

用于复杂环境下的疲劳检测系统人眼检测方法^①

孙立书^{1,2}, 朱予川¹

¹(浙江东方职业技术学院 工程技术系, 温州 325011)

²(北京工业大学 地震研究所, 北京 100022)

摘要: 针对光照、眼镜等对驾驶员人眼检测的影响, 提出采用霍夫变换和神经网络分类器进行人眼检测. 通过应用虹膜几何信息和对称性, 选择可能包含人眼的两个候选区域. 运用边缘检测算子和 MAE 进行人眼粗定位. 然后在此基础上采用 B-P 神经网络进行人眼精确定位. 针对三种不同情况, 即不同光照、不同背景和不同肤色的人拍摄 6 组视频图像, 采用 matlab7.0 进行 3 组仿真实验, 实验结果表明该算法对复杂情况的人眼检测具有较强的鲁棒性. 大大提高人眼检测准确率.

关键词: 霍夫变换; 神经网络; 边缘检测算子; 虹膜检测; 人眼检测

Eye Detection Method for Fatigue Detection System under Complex Environment

SUN Li-Shu^{1,2}, ZHU Yu-Chuan¹

¹(Zhejiang Dongfang Vocation and Technical College, Engineering Department, Wenzhou 325011, China)

²(Beijing University of Technology Institute of Earthquake, Beijing 100022, China)

Abstract: This paper focuses on the effects of light condition, glass-wearing on driver's eye, and proposes a way of human eye detection by Hough transform and neural network classifier. Firstly, two eye candidate regions were selected based on the geometry and symmetry of the iris. Then, coarse human eye positioning is conducted by edge detection and MAE operator. At last, the B-P neural network was utilized to pinpoint the human eye. For six groups of video images captured in three different situations, that is, different light, different backgrounds and different skin color, three groups were performed simulation experiment using matlab7.0. Results show that the algorithm for complex situations human eye detection has a strong robustness, improve the accuracy of eye detection greatly.

Key words: Hough transform; neural network; edge detection operator; iris detection; eye detection

1 引言

驾驶员人眼检测对判断驾驶员疲劳或瞌睡是非常重要的, 如果这些行为能被及时检测并给予警告, 可以有效避免大量死亡事故发生. 文献[1-3]报道很多人试图开发安全系统以减少道路交通事故. 这些系统主要是通过监测车道保持距离、车轮转向运动、加速度、刹车和齿轮变化来检测驾驶员的驾驶行为^[1]. 其次是通过跟踪驾驶员头部和眼部运动, 监测心跳、呼吸频率以及大脑的活动^[2], 或者通过识别手臂和腿部运动

来检测驾驶员的驾驶行为^[3]. 大量实验表明, 人眼闭合百分比^[4,5] (Perclos)可以有效地判断驾驶员是否疲劳. 然而, 用于检测驾驶员疲劳驾驶的大部分图片都面临光照变化的问题或者司机戴眼镜的情况. 针对这种情况, 采用上述方法, 驾驶员疲劳检测效果不是很好, 检测准确率最高达到 85%左右^[6-8]. 基于这种原因, 提出一种新型方法用以实现复杂环境下的人眼检测. 首先, 对采集的驾驶员视频图像进行人脸检测; 其次完成人眼检测和定位; 最后采用 Perclos 理论进行

① 基金项目:2013 年浙江省教育厅科研项目(Y201330164);2013 年温州市科技局科技计划(2013G0020);2013 年浙江省高等教育课堂教学改革研究项目(kg2013851);2013 年浙江省大学生科技创新项目(2013R455001)

收稿时间:2014-03-29;收到修改稿时间:2014-04-29

疲劳检测.

2 人眼检测

人眼检测包含 3 步. 首先, 虹膜检测, 将改进的 Hough 变换应用到整个图像去检测可能包含人眼的候选区域; 然后在有限的区域里搜索对称区域; 最后, 应用神经网络分类器验证图像中存在人眼. 若人眼被正确找到, 他们的位置被应用在连续的图像中, 限定虹膜检测算法的搜索范围. 下面就是具体的检测步骤.

