

过去几十年的快速城市化导致了私人汽车使用的显著增加。虽然私家车在任何时候都能提供方便的、门到门的服务,但它们的普及导致了广泛的交通拥堵、排放增加和大量的生产时间损失。作为应对, Mobility-on-Demand (MoD) 服务成为了一个引人注目的替代方案。通过基于实时需求动态分配车辆, MoD 系统提供个性化的旅行选项, 同时减少了对私家车拥有的依赖。因此, 它们保留了私家车的许多优点, 提供了更可持续且可扩展的交通解决方案。随着自动驾驶技术的进步, Autonomous Mobility-on-Demand (AMoD) 已成为下一代交通系统的重要推动者。AMoD 系统(即执行按需出行任务的自动驾驶出租车车队)能够自主管理车队, 以有效响应乘客请求并满足交通需求。这类系统本质上是复杂的: 它们涉及高度的交互, 并需要在空间和时间尺度上进行协调 [1]。结果, 不同的研究经常专注于不同的操作挑战, 每一个都针对系统动态和乘客行为采取特定的假设。这种方法的多样性使得研究的可重复性和基准比较的努力变得复杂。然而, 可重复性仍然是严格科学实践的基石。它增加了可信度, 加速了进展, 并在研究贡献中实现有意义的比较 [2]。在计算科学、机器人学和管理科学等学科中, 可重复性通过标准化评估程序、常见基准以及定期共享代码和数据来广泛促进 [3]-[6]。相反, 尽管在交通研究中对可重复性的重要性日益得到认可 [7], [8], 但一致的实践和社区标准仍然稀缺。

本文旨在通过识别和分析决定 AMoD 控制研究可再现性的关键组成部分来解决这一空白。我们建议将这些从建模选择到实验设置的组成部分明确地记录在研究成果中。尽管重点是 AMoD, 但所讨论的原则适用于广泛的网络化控制和优化问题, 包括航空、海上运输及其他复杂的网络物理系统中的问题。

“可重复性”一词已被用来描述科学发现在交流和验证上所具有的不同程度的严谨性。在其最基本的层面上, 可重复的研究要求具备足够的透明度和方法的清晰性, 以便他人能重新创建结果并验证其基础逻辑。这个最低标准通常假定可获得相同的输入数据, 并要求所描述的方法和条件足够详细, 以再现原始结果。更严格的标准则是在独立研究人员使用可比的技术和假设(不一定相同的数据)的情况下, 能得出类似的发现和推论。这个更高水平, 有时被称为推论可重复性或可复制性, 不仅对于确认科学主张的稳健性至关重要, 而且对于使未来研究能够在原始工作基础上进行扩展也是关键的。在本文中, 我们努力提供建议来加强 AMoD 研究的这两个层次的可重复性, 但我们并不在这些术语之间做严格区分。

A. 针对 AMoD 的整体、系统级可重复性

AMoD 系统操作 Autonomous Vehicles (AVs) 车队以在交通网络中满足乘客请求。用户通过移动应用程序请求行程, 系统必须实时协调车辆以提供高质量的服务。因此, AMoD 控制问题集中于优化车队管理, 性能指标包括盈利能力、服务率、乘客等待时间和环境影响。

Fig. 1 提出了 AMoD 系统的系统级可重复性方案, 强调了在此背景下提高可重复性所需的基本组件。具体来说, 它不仅包括特定研究工作的建模和算法方面, 还包括关键的实验和上下文细节, 例如假设、约束和数据来源, 这些通常未被充分报道。这些组件共同提供了一个全面的蓝图, 以透明地传达研究并促进可重复性。

要定义一个 AMoD 控制问题, 必须明确三个关键要素: (1) 系统模型, (2) 目标操作, 和 (3) 控制目标。系统模型提供了真实世界 AMoD 网络的一个可处理的数学表示, 并作为问题形成的基础。在这样的模型基础上, 研究人员定义关注的操作, 通常是一些受基础设施特性约束的车队控制方面(例如, 道路容量), 并选择一个合适的目标函数,

这个目标函数通常反映运行效率、盈利能力或可持续性。至关重要的是, 任何提出的解决方案仅在其假设的精确背景下才有意义。这些包括显式的建模假设(例如, 需求弹性、拥堵模型、新技术的渗透率)和隐式的设计选择(例如, 模拟的准确性)。这些假设直接影响结果的适用性、可推广性和可复制性。一旦开发出解决方案, 应通过实验来评估其性能基准、展示鲁棒性, 并评估计算可行性。清晰地报告流水线中所有步骤, 对于支持可重复的研究至关重要。

虽然以往关于 AMoD 控制的调查主要集中于具体的操作问题或解决方法 [1], [9], 据我们所知, 这是第一个以可重复性为中心的视角。在这项工作剩余部分中, 我们详述了 Fig. 1 中报告的组件, 讨论了当前实践, 识别了常见的陷阱, 并提出了改进的指导方针。

B. 论文的组织结构

本文的其余部分组织如下。Section I 展示了 AMoD 系统的建模方法。Section II 讨论了关键的操作挑战。Section III 回顾了用于应对这些挑战的算法技术。Section IV 概述了关于系统动态的基础假设及其对研究适用性的影响。此外, Section V 详细介绍了实验设计和文档编制的最佳实践。然后, ?? 探讨了 AMoD 系统与基础设施之间交互的研究。最后, Section VI 以可重现性核对表作为未来研究的参考来总结这项工作。

I. 自动驾驶出行系统的数学建模

建立 AMoD 系统模型的核心在于捕捉乘客、车辆及其在交通网络中的动态交互。系统模型是任何资源分配策略的基础, 因为它正式定义了涉及的实体、资源 (AVs)、消费者(乘客)及其交互的逻辑。在现有的 AMoD 文献中, 大多数系统模型可以被广泛地分为三种主要类型: 排队理论模型、网络流动模型和以车辆为中心的(基于代理的)模型。每种建模范式基于不同的假设, 并旨在突出 AMoD 系统的不同操作特性。本节介绍这三种建模方法, 重点关注它们各自的假设、优势和局限性。明确理解这些权衡对于选择适当的建模框架和解释所得结果的适用性和可重复性至关重要。我们结束本节时鼓励未来的研究明确指定选择的系统模型, 包括其假设和结构局限性。本节的目标不仅是调查主流建模策略, 还希望建立一个参考来实现跨研究的透明交流和可比性。

A. 排队论模型

排队理论提供了分析等待队列和服务系统的数学框架。在 AMoD 的背景下, 排队理论模型通常将旅程请求表示为作为服务器的随机到达过程, 当车辆接载乘客时表示服务。网络中的位置被建模为队列, 系统动态通过车辆和乘客之间的流动来描述 [10], [11]。

1) 假设: 首先, 这些模型将乘客和车辆表示为离散实体。假设顾客根据外生随机过程(例如, 泊松过程)到达, 并以固定的速率到达起始站, 并根据概率选择他们的目的地 [12], [13]。

为了在排队框架内呈现 AMoD 问题, 需要对乘客到达、旅行时间和乘客行为进行特定假设。具体而言, 常见假设包括: 需求遵循时间不变的泊松分布, 车站之间的旅行时间遵循指数分布, 以及乘客如果没有与车辆匹配则立即离开系统 [10]-[12]。这些假设在保持准确性的同时简化了相关问题, 正如在 [14] 中所展示的那样, 合理的偏差被证明对性能的影响可以忽略不计。

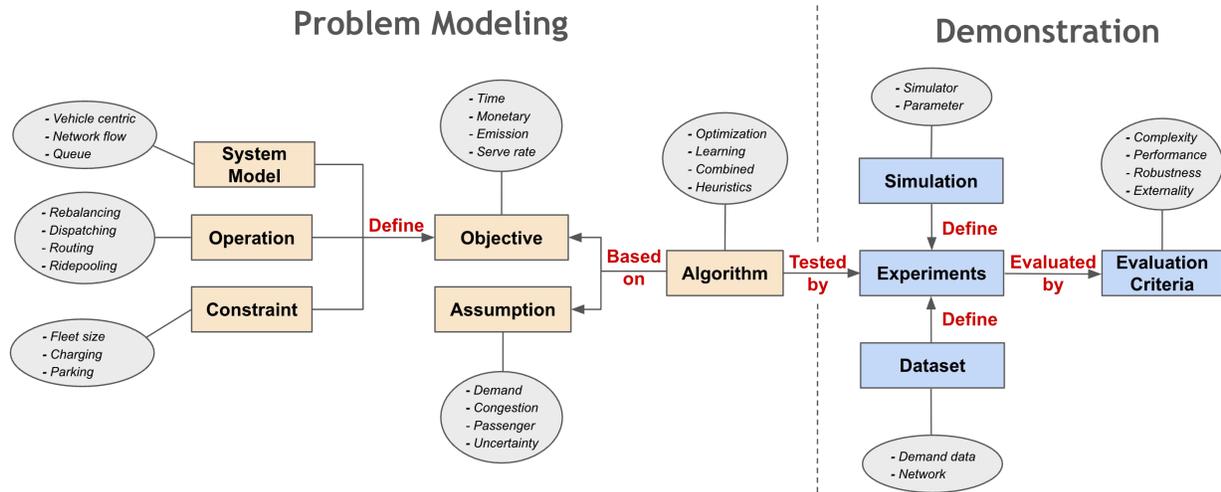


Fig. 1: 复现性方案。该图包括提高 AMoD 控制研究复现性的关键组成部分。

2) 益处：排队理论模型保留了乘客到达的离散性，并允许直接应用排队理论来计算关键性能指标，例如节点吞吐量 [15]，这对应于 AMoD 系统中的车辆移动和可用性。它明确考虑了系统的随机性并确保性能在期望中。推导出的策略保持了系统的平衡，防止排队和等待时间无限增长 [10]–[12]。

3) 局限性：如在 ?? 中所讨论的，排队理论模型依赖于关于乘客到达率和旅行时间的强假设。这些假设对于推导分析结果和确保可控性是必要的。在许多公式中，到达率进一步被假设为时间不变，以便于稳态分析。然而，这样的简化可能无法准确反映现实世界交通系统的动态，特别是在需求模式非平稳并受到外部因素影响的长期规划场景中。

B. 网络流模型

网络流模型是 AMoD 研究中采用最广泛的方法之一。此类模型将交通系统表示为一个有向图，其中节点对应于物理或逻辑位置，弧代表可能的车辆或乘客移动。系统动态由网络中车辆和乘客的流动捕捉。

1) 假设：当与流体力学 [16] 结合使用时，网络流模型将车辆和乘客流量视为连续变量。尽管这种抽象偏离了个体行程和车辆的离散性质，但它带来了显著的计算简化。例如，最初构建为整数规划的问题常常能够放宽为线性规划，允许在考虑大型网络时进行更具扩展性的优化。事实上，在研究大型交通网络时，最近的一项研究表明，当分析系统层面的影响时，使用微观模拟或（连续的）网络流模型之间的差异是微小的 [17], [18]，这进一步推动了网络流模型的使用。这些模型自然地与运输科学中的许多基础理念相一致，例如通过 Origin-Destination (OD) 对进行需求建模和网络均衡分析。基于图的结构为捕捉车队移动、需求满足和操作约束提供了一个直观且模块化的框架。当使用足够数量的节点时，网络流模型可以有效地用高保真度和最小离散化误差来逼近自由流动的 AMoD 系统 [19]。尽管网络流模型的使用广泛且概念清晰，但从抽象流向可操作控制策略的转变中仍然存在局限性。在大多数公式化中，控制决策被表达为节点之间的总流量，而不是明确定义的车辆轨迹。因此，将这些流量转换为 AVs 的路径级指令需要一个额外的路径重建步骤。尽管在模拟研究中这个步骤大多被忽略，但在实际应用中它变得至关重要，在实际应用中，必须考虑到路径的可行性、车辆级状态和道路网络约束（例如容量） [20]。

C. 以车辆为中心的模型

与那些在网络流或排队理论模型中抽象掉车辆身份以突出整体流量的方法不同，这种方法明确地跟踪系统中每辆车的状态和控制动作。

1) 假设：以车辆为中心的模型假设系统动态可以在单个车辆的层面上被描述和控制。每辆车的状态通常包括位置、载客量、电池电量和分配的任务（例如，服务客户或再平衡） [21]–[23]。控制动作，如调度、路径规划和再平衡，是基于每辆车的情况独立决定的，通常依赖于本地或部分观测的信息。

2) 好处：这种建模范式为每辆车实现直接和可解释的决策，这简化了在现实世界车队管理系统中的实施。与需要路径重构步骤将抽象流转换为个体动作的网络流模型相比，这类模型通过设计提供可执行的计划。此外，它们自然地适应异构环境：车队，支持运行特性如车辆特定的容量、偏好或限制。

在集中控制下，以车辆为中心的模型的主要限制在于其可扩展性。由于决策是在单个车辆层面做出的，控制变量的数量与车队规模线性增长，不像排队或网络流模型，通常随成对的 OD 数量扩展。这个细粒度的表述显著增加了计算负担，尤其是对于大规模系统，并可能限制集中优化方法的可处理性。虽然分布式算法可以帮助保持可扩展性，但它们可能会影响决策的质量和整体车队性能。

D. 可重复性考虑

建模选择在确定 AMoD 控制研究的可重复性和可比性方面起着根本性的作用。每种建模范式都拥有隐含的假设，这些假设会影响问题的制定、解决方法以及结果的解释。然而，这些假设并不总是能在发表的研究中明确说明，使得后续研究人员难以复制研究或公平地比较方法。例如，基于队列的模型可能会掩盖对时间变化需求的处理方式，网络流模型通常省略路径重构逻辑的细节，而以车辆为中心的模型则需要精确的车辆状态和约束的规定。为了促进可重复性，研究人员应清楚地记录所选择的建模框架，包括其结构假设、抽象以及为了易处理性而进行的任何简化。

II. 运营 AMoD 系统

AMoD 系统的部署需要实时的操作策略，以确保高效的服务。这些设计策略的主要目标是最大化服务性能，既可以通过派遣车辆接送乘客，也可以通过主动将车辆重新定

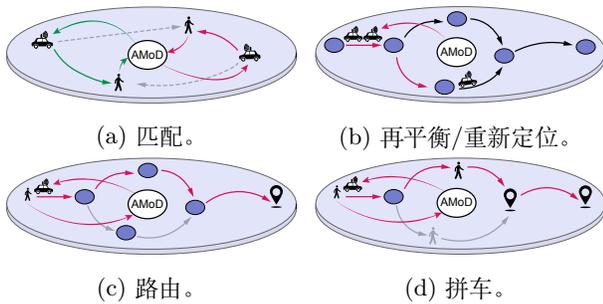


Fig. 2: AMoD 控制中的操作问题 [1]。

位到预期高需求的区域。这些操作受特定于系统的各种约束的限制。在本节中，我们介绍了管理 AMoD 系统的关键操作任务和约束。不提供现有解决方案的全面回顾，我们的重点是定义这些任务，以建立未来参考的清晰背景。

