arXiv:2602.01892v1 [cs.RO] 2 Feb 2026

用于自动驾驶车辆的动态控制点混合路径跟踪：实验研究

Alexandre Lombard、Florent Perronnet、Nicolas Gaud、Abdeljalil Abbas-Turki

摘要—本文对一种自动驾驶车辆路径跟踪框架进行了实验研究。在该框架中，横向控制指令施加于轴距上的动态控制点。该方法并非将参考点固定在前轴或后轴，而是在两者之间连续插值，从而能够适应不同驾驶场景，包括低速机动和倒车运动。横向转向指令通过对两个互补控制器进行重心混合获得：基于前轴的 Stanley 公式和基于后轴曲率的几何控制器，由此实现转向行为的平滑过渡并提高跟踪稳定性。此外，我们还提出一种感知曲率的纵向控制策略，该策略基于虚拟赛道边界和光线追踪，将前方几何约束转换为虚拟障碍物距离，并据此调节速度。完整方法已集成至统一控制栈，并在仿真中以及一辆配备 GPS-RTK、雷达、里程计和 IMU 的真实自动驾驶车辆上进行了验证。闭环跟踪和倒车机动的结果表明，与固定控制点基准方法相比，该方法提高了轨迹准确性，使转向曲线更加平滑，并增强了适应性。

索引词—**自动驾驶车辆、横向控制、纵向控制**

I. 引言

自动驾驶车辆（AV）因其革新交通运输系统、提升道路安全和减少交通拥堵的潜力，已成为研究与开发的重点。自动驾驶车辆的核心功能在于控制系统，该系统负责控制车辆的运动，并确保车辆以高精度沿预定义轨迹行驶。在各种控制机制中，横向控制涉及车辆跟随期望路径的能力，仍是一个关键且具有挑战性的方面。

传统的横向控制策略主要通过调整转向角，尽量减小车辆实际路径与期望轨迹之间的横向偏差，具体考量车辆到路径的距离以及与路径的相对角度[3]。这类策略通常在一个固定点施加控制指令，该点通常是车辆质心或车身长度方向上的某个特定位置，从而影响车辆的航向

本文已提交至 IEEE Transactions on Intelligent Vehicles。研究工作得到 ANR/xHUB 的支持。所有作者均来自法国贝尔福的 UTBM、CIAD，邮编 F-90010。通讯作者：alexandre.lombard@utbm.fr

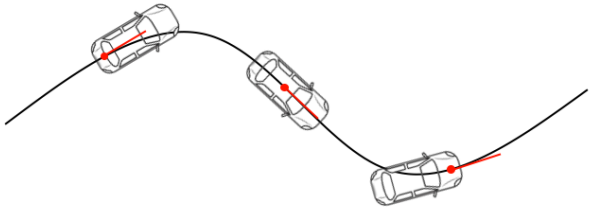


图 1. 横向控制中的三种不同控制点及其对车辆沿赛道跟踪时行为的影响

和路径跟踪能力。然而，这种传统方法可能存在局限性，尤其是在需要较高机动性的场景中，或面对多样化的道路条件时。

本文提出一种面向自动驾驶车辆的新型横向控制指令，相较现有方法具有显著进步。本方法的关键创新在于能够控制横向指令的作用点。这种灵活性允许选择车辆前部或后部作为轨迹跟随的参考点，从而影响车辆行为，如图1所示。由此，所提出的控制指令提升了车辆对各种驾驶场景的适应性，并改善了其整体轨迹跟踪性能。

切换控制指令作用点的能力带来多项益处。例如，控制车辆前部跟随轨迹可实现更精确的转弯，并在狭窄空间中获得更好的操控性，这在城市环境中尤为有利。相反，控制车辆后部可在高速机动或驶过湿滑路面时提升稳定性与安全性。在机动过程中（如倒车入库），能够动态调整控制点可能是必需的。此外，图2说明了选择控制点的能力如何简化路径规划过程。

此外，该方法结合了一种具备曲率感知能力的纵向控制方案，可根据待跟踪路径的曲率半径调整车速。将所提出的横向和纵向控制方法结合起来，可显著提高路径跟踪的准确性。

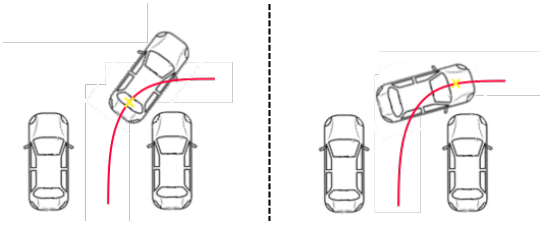


图 2. 示例：倒车泊车时，根据障碍物确定轨迹，选择控制点即可完成泊车

简要回顾相关研究后，我们首先详细介绍所提出的横向控制指令的数学表达。我们提出了一套实验方案，用于评估该指令在准确性和稳定性方面的可行性与性能。结果表明，在广泛的运行条件下，我们的方法显著提升了车辆的轨迹跟踪精度和响应能力。

总之，本文提出了一种用于自动驾驶车辆横向控制的创新方法，其特点是能够动态选择控制指令的作用点，并采用简单而稳健的方法根据路径曲率控制车辆速度。这种灵活性不仅拓展了自动驾驶车辆的运行能力，也为未来更先进、更具适应性的控制策略铺平了道路。

II. 背景

在研究车辆横向控制时，运动可分为两种类型：完整约束运动和非完整约束运动。完整约束车辆可根据需要在其构型空间中沿任意方向和朝向独立移动，这意味着其可控自由度与系统的总自由度相同。相比之下，非完整约束车辆受到不可积速度约束的限制，导致其有效机动性降低，无法进行某些瞬时运动，因此其可控自由度少于构型空间维数。本文聚焦于非完整约束车辆，因为它们更准确地代表了现实世界中的移动系统（例如道路车辆）：这类系统的运动受其机械设计和接触条件的固有限制，因此需要特定的运动规划与控制策略。

准确的车辆建模对于开发有效的横向控制算法至关重要，尤其是在实现具有可调应用点的自适应路径跟踪系统时。本节介绍本研究采用的运动学自行车模型，以捕捉车辆在横向机动过程中的基本行为特征。