2.1 虹膜检测

人眼很容易在图像中定位, 因为虹膜比巩膜颜色深. 这样, 虹膜边缘很容易用一个圆检测出来. 但是圆的直径不是固定值, 因为每个人的虹膜尺寸是不同的, 基于这种原因, 不得不调整驾驶员和摄像机之间的距离, 使虹膜半径在 $[R_{min}, R_{max}]$ 区间变化. 采用圆检测算子进行虹膜边缘检测, 当半径在 $[R_{min}, R_{max}]$ 区间变化的圆被检测出来, 通过算子可以产生一个最大值. 如下所示:

$$u(x,y) = \frac{\iint_{D(x,y)} g(\alpha,\beta) o(\alpha-x, \beta-y) d\alpha d\beta}{2\pi(R_{max} - R_{min})} \quad (1)$$

$D(x,y)$ 被定义为:

$$D(x,y) = \{(\alpha,\beta) \in R \times R | R_{min}^2 \leq (\alpha-x)^2 + (\beta-y)^2 \leq R_{max}^2\} \quad (2)$$

g 是梯度向量.

$$g(x,y) = \left[\frac{\partial}{\partial x} I(x,y), \frac{\partial}{\partial y} I(x,y) \right]^T \quad (3)$$

O 是核向量,

$$O(x,y) = \left[\frac{\cos(\arctan(y/x))}{\sqrt{x^2+y^2}}, \frac{\sin(\arctan(y/x))}{\sqrt{x^2+y^2}} \right]^T \quad (4)$$

核向量包含归一化因子, 该因子在分母上, 代表每一点到核中心的距离. 归一化的目的是要使不同半径的圆找到的时候(半径在 $[R_{min}, R_{max}]$ 区间变化)使算子在积分空间具有相同的值. 除此之外, 归一化能确保获得卷积结果的峰值, 满足最合适的圆而不是环(直径)最大的圆. 圆检测算子应用于整个图像, 该图像是在简单的背景下含没有任何约束或限制的眼睛区域. 结果最大值代表最有可能包含人眼的候选区域. 原始图像卷积之后的结果如图 1 所示. 峰值可以在人眼周围区域获得, 也可以在人眼的其它区域获得.



(a)原始灰度图像 (b)卷积结果

图 1 原始图像卷积之后的结果

2.2 寻找对称区域和相关性

通过第一次获得的最大值, 可以确定包含一只人眼的候选区域. 从这里开始到两个相反的区域搜索第二只人眼. 两个区域之间的距离满足瞳孔之间的距离. 令 (x_1, y_1) 为第一次获得的最大值的中心点, (x_2, y_2) 为第二只人眼所在区域 $D(x, y)$ 的一点. (x_2, y_2) 满足如下条件:

$$D(x, y) = \{(x_2, y_2) | x_2 = x_1 \pm d, y_2 = \tan \alpha(x_2 - x_1) + y_1\} \quad (5)$$

这里 $d \in [d_1, d_2]$, $\alpha \in [-\pi/6, \pi/6]$

搜索第二只眼睛的步骤如下:

- 1) 搜索整个图像卷积输出的最大值 M_1 .
- 2) 在含有第二只人眼的候选区域 D 里搜索最大值 M_2 , D 区域的定义如下:

$$D(x, y) = \{(x_2, y_2) | x_2 = x_1 \pm d, y_2 = \tan \alpha(x_2 - x_1) + y_1\}$$

- 3) 应用 MAE 比较 M_1 和 M_2 . 若

$MAE(M_1, M_2) < Threshold$, 那么 M_1, M_2 就是找到的两个人眼位置. 否则, $M_1=0$. 重复第一步.

$$MAE = \frac{\sum_{i=1}^N \sum_{j=1}^M |a_{ij} - b_{i(M-j+1)}|}{N \cdot M} \quad (6)$$

