

# 基于集合贝叶斯交互基元的机械臂自主肝脏超声扫查

马骥<sup>1</sup> 赵悦<sup>1,2</sup> 刘壮<sup>1</sup> 胡悦<sup>3</sup> 刘健行<sup>1</sup> 沈毅<sup>1</sup>

**摘要** 针对人体肝脏结构的超声扫查需求, 提出一种基于集合贝叶斯交互基元的全自主机械臂扫查方法, 并搭建了相应的实验系统. 该方法将扫查流程划分为顺序执行的“初始定位”与“模仿学习”两个阶段. 在初始定位阶段, 系统通过 RGB-D 图像引导探头与患者建立接触, 并基于实时超声图像判断向模仿学习阶段切换的时机; 在模仿学习阶段, 系统将医师示范的扫查技能编码为超声图像与探头运动轨迹, 并通过集合贝叶斯交互基元实现对扫查技能的学习与复现, 最终完成肝脏的自主超声扫查. 另外, 在人体腹部体模上对所提方法进行了实验验证. 实验结果表明, 该方法在无需人工干预的条件下即可完成肝脏自主扫查任务, 展现出良好的临床应用前景.

**关键词** 机械臂; 自主超声扫查; 模仿学习; 集合贝叶斯交互基元

**引用格式** 马骥, 赵悦, 刘壮, 胡悦, 刘健行, 沈毅. 基于集合贝叶斯交互基元的机械臂自主肝脏超声扫查. 自动化学报, 2026, 52(6): 1291-1303

**DOI** 10.16383/j.aas.c250530 **CSTR** 32138.14.j.aas.c250530

## Autonomous Liver Ultrasound Scanning via Robotic Arm Using Ensemble Bayesian Interaction Primitives

MA Ji<sup>1</sup> ZHAO Yue<sup>1,2</sup> LIU Zhuang<sup>1</sup> HU Yue<sup>3</sup> LIU Jian-Xing<sup>1</sup> SHEN Yi<sup>1</sup>

**Abstract** To advance liver ultrasound examination, this study proposes a fully autonomous robotic arm ultrasound scanning method based on ensemble Bayesian interaction primitives (enBIP), and develops the corresponding experimental system. The proposed method consists of two sequential stages: Initial positioning and imitation learning. In the initial positioning stage, the system guides the probe to establish contact with the patient using RGB-D images and determines the transition to the imitation learning stage based on real-time ultrasound images. In the imitation learning stage, the system encodes expert scanning skills into ultrasound image state trajectories and probe motion trajectories, and learns to reproduce these skills using enBIP. Consequently, fully autonomous robotic arm liver ultrasound scanning is achieved. In addition, the proposed framework was experimentally validated on a human abdominal phantom. Experimental results demonstrate that the proposed method successfully performs the liver scanning task without human intervention, highlighting its potential for clinical application.

**Keywords** robotic arm; autonomous ultrasound scanning; imitation learning; ensemble Bayesian interaction primitives

**Citation** Ma Ji, Zhao Yue, Liu Zhuang, Hu Yue, Liu Jian-Xing, Shen Yi. Autonomous liver ultrasound scanning via robotic arm using ensemble Bayesian interaction primitives. *Acta Automatica Sinica*, 2026, 52(6): 1291-1303

收稿日期 2025-10-13 录用日期 2026-01-30

Manuscript received October 13, 2025; accepted January 30, 2026

国家自然科学基金 (62473108, 62173116, 62371167, 62373127), 国家资助博士后研究人员计划 (GZB20250957), 中国博士后科学基金 (2024M764189) 资助

Supported by National Natural Science Foundation of China (62473108, 62173116, 62371167, 62373127), Postdoctoral Fellowship Program of China Postdoctoral Science Foundation (GZB20250957), and China Postdoctoral Science Foundation (2024M764189)

本文责任编辑 罗彪

Recommended by Associate Editor LUO Biao

1. 哈尔滨工业大学航天学院 哈尔滨 150001 2. 哈尔滨工业大学郑州高等研究院 郑州 450000 3. 哈尔滨工业大学电子与信息工程学院 哈尔滨 150001

1. School of Astronautics, Harbin Institute of Technology, Harbin 150001 2. Zhengzhou Advanced Research Institute, Harbin Institute of Technology, Zhengzhou 450000 3. School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150001

肝脏疾病严重威胁着人类健康<sup>[1]</sup>, 医学超声成像凭借其低成本、无辐射及实时性好等优势, 已成为肝脏疾病筛查与检测的主要手段. 然而, 传统徒手超声扫查高度依赖医师的经验与手法, 操作者的主观差异导致诊断结果的标准化程度较低<sup>[2]</sup>. 此外, 长期、重复性的扫查工作迫使医师面临严重的职业损伤风险<sup>[3]</sup>, 且优质超声医疗资源难以有效下沉.

为应对上述挑战, 借助机械臂高精度、高重复性等优势, 研发能够辅助甚至替代医师完成标准切面获取的自主扫查系统, 已成为该领域的研究热点<sup>[4-5]</sup>. 然而, 面对肝脏扫查中解剖结构复杂、患者生理活动干扰等挑战, 传统基于简单视觉特征的伺服控制往往难以适应复杂多变的临床环境<sup>[6]</sup>. 人工智

能 (artificial intelligence, AI) 技术为突破这一瓶颈提供关键契机: 它赋予机械臂更强的环境感知与自主决策能力, 推动自主扫查从“机械自动化”向“感知-决策-执行”的闭环智能跨越. 这种 AI 驱动的模式对于提升在复杂动态场景下的超声扫查标准化水平具有重要的研究意义.

在这一智能化趋势下, 强化学习与模仿学习成为实现自主扫查的主流路径. 已有研究<sup>[7-8]</sup>尝试利用强化学习融合多模态信息预测探头运动, 但其对奖励函数设计的高度敏感性以及对高保真仿真环境的依赖, 限制了该方法在真实临床场景的快速部署. 相比之下, 模仿学习能够直接从专家示教数据中提取操作技能<sup>[9]</sup>, 兼顾任务执行的可靠性与开发效率, 为实现轻量化、高可靠的 AI 驱动自主扫查提供更优的解决方案.

模仿学习的核心思想是基于超声医师的示教数据, 将当前扫查状态映射为下一时刻探头的目标位姿, 该过程亦称为动作推理. 运动基元方法作为模仿学习的代表性方法之一, 具有结构简洁、执行高效等特点. 文献 [9] 提出区间交互概率运动基元法并应用于乳腺血肿扫查. 该方法虽然通过区间概率模型增强了对有限观测的鲁棒性, 但其底层依赖于时间相关的基函数对轨迹进行建模, 缺乏显式的相位 (用于表征任务执行进度的归一化变量) 变换与估计机制来解耦任务进度与绝对执行时间. 文献 [10] 采用动态运动基元方法, 通过直接复现整条示教轨迹完成肝脏自主超声扫查. 该方法虽以任务相位替代绝对时间, 但忽略了关键的超声图像信息, 导致系统无法根据实时图像反馈在线调整探头轨迹, 灵活性受限. 文献 [11] 基于高斯混合模型构建模仿学习框架, 结合高斯混合回归, 以超声图像、探头姿态与接触力等多模态传感信息作为输入实现动作推理. 然而, 该方法未对反映任务进程的相位信息进行建模与估计, 致使探头在面对非平稳观测时, 难以保持动作在时序上的连贯性, 容易出现抖动. 此外, 该研究仅通过离线采集的数据集验证方法有效性, 缺乏在线实验验证, 其工程可行性仍需进一步探究.

由此可见, 在上述基于运动基元的方法中, 任务相位是解耦扫查进程与绝对执行时间的关键, 而引入图像观测的实时状态反馈离不开精准的相位估计. 然而, 传统模仿学习方法中的相位估计多依赖外部算法, 往往面临计算效率低下或迭代误差累积的挑战. 此外, 上述研究多集中于模仿学习动作复现本身, 忽略了扫查起始位姿的自主定位问题, 因此难以实现真正意义上的全流程自主扫查. 为更直观地体现本文方法相较于现有研究的优势, 我们在

表 1 中对上述方法的关键特性进行系统性对比.

表 1 本文方法与现有代表性研究的特性对比  
Table 1 Feature comparison between the proposed method and existing representative studies

方法	自主初始定位	显式相位估计	图像观测反馈	时空联合推断	在线闭环验证
文献 [9]	×	×	√	×	√
文献 [10]	√	×*	×	×	√
文献 [11]	×	×	√	×	×
本文	√	√	√	√	√

注: “\*”表示文献 [10] 中的相位变量由时间驱动的正则系统生成, 而非基于状态观测的实时估计.

