

文章编号: 2097-5899(2026)09-0071-08 中图分类号: U294.1 文献标识码: A

DOI: 10.16669/j.cnki.issn.2097-5899.202503140001

引用格式: 卜思豪. 基于GAN-CNN的铁路混装运输查危方法运用探索[J]. 铁路物流, 2026, 44(9): 71-78.

BU Sihao. Exploration on Application of Method for Dangerous Goods Inspection in Railway Mixed Transportation Based on GAN-CNN[J]. Railway Logistics, 2026, 44(9): 71-78.

基于GAN-CNN的铁路混装运输查危方法运用探索

卜思豪

(中国铁路上海局集团有限公司 杭州铁路物流中心, 浙江 宁波 315000)

摘要: 铁路混装货物安检是混装货物安全运输的重要保障, 针对危险货物数据集较少、人工安检识别效率较低、物品种类繁多且数量较大的问题, 提出一种基于数据增强的卷积神经网络铁路混装运输查危方法, 首先利用生成对抗网络扩充危险货物图像样本数据集, 再通过卷积神经网络提取危险货物种类特征, 最后对全样本数据集进行训练。以函数损失值、识别准确率、召回率及识别准确率和召回率的调和平均数作为模型评价指标, 实验结果表明, 该模型危险货物识别准确率达99.5%。研究成果可以为铁路混装运输安检查危提供技术支撑。

关键词: 卷积神经网络; 生成对抗网络; 铁路混装货物; 危险货物识别; 铁路安检

0 引言

铁路混装货物运输是指托运的货物包含2个及以上品名, 且按整车一批运输或使用同一集装箱运输的货物运输形式。具体可分为以下2种情形。①整车运输, 整车货物以每车为一批进行运输, 当整车一车装载2个及以上不同品名的货物时, 即属于混装货物运输; ②集装箱运输, 集装箱以每张运单为一批进行运输, 当一张运单记载多个集装箱, 且每个集装箱内均装载2个及以上不同品名的货物时, 属于混装货物运输。

针对铁路混装货物的运输特点, 目前主要采用人工检查与机器检测相结合的模式, 但该模式在实际应用中存在显著局限性: 一方面, 货物混装易造成关键物品遮挡, 且不同货物的密度、体积存在显著差异, 仅通过颜色特征进行识别, 不仅检测效率低下, 还易产生漏检、误检等问题; 另一方面, 当装运货物数量大幅增加时, 单靠人工检查与机器检测的协同配合, 难以实现对夹带危险货物的精准识别, 无法满足规模化运输场景下的安检需求^[1]。

卷积神经网络(Convolutional Neural Network, CNN)作为一种经典的深度学习图像识别模型, 能够有效解决上述混装货物安检中的图像识别难题。其核心优势在于可自动提取图像深层特征, 且具备较高的识别准确率, 目前已成功应用于医疗图像识别^[2]、机械故障诊断^[3]、高速公路车辆检测^[4]等多个领域。尽管CNN在图像识别中取得成效, 但传统CNN模型对训练数据样本的依赖性较强, 在模型设计过程中, 往往侧重优化模型的识别准确率与实时性, 却未充分考虑数据集的质量(如样本数量、分布均衡性)对模型识别效果的影响, 这一缺陷在样本数量不足、数据分布不均衡的铁路混装货物安检场景中尤为突出, 严重制约了模型的实际应用效果。

针对上述传统CNN模型的问题, 引入生成对抗网络(Generative Adversarial Networks, GAN)进行改进。GAN通过生成器与判别器的对抗训练, 能够基于已有样本数据生成高质量的模拟样本, 有效扩充训练样本数据集, 弥补训练样本数量不足、分布不均衡的缺陷, 目前已在网络入侵检测^[5]、数据修复^[6]、图像生成^[7]等领域

