NMPC增强型大型移动机器人视觉导航与安全学习控制

Mehdi Heydari Shahna、Pauli Mustalahti 和 Jouni Mattila

arXiv:2601.00609v1 [cs.RO] 2 Jan 2026

摘要——**大型移动机器人（LSMR）是一种高阶多体系统，通常在松散、未压实的地形上运行，牵引力因此降低。本文提出了一种面向 LSMR 的综合导航与控制框架，可确保稳定性和满足安全性定义的性能，并通过协同运用高性能技术，使机器人能够在易打滑地形上稳定运行。所提出的架构包含四个主要模块：（1）视觉位姿估计模块，融合机载传感器与立体相机，以提供准确、低延迟的机器人位姿；（2）高层非线性模型预测控制，用于更新车轮运动指令，以纠正在易打滑地形上机器人相对于参考位姿的漂移；（3）低层深度神经网络控制策略，用于近似 LSMR 中车轮驱动执行机构的复杂行为，并结合鲁棒自适应控制处理分布外扰动，确保车轮准确跟踪高层控制模块发出的更新指令；（4）对数安全模块，用于监控整个机器人系统栈并确保安全运行。所提出的低层控制框架可保证执行子系统具有一致指数稳定性，而安全模块则确保运行期间整个系统的系统级安全。本文还开展了对比实验，实验对象为一台由两个复杂电静液驱动器驱动的 6,000 千克 LSMR，同时对不同频率运行的模块进行同步。**

关键词—**机器人学、鲁棒控制、自适应控制、人工智能。**

I. 引言

在VER未来二十年，重型车辆正通过整合自动化、物联网、机器人学、无人机和人工智能，转型为大型移动机器人（LSMR）。基于视觉的 LSMR 能够在非结构化环境中持续作业，降低事故风险，并提高钻孔、挖掘和重载搬运的精度，从而提升生产力 [1]。对于高性能机器人学而言，在系统模型准确的情况下，基于模型的控制是一种有效方法[2]。基于模型这一术语表示控制器设计在多大程度上融入了对系统动力学的了解。因此，由于其对自主导航 [3]的重要性，这种方法与基于视觉的算法相结合，如今已成为学术界和工业界的重点关注方向。

大多数现代基于模型的控制器都需要准确的被控对象模型，通常以传递函数或状态空间形式给出 [4]。然而，与轻型机器人相比，大型地面移动机器人通常采用复杂的机械传动链，例如电机、联轴器和齿轮箱，将动力传递至接地车轮以产生运动 [5]。执行器链中的每个环节都有各自的非线性动态特性，使输入到输出的行为变得复杂 [6]。因此，要为大型地面移动机器人设计高性能控制，需要构建高参数模型，而这类模型在解析上复杂且计算开销大 [7]。为避免依赖完全精确的模型，近期研究通常基于简化动力学设计控制器 [8], ，并有意省略车轮与地形的相互作用以及其他难以表征的行为[9]。这些简化可能会降低控制性能。为应对这一挑战，机器学习模型架构能够直接从可用数据中学习，从而准确近似复杂的系统动力学并提升控制性能 [10]。遗憾的是，将这些高性能学习方法部署到大型地面移动机器人上并不容易，因为训练好的模型缺乏可解释性，在高风险场景中难以使用。此外，大型地面移动机器人即使只是稍微偏离规定轨迹，也可能导致系统不稳定并造成高昂损失 [11]。而且，这些方法受训练分布限制，当测试数据超出训练域时，性能会很差[12], ；对于在易打滑地形上行驶的大型地面移动机器人 [13], ，由于无法收集涵盖所有运行条件的数据以实现泛化，因此失去移动能力的风险会增加 [14]。例如， [15] 中的大型地面移动机器人系统需要人工监督，以补偿各个车轮的打滑，从而降低了自主性。打滑受车辆因素（质量、速度、轮胎气压）和地形属性（沙地压实度、岩石摩擦、表面粗糙度）的影响。因此，目前数吨重的越野大型地面移动机器人需要额外的模块，以减轻过度车轮打滑所导致的定位误差和路径跟踪误差 [13]。为应对这一挑战，需要一种高效的高层控制，能够实时检测打滑，并在考虑安全约束的同时，智能调整驱动层所需的车轮运动，使机器人返回期望路径。非线性模型预测控制（NMPC）可与能够利用多个传感器读数的兼容算法配合，在线更新参考运动 [16]。在实践中，将非线性模型预测控制实时部署到大型地面移动机器人上并不容易，因为非线性模型预测控制需要快速优化、稳健的状态估计，以及嵌入式硬件上的确定性时序；这些要求限制了预测时域长度和模型保真度，也使闭环执行面临挑战 [17]。 [18] 中提出的多重射击法可使非线性模型预测控制的公式实现稳健的最优控制，同时适用于实时执行 [19]。然而，如果控制回路的速度慢于系统动力学

本研究由 BusinessFinland 合作项目“未来全电动崎岖地形自主移动操作机器人”（资助编号：2334/31/2022）提供经费支持。所有作者均任职于芬兰坦佩雷大学工程与自然科学学院，邮编 33720。（通讯邮箱：mehdi.heydarishahna@tuni.fi）

，控制器就无法抑制快速扰动，从而可能导致不稳定；对于导航与控制子系统必须紧密同步的大型地面移动机器人而言，这类在线实现尤其困难。最后，要保证大型地面移动机器人整个导航与控制系统的闭环稳定性和性能仍然颇具挑战，相关文献中尚未对此进行验证。

本文提出了一种全面的 LSMR 架构，以应对上述挑战，具体如下：1）为避免对 LSMR 建立复杂的多阶段动力学模型，本文在驱动层采用监督式深度神经网络（SDNN），同时利用鲁棒自适应律补偿分布外扰动，从而实现高跟踪性能。2）经过深入评估后，本文为所研究的 LSMR 实施并调优了一套采用双目摄像头配置的高性能视觉同步定位与建图（SLAM）系统。3）为减轻未固结地形上过度车轮打滑造成的定位误差，本文采用多重射击法，使非线性模型预测控制能够实时更新用于驱动层控制的参考车轮运动，同时考虑关键约束。4）框架中集成了对数安全模块，以确保运行安全，并支持采用黑箱方法。因此，所提出的基于 SDNN 的低级控制框架保证了执行子系统的一致指数稳定性，而安全模块则确保整个系统在运行期间的安全。5）通过真实环境实验验证了性能提升，同时实现了不同频率运行组件之间的同步。据我们所知，这是首篇报告一种 LSMR 的研究，该系统融合了视觉 SLAM、高级与低级控制以及对数障碍安全监督器，并提供驱动层稳定性保证和全系统安全保障。

本文其余部分的组织如下。第二节在复杂的车轮驱动执行机构中，通过自适应控制器构建 SDNN策略，将实际的大扭矩车轮运动调整为所需运动。第三节介绍视觉 SLAM方法的实现，以便在导航过程中进行准确的位姿估计。第四节构建高层 NMPC，融合传感器数据以补偿车轮打滑，并根据同步定位与建图模块获取的当前机器人状态，细化参考车轮运动。第五节进行稳定性分析，并建立一致指数稳定性。第六节对适用于一台 6,000 kg LSMR 的整体框架进行实验验证。

II. 低级控制：鲁棒 SDNN（RSDNN）

LSMR 采用复杂的驱动机构来产生高驱动力，其中包含多个能量转换级（电动或液压，或两者兼有）、齿轮传动以及车轮与地面相互作用，这使得系统建模极具挑战性。然而，为确保车轮跟踪指令运动，需要高性能控制来实时调节执行器信号，而这依赖于对这种复杂轮内驱动动力学的准确建模。例如，本文研究的 LSMR 是一台重 6000 千克的滑移转向机器人，采用混合式轮内

