010)11-2983-03

低对比度下水印图像缺陷检测

李全文, 阮 波, 徐可佳, 于 勇, 肖劲飞

(中国科学院 成都计算机应用研究所, 成都 610041)

(lqw163love@163.com)

摘要:在主成分分析(PCA)及核主成分分析(KPCA)进行特征提取基本原理的基础上,提出了一种改进的提取非线性的图像特征来重建图像方法,应用于嵌入式防伪水印图案缺陷的检测。该方法使得图像协方差矩阵维数大幅下降,且有效地保留了嵌入式防伪水印图案的信息,通过比较检测出图像的缺陷。实验结果表明,该方法对输入数据实现了有效的降维,缩短了计算时间,提高了检测效果和精确度。KPCA 算法相比原有的 PCA 算法具有更高的性能指标,适用范围更广。

关键词:核主成分分析;水印图案;缺陷检测

中图分类号: TP391.41 **文献标志码:**A

Defect detection of low contrast watermark image

LI Quan-wen, RUAN Bo, XU Ke-jia, YU Yong, XIAO Jin-fei

(Chengdu Institute of Computer Application, Chinese Academy of Sciences, Chengdu Sichuan 610041, China)

Abstract: Based on the fundamental principles of feature extraction of PCA and KPCA, an improved method to extract features of non-linear image so as to rebuild image was proposed for detecting embedded watermark image defects. This method decreased greatly the dimension of Core Matrix and kept the information of embedded watermark image effectively. Thus the defects of images could be found out through comparison. The experimental results show that this method enables input data to reduce dimension effectively, shortens computation time and improves detection effect and accuracy. KPCA has a higher performance index and wider range of application than PCA.

Key words: Kernel Principal Component Analysis (KPCA); watermark image; defect detecting

0 引言

随着信息技术和计算机视觉技术的飞速发展,利用机器视觉代替人眼对图像信息质量的检测大大提高生产效率。为提高生产质量和生产工艺,本文提出一种基于主成分分析(Principal Component Analysis, PCA)非线性的方法来检测产品的嵌入式防伪水印图案是否存在缺陷。

传统的印刷品缺陷检测主要有以下几种质量检测方法:
1)主观目测法。即通过肉眼直接将印刷品和标准样张进行对比,同时借用其他辅助设备来寻找差异,做出定性评估。虽然简单灵活,但是由于观测人员的经验和生理、心理等主观因素的影响,该方法的准确性和可靠性不会太高,且该方法对图像的缺陷不能进行定量研究描述。2)差影法^[1]。即图像的相减运算。差影图像提供了图像间的差异信息,对于缺陷目标识别和检测非常适合,但它必须使两相减图像对应点位于空间中同一目标点上,否则无法正确反映缺陷,更有可能产生误检。3)模板匹配法^[1]。是目前工业检测中使用最为广泛的一种,将待检测的图像用某种模型来描述,模型中包含相应的参数,将这些参数取值范围作为图像的判别标准。如果待检测图像区域的模型参数在正常范围内,则认为不存在缺陷。4)兴趣点特征匹配法^[2]。计算两幅图像特征点对的变换矩阵来实现缺陷图像的检测,该方法能够准确地提取图像间的对应特征点,降低误匹配的概率,相应地提高了缺陷检测准确

性。但是待检测水印图案个体大小形状存在允许差异、成像对比度弱、干扰噪声大、纸张纹理干涉等。因此这些传统的检测方法常出现误报、漏检,达不到实际应用的要求。钞纸质量检测要求尽可能做到 100%,传统的检测方法一般只能做到 70% 左右的正确检测。