收稿日期: 2025-03-14

取得良好效果。Slim等^[8]将GAN与CNN模型相结合,有效解决了因数据稀缺、分布不平衡导致的检测模型性能不佳的问题,为本研究模型的构建提供了重要参考。

基于此,构建GAN-CNN铁路混装货物运输安检查危模型,利用GAN扩充数据样本以实现训练样本的均衡化,提升铁路混装货物安检识别准确率。通过与传统CNN、单一GAN模型进行识别效果量化对比,验证所提模型的有效性与优越性,为铁路混装货物安检查危提供技术支撑。

1 铁路混装货物安检查危存在的问题

当前铁路混装货物安检查危工作在人防、物防、技防3个维度均存在短板,可能会影响安检效能^[9]。在人防层面,安检模式以人工开包检查与X光机人工判图为主,对作业人员的依赖程度较高。在大批量货物集中安检场景下,人工检测能力难以匹配实际作业需求,易引发误检、漏检等安全风险。在物防层面,安检设备配置呈现明显的不均衡特征。仅部分大型货场配备CT安检机、门架式安检设备等,多数货场及专用线仍以小型安检仪器为主,不仅无法满足大件货物的安检需求,且成像效果较差,难以精准识别装运货物中夹带的危险物品。在技防层面,现有混装货物安检设备缺乏统一的类型规范与技术标准,导致货物信息与安检数据无法实现互联互通,造成数据样本缺失,难以对危险货物实现精准溯源与定位^[10]。同时,危险货物样本数据集规模偏小、分布不均衡,致使安检设备成像难以满足多品类危险货物识别需求,无法有效提取危险货物特征信息,存在危险货物辨识困难、成像清晰度不足等问题^[11]。

综上所述,人防效能受安检人员业务素质、作业疲劳度等主观因素制约,物防水平受货场建设条件、设备投入等客观条件限制,二者的优化提升均存在较强约束性,短期内难以实现突破性改善。相较之下,技防体系升级具有更高的可控性与提升空间,因此聚焦铁路混装货物安检查危技防能力优化,构建GAN-CNN模型,着力解决危险货物样本数据集稀缺与不均衡的难题,通过强化危险货物图像特征提取效果,进一步提升安检查危识别准确率。

2 基于GAN-CNN的铁路混装运输安检查危识别模型

2.1 对抗网络模型

为有效解决危险货物数据集较少且不均衡的问题,

采用GAN增强危险货物样本数据。GAN^[12]由2部分组成:生成器和判别器。这2个部分通过一种对抗的过程来相互改进和优化。对抗的过程可以描述为一个最小最大化的优化问题,其计算公式如下。

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log D(x)] + E_{z \sim p(z)} [\log (1 - D(G(z)))] \quad (1)$$

式中: $\min_G \max_D V(D, G)$ 表示判别器(D)与生成器(G)的价值函数,衡量二者对抗博弈的目标; $D(x)$ 为判别器判断真实样本 x 为真实的概率; $G(z)$ 为生成器以噪声 z 为输入生成的假样本; $E_{x \sim p_{\text{data}}(x)} [\log D(x)]$ 表示从真实数据分布 $P_{\text{data}}(x)$ 中采样所有样本 x , 对 $\log D(x)$ 取平均值; $E_{z \sim p(z)} [\log (1 - D(G(z)))]$ 表示从先验噪声分布 $P(z)$ 中采样所有噪声 z , 经生成器得到伪造样本 $G(z)$, 再对判别器正确识别这些伪造样本的对数似然取平均值。

判别器的训练目标为最大化目标函数,此时生成器的输出概率应趋近于0;二者训练目标呈对抗关系。生成器以随机噪声为输入,将其反映为具备真实数据分布特征的生成样本,核心任务是拟合真实训练数据的分布特征,输出与真实样本高度近似的生成数据。判别器则致力于精准区分输入样本为真实训练数据或生成器伪造数据,并对分类结果进行有效性判别与分析,GAN网络模型如图1所示。

