

基于多尺度自卷积归一化直方图的 仿射不变量模式识别

黄 波¹,赵继印¹,郑蕊蕊²,李 敏²

(1. 吉林大学通信工程学院, 吉林长春 130025; 2. 大连民族学院机电信息工程学院, 辽宁大连 116600)

摘 要: 仿射不变量特征提取方法已成为计算机视觉研究的重点课题之一. 本文提出一种归一化直方图算法, 该算法基于多尺度自卷积变换中密度函数的概念, 研究归一化密度函数的方法, 构建了从目标图像中提取直方图仿射不变量特征提取算法, 实现了基于多尺度自卷积归一化直方图的仿射不变量模式识别. 仿真实验表明, 本算法对一定范围内的噪声, 局部遮挡, 照度及视角变化具有良好的适应性, 特别是在多种环境下, 其识别率优于多尺度自卷积和基于多尺度自卷积的其它直方图算法.

关键词: 目标识别; 仿射不变特征; 归一化直方图; 多尺度自卷积

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2011) 01-0064-06

Affine Invariant Pattern Recognition Based on Multi-Scale Autoconvolution Normalized Histograms

HUANG Bo¹, ZHAO Ji-yin¹, ZHENG Rui-rui², LI Min²

(1. College of Communication Engineering, Jilin University, Changchun, Jilin 130025, China;

2. College of Electormechanical & Information Engineering, Dalian Nationalities University, Dalian, Liaoning 116600, China)

Abstract: Affine invariant feature extraction methods have been one of the key issues of computer vision research. This paper proposes a normalized histogram algorithm based on the density function of multi-scale autoconvolution transform and researches the normalization method of the density function, and constructs a method to extract the histogram affine invariant feature, and implements affine invariant pattern recognition based on multi-scale autoconvolution normalized histograms. Simulation results show that this algorithm has good adaptability for a certain range of noise, partial occlusion, illumination and view angle variance. The recognition rate of this algorithm is superior to multi-scale autoconvolution and other multi-scale autoconvolution based histogram algorithms, especially under a variety of environments.

Key words: object recognition; affine invariant feature; normalized histogram; multi-scale autoconvolution (MSA)

1 引言

被测目标在图像传感器上所成的图像满足透视变换关系, 当目标尺寸远小于目标与传感器的距离时, 透视变换可以近似为仿射变换模型. 仿射变换较好的描述了目标在不同视点、距离下所成图像间的关系. 在仿射变换下保持不变的性质或数量称之为仿射不变特征, 它在稳健性、区分度和适用范围方面具有极大的优势, 已广泛用于图像检索、图像配准和目标识别, 对仿射不变特征的提取主要是提取识别目标的局部或全局特征^[1].

局部仿射不变特征利用目标的局部信息, 对局部遮挡、背景斑纹和全局几何变形等具有稳定性, 用直方图

描述局部特征具有计算简单, 对旋转、平移和仿射等变换具有不变性的优点, 特别是待描述区域经适当处理后, 直方图特征具有很强的区分性和稳定性. Lowe 提出了 SIFT 方法, 使用梯度和位置方向的 3D 直方图描述区域特征, 大量实验表明, SIFT 对旋转和尺度变换, 一定范围内的照度变化、透视变换、噪声干扰均有良好的适应性^[2]. 在 SIFT 基础上, Yan 提出了 PCA-SIFT, 提高了特征匹配率和运算速度^[3]; Michael 提出一种 SIFT 近似计算方法, 虽然在特征性能方面有所下降, 但计算速度提高了近 8 倍^[4]. Mikolajczyk 把 SIFT 在直角坐标系下对局部区域的划分改为在极坐标系下, 同时采用 PCA 降维, 提出了 GLOH 描述符, 提高了稳定性和区分性^[5]. 近些年

