

DOI: 10.19650/j.cnki.cjsi.J2312227

基于 TOI-Net 的高精度货车超载智能判别方法*

梁健¹, 康杰虎¹, 赵宗扬¹, 吴斌¹, 王雪森²

(1. 天津大学精密测量技术与仪器国家重点实验室 天津 300072; 2. 天津市政工程设计研究总院有限公司 上海 300051)

摘要:针对货车超载运输为道路安全带来巨大威胁,而目前主流的货车超载判别方法存在判别效率低、监管范围小、检测成本高的问题,提出了一种基于 TOI-Net 的高精度货车超载智能判别方法。首先,设计了一种针对货车超载判别任务的货车行驶轨迹图像生成方法,可将多维度货车行驶轨迹时空数据转化为货车行驶轨迹图像,在降低数据复杂性的同时实现了特征的聚合;然后,设计了一个高精度货车超载智能判别模型 TOI-Net,其由 RepVGG 模块和位置注意力模块组成,能够充分挖掘货车行驶轨迹数据中的超载信息特征,高效完成超载判别任务。在货车超载数据集上的实验结果表明,所提方法的超载判别准确率为 96.1%,且性能指标均高于主流识别网络,实现了对于货车超载行为的精确、快速和全面的判别。

关键词: 智能交通; 人工智能; 货车超载判别; 卷积神经网络; 注意力机制

中图分类号: U491.2 TH39 **文献标识码:** A **国家标准学科分类代码:** 580.70

High-precision intelligent identification method of truck overload based on TOI-Net

Liang Jian¹, Kang Jiehu¹, Zhao Zongyang¹, Wu Bin¹, Wang Xuesen²

(1. State Key Laboratory of Precision Measurement Technology and Instruments, Tianjin University, Tianjin 300072, China;

2. Tianjin Municipal Engineering Design & Research Institute, Tianjin 300051, China)

Abstract: Truck overload transportation is an enormous threat to road safety. Currently, the main identification method for truck overload has low identification efficiency and a small scope of supervision. To address these problems, this article proposes a truck overload identification method based on deep learning. Firstly, a method is designed for generating truck trajectory images specifically for the overload determination task, which can transform multidimensional spatiotemporal truck trajectory data into truck trajectory images, reducing data complexity while aggregating features. Then, we design a high-accuracy truck overload intelligent identification model TOI-Net, which consists of RepVGG modules and location attention modules. It can fully extract overload information features from truck trajectory data and efficiently complete the overload checkpoints task. Experiments are implemented on the truck overload dataset. The results show that the accuracy of the proposed method for overload identification is 96.1%, with performance metrics higher than mainstream recognition networks, achieving precise, rapid, and comprehensive identification of overload behavior.

Keywords: intelligent transportation system; artificial intelligence; truck overload identification; convolutional neural networks; attention mechanism

0 引言

公路运输是交通运输最重要的运输方式之一,但受超载运输获利多、违法成本低等因素的影响,公路运输从业人员超载运输现象屡禁不止。货车超载运输不仅会缩

短公路桥梁使用寿命,且易发生交通事故,严重危害人民群众生命财产安全^[1]。目前,货车超载判别的常规方法为人工治超点称重法,需执法人员在高速路口、交通干道等治超点对货车进行逐辆称重来判断货车是否超载运输,存在监测范围小、判别效率低^[2],消耗大量人力物力,且无法解决货车故意绕路行驶躲避检查的问题,因此研

收稿日期:2023-12-02 Received Date: 2023-12-02

* 基金项目:天津市交通运输科技发展计划项目(2022-09)、国家自然科学基金(52375545,62371339)项目资助

究新型货车超载判别方法对于提升交通执法水平,推进交通运输高质量发展具有重要的意义。

近年来,非现场超载检测成为治超工作的发展重点,非现场超载检测方法根据检测原理可分为动态称重法和车载式测重法。动态称重法无需停车,当货车行驶通过固定点位的称重装置时自动记录重量,并判断车辆是否超载。例如借助动态称重传感器进行测量^[3-5],当车辆通过称重装置时自动记录重量,同时利用相机拍摄车辆,记录车辆轴数和车牌号等基本信息,进而判断车辆是否超载,该方法大大提高了称重效率,但其判别准确率较低。部分学者对算法进行了优化改进^[6-12],提高了动态称重系统的测量精度,为实际应用奠定了基础,但该方法从根本上始终无法解决货车绕路行驶的问题。车载式测重法通过在货车上安装传感装置测量车辆重量,并判断超载情况,例如利用激光位移传感器来测量钢板弹簧形变程度来估计车辆重量^[13],判断是否超载。该方法难点在于对于车辆重量的估计,需要经过大量测试来获取弹簧形变与重量之间的对应关系^[14],才能保证测量精度。也有部分学者研究了新型的微机电车载称重系统,由微机电车载称重传感器^[15-20],定位通信终端和数据处理模块组成,利用微机电车载传感器将重量信息转化为电流,并利用通信模块传输数据到终端进行记录和进一步的处理从而完成货车重量的实时测量。车载式称重法虽可实现实时测量,但需要在货车上安装各式传感器来采集信息,价格昂贵,而国内运输货车基数大,因此短时间难以普及,实用所需时间较长。

