DOI: 10.3901/JME.2019.02.018

基于面部几何特征及手部运动特征的 驾驶员疲劳检测^{*}

刘明周 蒋倩男 扈 静

(合肥工业大学机械工程学院 合肥 230009)

摘要: 驾驶员疲劳驾驶是造成交通事故的主要原因之一,为解决该问题,提出一种新的基于机器视觉的驾驶员疲劳状态检测方法。根据驾驶员视频图像特点,采用基于肤色检测的 Adaboost 算法提取面部以及手部的感兴趣区域(Regions of interest, ROIs)。基于尺度不变特征变换(Scale invariant feature transform, SIFT)特征点匹配获取眼、嘴以及手部的 SIFT 特征点,据此得出面部以及手部特征参数。将 Perclos、MClosed、Phdown 以及 SA 4 个特征参数作为模型输入,疲劳度等级作为模型输出,建立三层 BP 神经网络模型,并应用贝叶斯正则化并结合动量梯度下降法较好地解决了传统 BP 神经网络训练高精度和预测低精度的过拟合现象。试验数据表明,该方法能够克服光照、背景、角度以及个体差异的影响,且疲劳检测的正确识别率达到 99.64%。

关键词: 驾驶疲劳; 机器视觉; SIFT 特征点匹配; 肤色检测; BP 神经网络

中图分类号: TP391

Based on Facial Geometric Features and Hand Motion Characteristics Driver Fatigue Detection

LIU Mingzhou JIANG Qiannan HU Jing

(School of Mechanical and Automotive Engineering, Hefei University of Technology, Hefei 230009)

Abstract: Fatigue driving is one of the major causes of traffic accidents. In order to solve the problem, a new method based on machine vision for driver fatigue detection is proposed. According to the characteristics of the driver's video image, the regions of interest (ROIs) of face and hand are extracted by the Adaboost algorithm based on skin color detection. Based on SIFT (scale invariant feature transform) feature points matching, the SIFT feature points of the eye, mouth and hand are extracted, and the facial and hand feature parameters are obtained. The 4 characteristic parameters of Perclos, MClosed, Phdown and SA are used as model inputs, and the fatigue grade is used as model output. Three layer BP neural network model is established. The Bayesian regularization and the momentum gradient descent method are used to solve the overfitting phenomena of the traditional BP neural network training with high accuracy and low prediction accuracy. The experimental data show that the method can overcome the influence of illumination, background, angle and individual difference, and the correct recognition rate of fatigue detection is 99.64%.

Key words: driving fatigue; machine vision; SIFT feature point matching; skin color detection; BP artificial neural network

0 前言

驾驶员疲劳是公认的导致严重受伤或死亡的车祸的主要原因^[1]。因疲劳驾车造成的交通事故占总数的 20% 左右, 占特大交通事故的 40% 以上^[2]。据有关研究表明, 若在交通事故发生前一秒钟向驾驶员发出警报, 则可避免 90% 的类似交通事故^[3], 因

此, 运用车载传感器实时检测驾驶员的疲劳状态, 可以降低交通事故的频率。

现有的驾驶员疲劳检测方法众多, 本文将其总结为以下三个方面。基于驾驶员生理信号的检测(如心电信号、脑电信号以及肌电信号等)、基于车辆状态的检测(如车速、车辆位置、方向盘转动角度等)以及基于驾驶员行为特性的检测(如司机的动作、眼睛的闭合状态、面部表情、眨眼速度或持续时间等)。LIN 等^[4]检测驾驶员脑电图, 并提取脑电信号(Electro-encephalogram, EEG)中代表性 ICA 特征,