来也出现了角射线分割直方图和局部核直方图^[6-8]等方法。

全局仿射不变特征利用目标的整体信息,无需局部仿射不变特征的点检测和特征区域检测^[9]。矩不变量^[10-13]是提取全局不变特征的常用方法,但高阶矩对噪声敏感,因此只能使用一些低阶矩,这就限制其对海量数据库中目标分类的能力。Esa Rathu 等人提出多尺度理论框架构造目标图像一系列仿射协变形式,然后分别从这些形式中提取不变量特征,特征个数不受限制,为全局仿射不变性特征提取开拓了新思路,作者相继提出了多尺度自卷积(MSA)和多尺度自卷积直方图(MSA hist)等方法,这些方法不需要提取图像感兴趣点或边缘的条件下直接用于图像配准和目标识别,得到了较高的配准精度和识别率^[14-20]。MSA hist 比 MSA 提取的信息更丰富,它包含传统直方图所没有的灰度空间分布信息,单参数最多可构造 256 个特征,由于构造仿射协变形式计算量远高于从其中提取不变量特征的计算量,所以直方图方法构造特征的效率高。但是随着图像变形的加剧会引起正确识别率的迅速下降。

在多尺度理论框架下,本文系统研究了多尺度自卷积归一化直方图算法,利用多尺度自卷积变换中密度函数,直接从密度函数计算不变特征,实现了目标图像的直方图仿射不变量的提取。当图像变形时,有效减少重复利用原始图像而产生的累积误差,提高了正确识别率。同时本算法对一定范围内的噪声,局部遮挡,照度及视角变化具有良好的适应性。

2 多尺度自卷积

介绍仿射变换和多尺度自卷积密度函数的概念和定义^[14],这些是构建多尺度自卷积归一化直方图算法的基础。

2.1 仿射变换

定义仿射变换 $\mathcal{A} = \mathcal{A}\{\mathbf{T}, \mathbf{t}\}$ 为:

$$\mathcal{A}(\mathbf{x}) = \mathbf{T}\mathbf{x} + \mathbf{t}$$

式中, $\mathbf{t}, \mathbf{x} \in R^2$, 且 $\mathbf{T}$ 为 2×2 非奇异型实数矩阵,因此上式的逆变换为:

$$\mathcal{A}^{-1}(\mathbf{x}) = \mathbf{T}^{-1}\mathbf{x} - \mathbf{T}^{-1}\mathbf{t}$$

设 $f(\mathbf{x}): R^2 \rightarrow R, f \geq 0$ 是平面灰度图像的灰度值函数,用 f' 表示仿射变换 $\mathcal{A}$ 作用于上述图像后生成新的灰度图像,则有:

$$f'(\mathbf{x}) = f \circ \mathcal{A}^{-1}(\mathbf{x}) = f(\mathbf{T}^{-1}\mathbf{x} - \mathbf{T}^{-1}\mathbf{t})$$

称 f' 为 f 经仿射变换 $\mathcal{A}$ 作用后的形式。对于从函数 f 及其任何仿射变换形式 f' 中提取的特征 I , 如果 I 值相同, 称 I 为仿射不变量。

2.2 多尺度自卷积密度函数

设 $f(\mathbf{x})$ 为 $R^2 \rightarrow R$ 的映射, $f \geq 0$ 为图像的灰度值函

数, 满足 $f(\mathbf{x}) \in L^1(R^2) \cap L^2(R^2)$ 。定义 $p(\mathbf{x}) = \frac{f(\mathbf{x})}{\|f\|_{L^1}}$,

则 $\int_{R^2} p(\mathbf{x}) d\mathbf{x} = 1$, 称 $p(\mathbf{x})$ 为概率密度函数。任取 R^2 上自变量 X_0, X_1 和 $X_2, p(X_j)$ 表示 X_j 点概率密度, $j = 0, 1$ 或 2 , 设 $(\mathbf{x}_0, \mathbf{x}_1, \mathbf{x}_2)$ 为上述变量的样本值, 以此样本值为基作如下变换:

$$\mathbf{u} = \alpha(\mathbf{x}_1 - \mathbf{x}_0) + \beta(\mathbf{x}_2 - \mathbf{x}_0) + \mathbf{x}_0 \quad (1)$$

根据上式定义随机变量:

$$\mathbf{U}_{\alpha, \beta} = \alpha(X_1 - X_0) + \beta(X_2 - X_0) + X_0 \quad (2)$$

