

基于混合结构神经网络的自适应背景模型

王志明¹, 张 丽², 包 宏¹

(1. 北京科技大学计算机与通信工程学院计算机科学与技术系, 北京 100083; 2. 清华大学工程物理系, 北京 100084)

摘 要: 本文提出一种基于神经网络的视频中运动目标检测自适应背景模型. 对每个像素点(或局部区域)建立一个混合结构的神经网络背景模型, 模型由一个4层前馈神经网络组成, 输入层接受像素 HSV 特征, 特征层实现特征提取功能, 模式层以概率神经网络的方式完成像素属于背景概率的计算, 输出层以赢者取胜的方式完成前景背景分类和模式层激活节点选择功能. 网络的权值和结构随着视频中运动检测过程动态更新, 无需独立的训练视频. 网络的自适应性表现在网络的学习速率根据相邻帧运动差异自适应计算得到, 且网络中的模式节点个数根据权重的变化动态增加或删除. 实验结果表明, 本文提出的方法在无需手工设置学习速率的情况下, 运动区域检测准确率优于其他几种常见的运动检测背景模型, 对背景或灯光的突然变化适应速度很快.

关键词: 视频监控; 运动检测; 神经网络 (NN); 概率神经网络 (PNN); 赢者取胜 (WTA)

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2011) 05-1053-06

Adaptive Background Model Based on Hybrid Structure Neural Network

WANG Zhi-ming¹, ZHANG Li², BAO Hong¹

(1. Department of Computer Science and Technology, School of Computer and Communication Engineering, University of Science and Technology Beijing, Beijing, 100083, China; 2. Department of Engineering Physics, Tsinghua University, Beijing, 100084, China)

Abstract: This paper proposed a new background model for motion detection in video surveillance based on neural network (NN). A neural network background model was build for every pixel (or a small local region). It is a four-layer feedforward neural network. Input layer accept HSV pixel value, feature layer extract features form HSV, pattern layer work as a background probability calculator. Output layer classifies the pixel into background or foreground, and finds the activated node. Weights and structure of network updated dynamically along with motion detection and no training video needed. Adaptability of background model includes adaptive learning rate calculated form motion difference between adjacent frames, and number of pattern node changes according to weight variation. Experimental results on benchmark videos show that, without any manual setting of learning rate, the proposed algorithm can detection motion more precisely than other familiar background models, and it can also adapts to sudden background or lighting changes more quickly.

Key words: video surveillance; motion detection; neural network (NN); probabilistic neural network (PNN); winner take all (WTA)

1 引言

视频监控已广泛应用于各种生产、生活环境中,如生产车间、办公楼宇、机场、地铁,等等. 视频监控的一个基本的但非常重要的任务就是检测视频中的运动目标,它是后续目标跟踪、目标识别、乃至行为分析的基石. 但面对各种复杂的天气环境、灯光变化等因素影响,准确、鲁棒的运动区域检测仍是一个非常困难的任务.

Hu^[1]将运动检测方法分为三类:背景减除法、时间差法和光流法. 时间差法容易漏掉运动较慢的物体,或在检测结果中产生大面积的空洞,严重影响后期的处

理,因此很少单独采用;光流法计算图像中每个像素的运动方向和速度,具有较高的精度,可用于移动摄像头,但计算量非常大,且对噪声和光照变化敏感,因此很难实际应用;背景减除法概念直观,实际效果较好,在近十年的研究中受到广泛的关注,属于研究最多、应用最广的方法. 本文针对背景减除法,提出了一种新的基于混合结构前馈神经网络的背景模型.

2 相关研究背景

根据建模方法,背景减除法可分固定背景模型方法,固定背景与帧差法结合方法,高斯或混合高斯模型

方法,核函数概率密度估计方法,神经网络方法,等等.最简单的是固定背景模型,通过均值滤波、中值滤波、聚类分析或其他基于运动分析的方法得到背景图片,而后将当前图像与背景图像差得到运动区域.近些年对这种方法的研究:(1)固定背景提取方法的改进,如 Zhang^[2]对提取的背景图像进行自适应的亮度和色度畸变校正;(2)是将固定背景法与其他方法相结合,如李波^[3]将时间差法与背景减法相结合.但这些方法本质上仍是以单一图像作为背景,仅适用于固定背景或背景变化非常缓慢的情况,缺点是无法适应背景的快速动态变化(如光照突然改变、树叶摇动、水面波动、等等).