^{*} 国家自然科学基金资助项目(51375134)。20170913 收到初稿, 20180619 收到修改稿

将 ICA 作为特征矢量构建模糊神经网络模型, 最终实现驾驶员的疲劳预测。HAYASHI 等^[5]一方面利用生理信号测量仪获得驾驶员的多个生理信号, 提取其中的 Lyapunov 指数、交感神经活动以及脉搏次数等特征, 另一方面基于 Epworth 获取驾驶员的精神状态值, 基于以上两类特征矢量构建用于实现驾驶员疲劳评价的神经网络模型。TAKEI 等^[6]基于车辆状态对驾驶员的疲劳进行检测, 利用传感器获得转向过程中车辆的转向角信号, 通过小波变换以及傅里叶变换处理上述信号, 进而获取准确的转向角信息, 实现驾驶员疲劳状态的实时检测。POMERLEAU^[7]获取车辆前方道路的图像信息, 基于模板匹配的方法得出图像中车辆偏离行驶中线的程度, 依据偏离程度推测驾驶员的疲劳情况。WANG 等^[8]通过驾驶员的嘴部状态来检测疲劳, 基于卡尔曼滤波对图片中嘴部区域进行定位, 进而获得嘴巴高度、宽度以及唇间距离, 并将其作为特征矢量, 结合 BP 神经网络模型实现嘴巴状态的分类。

由于生理信号能够直接反应人体的生理状态, 基于驾驶员生理信号的疲劳检测被认为是最直观、最准确的检测方法。但是在获取驾驶员生理信号时, 生理传感器与驾驶员之间一般存在接触, 不仅会对驾驶员造成心理负担, 影响生理信号的准确性, 而

且还会给驾驶员的操作带来不便, 不利于驾驶安全, 且成本高。车辆状态检测法的优点是非接触检测, 信号容易提取, 可直接反映车辆行驶状态的安全性。缺点是当车型、行驶道路以及驾驶员发生变化时, 其疲劳检测的标准也会发生改变, 不具有普适性。基于驾驶员行为特性的疲劳检测法不仅具有非接触性, 而且驾驶员行为特性能够直接反应驾驶员的疲劳状态, 但检测算法的设计对检测的鲁棒性以及实时性影响较大, 因此基于驾驶员行为特性的疲劳检测算法的设计成为目前研究的热点。

为了解决基于单一特征检测算法的准确率和鲁棒性差的问题, 本文提出了一种基于面部特征以及手部运动特征的驾驶员疲劳融合检测算法, 该算法提取眼部和嘴部的特征参数以及手部的运动特征参数, 并将特征参数输入到基于 BP 神经网络构建的特征参数分类器, 综合判断驾驶员的疲劳状态, 从而使得该算法在背景、角度、光照以及驾驶员存在差异的情况下能够实时、准确、高鲁棒性检测驾驶员的疲劳状态。

1 方法

本文的驾驶疲劳检测算法流程如图 1 所示。

图 1 驾驶疲劳检测算法流程

1.1 人脸及人手检测

人脸及人手检测是进行面部特征及手部运动特征提取的基础。在人脸检测算法中,依照时间顺序的发展有模板匹配模型,肤色模型、ANN 模型、SVM 模型、Adaboost 模型^[9-10]等。其中 Adaboost 模型在速度与精度的综合性能上表现最好,基本上可以达到视频流实时的检测效果,因此被广泛应用于感兴趣区域(Regions of interest, ROIs)检测与识别中。本文首先将图像帧从原来的色彩空间变换到 YCbCr 色彩空间,基于肤色模型分割肤色区域与非肤色区域,获得多个连通区域,再对连通区域进行闭运算填充空洞,最终依据形状特征提取脸部候选区域以及手部候选区域,脸部候选区域以及手部候选区域分别如图 2、3 所示。

在获取候选区域后,将 Adaboost 算法作为校正算法在候选区域内进行人脸及人手检测。基于 Adaboost 模型的人脸检测算法可以分为以下三个步骤。

- (1) 使用 Harr-like 特征表示人脸,并可以通过“积分图”实现特征数值的快速计算。
- (2) 使用 Adaboost 算法挑选出一些最能代表 ROIs 的矩形特征(弱分类器),按照加权投票的方式将弱分类器构造为一个强分类器。
- (3) 将训练得到的若干强分类器串联组成一个级联结构的层叠分类器,级联结构能有效地提高分类器的检测速度。基于以上方法即可在候选区域内准确标定出人脸及人手的位置和大小,人脸的检测结果如图 4 所示,人手的检测结果如图 5 所示。

