

高速公路应急车道紧急启用模型研究

申雨泽*, 王冠洲, 张英豪

西京学院计算机学院, 陕西 西安

收稿日期: 2025年5月9日; 录用日期: 2025年7月17日; 发布日期: 2025年7月29日

摘要

本研究聚焦于高速公路拥堵问题, 旨在构建科学有效的应急车道紧急启用模型。通过对高速公路交通流数据的深入分析, 运用ARIMA和LSTM等模型预测拥堵情况, 设计合理的应急车道启用规则, 并提出优化的视频监控点布置方案。研究结果为高速公路管理部门提供了决策支持, 有助于提高高速公路的运行效率和安全性, 最大化利用应急车道资源。

关键词

高速公路, 应急车道, 交通拥堵预测, ARIMA模型, LSTM模型

Research on the Emergency Activation Model of Expressway Emergency Lanes

Yuze Shen*, Guanzhou Wang, Yinghao Zhang

School of Computer Science, Xijing University, Xi'an Shaanxi

Received: May 9th, 2025; accepted: Jul. 17th, 2025; published: Jul. 29th, 2025

Abstract

This research focuses on the congestion problem of expressways, aiming to construct a scientific and effective emergency activation model for emergency lanes. Through in-depth analysis of expressway traffic flow data, models such as ARIMA and LSTM are used to predict congestion situations, reasonable emergency lane activation rules are designed, and an optimized video surveillance point layout scheme is proposed. The research results provide decision-making support for expressway management departments, which is helpful to improve the operational efficiency and safety of expressways and maximize the utilization of emergency lane resources.

*通讯作者。

Keywords

Expressway, Emergency Lane, Traffic Congestion Prediction, ARIMA Model, LSTM Model

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

1.1. 研究背景与意义

随着经济的快速发展,高速公路交通流量急剧增长,拥堵问题日益严重。高速公路拥堵不仅降低了交通运输效率,增加了出行成本,还对环境造成了负面影响。交通事故、特定路段的瓶颈现象(如匝道出入口、桥梁入口等)以及车道数量有限等因素,共同制约了高速公路的通行能力。尽管拓宽道路等传统方法能在一定程度上缓解拥堵,但在现有资源条件下,如何更高效地利用现有设施成为亟待解决的问题。

应急车道作为高速公路的重要组成部分,在正常情况下专供特殊车辆使用,但在特定条件下合理临时启用应急车道,能够有效降低车流密度,缓解交通拥堵。目前,应急车道的启用主要依赖高速管理部门的经验和视频监控,缺乏科学的理论依据和有效的效果评估手段。因此,建立一套科学合理的高速公路应急车道紧急启动模型具有重要的现实意义,它能够为交通管理部门提供决策支持,提高高速公路的运行效率和安全性,减少拥堵带来的经济损失和社会影响。

1.2. 国内外研究现状

在人工智能技术迅猛发展以及智能交通设备广泛普及的大背景下,利用智能化手段环节交通拥堵具备了现实可行性。为了建立性能优异的交通流模型,需按顺序完成车辆的精准检测、持续跟踪、交通流预测等关键步骤,在此过程中,目标检测、多目标跟踪、图像分类、深度学习算法建模等前沿技术的运用不可或缺,本论文将围绕上述技术展开全面且深入的调研工作,其中国内外研究现状如下所示。

1.2.1. 交通流预测方法相关研究

智能交通系统作为处理城市交通的重要信息化手段[1],其主要通过交通流预测技术,深度剖析当前交通运行的实际状况展开精准评估与前瞻性预测,以便为交通管理部门提供预警决策依据[2],通过数字化手段有效环节交通拥堵难题。

Zhu 等[3]采用 Transformer 架构学习交通流时序的全局依赖关系,利用图卷积注意网络(GCAT)学习区域路网间的空间依赖关系,并通过串联方式建立基于混联交通流的时空网络(TRGCAT)预测模型。Zhao 等[4]结合预定义图和历史交通流数据,利用 CNN 提取交通流时间特征,利用 GCN 提取空间特征,并通过时空同步建模机制实现交通流时空特征的一致性提取。Bai 等[5]提出一种用于流量预测的自适应图卷积循环网络,该方法基于自适应邻接矩阵,通过数据驱动方式学习路网节点间的动态关联关系,但没有充分利用历史交通数据,且模型会随训练停止而固定。Ju 等[6]提出一种时空动态融合图卷积网络,虽通过超图有效表征现实路网中节点动态时空关联关系,但忽略了多层图卷积空间特征提取时易产生冗余信息的问题。Cao 等[7]提出一种用于交通速度预测的多头自注意力门控时空图卷积网络,结合 TCN 和 G 分别提取交通时空特征,并通过循环门控机制避免特征冗余。

