

## 基于卷积神经网络的矿井安全帽佩戴检测\*

刘欣, 张灿明

(安徽省煤炭科学研究院, 安徽 合肥 230001)

**摘要:** 在煤矿生产中, 工人由于未佩戴安全帽而受伤的事故时有发生。为了构建数字化安全帽监测系统, 提出了一种基于卷积神经网络的安全帽佩戴检测模型。采用先进的 Darknet53 网络作为模型主干, 用于提取图片的特征信息。此外, 在模型中引入注意力机制用于丰富特征之间的信息传播, 增强模型的泛化能力。最后, 制作了安全帽佩戴预训练数据集和实际矿井场景数据集, 并在 PyTorch 平台进行全面的对比实验验证了模型设计的有效性, 模型在实际矿井场景数据集上获得 92.5 mAP 的优异性能。

**关键词:** 安全帽佩戴检测; 深度学习; 卷积神经网络; 注意力机制

**中图分类号:** TN919.8; TP391.41

**文献标识码:** A

**DOI:** 10.16157/j.issn.0258-7998.200109

**中文引用格式:** 刘欣, 张灿明. 基于卷积神经网络的矿井安全帽佩戴检测[J]. 电子技术应用, 2020, 46(9): 38-42, 46.

**英文引用格式:** Liu Xin, Zhang Canming. Wearing safety helmet detection based on convolutional neural networks for mines[J]. Application of Electronic Technique, 2020, 46(9): 38-42, 46.

## Wearing safety helmet detection based on convolutional neural networks for mines

Liu Xin, Zhang Canming

(Anhui Academy of Coal Science, Hefei 230001, China)

**Abstract:** In the production of coal mines, accidents happen to workers once in a while because of absence of safety helmet. In order to establish digital safety helmet detection system, a wearing safety helmet detection model based on convolutional neural networks is proposed. Specifically, the model is based on advanced Darknet53 as model backbone, which is used to extract feature information from pictures. In addition, attention mechanism is introduced to enrich the propagation of information between features, enhancing the generalization of model. Finally, a wearing safety helmet pre-training dataset and a real mine scene dataset are built, and comprehensively comparative experiments are conducted on PyTorch platform to verify the effectiveness of the model designs, which achieves an excellent performance of 92.5 mAP on the real mine scene dataset.

**Key words:** wearing safety helmet detection; deep learning; convolutional neural networks; attention mechanism

## 0 引言

在煤矿生产过程中, 佩戴安全帽对于生产人员的人身安全至关重要。但由于缺乏安全意识和监管不足等原因, 工人因未佩戴安全帽而受伤的事故频频发生, 轻则停工整顿影响生产进度, 重则危害生命安全。现如今, 在数字化矿山的发展浪潮中, 对于安全帽佩戴的监测需求日益提升。

自 2012 年 AlexNet<sup>[1]</sup>在 ImageNet 图片分类比赛上大放光彩, 以卷积神经网络(Convolutional Neural Networks, CNNs)为代表的深度学习技术在多个领域上取得突破性成功, 例如人脸检测<sup>[2]</sup>、火灾预防<sup>[3]</sup>、风格迁移<sup>[4]</sup>等。基于 CNNs 的目标检测方法采用多个卷积层堆叠, 凭借着卷积运算的特性, 能够自动地获取丰富的特征信息, 进而

分类获得优异的预测性能。在目标检测领域, 基于深度学习的方法多数可分成两类: 第一类是基于候选区域的检测方法, R-CNN<sup>[5]</sup>率先将深度学习技术应用于目标检测任务。Faster R-CNN<sup>[6]</sup>引入候选区域网络替代手工选择候选区域, 并实现多步骤联合训练; 第二类是基于回归分类的检测方法, REDMON J 等人<sup>[7]</sup>率先提出单步目标检测模型 YOLO, 该模型将待检图片分成若干个网格区域, 直接预测目标边界框和置信度。在此之后, YOLO2<sup>[8]</sup>和 YOLO3<sup>[9]</sup>在 YOLO 的基础上增加了多种深度学习技术, 大幅度提升预测性能和推断速度。

