

JEPA-X：基于连续隐空间轨迹预测与解析碰撞认证的实时安全机器人规划

塔里克(Jean-Luc Tarik Aslan) 和张东炜 (Zhang Dongwei)

北京糖塔科技有限公司，中国北京

邮箱: aslan.tarik@tangta-technology.com

DOI: 10.51094/jxiv.5833 - <https://jxiv.jst.go.jp/index.php/jxiv/preprint/view/5833>

作者注

本文档将 JEPA-X 作为一种具有经验证的实际世界性能的连续时间预测机器人规划研究架构进行介绍。核心方法论源自本公司的 JEPA-X 技术实现，并受待批专利申请（参考文献 [11]）和已登记软件著作权（参考文献 [12]）保护。本出版物中的声明均采用科学语言并附有适当的免责声明：轨迹被称为“经解析认证无碰撞”仅在认证模块所使用的建模几何、状态和不确定性假设下成立。

JEPA-X 认知决策系统（软件著作权登记号：2026R11L2342491, 2026R11L2613892）是一项已登记的软件作品，具有全面的技术文档。如需许可、合作或技术咨询，请联系通讯作者：3559870647@qq.com。

© 2026 Aslan Jean-Luc Tarik, 董伟及北京糖塔科技有限公司。保留所有权利。

摘要

摘要—隐空间世界模型为机器人预测和规划提供了紧凑的表示，但许多现有方法通过离散状态转换来表示未来演化。这种表示无法直接描述预测状态之间的连续物理运动，当机器人快速移动或与动态障碍物交互时，会产生验证盲区。

我们提出了 JEPA-X，这是一种动作条件的连续时间世界模型架构，可联合预测隐空间语义演化和物理 3D 轨迹。环境被表示为结构化隐空间场景图 (SLSG)，而隐空间运动学路径预测器 (LKPP) 在共享的时间参数化下，为机器人和周围物体生成锚定的伯恩斯坦 (Bernstein) 多项式轨迹。这种公式支持连续的相对距离、最小间距、速度、加速度和碰撞时间 (TTC) 评估。

JEPA-X 引入了两阶段碰撞评估管线。保守的凸包分离测试在建模的几何和不确定性假设下提供了充分的几何安全认证。当该认证不可用时，基于 GPU 的采样曲线距离细化算法会估计最小轨迹间距。控制点不确定性被传播到随时间变化的不确定性包络中，并映射到分级的执行状态，从而在不确定性下实现减速、增加安全余量、重新规划或停止。该系统还支持多时间尺度预测和具有平滑位置、速度和加速度过渡的分段轨迹。

在 RTX 2070 和 Jetson Orin NX 上的原型评估表明，在报告的基准配置下，平均端到端延迟分别为 7.2 ms 和 16.2 ms。与同一硬件上的顺序执行相比，GPU 批处理候选评估分别提供了 $16.9\times$ 和 $22.0\times$ 的加速。这些结果表明，连续隐空间-物理轨迹预测在实时边缘机器人规划中是计算可行的。物理全身人形验证和动态关节扫描体积建模仍是未来的工作。

Index Terms—联合嵌入预测架构 (JEPA), 结构化隐空间场景图 (SLSG), 连续轨迹预测, 隐空间世界模型, 模型预测控制 (MPC), 碰撞避免, Bézier 曲线, 不确定性感知规划, 碰撞时间 (TTC), 边缘机器人技术。

索引词

联合嵌入预测架构 (JEPA), 结构化隐空间场景图 (SLSG), 连续轨迹预测, 隐空间世界模型, 模型预测控制 (MPC), 碰撞避免, Bézier 曲线, 不确定性感知规划, 碰撞时间 (TTC), 边缘机器人技术。

I. 引言

自主机器人面临的一个核心挑战是将紧凑的学习世界模型与连续时间物理安全性结合起来。联合嵌入和隐空间预测架构降低了表示高维感官输入的成本，但规划通常通过离散的未来状态进行。即使两个连续的预测状态各自都是有效的，它们之间的连续物理运动仍然可能与障碍物相交。当机器人移动迅速、在人类附近操作或与动态物体交互时，这种“时间盲区”问题变得尤为关键。

第二个困难是认知表示与安全验证之间的“表示脱节”。高级规划可能在学到的隐空间中进行，而碰撞检查则由单独的笛卡尔空间模块执行。这引入了表示转换、额外的延迟和误差累积。对于高度反应式的模型预测控制 (MPC)，机器人需要一种表示，使得未来语

义状态、物理运动、不确定性和安全约束能够被连贯地评估。

为了缓解这一问题，现有系统将隐空间认知与笛卡尔空间安全解耦。它们要么将隐状态解码回像素空间进行碰撞检查（产生约 $\sim 100\times$ 的计算开销），要么将验证卸载到外部 3D 物理引擎（如 MoveIt [4], MuJoCo）。这种“表示脱节”引入了严重的延迟、坐标变换误差累积，并从根本上排除了在资源受限的边缘硬件上进行实时模型预测控制 (MPC) 的可能性。此外，这些离散或解耦的系统缺乏连续时间因果推理能力，无法预测次要的物理后果——例如，当一个人形机器人在拥挤区域行走时，一个奔跑的孩子突然穿过其路径，产生了对孩子可能很危险的迫在眉睫的碰撞风险。

JEPA-X 通过用连续的、动作条件的轨迹预测替代离散的未来点预测来解决这个问题。结构化隐空间场景图表示物体、关系和物理锚点。隐空间运动学路径预测器将当前的结构化状态和候选动作映射到同步的隐空间和物理伯恩斯坦多项式轨迹。自身节点 (Ego-Node) 使用与动态物体相同的公式，因此可以直接在连续时间内评估相对运动。

A. 主要贡献

- 1) **连续隐空间轨迹参数化**：隐空间运动学路径预测器 (LKPP) 输出以结构化隐空间场景图 (SLSG) 为条件的双分支 Bézier 控制点（隐空间和物理）。严格的锚点约束 ($C_0 = p_{\text{current}}$) 消除了隐空间幻觉并确保物理连续性。
- 2) **统一的自身运动与动态物体连续预测**：机器人和周围物体使用相同的连续时间参数化进行预测，从而实现直接的相对距离和 TTC 推理。
- 3) **纯 GPU 解析碰撞认证**：一种新颖的两阶段安全管线，利用 $\mathcal{O}(1)$ 的控制点凸包分离轴定理 (SAT) 测试，随后进行纯 GPU 的伯恩斯坦采样曲线距离优化（100 个点，精度 $< 1\text{ mm}$ ）。这提供了主要的实时路径，传统的基于 CPU 的 L-BFGS-B/scipy 仅作为异常恢复的回退机制保留，实现了比传统基于网格的碰撞检查 $53\times$ 到 $146\times$ 的加速。
- 4) **因果边缘动态与计算门控**：一种持续更新关系边缘隐向量（例如 SUPPORTED $\rightarrow$ FALLING）的机制。至关重要的是，我们引入了计算门控，在 MCTS 规划期间跳过边缘演化，每个周期节省约

40 MB VRAM 和约 1 TFLOP，实现极致的边缘效率。

- 5) **不确定性感知分级安全**：控制点不确定性被传播到随时间变化的管状区域，并映射到分级安全状态（CERTIFIED_SAFE, PROBABILISTIC_SAFE, UNCERTAIN, UNSAFE），从而改变速度、安全余量和执行策略。
- 6) **统一训练与自主演化**：连续时间积分损失函数 ($\mathcal{L}_{\text{JEPA-X}}$) 配合自适应梯度范数加权（阶段 B），结合贝叶斯超参数优化和弹性权重巩固 (EWC) [7]（阶段 C），实现安全的自我提升而不发生灾难性遗忘。
- 7) **广泛的边缘部署验证**：全面的基准测试证明了在 RTX 2070 上 139 FPS (7.2 ms) 和 Jetson Orin NX 上 62 FPS (16.2 ms) 的实时性能，CERTIFIED_SAFE 率达到 85–89%，且多物体缩放呈近线性 $\mathcal{O}(N^{1.02-1.04})$ ，表明其适用于资源受限的机器人平台。

本文的其余部分组织如下：第 II 节回顾相关工作。第 III 节详细介绍系统架构和数学公式。第 IV 节展示实验设置和基准测试结果。第 V 节讨论影响和局限性。第 VI 节得出结论。

II. 相关工作

我们的工作与隐空间世界模型、安全运动规划、连续轨迹表示和自主持续学习相交。我们讨论了现有范式的局限性，并强调了 JEPA-X 如何桥接紧凑的隐空间推理与数学上严格的物理安全性。

A. 隐空间预测架构

从像素空间到隐空间推理的转变是由绕过计算上难以处理的高维视觉输入的需求所驱动的。基于 JEPA [1] 和基于重建的模型（如 DreamerV3 [3]）的架构在学习用于规划的紧凑内部表示方面展现了卓越的能力。

JEPA 风格的模型从上下文中预测目标表示，而不是重建每个像素。这对于机器人技术很有吸引力，因为视觉上无关的细节不必主导学习目标。然而，这些系统主要依赖于离散自回归步进预测 ($z_t \rightarrow z_{t+1}$)，这在高速动态环境中固有地产生了“时间盲区”——即使 t 和 $t+1$ 的状态被认为是安全的，它们之间的连续物理轨迹也可能与动态障碍物相交。

基于重建的模型进一步需要将隐状态解码回像素空间以进行奖励计算或安全验证，产生约 $\sim 100\times$ 的计算开销，并引入量化伪影，模糊了精确操作所需的连续几何边界。

JEPA-X 通过引入隐空间运动学路径预测器 (LKPP) 从根本上脱离了离散自回归，该预测器直接在共享的 128D 隐流形中将未来轨迹参数化为连续的伯恩斯坦多项式 (Bézier 曲线)——消除了时间盲区，绕过了像素重建，并实现了没有量化伪影的连续时间物理推理。

