

基于优化 CBAM 改进 ResNet50 的异常行为识别方法^{*}

周璇¹ 易剑平²

(1. 西安交通工程学院机械与电气工程学院 西安 710300; 2. 西安工程大学电子信息学院 西安 710600)

摘要:在自动视频监控应用中,准确地识别出人类的异常行为是非常困难的任务。为了解决监测系统中异常人类活动的高效识别问题,提出了一种加强局部以及全局特征信息融合的异常行为识别模型 ICBAM-ResNet50。在 UTI 和 CASIA 两个数据集上进行实验,结果表明该研究比 ResNet50 模型准确率分别提高了 7% 和 8%。ICBAM 模块引入一维卷积替换了原始 CBAM 中通道注意力的 MLP 操作,将局部的时间特征整合到通道描述符中,缓解了通道维度由于全局处理产生的忽略信息交互的问题;其次引入时空注意力机制替换 CBAM 中的单一空间注意力机制,来提高模型的时空表征能力。最后,将优化的 CBAM 模块嵌入到 ResNet50 中,通过在 ImageNet 上对其进行预训练,在两个基准数据集上该模型分别达到了 98.8% 和 97.9% 的准确率。使用相同的数据集,将实验结果与原始识别方法进行了比较,结果表明该模型优于所比较的其他方法。

关键词:异常行为识别;CBAM;注意力机制;ResNet50

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 510.4

Improved abnormal behavior recognition method of ResNet50 based on optimized CBAM

Zhou Xuan¹ Yi Jianping²

(1. School of Mechanical and Electrical Engineering, Xi'an Traffic Engineering Institute, Xi'an 710300, China;

2. School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710600, China)

Abstract: In automatic video surveillance applications, accurately identifying abnormal human behavior is a very difficult task. To solve the problem of efficient recognition of abnormal human activities in the monitoring system, an abnormal behavior recognition model ICBAM-ResNet50 that strengthens the fusion of local and global feature information is proposed. Experiments are carried out on the UTI and CASIA datasets, and the results show that the accuracy of the study is 7% and 8% higher than that of the ResNet50 model, respectively. The ICBAM module introduces one-dimensional convolution to replace the MLP operation of channel attention in the original CBAM, integrating local temporal features into channel descriptors. Which alleviates the problem of ignoring information interaction caused by global processing in the channel dimension. Secondly, the spatiotemporal attention mechanism is introduced to replace the single spatial attention mechanism in CBAM to improve the spatiotemporal representation ability of the model. Finally, the optimized CBAM module is embedded in ResNet50, and by pre-training it on ImageNet, the model achieves 98.8% and 97.9% accuracy on two benchmark datasets, respectively. Using the same dataset, the experimental results are compared with the original recognition method, and the results show that the model is superior to the other methods compared.

Keywords: abnormal behavior recognition; CBAM; attention mechanism; ResNet50

收稿日期:2023-11-23

^{*} 基金项目:陕西省教育厅科学研究计划(23JK0529)项目资助

0 引言

近年来,随着人工智能技术的飞速发展,视频监控系统在安防领域已经成为当代社会不可或缺的一部分^[1]。在传统的视频监控中,大量的视频信息需要在屏幕上进行人工监控,这不但需要大量人力,而且效率也不尽人意。为了提高视频监控的效率,传统视频监控逐渐发展为智能视频监控,该技术有效地运用了图像智能分析、视频智能分析、人工智能等技术^[2]。与传统的视频监控相比,它可以实时检测、识别和理解图像,同时也减少了时间和人力的浪费^[3]。本文主要研究智能视频监控中的视频智能分析技术,能够快速准确地分析监控视频中的不同画面信息,高效识别视频中的异常行为。

