

第 1 章 引言

本书旨在帮助当前和未来交通行业专业人员利用机器学习（machine learning, ML）的方法和工具来解决交通领域的挑战，提升读者对机器学习的理解和运用能力。尽管本书是作为本科生或研究生的入门教科书进行设计的，但它也可以作为交通工程专业人士进行机器学习研究和应用的参考书。

阅读本书无须拥有编程经验，也无须掌握机器学习及其在交通领域相关应用的概念，读者可以通过阅读本书以及完成每章的练习逐步建立起所需的编程技能。考虑到本书涵盖的主题广度以及编程脚本和支持软件包需要频繁更新，作者选择在线提供所有练习的计算机代码，而不是在书中提供。

本章剩余部分介绍了交通和机器学习的一般背景，并介绍了作者认为本书对交通教育的必要性，最后是本书的组织架构。

1.1 背景

1.1.1 交通运输的重要性

交通运输作为移动货物和人员的手段，在日常生活及现代经济体系中扮演着不可或缺的角色。各项经济活动及其支撑的生活方式均与交通运输直接或间接相关，从而彰显其在经济发展中的重要性。2020 年我国人均消费支出中交通通信占比为 13.0%。2022 年的信息提到交通运输、仓储和邮政业在第三产业中的占比达到 10.4%，而第三产业占 GDP 的比例为 53.3%，据此可以粗略计算交通运输业在 GDP 中的占比为 5.54%。

交通运输在气候变化问题中占有重要地位。我国交通运输部门的能源消耗在 2020 年占全国总能耗的比例为 8.3%。交通运输领域的碳排放量大约占中国碳排放总量的 10%，国际能源署（IEA）统计数据显示，1990—2021 年，我国交通领域碳排放量从 9400 万吨增至 9.6 亿吨左右，增长了约 9 倍。

交通运输对公共健康的影响同样不容忽视。运输工具所排放的空气污染物质引发了雾霾和空气质量下降，这直接损害了公共健康。众多健康问题，包括呼吸系统感染、心脑血管疾病、肺癌等，均与交通源污染紧密相关。另外，全球每年约有 135 万人死于交通事故。依据世界卫生组织在 2018 年发布的《全球道路安全报告》，道路交通伤害已成为 5~29 岁年龄段人群的主要死因。虽然车辆及道路已采纳多项新型安全技术，根据国家统计局数据，

2022 年中国交通事故总死亡人数为 60676 人。值得注意的是，这项数字是 2016—2022 年间最低的一年。

1.1.2 研究动机

交通运输的重要性不可小觑。对交通系统的优化能够为经济社会带来显著利益。研究显示，交通基础设施的投资可取得 5%~20% 的年收益率 (Rodrigue, 2020)。尽管如此，交通系统是一个高度复杂的体系，涉及人、技术和基础设施的多方面互动。我们的交通体系关系到人类的连接方式、构建模式、消费行为及工作过程，其影响因素众多，包括政策、人文、地理和技术等多个维度。为了深入剖析交通领域的问题，并制定出切实可行的解决策略，高质量的数据支撑是不可或缺的。

在过去的几十年里，交通运输机构在系统传感和数据收集方面进行了大量投资。例如，数据交换和人工智能/机器学习都被列为智能交通系统 (ITS) 的基本要素，ITS 是一种提高整个交通系统能力的技术和操作进步系统。全球对 ITS 技术的投资预计将以 8.8% 的复合年增长率增长，到 2026 年将达到 495 亿美元。这些新的 ITS 系统数据、第三方数据（如来自导航软件的数据）以及经典的交通传感器和调查数据构成了大数据流，可以对各种重要交通问题进行系统的深入分析。

然而，传统的交通研究和实践主要基于定期调查收集的非常有限的数据或有限的传感器位置。大多数方法，包括那些常用方法，都是基于没有充分验证的数学假设 (Ma et al., 2011)，并不适用于这样的新数据集。当前高校的交通课程以设计、施工、运营为主，而数据库、数据分析、信息技术等方面的内容较少。因此，运输机构和公司正面临着越来越多的劳动力挑战，特别是在应用传感器、物联网 (IoT)、智能网联车、无人机、大数据分析和人工智能 (AI) 等新技术方面。