$\mathbf{U}_{\alpha, \beta}$ 的样本值为 $\mathbf{u}$, 令 $\gamma = 1 - \alpha - \beta$, 根据文献[14]中引理 2.1, $\mathbf{U}_{\alpha, \beta}$ 在样本点 $\mathbf{u}$ 处的概率密度为:

$$p_{\mathbf{U}_{\alpha, \beta}}(\mathbf{u}) = (p_\alpha * p_\beta * p_\gamma)(\mathbf{u}) \quad (3)$$

式中当 $a \neq 0$ 时, $p_a(\mathbf{x}) = \frac{1}{a^2} p(\frac{\mathbf{x}}{a})$; 当 $a = 0$ 时, $p_a(\mathbf{x}) = \delta(\mathbf{x})$ (单位冲击函数)。

f' 上点 $\mathbf{x}'$ 的概率密度为 $p'(\mathbf{x}') = \frac{f'(\mathbf{x}')}{\|f'\|_{L^1}}$, 利用 f' 按照式(1)和(2)构造 $\mathbf{u}'$ 和 $\mathbf{U}'_{\alpha, \beta}$, 则 $\mathbf{U}'_{\alpha, \beta}$ 在 $\mathbf{u}'$ 的概率密度为:

$$p'_{\mathbf{U}'_{\alpha, \beta}}(\mathbf{u}') = (p'_\alpha * p'_\beta * p'_\gamma)(\mathbf{u}') \quad (4)$$

式中 $a \neq 0$ 时, $p'_a(\mathbf{x}') = \frac{1}{a^2} p(\frac{\mathbf{x}'}{a})$; $a = 0$ 时, $p'_a(\mathbf{x}') = \delta(\mathbf{x}')$ (单位冲击函数)。

3 多尺度自卷积归一化直方图

当 $\alpha, \beta, \gamma \neq 0$ 时, 式(3)的积分形式为:

$$p_{\mathbf{U}_{\alpha, \beta}}(\mathbf{u}) = \frac{1}{\alpha^2 \beta^2 \gamma^2} \int_{R^2} \int_{R^2} p(\frac{\mathbf{x}}{\alpha}) p(\frac{\mathbf{y}}{\beta}) p(\frac{\mathbf{u} - \mathbf{x} - \mathbf{y}}{\gamma}) d\mathbf{x} d\mathbf{y} \quad (5)$$

式(4)的积分形式为:

$$p'_{\mathbf{U}'_{\alpha, \beta}}(\mathbf{u}') = \frac{1}{\alpha'^2 \beta'^2 \gamma'^2} \int_{R^2} \int_{R^2} p'(\frac{\mathbf{x}'}{\alpha'}) p'(\frac{\mathbf{y}'}{\beta'}) p'(\frac{\mathbf{u}' - \mathbf{x}' - \mathbf{y}'}{\gamma'}) d\mathbf{x}' d\mathbf{y}' \quad (6)$$

令 $\mathbf{x}' = \mathbf{T}\mathbf{x} + \alpha\mathbf{t}, \mathbf{y}' = \mathbf{T}\mathbf{y} + \beta\mathbf{t}, \mathbf{u}' = \mathbf{T}\mathbf{u} + \mathbf{t}$, 代入式(6)得:

$$p'_{\mathbf{U}'_{\alpha, \beta}}(\mathbf{u}') = \frac{|\mathbf{T}|^2}{\alpha^2 \beta^2 \gamma^2} \int_{R^2} \int_{R^2} p'(\mathbf{T} \frac{\mathbf{x}}{\alpha} + \mathbf{t}) p'(\mathbf{T} \frac{\mathbf{y}}{\beta} + \mathbf{t}) \cdot p'(\mathbf{T} \frac{\mathbf{u} - \mathbf{x} - \mathbf{y}}{\gamma} + \mathbf{t}) d\mathbf{x} d\mathbf{y} \quad (7)$$

根据密度函数定义, 可知 $p(\mathbf{x}) = |\mathbf{T}| p'(\mathbf{T}\mathbf{x} + \mathbf{t})$, 代入式(7)得:

$$p'_{\mathbf{U}'_{\alpha, \beta}}(\mathbf{u}') = \frac{1}{|\mathbf{T}| \alpha^2 \beta^2 \gamma^2} \int_{R^2} \int_{R^2} p(\frac{\mathbf{x}}{\alpha}) p(\frac{\mathbf{y}}{\beta}) p(\frac{\mathbf{u} - \mathbf{x} - \mathbf{y}}{\gamma}) d\mathbf{x} d\mathbf{y} \quad (8)$$