集合贝叶斯交互基元 (ensemble Bayesian interaction primitives, enBIP) 是一种专为人机交互任务设计的模仿学习方法, 已成功应用于抛接球<sup>[12]</sup>、握手<sup>[13]</sup>及下肢外骨骼控制<sup>[14]</sup>等多种交互场景. 相较于前述方法, enBIP 将交互任务的时间动态特性作为系统的增广状态, 使其能够基于观测信息同步预测智能体的响应轨迹及任务的时间相位. 这种时空联合估计与推理的机制, 无需依赖额外的相位估计算法, 因而在人机交互任务中展现出更高的精度、鲁棒性与计算效率<sup>[14]</sup>. 尽管 enBIP 的原生场景通常涉及两个独立智能体 (如人机协作), 但本研究将其创新性地泛化至单智能体自主扫查场景. 在此场景中, 本文将“机器人未来动作流”与“扫查环境的多模态历史观测流”视为交互双方, 利用 enBIP 挖掘两者之间的时空联系.

综上所述, 针对现有运动基元方法在自主超声扫查中面临的相位估计和初始位姿定位问题, 本文提出一种基于 enBIP 的全自主肝脏超声扫查方法. 该方法包含两个顺序衔接的扫查阶段: 初始定位阶段 (S1) 及模仿学习阶段 (S2). 在 S1 阶段, 基于患者腹部体表三维视觉数据规划搜索路径, 引导探头与患者建立初始接触并沿该路径搜索肝脏结构, 据此确定模仿学习阶段的启动时机, 从而有效解决初始位姿定位问题; 在 S2 阶段, enBIP 利用实时传感数据与医师示教数据, 迭代执行探头动作推理, 引导探头运动至预设的肝脏标准切面, 无需依赖外部相位估计算法. 进一步, 在人体腹部体模上开展的模块化与系统性实验验证了所提方法的有效性. 结果表明, 该方法能够在全流程无人参与的情况下完成肝脏扫查任务, 展现出良好的临床应用前景.

## 1 系统描述

### 1.1 系统配置

本文参考文献 [15] 搭建了如图 1 所示的机械

臂自主肝脏超声扫查系统(以下简称“系统”). 在系统中, 机械臂作为核心执行元件, 负责驱动超声探头沿人体表面运动以完成扫查任务; 超声探头与超声成像系统用于清晰显示人体内部的解剖结构, 为医生的诊断提供可靠依据; RGB-D 相机用于获取患者在任务空间中的位姿信息, 其与超声成像系统共同构成了系统的视觉感知模块; 力/力矩传感器用于监测探头与患者间的接触力, 确保建立良好的声学耦合并保障患者安全; 体模用于模拟人体腹部的真实解剖结构, 为方法验证提供高保真环境.

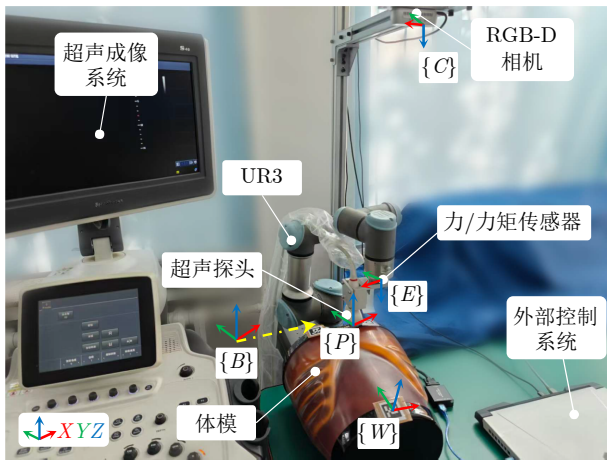


图 1 机械臂自主肝脏超声扫查系统

Fig.1 Robotic arm system for autonomous liver ultrasound scanning

本文搭建的自主超声扫查系统定义了以下坐标系:  $\{B\}$  为机械臂基坐标系, 亦作为系统全局坐标系;  $\{E\}$  为机械臂末端坐标系;  $\{P\}$  为超声探头坐标系;  $\{C\}$  为 RGB-D 相机坐标系;  $\{W\}$  为体模坐标系. 为实现多设备间的坐标统一, 需定义若干关键坐标变换矩阵. 首先, 采用“眼在手外”式相机标定方法, 建立从坐标系  $\{C\}$  到  $\{B\}$  的变换矩阵  ${}^B_C T$ . 进而, 借助此矩阵, 可将由 RGB-D 相机获取的体模上肚脐和乳头(本文以三个 ArUco 标记模拟)的位置信息转换至全局坐标系  $\{B\}$ , 并据此定义体模坐标系  $\{W\}$  及坐标变换矩阵  ${}^B_W T$ .  $\{W\}$  的具体定义如下:  $\{W\}$  的原点设于体模肚脐处; 其  $z$  轴与  $\{B\}$  的  $z$  轴保持一致;  $x$  轴同时垂直于  $z$  轴以及由肚脐指向双乳连线中点的向量;  $y$  轴则依据右手定则确定.

## 1.2 扫查流程概述

本文提出的自主超声扫查框架包含初始定位与模仿学习两个阶段, 其总体流程如图 2 所示.

扫查任务启动后, 系统首先进入图 2 中浅绿色区域的 S1 阶段. 在该阶段中, 系统首先根据体模表

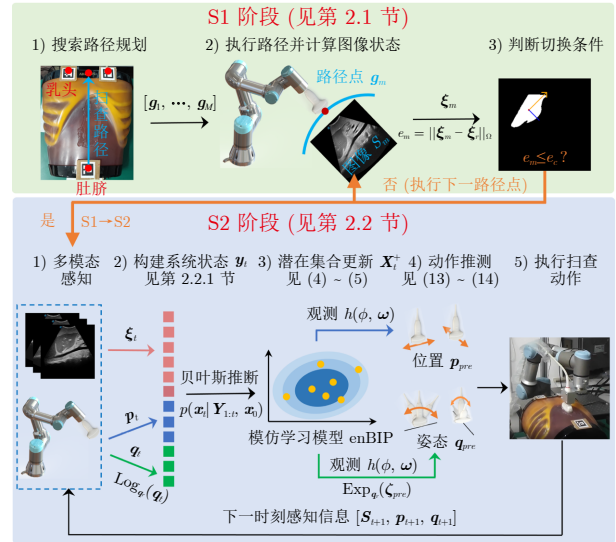


图 2 机械臂自主超声扫查流程

Fig.2 Workflow of autonomous ultrasound scanning via the robotic arm

面位置信息生成一条离散搜索路径. 随后, 机械臂引导超声探头与体模建立初始接触, 并沿该路径运动. 在每个路径点, 系统利用深度网络 UVM-UNet (UltraLight Vision Mamba UNet)<sup>[16]</sup> 实时分割所采集的超声图像, 并基于生成的掩模判断是否满足向 S2 阶段切换的条件. 若满足预设的图像阈值条件, 系统即切换至 S2 阶段; 否则, 将驱动超声探头移至下一路径点.

当扫查任务进入图 2 中浅蓝色区域的 S2 阶段后, 系统控制策略切换为利用 enBIP 算法复现学习得到的专业扫查技能, 以引导超声探头最终抵达目标切面. 在此阶段中, 系统首先将传感器采集的超声图像信息与探头位姿信息整合为一组状态向量; 随后, 根据当前系统状态更新 enBIP 算法学习得到的潜在空间概率模型, 并利用该模型预测探头在下一时刻的目标位姿; 最后, 由机械臂驱动探头运动至该位姿. 这一过程迭代执行, 直至扫查任务完成.

## 2 两阶段自主超声扫查框架技术细节

本节将详细阐述所提出的两阶段自主超声扫查方法. 为了清晰地展示技术细节, 本节安排如下: 首先, 第 2.1 节介绍了 S1 阶段的实施策略, 涵盖搜索路径规划、超声图像状态定义及阶段切换条件; 接着, 第 2.2 节重点阐述了 S2 阶段的核心算法流程, 从系统状态与示教轨迹的定义出发, 逐步解析基函数分解、潜在空间建模以及基于集合卡尔曼滤波的状态估计与控制指令生成过程; 最后, 第 2.3 节补充了示教轨迹的坐标系变换方法与保证接触安全的导

纳控制策略。

## 2.1 初始定位阶段实施细节

S2 阶段的自主超声扫查通常需要从超声图像中已能观察到部分目标解剖结构的位置开始执行。然而,在探头与患者初始接触时,往往难以确保目标结构在超声图像中的可见性。本文考虑到肚脐与乳头是人体腹部超声检查中显著且常见的体表标志,因此在 S2 阶段之前增设 S1 阶段,旨在确保模仿学习能够从适宜的位置开始。S1 阶段主要包含两个核心功能模块:搜索路径规划与切换条件判定。