A. 操作任务

操作任务包括派遣、再平衡、路径规划和拼车，图形化地报告在 Fig. 2 中。有关操作策略的深入回顾，读者可以参阅 [1]。

1) 匹配：给定可用的乘客和车辆集合，匹配问题集中在将车辆分配给乘客 (Fig. 2a)。在一对一的乘客与车辆分配设置中，匹配问题可以被表述为 Bipartite Matching Problem (BMP) [21], [24], [25]，其中 BMP 中的弧成本与控制任务的目标有关。

2) 再平衡：车辆再平衡或重新定位，是指将可用车辆重新分配到供需不平衡的区域的过程 (Fig. 2b)。通过优化车队分布，再平衡改善服务率，提高使用率，并可以减少平均等待时间和延误 [26]。在车辆供应稀缺的情况下，其益处尤其显著 [27]。

3) 车辆路径规划：车辆路径问题关注如何在给定一组任务 (Fig. 2c) 的情况下优化访问停靠点的计划。关于这一主题的综合评述可见于 [28]。在 AMoD 系统中，路径规划发生在两个层面。第一个是道路网络层面，在给定一个 OD 对的情况下，目标是确定车辆高效穿越道路网络的最佳路线 [29]。在这种情况下，算法解决方案可能不仅限于计算简单的最短路径。特别是在 AMoD 环境中，通过在替代路径上平衡各自的流量 [30] 或在时间上错开它们 [31] 以避免拥堵瓶颈，可以大大优化车队路径规划。第二个是车辆操作层面，涉及基于再平衡、调度或两者结合的情况下确定车辆访问站点的顺序。在 AMoD 文献中，“路径规划”这一术语通常指车辆操作层面。

4) 充电调度：环境可持续性意识的提高推动了 Electric Vehicle (EV) 的采用激增，预计到 2035 年将增加 12 倍 [32]。车辆电气化已成为可持续未来移动系统的关键组成部分。与传统的 AMoD 系统相比，电动 AMoD 引入了与充电需求相关的额外操作任务，这些任务必须在车队协调时予以考虑。一项研究涉及通过建模电动 AMoD 与电网之间的系统级交互来设计主动充电计划。这种耦合通常通过根据可用电力系统供应 [23] 限制充电请求或集成 Vehicle-to-Grid (V2G) 功能来表示，其中 EVs 可以从电网中获取并反馈能量 [33], [34]。除了一起建模充电计划和电力网络影响外，通过价格信号考虑此类复杂性的全车队充电计划作为提高系统效率的有前途的途径 [35]。

在 AMoD 中，合乘允许多个乘客共享一辆车 (Fig. 2d)，通过减少车辆数量、降低能量消耗和缓解拥堵来提高服务效率 [36], [37]。合乘通常根据车辆容量进行分类：区分这两种情况至关重要，因为容量限制直接影响解决方案

方法的可扩展性。在低容量设置中，控制策略通常类似于单乘客系统，因为复杂性仍然是可处理的 [22]。相比之下，高容量合乘引入了显著的计算挑战，通常需要启发式方法 [22], [38] 或问题简化，如先到先得的分配原则 [39]，并限制每个时间步只分配给一个乘客 [40], [41]。值得注意的是，单请求与批量分配之间的选择是影响合乘问题复杂性的重要因素。单请求分配限制每个决策最多为每个可用车辆分配一个新的乘客 [21], [40], [42]。相比之下，批量分配同时将多个乘客与车辆匹配 [22], [43]。单请求分配通过忽视不同乘客的分配决策之间的时间依赖关系来简化问题，而批量分配则捕捉这些依赖关系，但增加了计算复杂性。

在控制文献中，术语使用往往不一致，导致混淆并掩盖了实际要解决的操作问题。为了提高清晰度并促进研究社区的共同理解，我们提出以下术语指导。术语调度有时用于表示匹配。然而，使用调度来表示车辆-乘客分配可能会导致对任务的解释产生歧义，因为车辆还可以用于其他操作。此外，当用于表示匹配时，调度有时与再平衡互换使用，尽管指的是不同的操作。为确保清晰度和一致性，我们建议使用匹配来指车辆分配以满足乘客请求，而再平衡应指将空闲车辆重新定位到预计需求的区域。

在 AMoD 系统中，路由决策可能由于调度、重新平衡或两者结合而产生。使用路由作为整体操作问题的通用术语可能会掩盖决策过程的性质。我们鼓励研究人员明确指出优化过程中考虑的基本操作，以明确路由决策的范围和意图。有时，“共享” AMoD 一词用于描述在用户之间共享车队的系统，但任何时候都只有一个乘客占据车辆。为了避免歧义，我们建议在提到涉及多名乘客同时乘坐同一辆车的共享行程时明确使用“共乘”一词。为了解决 Section II-A 中提到的控制任务，重要的是考虑系统特定特性带来的操作约束。这些约束在现实世界的情景中是基础性的。

当前的研究通常专注于现有车队的管理，其中车队的规模在决策过程中作为一个约束条件

5) 车队规模：显然，这个约束条件的纳入方式在不同的建模方法中会有所不同。在以车辆为中心的模型中，约束条件是隐含嵌入的，并且对于现有车队中的每辆车进行迭代决策。对于排队理论模型来说，车队规模是在闭环排队网络结构中固有定义的，使得它成为模型的一个组成部分。在基于网络流的方法中，通过对可用车辆数量施加硬性限制来明确执行约束条件。车队规模通常计算为所有运输中车辆的总和 [44], [45]，或者从初始条件中计算得出 [16]。

一些研究将车队的规模视为一个设计变量，而不是一个固定约束。在这些情况下，目标是根据系统性能指标确定最佳车队规模 [39], [46]-[50]。除了将主动充电调度视为一个操作任务之外，许多研究将充电视为操作控制中的一个限制条件，这对车队协调施加了限制。实际上，这些限制是由于 EVs 的有限运行范围，该范围取决于可用的电池容量 [25], [51], [52]。限制条件的表达形式是有限的电池容量和旅行中的能耗率。此外，除了预定义的充电站布局外，充电基础设施的设计仍然是一个关键的研究领域 [53]-[55]。一种更加综合的方法考虑充电站布局与车队操作的联合优化，以实现高效的系统级协调 [56]。对于一般的维护活动（例如，清洁车辆、校准车辆等）可以提出类似的论点 [1]。

6) 停车：交通活动通常以停车开始和结束，这使得停车位成为一种关键资源，特别是在城市环境的限制区域内 [57]。为了有效管理 AMoD 车队，一种方法是对节点上允许的停车数量施加上限，将停车限制直接纳入系统模型中 [58]-[60]。另一种方法是引入节点空闲的额外成本，以

减少车辆的过长驻留时间，并间接地考虑停车限制 [47], [61], [62]。特别是，大多数 AMoD 控制研究假设停车资源无限，无论是显式还是隐式地。在许多模型中，车辆在节点的拾取和空闲不受停车容量的限制，这可能忽视了现实中的操作挑战。

7) 可重复性考虑：操作约束对 AMoD 控制方法的适用性至关重要，但在已发表的工作中，它们常常被描述得不够具体或沟通不一致。这些操作约束提供了关于感兴趣场景和所提方法现实差距的重要信息。在定义操作时，应该明确具体说明哪些约束被考虑以及它们如何在问题表述中进行编码。在操作约束中，充电通常被清楚定义，因为它表明了对所涉及系统的具体关注 EVs，但关于车队规模和停车空间的约束往往不够透明。尽管可以从用于解决问题的方法中推断出来，明确在问题定义中陈述这些约束有助于工作理解。即使这些约束在建模或优化框架中是隐含的，使其显式化能够提高清晰度，并使其他研究人员能够重现和基准化结果。

III. AMoD 控制的算法

为 AMoD 车队管理开发有效的控制策略依赖于解决 Section II-A 中概述的操作挑战的算法设计。近年来，这一领域在多个学科中获得了广泛关注，包括机器人、控制、运输、运筹学和机器学习。我们将现有算法分为四大类：数学规划、基于学习的方法、混合方法和定制启发式算法。每一类都体现了不同的建模假设、解决方案策略以及在最优性、可扩展性和可解释性之间的权衡。本节介绍每种算法类型背后的基本概念，并调查它们在 AMoD 控制问题中的应用。因为解决算法通常代表这一领域研究工作的核心贡献，其设计、公式化和实施细节必须明确表述。透明的算法描述不仅对评估方法创新至关重要，而且能够支持公平的基准测试和促进同一问题类别研究的可复现性。

A. 数学规划

数学规划，也称为数学优化，是运筹学中的一个基础工具，也是复杂系统中决策制定最广泛应用的方法之一。它涉及通过制定一个包含目标函数和一组约束的系统模型，以捕获系统动态和操作要求。时间通常被离散化为决策间隔，通过在每个间隔解决一个优化问题来计算控制动作 [63]。在 AMoD 控制的背景下，优化目标通常围绕服务时间和系统盈利性。有关常见目标的详细讨论请见 ??。数学规划模型中的约束根据基础网络模型和操作要求而异。具体来说，再平衡通常通过网络流方法 [16], [48], [64], [65] 或队列理论模型 [10]-[13], [51] 来建模。

1) 网络流问题中的再平衡：假设 N 个站点和离散化的决策窗口 $t \in \{1, 2, \dots, T\}$ ，再平衡决策是为 OD 对各站点之间作出的。特别地，令 p_{ij} 和 c_{ij} 分别表示从站点 i 到 j 的载客旅行利润和车辆再平衡成本。令 S_i^t 表示时间 t 站点 i 的车辆数量。此外， x_{ij}^t 表示时间 t 从 i 到 j 的空车再平衡数量，而 y_{ij}^t 表示时间 t 从 i 到 j 的载客车辆数量。给定客户需求 d_{ij}^t 和旅行时间 t_{ij}

，最佳再平衡问题被表述为：

$$\max \sum_{i,j,t} p_{ij} y_{ij}^t - \sum_{i,j,t} c_{ij} x_{ij}^t \quad (1a)$$

$$\text{s.t. } y_{ij}^t \leq d_{ij}^t \quad \forall i \in N, \forall t \in T, \quad (1b)$$

$$s_i^{t+1} = s_i^t + \sum_{j=1}^n x_{ji}^{t-t_{ji}} + \sum_{j=1}^n y_{ji}^{t-t_{ji}} - \sum_{j=1}^n x_{ij}^t \quad (1c)$$

$$- \sum_{j=1}^n y_{ij}^t \quad \forall i \in N, \forall t \in T, \\ x_{ij}^t, y_{ij}^t, s_i^t \in \mathbb{N} \quad \forall i, j \in N, \forall t \in T, \quad (1d)$$

，其中 Eq. (1b) 确保满足的需求不超过乘客到达量，Eq. (1c) 确保流量守恒。Eq. (1a) 表示与最大化服务利润相关的目标。

2) 排队论问题中的再平衡：排队理论模型根据排队网络的特定优化目标施加约束，通常解决系统稳定性 [51] 和资源的平衡分配 [10]-[12]。使用与网络流模型相同的网络和需求设置，基于 Jackson 网络模型的最优再平衡问题 [11] 旨在在保持所有站点的平衡服务率的同时，最小化再平衡时间。

$$\min \sum_{i,j} t_{ij} \alpha_{ij} \psi_i \quad (2a)$$

$$\text{s.t. } \gamma_i = \gamma_j \quad \forall i, j \in N, \quad (2b)$$

$$\sum_j \alpha_{ij} = 1 \quad \forall i \in N, \quad (2c)$$

$$\alpha_{ij}, \psi_i \geq 0 \quad \forall i, j \in N, \quad (2d)$$

其中 ψ_i 是从站点 i 的再平衡率， α_{ij} 表示从站点 i 到站点 j 的车辆再平衡的概率。服务率则为 $\gamma_i = \pi_i / (\lambda_i + \psi_i)$ ，其中 λ_i 表示乘客到达率， π_i 为吞吐量，闭合 Jackson 网络的一种性质。这些约束源自排队理论的基本原理，允许有效制定再平衡策略。

在许多研究中，匹配和再平衡是联合优化的，因为两者都对整体车辆流量有贡献。这种关系在 Eq. (1c) 中是显而易见的，其中 y_{ij}^k 代表在时间 k 匹配的乘客人数。然而，拼车显著增加了同时解决匹配和再平衡问题的复杂性。在这种情况下，联合优化为已经在计算上具有挑战性的拼车分配问题引入了另一个复杂层次，如 Section II 中所述。更常见的方法是分步骤处理匹配和再平衡。

3) 匹配的优化：当与重新平衡一起研究时，通常假设匹配发生在同一地区的乘客和车辆之间 [66], [67]。重新平衡操作可以解释为车辆从其起始地区重新部署到目的地区，以容纳那些目的地区的乘客。在单独建模时，匹配优化问题主要采用以车辆为中心的方法建模 [68]-[70]。来自不同地区的乘客和车辆之间的匹配动态导致以下格式：

$$\max \sum_{i,j} p_{ij} x_{ij} \quad (3a)$$

$$\text{s.t. } \sum_j x_{ij} \leq 1 \quad \forall i \in V, \quad (3b)$$

$$\sum_i x_{ij} \leq 1 \quad \forall j \in P, \quad (3c)$$

$$x_{ij} \text{ binary} \quad \forall i, j \in N. \quad (3d)$$

其中 x_{ij} 表示一个二进制变量，指示车辆 i 是否与乘客 j 匹配。这是一个 BMP，这是广泛的指派问题的典型形式 [71]。虽然有各种解决方法用于该问题的不同版本，但其中一个最广泛使用的算法是匈牙利方法 [72], [73]。

4) 通过 MPC 进行未来状态优化：再平衡和匹配决策不仅取决于当前系统状态，还取决于未来的状态。Model Predictive Control (MPC) 常常用于在扩展的规划范围内计算解决方案，结合需求预测 [34], [74]。具体来说，预测可以通过相似条件下的历史数据获得 [19], [75]，或者通过确定性或随机预测模型来考虑不确定性 [76]–[79]。基于优化的方法能够保证解决方案符合特定约束，且存在成熟的定理以确保解决方案的最优性。然而，随着系统规模和问题复杂性的增加，MPC 方法由于可能决策的组合爆炸而变得不再可行。

5) 可重复性考虑因素：在基于优化的 AMoD 控制中，大量研究集中于提高模型的可扩展性。为了支持这些主张，研究人员应明确阐述他们提出的公式如何在理论和实证上促进可扩展性 [80]。特别重要的是要避免隐式松弛的陷阱，即问题最初以某种方式构建，但在实验过程中被修改以使其在计算上可处理，却未能清晰传达这些变化。这种做法可能会掩盖问题的真正复杂性，并阻碍公平的比较。因此，任何松弛或近似都应明确提出，并应在问题表述中或紧随其后提供充分的解释或理由。

