形状可解释视觉自建模赋能几何感知连续体机器人控制

Peng Yu、Xin Wang 和 Ning Tan*

arXiv:2603.01751v1 [cs.RO] 2 Mar 2026

摘要——**连续体机器人具有高度柔性和冗余性，非常适合在复杂环境中进行安全交互；然而，其连续变形和非线性动力学给感知、建模和控制带来了根本性挑战。现有的基于视觉的控制方法通常依赖端到端学习，虽能实现形状调节，却无法显式感知机器人几何形态及其与环境的交互。在此，我们提出一种面向连续体机器人的形状可解释视觉自建模框架，以实现几何感知控制。该框架利用 B´ezier 曲线表示，从多视图平面图像中编码机器人形状，将视觉观测转化为紧凑且具有明确物理意义的形状空间，从而唯一表征机器人的三维构型。基于这一表示，我们采用神经常微分方程，直接从数据中对形状和末端执行器动力学进行自建模，无需解析模型或密集的本体标记点，即可实现形状-位置混合控制。所学习的形状空间具有显式几何结构，使机器人能够推理自身形体及周围环境，从而支持避障和自运动等环境感知行为，同时维持末端执行器目标。在绳驱连续体机器人上的实验表明，该方法能够准确调节和跟踪形状位置：形状误差不超过图像分辨率的 1.56%，末端执行器误差不超过机器人长度的 2%；此外，该方法在受限环境中也表现稳健。通过将视觉形状表示从二维观测提升为可解释的三维自模型，本研究为基于视觉的端到端控制确立了一种有理论依据的替代方案，并推动了面向连续体机器人的自主几何感知操作。**

关键词—**连续体机器人、自建模、形状/位置控制**

一、引言

连续体机器人是一类独特的机器人系统，其运动并非由离散的刚性关节产生，而是通过柔性骨架的连续变形实现。这种形态范式使其能够实现类似生物附肢的运动，例如章鱼触手 [1],蛇 [2],和象鼻 [3], ，赋予连续体机器人高度的运动学冗余、固有柔顺性，以及对非结构化环境的卓越适应性。这些特性使其特别适用于需要在狭窄、复杂或不确定空间内进行安全、平稳且灵巧交互的任务，包括微创手术 [4]，灾害救援 [5]，以及对……的检查复杂管道和工业设备 [6]，以及人机协作 [7]。然而，赋予连续体机器人多功能性的特性，即连续变形、结构柔性和高度冗余，也带来了显著的非线性、强耦合和较大的参数不确定性。因此，实现对连续体机器人的可靠感知、建模和控制，仍是一项根本性且尚待解决的挑战。

过去几十年来，研究人员针对连续体机器人的末端执行器控制开展了大量研究。人们探索了基于模型和数据驱动策略，包括基于恒定曲率假设的逆运动学求解器 [8], 基于有限元的动力学模型 [9],以及基于Cosserat杆的运动静力学公式 [10]。尽管这些方法已展现出令人瞩目的性能，但其效果往往受限于连续体机器人固有的强非线性、高耦合性和参数不确定性。为减轻建模误差，越来越多的研究转向无模型和数据驱动控制 [11]。早期研究利用在线雅可比矩阵估计 [12], [13], 而近期工作则借助Koopman算子 [14]–[18] 和神经常微分方程（NODE） [19], [20] ，直接从数据中学习机器人动力学。这些基于学习的方法大幅简化了控制器设计并提高了数据效率，即使存在显著不确定性，也能实现准确的末端执行器控制 [21]。

然而，对于涉及连续体机器人的许多现实任务而言，仅控制末端执行器并不足够。由于这类机器人的身体细长且易变形，要在杂乱或受限环境中安全、有效地运行，往往需要机器人主动调节自身形状 [22]–[24], ，而非仅仅定位其末端。因此，形状控制已成为末端执行器控制的重要补充能力。

现有的连续体机器人形状控制方法，根据其形状表示范式，大致可分为三类：基于模型的方法、基于离散形状点的数据驱动方法，以及基于视觉的端到端学习方法。基于模型的方法通常依赖明确的物理和几何模型，通过解析结构表示形状，例如分段恒定曲率模型 [25],梁理论 [26], [27],或 Cosserat杆公式。这些模型已成功融入优化或预测控制框架，用于调节机器人形状并避开障碍物。然而在实际应用中，由于材料

* 通讯作者。所有作者均任职于中国广州510006中山大学计算机科学与工程学院。（电子邮箱：yupeng6@mail2.sysu.edu.cn；wangx767@mail2.sysu.edu.cn；tann5@mail.sysu.edu.cn）

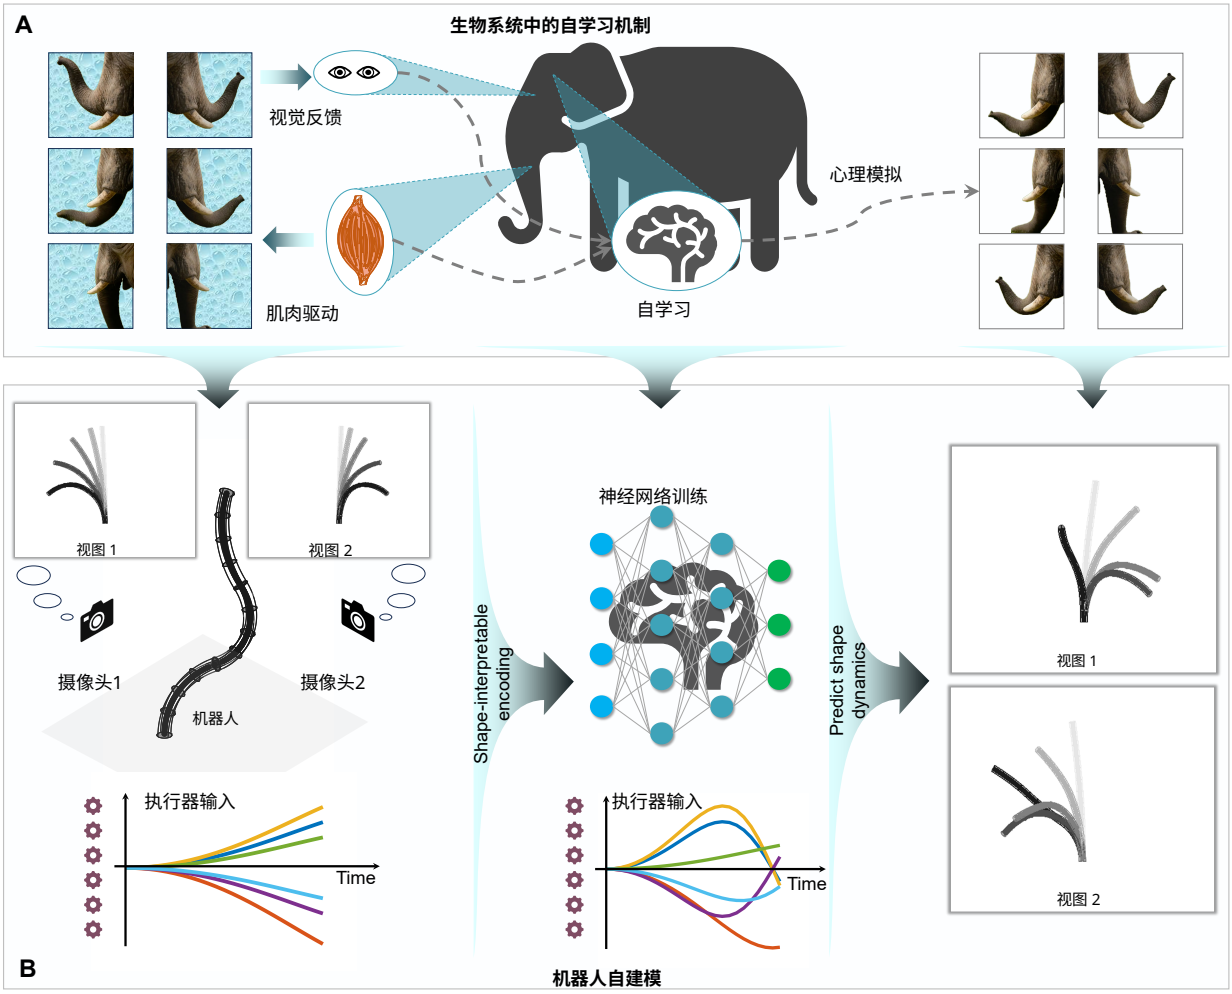


图1. 生物启发的自建模机制概念图。(A) 生物系统中的自学习机制。大象通过肌肉驱动控制象鼻运动，并通过双目视觉获取相应的象鼻形态反馈，从而学习肌肉激活与象鼻形态之间的关系。基于这一习得的内部模型，大象可以预见自身运动指令引起的形状变化，并据此控制象鼻完成复杂操作任务。(B) 连续体机器人由任意时序输入信号驱动，同时从两个不同视角记录机器人每个时刻的图像数据。图像数据经过参数化，并与驱动信号一同编码，形成用于神经网络训练的数据集。训练完成后，连续体机器人可以利用学习到的网络，在给定时序输入信号的情况下，自主预测不同视角下的视觉形状动态。

非线性、摩擦、滞后以及未建模的外部相互作用，要准确建模连续体机器人仍极具挑战。因此，纯粹的模型驱动方法在现实场景中往往鲁棒性有限、性能下降。为减少对建模的依赖，研究人员提出了基于离散特征点的数据驱动形状控制方法 [28]–[35]。这些方法使用沿主干分布的一组带标签点来表示机器人形状，并联合调节这些点的位置。尽管这类方法效果良好，但通常需要密集的实体标记 [36],、精细的相机标定或昂贵的深度传感器。这些要求增加了系统复杂度，影响机器人的固有柔顺性，并限制了实际部署。近年来，基于视觉的端到端学习方法受到越来越多的关注。通过使用深度神经网络直接将图像映射为控制指令 [22], [37],[38], ，这类方法无需进行明确的形状建模或标记布置。尽管它们对视觉干扰表现出很强的鲁棒性，但现有的大多数方法局限于平面形状控制，并且受到根本性限制：（i）学习到的形状表示是隐式的，无法显式提供对机器人本体几何特征或其与环境之间距离的几何感知；（ii）单视图表示存在非唯一映射问题，不同的三维形状可能产生相同的二维投影。因此，这类方法难以支持避障或通过形状调节实现自运动等灵活操作。

尽管存在差异，现有的形状控制范式仍有一个共同局限：缺乏对机器人完整三维形状进行有原则、可解释且可学习的表示。在以往的研究中，形状要么受到不准确模型的过度约束，要么由稀疏测量进行不充分表示，要么被隐式编码在黑箱模型中，从而妨碍了泛化、可解释性以及跨任务的灵活复用。这一观察促使我们采取一种根本不同的视角：不再预先规定或绕过形状

模型，连续体机器人能否直接从多视角观测中学习自身的三维形状动力学，并将其用于控制?