图 2 候选人脸

图 3 候选人手

图 4 人脸检测结果

图 5 人手检测结果

1.2 SIFT 特征点提取

将人脸及人手区域作为感兴趣区域 ROIs，基于 SIFT 描述子的匹配算法提取 ROIs 内眼部、嘴部以及手部的 SIFT 特征点。优化的 SIFT 特征算子是由 LOWE^[11]提出的，该算子具有很强的鲁棒性，当图片的大小、位置、方向、背景以及噪声发生变化时，其仍能具有良好匹配效果。

基于优化的 SIFT 特征算子的匹配算法包含以下三个步骤。

(1) 提取模板图像以及待处理图像 ROIs 中的 SIFT 特征点。

SIFT 特征点本质上是高斯金字塔(Difference of gaussian, DoG)不同尺度空间上的极值点，SIFT 特征点应具有以下三个特性。与同尺度空间 8 个邻近点以及相邻两个尺度空间的 18 个邻近点比较，SIFT 特征点为最值点；具有稳定性；需要经过检验才能精确定位^[12]。

(2) 在模板图像中生成眼部、嘴部以及手部的 SIFT 特征点的描述子。

模板图像中 ROIs 的 SIFT 特征点描述子生成分为以下两步。首先确定 SIFT 特征点描述子的梯度主方向，即 SIFT 特征点领域像素梯度直方图的峰值位置；然后将 $4 \times 4 \times 8$ 共 128 维矢量作为 SIFT 特征点的描述子^[13]。

(3) 通过特征点匹配从待处理图像中提取眼部、嘴部以及手部的 SIFT 特征点集。

待处理图像 ROIs 中的 SIFT 特征点提取分为以下两步。首先，通过特征点匹配得到模板图像 ROIs 的 SIFT 特征点描述子与待处理图像中 ROIs 的特征点描述子之间的欧氏距离；然后将最近的欧氏距离值和次近的欧氏距离值的比值与阈值进行比较，若小于该阈值，则待处理图像中 ROIs 的特征点即为 SIFT 特征点^[14]。按照上述方法提取待处理图像中 ROIs 的全部 SIFT 特征点，构成 SIFT 特征点集。

1.3 提取眼部、嘴部以及面部朝向特征矢量

驾驶员在疲劳情况下，面部具有以下三个特征：

① 眼睛较长时间出现闭合状态；② 嘴部张开较大；③ 面部朝向发生偏转。因此，上述三个面部特征对应的特征参数的获取是进行驾驶员疲劳状态的检测的前提。首先，基于 SIFT 特征点匹配获取左眼、右眼以及嘴部的 SIFT 特征点，并将其作为提取面部特征的处理对象；然后分别计算左眼、右眼以及嘴部的 SIFT 特征点的中点坐标 $L(x_L, y_L)$ 、 $R(x_R, y_R)$ 、 $M(x_M, y_M)$ ，基于中点坐标计算以下三个特征矢量。

(1) 提取眼部特征矢量。设左眼、右眼的 SIFT 特征点集分别为 $\{(x_{Li}, y_{Li})\}$ 、 $\{(x_{Rj}, y_{Rj})\}$ ，

$i=1, 2, \dots, I$ ， $j=1, 2, \dots, J$ 。

计算左眼所有特征点到 $L(x_L, y_L)$ 的距离 $d_i(L)$ 、右眼所有特征点到 $R(x_R, y_R)$ 的距离 $d_j(R)$

$$d_i(L) = \sqrt{(x_{Li} - x_L)^2 + (y_{Li} - y_L)^2} \quad (1)$$

$$d_j(R) = \sqrt{(x_{Rj} - x_R)^2 + (y_{Rj} - y_R)^2} \quad (2)$$

式中， $x_L = \sum_{i=1}^I x_{Li}$ ， $y_L = \sum_{i=1}^I y_{Li}$ ， $x_R = \sum_{j=1}^J x_{Rj}$ ， $y_R = \sum_{j=1}^J y_{Rj}$ 。