运动学自行车模型 [4] 是一种简化表示，用于描述车辆运动的几何关系，而不考虑作用于车辆的动力学力。该模型特别适用于低速场景，此时轮胎力和惯性效应可以忽略不计。

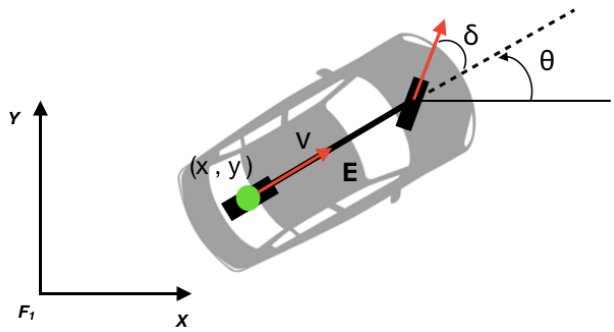


图 3. 运动学自行车模型

状态变量包括车辆的位置（x， y）、方向 θ和转向角 δ。运动方程如式（1）所示。

$$\begin{aligned} \dot{x} &= v\cos(\theta) \\ \dot{y} &= v\sin(\theta) \\ \dot{\theta} &= \frac{v}{E}\tan(\delta) \end{aligned} \tag{1}$$

其中： v 为纵向速度， E 为轴距（前后车轴之间的距离），如图 3 所示。

该模型假设所有车轮可合并为一个前轮和一个后轮（自行车近似），且车辆的横向运动完全由转向角δ引起；当车辆以安全方式行驶时，这是一种可接受的近似 [5]。

III. 相关工作

A. 横向控制

近几十年来，自动驾驶车辆横向控制领域得到了广泛研究， [2],人们提出了众多方法，以提高路径跟踪能力的准确性和鲁棒性。本节回顾了推动横向控制系统发展的相关研究和方法，并重点介绍了我们提出的新方法旨在解决的进展与局限。

横向控制的一项基础技术是纯追踪算法，它用于计算$\delta(t)$转向角，使车辆沿着一段圆弧行驶，该圆弧从后轴中点延伸至期望轨迹上的前视点。这种方法虽然简单，且在平滑路径上效果良好，但面对曲率的快速变化时可能难以应对，从而导致振荡和不稳定性。此外，纯追踪算法会给出预期转向角，使后轴中点到达前视点。因此，根据这一指令，车辆后部应沿轨迹行驶，但无法保证车辆前部也沿轨迹行驶。在这种情况下，指令的作用点是后轴中点。

另一种广泛采用的方法是斯坦利方法[6]，，它能同时最小化车辆与期望路径之间的横向误差和航向误差（公式 2 ）。Stanley 控制器在以下方面取得了显著改进：

与纯跟踪相比，其稳定性和准确性更高，尤其是在高速行驶时。然而，由于控制点的应用位置固定，该方法在低速机动或急转弯场景下的性能可能会下降。在 Stanley 控制指令中，横向误差$e_{fa}(t)$和角度误差 $\theta_e(t)$是根据车辆前部计算的，因此车辆前部是该指令的作用点（$v_x(t)$为车辆速度， k 为增益因子）。

$$\delta(t) = \theta_e(t) + tan^{-1}\left(\frac{ke_{fa}(t)}{v_x(t)}\right) \tag{2}$$

模型预测控制（MPC）也已被广泛应用于自动驾驶车辆的横向控制研究中 [7], [8]。MPC 会在有限时间范围内优化代价函数，同时考虑车辆动力学和约束，以生成控制输入。这种方法为处理复杂轨迹和动态环境提供了更全面的框架。然而，MPC 的计算复杂度以及实时实现方面的挑战，往往限制了其在快速变化场景中的实际应用。如果模型复杂度较高，且需要难以准确获取的数据，也会增加其应用难度。

近期研究探索了运用机器学习和数据驱动方法来增强横向控制。例如，深度强化学习 [9], [10]已被用于开发能够通过经验学习、适应各种驾驶条件的控制器。尽管这些方法在适应性和性能方面展现出良好的前景，但它们需要大量训练数据，而且在遇到新颖情况时可能出现泛化问题。此外，确保其安全性和鲁棒性也颇具挑战，因此通常不适用于现实世界的应用。

在 [11],中介绍了一种由（3）描述的几何方法，其效果优于当前最先进的方法，同时基于几何原理，避免了数据驱动方法所带来的问题。

$$\delta_t = s \times tan^{-1}\left(\frac{2Ecos(e_t - tan^{-1}(\frac{d}{e_d}))}{\sqrt{e_d^2 + d^2}}\right) + sin^{-1}\left(\frac{2E}{L}sin^{-1}\frac{\kappa}{2}\right) \tag{3}$$

多项研究专门探讨了控制指令的作用点。例如， [12]的研究提出了一种控制车辆前部和后部的框架，以提高高速机动过程中的稳定性。同样， [13]的工作提出了一种双控制点策略，可根据驾驶环境动态调整控制点。这些研究强调了灵活应用控制点的重要性，但通常涉及复杂的控制律，并需要大量计算资源。

我们的工作在这些奠基性研究的基础上，提出了一种横向控制指令，可在前部和后部作用点之间无缝切换。这种新颖的方法充分发挥了现有方法的优势，同时克服了其在适应性和计算效率方面的局限。通过提供一种更灵活、响应更迅速的控制机制，我们的方法提升了更广泛驾驶场景下的轨迹跟踪性能。

总而言之，尽管自动驾驶车辆横向控制领域已经取得了显著进展，但在实现高度适应性和精度方面仍然面临挑战。我们提出的方法通过提供一种灵活且高效的解决方案，为这一持续发展的研究作出了贡献。该方法能够动态调整控制指令的作用点，从而提升自动驾驶车辆横向控制系统的整体性能和鲁棒性。

B. 纵向控制

高效的纵向控制对于确保车辆安全性和乘客舒适性至关重要，尤其是在行驶于曲率变化的路径上时。根据路径曲率调整车辆速度，可以使轨迹更加平顺，降低打滑或失控的风险，并提升乘客舒适性。本小节回顾了现有的考虑路径曲率的纵向控制方法，并重点介绍其方法和对该领域的贡献。

车辆行驶在弯道上时，所受横向加速度与车辆速度的平方成正比，与曲率半径成反比 $a_{lat} = \frac{v^2}{R}$ 其中， a_{lat} 为横向加速度， v 为车辆速度， R 为路径的曲率半径。

