

基于深度学习的疲劳状态识别算法

周 慧 周 良 丁秋林

(南京航空航天大学计算机科学与技术学院 南京 210016)

摘 要 目前国内外的疲劳状态识别算法大多数是基于单一的、人为制定的疲劳状态特征实现的,且大部分算法结构复杂,效率比较低,对驾驶员的个人行为习惯的适应性不强。为此,提出一种基于深度学习的疲劳状态识别算法,它引入深信度网络(DBN)来模拟输入图像数据分布,完成对疲劳特征的分层自动抽取,进而基于时间窗实现视频流图像的疲劳状态识别;同时,算法自适应调整网络学习率以减少网络预训练时间,采用反馈机制实现网络自进化,从而提高对用户个性化疲劳特征的适应性。实验结果表明,算法可以使网络获取到良好的疲劳特征,且误判率会随使用时间的增加而逐渐降低。

关键词 疲劳状态识别,深度学习,深信度网络,疲劳特征,反馈机制

中图分类号 TP181 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.3.039

Fatigue Recognition Algorithm Based on Deep Learning

ZHOU Hui ZHOU Liang DING Qiu-lin

(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract Current domestic and overseas fatigue recognition algorithms are implemented using fatigue features which are mostly singular and man-made. Most of those algorithms have complex structure, low efficiency and weak adaptability for drivers' individual behavior habit. To this end, the paper put forward a fatigue recognition algorithm based on deep learning. It introduces deep belief network (DBN) to simulate the data distribution of input images, extracts fatigue features automatically layer by layer, and then recognizes state of fatigue from video images based on time window. The algorithm adjusts the learning rate of the net adaptively to reduce pre-training time, uses feedback mechanism to let the net evolve by itself and as a consequence improves its adaptability for user personalized fatigue features. The experimental result shows that our algorithm acquires good fatigue features, and its misjudgment rate reduces gradually along with incremental time.

Keywords Fatigue recognition, Deep learning, DBN, Fatigue feature, Feedback mechanism

1 引言

由于疲劳驾驶的高发性与危险性,驾驶人疲劳监测预警技术(Driver Fatigue Monitoring and Pre-warning, DFMP)的研究已成为交通安全领域的研究重点,且具有广阔的市场前景。DFMP的关键是疲劳状态识别,目前疲劳状态识别技术可分为3大类:基于医学的识别、基于车辆行驶参数的识别和基于机器视觉的识别。Correa等^[1]提出使用时间、谱和小波分析来自动检测疲劳阶段的方法,从一个EGG频道共提取19个特征来分类警觉和疲劳阶段,基于lambda of Wilks准则选取7个参数来调整神经网络分类器以便很好地区分两个阶段。Li等^[2]利用短时间内的HRV信号的小波变换来分类警觉和疲劳驾驶状态,运用接收器运行曲线(ROC)来选取特征,用支撑向量机(Support Vector Machine, SVM)分类器来分类;ROC分析结果表明基于小波变换的方法性能优于传统的快速傅里叶变换法(FFT)。基于医学的识别方法主要通过检测脑电信号(Electroencephalogram, EEG)、肌电信号(Electromyography, EMG)、心电信号(Electrocardiogram, ECG)、心率

