混合交通中用于变道的连接增强型安全神经网络规划器

Xiangguo Liu Ruochen Jiao Bowen Zheng 西北大学 西北大学 Pony.ai 美国伊利诺伊州埃文斯顿 美国伊利诺伊州埃文斯顿 美国加利福尼亚州弗里蒙特 xg.liu@u.northwestern.edu RuochenJiao2024@u.northwestern.edu bowen.zheng@pony.ai

Dave Liang
Pony.ai 美国加利福尼亚州弗里蒙特
dave.liang@pony.ai

Qi Zhu 西北大学 美国伊利诺伊州埃文斯顿
qzhu
@northwestern.edu

arXiv:2302.02513v1 [cs.RO] 6 Feb 2023

摘要

连接技术通过提供超越单辆车感知与预测能力的信息，在提升交通运输系统的安全性和效率方面展现出巨大潜力。然而，预计在向全面联网自动化交通运输系统过渡期间，人工驾驶车辆与自动驾驶车辆、联网车辆与非网联车辆需要共用交通网络。这类混合交通场景显著增加了分析系统行为以及量化高度交互场景（如变道）中不确定性的复杂性。当采用基于神经网络的规划器进一步提升效率时，确保系统安全则更加困难。本文提出一种连接性增强的神经网络换道规划器。通过与动态环境中的周围联网车辆协作，所提出的规划器将根据对安全避让轨迹的分析调整其规划轨迹。我们通过大量仿真，展示了该规划器设计在各种混合交通场景中提升效率并确保安全性的优势。我们还分析了通信或协调不完善时系统的鲁棒性。

关键词

网联自动驾驶车辆、安全神经网络规划器、混合交通、人工驾驶车辆

1 引言

用于自动驾驶的连接技术日益受到学术界和工业界的关注，预计将显著提升交通运输系统的安全性、能源效率和时间效率。 [1], [21,22] 在互联性增强的交通系统中，车辆可以通过专用短程通信（DSRC） [14] 或蜂窝车联网（C-V2X） [9]彼此通信和/或与周边基础设施通信。这些通信可共享车辆当前状态（如位置、速度、加速度）和未来意图（如计划采取的行动和轨迹）等重要信息，其范围远超单车的感知和预测能力，例如共享自车视野之外的信息，或无法准确预测的意图 [12]。除此之外，车辆还可以通过分布式方式协商和协调 [33], , 或者遵循中央单元的指令 [40] ，以进一步优化系统。这使互联性成为自动驾驶车辆和人工驾驶车辆的绝佳补充。

然而，连接技术的应用面临着重大挑战：系统行为分析的复杂性日益增加，确保系统安全也愈发困难；尤其是车辆决策中神经网络组件的使用日益广泛 [42]。在向下一代交通系统过渡时期，由人工驾驶车辆和自动驾驶车辆 [38], 以及网联和非网联车辆组成的混合交通流需要共享交通网络。近期已有研究致力于确保所有车辆类型相同 [8, 15], 或未启用互联性 [17, 19, 28, 29],时的系统安全，而只有少数研究 [19, 28] 能够将方法推广至包含神经网络组件的系统。变道，尤其是在拥堵交通中，是一种具有挑战性的场景，因为这些车辆需要彼此密切交互 [20]。如何对包含各种车辆的一般系统进行建模仍是一项开放性挑战，更不用说在不过度牺牲效率的同时提供安全保证了。

为克服这些挑战，我们提出一种基于连接性增强神经网络的规划器设计，以确保混合交通中的变道安全。在这一通用框架中，我们假设自车为网联自动驾驶车辆，而周围车辆既可能是网联或非网联车辆，也可能是自动驾驶或人工驾驶车辆[1]。图1展示了一个换道场景示例。网联自车 E打算驶入目标车道。从邻近区域到交通下游，目标车道上有若干辆网联前车L_1、 L_2、…、L_N，以及一辆非联网前车 L_{N+1}。在本研究中，我们在规划器设计中考虑了周围车辆类型和数量各异的所有可能场景。根据动态混合交通环境，网联前车 N的数量可能会变化[2]。目标车道上的后车 F既可能是网联车辆，也可能是非网联车辆。

为确保安全，我们验证在最坏情况下，沿着规划轨迹是否存在安全避让轨迹。也就是说，

[1]对于联网人工驾驶车辆，我们假设为确保安全，需要保持较大的车间距离，因为与自动驾驶车辆相比，人工驾驶车辆可能存在更大的执行误差。[2]其中，$N = 0$表示紧邻前车为非网联车辆。

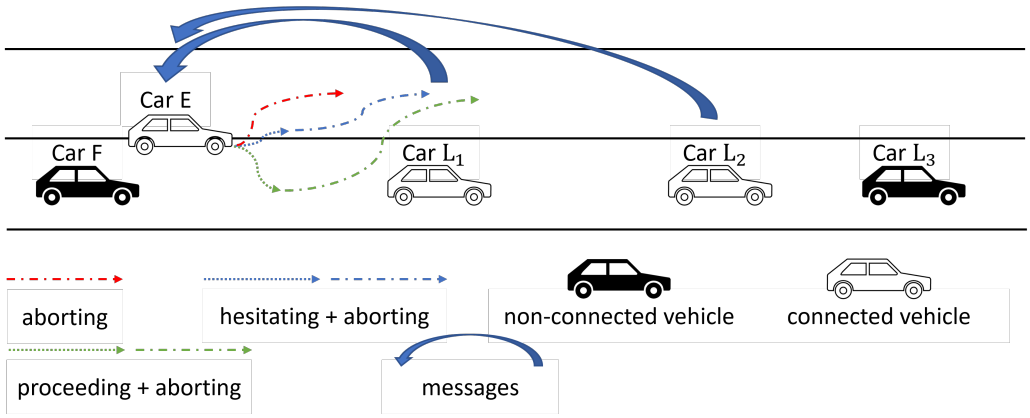

图1：自车 E 打算变道。借助连接技术，车辆 E 接收来自联网前车 L_i、 $1 \le i \le N$ 的计划加速度曲线和实时运动状态，并据此分析车辆 L_1 在变道过程中的最大减速度。通过识别后车 F 的行为并分析最坏情况下的系统安全性，车辆 E 可以继续变道、在当前横向位置附近等待，或取消变道计划。该图展示了一个 $N = 2$ 的示例，且后车 F 为非网联车辆。

规划轨迹无需一次性完成变道。只要存在安全避让轨迹，自车就可以开始尝试并与周围车辆进行交互。我们分析动态环境下自车所面临的最坏情况。对于没有联网前车的情况，即 $N = 0$，我们可以直接假设，在最坏情况下，车辆 L_1 会在机械约束下采取最大减速度。对于其他情况，即 $N > 0$，我们可以利用联网车辆的协调，以避免过于保守的规划。我们评估自车在紧急情况下的最快避让轨迹。例如，当下游发生紧急制动时，首先发现该事件的联网车辆可以在确保自身安全的前提下协同采取较小的减速度，从而为自车留下更多反应时间。如果避让轨迹能够避免碰撞，自车就可以在基于神经网络的规划器作用下继续变道；否则，为了安全起见，自车必须在两条车道的边界附近暂缓变道，或返回原车道。

我们的工作贡献可概括如下 as:

- 我们提出了一种基于车联网增强的神经网络换道规划器，适用于有人驾驶车辆与自动驾驶车辆、网联车辆与非网联车辆并存的混合交通环境。
- 我们通过连接技术或激进程度评估对周围车辆的行为进行建模，以开展安全分析。如果通信完美、激进程度评估准确，或者我们始终将后车视为激进车辆，则我们的规划器设计能够保证安全。
- 我们通过全面的仿真实验，展示了利用动态环境中的互联性可显著提升系统效率。我们还分析了联网车辆之间协调不完善时的系统鲁棒性。

本文其余部分安排如下：第2节回顾变道、车辆间交互、基于神经网络的规划以及联网车辆方面的相关工作。第3节介绍我们的车联网增强规划框架。第4节展示实验结果，第5节总结全文。

2 相关工作

自动驾驶中的规划器设计一直是一个十分活跃的研究领域，原因在于它有望大幅提升交通系统性能，同时也面临着确保系统安全的挑战。在考虑环境不确定性和复杂的车辆间交互时，迫切需要避免过于保守的设计，同时提供安全保证 [7, 19, 37]。[28] 中的研究提出了合法安全这一概念，即只要周围车辆遵守交通规则，自动驾驶车辆就不会成为事故的肇因，也不会发生碰撞。其实现方式是始终证明在规划器下存在故障安全轨迹。类似地， [29], 提出了责任敏感安全这一概念，假设其他参与者会遵循常识规则，并针对近事故场景定义自动驾驶车辆的适当应对方式。然而，如果其他车辆的行为违反这些假设，安全性就可能受到影响。 [17, 37]中的研究提出了一种不过度保守的防御性驾驶策略，采用基于采样或基于优化的方法。规划轨迹经过安全评估后才会执行。基于模型预测控制（MPC）的方法可通过施加约束或设计代价函数来解决安全问题 [34, 35]。

基于机器学习的技术在自动驾驶的规划和决策中日益普及 [13, 24,39], ，因为它们有望提升复杂场景下的平均系统性能。文献 [30]提出了社会感知的概念，即从其他车辆的反应中推断周围环境。随后，该研究利用逆强化

学习（IRL）获取人类驾驶的代价函数，并使用马尔可夫决策过程（MDP）求得概率意义上的最优解。 [16] 将换道规划问题表述为部分可观测马尔可夫决策过程（POMDP），其中其他交通参与者的合作意愿是一种不可观测状态。该研究通过逻辑回归分类器预测人类驾驶车辆的未来行为，并使用蒙特卡洛树搜索求解 POMDP。文献 [3] 针对近事故场景提出了一种分层强化与模仿学习（H-REIL）方法，该方法包含通过模仿学习（IL）为离散驾驶模式学习的低层策略，以及通过强化学习（RL）学习、用于在不同驾驶模式间切换的高层策略。文献 [18] 证明，与基于单一神经网络的规划器相比，基于分层神经网络的规划器在安全性和可验证性方面表现更优。

尽管这些方法展现出显著的性能提升，但验证学习型系统的安全性仍然颇具挑战 [31, 32]。感知 [26] 的不确定性以及单个车辆的预测结果，也限制了系统效率。此外，互联性可通过减少此类不确定性来提升交通系统 [2, 27, 36]。例如，文献 [15] 提出了一种交叉口管理方案，由中央管理器为车辆分配到达速度和到达时间。该方案假设所有车辆均为网联自动驾驶车辆。文献 [8] 利用动态贝叶斯网络（DBN）对车辆状态演变进行建模。中央管理器可以向车辆发送警告信息，以实现碰撞规避。该方案假设所有车辆均已网联且由人类驾驶，并认为碰撞率取决于速度和驾驶员反应时间。文献 [5] 假设所有车辆均已网联，并利用深度强化学习（DRL）进行变道行为层决策。具体而言，该方法通过车际通信将下游交通状况纳入考量，从而提升性能。

已有多项研究针对网联车辆与非网联车辆混合交通开展了研究。 [4, 6, 23, 41] [10] 提出了一种基于强化学习的网联自动驾驶汽车多智能体纵向规划器，通过调整上游交通中的车速来缓解下游交通冲击波。研究结果表明，即使网联自动驾驶汽车的渗透率仅为10%，也能显著缓解高速公路交通中的瓶颈。 [25] 所述方法利用强化学习，为高速公路汇入场景中的网联车辆提供轨迹推荐。该方法假设并非所有车辆都已联网，并使用路侧摄像头进行数据融合，以识别所有车辆。 [11] 提出了一种基于强化学习的方法，使网联自动驾驶汽车能够根据观测结果和邻近车辆的共享信息，决定变道或保持车道等行动。由于并非所有车辆都已联网，该系统采用混合部分可观测马尔可夫决策过程（HPOMDP）建模。然而，该方法没有明确建模车辆间交互，其安全性高度依赖于对周围车辆（尤其是非网联车辆）的准确建模。在本研究中，我们提出了一种适用于混合交通、具有安全保证的通用变道规划器，无论网联车辆渗透率如何，都能安全高效地运行。

3 我们的框架设计

3.1 概述

借助连接技术，我们的规划器设计能够在确保系统安全的同时进一步提升系统效率。框架如图2所示。基于规划时域内的计划加速曲线以及周围车辆的实时运动状态，我们可以利用神经网络进行纵向和横向轨迹规划。同时，我们可以推导出前车的最大减速度 L_1（场景如图1所示），进而针对最坏情况进行系统分析并调整轨迹，以确保安全。对于后车 F，当车辆 F 为非网联车辆时，我们采用与 [19]相同的激进程度评估方法。对于后车 F 为网联车辆的情况，我们假设其能够协同。

安全分析和轨迹调整会定期进行。在变道过程中，自车在每个步骤都有三个优先级严格递减的行为层选项：继续变道、在当前横向位置附近犹豫，或放弃变道并返回原车道。它会分析基于神经网络的规划器执行一个时间步的加速度后的状态。如果最坏情况下存在安全避让轨迹，就可以继续变道。否则，它必须尝试优先级较低的行为，直到找到安全避让轨迹。

3.2 连接假设

在这项工作中，我们假设联网前车 L_i、$1 \le i \le N$（例如，图1场景中的 $N = 2$）会协同协助自车 E 的换道过程，并避免与它们各自的紧邻前车 L_{i+1} 发生碰撞。具体而言，如果将加速度保持在 $[-a_i^{m,d}, a_i^{m,a}]$ 范围内足以使其与 L_{i+1} 保持安全距离，联网前车 L_i 就会在该范围内保持加速度，以完成自身的驾驶任务。需要指出的是，$a^{m,\,i\,\,d}$ 和 $a^{m,\,i\,\,a}$ 的数值会传达给其他联网车辆。只有在突发场景中，例如前车 L_{i+1} 突然减速时，L_i 才可能违背‘承诺’并采取减速度 $a_{x,\,i,\,d} > a^{m,\,i\,\,d}$ 以确保安全。请注意，这被视为对承诺的预期违背，我们的规划器框架能够在此类情况下确保安全（稍后在第4节中，我们将展示此类承诺遭到意外违背时的影响，例如周围车辆发生故障或受到其他未知障碍物的影响）。

为使模型具有一般性，我们假设，网联人工驾驶车辆和联网自动驾驶车辆都以相同的方式向其他车辆传达其计划加速度范围。不过，由于人工驾驶员的行为和执行过程通常存在更大的不确定性，人工驾驶车辆的加速度范围可能更大。对于非网联车辆，我们假设其可以在机械约束范围内取任意加速度值。