由 $d_i(L)$ 、 $d_j(R)$ 可以分别得出距离的均值 $\bar{d}(L)$ 、 $\bar{d}(R)$ 以及距离的标准差 $\delta(L)$ 、 $\delta(R)$

$$\bar{d}(L) = \frac{\sum_{i=1}^I d_i(L)}{I} \quad (3)$$

$$\bar{d}(R) = \frac{\sum_{j=1}^J d_j(R)}{J} \quad (4)$$

$$\delta(L) = \frac{\sum_{i=1}^I [d_i(L) - \bar{d}(L)]^2}{I} \quad (5)$$

$$\delta(R) = \frac{\sum_{j=1}^J [d_j(R) - \bar{d}(R)]^2}{J} \quad (6)$$

通过观测统计，得出眼睛处于张开状态 $d_i(L)$ 、 $d_j(R)$ 的频数的拟合分布曲线如图 6a 所示，眼睛处于闭合状态 $d_i(L)$ 、 $d_j(R)$ 的频数分布的正拟合曲线如图 6b

(a)

(b)

图 6 $d_i(L)$ 、 $d_j(R)$ 的频数的拟合分布曲线

所示。由图 6 可知,当眼睛处于不同状态时其 $d_i(L)$ 、 $d_j(R)$ 的频数拟合分布曲线不同即相应的均值和标准差也不相同。因此,以上 4 个特征值组成一组矢量可以描述出眼睛所处的状态。将以上 4 个特征参数组成一个特征矢量 $\mathbf{X}$,即可作为眼睛所处状态分类的输入矢量 $\mathbf{X}=(\bar{d}(L), \bar{d}(R), \delta(L), \delta(R))$ 。

(2) 提取嘴部特征参数。设嘴部的 SIFT 特征点集为 $\{M(k)=(x_{Mk}, y_{Mk})\}, (k=1, 2, \dots, K)$, 计算左眼所有特征点到 $M(x_M, y_M)$ 的距离 $d_k(M)$

$$d_k(M)=\sqrt{(x_{Mk}-x_M)^2+(y_{Mk}-y_M)^2} \quad (7)$$

式中, $x_M=\sum_{k=1}^K x_{Mk}$, $y_M=\sum_{k=1}^K y_{Mk}$ 。由 $d_k(M)$ 可得出距离的均值 $\bar{d}(M)$ 以及距离的标准差 $\delta(M)$

$$\bar{d}(M)=\frac{\sum_{k=1}^K d_k(M)}{K} \quad (8)$$

$$\delta(M)=\frac{\sum_{k=1}^K [d_k(M)-\bar{d}(M)]^2}{K} \quad (9)$$

嘴巴处于张开或闭合状态时, $d_k(M)$ 的频数分布曲线与眼睛 $d_i(L)$ 、 $d_j(R)$ 的频数分布曲线类似,因此,特征矢量 $\mathbf{Y}=(\bar{d}(M), \delta(M))$ 即可作为嘴巴所处状态分类的输入矢量。

(3) 提取面部朝向特征参数。

当驾驶员处于严重疲劳时,驾驶员的面部会向左下方、向右下方或向正下方倾斜。如图 7a 所示为驾驶员清醒状态面部朝向,如图 7b~7d 所示为驾驶员疲劳状态面部朝向。图 7 中 d_1 表示左眼中点坐标与右眼中点坐标之间的距离, d_2 表示左眼中点坐标与嘴部中点坐标之间的距离, d_3 表示右眼中点坐标与嘴部中点坐标之间的距离。

$$d_1=\sqrt{(x_L-x_R)^2+(y_L-y_R)^2} \quad (10)$$

$$d_2=\sqrt{(x_L-x_M)^2+(y_L-y_M)^2} \quad (11)$$

$$d_3=\sqrt{(x_R-x_M)^2+(y_R-y_M)^2} \quad (12)$$

1.4 面部几何特征及手部运动特征参数获取

将眼部特征参数、嘴部特征参数以及面部朝向特征参数分别输入到眼部状态、嘴部状态以及头部朝向分类器,对眼部状态进行判别。由于上述分类问题具有较多的输入维数,如果选用 BP、RBF (Radial basis function, RBF) 等方法进行模式识别时,需要克服训练网络规模过大、训练速度较慢等问题。但基于 SVM 进行分类时,无须构建网络,且其计算量与输入维数无关。因此,本文选用 SVM 来结

图 7 驾驶员面部朝向

构建眼部状态、嘴部状态以及头部朝向分类器,且选用径向基核函数作为核函数。

手工分割 200 幅睁眼图像和 200 幅闭眼图像、200 幅张嘴图像和 200 幅闭嘴图像、200 幅面部不发生偏转图像和 200 幅面部发生偏转图像,转换成为灰度并归一化后,分别进行训练。

