

doi: 10.7690/bgzdh.2024.12.007

## 基于 RepVGG 的疲劳驾驶检测算法

夏庆锋<sup>1</sup>, 李明阳<sup>2</sup>, 宋志强<sup>1</sup>, 许可儿<sup>2</sup>

(1. 无锡学院自动化学院, 江苏 无锡 214105; 2. 南京信息工程大学自动化学院, 南京 210044)

**摘要:** 为提高疲劳驾驶检测方法的准确率和可部署性, 提出一种基于 RepVGG 的疲劳驾驶检测算法。在模型中增添空洞卷积金字塔池化 (atrous spatial pyramid pooling, ASPP) 模块, 以捕捉多尺度疲劳特征信息。将卷积块注意力模块 (convolutional block attention module, CBAM) 与 ASPP 模块结合, 单独应用于模型中, 进一步强调和捕捉疲劳特征表达的多尺度信息和重要区域信息, 并抑制图像中的背景信息, 从而提高模型的性能和鲁棒性。结果表明: 改进 RepVGG 算法在疲劳驾驶数据集上的准确率达到 97.34%, 比原算法提高了 2.51%, 且模型参数量仅为  $7.1 \times 10^6$ , 具有良好的检测精度和可部署性。

**关键词:** RepVGG; 疲劳驾驶检测; ASPP; CBAM**中图分类号:** TP391 **文献标志码:** A

## Fatigue Driving Detection Algorithm Based on RepVGG

Xia Qingfeng<sup>1</sup>, Li Mingyang<sup>2</sup>, Song Zhiqiang<sup>1</sup>, Xu Keer<sup>2</sup>

(1. School of Automation, Wuxi University, Wuxi 214105, China;

2. School of Automation, Nanjing University of Information Science and Technology, Nanjing 210044, China)

**Abstract:** In order to improve the accuracy and deployability of fatigue driving detection method, a fatigue driving detection algorithm based on RepVGG is proposed. An atrous spatial pyramid pooling (ASPP) module was added to the model to capture the multi-scale fatigue characteristics. A Convolutional block attention module (convolutional block attention module, CBAM) is combined with an ASPP module and separately applied to the model to further emphasize and capture the multi-scale information and important regional information expressed by fatigue features, and to suppress the background information in the image. Thereby improving the performance and robustness of the model. The results show that the accuracy of the improved RepVGG algorithm on the fatigue driving data set reaches 97.34%, which is 2.51% higher than that of the original algorithm, and the number of model parameters is only  $7.1 \times 10^6$ , which has good detection accuracy and deployability.

**Keywords:** RepVGG; fatigue driving detection; ASPP; CBAM

### 0 引言

疲劳驾驶是导致车祸的主要原因之一。根据公安部交管局统计, 20%~30%的道路交通事故是因疲劳驾驶引起的。相关研究表明, 如果能够实时检测驾驶员的疲劳状态, 并在其出现疲劳之前发出警报, 则可以避免 96%的疲劳驾驶事故<sup>[1]</sup>; 因此, 对驾驶员进行疲劳状态检测和警告具有重要意义。

近年来, 许多学者和团队对疲劳驾驶检测进行了研究。目前主流的疲劳驾驶检测技术分为主观检测和客观检测。客观检测方法包括基于驾驶员生理特征、车辆参数和驾驶行为特征 3 种检测方式。其中, 基于驾驶行为特征的检测方法是一种非侵入式方法, 不会干扰驾驶员的正常驾驶, 且检测准确性较高, 成为了研究疲劳驾驶检测和预警的主要方向。Savas 等<sup>[2]</sup>提出用于驾驶员疲劳检测的深度置信网络模型, 并使用贪婪策略优化了其结构。

实验结果验证了该 DBN 架构的鲁棒性, 但其复杂的网络结构不适合实时检测的部署。Bai 等<sup>[3]</sup>基于双流时空图卷积网络开发了一种新颖且鲁棒的驾驶员疲劳检测方法, 通过面部特征检测从实时视频中提取驾驶员的面部特征, 并利用训练后的 2s-STGCN 进行疲劳检测。尽管该模型检测精度较高, 但其复杂的网络结构不适合实时检测的部署。