3.3 安全分析

接下来，我们将分析给定系统状态下的避让轨迹。假设车辆 L_i 以 $a_{x,\,i,\,d}$ 减速，车辆 L_{i-1} 需要

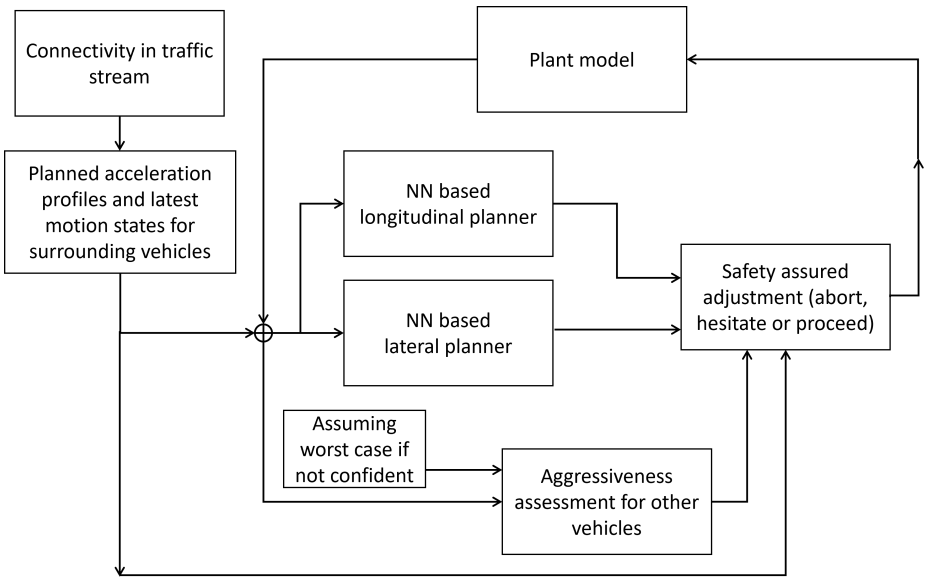

图2：通过纳入连接技术更新的周围车辆计划加速曲线和实时运动状态，我们可以进一步提升基于神经网络的换道规划器的性能。同时，我们可以推导出前车 L_1 的最大减速度（场景如图1所示），对最坏情况进行激进程度评估和系统分析，并调整轨迹以确保安全性。

以$z_{x、i-1、d}$减速，防止发生碰撞。令 p_m表示两辆车之间的最小安全距离，则有

$$\begin{cases} p_{x,i}+v_{x,i}t_{L_i}+\frac{a_{x,i,d}t_{L_i}^2}{2}-p_{x,i-1}-v_{x,i-1}t_{L_i}-\frac{z_{x,i-1,d}t_{L_i}^2}{2}-p_m=0 \\ \qquad \text{if } v_{x,i}<v_{x,i-1} \text{ and } \frac{v_{x,i}}{a_{x,i,d}}\geq\frac{v_{x,i-1}}{z_{x,i-1,d}}, \\ p_{x,i}+\frac{v_{x,i}^2}{2a_{x,i,d}}-p_{x,i-1}-\frac{v_{x,i-1}^2}{2z_{x,i-1,d}}-p_m=0 \\ \qquad \text{otherwise}, \end{cases} \tag{1}$$

其中，$p_{x、i}, v_{x、i}, p_{x、i-1}$ 和 $v_{x、i-1}$ 分别表示车辆 L_i 和 L_{i-1}的位置和速度。第一个方程对应两辆车在 $t_{L_i}=\frac{v_{x\,i-1}-v_{x\quad i}}{z_{x\,i-1\,d}-a_{x\;、、、i、\;d}}$、、时速度相同，并同时达到最小车间距的情况。第二个方程对应 L_{i-1} 停止时与 L_i 距离最近的情况。

通过求解方程（1），即可得到车辆 L_{i-1} 的减速度

$$z_{x,i-1,d}=\begin{cases} \frac{3(v_{x,i-1}-v_{x,i})^2}{2(p_{x,i}-p_{x,i-1}-p_m)}+a_{x,i,d} \\ \qquad \text{if } v_{x,i}<v_{x,i-1} \text{ and } \frac{v_{x,i}}{a_{x,i,d}}\geq\frac{v_{x,i-1}}{z_{x,i-1,d}}, \\ \frac{v_{x,i-1}^2}{2(p_{x,i}-p_{x,i-1}-p_m)+\frac{v_{x,i}^2}{a_{x,i,d}}} \\ \qquad \text{otherwise}. \end{cases} \tag{2}$$

考虑到车辆 L_{i-1} 已在消息中声明，为执行自身的驾驶任务，其加速度将在范围 $[-a_{i-1}^{m,d}, a_{i-1}^{m,a}]$ 内，因此我们可得出最坏情况下车辆 L_{i-1} 的减速度

$$a_{x,i-1,d}=max(a_{i-1}^{m,d}, z_{x,i-1,d}). \tag{3}$$

令 $a_{x,\ d}$和 $a_{x,\ a}$ 分别表示车辆在机械约束下的最大纵向减速度和加速度。令$a_{y,\ m}$表示机械约束下最大横向加速度的绝对值。在最坏情况下，我们假设非联网前车 L_{N+1}可以按 $a_{x,\ N+1,\ d}=a_{x,\ d}$减速，然后根据方程（2）和（3）可得 $a_{x,\ N,\ d}$。同理，我们可以计算最坏情况下其他前车的减速度 $a_{x,\ N-1,\ d}, a_{x,\ N-2,\ d}, \cdots, a_{x,\ 1,\ d}$。

已知前车 L_1 以 $a_{x、1、d}$减速，其在时刻 t 的位置为

$$p_{x,1,t}=\begin{cases} p_{x,1}+v_{x,1}t-\frac{a_{x,1,d}t^2}{2} \\ \qquad \text{if } t\leq\frac{v_{x,1}}{a_{x,1,d}}, \\ p_{x,1}+\frac{v_{x,1}^2}{2a_{x,1,d}} \\ \qquad \text{otherwise}. \end{cases} \tag{4}$$

接下来，我们将分析最坏情况下自车 E 的避让轨迹。如果安全，自车 E 可以在基于神经网络的规划器控制下开始变道；否则，它可以调整行为和轨迹以确保安全。对于横向运动，最快的避让轨迹是在 $a_y=-a_{y\,m}$ $t\in[0,t_1]$ $a_y=a_{y\,m}$ $t\in[t_1,t_{y,f}]$，时加速，然后在，时加速。该轨迹可通过求解下方方程获得。

$$\begin{cases} p_{y,t_0}+v_{y,t_0}t_1-\frac{a_{y,m}t_1^2}{2}+(v_{y,t_0}-a_{y,m}t_1)(t_{y,f}-t_1) \\ \qquad +\frac{a_{y,m}(t_{y,f}-t_1)^2}{2}=\frac{w_l-w_v}{2}, \\ v_{y,t_0}-a_{y,m}t_1+a_{y,m}(t_{y,f}-t_1)=0, \end{cases} \tag{5}$$

其中，p_{y,t_0}和v_{y,t_0}分别是自车在 $t=0$时的横向位置和速度。原车道和目标车道的中心分别为$y=0$和 $y=w_l$。车辆宽度为 w_v。