这样, 采用这种算法, 就会将人头发区域或人脸的其它区域, 如鼻子、嘴等去除掉. 因为它们之间的距离和人眼之间的距离是不一致的. 有许多不同的相似性测量方法, 这里选取计算量最小的平均绝对值误差测量方法, 其表达式如(6). 在这里 a 和 b 代表这两个区域中的点, 区域大小是 $N \times M$ 维的. 如果相似性测量的结果在一定阈值以下, 这两个区域被认为是最匹配的人眼候选区域. 否则, 恢复到第一步, 继续进行搜索. 检测结果严格依赖于检测区域的大小, 检测区域越小, 检测错误率越高. 直观上可以发现, 在人脸图像上, 两个相似的圆形区域可以找到. 如卷曲的头发, 嘴的两侧还有前额等等. 然而, 如果这两个相似的圆形区域比第一步里找到的圆形区域大得越多的话, 那

么找到错误匹配的概率就越高. 实验表明, 许多错误的候选区域可以去除掉, 因为它们之间的相似性不满足一定的阈值. 阈值可以通过先前知道的人眼区域相似性来进行估计选择. 除此之外, 实验结果已经证明, 在均匀光照的条件下, 相似性检测的准确率几乎是 100%. 但是, 在通常情况下, 都是部分光线照射在人脸, 这种情况, 相似性检测准确率不足 100%. 针对这种情况, 可以在两个区域引入归一化程序, 减去像素密度平均值, 然后进行相似性测量, 这样实验结果将不受光照的影响.

2.3 改进 BP 神经网络确定人眼

在包含人眼的候选区域确定之后, 接下来, 采用改进 BP 神经网络进行人眼的精确定位. 主要原因是传统的 BP 神经网络算法存在一些自身的限制与不足, 如需要较长的训练时间、会收敛于局部极小值等, 使得传统 BP 算法在实际人眼识别应用中并不能胜任. 这里对传统 BP 算法进行了下列两步改进.

2.3.1 传统的 BP 神经网络

传统的 BP 神经网络是根据 Widrow—Hoff 规则, 采用梯度下降算法, 在非线性多层网络中, 反向传播计算梯度, 采用 BP 算法的多层前馈网络. 其包含输入层、隐含层和输出层三层网络. 其中, 三层前馈网中,

$$\text{输入向量为: } X=(\chi_1, \chi_2, \dots, \chi_j, \dots, \chi_n)^T \quad (7)$$

隐含输出向量为:

$$Y=(y_1, y_2, \dots, y_j, \dots, y_m)^T \quad (8)$$

输出层输出向量为:

$$O=(o_1, o_2, \dots, o_k, \dots, o_l)^T \quad (9)$$

期望输出向量为:

$$d=(d_1, d_2, \dots, d_k, \dots, d_l)^T \quad (10)$$

输入层到隐含层之间的权值矩阵用 V 表示,

$$V=(V_1, V_2, \dots, V_j, \dots, V_m) \quad (11)$$

其中列向量 V_j 为隐层第 j 个神经元对应的权向量; 隐含层到输出层之间的权值、矩阵用 W 表示, $W=(W_1, W_2, \dots, W_k, \dots, W_l)$, 其中, 列向量 W_k 为输出层第 k 个神经元对应的权向量. 三层 BP 神经网络结构图如图 2 所示.