变化(Heart Rate Variability, HRV)等生理信号来判断驾驶员是否处于疲劳状态,该方法成本高且佩戴的传感器会影响驾驶员的正常驾驶,因此实际应用效果并不是很好。李伟等^[3]通过采集转向盘的转角信号,运用精神运动警戒算法(Psychomotor Vigilance Task)建立了基于神经网络的疲劳监测系统。张希波等^[4]通过分析驾驶人在疲劳状态下的转向盘操作特征,运用双时间窗指标提取法建立了基于Fisher线性算法的疲劳判别准则。这两种基于车辆行驶参数的识别方法存在算法复杂、识别率较低、反应速度较慢等缺点。基于机器视觉的识别方法已成为目前智能车辆及安全辅助驾驶中疲劳状态识别的主要途径,在车辆内部安装摄像头对驾驶员进行拍摄,通过人在疲劳时会出现的打哈欠、眨眼、头部倾斜等特征来判断。李绍文等^[5]提出一种综合判定的疲劳识别方法实现对人脸的快速检测和对人眼的准确定位,通过PERCLOS、眼睛闭合时间、眼睛眨眼频率、嘴巴张开程度、头部运动的计算,进行驾驶员疲劳程度的综合判定。这些由识别面部器官变化状态而得出的疲劳检测标准,由于没有区分个体差异,且人为标定的特征难以清楚地表征疲劳状态,因此这类算法得

到稿日期:2014-05-23 返修日期:2014-08-07 本文受江苏省产学研联合创新资金项目(SBY201320423)资助。

周 慧(1991—),女,硕士生,主要研究方向为信息系统及集成、人工智能等,E-mail:zh67730ing@gmail.com;周 良(1966—),男,博士,副教授,硕士生导师,主要研究方向为信息系统、知识工程;丁秋林(1936—),男,博士,教授,博士生导师,主要研究方向为信息系统、企业信息化。

到的判决效果不是十分理想。

为此,本文提出一种基于深度学习的疲劳状态识别算法(Fatigue Recognition Algorithm based on Deep Learning, FRADL),旨在让系统自动去发现和学习无法预先设定而又能够表征疲劳状态的特征,并不断更新网络自身的认知结果,以得到更好的疲劳识别结果。算法用深度学习网络模型来模拟图像数据分布,训练网络学习潜在的疲劳特征,同时结合自适应步长技术减少网络训练时间,并采用反馈机制实现网络自进化,以提高算法对用户个性化疲劳特征的适应性。

2 FRADL 算法设计

深度学习是通过深层非线性网络结构的学习,实现复杂函数逼近、表征输入数据的分布式表示,是机器学习的一个分支,也可以理解为神经网络层次结构上的一个发展。自 20 世纪 80 年代末以来,机器学习得到了迅速发展,但发展仅局限于浅层机器学习模型,如支撑向量机(Support Vector Machines, SVM)、Boosting、最大熵法(Logistic Regression, LR)等。2006 年 Geoffrey Hinton^[6]证明了多层神经网络有优异的特征学习能力,并且证明了可以通过逐层预训练的方法来克服深层网络训练上的难度,这使机器学习的研究进入第二个发展阶段。

本文提出的基于深度学习的疲劳识别算法采用深信度网络(Deep Belief Network, DBN)表征输入数据的分布式表示,进而分层获取疲劳特征。因此,算法的核心是训练 DBN 以使 DBN 能很好地模拟输入图像的特征分布,从而实现疲劳特征的自学习。训练过程包括两个阶段:首先采用无标签数据逐层预训练网络,调整网络参数,这一阶段属于无监督训练过程;然后通过有标签数据训练,自顶向下传输误差,对网络进行整体微调,这一阶段属于有监督微调过程。通过预训练得到的网络初始权值能够比人为预设的权值更加准确地反映输入数据的结构,从而可以得到更具有表示能力的疲劳特征,取得更好的识别效果。本文提出的 FRADL 算法总体流程如图 1 所示。