过大的横向加速度会导致乘客不适，甚至造成车辆不稳定性。因此，根据曲率变化调整速度，对于维持安全、舒适的驾驶条件至关重要。

模型预测控制（MPC）因具备处理约束和预测未来状态的能力，已广泛应用于纵向控制。在曲率自适应速度控制中，模型预测控制算法通过最小化包含跟踪误差、控制量和乘客舒适性等项的代价函数来优化速度曲线 [14]。

基于规则的系统根据预先定义的规则调整车速，这些规则将速度与曲率或路况关联起来。这类系统更易于实现，且所需的计算能力较低。

模糊逻辑控制器利用模糊集和推理规则处理不确定性与非线性问题。它们能够有效地模拟类似人类的速度调整决策过程。

强化学习（RL）方法通过与环境交互来学习最优策略。在速度调整方面，强化学习智能体旨在最大化奖励函数，同时兼顾安全性、舒适性和效率。

IV. 自适应路径跟踪算法

A. 自适应横向控制

大多数横向控制方法旨在通过距离和角度差，尽可能减小车辆上的特定参考点与指定轨迹之间的偏差。这个参考点通常称为“控制点”。将控制点设在车辆前部，有助于使车辆前端精确沿轨迹行驶；将其设在后部，则可确保车辆后部与轨迹对齐。这两种策略都

切实可行，具体选择取决于驾驶情境。例如，在倒车机动（如停车）时，将控制点设在后部更有优势。因此，动态调整控制点的能力能够提升车辆横向控制的灵活性，使车辆更有效地适应不同的驾驶条件。

本文提出的方法基于 [6]和[11]。二者都是最先进的横向控制方案，但在设计上， [6] 将前轴中点作为控制点，而 [11]将后轴中点作为控制点。

因此，提出的控制指令由式 (4) 表示。

$$\delta(t) = \alpha \times \delta_{front}(t) + (1-\alpha) \times \delta_{rear}(t), \alpha \in [0,1] \quad (4)$$

$\delta_{front}(t)$可以是任何旨在使前轴沿赛道行驶的指令。应用 [6] 提出的方法，并由式 (2) 表示，可得 $\delta_{front}(t) = \delta_{stanley}(t)$。 $\delta_{rear}(t)$可以表示任何旨在使后轴沿赛道行驶的指令，因此我们设 $\delta_{rear}(t) = \delta_{cf}(t)$，其中 δ_{cf}表示采用[11], 中所述方法针对后轴参数化得到的控制输出。重心权重α 对应于期望控制点相对于前后车轴的位置。该权重决定了如何混合控制输出，以实现期望的控制行为。

此外，本文中的指令 $\delta_{cf}(t)$ 由式（5）表示。

$$\delta_{cf}(t) = s \times tan^{-1}\left(\frac{2Ecos(e_t - tan^{-1}(\frac{d}{e_d}))}{\sqrt{e_d^2+d^2}}\right) + tan^{-1}\left(\frac{2E}{L}sin^{-1}\frac{\kappa}{2}\right) \quad (5)$$

其中： s 等于1表示车辆位于轨迹左侧（否则为-1），E 为车辆的轴距， e_d 为后轴与轨迹之间的有符号距离， e_t 为车辆行驶方向与轨迹切线之间的角度； d 和 L 为“前视”距离， κ 为车辆行驶方向与前视距离 L处的轨迹切线之间的总曲率变化。与 [11], 相比，该表达式经过了修改，尤其是为了更好地控制车辆后部的运动；各参数均根据后轴的位置表示。这些修改所产生的影响将在第 VI 节中详细说明。

此外，尽管直观上可以通过对控制前轴的指令和控制后轴的另一条指令进行线性插值，以控制车辆上的任意点，但这一想法很难从理论上证明，因此，指令的验证是通过实验进行的，具体如第 V 节所述。

B. 倒车机动

使用可调节控制点，能够精确控制前轴位置或后轴位置。对后轴位置的控制尤其在某些倒车机动中非常有用；重要用例包括倒车入库或停靠。

为了使控制方案适用于倒车机动，我们利用式 (1) 所示运动学自行车模型的对称性。因此，在车辆倒车时，指令由式 (6) 给出。

$$\delta_{cf,r}(t) = s \times tan^{-1}\left(\frac{2Ecos(e_t - tan^{-1}(\frac{d}{e_d}))}{\sqrt{e_d^2+d^2}}\right) + tan^{-1}\left(\frac{2E}{L}sin^{-1}\frac{\kappa}{2}\right) \quad (6)$$

C. 基于虚拟边界的纵向控制

本节介绍一种根据赛道曲率调节自动驾驶车辆速度的模型。

事实上，根据赛道曲率调整车辆速度，是确保路径跟踪指令准确性的关键因素。速度过快时，纯滚动假设（无侧向滑移）将不再成立。为避免这种情况，我们设计了一种能够预判曲率的纵向控制方法。该方法的灵感来自人类驾驶员根据弯道视野调整车速的方式。具体而言，我们在赛道周围设置具有参数化宽度的虚拟边界，并采用光线追踪技术生成前方的虚拟障碍物。从车辆发出的射线与虚拟边界的第一个交点被视为虚拟障碍物，纵向控制模型据此计算车辆的加速。

1) 虚拟边界： 为将赛道曲率纳入速度调整模型，在赛道周围设置虚拟边界。这些边界定义了安全行驶走廊，其宽度 $w(s)$可通过参数化表示，并可根据道路条件或安全要求沿路径变化。

设赛道中心线由连续曲线 $C(s)$表示，其中 s 表示沿路径的弧长。虚拟边界 B_{left} 和 B_{right} 定义为相对于中心线的偏移量（7）。

$$\begin{aligned} B_{left}(s) &= C(s) + w(s)n(s) \\ B_{right}(s) &= C(s) - w(s)n(s) \end{aligned} \quad (7)$$

其中， $n(s)$是路径在点s处的单位法向量。参数化宽度 $w(s)$使行驶走廊的定义更灵活，能够适应不同的道路宽度和安全裕度。实际上，对于给定的限速，令 $w(s)$取常数即可得到令人满意的结果。