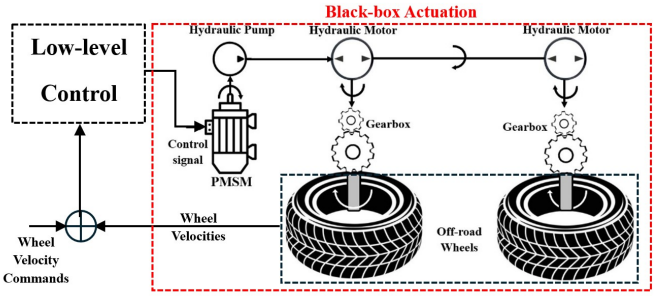

图1：作为黑箱模型的电静液驱动。

架构：两侧各有一个永磁同步电机（PMSM），驱动一台液压泵，为两个轮内液压马达（每个车轮一个）产生压差；扭矩通过齿轮减速机构传递至车轮。在本文中，我们将整个驱动机构视为一个黑箱，仅已知其输入和输出，而内部行为未知；见图1。

A. 用于建模驱动机构的 *SDNN*策略

由于所研究的 LSMR 每侧的两个车轮速度相同，我们将 SDNN 方法的输入统一为每侧的速度指令：

$$v_i = r\theta_i \qquad i \in \{L, R\}$$ 其中，

$\theta_i \in \mathbb{R}$是 LSMR i侧的角速度指令，$r \in \mathbb{R}$ 是车轮半径。SDNN 的输出是 PMSM 转速信号 $u_{\mathrm{SDNN}_i} \in \mathbb{R}$。对于每一侧，我们可以在用户监督下，在安全工作范围内沿两个方向将控制输入（执行器信号）u_{SDNN_i} 从 0 逐渐提升至额定极限，同时通过传感器读数记录相应的车轮速度，从而采集黑箱机制的输入/输出数据。然后，我们可以为每一侧使用一个前馈SDNN，即多层感知器（MLP）。网络有 L个隐藏层，其大小为n_ℓ（$\ell = 1, \ldots, L$），其中 $n_0 = 1$且 $n_{L+1} = 1$。对于第ℓ层，$a^{(0)} = v_i$，$z^{(\ell)} = W^{(\ell)} a^{(\ell-1)} + b^{(\ell)}$，$a^{(\ell)} = \varphi^{(\ell)}(z^{(\ell)})$，其中 $W^{(\ell)} \in \mathbb{R}^{n_\ell \times n_{\ell-1}}$ 是权重矩阵，$\varphi^{(\ell)}$ 是激活函数（例如双曲正切），$b^{(\ell)} \in \mathbb{R}^{n_\ell}$是相应的偏置向量，预激活（仿射变换）记为 $z^{(\ell)}$，$a^{(\ell)} \in \mathbb{R}^{n_\ell}$。输出层为 $\varphi^{(L+1)}(z) = z$，其中 $u_{\mathrm{SDNN}_i} = a^{(L+1)} = z^{(L+1)}$。对于包含 P个样本的小批量，将其堆叠成 $1 \times P$输入行 $\mathcal{V}_i = [v_i^{(1)} | v_i^{(2)} | \cdots | v_i^{(P)}] \in \mathbb{R}^{1\times P}$。逐层前向传播为 $A^{(\ell)} = \varphi^{(\ell)}(W(\ell) A^{(\ell-1)} + b^{(\ell)}\mathbf{1}^T)$，其中 $A^{(0)} = \mathcal{V}_i$，其中 $\mathbf{1} \in \mathbb{R}^P$ 是全 1 列向量。令 $\psi = \{W^{(\ell)}, b^{(\ell)}\}_{\ell=1}^{L+1}$ 表示所有可训练参数。我们使用误差损失（）来量化预测 u_{SDNN_i} 与目标 t_{p_i} E_{MSE} $\psi = \frac{1}{P}\sum_{p=1}^{P} \|u_i^{(p)} - t_{p_i}^{(p)}\|_2^2 =$ 之间 $\frac{1}{P}\|U_i - T_{p_i}\|_F^2$ U_i T_{p_i} $n_{L+1} \times P$ 的偏差，其中 和 分别是将网络输出和目标堆叠而成的矩阵，$\|.\|_F$ 表示弗罗贝尼乌斯范数。为减少相较于普通梯度下降的迭代次数，我们采用莱文伯格–马夸尔特法（LM）反向传播：将训练表示为非线性最小二乘问题，利用高斯–牛顿法近似海森矩阵，并通过阻尼项 [20]提高稳定性。令 $w \in \mathbb{R}^{N_w}$ 堆叠所有可学习参数：对每一层，将 $W^{(\ell)}$ 与 $b^{(\ell)}$拼接。其

长度为 $N_w = \sum_{\ell=1}^{L+1} (n_\ell n_{\ell-1} + n_\ell)$。将每个样本的误差堆叠为 $\xi_{p_i}(w) = [\xi_{p_i}^{(1)}, \xi_{p_i}^{(2)}, \ldots, \xi_{p_i}^{(P)}]^T \in \mathbb{R}^{mP}$，其中 $m = n_{L+1} = 1$。均方误差（按 $1/P$缩放）为 $E_{\text{MSE}}(w) = \frac{1}{P}\|\xi_{p_i}(w)\|_2^2 = \frac{1}{P}\xi_{p_i}(w)^\top \xi_{p_i}(w)$。因此，最小化 $E_{\text{MSE}}(w)$ 是一个非线性最小二乘问题。定义雅可比矩阵为J_k, $_j(w) = \frac{\partial s_k}{\partial w_j}(w)$，其中 s_k 是堆叠误差向量ξ_{p_i}的第 k个元素，而 E_{MSE} 的精确梯度为 $\nabla E_{\text{MSE}}(w) = \frac{2}{P}J(w)^T \xi_{p_i}(w)$。由于海森函数中的一项包含二阶导数，计算精确的牛顿步 $\Delta w = -H(w)^{-1}\nabla E(w)$ 代价很高。高斯–牛顿法则使用 $H(w) \approx \frac{2}{P}J(w)^T J(w)$，得到 $\Delta w_{\text{GN}} = -(J^T J)^{-1} J^T \xi_{p_i}$。为缓解 $J^T J$接近奇异的问题，加入蒂霍诺夫阻尼，得到 $\Delta w = -(J^T J + \mu I)^{-1} J^T \xi_{p_i}$。当 μ 较大时，μI 占主导，且 $\Delta w \approx -\frac{1}{\mu} J^\top \xi = -\eta \nabla E_{\text{MSE}}$，其中 $\eta = 1/\mu$；随着 $\mu \to 0$，该方法恢复为高斯–牛顿步。因此，LM 在稳定但较慢的梯度下降法与快速但稳定性较差的高斯–牛顿法之间平滑切换。在第 b 次迭代中：在 w_b处计算 J_b、ξ_b；选择 μ_b；求解 $(J_b^\top J_b + \mu_b I)\Delta w_b = -J_b^\top \xi_b$；设置 $w_{\text{cand}} = w_b + \Delta w_b$ 并评估E_{MSE}。若有所改善，则接受 $w_{b+1} = w_{\text{cand}}$ 并减小μ（$\mu_{b+1} = \mu_b/\beta$，$\beta \approx 10$）；否则，保留 $w_{b+1} = w_b$ 并增大 μ（$\mu_{b+1} = \beta\mu_b$）。

B. 自适应控制增强的已训练 *SDNN* 模型

通过评估并达到可接受的结果后，经过 LM 训练的 SDNN 模型即可在实时运行中接收速度指令 $v_i = r\theta_i$，并输出预测的控制信号 u_{SDNN_i}，该信号作为与车轮参考速度 θ_i 相对应的低级控制框架中的驱动建模项。这意味着，如果机器人运行期间的状况始终处于训练数据分布范围内，那么理想情况下，对于机器人的每一侧，我们都有如下二阶动力学：

$$A_i\ddot{\theta}_i(t) = u_{\text{SDNN}_i}(\dot{\theta}_i, t) + F_i(\dot{\theta}_i, t) \tag{1}$$