如图 2 中浅绿色区域所示,系统规划的搜索路径始于肚脐,终点为两乳头连线的中点。当探头沿该路径移动时,肝脏结构预计将在某一时刻显现于超声图像中。搜索路径的生成流程如下:首先,基于采集的 RGB 图像,在相机坐标系  $\{C\}$  的 XY 平面内通过线性插值生成初始二维路径;随后,依据体模的点云数据提取各路径点对应的  $z$  坐标;最后,利用第 1.2 节定义的坐标变换矩阵  ${}^B_C T$ ,将规划好的搜索路径转换至全局坐标系  $\{B\}$  下。各路径点处的探头姿态均被设定为一特定的参考单位四元数  $q_r$ ,此举确保了前后两个扫查阶段间的平滑过渡。

设置切换条件的目的是根据实时超声图像的状态,判定系统能否由 S1 阶段切换至 S2 阶段。超声图像状态向量的构建流程如图 3 所示:首先,采用 UVM-UNet 自采集的超声图像中分割出肝脏区域,生成二值化掩模;随后,对该掩模进行主成分分析 (principal component analysis, PCA),提取其关键图像特征;最终,构建得到图像状态向量  $\xi := [s, c_x, c_y, \theta, l, b]^T \in \mathbf{R}^6$ 。这些特征元素均定义于以掩模左上角为原点的图像坐标系  $O_I$  中:  $s$  为分割所得肝脏区域的面积,  $c_x$  与  $c_y$  分别为肝脏区域质心的横、纵坐标,  $\theta$  为肝脏区域主轴与图像坐标系水平轴的夹角,  $l$  和  $b$  则分别代表肝脏区域主轴与短轴的长度。选择上述六维特征旨在构建针对超声掩模




图 3 超声图像状态定义

Fig. 3 Definition of ultrasound image states

的完备几何描述。其中,  $c_x$ 、 $c_y$  和  $\theta$  唯一确定了肝脏区域在图像内的位置与旋转朝向;  $s$ 、 $l$  和  $b$  分量则进一步明确肝脏区域的长宽比与具体几何形态。这组特征实现了对肝脏“位姿-形状-尺度”的完整约束,确保了图像状态描述的唯一性。

当探头运动至规划路径点时,系统计算当前图像状态  $\xi_t$  与参考状态  $\xi_r$  之间误差向量的加权欧几里得范数  $e_t$ 。当误差  $e_t$  满足以下条件时,系统的自主扫查任务即从 S1 阶段切换至 S2 阶段:

$$e_t = \|\xi_t - \xi_r\|_{\Omega} \leq e_c \quad (1)$$

式中,  $\Omega \in \mathbf{R}^{6 \times 6}$  为对角权重矩阵;  $e_c$  为预设误差阈值;参考状态  $\xi_r$  定义为医师采集的全部示教轨迹在初始时刻处的超声图像状态的均值。

需说明的是,本文使用三个 ArUco 标记来模拟肚脐与乳头。该设置是对实际临床场景的合理简化,其依据在于:初始定位阶段仅需获取这些体表标志的位置坐标,而此需求可通过简单的目标识别算法<sup>[17]</sup>有效满足。

## 2.2 基于 enBIP 的模仿学习阶段实施细节

S2 阶段旨在复现专业医师所演示的超声扫查轨迹。本文采用的模仿学习方法为 enBIP,该方法包含两个核心步骤:1) 将示教轨迹分解至潜在空间,并进行概率建模;2) 在实际扫查过程中依据系统状态进行动作推理。本文将一条完整的扫查轨迹  $\mathbf{Y}$  定义为由  $T$  个离散时间步的系统状态  $\mathbf{y}_t$  构成的时间序列。据此,本节首先明确系统状态的定义,继而阐述示教轨迹的潜在空间建模方法,最后介绍基于 enBIP 的动作推理流程。

### 2.2.1 系统状态定义

系统状态由超声图像状态及探头运动状态共同组成。其中,超声图像状态已在第 2.1 节中详细阐述;探头运动状态则包含探头的位置  $\mathbf{p}_t$  与姿态  $\mathbf{q}_t$ 。考虑到探头与机械臂末端为固定连接,二者位姿存在恒定变换关系,因此本文采用机械臂末端位姿替代探头位姿,以简化运算。本文采用单位四元数(下文简称“四元数”)表示姿态,但由于四元数空间存在单位模长约束,直接通过 enBIP 处理系统的四元数轨迹会导致结果偏差。为此,本文参考文献 [18] 提出的方法,通过对数映射  $\text{Log}(\cdot)$  将系统的四元数轨迹转换至某一参考四元数的切空间——欧几里得空间,可使 enBIP 对转换后的四元数数据进行有效处理。

如文献 [18] 所述,令  $\mathbf{q}_1$  和  $\mathbf{q}_r$  (其中  $\mathbf{q}_j \in S^3$ ,  $j \in$

$\{1, r\}$ ) 分别表示工作四元数与参考四元数. 记  $\bar{q}_r$  为  $q_r$  的共轭四元数, 则记四元数乘积为  $q_{\times} = q_1 * \bar{q}_r = [q_w, \mathbf{u}]^T$ . 其中,  $q_w$  为标量部分,  $\mathbf{u}$  为三维矢量部分. 对数映射  $\text{Log}(\cdot): S^3 \rightarrow \mathbf{R}^3$  定义如下:

$$\text{Log}_{q_r}(q_1) = \text{Log}(q_{\times}) = \begin{cases} \arccos(q_w) \frac{\mathbf{u}}{\|\mathbf{u}\|}, & \mathbf{u} \neq \mathbf{0} \\ [0, 0, 0]^T, & \text{其他} \end{cases} \quad (2)$$

式中,  $\|\cdot\|$  表示欧几里得范数. 基于此映射, 可将系统的四元数轨迹  $q_t$  转换为  $\zeta_t := \text{Log}_{q_r}(q_t)$ . 进而, 探头的运动状态向量定义为  $[\mathbf{p}_t^T, \zeta_t^T]^T$ .

结合上述超声图像状态与探头运动状态, 将系统状态定义为  $\mathbf{y}_t := [\xi_t^T, \mathbf{p}_t^T, \zeta_t^T]^T \in \mathbf{R}^D$ , 其中  $D$  表示系统状态向量的总维度. 由此, 一条完整的扫查轨迹可表示为  $\mathbf{Y} := [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_T] \in \mathbf{R}^{D \times T}$ . 故而, 以原始传感器数据形式记录的示教轨迹需先通过上述方法预处理为系统状态序列, 以便后续进行示教建模与运动推理.

### 2.2.2 示教轨迹的潜在空间建模

依据 enBIP 方法<sup>[14]</sup>, 为降低概率建模的复杂度, 将系统状态  $\mathbf{y}_t$  的每一维度  $d \in \{1, \dots, D\}$  分解为  $B^d$  个基函数  $\Phi_{\phi(t)} \in \mathbf{R}^{B^d}$  与对应权重  $\omega^d \in \mathbf{R}^{B^d}$  的线性组合, 即  $y_t^d = \Phi_{\phi(t)}^T \omega^d + \epsilon_y^d$ . 式中,  $\epsilon_y^d$  为高斯白噪声. 通过此分解, 时变的系统状态  $y_t^d$  被转换为一组时不变的权重  $\omega^d$ . 综合所有状态维度的基函数权重, 即可将扫查轨迹  $\mathbf{Y}$  映射到一个潜在的基函数空间. 相应地, 原观测空间的系统状态可通过观测函数  $\mathbf{y}_t = h(\phi(t), \omega)$  进行重构, 该函数由基函数值及其对应权重组合而成. 其中,  $h(\cdot)$  为非线性观测函数; 相位  $\phi(t)$  (下文简记为  $\phi \in \mathbf{R}$ ) 是一个衡量扫查任务进度的无量纲归一化变量, 依照示教轨迹长度经线性插值获得, 满足  $0 \leq \phi(t) \leq 1, 0 \leq t \leq T$ .

融合潜在空间的基函数权重  $\omega$ 、相位  $\phi$  及其导数  $\dot{\phi}$ , 可为每条示教轨迹构建增广的潜在状态向量  $\mathbf{x} = [\phi, \dot{\phi}, \omega^T]^T$ . 其中,  $\dot{\phi}$  表示相速度, 定义为  $\dot{\phi} := 1/T$ , 其数值决定了扫查任务的演化速率. 基于医师演示的  $N$  条扫查轨迹, 可构建一个封装了专业扫查技能的初始潜在状态概率模型  $\mathbf{X}_0 = [\mathbf{x}_{0,1}, \dots, \mathbf{x}_{0,N}] \in \mathbf{R}^{(B^d \times D + 2) \times N}$ , 该模型将被用于 S2 阶段的探头动作推理. 需要说明的是, 示教轨迹的潜在空间建模是一个独立的流程, 既可在 S2 阶段开始时执行, 也可在整个扫查任务开始前完成. 为保证扫查任务的整体连续性, 本文选择在扫查开始前完成建模.