近年来，应用基于学习的方法，尤其是 Reinforcement Learning (RL)，来控制 AMoD 系统的兴趣日益增长。RL 提供了一个强大的框架，通过经验开发控制策略，使智能体能够在动态和不确定的环境中自适应地学习如何做出决策 [81]。在数学上，RL 问题通常被形式化为 Markov Decision Processes (MDPs)，其特征由一个元组 $(\mathcal{S}, \mathcal{A}, \mathcal{P}, d_0, R)$ 表示，其中 \mathcal{S} 是系统中所有可能状态的集合， \mathcal{A} 是可能动作的集合， $\mathcal{P}(s'|s, a)$ 是在当前状态 s 和动作 a 下转移到状态 s' 的概率， $d_0(s_0)$ 表示初始状态分布， $R: \mathcal{S} \times \mathcal{A} \rightarrow \mathbb{R}$ 是奖励函数。

RL 的目标是学习一个可能是随机的策略 $\pi(a|s)$ ，以在有限的时间范围 T 内最大化期望累积奖励。根据策略 π 观察到某一轨迹 $\tau = (s_0, a_0, \dots, s_T, a_T, s_{T+1})$ 的概率为：

$$p_\pi(\tau) = d_0(s_0) \prod_{t=0}^T \pi(a_t|s_t) \mathcal{P}(s_{t+1}|s_t, a_t), \quad (4)$$

，学习目标为

$$\max_{\pi} \mathbb{E}_{\tau \sim p_\pi(\tau)} \left[\sum_{t=0}^T \gamma^t R(s_t, a_t) \right], \quad (5)$$

，其中 $\gamma \in (0, 1]$ 是一个标量折扣因子，它逐渐减小分配给未来奖励的权重。在 AMoD 控制的背景下，状态空间通常包括与需求相关的变量（如乘客到达、队列长度、旅行时间）、车队状态和网络配置，而动作空间包括运营决策，例如再平衡流量或车辆-乘客匹配。关于基于 RL 的 AMoD 控制框架的全面综述，我们推荐读者参考 [82]。

6) 在线 RL：大多数 RL 算法遵循一个标准的学习循环，其中智能体通过观察当前状态 s_t 、选择一个动作 a_t 、获取奖励 $r_t = R(s_t, a_t)$ ，以及转换到下一个状态 s_{t+1} 来与环境交互。这个交互序列被用来迭代地改进策略。从历史上看，出现了两个主要范式：(1) 一个全局的、集中化的控制器观察整个系统状态，并为所有车辆 [41], [83] 做出联合决策；(2) 机群中的每辆车作为一个独立的代理，拥有本地信息访问权限，以去中心化的方式采取协调行动 [84], [85]。这种方法也被称为 Multi-Agent Reinforcement Learning (MARL)。每种范式都有其权衡。集中控制能够实现更有效的机群协调，但随着系统规模的增加，面临着高维状态和动作空间的问题。MARL 通过分解问题提高了可扩展性；然而，由于需要对代理之间的交互和出现的行为进行建模，使得训练变得更加复杂。该领域的研究通常聚焦于如何建模代理间的通信和合作策略。

7) 离线 RL：传统的（在线）RL 需要持续与环境或模拟器交互。然而，由于安全、成本或模拟逼真度的限制，这在现实世界的 AMoD 系统中通常是不可行的。在这种情况下，离线 RL（也称为批量 RL）通过仅在预先收集的轨迹上训练策略提供了一种替代方法 [86]。它能够在没有主动探索的情况下进行学习，但却引入了新的挑战，最显著的是，收集数据时使用的行为策略与正在学习的策略之间的分布偏移问题。这种不匹配可能导致在评估过程中错误的累积，许多文献都集中于缓解这一问题 [27], [67]。

在离线 RL 中，训练是使用预先收集的轨迹进行的，轨迹由历史状态-动作对组成。当这些动作的质量有保证时，智能体可以直接训练以学习从状态到动作的映射。这种监督学习过程被称为模仿学习 [87]。对于 AMoD 控制，这些质量保证通常来自基于优化模型或设计良好的启发式方法的解决方案 [88]。虽然优化模型可以提供最优性的保证，但它们在大规模网络的实时控制中通常是难以解决的。模仿学习旨在通过训练智能体在在线操作期间再现这些决策，捕捉从优化模型得出的最优解决方案的结构模式，从而避免计算密集型的优化过程。

为了确保基于 RL 的 AMoD 控制的可重复性，作者应该明确指定 MDP 的四个核心组成部分：状态空间、动作空间、奖励函数和转移动态。特别是，如何编码需求模式、车辆状态和控制决策的详细文档是至关重要的。这些要素不仅定义了 RL 学习的设置，还澄清了如何将原始问题表述为一个 MDP，这对于可重复性和可比性至关重要。此外，通常实现为神经网络的策略表示必须详细描述，包括架构细节、训练超参数和优化方法。对于离线 RL 和模仿学习方法，至关重要的是离线轨迹需公开可用或附有其生成方式的全面文档。更广泛的 RL 社区已经认识到数据和实现细节在实验可重复性中的关键作用 [89]；这里也适用相同的标准。最后，鉴于 AMoD 问题的高维性，作者应报告收敛性、在多个随机种子下的稳健性以及在不同系统规模下的性能一致性。这对于评估实际应用的准备情况特别重要，因为控制策略必须超越一小部分训练情景实现泛化。

如前几节所述，数学优化和 RL 在 AMoD 控制中各自提供了不同的优势和限制。基于优化的方法提供了解释性、稳健性和性能保证，但通常需要在每个决策间隔反复解决复杂问题，使其在计算上非常密集，尤其是在规模较大或实时约束下。相比之下，RL 方法通过将大部分计算负担转移到离线训练中，能够快速地进行在线决策。虽然 RL 需要更少的建模假设并提供更快的在线推理，但它缺乏相同水平的保证，并且可能难以调试和解释。认识到这些互补优势，越来越多的研究探索了优化与学习的整合，以实现高效的 AMoD 控制。这些混合方法大致可以分为三个类别。

在这种方法中，优化结构被保留，但利用学习来简化或参数化问题的某些方面。例如，与其直接学习基于 OD 的再平衡流量，RL 代理可以学习可用车辆在各个区域的期望分布 [66], [90], [91]。实际的流量随后通过解决一个轻量级的优化问题来计算，该问题在满足学习的目标分布的同时最小化再平衡成本。这种特定的方法将动作空间从 $\mathcal{O}(N^2)$ 减少到 $\mathcal{O}(N)$ ，显著提高了可扩展性，同时确保控制动作符合领域约束。此外，优化组件与基于学习的策略的整合进一步促进了离线 RL [92]。

8) 学习改进优化目标：第二类方法利用学习来改进或增强非目光短浅的优化公式。在这里，学习模型用于估计作为优化例程输入的权重、偏好或预测。例子包括学习二部匹配图中的弧权重或指导多步再平衡决策的行进成本估计 [21], [24], [43], [93], [94]。这些方法保留了经典优化的结构和保证，但通过学习的组件获得了灵活性和适应性。



Fig. 3: CO 富集的 ML 管道 [95]。

9) 组合优化丰富的机器学习：除了传统的 RL 框架之外，最近的一项研究线探讨了如何将 Combinatorial Optimization (CO) 直接嵌入到 Machine Learning (ML) 流水线中。这种方法，被称为 CO 丰富的 ML [95]，在通过精确求解器或近最优启发式方法提供高质量解决方案时特别有效。主要思想是训练一个 ML 模型以预测简化 CO 问题的中间参数，这个问题比原始问题更容易解决，同时仍保留关键的结构特性。如 Fig. 3 所示，CO 丰富的 ML 流水线可以描述如下：一个问题场景 x 通过一个 ML 模型映射到一个参数化的 CO 问题。求解器 f 计算相应的解决方案 y ，而训练则最小化预测解决方案 y 和真实最优解决方案 \bar{y} 的目标值间的差距。损失函数定义为：

$$\mathcal{L}(\theta, \bar{y}) = \theta^T g(y) + h(y) - (\theta^T g(\bar{y}) + h(\bar{y})),$$

其中 $\theta^T g(y) + h(y)$ 编码了简化 CO 问题的目标。

在 CO 增强的 ML 中，一个关键挑战在于组合目标的不可微性，这些目标通常是分段常数的，几乎到处是梯度消失的。为了解决这个问题，在训练期间使用概率代理方法来近似梯度 [95]。这些技术在数据稀缺的环境中展示了有前途的结果，包括 AMoD 调度任务 [88], [96]。

虽然 RL 和 CO 丰富的 ML 都旨在将问题配置（状态）映射到操作决策（动作），但它们的学习动态有显著不同。在 RL 中，学习信号通过直接映射到控制动作的价值函数或策略传播。在 CO 丰富的 ML 中，学习信号通过优化问题本身的参数化传播，有效地学习如何构建仍能产生高质量解决方案的更简单问题。这通常会在事先知道最优或近似最优解决方案时导致更高效的样本训练 [95]。最近，首次有工作提出将 CO 丰富的 ML 嵌入到 RL 范式中，这允许结合两种方法的优势 [97]。

在混合方法中，再现性依赖于对优化和学习如何结合的明确说明。必须记录的关键方面包括：a) 优化模型的结构和约束，b) 学习在参数估计、目标塑造或问题简化中的作用，c) 模型架构、训练数据集和损失函数（针对学习组件），d) 用于训练的算法，以及 e) 用于比较的评估指标和基线。在两个模块之间良好记录的分配资源对于解释结果和在未来工作中实现重用至关重要。

B. 启发式方法

除了目前介绍的范式之外，关于 AMoD 控制的研究主要集中于开发针对具体问题设置或系统特性量身定制的特定启发式方法。这些方法通常旨在解决难以在标准框架中捕捉的挑战，例如高度局部化的动态、非均匀的需求分布或计算约束。例如，[98] 提出了一个针对高级旅行预约系统的两阶段解决方案：短期路由决策通过优化来进行，而长期路线设计则使用一种以短期结果为基础的启发式方法。或者，[99] 引入了一种层次化的控制策略，其中高级别的基于学习的控制器管理区域间的再平衡，而低级别的覆盖控制算法则管理每个区域内细粒度的车辆移动。Ruch 等人 [70] 通过一种策略来解决空间相关的需求，该策略向单个请求派遣多辆车辆，以增加响应能力，特别是在需求突增或不确定的地区。其他研究关注通过加速优化的启发式方法 [42], [49], [100], [101] 或通过实施基于规则的策略 [39], [68], [102], [103] 来提高计算效率，从而减少实际部署中决策的复杂性。

由于启发式算法具有特定领域的性质，因此明确说明问题设置、假设和其预期的应用场景尤其重要。这样做有助

于澄清其贡献，理解其性能在何种情境下适用，并指导未来的研究者识别这些方法在何时可能是合适或可扩展的。

对主要 AMoD 研究的总结，包括其建模框架、操作重点、约束条件和算法方法，在 Table I 中提供。

IV. 建模假设

假设在塑造 AMoD 算法的设计中扮演着关键角色。通过缩小所提方法的潜在用例范围，它们补全了模型。在本节中，我们讨论了 AMoD 研究中常见的核心假设，以突出实验设置与现实世界场景之间的差距。在研究报告中清晰地指定这些假设对于有效的基准测试以及不同工作的比较来说是至关重要的。

A. 需求建模

客户需求在制定运营决策中起着关键作用，正如在 Section III 中讨论的那样。可以对需求行为做出各种假设，每种假设都会影响建模方法和决策过程。

1) 时变与时不变：时间变化的需求随着时间的推移而波动，反映现实世界的动态。需求可以根据旅行模式随时间变化，或者受 AMoD 运营（即根据可用车辆而变化的弹性需求）的影响。相比之下，时不变需求在时间上是恒定的。这一假设常用于排队理论模型中，以估计预期等待时间和建立均衡条件 [11], [12]。当需求逐渐变化时，此假设是合理的，这在密集的城市环境中常常被观察到 [124]。

2) 确定性与随机性：确定性需求被假设为准确已知的，或者直接从历史数据中得出，或者通过能够提供准确预测的预测模型获得。而随机需求考虑的是乘客到达遵循随机过程，通常利用泊松过程 [16], [48], [52], [103]。此类假设在排队理论模型和将乘客到达视为排队系统一部分的研究中无处不在。AMoD 研究中关于交通需求的假设类似于电网控制或通信网络研究中关于需求的假设。明确这些假设同样会影响这些研究的可重复性。

交通拥堵是交通管理中的关键方面，因为它导致排放增加和生产浪费。在大多数控制研究中，假设拥堵是外源性的（即，不受车队运营影响），无论运营如何，旅行时间保持固定。如果车队仅占整体交通的一小部分比例，并且不会显著影响网络条件，这一假设成立。然而，随着车队规模的增加，运营可能对拥堵产生实质性贡献。在这种情况下，有必要建模内生拥堵，即车队的活动影响网络的动态。文献中提出了多种方法，并在以下段落中进行了概述。

在这个简化模型中，车辆以自由流动速度行驶，只要流量保持在给定路段的预定义临界流量阈值以下。当操作超过此阈值时，施加流量限制。该方法植根于经典交通流理论，当目标是防止拥堵的发生而不是模拟其全动态时，此方法是有效的。

该模型是用于在系统中建模拥堵的最广泛使用的方法。它在 [104] 中开发，表达了交通流量和旅行时间之间的关系：

其中是道路上的自由流动旅行时间，是道路上的交通流量，并表示道路的容量。通过跟踪每个链路上的流量，该模型捕捉了拥堵对旅行时间的影响，使其成为一种被广泛采用且计算效率高的方法。

3) 宏观基础图：模型描述了交通流、密度和速度在交通网络中的关系 [99]。流速 Macroscopic Fundamental Diagram (MFD) 根据特定链接的交通流解锁速度估计，然后用于计算旅行时间。不像 Bureau of Public Roads (BPR) 模型，MFD 必须为每个特定网络使用链接和交叉点参数构建。在 [125] 中首次提出了近似 MFD 的分析方法。

TABLE I: 先前关于使用不同方法进行 AMoD 控制的工作。

System model			Operations			Constraints			Algorithm				Reference
N	Q	V	Matching	Rebalancing	Ridepooling	Charging	Parking	Fleet	O	L	Combined	Customized	
✓			✓						✓				[16]
✓				✓					✓				[19], [48], [64], [65], [104], [105]
✓				✓				✓	✓				[48]
✓			✓	✓					✓				[20], [64], [77], [78], [106], [107]
		✓	✓					✓					[23]
		✓	✓							✓			[21], [94], [108]
✓		✓	✓	✓	✓				✓			✓	[22], [109], [110]
✓			✓	✓					✓				[99]
✓			✓	✓					✓				[111]
✓	✓		✓	✓			✓		✓				[12]
✓		✓	✓	✓						✓			[96]
✓		✓	✓	✓						✓			[24]
✓		✓	✓	✓	✓							✓	[100], [112]
	✓		✓	✓					✓				[113]
	✓		✓	✓			✓		✓				[10], [11], [114]
✓			✓	✓	✓			✓				✓	[51]
✓			✓	✓	✓			✓				✓	[39]
✓			✓	✓	✓			✓				✓	[49]
✓			✓	✓	✓		✓		✓			✓	[59]
		✓	✓	✓	✓							✓	[68]
		✓	✓	✓	✓					✓			[85]
✓		✓	✓	✓	✓				✓				[115], [116]
		✓	✓	✓								✓	[69], [102], [103]
		✓	✓	✓								✓	[70], [98]
✓			✓	✓				✓	✓				[50]
✓			✓	✓	✓				✓				[38]
		✓	✓	✓			✓		✓				[34], [117]
✓		✓	✓	✓								✓	[118]
		✓	✓	✓					✓				[119]
		✓	✓	✓					✓				[83], [120]
		✓	✓	✓	✓		✓			✓			[121]
✓			✓	✓			✓		✓				[76]
✓			✓	✓	✓		✓		✓	✓			[84]
		✓	✓	✓	✓				✓		✓		[26]
		✓	✓	✓	✓					✓			[40]
		✓	✓	✓	✓					✓			[41], [43]
		✓	✓	✓	✓							✓	[42]
✓		✓	✓	✓	✓			✓	✓				[45]
		✓	✓	✓	✓		✓	✓	✓				[58]
		✓	✓	✓	✓		✓	✓	✓				[47]
		✓	✓	✓	✓		✓					✓	[101]
✓		✓	✓	✓	✓		✓	✓	✓				[52]
		✓	✓	✓	✓				✓	✓			[122]
✓		✓	✓	✓	✓				✓				[123]
		✓	✓	✓	✓					✓			[66]
		✓	✓	✓	✓		✓				✓		[25]

- ¹ In the system model column, “N” represents “Network flow”, “Q” represents “Queue-theoretical”, and “V” represents “Vehicle-centric”.
² In the constraints column, “Fleet” means that the number of vehicles appears as a constraint or decision variable in the model explicitly.
³ In the algorithm column, “O” represents “Optimization” and “L” represents “Learning”.

