

基于多特征的疲劳驾驶安全检测

刘晨熙, 刘 芬

天津职业技术师范大学电子工程学院, 天津

收稿日期: 2023年3月6日; 录用日期: 2023年4月4日; 发布日期: 2023年4月12日

摘 要

针对目前因疲劳驾驶导致的车祸比例占总车祸比例的极大一部分的情况, 故本文设计出一种基于改进的Yolov5算法的疲劳驾驶检测系统。Yolov5算法的疲劳检测是指通过对车辆内部安装摄像头等图像传感器来获取驾驶员的人脸和面部特征, 并通过机器视觉中的面部特征提取等方式获取驾驶员眼部以及嘴部状态, 从而实现对驾驶员疲劳状态的分析判断。基于Yolov5算法的检测方法成本低, 不需接触、检测方便, 能够准确地分析出驾驶人的疲劳状况, 可以极大地降低因疲劳驾驶而导致事故发生概率。

关键词

Yolov5, 深度学习, 疲劳检测

Fatigue Driving Safety Detection Based on Multi-Feature

Chenxi Liu, Fen Liu

School of Electronic Engineering, Tianjin University of Technology and Education, Tianjin

Received: Mar. 6th, 2023; accepted: Apr. 4th, 2023; published: Apr. 12th, 2023

Abstract

Aiming at the fact that the proportion of car accidents caused by fatigue driving accounts for a large part of the total number of car accidents, a fatigue driving detection system based on the improved Yolov5 algorithm is designed in this paper. The fatigue detection of the Yolov5 algorithm refers to the acquisition of the driver's face and facial features by installing image sensors such as cameras in the vehicle, and the driver's eye and mouth status through facial feature extraction in machine vision, so as to realize the analysis and judgment of the driver's fatigue state. Based on Yolov5 algorithm, the detection method has low cost, no contact, convenient detection, can accurately ana-

lyze the fatigue of the driver, and can greatly reduce the probability of accidents caused by fatigue driving.

Keywords

Yolov5, Deep Learning, Fatigue Detection

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着人们生活水平的逐渐提高以及各大城市道路交通系统的不断完善,我国的汽车保有总量也在不断增加,这在为人们的出行带来便捷的同时,也导致了交通事故的频频发生,疲劳驾驶[1]已然成为行车事故的主要原因之一,每年在众多交通事故中有超过 20%是因疲劳驾驶引发的事故[2]。

根据我国交通部门相关调查信息显示:当今导致我国交通事故频发的三大主要因素分别为酒后驾驶、超速驾驶和疲劳驾驶[3]。其中,现如今我国针对超速驾驶和酒后驾驶已经进行了严格的管控,不仅定制了严格的法律条例,而且在人为监测方面也进行了极大的加强,但至今仍缺乏对疲劳驾驶方面有效的预防和处理措施。

在车辆行驶的过程中,若驾驶者是在疲劳状态下驾驶车辆的话,则会导致其对于特殊情况的反应时间以及处理能力都会严重影响[4],甚至如果驾驶员在驾驶的途中因困意随时可能会进入短暂的休眠状态[5],从而会导致其失去对车辆的控制,对路上行驶的车辆以及行人的安全造成严重的威胁。

针对上述问题,本文提出一种基于加入注意力机制的 Yolov5 算法的驾驶员疲劳检测技术[6],通过对车辆驾驶员驾驶过程中眨眼次数以及驾驶员嘴巴的张开幅度来判断驾驶员当前的疲劳状况[7],从而实现对疲劳驾驶的有效监控,减少因疲劳驾驶而产生的事故发生概率,从而达到保护驾驶人和行人的安全。

2. Yolov5 算法原理概述

Yolov5 是一种单阶段目标检测算法,该算法在 Yolov4 的基础上进行了一些新的改进[8],使得算法的检测速度与检测精度都得到了极大的提升,更加符合本实验所需的检测要求以及标准。图 1 展示了 Yolov5 目标检测算法的整体框图。

对于 Yolov5 算法,我们可以将其划分为四个部分,分别为:输入端、基准网络、Neck 网络和输出端。

输入端: Yolov5 算法相对于前面的 Yolov4 算法在模型训练阶段进行了一些新的改进,提出了一种自适应锚框计算的方式,针对所选取训练数据集的不同,会自动设定初始锚框的长宽值,再根据所需的长宽值自动地调整需要的数值,将原始的数据集统一根据需求缩放到一个这定好的尺寸,再送入检测网络中,从而使得对图片特征的提取更加容易。

