

文章编号: 1007-2780(2013)04-0641-08

基于轮廓特征的神经网络目标识别研究

王灿进^{1,2}, 孙 涛¹, 王挺峰¹, 陈 娟^{1*}

(1. 中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033, E-mail: wcj@mail.ustc.edu.cn;

2. 中国科学院大学, 北京 100049)

摘 要: 为了实现威胁源自动报警, 使用 BP 神经网络构建自动报警系统。针对帧差法提取出的目标轮廓有重复和受变化背景影响的问题, 提出了一种基于轮廓片段的目标特征提取方法。首先使用 k-mediod 聚类以剔除重复轮廓, 再结合轮廓片段生长的方法, 计算待识别轮廓和验证图片集的匹配代价以剔除背景轮廓, 提取出匹配代价最小的轮廓生成轮廓片段字典。随后计算归一化的轮廓矩生成特征向量。最后将提取出的特征向量输入事先训练生成的 BP 神经网络进行分类。实验结果表明, 算法适用于典型刚性目标识别, 对于实验视频中枪支的平均识别率达到 93.5%, 单帧平均运算时间 3.67 ms; 对于 Berkeley 运动分割数据集中车辆的识别率达到 98.2%, 单帧平均运算时间 5.26 ms。算法具有高实时性、高准确率的特点。

关 键 词: 轮廓片段; K-mediod 聚类; 匹配代价; 神经网络

中图分类号: TN391

文献标识码: A

DOI: 10.3788/YJYXS20132804.0641

Target Recognition Using Neural Network Based on Contour Features

WANG Can-jin^{1,2}, SUN Tao¹, WANG Tin-feng¹, CHEN Juan^{1*}

(1. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Science,

Changchun 130033, China, E-mail: wcj@mail.ustc.edu.cn;

2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: In order to achieve automatic alarm for source of threats, an automatic alarming system is established using BP neural network. A feature extraction algorithm using contour fragments are proposed to solve the problem that the edges of the target extracted by frame subtraction is repeated and affected by changing background. Firstly, K-mediod clustering is used to remove repeated edge fragments. Then the matching cost between fragments to be recognized and validation set are computed combining with fragments growing method to eliminate the fragments of background. Then the fragments that have the minimal matching costs are extracted to obtain a codebook of edge fragments. Then improved normalized moments are calculated to generate the feature vector. At last the feature vector is inputted into the improved BP neural network for classification. Experimental results indicate that the algorithm is suitable for typical rigid target recognition. The averaging detection rate is up to 93.5% and averaging computing time of single frame is 3.67 ms for guns in experimental video. For cars in motion segmentation data set from Berkeley the averaging detection rate is up to 98.2% and averaging computing time of single frame is 5.26 ms. The algorithm proposed in this article has a high recognition rate and good real-time performance.

Key words: contour fragments; k-mediod clustering; matching cost; neural network

收稿日期: 2012-11-01; 修订日期: 2012-12-29

基金项目: 院地合作(长吉图专项基金)(No. 2011CJT0006)

作者简介: 王灿进(1987—), 男, 福建龙岩人, 博士研究生, 主要从事模式识别和图像处理的研究

* 通信联系人, E-mail: chenjuan@mail.ccit.edu.cn

1 引 言

随着人工智能的发展,自动目标识别技术在军事和国防安全领域越来越受关注,广泛应用于武器、反恐和边境监控等领域。本文项目背景旨在搭建一套威胁源自动报警系统,用于重点场所对威胁目标的识别与分类。实时监控要求算法必须快速有效,而场所中背景的复杂性及变化性、以及威胁源目标可能在视场中发生平移、旋转、仿射以及被遮挡等情况,对算法的鲁棒性提出了很高的要求。