卷积神经网络(convolutional neural network,CNN)是主流的深度学习方法,大多数新的神经网络都是在此基础上延伸、优化的^[4],包含 AlexNet^[5]、VGG-Nets^[6]、GoogLeNet^[7]等,这些经典的网络都曾在图像分类、目标检测等领域获得过优秀的战绩^[8]。在基于视频的人体异常行为识别任务中,除了从每个单独的图像中提取空间特征外,还需要提取视频帧之间的时间信息。Ji 等^[9]提出的 3D CNN 框架是一种有效的策略,其在二维空间卷积的基础上增加了一维时间信息,从而将不同视频帧联系起来。该网络分别对空间域和时间域的 x 、 y 方向进行特征提取,其提取的特征更具有代表性,且在 KTH 数据集表现优秀,也为行为识别提供了新思想。受此启发,Simonyan 等^[10]提出了双流 CNN,其将视频帧和对应的光流信息分为两个分支,分别用于提取空间和时间特征。然而,3D CNN 和双流 CNN 的计算成本高,对硬件设备的要求高,无法在移动设备或嵌入式设备上进行部署,一定程度地限制了其在实际中的应用。对于异常行为识别,上述方法不能较好地捕获时间维度的依赖关系,因此,识别性能较差。

为了进一步提高网络的性能,很多学者开始对注意力机制进行研究,其能够直接嵌入到 2D CNNs 中,使其关注重要的特征,抑制不必要的特征。基于此,Hu 等^[11]提出了 SE(squeeze-and-excitation)注意力机制,其是在通道维度上增加注意力机制,通过对获取到特征图的每个通道赋予不同的权重,从而实现重点关注某些特征通道。然而,该网络中的降维操作会给通道注意力机制带来副作用,并且捕获所有时间之间的依赖关系效率很低。在此基础上,Wang 等^[12]提出了高效通道注意力(efficient channel attention,ECA)机制,该模块通过使用一维卷积来完成跨通道间的信息交互,卷积核的大小通过一个函数来自适应变化,使得通道数较大的层可以更多地跨通道交互。该模块避免了维度缩减,并有效捕获了跨通道交互。此外,卷积块注意力模块(convolutional block attention module,CBAM)^[13]从通道和空间两个维度出发,实现从通道到空间的顺序注意力结构。空间注意力可使神经网络更加关注图像中对识别起决定作用的像素区域而忽略无关紧要

的区域,通道注意力则用于处理特征图通道的分配关系,同时对两个维度进行注意力分配增强了注意力机制对模型性能的提升效果。将这些注意力机制模块嵌入到残差网络^[14]中可以提高识别人体异常行为的性能,然而,这些方法仅仅只关注了空间或时间特征中的其中一个,对于视频行为识别任务而言,捕获空间和时间依赖关系缺一不可。

本文提出对传统的 CBAM 算法进行优化,通过将时间特征提取整合到通道以及空间注意力机制中,来提高通道时空信息的特征融合能力。并且,将 ICBAM 模块插入到经典的 ResNet50 中,该模块沿着通道和时空两个独立的维度对视频帧的重要信息进行提取,从而获得其此时每个通道以及时空信息的权重^[15]。此外,采用迁移学习对 ICBAM-ResNet50 模型进行训练,从而提高模型的更新速度以及鲁棒性。

1 网络设计

1.1 基于 CBAM 的改进注意力模块

CBAM 注意力机制主要通过学习不同通道之间以及不同空间位置的重要性,来提取具有区分性的空间和通道特征,以便模型更好地关注特征“在哪里”和“是什么”。其参数量较小,并且在多个数据集的检测和分类任务上表现出良好的泛化性能。但异常行为数据集往往具有背景复杂、姿态多样、大小不一等特点,并且在时间维度上表现出极强的复杂性,因此本文对 CBAM 注意力机制进行了优化,将时间特征学习整合到通道和空间注意力机制中,进一步提高其识别性能。改进后的 CBAM 注意力机制的结构如图 1 所示。




图 1 ICBAM 结构

Fig. 1 ICBAM structure diagram

原通道注意力机制首先分别采用全局最大池化和平均池化对特征图的空间信息进行聚合,之后再采用 MLP 对中间特征图进行先降维后升维,最后再经过 Sigmoid 操作^[16]生成最终的通道注意力特征。这一系列操作对捕获通道之间的交互信息是低效的,因此本文对 CBAM 的通道注意力机制进行了改进。采用时间维度的一维卷积替换原始的 MLP 操作,避免维度缩减,从而减少了特征损失,实现高效的跨通道交互。并且,通过固定的时间滤波器将局部的时间关系整合到通道描述符中,有助于模型更好地关注特征“在何时”和“是什么”。最后,经过 Sigmoid 操作生成最终的通道注意力掩码,并通过元素式的乘法操