由于人工智能技术自适应性、快速处理和泛化能力强,近年来已应用于城市交通的预测、分析和决策等过程^[21-25],不断推动交通智能化发展。其中,交通模式识别是构成智能交通系统的最重要部分之一,通过利用神经网络、卷积神经网络和图神经网络等,挖掘行驶轨迹数据中的隐式特征和逻辑,从而进一步完成识别和分类等复杂任务^[26-31]。这充分证明了通过挖掘车辆行驶轨迹特征来完成复杂任务方法的可行性,同时验证了深度学习模型在处理复杂车辆行驶轨迹数据时表现出的优越性能,因此本文提出了一种基于 TOI-Net 的高精度货车超载智能判别方法,借助设计的高精度货车超载智能判别模型 TOI-Net 来充分挖掘货车行驶轨迹数据中的典型超载特征,从而实现对于货车超载行为的快速、精确和全面的判别。

1 方法描述

针对现有超载判别方法所存在的效率低、不全面的问题,本文提出了一种基于 TOI-Net 的高精度货车超载智能判别方法,通过分析货车上安装的卫星定位装置所采集到的数据,实现对于货车超载行为的准确、高效和低成本的判别。如图 1 所示,本文所提方法首先将货车行驶轨迹数据转化为货车行驶轨迹图像,之后利用所设计的 TOI-Net 充分挖掘和识别其中的超载行为特征,得到超载判别结果,据此为执法人员提供精准、有效的执法区域,有效制止货车超载运输现象。

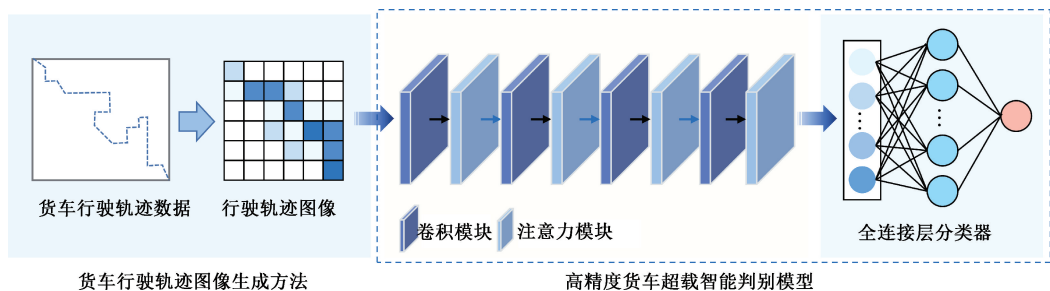


图 1 基于 TOI-Net 的高精度货车超载智能判别方法示意图

Fig. 1 Diagram of the high-precision intelligent identification method of truck overload based on TOI-Net

所输入的货车行驶数据,包括车牌号、行驶时间、速度和位置信息,由货车上安装的卫星定位装置采集,并及时传输至交通管理平台的数据终端进行记录。超载行驶货车与正常行驶货车相比,受到货车司机自身驾驶心理的影响和交通管制的约束,使得其驾驶过程中存在着典型超载特征,例如绕路行驶、变道次数多、“跑小路”、夜间行驶、装卸点聚集等,这些特征作为目标信息特征被隐含于货车行驶数据之中。而原始货车行驶轨迹数据维度

高,特征较为分散,提取难度大,故本文针对于特定超载判别任务设计了货车行驶轨迹图像生成方法,将货车行驶轨迹数据转化为行驶轨迹图像,实现了特征的降维和聚合。进一步的,本文所设计的 TOI-Net,其可通过多层次的卷积特征提取和组合操作,从大规模数据集中自动学习超载货车行驶轨迹图像中的模式和规律,从而可充分挖掘行驶轨迹图像中的超载信息特征,对超载行为做出精确判别。

2 货车行驶轨迹图像生成方法

为解决初始货车行驶轨迹数据维度高、数据量大、特征分散、难以进行分析的问题,本文提出了一种针对于超载货车判别任务的轨迹图像生成方法,可将复杂的货车行驶轨迹多维时空数据转换为二维轨迹图像,在降低数据的维度和复杂性基础上,增强数据中的超载特征,削弱无效特征,从而更易实现超载信息特征的提取和分析。单辆车初始货车行驶轨迹数据如图 2 所示,其中单个位置点的速度大小用不同颜色进行表示。

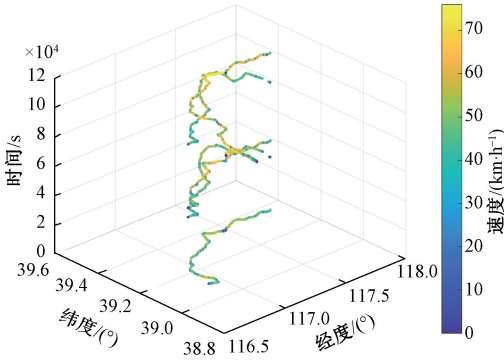


图2 单辆货车行驶轨迹数据

Fig.2 Single truck driving trajectory data




图3 货车行驶轨迹图像生成流程

Fig.3 Truck driving trajectory image generation process

其中:

$$f(p_x, m_{i,j}) = \begin{cases} 1, & p_x \in m_{i,j} \\ 0, & p_x \notin m_{i,j} \end{cases} \quad (2)$$

$$T(N_{i,j}) = 255 \left(\frac{2}{\pi} \arctan \left(\frac{N_{i,j}}{50} \right) \right) \quad (3)$$

$$N_{i,j} = \sum_{p_x \in P} f(p_x, m_{i,j}) \quad (4)$$

式中: i, j 分别表示图像坐标系下的横纵坐标; $g_{i,j}$ 表示像素点 $m_{i,j}$ 处的灰度值; p_x 表示第 x 个坐标点; P 表示所有的轨迹点集合; $f(*)$ 为坐标点像素格位置的判断函数; $T(*)$ 为映射函数,用于将单个像素格内行驶轨迹点数量转化为像素灰度,即映射到 $[0, 255]$; $N_{i,j}$ 为映射函数输入,表示单个像素格内的行驶轨迹点数量。