B. 安全运动规划与连续时间安全认证

传统的安全运动规划框架，如 CHOMP [16] 和 STOMP [17]，将轨迹生成表述为笛卡尔空间中的连续优化问题。虽然在数学上是合理的，但这些方法严重依赖于显式的 3D 网格渲染 (URDF/Octomap) 和外部物理引擎 (如 MoveIt [4], FCL [5])。这引入了严重的“表示脱节”：高级认知规划在低维隐空间中进行，而安全验证则被降级到显式的 3D 笛卡尔网格，需要连续的坐标变换和密集的空间采样。

最近，控制障碍函数 (CBFs) [18] 已成为在机器人技术中提供连续时间、前向不变安全保证的最先进技术。然而，为高维、非凸或动态变化的环境合成有效的 CBF 在计算上仍然难以处理，通常需要保守的近似或显式的已知动态模型。

JEPA-X 通过将安全性直接嵌入隐空间表示来弥合这一差距。通过将轨迹参数化为 Bézier 曲线，我们利用了它们的全局凸包性质。这允许我们的解析碰撞模块使用分离轴定理 (SAT) 评估物理控制点的 3D 凸包，为任何轨迹对实现 $\mathcal{O}(1)$ 常数时间的碰撞认证。这完全绕过了网格渲染和显式 CBF 合成的需要，同时仍然提供严格的、连续时间的几何安全保证。对于多物体场景，空间哈希和包围体层次结构 (BVH) 剪枝将全局复杂度降低到近线性的 $\mathcal{O}(N \log N)$ ，与传统的物理引擎相比，碰撞检测吞吐量提高了两个数量级以上。

C. 因果推理、不确定性与自主自我提升

纯几何规划器无法执行因果链式反应推理。JEPA-X 通过将连续轨迹规划嵌入结构化隐空间场景图 (SLSG) 中，输出具有严格锚点约束的双分支控制点以防止“隐空间幻觉”，从而提升了连续轨迹规划。我们的因果边缘动态引擎在预测的轨迹上持续更新关系

边缘隐变量，使得连续的物理因果链式反应完全在隐流形内发生。

此外，在自主学习过程中确保安全性是安全强化学习中的一个基本挑战 [15]。虽然当前的具身 AI 系统依赖于静态部署，并且在不进行昂贵的离线重新训练的情况下无法适应分布外 (OOD) 场景，但 JEPA-X 引入了自我提升自主学习循环 (阶段 C)。与依赖通过收缩流模型进行复杂不确定性量化的方法 [19] (产生高计算开销) 不同，JEPA-X 采用轻量级、解析上可处理的高斯不确定性传播，通过伯恩斯坦基函数进行传播。这产生了随时间变化的不确定性管，直接映射到分级安全状态 (CERTIFIED_SAFE, PROBABILISTIC_SAFE, UNCERTAIN, UNSAFE)。

通过自主收集真实世界的轨迹经验，基于数据质量阈值触发重新训练，并利用贝叶斯优化 [9] 来调整多目标统一连续时间损失函数 ($\mathcal{L}_{\text{JEPA-X}}$)，系统实现了持续的自我提升。这种演化受到严格的安全验证门 ($\geq 5\%$ 损失减少且安全评分 ≥ 0.8) 和弹性权重巩固 (EWC) [7] 正则化的保护，确保安全的探索和学习，而不会发生灾难性遗忘或依赖基于云的离线重新训练。

III. 系统架构与方法论

与依赖离散自回归步骤的先前隐空间世界模型不同，JEPA-X 完全在共享的 128 维隐流形内运行，利用连续的 Bézier 参数化进行轨迹预测，并利用解析凸包性质进行 $\mathcal{O}(1)$ 数学安全认证 (图 1)。

A. 结构化隐空间场景图 (SLSG)

为了实现以物体为中心的推理和因果推断，我们将环境表示为结构化隐空间场景图 $\mathcal{S}_t = \{\mathcal{O}_t, \mathcal{E}_t, \mathcal{P}_t\}$ 。使用迭代 Slot Attention [6]，多模态传感器观测被分解为 N 个离散的物体槽。每个物体节点 $\mathbf{o}_{i,t} \in \mathbb{R}^{128}$ 通过位置头增加了一个物理 3D 锚点 $\mathbf{p}_{i,t} \in \mathbb{R}^3$ 。机器人被建模为自身节点 ($i = 0$)，其 6-DOF 姿态通过隐空间视觉里程计编码，统一了自身运动和动态障碍物跟踪 (图 2)。

关系边缘隐变量 $\mathbf{e}_{ij,t} \in \mathbb{R}^{d_e}$ 编码连续的物理和语义约束 (例如，SUPPORTED_BY, NEAR)。图神经网络 (GNN) 消息传递层聚合上下文约束。物体 i 的运动学上下文向量 $\mathbf{c}_{i,t}$ 为：




图 1. JEPA-X 系统架构。多模态输入编码为 128D 结构化隐空间场景图 (SLSG)。隐空间运动学路径预测器 (LKPP) 生成连续的 B ezier 控制点，由解析碰撞模块评估并由行为树协调。阶段 C 学习循环在后台正交运行。

$$\mathbf{m}_{i,t} = \sum_{j \in \mathcal{N}(i)} \text{MLP}_{\text{edge}}([\mathbf{o}_{i,t}, \mathbf{o}_{j,t}, \mathbf{e}_{ij,t}]) \quad (1)$$

$$\mathbf{c}_{i,t} = \text{MLP}_{\text{fuse}}([\mathbf{o}_{i,t}, \mathbf{m}_{i,t}, \mathbf{a}_t]) \quad (2)$$

其中 $\mathbf{a}_t \in \mathbb{R}^{d_a}$ 是候选动作嵌入。显式的动作项至关重要：JEPA-X 预测在候选机器人动作下预期会发生什么，而不仅仅是推断被动的场景动态。

B. 隐空间运动学路径预测器 (LKPP) 与 B ezier 参数化

隐空间运动学路径预测器 (LKPP) 是 JEPA-X 的核心引擎，将离散的场景表示转化为连续的、基于物理的轨迹。与传统的离散自回归预测器不同，LKPP 作为多头神经网络运行，输出参数化的 B ezier 曲线。完整的架构数据流如图 3 所示。

1) 控制点生成：给定上下文 $\mathbf{c}_{i,t}$ ，LKPP 输出隐空间和物理空间的 $(K + 1)$ 个控制点：




图 2. 结构化隐空间场景图 (SLSG) 和 GNN 上下文聚合。物体节点 (128D 隐变量 + 3D 物理锚点) 由编码连续物理约束的关系边缘隐变量连接。GNN 聚合邻居消息和候选动作嵌入，为每个物体生成丰富的运动学上下文向量 $\mathbf{c}_{i,t}$ 。




图 3. 具有 B ezier 参数化的 LKPP 轨迹预测。场景上下文（物理位置、动作嵌入、SLSG）流经 GNN 上下文聚合器，生成双分支 B ezier 控制点（隐空间 128D + 物理 3D）。边缘演化头（红色，仅限训练）在 MCTS 期间被跳过以提高效率。轨迹评估使用 cuBLAS 张量核心 GEMM 进行批处理推理，并强制执行锚点约束。

$$\{\mathbf{C}_{i,k}^{(z)}\}_{k=0}^K \in \mathbb{R}^{(K+1) \times 128} \quad (3)$$

$$\{\mathbf{C}_{i,k}^{(p)}\}_{k=0}^K \in \mathbb{R}^{(K+1) \times 3} \quad (4)$$

为了消除隐空间幻觉，我们强制执行严格的锚点约束：

$$\mathbf{C}_{i,0}^{(p)} = \mathbf{p}_{i,t}, \quad \mathbf{C}_{i,0}^{(z)} = \mathbf{o}_{i,t} \quad (5)$$

在 $\tau \in [0, \Delta T]$ 上的连续物理轨迹 $\hat{\mathbf{p}}_i(\tau)$ 和隐空间

轨迹 $\hat{\mathbf{z}}_i(\tau)$ 使用伯恩斯坦基多项式定义:

$$B_{k,K}\left(\frac{\tau}{\Delta T}\right) = \binom{K}{k} \left(\frac{\tau}{\Delta T}\right)^k \left(1 - \frac{\tau}{\Delta T}\right)^{K-k}. \quad (6)$$

轨迹随后表示为:

$$\hat{\mathbf{p}}_i(\tau) = \sum_{k=0}^K B_{k,K}\left(\frac{\tau}{\Delta T}\right) C_{i,k}^{(p)}, \quad (7)$$

$$\hat{\mathbf{z}}_i(\tau) = \sum_{k=0}^K B_{k,K}\left(\frac{\tau}{\Delta T}\right) C_{i,k}^{(z)}. \quad (8)$$

由于 Bézier 曲线的导数是较低阶的 Bézier 曲线, 因此速度 $\dot{\mathbf{p}}_i(\tau)$ 和加速度可以在零网格渲染开销下计算。

2) 场景上下文与 GNN 聚合: LKPP 不在孤立的物体上运行。它接收丰富的场景上下文, 包括: (1) 来自 SLSG 物理锚点的物理位置 $(N, 3)$; (2) 代表候选机器人动作的动作嵌入 $(B, 64)$; 以及 (3) 包含 $O(N)$ 个物体及其关系边缘的 SLSG 拓扑。

为了理解候选动作如何影响特定物体及其邻居, LKPP 采用 GNN 上下文聚合器。首先, 边缘特征 MLP 处理源节点、目标节点和边缘隐向量的拼接 $[o_i, o_j, e_{ij}]$ 以生成成对消息 m_{ij} 。这些消息通过求和 ($m_i = \sum m_{ij}$) 进行聚合以捕获关系上下文。最后, 上下文融合 MLP 整合物体的内在状态、聚合的关系消息和动作嵌入, 为每个物体生成高维的运动学上下文向量 $\mathbf{c}_{i,t} \in \mathbb{R}^{d_c}$ 。