其中，这是标称条件，$\theta_{\text{msr}_i} = \theta_i$ 和 $F_i \in \mathbb{R}$ 表示由机器人在标称条件下的驱动机构以及 $A_i \in \mathbb{R}^+$决定的未知非线性映射。然而，在 LSMR 中，可能会出现分布外条件和外部扰动。在此类条件下，应用基于 SDNN 的策略会产生偏离参考值的测量车轮速度，从而导致非零误差 $e_i(t) = \theta_{\text{msr}_i} - \theta_i$。因此，我们将式（1）中的理想模型扩展为真实世界形式：

$$A_i(\ddot{\theta}_i + \dot{e}_i) = u_i(t) + F_i(\dot{\theta}_i, t) + d_i(\dot{\theta}_i, e_i, t) \tag{2}$$

其中 $d_i(\cdot) \in \mathbb{R}$ 捕获未建模动力学和扰动，而 $u_i(t)$ 是需要设计的控制信号。因此，由式（1）和式（2）最终可得

$$\dot{e}_i = A_i^{-1}[u_i(t) - u_{\text{SDNN}_i}(\dot{\theta}_i) + d_i(\dot{\theta}_i, e_i, t)] \tag{3}$$

假设 *II.1*。与鲁棒控制领域已有研究结果一致，[21], 假设函数控制增益 A_i 以及动力学函数 $F_i(\cdot)$和 $d_i(\cdot)$均局部 Lipschitz 连续且有界。

现设计如下控制策略 $u_i(\cdot)$，该策略在执行机构的所有运行条件下均有效，包括标称条件和受扰条件：

$$u_i(t) = u_{\text{SDNN}_i}(\dot{\theta}_i) - \frac{1}{2}\epsilon_i e_i - \gamma_i e_i \log^2\left(\frac{O}{O-E}\right)\hat{\chi}_i \tag{4}$$

其中，$\gamma_i \in \mathbb{R}^+$ 和 $\epsilon_i \in \mathbb{R}^+$，而 $\hat{\chi}_i$ 是所提出的自适应律，定义如下：

$$vbfvfvf39\dot{\hat{\chi}}_i(t) = -\delta_i\hat{\chi}_i + \gamma_i e_i^2 \log^2\left(\frac{O}{O-E}\right) \tag{5}$$

其中 $\delta_i \in \mathbb{R}^+$，且$\hat{\chi}_i(t_0) \in \mathbb{R}^+$。根据 [5], [22], 并如式（4）和式（5）所示，我们在所提出的底层控制框架中定义一个对数障碍函数，作为整个系统的安全模块。此处，$E(t)$表示机器人位姿误差，其定义为

$$E = \sqrt{||\boldsymbol{x}_{\text{msr}}(t) - \boldsymbol{x}^r(t)||^2} \tag{6}$$

其中 $\boldsymbol{x}^r(t) \in \mathbb{R}^3$ 为参考位姿轨迹，$\boldsymbol{x}_{\text{msr}}(t) \in \mathbb{R}^3$ 为测量机器人位姿。我们施加阈值安全约束 $0 \le E(t) < O$，其中 $O > 0$。

注释 *II.1.* 如式（1–6）所示，如果机器人初始位姿满足 $E(t_0) < O(t_0)$，则运行期间会将跟踪误差限制为满足 $E(t) < O(t)$，对所有 t 均成立。据此，对于对数安全模块，如果 $E(.)$ 增大至预定义的安全界限 $O(.)$，则可能出现数值奇异；当计算值超出数值限制 [5] 时，执行可能因警告（例如“遇到 Infinity 或 NaN 值”）而停止。安全监控器可以运行一个清晰的状态机，在接近屏障时限制速度，在越界时执行确定性的制动曲线，并在触发急停时锁定为安全停止状态。

假设 *II.2.* 所需轨迹 $\boldsymbol{x}^r(t)$ 在流形 $SE(2)$ 上可微且连续。

III. 基于视觉的机器人位姿

如式（6）所示，底层控制框架中设计的安全模块需要实时获取机器人位姿估计 $\boldsymbol{x}_{\text{msr}}(t)$。对于越野LSMR，基于视觉的位姿估计可提供高频定位和环境感知，而基于全球导航卫星系统（GNSS）的位姿估计会受到传播损伤 [23] 的影响而精度下降。此外，视觉SLAM是一种更可取的无GNSS架构，因为它能够通过回环检测实现重新定位和漂移校正，其地图还可进一步用于避障及其他功能，从而支持在未知环境中的长期导航[24]。文献 [25]介绍了成熟的开源系统 ORB-SLAM3。该系统在室内和室外环境中实现了实时双目视觉SLAM，具有稳健的回环检测能力，并在 EuRoC [26] 和 TUM-VI [27]上取得了顶尖精度。因此，本文将 ORB-SLAM3 用作所研究 LSMR 的位姿估计模块，因为它在标准基准测试中精度高且鲁棒性强。该系统通过 DBoW2 实现回环检测和地图融合，并使用 EPnP 进行重定位。ORB-SLAM3 是一种紧密集成、基于关键帧和特征点的视觉SLAM系统，采用最大后验（MAP）方法结合多种时间数据关联策略来估计姿态。它还支持使用针孔或鱼眼相机模型处理我们的双目输入。ORB-SLAM3 可通过 C++实现，

并使用多个开源库。该系统接收相机帧，运行跟踪线程以提取 ORB特征，根据上一帧或通过重定位、地图初始化来估计当前姿态，维持与局部地图的对齐，并判断何时创建新的关键帧。Atlas 管理多个地图，其中一个为活动地图，其余为非活动地图；每个地图都包含关键帧、地图点、共视图以及用于多会话复用和后续合并的生成树。DBoW2关键帧数据库提供视觉词汇和识别索引，以便快速进行地点识别和重定位。局部建图线程会插入新关键帧、剔除近期地图点和冗余关键帧、创建新点、执行局部光束法平差和尺度优化。闭环检测和地图合并通过数据库查询来检测地点、计算 SE3 或 Sim3 约束、融合回环、优化本质图，并连接或合并独立地图。回环校正或地图合并后，全局光束法平差会优化整个地图 [25]。最后，状态 $\mathcal{S}$ 包含相机姿态 $\mathbf{T} = [\mathbf{R}\ \boldsymbol{x}_{\text{msr}}] \in SE(3)$，其中 $\boldsymbol{x}_{\text{msr}} \in \mathbb{R}^3$ 是姿态向量，$\mathbf{R} \in SO(3)$ 是旋转矩阵。第六节将介绍面向所研究 LSMR 的 ORB-SLAM3 模块的实验实现和参数调优。

IV. 高层控制

如图1所示，LSMR 的执行器控制需要车轮速度指令，以使机器人执行特定的运动任务。然而，由于 LSMR 在易打滑地形上运行，这些指令必须实时更新。利用测量机器人位姿 $\boldsymbol{x}_{\text{msr}}$（见第五节），我们设计了一种高层控制器，用于实时更新车轮控制指令，以补偿参考位姿轨迹中的打滑引起的偏差，同时满足运动约束。本文采用 [28]，提出的多重射击非线性模型预测控制作为高层控制，并配合一种兼容算法，利用多种传感器读数实现真正的实时性能。在该方法中，转录阶段 [13] 将无限时域最优控制问题（OCP）转换为非线性规划问题（NLP），并在每次迭代时执行，以实现实时运行速度和同步感知。假设机器人本体坐标系位于车轮坐标系的几何中心。用机体坐标系表示，机器人的旋量为$\boldsymbol{\nu}^{(b)} = [\ v_x \quad v_y \quad \omega_z\ ]^\top \in \mathbb{R}^3$，其中包含沿 x和 y 方向的线速度，以及绕 z的角速度。定义向量 $\dot{\boldsymbol{\theta}} = [\ \dot{\theta}_R \quad \dot{\theta}_L\ ]^\top \in \mathbb{R}^2$，其中包括机器人右侧和左侧的速度。局部坐标系根据一阶运动学映射 [29], 推导得出，即 $\boldsymbol{\nu}^{(b)} = \boldsymbol{J}\dot{\boldsymbol{\theta}}$，其中雅可比矩阵定义为

$$\boldsymbol{J} = \frac{r}{2}\begin{bmatrix} 1 & 0 & 1/c \\ 1 & 0 & -1/c \end{bmatrix}^\top \tag{7}$$