4) 单元和链路传输模型：模型通过将其离散化为等长单元来模拟单一道路段的交通演变 [29], [59], [100], [126]。单元的数量取决于自由流速和时间间隔的持续时间。拥堵通过瓶颈扩散到单元中，动态降低车辆速度。Link Transmission Model (LTM) 简化了 Cell Transmission Model (CTM)，通过仅在每个链接的上游和下游端追踪车辆，降低了计算复杂性 [127]。

虽然目前现有研究中提出的大多数操作政策通过声称服务的渗透率较低而忽略了拥堵效应，但随着 AMoD 份额的增加，拥堵效应将变得显著且不可忽视。实际上，由于再平衡和空驶行程，AMoD 已被证明可能导致车辆行驶距离和拥堵水平的增加 [128]。拥堵效应的一个重要方面是诱发的碳排放。交通运输部门是全球碳排放快速增长的贡献者之一，而在美国，80% 的交通部门排放来自个人地面交通 [129]。强烈建议未来的研究考虑 AMoD 对道路使用的影响，并设计算法将该影响限制在合理水平。

B. 对乘客进行建模

模拟乘客如何对系统性能作出反应是很重要的，特别是关于需求弹性。当需求是没有弹性时，乘客会一直留在系统中直到与车辆匹配。然而，在多模式交通系统中，由于存在替代出行选项，乘客可能会因为过长的等待时间或增加的旅行成本而放弃该系统。弹性需求可以通过多种方式建模，下面将对此进行描述。

在这里，乘客对时间很敏感，如果他们在请求行程的相同时间窗口内没有被匹配到，他们就会退出系统。这被称为拒绝模型，即如果乘客的请求被拒绝，他们就会离开。这类模型在要求高服务可靠性的系统中特别相关。

在这里，乘客将留在系统中，直到他们的等待时间超过一个预定义的最长等待时间或指定的接送间隔 [19], [25], [84], [108], [120], [122]。否则，他们将放弃该系统。

只有当乘客的行程能够在指定的下车时间 [22], [42], [43] 之前完成时，他们才会被匹配。否则，他们将在系统中保留，直到其最晚可接受的上车时间过期。

1) 选择模型：乘客基于效用函数进行旅行决策，该效用函数综合考虑了等待时间、费用和服务质量等因素 [40], [130], [131]。该模型提供了对人类决策过程的更现实的近似，并允许以概率方式表示乘客行为。将选择模型整合到 AMoD 控制模块中是一个新兴且有前景的研究方向。在应用时，需要报告旅行属性对选择的弹性，比如时间价值，以证明乘客行为的合理性，并澄清控制行为影响的范围。

由于在操作计划过程中未来需求未知，但对于非短视决策至关重要，因此采取了各种策略来获取需求信息。首先，可以利用历史数据，直接使用过去的需求作为未来需求的替代，或者使用预测模型。此方法通常需要高质量的数据和准确的预测，这使得它往往不太实用。即使有高质量的数据，基于历史需求的预测也可能有偏差，因为历史需求通常高度依赖于历史供给。在这种情况下，需要采取截断

需求预测, 以提供考虑潜在需求的无偏估计 [132]。

为了减轻对准确预测的依赖, 可以设计稳健算法来处理预测不确定性。具体来说, 在基于优化的方法中, 稳健优化通过基于潜在需求分布 [74], [84] 或不确定集合 [78] 的最坏情况性能来优化决策, 提高解决方案的稳健性。

当未来的需求或需求分布未知且难以预测时, 有两种可选方法: 可以在观察到新的乘客到达时动态运行确定性优化问题 (实时优化), 或者, 替代地, 使用 RL, 因为 RL 通过训练政策以最大化多步时间内的期望回报, 本质上考虑了随机性, 而不需要明确知道系统动态。

如前所述的假设通常可以从模型和实验部分推断出来, 即使它们没有被明确说明。例如, 拥堵假设和乘客模型有时是被集成为系统模型和算法设计中的约束的重要组成部分, 需求假设可以从实验设置中推断出来。然而, 我们鼓励在问题定义中明确说明这些假设。这样做允许读者在无需彻底审阅整个工作的情况下快速识别研究工作的应用场景, 从而促进更容易和更快速的基准测试。

在前面的章节中, 我们已经介绍了与研究相关的方法学方面。在进行实验以测试所提出的方法之前, 建立评估标准是至关重要的, 因为它们在基准测试和展示特定方法的贡献中起着基础性作用。在这一节中, 我们主要关注与控制有关的重要基准测试标准。关于不同系统的基准测试的一般指南可以在 [133] 中找到。

控制系统的任务在计算上是一个繁重的任务, 这主要是由于系统规模和潜在的交互程度。在这种情况下, 计算复杂度是决定实际应用和相对于最新技术提高的关键因素。具体而言, 几个指标通常被用于比较。作者通常参考绝对解决时间, 或者实时最优性, 在操作时间限制内评估解决方案的质量。进一步的指标包括收敛性能 (例如, 对于学习方法) 和计算复杂度的可扩展性分析。另一种直接评估算法的方法是通过衡量其相对于定义的控制目标的性能, 正如在 Section III 中讨论的那样。常用的指标包括平均旅行时间、旅行距离、服务率和收入。重要的是, 指标的选择应与模型假设保持一致。例如, 如果一个模型施加了最大等候时间或服务窗口, 仅用平均等候时间的概念可能不足以全面反映服务质量。在这种情况下, 可以另外考虑服务率, 同时考虑封顶的等候时间。此外, 在没有严格等候时间限制的模型中, 一些乘客等待时间显著长于其他人的异常值可能会被平均值所掩盖。关键是, 这可能引入公平性问题, 需明确承认。揭示此类差距是否存在的一种方法是报告 95% 分位数的等待时间, 正如在 [134] 中建议的那样。

展示性能提升不仅需要展示效率增益, 还需要在不同场景中建立这些改进的稳健性, 从而确保新方法的泛化能力。具体来说, 稳健性可以通过敏感性分析来验证, 评估在不同条件下的性能变化, 包括需求模式 [66], [120]、算法特定参数 (即, AV 渗透率 [44]、容量 [42]) 和车队规模 [98], [103]。报告性能提升的稳健性及其影响因素对于结果的可复制性至关重要。

随着 AMoD 的采用率增加, 它开始影响整个交通网络。对 AMoD 的一个常见批评是其可能增加道路拥堵。因此, 一个提出方法的重要贡献可能是展示其在保持服务效率的同时减轻交通影响的能力。这种影响可以通过检查道路利用率 [11], [12], [100], [135] 和旅行时间 [29], [64], [122] 来评估。

另一个重要但未充分研究的话题是控制算法对公平性的影响。在 AMoD 控制的背景下, 开发特别关注服务公平的算法有助于创建公平的交通系统。值得一提的是, 公平并不意味着对所有人进行平等分配。这更关注于根据不同社会群体的需求和能力来分配资源 [136]。

具体来说, AMoD 对公平性的影响涉及多个因素, 其

中包括服务的可用性和可负担性。如在 ?? 节中讨论的, AMoD 控制目标主要集中在时间和货币指标上。如果没有关注公平性, 设计的算法不可避免地会优先考虑在较短时间内提供更高利润的行程。大多数与公平性相关的 MoD 研究主要集中在通过设计以公平性为重点的服务指标来量化公平影响, 并评估所提出的控制算法的影响 [137], [138]。下一步将是推动以公平性为中心的算法, 这是 AMoD 研究社区一个新颖且重要的研究课题。

V. 实验

实验设计在验证提议的方法中起着核心作用, 并且是可重复研究的基石。重复性依赖于实验结果的可复制性以及从中得出的结论的有效性, 这又要求结构良好且透明记录的实验设置。在本节中, 我们识别并讨论实验设计的关键组成部分, 这些部分影响了 AMoD 控制研究中的可重复性。此外, 我们提供了一份经过精心挑选的公开可用数据集和模拟器列表, 以支持标准化的实验并促进未来的基准测试工作。

A. 需求数据集

行程记录数据是 AMoD 控制研究中最常用的数据类型。此类记录通常包括接送时间和地点、行程距离, 有时还包括附加的元数据, 如票价金额和支付类型。多个公开可用的数据集已经成为该领域的事实标准, 支持各种模拟和验证工作。

1) 纽约出租车 & 豪华轿车委员会 (TLC) 数据: 这是 AMoD 研究中最广泛使用的数据集 [139]。它提供了纽约市五个行政区 (曼哈顿、布朗克斯、布鲁克林、皇后区和史坦顿岛) 的详细行程级数据, 其中曼哈顿是文献中研究最多的区域。自 2009 年以来, 该数据集包括黄色和绿色出租车行程, 并在 2019 年开始还包括被归类为“租赁车辆 (FHV)” 标签的网约车记录 (如 Uber 和 Lyft)。为了保护隐私, 位置信息使用预定义的出租车区进行了匿名化处理, 并且相关的形状文件和区域地图可以通过 TLC 网站轻松访问。TLC 数据集由于其丰富的元数据和维护良好的文档而备受珍视, 这减少了研究人员详细描述预处理步骤的负担。此外, 该数据集每月更新, 确保其持续相关性并最大限度地减少关于数据过时的担忧。

纽约市数据的另一种变体由伊利诺伊数据银行托管。该集合包含 2019 年至 2013 年的出租车行程记录, 这些数据最初来自纽约市出租车与礼车委员会。与更新的 TLC 数据中的区域表示不同, 该数据集包括用于上下车地点的原始 GPS 坐标。它已在某研究中使用, 并且附带的预处理脚本是公开可用的, 为从事基于 GPS 的移动数据研究的科研人员提供了一个可重复的分析流程。

2) 旧金山出租车轨迹数据: 这个数据集 [140] 提供了 2008 年 5 月至 6 月间约 500 辆出租车的 GPS 轨迹。除了位置信息外, 它还包括一个“乘客”标志, 用于指示出租车是否载有乘客。这使得能够从连续轨迹数据中重建行程。尽管较旧, 这个数据集在多个 AMoD 研究中被利用 [70], [116], [118], 尤其是用于评估在空间异质性和需求不平衡场景中的算法。

3) 苏福尔斯数据: 一个更合成的数据集是基于苏福尔斯交通网络的, 这个网络包含在一个经典交通基准数据库中 [141]。这个数据集提供了没有时间分辨率的静态 OD 流数据, 原本用于研究交通分配。尽管其简单性和缺乏现实性, 苏福尔斯网络已在几个 AMoD 控制论文中使用 [45], [68], 常用于在受控环境中调试或测试算法, 因为它体积小且拓扑结构清晰。

为了确保可重复性和社区的可比性, 研究人员被鼓励使用公开可用的数据集, 这些数据集被积极维护。Fig. 4 展

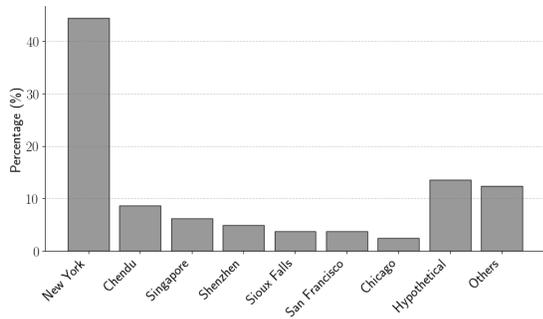


Fig. 4: AMoD 案例研究中使用的网络分布。

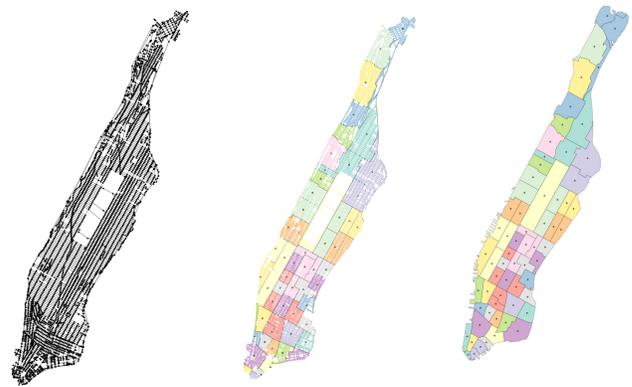
示了在所审查研究中的 AMoD 研究案例研究中使用的网络。纽约是使用最广泛的网络，因为该数据集被积极维护且公开可访问。NYC TLC 数据集提供了一个强有力的基准，其影响类似于 ImageNet [142] 和 KITTI [143] 在计算机视觉和机器人领域加速了进展。我们还提供工具以基于这些数据集在 <https://github.com/mit-zardini-lab/scenario-generation> 生成现实的 AMoD 场景。

同样值得注意的是，尽管深圳网络被用于许多研究中，但其数据来自滴滴在 2016 年发布的一个挑战 [144]，且不再在原始网站上公开维护或可获得。此外，许多论文使用了特定城市的网络或专有数据集（在 Fig. 5c 中分类为“其他”）这些数据集并不公开可访问 [13], [76], [85], [99], [101], [104]。在这种情况下，如果数据集无法共享，作者至少应提供详细的元数据和高层次的总结，例如空间覆盖范围、时间跨度、需求分布和采样频率，以便他人能够构建可比的实验场景。

最后，数据预处理是一个关键步骤，它常常没有被详细报道。清洗过程、采样、路径过滤或需求聚合都可能显著影响实验结果。特别是对于基于网络的研究，网络图有时会被裁剪，以加速获取结果的计算，但这通常没有被提及。为了支持可重复性，任何偏离原始数据集的预处理步骤都应该被清晰记录。这包括阈值化、区域聚合、图裁剪、轨迹简化或噪声去除技术，这些细节在当前研究中常被忽略，但对于公平比较和复制是至关重要的。