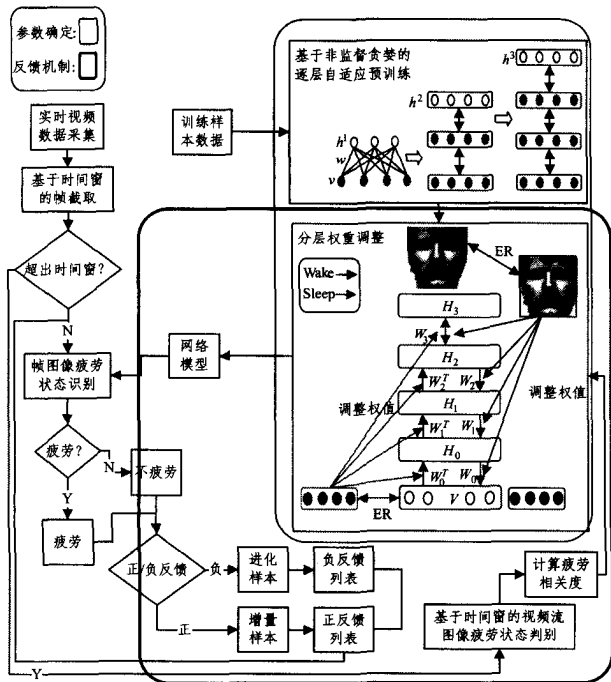


图 1 FRADL 算法流程

FRADL 算法的实现分为两阶段:训练阶段和反馈阶段。训练阶段由非监督预训练算法和监督微调算法组成,其中预训练算法采用改进的非监督贪婪逐层预训练算法,微调采用 Wake-Sleep 算法。反馈阶段分为正反馈和负反馈,有两个列表记录正负反馈阶段对应的特征及权重,利用生成的标签数据和增量样本修正、加强网络。

2.1 基于非监督贪婪的逐层自适应预训练

非监督预训练 DBN 是利用大量的非标签数据训练网络,使网络获得数据的有效特征表示,以用于后续的分类。Hinton^[8]提出的非监督贪婪逐层预训练算法(Unsupervised Greedy Layer-wise Pre-training Algorithm)使用非监督形式逐层预训练网络,需要的大量数据都是获得形式容易的非标签数据,预训练之后的网络获得的权值能够比随机初始化的权值更好地表达输入数据结构,使网络获得更有意义的特征表示和更好的泛化性能。

贪婪逐层预训练算法的主要思想是使 DBN 中的每一层都获得输入数据的不同表示;模型对输入数据进行非线性映射,然后产生输出并用于网络下一层模型的输入。该算法的本质就是让 L 层以下所有层数据都取自其后验分布 $Q(h^l | h^{l-1})$,依次取到 $L-1$ 层的数据后,将第 L 和 $L-1$ 层看作一个限制玻尔兹曼机(Restricted Boltzmann Machine, RBM)来进行训练,通过 RBM 的概率分布可以得到 DBN 的概率分布。

RBM 是一个二部图,每层层内节点之间没有连接,层与层之间节点有对称的权值连接。一层是可视层 v ,即输入层;另一层是隐层 h ,即抽取的输入数据特征。所有节点都是随机二值变量,且联合概率分布 $P(v, h)$ 符合 Boltzmann 分布。RBM 是一个基于能量函数的网络^[9],网络的能量函数如式(1):

$$E(v, h) = -\sum_i a_i v_i - \sum_j b_j h_j - \sum_{i,j} v_i w_{ij} h_j \quad (1)$$

其中, v_i 和 h_j 是可视单元 v 和隐单元 h 的二值状态, a_i 和 b_j 分别是它们的偏置, w_{ij} 是对称权值,网络参数记为 $\theta \in \{a_i, b_j, w_{ij}\}$,对 RBM 的训练就是确定 θ 的过程。确定参数更新规则: $\theta_m = \epsilon \times (\text{update_rule})$ 使 RBM 定义的模型分布 P_θ 尽可能地与训练样本集定义的概率分布 P^0 相一致。采用对比分歧法^[10](Contrastive Divergence, CD)得到更新规则。CD 法是指用一步完全 Gibbs 采样得到概率分布 P_θ^c ,将 $P^0 \parallel P_\theta^c$ 与 $P_\theta^c \parallel P_\theta^c$ 的差作为对比分歧目标函数(其中 \parallel 为交叉熵(Kullback-Leubler Divergence)),以该目标函数的对数似然估计作为参数更新规则。