该算法的前向过程为: 输入信号 x 从输入层进入后, 通过隐层各节点的内星权向量 V_j 得到该层的输

出信号 Y , 该信号向前输入到输出层, 通过其各节点




图 2 三层 BP 神经网络结构图

内星权向量 W_k 得到该层输出 O , 反向过程是: 在输出层期望输出 d 与实际输出 O 相比较得到误差信号. 对于输出层, 有:

$$O_k = f(net_k), k=1,2,\dots,n \quad (12)$$

$$net_k = \sum_{j=0}^n w_{jk} y_j, k=1,2,\dots,n \quad (13)$$

对于隐含层, 有:

$$y_j = f(net_j), j=1,2,\dots,n \quad (14)$$

$$net_j = \sum_{i=0}^n v_{ij} x_i, j=1,2,\dots,n \quad (15)$$

以上两式中, 转移函数均为单极性 Sigmoid 函数:

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (16)$$

若任意设置初始权值, 那么对每个输入模式 P , 当网络输出与期望输出不等时, 存在输出误差 E , 定义如下:

$$E_p = \frac{1}{2} (d - O)^2 = \frac{1}{2} \sum_{k=1}^n (d_k - O_k)^2 \quad (17)$$

进一步展开至输入层, 有

$$E = \frac{1}{2} \sum_{k=1}^n \left\{ d_k - f \left[\sum_{j=0}^n w_{jk} f \left(\sum_{i=0}^n v_{ij} x_i \right) \right] \right\}^2 \quad (18)$$

由上式可以看出, 网络输入误差是各层权值的函数, 因此调整权值可以改变误差 E , 调整权值的原则是使误差不断地减小, 因此应使权值的调整量与误差的负梯度成正比, 即

$$\Delta w_{jk} = \eta \delta_k^o y_j \quad j=0,1,2,\dots,m; \quad k=0,1,2,\dots,l \quad (19)$$

$$\Delta v_{ij} = -\eta \delta_j^y x_i \quad i = 0, 1, 2, \dots, n; \quad j = 0, 1, 2, \dots, m \quad (20)$$

$$\delta_k^o = -\frac{\partial E}{\partial net_k} = (d_k - o_k) o_k (1 - o_k) \quad (21)$$

$$\delta_j^y = -\frac{\partial E}{\partial net_j} = \left(\sum_{k=1}^l \delta_k^o w_{jk} \right) y_j (1 - y_j) \quad (22)$$

式中负号表示梯度下降, 常数 $\eta \in (0, 1)$ 表示比例系数, 在训练中反映了学习速率. 从上面的推导中可以看出, 在计算具有隐层的前馈多层神经网络的训练误差 δ_{kj} 时, 先从输出层开始计算, 逐层向前进行. 该算法采用梯度下降法把一组样本的输入/输出问题变为一个非线性优化问题. 采用迭代运算求解权值, 相当于神经网络的学习记忆问题. 通过增加隐含层神经单元可调参数使问题得到优化, 从而得到更精确的解.

2.3.2 改进的 BP 神经网络算法

传统的 BP 神经网络算法进行人眼检测与识别, 但是传统的 BP 算法存在一些自身的限制与不足, 使得传统 BP 算法在实际人眼识别中并不能胜任. 因此需要对该算法进行改进.

1) 对转移函数引入陡度因子

一般来说, BP 网络的隐含层转移函数采用 Sigmoid 函数, 如式(16)所示, Sigmoid 函数用于将神经元的输入范围 $(-\infty, +\infty)$ 映射到 $(0, 1)$, 在实际训练时在转移函数中引入了一个陡度因子 λ , 使得转移函数如下式所示.

$$f(x) = \frac{1}{1 + \exp(-x/\lambda)} \quad (23)$$

期望输出减去实际输出较大时, 可令 $\lambda > 1$, 在其它情况, $\lambda = 1$, 陡度因子的引入从理论上可以减少训练的次数.

(2) 由 RPROP 算法对 BP 网络进行权更新

RPROP 算法的基本原理为: 首先为各权重变化赋一个初始值, 设定权重变化加速因子与减速因子, 在网络前馈迭代中当连续误差符号不变时, 采用加速策略, 加快训练速度; 当连续误差梯度符号变化时, 采用减速策略, 以期稳定收敛, 网络结合当前误差梯度符号与变化步长实现 BP.