目前已有许多文献专注于对目标的快速检测和识别^[1-2],其中,模板匹配^[3]利用模板的像素或特征进行搜索,定位精度高,缺点是在目标发生平移和旋转时导致匹配失败,不适用于背景复杂的情况;句法识别^[4]以形式语言理论的概念为基础进行结构模式识别,提取图像的基元特征十分困难,目前应用不广泛;模糊图像识别^[5]用模糊集合的概念代替确定子集,得到模糊的分类结果,适用于类别分界不明确的情况;人工神经网络事先进行监督或无监督的样本训练,得到合适的网络权值,识别时只需调用训练好的网络结构进行分类即可,算法耗时较短,同时神经网络具有信息分布存储、大规模自适应并行处理和较高的容错性、鲁棒性等优点。神经网络算法包括前向神经网络^[6]、反馈神经网络^[7]、自组织神经网络^[8]、Hopfield 神经网络^[9]、混沌神经网络^[10]、模糊神经网络^[11]等,本文选择前向神经网络中应用较广且比较成熟的 BP(Back Propagation)神经网络作为识别分类器。

文献[12]指出对于纹理、形状变化较大的目标,轮廓信息具有最优的分类能力,因此本文使用目标的轮廓信息进行识别。提取出的轮廓片段会出现重复以及掺杂背景轮廓的问题,重复的轮廓片段会导致目标中心的偏移以及重复的特征计算;背景轮廓不属于目标的轮廓集,也会影响特征向量的值,致使分类失败。文献[13-14]提出一种利用边缘片段特征检测目标的算法,对静止目标构建分类器,并不适合运动目标的轮廓筛选。为此本文提出一种基于轮廓片段的运动目标特征提取方法,用帧差法提取粗略轮廓,使用 k-mediod 聚类别除重复轮廓片段,计算待识别目标轮廓片段和验证图片集的匹配代价函数,剔除背景轮廓

并生成最佳轮廓片段集。最后计算剩余轮廓片段的归一化矩构成特征向量,作为神经网络的输入。实验证明本文提出的算法对于枪支能够取得 93.5% 的平均识别率,单帧运算时间为 3.67 ms。

2 轮廓片段特征提取

2.1 轮廓片段提取

假定枪支在场景中运动,采用帧差法和 Canny 算子提取出轮廓,提取过程如图 1 所示。




图 1 轮廓片段提取过程

Fig. 1 Extracting process of edge fragments

由于视频图像光照不均匀、对比度不一致,二值化整幅图像不宜采用单一的阈值。本文采用一种自适应的阈值分割法:取每个像素的 8 邻域,Max 表示 8 邻域中的最大灰度值,Min 表示 8 邻域中的最小灰度值,则阈值

$$T = \frac{\text{Max} + \text{Min}}{2} \quad (1)$$

提取出的轮廓片段会出现重复和间断。如图 2 所示。



图 2 经过 Canny 算子后轮廓重复和间断

Fig. 2 Repetition and gaps of contours after Canny operators

实验中以手为轴将枪支进行转动,发现距手越远轮廓重复越严重,距手越近轮廓间断越严重。原因是相邻的两帧距轴越远相对位移越大,而近轴附近则几乎没有相对位移,经过帧间相减,没有相对位移的部分被消去,有相对位移的部分出现

两条轮廓。握着枪托的手臂也随着枪支旋转,因此右下角手臂的轮廓也被提取出来,从而所有轮廓被分割成多个分属不同类别的片段。

假设以上检测出的轮廓片段集合为 $E = \Gamma \cup A \cup B$, 其中 $\Gamma = \{\gamma_1, \gamma_2, \dots, \gamma_L\}$ 表示真实目标轮廓片段, $A = \{\alpha_1, \alpha_2, \dots, \alpha_M\}$ 为与 Γ 中重复的轮廓片段, $B = \{\beta_1, \beta_2, \dots, \beta_N\}$ 为背景的轮廓片段。令 A 中 α_i 对应 Γ 中 γ_i , 则 α_i 仅是 γ_i 的一个平移, 即

$$\alpha_i(x, y) = \gamma_i(x - \mu, y - \nu), i = 1, \dots, M \quad (2)$$

用 A 计算目标的中心时引入偏移量 (μ, ν) , 导致归一化不准确; 而 B 原本并非目标的轮廓, 也会给特征向量的计算带来不可预料的影响。因此需要将 A 和 B 从集合 E 中剔除。首先对目标定位, 画出包含全部轮廓的最小矩形, 如图 3 所示。