为了应对劳动力市场的挑战，作者团队着手编写了本书，并将重点放在机器学习 (ML) 上，因为它有潜力“在各个层面上革新 ITS” (Chan-Edmiston et al., 2020)。机器学习技术已在交通数据采集、自动驾驶技术、交通资产管理、需求预测、安全性增强以及移动性即服务 (MaaS) 等领域得到了广泛运用，它无疑是未来交通专业人才必备的关键技能。本书旨在为有志于深入研究该学科的交通专业学生与从业人员提供机器学习方法的系统入门知识。我们期望本书能为应对当下及未来的交通行业劳动力挑战打下扎实的基础。

1.2 机器学习在交通研究和应用中前景广阔

1.2.1 机器学习发展简述

在展开对机器学习的讨论前，需先对人工智能进行概述。人工智能作为一个研究领域，其起源可追溯至 1956 年夏季于美国达特茅斯学院召开的研讨会 (Kaplan and Haenlein, 2019)。AI 一词最初由斯坦福大学计算机科学教授 John McCarthy 在该会议上提出。尽管对于人工智能的定义尚未统一，但其核心理念一致，即通过计算机及机器设备模拟人类心智的问题解决与决策过程，IBM 官方网站有更详细的阐述。关于机器能否智能化的探讨，最早可追溯至 1945 年 Vannevar Bush 提出的旨在扩展人类知识与认知的系统 (Bush et al., 1945)。而机器智能的概念则在 1950 年由 Alan Turing 更为明确地阐释，作为一位在

数学、密码解析、逻辑、哲学及数学、生物学等领域做出巨大贡献的英国数学家与逻辑学家，图灵亦对后来诞生的计算机科学、认知科学、人工智能与人工生命等新兴领域有所贡献。图灵在其著作（Turing and Haugeland, 1950）中提出了一种解答其论文开头所提问题“机器能思考吗？”的方法，该方法现称为图灵测试，用以评估机器是否具备与人类等同或难以分辨的智能行为表现。

在过去的数十年中，人工智能受到了广泛关注，并得到了深入的研究。随着智能电话的广泛使用以及物联网技术的部署，数据获取变得日益便利，这一趋势进一步推动了人工智能领域，尤其是机器学习的研究进展。尽管人工智能与机器学习常被混用，但它们指的是两个不同的概念，机器学习是人工智能的子集。机器学习作为人工智能的一种应用，侧重于通过数据及算法模拟人类学习过程，逐步提升其预测的准确性。机器学习算法基于称为训练数据的样本数据建立模型，以在无需显式编程的情况下进行预测或做出决策。

机器学习起源于 1943 年对神经网络的数学模型构建，Pitts 和 McCulloch 尝试将人脑认知过程中的思维活动和决策机制进行数学映射（McCulloch and Pitts, 1943）。随着数据集合的涌现以及计算技术的革新，机器学习技术迅猛进步，形成了与早期截然不同的技术面貌。其中，AlphaGo 的开发标志着一个划时代的成就，它是首个在 2016 年战胜围棋世界冠军李世石的计算机程序，并被广泛认为代表了围棋史上最高水平。AlphaGo 由 Google DeepMind 团队开发，旨在执行围棋这一棋盘游戏。该程序的算法融合了机器学习与树搜索技术，并经过了包括人类棋局和自我对弈在内的大量训练。初始版本 AlphaGo 接受了数千局人类业余及专业水平的棋局训练，从而掌握了围棋技巧。其后继版本 AlphaGo Zero，于约一年后推出，摒弃了基于人类棋局数据的训练环节，仅通过自我对弈从完全随机的走法中学习。结果，它迅速超出了人类棋手的水平，并以全胜的战绩击败了先前版本的 AlphaGo。此案例充分体现了机器学习的巨大潜能。

1.2.2 交通研究与应用中的机器学习

虽然机器学习技术在交通领域的应用历程尚短，但研究人员已在此方面取得了卓越的成就，充分展示了该技术的极高价值。无论是在交通数据的采集、交通系统的运行，还是需求预测与规划方面，机器学习方法相较于传统手段均展现出了其优越性。以下为若干实例。