为描述背景的复杂变化,人们提出以高斯模型或混合高斯模型(MoG: Mixture of Gauss, 又称 GMM: Gaussian Mixture Model)描述每个位置点的像素值变化,有许多学者对 MoG 进行了改进和推广.有些增加对边缘信息的利用,如 Tian^[4]利用边缘纹理信息消除因光照突然变化引起的误报,万成凯^[5]将混合高斯模型与活动轮廓结合为统一的能量最小化问题抑制前景中的空洞和阴影;有些利用邻域信息和时间连续性信息,如王永忠^[6]、Huang^[7]将时间域和空间域信息相结合进行分类;有些将 MoG 方法与其他方法相结合,如刘鑫^[8]将 MoG 与帧间差分相结合,区分背景显露和缓慢运动并采用不同的背景更新策略.这些方法相比基本的 MoG 模型有一定的改进,但都还受到 MoG 基于像素值分布呈高斯分布假设的限制,当 MoG 混合模型个数较少时,无法反应实际像素概率分布,较多时处理速度迅速下降.高斯模型的个数、学习速率等参数也往往需要针对不同场景根据经验确定.针对 MoG 的局限性,有学多学者研究了更一般的非参数背景模型,无需估计均值、方差等参数,对像素概率分布描述能力更强,其中基于核函数估计像素背景概率的方法得到了广泛研究.如 Li^[9]的基于贝叶斯分类理论的背景模型,采用特征直方图描述概率,综合利用像素点的频谱、空间和时间信息来进行背景和前景的分类;贾立好^[10]的结合颜色亮度畸变模型的双阈值背景减法;McHugh^[11]利用空间邻域信息建立前景模型来提高运动目标检测的可靠性.近几年,有学者提出了一些基于神经网络的运动检测背景模型,属于一类新的非参数背景模型.如 Culibrk^[12]提出的概率神经网络背景模型(BNN: Background Neural Network),Maddalena^[13]的自组强神经网络(SONN: Self-Organizing Neural Network)背景模型.

本文提出的基于混合结构前馈神经网络的自适应背景模型与 Culibrk^[12]的 BNN 有相似之处,但也具有明显的区别.(1)在本文算法中,不仅是网络权值,学习速率和网络结构也动态变化,从而具有很强的自适应性,

无需对不同场景的视频设定学习不同的学习速率;(2)分类规则是基于一个赢者取胜(WTA: Winner Take All)规则,而不是 Culibrk 所采用的基于联合概率的贝叶斯规则;(3)网络中增加一个特征提取层,使概率估计依赖于经过变换的 HSV(色调、饱和度、亮度)颜色特征,而不是像素灰度值或直接的 RGB 或 HSV 等特征,对像素颜色变换检测更为准确.

3 前馈神经网络背景模型框架

人工神经网络具有较强的自学习能力和记忆功能,已广泛用于人工智能、模式识别、图像处理等许多领域.考虑到视频背景的复杂变化,用神经网络描述背景受到许多学者关注,并取得了较好的效果.

本文在前人工作的基础上针对网络学习速率难以确定、直接以 RGB 像素值作为特征不适合运动检测、以及网络结构复杂度与计算速度矛盾等几个问题进行了深入研究,提出一种包含特征转换层、能够自动调节学习速率、自适应能力更强的神经网络背景模型,我们称为自适应神经网络背景模型(ANNBM: Adaptive Neural Network Background Model).

在我们的神经网络背景模型中,为每个像素(或一个局部小区域)建立一个分类神经网络,网络结构为四层前馈神经网络,分别为输入层、特征层、模式层和输出层.如图 1 给出了本文提出的运动检测神经网络框架图.