其中，c 是横向轨道宽度的一半，r 是车轮半径。

假设 *IV.1*。在移动机器人中，通常假设横向速度为零，即 $v_y = 0$，因此机体坐标系 b受限于沿路径的切线方向运动。

使用螺旋理论，李群 $SE(2) = \mathbb{R}^2 \times SO(2)$ 表示帧间所有平面刚体运动，机体坐标系 b 相对于 W 的运动状态为 $\boldsymbol{x}_W^b = \begin{bmatrix}\boldsymbol{p}_W^b\ \alpha_W^b\end{bmatrix} \in \mathbb{R}^3$。$\boldsymbol{p}_W^b \in \mathbb{R}^2$ 和 α 分别表示位置和方向，而 $SO(2)$ 和 $SE(2)$ 是正交矩阵和欧几里得矩阵的李群。$\boldsymbol{x}_W^b \in \mathbb{R}^{3\times3}$ 可由齐次变换 $\boldsymbol{G}_W^b \in \mathbb{R}^{3\times3}$ 得到，如下所示

$$\boldsymbol{G}_W^b = \begin{bmatrix} \boldsymbol{R}_W^b & \boldsymbol{p}_W^b \\ \mathbf{0} & 1 \end{bmatrix} \tag{8}$$

由于 $\boldsymbol{\nu}^{(b)}$ 属于 $SE(2)$，可以通过伴随算子 $\text{Ad}_G : SE(2) \to \mathbb{R}^{3\times3}$ [30]将其转换到惯性坐标系 W。因此，将 $\boldsymbol{\nu}^{(W)}$ 视为位姿时间导数 $\dot{\boldsymbol{x}}$，可得到速度层运动学模型

$$\dot{\boldsymbol{x}} = \text{Ad}_{G_W^b}\boldsymbol{\nu}^{(b)} = \text{Ad}_{G_W^b}\boldsymbol{J}\dot{\boldsymbol{\theta}} = \boldsymbol{f}(\boldsymbol{x}, \dot{\boldsymbol{\theta}}) \tag{9}$$

我们采用带输入正则化的非线性模型预测控制，为参考轨迹$\boldsymbol{x}^r(t)$在 $t \in [0, T]$ 上构建跟踪最优控制问题。目标函数为

$$\min_{\dot{\boldsymbol{\theta}}(\cdot)} \frac{1}{2}\int_0^T \dot{\boldsymbol{\theta}}(t)^\top \dot{\boldsymbol{\theta}}(t), dt. \tag{10}$$

该优化问题受式 (9) 中系统模型的约束，即

$$\text{s.t.} \begin{cases} \boldsymbol{x}(t) = \boldsymbol{x}^r(t), \\ \dot{\boldsymbol{x}}(t) = \dot{\boldsymbol{x}}^r(t), \\ \dot{\boldsymbol{x}}_{\min} \le \dot{\boldsymbol{x}}(t) \le \dot{\boldsymbol{x}}_{\max}, \\ \dot{\boldsymbol{\theta}}_{\min} \le \dot{\boldsymbol{\theta}}(t) \le \dot{\boldsymbol{\theta}}_{\max}. \end{cases} \tag{11}$$

其中，$\dot{\boldsymbol{x}}_{\min}$ 和 $\dot{\boldsymbol{x}}_{\max}$ 设定机器人速度的下限和上限。同样，$\boldsymbol{\theta}_{\min}$ 和 $\boldsymbol{\theta}_{\max}$ 设定车轮角速度的上下限。为了将时域为 $N \in \mathbb{N}$ 的最优控制问题转换为用于非线性模型预测控制的非线性规划，引入时间网格 t_k，其范围为$k = 0$、.....、N，步长为 $\Delta t = t_{k+1} - t_k$。令 $\boldsymbol{x}_k$和 $\boldsymbol{\theta}_k$分别表示第 k步的状态和控制量。连续模型(9)经采样后表示为 $\dot{\boldsymbol{x}}_k = \boldsymbol{f}(\boldsymbol{x}_k,\ \boldsymbol{\theta}_k)$，并通过 $\hat{\boldsymbol{x}}_{k+1} = \text{int}(\boldsymbol{x}_k,\ \dot{\boldsymbol{x}}_k,\ \Delta_t)$推进，其中 int(·)表示用于近似下一状态 $\hat{\boldsymbol{x}}_{k+1}$的数值积分器（例如欧拉法、龙格–库塔法）。将整个时域内的所有状态和控制量堆叠起来，得到决策向量 $\boldsymbol{z} \in \mathbb{R}^{5N+3}$，即

$$\boldsymbol{z} = [\ \boldsymbol{x}_0^\top\ \dot{\boldsymbol{\theta}}_0^\top \cdots\ \boldsymbol{x}_k^\top\ \dot{\boldsymbol{\theta}}_k^\top \cdots \boldsymbol{x}_N^\top\ ]^\top \tag{12}$$

因此，在网格时刻 t_k 和 t_N，定义阶段代价$L_k(\cdot)$和终端代价 $L_N(\cdot)$，每个代价均综合了多个目标，如下所示：

$$\begin{aligned} L_k(\boldsymbol{x}_k, \boldsymbol{x}_k^r, \dot{\boldsymbol{\theta}}_k) &= \|\boldsymbol{x}_k - \boldsymbol{x}_k^r\|_{Q_x}^2 + \|\dot{\boldsymbol{x}}_k - \dot{\boldsymbol{x}}_k^r\|_{Q_{\dot{x}}}^2 + \|\dot{\boldsymbol{\theta}}_k\|_R^2, \\ L_N(\boldsymbol{x}_N, \boldsymbol{x}_N^r) &= \|\boldsymbol{x}_N - \boldsymbol{x}_N^r\|_{Q_{xN}}^2 + \|\dot{\boldsymbol{x}}_N - \dot{\boldsymbol{x}}_N^r\|_{Q_{\dot{x}N}}^2 \end{aligned} \tag{13}$$

在每个网格时刻 t_k，阶段代价为二次型：$R \in \mathbb{R}^{2\times2}$ 对控制 effort 进行加权，而 $Q_x,\ Q_{\dot{x}} \in \mathbb{R}^{3\times3}$则对相对于 $\boldsymbol{x}_k^r$ 和 $\dot{\boldsymbol{x}}_k^r$的跟踪误差进行加权。终端矩阵Q_{xN}, $Q_{\dot{x}N} \in \mathbb{R}^{3\times3}$在 t_N处施加相同的惩罚。以测量状态 $\boldsymbol{x}_{\text{msr}}$ 和测量轮速度 $\boldsymbol{\theta}_{\text{msr}}$为基础，在（$t_0$）处初始化一个优化问题，从而构造状态反馈律，其形式为

$$\arg\min_{\boldsymbol{z}}\ J = \frac{1}{2}\sum_{k=1}^{N-1} L_k(\boldsymbol{x}_k, \boldsymbol{x}_k^r, \dot{\boldsymbol{\theta}}_k) + L_N(\boldsymbol{x}_N, \boldsymbol{x}_N^r) \tag{14}$$

其中

$$\text{s.t.}\begin{cases} \boldsymbol{x}_0 = \boldsymbol{x}_{\text{msr}},\ \dot{\boldsymbol{\theta}}_0 = \dot{\boldsymbol{\theta}}_{\text{msr}} \\ \boldsymbol{x}_{k+1} = \hat{\boldsymbol{x}}_{k+1} \\ \boldsymbol{x}_{\min} \le \boldsymbol{x}_k \le \boldsymbol{x}_{\max} & k = 0 \cdots N \\ \dot{\boldsymbol{\theta}}_{\min} \le \dot{\boldsymbol{\theta}}_k \le \dot{\boldsymbol{\theta}}_{\max} & k = 0 \cdots N-1 \\ \ddot{\boldsymbol{\theta}}_{\min} \le \ddot{\boldsymbol{\theta}}_k \le \ddot{\boldsymbol{\theta}}_{\max} & k = 0 \cdots N-1 \end{cases} \tag{15}$$