目前在造纸工业中产品质量检测,主要依靠人工视觉检测方法。本文采用机器视觉代替人工视觉检测方法主要是模拟人工检测方法,使用透视图像对比进行质量检测。

核主成分分析 (Kernel Principal Component Analysis, KPCA) 广泛应用于各行各业^[3-4]。本文基于 PCA 算法^[5] 在图像缺陷检测行业构造一种 KPCA 算法——提取非线性特征图像的特征来检测嵌入式弱对比度水印图像的缺陷。其基本思想是:将图像作为数据通过一种核运算映射到另一个空间,在得到的空间中对图像进行 PCA 处理,提取主要成分,再将待检测的图像映射到此空间与主成分进行运算匹配,得到主要成分重建图像,将重建图像与待检测图像进行比较检测缺陷。

1 PCA 算法

PCA 是一种常用的基于变量协方差矩阵对信息进行处理、压缩和抽提的有效方法,是一种标准的信息处理工具。在现行的图像处理工程中,经常把 PCA 用于图像预处理进行降维去噪^[6-7]。如将 N 幅样本图像组建成一个随机矩阵 $X =$

收稿日期:2010-05-13;修回日期:2010-07-19。

作者简介:李全文(1984-),男,广西桂林人,硕士研究生,主要研究方向:图像处理、机器视觉; 阮波(1971-),男,重庆人,副研究员,主要研究方向:机器视觉、工业自动化; 徐可佳(1979-),男,浙江江山人,博士研究生,主要研究方向:图像处理、机器视觉; 于勇(1973-),男,四川成都人,工程师,主要研究方向:模式识别、机器视觉; 肖劲飞(1982-),男,湖南邵阳人,硕士研究生,主要研究方向:图像处理、工业视觉。

$[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]^T$, 其均值 $\bar{\mathbf{X}} = E[\mathbf{X}]$, 其协方差矩阵 $\mathbf{C}_x = E[(\mathbf{X} - \bar{\mathbf{X}})(\mathbf{X} - \bar{\mathbf{X}})^T]$ 。求协方差矩阵的特征值 λ_k 与特征向量 \mathbf{V}_k :

$$\mathbf{C}_x \mathbf{V}_k = \lambda_k \mathbf{V}_k \quad (1)$$

将所有的特征向量按照对应的特征值由大到小排列组建特征矩阵 \mathbf{V}_s , 然后再对特征矩阵进行正交化取前 M 维得到一个投影空间 \mathbf{R}^M 用矩阵 \mathbf{W} 表示。

将检测图像投影到空间 \mathbf{R}^M 得到图像的主分量, 再用主分量重建图像, 如式(2)。将测试图像与重建图像进行比较即可以检测出图像缺陷。

$$\mathbf{Y} = \mathbf{W} \mathbf{W}^T \mathbf{X} \quad (2)$$

2 Kernel PCA 算法

2.1 KPCA 特征提取基本原理

由线性 PCA 推广到非线性情况 KPCA。

设有非线性变换 $\Phi: \mathbf{R}^M \rightarrow F, \mathbf{x} \rightarrow \Phi(\mathbf{x})$; 将原空间中的数据投影到特征空间 F , 则原空间中的协方差矩阵 \mathbf{C}_x 在特征空间中具体如下形式:

$$\bar{\mathbf{C}} = \frac{1}{n} \sum_{i=1}^n \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_i)^T \quad (3)$$

非线性主成分分析可看做在 F 空间中对 $\bar{\mathbf{C}}$ 进行主成分分析, 显然 $\bar{\mathbf{C}}$ 的所有特征值 $\lambda \neq 0$ 和特征向量 $V \in F \setminus \{0\}$ 满足等式 $\bar{\mathbf{C}} V = \lambda V$, 且其所有解均在 $\Phi(\mathbf{x}_i), i = 1, \dots, n$ 张成的子空间内, 因此:

$$\lambda (\Phi(\mathbf{x}_k) \cdot V) = (\Phi(\mathbf{x}_k) \cdot \bar{\mathbf{C}} V) \quad (4)$$