- 交通数据的采集是 ITS 构建的基石，在交通系统的精准控制、准确预测交通需求、实时监控与管理基础设施等环节发挥着至关重要的作用。此外，该技术亦是自动驾驶汽车领域的核心技术之一。从功能性角度出发，交通数据采集亦称为交通感知，涵盖了基础设施传感、车载传感以及航空传感等多种方式。鉴于各类交通感知技术的独特性质，有效提取交通数据并整合不同感知技术的策略对于未来交通体系的构建尤为关键。目前，机器学习方法已广泛应用于车辆的检测与分类、道路表面状况的感知以及对行人及骑行者的统计等方面。
- 交通预测领域，与交通感知技术相结合，对交通状态进行预测是一项重要的应用研究。其中，交通状态变量主要包括车速、流量、行程时间以及起讫点（OD）等出行需求指标。在处理道路网络的交通状态预测问题时，通常将其视为时间序列预测问题，并可利用多种方法予以有效处理。然而，面对涵盖成百上千个路段的大型城市

区域，常规的时间序列预测手段可能难以适用。关键在于如何精准提炼路网中的空间-时间特征，以便实施准确的交通预测，并为后续的交通管理提供决策支持，这对于交通规划与运营管理至关重要。目前，机器学习技术已广泛应用于短期及长期交通预测领域。

- 人工智能交通管理正日益成为城市交通运行模式改革的关键，其通过优化解决城市交通中频繁出现的瓶颈与堵点问题，显著降低交通拥堵程度与出行时间，同时减少机动车排放。交通拥堵常因忽视诸如车辆间距离、交通信号灯及路标等关键要素而发生，这不仅导致燃油消耗增加、空气污染加剧，还造成时间与能源的不必要浪费、长期压力以及其他生理健康问题。此外，高发的交通违法行为是引发道路交通事故死亡的主要原因。智能交通管理系统依托人工智能、机器学习、计算机视觉、传感技术及数据分析等工具，实现对交通数据的高效采集与分析，并据此生成针对性的解决策略，进而应用于交通基础设施的改进。人工智能可通过实时视频监控、传感器数据甚至谷歌地图信息，构建包含预测算法在内的交通管理方案，提升交通流速度。西门子研发了一款基于机器学习的视频监控系统，能自动识别交通异常情况并及时通报给交通管理机构。该系统在评估道路交通密度方面表现出色，据此调整交通信号，确保交通流动更为顺畅。机器学习技术的进步预示着智能交通领域多个应用将得到显著提升，其中包括应急车辆优先通行、公交信号优先以及行人安全保护等方面。

1.3 本书架构

本书章节的安排遵循了所选机器学习方法的最优学习序列，各章先对机器学习算法进行阐述，随后引入这些算法可应用的交通运输领域案例分析。具体而言，本书结构包含以下几部分：

- 第2章详细阐述了各类交通数据及传感技术，包含基于基础设施、车辆装载以及航空遥感技术，并探讨了相应生成的数据集。同时，该章对现存的交通数据及传感技术的挑战进行了阐述。
- 第3章深入讲解了机器学习领域的重点概念，首先从机器学习的定义和类别入手，随后解析了先进机器学习算法的基础模块。该章还对常见的回归理论（如线性回归和逻辑回归）、梯度下降算法、正则化及其他机器学习核心理念进行了讨论。
- 第4章系统地介绍了神经网络技术，内容涵盖从线性回归到前馈神经网络（FNN）。本章详细讲述了基础FNN组成部分，包括层级、激活函数、反向传播算法以及训练策略，并展示了利用FNN的代表性交通应用案例研究。
- 第5章全面解析了广泛应用于学习矩阵型数据（如图像）的卷积神经网络（CNN）的根本原理。该章所涉及的案例研究包含了交通视频感知和时空交通模式学习。
- 第6章深入剖析了循环神经网络（RNN）及其著名变体，比如LSTM和GRU的基本原理。本章还介绍了采用RNN的交通相关案例研究，其中包括道路交通预测和交通时间序列数据插补。
- 第7章详尽地介绍了强化学习（RL），这是机器学习的一个分支，主要解决序列决