对于安全帽佩戴检测, 大多数现有方法可以归纳为 3 个方案, 如图 1 所示。

(1) 基于行人检测模型的方案<sup>[10]</sup>, 使用行人检测模型检测出行人所在的位置区域, 再添设分类器判断行人是否佩戴安全帽。此方案的缺点在于: 模型需要分步设计、训练、调优, 且难以获得安全帽的位置信息。

\* 基金项目: 安徽科技创新战略与软科学研究专项项目(1706a02020044); 安徽省重点研究与开发计划项目(1704a0902063)

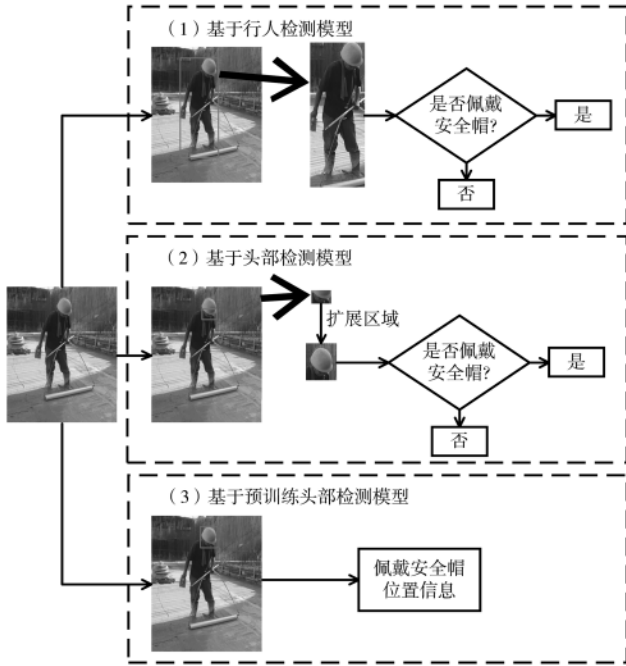


图1 安全帽佩戴检测方法对比示意图

(2)基于头部检测模型的方案<sup>[11]</sup>,使用头部检测模型检测行人的头部位置区域,扩展得到安全帽待检区域。再添设分类器对待检测区域做分类。此方案的缺点在于:模型需要分成多步骤,且安全帽待检区域的选取较为困难。

(3)基于预训练头部检测模型的方案<sup>[12]</sup>,基于深度学习技术构造端对端的检测模型,能够使用单步骤的卷积神经网络模型获得安全帽的准确信息。但此类方法构建的模型难以训练和收敛,且泛化能力差。

本文针对方案(3)存在的难点,选用预训练的 Darknet53<sup>[8]</sup>作为模型主干,并引入基于注意力机制的特征提取模块用于增强模型的泛化能力。本文主要贡献如下:

(1)选用先进的 Darknet53 网络作为模型主干,并在模型中引入基于注意力机制的特征提取模块,促使模型能够适应不同检测场景,大幅提升模型检测性能;

(2)收集 7 000 多张图片构成安全帽佩戴预训练数据集用于预训练模型,收集并标注 4 000 张实际矿井图片构成矿井场景数据集,用于测试模型对不同的环境的泛化能力。

## 1 安全帽佩戴检测模型

### 1.1 基于注意力机制的特征提取模块

注意力机制是受人类视觉机制启发<sup>[13]</sup>,在卷积神经网络通过提取特征图的权重向量,用以对特征图的通道加权,促使模型的特征信息相互传播。注意力机制的本质是增强模型中各个尺度特征之间的信息传播,有效地捕获图片的全局上下文信息,包含感受野较大的语义信息和感受野较小的空间信息,提升模型预测目标的类别和边界的准确性。

考虑到实际矿井生产场景的复杂性,本文提出基于注意力机制的特征提取模块,用于提升模型的泛化能力。具体来说,本文引入两个特征提取模块:通道注意力模块和空间注意力模块。通道注意力模块是通过全局平均池化层(Global Average Pooling, GAP)捕获输入特征的通道特征权重向量,并将权重向量按各个通道加权到输入特征图,如图 2 所示。