在生成器与判别器的迭代对抗训练过程中,生成器的最终优化目标为使生成数据能够更接近真实数据,因此需构建合适的损失函数以量化真实数据分布与生成数据分布之间的差异程度。选用 Wasserstein 距离构建对抗损失函数,该损失函数可有效提升模型训练的稳定性,同时可作为量化对抗训练进程的关键指标,对抗损失函数表达式如下。

$$L_g = \max_x E_{x \sim p_{\text{data}}} [D_x(x)] - E_{x \sim p_g} [D_x(G_x(z))] \quad (2)$$

式中: G_x 为生成器函数; D_x 为判别器函数; L_g 为对抗损失函数。

2.2 GAN-CNN模型推理

采用GAN训练后,将生成的数据集输入CNN^[13],该模型由Conv1, Conv2, Conv3, Conv4四个隐藏层和一个全连接层组成,C1为第一个隐藏层的卷积层、S1为第一个隐藏层的激活层、P1为第一个隐藏层的池化层,将每个隐藏层处理后输入全连接层,最后利用Softmax函数识别危险货物。CNN网络模型如图2所示。




图1 GAN网络模型

Fig.1 GAN model




图2 CNN网络模型

Fig.2 CNN model

卷积层的核心技术是卷积处理计算，其计算公式如下所示。

$$O(i,j) = \sum_m \sum_n I(i+m,j+n)K(m,n) + b \quad (3)$$

式中： $I(i+m,j+n)$ 为输入矩阵； $K(m,n)$ 为卷积核； b 为偏置项； $O(i,j)$ 为输出结果。

卷积层输入C1的图像矩阵大小为 $100 \times 100 \times 3$ 。C1, C2, C3, C4使用 5×5 的卷积核，卷积核个数分别是32, 64, 128, 128；C1, C2, C3, C4的卷积移动步长均为1，这里偏置项取0。采用自门控激活函数Swish作为模型的激活函数，其计算公式如下所示。

$$f(x) = x \cdot \sigma(\beta x) \quad (4)$$

$$\sigma(\beta x) = \frac{1}{1 + e^{-\beta x}}$$

式中： β 为训练参数， β 取值为 $0.8^{[14]}$ ； $\sigma(x)$ 表示Sigmoid逻辑函数。

池化层(P)用于降低特征图的维度，同时保留重要信息，由于混装货物数据样本较为繁杂，使用最大池化的方法可能会存在较大偏差，故引入平均池化的方

法降低偏差。池化层P1, P2, P3, P4均使用核大小为 2×2 、步长为1的平均池化操作，计算公式如下所示。

$$P(i,j) = \frac{1}{|P|} \sum_{(m,n) \in P} I(i+m,j+n) \quad (5)$$

式中： $P(i,j)$ 为池化后输出特征图在坐标 (i,j) 处的像素值； P 为经过卷积处理后输入的特征值； $I(i+m,j+n)$ 为输入特征图在坐标 $(i+m,j+n)$ 的初始像素值。

利用Softmax函数识别危险货物特征，其计算公式如下所示。

$$P(y_i) = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad (6)$$

式中： e^{z_i} 为CNN原始输入值； $P(y_i)$ 为归一化后的概率。

将GAN与CNN模型融合，首先利用GAN增强危险货物数据集使其均衡化，其次将生成的样本数据进行对抗网络训练，利用GAN的生成器和判别器对初始

数据优化,最后采用CNN模型进行训练, GAN-CNN混合网络模型如图3所示。




图3 GAN-CNN混合网络模型
Fig.3 GAN-CNN hybrid model

- 步骤1: 确定铁路混装货物初始数据集, 输入模型。
- 步骤2: 输入GAN进行数据增强。
- 步骤3: 生成的样本数据进行对抗训练。
- 步骤4: 分别利用生成器和判别器识别样本数据集。
- 步骤5: 在生成器中随机接收样本数据, 在判别器中计算对抗和提取的特征损失。
- 步骤6: 输出的GAN特征参数值是否优化, 如果是则全样本识别危险货物, 输入CNN网络进行模型训练, 如果不是转入步骤2, 重新增强网络数据。
- 步骤7: 输入CNN, 提取数据集中危险货物的特