策问题。本章深入讲解了 RL 的基本概念,如马尔可夫决策过程(MDP),以及基于值和基于策略的 RL 算法。同时,本章也简要介绍了多智能体强化学习(MARL),目标是协同控制一群对象/智能体以达到更优秀的系统性能,并展示了在交通应用中运用不同 RL 算法的典型模拟及实际场景,如交通信号控制和车辆跟驰问题。

- 第 8 章探讨了迁移学习及其在提升 ITS 中的运用,如加强停车场监控和交通流量检测。
- 第 9 章系统地讲解了图神经网络(GNN)作为深度神经网络的重要组成部分,在提取和处理图数据的综合特性方面的优势,并增强了神经网络模型的可解释性。本章详述了 GNN 的基本概念和最新 GNN 变体,如图卷积神经网络(GCN)。此外,还介绍了运用 GNN 的多种交通应用,包括交通信号控制和道路交通预测。
- 第 10 章详细介绍了一种具有代表性的生成模型——生成对抗网络(GAN)。这是一种无监督学习任务,涉及自动挖掘和学习数据集中的模式或分布,以生成带有某些变化的新数据样本。本章深入解析了生成模型的理论背景和 GAN 及其变体的框架细节,并简要介绍了交通领域中与 GAN 有关的案例研究,如交通状态估计。
- 第 11 章强调了边缘计算在未来 ITS 应用中的重要性,以实现连接的交通参与者之间的互动。本章还介绍了 ITS 领域内代表性的边缘计算场景,并讲解了联邦学习(FL)的背景和基本理念,这是一种在众多边缘计算设备上执行分布式模型训练的方式。

第 12 章 ~ 第 15 章为应用篇,介绍了一些在交通研究与应用中实际应用机器学习的案例。

- 第 12 章介绍了深度学习模型在短时交通流预测领域的运用,并结合图卷积网络与长短时记忆网络,搭建了能够深层次提取交通流时空特征的混合模型 LSTGCN,实现了精准的短时交通流预测。
- 第 13 章介绍了基于视频特征的图像定位算法,通过结合基于深度学习的视频特征,沿用视频动作识别技术发展路线,介绍基于传统特征、卷积特征、注意力机制特征的分类定位模型方向,逐步探索图像定位问题的解决方案。
- 第 14 章以基于特征的图像匹配算法为出发点,探讨了基于稀疏图神经网络的特征匹配算法,并且针对匹配过程中的错误建图方法,介绍层次化聚类结构,并使用全局信息,减少错误分类的影响,在视觉定位、位姿估计等下游任务上表现良好。
- 第 15 章介绍了单摄像头和多摄像头车辆检测跟踪定位算法,基于摄像头对车辆进行定位可以使用目标检测算法,但是车辆实际运动中不可避免存在遮挡,单靠目标检测算法无法时刻获得目标的位置,需要使用目标跟踪算法加以辅助。

第 16 章指出人工智能将成为未来交通系统的基础之一。本章概述了将对城市交通系统产生深远影响并推动其发展的关键 AI 技术和方向。另外,也对本书的延伸和未来规划进行了探讨。

第 2 章 交通数据与传感

2.1 数据量激增

城市化的进程为诸多领域带来了前所未有的发展机遇与挑战，涉及环境、医疗、经济、居住以及交通等多个方面。这些挑战与机遇催生了网络—物理技术的飞速发展，并使得移动互联设备成为人们日常生活中不可或缺的一部分。据统计，目前约 90 % 的人口已接入互联网，能够迅速获取丰富的信息资源。城市地区高效的通信基础设施建设正吸引着人口以空前的速度和规模向城市聚集。为高效处理日益增加的城市数据，并基于此更合理地配置城市资源，“智慧城市”理念应运而生。该理念综合运用传感器技术、系统工程学、人工智能及信息通信技术，旨在提升城市服务与运营的效率。在智慧城市框架中，交通系统作为核心部分，承担着物资与人员的高效流动。智能交通系统（intelligent transportation systems, ITS）便是在此背景下提出的概念，它通过整合传感、分析、控制及通信技术，致力于提升地面交通的安全性、流畅性、效率及可持续性。