图2 通道注意力模块结构图

对于输入特征图  $X_c = \{x_1, \dots, x_n\}$  而言,经过 GAP 层后,输出的权重向量为  $V_{gmp} = \{v_1, \dots, v_n\}$ 。 $V_{gmp}$  用于对  $X_c$  按通道加权,实现特征之间的信息传播,最终输出特征图  $Y_c = \{y_1, \dots, y_n\}$ ,计算过程如式(1)所示:

$$y_c = \Psi(x_c, \text{GAP}(x_c)) = \sum_d^D (\xi(v_c) x_d + x_d) \quad (1)$$

其中,  $c \in \{1, \dots, n\}$ ,  $\Psi$  表示通道注意力运算, GAP 表示全局平均池化操作,  $D$  表示单通道输入特征图上各个特征点的集合,  $x_d$  表示单层特征图  $x_c$  上序号为  $d$  的特征点,  $\xi$  表示 sigmoid 激活函数。

类似地,空间注意力模块是通过全局最大池化层(Global Max Pooling, GMP)在输入特征图的空间维度上提取空间特征权重图,并将权重图按空间位置加权到输入特征图,如图 3 所示。




图3 空间注意力模块结构图

对于输入特征图  $X_s = \{x_1, \dots, x_n\}$  而言,将 GMP 层按空间维度应用于  $X_s$  之上,得到空间特征权重图  $M_{gmp} = \{m\}$ 。 $m$  用于对输入特征图  $X_s$  的空间坐标进行加权,增强特征图各通道之间的空间信息传播,最终输出特征图  $Y_s = \{y_1, \dots, y_n\}$ ,计算过程如式(2)所示:

$$y_c = \mathcal{A}(x_c, \text{GMP}(x_c)) = \sum_d^D (\xi(m_d) x_d + x_d) \quad (2)$$

其中,  $c \in \{1, \dots, n\}$ ,  $y_c$  表示  $Y_s$  内序号为  $c$  的特征图;  $\mathcal{A}$  表示空间注意力运算, GMP 表示按空间维度的全局最大

值池化操作; $x_d$ 表示单层特征图 $x_c$ 上序号为 $d$ 的特征点; $m_d$ 表示空间特征权重图 $M_{\text{gmp}}$ 上序号为 $d$ 的特征权重; $D$ 表示单通道特征图上各个特征点的集合; $\xi$ 表示sigmoid激活函数。

### 1.2 安全帽佩戴检测模型

本文选用 Darknet53 作为模型主干,并将通道注意力模块和空间注意力模块引入网络之中,检测模型结构如图4所示。

检测模型共包含 23 个残差卷积模块和 6 个卷积层。为了保持对各个尺度安全帽检测的有效性,模型在 3 个尺度上同时做目标检测。考虑到在 Darknet53 网络中,网络后端的特征图有较大的感受野和丰富的语义信息,适用于检测大目标。而网络前端的特征图有较小的感受野但具备丰富的空间信息,适用于检测小目标。基于这样的观察,本文在网络中引入基于注意力机制的特征提取模块,其中通道注意力模块应用于后端特征图的上采样过程中,增强特征图中的语义信息传播。空间注意力模块应用于前端特征图之上,增强特征图的空间信息传播。两个注意力模块共同增强模型的特征信息传播,实现两端的特征图相融合,提升模型在不同场景下的预测能力和泛化能力。

模型在预测目标时,需要对特征图中每个网格应用

多个尺寸和形状的 anchor。考虑到 anchor 的选择是强先验的手工选择特征,若 anchor 选择过多,模型的计算量成倍上升;若 anchor 选择过少,则不利于模型预测不同形状的目标。为了寻求模型在计算复杂度和准确率之间的平衡点,本文采用 k-means 聚类<sup>[8]</sup>对数据集中标注的安全帽做聚类处理。

在实际预测中,边界框大的目标相较于边界框小的目标有着更大的欧几里得距离,而模型的评价标准是获取更高的 IoU(Intersection-over-Union)值。故在聚类过程中,调整距离尺度 $d$ 的计算方法为式(3):

$$d(\text{box}, \text{center}) = 1 - \text{IoU}(\text{box}, \text{center}) \quad (3)$$