1.2.2. 车辆检测相关研究现状

岳等[8]提出基于轻量化 CenterNet 的车辆检测算法,采用深度可分离的 PANet 取代 MobileNetV3 [9]

网络以及原有的 ResNet-50 网络, 以此降低计算量。将特征增强网络替换为深度可分离的 PANet, 以获取多尺度特征信息融合后的特征。同时, 引入 SimAM 注意力机制[10], 在特征融合之前强化对目标特征的关注度。并且, 用 SiU [11]激活函数替换原目标检测网络中的 ReLU 激活函数, 以增强网络的学习能力。最后, 提出 CPAN-ASFF 模块, 对深度可分离的 PANet 输出的多尺度特征图进行融合, 进而提升目标检测精度。Rani 等人构建了一种以 YOLOv3-tiny [12]网络为基础的轻量级模型 Little YOLO-SPP, 在该模型中引入 SPP (Spatial Pyramid Pooling)结构, 旨在提高模型精度, 实现对车辆的实时有效检测。付世达则运用 SSD [13] (Single Shot MultiBox Detector)网络与车道线信息相结合的方式对车辆进行检测, 此方法在速度方面有一定成效, 能够有效检测出违规车辆, 但在检测视线较远的车辆时效果欠佳。

1.2.3. 车辆多目标跟踪相关研究现状

郭玉彬运用 YOLOv5 算法达成车辆的检测与跟踪目标[14], 在检测环节, 其针对 YOLOv5 实施了网络架构的优化举措, 构建出一种效率更为出众的 CG3 瓶颈构造, 并且引入了 ECA (高效通道注意力)注意力机制, 以此强化检测效果。在轨迹预测方面, 摒弃了传统的 SORT [15] (简易在线实时跟踪)算法, DeepSORT [16]在 SORT 架构的根基之上融入了外观信息, 借此有效提升了算法效能, 从而达成在目标遭遇较长时段遮挡情形下的精准跟踪, 鉴于 DeepSORT 存在特征表征能力欠佳的情况, 额外引入三元组损失, 从而有效提升模型针对车辆目标的特征提取水平, 增强整体的跟踪性能与准确性。李震霄着眼于车辆多目标跟踪过程中出现的身份跳变难题, 精心研发出 DeepSORT 的改良算法——L-DeepSORT [17]。

1.2.4. 车辆识别相关研究现状

多车辆目标识别在机器学习领域占据着重要的研究地位, 其实现过程主要依赖于特征提取与分类器训练[18], 传统机器学习算法所提取的特征多为浅层信息, 难以对车辆特征的动态变化进行精准刻画。近年来, 车辆目标识别已逐渐从传统算法全面迈向深度学习算法, 检测精度也显著提高。其中, 以单步多框目标检测器(SSD) [19]以及 YOLO [20]系列算法为典型的单阶段算法, 摒弃了候选区域生成环节, 借助卷积运算直接开展分类与回归操作, 进而生成物体的类别概率与坐标信息, 在识别精度与识别速度的平衡方面表现更为出色。李等[21]提出一种基于 YOLO 的改进 YOLO v7-R 算法, 将全局注意力机制(GAM)集成于骨干网络, 简化了特征提取的性能, 使用全维动态高效聚合网络(ODEANet)重构主干网络, 又采用 K-means++聚类算法优化先验框, 提高了算法性能。

1.3. 研究内容与方法

本研究主要包括以下几个方面: 首先, 对高速公路路段的视频数据进行处理, 使用 Yolo v8 对车辆进行识别和跟踪, 提取交通流参数(车流密度、车速和交通流量), 并分析其随时间的变化规律。其次, 利用自回归积分滑动平均模型(ARIMA)和长短期记忆网络(LSTM)建立交通流拥堵预测模型, 预测特定路段可能出现的持续拥堵情况。然后, 构建合理的高速公路应急车道启用模型, 确定启用的理论依据和决策规则, 并通过真实数据验证模型的实用性和可靠性。