2) 用于虚拟障碍物检测的光线追踪： 该方法采用光线追踪来检测车辆前方的虚拟障碍物。从车辆当前位置 $P_v = (x_v,\ y_v)$ 沿其航向角 θ_v方向发射一条射线。该射线的数学定义见式 (8)。

$$R(t) = P_v + t \cdot d \quad (8)$$

其中， $t \geq 0$ 为标量参数， $d = [\cos(\theta_v), \sin(\theta_v)]$ 为车辆航向的单位方向向量。

射线与虚拟边界的交点 P_{obs} 表示虚拟障碍物的位置。与虚拟障碍物的距离 d_{obs} 根据式（9）计算。

$$d_{obs} = \min_{t \geq 0}\{t : R(t) \in B_{left} \cup B_{right}\} \tag{9}$$

该距离反映了车辆到达虚拟边界之前前方可用的空间，有效体现了赛道曲率对车辆路径的影响。

3）纵向控制：已知与虚拟障碍物的距离后，可以采用任何能够根据障碍物调整车速的纵向控制模型，例如智能驾驶员模型（IDM） [15]。

本文决定使用 IDM 进行自由流加速，并使用 [16], 中给出的指令（简化后如式（10）所示）来处理障碍物（已知虚拟障碍物的速度 v_l 等于 0），因为该模型能够处理系统的反应时间。

$$a_r = \frac{b_f\tau - 2v \pm 2b_f\sqrt{\frac{b_f b_l \tau^2 + 4b_l v\tau - 8b_l s}{4b_f b_l}}}{2\tau} \tag{10}$$

其中： a_r 为施加于车辆的加速度， b_f 为舒适减速度， b_l 为紧急减速度， s为与虚拟障碍物的距离， v 为车辆速度，τ 为系统的反应时间。

最终的纵向控制通过取自由流 IDM 与公式 (10) 之间的最小加速值得到，即 $a = \min(a_r, a_{idm})$。

V. 实验

为评估所提出的自适应路径跟踪算法，进行了仿真和实车测试。测试场景包括两个关键用例：直线轨迹跟踪和圆形赛道轨迹跟踪。选择这些用例旨在展示指令的稳定性，以及其应对多种驾驶条件的能力，包括连续路径跟随和低速倒车操作。

测试的目的是在实际测试场景中评估所提出的控制方案（包括纵向和横向控制）的表现，因此观察以下指标：

- 车辆相对于赛道的距离，用于评估指令的准确性和稳定性
- 车辆速度，用于观察通过指令如何管理弯道
- 指令的输出（即预期转向角），用于评估其稳定性

测试中考虑了 3 种情况：
1) 控制点设置在前轴上 2) 控制点设置在中间位置（位于前轴与后轴之间）3）控制点置于后轴
对于每种情况，我们分别测试前向和向后指令，共计 6 种不同的场景。

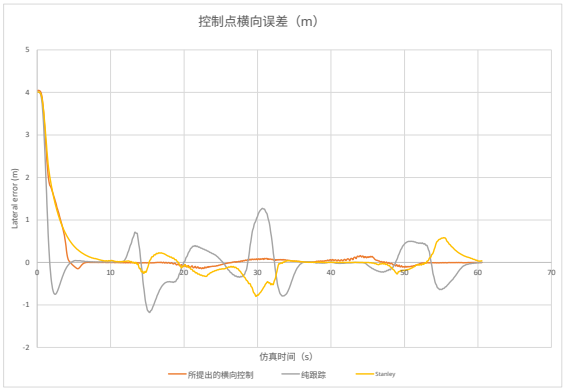


图4. 不同指令下控制点的横向误差（控制点与其在轨迹上的投影之间的距离，单位为米）

A. 仿真

仿真使用专门开发的仿真器进行，该仿真器实现了车辆运动的标准模型。仿真器可通过 https://alexandrelombard.github.io/autonomous-driving-sim/ 获取。该指令通过使用 Rust 开发的库实现。

测量指标包括横向偏差、航向误差和控制平滑度，用于评估跟踪性能。所提出的指令与纯跟踪和Stanley控制指令进行对比作为参考（这些横向控制方案采用常用参数）。

起始时，车辆被放置在距轨迹4米处，随后需要跟随缩小版的纽博格林赛道，该赛道包含若干不同曲率的弯道。

为评估指令在真实传感器条件下的稳定性，还进行了仿真：在测量数据上加入模拟均匀噪声，并模拟环境感知与指令施加之间的延迟。

图4以米为单位显示了控制点与其在赛道上的投影之间的横向误差。可以看出，与纯跟踪和Stanley控制指令相比，提出的控制指令的横向误差更小。起始阶段可观察到较小的超调，但其幅度小于纯跟踪，同时比Stanley更快到达轨迹。

图5显示了航向误差。该图说明了各指令的稳定性，而提出的控制指令的航向误差更集中于0附近，表明其稳定性优于另外两种指令。需要注意的是，快速振荡是由赛道离散化引起的，导致轨迹航向出现大量微小而迅速的变化。

最后，图 6 通过一个特定场景展示了采用动态控制点时指令的稳定性：在该场景中，控制点从车辆后部动态移动到前部。控制点的相对坐标在车辆后部为 0，在

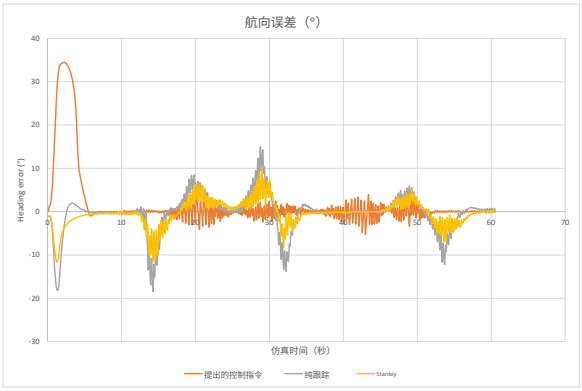


图 5. 控制点的航向误差（度）（车辆航向与控制点投影处轨迹航向之间的角度）

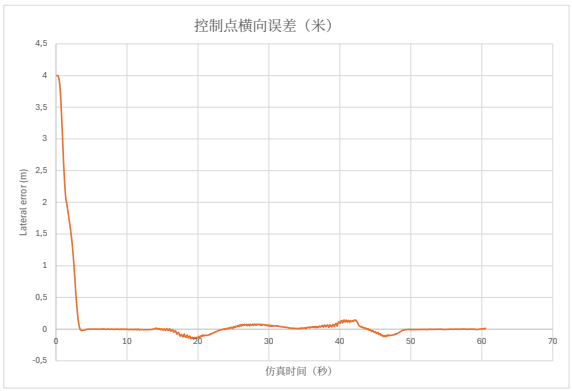


图 6. 使用提出的控制指令和移动控制点时控制点横向误差的变化

前部为 1，此时有效控制点由 $A(t) = 0.5 \times (sin(\omega t) + 1.0)$ 给出（本例中为 $\omega = 0.2$）。可以观察到，即使指令交替尝试使车辆前部和后部贴合赛道，其结果仍准确且稳定。