J 汇总了阶段惩罚和终端惩罚。式（15）中的第一个约束将初始状态和输入固定为测量值，从而闭合控制回路。第二个约束通过使决策状态与积分动力学相匹配，确保多重打靶一致性。其余约束则通过给定的最小值和最大值，对状态 $\boldsymbol{x}_k$、 $\dot{}$ $\ddot{}$输入 $\boldsymbol{\theta}_k$以及输入速率 $\dot{\boldsymbol{\theta}}_k$ 施加盒约束。所提出的完整控制框架，包括针对所研究 LSMR 的不同模块，如图2所示。

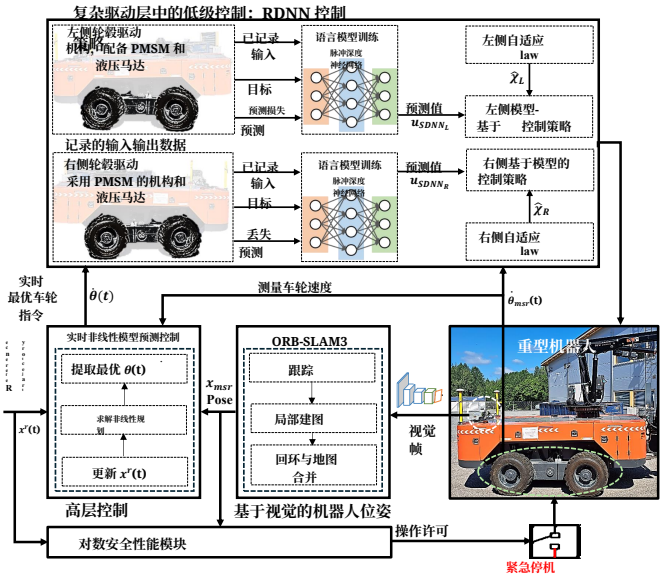

图2：所研究的 LSMR 的拟议控制框架。

V. 稳定性分析

如果机器人处于运行模式，根据图2和式（4）、（5）所示的对数安全模块，机器人满足安全定义的约束 $E(t) < O$。接下来，定义一个李雅普诺夫函数，如下：

$$\bar{V} = \frac{A_R}{2}e_R^2 + \frac{A_L}{2}e_L^2 + \frac{1}{2}\hat{\chi}_R^2 + \frac{1}{2}\hat{\chi}_L^2 \tag{16}$$

对式（16）求导并代入 e_i，可得

$$\begin{aligned}\dot{\bar{V}} =& e_R[u_R - u_{\text{SDNN}_R} + d_R] + \hat{\chi}_R\dot{\hat{\chi}}_R \\ &+ e_L[u_L - u_{\text{SDNN}_L} + d_L(t)] + \hat{\chi}_L\dot{\hat{\chi}}_L\end{aligned} \tag{17}$$

代入 (4) 后，我们得到

$$\begin{aligned}\dot{\bar{V}} =& -\frac{1}{2}\epsilon_R e_R^2 - \gamma_R e_R^2[\log(\frac{O}{O-E})]^2\hat{\chi}_R + e_R d_R \\ &+ e_R(u_{\text{SDNN}_R} - u_{\text{SDNN}_R}) + \hat{\chi}_R\dot{\hat{\chi}}_R \\ &- \frac{1}{2}\epsilon_L e_L^2 - \gamma_L e_L^2[\log(\frac{O}{O-E})]^2\hat{\chi}_L + e_L d_L \\ &+ e_L(u_{\text{SDNN}_L} - u_{\text{SDNN}_L}) + \hat{\chi}_L\dot{\hat{\chi}}_L\end{aligned} \tag{18}$$

根据 假设 *II.1*，我们定义未知常数 $d_i^* \ge 0$，使得 $|d_i| \le d_i^*$。因此，代入 (5) 后，

$$\begin{aligned}\dot{\bar{V}} \le& -\frac{1}{2}\epsilon_R e_R^2 - \gamma_R e_R^2[\log(\frac{O}{O-E})]^2\hat{\chi}_R + |e_R|\ d_R^* \\ &- \frac{1}{2}\delta_R\hat{\chi}_R^2 + \gamma_R e_R^2[\log(\frac{O}{O-E})]^2\hat{\chi}_R \\ &- \frac{1}{2}\epsilon_L e_L^2 - \gamma_L e_L^2[\log(\frac{O}{O-E})]^2\hat{\chi}_L + |e_L|\ d_L^* \\ &- \frac{1}{2}\delta_L\hat{\chi}_L^2 + \gamma_L e_L^2[\log(\frac{O}{O-E})]^2\hat{\chi}_L\end{aligned} \tag{19}$$

根据柯西-施瓦茨不等式，可得

$$\begin{aligned}\dot{\bar{V}} \le& -\frac{1}{2}\epsilon_R e_R^2 + \frac{1}{2}\kappa_R e_R^2 + \frac{1}{2\kappa_R}{d_R^*}^2 - \frac{1}{2}\delta_R\hat{\chi}_R^2 \\ &- \frac{1}{2}\epsilon_L e_L^2 + \frac{1}{2}\kappa_L e_L^2 + \frac{1}{2\kappa_L}{d_L^*}^2 - \frac{1}{2}\delta_L\hat{\chi}_L^2\end{aligned} \tag{20}$$

其中，ϵ_i 和 κ_i 为正的常数，且满足 $\epsilon_i > \kappa_i$。因此，

$$\begin{aligned}\dot{\bar{V}} \le& -\frac{1}{2}(\epsilon_R - \kappa_R)e_R^2 + \frac{1}{2\kappa_R}{d_R^*}^2 - \frac{1}{2}\delta_R\hat{\chi}_R^2 \\ &\frac{1}{2}(\epsilon_L - \kappa_L)e_L^2 + \frac{1}{2\kappa_L}{d_L^*}^2 - \frac{1}{2}\delta_L\hat{\chi}_L^2\end{aligned} \tag{21}$$

最后，可得 $\dot{\bar{V}} \le -\mu\bar{V} + \ell$ 其中 $\mu = \quad \epsilon_R - \kappa_R \quad A_L^{-1}\ \epsilon_L - \kappa_L \quad \delta_R\ \delta_L]$ $\ell = \frac{1}{2\kappa_R}{d_R^*}^2 + \frac{1}{2\kappa_L}{d_L^*}^2$ min $[A_R^{-1}(\,)\,(\,)$,且 . 根据 [31], 的定义1，这保证了所提出的基于 RSDNN 的控制能够确保黑箱驱动机构的一致指数稳定性，而安全模块则确保整个运行过程的安全性。

VI. 实验有效性

所研究的 LSMR 是一台重 6,000 kg、配备四个越野车轮的滑移转向机器人。该机器人配备两台 Basler acA1920-50gc 全局快门彩色相机（30 fps）、一台处于双天线模式的 Trimble BD992-INS（20 Hz），以及安装在轮内液压马达上的 Danfoss EMD 速度传感器（图1）。立体标定得到的基线为 0.32 m，两台相机均向下倾斜约 5°，以改善近距离视野覆盖并减少远距离误检。图像以未压缩格式存储，这是 ORB-SLAM3 所要求的；全局快门则可减少移动平台上的运动畸变。BD992-INS 为 ORB-SLAM3 提供参考值，其 INS-RTK 精度为：水平 0.05 m、垂直 0.03 m；在天线基线为 2 m 时，姿态精度为 0.10° 横滚/俯仰和 0.09° 航向。相机内参通过 Kalibr 的多相机工具[32]进行棋盘格标定获得。硬件以一台嵌入式 Beckhoff PC 为核心，通过 EtherCAT 采集传感器数据、为其添加时间戳，并将 UDP 数据报分发至 Linux 感知栈。相机视频流通过 UDP 上的 ROS 驱动程序传输。