在研究方法上, 本研究综合运用数据处理、模型构建和实证分析等方法。通过对大量视频数据的处理和分析, 获取交通流参数; 运用数学模型和深度学习算法进行拥堵预测和模型构建; 利用实际数据对模型进行验证和评估, 确保研究结果的准确性和可靠性。

2. 相关理论基础

2.1. 交通流理论

交通流理论是研究交通流变化规律的基础理论, 它主要研究交通流量、车速和车流密度之间的关系。

常用的交通流模型包括 LWR 模型、气体动力学模型、元胞自动机模型、格子流体力学模型等。这些模型从不同角度描述了交通流的特性，为交通拥堵的研究提供了理论支持。例如，LWR 模型基于宏观连续介质假设，通过建立偏微分方程来描述交通流的变化；元胞自动机模型则从微观角度出发，将道路划分为离散的元胞，模拟车辆在元胞上的运动。

2.2. 时间序列分析

时间序列分析是一种用于分析随时间变化的数据序列的方法。自回归积分滑动平均模型(ARIMA)是时间序列分析中的重要模型之一，它能够对非平稳时间序列进行建模和预测。ARIMA 模型通过对原始数据进行差分处理，使其变为平稳序列，然后建立自回归和滑动平均模型，从而捕捉数据的趋势和季节性特征。在交通流预测中，ARIMA 模型可以根据历史交通流数据预测未来的交通状况。

2.3. 深度学习算法

深度学习算法在近年来得到了广泛的应用，长短期记忆网络(LSTM)是其中一种专门用于处理时间序列数据的递归神经网络。LSTM 具有记忆单元和门控机制，能够有效解决传统递归神经网络中的梯度消失和梯度爆炸问题，更好地捕捉时间序列中的长期依赖关系。在交通拥堵预测中，LSTM 可以学习到交通流参数之间复杂的非线性关系，提高预测的准确性。

3. 模型假设与符号说明

3.1. 模型假设

本研究提出以下假设：

假设题目所给的视频都是在相同环境下拍摄的，包括天气、道路条件等因素保持相对稳定，以确保数据的一致性和可比性。

假设车辆在类型和性能方面具有一致性，不存在因车辆外形的不同而对交通流状况以及应急车道的使用情况带来明显的差异。这样可以简化模型的复杂性，集中研究交通流的整体规律。

假设在一定时间段内，高速公路的交通需求是相对稳定的，不会出现突然的大幅增长或减少。尽管实际交通需求会有波动，但在较短的研究时间段内，这种假设具有一定的合理性，有助于模型的建立和分析。

假设在应急车道启用前，应急车道是畅通无阻的，没有被违法占用或存在障碍物。这是保证应急车道能够正常发挥作用的前提条件，也是模型能够有效应用的基础。

3.2. 符号说明

本研究使用的主要符号如下：

符号	说明
p	自回归阶数，表示模型中考虑的去观测值的数量，它反映了模型对历史数据的依赖程度。在 ARIMA 模型中， p 的选择会影响模型对数据趋势的捕捉能力。
d	差分阶数，用于使非平稳时间序列变为平稳。通过对原始数据进行差分操作，可以消除数据中的趋势和季节性成分，使数据更适合建立模型。
v	车辆平均速度，是衡量交通流运行状态的重要参数之一，它与车流密度和交通流量密切相关。
ρ	交通密度，指单位长度的车辆数，反映了道路上车辆的密集程度，是判断交通拥堵的关键指标之一。
q	交通流量，单位时间内通过特定地点的车辆数量，是交通流研究中的核心参数之一。