对于纵向运动，当紧邻前车 L_1 以$a_{x,\ 1,\ d}$ [19]减速时，可直观地分析最优轨迹：自车先以$a_{x,\ a}$加速，然后以$a_{x,\ d}$减速，并在 $t\in[0,t_{y,f}]$时保持车间距不小于 p_m。这是自车接近前车的最快纵向运动，因此在后车追上之前，能为横向避让争取更多时间。

然而，本研究考虑的是一种更一般的情况：前车 L_1 可能具有$a_{x,\ 1,\ d}\le a_{x,\ d}$的减速度。因此，当自车 E 减速至与前车 L_1相同的速度时，其减速度应从$a_{x,\ d}$变为$a_{x,\ 1,\ d}$。否则，当自车速度低于车辆 L_1的速度时，自车的车头时距会增大。这样一来，自车为避免碰撞而反应过度，无法获得最优轨迹。

最优纵向运动分为三个阶段。自车首先在 $t\in[0,t_{x,1}]$时以 $a_x=a_{x,\ a}$ 加速，随后在 $t\in[t_{x,1},t_{x,2}]$时以 $a_x=-a_{x,\ d}$ 减速，然后以 $a_x=-a_{x,\ 1,\ d}$ 减速，直到在 $t\in[t_{x,2},t_{y,f}]$时停止。自车在$t=t_{y,\ f}$时的位置表示为

$$p_{x,t_{y,f}}=\begin{cases} p_{x,t_0}+v_{x,t_0}t_{x,1}+\frac{a_{x,a}t_{x,1}^2}{2}+(v_{x,t_0}+a_{x,a}t_{x,1})(t_{y,f}-t_{x,1}) \\ \quad -\frac{a_{x,d}(t_{y,f}-t_{x,1})^2}{2} \\ \qquad \text{if } v_{x,t_0}+a_{x,a}t_{x,1}-a_{x,d}(t_{y,f}-t_{x,1}) \\ \qquad\quad \ge max(0,v_{x,1}-a_{x,1,d}t_{y,f}), \\ p_{x,t_0}+v_{x,t_0}t_{x,1}+\frac{a_{x,a}t_{x,1}^2}{2}+\frac{(v_{x,t_0}+a_{x,a}t_{x,1})^2}{2a_{x,d}} \\ \qquad \text{else if } \frac{v_{x,1}}{a_{x,1,d}}\le\frac{v_{x,t_0}+a_{x,a}t_{x,1}}{a_{x,d}}+t_{x,1}\le t,y,f, \\ p_{x,t_0}+v_{x,t_0}t_{x,1}+\frac{a_{x,a}t_{x,1}^2}{2}+(v_{x,t_0}+a_{x,a}t_{x,1})(t_{x,2}-t_{x,1}) \\ \quad -\frac{a_{x,d}(t_{x,2}-t_{x,1})^2}{2}-\frac{a_{x,1,d}(t_{y,f}-t_{x,2})^2}{2} \\ \quad +(v_{x,t_0}+a_{x,a}t_{x,1}-a_{x,d}(t_{x,2}-t_{x,1}))(t_{y,f}-t_{x,2}) \\ \qquad \text{else if } \frac{v_{x,1}}{a_{x,1,d}}\ge t_{y,f}, \\ p_{x,t_0}+v_{x,t_0}t_{x,1}+\frac{a_{x,a}t_{x,1}^2}{2}+(v_{x,t_0}+a_{x,a}t_{x,1})(t_{x,2}-t_{x,1}) \\ \quad -\frac{a_{x,d}(t_{x,2}-t_{x,1})^2}{2}+\frac{(v_{x,t_0}+a_{x,a}t_{x,1}-a_{x,d}(t_{x,2}-t_{x,1}))^2}{2a_{x,1,d}} \\ \qquad \text{otherwise,} \end{cases} \tag{6}$$

其中，$p_{x,\ t_0}$和$v_{x,\ t_0}$分别是自车在 $t=0$时的纵向位置和速度。

根据初始状态和$t_{y,\ f}$，公式（6）中有四种情况，分别对应图3中的四条速度曲线。黑色实线和黄色点划线分别表示自车 E和前车 L_1的速度曲线。第一种情况表示，自车在减速至与车辆 L_1 速度相同并改变减速度之前，已经完成横向运动。第二种情况是，自车以$a_{x,\ d}$减速直至停止，然后保持 $v_x=0$，直到$t=t_{y,\ f}$。第三种情况是，自车在以减速度$a_{x,\ 1,\ d}$到达 $v_x=0$ 之前，已经完成横向运动。第四种情况表示自车以$a_{x,\ 1,\ d}$减速直至停止，然后保持 $v_x=0$，直到$t=t_{y,\ f}$。

鉴于两辆车在$t=t_x$,2时达到相同速度，我们有 $v_{x,t_0}+a_x$,$_at_x$,$1-a_x$,$_dt_x$,$1-a_x$,1,$_dt_x$,2。在这四种情况下，自车 E 与前车 L_1 之间的车间距在$t=t_{y,f}$时达到最小。令p_x,1,$_{t_{y,f}}-p_x$,$_{t_{y,f}}-p_m=0$，即可计算出 t_x,1 的值

$$t_{x,1}=\begin{cases} t_{y,f}-\sqrt{t_{y,f}^2+\frac{2v_{x,t_0}t_{y,f}-a_{x,d}t_{y,f}^2+2p_{x,t_0}+2p_m-2p_{x,1,t_{y,f}}}{a_{x,a}+a_{x,d}}} \\ \qquad \text{if } v_{x,t_0}+a_{x,a}t_{x,1}-a_{x,d}(t_{y,f}-t_{x,1}) \\ \qquad\quad \ge max(0,v_{x,1}-a_{x,1,d}t_{y,f}), \\ -\frac{v_{x,t_0}}{a_{x,a}}+\sqrt{(\frac{v_{x,t_0}}{a_{x,a}})^2-\frac{2p_{x,t_0}a_{x,d}+v_{x,t_0}^2+2p_ma_{x,d}-2p_{x,1,t_{y,f}}a_{x,d}}{(a_{x,a}+a_{x,d})a_{x,a}}} \\ \qquad \text{else if } \frac{v_{x,1}}{a_{x,1,d}}\le\frac{v_{x,t_0}+a_{x,a}t_{x,1}}{a_{x,d}}+t_{x,1}\le t_{y,f}, \\ \frac{-(v_{x,t_0}-v_{x,1})+\sqrt{(v_{x,t_0}-v_{x,1})^2-2(a_{x,a}+a_{x,1,d})C_2}}{a_{x,a}+a_{x,1,d}} \\ \qquad \text{else if } \frac{v_{x,1}}{a_{x,1,d}}\ge t_{y,f}, \\ \frac{-(v_{x,t_0}-v_{x,1})+\sqrt{(v_{x,t_0}-v_{x,1})^2-2(a_{x,a}+a_{x,1,d})C_2}}{a_{x,a}+a_{x,1,d}} \\ \qquad \text{otherwise,} \end{cases} \tag{7}$$

where $C_2=\frac{(v_{x,t_0}-v_{x,1})^2+(2p_{x,t_0}+2p_m-2p_{x,1})(a_{x,d}-a_{x,1,d})}{2(a_{x,a}+a_{x,d})}$.