3) 双分支 Bézier 预测头: 以运动学上下文向量 $\mathbf{c}_{i,t}$ 为条件, LKPP 分支为并行的多层感知器 (MLP) 头以生成连续轨迹参数:

- **物理控制点头:** 将 $\mathbf{c}_{i,t}$ 映射到 $(K+1) \times 3$ 个物理 3D 控制点。这些点定义了物体的实际空间路径, 并直接用于碰撞认证。
- **隐空间控制点头:** 将 $\mathbf{c}_{i,t}$ 映射到 $(K+1) \times 128$ 个隐空间语义控制点。这些点控制物体语义特征在 128D 流形内的演化。

4) 128D 隐空间的解释: 共享的隐流形 $\mathbb{R}^{128}$ 提供了一个紧凑的、分布式的表示, 联合编码了观察场景的语义、几何、外观和动态属性。与现代自监督表示学习一致, JEPA-X 不为单个维度分配特定的语义意义; 相反, 信息在整个隐向量中进行整体编码。

选择 128 维是表示能力、计算效率以及边缘部署的严格内存带宽约束之间的深思熟虑的设计权衡。虽

然较低维度的空间减少了内存占用, 但它们有使复杂动态环境所需的表达能力成为瓶颈的风险。相反, 较高维度的表示增加了 GNN 消息传递和 MLP 推理的计算成本, 通常在不按比例提高准确性的情况下, 在下游规划性能中产生递减的回报。

从系统角度来看, 所选维度提供了几个关键优势:

- **与硬件对齐的边缘部署:** 128 维向量与 GPU 内存对齐要求和张量核心利用率最佳匹配, 能够在 Jetson Orin NX 等嵌入式平台上实现低延迟推理, 而不会使内存带宽饱和。
- **统一的多任务表示:** 共享的隐空间同时支持感知、轨迹预测、内存检索、不确定性估计和规划, 而无需多个特定任务的特征嵌入。
- **高效的内存检索:** 固定维度的隐空间表示与 FAISS 等向量数据库直接兼容, 从而实现高效的最近邻检索, 用于长期记忆和经验重用。
- **双分支轨迹参数化:** 能够在批处理 MCTS 评估期间并行生成 $(K+1) \times 128$ 个隐空间控制点和 $(K+1) \times 3$ 个物理控制点, 而不会产生过多的内存惩罚。

最终, 128D 隐空间的动机源于整体系统架构和实时约束。它提供了一个强大的信息瓶颈, 可以防止过拟合, 同时保持足够的容量进行连续时间的物理和语义推理。

5) 不确定性与边缘演化头: 为了支持不确定性感知规划、概率安全评估和连续因果推理, 隐空间运动学路径预测器 (LKPP) 除了连续轨迹预测器外, 还结合了两个辅助预测头。

- **不确定性头:** 对于每个预测的伯恩斯坦控制点, 网络估计物理轨迹的相应不确定性。设物体 i 的第 k 个控制点与空间协方差矩阵相关联

$$\Sigma_{i,k}^{(p)} \in \mathbb{R}^{3 \times 3},$$

该矩阵对该控制点的预测 3D 位置不确定性进行建模。

假设与每个伯恩斯坦控制点相关的不确定性遵循独立的高斯分布, 则可以通过将控制点协方差通过平方伯恩斯坦基函数 $B_{k,K}^2\left(\frac{\tau}{\Delta T}\right)$ 传播来近似连续轨迹的协方差:

$$\Sigma_i^{(p)}(\tau) \approx \sum_{k=0}^K B_{k,K}^2\left(\frac{\tau}{\Delta T}\right) \Sigma_{i,k}^{(p)}, \quad (9)$$

其中该近似假设相互独立的高斯控制点不确定性，并忽略了不同控制点之间的交叉协方差项。传播的协方差定义了围绕预测轨迹的连续、随时间变化的不确定性包络。安全模块随后使用该不确定性管，根据预测的估计置信度来调整碰撞余量、执行速度和决策策略（第 III-G 节）。

当前的实现为了计算效率假设了独立的控制点不确定性。扩展到相关的协方差传播仍是未来的工作。

- **边缘演化头：** 边缘演化头预测关系边缘的连续时间演化 $\hat{e}_{ij}(\tau)$ ，捕获实体之间的因果状态转换（例如，SUPPORTED→FALLING，CLEAR_PATH→POTENTIAL_COLLISION，或 VISIBLE→OCCLUDED）。

如第 III-C 节所述，该分支在 MCTS 候选评估期间通过计算门控被禁用。因为预测的边缘动态不会直接影响轨迹候选者的即时几何评分；两者都直接在预测的物理轨迹、安全证书、运动学约束和相关候选分数上运行。因此，对每个 MCTS 候选者评估边缘演化头将引入大量计算和内存流量，而不会影响动作选择。因此，JEPA-X 在 MCTS 热路径期间禁用此分支（compute_edge_evolution=False），而在训练和因果场景模型更新期间保留它，从而在在线规划期间减少约 40 MB 的 GPU 内存消耗，并消除约 1 TFLOP 的不必要计算。

6) 隐空间轨迹的作用：JEPA-X 同时预测隐空间轨迹及其对应的物理轨迹，因为这两种表示起着互补的作用。物理轨迹提供碰撞检查、安全认证和机器人执行所需的几何可解释信息。相比之下，隐空间轨迹保留了在物理坐标中无法直接观察到的高级语义信息，包括物体身份、交互上下文、运动意图和场景动态。

在规划期间，隐空间轨迹能够对未来语义场景演化进行推理，而物理轨迹保证了物理上可执行的运动和几何安全性。这种双重表示设计允许 JEPA-X 在统一的隐空间世界模型中联合优化语义预测和连续轨迹生成。

7) 轨迹评估：生成的控制点使用高度优化的轨迹评估管线进行评估。为了确保物理真实性，系统强制执行严格的锚点约束（ $C_0 = p_{\text{current}}$ ），强制零阶控制点精确匹配物体的当前物理状态，从而消除隐空间幻觉。此外，轨迹被结构化为多段速度剖面（例如，5 个速度




图 4. 具有 LRU 驱逐（64 个条目边界）的安全伯恩斯坦缓存（权利要求 28）和 cuBLAS 张量核心 GEMM 管线（权利要求 27）。控制点 $(B, K+1, D)$ 被转置并通过批处理 GEMM 与缓存的伯恩斯坦基相乘，直接分派到 NVIDIA 张量核心，与 torch.einsum 相比实现了 20–30% 的加速。

段从快速接近过渡到缓慢对接），从而实现基于速度的梯度着色和平滑执行。

C. GPU 特定优化

为了在边缘硬件上实现实时性能，我们实现了几个 GPU 特定的优化：

cuBLAS 张量核心 GEMM： 为了计算效率，Bézier 评估不是顺序执行的。相反，LKPP 利用 evaluate_bezier_batched() 函数。通过将 Bézier 基评估公式化为批处理矩阵乘法 $(C^T \otimes B^T)^T$ ，计算直接分派到 cuBLAS 张量核心 GEMM 内核。这允许 LKPP 在单个 GPU 调用中评估所有物体和 MCTS 候选者的整个 (B, M, D) 张量，与标准的 torch.einsum 实现相比，实现了巨大的吞吐量增益：20-30% 的加速。

伯恩斯坦基缓存： 我们缓存以 $(\text{degree}, M, t_{\min}, t_{\max}, \text{device})$ 为键的伯恩斯坦基矩阵，限制为 64 个条目。这消除了热路径中冗余的幂计算和二项式系数计算，提供了 18% 的 LKPP 加速（图 4）。

计算门控：边缘演化头预测连续的关系动态，并通过 2 层 MLP（约 1 TFLOP）生成 $(B, N, N, M, 2L + E)$ 张量（约 40 MB）。然而，在 MCTS 候选评估期间，解析碰撞检查器或 MCTS 评分函数都不消耗预测的边缘演化输出。因此，对每个 MCTS 候选者评估边缘演化头将引入大量计算和内存流量，而不会影响动作选择。因此，JEPA-X 在 MCTS 热路径期间禁用此分支，而在训练和因果场景模型更新期间保留它，从而提供 $2.25\times$ 的 LKPP 批处理加速。

D. 统一的自身运动与动态物体连续预测

JEPA-X 对自身节点和动态障碍物应用相同的连续轨迹表示。对于自身轨迹 $\mathbf{p}_E(\tau)$ 和物体轨迹 $\mathbf{p}_i(\tau)$ ，定义相对位移：

$$\mathbf{r}_i(\tau) = \mathbf{p}_E(\tau) - \mathbf{p}_i(\tau) \quad (10)$$

$$d_i(\tau) = \|\mathbf{r}_i(\tau)\|_2 \quad (11)$$

视界内的最小间距为：

$$d_{\min,i} = \min_{\tau \in [0, \Delta T]} d_i(\tau) \quad (12)$$

碰撞时间量可以定义为：

$$\text{TTC}_i = \inf\{\tau : d_i(\tau) \leq d_{\text{safe}}\} \quad (13)$$

这种公式区分了空间上接近但在时间上分离的物体，与那些实际上在同一未来时间进入安全包络的轨迹。

E. 速度感知分段连续轨迹

对于物理执行，仅靠位置是不够的。机器人还必须在整个运动过程中调节其速度、加速度和置信度。因此，JEPA-X 将可执行轨迹表示为

$$T = \{p(\tau), v(\tau), a(\tau), \Sigma(\tau)\}, \quad (14)$$

其中 $p(\tau)$ 表示连续空间轨迹， $v(\tau)$ 和 $a(\tau)$ 是相应的速度和加速度剖面， $\Sigma(\tau)$ 表示传播的执行不确定性。

与假设单一速度剖面的传统轨迹生成器不同，JEPA-X 将轨迹划分为多个可执行段：

$$T = \{T_1, T_2, \dots, T_M\},$$

其中每个段具有自己的持续时间、多项式阶数和期望速度剖面。这使得机器人能够在低风险区域快速移动，同时在目标、人类、障碍物、狭窄通道或不确定性升高的区域附近自动减速。