征参数, 训练模型。

步骤8: 得到最终网络识别结果。

2.3 模型评价指标

通过识别准确率(P)、召回率(R)、F1-score(F1)对GAN-CNN模型进行评价。计算公式如下所示。

$$TP + FP + FN + TN = N$$
 (7)

$$P = \frac{TP}{TP + FP}$$
 (8)

$$R = \frac{TP}{TP + FN}$$
 (9)

$$F1 = \frac{2 \times P \times R}{P + R}$$
 (10)

式中: N为初始样本总数; TP, FP, TN, FN分别表示真正例、假正例、真反例与假反例的数量。

真正例表示模型将正类样本正确预测为正类的数量; 假正例表示模型将负类样本错误预测为正类的数量; 真反例表示模型将负类样本正确预测为负类的数量; 假反例表示模型将正类样本错误预测为负类的数量; 识别准确率表示模型预测为正类的样本中真实正类样本所占比例, 反映模型预测结果的可靠性; 召回率为真实正类样本中被模型正确识别为正类的比例, 高召回率意味着模型对正类样本的漏检率较低。F1值为识别准确率与召回率的调和平均值, F1值越高, 表明模型的综合识别性能越强^[15-16]。

3 实验验证

3.1 实验数据集

实验数据集来源于SIXray数据集, 研究参照法慧妍、黄文成等研究方法^[17-18], 经过针对性筛选与处理, 得到包含5760幅安检图像的实验数据集。初始数据集中危险货物特征图(部分)如图4所示; 在模型训练过程中, 输入图像经过各卷积层处理后, 卷积层输入特征图及输出特征图大小如表1所示; 初始数据及数据增强后危险货物数量如表2所示。

筛选的9种危险货物与铁路混装运输密切相关, 因其固有危险性, 成为安检查危作业的重点监控对象, 各类危险货物的具体特性及安检特征如下。①烟花爆竹遇明火易发生爆炸, 进而导致行车中断、货物滞留, 其安检特征图表现为密集高点、线状分布特征; ②枪支弹药易被用于违法犯罪活动, 严重威胁公共安全; ③毒性物质包含砒霜、氰化物等剧毒化学品, 外观多呈深绿色, 安检特征图中以瓶装形态呈现, 且密度分布均匀; ④锂电池能量密度较高, 受热易引发火灾, 其安检特征图辨识度较高, 可直接通过形态特征识别; ⑤易燃液体在挤




图4 初始数据集中危险货物特征图(部分)

Fig.4 Feature maps of dangerous goods in original dataset (part)

压、碰撞作用下易发生泄漏，安检特征图中呈长方形瓶装，颜色以绿色为主；⑥腐蚀性液体(如强酸、强碱等)泄漏后易腐蚀列车设备、污染周边环境，安检识别以液体容器特征为主，其在安检设备下密度分布均匀，颜色呈蓝绿色；⑦压力罐主要用于装灌易燃气体，受高温、撞击影响存在爆炸风险，安检过程中重点识别其圆柱形金属罐体及阀门结构，颜色多为蓝色；⑧易燃固体包括充电宝、打火机等易自燃物质，运输过程中存在爆炸隐

患，安检特征图呈长方形，颜色为浅绿色；⑨其他易发生自燃的物质(如棉花、火胶棉等)，其安检特征图密度分布不均匀，颜色多为橙色。上述9种危险货物在铁路混装货物运输中较为常见，准确识别其图像特征是保障铁路混装货物运输安全的关键环节。

3.2 模型有效性验证

将初始数据集分别输入CNN，GAN-CNN模型，对比测试新模型的优势。实验迭代轮次为10 000次，

表1 卷积层输入特征图及输出特征图大小
Tab.1 Size of input and output feature maps in convolutional layers