对驾驶员疲劳检测研究的回顾表明: 尽管已经进行了大量调查, 但仍存在一些缺陷。例如, 驾驶员佩戴墨镜或在复杂光照环境下的检测准确率较低, 且现有主流模型参数量大、计算资源需求高。针对上述问题, 笔者选择轻量级模型 RepVGG 作为实验的骨干网络, 并对其结构和特征提取能力进行改进和优化, 旨在保持网络模型复杂度低、计算资源需求小的情况下, 通过提取驾驶员面部的全局特征进行综合分析, 实现了高准确率的疲劳检测。

收稿日期: 2024-06-09; 修回日期: 2024-07-15

基金项目: 江苏省产学研合作项目 (BY20230688); 新一代信息技术创新项目 (2022IT208); 江苏高校“青蓝工程”

第一作者: 夏庆锋 (1982—), 男, 山东人, 博士。

## 1 RepVGG 网络模型

RepVGG<sup>[4]</sup>是一种创新的卷积神经网络架构，主要由输入端和主干网络组成。在本实验中，输入端是尺寸为 224×224 像素的 3 通道图像。主干网络由多个 RepVGG 块构成，通过 3×3 卷积和 ReLU 激活函数，在训练阶段展现出强大的特征提取能力。RepVGG 块采用重参数化技术，在推理阶段将复杂的多分支结构转换为简单的 3×3 卷积操作，从而显著提高推理速度。通过结合训练和推理时的不同架构设计，RepVGG 模型实现了高性能。

## 2 改进的 RepVGG 模型

笔者在 RepVGG 算法的基础上进一步改进。为了提高模型的特征提取能力，添加了空洞卷积金字塔池化 (ASPP) 模块，通过不同扩张率的空洞卷积同时捕捉图像中不同尺度的疲劳特征信息。为了增强模型的特征表示能力和鲁棒性，增加了卷积块注意力模块 (CBAM)。CBAM 不仅与 ASPP 模块相结合形成 ASPP-CBAM 结构，而且独立应用于

RepVGG 模型，更好地捕捉和强调重要的疲劳特征，并抑制图像中的不相关信息。改进后的 RepVGG 模型整体网络结构如图 1 所示，其中结构 2 为 RepVGG 块。

### 2.1 ASPP 模块

ASPP 模块最初在 Deeplab 中提出，结合了空洞卷积和金字塔池化 (spatial pyramid pooling, SPP)。SPP 的核心思想是利用多个不同尺度的池化层进行特征提取，并将其融合成一个统一尺度的向量输入到全连接层，从而解决池化层产生的不同输出导致全连接层无法训练的问题。如图 2 所示，在本实验中，第 3 阶段处理输出的特征图作为 ASPP 模块的输入。ASPP 使用不同扩张率的空洞卷积进行并行采样，其中包括 1 个 1×1 卷积层、3 个扩张率分别为 6、12、18 的 3×3 卷积层以及 1 个 1×1 池化层。池化后的特征信息经过 1×1 卷积降维和上采样操作将图像尺寸恢复至初始值。最后，将所有得到的结果进行拼接以扩大通道数，再通过 1×1 卷积将通道数降低到目标值进行输出。