所提轨迹图像生成方法首先将输入的初始货车行驶轨迹数据去除时间维度并映射到空间维度上,之后选定轨迹图像的范围和分辨率,建立行驶轨迹点与图像像素之间的转换模型,将单个格内轨迹信息用像素灰度值来表示,最终得到货车行驶轨迹图像,实现将多维时空数据转换为二维行驶轨迹图像。行驶轨迹点图像中单个像素点的坐标对应实际空间位置,其灰度值代表在该空间位置区域的活动信息,即轨迹点数越多,行驶时间越长,灰度值越大。因此该货车行驶轨迹图像中包含了货车的行驶时间、速度和位置等信息,实现了数据的降维和压缩,货车行驶轨迹图像生成的流程如图 3 所示。

本文的研究对象为天津市内货车,通过对货车行驶轨迹分布区域的分析,结合天津市市域范围,最终选取货车行驶轨迹图像的范围为东经 $116.6^\circ \sim 118.2^\circ$,北纬 $38.6^\circ \sim 40.2^\circ$ 。考虑到轨迹图像像素实际覆盖范围和卷积神经网络训练和推理时间,选择生成的行驶轨迹图像分辨率为 500×500 。

建立行驶轨迹点与图像像素之间的转换模型,将单个格内轨迹信息用像素灰度值来表示,转换模型如下:

$$g_{i,j} = T \left(\sum_{p_x \in P} f(p_x, m_{i,j}) \right) \quad (1)$$

映射函数在货车行驶轨迹图像中作为信息表征的工具,其一方面可将多个行驶轨迹点划分为一个区域从而实现信息的压缩;另一方面可将单个像素格所代表的空间范围内的货车行驶时间和速度信息用灰度值可表示,即在该空间范围内停留时间越长,灰度值越大。

所用映射函数的映射关系如图 4 所示,该函数在输入单个格内行驶轨迹点数 $N_{i,j} \in [10, 60]$ 时输出灰度值 $g_{i,j}$ 变化率较大;在 $N_{i,j} > 60$ 时变化率较小。映射函数的特点对应到货车行驶轨迹图像上,灰度值变化率越大在图像中可表现出更加丰富的纹理信息,因此更易被网络所捕捉,而变化率较小表明货车行驶时间和速度等信息的变化对图像影响很小,所表现出的不明显的特征在图像中也难以被网络所关注。充分分析货车行驶行为,当

单个像素格内轨迹点数位于 $[0, 10]$ 区间范围,货车行驶速度较快,故无明显特征;当单个像素格内轨迹点数超过60时(对应时间长度为30 min)认为货车处于停车状态;当点数在 $[10, 60]$ 的货车处于慢速行驶、减速、拐弯、换道等状态,故超载特征最丰富且最为重要。因此该映射函数能够增强 $[10, 60]$ 区间范围内的特征,同时削弱 $N_{i,j} > 60$ 范围内的特征,规避了货车停车对行驶轨迹图像所带来的影响,使超载特征信息在行驶轨迹图像中更为突出,更易实现特征的提取和分类。




图4 单个像素块内行驶轨迹坐标点数量与像素灰度的映射
Fig. 4 The curve between the number of driving trajectory points and the gray in a single pixel

3 高精度货车超载智能判别模型

为充分挖掘货车行驶轨迹图像中的典型超载特征信息,完成货车超载判别任务,本文设计了一种高精度货车超载智能判别模型 TOI-Net,其由多个 RepVGG 模块^[32]构成基础卷积神经网络,在此基础上为引导网络关注更加重要的特征,提高网络的超载判别能力,在网络中增加了位置注意力模块^[33],使网络充分利用货车行驶轨迹图像中的丰富注意力信息。

TOI-Net 的整体结构如图5所示,包含1层卷积层、4层 RepVGG 模块、4层位置注意力模块、1层平均池化层和1层全连接层。其中卷积层和 RepVGG 模块用于提取超载轨迹图像的超载特征。位置注意力模块帮助网络获取更加精准的特征位置信息。平均池化层进行特征降维,最后经过全连接层输出超载判别结果。TOI-Net 各层结构的具体参数如表1所示。

TOI-Net 中 RepVGG 模块结构如图6所示,其由3条分支组成,分别利用两种大小的卷积核来提取特征,并构建了残差连接分支来增加信息的流动,最终将个分支得到的特征图融合到一起。在推理时 RepVGG 模块可通过结构重参数机制^[32]将原模块结构等效为单个 3×3 卷积核,从而减少模型计算量。因此,通过引入 RepVGG 模