基于上述分类器判别单帧图像中眼部状态,据此计算眼部特征参数即 *Perclos* 的值。*Perclos* 是指眼睛闭合时间占某一特定时间的百分比。*Perclos* 法是 1994 年 Wierwille 等根据在驾驶模拟器上的试验结果确立的。本文以 15 s 为周期,计算 15 s 内 *Perclos* 的值,计算公式如下

$$Perclos = \frac{N_1}{M_1} \quad (13)$$

式中, N_1 为周期内眼睛闭合图像采样帧数, M_1 为周期内的所有图像采样帧数。*Perclos* 值越大,即眼睛闭合的时间越长,即驾驶疲劳程度越深。

由于人在疲劳时,眼睛闭合是持续性的而嘴巴张开是间歇性的,因此将单位时间内嘴巴张开的次数作为嘴部的特征参数。同样以 15 s 为周期计算 *MClosed* 的值,计算公式如下

$$MClosed = N_2 \quad (14)$$

式中, N_2 为周期内嘴巴张开图像采样帧数。

面部朝向特征参数的计算方法与眼部特征参数的提取方法相同,基于面部朝向分类器计算面部向下时间占某一特定时间的百分比,该百分比即为面部朝向特征参数,计算公式如下

$$Phdown = \frac{N_3}{M_3} \quad (15)$$

式中, N_3 为周期内面部向下图像采样帧数, M_3 为周期内的所有图像采样帧数。*Phdown* 值越大,即面部向下的时间越长,即驾驶疲劳程度越深。

通常, 驾驶员在行车过程中, 需要不断对方向进行调整, 即使在笔直的道路行驶, 也总是需要对方向盘做一些轻微的转动。但当驾驶员处于驾驶疲劳状态时会出现操纵停顿等现象, 因此通过监测驾驶员手部的动作状态可以间接反映驾驶员是否处于疲劳状态, 如果在经历一定时间内手部没有任何动作, 就可以判断为驾驶疲劳, 而且该疲劳的程度与手部无动作的时间成正比关系。首先, 基于 SIFT 特征点匹配获取左右手的 SIFT 特征点, 并分别计算左右手的 SIFT 特征点的中点坐标, 依据中点坐标是否发生变化来实时判断手部动作。根据疲劳驾驶监测理论, 通常以 4 s 作为判断阈值, 当检测到方向盘持续不动时间超过 4 s 时, 可以判定为驾驶疲劳。本文以 4 s 为基准进行疲劳判断, 设手部持续 4 s 不动的累计时间之和为 t_1 , 得到手部运动特征参数 SA 的值, 如式(16)所示。

$$SA = \frac{t_1}{T_1} \quad (16)$$

式中, T_1 为常值 15 s, 当累计时间 t_1 很小时, SA 值也相应较小, 此时说明驾驶员状态较为清醒, 当 t 较长时, SA 值也较大说明驾驶员处于疲劳状态。

2 驾驶员疲劳检测

2.1 构建检测模型

我们提取了 4 种驾驶疲劳检测特征参数, 每个特征参数均能够一定程度地检测出疲劳, 但由于不同驾驶员的习惯不同, 单一参数在检测时通常呈现出不稳定性, 所以有必要利用综合特征参数对驾驶疲劳进行判断。本文利用 BP 网络构建驾驶员疲劳检测模型, 并应用贝叶斯正则化和动量梯度下降法解决传统 BP 人工神经网络训练高精度和预测低精度的过拟合现象。

当确定输入矢量以及输出矢量后, BP 神经网络的结构由隐层层数以及隐层神经元个数决定, 隐层层数越多, 网络规模越大、计算越复杂。为简化网络结构、减少计算量, 本文悬着单隐层神经网络模型, 且该模型能够任意含有多个隐层的神经网络模型^[15]。

在运用 ANN 建立作业环境综合评价模型过程中, 将 Perclos、MClosed、Phdown 以及 SA 4 个特征参数作为模型的输入变量, 故输入层的神经元数为 4, 用 x_i 表示($i=1,2,3,4$)。输出层只有一个神经元, 表示驾驶员疲劳检测结果用 Y 表示, 它是一个代数, 取值范围在 $[0, 1]$ 区间, 输出层分值越高, 说明