4. 高速公路交通流拥堵预测模型的建立与求解

4.1. 数据提取与处理

本研究收集了高速公路路段的九个视频数据，从中提取出上万条车辆数据，使用 cv2.VideoCapture 进行提取视频帧，将视频逐帧读取为图像格式，通过循环读取视频的每一帧，将其转化为可处理的图像数据结构，如图 1 所示，以便进一步分析和处理。为了便于后续分析，根据时间对车流量进行时间段划分，以统计不同时间段内的交通流参数。在数据处理过程中，首先对视频数据进行预处理，包括灰度转换、高斯模糊、边缘检测等操作，以提取车道线信息，确定每个像素代表的实际距离。然后，通过 yolov8 实现车辆检测和跟踪算法，如图 2 所示获取不同帧中车辆的边界框中心位置，计算车辆移动的实际距离，进而得出车流速度、流量等参数值。



Figure 1. Random frame image

图 1. 随机帧图像



Figure 2. Schematic diagram of vehicle recognition and tracking

图 2. 车辆识别、跟踪示意图

4.2. 交通流参数的计算

流量：流量是单位时间内通过特定地点的车辆数量，计算公式为 $q(t) = \frac{N(t, \Delta t)}{\Delta t}$ 。

其中 $N(t, \Delta t)$ 表示在 $(t, \Delta t)$ 时间内通过的车辆数。通过统计单位时间内通过的车辆数，即可得到不同时刻的交通流量。

密度：密度是单位长度的车辆数，通过统计单位时间内观测到的车辆数量除以观测路段的长度来计算，公式为 $\rho(t) = \frac{N(t)}{L}$ ，其中 $N(t)$ 表示某时刻的车辆数， L 表示观测路段的长度。

速度：使用 yolo v8 对数据集中的车辆进行识别和帧跟踪，在视频数据中，由于缺乏实际的尺度和距离信息，直接从像素坐标估计车辆的实际速度具有挑战性。因此采用透视变换，将视频中的图像转换为鸟瞰视角(俯视图)，减少透视畸变，获得更准确的距离估计。

(1) 透视变化矩阵 M 的计算

dst points = predefined real-world coordinates

src points = selected points in the image

$M = \text{cv2.getPerspectiveTransform}(\text{src_points}, \text{dst_points})$

(2) 尺度估计

在鸟瞰图中，已知两点间的实际距离 D_{real} 和像素距离 D_{pixel} ，计算尺度因子 $s = \frac{D_{\text{real}}}{D_{\text{pixel}}}$ 。

(3) 对于同一车辆在不同时刻的位置 (x_1, y_1) 和 (x_2, y_2) ，时间间隔 Δt

$$v = \frac{\sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}}{\Delta t} \times s \times 3.6$$

其中，3.6 是单位转换系数。

最后将交通流参数存储到 excel 中，以便未来的建模。

4.3. 自回归积分滑动平均模型(ARIMA)的建立与分析

ARIMA 模型公式

$$y(t) = c + \sum_{i=1}^p \phi_i y_{t-i} + \int_t + \sum_{j=1}^q \theta_j \int_{t-j}$$

平稳性检验：在建立 ARIMA 模型之前，需要对原始时间序列进行平稳性检验。本研究采用 ADF 检验方法，输出 ADF 统计量、p 值和临界值等信息。如果原始数据非平稳，对其进行一阶差分操作，然后再次进行 ADF 检验，确保差分后的数据平稳。平稳性检验是建立 ARIMA 模型的重要前提，只有平稳的数据才能使用该模型进行有效建模。

模型构建与训练：将差分后的时间序列数据按照一定比例(本研究中取 80%)拆分为训练集 train 和测试集 test。构建 ARIMA 模型时，根据数据的特点和试验分析确定模型的阶数 p 、 d 、 q 。由于已经进行了差分操作使数据平稳，所以 $d = 0$ 。 p 和 q 的值通过尝试不同的组合，根据模型的拟合效果和预测准确性来确定最优值。利用训练集数据训练 ARIMA 模型，使模型学习到数据的特征和规律。

模型预测与评估：利用训练好的 ARIMA 模型对测试集数据进行预测，并分析预测结果。通过比较预测值与实际值，可以评估模型的预测准确性和实用性。常用的评估指标包括均方误差(MSE)、均方根误差(RMSE)等。根据评估结果，不断调整模型的参数，优化模型的性能，为高速公路管理部门提供更可靠的决策支持。将交通流参数导入 ARIMA 模型后，历史真实值在前期(大致 0~400 左右时间区间)有明显波动，呈现出不规则的上下起伏；后续(400 之后)趋于平稳，保持相对稳定的数值，而未来预测值前期(0~400 左右)数值相对平稳，400 左右开始，随时间推进逐渐下降，呈现出缓慢递减的趋势，且交通流参数下降幅度、起始平稳值有差异，反映模型对未来不同指标变化的预测。

