基于多尺度优化YOLO的综采工作面作业人员行为状态识别方法*

史兆伟[1]，薛旭升[2]，朱辉[1]，张恩桥[2]，郭逸风[2]，岳佳宁[2]

（1.兰州资源环境职业技术大学， 甘肃 兰州 730123；
2.西安科技大学 机械工程学院， 陕西 西安 710054）

摘要：针对煤矿井下光照不均、背景复杂及人为违规操作导致的事故频发问题，提出一种基于改进Retinex与YOLOv5融合优化的井下人员行为识别方法。首先，采用改进多尺度Retinex算法对井下图像进行增强处理，通过多尺度融合与颜色恢复技术，消除低照度、煤尘、水雾对图像的干扰，提升图像清晰度与色彩还原度；其次，将增强后的图像数据输入YOLOv5网络，构建基于Retinex与YOLOv5融合优化的目标检测模型，以适配井下设备密集、背景复杂的检测场景。试验结果表明：该方法对井下人员安全帽佩戴行为和现场作业违规姿态识别的平均精确率分别达95%和85%以上，可实现井下人员违规行为的精确识别与判定，为煤矿安全智能化监管提供了技术支撑。

关键词：Retinex图像增强；YOLO目标检测；人员行为状态识别；安全监管

中图分类号：TD76 **文献标识码**：A **文章编号**：1005-2763(2026)06-0225-10

A Recognition Method for Operational Personnel Behavior State in Fully Mechanized Mining Face Based on Multi-Scale Optimized YOLO

Shi Zhaowei[1], *Xue Xusheng*[2], *Zhu Hui*[1], *Zhang Enqiao*[2], *Guo Yifeng*[2], *Yue Jianing*[2]

(1.Lanzhou Resources Environment Vocational and Technical University, Lanzhou, Gansu 730123, China;
2.College of Mechanical Engineering, Xi'an University of Science and Technology, Xi'an, Shaanxi 710054, China)

Abstract: To address the frequent accidents caused by uneven illumination, complex backgrounds, and human rule-breaking operations in underground coal mines, a personnel behavior recognition method based on the fusion and optimization of improved Retinex and YOLOv5 was proposed. Firstly, an improved multi-scale Retinex algorithm was employed to enhance underground images. Through multi-scale fusion and color restoration techniques, the interference of low illumination, coal dust, and water mist on the images was eliminated, thereby improving image clarity and color fidelity. Subsequently, the enhanced image data were input into YOLOv5 network to construct a target detection model based on the fusion and optimization of Retinex and YOLOv5, which was adapted to detection scenarios with dense equipment and complex backgrounds in underground mines. The experimental results show that the average accuracy of this method for recognizing helmet-wearing behavior and on-site operational violation postures of underground personnel reaches over 95% and 85%, respectively. This method can achieve the precise identification and judgment of rule-breaking behavior by underground personnel, providing technical support for intelligent safety supervision in coal mines.

Key words: Retinex image enhancement, YOLO target detection, Personnel behavior state recognition, Safety supervision

0 引言

煤矿是我国经济发展的主体能源，长期以来为我国经济社会发展和国家能源安全提供了核心支撑[1]。然而，矿井地质条件复杂、井下作业条件恶劣，煤矿生产安全事故时有发生[2]。相关研究表明，安全监管不力、员工安全意识薄弱引发的人员不安全行为仍是事故发生的首要原因[3-4]。因此，实现对

* **收稿日期**：2025-10-12
基金项目：2025年甘肃省高校教师创新基金资助项目(2025B-337)
作者简介：史兆伟(1985—)，男，陕西岐山人，博士，副教授，主要从事应急管理、安全生产的教学及管理工作。E-mail：shizhaowei393@lzre.edu.cn

井下人员不安全行为的识别和分析,进而针对不安全人员行为采取管控措施,是降低煤矿安全事故发生率的关键路径。

随着我国智慧矿山建设的持续推进与煤矿安全生产智能化监管需求的日益提升,人工智能技术在煤矿井下人员行为识别领域得到了广泛应用[5-7]。王宇等[8]采用 SlowOnly 网络与 PoseC3D 网络,分别提取视频流的 RGB 视觉特征与人体骨骼模型特征,实现了井下人员不安全行为的识别。韩康等[9]采用改进 YOLOv7 和 ByteTrack 算法进行目标检测和人员跟踪,实现了对煤矿关键岗位人员不安全行为的实时识别。刘浩等[10]针对煤矿井下人员不安全行为识别过程中存在行为类型复杂、识别准确率低的问题,提出了基于动态注意力与多层感知图卷积网络的煤矿人员行为识别方法。黄瀚等[11]针对井下人员行为类型复杂、识别准确率较低的问题,提出了一种基于动态注意力与多层感知图卷积网络的煤矿人员行为识别方法。但上述方法对复杂井下环境的适应性较差,难以在光照不均、煤尘干扰严重的场景下保证检测精度;同时,算法实时性和处理效率受限,难以满足井下人员不安全行为的高效识别与快速预警的工程需求,对多类型不安全行为识别的准确率和鲁棒性仍需进一步提升。

煤矿井下高粉尘、低照度的复杂作业环境下,采集的 RGB 图像会出现图像质量差、数据细节信息缺失等问题,严重影响后续网络的特征提取效果和行为识别精度[12]。Retinex 算法可在光照不均的井下环境中,显著提升图像对比度和清晰度,同时实现图像色彩的精准还原,从而使 YOLOv5 模型能更高效地提取图像深层特征,实现对井下人员行为的精准识别[13],增强系统的鲁棒性和可靠性。因此,本文采用 Retinex 增强算法[14]对图像进行增强预处理,提升图像清晰度与有效细节特征。然后利用 YOLOv5 模型对视频中人员的安全帽及行为状态进行识别,构建基于 Retinex 增强 YOLOv5 的图像优化模型,提高井下人员不安全行为的识别准确率,实现煤矿井下人员行为状态的精准识别。