RBM 的一步完全吉布斯采样是指首先根据输入数据 v 利用 $Q(h_j = 1 | v) = \text{sigm}(b_j + \sum_i v_i w_{ij})$ 更新所有隐层单元 h ;然后根据获得的 h 利用 $P(v_i = 1 | h) = \text{sigm}(a_i + \sum_j h_j w_{ij})$ 更新所有可视单元得到 v' ;最后再次利用 $Q(h_j = 1 | v')$ 得到 h' 。其中 $\text{sigm}(x) = \frac{1}{1+e^{-x}}$ 。交替吉布斯采样过程如图 2 所示。




图 2 交替吉布斯采样过程

此时参数的更新公式为 $\Delta w_{ij} = \epsilon \times (v_i h_j - v_i' h_j')$, $\Delta b_j =$

$\varepsilon \times (h_j - h_j')$, $\Delta a_i = \varepsilon \times (v_i - v_i')$, 其中 ε 为学习率。然而该算法通常训练时间非常长, 特别是在训练大数据集时。而疲劳识别的对象就是大尺寸多维度的图像数据, 为了提高预训练时间, 就要提高 CD 算法的收敛速度, 本文使用自适应变化的学习率替代全局学习率, 学习率的自适应调整如式(2)所示:

$$\varepsilon = \begin{cases} \mu\varepsilon, & \text{if } (v_i h_j - v_i' h_j')(v_i h_j^{dd} - v_i' h_j'^{dd}) > 0 \\ \gamma\varepsilon, & \text{if } (v_i h_j - v_i' h_j')(v_i h_j^{dd} - v_i' h_j'^{dd}) < 0 \end{cases} \quad (2)$$

其中, $\mu > 1$ 是学习率的增长率, $\gamma < 1$ 作为学习率的衰减率, 当两次连续更新方向相同时增加学习率, 当方向相反时减少, 这样可以减少学习过程中在更新方向相反时由于过大的学习率导致的振荡, 加速算法收敛, 从而加速网络的训练时间。

2.2 分层权重调整

为了对特征状态进行分类, 在训练好的 DBN 顶层增加一层, 与原顶层构成联想记忆层作分类器。预训练好的 DBN 已经通过学习获取到输入图像的疲劳状态特征和非疲劳状态特征, 此时需要让网络对两种状态特征进行区分, 也即调整特征单元对应的权重。运用有标签的数据作为输入, 利用 Wake-Sleep 算法对网络进行微调。Wake-Sleep 算法分为醒(wake)和睡(sleep)两个部分。wake 阶段是认知过程, 通过外界的特征和向上的权重(认知权重)产生每一层的抽象表示(隐单元状态), 并且使用 CD 法修改层间的下行权重(生成权重)。sleep 阶段是生成过程, 通过顶层表示(wake 阶段学得的概念)和向下权重, 生成底层的状态, 同时修改层间向上的权重。通过这样的双向调节, 最终使网络很好地分类出能够表示疲劳状态的特征。

网络训练阶段使用 Wake-Sleep 算法让网络的疲劳状态特征具有了区分性, 这时网络的各层权重都已调整好, 可以进行疲劳状态识别。然而为了使网络性能增强, 让网络自进化以能够适应驾驶员的个性化特征, 引入反馈机制, 反馈机制的实质也是分层调整权重。反馈分为正反馈和负反馈, 正反馈是指疲劳识别的结果反馈, 而负反馈是指非疲劳识别和误识的结果反馈, 误识包括将疲劳状态识别为非疲劳状态和将非疲劳状态识别为疲劳状态。反馈阶段修改权重的目标与训练时的修改目标不同, 这里是将在多幅图中表达疲劳状态的特征权重增加, 减少不能表达或者表达错误的特征权重。因为疲劳状态判别是基于时间窗的, 所以这里的反馈也是基于时间窗的, 针对一个时间窗中一系列识别结果进行一次反馈调整。设计两个相关列表, 即正反馈列表 L^+ 和负反馈列表 L^- , 分别用来存储所有正反馈和负反馈图像所关联的特征及其初始权重 1。一次帧图像识别结果为正反馈时, 记录网络中被激活的特征集, 判断其与 L^+ 中的特征集的关系: 若有 L^+ 中未包含的, 则增加, 且置其初始权重为 1; 否则将其权重加 1。对 L^- 做同样操作。当一个时间窗内的帧图像全部识别结束之后, 用式(3)计算所有 k 特征与疲劳状态的相关度:

$$\lambda = \begin{cases} 0, & k \notin L^+ \\ W_k^+ / (W_k^+ + W_k^-), & k \in L^+ \end{cases} \quad (3)$$

相关度越高的特征越能表示疲劳状态。根据相关度并结合 Wake-Sleep 算法分层调整网络权重, 增加相关度高的特征点的网络权重, 减少相关度低的网络权重。这里正负反馈阶段产生的标签数据不同, 正反馈阶段产生增量训练样本, 目的

是增强网络对疲劳状态的表示能力; 负反馈阶段产生进化训练样本, 目的是修正网络的部分疲劳状态表示。这两阶段反馈能够使网络性能和个体适应性显著增强。

2.3 基于时间窗的疲劳状态判别

由于获取到的视频中图像信息太大, 对其每一帧都进行识别势必影响系统运行速度, 且连续帧图像的识别对于疲劳识别是无意义的, 因此, 本文在自适应预训练及分层权重调整的基础上, 设计了一种基于时间窗的疲劳状态判别方法。基于时间窗的视频流图像截取示意图如图 3 所示。




图3 基于时间窗的视频流图像截取

事先定义好时间窗 t_w 的大小, 每次的系统输入均为该时间窗内的帧图像, 即一次识别是对 t_w 窗口内的视频流图像进行处理。为了降低系统在每次取到的图像都是人闭眼的情况下的误判率, 间隔时间 $t = t_p^i - t_{p-1}^i$ 的确定主要依据人的眨眼频率, 以间隔时间 t 从时间窗中获取 p 帧图像作为算法输入。设网络对每帧图像 i 的识别结果如式(4)所示:

$$D(i) = \begin{cases} 1, & \text{疲劳状态} \\ 0, & \text{非疲劳状态} \end{cases} \quad (4)$$


则基于时间窗的疲劳状态最终判定公式如式(5)所示:

$$D = \frac{\sum_{i=1}^p \{D(i)\}}{p} \quad (5)$$

当 $D \geq \omega$ (ω 为预先设定的疲劳阈值) 时, 判定该时间窗内视频流图像为疲劳状态; 否则为非疲劳状态。

3 实验结果与分析

由于目前并没有公开的疲劳状态检测数据库, 本文以日本 Kyushu 大学的 JAFFE (Japanese Female Facial Expression) 数据库、Yale 数据库以及自建的数据库作为实验对象。其中 JAFFE 数据库中有 213 张图片, Yale 数据库中有 165 张图片, 自建数据库中有 150 张, 疲劳表情图主要来自 Yale 数据库和自建数据库, 因此总共用于实验的图像有 528 张。部分数据库图像及 DBN 的第一层网络权重图如图 4 所示。



(a) JAFFE 部分图像 (b) Yale 部分图像 (c) 第一层权重图像

图4 实验数据及网络权重

疲劳识别最主要的就是对图像中疲劳特征进行抽取, 因此特征抽取的充分性和有效性对算法的准确性及性能影响很大。本文算法首先采用非监督贪婪逐层提取特征, 再采用有监督方式进行分层权重调整以获得疲劳特征。这种方式比普通特征抽取即目前现有的疲劳识别算法中采用的特征抽取所获得的特征更加充分有效。由图 5 可以看出, 普通特征提取是预先设定好一个标签准则(疲劳特征), 对图像中特殊部位