基准网络:基准网络通常是一些性能优异的分类器种的网络,该模块用来提取一些通用的特征表示。Yolov5 中不仅使用了 Focus 结构作为基准网络[9],而且使用了 CSP Darknet53 结构。

Neck 网络: Neck 网络通常位于基准网络与 Head 模块之间,且 Neck 网络可以进一步提升从数据源中提取的特征的多样性及鲁棒性。Yolov5 在 Neck 部分变动较大,首先将 SPP 换成了 SPPF。在 Yolov4

中, Neck 的 PAN 结构是没有引入 CSP 结构的, 但在 Yolov5 中在 PAN 结构中加入了 CSP。

Head 输出端: Head 模块是用来将检测结果进行输出的模块。

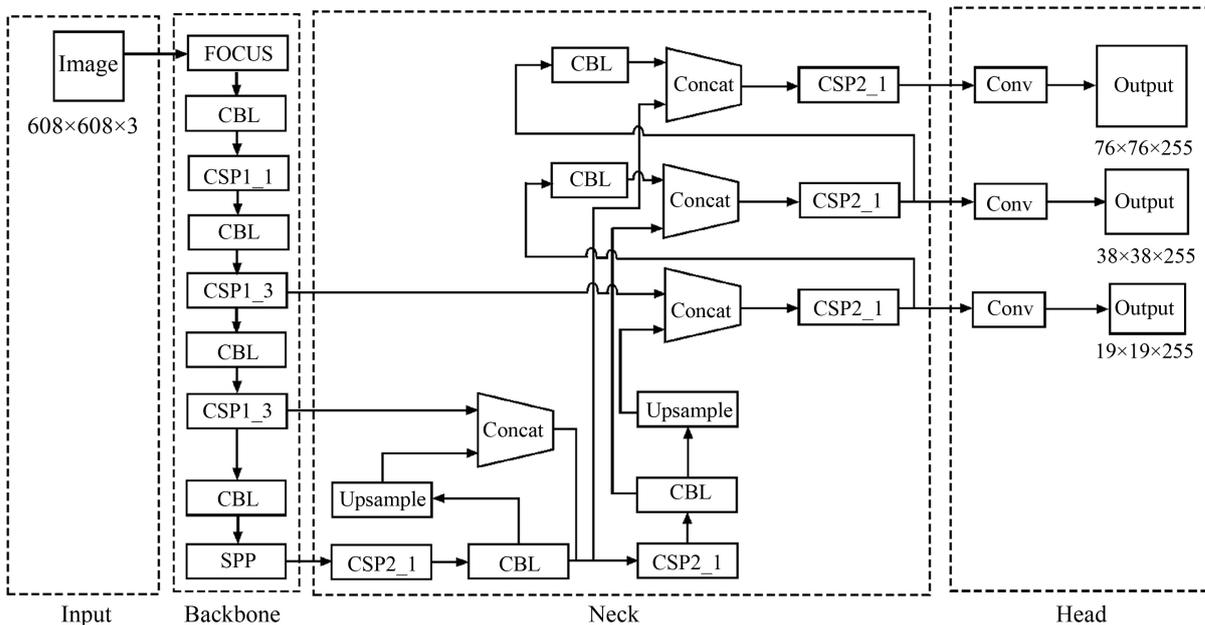


Figure 1. Overall framework of Yolov5 algorithm

图 1. Yolov5 算法整体框架

3. 激活函数

在多层神经网络中, 神经元上层输出和下层输入之间由激活函数(Activation Function)相连接[10], 激活函数是用来提高神经网络对模型的表达能力而存在的函数, 可以用来解决一些线性模型解决不了的问题。而 Yolov5 模型相比于 Yolov4 模型在激活函数方面也做了改动, 在 Yolov5 中, 中间/隐藏层使用了 Leaky ReLU 激活函数, 如图 2, 最后的检测层则使用了 Sigmoid 激活函数, 如图 3。