设 t 为迭代次数, $\Delta_{ij}^{(0)}$ 为网络可变参数调整量的幅值, $\partial E^{(0)} / \partial W_{ij}$ 为网络可变参数网络误差的一阶偏导数, $\Delta W_{ij}^{(0)}$ 为网络可变参数的调整量. Δ_{ij} 的调整如下式所示:

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ * \Delta_{ij}^{(t-1)}, & \text{如果 } \frac{\partial E^{(t-1)}}{\partial W_{ij}} * \frac{\partial E^{(t)}}{\partial W_{ij}} > 0 \\ \eta^- + \Delta_{ij}^{(t-1)}, & \text{如果 } \frac{\partial E^{(t-1)}}{\partial W_{ij}} * \frac{\partial E^{(t)}}{\partial W_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{其他} \end{cases} \quad (24)$$

式中, η^+ 通常取 1.2; η^- 通常取 0.5. 在计算出 Δ_{ij} 后, 可用下式计算出可变参数的调整量(权值调整量):

$$\Delta W_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t)}, & \text{如果 } \frac{\partial E^{(t)}}{\partial W_{ij}} > 0 \text{ 并且 } \frac{\partial E^{(t-1)}}{\partial W_{ij}} * \frac{\partial E^{(t)}}{\partial W_{ij}} \geq 0 \\ +\Delta_{ij}^{(t)}, & \text{如果 } \frac{\partial E^{(t)}}{\partial W_{ij}} < 0 \text{ 并且 } \frac{\partial E^{(t-1)}}{\partial W_{ij}} * \frac{\partial E^{(t)}}{\partial W_{ij}} \geq 0 \\ -\Delta W_{ij}^{(t-1)}, & \frac{\partial E^{(t-1)}}{\partial W_{ij}} * \frac{\partial E^{(t)}}{\partial W_{ij}} < 0 \\ 0, & \text{其它} \end{cases} \quad (25)$$

网络的可变参数即权值用下式调整:

$$W_{ij}^{(t+1)} = W_{ij}^{(t)} + \Delta W_{ij}^{(t)} \quad (26)$$

3 实验过程及结果分析

实验中把人眼图像经三级小波变换后的系数的数量作为 BP 神经网络输入层神经元的个数. 将含有人眼检测结果的子图像作为神经网络训练器的输入, 把图像分为含有人眼和不含有人眼两种. 应用改进 BP 神经网络的主要原因是它能满足于实时性. 实时性要求特征提取算法能够在系数集里储存所有必要信息. 采用分类算法, 利用系数集, 在最短的时间内找到正确答案. 为完成这一目标, 采用离散小波变换对图像进行分解, 分为两个步骤, 一个是频率域的低通滤波(相似滤波), 一个是频率域的补充滤波(详细滤波). 在每一步, 小波变换把图像分解为四个子图像. 图 3 显示 3 级小波变换的结果, 子图像上的字母代表应用在前一级图像上的滤波种类, H 代表高通滤波, L 代表低通滤波. 第一个字母代表水平方向上的滤波, 第二个字母代表垂直方向上的滤波. LL 带代表图像的低频部分-(和原始图像相似), LH 和 HL 记录图像水平方向和垂直方向的变化. HH 代表图像的高频部分. LL 子带上的分解能被叠加. 经 3 级小波变换以后, 图像被分解为不同频率域的子带. 由于 Haar 滤波的单一性, Haar 滤波被用于小波变换. 小波变换后的系数含有大量的图像中物体的纹理和形状等信息, 采用这种方式区别

人眼. 人眼图像 3 级小波变换的结果如图 5 所示. 选择小波变换后的系数, 因为它含有主要的形状和纹理信息. 提取的特征点的数量近似等于原始图像像素总数的 1/16. 用改进的 BP 算法进行训练, 输入层节点的数量等于三级小波变换后的系数的数量, 即 $L=50$, 输出层节点数 $n=1$. 隐含层节点数目 m 根据公式(27)估算, 求得 $m=80$.