1 煤矿巷道人员行为识别方法

煤矿巷道内重点管控的人员违规行为主要包括未佩戴安全帽、吸烟、违规使用手机、睡岗等,该类行为严重威胁矿井安全生产,是引发煤矿安全事故的重要因素。因此,本研究主要针对上述违规行为进行识别和分析。

本研究提出的基于 Retinex-YOLOv5 优化的煤矿巷道人员行为识别方法结构如图 1 所示。

(1) 通过井下摄像头获取巷道内的实时监控视频,采用改进多尺度 Retinex 模型对井下环境图像进行增强预处理,并对巷道内的人员进行准确定位,为后续行为检测提供高质量的输入数据。

(2) 为减少煤尘和复杂背景对违规行为检测的干扰,采用 YOLOv5 模型实现安全帽佩戴状态检测与作业行为识别,保障检测的稳定性和准确率。

(3) 将检测到的人员位置送入行为识别模块,对人员的动作和行为进行特征分析。最后,基于深度学习网络对人员不安全行为进行分类,实现对煤矿巷道内不安全行为的自动识别与实时预警。

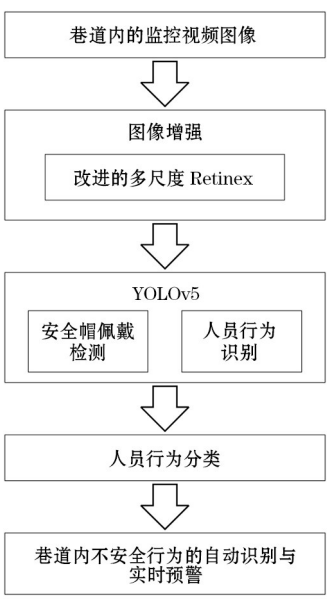


图 1 基于 Retinex-YOLOv5 优化的煤矿巷道人员行为识别方法结构

Fig.1 Structure of human behavior recognition method in coal mine roadway based on Retinex-YOLOv5

2 改进多尺度 Retinex 图像增强方法

Retinex 算法是经典的图像增强算法,其通过模拟人类视觉系统的色彩恒常性机制实现图像质量提升。核心变种包括单尺度 Retinex(SSR)、多尺度 Retinex(MSR)与带颜色恢复的多尺度 Retinex(MSRCR)。其中,SSR 采用单一尺度的高斯滤波

器[15]对局部动态范围进行增强，但易出现细节丢失或过度增强的问题。MSR 通过融合多尺度的滤波器的权重结果，实现了图像动态范围的均衡压缩，但在色彩保真度方面仍存在不足。MSRCR 在 MSR 基础上结合颜色恢复机制，不仅有效修正了色彩失真问题，而且进一步提升了图像的对比度和细节表现。

MSRCR 算法的核心公式为：

$$R_{\mathrm{MSRCR}i}(x,y)=C_i(x,y)\cdot R_{\mathrm{MSR}i}(x,y) \quad (1)$$

式中：$R_{\mathrm{MSRCR}i}(x,y)$ 为第 i 个颜色通道的输出增强图像；$C_i(x,y)$ 为第 i 个颜色通道的颜色恢复因子；$R_{\mathrm{MSR}i}(x,y)$ 为第 i 个颜色通道的多尺度 Retinex 输出结果。

颜色恢复因子 $C_i(x,y)$ 定义为：

$$\begin{cases} C_i(x,y)=\beta\cdot\log[\alpha\cdot I'_i(x,y)] \\ I'_i(x,y)=\dfrac{I_i(x,y)}{\sum\limits_{j=1}^{M}I_j(x,y)} \end{cases} \quad (2)$$

式中：β 是增益常数；α 是受控制的非线性强度；$I_i(x,y)$ 为原始图像在第 i 个颜色通道的像素值；$\sum\limits_{j=1}^{M}I_j(x,y)$ 为同一像素位置(x,y)所有 M 个颜色通道的像素值之和；$I'_i(x,y)$ 表示第 i 个通道的像素值在该点所有通道像素和中所占的比例。

多尺度 Retinex 输出 $R_{\mathrm{MSR}i}(x,y)$ 为：

$$R_{\mathrm{MSR}i}(x,y)=\sum_{n=1}^{N}W_n\cdot [\log I_i(x,y)-\log(F_n(x,y)I_i(x,y))] \quad (3)$$

式中：N 为尺度的个数；W_n 表示与 $F_n(x,y)$ 相关的权重系数；$F_n(x,y)$ 为高斯环绕函数。

针对煤矿井下生产环境中高粉尘、低照度等复杂作业工况，本文提出一种改进的带颜色恢复多尺度 Retinex(MSRCR) 算法，通过动态调整滤波器权重和颜色恢复因子，使算法更好地适应环境特征。改进后的公式为：

$$R_{\mathrm{Improved\text{-}MSRCR}i}(x,y)=C_i^{\mathrm{adaptive}}(x,y)\cdot R_{\mathrm{Improved\text{-}MSR}i}(x,y) \quad (4)$$

其中，改进的颜色恢复因子 $C_i^{\mathrm{adaptive}}(x,y)$ 为：

$$C_i^{\mathrm{adaptive}}(x,y)=\beta\cdot\log[\alpha\cdot I'_i(x,y)+\gamma\cdot E(x,y)] \quad (5)$$