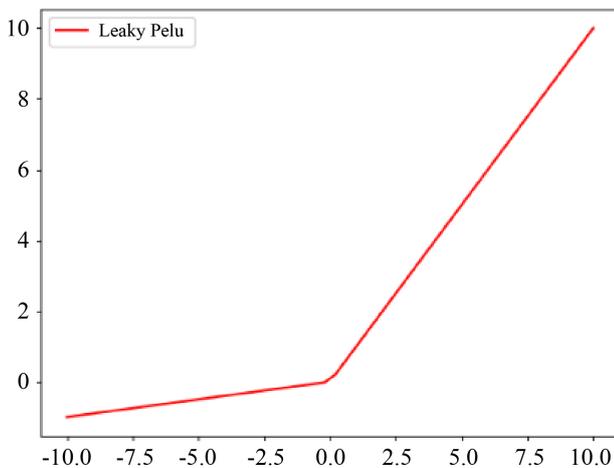


Figure 2. LeakyReLU activates the function

图 2. LeakyReLU 激活函数

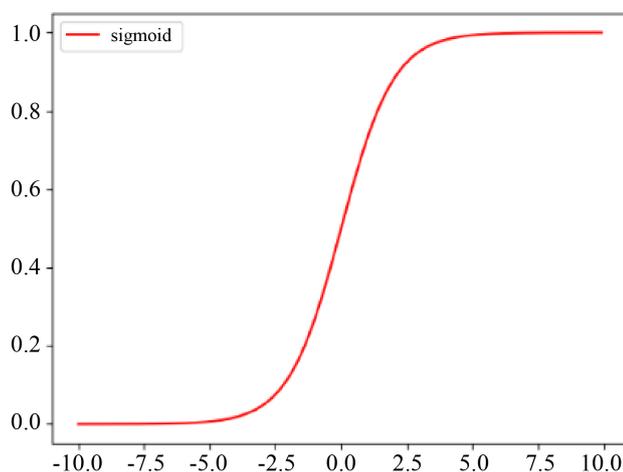


Figure 3. Sigmoid activates the function
图 3. Sigmoid 激活函数

3.1. Leaky ReLU 激活函数

Leaky ReLU 是在 ReLU 的基础上进行改进, 两者的差别仅仅在输入部分小于 0 时才能体现出来, Leaky ReLU 函数在输入的值小于 0 时其值通常都为负, 而 ReLU 函数在输入值小于 0 时其值通常都为 0。相比于 ReLU 激活函数来说, Leaky ReLU 激活函数在反向传播的过程中, 对于输入的值小于 0 的部分, 也可以计算得到梯度, 而 ReLU 激活函数则值为 0, 这样就可以有效地避免输入的值负时梯度消失的问题。通常情况下 Leaky ReLU 的 α 取值一般为 0.01, 表达式为:

$$\text{Leaky ReLU}(x) = \begin{cases} x, & x > 0 \\ \alpha x, & x \leq 0 \end{cases} \quad (1)$$

3.2. Sigmoid 激活函数

Sigmoid 函数在我们的网络模型中比较常用, 是一种常见的 S 型函数, 也称为 S 型生长曲线。由于其单增以及反函数单增等性质, 常被用作神经网络的阈值函数, 作为二分类任务的输出层, 函数的输出范围为 (0, 1), 表达式为:

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2)$$

4. 引入 CA 注意力机制

注意力机制(Attention Mechanism)源于对人类视觉的研究[11]。引入注意力机制, 就是在所提供的众多数据中拿到对于当前任务所需要的信息, 过滤掉其他不重要的信息或者是干扰信息, 降低对于那些不重要信息的关注度, 就可以有效地解决由于特征提取过多带来的过拟合问题, 提高在检测过程中对于目标提取的效率以及准确性。比如要识别一张动物图片中是什么动物时, 我们让机器也存在这样的一个注意力侧重, 最重要该关注的地方就是图片中动物的面部特征, 包括耳朵、眼睛、鼻子、嘴巴, 而不用太关注背景的一些信息, 核心的目的就在于希望机器能在很多的信息中注意到对当前任务更关键的信息, 而对于其他的非关键信息就不需要太多的注意力侧重。

最新研究成果表明, 通道注意力[12] (例如, SE 注意力)会给模型带来比较显著的性能提升, 但是通道注意力通常会忽略对生成空间选择性注意力图非常重要的位置信息。因此, 在本文中, 将使用移动网