生物系统有力地证明，控制高度可变形物体并不以显式解析模型为前提。例如，大象能够灵巧地操纵物体、避开障碍物，并在其象鼻具有极高冗余度和柔顺性的情况下灵活改变象鼻形状。这些能力通过经验驱动的自学习而形成：动物借助传出动作信号和传入视觉反馈，逐步获得驱动与身体变形之间关系的内部表征 [37]。受这种自建模范式的启发，如图1所示，本文研究一种在最低限度传感假设下，基于视觉的连续体机器人形状控制方法。所提方法无需依赖解析模型、实体标记或相机标定，即可使机器人仅凭多视角视觉观测自主学习自身的形状动力学。尽管每个单一视角仅提供二维表征，但多个不同视角相结合，便能与机器人的三维形状建立唯一对应关系，而无需显式进行三维重建。详细的自建模与控制框架如图 2所示。利用 B´ezier 曲线对各视角下的机器人主干进行参数化，从而得到一种紧凑、具备几何感知能力且可解释的形状表示。基于该表示，采用 NODE模型学习视觉空间中的形状动力学，形成对机器人三维形状演化的隐式自建模。同时，另行学习一个基于 NODE 的模型，以描述末端执行器位置动力学。在所学习的模型基础上，构建统一的基于雅可比矩阵的形状-位置混合控制框架。在该框架下，形状调节可自然实现避障和自主运动等灵活行为，同时保持末端执行器的精确定位。

与现有方法相比，所提方法从几个关键方面推进了连续体机器人控制。（i）不同于依赖精确解析描述的基于模型的策略，所提框架通过基于视觉的自建模，消除了显式物理建模的需求。（ii）不同于依赖稀疏或密集标注身体点的数据驱动形状控制方法，所提方法仅利用低成本的单目视觉观测，实现了无标记形状表征。（iii）不同于将形状隐式编码在不透明潜在空间中、且通常局限于平面控制的基于视觉的端到端控制方法，所提框架以具有几何意义的形式显式表示机器人形状，并自然地将形状调节从二维视觉投影扩展到一致的三维形状控制。

本工作的主要贡献有三点。(i) 我们提出了一种形状可解释视觉自建模框架，使连续体机器人能够直接根据多视图视觉观测自主学习自身的形状动力学，无需解析模型、实体标记或相机标定。(ii) 我们开发了一种具备几何感知能力的形状-位置控制策略，显式利用学习到的形状表示来调节本体变形，从而支持避障和自运动等灵活行为。(iii) 我们通过在绳驱动连续体机器人上开展全面实验，验证了所提方法的有效性，展示了精准的形状-位置调节、可靠的环境交互，以及相较于一种具有代表性的基于视觉的端到端控制方法的显著性能优势。

II. 预备知识

本节介绍连续体机器人的形状-位置动力学以及用于形状表征的 B´ezier 曲线的基本背景知识。

A. 形状-位置动力学

对于具有 m 个执行器的连续体机器人，其形状动力学可表示为

$$\dot{\mathbf{x}}_{\mathrm{s}}(t) = f_{\mathrm{s}}(\mathbf{x}_{\mathrm{s}}(t), \mathbf{u}(t)) \tag{1}$$

其中$\mathbf{x}_{\mathrm{s}}(t) \in \mathbb{R}^k$ 表示机器人在时间 t的 k维形状状态向量，该向量通过对来自不同视角的机器人图像进行编码而获得，$\dot{\mathbf{x}}_{\mathrm{s}}(t)$表示$\mathbf{x}_{\mathrm{s}}(t)$的一阶时间导数，$\mathbf{u}(t) \in \mathbb{R}^m$ 是驱动输入向量，f_{s} 是刻画形状动力学的非线性函数。

同样，其末端执行器动力学通常表述为
as

$$\dot{\mathbf{x}}_{\mathrm{p}}(t) = f_{\mathrm{p}}(\mathbf{x}_{\mathrm{p}}(t), \mathbf{u}(t)) \tag{2}$$

其中$\mathbf{x}_{\mathrm{P}}(t) \in \mathbb{R}^n$ 表示 n维任务空间中的末端执行器状态（在本研究中对应于末端执行器位置），$\dot{\mathbf{x}}_{\mathrm{P}}(t)$表示$\mathbf{x}_{\mathrm{P}}(t)$的一阶时间导数，$f_{\mathrm{p}}$ 是刻画末端执行器动力学的非线性函数。

本研究的目标是确定一种合适的方法来编码机器人的三维形状，以促进视觉形状动力学自建模，并学习上述未知的形状动力学（1）和末端执行器动力学（2），从而能够设计混合形状-位置控制策略。

B. 贝塞尔曲线

本文尝试利用连续体机器人的多视角平面图像，确定其唯一的三维构型。连续体机器人的平面形状通常表示为分段曲线。为了描述连续体机器人在平面上的形状，本文采用贝塞尔曲线，因为它具有明确的几何解释和简单的多项式形式。如图 2 所示，只需少量控制点即可直接控制曲线形状 [36], ，这有助于直观建模，并能高效地在相邻线段之间施加连续性约束，因此贝塞尔曲线特别适合对平面多段曲线进行紧凑且可解释的建模。

考虑一条由 M 个二次贝塞尔线段表示的平面曲线，每个线段定义在局部参数 $s \in [0, 1]$ 上。

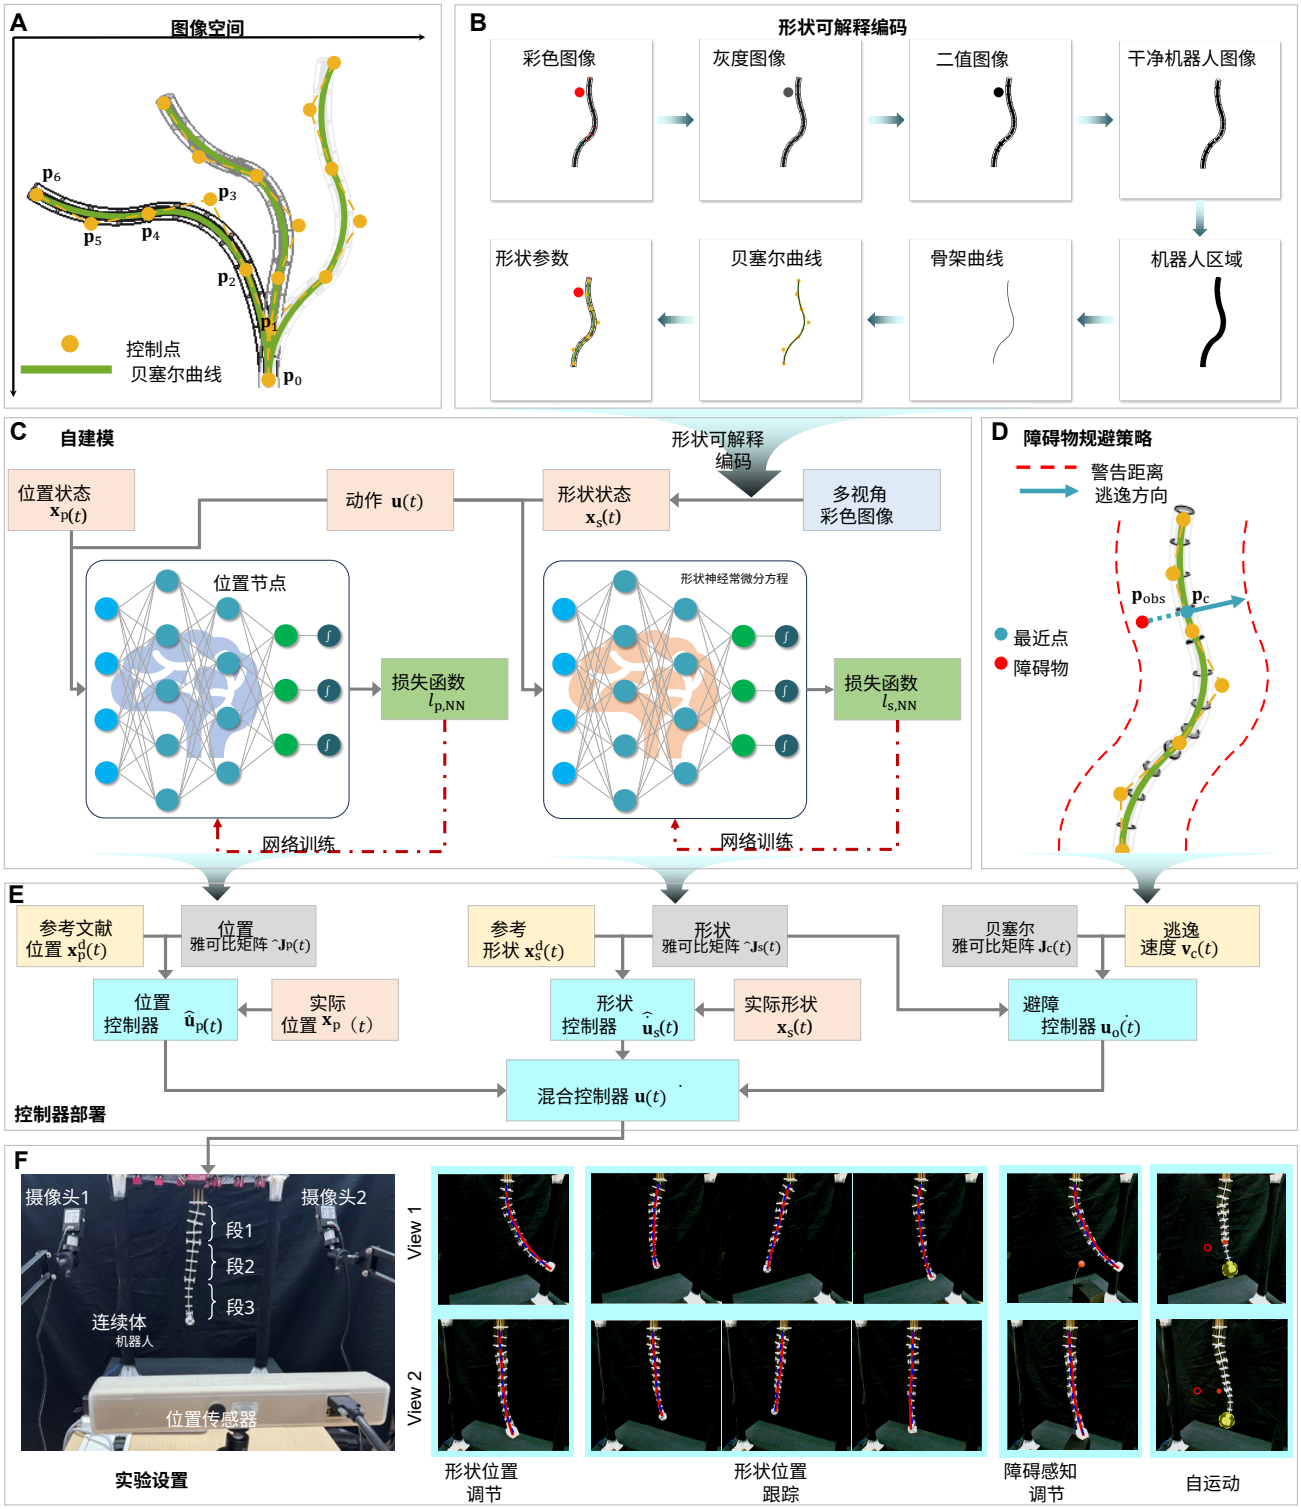


图 2. 面向连续体机器人的形状可解释视觉自建模与几何感知控制框架。(A) 机器人形状采用分段B´ezier曲线表示，该曲线以少量控制点刻画全局形状特征。(B) 首先利用图像处理技术提取机器人区域，并通过形态学操作获得骨架曲线。随后用B´ezier曲线拟合骨架，并将所得控制点用作形状参数，从而实现可解释形状编码。(C) 利用采集的形状、位置和驱动数据训练位置节点和形状神经常微分方程模型，以实现形状-位置自建模。(D) 当环境障碍物进入预定义的警告距离时，避障机制被激活。在机器人本体上距障碍物最近的点施加排斥逃逸速度，并将该局部逃逸速度映射为全局形状变化，从而通过形状控制实现避障。(E) 训练得到的位置节点和形状神经常微分方程分别用于估计位置雅可比矩阵和形状雅可比矩阵。随后通过整合位置控制器、形状控制器和避障控制器构建混合控制器。(F) 所提出的控制框架在三段式连续体机器人上得到验证，能够执行形状-位置调节、形状-位置跟踪、障碍感知调节和自运动任务。