比较式(5)和式(8), 得:

$$p_{U_{\alpha,\beta}}(\mathbf{u}) = |\mathbf{T}| p'_{U'_{\alpha,\beta}}(\mathbf{u}') \quad (9)$$

如果 α, β, γ 中某个参数为 0, 仅需去掉式(3)、(4)中 0 值参数的对应项后计算密度函数. 令 $p_{\max}(\mathbf{u}) = \max$

$(\arg p_{U_{\alpha,\beta}}(\mathbf{u}))$, 定义 $\bar{p}_{U_{\alpha,\beta}}(\mathbf{u}) = \frac{p_{U_{\alpha,\beta}}(\mathbf{u})}{p_{\max}(\mathbf{u})}$, $\bar{p}'_{U'_{\alpha,\beta}}(\mathbf{u}') = \frac{p'_{U'_{\alpha,\beta}}(\mathbf{u}')}{p'_{\max}(\mathbf{u})}$, 分别表示 $p_{U_{\alpha,\beta}}(\mathbf{u})$ 和 $p'_{U'_{\alpha,\beta}}(\mathbf{u}')$ 的归一化形式. 设 $p_{U_{\alpha,\beta}}(\mathbf{u})$ 在 $\mathbf{U}_0$ 点取得最大值 $p_{\max}(\mathbf{U}_0)$, 那么存在

$\mathbf{U}'_0 = \mathbf{T}\mathbf{U}_0 + \mathbf{t}$ 使得 $p'_{U'_{\alpha,\beta}}(\mathbf{U}'_0) = \frac{p_{\max}(\mathbf{U}_0)}{|\mathbf{T}|}$, 利用反证法

由式(9)可证 $p'_{\max}(\mathbf{u}') = \frac{p_{\max}(\mathbf{u})}{|\mathbf{T}|}$, 因此对任意的 (α, β) , 有 $\bar{p}_{U_{\alpha,\beta}}(\mathbf{u}) = \bar{p}'_{U'_{\alpha,\beta}}(\mathbf{u}')$, 所以归一化密度函数之间满足仿射变换关系. 归一化密度函数值划分成 N 个互不相交集 $B_j, j=1, \dots, N$, 对每个 B_j 有:

$$p(\bar{p}_{U_{\alpha,\beta}}(\mathbf{u}) \in B_j) = p(\bar{p}'_{U'_{\alpha,\beta}}(\mathbf{u}') \in B_j)$$

因此归一化密度函数直方图是仿射不变量.

式(9)两边分别乘以 $f(\mathbf{u})$ 和 $f'(\mathbf{u}')$ 后作积分运算, 得:

$$\int_{R^2} f(\mathbf{u}) p_{U_{\alpha,\beta}}(\mathbf{u}) d\mathbf{u} = \int_{R^2} f'(\mathbf{u}') p'_{U'_{\alpha,\beta}}(\mathbf{u}') d\mathbf{u}' \quad (10)$$

根据文献[14]中 MSA 的定义 $F(\alpha, \beta) = \int_{R^2} f(\mathbf{u}) \cdot p_{U_{\alpha,\beta}}(\mathbf{u}) d\mathbf{u}$, 根据式(10), $\forall (\alpha, \beta)$, 有 $F(\alpha, \beta) = F'(\alpha, \beta)$, 这从仿射变换前后密度函数的关系证明了 MSA 变换可以用于仿射不变量分类. 在式(9)基础上, 式(10)成立的前提是 $f(\mathbf{u}) = f'(\mathbf{u}')$, 但当图像受噪声和照度等影响而发生变形时, $f'(\mathbf{u}')$ 和 $f(\mathbf{u})$ 存在差异, 这种差异随着图像变形的加剧而增加, MSA 的误差识别率增长速度也随之加快, 所以 $f(\mathbf{u}_{\alpha,\beta})$ 的阶数越高, 其矩对噪声越敏感[14].