卷积层	输入特征图	输出特征图
C1	$100 \times 100 \times 3$	$50 \times 50 \times 32$
C2	$50 \times 50 \times 32$	$25 \times 25 \times 64$
C3	$25 \times 25 \times 64$	$15 \times 15 \times 128$
C4	$15 \times 15 \times 128$	$8 \times 8 \times 128$

表2 初始数据及数据增强后危险货物数量
Tab.2 Number of dangerous goods in original data and after data enhancement

危险货物种类	初始数据中危险货物数量	GAN数据增强后危险货物数量
烟花爆竹	120	876
枪支弹药	486	985
毒性物质	535	892
锂电池	562	862
易燃液体	687	1 088
腐蚀性液体	362	685
易燃气体	567	879
易燃固体	1 455	1 920
其他物质	986	2 038

每次迭代增加200组数据,经过10 000轮次后,得到CNN和GAN-CNN的损失值和识别准确率,损失值如图5所示,识别准确率如图6所示。

如图5所示,基于GAN-CNN模型训练的数据集




图5 损失值
Fig.5 Loss value




图6 识别准确率
Fig.6 Recognition accuracy

在训练轮次3 000至6 000次期间处于快速收敛阶段,随着训练轮次的持续增加,模型收敛速度逐渐放缓并趋于稳定。对比传统CNN模型,当迭代轮次增加时,GAN-CNN模型的损失值下降速率更快,且更趋近于0,表明GAN-CNN模型相较于传统CNN模型具有更优异的收敛性。

如图6所示,在整个训练过程中,GAN-CNN模型的识别准确率始终高于传统CNN模型;当训练轮次达到5 000次后,GAN-CNN模型的平均识别准确率稳定在99.5%,较传统CNN模型53.8%的平均识别准确率提升显著,充分验证了该模型在整体识别准确率上显著优于传统CNN模型。

3.3 对比实验分析

为了更好地验证GAN-CNN模型的优势,对危险货物所占比例进行灵敏度分析,实验以0.001为初始比例,每次测试依次增加0.000 1个比例。分析对比GAN-CNN、CNN识别准确率、F1-score值。不同占比下危险货物识别准确率如图7所示,不同占比下F1-score值如图8所示。

如图7所示,随着危险货物样本比例增加,GAN-CNN模型的识别准确率提升幅度达82.3%,显著高于传统CNN模型;且当危险货物占比达到0.5%时,GAN-CNN模型达到最优识别状态,识别准确率稳定在99.5%,而传统CNN模型的识别准确率随危险货物占比增加的提升幅度较为平缓。实验对比结果表明,当危险货物占比大于0.5%时,GAN-CNN模型的识别优势尤为显著,其F1平均提升幅度达79.8%,综合性能明显优于传统CNN模型。

为进一步验证所提GAN-CNN模型的有效性,设




图7 不同占比下危险货物识别准确率

Fig.7 Recognition accuracy of dangerous goods under different proportions




图8 不同占比下F1-score

Fig.8 F1-score under different proportions

计对比实验,将传统CNN模型、GAN模型与GAN-CNN模型进行对比分析,实验评价指标如表3所示。

表3 实验评价指标

%

Tab.3 Experimental evaluation indicators

实验方法	识别准确率	F1	召回率
GAN-CNN	99.5	99.3	98.9
CNN	53.8	52.6	51.2
GAN	61.5	66.3	65.7

由表3实验数据可知, GAN-CNN模型的危险货物识别准确率分别较传统CNN模型、GAN模型高出45.7%, 38%; F1值分别高出46.7%, 33%; 召回率分别高出47.7%, 33.2%。上述实验结果进一步验证了GAN-CNN模型的有效性与优越性。