式中：$E(x,y)$ 为环境特征参数，用于调整颜色恢复因子以适应不同工况；γ 为环境特征调整系数。

改进的多尺度 Retinex 输出公式为：

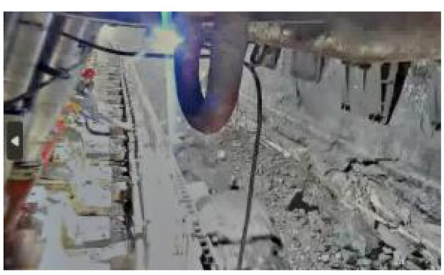
$$R_{\mathrm{Improve\text{-}MSR}i}(x,y)=\sum_{n=1}^{N}W_n^{\mathrm{adaptive}}(x,y)\cdot [\log I_i(x,y)-\log(F_n(x,y)I_i(x,y))] \quad (6)$$

式中，$W_i^{\mathrm{adaptive}}(x,y)$ 为动态调整的权重函数。

在高粉尘环境中，算法自动降低大尺度滤波器权重，以增强局部细节特征；在低照度环境中，提升大尺度权重以均衡整体亮度。通过上述自适应改进，算法可显著提升矿井复杂环境中的图像处理性能，在对比度增强和色彩保真方面表现优异。井下图像利用改进后的 Retinex 算法处理前后的对比如图 2 所示。



(a) 未经处理的原始图像



(b) 增强处理后的图像

图 2　图像增强前后效果对比

Fig.2　Comparison of effects before and after image enhancement

通过图像对比可发现，优化前的图像存在明显的亮度不均和颜色失真问题，且细节辨识度较差，不利于后续目标监测网络关键信息特征提取；而经过算法增强后的图像在对比度、清晰度与细节表现方面均显著提升，关键目标特征的可见性显著增强。该改进有效提升了井下图像质量，可为后续目标检测算法的特征提取与模型训练提供更加优质的输入数据。

3　基于改进多尺度 Retinex 图像优化 YOLOv5 的人员行为识别

随着深度学习技术的快速发展，基于手工特征

的传统目标检测方法逐渐被深度学习算法取代。YOLOv5 作为典型的单阶段目标检测算法,凭借其检测速度快、模型轻量化、部署便捷的优势而被广泛应用于各类场景中。因此,本研究采用 YOLOv5 模型,对矿工安全帽佩戴情况及井下人员行为进行检测和识别,以提高安全监控的效率与准确性。所构建的基于改进多尺度 Retinex 图像优化 YOLOv5 的人员行为识别模型如图 3 所示。

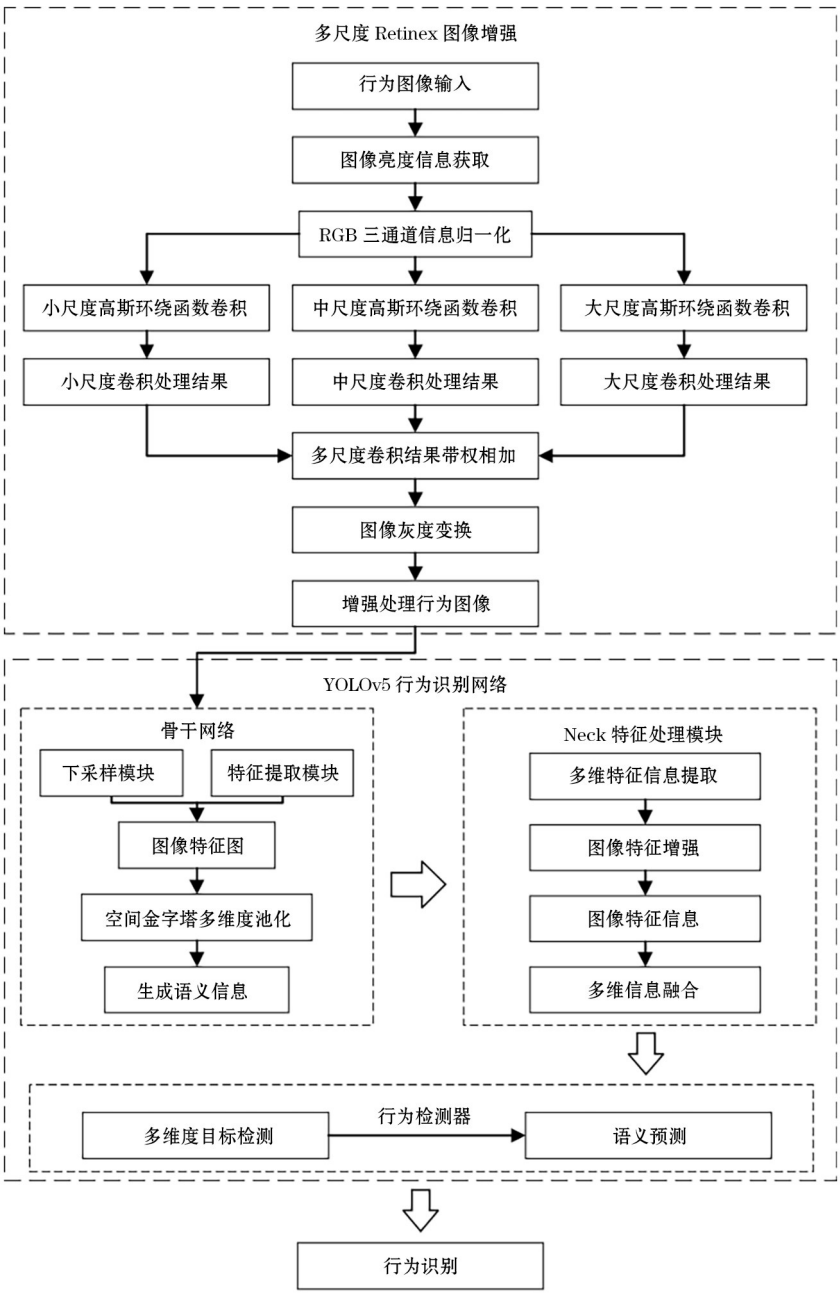


图 3 基于改进多尺度 Retinex 图像优化 YOLOv5 的人员行为识别模型

Fig.3 Human behavior recognition model based on improved multi-scale Retinex image-optimized YOLOv5