设段 m 由阶数为 K_m 的伯恩斯坦多项式、控制点 $\{C_{m,0}, \dots, C_{m,K_m}\}$ 和执行持续时间 ΔT_m 表示。由于相邻段可能具有不同的持续时间，因此必须相对于物理时间而不是归一化的伯恩斯坦参数强制执行连续性。

a) 位置连续性 (C^0)。：一段的终点必须与下一段的起点重合：

$$C_{m,K_m} = C_{m+1,0}. \quad (15)$$

b) 速度连续性 (C^1)。：为了避免不连续的速度命令，段边界处的物理速度被约束为

$$\begin{aligned} & \frac{K_m}{\Delta T_m} (C_{m,K_m} - C_{m,K_m-1}) \\ &= \frac{K_{m+1}}{\Delta T_{m+1}} (C_{m+1,1} - C_{m+1,0}). \end{aligned} \quad (16)$$

c) 加速度连续性 (C^2)。：平滑的动态执行进一步需要加速度连续性：

$$\begin{aligned} & \frac{K_m(K_m-1)}{\Delta T_m^2} (C_{m,K_m} - 2C_{m,K_m-1} + C_{m,K_m-2}) \\ &= \frac{K_{m+1}(K_{m+1}-1)}{\Delta T_{m+1}^2} (C_{m+1,2} - 2C_{m+1,1} + C_{m+1,0}). \end{aligned} \quad (17)$$

这些约束保证了物理时间上的 C^0 、 C^1 和 C^2 连续性，确保相邻轨迹段之间的平滑过渡，尽管速度剖面不同。最终，这将预测路径从纯粹的几何曲线转换为时间上可执行的运动剖面，允许物理机器人直接执行，而不会在段边界处引入速度跳跃或机械冲击。

1) 多时间尺度预测：LKPP 在三个分辨率下并发运行（表 I）：

表 I
按级别划分的分层规划参数

级别	时间视界 (ΔT)	多项式 阶数 (K)	规划 类别
低级反应式避障	0.5 s	6	反应式
中级战术交互	5.0 s	4	战术式
高级拓扑导航	60.0 s	2	战略式




图 5. 具有双分支控制点（隐空间 128D + 物理 3D）和锚点约束 ($C_0 = p_{\text{current}}$) 的 LKPP。Bézier 凸包性质保证连续轨迹包含在其控制点的凸包内，从而为固定多项式阶数的每对轨迹实现有界成本的几何分离测试。

F. 纯 GPU 解析碰撞认证与多物体剪枝

利用伯恩斯坦多项式的凸包性质，每个连续轨迹完全包含在其物理控制点的凸包内。对于物体 i ，设

$$\mathcal{H}_i = \text{ConvHull}(\{C_{i,k}^{(p)}\}_{k=0}^K), \quad (18)$$

其中 $\mathcal{H}_i$ 表示包围预测物理轨迹的所有伯恩斯坦控制点的凸包。

该性质构成了所提出的碰撞认证框架的数学基础。

定理 III-F.1 (凸包安全认证). 设 $\hat{\mathbf{p}}_A(\tau)$ 和 $\hat{\mathbf{p}}_B(\tau)$, $\tau \in [0, \Delta T]$, 为两个伯恩斯坦轨迹，其凸包 $\mathcal{H}_A$ 和 $\mathcal{H}_B$ 由各自的控制点构建。如果

$$\mathcal{H}_A \cap \mathcal{H}_B = \emptyset, \quad (19)$$

那么

$$\hat{\mathbf{p}}_A(\tau) \neq \hat{\mathbf{p}}_B(\tau), \quad \forall \tau \in [0, \Delta T]. \quad (20)$$

等价地，

$$\hat{\mathbf{p}}_A([0, \Delta T]) \cap \hat{\mathbf{p}}_B([0, \Delta T]) = \emptyset. \quad (21)$$

因此，在建模的几何假设下，预测的轨迹在整个规划视界内保持不相交。

证明. 伯恩斯坦多项式的一个基本性质指出，伯恩斯坦曲线上的每个点都位于其控制点的凸包内。因此，

$$\hat{\mathbf{p}}_A([0, \Delta T]) \subseteq \mathcal{H}_A, \quad \hat{\mathbf{p}}_B([0, \Delta T]) \subseteq \mathcal{H}_B.$$

如果 $\mathcal{H}_A \cap \mathcal{H}_B = \emptyset$ ，则两个凸包是不相交的。因此，两个轨迹集不能相交，从而确立了等式 (21)。 $\square$

该定理提供了保守的几何安全认证。如果凸包不相交，则在采用的占用模型下，保证预测的轨迹保持分离。相反，重叠的凸包不一定意味着碰撞；它们仅表明保守的认证不可用，并且需要更精确的几何评估。

定理 1 因此确立了所提出的碰撞认证框架的理论基础。基于此结果，JEPa-X 采用两阶段碰撞评估管线。第一阶段执行保守的凸包分离测试，可以立即认证安全的轨迹对。仅当该认证不可用时，第二阶段才会调用基于 GPU 的伯恩斯坦采样最小距离细化，以获得更准确的几何评估。

1) 阶段 1: 保守凸包分离认证: 对于任何一对（自身节点 A 和障碍物 B ），计算 3D 凸包 $\mathcal{H}_A, \mathcal{H}_B$ 并应用分离轴定理 (SAT)。如果 $\mathcal{H}_A \cap \mathcal{H}_B = \emptyset$ ，则轨迹在数学上是无碰撞的。系统颁发 **CERTIFIED_SAFE**（认证安全）证书。

重要提示: 凸包测试故意是保守的。凸包重叠并不意味着碰撞；它仅意味着快速的充分认证不可用，需要更精确的距离评估。相反，不相交的保守包络提供了强大的几何分离结果，但这仅在建模的物体几何、预测状态和不确定性边界的正确性下成立。

2) 阶段 2: 纯 GPU 伯恩斯坦采样距离优化: 如果凸包重叠，V2.0 会调用纯 GPU 伯恩斯坦采样的 Bézier 曲线距离计算（通过 cuBLAS 张量核心 GEMM 评估 100 个点）。这完全消除了传统的基于 CPU 的 scipy/L-BFGS-B 瓶颈和 CPU↔GPU 传输开销，以巨大的吞吐量增益实现了 $< 1 \text{ mm}$ 的精度。

对于多物体场景，空间哈希和包围体层次结构 (BVH) 剪枝消除了不必要的成对检查，保持了近线性的 $\mathcal{O}(N^{1.02-1.04})$ 缩放。

计算门控与空间剪枝: 为了最大化边缘效率，edge_evolution 计算被动态门控——在 MCTS 规划期间跳过（节省约 40 MB VRAM 和约 1 TFLOP），




图 6. 纯 GPU 解析碰撞认证管线。候选 Bézier 轨迹对通过 GPU 控制点预过滤和伯恩斯坦采样曲线距离细化进行评估。保守的凸包分离提供直接的 CERTIFIED_SAFE 决策，而不确定性和距离阈值产生分级的 CERTIFIED_SAFE、PROBABILISTIC_SAFE、UNCERTAIN 和 UNSAFE 状态。CPU/SciPy 优化仅保留为异常恢复回退，不属于正常的实时规划路径。

并且仅在阶段 B 训练期间启用。对于多物体场景，两阶段空间哈希和 BVH 剪枝将全局复杂度降低到近线性的 $O(N^{1.02-1.04})$ 经验缩放（图 6）。

G. 物理占用表示

仅预测参考轨迹并不能完全描述物理机器人的占用空间。因此，JEPA-X 将每个轨迹与保守的几何包络相关联。在当前的实现中，实体使用简化的图元（点半

径、球体、胶囊或轴对齐边界框）表示。实体 i 在时间 τ 的占用集为：

$$\mathcal{O}_i(\tau) = \hat{\mathbf{p}}_i(\tau) \oplus \mathcal{B}_i \oplus \mathcal{U}_i(\tau), \quad (22)$$

其中 $\hat{\mathbf{p}}_i(\tau)$ 是预测的参考轨迹， $\mathcal{B}_i$ 是保守的物体包络， $\mathcal{U}_i(\tau)$ 是不确定性扩展。碰撞评估是在这些扩展的占用集之间进行的，而不是仅在数学轨迹点之间进行。

在我们的实验中，对于人形机器人， $\mathcal{B}_i$ 被实例化为半径 $r = 0.5 \text{ m}$ 的球体，并且 $\mathcal{U}_i(\tau)$ 被计算为从 $\Sigma(\tau)$ 导出的 3σ 置信椭圆。碰撞检查使用这些随时间变化的占用集之间的连续时间分离测试。

a) 未来扩展：动态关节占用。：当前的实现使用刚性的、固定大小的包络。更准确的物理表示会将人形机器人建模为随关节身体运动而演化的动态体积。这可以通过以下方式实现：

- **多球体分解：** 将机器人几何近似为附着在身体段（躯干、四肢、末端执行器）上的球体或胶囊的聚集体，其位置根据预测的关节配置演化。
- **扫掠体积预测：** 计算随时间变化的并集 $\mathcal{B}_i(\tau) = \bigcup_{k=1}^{N_{\text{body}}} \mathcal{S}_k(\mathbf{q}(\tau))$ ，其中每个图元 $\mathcal{S}_k$ 由预测的关节状态 $\mathbf{q}(\tau)$ 定位。
- **构型空间不确定性：** 将关节级不确定性 $\Sigma_{\mathbf{q}}(\tau)$ 通过运动学链传播，以获得随时间变化的占用边界。

这种表示将通过考虑肢体摆动、手臂伸展和脚部放置来实现真正的碰撞避免，而不是依赖于保守的过度近似。将其与 JEPA-X 的不确定性感知预测框架集成是未来工作的主要方向。