疲劳等级越高。BP 网络结构示意图如图 8 所示。

图 8 驾驶疲劳检测的 BP 神经网络模型

目前在关于睡眠、药物和疲劳的相关研究中, 被广泛使用的疲劳测量方法是心理动作警觉作业法 (Psychomotor vigilance task, PVT)^[16]。PVT 值越大疲劳程度越高, 且与疲劳程度呈线性相关。因此, 本文可将 PVT 值量化为 5 个等级, 量化值如表 1 所示, 等级 I 表示清醒状态, 等级 II 表示轻微疲劳状态, 等级 III 表示疲劳状态, 等级 IV 表示较疲劳状态, 等级 V 表示极度疲劳状态。

表 1 疲劳程度的主观量化值

疲劳等级	I 级	II 级	III 级	IV 级	V 级
量化值	0.0~0.2	0.2~0.4	0.4~0.6	0.6~0.8	0.8~1.0

目前隐层神经元个数的选择没有标准的方法, 一般根据经验公式(3)计算出估计值, 作为参照依据。在此基础上, 对含有不同隐层神经元个数的网络进行测试, 综合考虑误差的大小以及收敛速度的快慢对神经元个数进行调整, 进而使得网络具有较高准确率以及收敛速度。在网络结构确定后, BP 算法的选择对网络的优劣也会造成影响。较好的算法不仅能够是网络具有较快的收敛速度, 而且能够解决 BP 神经网络过拟合问题。

$$m = \sqrt{n+l} + \alpha \quad (19)$$

式中, m 为隐层节点数, n 为输入层节点数, l 为输出层节点数, α 为 1~10 之间的常数。

为保证试验的安全性, 试验在驾驶模拟器上进行。在试验车上我们通过一个摄像头来获取驾驶员的脸部图像以及手部图像, 本文利用 Halcon 进行图像处理, 利用 Matlab 进行分类器训练以及疲劳检测。原型系统如图 9 所示。由于图像的获取受光照强度以及个体差异的影响, 在文中我们取 7 个光照标准值: 150 lx、250 lx、350 lx、450 lx、550 lx、650 lx、750 lx, 在各光照标准值下我们分别采集 10 名驾驶员在不同疲劳状态下的 30 组样本(每个疲劳等级含有 6 个样本), 共 2 100 个样本, 每个样本都

包含 15 s 的驾驶人员操作视频。

图9 驾驶员疲劳检测的原型系统

将采集数据中的 2 100 个样本,按交叉验证的思想,将样本以 3:1 的比例划分为 1 575 个训练样本和 525 个测试样本。在 0~20 个神经元个数区间内,以 1 个神经元为间隔,对比不同隐层神经元个数下的训练及测试效果。图 10a~10d 分别为基于传统 BP 算法、Levenberg-Marquardt 算法、Broyden-Fletcher-Goldfarb-Shanno 算法以及基于贝叶斯正则化并结合动量梯度下降算法,训练及测试均方误差随着隐层神经元个数的增加的变化规律。

由图 10a 可知基于传统 BP 算法构建该神经网络模型时,其训练样本的均方误差接近于 0.005,然而测试样本的均方误差与训练样本的均方误差相差较大,出现了过拟合现象。当隐层节点数为 4 时,测试样本的均方误差最小,其值为 0.006 12,仍远大于训练样本的均方误差 0.005。由图 10b 和 10c 可知,当基于 Levenberg-Marquardt 算法和 Broyden-Fletcher-Goldfarb-Shanno 算法构建该神经网络模型时,训练样本的均方误差很快趋近于 0.001,同时测试样本的均方误差与训练样本的均方误差相差较小,网络的过拟合现象不明显。当隐层节点数分别为 6 时,基于 Levenberg-Marquardt 算法测试样本的均方误差最小,其值为 0.002 35。当隐层节点数分别为 8 时,基于 Broyden-Fletcher-Goldfarb-Shanno 算法测试样本的均方误差最小,其值为 0.001 79。由图 10d 可知,当隐层神经元在 5~10 之间时,测试样本的均方误差与训练样本的均方误差之间的差值较小,可以克服神经网络模型的过拟合问题。当隐层节点数分别为 8 时,测试样本的均方误差最小,其值为 0.001 56。因此,基于贝叶斯正则化并结合动量梯度下降算法构建该神经网络模型时,其训练和测试的均方误差以及稳定性均优于以上三种算法。