作来激活原始特征。通道注意力计算公式如下:

$$M_{IC}(F) = \sigma(\text{conv}1d_{k=3}(\text{AvgPool}(F))) = \sigma(W(F_{avg}^c)) \quad (1)$$

式中: σ 为 Sigmoid 函数; $\text{conv}1d_{k=3}$ 表示卷积核大小为 3 的一维卷积; AvgPool 表示平均池化操作; W 表示各个通道所占的权重。改进后的 CBAM 注意力机制的通道注意力(ICA)模块如图 2 所示。




图 2 ICBAM 的通道注意力模块

Fig. 2 Channel attention module of ICBAM

原空间注意力机制主要是对通道注意力机制的输出特征图进行空间维度的处理。首先沿着通道维度对输入特征图进行最大池化和平均池化操作,然后采用卷积核聚合后的特征图进行空间特征提取,从而捕获到全局的空间信息,最后经过 Sigmoid 操作生成最终的空间注意力特征。由于现在大多数行为识别数据集都是视频格式,而此操作只关注了空间维度,而忽略了时间维度的信息,因此本文改变了原始 CBAM 的空间注意力机制,采用时空注意力机制来更好地提取时间和空间维度的信息。首先,在时间维度上应用通道方向的一维卷积来融合时间信息,不仅能够学习通道维度的信息还可以降低计算量。此操作可表述为:

$$G_{c,t} = \sum_i K_i^* F_{c,t+i}^* \quad (2)$$

式中: K_i^* 表示属于通道 c 的时间组合核权值; i 是时间核的索引值; $F_{c,t+i}^*$ 表示输入特征的序列; $G_{c,t}$ 表示通道时序融合特征的更新结果。然后,再通过卷积核为 3×3 的二维卷积对局部空间信息进行建模。改进后的 CBAM 注意

力机制的时空注意力(ISA)模块如图 3 所示。




图 3 ICBAM 的时空注意力模块

Fig. 3 Spatiotemporal attention module of ICBAM

1.2 ICBAM-ResNet50 模型整体架构

所提出的 ICBAM 注意力机制通过在通道维度以及时空维度为输入数据进行特征提取,对局部信息和全局信息进行了高效融合,从而极大提高了模型的识别性能。该注意力机制采用通道注意力模块和时空注意力模块,能够以全局和局部融合的模式来捕获视频中的短期和长期的信息,同时还能够减少模型的计算成本。此外,所提出的 ICBAM 注意力机制和原始 CBAM 一样,能够以即插即用的方式嵌入到 2D CNN 中。

为进一步提取高效的空间表示来验证 ICBAM 注意力机制的有效性,本文采用 ResNet50 实例化该机制。首先,将 ICBAM 注意力机制嵌入到 ResNet50 的瓶颈块中从而构建 ICBAM-block。然后,使用构建的 ICBAM-block 来替换 ResNet50 的 Conv_2 至 Conv_5 的所有残差单元,从而构建出了一个加强局部以及全局特征信息融合的异常行为识别模型 ICBAM-ResNet50。最后,应用时间平均池化来聚合所有的帧级预测,从而得到视频级的预测结果。网络的整体架构如图 4 所示。ICBAM 的引入可以提高 ResNet50 的性能,使其能够更高效地捕捉特征信息并提高识别准确率。通过使用通道和时空注意力机制,ICBAM 模块能够自适应地选择和调整特征图中的重要信息,从而提高网络的表达能力和感知能力。