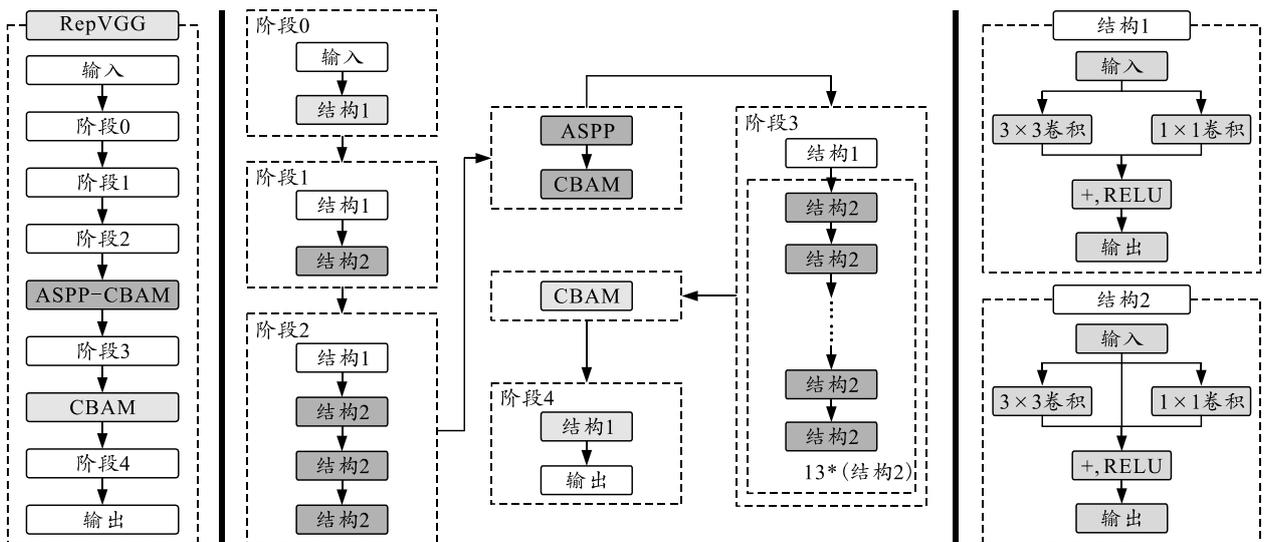


图 1 改进 RepVGG 模型结构

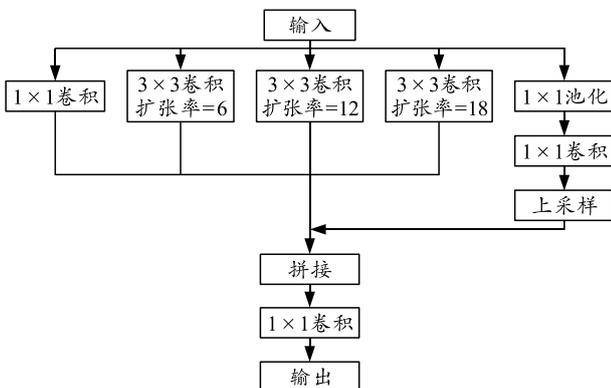


图 2 ASPP 结构

### 2.2 CBAM 模块

深度学习模型<sup>[5]</sup>结合注意力机制，可以增强模型对全局和局部特征的捕捉能力，同时提升计算效率和模型性能。其中，CBAM 是一种应用于前馈神经网络的轻量级注意力模块，由通道注意力模块 (channel attention module, CAM) 和空间注意力模块 (spatial attention module, SAM) 组成，如图 3 所示。在疲劳特征提取和判别任务中，CBAM 模块通过对特征图的通道和空间维度进行加权，更有效地捕捉重要特征，从而增强特征表示能力。CBAM 模块的

引入使得 RepVGG 模型在处理较暗背景或驾驶员佩戴墨镜等复杂情况下, 能更准确地聚焦于重要目标区域, 显著提高模型的鲁棒性。此外, CBAM 模块能够自动抑制与最终分类判别任务无关的特征, 减少噪声, 提高模型的判别能力。CBAM 模块还使得模型决策过程更加透明, 能直观地显示模型关注的区域和通道, 增强了模型的可解释性。

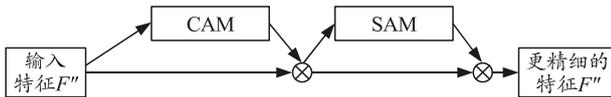


图 3 CBMA 模块

CBAM 操作可以用式(1)表示:

$$F' = M_{CAM}(F) \otimes F, F'' = M_{SAM}(F') \otimes F' \quad (1)$$

式中:  $F$  为输入特征图;  $F''$  为更精细的特征;  $\otimes$  为逐元素乘法;  $M_{CAM}$  为通道注意力模块的提取操作;  $M_{SAM}$  为空间注意力模块的提取操作。

本实验中, 在 ASPP 模块后引入 CBAM 模块, 形成 ASPP-CBAM 结构。这种结构使得 ASPP 模块能够通过多尺度空洞卷积捕获丰富的上下文疲劳特征信息, 而 CBAM 模块则对提取的多尺度疲劳特征进行精细的通道和空间重加权, 进一步增强了对重要疲劳特征的关注, 并抑制了冗余信息。图 4 为 ASPP-CBAM 结构, 描述了 ASPP 与 CBAM 模块的功能及其集成方式。左侧的 ASPP 模块利用  $1 \times 1$  卷积和 3 种不同的空洞卷积率提取输入数据的特征。这些特征经过池化、 $1 \times 1$  卷积和上采样处理后, 汇总并通过拼接和  $1 \times 1$  卷积操作输出结果。ASPP 的输出作为 CBAM 模块的输入, 依次经过 CAM 和 SAM 处理并输出。此外, CBAM 模块还独立应用于 RepVGG 模型, 简化了模型结构, 并通过注意力机制显著增强了特征表示能力, 进一步提升模型的特征提取效果。