进行特征抽取,如眼部、头部、嘴部等,然后将抽取到的特征与标签对比以确定是否判定为疲劳。这种方式在最开始就限制了特征抽取的范围,且若标签设定得不合适,则会极大地影响算法提取的特征有效性。而本文算法是先通过非监督方式充分地提取图像特征,然后再加以权重调整确定疲劳特征,网络自己分别学习到特征和标签,并且后期的调整和反馈机制能够强化学习,获得更有效的疲劳特征。




图5 特征抽取比较

为验证本文算法的可行性及性能,实验分3组进行,一组200张无标签图像做网络预训练用,一组200张有标签图像(标明疲劳、非疲劳)做网络微调训练用,一组128张图像做测试用,使网络自进化。为测试算法在实际运行中的识别情况,以车内摄像机拍摄的连续视频图像流作为测试对象,摄像机分辨率为 320×240 像素。共拍摄了不同疲劳程度的30个视频段,每段10分钟。疲劳状态判别参数设置为 $t_w=30s, t=3s, p=7, \omega=0.5$,网络参数 θ 中将可视单元偏置 a_i 的初始值设置为 $\log[p_i/(1-p_i)]$,其中 p_i 为可视单元 v_i 被激活的概率,其余设置为0,网络隐层为3层;自适应步长参数 $\epsilon=0.1, \mu=1.2, \gamma=0.8$ 。对视频流图像运用本文算法进行状态识别,图6给出了4个视频流中基于时间窗提取的帧图像序列,其算法识别的结果如表1所列。




图6 帧图像序列

表1 识别结果

No.	D1	D2	D3	D4	D5	D6	D7	D	疲劳
(a)	0	0	0	0	0	0	1	0.14	否
(b)	0	0	0	1	1	1	0	0.43	否
(c)	1	1	1	0	1	1	1	0.86	是
(d)	1	0	0	1	1	0	1	0.57	是

表1给出了对图6中不同帧图像序列输入网络所取得的结果 $D(i)$ 和基于时间窗的疲劳状态进行判定公式 D 的结果。实验结果表明,FRADL能够很好地识别出疲劳状态。

在上述参数下,网络的平均预训练时间随着隐层单元个数增加的变化情况如图7所示,可以看出,结合自适应步长的预训练算法明显减少了预训练时间。反馈机制对误判率的影

响曲线如图8所示,随着算法对截取的帧图像序列进行识别次数的增加,反馈次数增加,网络修正次数增加,因此算法后期能更好地识别出疲劳状态。




图7 平均预训练时间




图8 反馈效果

本文提出的识别算法应用于驾驶过程中疲劳状态的实时识别,因此对算法的实时性要求比较高。表2是本文算法(A)与目前广泛运用的PERCLOS技术(B)的运行时间对比。实验结果表明,本文算法能够更好地满足使用的实时性要求。

表2 算法运行时间对比

算法	A	B
运行时间 \leq	0.9s	1.5s

由于本文算法采用了基于时间窗的疲劳状态识别方法以及反馈机制,在准确性方面同样具有明显的优势。如表3所列,对于一系列视频流图像,A和B算法在进行第一次疲劳识别时,达到的准确率分别是90.7%和87.1%。对于同样的图像,在运行30次之后,可以看出B算法的准确性不变,而本文算法准确性明显提高,这是因为本文的反馈机制的作用,在识别的同时,根据错误识别来修正网络,以达到强化学习,而B算法并未有后续调整的机制。基于视觉的疲劳识别中频繁出现的伪疲劳状态能够充分地检验算法的准确性。伪疲劳状态是指视频流中,驾驶员出现大笑而张嘴或者太阳光照射导致的眼睛眯起等情况,而使系统误以为是疲劳的状态。对于这类情况,由于本文算法是基于时间窗来识别的,除非时间窗内出现大量伪疲劳状态,否则对算法识别准确性的影响是很低的;而B算法并没有这种机制,一旦出现伪疲劳状态,尤其是引起眼部闭合变化的情况,会极大影响识别的准确性。