综上所述,BP 网络模型具有一层隐层且隐层神经元个数为 8,4 个输入矢量,1 个输出矢量,输出层的传递函数为 logsig,目标误差为 0.001,最大迭代次数为 3 000,并基于贝叶斯正则化并结合动量梯

度下降算法优化传统 BP 算法。

(a)

(b)

(c)

(d)

图10 BP神经网络测试误差曲线

2.2 驾驶员疲劳检测

为说明上述人工神经网络模型及算法的应用有效性,采集 10 名驾驶员在不同疲劳状态下的 1 400 个测试样本,共包含 7 个测试集,其中, Q_1 、 Q_2 、 Q_3 、 Q_4 、 Q_5 、 Q_6 、 Q_7 分别表示上述 7 个光照标准值: 150 lx、250 lx、350 lx、450 lx、550 lx、650 lx、750 lx 对应的测试集,且每个测试集包含 200 个样本。将 1 400 个测试样本输入到上述神经网络模型中进行测试,基于本文方法的测试结果与单个特征参数评价结果对比见表 2,由表可知,当只采用单个特征参数作为分级依据时,其正确识别率为 80.64%,错分的主要原因是单一参数在检测时通常

呈现出不稳定性；当基于本文方法时准确率达到 99.64%，其中，样本集 Q_1 和 Q_2 中分别有 3 个和 1 个别错分样本，而样本集 Q_3 、 Q_4 、 Q_5 和 Q_6 中无错分样本，样本集 Q_7 中只含有 1 个错分样本。因此，

此人工神经网络的建立对训练外数据预测具有高的精度和很好的泛化和实用性，也表明依据多个特征参数能够较准确地进行驾驶员疲劳检测，且降低了单参数检测算法误判的概率。

表 2 基于本文方法的测试结果与单项指标评价结果对比

样本集种类	Q_1	Q_2	Q_3	Q_4	Q_5	Q_6	Q_7
分类正确样本数/个	151	159	163	166	168	165	157
分类错误样本数/个	49	41	37	34	32	35	43
正确识别率(%)	75.5	79.5	81.5	83.0	84.0	82.5	78.5
错误识别率(%)	24.5	20.5	18.5	17.0	16.0	17.5	21.5
分类正确样本数/个	197	199	200	200	200	200	199
分类错误样本数/个	3	1	0	0	0	0	1
正确识别率(%)	98.5	99.5	100.0	100.0	100.0	100.0	99.5
错误识别率(%)	1.5	0.5	0.0	0.0	0.0	0.0	0.5

3 结论

(1) 本文选取能够直接反映驾驶员疲劳程度的 3 个面部特征(眼睛、嘴巴和面部朝向)以及手部运动特征对驾驶员状态进行综合判断，克服了单一指标在检测驾驶疲劳程度中的不足，消除单一指标失效时产生的误判和漏判。通过试验表明，当只采用单个特征参数作为分级依据时，其正确识别率为 80.64%，当基于本文方法时准确率达到 99.64%，提高了识别的准确率。

(2) 通过 BP 人工神经网络建立了驾驶员疲劳状态检测模型，由于模型的权值是通过样本学习得到的，消除了人为计取权重和相关系数的主观影响和不确定性。选择贝叶斯正则化算法使 BP 网络具有优良的综合训练和预测能力及卓越的泛化能力，并运用已训练好的网络对样本数据进行测试，使得该模型具有较高的预测精度和高稳定性。

(3) 基于面部及手部 SIFT 特征点进行面部特征参数以及手部运动特征参数提取，当尺度、平移、旋转、视角、光照发生变化时，该提取算法仍具有较高的鲁棒性，进而使得本文提出的驾驶员疲劳状态检测方法能够克服光照、背景、角度以及个体差异的影响，且疲劳检测的正确识别率达到 99.64%。