H. 因果边缘动态与不确定性传播

1) 因果涟漪效应：为了模拟连续的物理链式反应（例如，当奔跑的孩子突然穿过其路径时，人形机器人在拥挤的环境中导航），边缘动态头预测关系边缘隐变量 $\hat{\mathbf{e}}_{ij}(\tau)$ 的连续演化。如果人形机器人预测轨迹与孩子预测路径之间的解析距离 $d_{\min}$ 低于临界阈值，则边缘状态连续地从 CLEAR_PATH → POTENTIAL_COLLISION → IMMINENT_DANGER 转换。然后，LKPP 会根据更新的边缘隐变量自动重新计算机器人的下游轨迹。

$$\hat{\mathbf{e}}_{ij}(\tau) = f_{\text{edge}}(\mathbf{e}_{ij}, \tau, \hat{\mathbf{z}}_i(\tau), \hat{\mathbf{z}}_j(\tau), d_{ij}(\tau)) \quad (23)$$

显著的关系变化可以触发下游重新预测：

轨迹 → 关系变化 → 预测后果 → 重新预测

2) 不确定性传播与分级安全证书：每个物理伯恩斯坦控制点都与高斯协方差矩阵 $\Sigma_{c,i,k}$ 相关联。假设相互独立的高斯控制点不确定性 [?]，则通过伯恩斯坦基函数传播控制点协方差来近似轨迹级协方差：

$$\Sigma_{\mathbf{p}}(\tau) \approx \sum_{k=0}^K B_{k,K}^2 \left(\frac{\tau}{\Delta T} \right) \Sigma_{c,i,k}. \quad (24)$$

JEPA-X 将确定性几何认证与概率安全评估分开。产生的执行状态被分类为四个级别（表 II）：

表 II
分级安全状态

安全状态	解释
CERTIFIED_SAFE	在建模边界下，保守的几何包络在解析上是分离的。
PROBABILISTIC_SAFE	没有确定性证书可用，但感知不确定性的碰撞概率满足配置的可接受标准。
UNCERTAIN	模型/感知不确定性过高，无法进行正常的自主执行。
UNSAFE	预测的运动违反了配置的碰撞或运动学安全余量。

对于高斯近似，碰撞概率估计为：

$$P(\text{safe}) = 1 - \Phi \left(\frac{d_{\text{thresh}} - d_{\text{min}}}{\sigma_{\text{total}}} \right) \quad (25)$$

其中 Φ 是标准正态累积分布函数 (CDF)。此概率不用作确定性凸分离证书的替代品。

I. 不确定性感知行为适应

不确定性会改变机器人行为，而不是保持被动的诊断值。一个简单的策略是：

$$v_{\text{max}}^{\text{adaptive}} = v_{\text{max}} \cdot g(\sigma) \quad (26)$$

$$d_{\text{safe}}^{\text{adaptive}} = d_0 + \alpha \sigma \quad (27)$$

其中 $g(\sigma)$ 随着不确定性的增加而减小。在低不确定性状态下，机器人可以使用标称速度。在中等不确定性下，它会减速并增加安全余量。在高不确定性下，它可能会停止、重新感知或请求重新规划，而不是执行高风险动作。

J. 运行时运动学可行性

由于 Bézier 曲线的导数本身是较低阶的 Bézier 曲线，因此可以解析地计算速度和加速度。在训练期间，物理上不可信的预测会受到惩罚。在运行时，如果候选轨迹违反了特定类别或机器人的限制，则会被明确拒绝：

$$\mathcal{F}(T) = \mathbf{1} \left[\max_{\tau} \|\dot{\mathbf{p}}(\tau)\| \leq v_{\text{max}} \wedge \max_{\tau} \|\ddot{\mathbf{p}}(\tau)\| \leq a_{\text{max}} \right] \quad (28)$$

这提供了两层保护：模型被训练为具有可行的动力学，而在线规划器不仅仅依赖学习到的行为来强制执行硬运动学限制。运动学惩罚是特定于类别的：杯子为 0.5 m/s，人类为 2.0 m/s。

K. 隐空间 MCTS 与行为树协调

隐空间蒙特卡洛树搜索 (MCTS)： 直接在连续的 Bézier 控制点空间中使用 UCB1 选择和高斯扰动运行。GPU 批处理张量评估 (forward_batched) 在单次前向传播中评估多达 35 个候选轨迹，实现实时全局优化。候选轨迹使用任务得分、目标进度、运动学可行性、碰撞状态和不确定性感知安全性进行评估。

行为树状态机： 为了解决 1Hz 隐空间 MCTS、10Hz LKPP 和 100Hz 低级控制之间的“频率脱节”，我们部署了一个非阻塞的行为树作为执行仲裁器。它管理显式状态 (NAVIGATING, SCANNING, WAITING_FOR_HUMAN, EXECUTING_TRAJECTORY)。在状态转换期间，行为树强制执行平滑的梯形减速曲线，防止机械冲击和死锁。

计算门控： 在 MCTS 规划期间，跳过边缘演化以节省每个周期约 40 MB VRAM 和约 1 TFLOP，实现极致的边缘效率。

L. 统一连续时间训练目标 (阶段 B)

为了确保 LKPP 学习的轨迹在语义上准确、物理上精确、运动学上可行且因果上一致，我们引入了连续隐空间轨迹一致性损失 $\mathcal{L}_{\text{JEPA-X}}$ 。将其公式化为视界 ΔT 上的连续时间积分：

$$\begin{aligned}
\mathcal{L}_{\text{JEPA-X}} = & \underbrace{\int_0^{\Delta T} \|\hat{\mathbf{z}}_i(\tau) - \mathbf{z}_i(t + \tau)\|^2 d\tau}_{\mathcal{L}_{\text{latent}}} \\
& + \lambda_1 \underbrace{\int_0^{\Delta T} \|\hat{\mathbf{p}}_i(\tau) - \mathbf{p}_i(t + \tau)\|^2 d\tau}_{\mathcal{L}_{\text{physical}}} \\
& + \lambda_2 \underbrace{\int_0^{\Delta T} \max\left(0, \|\dot{\hat{\mathbf{p}}}_i(\tau)\|_2 - \nu_{\max}^{(\text{class})}\right) d\tau}_{\mathcal{L}_{\text{kinematic}}} \\
& + \lambda_3 \underbrace{\int_0^{\Delta T} \|\hat{\mathbf{e}}_{ij}(\tau) - \mathbf{e}_{ij}(t + \tau)\|^2 d\tau}_{\mathcal{L}_{\text{edge}}}
\end{aligned} \tag{29}$$

$\mathcal{L}_{\text{kinematic}}$ 惩罚 Bézier 导数超过特定类别速度限制 $v_{\max}$ (杯子为 0.5 m/s, 人类为 2.0 m/s) 的轨迹。积分使用梯形法则离散化, 具有 $N = \max(50, \Delta T \times 100)$ 个均匀点。自适应损失加权根据历史梯度范数的逆比率动态调整 $\lambda_1, \lambda_2, \lambda_3$, 以防止梯度冲突。

M. 自我提升自主学习循环 (阶段 C)

如图 7 所示, 与静态部署不同, JEPA-X 具有自主演化循环。在操作期间, 系统持续收集轨迹经验数据。当满足阈值时 (≥ 1000 条轨迹, ≥ 10 种场景类型), 自主训练器触发离线重新训练:

- 1) 贝叶斯超参数优化: 具有期望改进 (EI) [9] 采集函数的高斯过程自动搜索连续空间以优化损失权重 ($\lambda_1, \lambda_2, \lambda_3$)。
- 2) 防止灾难性遗忘: 应用弹性权重巩固 (EWC) [7] 来计算费雪信息矩阵, 正则化关键参数的更新。
- 3) 安全门控部署: 新训练的模型仅在通过严格的验证门时才进行热部署: 损失减少 $\geq 5\%$ 且安全评分 ≥ 0.8 。确保在不断适应 OOD 环境的同时不会发生安全退化。

N. 联合嵌入预测训练机制

虽然前面的部分已经详细介绍了动作条件的架构, 但完整的联合嵌入预测框架需要明确的训练机制。JEPA-X 遵循联合嵌入预测架构原则 [1], 但将其扩展到具有动作条件的连续时间轨迹预测。

1) 预测目标: 设 $\mathbf{x}_{\text{context}}$ 表示时间 t 的多模态传感器输入, $\mathbf{x}_{\text{future}}$ 表示未来时间 $t + \tau$ 的相应输入, 其中 $\tau \in [0, \Delta T]$ 。我们定义两个编码器:

$$\mathbf{z}_c = f_{\theta}(\mathbf{x}_{\text{context}}) \tag{30}$$

$$\mathbf{z}_{\tau} = f_{\bar{\theta}}(\mathbf{x}_{\text{future}}) \tag{31}$$

其中 f_{θ} 是在线编码器 (上下文编码器), $f_{\bar{\theta}}$ 是目标编码器 (未来编码器)。目标编码器参数 $\bar{\theta}$ 通过在线参数的指数移动平均 (EMA) 进行更新:

$$\bar{\theta} \leftarrow \mu \bar{\theta} + (1 - \mu) \theta \tag{32}$$




图 7. JEPA-X 自我提升自主学习循环 (阶段 C)。在部署期间, 收集成功的机器人轨迹经验并过滤质量和场景多样性。贝叶斯超参数优化调整训练配置, 同时使用 EWC 正则化重新训练 LKPP 和因果边缘动态, 以减轻灾难性遗忘。更新的模型仅在通过安全和实时性能验证后才会部署, 形成受控自主改进的闭环过程。