### 2.2.3 潜在状态集合估计与更新

在本文中, S2 阶段的目标是基于当前系统状

态, 预测探头下一时刻的目标位姿, 从而最终完成人体肝脏左叶纵切面的超声扫查任务. 为实现该目标, 系统需首先估计并更新当前时刻的潜在状态  $\mathbf{x}_t$ . 基于第 2.2.2 节建立的概率模型  $\mathbf{X}_0$ , enBIP 采用贝叶斯推断方法估计  $\mathbf{x}_t$  的后验分布:

$$p(\mathbf{x}_t | \mathbf{Y}_{1:t}, \mathbf{x}_0) \propto p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{Y}_{1:t-1}, \mathbf{x}_0) \quad (3)$$

式中,  $\mathbf{x}_0$  为基于  $\mathbf{X}_0$  计算得到的初始潜在状态;  $\mathbf{Y}_{1:t-1}$  表示截至前一时刻的所有观测序列;  $\mathbf{y}_t$  为当前时刻观测到的系统状态, 也称为观测量.

为在执行扫查任务时有效实现上述推理过程, 需首先对潜在概率模型  $\mathbf{X}_0$  各成员的时间分量  $\phi_{0,i}, i \in \{1, 2, \dots, N\}$  进行初始化. 每个  $\phi_{0,i}$  均从正态分布  $N(\mu_{\phi_0}, \Sigma_{\phi_0})$  中采样. 其均值  $\mu_{\phi_0}$  略偏离零, 这是由于在实际执行过程中, 系统的模仿学习阶段未必总是从相位零点开始. 随后, enBIP 通过恒速状态转移算子  $g(\cdot)$  将  $\mathbf{X}_{t-1}^+ = [\mathbf{x}_{t-1,1}^+, \dots, \mathbf{x}_{t-1,N}^+]$  中的每个集合成员向前传播一个时间步, 并引入遵循零均值正态分布的过程噪声  $N(0, \mathbf{Q}_{proc})$ , 从而近似  $p(\mathbf{x}_t | \mathbf{Y}_{1:t-1}, \mathbf{x}_0)$ :

$$\mathbf{x}_{t,i}^- = g(\mathbf{x}_{t-1,i}^+) + N(0, \mathbf{Q}_{proc}) \quad (4)$$

式中,  $\mathbf{Q}_{proc}$  表示过程噪声协方差矩阵. 随后, 基于当前观测到的系统状态  $\mathbf{y}_t$  与非线性观测函数  $h(\cdot)$ , 即可更新得到当前时刻的潜在概率模型为:

$$\mathbf{X}_t^+ = \mathbf{X}_t^- + \mathbf{K}_t(\tilde{\mathbf{y}}_t - \mathbf{H}_t \mathbf{X}_t^-) \quad (5)$$

$$\tilde{\mathbf{y}}_t = [\mathbf{y}_t + N(0, \mathbf{R}_{obs}), \dots, \mathbf{y}_t + N(0, \mathbf{R}_{obs})] \quad (6)$$

$$\mathbf{H}_t \mathbf{X}_t^- = [h(\mathbf{x}_{t,1}^-), \dots, h(\mathbf{x}_{t,N}^-)] \quad (7)$$

式中,  $N(0, \mathbf{R}_{obs})$  为遵循零均值正态分布的观测噪声;  $\mathbf{R}_{obs}$  表示观测噪声协方差矩阵, 其值基于各条示教轨迹基函数分解后的拟合误差统计得到;  $\mathbf{K}_t$  表示卡尔曼增益, 其计算公式为:

$$\mathbf{K}_t = \frac{1}{N-1} \mathbf{A}_t (\mathbf{H}_t \mathbf{A}_t)^T \mathbf{S}_t^{-1} \quad (8)$$

$$\mathbf{A}_t = \mathbf{X}_t^- - \frac{1}{N} \sum_{i=1}^N \mathbf{x}_{t,i}^- \quad (9)$$

式 (8) 中,  $\mathbf{S}_t$  表示新息协方差, 其计算公式如下:

$$\mathbf{S}_t = \frac{1}{N-1} (\mathbf{H}_t \mathbf{A}_t) (\mathbf{H}_t \mathbf{A}_t)^T + \mathbf{R}_{obs} \quad (10)$$

$$\mathbf{H}_t \mathbf{A}_t = \mathbf{H}_t \mathbf{X}_t^- - \left[ \frac{1}{N} \sum_{i=1}^N h(\mathbf{x}_{t,i}^-), \dots, \frac{1}{N} \sum_{i=1}^N h(\mathbf{x}_{t,i}^-) \right] \quad (11)$$

可以看出, 上述潜在状态集合  $\mathbf{X}_t$  的估计与更

新过程遵循集合卡尔曼滤波框架. 这意味着可以仅利用部分系统状态分量作为观测量, 来完成全部潜在状态的估计与更新. 在此部分观测设定下, 需对未作为观测量的系统状态分量进行以下处理: 首先, 将其观测值设为零或随机高斯噪声; 其次, 将对应维度的观测噪声人为设定为较大值, 从而在滤波过程中有效抑制不可观测状态分量对估计结果的影响.

### 2.2.4 探头动作推理

在完成对潜在状态集合  $\mathbf{X}_t$  的估计与更新后, 系统即可基于观测函数  $h(\cdot)$  计算下一时刻探头的目标位姿:

$$\bar{\mathbf{x}}_t^+ = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_{t,i}^+ \quad (12)$$

$$\mathbf{y}_{pre} = h(\bar{\mathbf{x}}_t^+) = \Psi_{\phi+\Delta\phi}^T \boldsymbol{\omega}_t \quad (13)$$

式中,  $\Psi_{\phi} = \text{diag}\{\Phi_{\phi}, \dots, \Phi_{\phi}\} \in \mathbf{R}^{B^d D \times D}$  为增广基函数矩阵;  $\mathbf{y}_{pre} := [\boldsymbol{\zeta}_{pre}^T, \mathbf{p}_{pre}^T, \boldsymbol{\zeta}_{pre}^T]^T$  为预测向量,  $\boldsymbol{\zeta}_{pre}$  为预测的超声图像状态,  $\mathbf{p}_{pre}$  为预测的探头位置,  $\boldsymbol{\zeta}_{pre}$  为预测的探头姿态;  $\Delta\phi$  为相位前进步长, 用于控制自主扫查任务的推进速度.

为控制探头顺利运动至目标位姿, 需通过指数映射  $\text{Exp}(\cdot)$  将  $\boldsymbol{\zeta}_{pre}$  还原为四元数  $\mathbf{q}_{pre}$ :

$$\mathbf{q}_{pre} = \text{Exp}_{\mathbf{q}_r}(\boldsymbol{\zeta}_{pre}) = \text{Exp}(\boldsymbol{\zeta}_{pre}) * \mathbf{q}_r \quad (14)$$

此处, 参照文献 [18], 指数映射  $\text{Exp}(\cdot): \mathbf{R}^3 \rightarrow S^3$  定义如下:

$$\text{Exp}(\boldsymbol{\zeta}) = \begin{cases} \begin{bmatrix} \cos(\|\boldsymbol{\zeta}\|) \\ \sin(\|\boldsymbol{\zeta}\|) \frac{\boldsymbol{\zeta}}{\|\boldsymbol{\zeta}\|} \\ [1, 0, 0, 0]^T \end{bmatrix}, & \boldsymbol{\zeta} \neq \mathbf{0} \\ [1, 0, 0, 0]^T, & \text{其他} \end{cases} \quad (15)$$

本文定义的参考四元数  $\mathbf{q}_r$  为所有示教轨迹初始时刻对应四元数的黎曼质心, 该质心通过以下最大似然估计方法<sup>[19]</sup> 计算:

$$f(\mathbf{q}_r^k) = -\frac{1}{2} \sum_{i=1}^N (\text{Log}_{\mathbf{q}_r^k}(\mathbf{q}_i))^T \boldsymbol{\Lambda}^{-1} \text{Log}_{\mathbf{q}_r^k}(\mathbf{q}_i) \quad (16)$$

$$\mathbf{q}_r^{k+1} = \text{Exp}_{\mathbf{q}_r^k} \left( \frac{1}{N} \sum_{i=1}^N \text{Log}_{\mathbf{q}_r^k}(\mathbf{q}_i) \right) \quad (17)$$

其中,  $\boldsymbol{\Lambda} \in \mathbf{R}^{3 \times 3}$  为定义于  $\mathbf{q}_r$  切空间内的协方差矩阵,  $f(\cdot)$  为似然函数,  $\mathbf{q}_i$  为第  $i$  条示教轨迹的初始时刻四元数,  $k$  为迭代次数.

综上所述, 系统在每一控制周期内均可推理出探头的目标位姿  $[\mathbf{p}_{pre}^T, \mathbf{q}_{pre}^T]^T$ , 并将该指令下发至机械臂, 以引导探头运动. 该过程迭代执行, 直至超声扫查任务完成 (如图 2 浅蓝色区域所示).