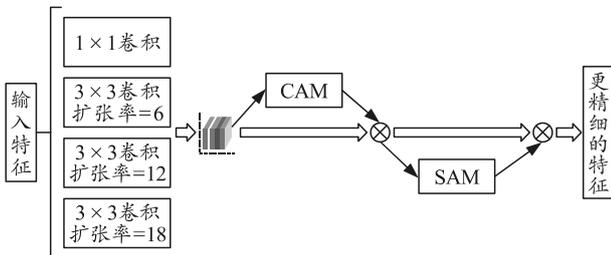


图 4 ASPP-CBAM 结构

### 3 实验结果与分析

#### 3.1 实验环境

在本实验中, 图像输入尺寸设置为  $224 \times 224$  像素, 批量大小为 32, 训练 50 个 epoch, 初始学习率

设置为 0.000 1, 权重衰减系数设置为 0.000 1, 以减少过拟合的可能性。

表 1 实验环境配置

| 设备名称       | 设备信息             |
|------------|------------------|
| 操作系统       | Windows 11       |
| CPU        | i5-13490F        |
| GPU        | RTX3080(10.0 GB) |
| Python 版本  | 3.8              |
| CUDA 版本    | 11.3             |
| Pytorch 版本 | 1.12.0           |

#### 3.2 实验数据集

本实验采用打哈欠检测数据集 (yawning detection dataset, YawDD), 该数据集包含驾驶过程中拍摄的驾驶员面部视频数据, 分为驾驶员正面和侧面 2 种情况。通过对这些视频进行切片和筛选, 分别获得了打哈欠和非打哈欠的数据各 700 余帧, 包括驾驶员戴近视镜和墨镜的情况。为了应对复杂环境和实验需求, 对数据集进行数据增强处理, 包括降低光照模拟夜间情况和增加曝光模拟白天光照刺眼情况。最终, 获得超过 4 300 帧的数据, 其中包括 2 169 帧的打哈欠数据。按照 7:2:1 的比例将经过处理的数据集划分为实验集、验证集和测试集, 数据集示例如图 5 所示。



(a) 暗光配戴墨镜

(b) 亮光配戴墨镜

图 5 疲劳数据集示例

#### 3.3 实验分析与对比

在复杂环境下进行疲劳驾驶检测任务时, 笔者引入了改进后的 RepVGG 检测算法, 旨在提升模型的检测性能。为了验证算法的有效性, 笔者将改进后的算法与 YOLOv3-SPP<sup>[6]</sup>、YOLOv4、YOLOv7、EMLite-YOLOv4<sup>[7]</sup>、CBAM-YOLOv5s<sup>[8]</sup>、ResNet50<sup>[9]</sup> 和 GhostNet<sup>[10]</sup> 等主流检测算法在同数据集上进行了性能对比, 包括检测准确率和参数量, 具体结果见表 2 所示。通过对比不同模型的实验结果, 提出的改进 RepVGG 模型相较于 YOLOv3-SPP、YOLOv4、CBAM-YOLOv5s、YOLOv7、ResNet 50 和 GhostNet 模型在参数量和准确率方面均表现出领先水平。尽管与 EMLite-YOLOv4 对比, 笔者改进的算法模型的准确率降低了 0.1%, 但是参数量却减少了 21%。

实验结果证明：本文中方法在与各种先进方法的对比中展现出显著优势，验证了本文中方法的有效性和性能优势。

表 2 不同模型的实验结果对比

| 模型            | 参数个数( $\times 10^6$ ) | 准确率/% |
|---------------|-----------------------|-------|
| YOLOv3-SPP    | 61.5                  | 82.5  |
| YOLOv4        | 64.0                  | 94.3  |
| EMLite-YOLOv4 | 9.0                   | 97.4  |
| CBAM-YOLOv5s  | 8.3                   | 95.2  |
| YOLOv7        | 36.9                  | 95.8  |
| ResNet50      | 25.6                  | 90.6  |
| GhostNet      | 7.3                   | 96.5  |
| 本文中算法         | 7.1                   | 97.3  |