双目 ORB-SLAM3 在崎岖地形上进行了离线调优，随后进行了在线验证。在 Ubuntu 20.04 和 ROS Noetic 上，使用 i9-14900K 和 32 GB 内存，通过 evo 将轨迹与 INS-RTK 真值进行比较。测试了 12 种配置，同时跟踪计算负载、建图质量、位姿精度和回环可靠性。影响最大的参数是每帧特征数量、FAST 阈值和双目深度截断距离：在 40 时约为 12.8 m，在 50 时为 16.0 m

表 I：设置深度为 40 时 ORB-SLAM3 的参数。

特征数量 ×1000	FAST ini	APE关键帧 (mm)	APE里程计 (mm)	RPE里程计 (mm)	CPU (%)	Mem (%)
1	12	590.6	513.8	110.8	14.21	3.41
2	12	549.6	490.7	112.7	13.39	3.11
3	12	599.1	557.2	130.7	12.73	3.32
1	20	582.8	510.2	109.8	14.26	3.25
2	20	562.9	508.3	109.6	12.58	2.88
3	20	546.5	504.6	110.1	13.69	3.16

表 II：设置深度为 50 时 ORB-SLAM3 的参数。

特征数量 x1000	FAST ini	APE关键帧 (mm)	APE里程计 (mm)	RPE里程计 (mm)	CPU (%)	Mem (%)
1	12	604.5	509.1	109.9	14.02	3.46
2	12	552.6	510.9	111.4	12.39	2.26
3	12	643.8	570.0	130.1	12.66	3.20
1	20	598.4	516.6	109.6	14.02	3.52
2	20	542.8	502.8	109.7	13.19	3.14
3	20	556.0	498.2	109.7	13.09	3.13

。精度以绝对位姿误差（APE）和相对位姿误差（RPE）表示。最佳结果出现在约 2000 个特征点时；特征点为 1000 或 3000 时，APE 略差。配置 2（深度 40、FAST 12 px）增加了候选数量，尽管 ORB 质量略低，仍能提供可靠的估计。深度为 50、FAST 为 20 的配置表现也很出色，产生了质量更高的特征点，且探测距离更远。所有情况下均成功完成回环检测，校正前未观察到明显的 Z 轴漂移。中央处理器负载在约 1000 个特征点时达到峰值，随后随着特征点增加略有下降，平均约为 13%。各种配置下，内存占用均保持在约 3%。如图2所示，ORB-SLAM3 以 20 Hz 向高层非线性模型预测控制器发布机器人位姿 $\boldsymbol{x}_{\text{msr}}(t)$，轮内速度传感器则以 1 kHz 提供 $\boldsymbol{\theta}_{\text{msr}}(t)$。非线性模型预测控制器每 1 ms 计算一次最优车轮控制指令 $\boldsymbol{\theta}(t)$，并将其发送给低层控制器；低层控制器调节两侧永磁同步电机的转速，以驱动高要求的轮内液压马达达到目标速度 $\boldsymbol{\theta}_{\text{msr}}(t)$，从而实现更新后的车轮速度（见图1）。所有计算均在 Beckhoff 系统上进行。换言之，高层控制器通过生成更新后的车轮速度控制指令 $\boldsymbol{\theta}(t)$，驱动 $\boldsymbol{x}_{\text{msr}}(t)$ 朝参考值 $\boldsymbol{x}^r(t)$ 行进。低层控制器负责执行器控制，调节永磁同步电机电机 $u_R(t)$ 和 $u_L(t)$，使得 $\boldsymbol{\theta}_{\text{msr}}(t) \rightarrow \boldsymbol{\theta}(t)$。非线性模型预测控制采用 C++ 实现，并使用非线性优化器、符号表达式、BFGS [33],和热启动，在传感器采样周期内完成求解。在线求解以初始高精度阶段得到的精细热启动作为初值。通过采用较小且固定的迭代预算，并在多个步骤间频繁更新非线性模型预测控制以不断优化解，确保了实时性 [34]。UDP 和智能指针缓冲最大限度地减少了排队和延迟。所有实验均在一台工业PC（Nuvo-9160GC）上运行，配备

配备 Intel Core i9、NVIDIA RTX 3050、32 GB 内存和 1 TB 固态硬盘，运行 Linux 并使用 C++ 实现。该设备安装在移动平台上，并通过以太网联网。非线性规划是在 MATLAB 中开发的，使用 CasADi 生成 C++代码，并将问题及一阶导数提供给 IPOPT。BOOST 负责 UDP 通信。低级控制运行在 Beckhoff CX2043 上，采样率为 1 ms。借助热启动和高频率

传感器，每个非线性模型预测控制步骤仅执行一次 SQP迭代，同时仍能改进非线性规划 [34]。我们设置 $R = \text{diag}(0.2,0.2)$ 和 $Q_x = Q_{xN} = \text{diag}(20,20,12)$。高层 NMPC 的边界为 $\dot{\boldsymbol{\theta}}_{\min} = [0,0]$、$\dot{\boldsymbol{\theta}}_{\max} = [0.8,0.8]$、$\ddot{\boldsymbol{\theta}}_{\min} = [-0.2,-0.2]$、和 $\ddot{\boldsymbol{\theta}}_{\max} = [0.2,0.2]$。请注意，为降低求解非线性规划的计算量，我们未考虑任何机器人位姿约束（$\boldsymbol{x}_{\min} = [-\text{inf}\ -\text{inf}\ -\text{inf}]$ 和 $\boldsymbol{x}_{\max} = [\text{inf},\text{inf},\text{inf}]$）；不过，$\boldsymbol{x}_{\text{msr}}$ 还受到安全定义性能模块的进一步限制；参见公式 (6)。

对于低级控制框架中的 SDNN 模块，我们通过扰动 PSMM 的转速信号 u_{SDNN_i}，并使用 Danfoss EMD传感器在各种工况下记录由此产生的履带速度 v_i，采集了 9，900，000 个同步样本。对数据流进行对齐、去尖峰处理，并划分为训练集、验证集和测试集。从原始向量中使用 MATLAB 的 *dividerand*按 70/15/15 的比例划分索引。使用*mapminmax*将训练子集缩放至 $[-1,1]$，并将相同参数应用于验证集和测试集。我们训练了具有五个隐藏层 $[35,20,12,10,8]$,、采用正切S形隐藏层激活函数和线性输出的 MATLAB SDNN，并禁用了内置预处理。优化采用缩放共轭梯度法（*trainscg*）。目标为 MSE 1×10^{-3}、最小梯度 1×10^{-4}，训练上限为 200 个周期，并依据验证集 MSE 提前停止。



图3：在沥青路面和软土上的真实环境验证。

如图3和图4所示，为进行严格评估，我们在两种地面类型——沥青路面和软土——上测试了多种配置。在沥青路面上，LSMR仅表现出轻微滑移，因此结果几乎完全一致。而在软土上，这种地面是越野LSMR的常见作业表面，结果出现了明显分化，性能差异显著。为评估整个框架，我们为机器人实现了三种配置，使其跟踪一条参考位姿轨迹，即一条长19米、宽10米的双纽线，具体如下。

（*1*）缺少高层控制：我们在禁用高层 NMPC 的情况下运行了完整的所提框架。由预定义的双纽线轨迹 $\boldsymbol{x}^r(t)$ 通过解析方法得出的车轮参考速度，被直接发送至执行器层中的低层控制器（RSDNN策略）。此场景旨在展示高层控制器在发生滑移时的作用。在沥青路面上，由于滑移极小且车轮与地面接触良好，即使没有高层 NMPC，任务仍成功完成。在软土上，尽管低层控制回路能够准确跟踪执行器级速度指令，