图3 目标定位

Fig. 3 Target locating

2.2 去除重复轮廓片段

为了剔除重复的轮廓片段, 对轮廓进行聚类。k-means 是常用的聚类方法, 它简单快捷但对脏数据较敏感。为此本文使用一种称为 k-mediod 的改进方法, 该方法在数据集中选取一个成员作为 mediod 代替 k-means 的聚类中心^[15]。本文使用 Chamfer Distance^[16] 来衡量两个轮廓之间的相似度。Chamfer Distance 对噪声、旋转和尺度缩放都有良好的鲁棒性, 适用于本文枪支旋转和尺度缩放的情况。聚类算法如下:

(1) 随机选择 k 个轮廓片段作为 k-mediod 的初始 mediod。

(2) 将剩下的轮廓片段对于(1)中每个 mediod 计算 Chamfer Distance, 分到与之距离最小的类中。

(3) 在每个类中顺序选取轮廓片段 γ_i , 计算它到该类中其他轮廓片段的 Chamfer Distance 之和

$E_i = \sum_{j=1}^N d(\gamma_i, \gamma_j)$, 选择 E_i 最小的轮廓片段作为新的 mediod。

(4) 返回步骤 2 直至 mediod 稳定。

k-mediod 算法在确定新的聚类中心时需要在每一类中对每个轮廓计算到其他轮廓的距离, 而 k-means 只需将类中的点集求平均即可得到新的聚类中心。假设某一子类中轮廓数为 N , 则 k-mediod 需要计算 $N(N-1)/2$ 次 Chamfer Distance, 而 k-means 只需要计算一次轮廓平均, 因此 k-mediod 比 k-means 计算量大。但 k-mediod 解决了脏数据敏感的问题, 适用于本文受背景影响较大的情况。最后保留每个类中作为 mediod 的轮廓, 删除其他重复的片段。结果如图 4 所示。



图4 删除重复轮廓后的结果

Fig. 4 Result after deleting repeated fragments

某些属于集合 τ 的轮廓也被剔除了, 原因有二: 一是聚类算法的 K 、 T 选择不当, 导致某些本应该分属两类的轮廓片段也归为一类; 二是某些不同位置的轮廓片段却极为相似, 被聚为一类, 例如上面瞄准镜上下的轮廓。

2.3 去除背景轮廓片段

为了找出集合 B 中的轮廓, 文献[14]提出一种计算轮廓匹配代价的方法。对于聚类后提取出的 k 个轮廓, 随机选择一些其上的点作为“种子”, 沿着提取出的轮廓进行生长, 遇到下列 3 种情况之一停止: 已经到达预先规定的最大长度; 生长到轮廓片段的终点; 回到生长的起点^[17]。进行轮廓生长的同时计算其到验证集图片的匹配代价:

$$c_{\text{match}}(\gamma_i) = \frac{\sum_{i=1}^{M_P} d(\gamma_i, P_{v_i}) / M_P}{\sum_{i=1}^{M_N} d(\gamma_i, N_{v_i}) / M_N} \quad (3)$$

P_{v_i} 表示正例图片, N_{v_i} 代表反例图片, M_P 是正例图片数, M_N 是反例图片数。

$$d(\gamma_i, I_{v_i}) = \frac{1}{|\gamma_i|} \min \sum_t DT_{I_{v_i}}(t) \quad (4)$$

d 表示 γ_i 到 I_{v_i} 中最近像素点的平均距离。轮廓片段与正例图片越相似,则 $d(\gamma_i, P_{v_i})$ 越小, $d(\gamma_i, N_{v_i})$ 越大,即 c_{match} 越小,反之与反例图片越相似则 c_{match} 越大。如果在生长的过程中 c_{match} 始终大于阈值 T ,则该轮廓不在正例图片的轮廓集中,舍弃;否则选择 c_{match} 最小时得到的轮廓保存到轮廓片段字典中。如图 5 所示,经过上面的代价筛选之后,手臂位置的轮廓已经去除。