图1 运动检测神经网络

第一层是输入层,它直接接受每个像素的 HSV 值,采用 HSV 值是由于 HSV 与人眼对颜色的感知接近.第二层是特征层,以普通前馈网络方式工作,实现特征提取的功能,它将 HSV 值转换为某种更适合于分类的像素特征.第三层是模式层,是一组基于高斯核函数的概率估计器,以概率神经网络方式工作.每个神经元存有一个背景像素的特征值,可计算新的像素特征值属于这一模式的概率.背景概率根据由模式节点的输出乘以一个连接到输出分类节点的权重得到,这一权重由在线学习过程中自适应学习,它代表这一模式属于背景的先验概率.模式节点的个数也随着连接权重的改变在线动态调整.

第四层是输出层,包括两个不同类型的节点,均以赢者取胜(WTA)方式工作.一个是分类节点,选择所有

输入的最大值,并通过将这一值与一个预先设定的阈值相比较完成分类.在这一点上与 BNN 完全不同,BNN 是通过一个累加(summation)神经元计算联合概率,而我们的网络是找最大值.直观的含义是,BNN 以背景联合概率大于前景联合概率作为是否为背景的依据,而我们的算法是只要有一个背景节点足够相似,并具有一定的背景先验概率,当前像素就应该被判定为背景.

输出层的另一个节点是激活节点,也是以 WTA 方式工作,但它的输出是所有模式节点概率最大值的索引号(如果最大值超过某个阈值),所有模式节点连接到它的权值均为 1.这一索引用于网络的动态更新.

对于空间位置相关性的考虑我们放在后处理阶段进行,我们所采用的滤波后处理算法^[14],考虑了每个像素其周围一定范围内邻域对它的影响.

4 运动检测与模型更新

4.1 高斯核函数背景概率估计

在输入层,我们选择 HSV 而不是 RGB 作为网络输入.因为 HSV 值更接近于人类对颜色的感知,已在许多计算机视觉系统中得到了成功的应用.但直接采用 HSV 值存在一些问题:(1)在饱和度(S)较低时色调(H)值存在着较大的不稳定性;(2)色调值本身是周期性的,如接近 0 度和 360 度的值虽然相差很大,但颜色非常接近(都呈显红色).

因此,我们在特征层将 HSV 转换为以下新的特征^[13]:

$$(x_V, x_S, x_H) \Rightarrow (x_1 x_S \cos(x_H), x_1 x_S \sin(x_H), x_V) \quad (1)$$

显然,这一转换可以有效解决上述两个问题,色调的周期在新的特征上不会产生不连续;饱和度和亮度较小时,色调的影响也很小.

在模式层中,某一个颜色向量 \mathbf{x} 属于某一背景模式 \mathbf{b}_i 的条件概率 $p(\mathbf{b}_i | \mathbf{x})$ 由高斯核函数估计得到,每个模式节点对应于背景的一种模式,并作为一个独立的概率估计器工作.每个模式的先验背景概率 $p(B | \mathbf{b}_i)$ 保存于模式神经元到分类神经元的连接权值中.某一颜色向量 \mathbf{x} 属于某一背景模式 \mathbf{b}_i 的等效概率 $p_i(B | \mathbf{x})$ (这里并非严格意义上的概率值,只是与概率成正比)由以下两式估计:

$$p_i(B | \mathbf{x}) = p(B | \mathbf{b}_i) \cdot p(\mathbf{b}_i | \mathbf{x}) \quad (2)$$

$$p(\mathbf{b}_i | \mathbf{x}) = \exp(-d^2(\mathbf{x}, \mathbf{b}_i)/2\sigma^2) \quad (3)$$