但不同程度的地形引起的打滑导致位姿相对于机器人级参考值逐渐漂移。一旦漂移超过预定义的安全界限 $E(t) < O = 0.4$，所提出的对数安全模块便会触发紧急停机（参见图 4 和图 5 中的深红色轨迹）。此场景的结果证实了所提出的高层控制器对于 LSMR 的必要性。

（2）驱动机构中的 *SDNN* 底层控制：我们部署了完整框架，包括用于位姿估计的视觉SLAM、在发生滑移时实时更新参考指令的高层 NMPC，以及驱动机构中的训练后的SDNN底层控制策略，但未采用用于处理潜在分布外行为的自适应律（见图 4 和图 5 中的绿色轨迹）。在安全约束范围内，实验结果总体上是成功的，但在机器人需要急剧改变朝向的位置存在轻微误差，尤其是在位置 (5, 6) 和 (13, 5) 附近。这些误差是因为快速改变朝向使驱动机构进入了训练后的 SDNN 模型所面对的分布外条件，而此时自适应控制器处于禁用状态。

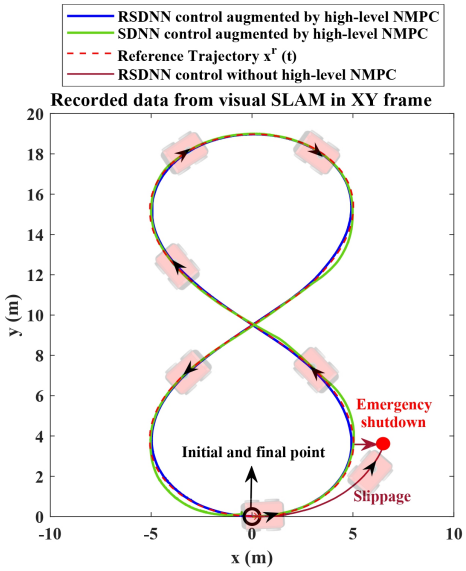

图 4：软土路面三个场景的 SLAM 数据。

（3）完整的所提框架：我们部署了完整框架，包括用于位姿估计的视觉SLAM、在发生滑移时实时更新参考指令的高层 NMPC，以及 RSDNN驱动策略；后者将训练后的 SDNN 控制器与用于处理潜在分布外行为的自适应律相结合。该框架表现稳健，且始终处于安全约束范围内（见图 4 和图 5 中的蓝色轨迹）。

除了对完整框架进行比较研究外，我们还在执行器控制层实现了两种先进的鲁棒控制器，以便与所提出的策略进行比较：一种结合了神经网络 [35]，的基于模型的鲁棒自适应控制器（RAC），以及一种无模型RAC [36]。此评估忽略了机器人任务，仅专注于

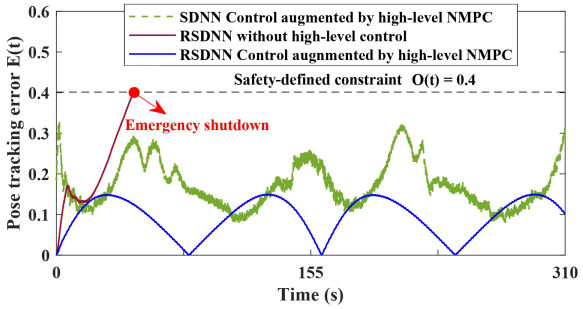

图5：对数模块的结果（E(t)，单位：米）。

调节永磁同步电机转速输入，以产生足够的车轮运动来跟踪车轮运动参考值，尽管存在显著的非线性因素，且多级驱动机构十分复杂（见图1）。如图6和表 III 所示，所有四种控制器对参考车轮运动的跟踪精度各不相同。

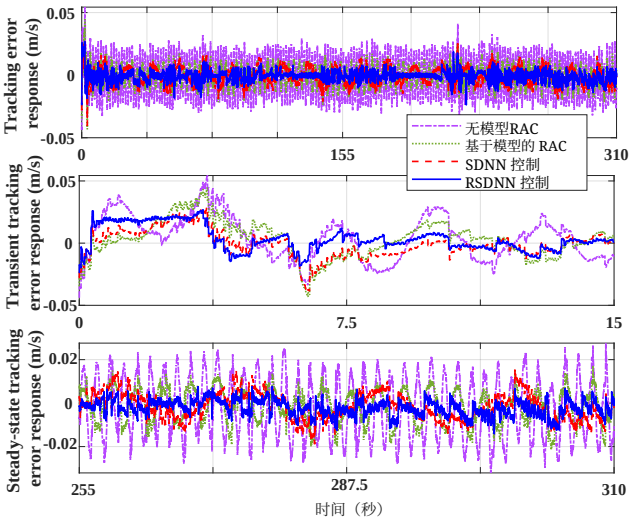

图 6：三个时间跨度内的驱动层跟踪。

RSDNN策略的综合表现最为出色：峰值时间最短、最大超调量最小、稳定时间较短，且稳态误差最低。SDNN紧随其后，稳定时间最快。基于模型的 RAC 排名第三。无模型 RAC 表现最差，出现了频率更高的振荡和更大的跟踪误差，这可能是因为其无模型特性需要更强的自适应能力，以补偿未知动力学。尽管基于模型的 RAC 偶尔在峰值时间和稳定时间方面与所提出的策略相当，但在具有挑战性的机器人任务中，其精度误差会与其他模块产生的误差累积，导致明显的性能损失。因此，所提出的高精度驱动层控制策略对整体框架具有重要价值。

表 III：执行器控制层面不同低层控制方法的汇总比较。

控制方法	Peak 时间（秒）	最大超调量（米/秒）	稳定时间（秒）	稳态误差（米/秒）
无模型RAC [36]	3.050	0.060	8.150	0.021
基于模型的 RAC [35]	3.200	0.040	4.650	0.019
SDNN 控制策略	3.100	0.029	4.500	0.017
RSDNN 控制策略	3.000	0.025	4.550	0.008

VII. 结论

本文提出了一套针对 6,000 千克 LSMR 的综合控制框架，可确保稳定性和安全性定义的性能，并使车辆能够在湿滑的越野地形上稳健运行。首先，采用双目相机配置的 ORB-SLAM3 估计机器人位姿，高层 NMPC 根据该位姿实时更新车轮运动指令，以补偿越野车轮滑移。随后，混合驱动层的 RSDNN 控制策略调节轮毂永磁同步电机和液压马达，使车轮跟踪更新后的指令。对数安全模块确保了闭环安全和指定性能。实验结果在多个场景和对比配置中验证了该框架。据我们所知，这是文献中首个针对数千千克级 LSMR 的研究，通过整合高性能深度学习，在保证越野地形上系统稳定性与安全性的同时，实现了真实环境自主运行。