其中 $k = 1, 2, \dots, n$ 。假设存在系数 $\alpha_1, \dots, \alpha_n$, 使:

$$V = \sum_{i=1}^n \alpha_i \Phi(\mathbf{x}_i) \quad (5)$$

由式(3) ~ (5) 得:

$$\begin{aligned} \lambda \sum_{i=1}^n \alpha_i (\Phi(\mathbf{x}_k) \cdot \Phi(\mathbf{x}_i)) &= \\ \frac{1}{n} \sum_{i=1}^n \alpha_i \left[\Phi(\mathbf{x}_k) \cdot \sum_{j=1}^n \Phi(\mathbf{x}_j) (\Phi(\mathbf{x}_j) \cdot \Phi(\mathbf{x}_i)) \right] \end{aligned} \quad (6)$$

其中 $k = 1, 2, \dots, n$ 。

定义 $n \times n$ 阶矩阵 A :

$$A_{ij} := \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j) \quad (7)$$

由式(6) ~ (7) 化简得:

$$n \lambda \alpha = A \alpha \quad (8)$$

其中: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ 代表 A 的特征值, $\alpha_1, \dots, \alpha_n$ 为相应的特征向量。

对于主成分提取, 只需计算测试图像在特征空间 F 中的非零特征值对应的特征向量上的投影, 令它为 β_k , 即:

$$\beta_k = (V^k \cdot \Phi(\mathbf{x})) = \sum_{i=1}^n \alpha_i^k (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x})) \quad (9)$$

可以看出, 若直接求解主成分, 不仅需要知道非线性映射 Φ 的确切形式, 而且计算量将随着特征空间维数的增加呈指数增长, 使求解难度加大甚至不能求解。因为式(9)涉及内积运算, 所以根据 Hilbert-Schmidt 原理, 可找到满足 Mercer 条件^[8] 的核函数 $K(\mathbf{x}_i, \mathbf{x})$, 使 $K(\mathbf{x}_i, \mathbf{x}) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x})$, 那么, 式(9) 可写成:

$$\beta_k = \sum_{i=1}^n \alpha_i^k K(\mathbf{x}_i, \mathbf{x}) \quad (10)$$

其中 α 为 K 的特征向量。式(10) 即为基于 KPCA 的特征提取

器^[4]。

2.2 基于特征空间的图像重建

特征提取器的输出 β_k 实质上是 $\Phi(\mathbf{x})$ 在特征空间 F 中的主成分上的投影。为了由 β_k 重建 $\Phi(\mathbf{x})$, 在此定义一投影操作:

$$F^m \Phi(\mathbf{x}) = \sum_{k=1}^m \beta_k V^k \quad (11)$$

其中: m 为 F 的前 m 个主成分, 对应的特征值由大到小排列。式(11)有如下性质: 1) 当 m 足够大包含所有非零特征值对应的特征向量时, 将式(10)代入式(11)可得 $F^m \Phi(\mathbf{x}_i) = \Phi(\mathbf{x}_i)$ 。2) 当 m 只是截取前面一小部分主分量时, 式(11)仍能满足能使重建误差 $\sum_{i=1}^n \| F^m \Phi(\mathbf{x}_i) - \Phi(\mathbf{x}_i) \|^2$ 最小。

因为要检测提取测试图像的缺陷, 所以感兴趣的是对测试图像 \mathbf{x} 的重建, 而不是特征空间 F 。因此希望找到一个向量 $\mathbf{z} \in \mathbf{R}^M$, 作为测试图像 \mathbf{x} 的近似, 并使之在条件

$$\rho(\mathbf{z}) = \| \Phi(\mathbf{z}) - F^m \Phi(\mathbf{x}) \|^2$$

为最小下, 满足 $\Phi(\mathbf{z}) \approx F^m \Phi(\mathbf{x})$, 即 $\Phi(\mathbf{z}) \approx \Phi(\mathbf{x})$ 。将 $\rho(\mathbf{z})$ 展开, 并用 Ω 取代展开后与 \mathbf{z} 向量无关的项, 即可得:

$$\rho(\mathbf{z}) = \| \Phi(\mathbf{z}) \|^2 - 2(\Phi(\mathbf{z}) \cdot F^m \Phi(\mathbf{x})) + \Omega \quad (12)$$