这里 $\mathbf{x} = \{x_H, x_S, x_V\}^T$, $\mathbf{b}_i = \{u_{iH}, u_{iS}, u_{iV}\}^T$ 给出当前像素和第 i 个模式神经元的 HSV 值.考虑到我们用式(3)估计一个 0~1 的概率值,式中省略了高斯函数的归一化因子. $d(\mathbf{x}, \mathbf{b}_i)$ 是 \mathbf{x} 与 \mathbf{b}_i 之间的距离,由下式计算:

$$d(\mathbf{x}, \mathbf{y}) = \left\| (x_1 x_S \cos(x_H), x_1 x_S \sin(x_H), x_V) - (y_1 y_S \cos(y_H), y_1 y_S \sin(y_H), y_V) \right\|_2 \quad (4)$$

σ^2 是一个平滑因子,当 σ 较小时,表示对概率描述粒度较小,单个模式节点所允许的背景变化差异较小,需要更多的节点来描述背景概率;反之,当 σ 较大时,表示概率估计节点的方差较大,对概率描述的粒度较大,允许的背景变化差异较大.

4.2 分类与激活

对于输出层,分类神经元与模式节点构成一个 WTA 子网络,它的输出定义为:

$$O_1 = \begin{cases} 1, & \max\{p_i(B | \mathbf{x})\} \geq \theta_1 \\ 0, & \text{otherwise} \end{cases} \quad (5)$$

$p_i(B | \mathbf{x}) (i = 1, 2, \dots, N)$ 由式(2)计算得到,是模式层神经元的输出乘以先验背景概率.如果分类神经元的输入(模式节点输出乘以权值)大于某个阈值 θ_1 (实验中直观地取 0.5),当前像素被分类为背景(输出‘1’),否则被分类为前景(输出‘0’).

对比一下 Culibrk^[12] 的 BNN 中判断一个像素为背景分类规则为:

$$\sum p_i(B | \mathbf{x}) > \sum p_i(F | \mathbf{x}) \quad (6)$$

考虑到:

$$\sum p_i(F | \mathbf{x}) = \sum p(\mathbf{b}_i | \mathbf{x}) - \sum p_i(B | \mathbf{x}) \quad (7)$$

我们有:

$$\sum p_i(B | \mathbf{x}) > \frac{1}{2} \sum p(\mathbf{b}_i | \mathbf{x}) \quad (8)$$

但我们在实验中发现,如果当前像素属于某个背景像素的概率 $p(\mathbf{b}_i | \mathbf{x})$ 较高,但这一背景像素的先验概率 $p(B | \mathbf{b}_i)$ 并不是很高,或有许多其他背景像素的先验概率较高,会导致最终这一条件无法满足,从而将当前背景像素误判断为前景.

输出层的第二个神经元是一个激活神经元,它也与模式节点构成另一个 WTA 子网络,它的功能是选择模式节点输出的最大值,作为判断网络是否被激活的依据,它的输出为最大值索引或 0:

$$O_2 = \begin{cases} \operatorname{argmax}\{p(\mathbf{b}_i | \mathbf{x})\}, & \max\{p(\mathbf{b}_i | \mathbf{x})\} \geq \theta_2 \\ 0, & \text{otherwise} \end{cases} \quad (9)$$

如果 $\max(p(\mathbf{b}_i | \mathbf{x}))$ 大于某一预先设定的阈值 θ_2 (实验中直观地取 0.5),它的输出为最大值模式节点的索引,否则输出‘0’,表示当前网络没有被激活.这一结果用于指导下一步的网络更新.

4.3 模型更新

经分类节点判断,每个像素被分类为运动区域和背景区域,模型参数根据分类结果进行更新.连接模式节点和分类节点的权重根据下式更新:

$$\begin{cases} w_i^{t+1} = \min(1, w_i^t + \beta^t), & i = i_{\max} \\ w_i^{t+1} = (1 - \frac{\beta^t}{N}) \cdot w_i^t, & \text{otherwise} \end{cases} \quad (10)$$

w_i^t 是第 i 个模式节点在时间 t 时的权重, β^t 是时间 t 时的学习速率, i_{\max} 是激活节点输出的具有最大输出值的模式节点索引号, N 为当前模式层节点个数.