需要指出的是，如果$\frac{t_{y,f}^2+\ \ \ \ ,t_0t_{y,f}-a_x,_dt_{y,f}+2p_x,_{t_0}+2p_m-2p_x,}{1t_{yf},,,,d}\le 0$，自车可以持续加速，直到$a_x+a_xt_{y,f}$，即 $t_{x,1}=t_{y,f}$，并保持安全。如果在第一种情况下 $2v_{x,t_0}t_{y,f}-a_{x,d}t_{y,f}^2+2p_{x,t_0}+2p_m-2p_{x,1,t_{y,f}}>0$，或在第二种情况下 $2p_{x,t_0}a_{x,d}+v_{x,t_0}^2+2p_ma_{x,d}-2p_{x,1,t_{y,f}}a_{x,d}>0$，或在第三和第四种情况下 $C_2>0$，则有$t_{x,1}<0$，这意味着即使自车从 $t=0$开始以 $a_{x,d}$持续减速，也无法避免碰撞，这意味着不存在安全避让轨迹。

令 τ_1 表示自车减速至与前车速度相同所需的时间，令 τ_2 表示自车纵向减速至速度为零所需的时间。我们在图3中展示了四种情形下的 τ_1 和 τ_2。根据$t_{x,\ 1}$的值，可以得到时刻 $t\in[0,t_{y,f}]$ 自车的位置：

$$p_{x,t}=\begin{cases} p_{x,t_0}+v_{x,t_0}t+\frac{a_{x,a}t^2}{2} \\ \qquad \text{if } t\in[0,t_{x,1}], \\ p_{x,t_0}+v_{x,t_0}t_{x,1}+\frac{a_{x,a}t_{x,1}^2}{2}+(v_{x,t_0}+a_{x,a}t_{x,1})(t-t_{x,1}) \\ \quad -\frac{a_{x,d}(t-t_{x,1})^2}{2} \\ \qquad \text{else if } t\in[t_{x,1},min(\tau_1,\tau_2,t_{y,f})], \\ p_{x,1,t}-p_m \\ \qquad \text{otherwise.} \end{cases} \tag{8}$$

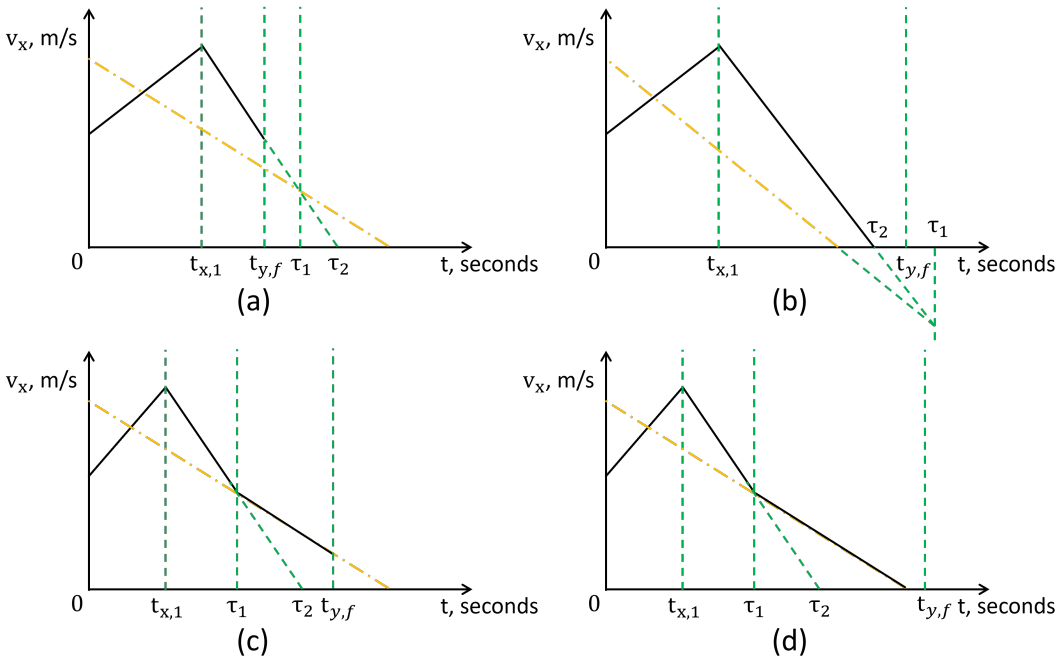

图3：根据初始状态和$t_{y,\ f}$，自车E的纵向避让轨迹有四种情况，分别展示在四个子图中。黑色实线和黄色点划线分别表示自车 E 和前车 L_1的速度曲线。(a)表示自车在减速至与车辆 L_1 速度相同并改变减速度之前，已经完成横向运动。(b)表示自车以$a_{x,\ d}$ 减速直至停止，然后保持 $v_x = 0$，直到$t = t_{y,\ f}$。(c)表示自车在以减速度$a_{x,\ 1,\ d}$到达 $v_x = 0$ 之前，已经完成横向运动。(d)表示自车以$a_{x,\ 1,\ d}$ 减速直至停止，然后保持 $v_x = 0$，直到$t = t_{y,\ f}$。

假设后车以$a_{x,\ f} \in [-a_{x,d}, a_{x,a}]$加速，其在 t 时的位置为

$$p_{x,f,t} = \begin{cases} p_{x,f} + v_{x,f}t + \frac{a_{x,f}t^2}{2} \\ \qquad \text{if } v_{x,f} + a_{x,f}t \geq 0, \\ p_{x,f} + \frac{v_{x,f}^2}{2|a_{x,f}|} \\ \qquad \text{otherwise.} \end{cases} \tag{9}$$

在本研究中，我们采用与 [19] 相同的假设：如果后车具有协同性，且愿意为自车留出间隙，则至少可以以 $a_{x,f} = -a_{x,d}$ 的加速度减速；如果后车具有攻击性，那么在最坏情况下，它可以以 $a_{x,f} = a_{x,a}$ 的加速度加速，以阻止自车切入。如果$p_{x,\ t} - p_{x,f,t} \geq p_m, \forall t \in [0, t_{y,f}]$，则安全避让轨迹存在，其表达式见公式（8）。若该轨迹存在，自车便可继续行驶并执行规划轨迹；否则，为确保安全，自车必须采取较不理想的行为，例如在两条车道的边界附近犹豫不决，或返回原车道。需要指出的是，返回原车道这一行为对应于上一个控制步计算出的避让轨迹，该轨迹已验证为安全且可行。

4 实验结果

4.1 我们的框架在完全协调下的有效性

本节首先展示连接增强型规划器框架的统计性能，然后通过一个示例展示详细轨迹。我们比较了几种不同规划器下的系统性能，以证明所提方法的有效性：“CV_all”表示图2所示的完整规划器框架，其中利用了所有联网车辆共享的信息；“CV_follow”表示仅使用后方联网车辆 F 共享的信息；“CV_none”表示未采用连接技术的规划器，该规划器见 [19]，可视为我们的主要基线；“No_agg_assess

，

这意味着我们保守地假设后车始终具有攻击性，并禁用激进性评估函数。

在本研究中，我们使用合成数据训练纵向和横向规划器，这与文献 [19]中的做法类似。我们通过均匀采样开展了大量仿真，采样范围为$v_{x,t_0} \in [29, 31]$ 米/秒和 $\delta p \in [17, 22]$ 米，并设置 $a^m{}_i{}^d = 0.5$ 米/秒²、$v_{x,i} = 30$ 米/秒、 $i = 1, \cdots N$。其中， δp 表示初始纵向车间距。