其中,box 为安全帽的边界框,center 是聚类时被选为中心簇的边界框,IoU 是计算目标边界框之间的 IoU 值函数。当目标边界框之间的 IoU 值越大时,目标边界框之间的距离 $d$ 越近。最终,本文选择 anchor 数量为 6,对应的边界框的宽和长的比例为:[0.57, 0.58, 0.59, 0.59, 0.61, 0.64]。

## 2 实验结果与分析

### 2.1 实验配置

本文构建安全帽佩戴预训练数据集,用于辅助模型预训练。预训练数据集共包含正负样本两部分:(1)负样本图片选用 SCUT-HEAD 数据集<sup>[14]</sup>,该数据集由 PartA 和

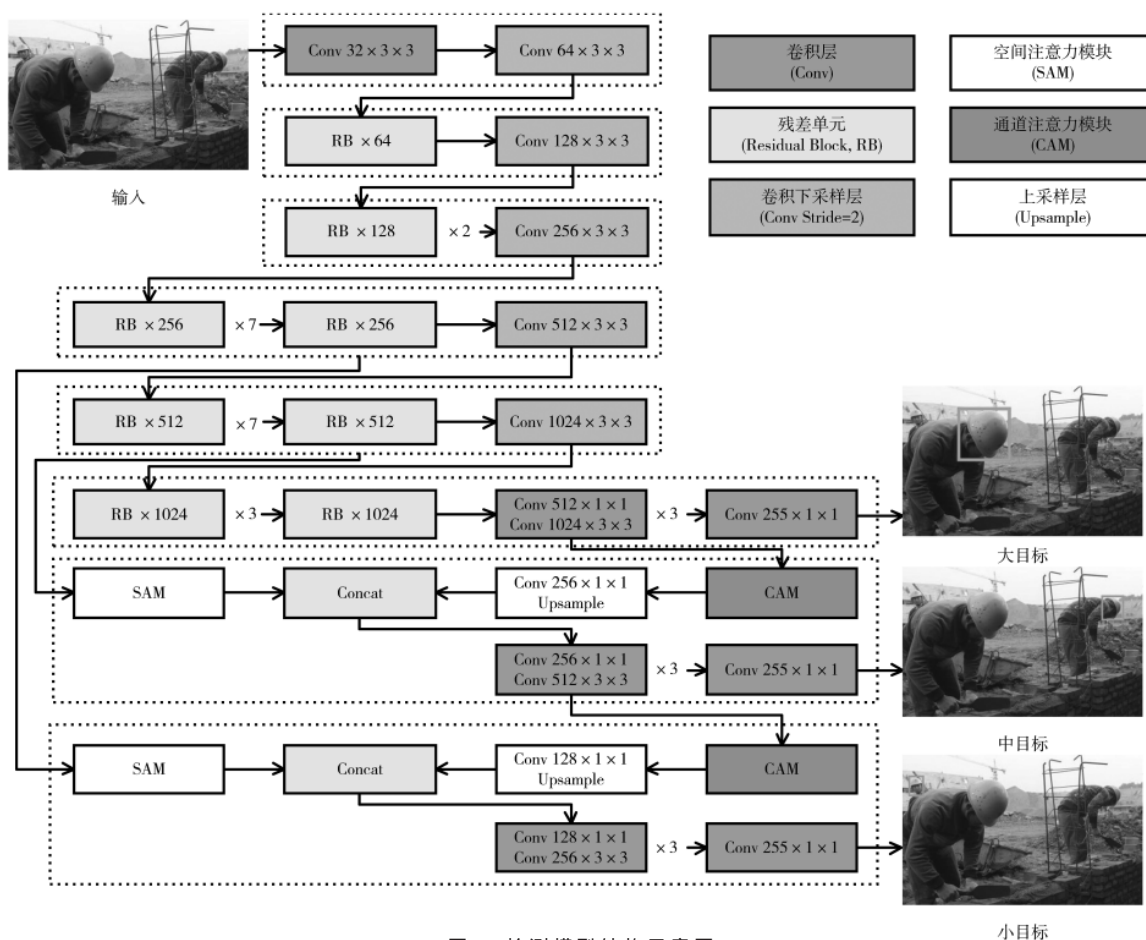


图4 检测模型结构示意图



PartB 组成, PartA 包含 2 000 张图片, 标注 67 321 组头部信息; PartB 包含 2 405 张图片, 标注 43 930 组头部信息。  
(2) 正样本部分包含标注安全帽佩戴图片共 3 219 张, 共包含 9 044 组佩戴安全帽的标注信息。