模型以煤矿井下人员的行为图像为输入,首先通过改进多尺度的 Retinex 算法对输入图像数据进行多尺度卷积处理,增强图像有效特征辨识度。在此基础上,采用 YOLOv5 骨干网络提取图像中的行为特征,经空间金字塔快速模块完成多维度池化,获取图像深层语义信息。在 Neck 模块中对图像数据进行多维度特征提取,并进行多维特征图交叉融合,输出多尺度信息互补特征图,提升多尺度目标检测精度,结合多维度的行为目标检测方法,对图像数据进行行为预测,最终得出行为识别结果,识别网络架构如图 4 所示。

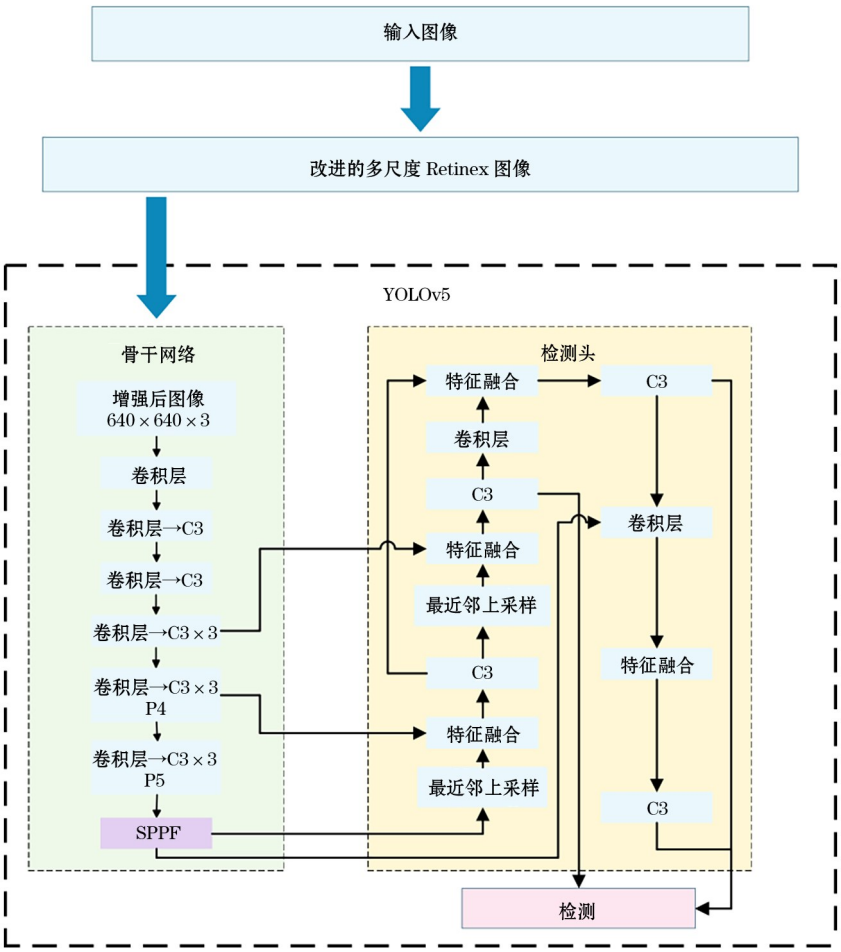


图 4　改进多尺度 Retinex 图像优化 YOLOv5 网络架构

Fig.4　Improved multi-scale Retinex image-optimized YOLOv5 network architecture

4　识别方法性能评价

本研究将改进后的 MSRCR 图像增强优化技术与优化后的 YOLOv5 人员行为识别模型相融合，经过一定数据集的训练，模型在实际应用场景中的性能显著提升。为量化评估模型的改进效果，本研究基于混淆矩阵[16]构建评价模型，选取的核心性能指标有精确率、召回率、平均精确值均值等[17-20]。

(1) 准确率(A)。

准确率指模型正确预测的样本数占总样本数的比值，其公式如下：

$$A=\frac{TP+TN}{TP+TN+FP+FN} \tag{7}$$

式中：TP 表示实际为违规行为，且被模型正确识别为违规行为的样本数；TN 表示实际为正常行为，且被模型正确识别为正常行为的样本数；FP 表示实际为正常行为，却被模型误判为违规行为的样本数；FN 表示实际为违规行为，却被模型误判为正常行为的样本数。

(2) 精确率(P)。

精确率又称查准率，表示模型预测为正的样本中，实际为正的比例，其公式如下：

$$P=\frac{TP}{TP+FP} \tag{8}$$

(3) 召回率(R)。

召回率又称查全率，表示正样本预测为正的数量占所有真实正样本的数量的比例，公式如下：

$$R=\frac{TP}{TP+FN} \tag{9}$$

(4) F_1 分数。

F_1 分数为精确率和召回率的调和平均数，其公式为：

$$F_1=\frac{2TP}{2TP+FP+FN} \tag{10}$$

(5) 平均精度(AP)。

AP 表示 P-R 曲线与坐标轴围成的面积,公式为:

$$AP=\int_0^1 P(R)\mathrm{d}R \tag{11}$$

(6) 精确率-召回率 P-R 曲线。

精确率和召回率反映的是算法在图像上某个类别的表现。通常用精确率-召回率(P-R)曲线与坐标轴围成的面积判断网络模型的性能,面积越大,代表模型效果越好。

(7) 平均精确值均值(mAP)。

在目标检测模型训练时,通常会有多个目标类型,对每个类型的 AP 值取平均值,即 mAP,mAP 值越大,训练模型的精度越高,其公式为:

$$mAP=\frac{\sum_{k=1}^{S}AP_k}{S} \tag{12}$$

式中:S 为目标类别的总数;AP_k 为类别 k 的平均精度。

5 试验分析

5.1 识别试验及结果分析

基于改进多尺度 Retinex 与 YOLOv5 融合优化的人员行为识别方法,可对煤矿井下作业人员的多种异常行为及人员作业状态进行识别,本试验以作业人员安全帽佩戴这一状态为例,验证分析本方法的应用效果。