B. 真实世界验证

在真实自动驾驶车辆上部署了仿真中使用的同一 Rust 库，以验证该算法在真实世界场景中的有效性。将其直接部署到车辆上，确保了仿真环境与真实世界测试之间的一致性，从而能够在实际约束条件下对该算法的性能进行全面评估。

该无人车辆配备了以下传感器：

- GPS RTK，天线安装在靠近车辆轴距中心的位置
- 雷达
- 里程表



图 7. 赛道的俯视图，突出显示曲率突然变化的路段

参数	#1	#2	#3	#4	#5	#6
横向混合因子（α）	0.0	0.5	1.0	0.0	0.5	1.0
加速度指数 -（δ_{idm}）	3.0					
减速度因子 -	2.0					
最大减速度（b_f）	-4.0					
最大障碍物减速度（b_l）	-8.0					
路径宽度 m（$w(s)$）	12.0					
期望加速度（a）	1.0					
期望减速度（b）	-1.0					
期望速度 -（v）	3.0			1.0		
首选停车距离 -（s_0）	0.0					
反应时间（τ）	1.0					

表 I实车测试期间指令所使用的参数

- 惯性测量单元（IMU）

在闭环赛道上进行了 6 次测试，主要用于评估控制点变化对车辆轨迹的影响（3 次前向测试，控制点分别位于后轴、中部和前轴；另有 3 次向后测试）。测试开始时，将车辆放置在距赛道固定距离的位置，以观察控制系统如何尝试重新并入赛道。指令所用参数列于表 I 中。期望速度设定为较低值，因为在赛道上行驶过快很危险（尤其是赛道上有许多颠簸和坑洞）。图 7 展示了测试赛道和测试车辆的俯视图。

VI. 结果展示与讨论

图8显示了赛道坐标以及车辆尝试沿赛道行驶时测得的坐标（测试 #2，采用 ENU局部坐标系），可以看出车辆与参考赛道的距离有多近。

图9、图10展示了测试 #5 中控制点与赛道之间的相对距离（图9中车辆正在并入轨迹，图10中车辆正在沿轨迹行驶），体现了选择中间控制点的稳定性和准确性。

可以看出，测试 #5 的准确性较好（初始化后误差始终低于 0.15 m），而测试 #6（图11）的结果较差。这可以解释为，将控制点设置在前轴上时，仅使用 Stanley控制器，其行为不如公式（6）中的

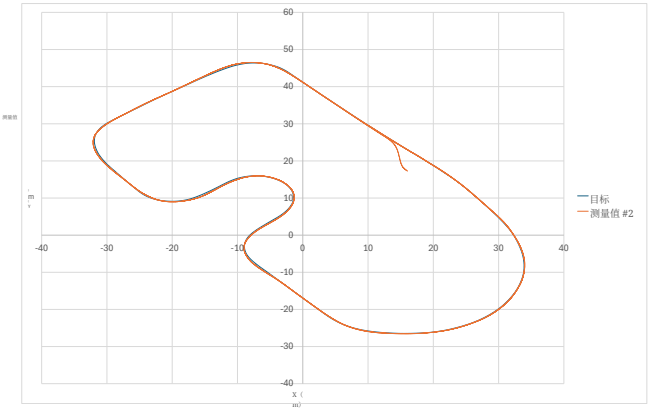


图8。 测试 #2 期间车辆在 ENU局部坐标系中的测量位置，与目标轨迹的对比

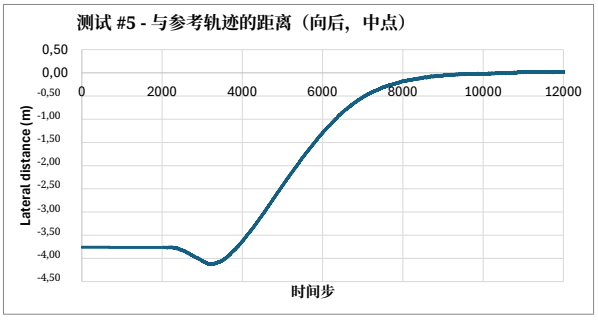


图9。 测试 #5 中车辆与参考赛道之间的横向距离（m），车辆到达目标轨迹

某一条指令准确。在这种情况下，图11可视为倒车机动的基准。另一方面，测试 #5 在中部应用该方法，表明两条指令可以有效融合。表II给出了各项测试的绝对平均距离，显示测试 #5 与测试 #6 之间的距离减少了 81.2%。测量值也评估了指令的稳定性。

所有测试的测量值见附录。

图15显示了测试 #2 期间的车辆速度（测试 #1 和测试 #3 的数值也相近，因为纵向控制不受控制点的直接影响）。可以清楚地看到车辆沿赛道行驶时速度的调整：曲率变化时减速，曲率保持不变时加速。