文献[20]中构造的仿射不变量:

$$Gf(\mathbf{x}) = \frac{1}{\|f\|_{L^1}^2} (f_a * f_\beta * f_\gamma)(\mathbf{x}) \quad (11)$$

式(11)中 $a \neq 0$ 时, $f_a = \frac{1}{a^2} f(\frac{\mathbf{x}}{a})$; $a = 0$ 时, 去掉对应项计算. $\forall (\alpha, \beta)$, $Gf(\mathbf{x})$ 和 $Gf'(\mathbf{x}')$ 服从相同的分布, 其直方图是仿射不变量. 式(11)的等价形式为 $Gf(\mathbf{x}) = \|f\|_{L^1} p_{U_{\alpha,\beta}}(\mathbf{x})$, 因此 $\|f\|_{L^1} p_{U_{\alpha,\beta}}(\mathbf{x}) = \|f'\|_{L^1} p'_{U'_{\alpha,\beta}}(\mathbf{x}')$, 当 $\frac{\|f'\|_{L^1}}{\|f\|_{L^1}} = |\mathbf{T}|$ 时, 式(11)与式(9)等价, 但当 $\frac{\|f'\|_{L^1}}{\|f\|_{L^1}} \neq |\mathbf{T}|$ 时, 用 $\|f'\|_{L^1}$ 和 $\|f\|_{L^1}$ 估计 $|\mathbf{T}|$ 值, 导致式(11)获取的特征值与真实值间存在误差, 随着误差的增加, 其误差识别率增长速度随之加快. 为表述方便, 下文中用 MSA ghist, MSA hist 和 MSA fhist 分别表示本文、文献[15]和[20]中的直方图方法.

本文的 MSA ghist 方法实质上是图像多尺度变换后

的协变形式中各灰度值像素与全部像素的比值, 具有各灰度值像素对特征值的贡献度等同的特征. MSA hist 方法是原始图像的各灰度值像素与全部像素的比值, 然后以相应像素点在多尺度变换后的协变形式中对应的密度函数值作为权重, 各灰度值像素对特征值的贡献不仅与各灰度值像素数量有关, 而且还与各像素多尺度变换后的灰度值有关.

本文的归一化直方图方法, 直接利用式(9)而无需再次借助原始图像计算仿射不变量, 同一目标不同图像的密度函数间是通过归一化建立相等关系, 因此引入的误差少, 将在实验中得到验证.

4 归一化直方图算法实现

使用数字图像计算归一化直方图, 首先要计算 $p_{U_{\alpha,\beta}}(\mathbf{u})$ 的离散形式, 式(3)的三次积分计算量大, 利用文献[15]中方法计算离散 $p_{U_{\alpha,\beta}}(\mathbf{u})$, 其表达式为:

$$p_{U_{\alpha,\beta}}(\mathbf{u}) = \frac{1}{\hat{f}(0)} \text{IDFT}(\hat{f}_\alpha(\mathbf{w}) \hat{f}_\beta(\mathbf{w}) \hat{f}_\gamma(\mathbf{w})) \quad (12)$$

式中 $\hat{f}$ 表示 f 的离散傅立叶变换, IDFT 表示离散傅立叶逆变换, 为了准确计算三次积分, 式(12)的变换长度应满足 $N_i \geq (|\alpha| + |\beta| + |\gamma|) M_i - 2, i=1, 2, M_1 \times M_2$ 和 $N_1 \times N_2$ 分别表示图像傅立叶变换前后尺寸.

计算出 $p_{U_{\alpha,\beta}}(\mathbf{u})$ 值后, 先把 $p_{U_{\alpha,\beta}}(\mathbf{u})$ 值归一化为 $\bar{p}_{U_{\alpha,\beta}}(\mathbf{u}) \in [0, 1]$, 然后将 $[0, 1]$ 区间划分成若干个互不相交的集合 $B_j, j=1, \dots, N$, 统计每个 B_j 中的点数. 目标像素越多, $\bar{p}_{U_{\alpha,\beta}}(\mathbf{u})$ 的值越丰富, 可划分的集合数量越多, 显然集合数越多区分能力越强, 但对图像变形也越敏感, 充分考虑识别率和稳定性双重因素, 优化 N 值为 15.