结合 Hilbert-Schmidt 原理, 并将式(5)和式(10)代入式(12), 可得

$$\rho(\mathbf{z}) = k(\mathbf{z}, \mathbf{z}) - 2 \sum_{k=1}^m \beta_k \sum_{i=1}^n \alpha_i^k k(\mathbf{z}, \mathbf{x}_i) + \Omega \quad (13)$$

要重建原测试图像 \mathbf{x} , 就是要寻找使式(13)最小的 \mathbf{z} 。为此, 应用标准的梯度下降法求得式(13)的最佳值 \mathbf{z} , 求解过程见参考文献[9]。最后可得:

$$\mathbf{z} = \frac{\sum_{i=1}^n \gamma_i k'(\|\mathbf{z} - \mathbf{x}_i\|^2) \mathbf{x}_i}{\sum_{i=1}^n \gamma_i k'(\|\mathbf{z} - \mathbf{x}_i\|^2)} \quad (14)$$

2.3 核函数选择与使用

通过以上讨论不难看出, 重建测试图像的好坏关键在于核函数具体形式的选择。满足 Mercer 条件的核函数^[10]及其应用。实验结果表明, 多项式核函数、高斯径向基核函数和两层前馈神经网络核函数明显优越其他形式。本文将对多项式核函数和高斯径向基核函数进行比较。

采用高斯径向基函数作为核函数, 它的具体形式为:

$$k(\mathbf{x}, \mathbf{y}) = \exp(-\|\mathbf{x} - \mathbf{y}\|^2/c)$$

选择不同的参数 c 也将导致检测效果的不同, 关于参数的选择可参考 Cross-validation 方法。式(14)在高斯核函数下重建形式为:

$$\mathbf{z} = \frac{\sum_{i=1}^n \gamma_i \exp\left(-\frac{\|\mathbf{z} - \mathbf{x}_i\|^2}{c}\right) \mathbf{x}_i}{\sum_{i=1}^n \gamma_i \exp\left(-\frac{\|\mathbf{z} - \mathbf{x}_i\|^2}{c}\right)} \quad (15)$$

采用多项式作为核函数时, 它的具体形式为 $k(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y})^d$ 。选择不同的参数 d 也将导致检测效果的不同, 具体取值依实验情况而定。式(14)在多项式核函数下重建形式为:

$$\mathbf{z} = \frac{\sum_{i=1}^n \gamma_i \|\mathbf{z} - \mathbf{x}_i\|^{2d-1} \mathbf{x}_i}{\sum_{i=1}^n \gamma_i \|\mathbf{z} - \mathbf{x}_i\|^{2d-1}} \quad (16)$$

假设 $F^m \Phi(\mathbf{x}) \neq 0$, 则有等式分母:

$$(\Phi(\mathbf{x}) \cdot F^m \Phi(\mathbf{x})) = (F^m \Phi(\mathbf{x}) \cdot F^m \Phi(\mathbf{x})) > 0$$

因为核函数是平滑的,可以推断式(14)分母不为零时式(13)存在一个邻域向极值点逼近。再者,知道式(14)求得任何图像向量将都是样本数据 \mathbf{x}_i 的协方差核矩阵主成分的一个线性组合。因此,可以将测试图像通过映射核函数投影到由样本构建的特征空间上,即得到一个特征空间向量的线性组合系数 γ_i ,由式(15)和(16)求得最佳重建图像。

3 KPCA 缺陷检测算法流程

通过上面的介绍,知道 KPCA 算法是首先使用标准图像采集样本数据,将图像的样本映射到另一个特定空间使原有的图像呈现线性特征然后再进行 PCA 处理提取有效的图像特征组建特征空间,然后将测试图像在特征空间上进行投影获得测试图像的主成分,利用主成分进行返回投影重建测试图像,对比处理前后的图像即可获得缺陷图像。