图 4 ICBAM-ResNet50 网络的整体架构

Fig. 4 The overall architecture of the ICBAM-ResNet50 network

2 实验结果与分析

2.1 数据集与实验细节

为了验证所提出的异常行为识别模型 ICBAM—

ResNet50 的有效性,本文在 UTI^[17]和 CASIA 数据集(<http://www.cbsr.ia.ac.cn/china/Gait%20Databases%20CH>)^[18]上进行实验。由于这两个数据集属于小规模数据集,因此训练集和测试集都遵循 4:1 的分配比例。UTI

数据集含有6种行为,由160段视频剪辑组成,其中训练集有128段视频,测试集有32段视频。CASIA数据集主要包括15种人体行为,总共1446个视频,其中包括1213段训练视频和233段测试视频。

由于这两个数据集规模都比较小,从头开始训练一个鲁棒性好的识别异常行为的网络还比较困难。因此,本文使用迁移学习^[18]对ICBAM-ResNet50模型进行训练。在本实验中,将UTI以及CASIA行为数据集作为目标域,而ImageNet数据集作为源域。先使用源域对ICBAM-ResNet50网络进行训练,再使用迁移学习将其模型应用在目标域上,并对其参数进行微调。采用UTI和CASIA行为数据集用来评估所提出识别异常行为的整体网络框架的性能。

本文在Pytorch框架上实现所提出的ICBAM-ResNet50,并利用小批量梯度算法优化模型,其动量设置为0.9,权重衰减系数为0.0005,初始学习率为0.001,并在训练到30、40和45轮次时,学习率衰减10倍。最后,网络在UTI和CASIA数据集上都训练50轮次。为了减少过拟合,采用多尺度裁剪技术、水平翻转和垂直翻转作为数据增强^[19],并在全局平均池化层之后添加一个比例为0.5的dropout层^[20]。

2.2 网络模型实验对比

为了客观评价本文方法的性能,实验对ICBAM-ResNet50与2D CNN、双流CNN、3D CNN以及一些经典网络组合算法分别在UTI和CASIA数据集上进行对比,量化的比较结果如表1所示。

表1 本文算法与其他经典网络组合算法的性能对比

Table 1 The performance of the proposed algorithm is compared with other classical network combination algorithms

UTI 数据集		CASIA 数据集	
方法	准确率/%	方法	准确率/%
YOLO v3+	83.8	2D-CNN+	89.7
VGG16 ^[21]		LSTM ^[23]	
Inception v3+	92.31	Farneback	92.33
LSTM ^[22]		光流算法 ^[24]	
CNN, Kalman+	97	双流深度残差	97.5
LSTM ^[21]			
本文算法	98.8	本文算法	97.9

由表1可知,本文算法在UTI、CASIA数据集上均取得了先进的结果。在UTI数据集上,本文算法要明显地优于相同实验条件下的2D CNNs架构,YOLO v3+VGG16(98.8% vs 83.8%),进一步验证了时间建模在异常行为识别任务中的必要性。相比于CNN+LSTM的架构,本文采用了ResNet50作为主干网络,有利于提取到更加深层次的特征,并有利于缓解梯度消失和网络退化的问题。此外,本文通过在ResNet50中引入ICBAM注意力机制,

进一步提升了网络的时间特征学习能力。同时,长短期记忆网络(long short term memory,LSTM)在建模时序信息时会引入大量的参数,不利于网络的后期优化。在CASIA数据集上,与2D-CNN+LSTM和Farneback光流算法相比,本文算法的准确率分别提升了8.2%和5.57%。原因在于CASIA数据集存在视角变化、背景混乱等问题,本文算法通过采用ICBAM注意力机制过滤掉与识别任务无关的背景信息而只保留人体相关信息,减少了噪声的干扰。本文算法与双流深度残差相比,准确率提升了0.4%。此外,双流网络的时间流网络需要将预先提取的光流图像作为输入模态,而提取光流的时间开销较大,会导致设备延迟的问题,不利于在移动端或者嵌入式设备上部署。本文算法只采用了RGB视频帧作为输入,对硬件设备要求相对较低,具有较高的实际应用价值。