图4展示了联网前车数量为

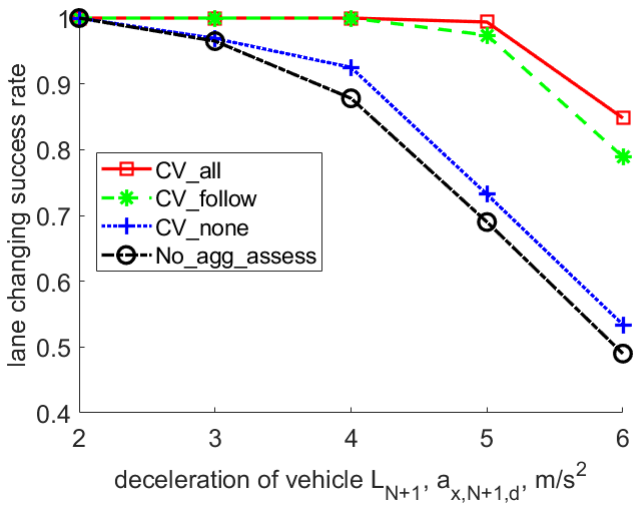

图4：比较联网前车数量为 $N = 5$ 时，不同规划器的换道成功率。横轴表示非联网前车的突然减速度 L_{N+1}。

$N = 5$时不同规划器下的平均换道成功率。横轴表示非联网前车的突然减速度 L_{N+1}。如果自车在仿真时域内最终越过两条车道的边界且未发生碰撞，则视为换道成功。由于轨迹调整函数确保了安全性，且所有仿真中确实均未发生碰撞，因此我们只展示换道成功率的结果。

正如我们预期的那样，随着减速度 $a_{x,\ N+1,\ d}$ 增大，换道成功率会降低。在这些规划器中，“CV_all”、“CV_follow”和“CV_none”分别表示完全、部分和完全不利用互联性。“No_agg_assess”表示禁用激进性评估函数的情况，此时利用的信息较少，决策也更加保守。结果表明，“CV_all”的表现略优于“CV_follow”，并且这两种规划器的成功率明显高于“CV_none”和“No_agg_assess”。**这清楚地表明，我们的方法能够有效提升系统性能**。这意味着，了解后车的意图有助于自车进行换道操作，而前车的互联性还能进一步提升换道效果。

表1展示了 N和$a_{x,\ N+1,\ d}$变道时的平均换道成功率。结果一贯表明，互联性的利用程度越高，系统性能越好。此外，随着N 增大，换道成功率也会提高，因为更多互联的前车能够协同为自车留出更大的空间。

图5通过一个具体示例展示了我们规划器设计的性能，其中 $N = 5$ 和 $a_{x,\ N+1,\ d} = 5$ 米每二次方秒。图中显示了不同规划器下自车的横向位置和纵向速度。在“CV_all”规划器下，自车约在三秒内完成变道。在其他三个规划器下，自车首先向目标车道横向移动

表1：不同规划器的换道成功率。

N	$a_{x,N+1,d}$	所有CV_	跟驰CV_	无CV_	无_聚合_评估
1	2	1	1	0.995	0.995
	3	1	1	0.875	0.83
	4	0.356	0.337	0.23	0.195
	5	0.001	0	0	0
	6	0	0	0	0
3	2	1	1	1	1
	3	1	1	0.928	0.894
	4	0.998	0.982	0.712	0.672
	5	0.534	0.489	0.288	0.256
	6	0.01	0.008	0.024	0.022
10	2	1	1	1	1
	3	1	1	1	1
	4	1	1	0.993	0.998
	5	1	1	0.969	0.956
	6	1	1	0.95	0.928

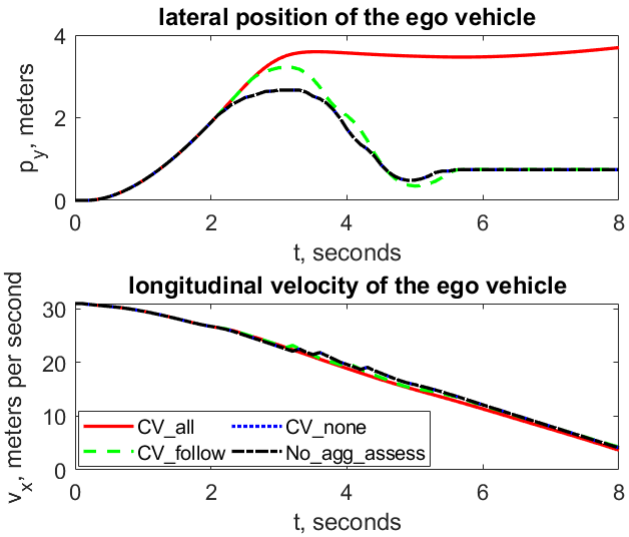

在不同规划器下，示例场景中自车的横向位置和纵向速度如图所示；网联前车数量为 $N = 5$，非网联前车的减速度为 L_{N+1} $a_{x,\ N+1,\ d} = 5$ 米每平方秒。

，然后在 $t = 3$ 秒时转回原车道。与“CV_none”和“No_agg_assess”相比，“CV_follow”使自车在目标车道停留的时间更长。在此示例中，“CV_none”和“No_agg_assess”使自车产生相同的轨迹。