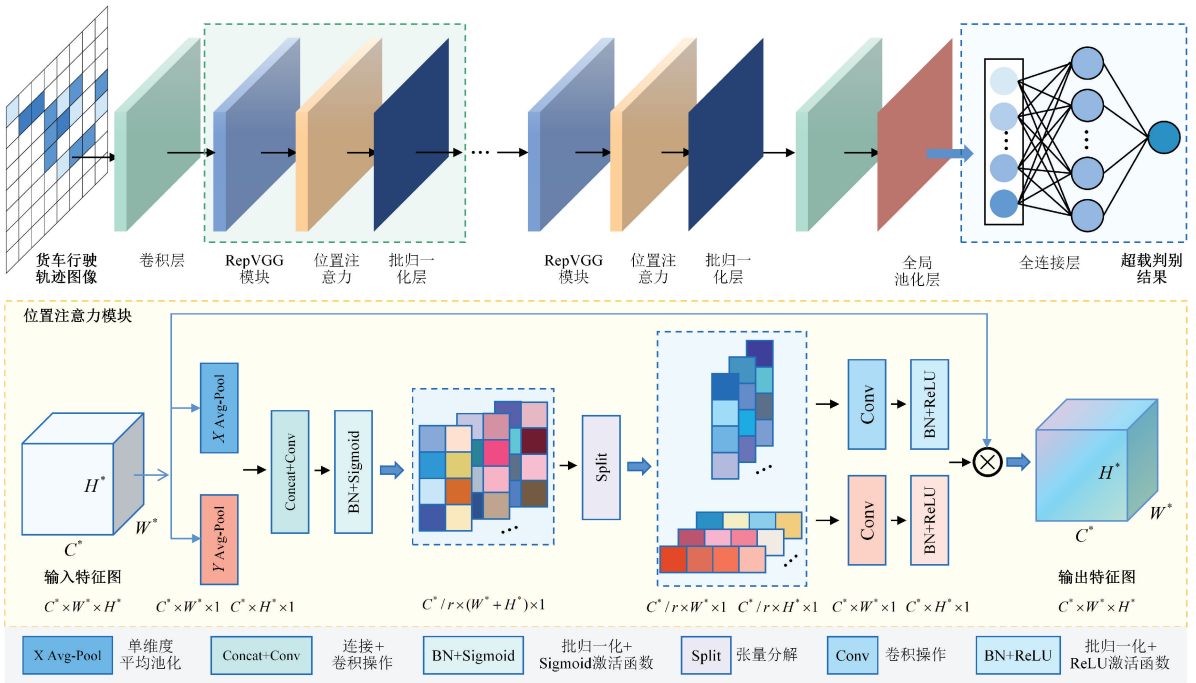


图5 TOI-Net 模型框架
Fig. 5 The framework of TOI-Net

块,能够在确保模型特征提取能力的同时,大大提高模型

推理的速度,从而提升 TOI-Net 的货车超载判别能力。

表 1 TOI-Net 各层结构

Table 1 The structure of TOI-Net each layer

名称	参数	输出尺寸
输入层	-	(500×500×1)
卷积层	(3×3, 48)	(250×250×48)
RepVGG 模块 1+位置注意力模块	RepVGG Block×2	(125×125×48)
RepVGG 模块 2+位置注意力模块	RepVGG Block×4	(63×63×96)
RepVGG 模块 3+位置注意力模块	RepVGG Block×14	(32×32×192)
RepVGG 模块 4+位置注意力模块	RepVGG Block×1	(16×16×512)
卷积层	(3×3, 1 024)	(8×8×1 024)
平均池化层	-	(1×1×1 024)
全连接层	(1 024×2)	(1×2)
输出层	-	(1×2)

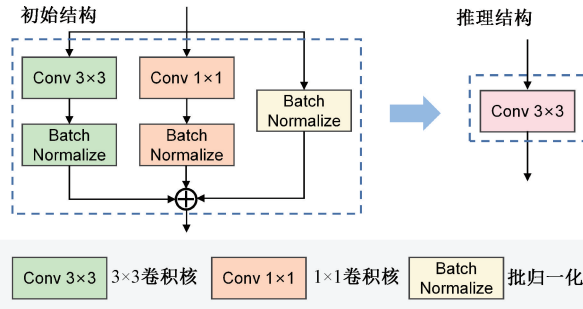


图 6 RepVGG 模块结构

Fig. 6 The structure of the RepVGG module

行驶轨迹图像中包含着典型超载特征,但由于其覆盖范围广和货车自身行驶特点,使得图像中大多信息为无效信息。此外,典型超载特征对于空间位置十分敏感,相同的轨迹空间特征在特征图的不同位置有完全不同的表现。因此,本文在原有网络基础上增加了位置注意力模块来帮助 TOI-Net 网络提取到更加精确、深层、有价值的信息,从而提高超载判别的精度。

位置注意力模块的结构如图 5 所示,对于给定输入 $\tilde{X}, \tilde{X} \in \mathbb{R}^{C^* \times W^* \times H^*}$,使用两个一维全局池化核进行处理得到水平和垂直方向的感知特征图 Z_w, Z_h :

$$Z_w = \frac{1}{H} \sum_{0 < h < H} \tilde{X}(c, w, h) \quad (5)$$

$$Z_h = \frac{1}{W} \sum_{0 < w < W} \tilde{X}(c, w, h) \quad (6)$$

将两个感知特征图级联,并经过一个卷积变换和 Sigmoid 激活函数处理,实现通道信息的挤压过程,得到处理后的特征图 F :

$$F = \text{Sigmoid}(\text{BN}(f^{1 \times 1}([\tilde{Z}_w, \tilde{Z}_h]))) \quad (7)$$

式中: $F \in \mathbb{R}^{C^*/r \times (W^*+H^*)}$; $[\cdot, \cdot]$ 表示沿空间维度的级联

运算;BN 为批归一化操作; $f^{1 \times 1}$ 表示 1×1 卷积运算; r 表示特征图通道缩减率。

之后将特征图 F 沿空间维度拆分为两个独立的方向特征图 $F^h \in \mathbb{R}^{C^*/r \times H}$, $F^w \in \mathbb{R}^{C^*/r \times W}$,分别经过卷积和非线性变换后恢复到原通道数,完成通道信息的激励过程,得到水平方向注意力权重 g^h 和垂直方向注意力权重 g^w :

$$g^h = \text{ReLU}(\text{BN}(f^{1 \times 1}(F^h))) \quad (8)$$

$$g^w = \text{ReLU}(\text{BN}(f^{1 \times 1}(F^w))) \quad (9)$$

式中:ReLU 表示 ReLU 激活函数; $g^h \in \mathbb{R}^{C^* \times W^* \times 1}$; $g^w \in \mathbb{R}^{C^* \times H^* \times 1}$ 。