除预训练数据集之外, 本文制作实际矿井场景数据集。该数据集共 4 000 张图片, 来源于某矿场的监控视频设备。其中训练集有 3 200 张图片, 测试集有 800 张图片。本文使用 LabelImg 工具对所有图片进行标注, 部分案例如图 5 所示。



图 5 数据集示例图

实验设置: 所有实验基于 PyTorch<sup>[15]</sup>深度学习平台, 依据文献[8]的训练策略, 在训练时, 所有图片均放缩到 416×416 大小, 训练采用梯度下降优化器, 动量设置为 0.9, 权重衰减设置为 0.000 1。初始学习率设置为 0.000 5, 每 1 万次迭代学习率乘以 0.1。实验平台配置如表 1 所示。实验性能评价标准采用 mAP(mean Average Precision)、推断时间和速度(Frames Per Second, FPS)。

## 2.2 预训练数据集对比实验

预训练数据集包含正负样本两个部分, 其中负样本包含 PartA 和 PartB。为了验证该数据集的有效性, 本节以原始的 Darknet53 作为测试基准, 测试数据集不同部分对于预测性能的影响, 实验结果如表 2 所示。

表 2 预训练数据集实验对比表

实验	安全帽佩戴预训练数据集			性能/mAP
	负样本 PartA	负样本 PartB	正样本	
1			✓	75.7
2	✓		✓	78.1
3		✓	✓	81.8
4	✓	✓	✓	82.3

由表 2 可知, 当预训练数据集中不存在负样本时, 实验(1)的预测性能只达到 75.7 mAP。当预训练数据集分别添加 PartA 和 PartB 作为负样本时, 实验(2)和实验(3)分别获得了 2.4 mAP 和 6.1 mAP 的性能提升, 与 PartA 相比, PartB 包含的场景更为丰富, 带来的性能提升也更为

明显。当使用完整的预训练数据集时, 实验(4)获得最高性能 82.3 mAP。这说明在数据集中添加适量的负样本能够为模型带来大幅的性能提升。

## 2.3 模型结构设计对比实验

本节测试在模型中引入基于注意力机制的特征提取模块带来的性能变化和计算损耗, 实验以 2.2 节中实验(4)的模型为基准, 实验结果如表 3 所示。

表 3 基于注意力机制模块实验对比表

实验	通道模块	空间模块	性能/mAP	推断时间/ms	速度/(f/s)
1			82.3	26	38
2	✓		84.2	28	35
3		✓	84.5	27	37
4	✓	✓	86.0	31	32

由表 3 可知, 当模型不采用任何基于注意力机制模块时, 实验(1)的预测性能和推断时间分别达到 82.3 mAP 和 26 ms。当模型采用通道注意力模块和空间注意力模块时, 实验(2)和实验(3)分别获得了 1.9 mAP 和 2.2 mAP 的性能提升。当同时使用两个模块时, 实验(4)的预测性能达到 86.0 mAP, 推断时间为 31 ms。这说明使用基于注意力机制的特征提取模块能够在不显著增加模型的计算时间的前提下, 大幅提升模型预测性能。

在 1.2 节中, 本文调整了模型预测过程中的 anchor 配置。当使用不同的 anchor 配置时, 对比实验结果如表 4 所示。

表 4 Anchor 配置实验对比表

配置	性能/mAP	推断时间/ms	速度/(f/s)
默认 anchor	86.0	31	32
自定义 anchor	87.3	33	30

由表 4 可知, 当模型采用自定义的 anchor 配置时, 获得了 1.3 mAP 的性能提升, 而推断时间只增加了 2 ms。自定义的 anchor 配置对模型有明显的性能提升。