ITS 的应用是数据驱动型的，对于处理、分析及储存大数据的计算服务与复杂模型需求极高。在城市计算领域，交通数据作为核心数据源，其特征表现为数据量庞大、格式异构性显著以及数据质量波动较大。机器学习技术已被广泛融入 ITS 中，显著提升了 ITS 数据的潜能与价值。然而，相较于传统的统计模型，机器学习模型往往对数据需求量大、计算成本昂贵。尤其是深度神经网络（DNNs）的训练过程，可能耗费数日乃至数周方可完成。而在多数情形下，机器学习模型的推理效率亦逊色于传统方法。因此，深入理解交通数据的类型与属性，对于掌握 ITS 中机器学习的应用至关重要。

交通数据采集亦称为交通感知，是构成 ITS 实施的关键环节。该步骤为交通建模、系统分析、预测及控制提供了基础性数据支持。从功能角度出发，交通数据采集与感知可细分为基于基础设施的感知、车载感知以及空中感知三大类。在地面交通系统中，交通基础设施与道路使用者构成了两大核心要素，而采用无人机等航空器执行的空中感知则代表了一项前沿技术，可视作地面交通系统向空间维度的拓展。

2.2 ITS 数据需求

数据收集构成了 ITS 应用的基础环节。在先进交通管理系统（ATMS）中，交通运行数据，如地磁感应线圈与监控摄像头所采集的数据对于道路与交叉口的实时监控不可或缺。

先进旅行者信息系统 (ATIS) 需整合交通及环境数据, 向公众提供关于交通拥堵、事故、施工区域以及极端气候等的信息。先进车辆控制系统 (AVCS) 则需获取本车及其周边环境信息, 以实现碰撞预警、自适应巡航等高级车辆功能。在商用车辆运营管理 (CVO) 领域, 车载称重与传感器数据对卡车运营监控及安全具有核心意义。ITS 各子系统的高效运转, 皆依赖于源自多渠道的高质量数据支持。

ITS 的数据来源于各类传感器的采集 (Klein et al., 2006)。ITS 中各类传感器基于各自独特的工作机制, 具备不同的性能特点及适用范围。其中, 感应式环形探测器依据车辆覆盖下导致的环路电感量下降原理进行车辆监测。该技术方案成熟可靠, 能够有效获取基础交通数据, 且对恶劣气候条件表现出较强的适应性。然而, 环形探测器的安装与维护不可避免地涉及路面开挖和车道封闭的问题。磁性传感器则通过侦测车辆覆盖区域地球磁场的变化来实现车辆监测, 适用于环形探测器难以部署的场景, 如桥梁甲板。尽管相较于环形探测器, 磁性传感器更能抵御交通负荷带来的压力, 但若未采纳特定布局与信号处理算法, 其无法实现对停靠车辆的有效监测。

气动管道传感器以其便携性突出, 能够简便地布设于道路之上, 并利用气压变化信号完成车辆计数。这类传感器能耗低、维护成本相对低廉, 但其测量准确性易受温度波动影响, 并在货车与公交车流量较高时, 轴数统计可能出现偏差。微波雷达传感器能以高精度提供速度及多车道车流计数数据, 但缺乏车辆分类信息。红外传感器不仅能探测车辆, 还能感知易受伤害的道路使用者, 但在极端天气 (如大雨、雪或浓雾) 下, 车辆检测灵敏度有所下降。交通摄像头作为一类信息量丰富的传感设备, 已被广泛应用, 尽管如此, 其数据处理过程往往需借助高级计算机视觉算法及强大计算能力。此外, 声学、超声波、激光雷达等传感器亦为 ITS 领域常用传感器, 有力支持了 ITS 的数据获取需求。

根据 (Ke, 2020), 在现代 ITS 的研究中, 从功能性与方法论两个维度出发, 其运营机制可大致划分为三个主要领域: 地面交通基础设施系统、地面交通车辆系统以及作为拓展领域的空中交通系统。上述三个子系统各有特定目标, 且在数据驱动型应用的开发过程中呈现出独特的属性。本章后续三节内容将以该分类为基础, 详细介绍各系统的数据集及相应的 ITS 数据驱动应用实例。