4.2 意外违反承诺的影响

根据第3节中提出的承诺 假设，网联前车 L_i 将保持其加速度在以下范围内

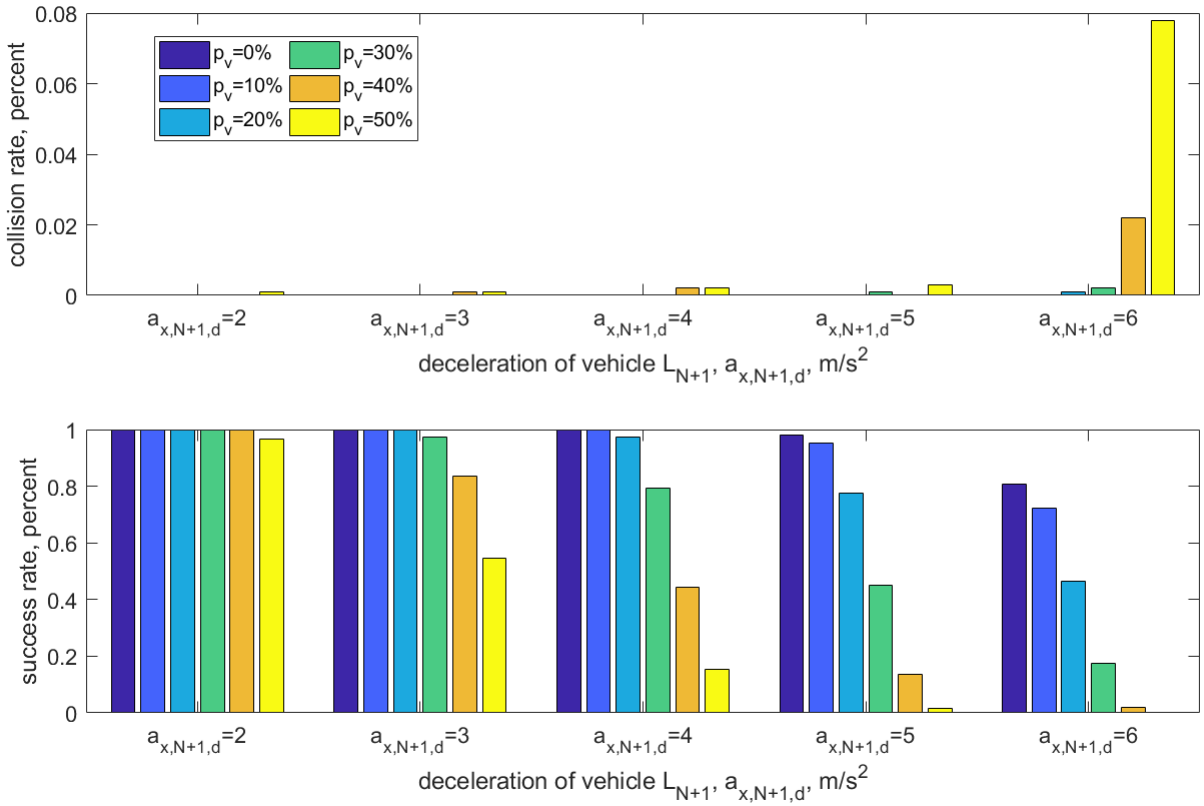

图 6：当联网前车数量为 $N = 10$ 时，展示不同承诺违约率下的碰撞率和换道成功率。承诺违约率 p_v 是指每个控制周期内承诺意外遭到违约的概率。我们假设所有联网车辆之间的承诺违约相互独立，且车辆违约时可采取符合均匀分布 $[z_{x,i,d}, a_{x,N+1,d}]$ 的任意减速度。横轴表示非网联前车的急剧减速度 L_{N+1}。

$[-a_i^{m,d}, a_i^{m,a}]$ 只要这不会损害其自身安全性。我们将承诺违约率 p_v定义为每个控制周期内承诺意外遭到违反的概率。我们假设所有联网车辆之间的承诺违约相互独立，并且车辆违约时可以按照均匀分布 $[z_{x,i,d}, a_{x,N+1,d}]$ 采取任意减速度。

图 6 展示了首辆非联网前车 L_{N+1} 采取不同急剧减速度 a_x 时$N+1,\ d$，不同承诺违约率 p_v 下的碰撞率和换道成功率。总体而言，承诺违约率和减速度越高，换道成功率越低，碰撞风险越高。然而，当承诺违约率不超过 20%，且急剧减速度小于每秒平方 5 米时，碰撞率为 0%，成功率仍然相对较高。**这表明我们的方法具有鲁棒性**。

5 结论

本文提出了一种互联性增强的规划框架，用于混合交通中基于神经网络的变道。该框架通过与动态环境中的周围网联车辆协同，能够显著提升变道性能。大量实验表明，我们的规划器设计在提升效率的同时能够确保安全性。实验结果表明：(1) 紧邻后车的互联性对自车变道的影响比前车的互联性更重要；(2) 网联前车越多，系统性能就越能进一步提升，因为更多车辆可以协同为自车留出更大的空间。我们还展示了在周围网联车辆的承诺违约率处于不同水平时，系统仍具有鲁棒性。

参考文献

[1] Yasir Ali、Md Mazharul Haque、Zuduo Zheng、Simon Washington 和 Mehmet Yildirimoglu。2019。基于风险率的持续时间模型：量化网联驾驶环境对强制变道期间安全性的影响。《交通研究C辑：新兴技术》106 (2019)，113–131。[2] Shunsuke Aoki、Takamasa Higuchi 和 Onur Altintas。2020。利用深度强化学习为网联车辆实现协同感知。载于《2020年IEEE智能车辆研讨会（IV）》。IEEE，328–334。[3] Zhangjie Cao、Erdem Bıyık、Woodrow Z Wang、Allan Raventos、Adrien Gaidon、Guy Rosman 和 Dorsa Sadigh。2020。基于强化学习的模仿策略控制，用于近事故驾驶。arXiv预印本 arXiv:2007.00178 (2020)。[4] Pin-Chun Chen、Xiangguo Liu、Chung-Wei Lin、Chao Huang 和 Qi Zhu。2023。利用网联自动驾驶汽车作为交通调节器进行混合交通路口管理。载于《第28届亚洲及南太平洋设计自动化会议论文集》（日本东京）（ASPDAC '23）。计算机协会，美国纽约州纽约市，52–57。https://doi.org/10.1145/3566097.3567849[5] Jiqian Dong、Sikai Chen、Yujie Li、Runjia Du、Aaron Steinfeld 和 Samuel Labi。2020。利用空间加权信息融合和基于深度强化学习的控制，促进网联自动驾驶车辆运行。arXiv预印本 arXiv:2009.14665 (2020)。[6] Runjia Du、Sikai Chen、Yujie Li、Paul Young Joun Ha、Jiqian Dong、Panagiotis Ch Anastasopoulos 和 Samuel Labi。2021。针对混合交通流中碰撞迫近情形下自动驾驶车辆的协同碰撞规避框架。载于《2021年IEEE国际智能交通系统会议（ITSC）》。IEEE，1997–2002。[7] Jaime F Fisac、Andrea Bajcsy、Sylvia L Herbert、David Fridovich-Keil、Steven Wang、Claire J Tomlin 和 Anca D Dragan。2018。利用基于置信度的人类行为预测实现概率安全的机器人规划。arXiv预印本 arXiv:1806.00109 (2018)。[8] Yuchuan Fu、Changle Li、Tom H Luan、Yao Zhang 和 Guoqiang Mao。2018。用于有效路口碰撞规避的基础设施协同算法。《交通研究C辑：新兴技术》89 (2018)，188–204。[9] Mario H Castaqeda Garcia、Alejandro Molina-Galan、Mate Boban、Javier Gozalvez、Baldomero Coll-Perales、Taylan Şahin 和 Apostolos Kousaridas。2021。5G NR V2X通信教程。《IEEE Communications Surveys & Tutorials》(2021)。[10] Paul Young Joun Ha、Sikai Chen、Jiqian Dong、Runjia Du、Yujie Li 和 Samuel Labi。2020。利用网联自动驾驶汽车的能力和多智能体强化学习缓解高速公路瓶颈拥堵。arXiv预印本 arXiv:2010.05436 (2020)。[11] Songyang Han 和 Fei Miao。2020。利用反馈式深度强化学习为网联自动驾驶车辆进行行为规划。arXiv预印本 arXiv:2003.04371 (2020)。[12] Ruochen Jiao、Xiangguo Liu、Takami Sato、Qi Alfred Chen 和 Qi Zhu。2022。用于轨迹预测的半监督语义引导对抗训练。arXiv预印本 arXiv:2205.14230 (2022)。[13] Ruochen Jiao、Xiangguo Liu、Bowen Zheng、Dave Liang 和 Qi Zhu。2022。TAE：半监督、可控且具备行为感知能力的轨迹生成器与预测器。载于《2022年IEEE/RSJ智能机器人与系统国际会议（IROS）》。IEEE，12534–12541。[14] John B Kenney。2011。美国的专用短程通信（DSRC）标准。《IEEE学报》99，7 (2011)，1162–1182。[15] Mohammad Khayatian、Mohammadreza Mehrabian 和 Aviral Shrivastava。2018。RIM：面向网联自动驾驶车辆的鲁棒路口管理。载于《2018年IEEE实时系统研讨会（RTSS）》。IEEE，35–44。[16] Jinning Li、Liting Sun、Wei Zhan 和 Masayoshi Tomizuka。2020。利用真实交通数据验证的自动驾驶车辆交互感知行为规划。载于《动态系统与控制会议》，第84287卷。美国机械工程师学会，V002T31A005。[17] Zhaoting Li、Wei Zhan、Liting Sun、Ching-Yao Chan 和 Masayoshi Tomizuka。2020。采用非保守防御策略的自适应采样运动规划，用于自动驾驶。《IFAC-PapersOnLine》53，2 (2020)，15632–15638。[18] Xiangguo Liu、Chao Huang、Yixuan Wang、Bowen Zheng 和 Qi Zhu。2022。基于分层神经网络的规划器的物理感知安全保障设计。《2022年ACM/IEEE第13届信息物理系统国际会议（ICCPS）》（2022），137–146。[19] Xiangguo Liu、Ruochen Jiao、Bowen Zheng、Dave Liang 和 Qi Zhu。2023。面向基于神经网络的变道的安全驱动交互式规划。载于《第28届亚洲及南太平洋设计自动化会议论文集》（日本东京）（ASPDAC '23）。计算机协会，美国纽约州纽约市，39–45。https://doi.org/10.1145/3566097.3567847[20] Xiangguo Liu、Neda Masoud 和 Qi Zhu。2020。共享驾驶态度信息的影响：一项关于变道的定量研究。载于《2020年IEEE智能车辆研讨会（IV）》。IEEE，1998–2005。[21] Xiangguo Liu、Neda Masoud、Qi Zhu 和 Anahita Khojandi。2022。将网络级数据纳入运动规划的马尔可夫决策过程框架