## 2.4 模型在实际数据集上的表现

本节以 2.3 节中最优模型为基准, 测试模型在实际矿井场景数据集的表现, 所有的实验结果如表 5 所示。

表 5 模型在矿井场景数据集实验对比表

实验	模型主干	预训练	注意力模块	自定义 anchor	性能/mAP
1	Resnet50	✓			81.3
2	Darknet53	✓			85.0
3	Darknet53	✓	✓		88.8
4	Darknet53	✓	✓	✓	90.5

由表 5 可知, 当模型采用不同的模型主干时, 基于 Resnet50 的实验(1)和基于 Darknet53 的实验(2)的预测性能分别达到 81.3 mAP 和 85.0 mAP, 基于 Darknet53 的实验(2)有着明显的性能领先。在实验(2)的基础上, 当模型

使用基于注意力机制的特征增强模块时,实验(3)获得了3.8 mAP的性能提升。当模型额外使用自定义 anchor 配置时,实验(4)获得了最高性能90.5 mAP。这说明本文提出的模型能够很好地满足煤矿场景下的安全帽佩戴检测需求。

### 3 结论

本文提出了一种基于 Darknet53 的安全帽佩戴检测模型,引入了基于注意力机制的特征提取模块用于增强模型的信息传播。此外,本文制定了安全帽佩戴预训练数据集和实际矿井场景数据集,用于训练模型和测试模型在不同场景下的有效性。实验结果表明提出模型在实际矿井场景下有着优异的预测性能。

(下转第46页)

(上接第37页)



图5 车标检测结果

### 参考文献

- [1] 王静波, 孟令军. 卷积神经网络人脸检测算法[J]. 电子技术应用, 2020, 46(1): 34-38.
- [2] 张璘, 杨丰琦. 基于深度学习的图像分类搜索系统[J]. 电子技术应用, 2019, 45(12): 51-55.
- [3] 李侠, 李文举, 孙娟红, 等. 基于模板匹配和边缘检测的车标定位方法[J]. 计算机工程与设计, 2011, 32(10): 3453-3456.
- [4] WANG Y, LIU Z, XIAO F. A fast coarse-to-fine vehicle logo detection and re-cognition method[C]. 2007 IEEE International Conference on Robotics and Biomimetics(ROBIO). IEEE, 2007: 691-696.
- [5] FUKUSHIMA K. Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position[J]. Biological-Cybernetics, 1980, 36(4): 193-202.
- [6] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic

### 参考文献

- [1] RAWAT W, WANG Z. Deep convolutional neural networks for image classification: a comprehensive review[J]. Neural Computation, 2017, 29(9): 2352-2449.
- [2] 王静波, 孟令军. 卷积神经网络人脸检测算法[J]. 电子技术应用, 2020, 46(1): 34-38.
- [3] 张杰, 隋阳, 李强, 等. 基于卷积神经网络的火灾视频图像检测[J]. 电子技术应用, 2019, 45(4): 34-38, 44.
- [4] 黄海新, 梁志旭, 张东. 基于深度学习的图像风格化算法研究综述[J]. 电子技术应用, 2019, 45(7): 27-31.
- [5] ZHAO Z Q, ZHENG P, XU S T, et al. Object detection segmentation[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). IEEE Computer Society, 2014: 580-587.
- [7] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]. 2005 IEEE Computer Society Conference on CVPR, 2005.
- [8] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[C]. Advances in Neural Information Processing Systems, 2015: 91-99.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [10] 张力, 张洞明, 郑宏. 基于联合层特征的卷积神经网络在车标识别中的应用[J]. 计算机应用, 2016, 36(2): 444-448.
- [11] REDMON J, FARHADI A. Yolov3: an incremental improvement[J]. arXiv Preprint arXiv: 1804.02767, 2018.
- [12] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv: 1409.1556, 2014.
- [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.