4.4. 长短期记忆网络(LSTM)模型的建立与分析

数据预处理：将提取的交通流参数数据进行归一化处理，使数据处于相同的尺度范围内，便于模型

的训练和学习。同时，将数据按照时间序列划分为训练集和测试集，用于模型的训练和评估。

模型构建：搭建 LSTM 模型，确定模型的层数、隐藏单元数量等参数。LSTM 模型通常由输入层、多个 LSTM 层和输出层组成。在本研究中，通过试验和分析确定合适的模型结构，以提高模型的预测性能。

模型训练与优化：使用训练集数据对 LSTM 模型进行训练，通过反向传播算法调整模型的权重和参数，使模型的损失函数最小化。在训练过程中，采用合适的优化算法，如 Adam 优化算法，以提高训练效率和模型的收敛速度。

模型预测与评估：利用训练好的 LSTM 模型对测试集数据进行预测，并与实际值进行比较。通过计算评估指标，如 MSE、RMSE 等，评估模型的预测准确性。与 ARIMA 模型的预测结果进行对比，分析 LSTM 模型在交通拥堵预测中的优势和不足。经过训练的轮数增多，可以看到训练损失与验证损失重合，模型的拟合和泛化能力提升，且损失值逐渐降低及精确度提升。

4.5. 模型结果与分析

通过计算得到车辆流量、车辆密度、车辆速度等交通流参数，并绘制其随时间的变化曲线。从曲线中可以看出，交通流参数在不同时间段内呈现出不同的变化趋势。在高峰时段，交通流量和密度明显增加，车速降低，表明交通拥堵情况较为严重；而在低峰时段，交通流量和密度相对较低，车速较高，交通状况较为顺畅。

通过 ARIMA 模型和 LSTM 模型对交通拥堵情况进行预测，结果显示两种模型都能够在一定程度上捕捉到交通流的变化趋势，但 LSTM 模型由于其能够学习到数据中的非线性关系，在预测准确性上表现更优。通过对比实际数据与预测数据，验证了模型的有效性，但也发现模型在一些特殊情况下(如突发事件导致的交通拥堵)的预测能力还有待进一步提高。

5. 高速公路应急车道启用模型的构建

5.1. 应急车道启用的理论依据

应急车道启用的核心目标是在不影响紧急救援等特殊需求的前提下，最大程度地缓解交通拥堵。根据交通流理论，当交通密度达到一定阈值，且持续一段时间后，表明交通拥堵已经较为严重，此时启用应急车道可能是缓解拥堵的有效措施。同时，考虑到应急车道的特殊用途，需要确保在启用期间不会对紧急救援车辆的通行造成阻碍。因此，应急车道启用的理论依据是综合考虑交通拥堵程度、持续时间以及对紧急救援的影响等因素，建立科学合理的决策指标体系。

5.2. 应急车道启用模型的构建

本研究采用设计阈值的方法来构建应急车道启用模型。通过对大量交通数据的分析和研究，确定交通流量、密度和速度等参数的阈值。当实时监测到的交通参数超过相应阈值时，判定为拥堵情况发生，触发应急车道启用决策。同时，为了避免频繁启用和关闭应急车道，设置了一定的缓冲时间和条件，确保决策的稳定性和可靠性。

我们通过建立交通流拥堵模型，计算了四个观测点的基本参数，从图 3 可以清晰地看出在第三观测点车辆平均速度明显低于各观测点。

从第三个观测点可以看出，当车辆行驶到第三个观测点末尾时，流量和密度都处于升高趋势，而速度呈降低趋势，具体参数如图 4 所示。




Figure 3. Traffic flow parameters at each measuring point
图 3. 各测点交通流参数




Figure 4. Traffic flow parameters at the third observation point
图 4. 第三观测点交通流参数

5.3. 模型的验证与评估

利用真实的交通数据对构建的应急车道启用模型进行验证和评估。通过模拟不同的交通场景，观察模型的决策结果是否符合实际情况。计算模型的准确率、召回率等评估指标，评估模型在不同情况下的性能表现。结果表明，该模型能够在一定程度上准确判断是否需要启用应急车道，并且在缓解交通拥堵方面具有一定的效果。然而，模型在面对复杂交通情况时，如多个拥堵点同时出现或交通流突变等情况，