2.3 基础设施导向型数据与传感技术

ITS 的核心目标在于充分利用已有的民用基础设施, 以提升交通运行效率。所谓的交通基础设施主要包括道路、桥梁、隧道、交通枢纽、铁路、交通信号控制设备、交通标识以及其他各类路侧设施等。这些设施中的关键节点, 如交叉口、路段、高速公路出入口以及停车场, 都会通过部署的传感设备进行实时监测。

2.3.1 交通流量监测

在基于基础设施的 ITS 中, 一项核心任务是实现特定区域的交通流检测与分类。该过程能提供车辆数量、流率、速度、密度、运动轨迹、车型分类等关键数据, 为交通管理与研究提供重要信息。Chen 等 (Chen et al., 2020b) 提出了一种交通流检测方法, 该方法利用经过优化的 YOLO (You Only Look Once) 算法进行车辆检测, 并采用 DeepSORT (deep

simple online and realtime tracking) 算法进行车辆跟踪。此外, 该方法已在 Nvidia 边缘计算设备 Jetson TX2 上成功实现。Haferkamp 等 (Haferkamp et al., 2017) 提出一种利用机器学习 (包括 k 近邻 (k -NN) 和支持向量机 (SVM)) 处理无线电衰减信号的方法, 该方法在交通流量的检测与分类方面取得了显著成效。进一步地, 通过采用高级信号处理技术, 传统交通传感器 (例如环形线圈检测器和雷达) 的检测范围和性能也得以提升。Ho 和 Chung (Ho and Chung, 2016) 采用快速傅里叶变换 (FFT) 算法对路侧雷达信号进行处理, 以实现交通流量的准确检测。Ke 等 (Ke et al., 2018b) 提出了一种利用环形检测器数据, 通过小波变换进行交通流量瓶颈检测的方法。此外, 该领域内其他领先的研究还包括基于声学传感的分布式感知、交通流量异常检测、深度学习技术的应用以及在交通拥堵状态下的鲁棒性交通流量监测等 (Liu et al., 2020c, 2018; Djenouri et al., 2018; Liang et al., 2020)。

2.3.2 旅行时间估算

在 ITS 感知领域, 除了交通流量探测, 旅行时间估算同样是核心任务之一。精准的旅行时间估算依赖于多地点感知技术以及能够对道路使用者进行连续识别的能力。蓝牙探测技术因其能提供设备的 MAC 地址而成为估算旅行时间的首选手段, 这一特性使其能自然而然地对携带设备的个体进行连续识别。无论是针对车辆 (Martchouk et al., 2011) 还是行人 (Malinovskiy et al., 2012) 的旅行时间信息, 均可借助蓝牙探测技术予以捕获。然而, 蓝牙探测所引起的隐私问题不容忽视。随着计算机视觉与深度学习技术的飞速发展, 通过监控摄像头实现对道路使用者的连续识别, 进而推动旅行时间的精确估算已成为可能。具体而言, 车辆与行人的深度图像特征得以提取, 并在广域监控系统的多摄像头间进行对比分析 (Liu et al., 2016; He et al., 2020; Lee et al., 2020; Han et al., 2020a, 2020b)。值得关注的是, Han 等 (Han et al., 2020b) 介绍了名为 KISS+ (保持简单直接加强版) 的方法, 该方法在原始 KISS 技术的基础上融合了多重特征并降低了特征维度。在实际应用中, 并非所有道路使用者的旅行时间估算都是必需的。对于这些场景, 采用更为传统的检测设备及方法往往能够取得满意结果。Oh 等在 2002 年提出一种基于环路检测器的路段行驶时间估算方法 (Oh et al., 2002), 该方法主要通过监测两个环路站点间的车流量来计算道路区段密度。尽管未能实现车辆的再识别, 但这些方法仍展现出较为理想的性能, 并为交通管理以及用户提供了有价值的行驶时间信息, 如参考文献 (Oh et al., 2002; Stehly et al., 2007; Cortes et al., 2002) 所述。