(收稿日期: 2020-02-05)

### 作者简介:

王林(1963-), 男, 博士, 教授, 主要研究方向: 复杂网络、社团分析、深度学习、数据挖掘等。

黄三丽(1993-), 女, 硕士研究生, 主要研究方向: 深度学习。

别邻居帧中对超分辨率有用的信息拟合到中心帧。与现有的方法相比,本文的框架达到更为先进的性能。

#### 参考文献

- [1] KRISHNA H, JAWAHAR C V. Improving small object detection[C]. Asian Conference on Pattern Recognition, 2017: 340-345.
- [2] FOOKES C, LIN F, CHANDRAN V, et al. Evaluation of image resolution and super resolution on face recognition performance[J]. Journal of Visual Communication and Image Representation, 2012, 23(1): 75-93.
- [3] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1646-1654.
- [4] CABALLERO J, LEDIG C, ANDREW A, et al. Real-time video super-resolution with spatio-temporal networks and motion compensation[C]. 2017 IEEE Conference on CVPR, 2017.
- [5] Xue Tianfan, Chen Baian, Wu Jiajun, et al. Video enhancement with task-oriented flow[J]. International Journal of Computer Vision, 2019, 127: 1106-1125.
- [6] JO Y H, OH S W, KANG J, et al. Deep video super-resolution network using dynamic upsampling lters without explicit motion compensation[C]. 2018 IEEE/CVF Conference on CVPR. IEEE, 2018.
- [7] HARIS M, SHAKHAROVICH G, UKITA N. Recurrent back-projection network for video super-resolution[C]. 2019 IEEE/CVF Conference on CVPR, 2019.
- [8] JADERBERG M, SIMONYAN K, ZISSERMAN A, et al. Spatial transformer networks[C]. Advance in NIPS, 2015.
- [9] XINGJIAN S, CHEN Z, WANG H, et al. Convolutional lstm network: a machine learning approach for precipitation nowcasting[C]. Advance in NIPS, 2015: 802-810.
- [10] TAO X, GAO H, LIAO R, et al. Detail revealing deep video super-resolution[C]. 2017 IEEE ICCV, 2017.
- [11] KAPPELER A, YOO S, DAI Q, et al. Video super-resolution with convolutional neural networks[C]. IEEE Transactions on Computational Imaging, 2016, 2(2): 109-122.
- [12] KINGMA D P, BA J. Adam: a method for stochastic optimization[J]. arXiv preprint arXiv: 1412.6980, 2014.

(收稿日期: 2020-01-17)

#### 作者简介:

刘佳(1996-), 男, 硕士研究生, 主要研究方向: 计算机图像处理。

安鹤男(1963-), 通信作者, 男, 副教授, 硕士研究生导师, 主要研究方向: 计算机视觉、图形处理, E-mail: anhenan@szu.edu.cn。

李蔚(1996-), 男, 硕士研究生, 主要研究方向: 计算机图像处理。

(上接第 42 页)

with deep learning: a review[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3212-3232.

- [6] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016: 779-788.
- [8] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]. IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, 2017: 7263-7271.
- [9] REDMON J, FARHADI A. YOLOv3: an incremental improvement[J]. arXiv preprint arXiv: 1804.02767, 2018.
- [10] 冯国臣, 陈艳艳, 陈宁, 等. 基于机器视觉的安全帽自动识别技术研究[J]. 机械设计与制造工程, 2015, 44(10): 39-42.
- [11] 刘晓慧, 叶西宁. 肤色检测和 Hu 矩在安全帽识别中的应用[J]. 华东理工大学学报(自然科学版), 2014, 40(3):

365-370.

- [12] 施辉, 陈先桥, 杨英. 改进 YOLO v3 的安全帽佩戴检测方法[J]. 计算机工程与应用, 2019, 55(11): 213-220.
- [13] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, 2018: 7132-7141.
- [14] PENG D, SUN Z, CHEN Z, et al. Detecting heads using feature refine net and cascaded multi-scale architecture[C]. International Conference on Pattern Recognition, Beijing, 2018: 2528-2533.
- [15] PASZKE A, GROSS S, MASSA F, et al. PyTorch: an imperative style, high-performance deep learning library[C]. Advances in Neural Information Processing Systems, Vancouver, 2019: 8024-8035.

(收稿日期: 2020-02-19)

#### 作者简介:

刘欣(1985-), 男, 硕士, 助理研究员, 国家安全生产评价师, 主要研究方向: 计算机技术、煤矿自动化及安全。

张灿明(1984-), 通信作者, 男, 硕士, 助理研究员, 主要研究方向: 深度学习、煤矿自动化及安全, E-mail: zhangcm0103@126.com。

## 版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所