### 3.4 消融实验

为了进一步深入评估改进后的 RepVGG 模型的贡献和优势，笔者进行了消融实验，逐步评估其各个组成部分的影响。如表 3 所示，笔者对提出的各个模块进行了组合实验，通过参数量、准确率、精确率、召回率、F1 Score 等判断指标全面验证了本文中所提方法的有效性能。对比实验结果表明：本文中采用的各个模块显著提升了原模型的整体性

能，验证了其在复杂环境下疲劳驾驶检测中的有效性。此外，改进后的 RepVGG 模型的参数量仅为  $7.1 \times 10^6$ ，flops 为  $1.43 \times 10^9$ ，符合轻量级检测模型的标准，将其部署在嵌入式设备上的难度会大幅度降低。

笔者所用算法在暗光情况、驾驶员佩戴墨镜以及暗光情况下配戴墨镜等复杂环境中，始终表现出较高的疲劳检测、识别和判定精度。为直观展示检测效果，使用笔者改进后的方法对复杂环境下的疲劳驾驶图像进行可视化，检测实际效果如图 6 所示。



(a) 暗光配戴墨镜疲劳检测 (b) 亮光配戴墨镜疲劳检测

图 6 实际检测效果

表 3 消融实验

| 算法               | ASPP | CBAM | 准确率   | 精确率   | 召回率   | F1 Score |
|------------------|------|------|-------|-------|-------|----------|
| RepVGG           | -    | -    | 94.83 | 94.86 | 94.82 | 94.83    |
| RepVGG_ASPP      | √    | -    | 96.63 | 96.62 | 96.66 | 96.63    |
| RepVGG_CBAM      | -    | √    | 96.30 | 96.34 | 96.28 | 96.29    |
| RepVGG_ASPP_CBAM | √    | √    | 97.34 | 97.35 | 97.33 | 97.34    |

## 4 结论

笔者以复杂环境下的疲劳驾驶检测为背景，针对现有的疲劳驾驶检测算法在低光照、驾驶员佩戴墨镜及低光照配戴墨镜等复杂情况下检测精度低、漏检错检等问题，提出一种改进的 RepVGG 疲劳检测算法，通过引入 ASPP 模块和 CBAM 对基础网络 RepVGG 进行优化。实验结果表明：改进后的 RepVGG 算法在复杂情况下的疲劳驾驶检测数据集中，检测准确率达到 97.34%，相较于原始网络提升了 2.51%。改进后的模型不仅提升了检测精度，而且符合轻量级模型的标准。未来的研究可以进一步关注改进方法的可扩展性和实时性能，将改进模型部署到嵌入式设备上，例如 JetsonNano 等，以提高模型的实用性。

现阶段，本实验使用的驾驶员疲劳检测数据集基于模拟驾驶场景，对于疲劳状态的主观定义不可避免地存在一定局限性。未来，笔者将专注于收集来自真实驾驶场景的驾驶员疲劳数据，以便深入开展进一步的研究。

## 参考文献：

- [1] SIKANDER G, ANWAR S. Driver fatigue detection systems: A review[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(6): 2339-2352.
- [2] SAVAS B K, BECERIKLI Y. Behavior-based driver fatigue detection system with deep belief network[J]. Neural Computing and Applications, 2022, 34(16): 14053-14065.
- [3] BAI J, YU W, XIAO Z, et al. Two-stream spatial-temporal graph convolutional networks for driver drowsiness detection[J]. IEEE Transactions on Cybernetics, 2021, 52(12): 13821-13833.
- [4] DING X, ZHANG X, MA N, et al. Repvgg: Making vgg-style convnets great again[C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2021: 13733-13742.
- [5] 李海军, 孔繁程, 魏嘉成, 等. 基于深度学习的小样本目标检测综述[J]. 兵工自动化, 2024, 43(1): 35-42.
- [6] 冯世霖, 李作进, 史蓝洋, 等. 改进的轻量级 GBC-YOLOv5 疲劳驾驶检测方法[J]. 重庆科技学院学报(自然科学版), 2023, 25(4): 65-73.