某一个模式被激活时, 激活节点权重增加, 其他所有节点权重减小; 当没有任何一个模式节点被激活时, 所有节点权重减小. 当某一模式节点权重小于某一阈值时, 它将被删除, 以减小计算压力.

当没有任何一个模式节点被激活时, 意味着当前像素值在最近一段时间内在这一位置上没有出现过, 模式节点没有保存它. 因此, 这一点被加入模式层中, 并赋予它的背景先验概率(连接到输出层分类节点的权重)为一较小的初始值(如当前学习速率 β^t). 若当前模式节点数未达到最大允许数, 直接将这一节点加入模式层; 若模式节点数已达到最大允许数目, 则选择背景条件概率最小的节点进行替换.

这一淘汰选择准则也与 BNN 不同, BNN 网络中即计算前景概率又计算背景概率, 选择对分类贡献最小的节点替换. 而我们的模型中只计算背景概率, 选择最不可能是背景的背景节点进行替换.

4.4 自适应学习率调节

网络学习速率是一个非常重要的参数, 偏小的学习速率会导致背景模型对场景的变化适应很慢, 导致在光照突然变化时有较大背景抖动时无法快速适应背景; 偏大的参数又会使慢速运动物体被判断为背景, 并在运动特征中产生空洞. 现有的许多算法(如 Li^[9]、Culibrk^[12]、Maddalena^[13])都是针对不同的视频根据经验或

实验手动设定学习速率, 这严重影响了算法的实用性.

在本文中, 采用了一种自适应的学习速率调节策略. 当背景变化较快(如光照或场景突然变化)、或物体运动速度较快时, 相邻两帧图像中的前景运动像素差异较大, 此时需要增大学习速率. 反之, 当前后两帧的运动区域基本一致时, 说明物体运动速度较慢, 此时需要减小学习速率, 以免将慢速运动物体的内部区域判断为背景而造成空洞现象. 基于这一先验知识, 设计如下的自适应学习率调节规则, 学习率正比于当前帧前景运动区域与前一帧前景运动区域的差异面积:

$$\beta^t = \frac{\Delta n_t}{n} \quad (11)$$

β^t 是 t 时刻的学习速率(不大于 0.5), Δn_t , n 分别为本帧与前一帧运动区域的前景差、总的像素数. 实验表明, 根据这一规则动态调整学习速率可以较好的适应各种场景视频, 无需再为每个视频单独设置学习速率, 而且可以很快地适应突然的光照变化.

5 实验结果

为评价本文所提出的背景模型, 我们在多个公用测试图像序列^[9,15]上进行了测试, 包括不同类型的室外和室内环境, 如校园场景(CAM)、机场(AP)、商场(SC)、餐馆(BR)、地铁站(SS)、会议室(MR)、活动厅(LB), 等等. 图 2 给出 ANNBM、BNN 和 SONN 三种算法在室外序列 CAM 上的运动检测结果比较, 同时给出了原图和手工标注的真实运动区域(Ground Truth). 图 3 给出这三种算法在室内序列 LB 上的运动检测结果比较. 从图中可以看出, 本文算法在无需手工设定学习参数的情况下性能与 BNN 接近. SONN 算法对于运动背景效果较差, 尤其是在存在光照突然变化的 LB 序列中.




图2 室外序列CAM上的运动检测结果示例




图3 室外序列LB上的运动检测结果示例

图 4 给出一些 LB 序列中灯光变化附近的检测结果及相应的帧序号,上排为原始图像,中排为 BNN 检测出的运动区域,下排为 ANNBM 检测出的运动区域.很明

显,与 BNN 相比,ANNBM 可以很快地适应背景的改变,充分显示了自适应学习速率的优越性.




图 4 运动检测相对灯光切换的自适应性

定量的统计评价基于 $Li^{[15]}$ 所给出的人工标注结果,统计自动检测运动区域与人工标注区域的相似性.设 D 是检测到的运动区域, G 是相应帧中的真实运动区域,则两个区域的定量相似性由下式给出:

$$S = \frac{D \cap G}{D \cup G} \quad (12)$$

即两个区域的交集除以两个区域的并集.