单条二次贝塞尔曲线由三个控制点 $\mathbf{p}_0$,$\mathbf{p}_1$,$\mathbf{p}_2 \in \mathbb{R}^2$ 定义，其参数化形式为

$$\mathbf{b}(s) = (1-s)^2\mathbf{p}_0 + 2(1-s)s\mathbf{p}_1 + s^2\mathbf{p}_2 \tag{3}$$

其中，$\mathbf{b}(s)$ 描述曲线上任意一点的平面坐标，$s=0$ 和 $s=1$ 分别对应起点$\mathbf{p}_0$ 和终点 $\mathbf{p}_2$,。因此，对于一条由 M 段组成的贝塞尔曲线，第 i 段定义为

$$\mathbf{b}_i(s) = (1-s)^2\mathbf{p}_{2i} + 2(1-s)s\mathbf{p}_{2i+1} + s^2\mathbf{p}_{2i+2} \tag{4}$$

其中 $i=0, \cdots, M-1$。

III. 方法

本节详细介绍所提方法，该方法用于连续体机器人的视觉形状动态自建模以及形状位置混合控制。

A. 形状编码

在本研究中，机器人的复杂平面构型采用少量控制点进行参数化。因此，首要挑战是如何将二维图像编码为控制点坐标。如图 2 所示，首先将彩色图像转换为灰度图像，然后进行二值化。为简单起见，我们假设机器人区域与背景的二值化结果互为相反，并且机器人区域对应于最大的连通前景分量。基于这一假设，可以对图像进行筛选，仅保留机器人区域。随后，应用形态学闭运算以获得干净的机器人区域。或者，也可以采用更先进的语义分割算法，直接识别机器人区域并去除这一假设；不过，这并非本研究的重点。接下来，执行细化运算以提取机器人区域的骨架曲线 [39]。这些步骤可以利用 MATLAB 中提供的相关函数轻松实现。

随后，采用最小二乘方法用 B´ézier 曲线拟合骨架曲线，从而获得控制点坐标。骨架可表示为一组有序点 $\mathcal{Q} = \{\mathbf{q}_j \in \mathbb{R}^2 | j = 1, \cdots, N\}$，其中$\mathbf{q}_j$ 表示图像空间中构成骨架的第 j个像素的坐标。我们以三段式二次 B´ézier 曲线为例，说明如何拟合机器人的骨架曲线。该过程可以轻松扩展到段数更少或更多的情况。根据二次 B´ézier 曲线（4）的定义，三段式二次 B´ézier 曲线由七个控制点 $\{\mathbf{p}_j \in \mathbb{R}^2 | j = 0, \cdots, 6\}$完全确定。点集 $\mathcal{Q}$ 被均匀划分为三个有序子集 $\mathcal{Q} = \mathcal{Q}_1 \cup \mathcal{Q}_2 \cup \mathcal{Q}_3$，每个子集对应一段 B´ézier 曲线。端点控制点直接根据数据确定：

$$\mathbf{p}_0 = \mathcal{Q}_1^{(1)}, \mathbf{p}_2 = \mathcal{Q}_1^{(\text{end})}, \mathbf{p}_4 = \mathcal{Q}_2^{(\text{end})}, \mathbf{p}_6 = \mathcal{Q}_3^{(\text{end})} \tag{5}$$

其中，$\mathcal{Q}_1^{(1)}$ 表示第一个子集中的第一个点，$\mathcal{Q}_1^{(\text{end})}$、$\mathcal{Q}_2^{(\text{end})}$ $\mathcal{Q}_3^{(\text{end})}$ 和分别表示三个子集的最后一个点，依次如此。对于每个二次 B´ezier 曲线段，只有中间控制点未知。考虑由式（4）定义的一般曲线段，其中 $\mathbf{p}_{2i}$ 和 $\mathbf{p}^{2i+2}$ 是已知端点，而 $\mathbf{p}^{2i+1}$ 是待估计的中间控制点。给定第 i段对应的骨架点 $\mathcal{Q}_i = \{\mathbf{q}_j^i\}_{j=1}^{n_i}$，其中 $\mathbf{q}_j^i$ 是第 i 段中的第 j个骨架点，n_i 是该段中骨架点的数量，为其分配一个归一化参数

$$s_j = \frac{j-1}{n_i - 1}, j = 1, \cdots, n_i. \tag{6}$$

对 B´ezier 方程进行整理，可得关于 $\mathbf{p}^{2i+1}$ 的线性关系：

$$2(1-s_j)s_j\mathbf{p}_{2i+1} = \underbrace{\mathbf{q}_j^i - (1-s_j)^2\mathbf{p}_{2i} - s_j^2\mathbf{p}_{2i+2}}_{\mathbf{r}_j}. \tag{7}$$

将第 i段的所有骨架点堆叠起来，可得到一个线性最小二乘问题：

$$\min_{\mathbf{p}_{2i+1}} \sum_{j=1}^{n_i} \|2(1-s_j)s_j\mathbf{p}_{2i+1} - \mathbf{r}_j\|^2. \tag{8}$$

通过求解该线性最小二乘问题，可得到最优中间控制点 $\mathbf{p}^{2i+1}$。将该过程分别独立应用于三个分段，可得控制点 $\mathbf{p}_1$,$\mathbf{p}_3$ 和 $\mathbf{p}_5$。

在使用 B´ezier 曲线拟合机器人形状并获得控制点坐标之后，下一个问题是如何定义形状参数向量 $\mathbf{x}_s$。如图 2 所示，对应于机器人基座的起点$\mathbf{p}_0$ 是固定的。因此，只需将剩余控制点视为动态变量。据此，机器人图像的平面形状特征矩阵定义为剩余控制点坐标向量的拼接：

$$\mathbf{S} = [\mathbf{p}_1, \cdots, \mathbf{p}_{2M}] \in \mathbb{R}^{2\times 2M}. \tag{9}$$

由于在本工作中，机器人的三维形状可由 K 个不同视角的平面图像唯一确定，因此机器人的三维形状特征可表示为

$$\bar{\mathbf{S}} = [\mathbf{S}_1, \cdots, \mathbf{S}_K]^\mathsf{T} \in \mathbb{R}^{2MK\times 2} \tag{10}$$

其中$\mathbf{S}_1$ 和$\mathbf{S}_K$ 分别表示从视图 1 和视图 K 获得的机器人平面形状特征矩阵。最后，机器人的三维形状特征向量可表示为

$$\mathbf{x}_\text{s} = \text{vec}(\bar{\mathbf{S}}) \in \mathbb{R}^{4MK} \tag{11}$$

其中 vec(·) 表示将矩阵各列堆叠为单个向量的向量化操作。由于最少两个视角即足以唯一确定机器人的三维形状，本研究中我们设定 $K = 2$。在实际应用中，可以纳入更多视角，以应对某些视角中的遮挡或有限可见性，从而增强所提方法的鲁棒性。

通过上述流程，可以将从不同视角采集的机器人图像编码为形状特征向量，从而促进后续的学习与控制。

B. 数据驱动自建模

接下来，我们将介绍如何以数据驱动的方式学习机器人的形状动力学和位置动力学。本研究主要采用神经常微分方程（NODEs）实现自建模。现有研究表明，与传统的基于神经网络的方法 [11] 或近期开发的基于 Koopman 算子的方法 [14],相比，该框架的数据效率更高 [19],[21], ，所需的训练样本少得多；这对于学习高维形状特征尤其有利。

为对形状动力学(1)进行建模，我们采用时变神经网络（NN）求解以下初值问题：

$$\begin{cases} \dfrac{\partial \mathbf{x}_{\mathrm{s}}(t)}{\partial t} = f_{s,\mathrm{NN}}(\mathbf{x}_{\mathrm{s}}(t), \mathbf{u}(t), t), \ t \geq t_0 \\ \mathbf{x}_{\mathrm{s}}(t_0) = \mathbf{x}_{\mathrm{s},0} \\ \mathbf{u}(t_0) = \mathbf{u}_0 \end{cases} \tag{12}$$

其中 $f_{\mathrm{s,\ NN}}$ 是基于神经网络的 f_{s} 近似，$\mathbf{x}_{\mathrm{s},\ 0}$ 和$\mathbf{u}_0$ 分别是初始时刻 t_0 时$\mathbf{x}_{\mathrm{s}}(t)$ 和 $\mathbf{u}(t)$ 的初始值。已知 $f_{\mathrm{s,\ NN}}$ 和初始值后，未知形状动力学(1)在任意时刻 $t^+ \geq t_0$ 的估计解可计算为

$$\hat{\mathbf{x}}_{\mathrm{s}}(t^+) = \mathbf{x}_{\mathrm{s}}(t_0) + \int_{t_0}^{t^+} f_{\mathrm{s,NN}}(\mathbf{x}_{\mathrm{s}}(t), \mathbf{u}(t), t)\mathrm{d}t \tag{13}$$

该解可使用标准数值常微分方程求解器（ODES）计算，例如龙格-库塔或亚当斯-巴什福斯系列算法 [19]。因此，估计解也记为

$$\hat{\mathbf{x}}_{\mathrm{s}}(t^+) = \mathrm{ODES}\left(f_{\mathrm{s,NN}}, \mathbf{x}_{\mathrm{s}}(t_0), \mathbf{u}(t_0), [t_0, t^+]\right). \tag{14}$$

为训练神经网络 $f_{\mathrm{s,\ NN}}$，损失函数定义为

$$l_{\mathrm{s,NN}} = \|\hat{\mathbf{x}}_{\mathrm{s}}(t^+) - \mathbf{x}_{\mathrm{s}}(t^+)\|. \tag{15}$$

为进行训练，我们需要收集形式为 $\{\mathbf{x}_{\mathrm{S}}(t_0),\ \mathbf{u}(t_0),\ \mathbf{x}_{\mathrm{S}}(t^+)\}$ 的数据对。为简单起见，我们假设控制输入 $\mathbf{u}(t)$ 在一个较短的时间间隔 $[t_0, t^+]$ 内保持恒定。

同样，在任意时间瞬间 $t^+ \geq t_0$ ，未知末端执行器动力学 (2) 的估计解计算如下

$$\hat{\mathbf{x}}_{\mathrm{p}}(t^+) = \mathrm{ODES}\left(f_{\mathrm{p,NN}}, \mathbf{x}_{\mathrm{p}}(t_0), \mathbf{u}(t_0), [t_0, t^+]\right) \tag{16}$$

其中$f_{\mathrm{p,\ NN}}$ 是对 f_{p}的基于神经网络的近似。为训练神经网络 $f_{\mathrm{p,\ NN}}$，损失函数定义如下

$$l_{\mathrm{p,NN}} = \|\hat{\mathbf{x}}_{\mathrm{p}}(t^+) - \mathbf{x}_{\mathrm{p}}(t^+)\|. \tag{17}$$

C. 基于雅可比矩阵的形状-位置混合控制器

接下来，我们将讨论形状-位置混合控制问题，首先从形状控制开始。给定参考形状状态 $\mathbf{x}_{\mathrm{s}}^{\mathrm{d}}(t)$，形状控制误差定义为 $\mathbf{e}_{\mathrm{S}}(t) = \mathbf{x}_{\mathrm{s}}^{\mathrm{d}}(t) - \mathbf{x}_{\mathrm{S}}(t)$。我们要求误差动力学满足

$$\dot{\mathbf{e}}_{\mathrm{s}}(t) + \lambda_{\mathrm{s}}\mathbf{e}_{\mathrm{s}}(t) = \mathbf{0} \tag{18}$$

其中， $\lambda_{\mathrm{s}} > 0$ 是一个常数参数。上述条件意味着误差 $\mathbf{e}_{\mathrm{S}}(t)$ 将指数收敛至零。将误差函数代入式（18）可得

$$\dot{\mathbf{x}}_{\mathrm{s}}^{\mathrm{d}}(t) - \dot{\mathbf{x}}_{\mathrm{s}}(t) + \lambda_{\mathrm{s}}\left(\mathbf{x}_{\mathrm{s}}^{\mathrm{d}}(t) - \mathbf{x}_{\mathrm{s}}(t)\right) = \mathbf{0}. \tag{19}$$