5.1.1 数据集构建及试验环境配置

本文采用某矿综采工作面作业现场人员安全帽佩戴图像数据,从数据集中筛选 2 153 张图片进行模型训练,包含佩戴安全帽、未佩戴安全帽两类图像;针对煤矿井下作业人员躺、坐、行走、弯腰等行为识别任务,选用 3 060 张现场图片作为数据集进行模型训练。本文所用图像均经过改进多尺度 Retinex 图像增强算法处理。其中,经改进多尺度 Retinex 图像增强处理后部分图像样本如图 5 所示。



图 5 部分图像样本

Fig.5 Part of the image samples

将安全帽佩戴行为识别数据集的 2 153 张图片样本,以 8∶2 的比例随机划分为训练集和验证集,其中训练集 1 723 张,验证集 430 张。将综采工作面现场作业行为识别数据集的 3 060 张图片,按照 8∶2 的比例划分为训练集和验证集,其中训练集 2 448 张图片,验证集 612 张图片。

5.1.2 安全帽佩戴行为识别结果及分析

完成数据集构建、试验环境配置和相关参数设置后,首先针对安全帽佩戴识别任务进行模型训练。模型训练过程中,损失函数是衡量模型预测结果与

实际目标之间误差的核心指标，迭代训练的核心目的是通过不断优化模型权重参数，使损失函数不断降低至收敛，进而使模型能够更精确地对目标进行检测。

通过对井下人员安全帽模型进行识别训练，得到模型核心性能评估参数曲线。精确率－召回率曲线可直观反映精确率与召回率之间的关系，横坐标表示召回率，纵坐标表示精确率，通常情况下，精确率和召回率之间存在权衡关系：即召回率升高时，对应的精确率会随之降低，综合评价模型性能指标时，通常通过生成的曲线与坐标轴围成的面积（即平均精度 AP）作为核心量化指标，平均精度值越接近 1，代表模型的综合检测性能越强。但工程实际中平均精度值无法趋近于 1，需根据井下检测场景实际需要决定 P、R 值大小的选择。精确率－召回率曲线如图 6 所示。

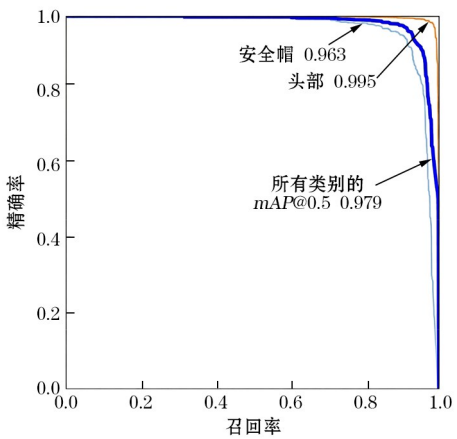


图 6　精确率－召回率曲线

Fig.6　Precision-recall relation curves

F_1 分数为精确率和召回率的调和平均数，其纵坐标数值越高，代表模型性能越好，因此在确定最佳置信度时，需要在图像中寻找 P 和 R 相对平衡的阈值，使 F_1 分数数值最大化，进而实现对模型检测精度的最优化，本次训练得到的 F_1 分数－置信度曲线如图 7 所示。

由图 7 可以看出，本模型在阈值为 0.05～0.88 时，F_1 分数数值介于 0.9～0.95 之间，为 F_1 分数数值的高性能区间，在此区间确定置信度阈值可实现模型对安全帽目标的精准识别。

通过对模型相关参数的分析，本模型对井下人员安全帽识别的精度达到了 95％以上，满足了煤矿井下安全管控的预期效果。

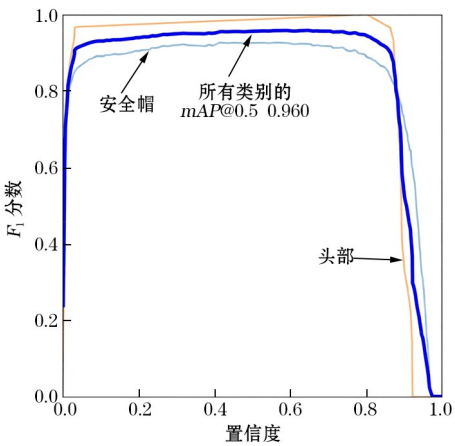


图 7　F_1 分数－置信度关系曲线

Fig.7　F_1 score-confidence curves

综合模型试验曲线和识别结果分析可知，本模型对煤矿巷道内的人员安全帽识别准确率达到了 95％以上，可实现工作人员安全帽佩戴状态的精准检测和识别，为煤矿井下安全生产可视化智能检测工作提供了可靠的技术支撑。

5.1.3　现场作业行为识别结果及分析

完成安全帽佩戴行为识别模型的训练与评价后，对井下人员行为数据进行模型训练。为保持训练体系的一致性，本阶段的训练仍采用 CIoU 作为边界框的损失函数，衡量模型预测结果与实际行为间的误差，通过迭代优化提升模型检测精度。模型性能评估采用 P-R 曲线和 F_1 分数－置信度关系曲线。其中 P-R 曲线可直观反映精确率与召回率的平衡关系，F_1 分数则作为精确率和召回率的调和平均数，用于辅助确定模型的最佳置信度阈值。表 1 为本次训练时 CIoU 损失函数的各项数据。