表3 算法准确性比较

准确性	第1次	第30次	伪疲劳视频流
A	90.7%	96.3%	94.8%
B	87.1%	87.1%	79.4%

结束语 本文算法采用DBN模拟输入图像数据分布,分层表示疲劳特征,自动学习潜在的、相关的疲劳特征。在非监督贪婪逐层预训练算法的基础上,提出的基于非监督贪婪的逐层自适应预训练方法克服了算法收敛过程中的振荡,大幅度减少了网络预训练时间。对于视频流图像识别,设计了基

(下转第200页)

- [6] Karen K. Affinity program slashes computing times[OL]. 2007-10-25. <http://www.news.utoronto.ca/bin6/070215-2952.asp>
- [7] Bodenhofer U, Kothmeier A, Hochreiter S. APCluster: an R package for affinity propagation clustering[J]. *Bioinformatics*, 2011, 27(17): 2463-2464
- [8] Guha S, Rastogi R, Shim K. CURE: an efficient clustering algorithm for large databases[J]. *ACM SIGMOD Record, ACM*, 1998, 27(2): 73-84
- [9] Ertöz L, Steinbach M, Kumar V. A new shared nearest neighbor clustering algorithm and its applications[C]// *Workshop on Clustering High Dimensional Data and its Applications at 2nd SIAM International Conference on Data Mining*, 2002: 105-115
- [10] J Fray B J, Dueck D. Clustering by Passing Messages Between Data Points[J]. *Science*, 2007, 315(5814): 972-976
- [11] Hsu D, Kakade S M, Zhang Tong. A spectral algorithm for learning hidden Markov models[J]. *Journal of Computer and System Sciences*, 2012, 78(5): 1460-1480
- [12] Powers D M W. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness & correlation[J]. *Journal of Machine Learning Technologies*, 2011, 2(1): 37-63
- [13] Rawashdeh M, Ralescu A. Crisp and fuzzy cluster validity: generalized intra-inter silhouette index[C]// *2012 Annual Meeting of the North American Fuzzy Information Processing Society (NAFIPS)*. IEEE, 2012: 1-6
- [14] Guan R, Shi X, Marchese M, et al. Text clustering with seeds affinity propagation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2011, 23(4): 627-637
- [15] Kazantseva A, Szpakowicz S. Linear text segmentation using affinity propagation[C]// *Proceedings of the Conference on Empirical Methods in Natural Language Processing*. Association for Computational Linguistics, 2011: 284-293
- [16] Patidar A K, Agrawal J, Mishra N. Analysis of Different Similarity Measure Functions and their Impacts on Shared Nearest Neighbor Clustering Approach[J]. *International Journal of Computer Applications*, 2012, 40(16): 1-5
- [17] Lee S S, Lin J C. An accelerated K-means clustering algorithm using selection and erasure rules[J]. *Journal of Zhejiang University SCIENCE C*, 2012, 13(10): 761-768
- [18] 鲁伟明, 杜晨阳, 魏宝刚, 等. 基于 MapReduce 的分布式近邻传播聚类算法[J]. *计算机研究与发展*, 2012, 49(8): 1762-1772
- [19] 唐东明, 朱清新, 杨凡, 等. 一种有效的蛋白质序列聚类分析方法[J]. *软件学报*, 2011, 22(8): 1872-1837
- [20] 沈洁, 赵雷, 杨季文, 等. 一种基于划分的层次聚类算法[J]. *计算机工程与应用*, 2007, 43(31): 175-177
- [21] 王开军, 李健, 张军英, 等. 半监督的仿射传播聚类[J]. *计算机工程*, 2007, 33(23): 197-198
- [22] 邢艳, 周勇. 基于互近邻一致性的近邻传播算法[J]. *计算机应用研究*, 2012, 29(7): 2524-2526

(上接第 194 页)