图 3 三级小波变换图像分解示意图




图 4 人眼原始图像





图 5 人眼小波变换图像

$$m = \begin{cases} L + 0.618 \times (L - n) & L \geq n \\ L - 0.618 \times (n - L) & L < n \end{cases} \quad (27)$$

式中 m 为隐含层节点数, n 为输出层节点数, L 为输入节点数. 神经网络参数依据经验值选取, 使人眼检测率方面达到最好的效果. 在学习阶段, 依据梯度下降原则权值不断更新, $\sigma=0.1$, $\eta=0.5$. 将许多不同人

的含有人眼和不含有人眼的图像作为神经网络的输入去训练分类器. 最初, 在训练阶段, 神经网络只运行一次. 在验证阶段, 采用同一神经网络, 对不同人在不同光照条件下(和训练阶段的人不同)识别人眼是否存在. 采用 BP 神经网络检测图像中人眼是否存在, 并且针对不同光照条件进行 2 组实验. 第一组实验是在均匀光照下通过摄像头拍摄 50 幅图像, 30 幅用于神经网络训练, 20 幅用于测试人眼检测算法. 人眼神经网络的样本库中正确样本数为 60, 错误样本数为 70, 经过 BP 神经网络的权值训练, 实验结果是对 18 幅均能正确检测. 检测准确率为 90%. 部分实验结果如图 5 所示. 第二组实验是在部分光照下通过摄像头拍摄 50 幅图像, 30 幅用于神经网络训练, 20 幅用于测试人眼检测算法. 人眼神经网络的样本库中正确样本数为 60, 错误样本数为 70, 经过 BP 神经网络的权值训练, 实验结果是对 17 幅均能正确检测. 检测准确率达到 85%. 部分实验结果如图 6(a)和(b)所示.



(a) 神经网络训练阶段所需正片



(b) 神经网络训练阶段所需负片

图 6 部分实验结果图

4 人眼检测结果

为了评价该算法对人眼检测的效果, 针对 2 组人, 一共做了 3 组实验, 前两组实验是在实验室进行的. 第一组是使用分辨率为 720*575, 30 帧/s 的照相机进行

拍摄图片,是在均匀光照情况下做的.第二组实验是采用同样的图片,是在部分光照的情况下做的.第三组是在车上用分辨率为 320*240, 15 帧/s 的网络摄像头拍摄的图片.因为实验是采用 2 组不同分辨率的图像,因此要进行 2 个不同的神经网络训练阶段.第一组图像,每张图像的大小是 61*61 个像素.将拍摄的前三个人的图像用于神经网络分类器训练,训练集含有 452 张负片(不含人眼的图像), 291 张正片(含有人眼的图像).如图 6 所示,第一行是含有人眼的样本,第二行是人脸的其它部分图片,不含有眼眼的样本.第二组图像,每张图像的大小是 30*30 个像素,将拍摄的前三个人的图像用于神经网络分类器训练,训练集含有 30 张负片(不含人眼的图像), 85 张正片(含有人眼的图像).三组实验的人眼检测结果如图 7-9 所示.测试图像包含三种情况,人眼睁开的情况、人眼部分睁开的情况、不含有人眼的情况(人眼闭合或人转头的情况).表 1-3 是三种不同情况下的人眼检测结果.测试图像分为三组:人眼完全睁开、人眼部分睁开(眼睑覆盖部分虹膜)和不含有人眼(人眼完全闭合或者是头部发生偏转)的图像.表中的第一列列出了每一个人用于实验的图片数量.每行列出了不同人测试图像的检测率.其中三组图像的检测率按照 TP(人眼睁开,算法能正确识别人眼百分比)FP(在错误区域错误识别人眼的百分比)FN(不能识别人眼的百分比)和 TN 列出来.其中对于不含有人眼的情况, TN 代表算法能正确识别不含有人眼的百分比.表的最后一行代表的总的检测率.*代表用于神经网络训练的人.