图 5 去除手臂轮廓后的结果

Fig. 5 Result after deleting edge fragments of arm

2.4 特征向量提取

从以上检测出的轮廓中提取特征向量。为了能分辨出枪支的不同朝向,选择的特征向量必须是旋转变化的。轮廓的 (p, q) 矩:

$$m_{pq} = \sum_x \sum_y x^p y^q f(x, y) \quad (5)$$

式(5)与坐标相关,是旋转变化但不是缩放不变。为此做改进,采用以上矩的归一化结果:

$$\mu_{pq} = \frac{m_{pq}}{m_{00}^{[(p+q)/2]+1}} \quad (6)$$

由于事先提取出了目标的矩形区域,矩提取操作在该矩形内部进行,该矩值不随目标的平移而发生变化,同时在公式(5)中也不必像 Hu 矩那样减去轮廓的中心。

本文使用 μ_{01} 、 μ_{02} 、 μ_{03} 、 μ_{10} 、 μ_{11} 、 μ_{12} 、 μ_{20} 、 μ_{21} 、 μ_{30} 矩。

3 构建 BP 网络

3.1 BP 神经网络

BP 神经网络是目前应用较广的神经网络方法,其激活函数划分区域的边界是非线性的超平面,理论上可以逼近任意非线性的函数,广泛应用于信息处理、模式识别、机器学习、智能控制和图像处理领域。

本文使用单隐层的 BP 网络,网络模型如图 6 所示。




图 6 BP 神经网络模型

Fig. 6 Model of BP neural network

假设理论输出为 $T_k = (y_1^k, y_2^k, \dots, y_q^k)$, 计算出输出层的一般化误差为:

$$d_t^k = (y_t^k - C_t) C_t (1 - C_t), t = 1, 2, \dots, q \quad (7)$$

根据误差梯度下降最快的原则可以调整 v_{jt} 和 γ_t :

$$v_{jt}(n+1) = v_{jt}(n) + \mu d_t^k b_j \quad (8)$$

$$\gamma_t(n+1) = \gamma_t(n) + \mu d_t^k \quad (9)$$

$$t = 1, 2, \dots, q, j = 1, 2, \dots, p, 0 < \mu < 1$$

同理往前一层推算,可调整 w_{ij} 和 θ_j :

$$e_j^k = [\sum_{t=1}^q d_t v_{jt}] b_j (1 - b_j) \quad (10)$$

$$w_{ij}(n+1) = w_{ij}(n) + \epsilon e_j^k a_i^k \quad (11)$$

$$\theta_j(n+1) = \theta_j(n) + \epsilon e_j^k \quad (12)$$

$$i = 1, 2, \dots, n, j = 1, 2, \dots, p, 0 < \epsilon < 1$$

随着样本输入的增加,误差会逐渐减小。当全局误差小于一个阈值时,训练完毕。

构建 BP 网络阶段,需要对每幅样本图像提取轮廓信息,逐渐调整权值。训练图片没有背景的干扰,提取出的轮廓均为枪支的轮廓。

3.2 BP 神经网络设计

3.2.1 初始权值的选择

为保证网络快速收敛到误差曲面的全局最小点,本文使用文献[9]提出的一种规则选择初始权值:①隐层节点的初始值选择均匀分布在零附近的小随机数;②每个输出节点所连的权值一半为+1,一半为-1;若连至输出节点的权值数是奇数,便置该输出节点的偏置为零。

3.2.2 各层节点数的选择

输入层选择为特征向量的维数即 9 个节点,输出层节点选为 2 个。隐层神经元个数并无定则,数目过少会导致下一层获得的信息量不足,难以进行分类;数目过多会导致学习时间过长,泛化

能力下降。可以根据需要动态的增加或者减小隐层单元数目,但太过耗时。本文为减小计算量,采用经验公式(13):

$$m = \sqrt{n+o} + a \quad (13)$$

m 是隐层节点数, n 是输入节点数, o 是输出节点数, a 是 1~10 的常量, 本文选 $a=5$ 。

3.2.3 BP 网络的学习步长

学习步长 n 的选择很重要, 步长过大导致不收敛, 步长过小收敛速度变慢, 为此在权值修改公式中加入动量项:

$$\Delta w_{ij}(n) = \alpha \Delta w_{ij}(n-1) + \eta \delta_j y_i(n) \quad (14)$$