4 结束语

立足铁路混装货物运输安检查危的实际痛点,针对当前行业内危险货物数据集稀缺且不平衡、人工与传统机检效率低、漏检误检率偏高等突出问题,提出基于GAN-CNN的铁路混装运输查危识别方法,先依托GAN完成危险货物样本数据增强与均衡化处理,破解小样本、不平衡数据制约模型性能的难题,再借助CNN精准提取危险货物图像特征,实现2类模型的优势融合与协同优化。同时选取识别准确率、召回率、F1-score等核心指标开展多组对比实验,通过与传统CNN模型、单一GAN模型的性能比对,充分验证了GAN-CNN方法的有效性与优越性,实验数据表明GAN-CNN模型危险货物识别准确率达99.5%,能有效适配铁路混装货物品类繁杂、数量庞大、成像复杂的查危场景,切实为铁路混装运输安检查危工作提供可靠的技术支撑。

参考文献:

- [1] 连福生, 丁昭彦. 基于CNN的铁路安检危险品图像检测方法[J]. 现代计算机, 2020, 26(31): 50-53, 57.
LIAN Fusheng, DING Zhaoyan. Live Dynamic Transfer of Facial Expression Based on Landmarks of Face[J]. Modern Computer, 2020, 26(31): 50-53, 57.
- [2] 王佳佳, 熊飞龙. 基于改进的MFCC与CNN心音信号识别方法的研究[J]. 计算机测量与控制, 2024, 32(12): 201-207, 215.
WANG Jiajia, XIONG Feilong. Research on Recognition Method of Heart Sound Signals Based on Improved MFCC and CNN[J]. Computer Measurement & Control, 2024, 32(12): 201-207, 215.
- [3] 官源林, 刘贵林, 于春雨, 等. 基于CNN与BLS的滚动轴承故障诊断方法[J]. 振动、测试与诊断, 2024, 44(5): 1017-1022.
GUAN Yuanlin, LIU Guilin, YU Chunyu, et al. Fault Diagnosis Method of Rolling Bearing Based on CNN and BLS[J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(5): 1017-1022.
- [4] 王 晗, 樊 迪, 裴晓栋, 等. 基于CNN-GAN的高速公路资产识别模型与系统[J]. 中国交通信息化, 2023(4): 149-152.
- [5] 王浩轩, 苏圣超, 崔文霞. 基于GAN-Transformer的车载网络入侵检测算法[J]. 计算机工程与设计, 2025, 46(6): 1710-1716.
WANG Haoxuan, SU Shengchao, CUI Wenxia. Vehicle CAN Bus Intrusion Detection Algorithm Based on GAN-Transformer[J]. Computer Engineering and Design, 2025, 46(6): 1710-1716.
- [6] 袁厚冬, 李红娇. 基于IDM-GAN-APLSTM的数据修复及入侵检测方法[J]. 计算机应用与软件, 2026, 43(2): 371-379, 397.
YUAN Houdong, LI Hongjiao. Data Repair and Intrusion Detection Method Based on IDM-GAN-APLSTM[J]. Computer Applications and Software, 2026, 43(2): 371-379, 397.