2.3.3 交通异常识别

在基于基础设施的感知领域, 另一个研究重点是交通异常识别。如其名所示, 交通异常指的是 ITS 中出现的非常规事件。这类事件的发生频率较低, 典型实例包括车辆故障、相撞、险撞、逆行等情况。面向交通异常侦测的挑战主要有两方面: ①可供算法开发的异常数据匮乏; ②异常类型繁多且缺乏统一明确的定义。由于需要详尽的信息, 异常侦测通常依赖监控摄像设备, 然而在某些较为简异的异常侦测任务中, 时间序列数据也显示出了其适用性 (Mercader and Haddad, 2020)。交通异常识别技术可归纳为三种主要类型: 监督学习、无监督学习以及半监督学习。在类别数目已明确并且训练数据集充足、足以确保

模型具备统计学意义的情况下, 监督学习方法尤为有效。然而, 该类方法需依赖人工标注, 不仅消耗数据资源, 还需投入大量人力, 且其无法识别出事先未被定义的异常类型 (Singh and Mohan, 2018; Lee et al., 2018; Loewenherz et al., 2017)。无监督学习无须对数据进行标记, 且在提供足够正常数据的情况下, 能够有效推广至未预见的异常情况, 具备较强的泛化能力。但是, 当数据特性随着时间的演进发生变化 (如监控摄像机频繁调整拍摄角度与方向) 时, 异常侦测的难度将显著增加 (Roshtkhari and Levine, 2013)。Li 等 (Li et al., 2020c) 提出了一种多粒度跟踪机制的无监督学习方法, 在 2020 年 AI 城市挑战赛中荣获首奖。此外, 该方法仅依赖弱标签进行半监督学习。Chakraborty 等 (Chakraborty et al., 2018) 提出了一种针对高速公路交通轨迹分类的半监督模型, 该模型融合了 YOLO 目标检测算法、SORT 跟踪算法以及基于最大似然的对比悲观似然估计 (CPLE)。通过这种模型, 能够有效地识别出轨迹中的异常情况, 并将分类精度提升了 14%。Sultani 等 (Sultani et al., 2018) 将视频视作多实例学习框架下的包, 而视频片段则作为实例, 基于弱标记数据自动构建了一个异常排序模型。近期, 交通异常识别技术的进展不仅归功于新型学习方法的提出, 还包括物体跟踪技术的应用。值得注意的是, 在 2021 年 AI 城市挑战赛中, 所有排名靠前的方法均在物体跟踪方面做出了显著贡献 (Zhao et al., 2021; Wu et al., 2021; Chen et al., 2021)。

2.3.4 车辆停放监测

在城市环境中, 除了对道路进行监测, 停车场所的监控亦是一个关键领域, 对于基础设施感知系统具有显著的重要性。基于基础设施的停车位侦测技术可按照传感器的功能特性, 划分为两个主要类别: 一是无线传感器网络 (wireless sensor network, WSN) 方案; 二是依赖摄像头的方案。在 WSN 方案中, 每个停车位均配备了独立的传感器, 这些传感器须具备低能耗、高耐久性及经济实惠的特点 (Lin et al., 2017; Lou et al., 2019; Park et al., 2008; Lee et al., 2008; Zhang et al., 2013, 2014; Jeon et al., 2018; Grodi et al., 2016; Sifuentes et al., 2011; Zhu and Yu, 2015)。无线传感器网络方案具备一定的优势与劣势: 在算法层面, 其设计往往简洁明了; 通常情况下, 阈值判定法便足以应对多数场景, 尽管如此, 较为简易的侦测手段可能会引起较高的虚警率。WSN 的一个显著特点是, 得益于大量传感器的部署, 其在传感器失效方面展现出了极强的韧性。这表明, 哪怕部分传感器失效, WSN 依旧能够实现对绝大部分监测区域的覆盖。然而, 大量传感器的使用无疑增加了在大规模部署时的人力及维护成本。目前, 应用最为广泛的传感器类型包括磁感应节点、红外传感器、超声波传感器、光学传感器以及电感线圈。举例来说, Sifuentes 等 (Sifuentes et al., 2011) 提出了一种经济有效的基于磁性节点的停车位检测算法, 并融合了光学传感器的唤醒机制。随着视频感知、机器学习及数据通信技术的不断发展, 基于摄像头的检测方案已逐渐得到广泛应用 (Lin et al., 2017; Bulan et al., 2013; Cho et al., 2018; Amato et al., 2017; Nurullayev and Lee, 2019; Alam et al., 2018; Wu et al., 2007; Rianto et al., 2018; Baroffio et al., 2015; Amato et al., 2016; Vitek and Melničuk, 2017; Ling et al., 2017; Nieto et al., 2018)。相较于无线传感器网络, 单个摄像头能监控多个停车位, 从而有效降低了单位停车位的成本。在维护管理方面, 摄像头系统的部署具有非侵入性特点, 易于实施。另外, 正如上文所提及, 视频数据相较于其他类型的传感器数据, 蕴含更为丰富的信息量, 这为处