如果提取的特征包含背景点的特征, 目标特征就不能得到准确的表达, 因此需要去除 $\bar{p}_{U_{\alpha,\beta}}(\mathbf{u})$ 值为 0 的背景点. 具体实现步骤为: 首先把 $[0, 1]$ 区间化分成 $N \times M + 1$ 个 bins, M 为大于 1 的整数; 然后从第二个 bins 起, 每 M 个 bins 合并为 1 个 bin; 最后计算合并后每个 B_j 中的点数和 $N \times M$ 个 bins 中总点数的比值. 上述方法用式(13)表示为:

$$p_i = \frac{\sum_{j=1}^M B_{1+(i-1) \times M+j}}{\sum_{k=2}^{M \times N+1} B_k}, i=1, \dots, N \quad (13)$$

$(p_1, \dots, p_N)$ 为目标的特征向量.

在直方图方法特征值计算方面, 本文的 MSA ghist 方法直接从密度函数计算不变量特征, 与 MSA hist 和 MSA fhist 两种方法相比, 不但具有等同的计算量, 而且有效地提高了目标图像的直方图仿射不变量的提取精度和鲁棒性.

5 仿真实验分析及结果

实验中 MSA ghist, MSA hist 和 MSA fhist 分别使用相同的 3 对参数 $(\alpha, \beta) = \{(-1, 1), (-0.4, 0.4), (0.2, 0.4)\}$ 构造 45 个特征值;由于 MSA 的参数选择和识别率间没有明确关系,为了较全面的体现 MSA 的性能,本文比较 MSA 在两组参数下的错误识别率,其中一组为文献[14]中提供的 29 对参数,另一组为从文献[14]中的 (α, β) 最小平面中选择的 13 对参数,分别表示为 MSA29 和 MSA13,其中 13 对参数为 $(\alpha, \beta) = \{(-1, 1), (-0.8, 0.8), (-0.6, 0.6), (-0.6, 0.8), (-0.4, 0.6), (-0.4, 0.4), (-0.2, 0.2), (-0.2, 0.4), (-0.2, 0.6), (0, 0.2), (0, 0.4), (0.2, 0.2), (0.2, 0.4)\}$. 本文采用互相关系数表示目标的相似程度,作为分类依据,互相关系数数值最大的两个目标即视为同一目标.

实验 1 以 Maria Petrou 提供的“fish”测试数据库^[21]为学习样本,测试 MSA ghist, MSA fhist 和 MSA 在目标图像受噪声,遮挡和光照变化条件下产生形变时的错误识别率.实验中没有加入 MSA hist 的比较,因为图像变形较大时,其错误识别率高.从“fish”数据库中选取有代表性的 15 种鱼图像,对它们进行 10 种随机仿射变换,得到 150 幅鱼图像仿射变换形式的样本图像,部分原始鱼图像如图 1(a).在样本图像中加入零均值高斯噪声,通过改变噪声的方差 v 值来模拟图像受噪声干扰时的变形程度,加入噪声后的部分测试样本如图 1(b),噪声对识别率的影响如图 2(a).在样本图像上随机放置尺寸为 $d \times d$,各点灰度值为 128 的方块模拟遮挡物,方块覆盖鱼体的面积尽量大,以增加识别的难度,加入遮挡后的部分测试样本如图 1(c),不同遮挡尺寸 d 对识别率的影响如图 2(b).照度的变化体现在图像上为灰度值的变化,均匀增减目标像素灰度值模拟图像受均匀照度影响的情况,或以图像中心为起始点线性增加目标像素点灰度






图1 目标图像样本




(a) 噪声方差和错误识别率关系




(b) 遮挡尺寸和错误识别率关系

图2 噪声和遮挡变形下的错误识别率



(a) 亮度均匀变化和错误识别率关系




(b) 亮度非线性变化和错误识别率关系


图3 照度变化下的错误识别率

值模拟图像受非线性照度影响的情况. 均匀变化值 c 、线性斜率 s 与识别率的关系分别如图 3(a) 和 3(b).