- [7] 贺睿敏, 成浩, 王柏琦, 等. 基于配准对抗生成网络的CBCT生成伪CT图像研究[J]. 工程科学学报, 2025, 47(9): 1853-1861.
HE Ruimin, CHENG Hao, WANG Baiqi, et al. Research on Synthetic-CT Generation from CBCT Using Reg-GAN[J]. Chinese Journal of Engineering, 2025, 47(9): 1853-1861.
- [8] SLIM A, MALAH M. ACGAN: Adaptive Loss-Guided GAN-CNN Framework for Semantically Coherent Synthetic Insider Threat Data Generation[J]. Sensors, 2024, 24(20): 6601.
- [9] 姚振坤. 铁路危险货物运输安全风险分析及防范措施建议[J]. 铁路物流, 2025, 43(7): 40-43.
YAO Zhenkun. Safety Risk Analysis and Preventive Measures for Railway Dangerous Goods Transport[J]. Railway Logistics, 2025, 43(7): 40-43.
- [10] 王建国, 李建国. 铁路危险货物运输智能检测及应急处置装置设计[J]. 铁路物流, 2025, 43(2): 27-33.
WANG Jianguo, LI Jianguo. Intelligent Detection and Emergency Device Design for Dangerous Goods in Railway Freight Transportation[J]. Railway Logistics, 2025, 43(2): 27-33.
- [11] 杨闻彪. 消费型锂电池货物混装运输安全管理研究[J]. 铁路物流, 2025, 43(10): 6-10.
YANG Wenbiao. Research on Safety Management of Railway Mixed Transportation of Consumer Lithium Battery Goods[J]. Railway Logistics, 2025, 43(10): 6-10.
- [12] 陈鹏, 刘子龙. 基于GAN-CNN的心律失常识别[J]. 电子科技, 2022, 35(3): 45-50.
CHEN Peng, LIU Zilong. Arrhythmia Recognition Based on GAN-CNN[J]. Electronic Science and Technology, 2022, 35(3): 45-50.
- [13] 焦柳丹, 刘莹, 吴雅, 等. 基于卷积神经网络的交通运输业碳排放预测研究[J]. 铁道运输与经济, 2024, 46(8): 49-57.
JIAO Liudan, LIU Ying, WU Ya, et al. Transportation Carbon Emission Prediction Based on Convolutional Neural Network[J]. Railway Transport and Economy, 2024, 46(8): 49-57.
- [14] AL-NAWI N, MADAIN A, ABDULLAH M. MishReLU: A Hybrid Activation Function for Deep Neural Networks[J]. Expert Systems with Applications, 2026, 319: 131953.
- [15] 李响, 雷描描, 刘国翔. 考虑区域风险公平的危险品公铁联运路径优化[J]. 铁道运输与经济, 2024, 46(11): 140-149.
LI Xiang, LEI Miaomiao, LIU Guoxiang. Path Optimization for Road-Rail Intermodal Transport of Dangerous Goods Considering Regional Risk Equity[J]. Railway Transport and Economy, 2024, 46(11): 140-149.
- [16] 高强, 潘俊, 洪锐锋. 基于CNN的机场安检危险品自动识别研究[J]. 计算机技术与发展, 2019, 29(10): 95-99.
GAO Qiang, PAN Jun, HONG Ruifeng. Research on Automatic Recognition of Dangerous Goods in Airport Security Inspection Based on CNN[J]. Computer Technology and Development, 2019, 29(10): 95-99.
- [17] FA H Y, SHUAI B, YANG Z L, et al. Mining the Accident Causes of Railway Dangerous Goods Transportation: A Logistics-DT-TFP Based Approach[J]. Accident Analysis & Prevention, 2024, 195: 107421.
- [18] HUANG W C, SUN L H, YANG Z L, et al. Using Radial Basis Function and back Propagation to Predicate Fault in a Railway Dangerous Goods Transportation System Considering the Markov Correction[J]. Applied Soft Computing, 2023, 145: 110593.

(责任编辑: 金晶)

Exploration on Application of Method for Dangerous Goods Inspection in Railway Mixed Transportation Based on GAN-CNN

BU Sihao

(Hangzhou Railway Logistics Center, China Railway Shanghai Group Co., Ltd., Ningbo 315000, Zhejiang, China)

Abstract: Security inspection of railway mixed goods is an important guarantee for the safe transportation of mixed goods. To address the problems of a small dataset of dangerous goods, low identification efficiency of manual security inspection, and a wide variety and large quantity of goods, this paper proposed a method for dangerous goods inspection in railway mixed transportation using a convolutional neural network based on data augmentation. Firstly, a generative adversarial network was used to expand the image sample dataset of dangerous goods. Then, the convolutional neural network was used to extract the type features of dangerous goods. Finally, the full sample dataset was trained. With the function loss value, recognition accuracy, recall rate, and harmonic mean of recognition accuracy and recall rate as model evaluation indicators, the experimental results show that the recognition accuracy of dangerous goods by this model reaches 99.5%. The research results can provide technical support for security inspection and dangerous goods inspection in railway mixed transportation.

Keywords: Convolutional Neural Network; Generative Adversarial Network; Railway Mixed Goods; Dangerous Goods Recognition; Railway Security Inspection