动量系数 $\mu = 0.995$ ，遵循自监督学习文献 [2]。这种 EMA 更新确保了稳定的目标表示并防止表示崩溃。

2) 动作条件的未来预测：隐空间运动学路径预测器 (LKPP) g_ϕ 接收上下文表示 $\mathbf{z}_c$ 、候选动作嵌入 $\mathbf{a}_t$ 和连续时间参数 τ ，并预测未来的隐空间轨迹：

$$\hat{\mathbf{z}}_\tau = g_\phi(\mathbf{z}_c, \mathbf{a}_t, \tau) \quad (33)$$

动作条件至关重要： g_ϕ 预测在候选动作下会发生什么，而不仅仅是被动地预测可能会发生什么。

3) 联合嵌入预测损失：训练目标最大化预测的隐空间轨迹 $\hat{\mathbf{z}}_\tau$ 与实际未来的目标表示 $\mathbf{z}_\tau$ 之间的一致性：

$$\mathcal{L}_{\text{JEPA}} = \mathbb{E}_{\mathbf{x}_{\text{context}}, \mathbf{a}_t, \mathbf{x}_{\text{future}}} \left[\int_0^{\Delta T} \|\hat{\mathbf{z}}_\tau - \mathbf{z}_\tau\|^2 d\tau \right] \quad (34)$$

与预测单一未来表示的原始 JEPA [1] 不同，JEPA-X 预测整个视界 ΔT 上表示的连续轨迹。

4) 停止梯度与防止崩溃：一个关键机制是停止梯度操作：来自预测损失 $\mathcal{L}_{\text{JEPA}}$ 的梯度不传播到目标编码器 f_θ 中：

$$\nabla_{\theta} \mathcal{L}_{\text{JEPA}} = 0 \quad (35)$$

结合等式 (32) 中的 EMA 更新，这防止了表示崩溃。

5) 与完整训练目标的关系：联合嵌入损失 $\mathcal{L}_{\text{JEPA}}$ 与第 III.K 节中的连续时间一致性损失相结合，形成完整的目标：

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{JEPA}} + \mathcal{L}_{\text{JEPA-X}} \quad (36)$$

其中 $\mathcal{L}_{\text{JEPA-X}}$ 是等式 (29) 中的连续时间积分损失，强制执行物理一致性、运动学可行性和因果边缘动态。虽然 $\mathcal{L}_{\text{JEPA}}$ 确保隐空间具有预测性，但 $\mathcal{L}_{\text{JEPA-X}}$ 确保预测的轨迹在物理上是有意义且安全的。

6) 与标准 JEPA 的关键区别：

IV. 实验与基准测试

我们在消费级边缘硬件上验证了 JEPA-X 的实时能力、数学安全保证和计算效率。本节详细介绍了实验设置、计算性能、碰撞检测功效、消融研究和场景验证。

表 III
标准 JEPA 与 JEPA-X 的比较

方面	标准 JEPA [1]	JEPA-X
预测目标	单一未来表示	连续轨迹
动作条件	未明确建模	显式动作嵌入 $\mathbf{a}_t$
时间结构	离散步骤	连续时间 Bézier
物理基础	无	双重隐空间 + 物理
安全验证	未解决	解析 $\mathcal{O}(1)$ 认证

A. 实验设置

硬件与软件： NVIDIA RTX 2070 Max-Q (8 GB VRAM) 和 NVIDIA Jetson Orin NX (15 GB 统一内存)，运行 Ubuntu 22.04 LTS、ROS 2 Humble 和 PyTorch 2.9.0 (CUDA 12.9)。

感知管线： 如图 8 所示，RGB 和深度观测通过 YOLOv8n 进行对象检测和深度感知以进行 3D 重建，然后输入到 SLSG 中。这使得在边缘硬件上能够进行实时环境感知。

基线：

- 1) **传统基于网格的规划 (MoveIt/FCL)：** 显式 3D 网格 (URDF/Octomap) + 灵活碰撞库 [5]——笛卡尔空间安全的行业标准。
- 2) **离散隐空间 MPC (DreamerV3 风格)：** 离散自回归隐空间展开 ($z_t \rightarrow z_{t+1}$) 结合像素空间解码以进行安全验证——领先的基于重建的隐空间规划范式。
- 3) **顺序 JEPA-X：** 未优化的 Python 实现，顺序评估 MCTS 轨迹——用于证明 GPU 张量化必要性的消融基线。

评估指标： 真实的端到端管线延迟 (ms)、持续吞吐量 (FPS/Hz)、单对碰撞检测时间 (μs)、内存占用 (MB)、运动学可行性率 (%), 以及数学认证安全轨迹的比例 (%)。

以下小节描述了用于确保可重复的延迟和吞吐量测量的基准测试方法。




图 8. 用于真实世界数据采集的 JEPAX 感知管线。多模态传感器输入 (RGB 相机、深度相机) 通过 YOLOv8n 进行对象检测和深度感知以进行 3D 重建, 然后输入到结构化隐空间场景图 (SLSG) 中。该管线能够在边缘硬件上实现实时环境感知。

B. 基准测试方法

所有报告的运行时测量都是使用在目标硬件上运行的完整在线推理管线获得的。端到端延迟定义为从接收到同步的 RGB-D 传感器帧到发布相应的 ROS 2 动作命令之间经过的时间。

在基准测试之前, 系统执行了一段预热期, 以消除初始化开销并稳定 GPU 内核执行。然后在相同的操作条件下, 在重复的推理迭代中收集运行时测量。在每个计时区域之前和之后同步 CUDA 内核, 以确保准确的 GPU 计时。

除非另有说明, 否则所有实验均使用第 IV-A 节中描述的硬件和软件配置、相同的神经网络权重、相同的规划视界、相同的 MCTS 候选数量以及所有比较方法的相同场景配置。

报告的延迟对应于平均端到端执行时间。吞吐量计算为测量延迟的倒数。内存使用量代表完整规划管线的峰值运行时内存消耗, 包括神经推理、轨迹预测、碰撞评估和 ROS 2 通信。

本文目前报告平均延迟测量。详细的统计分析, 包括中位数、标准差、P95、P99、最大延迟和错过截止时间的比率, 将在未来的工作中提出。

C. 计算效率与实时性能

JEPAX 通过向量化张量操作、cuBLAS GEMM 和批处理推理克服了隐空间 MPC 的瓶颈。

真实的端到端实时延迟 (相机 → 动作): 我们严格定义“端到端”延迟, 从原始相机帧摄取到最终 ROS 2 geometry_msgs/Twist 动作命令的发布。如表 IV 所示, 该完整管线在 RTX 2070 上实现了 7.2 ms (139 FPS) 的平均端到端延迟, 在 Jetson Orin NX 上实现了 16.2 ms (62 FPS)。两者都轻松超过了高频反应式 MPC 所需的严格 30 Hz (33.3 ms) 阈值。

注意: 尾部延迟统计 (P50, P95, P99) 和标准差将在随后的出版物中报告。

批处理推理加速: 通过堆叠多达 35 个 MCTS 候选轨迹并利用 cuBLAS 张量核心 GEMM, 与顺序 GPU 基线相比, JEPAX 在 MCTS 候选评估中产生了 $16.9\times$ (RTX 2070) 和 $22.0\times$ (Orin NX) 的加速 (RTX 2070 上为 68 ms 对比 4 ms)。相对于在 Intel i7-10700 上测量的同一管线的历史纯 CPU 实现, 批处理 GPU 版本实




图 9. 端到端 GPU 加速的 JEPa-X 运行时管线。序列图显示了从相机帧采集通过 CNN 编码、结构化隐空间场景图构建、GPU 批处理 LKPP 轨迹预测、纯 GPU 碰撞认证、隐空间 MCTS 动作选择到 ROS 2 命令发布的实时处理路径。GPU 批处理和计算门控实现了实时候选评估，同时避免了 MCTS 期间不必要的边缘演化计算。

表 IV

真实端到端管线性能比较（原始相机摄取 → ROS 2 动作命令发布）

方法	平均延迟 (ms)	吞吐量 (FPS)	内存 (MB)	实时 MPC (≥ 30 Hz)
MoveIt / FCL (网格)	185.4	5.4	412	✗
离散隐空间 MPC	142.0	7.0	1,250	✗
顺序 JEPa-X	250.0	4.0	890	✗
JEPa-X (RTX 2070)	7.2	139	1142	✓
JEPa-X (Orin NX)	16.2	62	975	✓

现了约 $871\times$ 的有效加速 ($3500\text{ ms} / 4.02\text{ ms}$)，突显了 GPU 批处理、解析碰撞认证和计算门控的综合优势。

边缘部署可行性： 整个系统保持了极低的 GPU VRAM 峰值，仅约 $\sim 30\text{ MB}$ ，总系统 RAM 为 1142 MB (RTX) 和 975 MB (Orin)，证明了其在高度资源受限的边缘设备上的可行性。

D. 解析碰撞与剪枝功效

JEPa-X 利用 Bézier 凸包性质，用两阶段解析管线替代了昂贵的基于网格的碰撞检查。




图 10. JEPa-X 与传统基于网格的方法之间的碰撞检测可扩展性比较。该图绘制了场景中的动态对象数量 (N) 与碰撞检查时间的关系。传统的 FCL 表现出 $O(N^2)$ 的二次复杂度，仅在 $N = 3$ 个对象时就突破了 30 Hz 实时阈值 (33.3 ms , 绿色虚线)。相比之下，JEPa-X 的两阶段解析碰撞模块结合了 $O(1)$ 凸包 SAT 检查与空间哈希和 BVH 剪枝，实现了近线性的 $O(N^{1.02-1.04})$ 缩放。在 $N = 50$ 个动态对象时，剪枝机制消除了 84% 的不必要成对碰撞检查，使碰撞评估时间保持在实时约束之下。

1. **每对恒定成本的几何认证：** 对于我们在实验中使用的固定 Bézier 阶数，阶段 1 凸包分离测试对于场景大小 N 具有每对轨迹的有界计算成本。它直接将 85.0% (RTX 2070) 和 89.0% (Orin NX) 的评估轨迹对解析为 CERTIFIED_SAFE，从而绕过了更昂贵的阶段 2 距离细化。