为推导控制器并获得驱动输入的显式表达式，我们还使用基于一阶雅可比矩阵的模型近似形状动力学:

$$\dot{\mathbf{x}}_{\mathrm{s}}(t) = \mathbf{J}_{\mathrm{s}}(t)\dot{\mathbf{u}}(t) \tag{20}$$

其中 $\mathbf{J}_{\mathrm{S}}(t) = \partial \mathbf{x}_{\mathrm{S}}(t)/\partial \mathbf{u}(t)$ 是连续体机器人的形状状态雅可比矩阵。将 (20) 代入 (19) 可得形状控制器:

$$\dot{\mathbf{u}}_{\mathrm{s}}(t) = \mathbf{J}_{\mathrm{s}}^{\dagger}(t)\left(\dot{\mathbf{x}}_{\mathrm{s}}^{\mathrm{d}}(t) + \lambda_{\mathrm{s}}\left(\mathbf{x}_{\mathrm{s}}^{\mathrm{d}}(t) - \mathbf{x}_{\mathrm{s}}(t)\right)\right) \tag{21}$$

其中$\mathbf{J}_{\mathrm{s}}^{\dagger}(t)$ 表示$\mathbf{J}_{\mathrm{S}}(t)$ 的伪逆。

对于末端执行器位置控制问题，给定参考位置状态 $\mathbf{x}_{\mathrm{p}}^{\mathrm{d}}(t)$，位置控制误差定义为 $\mathbf{e}_{\mathrm{P}}(t) = \mathbf{x}_{\mathrm{p}}^{\mathrm{d}}(t) - \mathbf{x}_{\mathrm{P}}(t)$。按照上述形状控制流程，我们可得以下位置控制器

$$\dot{\mathbf{u}}_{\mathrm{p}}(t) = \mathbf{J}_{\mathrm{p}}^{\dagger}(t)\left(\dot{\mathbf{x}}_{\mathrm{p}}^{\mathrm{d}}(t) + \lambda_{\mathrm{p}}\left(\mathbf{x}_{\mathrm{p}}^{\mathrm{d}}(t) - \mathbf{x}_{\mathrm{p}}(t)\right)\right). \tag{22}$$

其中，$\mathbf{J}_{\mathrm{P}}(t)$ 是机器人的位置雅可比矩阵， $\lambda_{\mathrm{p}} > 0$也是一个常数参数。

对于上述形状控制器和位置控制器，参考形状和位置通常由用户指定，而形状状态雅可比矩阵和位置雅可比矩阵由于缺少机器人的解析模型而未知。因此，我们的目标是基于自建模结果估计这些雅可比矩阵。具体而言，根据其定义，形状状态雅可比矩阵第 j列的估计可表示为

$$\hat{\mathbf{J}}_{\mathrm{s}}^{(j)}(t) = \frac{\Delta \mathbf{x}_{\mathrm{s}}}{2\Delta u} = \frac{\mathbf{x}_{\mathrm{s}}^{+} - \mathbf{x}_{\mathrm{s}}^{-}}{2\Delta u} \tag{23}$$

其中， $\Delta u > 0$ 是一个足够小的增量，$\mathbf{x}_{\mathrm{s}}^{+} = \mathrm{ODES}\ (f_{\mathrm{s,\ NN}}, \mathbf{x}_{\mathrm{S}}(t), \mathbf{u}(t) + \mathbf{E}_j\Delta u, [t, t^+])$ 和 $\mathbf{x}_{\mathrm{s}}^{-} = \mathrm{ODES}\ (f_{\mathrm{s,NN}}, \mathbf{x}_{\mathrm{S}}(t), \mathbf{u}(t) - \mathbf{E}_j\Delta u, [t, t^+])$，其中$\mathbf{E}_j$是一个向量，其第 j个元素为1，其余元素均为0。类似地，位置雅可比矩阵第 j列的估计可表示为

$$\hat{\mathbf{J}}_{\mathrm{p}}^{(j)}(t) = \frac{\Delta \mathbf{x}_{\mathrm{p}}}{2\Delta u} = \frac{\mathbf{x}_{\mathrm{p}}^{+} - \mathbf{x}_{\mathrm{p}}^{-}}{2\Delta u} \tag{24}$$

其中 $\mathbf{x}_{\mathrm{p}}^{+} = \mathrm{ODES}(f_{\mathrm{p,NN}}, \mathbf{x}_{\mathrm{P}}(t), \mathbf{u}(t) + \mathbf{E}_j\Delta u, [t, t^+])$ 和 $\mathbf{x}_{\mathrm{p}}^{-} = \mathrm{ODES}\ (f_{\mathrm{p,NN}}, \mathbf{x}_{\mathrm{P}}(t), \mathbf{u}(t) - \mathbf{E}_j\Delta u, [t, t^+])$。因此，分别得到估计的形状雅可比矩阵和位置雅可比矩阵，如下所示

$$\hat{\mathbf{J}}_{\mathrm{s}}(t) = \left[\hat{\mathbf{J}}_{\mathrm{s}}^{(1)}(t), \cdots, \hat{\mathbf{J}}_{\mathrm{s}}^{(m)}(t)\right] \tag{25}$$

and

$$\hat{\mathbf{J}}_{\mathrm{p}}(t) = \left[\hat{\mathbf{J}}_{\mathrm{p}}^{(1)}(t), \cdots, \hat{\mathbf{J}}_{\mathrm{p}}^{(m)}(t)\right]. \tag{26}$$

最后，通过结合式（21）和式（22），我们提出以下形状-位置混合控制器

$$\dot{\mathbf{u}}(t) = \hat{\dot{\mathbf{u}}}_{\mathrm{s}}(t) + \hat{\dot{\mathbf{u}}}_{\mathrm{p}}(t) \tag{27}$$

其中，$\hat{\dot{\mathbf{u}}}_{\mathrm{S}}(t)$ 与 $\hat{\dot{\mathbf{u}}}_{\mathrm{P}}(t)$ 是通过分别用 $\hat{\ }\hat{\mathbf{J}}_{\mathrm{S}}(t)$ 和 $\mathbf{J}_{\mathrm{P}}(t)$ 替换 (21) 中的形状状态雅可比矩阵和 (22) 中的位置雅可比矩阵而得到的。

D. 障碍物规避策略

如图 2 所示，障碍物的位置记为 $\mathbf{p}_{\mathrm{obs}}(t)$。利用拟合的 B´ezier 曲线，我们随后确定曲线上距离障碍物最近的点 $\mathbf{p}_{\mathrm{c}}(t)$。为了计算便利性，将 B´ezier 曲线均匀离散为 K 个点 $\mathcal{O}(t) = \{\mathbf{o}_1(t) \cdots, \mathbf{o}_K(t)\}$，其中这些点的值根据 (4) 计算，从而得到

$$\mathbf{p}_{\mathrm{c}}(t) = \underset{\mathbf{o}_j(t)\in\mathcal{O}(t)}{\arg\min} \ \|\mathbf{o}_j(t) - \mathbf{p}_{\mathrm{obs}}(t)\|_2. \tag{28}$$

当障碍物与最近点之间的距离 $d(t) = \|\mathbf{p}_{\mathrm{c}}(t) - \mathbf{p}_{\mathrm{obs}}(t)\|_2$ 小于预设的警告距离 d_{w} 时，避障功能将被激活。在这种情况下，我们的策略是对最近点施加以下逃逸速度:

$$\mathbf{v}_{\mathrm{c}}(t) = \frac{\mathbf{p}_{\mathrm{c}}(t) - \mathbf{p}_{\mathrm{obs}}(t)}{\|\mathbf{p}_{\mathrm{c}}(t) - \mathbf{p}_{\mathrm{obs}}(t)\|_2} \tag{29}$$

该速度会驱动该点沿远离障碍物的方向运动，直到距离 $d(t)$ 超过警告阈值 d_{w}。为了使最近点沿逃逸方向运动，需要确定机器人形状状态（即控制点）所需的变化率。为此，我们定义与最近点相关联的贝塞尔雅可比矩阵:

$$\mathbf{J}_{\mathrm{c}}(t) = \frac{\partial \mathbf{x}_{\mathrm{s}}(t)}{\partial \mathbf{p}_{\mathrm{c}}(t)} \tag{30}$$

该矩阵可直接根据贝塞尔曲线 (4) 的定义计算。因此，形状状态的逃逸速度可由下式得到:

$$\mathbf{v}_{\mathrm{s}}(t) = \mathbf{J}_{\mathrm{c}}(t)\mathbf{v}_{\mathrm{c}}(t) \tag{31}$$

由此可进一步得到以下逃逸控制器:

$$\dot{\mathbf{u}}_{\mathrm{e}}(t) = \alpha(d_{\mathrm{w}} - d(t))\hat{\mathbf{J}}_{\mathrm{s}}(t)\mathbf{v}_{\mathrm{s}}(t) \tag{32}$$

其中，$\alpha > 0$ 是一个用于平衡避障与形状位置控制的参数。

在上述公式中，仅考虑了来自单一视图的逃逸速度。由于本研究针对三维形状控制，我们接下来提出同时考虑两个不同视图逃逸控制器的避障控制器:

$$\dot{\mathbf{u}}_{\mathrm{o}}(t) = \begin{cases} \dot{\mathbf{u}}_{\mathrm{e}}^{(1)}(t), & \text{if } d_1(t) > d_2(t) \\ \dot{\mathbf{u}}_{\mathrm{e}}^{(2)}(t), & \text{else} \end{cases} \tag{33}$$

其中 $\dot{\mathbf{u}}_{\mathrm{e}}^{(1)}(t)$ 表示来自视图 1 的逃逸控制器，$d_1(t)$ 是障碍物与视图 1 中最近点之间的距离，$\dot{\mathbf{u}}_{\mathrm{e}}^{(2)}(t)$ 是来自视图 2 的逃逸控制器，$d_2(t)$ 是障碍物与视图 2 中最近点之间的距离。

最后，整合形状位置控制与避障的总体控制器如下:

$$\dot{\mathbf{u}}(t) = \begin{cases} \hat{\dot{\mathbf{u}}}_{\mathrm{s}}(t) + \hat{\dot{\mathbf{u}}}_{\mathrm{p}}(t), & \text{if } d_1(t) > d_{\mathrm{w}} \text{ or } d_2(t) > d_{\mathrm{w}} \\ \dot{\mathbf{u}}_{\mathrm{o}}(t) + \hat{\dot{\mathbf{u}}}_{\mathrm{p}}(t), & \text{else} \end{cases}. \tag{34}$$

也可以直接将两个视角中的逃逸控制器相加，构造避障控制器。然而，这种策略可能会减慢主要形状位置控制任务的执行速度，因为控制器必须确保两个视角中的机器人都远离障碍物后，才能恢复主要任务。相比之下，避障控制器（33）只需确保一个视角中的机器人逃逸至警告距离之外，即可继续执行主要任务。

IV. 结果

在本节中，我们介绍用于方法评估的连续体机器人平台。随后，我们在四项不同任务中评估所提方法的性能: 形状-位置调节、形状-位置跟踪、存在障碍物时的形状-位置调节以及机器人自运动，并将其与一种代表性的基于视觉的数据驱动控制方法进行比较。

A. 实验平台

本工作所使用的实验验证平台如图 2(F) 所示。它由一台绳驱动、三段式、定长骨干的连续体机器人组成，总长度为 0.3 m，其中每段的弯曲由四个伺服电机驱动。由于机器人的骨干长度固定，每段内两根相对的驱动缆绳相互耦合，即当一根缆绳被拉紧时，另一根被释放。所提出的控制器在 MATLAB 中实现，控制指令通过 Arduino Mega2560 开发板传输至电机。