络注意力机制“Coordinate Attention”，简称 CA 注意力机制[13]来代替传统的通道注意力机制，如图 4。

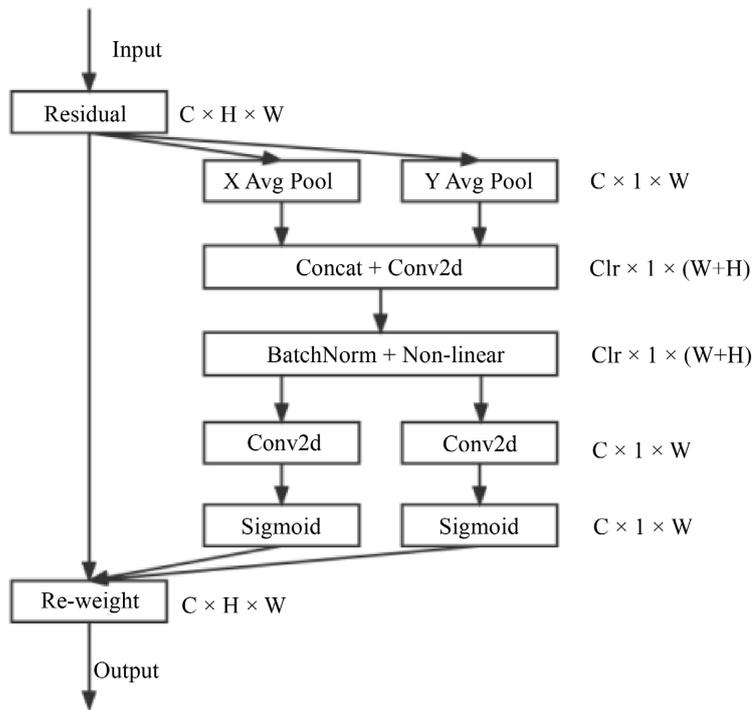


Figure 4. CA attention mechanism
图 4. CA 注意力机制

全局池通常用于通道注意力以全局编码空间信息，但它将全局空间信息压缩到通道描述符中，因此难以保存位置信息，这对于在视觉任务中捕获空间结构至关重要。为了鼓励注意力块用精确的位置信息在空间上捕捉长距离的交互，我们将全局池分解为等式。

首先使用池化核分别沿着水平坐标和垂直坐标对每个通道进行编码，且对其大小也进行了规定，尺寸为(H, 1)或(1, W)，并且分别沿着水平和垂直的这两个空间方向进行池化，得到 C*H*1 和 C*1*W 的特征图，公式如下所示。

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \tag{3}$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \tag{4}$$

级联 z^h 和 z^w 这两个生成的特征图，然后使用一个共享的 1×1 的卷积核将生成的特征图放入 F_1 的变换函数中，得到特征图 f 。如公式 5 所示，其中 δ 是非线性激活函数。

$$f = \delta\left(F_1\left(\left[z^h, z^w \right]\right)\right) \tag{5}$$

接着沿着水平和垂直方向的空间维度将 f 分成 f^h 和 f^w ，然后将 f^h 和 f^w 经过激活函数后就会得到在高度方向的注意力权重 g^h 和在宽度方向的注意力权重 g^w 。从而得到：

$$g^h = \sigma\left(F_h\left(f^h\right)\right) \tag{6}$$

$$g^w = \sigma\left(F_w\left(f^w\right)\right) \tag{7}$$

最后在原始特征图上通过乘法加权计算, 将得到最终在宽度和高度方向上带有注意力权重的特征图, 公式如下所示。

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (8)$$

加入注意力机制后的 Yolov5 算法和传统的 Yolov5 相比, 在检测性能上有显著的提升, 由此可见, 改进后的算法对于疲劳驾驶检测的效果比传统的 Yolov5 算法更加优秀, 不仅检测速度更快, 而且检测的 mAP 值更高。对比实验结果如表 1 所示。

Table 1. Comparison of detection results of fatigue driving

表 1. 疲劳驾驶检测结果对比

模型	AP				mAP
	Open_eye	Closed_eye	Open_mouth	Closed_mouth	
Yolov5	0.983	0.995	0.984	0.981	0.983
Yolov5 + CA	0.991	0.992	0.995	0.991	0.992

5. 实验结果及分析

5.1. 数据集采集

本实验选用的数据集主要来自网络图片以及本人自己采集的图片, 图片的大小统一设置为 640×480 。一共 1347 张图片, 将图片分为训练集以及测试集, 其中训练集包括 1077 张图片, 测试集包括 270 张图片。并且设置了四个特征分别为 open_eye、open_mouth、close_eye 和 close_mouth。

5.2. 实验结果

驾驶员在驾驶车辆的过程中通过放置在驾驶员前方的低成本摄像头且在不遮挡驾驶员视线的情况下, 实时地获取当前时间驾驶员的面部状态, 从而判断当前驾驶员的疲劳状况, 实验结果如图 5 所示。