原始输入 \tilde{X} 与水平方向注意力权重和垂直方向注意力权重进行乘法计算得到具有两方向通道注意力的特征图 X_{out} :

$$X_{out} = \tilde{X} \times g^h \times g^w \quad (10)$$

4 实验验证

为评估本文提出的基于 TOI-Net 的高精度货车超载智能判别方法的有效性,构建了货车超载数据集,建立了实验平台,并在数据集上进行了实验和测试。本实验平台基于 Windows 11 的 64 位操作系统,配有 NVIDIA GeForce RTX 3090 的 GPU 显卡以及 AMD Ryzen 9 5950X 的 CPU。深度学习框架、编程语言和计算机视觉库分别为 Pytorch 1.10.0、Python3.7 和 OpenCV4.5.1。

4.1 数据集构建

本文所用数据库来源于天津市公共交通数据平台,共包含约 49×10^4 辆货车,其各项信息如表 2 所示,其行驶时间分布在 2022 年 11 月 1 日 0:00~30 日 24:00,其中超载货车约 15×10^4 辆,无超载行为的货车约 34×10^4 辆,数据库中所有货车行为均已通过人工治超点称重法确认是否超载,且数据库中车辆行驶轨迹数据时间范围为检测超载前 24 h。

表 2 数据库信息

Table 2 Database information

信息	值
数据集大小	240 GB
车辆数目	49×10^4 辆
信息条数	25×10^8 条
超载车辆数目	150 225
正常车辆数目	341 776
行驶时间	2022 年 11 月 1 日 0:00~30 日 24:00

相关部门所收集到的货车行驶轨迹数据原始数据文件如图 7 所示,单辆车的行驶数据无规律分布在数据

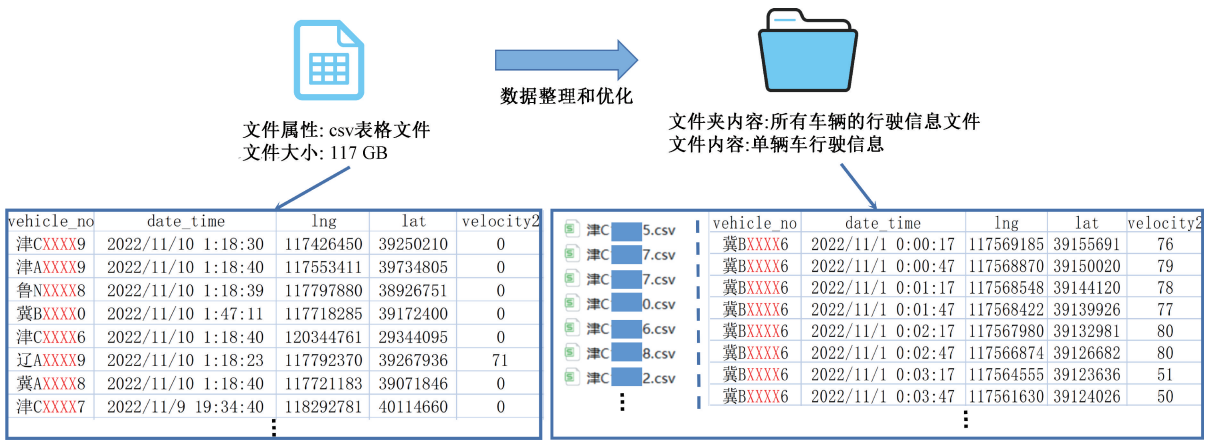


图7 整理和优化后的数据文件

Fig. 7 The organized and optimized data file

文件中的各个位置,且存在数据丢失,数据格式错误等问题,因此需将原始文件中的数据进行整理、优化处理。

将处理后的数据文件按照第2章所提方法转换为货车行驶轨迹图像,如图8所示,按照实际交通查处情况将

其分为超载和正常两类,共包含货车轨迹图像 200 000 张,其中超载货车与正常货车比例为 1:1,得到货车超载数据集。数据集中 90% 的图像构成训练集,用于模型的训练;10% 的图像构成测试集,用于验证模型有效性。




图8 生成的货车轨迹图像

Fig. 8 The transformed truck driving trajectory image


4.2 超载车辆行为分析

从数据集中随机抽取部分超载货车和正常货车数据信息,分析超载货车驾驶行为特征,来验证方法的有效性,共抽取 514 辆超载货车和 438 辆正常货车。

分析超载货车在道路选择上的差异性特征,定义车辆道路等级变化频次为 CFRC (changing frequency of vehicles in different road classes),表示车辆在不同等级道路之间的转换次数,单位距离的转换频次定义为 CFUD (changing frequency of vehicle in different road classes per unit distance),车辆道路等级行驶距离比例定义为 PDRC (proportion of distance in road class),表示车辆在不同等级的道路上的行驶距离的比例。样本集的 CFRC 散点图如图 9 所示,PDRC 分析结果如表 3 所示。


由图 9 可以看出,超载货车 CFUD 平均为 0.228,正常货车为 0.152,这说明超载货车与正常货车相比其不同等级道路之间的转换频率更高。由表 3 可以看出,超载货车主要行驶道路为非高速国道和省道,而正常货车主要为高速公路,且超载货车在县道和乡道上的行驶