采用两个来自不同视角的单目相机（每个仅需 11 美元）采集机器人的图像，图像分辨率设置为 256×256。为测量末端执行器位置，使用 MicronTracker H3-60 系统跟踪安装在机器人尖端的标记。控制机器人探索其工作空间，采集 1000 个数据样本，用于训练 NODE模型。

B. 任务 *1*：形状-位置调节

我们首先考虑形状-位置调节任务，在该任务中，使用所提出的形状-位置控制器(27)驱动机器人达到指定的形状状态和末端执行器位置。如图 3(A)所示，红色实线曲线表示参考形状，而蓝色虚线曲线表示机器人在不同时间点的实际形状（即 B´ezier 曲线拟合的结果）。来自两个不同视角（视图 1 和视图 2）的参考形状唯一确定了机器人的三维形状。可以观察到，在两个视角下，机器人的实际形状均平滑地收敛至参考形状。

如图 3(B)所示，末端执行器同时从初始位置移动到参考位置。图 3(C)和图 3(D)显示，形状状态误差和末端执行器位置误差均在前 6 s 内收敛至接近零。任务结束时（即 10 s 时），最大形状误差为 4 像素（占图像分辨率的 1.56%），最大位置误差为 0.003 m（占机器人总长度的 1%）。

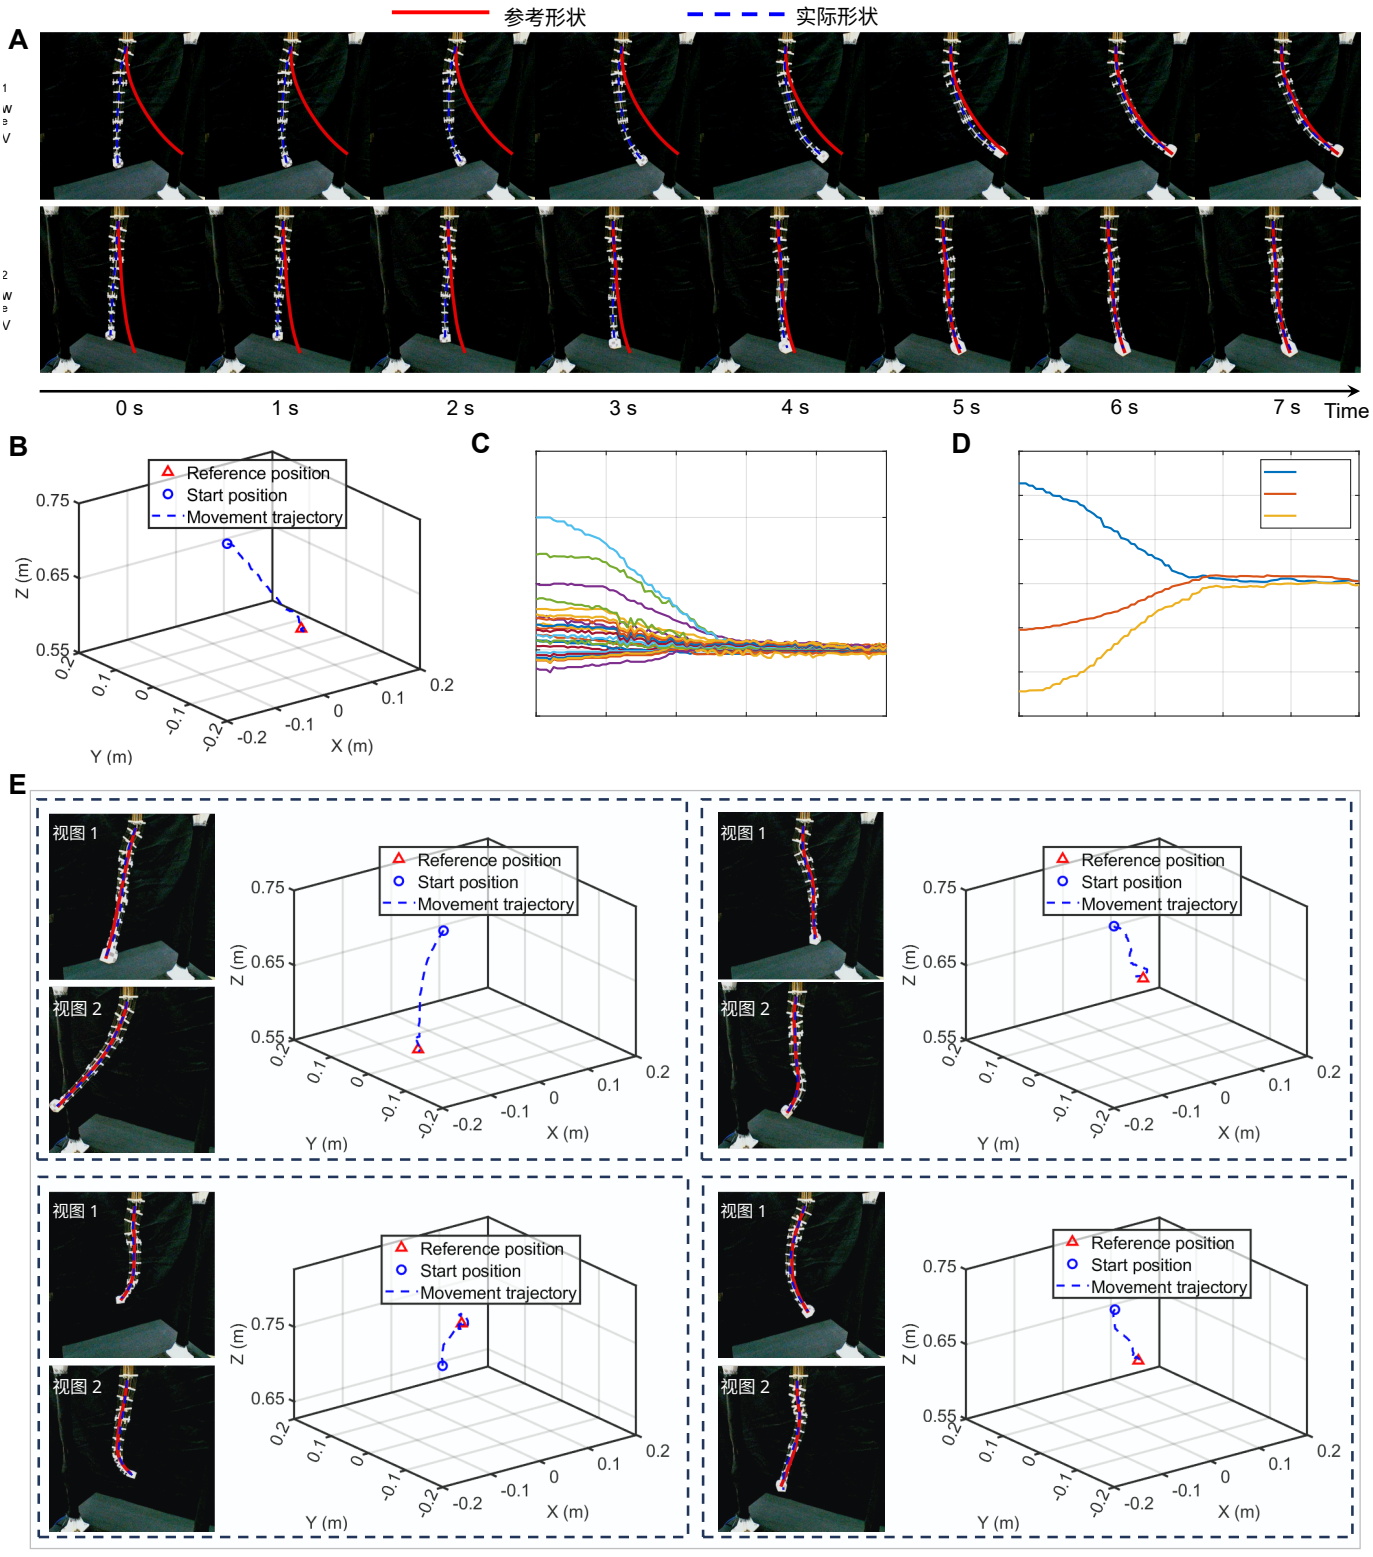


图 3. 使用所提方法对连续体机器人进行形状-位置调节的实验结果。(A) 所提方法将机器人调节至参考形状和末端执行器位置的过程中，来自两个不同视角的实验快照。(B) 机器人末端执行器从初始位置移动到参考位置。(C) 形状状态调节误差收敛至零。(D) 末端执行器位置调节误差收敛至零。(E) 四项不同的形状-位置调节任务均成功完成。