Figure 5. Eye and mouth status recognition

图 5. 眼部和嘴部状态识别

通过对驾驶员在驾驶过程中的实时监测, 获取每一时段驾驶员的眼部以及嘴部状态, 首先, 对驾驶员的眼部状态进行判断, 通过已经训练好的 YOLOv5 模型对当前驾驶员眼部状态进行特征提取, 通过设置阈值, 若当前驾驶员眨眼的可能性大于当前阈值则认定为一次眨眼。其次, 通过相同的方式对驾驶员嘴部状态进行判断, 本文所使用算法流程图如图 6 所示。

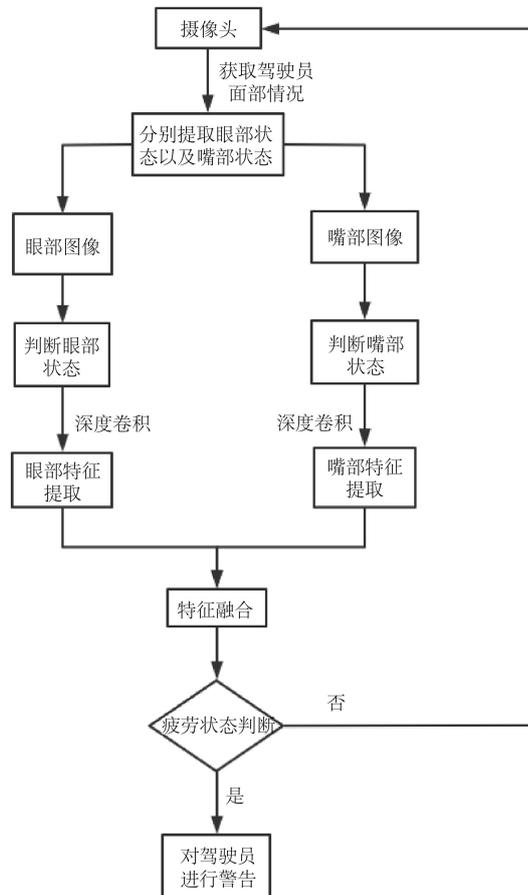


Figure 6. Flow chart of fatigue detection in this paper
图 6. 本文疲劳检测流程图

将提取到的眼部状态与嘴部状态进行特征融合, 通过判断在 3 min 内驾驶员的闭眼次数以及打哈欠的次数情况来判断驾驶员的疲劳状态。

当在 3 min 内驾驶员眨眼次数以及打哈欠次数超过规定值时会对驾驶员进行疲劳驾驶警告, 从而可以有效地检测驾驶员是否在疲劳状态下, 若判定为疲劳驾驶则对其进行警告, 提醒驾驶员进行休息, 以达到减少因疲劳驾驶导致的交通事故的概率, 从而保障过往行人以及车辆的安全。

6. 模型评估

本文所介绍的疲劳检测算法采用 Precision (准确率)和 Recall (召回率)作为最终实验检测结论的评判标准之一。其中, Precision 主要是针对当前实验的预测结果而言的, 它表示的是当前实验中预测结果为正的样本中为真的概率是多少, 如式 9。召回率(Recall)则是根据当前实验中原有的样本的预测成功数量而言的, 它表示的是在当前实验原有的样本中原本为正确的样本并且也被预测正确的样本的概率为多少,

如式 10。从图 7 可以看出, Precision 值和 Recall 值都趋近于 1, 说明该模型用于疲劳驾驶检测效果较好。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (9)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (10)$$