理停车场景中更为复杂的任务提供了可能。Bulan 等提出采用背景减除技术结合支持向量机 (SVM) 进行街道停车检测, 实验结果表明该方法展现出良好的性能, 并且在面对遮挡情况时表现出较强的鲁棒性 (Bulan et al., 2013)。Nurullayev 等构建了一个具有独特结构的扩张卷积神经网络 (CNN), 经过验证, 该网络结构在停车位检测方面表现出了高度的稳定性和适用性 (Nurullayev and Lee, 2019)。

2.4 车载数据与感知技术

车载感知技术是对基于基础设施的感知系统的有益补充, 它属于道路使用者端的感知手段。由于传感器与道路使用者同行, 其具备更高的灵活性, 并且能够实现更大范围的监控。车载传感器作为智能车辆的“视觉系统”, 使车辆具备对周边环境的感知与理解能力。这些特点为城市级感知应用及自动驾驶技术的发展提供了新的机遇, 同时也带来了一系列的创新挑战。其中, 传感器在移动中所呈现的非规则性是一个重大的技术难题。传统的 ITS 所依赖的基础设施固定式传感器, 面临的是静态背景与相对稳定的环境条件。例如, 测速雷达传感器预设了交通流的位置, 摄像头传感器面对的是固定不变的视频背景, 可适用传统背景建模算法。鉴于此, 要想充分利用车载感知技术的潜力, 就必须针对上述挑战提出解决方案。

2.4.1 交通临近碰撞检测

交通接近事故亦称交通擦身而过事件, 指的是道路使用者间潜在可能演变为碰撞的冲突。通过车载传感器进行接近事故探测是众多 ITS 应用的初步步骤: 接近事故数据不仅可作为交通安全研究的代理安全数据, 也可作为自动驾驶车辆测试的边缘案例数据, 同时充当碰撞预防系统的输入信息。在基础设施层面, 已有若干先导性研究采用激光雷达与摄像设备, 自动化地提取接近事故数据 (Ismail et al., 2009; Wu et al., 2018; Huang et al., 2020)。近年来, 基于车载传感器的近碰撞探测系统与算法的研发进程显著加快。Ke 等 (Ke et al., 2017) 和 Yamamoto 等 (Yamamoto et al., 2020) 在各自的近碰撞探测框架中, 分别采用了传统机器学习模型——支持向量机 (SVM) 与随机森林, 这些模型在标准计算机上的探测准确性和效率均达到了较为理想的水平。然而, 当前领先的技术趋势正逐步向深度学习技术倾斜, 以进行更为精准的近碰撞探测。近期研究成果表明, 将卷积神经网络 (CNN)、长短期记忆网络 (LSTM) 以及注意力机制相结合的方法, 在探测性能上显著超越了传统模型 (Yamamoto et al., 2020; Ibrahim et al., 2021; Kataoka et al., 2018)。Ibrahim 等的研究结果揭示, 集成自注意力机制的双向长短期记忆网络 (Bi-LSTM) 在性能方面明显优于仅采用传统注意力机制的单向长短期记忆网络 (Ibrahim et al., 2021)。近期研究的一个显著特征是融合了车载摄像传感器数据与车载远程信息技术数据 (包括车速、加速度及定位信息), 旨在增强临近碰撞事件的检测性能或者提高数据输出的多样性 (Yamamoto et al., 2020; Taccari et al., 2018; Ke et al., 2020a)。Ke 等的系统主要应用于机载视频的近距离碰撞检测, 同时也会采集远程信息处理数据以及车辆 CAN 数据, 以便于后续的分析工作 (Ke et al., 2020a)。