比例远高于正常货车。综上,超载货车与普通货车相比,其会存在一些绕路、频繁变道、“跑小路”等行驶特征,以此来躲避治超点的检查,进行违法运输,这证明了本文通过挖掘货车行驶轨迹中的典型超载特征来进行超载判别的可行性。



(a) 超载货车CFRC与距离散点图

(a) Scatter plot of CFRC and distance of the overloaded truck



(b) 正常货车CFRC与距离散点图
(b) Scatter plot of CFRC and distance of the normal truck

图 9 样本集货车 CFRC 与距离散点

Fig. 9 Scatter plot of CFRC and distance of the truck in sample set

表 3 PDRC 分析结果

Table 3 PDRC analysis results

货车类型	超载货车	正常货车
高速公路	0.082	0.463
(非高速)国道	0.489	0.271
(非高速)省道	0.309	0.207
(非高速)县道	0.077	0.039
乡道	0.031	0.007
其他道路	0.012	0.013

4.3 模型测试实验

在构建的数据库上并构建数据集以供模型进行训练和测试,其中训练集和测试集的大小比例为 10:1。

在构建的训练集上对模型进行训练,模型训练信息如表 4 所示。在测试集上对训练好的模型进行测试来验证方法的有效性和可行性,同时为验证本文设计的模型在货车超载判别上的优越性能,与主流图像分类算法进行了对比实验,结果如表 5 所示,最优结果以黑色加粗进行标注。

表 4 模型训练信息

Table 4 Model training information

信息	值
训练批次 (epochs)	50 代
批量大小 (batch size)	32 张
优化器 (optimizer)	Momentum
动量大小	0.9
学习率初始值	0.000 1

表 5 实验测试结果

Table 5 Experimental test results (%)

模型	准确率	查全率	查准率
TOI-Net	96.1	96.4	95.7
支持向量机 (SVM)	69.2	68.1	68.8
GoogLeNet ^[34]	89.7	91.1	88.5
ResNet-101 ^[35]	89.6	89.8	90.1
DenseNet ^[36]	91.9	92.5	91.1
EfficientNet ^[37]	92.8	92.9	92.2
MobileNetV3 ^[38]	92.3	93.1	92.4

测试结果显示本模型在超载判别任务中的预测准确率为 96.1%,查全率为 96.4%,查准率为 95.7%,均高于主流图像分类算法。这进一步说明了本模型在典型超载特征提取和分类方面能力更强,适应性更好,能够更好的完成超载判别任务。

为验证 TOI-Net 中注意力模块的作用,本文设计了消融实验,分别测试原网络和加入注意力模块后的网络的超载判别准确率,如表 6 所示。

表 6 注意力模块消融实验

Table 6 Attention module ablation experiment (%)

模型信息	准确率	查全率	查准率
TOI-Net	96.1	96.4	95.7
无注意力模块的网络	92.2	93.0	92.5

该消融实验表明,加入注意力模块后能够在一定程度上提高模型的超载判别能力,同时可提高本文方法的超载判别准确率,且对于其查全率即全面检测能力也有较大提高。验证了网络中的位置注意力模块能够充分获取货车轨迹图像中准确的空间位置信息,从而提升模型对于空间特征的提取能力,提高模型性能。

4.4 实际应用实验

将本文所提出的方法结合交通管理大数据平台,应用于天津市蓟州区的交通执法工作之中,对大范围内的货车超载行为进行检测来完成初始筛查,并根据检测结果为执法人员提供精确的执法区域,有效制止超载运输违法行为。2023 年 7~9 月实际应用测试结果如表 7 所示。

表 7 实际应用测试结果

Table 7 Practical application test results

本文方法标记超载货车	实际超载货车	实际查准率
7 802	7 591	97.3%

测试结果显示,本文方法在实际应用测试中的查准率为97.3%,因此可有效用于货车超载行为的判断任务。

在实际测试过程中,将本文方法与传统的人工治超点称重法的检测结果进行了对比,结果如表8所示。

表8 两种方法检测结果对比

Table 8 Practical application test results

方法类别	一季度检测货车数量	查处超载货车
本文方法	110 457	7 591
人工治超点称重法	40 979	4 484

从表8可以看出,本文所提出的方法与传统的货车超载判别方法相比具有更大的监测范围,且能够有效的查处故意绕路行驶躲避检查的超载货车。

实际应用测试结果表明,本文所提出的方法具有检测速度快、精度高、范围广等优势,可实现对于全市域内货车超载行为的快速检测,且无需额外安装传感器,具有很高的应用价值。

5 结论

针对现有超载判别方法效率低、不全面的问题,本文提出了一种基于TOI-Net的高精度货车超载智能判别方法,通过分析货车卫星定位装置所记录的行驶轨迹数据可实现对货车超载行为的快速、精确和全面的判别。

1) 提出了一种针对于超载货车判别任务的货车行驶轨迹图像生成方法,可将多维度货车行驶轨迹时空数据转化为行驶轨迹图像,在降低数据复杂性的同时实现了特征的聚合,更易实现货车行驶轨迹数据的特征提取和分析。

2) 设计了一种高精度货车超载判别模型TOI-Net,由Residual模块构成基础卷积神经网络模型,在此基础上增加了空间注意力模块和通道注意力模块丰富特征注意力信息,进一步提高了TOI-Net的超载判别能力。

3) 在构建的货车超载数据集上,对模型进行了测试,超载判别准确率为96.1%,查全率为96.4%,查准率为95.7%,检测准确率比MobileNetV3高了3.8%,充分验证了模型的有效性和准确性。此外,在天津市蓟州区进行了实际应用实验,实际查准率为97.3%,证明了方法的应用价值。实验结果表明,本文方法实现了最高效、准确的货车超载判别,能够作为新型超载判别方法接入交通管理大数据平台,在降低相关执法人员工作量的同时提升交通智能化管理水平。

参考文献

[1] HAN W, WU J, CAI C S, et al. Characteristics and dynamic impact of overloaded extra heavy trucks on

typical highway bridges [J]. *Journal of Bridge Engineering*, 2015, 20(2): 05014011.