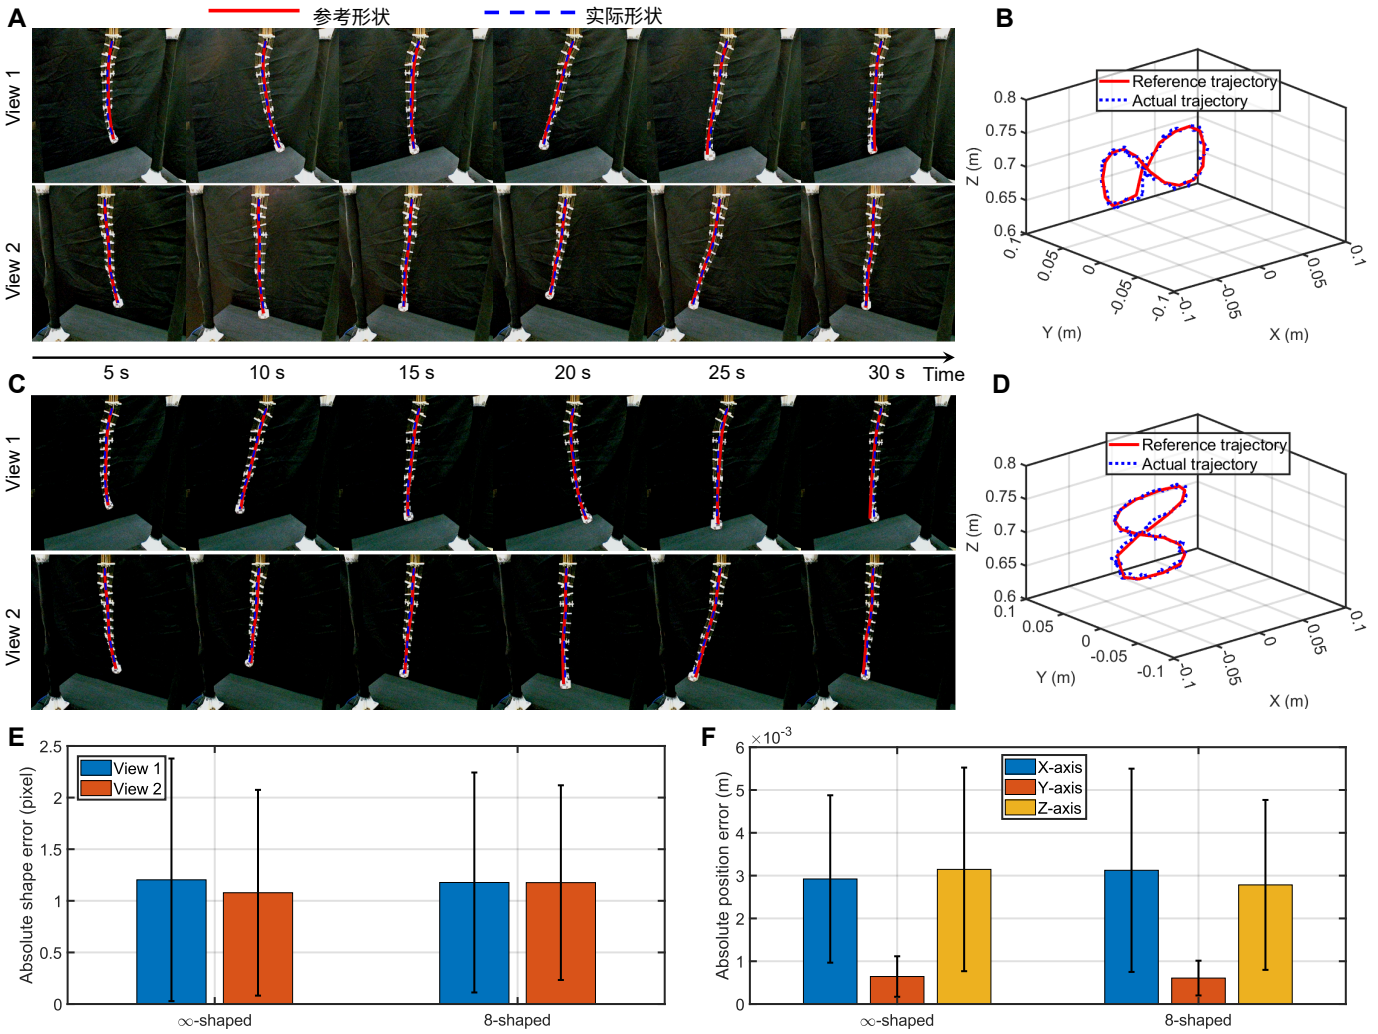


图4. 使用所提方法进行连续体机器人形状-位置同时跟踪控制的实验结果。(A)跟踪 ∞形末端执行器轨迹过程中两个不同视角下的实验快照。(B)跟踪∞形轨迹过程中机器人末端执行器轨迹的轮廓。(C)跟踪8字形末端执行器轨迹过程中两个不同视角下的实验快照。(D)跟踪8字形轨迹过程中机器人末端执行器轨迹的轮廓。(E)不同视角下的形状跟踪误差分布。(F)沿不同坐标轴的跟踪误差分布。

为进一步验证所提方法，在机器人任务空间内随机选取了四组参考形状和位置，如图 3(E) 所示。在所有情况下，所提方法均能在 10 秒内成功驱动机器人到达参考形状和位置。

在本研究中，形状控制器和位置控制器采用直接相加的方式。对于需要考虑任务优先级的情形（例如位置控制具有较高优先级时），可利用雅可比矩阵 [40] 的零空间设计具有任务优先级的分层混合控制器。这类扩展不在本文讨论范围内。

C. 任务 *2*：形状-位置跟踪

接下来，我们考虑形状-位置跟踪任务：机器人需要使用所提出的形状位置控制器（27），跟踪随时间变化的参考形状和末端执行器位置。我们评估了两组形状-位置跟踪任务。在第一组中，末端执行器沿着 ∞-形轨迹运动；在第二组中，它沿着 8 形轨迹运动。每项任务的总时长为 30 秒。

如图 4(A) 所示，对于 ∞ 形轨迹，在整个任务过程中，从两个不同视角观察到的实际机器人形状始终与参考形状保持一致。如图 4(B) 所示，实际末端执行器轨迹紧密跟随参考轨迹。对于 8 形轨迹跟踪任务，也获得了类似结果，如图 4(C) 和 4(D) 所示。

两项任务的形状跟踪误差和末端执行器位置误差的统计结果如图 4(E) 和图 4(F) 所示。可以观察到，在不同任务和视角下，形状跟踪误差的分布高度一致，没有显著差异。最大形状误差不超过 2.5 像素（即小于图像分辨率的 1%）。对于两项任务，末端执行器位置误差的分布也相似。然而，不同坐标轴之间存在明显差异。这主要是因为 Y轴的

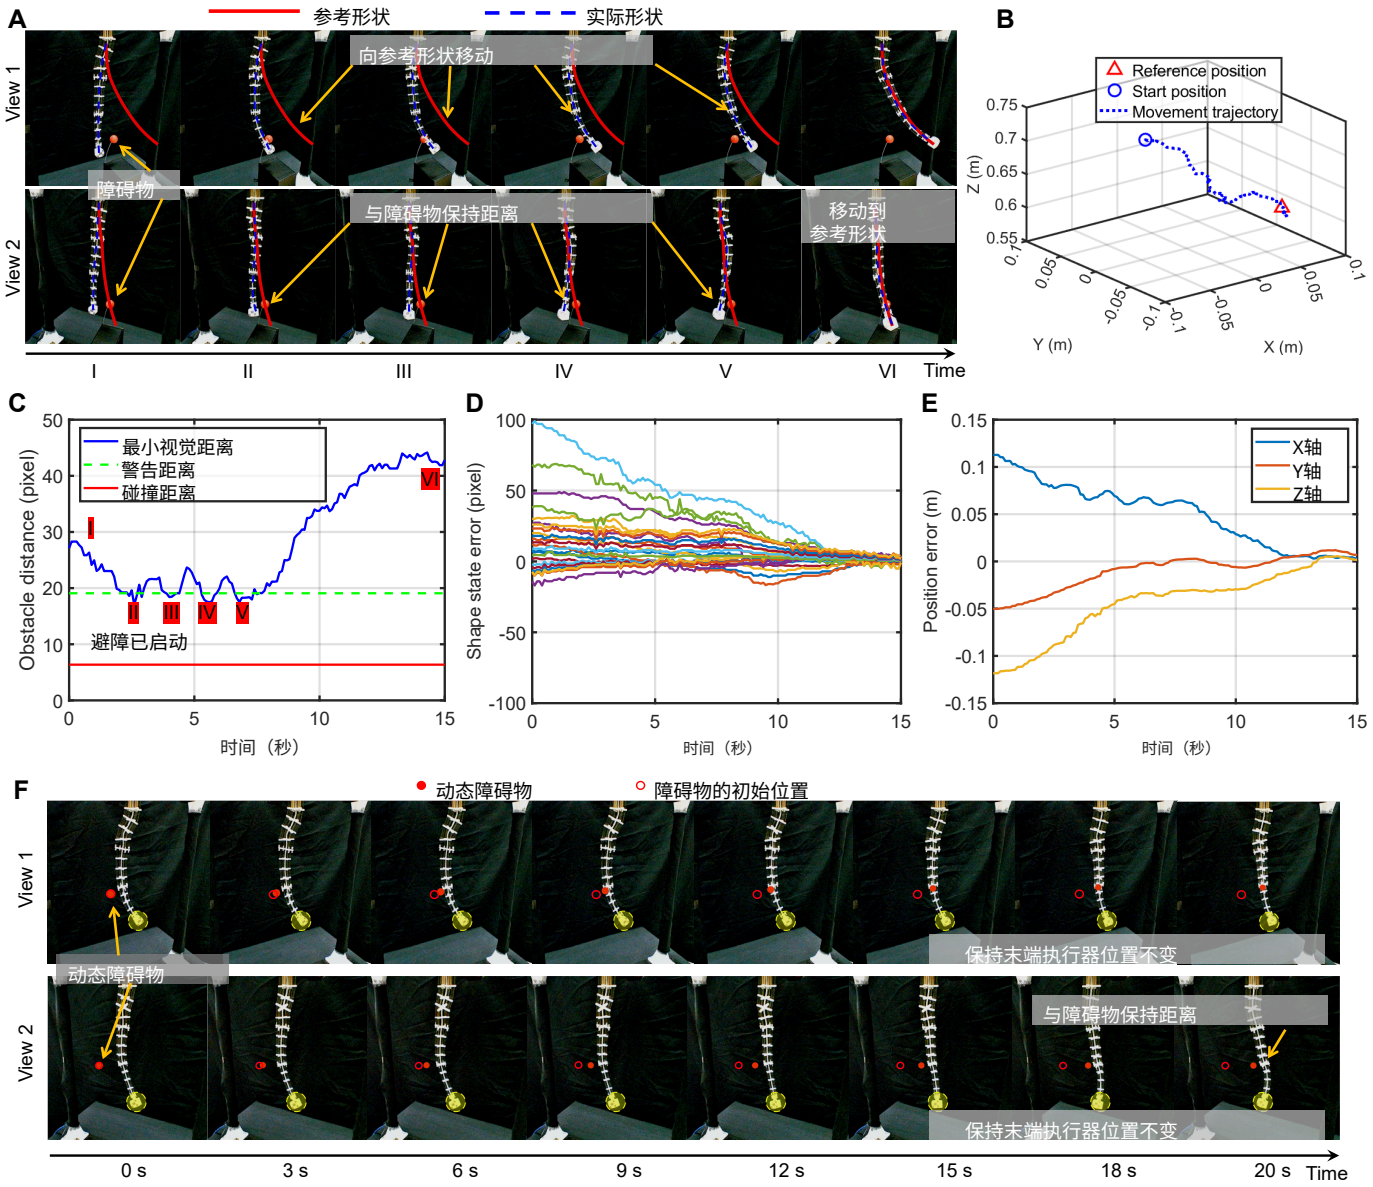


图5. 所提方法在障碍物环境中实现的连续体机器人形状位置控制实验结果。(A)障碍物环境下形状位置调节过程中的两个不同视角的实验快照。(B)存在障碍物时，形状位置调节任务中机器人末端执行器位置的变化。(C)机器人本体与障碍物之间的最小视觉距离。(D)障碍物环境下形状位置调节任务中的形状状态调节误差。(E)障碍物环境下形状位置调节任务中的末端执行器位置调节误差。(F)机器人通过形状控制避开动态障碍物，同时保持末端执行器位置不变。

坐标系与机器人垂直向下的方向对齐。由于机器人的骨干长度固定，其沿该轴的运动范围相对有限，因此跟踪误差比其他两个轴更小。尽管如此，沿其他两个轴的位置跟踪误差平均约为 0.003 m（机器人长度的 1%），最大误差不超过 0.006 m（机器人长度的 2%）。

D. 任务 *3*：障碍物感知形状-位置调节

所提出的框架不仅能够使机器人达到期望的全身形状和末端执行器位置，还能通过形状控制实现其他功能。本文以避障为例，介绍相应的策略。

我们评估控制器 (34) 在存在环境障碍物时执行形状-位置调节任务的性能。具体而言，控制器需要使机器人趋向参考形状和末端执行器位置，同时利用形状控制来避开障碍物。障碍物规避策略的基本原理是：只要机器人本体在至少一个视图（或两个视图）中不与障碍物发生碰撞，就可以确保机器人在三维空间中不会与障碍物碰撞。

图5(A)和图5(B)分别展示了机器人形状和末端执行器位置在任务执行过程中

的变化。图5(C)显示了机器人与障碍物之间的最小视觉距离。可以观察到，在阶段I-II期间，视觉距离始终大于警告距离，因此避障功能未被激活。机器人因此向参考形状和末端执行器位置移动。在时刻II、III、IV和V附近，最小视觉距离降至警告距离以下，从而触发避障机制。在阶段II-V期间，视图 1中的机器人继续正常接近参考形状，而在视图 2中，避障控制器施加方向相反的逃逸速度，确保机器人本体与障碍物保持安全距离。

在阶段V-VI中，由于视图 1中的机器人本体与障碍物相距足够远（即超出警告距离），视图 2中的机器人恢复向参考形状移动。最终，机器人成功达到参考形状和末端执行器位置，同时有效避开障碍物。如图5(D)和图5(E)所示，形状状态误差和末端执行器位置误差均收敛至零。

E. 任务*4*：自运动的形状-位置控制

最后一项任务是机器人自运动，即使用所提出的控制器(34)调整机器人的形状，同时保持末端执行器位置固定。如图5(F)所示，考虑一个正向机器人本体靠近的动态障碍物。在两个视角中，红色障碍物均从其初始位置开始向右移动。可以观察到，随着障碍物靠近机器人，避障功能被激活，机器人逐渐调整其形状。