测试编号	平均距离（m）
1	0.043
2	0.042
3	0.026
4	0.050
5	0.049
6	0.260

表II初始化后控制点与参考赛道之间的平均距离

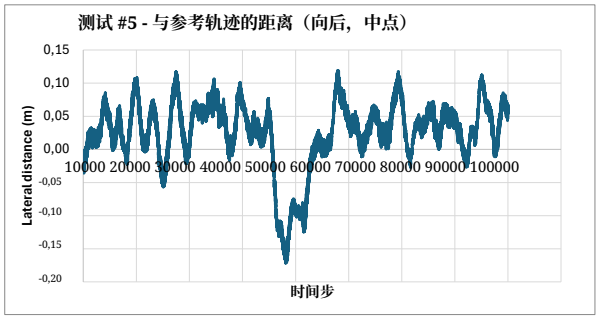


图10. 测试 #5 到达目标轨迹后，车辆与参考赛道之间的横向距离（m）

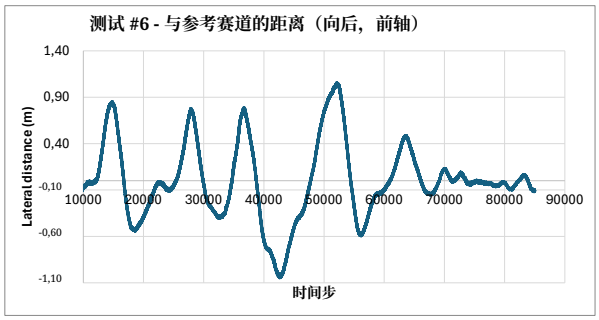


图11. 测试 #6 到达目标轨迹后，车辆与参考赛道之间的横向距离（m）

观测目标速度（$2.5m.s^{-1}$）与期望目标速度（$3.0m.s^{-1}$）之间的差异，是由比例控制器将指令中的目标加速度映射为油门控制所致。

VII. 结论

本文提出了一种面向自动驾驶车辆的自适应路径跟踪框架，通过连续融合施加于前后车轴的横向控制指令，并结合曲率感知纵向控制策略。该方法将横向转向指令表示为前轴 Stanley 控制器与后轴曲率几何控制器的重心组合，从而能够沿轴距动态选择有效控制点。这种灵活性使车辆能够在各种驾驶场景中无缝调整行驶行为，包括低速机动、急转弯和倒车。

在仿真和真实自动驾驶车辆上开展的实验结果表明，与固定控制点基线相比，所提出的方法显著提升了轨迹跟踪精度和转向平顺性。尤其是，中间控制点配置始终实现了准确性与稳定性之间的最佳折中；相较于仅采用前轴策略，在倒车机动中的测量横向误差降低了 80% 以上。实验还证实，这种混合

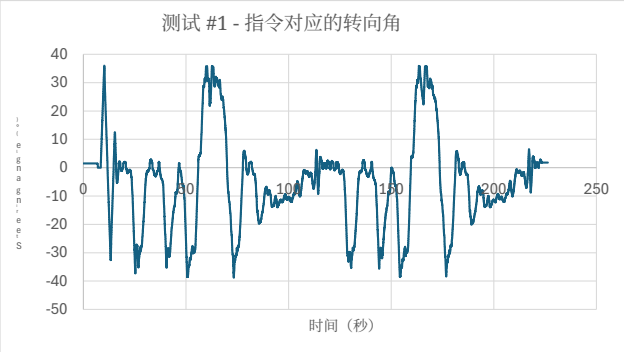


图12。 测试 #1 计算得出的转向角（°）

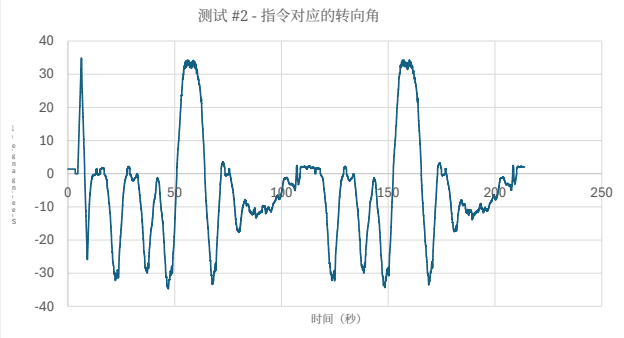


图13。 测试 #2 计算得出的转向角（°）

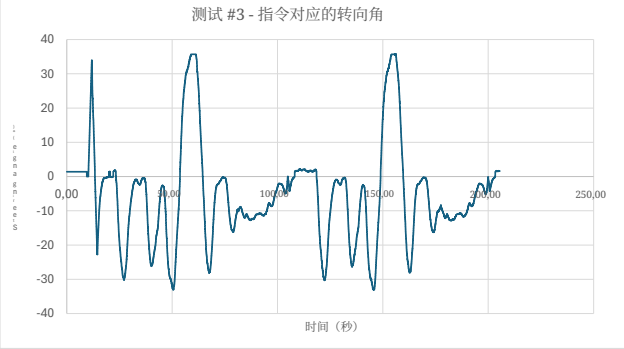


图14。 测试 #3 计算得出的转向角（°）

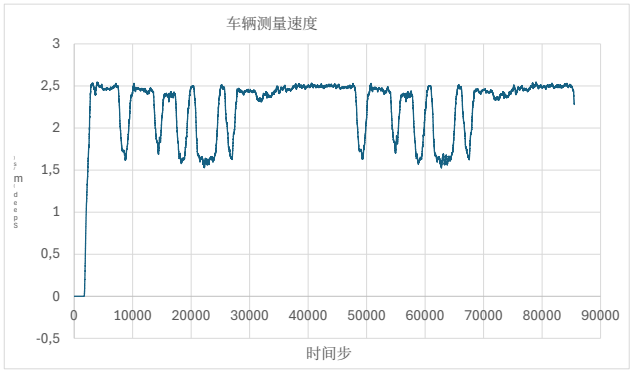


图15。 测试 #2 的车辆速度（m/s）

公式在存在传感器噪声和执行延迟的情况下仍能保持稳定，验证了其实际应用价值。

此外，所提出的基于虚拟边界的纵向控制能够有效预判即将出现的曲率变化，并据此调节车速。该方法通过射线追踪将几何约束转换为虚拟障碍物距离，以简单而稳健的机制实现速度调节，无需显式设置曲率阈值或进行复杂优化。由此得到的速度曲线呈现平滑的减速和加速阶段，有助于提升横向跟踪性能和整体车辆安全性。

总体而言，所提出的控制架构兼具简洁性、鲁棒性和适应性，在采用成熟控制律的同时，通过动态控制点融合扩展了其运行范围。未来工作将重点研究融合控制律的形式化稳定性分析、根据车辆状态和环境感知自动调整融合因子，以及将其扩展至扩展自行车模型，以处理牵引车-挂车系统。将所提出的框架集成到预测式或基于学习的监督层中，也是值得进一步研究的方向。

VIII. 参考文献

[1] I. O. Olayode、B. Du、A. Severino、T. Campisi 和 F. J. Alex，“自动驾驶车辆在道路运输系统中的应用、影响及公众认知：系统性文献综述”，*Journal of Traffic and Transportation Engineering (English Edition)*，第10卷，第6期，第1037–1060页，2023年。 [在线]。获取地址：https://www.sciencedirect.com/science/article/pii/S2095756423001216

[2] A. Artunedo、M. Moreno-Gonzalez 和 J. Villagra，“自动驾驶车辆的横向控制：比较评估”，*Annual Reviews in Control*，第57卷，文章编号100910，2024年。 [在线]。获取地址：https: //www.sciencedirect.com/science/article/pii/S1367578823000743