2.3 消融实验

针对人体异常行为识别的应用需求,进一步证明本文所提出的ICBAM注意力机制的子模块ICA模块和ISA模块的有效性,以ResNet50模型作为主干网络在UTI数据集上进行消融实验,定性的比较结果如表2所示。

表2 消融实验结果

Table 2 Results of ablation experiments

+ CBAM	+ ICA	+ ISA	+ ICBAM	准确率/%
—	—	—	—	91.2
✓	—	—	—	93.4
—	✓	—	—	96.9
—	—	✓	—	97.5
—	—	—	✓	98.8

由表2可知,在ResNet50基础上引入CBAM注意力机制对UTI数据集的识别结果有较小的准确率提升,这表明缺少时间建模难以处理复杂的行为动作。采用ICA模块替换原始CBAM的通道注意力机制,准确率提升了3.5%,这是由于一维卷积避免了维度缩减,从而实现高效的跨通道交互,同时,ICA将局部的时间关系整合到通道特征中,提高了模型的时间表征能力。采用ISA模块替换原始CBAM的空间注意力机制,使其更好地在时空维度捕获特征的同时,降低网络计算量。引入ICBAM注意力机制在原CBAM基础上提高了5.4%,这进一步强调了时间建模的必要性。其不仅能够以全局和局部融合的模式捕获视频中的短期和长期的信息,显著提升了模型的泛化性能。

2.4 可视化研究

为了验证ICBAM-ResNet50模型对视频中人体异常行为的建模能力,对ICBAM-ResNet50的行为推理过程进行了可视化研究。该研究主要通过绘制类激活映射图来评估ICBAM-ResNet50对运动显著区域的定位能力。ICBAM-ResNet50中Conv_4的中间帧类激活映射图如

图5所示,颜色越深的区域表明该模型在学习过程中越关注的地方。由图5可知,ICBAM-ResNet50在特征学习的过程中,能够显式地聚焦于运动显著区域,如在人体在打拳、踢、指和推时,模型更加关注手部、腿部行为的细节,这将进一步提高模型预测的准确性。这些实验结果表明,所提出的ICBAM注意力机制通过运动显著区域的类激活响应来描述行为,从而进一步提高模型对运动显著区域的定位能力。




图5 ICBAM-ResNet50模型的类激活映射图

Fig. 5 Class activation map of the ICBAM-ResNet50 model

3 结论

由于异常行为数据集具有背景复杂、姿态多样、大小不一等特点,本文提出了一种基于优化CBAM改进ResNet50的异常行为识别方法。该模型采用ResNet50作为主干网络,用改进后的ICBAM-block替换其原有基本残差单元。ICBAM注意力机制通过ICA模块来实现通道维度上的原始特征重标定,通过ISA模块来建模通道方向的时空特征,使其能够在降低计算量的同时提升其时空表征能力。此外,在没有任何3D卷积和预计算光流的情况下,所提出的ICBAM-ResNet50模型在人体异常行为相关数据集上均能取得先进的结果,与ResNet50基线相比,准确率均得到了提升,为异常行为识别提供了一种高效的方案。

参考文献

- [1] 钱慧芳,易剑平,付云虎. 基于深度学习的人体动作识别综述[J]. 计算机科学与探索, 2021, 15(3): 438-455.
- QIAN H F, YI J P, FU Y H. Review of human action recognition based on deep learning[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(3): 438-455.
- [2] 龚捷,罗聪,罗琴. 基于注意力机制和残差网络的动作识别模型[J]. 电子测量技术, 2021, 44(14): 111-116.