其中 α 是动量项。本文 α 在 1.07~1.005 变化, 训练前期收敛速度较快时动量项选择大一些, 训练后期收敛速度降低时动量项选小一些。

3.2.4 激活函数的选取

为了减小训练的时间, 尽快跳出局部最小点和较平坦的区域, 将神经元的激活函数定义为:

$$f(n) = -\frac{1}{2} + \frac{1}{1 + e^{-n}} \quad (15)$$

4 实验与结果

实验硬件平台包括工控机和云台部分, 如图 7 所示。工控机部分主要负责算法执行和云台控制。系统配置为 Windows XP, Pentium Dual-Core E5300 CPU, 主频为 2.60 GHz, 内存 2.0 GB, 测试在 Microsoft Visual C++ 2008 环境中进行。视频信号通过 cameralink 接口传到工控机的图像采集卡上。算法调用事先构建好的分类器, 对摄像头采集而来的图像进行处理, 识别出威胁目标(即枪支), 根据枪支的不同朝向标记为不同颜色。

训练阶段, 用蒙特卡洛方法随机选取 500 张




图 7 实验系统框图

Fig. 7 Block diagram of experimental system

水平朝向、500 张斜向上 45°朝向和 500 张竖直向上朝向的图片进行训练, 采用交替输入, 得到合适的神经网络权值。神经网络的训练时间为 9 758 s, 下文实验中提到单帧平均运算时间是用训练好的神经网络进行实验的时间。图 8 是 3 类目标 5 个典型的权值比较。




图 8 不同朝向枪支的归一化矩值

Fig. 8 Normalized moments of guns in different orientation

由公式(5)(6)可得:

$$\mu_{pq} = \frac{m_{pq}}{m_{00}^{[(p+q)/2]+1}} = \frac{\sum_x \sum_y x^p y^q f(x, y)}{m_{00}^{[(p+q)/2]+1}} \quad (16)$$

对于属于同一个目标的曲线如曲线 1, 观察到其矩值的大小主要取决于 q , q 越大则矩值越大, 这说明枪支的 y 值在矩中占较大比重, 称 y 方向即竖直方向为目标的“主方向”。

对比 1、2、3 发现, 枪支不同朝向时, 其矩值及变化趋势不同。记曲线 L 的 μ_{pq} 为 $L(\mu_{pq})$, p 和 q 相同时, 越靠近主方向矩值 $L(\mu_{pq})$ 越大, 越偏离主方向矩值 $L(\mu_{pq})$ 越小。这是因为当枪支由水平向竖直旋转过程, 对应曲线由 1 向 3 变化, 轮廓点向右上角移动, 总趋势是 x 和 y 均增大, 而 m_{00} 保持不变, 故矩值变大, 于是观察到 $3(\mu_{pq}) > 2(\mu_{pq}) > 1(\mu_{pq})$ 。

3 条曲线之间 μ_{03} 的值差最大, 而 μ_{10} 则几乎相同。也就是主方向 y 的指数 q 越大, 矩值差越大。记 $\Delta\mu_{pq} = L_1(\mu_{pq}) - L_2(\mu_{pq})$, 因为 y 值在矩中占较大比重, 则 q 越大, 矩值的变化量 $\Delta\mu_{pq}$ 必然越大, 于是观察到 $\max(\Delta\mu_{pq}) = L_1(\mu_{03}) - L_2(\mu_{03})$ 。

由以上得出结论, 若目标存在主方向, 则矩的主方向指数 q 越大, 该矩也就越大, 而且对于不同目标矩值差 $\Delta\mu_{pq}$ 也越大。主方向是识别目标的关键方向。在本文中, y 是主方向, μ_{02} , μ_{03} , μ_{12} 是区分不同朝向枪支的关键矩值。

4.1 旋转、平移和尺度缩放实验

为了验证算法对于旋转、平移和尺度缩放的特性,分别加以实验。旋转变换实验中,使枪支在垂直视轴的平面内转动,观察识别结果,如图 9 所示。




图 9 旋转变换识别结果
Fig. 9 Recognition result of rotation transformation

平移变换实验中,枪支和摄像头的距离不变,枪支保持水平朝向,使其从视场的右侧运动至视场的左侧,观察识别结果,如图 10 所示。



图 10 平移变换识别结果
Fig. 10 Recognition result of translation transformation

尺度缩放实验中,枪支朝向保持水平,改变枪支到摄像头的距离,使目标尺度发生缩放,观察识别结果,如图 11 所示。



图 11 尺度缩放识别结果
Fig. 11 Recognition result of scale transformation

图 9 使用不同颜色的矩形标识不同朝向的枪支,表示本文算法具有旋转变化性;图 10 和图 11 则表明本文算法具有平移和尺度缩放不变性。

定义识别率为正确标示出目标的帧数与总帧数的比值,单帧平均时间为算法处理一帧图像的时间,则识别率表明算法的准确度,单帧平均运算时间表明算法的实时性。算法对于 3 种变换的性能如表 1 所示。