参考文献

[1] Y. Chang, K. Ebadi, C. E. Denniston, M. F. Ginting, A. Rosinol, A. Reinke, M. Palieri, J. Shi, A. Chatterjee, B. Morrell 等，“Lamp 2.0：一种适用于大型复杂地下环境作业的鲁棒多机器人同步定位与建图系统”，*IEEE Robotics and Automation Letters*，第 7 卷，第 4 期，第 9175–9182 页，2022 年。[2] I. Abraham, A. Handa, N. Ratliff, K. Lowrey, T. D. Murphey 和 D. Fox，“利用路径积分控制，在参数不确定性下实现基于模型的泛化”，*IEEE Robotics and Automation Letters*，第 5 卷，第 2 期，第 2864–2871 页，2020 年。[3] H. Rizk, A. Chaibet 和 A. Krib`eche，“自主车辆的基于模型控制与无模型控制技术：技术综述”，*Applied Sciences*，第 13 卷，第 11 期，第 6700 页，2023 年。[4] D. He, H. Wang, Y. Tian 和 M. Fliess，“面向耦合机电系统的多输入多输出超局部模型自适应增强型无模型控制及极值搜索”，*ISA transactions*，第 157 卷，247，2025 年 233 页。。[5] M. H. Shahna, P. Mustalahti 和 J. Mattila，“ 移动机器人液压轮毂驱动系统的鲁棒转矩观测控制与安全输入–输出约束”，*Control Engineering Practice*，第 164 卷，第 106459 页，2025 年。[6] H. Du, X. Zhu, Q. Liu, T. Ren 和 Y. Wang，“基于轮胎侧向力和纵向力优化的重型车辆多轴转向分层协调控制”，*Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*，第 238 卷，第 9 期，第 2727–2740 页，2024 年。[7] S. Bruni, J. Meijaard, G. Rill 和 A. Schwab，“采用多体动力学方法研究铁路与道路车辆动力学的现状与挑战”，*Multibody System Dynamics*，第 49 卷，第 1 期，第 1–32 页，2020 年。[8] J.-L. Archut 和 B. Corves，“基于 PRISMA 的道路车辆实时多体仿真方法系统映射”，*Multibody System Dynamics*，第 1–48 页，2025 年。[9] J. Liao, Z. Chen 和 B. Yao，“考虑轮地相互作用与车轮动力学的四轮独立驱动滑移转向移动机器人的基于模型协调控制”，*IEEE Transactions on Industrial Informatics*，第 15 卷，第 3 期，第 1742–1752 页，2018 年。

[10] C. J. Ostafew、A. P. Schoellig、T. D. Barfoot 和 J. Collier，“基于学习的非线性模型预测控制，以改进基于视觉的移动机器人路径跟踪”，Journal of Field Robotics，第33卷，第1期，133–152页，2016年。[11] M. H. Shahna、P. Mustalahti 和 J. Mattila，“重型轮式移动机器人系统可用性与连续运行的容错控制”，载于2025年IEEE/ASME智能机电国际会议（AIM），2025年，第1–8页。[12] K. Li、A. N. Rubungo、X. Lei、D. Persaud、K. Choudhary、B. DeCost、A. B. Dieng 和 J. Hattrick-Simpers，“探究机器学习在材料领域的分布外泛化能力”，Communications Materials，第6卷，第1期，第9页，2025年。[13] M. Basri、A. Karapetyan、B. Hassan、M. Khonji 和 J. Dias，“一种用于越野环境下车辆车轮滑移预测的混合深度学习方法”，载于2022年IEEE机器人与传感器环境国际研讨会（ROSE）。IEEE，2022年，第1–7页。[14] R. E. Arvidson、K. D. Iagnemma、M. Maimone、A. A. Fraeman、F. Zhou、M. C. Heverly、P. Bellutta、D. Rubin、N. T. Stein、J. P. Grotzinger 等，“火星科学实验室好奇号火星车在盖尔撞击坑穿越巨型波纹地形，直至第710个火星日”，Journal of Field Robotics，第34卷，第3期，495–518页，2017年。[15] M. H. Shahna、P. Mustalahti 和 J. Mattila，“滑移转向机器人中具有全局指数稳定性的防滑AI驱动无模型控制”，IEEE/RSJ智能机器人与系统国际会议（IROS），2025年。[16] F. Micheli、M. Bersani、S. Arrigoni、F. Braghin 和 F. Cheli，“用于城市自动驾驶的非线性模型预测控制轨迹规划器”，Vehicle System Dynamics，第61卷，第5期，1387–1409页，2023年。[17] M. Diehl、R. Findeisen 和 F. Allg¨ower，“非线性模型预测控制的稳定实时实现”，载于《实时偏微分方程约束优化》。SIAM，2007年，第25–52页。[18] H. G. Bock 和 K.-J. Plitt，“直接求解最优控制问题的多重打靶算法”，IFAC会议论文集，第17卷，第2期，1603–1608页，1984年。[19] M. Diehl、H. G. Bock、H. Diedam 和 P.-B. Wieber，“用于机器人最优控制的快速直接多重打靶算法”，载于《生物力学与机器人学中的快速运动：优化与反馈控制》。Springer，2006年，第65–93页。[20] R. Zhou、D. Wu、L. Fang、A. Xu 和 X. Lou，“基于最小二乘方程拟合参数预测森林蓄积量的Levenberg–Marquardt反向传播神经网络”，Forests，第9卷，第12期，第757页，2018年。[21] J. Tan、S. Xue、T. Niu、K. Qu、H. Cao 和 B. Chen，“基于固定时间并发学习的鲁棒近似最优控制”，Nonlinear Dyn.，第1–21页，2025年。[22] K. P. Tee、S. S. Ge 和 E. H. Tay，“用于输出受限非线性系统控制的障碍李雅普诺夫函数”，Automatica，第45卷，第4期，918–927页，2009年4月。[23] P. Furgale 和 T. D. Barfoot，“用于远距离火星车自主导航的视觉示教与重复”，Journal of Field Robotics，第27卷，第5期，534–560页，2010年。[24] C. Cadena、L. Carlone、H. Carrillo、Y. Latif、D. Scaramuzza、J. Neira、I. Reid 和 J. J. Leonard，“同时定位与建图的过去、现在与未来：迈向鲁棒感知时代”，IEEE《机器人学汇刊》，第32卷，第6期，1309–1332页，2017年。[25] C. Campos、R. Elvira、J. G. Rodr´ıguez 和 J. Montiel，“用于视觉、视觉惯性及多地图SLAM的高精度开源库”，2021年，第37卷，1874–1890页。[26] M. Burri、J. Nikolic、P. Gohl、T. Schneider、J. Rehder、S. Omari、M. W. Achtelik 和 R. Siegwart，“EuRoC微型飞行器–数据集”，The International Journal of Robotics Research，第35卷，第10期，1157–1163页，2016年。[27] D. Schubert、T. Goll、N. Demmel、V. Usenko、J. St¨uckler 和 D. Cre-mers，“用于评估视觉惯性里程计的TUM VI基准”，载于2018年IEEE/RSJ智能机器人与系统国际会议（IROS）。IEEE，2018年，第1680–1687页。[28] A. Paz、P. Mustalahti、M. Dastranj 和 J. Mattila，“用于轨迹跟踪任务的重型滑移转向移动平台实时非线性模型预测控制”，arXiv预印本 arXiv:2510.02976，2025年。[29] K. Kozłowski 和 D. Pazderski，“四轮滑移转向移动机器人的建模与控制”，International Journal of Applied Mathematics and Computer Science，第14卷，第4期，477–496页，2004年。[30] R. M. Murray、Z. Li 和 S. S. Sastry，《机器人操作的数学导论》。CRC出版社，2017年。[31] M. H. Shahna、M. Bahari 和 J. Mattila，“面向清洁技术EMLA的具备鲁棒性保证且具有模块化特性的基于观测器控制策略——由……驱动

驱动的重型机器人机械臂”，*IEEE*《自动化科学与工程汇刊》，2024年。[32] J. Rehder、J. Nikolic、T. Schneider、T. Hinzmann 和 R. Siegwart，“扩展Kalibr：校准多个惯性测量单元及单个轴的外参”，载于*2016*年*IEEE*国际机器人与自动化会议（*ICRA*）。IEEE，2016年，第4304–4311页。[33] J. Nocedal 和 S. J. Wright，数值优化。Springer，2006年。[34] R. Grandia、F. Jenelten、S. Yang、F. Farshidian 和 M. Hutter，“通过非线性模型预测控制实现感知式运动”，*IEEE*《机器人学汇刊》，第39卷，第5期，3402–3421页，2023年。[35] Z. Chen、B. Niu、X. Zhao、L. Zhang 和 N. Xu，“非线性连续时间系统的基于模型的自适应事件触发控制”，《应用数学与计算》，第408卷，第126330页，2021年。[36] M. H. Shahna 和 J. Mattila，“具有能量转换分层洞察的伺服驱动执行机构无模型通用鲁棒控制”，载于*2025*年美国控制会议（*ACC*）。IEEE，2025年，第4331–4338页。