## 2.3 示教轨迹坐标系变换及导纳控制

### 2.3.1 示教轨迹坐标系变换

在实际自主超声扫查过程中, 患者可能处于系统工作空间内的不同位置. 为应对此情况, 通常需要超声医师采集覆盖所有患者可能位置的示教数据, 但这会显著增加医师的工作负担. 为此, 本文提出将示教轨迹从全局坐标系  $\{B\}$  转换至定义于患者肚脐处的局部坐标系  $\{W\}$  中. 基于第 1.1 节定义的局部坐标系  $\{W\}$ , 示教轨迹的坐标系变换公式如下:

$${}^W \mathbf{T}_{1:T} = ({}^B_W \mathbf{T})^{-1} \cdot {}^B_E \mathbf{T}_{1:T} \quad (18)$$

其中,  ${}^B_E \mathbf{T}_{1:T}$  表示示教轨迹在全局坐标系  $\{B\}$  下的齐次矩阵形式,  ${}^W_E \mathbf{T}_{1:T}$  表示同一条示教轨迹在体模局部坐标系  $\{W\}$  下的齐次矩阵形式. 需要说明的是, 该坐标系变换仅针对示教轨迹中的探头运动状态分量, 而超声图像状态轨迹保持不变.

该方法的核心优势在于: 超声医师只需在单一患者位置下采集一组示教数据, 系统即可通过上述坐标变换, 在不同患者位置下复现所学习的扫查技能. 这一特性对临床长期疾病监测具有重要意义, 能够保证不同检查周期间扫查操作的一致性与重复性, 从而为病情演变评估提供可靠的影像学依据.

### 2.3.2 导纳控制

为保证扫查过程中所采集超声图像的质量并保障患者安全, 系统需在探头与患者体表之间维持稳定的接触力. 为此, 本文沿探头坐标系  $\{P\}$  的  $z$  轴方向引入导纳控制<sup>[20]</sup>:

$$F_z - F_d = \frac{M_a}{\Delta t} (v_{t+1}^P - v_t^P) + D_a v_t^P \quad (19)$$

其中,  $M_a \in \mathbf{R}$  和  $D_a \in \mathbf{R}$  分别为虚拟质量与虚拟阻尼系数;  $F_d$  为预设期望接触力;  $F_z$  表示经卡尔曼滤波去噪后的实测接触力<sup>[21]</sup>;  $v^P$  为探头沿坐标系  $\{P\}$  的  $z$  轴方向的运动速度;  $\Delta t$  为系统控制周期. 需要注意的是, 在执行导纳控制前, 需对探头及夹具重力以及因机械臂安装构型引起的静态力进行标定与补偿<sup>[22]</sup>, 消除其对接触力控制精度的不利影响.

基于前述导纳控制算法, 将下一时刻的探头目标位置  $\mathbf{p}_{tar}$  修正为:

$$\mathbf{p}'_{tar, t+1} = [x_{t+1}^{tar}, y_{t+1}^{tar}, z_t, 1]^T + {}^B_P \mathbf{T} [0, 0, v_{t+1}^P \Delta t, 0]^T \quad (20)$$

其中,  $\mathbf{p}_{tar}$  的具体定义随扫查阶段而异: 在 S1 阶段, 其为路径规划给出的目标位置; 在 S2 阶段, 则为动作推理所得的预测位置.  ${}^B_P \mathbf{T} = {}^B_E \mathbf{T}_P^E \mathbf{T}$  为从探头坐

标系  $\{P\}$  到全局坐标系  $\{B\}$  的变换矩阵,  ${}^B_P T$  通过机械臂正运动学计算获得,  ${}^P_P T$  则依据探头夹具与力传感器的三维几何模型确定。

为了更清晰地展示本文所提两阶段自主扫查方法的执行逻辑与数据流过程, 本文将完整的算法流程总结于算法 1 中。

### 算法 1. 自主扫查执行流程伪代码

输入. 示教轨迹库  $L$ , 系统观测  $\mathbf{y}_t$ , 患者 RGB-D 图像  $I_s$ , 导纳标志位  $f_{ac}$ , 示教变换标志位  $f_{tc}$ .

输出. 机器人控制指令  $\mathbf{u}_{cmd}$ .

```

/* 潜在状态建模与初始化 */
1) if  $f_{tc}$  is true then
2)   基于式 (18) 将  $L$  变换至坐标系  $\{W\}$ ;
3) end if
4) 基于式 (16) ~ (17) 计算参考四元数  $\mathbf{q}_r$ ;
5) 基于第 2.2.2 节计算初始潜在状态模型  $\mathbf{X}_0$ ;
   /* S1: 初始定位阶段 */
6) 基于  $I_s$  规划搜索路径  $\{g_1, \dots, g_M\}$ ;
7) for  $m \leftarrow 1$  to  $M$  do
8)   采集图像  $S_m$  并构建状态  $\xi_m$ ;
9)   基于式 (1) 计算图像状态误差  $e_m$ ;
10)  if  $e_m \leq e_c$  then
11)   跳出循环, 进入 S2 阶段;
12)  end if
13) 设置下一目标点  $g_{next} \leftarrow g_{m+1}$ ;
14)  if  $f_{ac}$  is true then
15)   读取探头与患者当前的接触力  $F_z$ ;
16)   基于式 (19) ~ (20) 修正目标点  $g_{next}$ ;
17)  end if
18) 输出控制指令  $\mathbf{u}_{cmd} \leftarrow g_{next}$ , 并执行;
19) end for
   /* S2: 模仿学习阶段 */
20) while 扫查任务未完成 do
21) 基于式 (4) 执行  $\mathbf{X}_t^- \leftarrow \text{Propagate}(\mathbf{X}_{t-1}^+)$ ;
22) 基于式 (5) 执行  $\mathbf{X}_t^+ \leftarrow \text{BayesUpdate}(\mathbf{X}_t^-, \mathbf{y}_t)$ ;
23) 基于式 (13) ~ (14) 计算  $[\mathbf{p}_{pre}^T, \mathbf{q}_{pre}^T]^T$ ;
24)  if  $f_{tc}$  is true then
25)   基于式 (18) 将  $[\mathbf{p}_{pre}^T, \mathbf{q}_{pre}^T]^T$  变换回坐标系  $\{B\}$ ;
26)  end if
27)  if  $f_{ac}$  is true then
28)   读取探头与患者当前的接触力  $F_z$ ;
29)   基于式 (19) ~ (20) 修正目标位姿  $[\mathbf{p}_{pre}^T, \mathbf{q}_{pre}^T]^T$ ;
30)  end if
31) 输出控制指令  $\mathbf{u}_{cmd} \leftarrow [\mathbf{p}_{pre}^T, \mathbf{q}_{pre}^T]^T$ , 并执行;
32) end while

```

## 3 实验分析

### 3.1 系统配置及准备工作

#### 3.1.1 系统配置

本文所搭建的机械臂自主肝脏超声扫查系统硬件配置如下: 机械臂采用丹麦优傲公司生产的 UR3 型号; 超声探头与超声成像系统分别为深圳开立公司生产的 3C-A 探头和 S40 主机; RGB-D 相机为英特尔公司出品的 RealSense D435i; 六维力/力矩传感器为 ATI Mini 40-E; 腹部体模使用日本京都科学公司的 ABDFAN 型号。所有扫查策略相关算法均基于 ROS2 软件框架, 采用 Python 3.10 语言进行开发。算法运行平台为一台搭载 AMD Ryzen 7 7745HX CPU、16 GB RAM 及 GeForce RTX 4060 Laptop GPU 的便携式计算机。该计算机运行集成了实时补丁的 Ubuntu 22.04 操作系统, 以满足对 UR3 机械臂进行实时控制的性能需求。

#### 3.1.2 深度网络训练

本文从体模上共采集 489 张分辨率为  $512 \times 512$  pixel 的超声图像, 用于深度网络 UVM-UNet 和 UNet<sup>[23]</sup> 的训练。所有图像均由专业超声医师在不同探头位姿及接触力条件下采集并完成标注, 按 9 : 1 的比例将图像随机划分为训练集和验证集。在输入网络前, 全部图像统一缩放至  $256 \times 256$  pixel 大小。深度网络的训练基于搭载 Intel Xeon Gold 6226R CPU 与 NVIDIA RTX A6000 GPU 的工作站完成。具体训练超参数设置详见文献 [16]。

#### 3.1.3 示教轨迹收集及建模

示教轨迹的采集与潜在空间概率建模流程如图 4 所示, 由一位专业超声医师手动引导机械臂, 完成肝脏超声扫查任务。在该过程中, 为协调传感频率分别为 30 Hz 和 125 Hz 的超声图像数据与探头位姿数据, 系统采用多线程软件架构将其异步写入单帧缓冲区, 并由主线程以 20 Hz 的频率同步读取各缓冲区的最新传感值, 从而获取原始的多模态示教数据序列。最终, 共采集到 50 条示教轨迹。




图 4 示教轨迹采集与潜在状态建模过程

Fig. 4 Process of demonstrated trajectory acquisition and latent state modeling

所同步采集的传感器数据经预处理后转换为系统状态  $\mathbf{y}_t$ , 进而构成离散状态轨迹  $\mathbf{Y}$ . 采用高斯基函数将上述示教轨迹分解至潜在权重空间, 最终构建包含 50 个成员的潜在状态集合  $\mathbf{X}_0$ , 该集合将作为用于后续动作推理的概率模型. 本文设定基函数的数量  $B^d$  为 15, 因此每个集合成员  $\mathbf{x}_i$  的维度为 182. 每个集合成员的初始相位值从正态分布  $N(0.01, 10^{-4})$  中采样生成.