在现实世界的交通系统中，交通流量沿着连接详细城市网络中交叉路口的道路链接流动。此类链接的数量及其互动的复杂性显著影响控制问题 AMoD 的规模。为了管理实验设置中的计算复杂性，研究人员通常将道路层面的细节聚合为更高层次的抽象，通常以区域或站点的形式，在这些区域之间假设车辆移动，而不是单独的道路段。实验中使用的网络表示的粒度是一个关键设计选择。它影响模拟的保真度以及所提出算法的可扩展性 [91]。

如 Fig. 5 中所示，现有研究在如何建模基础网络上差异显著。这些差异大致可以分为三个减少粒度的层级。最高级别的细节是基于节点的网络 (Fig. 5a)，在这里操作是在具有个别节点和连接的显式道路网络上进行建模的 [22], [93], [110]。这种方法提供了最现实的城市拓扑表示，特别适合高保真模拟。然而，它也带来了显著的计算需求，使得算法效率成为关键问题。更抽象的形式是混合网络模型 (Fig. 5b)，在这一模型中，如调度或再平衡等决策是在区域层面进行的，而车辆移动仍在完整的节点连接网络上模拟 [99], [105]。这种混合方法在再平衡研究中很常见，其中空闲车辆可以无需固定目的地重新定位。它在操作现实性与易处理的决策之间取得了平衡，使其在准确性与扩展性之间成为实用的折中。最后，最简化的表示是基于区域的网络 (Fig. 5c)，其中操作和车辆移动都是在区域层面进行建模的。上下车位置被聚合，区域内部旅行动态被忽



(a) 基于节点。 (b) 混合。 (c) 基于区域。

Fig. 5: 纽约市的不同网络粒度。

略。这种抽象在 AMoD 控制研究中最常用，因为其简单性和减少的计算开销，适合评估高级政策或进行大规模敏感性分析。

在基于区域的实验中，用于将网络划分为不同区域的方法在确定模拟的空间分辨率方面起着关键作用。尽管这一点非常重要，但在许多已发表的论文中，这一方面常常被低估或完全忽视。区域的数量和布局直接影响实验的准确性、操作决策的细粒度程度，以及最终对控制算法性能的感知。通常有三种主要方法用于定义区域划分。第一种方法利用政府机构定义的行政或人口普查区域 [111]。这些划分提供了一种一致和政策一致的地理结构，但可能与实际需求模式或出行行为不一致。第二种方法使用无监督学习技术对旅行需求进行聚类，最常见的是 k-means 聚类 [34], [50], [64], [118]。在这些情况下，明确指定簇的数量（即区域数）的选择方法非常重要。这个数字可以从外部来源得出，例如城市的邮政编码数量 [48]，或者在内部进行优化，例如确保一个区域内的所有节点都能从该区域的中心到达 [26]。第三种方法是将网络离散化为固定大小单元的均匀网格 [41], [85], [119]。这种方法简单易行，特别是在需要有效空间索引或整合基于栅格数据的模拟中。然而，网格的大小和形状显著影响实验的分辨率和现实性，因此应始终明确报告。

选择合适的粒度水平涉及在建模逼真性和计算效率之间进行权衡。因此，研究人员必须清楚地报告他们在实验中使用的粒度，并结合预期范围、评估指标和算法假设对此进行解释。

由于 AMoD 控制策略旨在优化系统在较长时间范围内的性能，因此模拟控制动作如何随时间影响系统动态至关重要。模拟器是任何实验流程的骨干，但在现有的许多 AMoD 研究中，模拟的细节记录不够详尽或未公开提供 [8]。缺乏透明性对可重复性构成了主要障碍。明确记录模拟环境的假设、参数和状态转换逻辑，对于允许复制研究结果并促进不同研究之间的有意义比较至关重要。

总体而言，AMoD 研究中的仿真分为两种形式：针对特定实验设置量身定制的仿真器，以及提供更广泛功能和更高保真度的通用交通仿真器。在开发定制仿真器时，研究人员应提供详细的仿真流程描述，包括如何随时间建模车辆状态、乘客行为和网络演变。这种做法的良好示例包括 [74], [100]，作者使用流程图和专门部分清晰地传达其仿真框架。另一个记载良好的仿真器的好做法是在 [145] 中，

作者提供了开发的 AMoD 模拟器不同模块和可用功能的详细文档。源代码和用户指南也被提供。与定制仿真器相反，由大型研究社区开发和维护的通用仿真器提供成熟的基础设施和广泛的文档。这些工具结合了广泛的功能和假设，通常在多个用例中得到验证。用于 AMoD 研究的最常用的通用仿真器将在下文详细介绍。

4) *MATSim* [146]: MATSim 是一个开源的、基于活动的微观模拟器，设计用于大规模、基于代理的交通建模。它使用基于队列的交通流模型模拟个体旅行者的行为，并根据被解读为效用模型的评分函数为代理分配计划。虽然 MATSim 并未明确模拟详细的跟车行为，但它有效地在大规模捕捉交通拥堵的影响。重要的是，MATSim 允许通过重写计划选择模块来集成自定义的 AMoD 控制算法。在执行代理计划后，它会更新链接的旅行时间，这些时间随后用于告知后续的决策窗口。该架构支持实时优化和迭代情景分析。

5) *SimMobility* [147]: SimMobility 提供了一个多尺度的模拟框架，能够模拟短期、中期和长期范围内的交互。其短期模块捕捉微观行为，如变道和刹车；中期模块侧重于路线和模式选择动态；长期模块模拟结构性趋势，如土地使用、车辆拥有和工作地点决策。尽管 SimMobility 已在 AMoD 控制 [148] 中使用，但它更常用于评估 AMoD 系统对可达性 [149], [150] 的系统性影响及与其他交通模式 [151], [152] 的交互。其捕捉行为适应和跨模式反馈的能力使其特别适合于城市规划和政策评估。

6) 求和 [153]: SUMO 是另一个强调可用性和可扩展性的开源微观模拟器。与 MATSim 类似，它支持大规模模拟，同时对计算需求相对较低。SUMO 的一个关键优势在于其丰富的辅助工具套件，可以基于真实世界的数据库构建模拟。它还具有一个 Graphical User Interface (GUI)，用于实时可视化模拟和调试控制逻辑。Python 绑定的可用性进一步提高了 SUMO 的多功能性，使其可以嵌入更广泛的研究流程中，并能轻松与优化或学习算法集成 [91]。

7) *AMoDeus* [154]: 这是一个为 AMoD 系统专门设计的模拟器。它建立在 MATSim 之上，为模拟和基准测试各种车队控制算法提供了一个统一的框架。AMoDeus 包含一个精心策划的最先进的 AMoD 策略库，包括对拼车和电动车队变体的支持。可用算法的完整列表维护在 [155]，这使得 AMoDeus 成为目前为 AMoD 实验提供的最具可重现性的平台之一。

在选择或开发模拟器时，考虑逼真度和透明度之间的权衡是很重要的。通用模拟器提供了真实感和强大的文档支持，但可能更难以针对特定的 AMoD 实验进行定制。自定义模拟器允许进行精细化控制和快速迭代，但需要细致的文档支持以确保可重复性。不论选择哪种，未来的研究应优先考虑清晰地传达模拟假设、设计的模块化，以及代码和场景定义的公开获取。

B. 参数值

进行受控实验时，需要仔细指定模拟器和算法参数。在这些参数中，车队规模是一个影响巨大但经常未被充分报告的参数。系统中车辆的数量直接影响系统性能指标，如等待时间、车辆利用率和再平衡效率。因此，车队规模的选择不应该是随意的；它应该由明确的标准推动，并在实验设置中明确说明。

不同的研究采用多种策略来确定车队规模。一些研究旨在提供足够的车辆以满足所有需求 [100]，另一些则针对性能保证，例如限制乘客的最长等待时间 [39]，或确保拥有足够的闲置车辆以实现有效的再平衡 [83]。一种更稳健且被广泛采用的方法是评估算法在不同车队规模下的表现 [12], [24], [34], [96]。这不仅展示了算法的可扩展性

和普通性，还帮助识别出算法最有效的场景。所选择的车队规模，与实验数据集的规模和结构一起考虑时，提供了关于所提算法适用性的关键洞见。报告两者有助于读者理解操作环境并评估在实际场景中部署的潜力。此外，这也显示了算法的可扩展性以及在未来研究中扩展的适用性。

除了车队规模，许多其他参数，例如成本系数、车辆速度、需求弹性和特定算法的超参数，在塑造系统行为和结果方面起着关键作用。这些值应系统地呈现出来，理想情况下表现为一个参数表，该表应包括 i) 参数名称，ii) 实验中使用的值，以及 iii) 选择它的理由。提供这样的详细信息有两个关键目的：它通过允许其他研究人员精确复制结果来支持可重复性，并通过帮助其他人在将该方法信心十足地转移到新数据集或情境中实现可适应性。因此，彻底记录参数设置不仅是良好的实践，而且对于在 AMoD 研究中建立可信且可重用的工作体至关重要。

当算法或模拟器中存在随机性时，即使在相同的实验设置下，不同运行的结果也会有所不同。对于采用 ML 的数据驱动控制算法尤其如此，此类算法对训练条件和随机组件（例如，初始化、采样、探索）的敏感性可能导致显著的性能波动 [89]。为了确保结果的可信性和可重复性，有必要报告基于多次独立实验的性能统计数据。特别是，随机种子的均值和标准差等指标可以定量衡量算法的鲁棒性及其对随机变化的敏感性。这种做法在许多领域（例如 ML）已被广泛认同，作为证明所报告性能的稳定性和可推广性的一项标准 [156]。

除了本文中讨论的方法学透明性之外，代码的可用性和清晰性对于 AMoD 研究的可重复性至关重要。如果代码是公开可用的，那么代码的可重复性意味着能够使用原始代码库和文档重新生成已发布的结果，理想情况下无需深入了解底层实现。为了实现这一目标，代码库应该包含一个清晰的入口点（例如，README 文件），明确指定数据来源（或描述元数据如果数据不能共享），提供环境设置说明（例如，需求文件或 Docker 容器），并包含如何运行实验的可执行示例。此外，为了使将来扩展或调整到新的问题设置更为方便，建议作者对其代码库进行模块化，遵循既定的风格惯例，并提供清晰的内联文档。

另一方面，当代码不可公开访问时，可重复性指的是独立研究人员能够重新实现和验证所提出的方法或框架的能力，使用原始出版物中提供的材料，如论文、附录和补充文档。在这种情况下，这些材料必须包括对所有算法步骤的明确解释（例如，组织良好且清晰的伪代码），任何非简单的工程决策或系统级依赖的说明（例如，对原始实现中使用的外部库或求解器的引用），以及重建实验设置的足够信息（例如，超参数配置和数据预处理步骤）。这些要素有助于确保其他研究人员能够复制原始工作，而无需逆向工程原始工作的所有实现细节。

最近，ML 和系统研究领域的努力强调了可重复代码的重要性，并导致了分享开源软件的更强规范。读者可以参考 [7]，这提供了一个动手教程以改善控制和学习管道中的可重复性和可复制性。在 AMoD 领域，[157] 展示了可重复性最佳实践的一个强有力例子，其代码库文档齐全，模块化组织，并与这里概述的许多指南保持一致。

最后，值得强调的是，代码自身的可获取性仍然是一个显著的瓶颈。在许多研究中，即使方法论可靠且结果明确，可访问代码的缺乏仍然阻碍了验证、扩展和采用。因此，开源代码的发布，加上简要而维护良好的文档，应该被视为该领域研究的标准期望。

在多模式运输系统中，AMoD 服务与包括公共交通 [158], [159]、电网 [160], [161] 和其他运输方式 [162] 等广泛的外部系统和基础设施互动。此外，还可能在多个竞争或合作的移动服务提供商 [163] 之间发生互动。准确建

模此类互动对于评估 AMoD 部署的系统性影响至关重要，并且是其成功整合到现有城市基础设施的关键一步。这种互动的建模再次应在方法论中明确形式化，因为它显著影响分析的真实性和可解释性。

在 AMoD 研究中，最广泛研究的交互之一是 AMoD 与公共交通的融合。这种融合通常以两种形式建模：作为一种连接乘客到现有交通服务的首公里/末公里解决方案 [164]，或者作为一种完全多式联运系统，其中 AMoD 和公共交通被联合优化以提供端到端移动性 [135], [158], [159], [165]。早期关于这种融合的研究依赖于基于仿真的方法 [166]；然而，这些方法往往缺乏形式化，并且在不同场景中难以推广。为了解决这些限制，最近的工作引入了正式的多式联运网络模型 [135], [165]。在这些公式中，AMoD 和公共交通系统被表示为时间扩展图中的不同层。节点代表站点或车站，弧表示在模式内和跨模式的移动。模式转换通过层间弧捕捉，从而使多模式行程的显式建模成为可能。这种基于图形的结构通过 MPC 支持非目光短浅的控制，简化了跨两种模式的协调、预测性决策。

在固定基础设施下超出控制范围的扩展中，[167], [168] 提出了一个共同优化 AMoD 和公共交通的联合设计框架。该方法不是通过一个单一的优化问题来整合模式，而是将系统分解为相互连接的子设计问题。通过共享限制（如共享需求或资源限制）来捕捉互动行为，使得在无需完全集中化模型的情况下实现可扩展的协调。这种构成观点支持模块化设计，并为跨复杂分层运输生态系统的协调决策开辟了新的可能性。该框架可以延伸至未来移动系统的建模，其中 AMoD 的设计需要与各种其他模式协调，否则简单地将其作为替代品而非整合可能导致公共交通客流的蚕食 [151]。AMoD 支持的多模式运输系统的联合设计可以提供有用的见解，说明如何将 AMoD 可能地集成到未来移动系统中。现有关于 AMoD 与其他模式之间交互的研究集中于特定结构的问题，无法无缝延展到不同场景。联合设计原则允许复杂系统的模块化和构成设计，是通用设计框架的潜在方向 [167], [169]–[171]。

第二个主要的互动领域源于电动 AMoD 车队与电网的集成 [160], [161]。这种耦合来自 EVs 的双重角色：它们既作为移动代理，又作为电力负载。一方面，大规模 EV 充电可能会给地方配电网带来压力，并影响电网的稳定性。另一方面，定价机制或需求侧管理政策可以塑造 E-AMoD 的路由和充电行为。通过价格响应控制、负载平衡或对电网敏感的车队重新平衡，与电网协调运作的 E-AMoD 系统，为在不断电气化的环境下确保交通效率和电力系统可靠性提供了一个有前景的方向。