- GONG J, LUO C, LUO Q. Action recognition model based on attention mechanism and residual network[J]. Electronic Measurement Technology, 2021, 44(14): 111-116.
- [3] 朱阳光,刘瑞敏,黄琼桃. 基于深度神经网络的弱监督信息细粒度图像识别[J]. 电子测量与仪器学报, 2020, 34(2): 115-122.
- ZHU Y G, LIU R M, HUANG Q T. Fine-grained image recognition of weak supervisory information based on deep neural network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2): 115-122.
- [4] QIAN H, ZHOU X, ZHENG M. Abnormal behavior detection and recognition method based on improved resnet model[J]. Computers, Materials & Continua, 2020, 65(3): 2153-2167.
- [5] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]. Proceedings of the Annual Conference and Workshop on Neural Information Processing Systems, 2012, 2: 1097-1105.
- [6] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]. Proceedings of the International Conference on Learning Representations, 2015: 1-14.
- [7] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [8] 周璇,易剑平. 基于时间上下文模块的人体动作识别方法[J]. 国外电子测量技术, 2022, 41(10): 72-79.
- ZHOU X, YI J P. Human action recognition method based on temporal context network [J]. Foreign Electronic Measurement Technology, 2022, 41(10): 72-79.
- [9] JI S, XU W, YANG M, et al. 3D convolutional neural networks for human action recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(1): 221-231.
- [10] SIMONYAN K, ZISSERMAN A. Two-stream convolutional networks for action recognition in videos [C]. Proceedings of the Advances in Neural Information Processing Systems, 2014: 568-576.
- [11] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 7132-7141.
- [12] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional

- neural networks[C]. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2022: 11531-11539.
- [13] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the 15th European Conference on Computer Vision, Springer, 2018: 3-19.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [15] ZHOU X, YI J. Fine-grained action recognition based on temporal pyramid excitation network [J]. Intelligent Automation & Soft Computing, 2023, 37(2): 2103-2116.
- [16] LI Z, YANG W, PENG S, et al. A survey of convolutional neural networks: Analysis, applications, and prospects[J]. arXiv preprint, arXiv:2004.02806, 2020.
- [17] RYOO M, AGGARWAL J. UT-interaction dataset, ICPR contest on semantic description of human activities[C]. Proceedings of the IEEE International Conference on Pattern Recognition Workshops, 2010, 2: 4.
- [18] QIAN H, ZHOU X, ZHENG M. Detection and recognition of abnormal behavior based on multi-level residual network[C]. Proceedings of the IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference, 2019: 2572-2579.
- [19] 周育新,白宏阳,李伟.基于关键帧的轻量化行为识别方法研究[J].仪器仪表学报,2020,41(7):196-204.
ZHOU Y X, BAI H Y, LI W. Research on lightweight action recognition method based on key frame[J]. Chinese Journal of Scientific Instrument, 2020, 41(7): 196-204.
- [20] POERNOMO A, KANG D. Biased dropout and crossmap dropout: Learning towards effective dropout regularization in convolutional neural network[J]. Neural Networks, 2018, 104: 60-67.
- [21] KO K, SIM K. Deep convolutional framework for abnormal behavior detection in a smart surveillance system [J]. Engineering Applications of Artificial Intelligence, 2018, 67: 226-234.
- [22] 姬晓飞,谢旋,任艳.深度学习的双人交互行为识别与预测算法研究[J].智能系统学报,2020,15(3):484-490.
JI X F, XIE X, REN Y. Human interaction recognition and prediction algorithm based on deep learning [J]. CAAI Transactions on Intelligent Systems, 2020, 15(3):484-490.
- [23] 李俊鹏,姬晓飞,赵东阳.基于深度学习的人体跟踪与异常行为识别联合算法[J].沈阳航空航天大学学报,2022,39(4):51-59.
LI J P, JI X F, ZHAO D Y. Joint algorithm of human tracking and abnormal behavior recognition based on deep learning [J]. Journal of Shenyang Aerospace University, 2022, 39(4):51-59.
- [24] 郑萌萌,钱慧芳,周璇.基于监控视频的Farneback光流算法的人体异常行为检测[J].国外电子测量技术,2021,40(3):16-22.
ZHENG M M, QIAN H F, ZHOU X. Human abnormal action detection based on the Farneback optical flow arithmetic of surveillance video [J]. Foreign Electronic Measurement Technology, 2021, 40(3): 16-22.

作者简介

周璇,硕士,讲师,主要研究方向为人体动作识别、人体检测、模式识别与图像处理等。

E-mail:1138845898@qq.com

易剑平,硕士研究生,主要研究方向为视频理解、图像处理、动作识别等。