表 1 给出了 APBNN、BNN、SONN、MoG、及 $Li^{[9]}$ 等五种算法在 9 个测试序列上的检测相似性比较(视频 SW 序列无法下载,未能进行测试).由于 SC、AP、BR、SS 几个序列中开始处没有明显的无运动背景,不适合于 SONN 算法的训练(实验结果很差),未统计在 SONN 性能评价内.除 SONN 算法外,其他算法数据均为作者发表论文中所提供的数据.

表 1 不同算法在各个测试序列上的相似性比较

序列	BNN	SONN	MoG	$Li^{[9]}$	ANNBM
MR	0.737	0.607	0.445	0.911	0.806
LB	0.628	0.148	0.421	0.706	0.662
CAM	0.526	0.499	0.480	0.683	0.687
SC	0.570	-	0.423	0.645	0.656
AP	0.392	-	0.280	0.508	0.537
BR	0.478	-	0.358	0.564	0.626
SS	0.493	-	0.277	0.534	0.536
WS	0.754	0.774	0.536	0.851	0.880
FT	0.464	0.479	0.663	0.674	0.713
平均	0.560	0.501	0.431	0.675	0.678

从表 1 可以看出,ANNBM 平均性能明显优于 BNN、SONN 和 MoG,略好于 $Li^{[9]}$ 的算法.但考虑到 ANNBM 学习率参数完全自适应得到,无需任何手工设定,从而极大地方便了实际应用,因而优于其他 4 种算法.

更重要的一点是,ANNBM 整体上对各种场景的性能较为稳定.仔细对比 ANNBM 与其他算法的数据可以发现,其他算法即便是手工设定学习率的情况下,在不同视频序列上的性能差异还是比较大的,而 ANNBM 具有更好的一致性.这也说明如果采用固定学习速率,无论如何精心调节也难以达到很好的结果.然而这种推广能力(或称为泛化能力)却是实际应用中非常关心的一个因素.

6 结论

运动检测是视频监控的关键技术之一.本文给出了一种新的基于混合结构神经网络的自适应运动检测背景模型.模型综合了几种不同结构神经网络的特点,具有很强的自适应性,包括动态自适应地调整学习速率、神经网络权重和模式层节点个数.在多个不同场景的视频数据上的大量实验表明,混合结构可以很好地完成特征提取、背景描述、分类、激活和更新等功能,自适应学习速率可以很好的适应背景模型变化、运动物体速度变化等情况.定性和定量的测试结果验证了我们所提出算法的有效性,在无需人工干预的情况下性

能优于常见的 MoG 模型、Li^[9] 的核密度估计模型, 以及其他两种神经网络算法 BNN 和 SONN, 具有较好的实际应用前景. 进一步的研究内容包括如何利用更多的信息设计更好的学习速率自适应策略, 以及设计更为高效的神经网络结构.