- [2] 李忠奎, 荣朝和. 治理公路超载超限运输的长效机制和对策研究[J]. *中国公路学报*, 2005, 18(4): 96-99.
LI ZH K, RONG CH H. Research on long-term mechanism and countermeasures of controlling highway overload and over-limit transportation [J]. *China Journal of Highway and Transport*, 2005, 18(4): 96-99.
- [3] QIAO X X, ZHAO Y D. Vehicle overload detection system based on magnetoresistance sensor [C]. 2018 International Conference on Electronics Technology (ICET). IEEE, 2018: 102-105.
- [4] BURNOS P, GAJDA J, SROKA R, et al. High accuracy weigh-in-motion systems for direct enforcement [J]. *Sensors*, 2021, 21(23): 8046.
- [5] KONIOR A, KONIOR T, BRZOZOWSKI K, et al. New functionalities of the weigh-in-motion system: IWIM solution [J]. *Transport Problems*, 2023, 18(2): 161-170.
- [6] LIU Y L, LIU ZH H. An optimized method for dynamic measurement of truck loading capacity [C]. 2018 3rd IEEE International Conference on Intelligent Transportation Engineering (ICITE). IEEE, 2018: 120-124.
- [7] FU H, ZHANG Y, GANG X, et al. Research on on-board dynamic weighing algorithm based on two-degree-of-freedom 1/4 vehicle model [J]. *International Journal of Heavy Vehicle Systems*, 2021, 28(6): 792-807.
- [8] ZHAO SH F, YANG J W, TANG ZH H, et al. Methodological study on the influence of truck driving state on the accuracy of weigh-in-motion system [J]. *Information*, 2022, 13(3): 130.
- [9] 唐思豪, 滕召胜, 孙彪, 等. ADAM改进BP神经网络与动态称重应用 [J]. *电子测量与仪器学报*, 2021, 35(4): 127-135.
TANG S H, TENG ZH SH, SUN B, et al. ADAM improved BP neural network and its application in dynamic weighing [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(4): 127-135.
- [10] LEE H H, YOON K T, CHOI Y M. Checkweigher using an EMFC weighting cell with magnetic springs and air-bearings [J]. *Metrology and Measurement Systems*, 2021, 28(3): 465-78.
- [11] 杨洋, 王文成, 高攀, 等. 动态轨道称重光纤布拉格光栅压力传感器的设计 [J]. *激光与光电子学进展*, 2022, 59(3): 301-308.
YANG Y, WANG W CH, GAO P, et al. Design of fiber Bragg grating pressure sensor for dynamic track weighing [J]. *Laser & Optoelectronics Progress*, 2022,