对于给定的水印图案,KPCA 检测算法的基本步骤如下:

第 1 步 使用工业相机采集标准的样本图像,将图像向量化并获得样本矩阵 X 。

第 2 步 令 $Y = X$,对样本矩阵进行高斯核变换得到变换矩阵,并求得变换矩阵的特征值 λ 和特征向量 α 。

第 3 步 对特征值排序得到对应特征向量,然后正交化,取前 M 个特征向量组成特征空间矩阵 F 。

第 4 步 取测试图像经高斯核映射 $\Phi(\mathbf{x})$,然后在特征空间 F 中投影得到投影系数 β_k 。

第 5 步 根据投影系数 β_k ,利用式(11)、(12)求解重构测试图像的误差。

第 6 步 要使重构测试图像误差最小,即求解式(3)的极值点,因此可以分别通过式(15)~(16)两种不同的方式求得重构图像。

第 7 步 将测试图像与重构测试图像相减即可得到缺陷图像。

KPCA 检测算法的流程如图 1 所示。

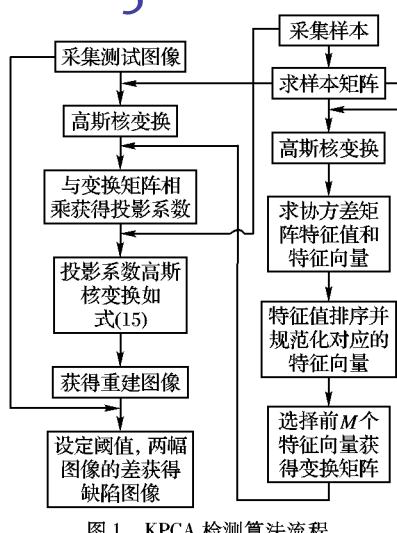


图 1 KPCA 检测算法流程

4 测试实验结果

当今工业印刷行业很多都用到了嵌入式防伪水印图案,比如票据、钞纸等,本文用票据、钞纸上的水印图案做实验进行检测。

本次实验选用 20 个样本水印图像进行学习获得样本矩阵,选择前 5 个最大的主分量组建投影空间。测试图像如图 2(a)、(b),将测试图像在投影空间中投影获得投影向量。

获得投影向量后,选择不同核函数重建测试图像。若使用多项式核函数如式(16)重建测试图像,得到重建图像如图 2(c),然后将图(a)与图(c)进行比较,显示差异大于 14 个灰度级的像素点如图(e);若使用高斯径向基核函数如式(15)重建测试图像,得到重建图像如图(d),然后将图(b)与图(d)进行比较,显示差异大于 14 个灰度级的像素点如图(f)。

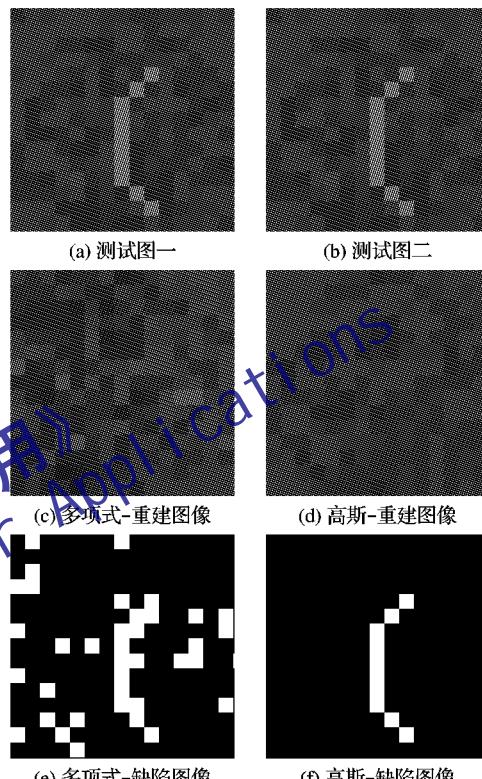


图 2 实验图像

比较图 2(e)、(f)可知:多项式核函数缺陷检测存在很大的误报,而高斯核函数检测在相同的条件下能够准确地反映缺陷图像,因此高斯径向基函数具有更好的非线性性能、更好的检测效果和更佳的推广能力。