[3] S. Dominguez、A. Ali、G. Garcia 和 P. Martinet，“自动驾驶车辆横向控制器的比较：实验结果”，载于*2016*年*IEEE*第*19*届智能交通系统国际会议（*ITSC*），2016年。[4] P. Polack、F. Altch´e、B. d’Andr´ea Novel 和 A. de La Fortelle，“运动学自行车模型：一种用于自动驾驶车辆可行轨迹规划的一致模型？”，载于*2017*年*IEEE*智能车辆研讨会（*IV*）。IEEE，2017年，第812–818页。

[5] H. F. Grip、L. Imsland、T. A. Johansen、J. C. Kalkkuhl 和 A. Suissa，“车辆侧滑估计”，*IEEE*控制系统杂志，第29卷，第5期，第36–52页，2009年。[6] S. Thrun、M. Montemerlo、H. Dahlkamp、D. Stavens、A. Aron、J. Diebel、P. Fong、J. Gale、M. Halpenny、G. Hoffmann 等，“Stanley：赢得DARPA大挑战赛的机器人”，《野外机器人学报》，第23卷，第9期，第661–692页，2006年。[7] L. Song、J. Li、Z. Wei、K. Yang、E. Hashemi 和 H. Wang，“从单车到自动驾驶车队的纵向和横向控制方法”，《绿色能源与智能交通》，第2卷，100066，2023 2，第p. .[8] Y. Kebbati、V. Puig、N. Ait-Oufroukh、V. Vigneron 和 D. Ichalal，“用于自动驾驶车辆横向控制的优化自适应模型预测控制”，载于*2021*年第九届控制、机电一体化与自动化国际会议（*ICCMA*）。IEEE，2021年，第95–103页。[9] D. Li、D. Zhao、Q. Zhang 和 Y. Chen，“基于强化学习和深度学习的自动驾驶横向控制 [应用说明],”，《*IEEE*计算智能杂志》，第14卷，第2期，第83–98页，2019年。[10] J. Liu、Y. Cui、J. Duan、Z. Jiang、Z. Pan、K. Xu 和 H. Li，“基于强化学习的自动驾驶车辆高速路径跟踪控制”，《*IEEE*车辆技术汇刊》，2024年。[11] A. Lombard、J. Buisson、A. Abbas-Turki、S. Galland 和 A. Koukam，“用于汽车横向控制的基于曲率的几何方法”，《富兰克林学会学报》，第357卷，第14期，第9378–9398页，2020年。[12] P. Falcone、F. Borrelli、J. Asgari、H. P. Tseng 和 D. Hrovat，“面向自动驾驶车辆系统的预测式主动转向控制”，*IEEE*控制系统技术汇刊，第15卷，580，2007 3，第566 no. pp. – .[13] J. Wang 和 R. Rajamani，“通过切换控制点提升地面车辆的轨迹跟踪能力”，《*IEEE*控制系统技术汇刊》，第19卷，第6期，第1288–1298页，2011年。[14] L. Guan、P. Liao、A. Wang、L. Shi、C. Zhang 和 X. Wu，“采用速度自适应模型预测控制的智能车辆弯道车道变曲率路径跟踪控制”，*Proc. Inst.Mech. Eng. Pt. D: J. Automobile Eng.*，第238卷，第4期，第802–824页，2024年3月。[15] A. Kesting、M. Treiber 和 D. Helbing，“改进的智能驾驶员模型，用于评估驾驶策略对交通通行能力的影响”，《英国皇家学会哲学汇刊*A*辑：物理-

工程科学，第 368 卷，第 1928 期，第 4585–4605 页，2010 年。[16] F. Outay、A. Abbas-Turki、S. Galland、A. Lombard 和 N. Gaud，“基于反应时间的协同速度控制与智能驾驶员模型在自动驾驶汽车基于智能体的仿真中的比较”，*Procedia Computer Science*，第 203 卷，第 189–196 页，2022 年。