除了与公共交通和电网的互动之外，作为未来移动网络中设想的重要模块，AMoD 的设计也应考虑各种交通方式之间的互动。AMoD 的设计应与其他模式协调，简单地将其用作替代而非整合可能会导致公共交通客流量的减损 [151]。采用 AMoD 的多模式运输系统的协同设计可以为 AMoD 如何可能被整合到未来移动系统中提供有用的见解。现有关于 AMoD 与其他模式之间互动的研究主要集中于特定结构的问题，无法无缝扩展到不同的场景。开发可普适设计框架的一个潜在方向是遵循范畴论中的协同设计原则，该原则允许复杂系统的模块化和组合设计 [167], [169]–[171]。

另一个有趣的研究问题是多模式运输网络中出现的模式选择问题。在现有的多模式运输网络中，乘客根据他们的偏好来选择出行方式，这种偏好受到社会人口学因素和旅行时间、成本等旅行特定因素的影响。用户偏好通常通过选择模型 [172], [173] 来捕获。由于乘客的选择代表了不同运输方式之间相互作用的重要方面，结合乘客选择模型有助于更准确地建模 AMoD 控制算法在现实中的潜在性能

[174]。

VI. 结论：迈向可重复的 AMoD 研究文化

AMoD 系统处于机器人、控制、交通和优化的交叉点，借鉴了一套丰富的方法论。然而，这种多样性导致了在假设、实验设置和算法细节的文档记录中出现碎片化实践，给再现性带来了巨大障碍。在本文中，我们朝着解决这一差距迈出了关键的一步。通过剖析 AMoD 研究流程，从建模和算法设计到实验评估，我们识别出了再现性常常出现问题的核心组件。

为了推进更可重复的研究文化，我们推荐以下关于在研究传递中需要指定组件的实用指南：

- 1) 用于表示 AMoD 的系统模型。
- 2) 具体操作及相关约束。在描述操作时，请根据第 II-A 节提供的定义，确保术语简明扼要。
- 3) 控制问题的目标。
- 4) 关于需求、拥挤、乘客模型和不确定性的假设。
- 5) 用于推导该解的算法。
- 6) 详细的实验设置，应包括：
 - 所使用数据集的描述和预处理步骤，以及源链接。
 - 仿真环境。
 - 网络的粒度水平。
 - 模拟和算法参数，包括特定参数值的合理性理由（如果适用）。
 - 评价算法的标准应与研究中陈述的贡献相一致。

除了论文之外，代码是 AMoD 研究的另一个重要成果。然而，在交通研究中共享代码还没有成为一种规范 [8]。为了确保可重复性，代码应该遵循以下指南：

- 1) 代码应公开可用。
- 2) 应包含一个详细的 README，其中有关于设置环境和运行实例的分步说明。
- 3) 代码应模块化、文档齐全，并遵循风格约定。

我们的核心信息很明确：可重复性不是一个次要问题，它是严谨科学的基础原则。没有它，创新就难以验证、比较或建立在其基础之上。有了它，我们可以创建一个透明、合作和可扩展的研究生态系统。

虽然我们的重点是 AMoD，但我们倡导的原则自然可以扩展到涉及网络自主、多模式移动性和数据驱动控制的其他领域。我们鼓励研究人员、审稿人和出版商将可重复性视为共同责任，并将其嵌入实验设计中，而不仅仅是事后的考虑。

REFERENCES

- [1] G. Zardini, N. Lanzetti, M. Pavone, and E. Frazzoli, “Analysis and control of autonomous mobility-on-demand systems,” *Annual Review of Control, Robotics, and Autonomous Systems*, vol. 5, no. 1, pp. 633–658, 2022.
- [2] M. R. Munafò, B. A. Nosek, D. V. Bishop, K. S. Button, C. D. Chambers, N. Percie du Sert, U. Simonsohn, E.-J. Wagenmakers, J. J. Ware, and J. Ioannidis, “A manifesto for reproducible science,” *Nature human behaviour*, vol. 1, no. 1, pp. 1–9, 2017.
- [3] R. D. Peng, “Reproducible research in computational science,” *Science*, vol. 334, no. 6060, pp. 1226–1227, 2011.
- [4] J. Leitner, A. W. Tow, N. Sünderhauf, J. E. Dean, J. W. Durham, M. Cooper, M. Eich, C. Lehnert, R. Mangels, C. McCool, et al., “The acrv picking benchmark: A robotic shelf picking benchmark to foster reproducible research,” in *2017 IEEE international conference on robotics and automation (ICRA)*. IEEE, 2017, pp. 4705–4712.
- [5] R. Baines, D. Shah, J. Marvel, J. Case, and A. Spielberg, “The need for reproducible research in soft robotics,” *Nature Machine Intelligence*, vol. 6, no. 7, pp. 740–741, 2024.

- [6] M. Fišar, B. Greiner, C. Huber, E. Katok, A. I. Ozkes, and M. S. R. Collaboration, “Reproducibility in management science,” *Management Science*, vol. 70, no. 3, pp. 1343–1356, 2024.
- [7] C. Wu, B. Ghosh, Z. Zheng, and I. Martínez, “Reproducibility in transportation research: A hands-on tutorial,” 2024. [Online]. Available: <https://www.rerite.org/itsc24-rr-tutorial/>
- [8] K. Riehl, A. Kouvelas, and M. A. Makridis, “Revisiting reproducibility in transportation simulation studies,” *European Transport Research Review*, vol. 17, no. 1, p. 22, 2025.
- [9] W. Tan, Y. Sun, Z. Ding, and W.-J. Lee, “Fleet management and charging scheduling for shared mobility-on-demand system: A systematic review,” *IEEE Open Access Journal of Power and Energy*, vol. 9, pp. 425–436, 2022.
- [10] R. Zhang, F. Rossi, and M. Pavone, “Analysis, control, and evaluation of mobility-on-demand systems: A queueing-theoretical approach,” *IEEE Transactions on Control of Network Systems*, vol. 6, no. 1, pp. 115–126, 2018.
- [11] R. Zhang and M. Pavone, “Control of robotic mobility-on-demand systems: a queueing-theoretical perspective,” *The International Journal of Robotics Research*, vol. 35, no. 1-3, pp. 186–203, 2016.
- [12] R. Iglesias, F. Rossi, R. Zhang, and M. Pavone, “A bcnp network approach to modeling and controlling autonomous mobility-on-demand systems,” *The International Journal of Robotics Research*, vol. 38, no. 2-3, pp. 357–374, 2019.
- [13] A. Braverman, J. G. Dai, X. Liu, and L. Ying, “Empty-car routing in ridesharing systems,” *Operations Research*, vol. 67, no. 5, pp. 1437–1452, 2019.
- [14] R. C. Larson and A. R. Odoni, *Urban operations research*. Prentice-Hall, 1981.
- [15] J. F. Shortle, J. M. Thompson, D. Gross, and C. M. Harris, *Fundamentals of queueing theory*. John Wiley & Sons, 2018, vol. 399.
- [16] M. Pavone, S. L. Smith, E. Frazzoli, and D. Rus, “Robotic load balancing for mobility-on-demand systems,” *The International Journal of Robotics Research*, vol. 31, no. 7, pp. 839–854, 2012.
- [17] J. Mölter, J. Ji, B. Lienkamp, Q. Zhang, A. T. Moreno, M. Schiffer, R. Moeckel, and C. Kuehn, “Public transport across models and scales: A case study of the munich network,” *PNAS nexus*, vol. 3, no. 11, p. pgae489, 2024.
- [18] B. Lienkamp and M. Schiffer, “Column generation for solving large scale multi-commodity flow problems for passenger transportation,” *European Journal of Operational Research*, vol. 314, no. 2, pp. 703–717, 2024.
- [19] K. Spieser, S. Samaranyake, W. Gruel, and E. Frazzoli, “Shared-vehicle mobility-on-demand systems: A fleet operator’s guide to rebalancing empty vehicles,” in *Transportation Research Board 95th Annual Meeting*, no. 16-5987. Transportation Research Board, 2016.
- [20] S. Wollenstein-Betech, M. Salazar, A. Houshmand, M. Pavone, I. C. Paschalidis, and C. G. Cassandras, “Routing and rebalancing intermodal autonomous mobility-on-demand systems in mixed traffic,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 8, pp. 12 263–12 275, 2021.
- [21] T. Enders, J. Harrison, M. Pavone, and M. Schiffer, “Hybrid multi-agent deep reinforcement learning for autonomous mobility on demand systems,” in *Learning for Dynamics and Control Conference*. PMLR, 2023, pp. 1284–1296.
- [22] J. Alonso-Mora, S. Samaranyake, A. Wallar, E. Frazzoli, and D. Rus, “On-demand high-capacity ride-sharing via dynamic trip-vehicle assignment,” *Proceedings of the National Academy of Sciences*, vol. 114, no. 3, pp. 462–467, 2017.
- [23] F. Boewing, M. Schiffer, M. Salazar, and M. Pavone, “A vehicle coordination and charge scheduling algorithm for electric autonomous mobility-on-demand systems,” in *2020 American Control Conference (ACC)*. IEEE, 2020, pp. 248–255.
- [24] Z. Woywood, J. I. Wiltfang, J. Luy, T. Enders, and M. Schiffer, “Multi-agent soft actor-critic with global loss for autonomous mobility-on-demand fleet control,” *arXiv preprint arXiv:2404.06975*, 2024.
- [25] L. Hu and J. Dong, “An artificial-neural-network-based model for real-time dispatching of electric autonomous taxis,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 2, pp. 1519–1528, 2020.
- [26] A. Wallar, M. Van Der Zee, J. Alonso-Mora, and D. Rus, “Vehicle rebalancing for mobility-on-demand systems with ride-sharing,” in *2018 IEEE/RSJ international conference on intelligent robots and systems (IROS)*. IEEE, 2018, pp. 4539–4546.
- [27] X. Li, C. Schmidt, D. Gammelli, and F. Rodrigues, “Learning joint rebalancing and dynamic pricing policies for autonomous mobility-on-demand systems,” *Available at SSRN 4798020*, 2024.
- [28] M. Schiffer, M. Schneider, G. Walther, and G. Laporte, “Vehicle routing and location routing with intermediate stops: A review,” *Transportation Science*, vol. 53, no. 2, pp. 319–343, 2019.
- [29] D. A. Lazar, E. Bıyık, D. Sadigh, and R. Pedarsani, “Learning how to dynamically route autonomous vehicles on shared roads,” *Transportation research part C: emerging technologies*, vol. 130, p. 103258, 2021.
- [30] D. Jalota, D. Paccagnan, M. Schiffer, and M. Pavone, “Online routing over parallel networks: Deterministic limits and data-driven enhancements,” *INFORMS Journal on Computing*, vol. 35, no. 3, pp. 560–577, 2023.
- [31] A. Coppola, G. Hiermann, D. Paccagnan, and M. Schiffer, “Staggered routing in autonomous mobility-on-demand systems,” *arXiv preprint arXiv:2405.01410*, 2024.
- [32] International Energy Agency, “Global ev outlook 2024: Moving towards increased affordability,” International Energy Agency, Tech. Rep., 2024, accessed: [Date]. [Online]. Available: <https://www.iea.org/reports/global-ev-outlook-2024>
- [33] R. Iacobucci, B. McLellan, and T. Tezuka, “Modeling shared autonomous electric vehicles: Potential for transport and power grid integration,” *Energy*, vol. 158, pp. 148–163, 2018.
- [34] —, “Optimization of shared autonomous electric vehicles operations with charge scheduling and vehicle-to-grid,” *Transportation Research Part C: Emerging Technologies*, vol. 100, pp. 34–52, 2019.
- [35] P. S. Klein and M. Schiffer, “Electric vehicle charge scheduling with flexible service operations,” *Transportation Science*, vol. 57, no. 6, pp. 1605–1626, 2023.
- [36] X. Bei and S. Zhang, “Algorithms for trip-vehicle assignment in ride-sharing,” in *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 32, no. 1, 2018.
- [37] S. Narayanan, E. Chaniotakis, and C. Antoniou, “Shared autonomous vehicle services: A comprehensive review,” *Transportation Research Part C: Emerging Technologies*, vol. 111, pp. 255–293, 2020.
- [38] C. Li, D. Parker, and Q. Hao, “Optimal online dispatch for high-capacity shared autonomous mobility-on-demand systems,” in *2021 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2021, pp. 779–785.
- [39] D. J. Fagnant and K. M. Kockelman, “Dynamic ride-sharing and fleet sizing for a system of shared autonomous vehicles in austin, texas,” *Transportation*, vol. 45, pp. 143–158, 2018.
- [40] Y. Kim, V. Jayawardana, and S. Samaranyake, “Learning-augmented vehicle dispatching with slack times for high-capacity ride-pooling,” *Available at SSRN 4801437*, 2024.
- [41] I. Jindal, Z. T. Qin, X. Chen, M. Nokleby, and J. Ye, “Optimizing taxi carpool policies via reinforcement learning and spatiotemporal mining,” in *2018 IEEE International Conference on Big Data (Big Data)*. IEEE, 2018, pp. 1417–1426.
- [42] A. Simonetto, J. Monteil, and C. Gambella, “Real-time city-scale ridesharing via linear assignment problems,” *Transportation Research Part C: Emerging Technologies*, vol. 101, pp. 208–232, 2019.
- [43] S. Shah, M. Lowalekar, and P. Varakantham, “Neural approximate dynamic programming for on-demand ride-pooling,” in *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 34, no. 01, 2020, pp. 507–515.
- [44] K. Yang, M. W. Tsao, X. Xu, and M. Pavone, “Planning and operations of mixed fleets in mobility-on-demand systems,” *arXiv preprint arXiv:2008.08131*, 2020.
- [45] D. Kang and M. W. Levin, “Maximum-stability dispatch policy for shared autonomous vehicles,” *Transportation Research Part B: Methodological*, vol. 148, pp. 132–151, 2021.
- [46] M. M. Vazifeh, P. Santi, G. Resta, S. H. Strogatz, and C. Ratti, “Addressing the minimum fleet problem in on-demand urban mobility,” *Nature*, vol. 557, no. 7706, pp. 534–538, 2018.
- [47] J. Ma, X. Li, F. Zhou, and W. Hao, “Designing optimal autonomous vehicle sharing and reservation systems: A linear programming approach,” *Transportation Research Part C: Emerging Technologies*, vol. 84, pp. 124–141, 2017.
- [48] M. Volkov, J. Aslam, and D. Rus, “Markov-based redistribution policy model for future urban mobility networks,” in *2012 15th International IEEE Conference on Intelligent Transportation Systems*. IEEE, 2012, pp. 1906–1911.
- [49] M. Li, N. Zheng, X. Wu, and X. Huo, “An efficient matching method for dispatching autonomous vehicles,” in *2019 IEEE*