运算时间上各种变换之间区别不大,平均时间在 3.67 ms,实时性得以保证。旋转情况下枪支不同朝向时识别率不同,这里规定水平为

表 1 对不同变换的识别性能比较

Table. 1 Comparison of recognition performance for different transformation

	平移	尺度缩放	旋转		
			水平	45°斜向上	竖直向上
识别率/%	95.5	89.4	86.0	82.6	89.5
单帧平均运算时间/ms	3.57	3.62	3.67	3.78	3.65

0°~10°,斜向上为 40°~50°,竖直为 80°~90°。其中在主方向即竖直向上识别率最高,45°斜向上时识别率最低。在 3 种变换中,平移的识别率最高。这是因为相对于尺度缩放和旋转,平移使用帧差法能够较为完整的提取出运动枪支的轮廓。

4.2 改变学习步长和输入输出函数

在训练阶段加入动量项, α 在 1.07~1.005

变化,并且将隐含层的输入输出函数由 $f(n) = \frac{1}{1+e^{-n}}$ 变为 $f(n) = -\frac{1}{2} + \frac{1}{1+e^{-n}}$,误差 $E < 0.0001$ 时停止训练。训练时间由原来的 266.5 s 缩短至 224 s。识别的性能如表 2 所示。

与表 1 相比,除旋转竖直向上外其余识别率均稍有提高,并且运算时间变化不大,可以认为在

表 2 改进 BP 神经网络参数后识别性能比较

Table 2 Comparison of recognition performance after upgrading parameters of BNN

	平移	尺度缩放	旋转		
			水平	45°斜向上	竖直向上
识别率/%	97.0	91.5	89.5	83.8	87.2
单帧平均运算时间/ms	3.58	3.60	3.62	3.78	3.62

随机变动范围内。

4.3 与 SURF 特征、类 Haar 小波特征的比较

SURF 特征点匹配是一种常用的图像配准算法,具有旋转和尺度不变性和较好的实时性。类 Haar 小波特征与 Adaboost 算法相结合,通过简单的矩形和扩展特征的计算,也能快速识别目标。使用 opencv 提供的库函数实现以上两种算法,并与本文的轮廓片段特征算法加以对比,对比实验采用相同的测试样本和视频,对比结果如表 3。

表 3 不同识别方法的性能比较

Table 3 Comparison of performance for different recognition method

	轮廓片段 特征向量	SURF 特征	类 Haar 小波特征
识别率/%	93.5	82.8	76.5
单帧平均运算 时间/ms	3.67	13.61	44.74

因为 SURF 和 Haar 特征均具有旋转不变性,不能识别枪支的旋转变化,所以这里采用平均的识别率 η 。计算公式为:

$$\eta = \alpha\eta_1 + \beta\eta_2 + \gamma\eta_3 \tag{17}$$

α 、 β 、 γ 分别是平移、旋转和尺度缩放实验帧数的比例, η_1 、 η_2 、 η_3 是该变换下的识别率。

对比结果可以看出对于纹理不明显且形状变化的目标,使用轮廓特征向量在识别率和运算时间上均有优势。

4.4 在其他典型目标上的识别性能

为了验证算法的一般性,使用 Berkeley 大学运动分割数据集的车辆图片进行实验,得到结果如图 12 所示。




图 12 车辆尺度缩放识别结果

Fig. 12 Recognition result of car in scale transformation

图 12 的车辆因为摄像头位置发生了变化,所以将背景中的车辆也识别出来,而图 13 通过帧差法,只识别出前景车辆。在所有的 220 帧图像中,识别 216 幅,识别率达到 98.2%,平均时间 5.26 ms。这进一步验证了算法具有良好的实时性和识别率。同时从图 13 可以看出,算法对于目标轻度仿射也具有一定的鲁棒性。