参 考 文 献

- [1] WEI C S, WANG Y T, LIN C T, et al. Toward drowsiness detection using non-hair-bearing eeg-based brain-computer interfaces[J]. IEEE Trans. Neural Syst. Rehabil Eng., 2018, 26(2): 400-406.
- [2] KHUNPISUTH O, CHOTCHINASRI T, KOSCHAKOSAI V, et al. Driver drowsiness detection using eye-closeness detection[C]// International Conference on Signal-Image Technology & Internet-Based Systems. IEEE, November 26-29, 2017, Las Palmas de Gran Canaria, Spain, 2017: 661-668.
- [3] KOH S, BO R C, LEE J I, et al. Driver drowsiness detection via PPG biosignals by using multimodal head support[C]// International Conference on Control, Decision and Information Technologies, April 10-13, 2017, Thessaloniki, Greece, 2017: 0383-0388.
- [4] LIN C T, CHEN Y C, WU R C, et al. Assessment of driver's driving performance and alertness using EEG-based fuzzy neural networks[C]// IEEE International Symposium on Circuits and Systems. IEEE, May 15-18, 2005, Rio de Janeiro, Brazil, 2005, 1: 152-155.
- [5] HAYASHI K, ISHIHARA K, HASHIMOTO H, et al. Individualized drowsiness detection during driving by pulse wave analysis with neural network[J]. Intelligent Transport Systems, 2005. Proceedings. IEEE, 2005: 901-906.
- [6] TAKEI Y, FURUKAWA Y. Estimate of driver's fatigue through steering motion[C]// 2005 IEEE International Conference on Systems, Man and Cybernetics, October 6-9, 2005, Bari, Italy, 2005, 2(10-12): 1765-1770
- [7] POMERLEAU D, JOCHEM T. Rapidly Adapting machine vision for automated vehicle steering[J]. IEEE Expert, 1996, 11(2): 19-27.
- [8] WANG Rongben, LI Guo, TONG Bing liang, et al. Monitoring mouth movement for driver fatigue or distraction with one camera[C]// The International IEEE Conference on Intelligent Transportation Systems, November 4-7, 2004 Maui, Hawaii, USA, 2004: 314-319.
- [9] PAUL V, MICHAEL J. Robust real-time face detection[J]. International Journal of Computer Vision, 2004, 57(2): 137-154.
- [10] GUO L, GE P S, ZHANG M H, et al. Pedestrian detection for intelligent transportation systems combining AdaBoost

- algorithm and support vector machine[J]. Expert Systems with Applications, 2012, 39(4): 4274-4286.
- [11] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [12] LI B, YU S, LU Q. An improved K-nearest-neighbor algorithm for text categorization[J]. Expert Systems with Applications An International Journal, 2012, 39(1): 1503-1509.
- [13] DINGES D F, GRACE R. PERCLOS: A valid psychophysiological measure of alertness as assessed by psychomotor vigilance, FHWAMCIRT-99-010[R]. Washington, DC, Federal Highway Administration, 1998.
- [14] PETER G, KURT K, VERA K, et al. Circadian and wake-dependent modulation of fastest and slowest reaction times during the psychomotor vigilance task[J]. Physiology&Behavior, 2004, 80: 695-701.
- [15] NEYAMADPOUR A, TAIB S, ABDULLAH W A T W. Using artificial neural networks to invert 2D DC resistivity imaging data for high resistivity contrast regions: A MATLAB application[J]. Computers & Geosciences, 2009, 35(11): 2268-2274.
- [16] ORON-GILAD T, RONEN A. Road characteristics and driver fatigue: A simulator study[J]. Traffic Injury Prevention, 2007, 8(3): 281-289.
-
- 作者简介: 刘明周, 男, 1968 年出生, 博士, 教授, 博士研究生导师。主要研究方向为人-机-环境工程学、制造过程监测、控制与管理以及工业工程系统理论、分析及决策方法。
E-mail: liumingzhou0551@163.com
- 蒋倩男(通信作者), 女, 1992 年出生, 博士研究生。主要研究方向为人-机-环境工程学和机器视觉。
E-mail: 1191758741@qq.com
- 扈静, 女, 1976 年出生, 博士, 教授, 硕士研究生导师。主要研究方向为人-机-环境工程学和制造过程监测与控制。
E-mail: 52868648@qq.com