还需要进一步优化和改进。

从图中可以看出, 预测误差的分布大致呈正态分布, 误差集中在 0 附近, 说明预测值与实际值较为接近。误差在-1.0 到 1.5 之间, 频率最高的是在 0 附近, 随着误差的增加或减少, 频率逐渐降低。这表明预测模型在大多数情况下表现良好, 大概率不会出现误差, 如图 5 所示。




Figure 5. Distribution map of prediction errors
图 5. 预测误差分布图

我们采用 LSTM 进行预测, 预测结果与实际结果大致相同, 说明模型的可用性, 如图 6 所示。




Figure 6. Comparison chart of predicted and actual densities
图 6. 预测与实际密度的对比图

6. 结语

本研究围绕高速公路应急车道的科学启用问题, 构建了融合 ARIMA 与 LSTM 模型的交通拥堵预测

框架，并设计了基于阈值决策的应急车道启用模型。通过对高速公路交通流数据的深度分析，验证了 ARIMA 模型对时间序列线性特征的捕捉能力，以及 LSTM 模型在处理非线性动态关系时的优势，为拥堵预测提供了多维度的技术支撑。同时，结合透视变换与车辆跟踪技术，实现了交通流参数的精准计算，为应急车道启用的阈值设定奠定了数据基础。

研究成果的实践价值体现在：一方面，通过量化交通密度、流量与速度的阈值关系，为管理部门提供了可操作的应急车道启用决策规则，有效平衡了拥堵缓解与紧急救援通道保留的需求；另一方面，优化的视频监控点布置方案与模型验证结果，为高速公路智能化管理提供了兼具可行性与可靠性的技术路径。例如，第三观测点的实验数据表明，模型能够准确识别拥堵趋势，启用应急车道后可显著改善车流速度与密度分布。然而，本研究仍存在一定局限性：一是模型假设基于特定环境稳定性，对极端天气、突发事件等动态场景的适应性有待提升；二是数据采集依赖固定路段的视频监控，缺乏多源数据(如 GPS 轨迹、雷达监测)的融合，可能影响复杂路网下的预测精度。此外，应急车道启用后的交通流重构机制尚未深入探讨，难以完全模拟实际交通参与者的行为变化。

未来研究可从以下方向拓展：其一，引入多传感器数据融合技术，结合实时交通事件检测，增强模型对突发状况的响应能力；其二，探索强化学习框架，动态优化应急车道启用策略，提升模型在非平稳交通流中的决策灵活性；其三，结合车路协同技术，构建车-路-人多主体交互模型，进一步挖掘应急车道资源的智能化管理潜力。通过持续优化模型的鲁棒性与适应性，有望为智慧高速建设中的交通应急管理提供更全面的技术支撑。