尽管在视图 1 中观察到障碍物与机器人重叠，但视图 2 中的机器人本体始终与障碍物保持安全距离，这表明三维空间中没有发生碰撞。更重要的是，在两个视图中，机器人末端执行器始终位于黄色区域内，且没有明显偏离。这些结果表明，机器人成功完成了自运动任务。

F. 比较

最后，我们将所提方法与Almanzor等人提出的深度视觉逆运动学（DVIK）方法进行定量比较 [22], ，因为这两种方法都是数据驱动的，并且基于视觉图像。由于DVIK方法仅处理形状控制，因此我们将其与本文提出的形状控制器进行比较。两种方法均用于驱动机器人达到相同的参考形状。

由于 DVIK 方法执行的是平面二维形状控制，因此仅使用来自视图 1 的图像进行控制，而视图 2 的结果仅用于对比分析。如图6(A)所示，所提方法能够使从两个视角观察到的机器人形状均收敛至参考形状。尽管 DVIK 方法能够驱动机器人在视图 1 中达到参考形状，但它本质上是一种单视图控制方法。因此，在视图 2 中可以观察到实际形状与参考形状之间明显的差异。在最坏情况下，由于平面观测与三维机器人形状之间的映射并不唯一，单视图控制可能会导致另一个视图中出现较大误差。

图 6(B) 和 6(C) 展示了两种方法的形状状态误差，结果表明，与DVIK方法相比，所提方法的稳态误差显著更小。为进一步确保比较的可靠性，我们随机选取了12种不同的参考形状状态来评估这两种方法，统计结果汇总于图 6(D)。可以看出，所提方法在两个视角下的误差分布相近。相比之下，DVIK方法在视图 1 中的误差大于所提方法；更重要的是，其在视图 2 中的误差显著高于视图 1 中的误差。

如图 6(E) 所示，我们还评估了两种方法在存在环境障碍物时的性能。正如预期，所提方法能够调节机器人，使其达到参考形状，同时避开环境中的障碍物。相比之下，DVIK 方法会导致机器人在形状调节过程中与障碍物发生碰撞，因为该方法是为无障碍物环境设计的，无法利用形状控制主动避障。

选择 DVIK 方法进行定量比较的原因如下。首先，基于模型的方法需要明确的物理知识来构建解析模型，而所提方法不依赖任何先验假设或物理建模。其次，基于离散点表示的形状控制方法，其硬件配置和传感要求通常与我们的方法存在显著差异。这些方法往往需要沿机器人本体分布大量标记或传感器来实现形状控制，而我们的方法仅凭视觉观测即可实现形状控制，无需此类设备。因此，无法与这些方法进行严格且公平的比较。相比之下，DVIK 方法与我们的实验设置十分接近。它是一种数据驱动方法，不依赖物理模型或本体安装标记点，仅利用机器人的视觉图像实现控制。尽管近期提出的一种通用控制器也能够实现基于图像的形状控制 [38],，但其主要侧重于提升在不同任务和扰动下的适应性。与 DVIK 类似，该通用控制器也基于单视图视觉输入，且无法提供机器人形状的可解释表示。相比之下，所提方法明确强调形状可解释性，从而能够有效利用形状控制实现更复杂的行为，例如避障和自运动。

V. 讨论与结论

本文提出了一种面向连续体机器人的新型形状可解释视觉自建模框架，无需解析运动学或动力学模型即可实现形状-位置混合控制。该方法利用基于 B´ezier 的形状参数化，从多视图平面图像中编码机器人形状，并通过神经常微分方程学习形状和位置动力学，从而实现

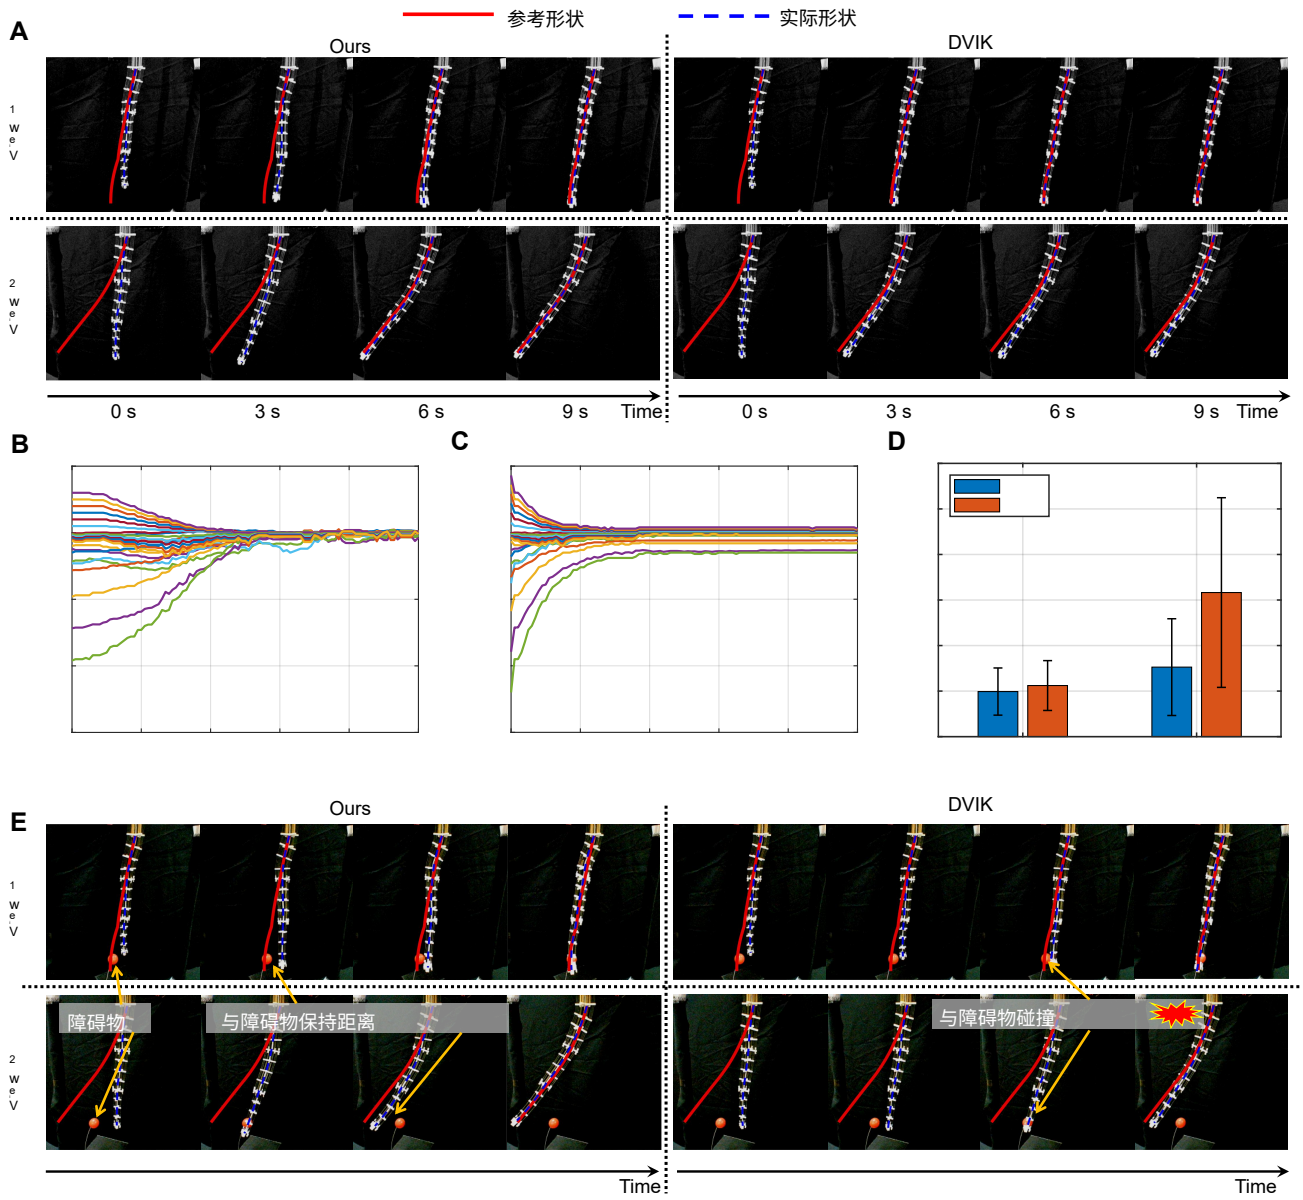


图 6. 形状调节的比较结果。(A) 机器人的快照。我们的方法确保机器人在两个不同视图中都能调节至参考形状；而 DVIK 方法 [22], 作为一种平面形状控制方法，只能保证机器人在视图 1 中达到参考形状。在视图 2 中，使用 DVIK 方法时，参考形状与实际机器人形状之间存在明显差异。(B) 我们方法的形状状态误差。(C) DVIK 方法的形状状态误差。(D) 12 个不同形状调节任务的统计误差结果。所提方法在两个视图中获得的误差分布几乎相同，且这些误差始终小于 DVIK 方法在视图 1 中的误差。此外，由于 DVIK 方法执行的是平面形状调节，其在视图 2 中的误差显著大于视图 1 中的误差。(E) 存在障碍物的环境中的形状调节结果。所提方法能够在形状调节过程中同时利用可解释的形状状态信息来改进控制器并实现避障，而 DVIK 方法无法避开障碍物，导致机器人与障碍物发生碰撞。

在单一数据驱动框架中实现统一建模、几何感知控制和避障。我们在一台绳驱动三段式连续体机器人上通过实验验证了该框架的有效性。结果表明，该方法能够准确地进行形状-位置调节与跟踪，并成功避开障碍物。

与现有连续体机器人建模与控制方法相比，所提出的方法具有若干显著优势。首先，与基于模型的方法相比，所提出的框架不依赖解析运动学或动力学模型。连续体机器人是特其特点是非线性强、冗余度高且参数不确定性显著，这使得精确推导模型和实时计算极具挑战性。通过利用基于视觉的自建模和数据驱动学习，所提方法无需承担这些建模负担，同时仍能实现精确的形状位置控制，从而提高实际应用性。其次，与基于离散点测量的数据驱动形状控制方法相比（例如依赖附着在机器人本体上的多个标记的方法），所提方法不需要密集物理传感或大量标注。所提方法并非

跟踪大量离散点，而是利用直接从视觉观测中提取的 B´ezier 曲线对机器人形状进行编码，从而获得紧凑而富有表现力的形状表示。这显著降低了系统复杂度、传感要求和准备工作量，同时保留了形状控制所需的充足几何信息。第三，与端到端视觉数据驱动控制方法相比，所提方法具有多项根本优势。端到端方法通常采用隐式潜在表示，缺乏明确的几何语义，因此限制了其推理机器人与环境交互的能力。相比之下，所提方法实现了：（i）通过多视图形状编码，将形状维度从平面空间扩展至三维空间；（ii）构建明确、具备几何感知能力且面向控制的形状表示，从而能够直接感知机器人与环境的距离；（iii）构建统一的混合形状位置控制框架，使形状调节能够应用于避障和自运动等高级行为。这些特性使所提方法更加灵活、易于解释，也更适用于安全关键任务。

所提方法优于基线方法，源于其嵌入数据驱动控制框架中的显式、可解释形状表示。不同于端到端视觉控制器（其中机器人形状和环境几何仍是潜变量），所提方法利用低维连续曲线参数重建机器人形状，使机器人与周围障碍物之间的几何关系变得直接可观测。这种显式可观测性使避障和自运动能够自然地融入控制律。此外，通过联合利用多个视图，所提方法解决了单视图形状控制固有的歧义，并确保不同视图之间的一致性。相比之下，现有方法通常受到不唯一的视觉到形状映射的影响，或依赖缺乏连续性和可扩展性的离散标记表示。