2. **近线性 $O(N)$ 经验缩放：** 如图 10 所示，对于多物体场景，两阶段剪枝机制在 RTX 上 $N = 50$ 时消除了 84% 的不必要成对检查，在 Orin 上 $N = 50$ 时消除了 77% 。对 $N = 2 \dots 100$ 的经验对数-对数斜率分析显示，RTX 上的缩放复杂度为 $O(N^{1.04})$ ，Orin 上为 $O(N^{1.02})$ ，证明了近线性的可扩展性。

3. **碰撞检测吞吐量：** 如图 11 所示，纯 GPU 解析碰撞模块在 RTX 2070 上实现了 $1,186\text{ Hz}$ （每对 $843\text{ }\mu\text{s}$ ）的持续吞吐量，在 Orin NX 上实现了 440 Hz （每对 $2,275\text{ }\mu\text{s}$ ）。这代表与传统的基于 CPU 的 FCL 网格碰撞检查（每对约 120 ms ）相比，实现了约 $142\times$ 到 $53\times$ 的加速。

E. 消融研究

为了隔离我们核心架构创新的贡献，我们在 20 物体动态场景上进行了定量消融研究。结果总结在表 V 中。

- **纯 GPU 碰撞与计算门控的影响：** 恢复为传统的基于 CPU 的管线并在 MCTS 期间启用




图 11. 三种认知架构之间的端到端管线延迟比较。JEPA-X 在 RTX 2070 上实现了 **7.2 ms 延迟 (139 FPS)**，在 Orin NX 上实现了 **16.2 ms (62 FPS)**，轻松超越了 30 Hz 实时阈值 (33.3 ms, 绿色虚线)。相比之下，传统的基于网格的规划 (MoveIt/FCL) 产生了 185.4 ms 的延迟 (5.4 FPS)，而离散隐空间 MPC 需要 142.0 ms (7.0 FPS)，两者均未能满足实时要求。通过纯 GPU 批处理张量评估和解析碰撞认证，JEPA-X 在 MCTS 候选评估中实现了高达 871× 的加速。

表 V

JEPA-X V2.0 核心组件的消融研究 (JETSON ORIN NX / RTX 2070 上的 20 物体场景)

配置	MCTS 延迟 (ms)	碰撞检查 (对)	运动学可行性 (%)	安全认证率 (%)
完整 JEPA-X (ours)	15.6	42 (78% 剪枝)	100.0	100.0
无批处理 GPU 执行	>194.0	42	100.0	100.0
无空间剪枝	15.6	190 (0% 剪枝)	100.0	100.0
无自适应损失加权	15.6	42	76.2	100.0

edge_evolution，会导致 Orin NX 上的规划延迟从 15.6 ms 飙升至 >194.0 ms，立即违反了 30 Hz 的实时约束。这验证了纯 GPU 伯恩斯坦采样和计算门控对于隐空间 MPC 的必要性。

- **空间剪枝的影响**：在 20 物体场景中禁用空间哈希和 BVH 剪枝，会将碰撞评估的数量从 42 对增加 4.5× 到 190 对，这表明解析的 $\mathcal{O}(1)$ 检查必须与空间剔除配对，以在高密度场景中保持实时性能。
- **自适应损失加权**：在阶段 B 训练期间，禁用基于梯度范数的自适应加权会导致严重的梯度冲突，其

中运动学惩罚占主导地位 (损失比率 >50:1)。这导致了物理上不可行的“隐空间幻觉” (例如，预测的杯子速度 >5 m/s)，将运动学可行性率降低到 76.2%。启用自适应机制成功地平衡了梯度，确保验证集上的运动学可行性达到 100%。

F. 场景验证

除了合成基准测试外，JEPA-X 还在两个符合专利实施例的代表性真实世界模拟场景中进行了验证：

高速动态避障 (实施例 1 和 5)：一个以 1.2 m/s 导航的移动机器人遇到了横向移动的动态障碍物 (模拟的宠物，速度为 2.5 m/s)。解析碰撞模块通过求解两条连续 Bézier 曲线之间的最小空间距离，直接计算了连续的碰撞时间 (TTC)。它识别出在未来时间参数 $\tau = 1.4$ s 处存在预测的碰撞风险，此时计算出的最小距离 $d_{\min}$ 降至 0.1 m，违反了预定义的 0.3 m 安全阈值。系统在 15 ms 内发出了 CERTIFIED_SAFE 规避轨迹，无需笛卡尔变换或物理引擎——成功以 0.3 m 的余量避开了障碍物。

因果涟漪效应 (实施例 2)：一个人形机器人在拥挤的行人区域导航时，一个奔跑的孩子突然穿过其路径。边缘动态头持续评估关系边缘隐变量，将状态从 CLEAR_PATH → POTENTIAL_COLLISION → IMMINENT_DANGER 转换。这触发了通过隐空间 MCTS 自动进行下游轨迹重新计算，产生了一条平滑、安全的绕行路线，保持了人形机器人的平衡和安全——完全在 128D 隐流形内完成。

关于加速比报告的说明

在本节中，加速比是相对于两个不同的基线报告的：

- 1) **同等 GPU 比较**：在同一 GPU 硬件上的顺序执行与批处理执行 (例如，RTX 2070 上 68 ms 顺序对比 4 ms 批处理，产生 17.0×)。
- 2) **历史 CPU 比较**：批处理 GPU 执行相对于在 Intel i7-10700 上测量的 v0.5.0 纯 CPU 基线 (35 个 MCTS 候选者需要 3500 ms)。这产生了 871× 的加速比数字，反映了 GPU 加速、张量批处理和算法改进相对于原型实现的累积影响。

871× 的数字旨在作为所取得总进展的数量级说明，而 16.9× / 22.0× 的数字代表了在当前硬件上 GPU 批处理的直接益处。

V. 讨论

A. 对 JEPA-X 的解释

JEPA-X 应被解释为一种连续时间世界模型规划架构，而不仅仅是一个 Bézier 轨迹生成器。其显著特征是，动作条件的隐空间预测、物理运动、相对动态物体推理、不确定性和安全验证共享相同的未来时间参数。

凸包测试故意是保守的。凸包重叠并不意味着碰撞；它仅意味着快速的充分认证不可用，需要更精确的距离评估。相反，不相交的保守包络提供了强大的几何分离结果，但这仅在建模的物体几何、预测状态和不确定性边界的正确性下成立。这是一个关键的科学细微差别：系统提供了安全的充分条件，而不是必要条件。

分段速度扩展加强了预测与控制之间的联系。机器人轨迹不仅应指定空间路径几何，还应指定速度如何随着风险、不确定性和目标接近度而变化。这对于在人类附近操作的人形机器人和服务机器人尤为重要。

B. 实际意义

在消费级边缘硬件（RTX 2070, Jetson Orin NX）上展示的性能表明，JEPA-X 适用于真实世界部署，而无需专用加速器或云连接。低内存占用（约 30 MB GPU VRAM）使其能够部署在移动机器人、无人机和服务机器人等资源受限的平台上。

自主学习循环（阶段 C）能够在无需手动重新训练或基于云的更新的情况下，持续适应新环境，解决了当前部署的机器人系统的一个关键限制。

C. 局限性

- 1) **真实机器人验证**：物理机器人部署正在进行中，并将在随后的出版物中报告。目前的结果基于广泛的模拟和边缘硬件基准测试。
- 2) **安全认证假设**：CERTIFIED_SAFE 证书仅在建模的几何、状态和不确定性假设下有效。违反这些假设（例如，未建模的物体、传感器故障）可能会损害该保证。
- 3) **可变形物体**：当前的实现假设刚体几何。扩展到可变形物体（布料、绳索）和关节机构仍是未来的工作。
- 4) **阶段 2 精度**：GPU 曲线距离细化声称具有亚毫米精度。这应在随后的出版物中针对高精度参考求

解器在许多随机轨迹对上进行验证，报告平均值、P95、P99 和最大绝对误差：

$$\epsilon_d = |d_{\min}^{\text{GPU}} - d_{\min}^{\text{reference}}| \quad (37)$$

- 5) **条件失败概率**：需要对大量随机动态场景进行关键的安全校准研究。推荐的指标包括：碰撞率、最小净空、假安全率、假不安全率、CERTIFIED_SAFE 决策的百分比、UNCERTAIN 决策的百分比、错过截止时间的比率，以及：

$$P(\text{collision} \mid \text{CERTIFIED_SAFE}) \quad (38)$$

这种条件失败概率直接测试了实际实现是否与建模的认证假设一致。

D. 安全关键考虑

在安全关键的机器人技术中，确定性几何分离和概率置信度不应混为一谈。因此，JEPA-X 将解析几何认证与不确定性感知安全评估区分开来。持续学习（阶段 C）被视为正交的适应机制，并且不是在线安全证书所必需的。安全证书是从当前模型和传感器数据计算得出的，独立于任何学习更新。

VI. 结论与未来工作

在本文中，我们介绍了 JEPA-X，这是一种新颖的认知架构，从根本上解决了先前隐空间世界模型中固有的“时间盲区”和“表示脱节”。通过放弃离散自回归步骤预测和像素级重建，JEPA-X 完全在共享的 128 维隐流形内执行连续轨迹预测和数学安全认证。

我们的核心技术贡献包括隐空间运动学路径预测器（LKPP），它使用具有严格锚点约束和多段速度剖面的连续伯恩斯坦多项式来参数化未来的物理和语义状态。通过利用数学凸包性质，我们的纯 GPU 解析碰撞模块实现了 $\mathcal{O}(1)$ 常数时间安全认证，完全绕过了 3D 网格渲染和传统 CPU 瓶颈。此外，我们引入了具有计算门控的因果边缘动态引擎、统一的连续时间积分损失函数和阶段 C 贝叶斯自主学习循环。

在消费级边缘硬件上进行的广泛基准测试表明，JEPA-X 是一个非常适合真实世界部署的高度可行系统。该架构在 RTX 2070 上实现了 7.2 ms (139 FPS) 的真实端到端认知管线延迟，在 Jetson Orin NX 上实现了 16.2 ms (62 FPS)，满足高频 MPC 的严格 ≥ 30