参考文献

- [1] Dimitrakopoulos, G. and Demestichas, P. (2010) Intelligent Transportation Systems. *IEEE Vehicular Technology Magazine*, **5**, 77-84. <https://doi.org/10.1109/mvt.2009.935537>
- [2] 侯越, 张鑫, 武月. 基于时空动态约束图反馈的交通流预测[J/OL]. 吉林大学学报(工学版), 1-16. <https://doi.org/10.13229/j.cnki.jdxbgxb.20240640>, 2024-10-25.
- [3] Zhu, C., Yu, C. and Huo, J. (2023) Research on Spatio-Temporal Network Prediction Model of Parallel-Series Traffic Flow Based on Transformer and GCAT. *Physica A: Statistical Mechanics and Its Applications*, **610**, Article 128414. <https://doi.org/10.1016/j.physa.2022.128414>
- [4] Zhao, L., Song, Y., Zhang, C., Liu, Y., Wang, P., Lin, T., et al. (2020) T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction. *IEEE Transactions on Intelligent Transportation Systems*, **21**, 3848-3858. <https://doi.org/10.1109/tits.2019.2935152>
- [5] Bai, L., Yao, L., Li, C., et al. (2020) Adaptive Graph Convolutional Recurrent Network for Traffic Forecasting. *Advances in Neural Information Processing Systems*, **33**, 17804-17815.
- [6] Ju, X., Xie, X. and Yu, Y. (2023) Spatial-Temporal Dynamic Fusion Graph Convolutional Network for Traffic Forecasting. *2023 5th International Academic Exchange Conference on Science and Technology Innovation (IAECST)*, Guangzhou, 8-10 December 2023, 709-713. <https://doi.org/10.1109/iaecst60924.2023.10503226>
- [7] Cao, C., Bao, Y., Shi, Q. and Shen, Q. (2024) Dynamic Spatiotemporal Correlation Graph Convolutional Network for Traffic Speed Prediction. *Symmetry*, **16**, Article 308. <https://doi.org/10.3390/sym16030308>
- [8] 岳永恒, 宁睿厚. 基于轻量化 CenterNet 的智能车辆目标检测算法[J]. 华南理工大学学报(自然科学版), 2024, 52(8): 45-55.
- [9] Howard, A., Sandler, M., Chen, B., Wang, W., Chen, L., Tan, M., et al. (2019) Searching for MobileNetV3. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, Seoul, 27 October-2 November 2019, 1314-1324. <https://doi.org/10.1109/iccv.2019.00140>
- [10] Yang, L.X., Zhang, R.Y., Li, L.D., et al. (2021) Simam: A Simple, Parameter-Free Attention Module for Convolutional Neural Networks. *Proceedings of International Conference on Machine Learning*, Williamstown, 18-24 July 2021, 11863-11874.
- [11] Ramachandran, P., Zoph, B. and Le, Q.V. (2017) Searching for Activation Functions.
- [12] Adarsh, P., Rath, P. and Kumar, M. (2020). YOLO V3-Tiny: Object Detection and Recognition Using One Stage Improved Model. *2020 6th International Conference on Advanced Computing and Communication Systems (ICACCS)*,

- Coimbatore, 6-7 March 2020, 687-694. <https://doi.org/10.1109/icaccs48705.2020.9074315>
- [13] 付世达. 基于 SSD 模型的违规使用专用车道检测方法[D]: [硕士学位论文]. 长春: 吉林大学, 2020.
- [14] 郭玉彬. 基于视频图像的车辆检测跟踪及行为识别研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2021.
- [15] Bewley, A., Ge, Z., Ott, L., Ramos, F. and Upcroft, B. (2016) Simple Online and Realtime Tracking. 2016 *IEEE International Conference on Image Processing (ICIP)*, Phoenix, 25-28 September 2016, 3464-3468. <https://doi.org/10.1109/icip.2016.7533003>
- [16] Wojke, N., Bewley, A. and Paulus, D. (2017) Simple Online and Realtime Tracking with a Deep Association Metric. 2017 *IEEE International Conference on Image Processing (ICIP)*, Beijing, 17-20 September 2017, 3645-3649. <https://doi.org/10.1109/icip.2017.8296962>
- [17] 李震霄. 交通监控场景中的车辆检测与跟踪算法研究[D]: [硕士学位论文]. 北京: 中国矿业大学, 2021.
- [18] 王海, 蔡英凤, 陈龙, 等. 基于 Haar-NMF 特征和改进 SOMCNN 的车辆检测算法[J]. 东南大学学报(自然科学版), 2016, 46(3): 499-504.
- [19] Liu, W., Anguelov, D., Erhan, D., *et al.* (2016) SSD: Single Shot Multibox Detector. *European Conference on Computer Vision*, Amsterdam, 11-14 October 2016, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2
- [20] 崔弥达, 王超, 陈金桥, 等. 基于 ROS 及 YOLOv3 的混凝土桥梁裂缝实时检测系统[J]. 东南大学学报(自然科学版), 2023, 53(1): 61-66.
- [21] 李珣, 伍荣兴, 周慧龙, 刘欣, 高涵, 王文杰. 基于 YOLOv7-R 的多车辆目标识别[J]. 东南大学学报(自然科学版), 2024, 54(5): 1260-1270.