所提出的基于视觉且形状可解释的控制框架，为连续体机器人控制提出了一种连接数据驱动学习与几何感知建模的新范式。通过使用从视觉观测中提取的低维、具有物理意义的参数显式表示机器人形状，所提方法能够实现超越传统目标到达任务的环境感知控制行为，例如避障和自运动。这使机器人形状从端到端学习中的潜变量，提升为与任务相关且具有感知基础的控制基元。因此，该框架为连续体机器人与复杂环境之间的安全、灵活交互提供了通用且可扩展的基础，并有望推广至其他软体或高度可变形的机器人系统。

尽管所提出的框架具有诸多优势，但仍存在一些局限性，也为未来研究指明了方向。首先，当前方法依赖准确的平面图像分割和骨架提取，因此可能容易受到光照、严重遮挡或背景复杂度的影响。集成先进或自适应的视觉分割技术，或许能够提升其在非结构化环境中的鲁棒性。其次，基于贝塞尔曲线的形状表示虽然简洁且面向控制，但会施加平滑性约束，可能无法充分捕捉局部高曲率变形。未来工作可以探索自适应或分段参数化表示，以更好地描述复杂形状。第三，尽管采用多视图平面图像来唯一确定三维形状，该框架并未明确重建完整的三维构型，因此限制了其在需要精确三维感知的应用中的使用。将显式的三维重建融入该方法，从视觉线索中恢复三维结构，是一个值得探索的方向。最后，当前的形状位置控制方案将形状任务和位置任务视为同等优先级，这对于具有分层任务需求的场景而言可能并非最优。引入任务优先级框架，例如零空间投影或加权优化，能够实现更灵活、安全的任务执行。解决这些局限性将进一步提升连续体机器人在复杂动态环境中的自主性、适应性和适用性。

总而言之，本研究提出了一种基于视觉、形状可解释的连续体机器人建模与控制框架。该框架为构建更加自主、适应性更强且安全的连续体机器人系统奠定了基础，并为在软体和高度可变形机器人领域中整合视觉感知与几何感知控制提供了一种可推广的范式。

参考文献

[1] Z. Xie, F. Yuan, J. Liu, L. Tian, B. Chen, Z. Fu, S. Mao, T. Jin, Y. Wang, X. He, G. Wang, Y. Mo, X. Ding, Y. Zhang, C. Laschi, and L. Wen, 《受章鱼启发的传感化软臂，用于环境交互》，*Science Robotics*，第8卷，第84期，页码 eadh7852，2023年。[2] G. Qin, A. Ji, Y. Cheng, W. Zhao, H. Pan, S. Shi, and Y. Song, 《受蛇启发的层驱动连续体机器人》，*Soft Robotics*，第9卷，第4期，第788–797页，2022年。[3] K. Ma, X. Chen, J. Zhang, Z. Xie, J. Wu, and J. Zhang, 《受象鼻物理智能启发：具有预编程局部刚度的仿生软体机器人》，*IEEE*机器人与自动化快报，第8卷，第5期，第2898–2905页，2023年。[4] J. Wang, C. Hu, G. Ning, L. Ma, X. Zhang, and H. Liao, 《用于微创手术的新型微型弹簧式连续体操作臂：设计与评估》，*IEEE/ASME*机电一体化汇刊，第28卷，第5期，第2716–2727页，2023年。[5] T. Wen, J. Hu, J. Zhang, X. Li, S. Kang, and N. Zhang, 《用于救援的软体机器人设计、性能分析与实验》，机构与机器人学期刊，第16卷，第7期，页码 071011，2023年。[6] Z. Yang, L. Yang, Y. Sun, and X. Chen, 《新型接触辅助连续体机器人系统：设计、建模与验证》，*IEEE*机器人学汇刊，第40卷，第3024–3043页，2024年。[7] J. Chen, Q. Qiu, and J. Ji, 《采用腱驱动连续体机器人的软硬混合机器人辅助喂食系统》，*IEEE*机器人与自动化快报，第10卷，第12期，第13217–13224页，2025年。[8] K. Qiu, H. Zhang, J. Zhang, R. Xiong, H. Lu, and Y. Wang, 《腱驱动连续体机器人的驱动空间最优运动学路径跟踪框架：理论、算法与验证》，国际机器人研究期刊，第44卷，第6期，第1006–1034页，2025年。[9] F. Li, H. Yang, G. Gu, Y. Wang, and H. Peng, 《绳驱张拉整体连续体机器人的位置与姿态跟踪控制》，*IEEE*机器人学汇刊，第41卷，第1791–1811页，2025年。[10] S. Lilge and J. Burgner-Kahrs, 《腱驱动并联连续体机器人的静运动学建模》，*IEEE*机器人学汇刊，第39卷，第1563–1579页，2023年。[11] T. G. Thuruthel, E. Falotico, M. Manti, A. Pratesi, M. Cianchetti, and C. Laschi, 《在非结构化环境中为连续体操作器学习闭环运动学控制器》，*Soft Robotics*，第4卷，第285–296页，2017年。

[12] M. C. Yip and D. B. Camarillo, 《受限环境中连续体操作器的无模型反馈控制》，IEEE机器人学汇刊，第30卷，第880–889页，2014年。[13] N. Tan, P. Yu, X. Wang, and K. Huang, 《异构连续体机器人的行为预定义自适应控制》，国际机器人研究期刊，第44卷，第65–95页，2025年。[14] D. Bruder, X. Fu, R. B. Gillespie, C. D. Remy, and R. Vasudevan, 《基于Koopman算子理论的软体机器人数据驱动控制》，IEEE机器人学汇刊，第37卷，第948–961页，2021年。[15] B. Thamo, D. Hanley, K. Dhaliwal, and M. Khadem, 《通过动态模态分解在未知环境中对同心管机器人进行数据驱动转向》，IEEE机器人与自动化快报，第8卷，第856–863页，2023年。[16] J. Wang, B. Xu, J. Lai, Y. Wang, C. Hu, H. Li, and A. Song, 《用于软体驱动器数据驱动建模与控制的改进型Koopman-MPC框架》，IEEE机器人与自动化快报，第8卷，第616–623页，2023年。[17] D. A. Haggerty, M. J. Banks, E. Kamenar, A. B. Cao, P. C. Curtis, I. Mezi´c, and E. W. Hawkes, 《具有惯性动力学的软体机器人控制》，Science Robotics，页码eadd6864，2023年。[18] P. Yu and N. Tan, 《论具有可证明鲁棒性、效率和泛化能力的连续体机器人基于学习的控制》，国际机器人研究期刊，第1–20页，2025年。[19] M. Kasaei, K. K. Babarahmati, Z. Li, and M. Khadem, 《可伸展软体操作器的数据高效非参数建模与控制》，载于 IEEE国际机器人与自动化会议，第2641–2647页，IEEE，2023年。[20] M. Kasaei, F. Alambeigi, and M. Khadem, 《用于连续体机器人形状估计学习与形状感知全身控制策略的协同框架》，载于 IEEE国际机器人与自动化会议，第13994–14000页，2025年。[21] P. Yu, Z. Liang, and N. Tan, 《连续体机器人的数据高效预设时间稳定控制》，IEEE机器人学汇刊，第42卷，第382–399页，2026年。[22] E. Almanzor, F. Ye, J. Shi, T. G. Thuruthel, H. A. Wurdemann, and F. Iida, 《利用深度视觉逆运动学模型对软体连续体机器人进行静态形状控制》，IEEE机器人学汇刊，第39卷，第2973–2988页，2023年。[23] P. E. Dupont, N. Simaan, H. Choset, and C. Rucker, 《用于医疗干预的连续体机器人》，IEEE会刊，第110卷，第7期，第847–870页，2022年。[24] A. Yeshmukhametov, K. Koganezawa, Y. Yamamoto, Z. Buribayev, Z. Mukhtar, and Y. Amirgaliyev, 《用于采摘樱桃番茄的连续体机械臂与夹持器的开发》，Applied Sciences，第12卷，第14期，页码6922，2022年。[25] K. Long, H. Parwana, G. Fainekos, B. Hoxha, H. Okamoto, and N. Atanasov, 《用于连续体机器人控制的神经构型距离函数》，载于2025年IEEE/RSJ智能机器人与系统国际会议（IROS），第358–364页，2025年。[26] S. Mbakop, G. Tagne, M. H. Frouin, M. Achille, and R. Merzouki, 《利用参数曲线对软体连续体手指机器人进行基于逆动力学模型的形状控制》，IEEE机器人与自动化快报，第6卷，第8053–8060页，2021年。[27] S. Mbakop, G. Tagne, T. Chevillon, S. V. Drakunov, and R. Mer-zouki, 《用于软体连续体操作器形状控制的PH-Gauss-Lobatto降阶模型》，IEEE机器人学汇刊，第40卷，第2641–2655页，2024年。[28] A. Gandhi, S. S. Chiang, C. D. Onal, and B. Calli, 《利用基于回旋线的视觉伺服控制变长度连续体机器人的形状》，IEEE智能机器人与系统国际会议，第6379–6386页，2023年。[29] B. Ouyang, Y. Liu, H. Y. Tam, and D. Sun, 《多段连续体机器人的交互式控制系统设计》，IEEE/ASME机电一体化汇刊，第23卷，第2379–2389页，2018年。[30] J. Lai, K. Huang, B. Lu, and H. K. Chu, 《迈向双向双段软体连续体操作器的基于视觉的自适应构型》，IEEE/ASME先进智能机电国际会议，第2020年7月卷，第934–939页，2020年。[31] A. Singh, J. Sun, and J. Zhao, 《利用Koopman算子控制软体机器人的形状》，载于美国控制会议，第153–158页，IEEE，2023年。[32] J. Hu and J. Zhang, 《利用深度视觉控制双段软体机器人的形状》，国际先进计算机科学与应用杂志，第14卷，第37–44页，2023年。[33] Y. Shen, J. Zhang, Y. Yuan, F. Zhang, and H. Ding, 《基于空间特征的软体操作器在线学习形状控制反馈，”*IEEE*机器人与自动化快报，第9卷，第10081–10088页，2024年。[34] Y. Cao、M. Cai、B. Sun、Z. Qi、J. Xue、Y. Jiang、B. Hao、J. Zhu、X. Liu、C. Yang和L. Zhang，“采用模块化轴向磁化的磁性连续体机器人：设计、建模、优化与控制”，*IEEE*机器人学汇刊，第41卷，第1513–1532页，2025年。[35] Z. Chen、Q. Guan、J. Hughes、A. Menciassi和C. Stefanini，“一种适用于模块化软体机械臂的多功能神经网络构型空间规划与控制策略”，*IEEE*机器人学汇刊，第41卷，第4269–4282页，2025年。[36] F. Xu、Y. Zhang、J. Sun和H. Wang，“利用B´ézier曲线特征的软体机器人操作臂自适应视觉伺服形状控制”，*IEEE/ASME*机电一体化汇刊，第28卷，第945–955页，2023年。[37] R. M. Monteiro、J. Shi、H. Wurdemann、F. Iida和T. G. Thuruthel，“软体机器人系统的视觉动态自我建模”，机器人学与人工智能前沿，第11卷，第1–14页，2024年。[38] Z. Tang、L. Tian、W. Xin、Q. Wang、D. Rus和C. Laschi，“受神经元结构与可塑性突触启发的通用软体机器人控制器，可适应不同的机械臂、任务和扰动”，《科学进展》，第12卷，第2期，文章编号eaea3712，2026年。[39] L. Lam、S.-W. Lee和C. Suen，“细化方法——综合综述”，*IEEE*模式分析与机器智能汇刊，第14卷，第9期，第869–885页，1992年。[40] Y. Yuan和W. Sun，“面向分层最优控制及任务优先级转换的连续整形优先雅可比矩阵方法”，*IEEE*机器人学汇刊，第41卷，第1639–1656页，2025年。