例如表 2 当中的第四个人,共有 368 张图片用于实验,其中人眼全部睁开的有 302 张,人眼部分睁开的有 39 张,不含有人眼的有 27 张,正确检测到人眼全部睁开的有 295 张,即 $TP=295/302=97.7\%$.在错误区域错误地检测到人眼全部睁开的有 2 张,即 $FP=2/302=0.6\%$.没能检测到人眼全部睁开的有 5 张,即 $FN=5/302=1.7\%$.正确检测到人眼部分睁开的有 36 张,即 $TP=92.3\%$.在错误区域错误地检测到人眼部分睁开的有 2 张,即 $FP=5.1\%$.没能检测出人眼部分睁开的有 1 张,即 $FN=2.6\%$.正确检测到不含有人眼的图片有 26 张,即 $TN=96.3\%$,没能检测出人眼不存在的图片有 1 张,即 $FN=3.7\%$.

如表 1-3 所示,人眼部分睁开的检测率为 90% 多一

点,这种情况发生在人眼正在闭合或者人脸被某种物品遮挡.该值不是很高,可能是因为瞳孔检测和神经网络分类器失效.如果他们的轮廓不完整,圆形检测算法不能识别瞳孔.人眼部分可见的检测结果如图 10 所示.



图 7 均匀光照下的人眼检测结果




图 8 部分光照下的人眼检测结果



图 9 驾驶员人眼检测结果



图 10 人眼部分可见的正确检测结果

表 1 均匀光照下的人眼检测结果

	人眼睁开			人眼部分睁开			无人眼	
	TP	FP	FN	TP	FP	FN	TN	FN
第一人*(%)	100	0	0	50	0	50	95	5
(95)	(73/73)	(0/73)	(0/73)	(1/2)	(0/2)	(1/2)	(19/20)	(1/20)
第二人*(%)	100	0	0	75	0	25	100	0
(235)	(210/210)	(0/210)	(0/210)	(3/4)	(0/4)	(1/4)	(21/21)	(0/21)
第三人*(%)	97.1	0.2	2.7	90	10	0	90	10
(454)	(402/414)	(1/414)	(11/414)	(9/10)	(1/10)	(0/10)	(27/30)	(3/30)
第四人(%)	97.7	0.6	1.7	92.3	5.1	2.6	96.3	3.7
(368)	(295/302)	(2/302)	(5/302)	(36/39)	(2/39)	(1/39)	(26/27)	(1/27)
第五人(%)	100	0	0	100	0	0	100	0
(266)	(235/235)	(0/235)	(0/235)	(14/14)	(0/14)	(0/14)	(17/17)	(0/17)
第六人(%)	98	1	1	91	0	9	89	11
(153)	(94/96)	(1/96)	(1/96)	(20/22)	(0/22)	(2/22)	(31/35)	(4/35)

表 2 不均匀光照下的人眼检测结果

	人眼睁开			人眼部分睁开			无人眼	
	TP	FP	FN	TP	FP	FN	TN	FN
第三人*(%)	97.5	0	2.5	91	3.7	5.3	97	3
(465)	(341/350)	(0/350)	(9/350)	(48/53)	(2/53)	(3/53)	(69/71)	(2/71)
第四人(%)	98.3	0.1	1.6	93.8	0	6.1	97	3
(845)	(702/715)	(1/715)	(12/715)	(92/98)	(0/98)	(6/98)	(31/32)	(1/32)
第六人(%)	81.5	9.5	9	85.8	2.8	11.4	89	11
(210)	(128/157)	(15/157)	(14/157)	(30/35)	(1/35)	(4/35)	(16/18)	(2/18)
第七人(%)	92	1	7	81.3	6.3	12.4	95	5
(135)	(90/98)	(1/98)	(7/98)	(13/16)	(1/16)	(2/16)	(20/21)	(1/21)
检测率(%)	95.5	1.3	3.2	90.6	2	7.4	95.7	4.3