- 59(3):301-308.
- [12] 孙彪,滕召胜,唐思豪,等. 联合时变低通与改进形态学滤波的智能在线称量方法研究[J]. 仪器仪表学报, 2021, 42(6): 29-36.
SUN B, TENG ZH SH, TANG S H, et al. Research on intelligent online weighing method combining time-varying low-pass and improved morphological filtering [J]. Chinese Journal of Scientific Instrument, 2021, 42(6): 29-36.
- [13] YIN J J, CHEN Z J, LIU C, et al. Design and experiments of a real-time bale density monitoring system based on dynamic weighing[J]. Sensors, 2023, 23(4): 1778.
- [14] AGORASTOU Z, GOGOLOU V, KOZALAKIS K, et al. Area estimation circuit for weigh-in-motion applications using piezoelectric transducers [C]. 2021 28th IEEE International Conference on Electronics, Circuits, and Systems (ICECS). IEEE, 2021: 1-5.
- [15] HE W, LIANG X, DENG L, et al. Axle configuration and weight sensing for moving vehicles on bridges based on the clustering and gradient method [J]. Remote Sensing, 2021, 13(17): 3477.
- [16] KWON J, PARK D. Efficient sensor processing technique using Kalman filter-based velocity prediction in large-scale vehicle IoT application [J]. IEEE Access, 2022, 10: 116735-116746.
- [17] LIANG H. Reliability evaluation method of vehicle acceleration sensor based on vector control [J]. International Journal of Vehicle Design, 2021, 86(1-4): 1-17.
- [18] ONAT A, KAYAALP B T. A joint unscented Kalman filter-based dynamic weigh in motion system for railway vehicles with traction[J]. IEEE Sensors Journal, 2021, 21(14): 15709-15718.
- [19] OUBRICH L, OUASSAID M, MAAROUFI M. A new analog filter for piezoelectric sensors signal processing designed for high speed weigh in motion system [J]. IEEE Access, 2021, 9: 138057-13866.
- [20] WANG H, NAGAYAMA T, SU D. Static and dynamic vehicle load identification with lane detection from measured bridge acceleration and inclination responses[J]. Structural Control & Health Monitoring, 2021, 28(11): e2823.
- [21] JIN G, CUI Y, ZENG L, et al. Urban ride-hailing demand prediction with multiple spatio-temporal information fusion network [J]. Transportation Research Part C: Emerging Technologies, 2020, 117: 102665.
- [22] MA Y, GUAN X, CAO J, et al. A multi-stage fusion network for transportation mode identification with varied scale representation of GPS trajectories [J]. Transportation Research Part C: Emerging Technologies, 2023, 150: 104088.
- [23] 梁继然,陈壮,董国军,等. 结合注意力机制和密集连接网络的车辆检测方法[J]. 电子测量与仪器学报, 2022, 36(3): 210-216.
LIANG J R, CHEN ZH, DONG G J, et al. Vehicle detection method combining attention mechanism and dense connection network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(3): 210-216.
- [24] 杜荣华,朱胜亿,魏克湘,等. 交通环境能量采集及自供电交通设施健康状态监测研究进展[J]. 仪器仪表学报, 2022, 43(3): 3-23.
DU R H, ZHU SH Y, WEI K X, et al. Research progress on energy harvesting and self-powered traffic facility health monitoring in traffic environments [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 3-23.
- [25] TRAN T, HE D, KIM J, et al. MSGNN: A multi-structured graph neural network model for real-time incident prediction in large traffic networks [J]. Transportation Research Part C: Emerging Technologies, 2023, 156: 104354.
- [26] ZHANG D, LEE K, LEE I. Mining hierarchical semantic periodic patterns from GPS-collected spatio-temporal trajectories [J]. Expert Systems with Applications, 2019, 122: 85-101.
- [27] FENG S, WEI S, ZHANG J, et al. A macro-micro spatio-temporal neural network for traffic prediction [J]. Transportation Research Part C: Emerging Technologies, 2023, 156: 104331.
- [28] ZHENG C, FAN X, WANG C, et al. Gman: A graph multi-attention network for traffic prediction [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 1234-1241.
- [29] 胡杰,许力,孟武强,等. 基于相空间重构的驾驶风格定量评估[J]. 仪器仪表学报, 2017, 38(3): 635-642.
HU J, XU L, MENG W Q, et al. Quantitative evaluation of driving style based on phase space reconstruction [J]. Chinese Journal of Scientific Instrument, 2017, 38(3): 635-642.
- [30] ZHOU S, LI J, WANG H, et al. GRLSTM: Trajectory similarity computation with graph-based residual LSTM [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(4): 4972-4980.
- [31] 殷礼胜,魏帅康,孙双晨,等. 基于 FEEMD-SAPSO-

BiLSTM 组合模型的短时交通流预测[J]. 电子测量与仪器学报, 2021, 35(10): 72-81.

YIN L SH, WEI SH K, SUN SH CH, et al. Short-term traffic flow prediction based on the FEEMD-SAPSO-BiLSTM composite model [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 72-81.

- [32] 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.
- [33] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [34] 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.
- [35] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [36] HUANG G, LIU Z, VAN D M L, et al. Densely connected convolutional networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.
- [37] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of The IEEE/Cvf Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 11534-11542.
- [38] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3 [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.

作者简介



梁健, 2021 年于哈尔滨工程大学获得学士学位, 2023 年于天津大学获得硕士学位, 现在天津大学博士研究生, 主要研究方向为深度学习、三维测量等。

E-mail: liangjian@tju.edu.cn

Liang Jian received his B.Sc. degree from Harbin Engineering University in 2021, and received his M.Sc. degree from Tianjin University in 2023. He is currently a Ph.D. candidate at Tianjin University. His main research interests include deep learning and three-dimensional measurement.



康杰虎(通信作者), 分别在 2010 年、2013 年和 2021 年在天津大学获得学士学位、硕士学位和博士学位, 现为天津大学仪器科学与技术专业副研究员, 主要研究方向为计算机视觉、视觉测量等。

E-mail: kangjiehu_305@tju.edu.cn

Kang Jiehu (Correspondence author) received his B.Sc. degree, M.Sc. degree, and Ph.D. degree all from Tianjin University in 2010, 2013, and 2021, respectively. He is currently an associate researcher with the Department of Instrumentation Science and Technology at Tianjin University. His main research interests include compute vision and vision measurement technology.



赵宗扬, 2020 年于中国矿业大学(北京)获得学士学位, 2023 年于中国矿业大学(北京)获得硕士学位, 现为天津大学博士研究生, 主要研究方向为深度学习和轨道交通等。

E-mail: azhaozongyang@163.com

Zhao Zongyang received his B.Sc. degree from China University of Mining and Technology (Beijing) in 2020, and M.Sc. degree from China University of Mining and Technology (Beijing) in 2023. He is currently a Ph.D. candidate at Tianjin University. His main research interests include deep learning, object detection and rail transit.



吴斌, 分别在 1997 年和 2002 年在天津大学获得学士学位和博士学位, 现为天津大学教授, 主要研究方向为计算机视觉、目标检测和视觉测量等。

E-mail: wubin@tju.edu.cn

Wu Bin received the B.Sc. degree and Ph.D. degree both from Tianjin University in 1997 and 2002, respectively. He is currently a professor at Tianjin University. His main research interests include compute vision, object detection and vision measurement technology.



王雪森, 2010 年于天津大学获得学士学位, 2013 年于天津大学获得硕士学位, 现为天津市工程设计研究总院有限公司高级工程师, 主要研究方向为智慧交通。

E-mail: E-angle_new@163.com

Wang Xuesen received his B.Sc. degree from Tianjin University in 2010, and M.Sc. degree from Tianjin University in 2013. He is currently a senior engineer at Tianjin Municipal Engineering Design and Research Institute Co., LTD. His main research interest is intelligent transportation.