图 13 车辆平移和轻度仿射变换识别结果

Fig. 13 Recognition result of car in translation and mild affine transformation

5 结 论

经过帧间差提取出的轮廓有重复以及其他背景目标的干扰,无法直接用于神经网络输入。本文据此提出了一种基于轮廓片段的运动目标特征提取方法。首先通过 k-mediod 聚类消除重复的片段,再通过轮廓生长和计算轮廓与验证图片集之间的匹配代价的方法,提取出合适的目标轮廓片段,计算轮廓矩作为 BP 神经网络的输入,实现目标的分类。同时本文也对神经网络设计时的学习步长、输入输出函数的选择做了对比试验,指出加入动量项和改进输入输出函数可以加快收敛速度和提高识别精度。本文提出的算法用于刚性目标识别,对于不同背景和运动方式的枪支的识别率达到 93.5%,而对于车辆的识别率达到 98.2%,与文献[14]算法的 90%相比有所提高,而相对于传统的 SURF 和 Haar 特征点算法要高得多,而且算法的单帧运算时间为 3.67 ms 和 5.26 ms,具有很好的实时性。实验证明该算法对于复杂背景下的运动目标具有很好的识别性能。

参 考 文 献:

[1] 刘翔,周桢. 基于分块背景建模的运动目标检测技术 [J]. 液晶与显示,2011,26(6):831-835.

- [2] 靳永亮,王延杰,丁南南,等.改进的红外弱小目标检测方法[J]. 液晶与显示,2011,26(4):555-560.
- [3] Chang S H, Cheng F H, Hsu W H. Fast algorithm for point pattern matching:invariant to translations,rotations and scale changes[J]. *Pattern Recognition*, 1997, 30(2): 311-320.
- [4] 舒宁,马洪超,孙和利. 模式识别的理论与方法[M]. 武汉:武汉大学出版社,2004.
- [5] 边肇祺. 模式识别[M]. 北京:清华大学出版社,1998.
- [6] Ma S, Ji C. Performance and efficiency: recent advances in supervised learning [J]. *Proceeding of the IEEE*, 1999, 87(9):1519-1535.
- [7] Skitt P J C. Process Monitoring using auto-associative feedforward artificial neural networks [J]. *J. Intell. Manuf.*, 1993, 4(1):79-94.
- [8] Lampinen J, Oja E. Distortion tolerant pattern recognition based on self-organized feature extraction [J]. *IEEE Trans on Neural Network*, 1995, 6:539-547.
- [9] Jenkins B K, Tanguay A R. *Handbook of Neural Computing and Neural Networks* [M]. Boston: MIT Press, 1995.
- [10] Xia M, Fang J N, Tang Y. Dynamic depression control of chaotic neural networks for associative memory [J]. *Neurocomputing*, 2010, 73(2):776-783.
- [11] McDuff R J, Simpson P K. An adaptive resonance diagnostics system [J]. *Neural Network Comp.*, 1990, 2(1): 19-29.
- [12] Leibe B, Schiel E B. Analyzing appearance and contour based methods for object categorization [C]//*Proceedings of CVPR*, Madison:IEEE Computer Society, 2003: 409-415.
- [13] Shotton J, Black A, Cipolla R. Countour-based learning for object detection[C]//*Proceedings of ICCV*, Beijing: IEEE, 2005: 503-510.
- [14] Opelt A, Pinz A, Zisserman A. A boundary-fragment-model for object detection[C]//*Proceedings of ECCV*, Graz: Institute of Electrical Measurement and Measurement Signal Processing and the Institute for Computer Graphics and Vision, 2006: 575-588.
- [15] Huang Z. Extensions to the k-means algorithm for clustering large data sets with Categorical values [J]. *Data Mining and Knowledge Discovery*, 1998, 2(3): 283-304.
- [16] Brraw H G, Tenenbaum J M, Bolles R C. Parametric correspondence and chamfer matching: two new techniques for image matching [C]// *Proc 5th Int Joint Conf Artificial Intelligence*, San Francisco, USA:Morgan Kanfmann Publishers Inc. , 1977: 659-663.
- [17] 崔潇潇,王贵锦,林行刚.基于边缘片段特征的目标检测 [J]. 清华大学学报,2008,48(10):1636-1638.