表 1　CIoU 损失函数数据统计（取第 30～40 轮为参考）

Table 1　Data statistics of CIoU loss function (taking the 30th to 40th as a reference)

训练轮次	边界框位置损失	目标检测损失	目标分类损失	精确率	召回率	$mAP@0.5$	$mAP@0.5:0.95$
30	0.030 595	0.011 200	0.020 001	0.717 35	0.626 13	0.643 58	0.363 56
31	0.030 935	0.011 660	0.021 025	0.730 80	0.558 85	0.619 70	0.365 73
32	0.030 806	0.011 246	0.020 852	0.792 63	0.591 26	0.680 06	0.420 65
33	0.030 126	0.011 083	0.020 525	0.739 50	0.554 23	0.662 44	0.402 72
34	0.030 119	0.011 278	0.020 360	0.654 16	0.645 19	0.611 61	0.354 75
35	0.029 848	0.011 226	0.019 411	0.773 29	0.542 19	0.687 07	0.401 69

续表

训练轮次	边界框位置损失	目标检测损失	目标分类损失	精确率	召回率	*mAP*@0.5	*mAP*@0.5:0.95
36	0.029 709	0.011 188	0.019 394	0.758 51	0.563 84	0.720 84	0.435 99
37	0.029 705	0.011 081	0.019 174	0.735 29	0.673 38	0.706 36	0.423 46
38	0.029 665	0.011 351	0.019 177	0.720 19	0.634 62	0.729 12	0.441 13
39	0.029 370	0.010 984	0.018 725	0.773 81	0.615 18	0.752 56	0.449 60
40	0.029 460	0.011 081	0.018 928	0.683 96	0.655 59	0.743 27	0.426 68

经过 150 轮迭代训练,以下是对整个训练过程及结果可视化参数与结果图像的详细分析。

完成所有训练后,系统会记录训练集每轮训练的损失函数,并生成对应变化曲线,本次训练结果曲线如图 8 所示。

图 8(a)与图 8(f)分别为训练集和验证集用于预测边界框位置的损失函数。指标值越小,代表真实边界框与预测边界框的位置偏差越小,模型的预测边界框精度越高,对目标的检测越准确,表明训练过程中的定位能力随训练迭代逐步优化。

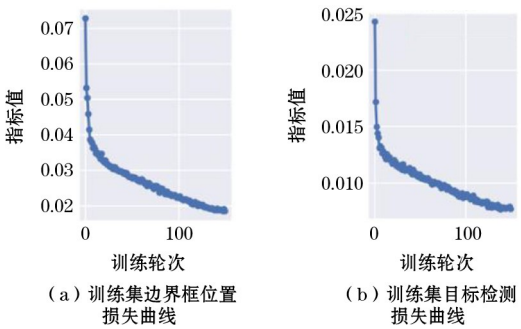
图 8(b)与图 8(g)分别为训练集、验证集的目标置信度损失曲线。指标值越小,代表模型对目标存在性的预测误差越小,检测精度越高。

图 8(c)与图 8(h)分别为训练集、验证集的目标分类损失曲线。指标值越小,代表模型在进行目标类别检测时与实际偏差越小,分类精度越高,反映出分类能力逐渐增强。

图 8(d)与图 8(e)分别为训练过程中精确率、召回率随训练轮次的变化曲线。可以看出,随着训练的进行,精确率和召回率均呈现稳定上升趋势,表明模型持续优化,对目标检测任务表现出了更高的准确性和完整性。

图 8(i)表示在 IoU 阈值大于 0.5 时,所有目标类别平均精度 *AP* 的平均值,可以看出,基于改进多尺度 Retinex 图像优化 YOLOv5 模型,在图像精度达到了 85%以上。

图 8(j)表示在 IoU 阈值从 0.5 到 0.95、步长 0.05范围内,所有目标类别的 *mAP* 平均值,从结果看,该改进模型在多个 IoU 阈值下均保持了较高的检测性能,具备较强的鲁棒性和泛化能力。