### 3.2 超声图像分割性能分析

从超声图像中准确分割肝脏结构是构建图像状态的重要前提. 为此, 本节评估所选深度网络的有效性与分割精度. 采用十折交叉验证方法评估 UVM-UNet 的分割性能, 使用的评价指标包括平均交并比 (mean intersection over union, mIoU)、Dice 相似系数、准确率 (accuracy, Acc)、特异度 (specificity, Spe) 及灵敏度 (sensitivity, Sen). 为评估该网络的实时性能, 同时测量了其单张超声图像的分割延迟时间. 为验证 UVM-UNet 的有效性与实时性, 将其分割性能与 UNet 进行对比, 结果如表 2 及图 5 所示.

由表 2 可知, 在本文所采用的各项分割性能评价指标上, UNet 的表现略优于 UVM-UNet. 但两种模型均保持了较高的整体性能, 这主要是因为训练图像均采集自同一模态, 数据分布相对一致. 然而, UVM-UNet 在实时性方面具有显著优势, 其单张图像分割延迟仅为  $9.09 \pm 0.30$  ms, 较 UNet 的  $43.04 \pm 0.19$  ms 存在显著提升, 这对保障自主超声扫查系统的控制实时性具有重要意义. UVM-UNet 的高实时性能源于其更轻量的网络结构, 使其相较于 UNet 更适用于计算资源受限的实际部署场景.

结合图 5 的定性分析可以看出, UVM-UNet (绿色区域) 与 UNet (蓝色区域) 所生成的分割掩模均能较好地贴合真实标签 (红色区域). 尽管 UVM-UNet 在部分肝脏区域的分割细节上与 UNet 存在细微差异, 但其整体分割精度已满足本文自主超声扫查任务的工程需求.

综上, 基于在分割精度和推理速度方面取得平衡的考虑, 本文最终选用 UVM-UNet 作为超声图像中肝脏结构的特征提取器, 从而在牺牲有限分割

性能的前提下, 有效保障系统控制的实时性.

### 3.3 基于 enBIP 的模仿学习阶段自主扫查实验

#### 3.3.1 可行性分析

在 S2 阶段, 系统控制策略的核心在于依据当前系统状态, 预测探头下一时刻的目标位姿, 并控制其运动至该位姿. 通过逐步迭代执行上述动作推理过程, 系统最终完成肝脏的自主超声扫查任务.

为验证 enBIP 方法在此阶段的可行性, 本节开展了基于 enBIP 的自主扫查实验. 实验手动设定扫查起点, 终止条件设为相位  $\phi \geq 0.98$ , 并在若干关键时间点采集了肝脏超声图像及其对应分割掩模, 结果如图 6 所示. 从图 6 可以看出, 在自主扫查任务启动初期, 仅少部分肝脏左叶结构出现在超声图像视野内. 随着扫查过程的推进, 肝脏左叶结构逐渐移入视野, 并最终完整显现. 此外, 扫查任务启动初期的系统相位为  $\phi = 0.026$ , 该值由 enBIP 根据示教数据与当前实际系统状态自主计算得出, 表明当系统进入 S2 阶段时, 其在时间维度上的位置未必严格始于  $\phi = 0$ . 这一现象也支持了本文从正态分布  $N(\mu_{\phi_0}, \Sigma_{\phi_0})$  中采样以初始化潜在集合  $\mathbf{X}_0$  中各成员的相位分量的必要性.

除可行性验证外, 本节进一步记录了 enBIP 在不同相位值处预测的探头  $z$  轴位置轨迹, 分析了各预测轨迹之间及其与示教轨迹概率分布的关系, 结果如图 7 所示. 图中, 蓝色点划线表示基于示教轨迹计算得到的均值轨迹; 浅蓝色阴影区域则表示涵盖  $\pm 3$  倍标准差的示教轨迹分布范围; 绿色点线为 enBIP 在  $\phi = 0.20$  时对后续所有时刻的探头  $z$  轴位置轨迹的预测结果; 棕色虚线、橙色双点划线与紫色实线分别对应  $\phi = 0.40$ 、 $\phi = 0.60$  及  $\phi = 0.80$  时刻的预测轨迹.

从图 7 可以看出, enBIP 所预测的轨迹在形态上与示教轨迹高度相似, 且其数值均落在示教轨迹的分布范围内, 直观体现了“模仿”的本质——enBIP 通过复现示教数据中所蕴含的扫查动态特征来生成实际运动轨迹. 然而, 不同相位处的预测轨迹之间存在一定差异. 在扫查初始阶段, 由于系统获取的观测信息有限, enBIP 所预测的轨迹具有较高的不确定性. 这体现在图 7 中: 棕色、橙色、紫色

表 2 深度网络分割性能指标  
Table 2 Segmentation performance metrics of deep networks

模型	mIoU	Dice	Acc	Spe	Sen	分割延迟 (ms)
UVM-UNet	$0.9529 \pm 0.0041$	$0.9759 \pm 0.0022$	$0.9935 \pm 0.0008$	$0.9963 \pm 0.0004$	$0.9755 \pm 0.0027$	$9.09 \pm 0.30$
UNet	$0.9674 \pm 0.0056$	$0.9834 \pm 0.0029$	$0.9955 \pm 0.0007$	$0.9973 \pm 0.0007$	$0.9846 \pm 0.0014$	$43.04 \pm 0.19$

与绿色曲线在数值上存在较明显偏离. 随着扫查任务推进, 系统累积的观测信息逐渐丰富, 其对自身动态行为的认知不断更新与明确, 从而使 enBIP 在任务中后期生成的预测轨迹逐渐收敛. 在图 7 中, 橙色与紫色曲线相较于棕色曲线的偏离程度减小, 且紫色与橙色曲线几乎重合. 这表明, 当扫查任务进行至中后期阶段, 可适当降低基于 enBIP 的探头

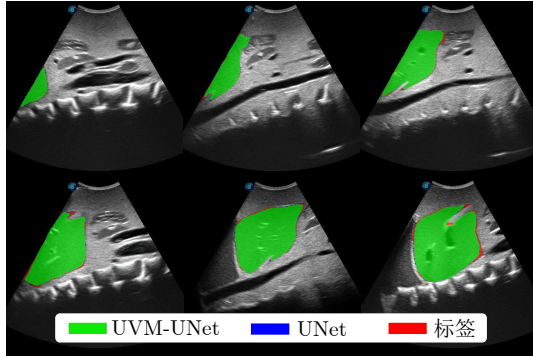


图 5 UVM-UNet 与 UNet 的分割结果

Fig. 5 Segmentation results of UVM-UNet and UNet

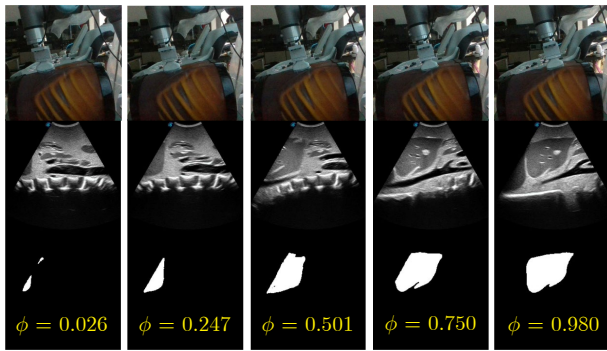


图 6 S2 阶段的扫查过程快照

Fig. 6 Snapshots of the scanning process during the S2 stage

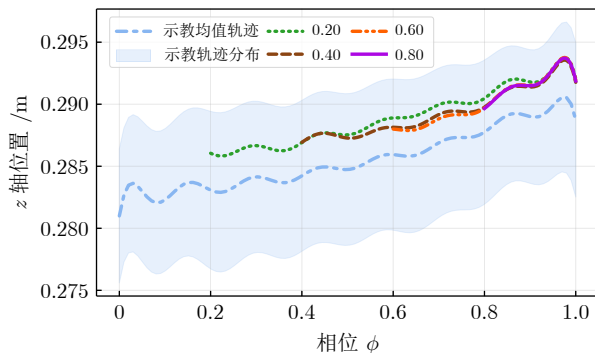


图 7 不同相位下 enBIP 预测的探头  $z$  轴位置轨迹对比

Fig. 7 Comparison of enBIP-predicted probe  $z$ -axis position trajectories at different phases

动作推理频率, 以减轻系统组件间的通信负载, 从而提高整体运行效率. 进一步地, 可基于 enBIP 的预测特性设计相应的事件触发机制, 以改进系统控制逻辑. 然而该方向已超出本文研究范畴, 故不作深入探讨.