此外,KPCA 检测适用于非线性特征图像的提取与检测,能更好地检测低对比度图像。KPCA 检测最大的改进是将 PCA 检测图像向量的相关性改进成图像像素点的相关性,使运算的复杂性大幅度下降,并由样本数来决定,而不是图像本身的大小。解决了 PCA 算法不适用处理较大的图像难题,避免将大图像分割成小块进行处理造成的复杂性。KPCA 算法大幅度缩短了运算时间。表 1 给出了两种算法测试时间的比较。

表 1 PCA 与 KPCA 测试时间表

图像大小	测试时间/ms	
	PCA	KPCA
4 × 4	65	63.2
16 × 16	72	80.0
32 × 32	1 200	85.6
64 × 64	14 800	118.9

(下转第 3031 页)

图 8 是采用 3 种算法对雾霾图像 Toys 图的复原结果比较。可以看出,图(b)、(d) 复原结果几乎相同,都取得了很好的雾霾去除效果;图(c)相对图(b)、(d) 雾霾去除得不够干净,相比图(a)只去掉了很少的雾霾,造成这种差异是因为图(c)采用的整体大气光不准确。

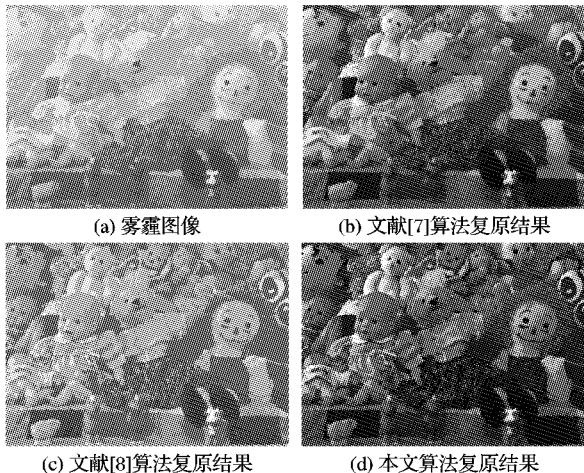


图 8 Toys 图

表 1 是 3 种算法所用时间比较,由表可以看出,文献[8]算法所花时间最少,分别是 10.829 s 和 5.844 s;文献[7]算法所花时间最多,分别为 459.922 s 和 240.953 s;本文算法所花时间为 31.125 s 和 14.563 s。虽然没有文献[8]算法速度快,但是复原效果优于文献[8];相对于文献[7],本文算法速度已大大提高。

表 1 算法所用时间比较

所用算法	算法所用时间/s	
	Stadium 图(1000×327)	Toys 图(500×360)
文献[7]算法	459.922	240.953
文献[8]算法	10.829	5.844
本文算法	31.125	14.563

由图 7~8 和表 1 可看出:本文算法复原效果相对较好算

(上接第 2985 页)

从表 1 可知,KPCA 算法在处理小图时不能明显展现处理速度,但随着图像的增大更能突出 KPCA 算法在运算时间上的优越性。

5 结语

水印缺陷检测是生产线上一种重要的反馈信息,也是提高防伪质量的重要手段,但目前的检测方法还不够完善。本文提出的 KPCA 检测方法,有非常好的检测效果,在调整参数的条件下,可以达到 100% 的缺陷检测效果。在工程现场,由于灯光、环境以及纸张本身的变化,需要实时更新样本,采集新的样本,建立新的样本参数达到更好的检测效果。实际结果表明,KPCA 检测算法应用到水印图案缺陷检测是可行的。

参考文献:

- [1] 陈廉清,崔治,王龙山. 基于差影和模板匹配的微小轴承表面缺陷检测[J]. 中国机械工程, 2006, 17(10): 1019~1022.
- [2] 陈万军, 陈亚军, 何怡. 基于兴趣点特征匹配的印刷图像缺陷检测[J]. 包装工程, 2007, 28(03): 22~24.