- Intelligent Transportation Systems Conference (ITSC)*. IEEE, 2019, pp. 3013–3018.
- [50] K. Spieser, S. Samaranyake, and E. Frazzoli, “Vehicle routing for shared-mobility systems with time-varying demand,” in *2016 American Control Conference (ACC)*. IEEE, 2016, pp. 796–802.
- [51] S. Belakaria, M. Ammous, L. Smith, S. Sorour, and A. Abdel-Rahim, “Multi-class management with sub-class service for autonomous electric mobility on-demand systems,” *IEEE Transactions on Vehicular Technology*, vol. 68, no. 7, pp. 7155–7159, 2019.
- [52] G. Guo and T. Xu, “Vehicle rebalancing with charging scheduling in one-way car-sharing systems,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 5, pp. 4342–4351, 2020.
- [53] T. D. Chen, K. M. Kockelman, M. Khan, *et al.*, “The electric vehicle charging station location problem: a parking-based assignment method for seattle,” in *Transportation Research Board 92nd Annual Meeting*, vol. 340, 2013, pp. 13–1254.
- [54] L. Jia, Z. Hu, Y. Song, and Z. Luo, “Optimal siting and sizing of electric vehicle charging stations,” in *2012 IEEE International Electric Vehicle Conference*. IEEE, 2012, pp. 1–6.
- [55] H. Zhang, S. J. Moura, Z. Hu, and Y. Song, “Pev fast-charging station siting and sizing on coupled transportation and power networks,” *IEEE Transactions on Smart Grid*, vol. 9, no. 4, pp. 2595–2605, 2016.
- [56] J. Luke, M. Salazar, R. Rajagopal, and M. Pavone, “Joint optimization of autonomous electric vehicle fleet operations and charging station siting,” in *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*. IEEE, 2021, pp. 3340–3347.
- [57] E. Inci, “A review of the economics of parking,” *Economics of Transportation*, vol. 4, no. 1-2, pp. 50–63, 2015.
- [58] K.-F. Chu, A. Y. Lam, and V. O. Li, “Joint rebalancing and vehicle-to-grid coordination for autonomous vehicle public transportation system,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 7, pp. 7156–7169, 2021.
- [59] M. W. Levin, “Congestion-aware system optimal route choice for shared autonomous vehicles,” *Transportation Research Part C: Emerging Technologies*, vol. 82, pp. 229–247, 2017.
- [60] R. Nair and E. Miller-Hooks, “Fleet management for vehicle sharing operations,” *Transportation Science*, vol. 45, no. 4, pp. 524–540, 2011.
- [61] H. Becker, F. Becker, R. Abe, S. Bekhor, P. F. Belgiawan, J. Compostella, E. Frazzoli, L. M. Fulton, D. G. Bicudo, K. M. Gurumurthy, *et al.*, “Impact of vehicle automation and electric propulsion on production costs for mobility services worldwide,” *Transportation Research Part A: Policy and Practice*, vol. 138, pp. 105–126, 2020.
- [62] L. Sieber, C. Ruch, S. Hörl, K. W. Axhausen, and E. Frazzoli, “Improved public transportation in rural areas with self-driving cars: A study on the operation of swiss train lines,” *Transportation research part A: policy and practice*, vol. 134, pp. 35–51, 2020.
- [63] R. Bellman, “Dynamic programming,” *science*, vol. 153, no. 3731, pp. 34–37, 1966.
- [64] F. Rossi, R. Zhang, Y. Hindy, and M. Pavone, “Routing autonomous vehicles in congested transportation networks: Structural properties and coordination algorithms,” *Autonomous Robots*, vol. 42, pp. 1427–1442, 2018.
- [65] M. Salazar, M. Tsao, I. Aguiar, M. Schiffer, and M. Pavone, “A congestion-aware routing scheme for autonomous mobility-on-demand systems,” in *2019 18th European Control Conference (ECC)*. IEEE, 2019, pp. 3040–3046.
- [66] D. Gammelli, K. Yang, J. Harrison, F. Rodrigues, F. C. Pereira, and M. Pavone, “Graph neural network reinforcement learning for autonomous mobility-on-demand systems,” in *2021 60th IEEE Conference on Decision and Control (CDC)*. IEEE, 2021, pp. 2996–3003.
- [67] C. Schmidt, D. Gammelli, F. C. Pereira, and F. Rodrigues, “Learning to control autonomous fleets from observation via offline reinforcement learning,” in *2024 European Control Conference (ECC)*. IEEE, 2024, pp. 1399–1406.
- [68] Z. Liu, T. Miwa, W. Zeng, M. G. Bell, and T. Morikawa, “Dynamic shared autonomous taxi system considering on-time arrival reliability,” *Transportation Research Part C: Emerging Technologies*, vol. 103, pp. 281–297, 2019.
- [69] K. Treleven, M. Pavone, and E. Frazzoli, “Asymptotically optimal algorithms for one-to-one pickup and delivery problems with applications to transportation systems,” *IEEE Transactions on Automatic Control*, vol. 58, no. 9, pp. 2261–2276, 2013.
- [70] C. Ruch, J. Gächter, J. Hakenberg, and E. Frazzoli, “The+ 1 method: model-free adaptive repositioning policies for robotic multi-agent systems,” *IEEE Transactions on Network Science and Engineering*, vol. 7, no. 4, pp. 3171–3184, 2020.
- [71] T. Motzkin, “The assignment problem¹,” *Numerical analysis*, no. 6, p. 109, 1956.
- [72] H. W. Kuhn, “The hungarian method for the assignment problem,” *Naval research logistics quarterly*, vol. 2, no. 1-2, pp. 83–97, 1955.
- [73] D. P. Bertsekas and D. A. Castañón, “Parallel asynchronous hungarian methods for the assignment problem,” *ORSA Journal on Computing*, vol. 5, no. 3, pp. 261–274, 1993.
- [74] X. Guo, N. S. Caros, and J. Zhao, “Robust matching-integrated vehicle rebalancing in ride-hailing system with uncertain demand,” *Transportation Research Part B: Methodological*, vol. 150, pp. 161–189, 2021.
- [75] J. Zraggen, M. Tsao, M. Salazar, M. Schiffer, and M. Pavone, “A model predictive control scheme for intermodal autonomous mobility-on-demand,” in *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*. IEEE, 2019, pp. 1953–1960.
- [76] S. He, Z. Zhang, S. Han, L. Pepin, G. Wang, D. Zhang, J. A. Stankovic, and F. Miao, “Data-driven distributionally robust electric vehicle balancing for autonomous mobility-on-demand systems under demand and supply uncertainties,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 24, no. 5, pp. 5199–5215, 2023.
- [77] M. Tsao, R. Iglesias, and M. Pavone, “Stochastic model predictive control for autonomous mobility on demand,” in *2018 21st International conference on intelligent transportation systems (ITSC)*. IEEE, 2018, pp. 3941–3948.
- [78] F. Miao, S. Han, A. M. Hendawi, M. E. Khalefa, J. A. Stankovic, and G. J. Pappas, “Data-driven distributionally robust vehicle balancing using dynamic region partitions,” in *Proceedings of the 8th International Conference on Cyber-Physical Systems*, 2017, pp. 261–271.
- [79] X. Guo, Q. Wang, and J. Zhao, “Data-driven vehicle rebalancing with predictive prescriptions in the ride-hailing system,” *IEEE Open Journal of Intelligent Transportation Systems*, vol. 3, pp. 251–266, 2022.
- [80] V. Beiranvand, W. Hare, and Y. Lucet, “Best practices for comparing optimization algorithms,” *Optimization and Engineering*, vol. 18, pp. 815–848, 2017.
- [81] R. S. Sutton, A. G. Barto, and R. J. Williams, “Reinforcement learning is direct adaptive optimal control,” *IEEE control systems magazine*, vol. 12, no. 2, pp. 19–22, 1992.
- [82] T. Chouaki, S. Hörl, and J. Puchinger, “A review on reinforcement learning methods for mobility on demand systems,” *arXiv preprint arXiv:2501.02569*, 2025.
- [83] J. Gächter, A. Zanardi, C. Ruch, and E. Frazzoli, “Image representation of a city and its taxi fleet for end-to-end learning of rebalancing policies,” in *2021 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2021, pp. 8076–8082.
- [84] S. He, Y. Wang, S. Han, S. Zou, and F. Miao, “A robust and constrained multi-agent reinforcement learning electric vehicle rebalancing method in amod systems,” in *2023 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2023, pp. 5637–5644.
- [85] K. Lin, R. Zhao, Z. Xu, and J. Zhou, “Efficient large-scale fleet management via multi-agent deep reinforcement learning,” in *Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining*, 2018, pp. 1774–1783.
- [86] S. Levine, A. Kumar, G. Tucker, and J. Fu, “Offline reinforcement learning: Tutorial, review, and perspectives on open problems,” *arXiv preprint arXiv:2005.01643*, 2020.
- [87] A. Hussein, M. M. Gaber, E. Elyan, and C. Jayne, “Imitation learning: A survey of learning methods,” *ACM Computing Surveys (CSUR)*, vol. 50, no. 2, pp. 1–35, 2017.
- [88] L. Baty, K. Jungel, P. S. Klein, A. Parmentier, and M. Schiffer, “Combinatorial optimization-enriched machine learning to solve the dynamic vehicle routing problem with time windows,” *Transportation Science*, 2024.
- [89] H. Semmelrock, S. Kopeinik, D. Theiler, T. Ross-Hellauer, and D. Kowald, “Reproducibility in machine learning-driven research,” *arXiv preprint arXiv:2307.10320*, 2023.
- [90] D. Gammelli, K. Yang, J. Harrison, F. Rodrigues, F. Pereira, and M. Pavone, “Graph meta-reinforcement learning for transferable autonomous mobility-on-demand,” in *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, 2022, pp. 2913–2923.

- [91] L. Tresca, C. Schmidt, J. Harrison, F. Rodrigues, G. Zardini, D. Gammelli, and M. Pavone, "Robo-taxi fleet coordination at scale via reinforcement learning," *arXiv preprint arXiv:2504.06125*, 2025.
- [92] C. Schmidt, D. Gammelli, J. Harrison, M. Pavone, and F. Rodrigues, "Offline hierarchical reinforcement learning via inverse optimization," in *International Conference on Learning Representations (ICLR)*, 2025.
- [93] E. Liang, K. Wen, W. H. Lam, A. Sumalee, and R. Zhong, "An integrated reinforcement learning and centralized programming approach for online taxi dispatching," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 9, pp. 4742–4756, 2021.
- [94] Z. Xu, Z. Li, Q. Guan, D. Zhang, Q. Li, J. Nan, C. Liu, W. Bian, and J. Ye, "Large-scale order dispatch in on-demand ride-hailing platforms: A learning and planning approach," in *Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining*, 2018, pp. 905–913.
- [95] G. Dalle, L. Baty, L. Bouvier, and A. Parmentier, "Learning with combinatorial optimization layers: a probabilistic approach," *arXiv preprint arXiv:2207.13513*, 2022.
- [96] K. Jungel, A. Parmentier, M. Schiffer, and T. Vidal, "Learning-based online optimization for autonomous mobility-on-demand fleet control," *arXiv preprint arXiv:2302.03963*, 2023.
- [97] H. Hoppe, L. Baty, L. Bouvier, A. Parmentier, and M. Schiffer, "Structured reinforcement learning for combinatorial decision-making," *arXiv preprint arXiv:2505.19053*, 2025.
- [98] L. Duan, Y. Wei, J. Zhang, and Y. Xia, "Centralized and decentralized autonomous dispatching strategy for dynamic autonomous taxi operation in hybrid request mode," *Transportation Research Part C: Emerging Technologies*, vol. 111, pp. 397–420, 2020.
- [99] Y. Huang, P. Zhu, R. Zhong, and N. Geroliminis, "A bi-level approach for optimal vehicle relocating in mobility-on-demand systems with approximate dynamic programming and coverage control," *Transportation Research Part E: Logistics and Transportation Review*, vol. 192, p. 103754, 2024.
- [100] M. W. Levin, K. M. Kockelman, S. D. Boyles, and T. Li, "A general framework for modeling shared autonomous vehicles with dynamic network-loading and dynamic ride-sharing application," *Computers, Environment and Urban Systems*, vol. 64, pp. 373–383, 2017.
- [101] L. Li, T. Pantelidis, J. Y. Chow, and S. E. Jabari, "A real-time dispatching strategy for shared automated electric vehicles with performance guarantees," *Transportation Research Part E: Logistics and Transportation Review*, vol. 152, p. 102392, 2021.
- [102] M. Maciejewski, J. Bischoff, and K. Nagel, "An assignment-based approach to efficient real-time city-scale taxi dispatching," *IEEE Intelligent Systems*, vol. 31, no. 1, pp. 68–77, 2016.
- [103] M. Hyland and H. S. Mahmassani, "Dynamic autonomous vehicle fleet operations: Optimization-based strategies to assign avs to immediate traveler demand requests," *Transportation Research Part C: Emerging Technologies*, vol. 92, pp. 278–297, 2018.
- [104] S. Sadeghi Eshkevari, X. Tang, Z. Qin, J. Mei, C. Zhang, Q. Meng, and J. Xu, "Reinforcement learning in the wild: Scalable rl dispatching algorithm deployed in ridehailing marketplace," in *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, 2022, pp. 3838–3848.
- [105] R. Iglesias, F. Rossi, K. Wang, D. Hallac, J. Leskovec, and M. Pavone, "Data-driven model predictive control of autonomous mobility-on-demand systems," in *2018 IEEE international conference on robotics and automation (ICRA)*. IEEE, 2018, pp. 6019–6025.
- [106] K. Solovey, M. Salazar, and M. Pavone, "Scalable and congestion-aware routing for autonomous mobility-on-demand via frank-wolfe optimization," *arXiv preprint arXiv:1903.03697*, 2019.
- [107] A. Carron, F. Seccamonte, C. Ruch, E. Frazzoli, and M. N. Zeilinger, "Scalable model predictive control for autonomous mobility-on-demand systems," *IEEE Transactions on Control Systems Technology*, vol. 29, no. 2, pp. 635–644, 2019.
- [108] H. Hoppe, T. Enders, Q. Cappart, and M. Schiffer, "Global rewards in multi-agent deep reinforcement learning for autonomous mobility on demand systems," in *6th Annual Learning for Dynamics & Control Conference*. PMLR, 2024, pp. 260–272.
- [109] J. Alonso-Mora, A. Wallar, and D. Rus, "Predictive routing for autonomous mobility-on-demand systems with ride-sharing," in *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2017, pp. 3583–3590.
- [110] A. Fielbaum, X. Bai, and J. Alonso-Mora, "On-demand ridesharing with optimized pick-up and drop-off walking locations," *Transportation research part C: emerging technologies*, vol. 126, p. 103061, 2021.
- [111] H. R. Sayarshad and J. Y. Chow, "Non-myopic relocation of idle mobility-on-demand vehicles as a dynamic location-allocation-queueing problem," *Transportation Research Part E: Logistics and Transportation Review*, vol. 106, pp. 60–77, 2017.
- [112] X. Yu and S. Shen, "An integrated decomposition and approximate dynamic programming approach for on-demand ride pooling," *IEEE Transactions on Intelligent Transportation Systems*, vol. 21, no. 9, pp. 3811–3820, 2019.
- [113] J. Miller and J. P. How, "Predictive positioning and quality of service ridesharing for campus mobility on demand systems," in *2017 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2017, pp. 1402–1408.
- [114] R. Zhang and M. Pavone, "A queueing network approach to the analysis and control of mobility-on-demand systems," in *2015 American Control Conference (ACC)*. IEEE, 2015, pp. 4702–4709.
- [115] X. Chen, F. Miao, G. J. Pappas, and V. Preciado, "Hierarchical data-driven vehicle dispatch and ride-sharing," in *2017 IEEE 56th Annual Conference on Decision and Control (CDC)*. IEEE, 2017, pp. 4458–4463.
- [116] M. Tsao, D. Milojevic, C. Ruch, M. Salazar, E. Frazzoli, and M. Pavone, "Model predictive control of ride-sharing autonomous mobility-on-demand systems," in *2019 International conference on robotics and automation (ICRA)*. IEEE, 2019, pp. 6665–6671.
- [117] R. Zhang, F. Rossi, and M. Pavone, "Model predictive control of autonomous mobility-on-demand systems," in *2016 IEEE international conference on robotics and automation (ICRA)*. IEEE, 2016, pp. 1382–1389.
- [118] M. Albert, C. Ruch, and E. Frazzoli, "Imbalance in mobility-on-demand systems: A stochastic model and distributed control approach," *ACM Transactions on Spatial Algorithms and Systems (TSAS)*, vol. 5, no. 2, pp. 1–22, 2019.
- [119] M. Han, P. Senellart, S. Bressan, and H. Wu, "Routing an autonomous taxi with reinforcement learning," in *Proceedings of the 25th ACM International Conference on Information and Knowledge Management*, 2016, pp. 2421–2424.
- [120] J. Wen, J. Zhao, and P. Jaillet, "Rebalancing shared mobility-on-demand systems: A reinforcement learning approach," in *2017 IEEE 20th international conference on intelligent transportation systems (ITSC)*. IEEE, 2017, pp. 220–225.
- [121] J. James, W. Yu, and J. Gu, "Online vehicle routing with neural combinatorial optimization and deep reinforcement learning," *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 10, pp. 3806–3817, 2019.
- [122] M. Guérliau, F. Cugurullo, R. A. Acheampong, and I. Dusparic, "Shared autonomous mobility on demand: A learning-based approach and its performance in the presence of traffic congestion," *IEEE Intelligent Transportation Systems Magazine*, vol. 12, no. 4, pp. 208–218, 2020.
- [123] F. Dandl, M. Hyland, K. Bogenberger, and H. S. Mahmassani, "Evaluating the impact of spatio-temporal demand forecast aggregation on the operational performance of shared autonomous mobility fleets," *Transportation*, vol. 46, no. 6, pp. 1975–1996, 2019.
- [124] H. Neuburger, "Economics of heavily congested roads," *Transportation Research/UK/*, 1971.
- [125] C. F. Daganzo and N. Geroliminis, "An analytical approximation for the macroscopic fundamental diagram of urban traffic," *Transportation Research Part B: Methodological*, vol. 42, no. 9, pp. 771–781, 2008.
- [126] C. F. Daganzo, "The cell transmission model: A dynamic representation of highway traffic consistent with the hydrodynamic theory," *Transportation research part B: methodological*, vol. 28, no. 4, pp. 269–287, 1994.
- [127] I. Yperman, S. Logghe, and B. Immers, "The link transmission model: An efficient implementation of the kinematic wave theory in traffic networks," in *Proceedings of the 10th EWGT Meeting*, vol. 24. Citeseer, 2005, pp. 122–127.
- [128] J. B. Oke, A. P. Akkinepally, S. Chen, Y. Xie, Y. M. Aboutaleb, C. L. Azevedo, P. C. Zegras, J. Ferreira, and M. Ben-Akiva, "Evaluating the systemic effects of automated mobility-on-demand services via large-scale agent-based simulation of auto-dependent prototype cities," *Transportation*