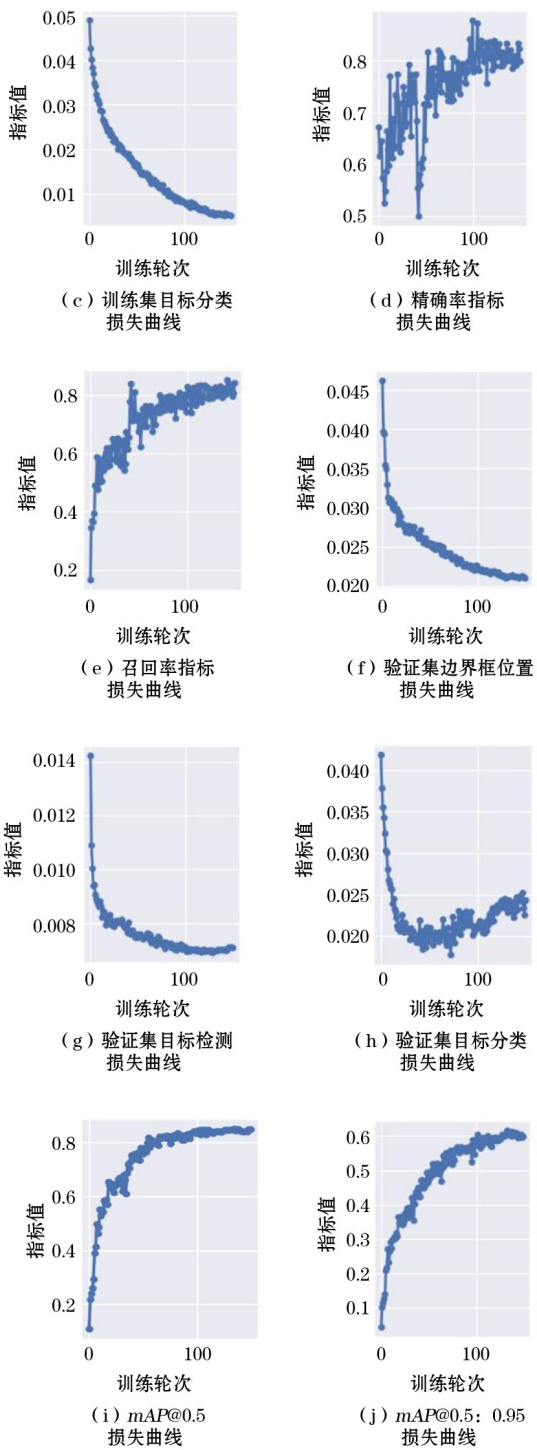


图 8 训练结果曲线

Fig.8 Training results curves

综合以上分析可知,基于改进多尺度 Retinex 图像优化的 YOLOv5 模型,在边界框定位、目标检测及分类精度上均表现出了显著的优化效果,验证了改进方法对矿井复杂场景图像目标检测的有效性和可靠性。

为直观展示模型的识别效果,图 9 和图 10 分别为训练集和验证集的人员行为目标识别结果。通过图像可看出,模型对图像中大多数人员行为均可进行准确识别,但仍存在部分遗漏的目标,其主要原因有两个:

(1) 由于图像的检测结果与训练质量和数据集质量密切相关,数据集部分行为图像数据区分度不高,有效特征信息有限,导致模型识别率低;

(2) 由于矿井生产环境复杂,部分区域可见度较差且空间狭小,存在较多的遮挡物,对实际检测造成干扰,进而影响训练与检测精度。

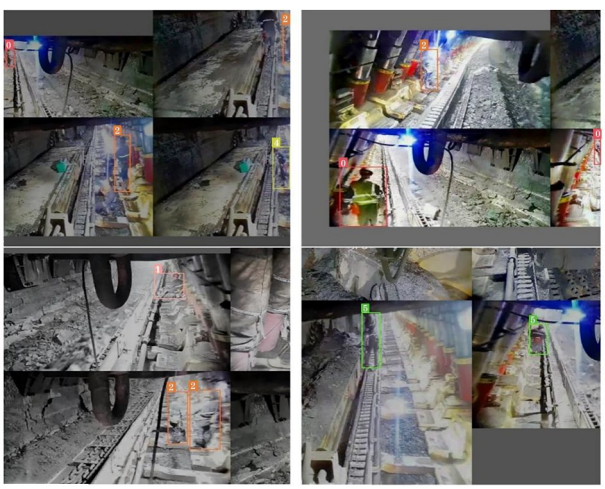


图 9 训练集的人员行为目标识别结果

Fig.9 Human behavior target recognition results for the training set



图 10 验证集的人员行为目标识别结果

Fig.10 Human behavior target recognition results for the validation set

综合对人员行为状态识别模型的试验曲线和识别结果分析,本研究对煤矿巷道内安全帽佩戴行为和现场作业行为识别的平均精确率分别达 95%和 85%以上,模型对于大多数行为状态的检测具有较强的鲁棒性,但在遮挡严重或行为特征不明显的情况下,检测性能仍存在提升空间。通过此模型与上节人员安全帽识别模型配合使用,可为后续的可视化智能检测工作提供坚实的技术支撑。

6 结论

(1) 针对煤矿井下高煤尘、光照不均等问题,提出了融合单、多尺度优点并引入颜色恢复机制的改进多尺度 Retinex 图像增强算法,该算法显著提升了图像对比度和清晰度,同时保留了色彩细节,为井下人员行为特征提取提供了高质量的图像数据。

(2) 针对煤矿井下低照度、高粉尘复杂环境中人员行为特征提取困难等问题,提出了基于多尺度特征融合优化的 YOLOv5 算法,通过增强特征提取能力和多尺度信息的融合效果,提高了目标定位精度与行为分类准确率,为井下人员行为精准识别提供了高效可靠的算法模型。

(3) 本研究提出了基于 Retinex 增强 YOLOv5 优化的煤矿作业人员行为识别方法,为煤矿井下人员安全与生产安全实时监控提供了新方法,经现场图像数据训练与验证,安全帽佩戴行为和现场作业行为识别的平均精确率分别达 95%和 85%以上,实现了井下人员行为状态的精准识别,对促进煤矿井下常态化安全作业状态的精准识别具有重要的应用价值。

参考文献(References):

[1] 马宏伟.煤矿机电装备智能化[J].西安科技大学学报,2020,40(5):748.
Ma Hongwei. Intelligent coal mine electromechanical equipment[J]. Journal of Xi'an University of Science and Technology,2020,40(5):748.

[2] 王海军,齐庆杰,梁运涛,等.我国煤矿重特大事故统计分析及对策建议[J].中国安全科学学报,2024,34(9):9-18
Wang Haijun, Qi Qingjie, Liang Yuntao, et al. Statistical analysis and countermeasures of malor accidents in coalmines in China[J]. China Safety Science Journal,2024,34(9):9-18.

[3] 付玉平,陈兆波,赵振保,等.煤矿安全事故的综合致因模型[J].安全与环境学报,2024,24(7):2731-2740.
Fu Yuping, Chen Zhaobo, Zhao Zhenbao, et al. Research on comprehensive causative model of coal mine safety accidents[J]. Journal of Safety and Environment,2024,24(7):2731-2740.

[4] 申娟娟,王向梅,王英臣.煤矿群体不安全行为的网络拓扑结构与传播特性研究[J].煤炭工程,2023,55(9):181-186.

Shen Juanjuan, Wang Xiangmei, Wang Yingchen. Research on network topology and propagation characteristics of unsafe behavior in coal mine group[J]. Coal Engineering, 2023,55(9):181-186.