法速度相对较快,可满足实际应用需求。

6 结语

实验结果表明,基于 DCP 先验知识和大散射光设计的快速去除单幅图像雾霾的算法是可行的,该算法能得到清晰的复原结果,且速度较快,能用于彩色图像和灰度图像的雾霾去除,算法简单,易实现,基本能满足实际的需求。

参考文献:

- [1] NAYAR S K, NARASIMHAN S G. Vision in bad weather [C]// Proceedings of International Conference on Computer Vision 1999. Kerkyra: IEEE Computer Vision, 1999(2): 820~827.
- [2] SCHECHNER Y Y, NARASIMHAN S G, NATAR S K. Instant dehazing of images using polarization [C]// Proceedings of Computer Society Conference on Computer Vision and Pattern Recognition 2001. Hawaii: IEEE Computer Society, 2001(1): I-325~I-332.
- [3] NARASIMHAN S G, NAYAR S K. Interactive (de)weathering of an image using physical models [C]// ICCV Workshop on Color and Photometric Methods in Computer Vision (CPMCV) 2003. Nice: IEEE Computer Vision, 2003.
- [4] OAKLEY J P, BU HONG. Correction of simple contrast loss in color images [J]. Image Processing, 2007, 16(2): 511~522.
- [5] TAN R T. Visibility in bad weather from a single image [C]// Proceedings of Computer Society Conference on Computer Vision and Pattern Recognition 2008. Alaska: IEEE Computer Society, 2008: 1~8.
- [6] FATTAL R. Single image dehazing [C]// SIGGRAPH 2008. New York: ACM Press, 2008: 1~9.
- [7] HE KAIMING, SUN JIAN, TANG XIAOOU. Single image haze removal using dark channel prior [C]// Proceedings of Computer Society Conference on Computer Vision and Pattern Recognition 2009. Miami: IEEE Computer Society, 2009: 1956~1963.
- [8] TAREL J-P, NICOLAS H. Fast visibility restoration from a single color or gray level image [C]// Proceedings of International Conference on Computer Vision 2009. Kyoto: IEEE Computer Vision, 2009: 2201~2208.

- [3] 黄国宏,邵惠鹤. 核主元分析及其在人脸识别中的应用[J]. 计算机工程, 2004, 13(5): 13~14.
- [4] 陆波,毕笃彦,谭军. 一种基于 KPCA 的图像去噪方法[J]. 红外技术, 2004, 26(6): 58~60.
- [5] 王松,夏绍伟. 一种鲁棒主成分分析(PCA)算法[J]. 系统工程理论与实践, 1998, 1(1): 9~13.
- [6] 孙颖楷,王光学. 基于 PCA 预处理的图像特征属性约简[J]. 中国图象图形学报, 2007, 12(10): 1897~1900.
- [7] DIAMANTARAS K I, KUNG S Y. Principal component neural networks [M]. New York: Wiley, 1996.
- [8] BURGES C. A tutorial on support vector machines for pattern recognition [J]. Data Mining and Knowledge Discovery, 1998, 2(2): 1~47.
- [9] SCHOLKOPF B, MIKA S, BURGES C J C. Input space vs. feature space in kernel-based methods [J]. IEEE Transactions on Neural Networks, 1999, 3(5): 127~145.
- [10] SAITO S. Theory of reproducing kernels and its applications [M]. Harlow, England: Longman Scientific & Technical, 1988.