实验 2 以“coil-100”数据库^[22]为实验样本, 测试纯视角变化对 MSA ghist, MSA hist, MSA fhist 和 MSA 识别率的影响. “coil-100”数据库中包含 100 种不同目标, 每种目标包含不同角下度获取的 72 幅图像, 角度间隔为 5° . 在“coil-100”数据库中选取视角为 $0^\circ - 35^\circ$ 的图像, 这些图像转换为灰度图像后用作测试样本, 其中视角为 15° 的图像兼作学习样本. 数据库部分图像如图 4(a) 所示, 错误识别率和视角变化的关系见图 4(b).



(a) “coil-100”数据库样本, 自左至右, 从上到下, 视角分别为 $0^\circ, 5^\circ, 10^\circ, 15^\circ, 20^\circ, 25^\circ, 30^\circ, 35^\circ$



(b) 错误识别率和视角变化的关系

图4 部分数据库目标图像和视角变化下的错误识别率

实验 1 分析结果表明, 在各种图像变形下, MSA ghist 的错误识别率最小, 而且随着图像变形程度的增加, 增长速度也远小于其它方法, 这验证了 MSA ghist 引入的误差最小, 识别率得到大大提高. 特别是对噪声和照度变化, MSA ghist 在某一段范围内为 0 或接近于 0, 这说明其对噪声和照度变化具有更好的适应性. 比较 MSA13 和 MSA29 的错误识别率, MSA 的识别率并不是纯粹的随着参数个数的增加而提高, 较少参数的识别率可能比较多参数的高. MSA fhist 对噪声和遮挡情况下识别率较高, 优于 MSA, 在照度变化时识别率最低, 特别是对照度均匀变化的情况, 错误识别率迅速在 18 点处达到 1, 而 MSA ghist 在 36 点处还不到 0.15, 这说明归一化还能消弱照度变化的影响, 此时的错误识别率主要来自目标像素灰度值的饱和.

实验 2 中 MSA ghist 在角度变化小于 10° 时错误识别率最低, 仅在 10° 以后的某个点才高于 MSA hist. 从错

误识别率和角度变化的关系分析, 对于较小范围的角度变化 MSA ghist 最有效, 角度增加到一定程度后, MSA hist 最有效.

6 结论

本文在多尺度自卷积概念中图像密度函数的基础上, 推导出密度函数经归一化后具有相同的分布, 为提取直方图仿射不变量提供了理论依据. 分析各种计算特征值方法的误差来源, 得到归一化直方图引入误差最小、在多数情况下其错误识别率最低、而且随图像变形的加剧其增长速度也最低的结论.

传统的归一化直方图特征值个数不仅局限于图像的灰度阶数, 而且单参数构造的特征量越多, 越容易受图像变形的影响, 本文使用多对参数来提高特征值数目, 有效地提高了特征量的区分能力和识别率. 因此, 该直方图方法单参数特征量的构造效率远高于多尺度自卷积方法. 同时对一定范围内的噪声, 遮挡, 光照和视角变化具有良好的适应性, 特别是在多种环境下, 在目标识别中具有重要的应用价值.

参考文献:

- [1] 贾建华, 焦李成, 黄文涛. 一种基于质心不变特性的仿射不变纹理特征提取算法[J]. 电子学报, 2008, 36(10): 1910 - 1915.
Jia Jian-hua, Jiao Li-cheng, Huang Wen-tao. Affine invariant texture feature extraction based on invariant centroid[J]. Acta Electronica Sinica, 2008, 36(10): 1910 - 1915. (in Chinese)
- [2] David G. Lowe. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 99 - 110.
- [3] Yan Ke, Rahul Sukthankar. PCA-SIFT: A more distinctive representation for local image descriptors[A]. Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition[C]. Washington, D C, USA: IEEE, 2004. 506 - 513.
- [4] Michael Grabner, Helmut Grabner, Horst Bischof. Fast approximated SIFT[A]. Proceedings of 7th Asian Conference on Computer Vision[C]. Hyderabad, India, 2006. 918 - 927.
- [5] K Mikolajczyk, C Schmid. A performance evaluation of local descriptor[A]. Proceedings of the 2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition[C]. Wisconsin, U S A: IEEE, 2003. 257 - 263.
- [6] S Belongie, J Malik, J Puzicha. Shape matching and object recognition using shape contexts[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2002, 24(4): 509 - 522.
- [7] Lei Qin, Wen Gao. Image matching based on a local invariant descriptor[A]. IEEE International Conference on Image Pro-