于时间窗的疲劳状态判别方法, 能够有效地从视频流图像中识别出疲劳状态。同时, 为提高算法的个体适应性, 在算法的识别阶段设计了基于时间窗和疲劳相关度的分层权重调整作为算法的反馈机制, 让网络具有自进化和自增长功能。本文算法较好地解决了疲劳特征自动提取的问题, 进一步提高了算法的个体适应性。实验结果表明, 该算法对疲劳状态具有良好的识别率, 且反馈机制能很好地使网络学习新的疲劳状态表示并调整已获得的疲劳状态表示, 随着时间的推移, 网络识别效果会越来越好。在实验过程中, 我们发现当输入的视频流图像为大尺寸、高维度时, 算法处理速度会明显变慢, 而在线疲劳识别及预警对实时性要求很高, 因此, 如何利用 GPU 实现并行处理, 以进一步提高算法效率, 是我们今后研究的重点。

参 考 文 献

- [1] Correa A G, Orosco L, Laciari E. Automatic detection of drowsiness in EEG records based on multimodal analysis[J]. *Medical Engineering & Physics*, 2014, 36(2): 244-249
- [2] Li G, Chung W Y. Detection of Driver Drowsiness Using Wavelet Analysis of Heart Rate Variability and a Support Vector Machine Classifier[J]. *Sensors*, 2013, 13(12): 16494-16511
- [3] 李伟, 何其昌, 范秀敏. 基于汽车操纵信号的驾驶人疲劳状态监测[J]. *上海交通大学学报*, 2010, 44(2): 292-295
- [4] 张希波, 成波, 冯睿嘉. 基于转向盘操作的驾驶人疲劳状态实时检测方法[J]. *清华大学学报: 自然科学版*, 2010, 50(7): 1072-1076
- [5] 李绍文, 王江波. 驾驶员疲劳检测系统研究[J]. *计算机工程与应用*, 2013, 49(15): 253-258
- [6] Hinton G, Salakhutdinov R. Reducing the Dimensionality of Data with Neural Networks[J]. *Science*, 2006, 313(5786): 504-507
- [7] 余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. *计算机研究与发展*, 2013, 50(9): 1799-1804
- [8] Hinton G E, Osindero S. A Fast Learning Algorithm for Deep Belief Nets[J]. *Neural Computation*, 2006, 18: 1527-1554
- [9] 刘建伟, 刘媛, 罗雄麟. 玻尔兹曼机研究进展[J]. *计算机研究与发展*, 2014, 51(1): 1-16
- [10] Hinton G. Training Products of Experts by Minimizing Contrastive Divergence[J]. *Neural Computation*, 2002, 14(8): 1771-1800
- [11] Neal R M, Hinton G E. A View of the EM Algorithm that Justifies Incremental, Sparse and other Variants[M]// *Learning in Graphical Models*, 1998, 355-368
- [12] 蒋斌, 贾克斌, 杨国胜. 人脸表情识别的研究进展[J]. *计算机科学*, 2011, 38(4): 25-31
- [13] Dasgupta A, George A, Happy S L, et al. A Vision-Based System for Monitoring the Loss of Attention in Automotive Drivers[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2013, 14(4): 1825-1838
- [14] 张伟, 夏利民, 罗大庸. 基于人脸运动信息和改进保局投影的疲劳识别[J]. *计算机学报*, 2010, 33(11): 265-267
- [15] Cyganek B, Gruszczynski S. Hybrid computer vision system for drivers' eye recognition and fatigue monitoring[J]. *Neural computation*, 2014, 126(SI): 78-94
- [16] 孙树亮, 林雪云. 基于记忆的 SVM 相关反馈算法[J]. *计算机科学*, 2011, 38(10): 256-258
- [17] 陈云华, 余永权, 张灵, 等. 基于面部视觉特征的精神疲劳可拓辨识模型[J]. *计算机学报*, 2013, 40(2): 284-288