Hz 要求。通过纯 GPU 批处理张量评估和空间哈希，JEPA-X 在轨迹评估中实现了高达 $871\times$ 的加速，保持了 85–89% 的 CERTIFIED_SAFE 签发率，并实现了近线性的 $\mathcal{O}(N^{1.02-1.04})$ 多物体缩放。总体而言，结果表明 JEPA-X 为具有自主学习能力的、具有数学基础和因果意识的机器人规划提供了一个有前途的框架。

A. 未来工作

虽然 JEPA-X 为安全的自主导航提供了坚实的基础，但仍有几个有前途的途径值得未来调查：

- 1) **大规模随机安全验证**：在大量随机动态场景上进行全面的安全校准研究，以验证 CERTIFIED_SAFE / PROBABILISTIC_SAFE 阈值，并计算第 V 节中推荐的 $P(\text{collision} \mid \text{CERTIFIED_SAFE})$ 。
- 2) **真实机器人验证**：在物理移动和人形平台上部署，包括全身扫描体积建模，以验证真实世界条件下的性能。
- 3) **实时环境数据验证与持续学习**：扩展阶段 C 以验证和过滤实时传感器数据，区分新颖的安全场景与需要人工审查的异常情况——从而实现从真实世界部署中进行安全的持续学习。
- 4) **自动扶梯导航与混合地形**：扩展多时间尺度 LKPP 和行为树以处理垂直移动平台（自动扶梯、移动人行道），使用动态支撑面更新 SLSG，并在登乘、乘坐和离开期间强制执行安全约束。
- 5) **动态儿童避障与密集行人场景**：增强不可预测代理（例如儿童）的因果边缘动态。重点：通过优化的不确定性传播实现更快的反应时间、对不稳定轨迹的预测建模以及平滑的社交感知重新规划。
- 6) **具有语音/听觉接口的去中心化多智能体协调**：将 SLSG 和隐空间 MCTS 扩展到去中心化框架，将人类视为具有意图的动态代理。使口头命令解释能够作为高级隐空间约束，结合观察到的行为和口头线索进行意图预测，并在拥挤空间中进行平滑协调。
- 7) **全身人形运动**：扩展行为树和多时间尺度 LKPP 以控制全身人形机器人（双足行走的 30+ 自由度），在超维动作空间中测试 128D 隐空间瓶颈和 $\mathcal{O}(N \log N)$ 剪枝，同时保持实时安全认证。

8) **复杂的可变形物理与关节物体**：扩展隐空间凸分解和边缘演化机制，以处理高度非凸、可变形物体（例如，布料、绳索）和复杂的多体关节动力学。

9) **GPU 距离细化的数值验证**：针对高精度参考，在许多随机轨迹对上验证亚毫米曲线距离精度声明，报告平均值、P95、P99 和最大绝对误差。

10) **主动感知策略**：开发由高认知不确定性触发的主动感知策略，以在执行高风险动作之前降低不确定性。

11) **双轨迹表示**：JEPA-X 联合预测连续的隐空间轨迹及其对应的物理轨迹。物理轨迹提供碰撞认证、运动学可行性分析和机器人执行所需的几何可解释信息，而隐空间轨迹在整个预测视界内保留高级语义演化、交互上下文和场景动态。

尽管这种双重表示架构的动机是语义推理和几何规划的互补作用，但本工作并未包括将纯物理轨迹预测与所提出的双轨迹公式进行比较的定量消融。未来的工作将进行系统的消融研究，以量化隐空间轨迹对长期预测准确性、规划性能、语义一致性和决策鲁棒性的贡献。

12) **动态关节占用**：当前的实现使用保守的刚性占用图元（如球体、胶囊或边界框）来表示机器人，这提供了高效的实时碰撞认证，但无法完全捕捉关节人形运动的演化几何。

未来版本的 JEPA-X 将预测连续的关节占用模型，其中占用体积与预测的身体配置一起演化。机器人不再表示为固定的包络，而是每个身体段将与自己随时间变化的几何图元相关联，从而产生连续的动态占用凸包：

$$\mathcal{O}(\tau) = \bigcup_{l=1}^L \mathcal{V}_l(q_l(\tau)), \quad (39)$$

其中 $q_l(\tau)$ 表示身体段 l 的预测关节配置， $\mathcal{V}_l(\cdot)$ 表示其相应的几何体积。这种公式使得预测的占用空间能够在机器人行走、转弯、操纵物体或改变姿势时连续变形。

13) **动态占用的连续碰撞认证**：在关节占用表示的基础上，未来版本的 JEPA-X 将把碰撞认证框架从基于轨迹的几何包络扩展到连续的关节占用体积。

碰撞模块将不再评估固定保守包络之间的分离，而是对两个随时间变化的占用集执行连续碰撞评估，确保它们保持不相交：

$$\mathcal{O}_A(\tau) \cap \mathcal{O}_B(\tau) = \emptyset, \quad \forall \tau \in [0, \Delta T], \quad (40)$$

其中每个占用集根据预测的关节身体运动而演化。这种扩展将允许碰撞推理考虑肢体摆动、手臂伸展、躯干旋转和其他无法用刚性边界体积表示的关节身体运动。

将连续的关节占用预测与不确定性感知碰撞认证相结合，代表了 JEPA-X 迈向物理上准确的全身人形规划的主要未来研究方向之一。

致谢

作者感谢北京棠塔科技有限公司对本研究的支持，并提供进行广泛基准测试所需的计算资源。

参考文献

- [1] Y. LeCun, “通往自主机器智能之路,” *Open Review*, 2022.
- [2] M. Assran, Q. Duval, I. Misra, P. Bojanowski, P. Vincent, M. Rabbat, Y. LeCun, and N. Ballas, “使用联合嵌入预测架构从图像中进行自监督学习,” in *IEEE/CVF 计算机视觉和模式识别会议论文集 (CVPR)*, 2023.
- [3] D. Hafner, J. Pasukanian, G. Voelker, and T. Lillicrap, “DreamerV3: 通过世界模型掌握多样化领域,” *arXiv 预印本 arXiv:2301.04104*, 2023.
- [4] S. Chitta, I. Sucan, and S. Cousins, “MoveIt!,” *IEEE 机器人与自动化杂志*, vol. 19, no. 4, pp. 106-110, 2012.
- [5] J. Pan, S. Chitta, and D. Manocha, “FCL: 用于碰撞和邻近查询的通用库,” in *IEEE 国际机器人与自动化会议 (ICRA)*, 2012, pp. 3859-3866.
- [6] F. Locatello, M. Weissenborn, T. Unterthiner, A. Nair, G. Heigold, A. van den Oord, T. Kipf, and I. Steeghs, “使用 Slot Attention 的以对象为中心的学习,” in *神经信息处理系统进展 (NeurIPS)*, 2020.
- [7] J. Kirkpatrick, R. Pascanu, N. Rabinowitz, J. Veness, G. Desjardins, A. A. Rusu, K. Milan, J. Quan, T. Ramalho, A. Grabska-Barwinska, et al., “克服神经网络中的灾难性遗忘,” *美国国家科学院院刊 (PNAS)*, vol. 114, no. 13, pp. 3521-3526, 2017.
- [8] C. Browne, E. Powley, D. Whitehouse, S. M. Lucas, P. I. Cowling, P. Rohlfshagen, S. Tavener, D. Perez, S. Samothrakis, and S. Colton, “蒙特卡洛树搜索方法综述,” *IEEE 计算智能与游戏人工智能汇刊*, vol. 4, no. 1, pp. 1-43, 2012.
- [9] B. Shahriari, K. Swersky, Z. Wang, R. P. Adams, and N. De Freitas, “将人类移出循环：贝叶斯优化综述,” *IEEE 学报*, vol. 104, no. 1, pp. 148-175, 2015.
- [10] M. Colledanchise and P. Ogren, *机器人与人工智能中的行为树：简介*, CRC Press, 2018.
- [11] J.-L. T. Aslan and D. Zhang, “一种通过连续隐空间轨迹预测和解析碰撞认证进行自主机器人决策的方法与系统,” 中国专利申请, 北京糖塔科技有限公司, 2026.
- [12] J.-L. T. Aslan and D. Zhang, “JEPA-X 认知决策系统软件手册 V6.0,” 软件著作权申请 2026R11L2342491, 北京糖塔科技有限公司, 中国北京, 2026.
- [13] M. Quigley, K. Conley, B. Gerkey, J. Faust, T. Foote, J. Leibs, R. Wheeler, and A. Y. Ng, “ROS: 一个开源的机器人操作系统,” in *ICRA 开源软件研讨会*, 2009.
- [14] S. Macenski, F. Martin, R. White, and J. Clavero, “机器人操作系统 2: 设计、架构与用途,” *Science Robotics*, 2022.
- [15] J. García and F. Fernández, “安全强化学习综合调查,” *机器学习研究杂志*, vol. 16, no. 1, pp. 1437-1480, 2015.
- [16] N. Ratliff, M. Zucker, J. A. Bagnell, and S. Srinivasa, “CHOMP: 用于高效运动规划的梯度优化技术,” in *IEEE 国际机器人与自动化会议 (ICRA)*, 2009, pp. 489-494.
- [17] M. Kalakrishnan, S. Chitta, E. Theodorou, P. Pastor, and S. Schaal, “STOMP: 用于运动规划的随机轨迹优化,” in *IEEE 国际机器人与自动化会议 (ICRA)*, 2011, pp. 4569-4574.
- [18] A. D. Ames, S. Coogan, M. Egerstedt, G. Notomista, K. Sreenath, and P. Tabuada, “控制障碍函数：理论与应用,” in *欧洲控制会议 (ECC)*, 2019, pp. 3420-3431.
- [19] P. Kidger, “关于神经微分方程,” 博士学位论文, 牛津大学, 2022.