- cessing[C]. Genova, Italy: IEEE, 2005. 377 – 380.
- [8] Philippe Noriega, Benedicte Bascle, Olivier Bernier. Local kernel color histograms for background subtraction[A]. International Conference on Computer Vision Theory and Applications [C]. Setúbal, Portugal, 2006. 213 – 219.
- [9] 蔡红苹, 雷琳, 陈涛, 粟毅. 一种通用的仿射不变特征区域提取方法[J]. 电子学报, 2008, 36(4): 672 – 678.
Cai Hong-ping, Lei Lin, Chen Tao, Su Yi. A general approach for extracting affine invariant regions[J]. Acta Electronica Sinica, 2008, 36(4): 672 – 678. (in Chinese)
- [10] M K Hu. Visual pattern recognition by moment invariants[J]. IRE Transactions on Information Theory, 1962, 8(2): 179 – 187.
- [11] J Flusser, T Suk. Pattern recognition by affine moment invariant[J]. Pattern Recognition, 1993, 26(1): 167 – 174.
- [12] C Gope, et al. Zernike moment invariant based photo-identification using fisher discriminant model[A]. Proceedings of the 26th Annual International Conference of the IEEE EMBS[C]. San Francisco, CA, USA: IEEE, 2004. 1455 – 1458.
- [13] 张力, 肖薇薇, 钱恭斌, 纪震. 基于 Krawtchouk 不变矩的仿射攻击不变性局部水印算法[J]. 电子学报, 2007, 35(7): 1403 – 1408.
Zhang Li, Xiao Wei-wei, Qian Gong-bin, Ji Zhen. Affine transform invariant image local watermarking by krawtchouk moment invariant[J]. Acta Electronica Sinica, 2007, 35(7): 1403 – 1408. (in Chinese)
- [14] E Rahtu, M Salo, J Heikkilä. Affine invariant pattern recognition using multi-scale autoconvolution[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(6): 908 – 918.
- [15] E Rahtu, M. Salo, J Heikkilä. Multi-scale autoconvolution histograms for affine invariant pattern recognition[A]. Proc. 16th British Machine Vision Conference [C]. Edinburgh, U K, 2006. 1039 – 1048.
- [16] E Rahtu, M Salo, J Heikkilä. A new efficient method for producing global affine invariants[A]. Proc. 13th International Conference on Image Analysis and Processing[C]. Springer, Germany, 2005. 407 – 414.
- [17] J Kannala, E. Rahtu, J Heikkilä. Affine registration with multi-scale autoconvolution[A]. Proc. International Conference on Image Processing[C]. Genoa, Italy, 2005. 1064 – 1067.
- [18] E Rahtu et al. Generalized affine moment invariants for object recognition[A]. Proc. 18th International Conference on Pattern Recognition[C]. Hong Kong, 2006. 634 – 637.
- [19] E Rahtu, M Salo, J Heikkilä. A new affine invariant image transform based on ridgelets[A]. Proc. 16th British Machine Vision Conference[C]. Edinburgh, U K, 2006. 1059 – 1068.
- [20] E Rahtu. A multi-scale framework for affine invariant pattern recognition and registration[D/OL]. <http://herkules.oulu.fi/isbn9789514286018/index.html?lang=en>, 2007 – 11 – 2.
- [21] Alexander Kadyrov, Maria Petrou. The trace transform and its application[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 23(8): 811 – 828.
- [22] Columbia University. Columbia Object Image Library: coil-100 [DB/OL]. <http://www.cs.columbia.edu/CAVE/software/softlib/coil-100.php>, 1996 – 2.

作者简介:



赵继印(通信作者) 男, 1961 年出生于吉林省九台市. 1993 年 9 月获得吉林工业大学通信与电子系统专业博士学位. 现任吉林大学通信工程学院教授、博士生导师. 主要从事智能信息处理与传输方面的教学和研究工作.

E-mail: zhaojiyin2000@163.com



黄 波 男, 1980 年出生于江苏省连云港市. 现在吉林大学通信工程学院攻读博士学位. 主要从事图像处理与模式识别方面的研究.

E-mail: huangbojlu@sina.com