- Research Part A: Policy and Practice*, vol. 140, pp. 98–126, 2020.
- [129] J.-P. A. L. J. P. A. Lab), “Transportation decarbonization white paper,” <https://www.povertyactionlab.org/publication/transportation-decarbonization-white-paper>, accessed: January 14, 2025.
- [130] Y. Liu, P. Bansal, R. Daziano, and S. Samaranayake, “A framework to integrate mode choice in the design of mobility-on-demand systems,” *Transportation Research Part C: Emerging Technologies*, vol. 105, pp. 648–665, 2019.
- [131] Y. Kim, G. Zardini, S. Samaranayake, and S. Shafiee, “Estimate then predict: Convex formulation for travel demand forecasting,” *Available at SSRN 4977199*, 2024.
- [132] D. Gammelli, I. Peled, F. Rodrigues, D. Pacino, H. A. Kurtaran, and F. C. Pereira, “Estimating latent demand of shared mobility through censored gaussian processes,” *Transportation Research Part C: Emerging Technologies*, vol. 120, p. 102775, 2020.
- [133] S. Kounev, K.-D. Lange, and J. Von Kistowski, *Systems Benchmarking*. Springer, 2020, vol. 1.
- [134] J. Bischoff and M. Maciejewski, “Simulation of city-wide replacement of private cars with autonomous taxis in berlin,” *Procedia computer science*, vol. 83, pp. 237–244, 2016.
- [135] M. Salazar, F. Rossi, M. Schiffer, C. H. Onder, and M. Pavone, “On the interaction between autonomous mobility-on-demand and public transportation systems,” in *2018 21st international conference on intelligent transportation systems (ITSC)*. IEEE, 2018, pp. 2262–2269.
- [136] T. Litman, *Evaluating transportation equity*. Victoria Transport Policy Institute Victoria, BC, Canada, 2017.
- [137] G. O. Kagho, K. Murthy Gurumurthy, Ö. Verbas, and J. Auld, “Framework for analyzing equity-concerns related to mobility on-demand,” in *103rd Annual Meeting of the Transportation Research Board (TRB 2024)*. IVT ETH Zurich, 2024.
- [138] I. A. Bhuyan, C. Chavis, A. Nickkar, and P. Barnes, “Gis-based equity gap analysis: Case study of baltimore bike share program,” *Urban Science*, vol. 3, no. 2, p. 42, 2019.
- [139] New York City Taxi and Limousine Commission, “TLC Trip Record Data,” <https://www.nyc.gov/taxi>, 2025, accessed: 2025-01-15.
- [140] M. Piorkowski, N. Sarafijanovic-Djukic, and M. Grossglauser, “Crawdad epfl/mobility,” 2022. [Online]. Available: <https://dx.doi.org/10.15783/C7J010>
- [141] T. N. for Research Core Team, “Transportation networks for research,” <https://github.com/bstabler/TransportationNetworks>, accessed: January 14, 2025.
- [142] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, “Imagenet: A large-scale hierarchical image database,” in *2009 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2009, pp. 248–255.
- [143] A. Geiger, P. Lenz, and R. Urtasun, “Are we ready for autonomous driving? the kitti vision benchmark suite,” in *2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2012, pp. 3354–3361.
- [144] Didi Global Inc., “Didi global official website,” <https://web.didiglobal.com/>, 2025, accessed: 2025-05-22.
- [145] R. Engelhardt, F. Dandl, A.-A. Syed, Y. Zhang, F. Fehn, F. Wolf, and K. Bogenberger, “Fleetpy: A modular open-source simulation tool for mobility on-demand services,” *arXiv preprint arXiv:2207.14246*, 2022.
- [146] K. W. Axhausen, A. Horni, and K. Nagel, *The multi-agent transport simulation MATSim*. Ubiquity Press, 2016.
- [147] M. Adnan, F. C. Pereira, C. M. L. Azevedo, K. Basak, M. Lovric, S. Raveau, Y. Zhu, J. Ferreira, C. Zegras, and M. Ben-Akiva, “Simmobility: A multi-scale integrated agent-based simulation platform,” in *95th Annual Meeting of the Transportation Research Board Forthcoming in Transportation Research Record*, vol. 2. The National Academies of Sciences, Engineering, and Medicine Washington, DC, 2016.
- [148] K. A. Marczuk, H. S. Soh, C. M. Azevedo, D.-H. Lee, and E. Frazzoli, “Simulation framework for rebalancing of autonomous mobility on demand systems,” in *MATEC Web of Conferences*, vol. 81. EDP Sciences, 2016, p. 01005.
- [149] B.-h. Nahmias-Biran, J. B. Oke, N. Kumar, C. Lima Azevedo, and M. Ben-Akiva, “Evaluating the impacts of shared automated mobility on-demand services: An activity-based accessibility approach,” *Transportation*, vol. 48, pp. 1613–1638, 2021.
- [150] M. Zhou, D.-T. Le, D. Q. Nguyen-Phuoc, P. C. Zegras, and J. Ferreira Jr, “Simulating impacts of automated mobility-on-demand on accessibility and residential relocation,” *Cities*, vol. 118, p. 103345, 2021.
- [151] S. Oh, R. Seshadri, C. L. Azevedo, N. Kumar, K. Basak, and M. Ben-Akiva, “Assessing the impacts of automated mobility-on-demand through agent-based simulation: A study of singapore,” *Transportation Research Part A: Policy and Practice*, vol. 138, pp. 367–388, 2020.
- [152] D. Q. Nguyen-Phuoc, M. Zhou, M. H. Chua, A. R. Alho, S. Oh, R. Seshadri, and D.-T. Le, “Examining the effects of automated mobility-on-demand services on public transport systems using an agent-based simulation approach,” *Transportation Research Part A: Policy and Practice*, vol. 169, p. 103583, 2023.
- [153] P. A. Lopez, M. Behrisch, L. Bieker-Walz, J. Erdmann, Y.-P. Flötteröd, R. Hilbrich, L. Lücken, J. Rummel, P. Wagner, and E. Wießner, “Microscopic traffic simulation using sumo,” in *2018 21st international conference on intelligent transportation systems (ITSC)*. IEEE, 2018, pp. 2575–2582.
- [154] C. Ruch, S. Hörl, and E. Frazzoli, “Amodeus, a simulation-based testbed for autonomous mobility-on-demand systems,” in *2018 21st international conference on intelligent transportation systems (ITSC)*. IEEE, 2018, pp. 3639–3644.
- [155] A. S. Team, “Amodeus: A framework for autonomous mobility-on-demand systems,” <https://github.com/amodeus-science/amodeus/tree/master?tab=readme-ov-file>, accessed: January 14, 2025.
- [156] H. Ahmed and J. Lofstead, “Managing randomness to enable reproducible machine learning,” in *Proceedings of the 5th International Workshop on practical reproducible evaluation of computer systems*, 2022, pp. 15–20.
- [157] G. Zardini, D. Gammelli, L. Tresca, C. Schmidt, J. Harrison, F. Rodrigues, M. Schiffer, and M. Pavone, “Data-driven methods for network-level coordination of autonomous mobility-on-demand systems across scales,” <https://github.com/StanfordASL/RL4AMOD>, 2024, accessed: 2025-04-17.
- [158] G. Zardini, N. Lanzetti, M. Salazar, A. Censi, E. Frazzoli, and M. Pavone, “Towards a co-design framework for future mobility systems,” *arXiv preprint arXiv:1910.07714*, 2019.
- [159] A. Vakayil, W. Gruel, and S. Samaranayake, “Integrating shared-vehicle mobility-on-demand systems with public transit,” *Transportation Research Board*, Tech. Rep., 2017.
- [160] F. Rossi, R. Iglesias, M. Alizadeh, and M. Pavone, “On the interaction between autonomous mobility-on-demand systems and the power network: Models and coordination algorithms,” *IEEE Transactions on Control of Network Systems*, vol. 7, no. 1, pp. 384–397, 2019.
- [161] A. Estandia, M. Schiffer, F. Rossi, J. Luke, E. C. Kara, R. Rajagopal, and M. Pavone, “On the interaction between autonomous mobility on demand systems and power distribution networks—an optimal power flow approach,” *IEEE Transactions on Control of Network Systems*, vol. 8, no. 3, pp. 1163–1176, 2021.
- [162] G. Zardini, N. Lanzetti, G. Belgioioso, C. Hartnik, S. Bolognani, F. Dörfler, and E. Frazzoli, “Strategic interactions in multi-modal mobility systems: A game-theoretic perspective,” in *2023 IEEE 26th International Conference on Intelligent Transportation Systems (ITSC)*. IEEE, 2023, pp. 5452–5459.
- [163] G. Zardini, N. Lanzetti, L. Guerrini, E. Frazzoli, and F. Dörfler, “Game theory to study interactions between mobility stakeholders,” in *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*, 2021, pp. 2054–2061.
- [164] T.-Y. Ma, S. Rasulkhani, J. Y. Chow, and S. Klein, “A dynamic ridesharing dispatch and idle vehicle repositioning strategy with integrated transit transfers,” *Transportation Research Part E: Logistics and Transportation Review*, vol. 128, pp. 417–442, 2019.
- [165] M. Salazar, N. Lanzetti, F. Rossi, M. Schiffer, and M. Pavone, “Intermodal autonomous mobility-on-demand,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 21, no. 9, pp. 3946–3960, 2019.
- [166] J. Bischoff, I. Kaddoura, M. Maciejewski, and K. Nagel, “Redefining the role of public transport in a world of shared autonomous vehicles,” in *Symposium of the European Association for Research in Transportation (hEART)*, 2017.
- [167] G. Zardini, N. Lanzetti, A. Censi, E. Frazzoli, and M. Pavone, “Co-design to enable user-friendly tools to assess the impact of future mobility solutions,” *IEEE Transactions on Network Science and Engineering*, vol. 10, no. 2, pp. 827–844, 2022.
- [168] G. Zardini, “Co-design of complex systems: From autonomy to future mobility systems,” Ph.D. dissertation, ETH Zürich, Switzerland, 2023. [Online]. Available: <https://www.research-collection.ethz.ch/handle/20.500.11850/648075>
- [169] G. Zardini, N. Lanzetti, M. Salazar, A. Censi, E. Frazzoli, and M. Pavone, “On the co-design of av-enabled mobility systems,”

- in *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*. IEEE, 2020, pp. 1–8.
- [170] G. Zardini, D. Milojevic, A. Censi, and E. Frazzoli, “Co-design of embodied intelligence: A structured approach,” in *2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2021, pp. 7536–7543.
- [171] G. Zardini, A. Censi, and E. Frazzoli, “Co-design of autonomous systems: From hardware selection to control synthesis,” in *2021 European Control Conference (ECC)*. IEEE, 2021, pp. 682–689.
- [172] F. Steck, V. Kolarova, F. Bahamonde-Birke, S. Trommer, and B. Lenz, “How autonomous driving may affect the value of travel time savings for commuting,” *Transportation research record*, vol. 2672, no. 46, pp. 11–20, 2018.
- [173] J. Liu, K. M. Kockelman, P. M. Boesch, and F. Ciari, “Tracking a system of shared autonomous vehicles across the austin, texas network using agent-based simulation,” *Transportation*, vol. 44, pp. 1261–1278, 2017.
- [174] J. Kamel, R. Vosooghi, J. Puchinger, F. Ksontini, and G. Sirin, “Exploring the impact of user preferences on shared autonomous vehicle modal split: A multi-agent simulation approach,” *Transportation Research Procedia*, vol. 37, pp. 115–122, 2019.