提升自动驾驶车辆的安全性。《交通研究C辑：新兴技术》136 (2022)，103543。[22] Xiangguo Liu、Yuan Zhao、Xi Chen、Qingxin Meng、Yixuan Wang、Chao Huang、Qi Zhu、Neda Masoud和Qi Zhu。2021。网联与自动驾驶车辆的轨迹规划：巡航、变道与编队行驶。SAE《联网与自动驾驶车辆国际期刊》4，12 04 04 0025 2021 315 333 - - - ( )，– 。[23] Yongyang Liu、Anye Zhou、Yu Wang和Srinivas Peeta。2021。针对人工驾驶车辆变道辅助的网联自动驾驶车辆主动纵向控制。载于2021年IEEE国际智能交通系统会议（ITSC）。IEEE，776–781。[24] Branka Mirchevska、Christian Pek、Moritz Werling、Matthias Althoff和Joschka Boedecker。2018。利用强化学习进行安全合理自主变道的高层决策。载于2018年第21届智能交通系统国际会议（ITSC）。IEEE，2156–2162。[25] Omar Nassef、Luis Sequeira、Elias Salam和Toktam Mahmoodi。2020。利用深度强化学习为联网车辆构建车道汇入协调机制。IEEE《物联网期刊》（2020）。[26] Piotr F Orzechowski、Annika Meyer和Martin Lauer。2018。利用基于集合的安全验证应对遮挡和有限传感器范围。载于2018年第21届智能交通系统国际会议（ITSC）。IEEE，1729–1736。[27] Juneyoung Park、Mohamed Abdel-Aty、Yina Wu和Ilaria Mattei。2018。在网联车辆环境中增强车内驾驶辅助信息。IEEE《智能交通系统汇刊》20，9（2018），3558–3567。[28] Christian Pek、Stefanie Manzinger、Markus Koschi和Matthias Althoff。2020。利用在线验证防止自动驾驶车辆引发事故。《自然·机器智能》2，9（2020），518–528。[29] Shai Shalev-Shwartz、Shaked Shammah和Amnon Shashua。2017。关于安全且可扩展的自动驾驶汽车的形式化模型。arXiv预印本arXiv:1708.06374（2017）。[30] Liting Sun、Wei Zhan、Ching-Yao Chan和Masayoshi Tomizuka。2019。具备社会感知能力的自动驾驶汽车行为规划。载于2019年IEEE智能车辆研讨会（IV）。IEEE，207–213。[31] Yixuan Wang、Chao Huang、Zhaoran Wang、Zhilu Wang和Qi Zhu。2022。设计即验证：通过验证在环实现构造正确的控制学习。载于第59届ACM/IEEE设计自动化会议论文集。925–930。[32] Yixuan Wang、Chao Huang和Qi Zhu。2020。为学习赋能的网络物理系统提供安全保证的能效控制自适应。载于第39届计算机辅助设计国际会议论文集（虚拟会议，美国）（ICCAD '20）。计算机协会，纽约，纽约州，美国，文章22，9页。https://doi.org/10.1145/3400302.3415676[33] Ziran Wang、Guoyuan Wu、Kanok Boriboonsomsin、Matthew J Barth、Kyungtae Han、BaekGyu Kim和Prashant Tiwari。2019。协同匝道汇入系统：利用游戏引擎进行基于智能体的建模与仿真。SAE《联网与自动驾驶车辆国际期刊》2，2（2019）。[34] Yaqi Wu、Anxing Xiao、Haoyao Chen、Shiwu Zhang和Yunhui Liu。2020。基于深度神经网络的非线性模型预测控制实现两栖机器人的轨迹跟踪。载于2020年IEEE/ASME先进智能机电一体化国际会议（AIM）。2019–2024。https://doi.org/10.1109/AIM43001.2020.9159003[35] Anxing Xiao、Hao Luan、Ziqi Zhao、Yue Hong、Jieting Zhao、Weinan Chen、Jiankun Wang和Max Q-H Meng。2022。通过渐进式感知和非线性模型预测控制实现机器人自主手推车收集。载于2022年机器人与自动化国际会议（ICRA）。IEEE，4480–4486。[36] Yang Xing、Chen Lv和Dongpu Cao。2019。基于联合时间序列建模的联网车辆个性化车辆轨迹预测。IEEE《车辆技术汇刊》69，2（2019），1341–1352。[37] Wei Zhan、Changliu Liu、Ching-Yao Chan和Masayoshi Tomizuka。2016。城市自动驾驶的非保守防御策略。载于2016年IEEE第19届智能交通系统国际会议（ITSC）。IEEE，459–464。[38] Zhengming Zhang、Renran Tian和Vincent G Duffy。2022。对自动驾驶车辆的信任：荟萃分析。载于《人机自动化交互：交通运输》。Springer，221–234。[39] Zhengming Zhang、Renran Tian、Rini Sherony、Joshua Domeyer和Zhengming Ding。2022。用于可解释自动驾驶的基于注意力的相互关系建模。IEEE《智能车辆汇刊》（2022）。[40] Bowen Zheng、Chung-Wei Lin、Shinichi Shiraishi和Qi Zhu。2019。容延智能交叉口管理的设计与分析。ACM《网络物理系统汇刊》4，1（2019），1–27。[41] Wei Zhou、Dong Chen、Jun Yan、Zhaojian Li、Huilin Yin和Wanchen Ge。2022。混合交通中网联自动驾驶车辆协同变道的多智能体强化学习。《自主智能系统》2，1（2022），1–11。[42] Qi Zhu、Chao Huang、Ruochen Jiao、Shuyue Lan、Hengyi Liang、Xiangguo Liu、Yixuan Wang、Zhilu Wang和Shichao Xu。2021。学习赋能自主系统的安全保障设计与自适应。载于第26届ACM/IEEE亚洲及南太平洋设计自动化会议（ASP-DAC）。