参考文献

- [1] W Hu, T Tan, L Wang, S Maybank. A survey on visual surveillance of object motion and behaviors [J]. IEEE Transactions on Systems, Man, and Cybernetics-Part C: Applications and Reviews, 2004, 34(3): 334 – 352.
- [2] R Zhang, S Zhang, S Yu. Moving objects detection method based on brightness distortion and chromaticity distortion [J]. IEEE Transactions on Consumer Electronics, 2007, 53(3): 1177 – 1185.
- [3] 李波, 姚春莲, 李炜, 等. 利用相邻帧和背景信息的运动对象检测[J]. 电子学报, 2008, 36(11): 2154 – 2159.
Li Bo, Yao Chun lian, Li Wei, et al. A novel motion object detection algorithm using adjacent frame and background frame [J]. Acta Electronica Sinica, 2008, 36(11): 2154 – 2159. (in Chinese)
- [4] Y L Tian, M Lu, A Hampapur. Robust and efficient foreground analysis for real-time video surveillance [A]. Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)[C]. San Diego, California, USA, 2005. 1182 – 1187.
- [5] 万成凯, 袁保宗, 苗振江. 一种基于活动轮廓和 Gauss 背景模型的固定摄像机运动目标分割算法[J]. 中国科学 F 辑: 信息科学, 2009, 39(4): 391 – 396.
Wan Cheng-kai, Yuan Bao-zong, Miao Zhen-jiang. A motion object segmentation algorithm for static camera based on active contour and gaussian background model [J]. Science in China Series F: Information Sciences, 2009, 39(4): 391 – 396. (in Chinese)
- [6] 王永忠, 梁彦, 潘泉, 等. 基于自适应混合高斯模型的时空背景建模[J]. 自动化学报, 2009, 35(4): 371 – 378.
Wang Yong-Zhong, Liang Yan, Pan Quan, et al. Spatiotemporal background modeling based on adaptive mixture of gaussians [J]. Acta Automatica Sinica, 2009, 35(4): 371 – 378. (in Chinese)
- [7] T Huang, J Qiu, T Sakayori, et al. Motion detection based on background modeling and performance analysis for outdoor surveillance [A]. 2009 International Conference on Computer modeling and simulation (ICCMS2009) [C]. Macau, China, 2009. 38 – 42.
- [8] 刘鑫, 刘辉, 强振平, 等. 混合高斯模型和帧间差分相融合的自适应背景模型[J]. 中国图象图形学报, 2008, 13(4): 729 – 734.

Liu Xin, Liu Hui, Qiang Zhen-ping, et al. Adaptive background modeling based on mixture gaussian model and frame subtraction [J]. Journal of Image and Graphics, 2008, 13(4): 729 – 734. (in Chinese)

- [9] L Li, W Huang, I Gu, et al. Statistical modeling of complex backgrounds for foreground object detection [J]. IEEE Transactions on Image Processing, 2004, 13(11): 1459 – 1472.
- [10] 贾立好, 邹建华. 基于新的阈值化方法的背景减法改进[J]. 自动化学报, 2009, 35(4): 394 – 400.
Jia Li-Hao, Zou Jian-Hua. Improved background subtraction based on novel thresholding approach, [J]. Acta Automatica Sinica, 2009, 35(4): 394 – 400. (in Chinese)
- [11] J M McHugh, J Konrad, V Saligrama, et al. Foreground-adaptive background subtraction [J]. IEEE Signal Processing Letters, 2009, 16(5): 390 – 393.
- [12] D Culibrk, O Marques, D Socek, et al. Neural network approach to background modeling for video object segmentation [J]. IEEE Transactions on Neural Networks, 2007, 18(6): 1614 – 1627.
- [13] L Maddalena, A Petrosino. A self-organizing approach to background subtraction for visual surveillance applications [J]. IEEE Transactions on Image Processing, 2008, 17(7): 1168 – 1177.
- [14] D Culibrk, V Radenkovic, D Socek. Enhancing video object segmentation results through biologically inspired postprocessing [A]. 8th International Conference on Telecommunications in Modern Satellite, Cable and Broadcasting Services [C]. Serbia, 2007. 329 – 332.
- [15] L Li. Statistical Modeling of Complex Background for Foreground Object Detection [DB/OL]. http://perception.i2r.a-star.edu.sg/bk_model/bk_index.html, 2010-03-29.

作者简介



王志明 男, 1968 年生, 博士, 副教授, 北京科技大学信息工程学院计算机科学与技术系, 主要研究方向包括智能视频监控、图像复原、图像增强等.

E-mail: wangzhiming@ies.ustb.edu.cn

张丽 女, 1970 年生, 教授, 清华大学工程物理系, 主要从事 CT 图像重建方法和图像处理研究.

E-mail: Zli@mail.tsinghua.edu.cn

包宏 女, 1956 年生, 教授, 北京科技大学信息工程学院计算机科学与技术系, 主要研究方向包括计算机图形学、可视化技术、图像处理等. E-mail: baohong@ies.ustb.edu.cn