[5] 沈铭华,马昆,杨洋,等.AI智能视频识别技术在煤矿智慧矿山中的应用[J].煤炭工程,2023,55(4):92-97.
Shen Minghua, Ma Kun, Yang Yang, et al. Application of AI identification technology in intelligent coal mine[J]. Coal Engineering,2023,55(4):92-97.

[6] 阮进林,高鹏,孙源,等.基于轻量级 OpenPose 的井下人员行为检测算法研究[J].煤炭工程,2024,56(4):150-156.
Ruan Jinlin, Gao Peng, Sun Yuan, et al. Detection algorithm of underground personnel behavior based on lightweight OpenPose [J]. Coal Engineering,2024,56(4):150-156.

[7] 左明成,焦文华.面向煤矿井下作业场景的安全帽佩戴识别算法[J].中国安全科学学报,2024,34(3):237-246.
Zuo Mingcheng, Jiao Wenhua. Helmel-wearing recognition algorithm for coal mine underground operation scenarios[J]. China Safety Science Journal,2024,34(3):237-246.

[8] 王宇,于春华,陈晓青,等.基于多模态特征融合的井下人员不安全行为识别[J].工矿自动化,2023,49(11):138-144.
Wang Yu, Yu Chunhua, Chen Xiaoqing, et al. Recognition of unsafe behaviors of underground personnel based on multi modal feature fusion[J]. Journal of Mine Automation,2023, 49(11):138-144.

[9] 韩康,李敬兆,陶荣颖.基于改进 YOLOv7 和 ByteTrack 的煤矿关键岗位人员不安全行为识别[J].工矿自动化,2024,50(3):82-91.
Han Kang, Li Jingzhao, Tao Rongying. Recognition of unsafe behaviors of key position personnel in coal mines based on improved YOLOv7 and ByteTrack[J]. Journal of Mine Automation,2024,50(3):82-91.

[10] 刘浩,刘海滨,孙宇,等.煤矿井下员工不安全行为智能识别系统[J].煤炭学报,2021,46(增刊 2):1159-1169.
Liu Hao, Liu Haibin, Sun Yu, et al. Intelligent recognition system of unsafe behavior of underground coal miners [J]. Journal of China Coal Society,2021,46(Suppl.2):1159-1169.

[11] 黄瀚,程小舟,云霄,等.基于 DA-GCN 的煤矿人员行为识别方法[J].工矿自动化,2021,47(4):62-66.
Huang Han, Cheng Xiaozhou, Yun Xiao, et al. DA-GCN-based coal mine personnel action recognition method[J]. Journal of Mine Automation,2021,47(4):62-66.

[12] 张立亚,郝博南,孟庆勇,等.基于 HSV 空间改进融合 Retinex 算法的井下图像增强方法[J].煤炭学报,2020,45(增刊 1):532-540.
Zhang Liya, Hao Bonan, Meng Qingyong, et al. Method of image enhancement in coal mine based on improved retex fusion algorithm in HSV space[J]. Journal of China Coal Society,2020,45(Suppl.1):532-540.

[13] 邵延华,张铎,楚红雨,等.基于深度学习的 YOLO 目标检测综述[J].电子与信息学报,2022,44(10):3697-3708.
Shao Yanhua, Zhang Duo, Chu Hongyu, et al. A review of YOLO object detection based on deep learning[J]. Journal of Electronics & Information Technology, 2022, 44(10): 3697-3708.

[14] 李锦,王俊平,万国挺,等.一种结合直方图均衡化和 MSRCR 的图像增强新算法[J].西安电子科技大学学报,2014,41(3):103-109.
Li Jin, Wang Junping, Wan Guoting, et al. Novel algorithm for image enhancement with histogram equalization and MSRCR[J]. Journal of Xidian University, 2014, 41(3): 103-109.

[15] Kumar A, Sodhi S S. Comparative analysis of gaussian filter, median filter and denoise autoenocoder [C]//2020 7th International Conference on Computing for Sustainable Global Development (INDIACom). New York:IEEE,2020:45-51.

[16] 张开放,苏华友,窦勇.一种基于混淆矩阵的多分类任务准确率评估新方法[J].计算机工程与科学,2021,43(11):1910-1919.
Zhang Kaifang, Su Huayou, Dou Yong. A new multi-classification task accuracy evaluation method based on confusion matrix[J]. Computer Engineering and Science, 2021,43(11):1910-1919.

[17] 赵德安,吴任迪,刘晓洋,等.基于 YOLO 深度卷积神经网络的复杂背景下机器人采摘苹果定位[J].农业工程学报,2019,35(3):164-173.
Zhao Dean, Wu Rendi, Liu Xiaoyang, et al. Apple positioning based on YOLO deep convolutional neural network for picking robot in complex background [J]. Transactions of the Chinese Society of Agricultural Engineering,2019,35(3):164-173.

[18] 李秀智,李家豪,张祥银,等.基于深度学习的机器人最优抓取姿态检测方法[J].仪器仪表学报,2020,41(5):108-117.
Li Xiuzhi, Li Jiahao, Zhang Xiangyin, et al. Detection method of robot optimal grasp posture based on deep learning[J]. Chinese Journal of Scientific Instrument,2020, 41(5):108-117.

[19] Du S J, Zhang B F, Zhang P, et al. An improved bounding box regression loss function based on CIoU loss for multi-scale object detection [C]//2021 IEEE 2nd International Conference on Pattern Recognition and Machine Learning (PRML). New York:IEEE,2021:92-98.

[20] 王照国,张红云,苗夺谦.基于 F_1 值的非极大值抑制阈值自动选取方法[J].智能系统学报,2020,15(5):1006-1012.
Wang Zhaoguo, Zhang Hongyun, Miao Duoqian. Automatice selection method of non-maximum suppression threshold based on F_1 score [J]. CAAI Transactions on Intelligent Systems,2020,15(5):1006-1012.