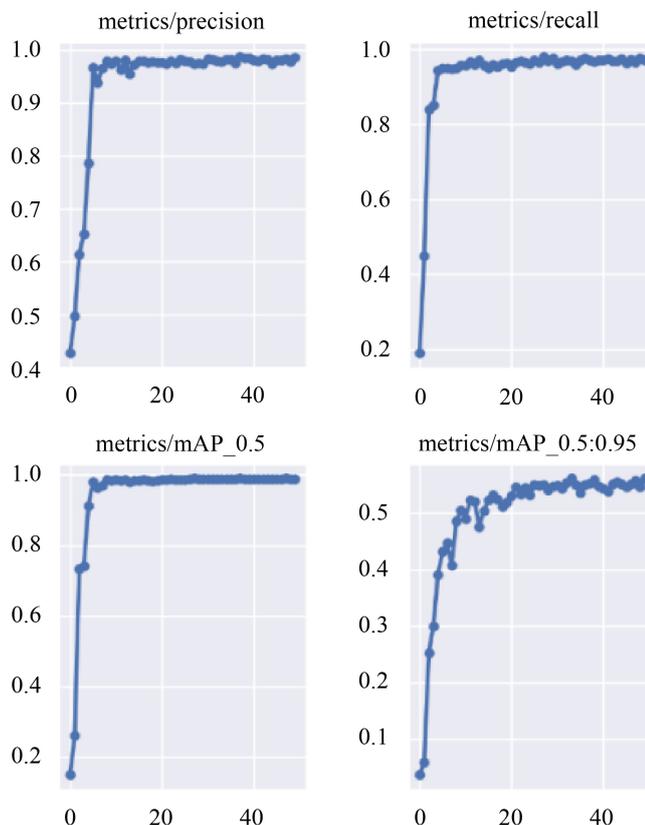


Figure 7. Comparison chart of Precision and Recall
图 7. Precision 和 Recall 对比图

7. 结论

本文提出的疲劳检测算法是在原有的 YOLOv5 算法的基础上引入了注意力机制, 提高了特征提取的准确性。且实验结果表明, 本算法满足了在驾驶车辆行驶时对驾驶人员的实时监测, 并且可以保证检测的准确性在 99% 以上, 能够在较高识别准确率的同时, 占用较少的存储空间, 在实时检测方面具有一定的可行性。

参考文献

- [1] (2001) Driver Fatigue and Road Accidents: A Literature Review and Position Paper. *The Royal Society for the Prevention of Accidents*, **1**, 1-24.
- [2] Tefft, B. (2014) Prevalence of Motor Vehicle Crashes Involving Drowsy Drivers. *AAA Foundation for Traffic Safety*, **45**, 1-8.
- [3] 袁泉, 李一兵, 陈康. 引发重大交通事故的显著因素特点分析及安全对策[J]. *中国司法鉴定*, 2015(5): 34-40.
- [4] Krajewski, J., Sommer, D., Trutschel, U., Edwards, D. and Golz, M. (2009) Steering Wheel Behavior Based Estimation

-
- of Fatigue. *Proceedings of the Fifth International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design*, Big Sky, MT, 23-25 June 2009, 118-124. <https://doi.org/10.17077/drivingassessment.1311>
- [5] Mott, G.E., Forsman, P., Short, K.R., Mott, C.G. and Van Dongen, H.P.A. (2013) Efficient Driver Drowsiness Detection at Moderate Levels of Drowsiness. *Accident Analysis & Prevention*, **50**, 341-350. <https://doi.org/10.1016/j.aap.2012.05.005>
- [6] 彭成, 张乔虹, 唐朝晖, 桂卫华. 基于 YOLOv5 增强模型的口罩佩戴检测方法研究[J]. 计算机工程, 2022, 48(4): 39-49.
- [7] Sun, C., Li, J.H., Song, Y. and Jin, L. (2014) Real-Time Driver Fatigue Detection Based on Eye State Recognition. *Applied Mechanics and Materials*, **457-458**, 944-952. <https://doi.org/10.4028/www.scientific.net/AMM.457-458.944>
- [8] 林向会. 基于视频分析的铁路异物侵限检测系统的设计[D]: [硕士学位论文]. 贵阳: 贵州大学, 2021.
- [9] Sun, Q., Liang, L., Dang, X.H. and Chen, Y. (2022) Deep Learning-Based Dimensional Emotion Recognition Combining the Attention Mechanism and Global Second-Order Feature Representations. *Computers and Electrical Engineering*, **104**, Article ID: 108469. <https://doi.org/10.1016/j.compeleceng.2022.108469>
- [10] 李庆盛, 缪楠, 张鑫, 等. 基于注意力机制非对称残差网络和迁移学习的玉米危害图像识别[J]. 科学技术与工程, 2021, 21(15): 6249-6256.
- [11] 李顺平, 彭成. 基于高效通道注意力机制和图像分割的轻量级表情识别算法[J]. 现代电子技术, 2022, 45(20): 149-156.
- [12] Wang, S.Z., Zhang, Y.F., Hsieh, T.-H., Liu, W., Yin, F. and Liu, B. (2022) Fire Situation Detection Method for Unmanned Fire-Fighting Vessel Based on Coordinate Attention Structure-Based Deep Learning Network. *Ocean Engineering*, **266**, Article ID: 113208. <https://doi.org/10.1016/j.oceaneng.2022.113208>
- [13] 褚文杰. 基于 YOLOv5 的坦克装甲车辆目标检测关键技术的研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2021.