IX. 附录

A. 附录：测试的有符号距离

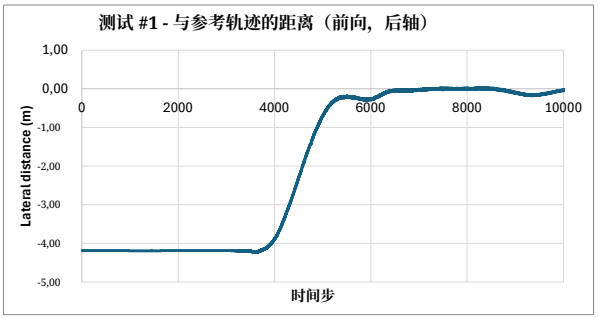


图 16. 测试 #1 到达目标轨迹时的横向距离

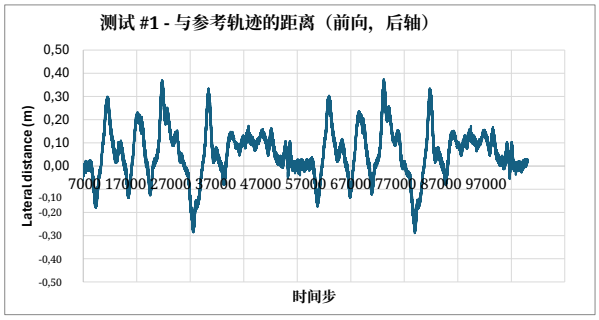


图 17. 测试 #1 到达目标轨迹后的横向距离

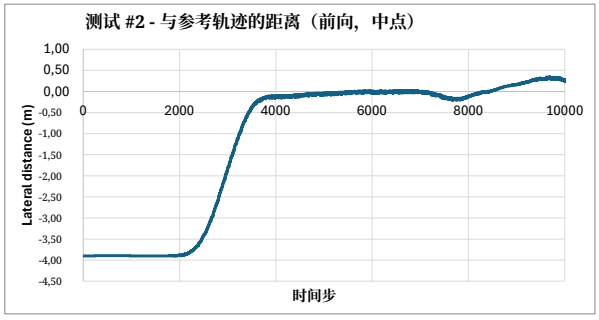


图 18. 测试 #2 到达目标轨迹时的横向距离

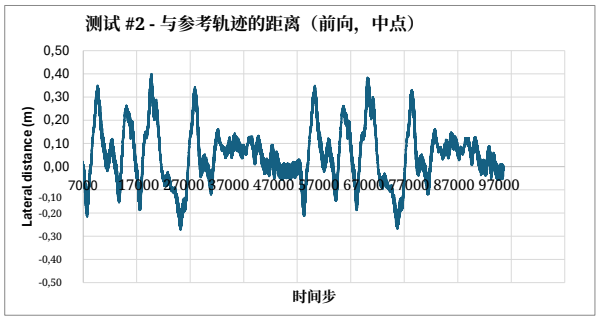


图 19. 测试 #2 到达目标轨迹后的横向距离

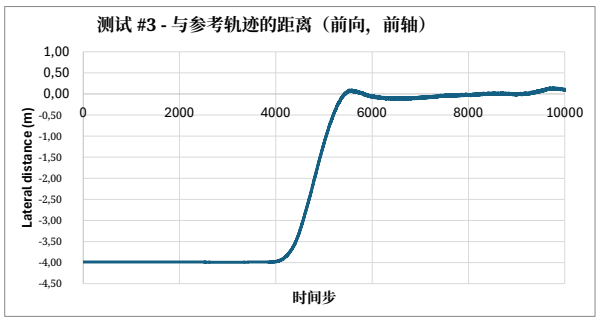


图 20. 测试 #3 到达目标轨迹时的横向距离

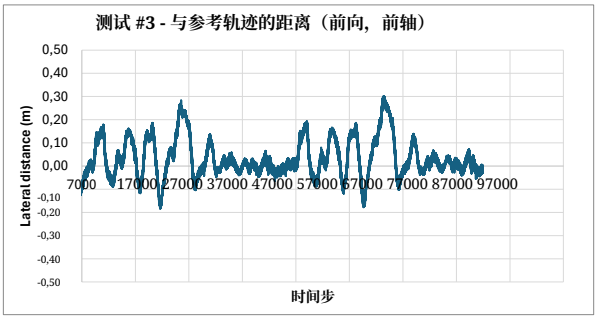


图 21. 测试 #3 到达目标轨迹后的横向距离

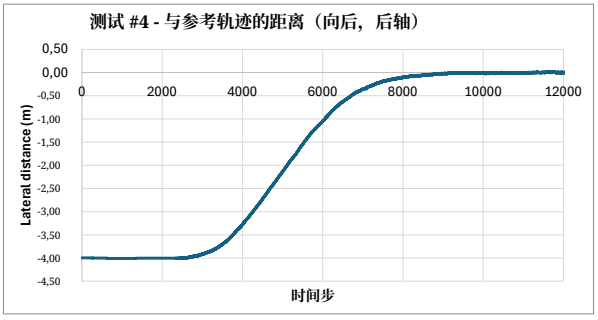


图 22. 测试 #4 到达目标轨迹时的横向距离

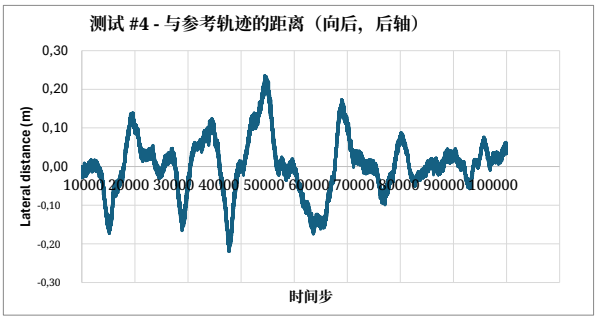


图 23. 测试 #4 到达目标轨迹后的横向距离

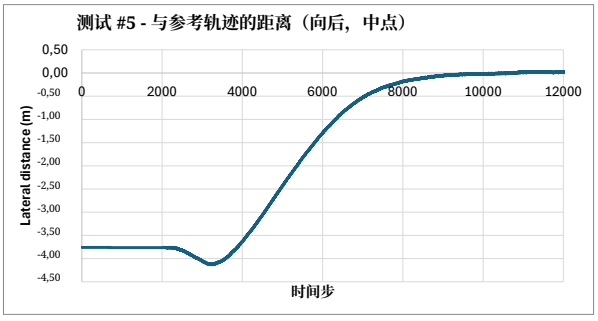


图 24. 测试 #5 到达目标轨迹时的横向距离

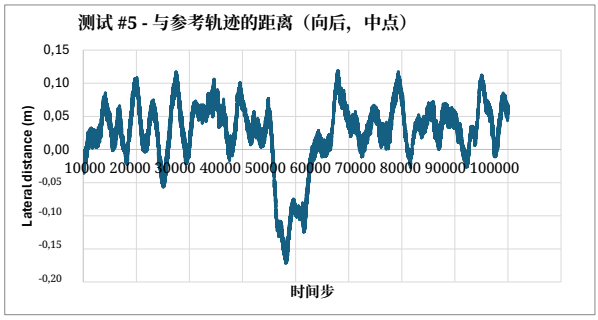


图 25. 测试 #5 到达目标轨迹后的横向距离

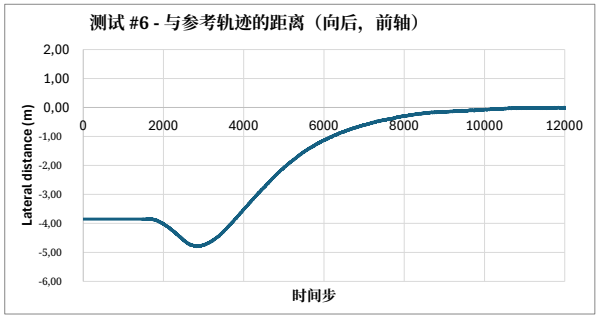


图 26. 测试 #6 到达目标轨迹时的横向距离

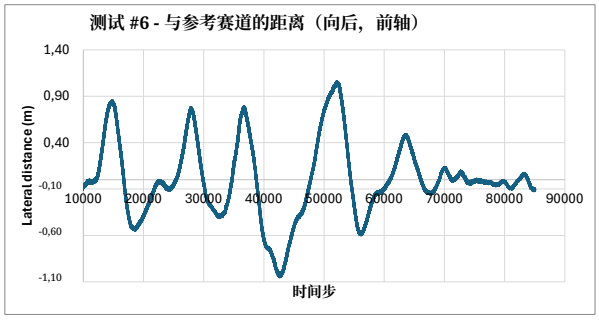


图 27. 测试 #6 到达目标轨迹后的横向距离