表 3 驾驶员人眼检测结果

	人眼睁开			人眼部分睁开			无人眼	
	TP	FP	FN	TP	FP	FN	TN	FN
第一人*(%)	97	0.5	2.5	89.8	3.9	6.3	94.3	5.7
(1024)	(785/809)	(3/809)	(21/809)	(115/128)	(5/128)	(8/128)	(82/87)	(5/87)
第二人*(%)	97.8	0	2.2	93.8	0	6.2	100	0
(1082)	(794/812)	(0/812)	(18/812)	(183/195)	(0/195)	(12/195)	(75/75)	(0/75)
第三人*(%)	98	0.5	1.5	94.4	2.8	2.8	96	4
(1276)	(848/865)	(4/865)	(13/865)	(201/213)	(6/213)	(6/213)	(190/198)	(8/198)
第四人(%)	85.5	0	14.5	87.4	1.0	11.6	98.5	1.5
(913)	(641/750)	(1/750)	(108/750)	(83/95)	(1/95)	(11/95)	(67/68)	(1/68)
第五人(%)	98.7	0	1.3	94.8	3.4	1.8	96.2	3.8
(937)	(597/605)	(0/605)	(8/605)	(165/174)	(6/174)	(3/174)	(152/158)	(6/158)
第六人(%)	92.3	0	7.7	90.1	7.7	2.2	95.8	4.2
(847)	(610/661)	(0/661)	(51/661)	(82/91)	(7/91)	(2/91)	(91/95)	(4/95)
检测率(%)	95.0	0.2	4.8	92.5	2.8	4.7	96.5	3.5

5 结语

红外照明方法被广泛用于人眼检测,而且该方法在可控的光照条件下鲁棒性能好。然而,该方法在光照较强或戴眼镜的情况下检测效果不好。对于这种情况,将采集的视频图像,采用改进的人眼检测算法,进行人眼检测。它主要分为三步。首先,将采集的视频图像用改进的 Hough 变换检测可能包含人眼的候选区域。其次,通过区域对称性和人眼相关性粗定位人眼位置;最后通过神经网络算法精确定位人眼。并针对 3 种不同情况,即不同的光照、不同肤色和不同背景的人做了三组实验,人眼检测率达到 90% 以上。该结果表明,改进的人眼检测算法对于光照和戴眼镜等复杂情况具有较强的鲁棒性,且提高了人眼检测正确率和可靠性。

参考文献

- 1 Torrkola K, Massey N, Wood C. Driver inattention detection through intelligent analysis of readily available sensors. Proc. of IEEE Conference on Intelligent Transportation Systems. Washington, DC. October 2004. 326–331.
- 2 Yang G, Lin Y, Bhattacharya P. A driver fatigue recognition model using fusion of multiple features. IEEE International Conference on Systems, Man and Cybernetics. Hawaii USA. October 2005. 1777–1784.
- 3 Park S, Trivedi M. Driver activity analysis for intelligent vehicles: issues and development framework. Proc. of IEEE Intelligent Vehicles Symposium. Las Vegas, USA. June 2005. 795–800.
- 4 D’Orazio T, Guaragnella C, Leo M, Distante A. A new algorithm for ball recognition using circle Hough transform and neural classifier. Pattern Recognition, 2004, 37: 393–408.
- 5 Flores MJ, Armingol JM, de la Escalera A. Driver drowsiness warning system using visual information for both diurnal and nocturnal illumination Conditions. EURASIP Journal on Advances in Signal Processing, 2010, Article ID 438205.
- 6 李智,谢剑斌,等.基于 Adaboost 的红外视频图像疲劳检测算法.计算机工程与科学,2012,34(5):107–111.
- 7 陈勇,黄琦,等.一种全天候驾驶员疲劳检测方法研究.仪器仪表学报,2009,30(3):636–640.
- 8 鲁松,乔陆.驾驶员疲劳状态检测仿真研究.计算机仿真,2012,29(11):378–381.