### 3.3.2 消融实验分析

为评估系统各状态分量在基于 enBIP 的自主超声扫查任务中的贡献, 本节设计了消融实验. 在保证示教数据、基函数分解机制、潜在状态集合初始化方式及实验超参数一致的前提下, 设计了四种采用不同观测维度的 enBIP 自主扫查策略:

策略 A. 使用全部系统状态作为观测量, 包括图像状态与探头位姿状态;

策略 B. 仅使用探头位姿状态作为观测量;

策略 C. 仅使用图像状态作为观测量;

策略 D. 仅使用图像状态的前三个分量作为观测量, 即肝脏区域的面积及质心坐标.

上述四种自主扫查策略在执行过程中的系统状态及增广时间状态 ( $\phi$  和  $\dot{\phi}$ ) 演化轨迹分别如图 8 和图 9 所示. 从图 8 可见, 在四种控制策略下的图像状态轨迹与探头位姿状态轨迹均落在示教轨迹分布范围内. 然而, 策略 A 与策略 B 所得到的系统状态轨迹在形态上较策略 C 与策略 D 更接近示教轨迹. 图 9 展示了扫查过程中相速度  $\dot{\phi}$  随任务进展的演化轨迹. 可以看出, 策略 A 与策略 B 控制下的  $\dot{\phi}$  轨迹整体波动较小, 对应地, 图 8 中的探头运动轨迹也更为平滑, 表明实际扫查过程中探头抖动较轻, 展现出更优的扫查动态性能. 而在策略 C 与策略 D 的控制下, 由于超声图像本身含有较多噪声与伪影, 加之数字传感器噪声与深度网络模型分割误差的共同作用, 当系统仅以图像状态作为 enBIP 观测量时,  $\dot{\phi}$  更新幅度更为剧烈, 这一点在图 8 中体现为探头运动轨迹存在显著波动. 这表明探头在短时间内运动幅度较大, 可能产生较大的瞬时冲击力, 对患者安全构成潜在风险.

此外, 为进一步对比四种策略的性能差异, 定义了以下四项评价指标:

1) 扫查结束时探头位置的重复性误差  $e_p$ ;

2) 扫查结束时探头姿态的重复性误差  $e_q$ ;

3) 单次成功扫查中 enBIP 的总推理次数;

4) 扫查成功情况, 即多次重复实验中成功完成扫查的次数.

为获取上述指标, 在相同实验条件下, 对四种策略分别重复执行自主超声扫查任务  $J$  次. 记录每次任务结束时 enBIP 的推理次数、探头位置样本  $p_j$  及四元数样本  $q_j$ , 其中  $j \in \{1, 2, \dots, J\}$ . 记位

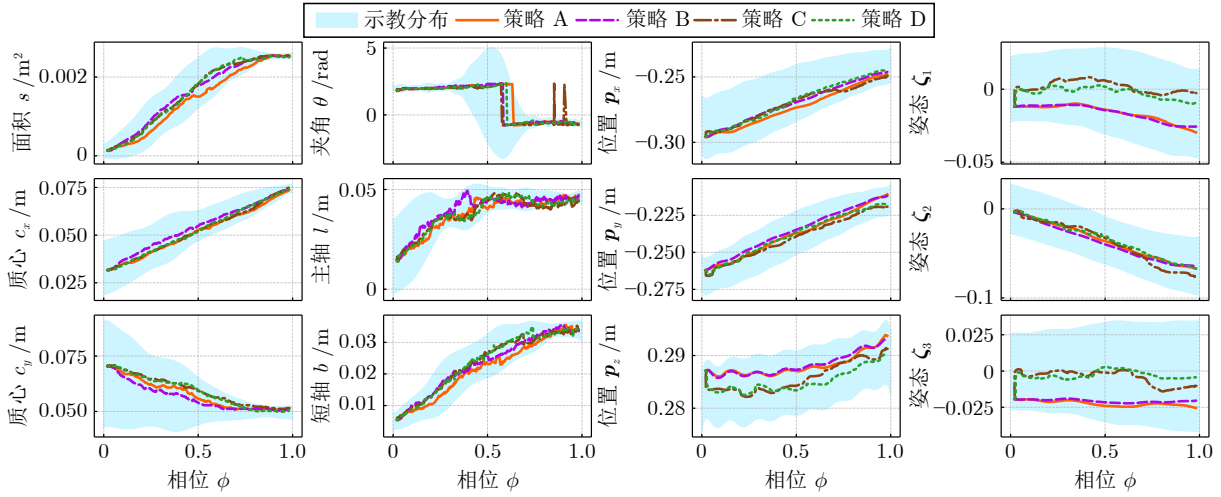


图 8 不同观测维度下系统状态轨迹

Fig. 8 System state trajectories under different observation dimensions

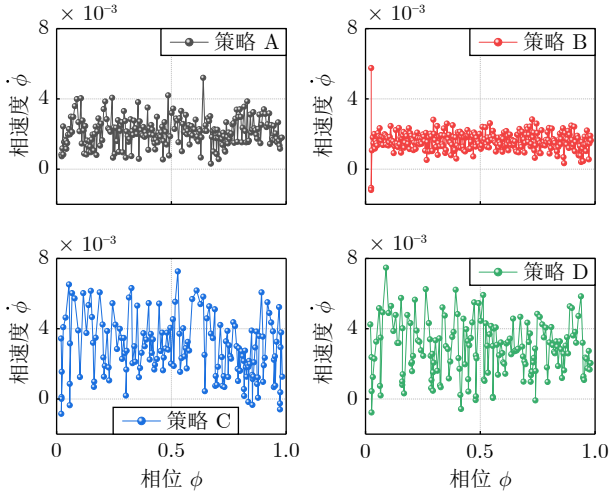


图 9 不同观测维度下系统增广时间状态轨迹

Fig. 9 System augmented temporal state trajectories under different observation dimensions

置样本与四元数样本的均值分别为  $\bar{p}$  和  $\bar{q}$ , 则重复性误差  $e_p$  与  $e_q$  的计算公式如下:

$$e_p = \sqrt{\frac{1}{J-1} \sum_{j=1}^J \|\mathbf{p}_j - \bar{\mathbf{p}}\|^2} \quad (21)$$

$$e_q = \sqrt{\frac{1}{J-1} \sum_{j=1}^J (\vartheta_{\bar{q}}(\mathbf{q}_j))^2} \quad (22)$$

$$\vartheta_{\bar{q}}(\mathbf{q}_j) = \begin{cases} 2\pi, & \mathbf{q}_j * \bar{\mathbf{q}} = [-1, 0, 0, 0]^T \\ 2\|\text{Log}_{\bar{q}}(\mathbf{q}_j)\|, & \text{其他} \end{cases} \quad (23)$$

设定重复实验次数  $J = 10$ , 四种策略下各项评价指标的计算结果如表 3 所示.

表 3 不同扫描策略评价指标对比

Table 3 Comparison of evaluation metrics of different scanning strategies

策略	$e_p$ (m)	$e_q$ (rad)	推理次数	扫描成功情况
A	0.0024	0.0153	244 ± 12	10/10
B	0.0012	0.0091	303 ± 6	10/10
C	0.0046	0.0295	170 ± 13	10/10
D*	0.0041	0.0255	175 ± 26	8/10

注: “\*”表示该策略下的评价指标以 8 个样本计算.


由表 3 可知, 策略 B 控制下系统的重复性误差最小. 其位置误差与姿态误差的数值分别为  $e_p = 0.0012$  m 和  $e_q = 0.0091$  rad. 然而, 该策略所需的推理次数最多, 表明其在实际扫描过程中耗时最长. 相比之下, 仅采用图像状态作为 enBIP 观测测量可显著提升任务执行速度, 仅需  $170 \pm 13$  次推理即可完成扫描. 但该策略的重复性误差较高 ( $e_p = 0.0046$  m 和  $e_q = 0.0295$  rad), 为四种策略中最差. 减少用于 enBIP 观测的图像状态分量数量虽可略微改善重复性误差, 但却会降低扫描任务的成功率, 因而并不可取. 此外, 就算法本身的计算实时性而言, 我们统计了一次成功扫描过程中 enBIP 执行单步推理的平均耗时. 结果显示, 策略 A 到策略 D 的单步耗时分别为  $1.28 \pm 0.19$  ms、 $1.25 \pm 0.22$  ms、 $1.24 \pm 0.10$  ms 和  $1.19 \pm 0.10$  ms. 可以看出, 各策略之间的差异微乎其微, 且均稳定在 1.50 ms 以内. 导致这一现象的原因在于, 本研究采用了如第 2.2.3 节所述的通过“增大观测噪声协方差”而非“降低矩阵维度”的方法来处理消融实验中的模式缺失, 从而保持了推理过程中计算负载的一致性. 由此可见, 前述任务执行速度的差异主要源于收敛所需的

物理迭代步数, 而非算法推理的计算时延. 综合来看, 策略 A(使用全部系统状态作为 enBIP 观测量) 在保持较低重复性误差的同时, 也具备较快的任务执行速度, 是实现性能平衡的较优选择.


### 3.4 全阶段自主扫查实验

基于前文对图像分割网络和 enBIP 方法的分析, 本节通过实验验证了所提完整自主扫查框架(含 S1 与 S2 阶段)的可行性. 设定从 S1 向 S2 阶段切换的阈值条件为  $e_c = 0.025$ , 其对应的对角权重矩阵  $\Omega$  设为单位矩阵. 在系统中引入第 2.3.2 节所述的导纳控制, 以确保探头与体模表面在整个扫查过程中保持稳定的接触力. 导纳参数设置为  $M_a = 2.5$ ,  $D_a = 500$ , 期望接触力设为 14 N.

图 10 展示了一次自主超声扫查过程中完整的系统接触力与探头位置变化曲线. 图中, “S1: 自由运动” 标识表示系统处于 S1 阶段且探头尚未接触



(a) 接触力 (稳态均值:  $13.92 \pm 0.32$  N)  
(a) Contact force (Steady-state mean:  $13.92 \pm 0.32$  N)



(b) 探头位置  
(b) Probe position

图 10 完整扫查过程中接触力与探头位置变化  
Fig. 10 Contact force and probe position variations during the entire scanning process

体模; “S1: 搜索阶段” 标识表示探头已与体模接触, 并正沿规划路径搜索肝脏结构. 当超声图像中出现肝脏结构且图像状态满足阈值条件  $e_c$  时, 系统立即切换至 S2 阶段, 在 enBIP 算法控制下迭代执行动作推理, 直至任务完成. 从图 10(a) 中可见, 当探头与体模建立初始接触时, 导纳控制算法被激活. 在该算法控制下, 探头与体模之间的接触力迅速收敛至期望接触力并保持稳定. 在  $t \geq 44.8$  s 的稳态区间内, 实测接触力为  $13.92 \pm 0.32$  N. 这表明导纳控制能够有效调节探头与体模之间的接触力至期望值, 从而保障扫查过程中的图像质量与患者安全. 值得注意的是, 初始接触时的接触力约为 9 N, 而非 0 N. 导致这一偏差的主要原因在于从 RGB-D 相机中获取的体模表面位置信息与实际值之间存在误差. 图 10(b) 清晰地标识了自主超声扫查过程中系统所处的各任务阶段. 基于本文提出的自主扫查框架, 超声探头从起始点向体模移动, 首先在 S1 阶段规划路径的起点与体模建立接触 (紫色点划线段), 随后沿规划路径搜索肝脏结构 (蓝色实线段). 当超声图像中的肝脏特征满足预设阈值条件时, 系统切换至 S2 阶段. 在此阶段, 系统基于 enBIP 算法引导探头向肝脏目标切面运动, 最终完成扫查任务 (红色点线段).

最后, 本节还验证了第 2.3.1 节所述坐标系变换方法的有效性, 结果如图 11 所示. 实验设置了两个体模位置 A 与位置 B, 其中仅在位置 A 采集示教轨迹并转换至局部坐标系  $\{W\}$ . 在本文所提自主扫查框架下, 系统不仅在位置 A 成功完成了扫查, 在未经示教的新位置 B 亦能复现任务, 验证了方法的适应性. 图 11 展示了两次扫查中的超声图像、分

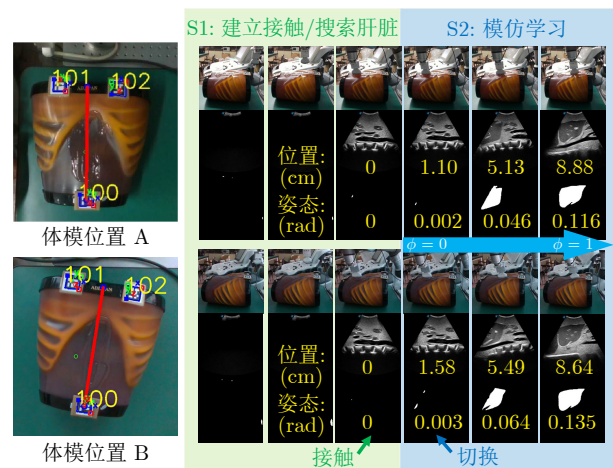


图 11 不同体模位置下的自主扫查过程快照  
Fig. 11 Snapshots of the autonomous scanning process under different phantom placements

割掩模及探头相对于初始接触点的位姿变化. 观察发现, 系统在两个位置上的扫查行为具有高度一致性, 但最终获取的肝脏结构超声图像存在细微差异. 这一结果符合预期, 其原因在于示教数据集本身包含了存在些许差异的有效图像; 同时, 受物理系统初始和运行状态差异的影响, 系统进入 S2 阶段的时刻与位姿不可能完全一致. 因此, enBIP 算法根据当前的观测信息推理出了不同的有效路径, 从而到达了示教分布内的不同目标终点. 这一现象表明, 为在自主扫查过程中获得尽可能一致的超声图像, 在采集示教数据时应尽量使各示教轨迹末端时刻的超声图像保持一致. 总体而言, 该示教数据坐标系变换方法展现出对体模位置变化的良好适应性, 对同一患者的长期疾病监测具有重要意义. 在定期复查的过程中, 患者无需也难以保证每次超声扫查时均处于完全相同的位置.

#### 4 结束语

本文针对人体肝脏超声扫查的自主化难题, 提出一种基于“感知-学习-控制”闭环的 AI 驱动机械臂自主扫查框架. 该框架包含初始定位 (S1) 与模仿学习 (S2) 两个顺序衔接的阶段. 首先, 融合 UVM-UNet 网络、四元数流形空间变换与基函数分解方法, 将医师示教数据构建为潜在空间状态集合; 随后, 通过 S1 阶段的路径规划与切换条件设定, 引导系统建立“探头-患者”初始接触, 并确定 S2 阶段的起始位姿; 进而, 在 S2 阶段利用 enBIP 算法从示教数据中提取专家技能分布, 赋予机械臂一定的认知推理与决策能力, 配合接触力导纳控制与示教数据坐标系变换机制, 实现了对肝脏目标切面的柔顺、精准扫查. 实验结果验证了该框架的可行性以及对患者位置变化的适应性, 为 AI 自动化技术在医疗机器人领域的进一步应用奠定了基础.

尽管本文方法展现了 AI 驱动全自主超声扫查的潜力, 但本研究仍存在一定局限性. 目前的实验验证主要局限于静态环境下的单个体模, 尚未充分量化系统在动态临床环境 (如呼吸运动干扰、患者个体差异) 下的鲁棒性. 未来工作中, 将引入动态环境测试, 进一步验证系统在真实临床场景下的适应能力. 此外, 拟结合高斯混合建模等方法, 将当前的单一切面扫查策略拓展至肝脏其他标准切面.

展望未来, AI 驱动的医疗机器人正朝着与“具身智能”和“基础大模型”深度融合的方向演进. 未来的自主超声系统有望突破单一执行能力的边界, 通过与大模型的语义理解能力结合, 实现涵盖“自主扫查-实时诊断-报告生成”的全流程闭环, 并具

备针对患者个体差异制定个性化诊疗方案的高级智能能力.

#### 参考文献

- 1 Bray F, Laversanne M, Sung H, Ferlay J, Siegel R L, Soerjomataram I, et al. Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*, 2024, **74**(3): 229–263
- 2 Zhou J K, Tian H Z, Wang W, Huang Q H. Fully automated thyroid ultrasound screening utilizing multi-modality image and anatomical prior. *Biomedical Signal Processing and Control*, 2024, **87**(A): Article No. 105430
- 3 Huang Q H, Gao B, Wang M L. Robot-assisted autonomous ultrasound imaging for carotid artery. *IEEE Transactions on Instrumentation and Measurement*, 2024, **73**: Article No. 4003009
- 4 Priester A M, Natarajan S, Culjat M O. Robotic ultrasound systems in medicine. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 2013, **60**(3): 507–523
- 5 Huang Q H, Zhou J K, Li Z J. Review of robot-assisted medical ultrasound imaging systems: Technology and clinical applications. *Neurocomputing*, 2023, **559**: Article No. 126790
- 6 Ma X H, Zeng M J, Hill J C, Hoffmann B, Zhang Z M, Zhang H C K. Guiding the last centimeter: Novel anatomy-aware probe servoing for standardized imaging plane navigation in robotic lung ultrasound. *IEEE Transactions on Automation Science and Engineering*, 2025, **22**: 6569–6580
- 7 Ning G C, Zhang X R, Liao H G. Autonomic robotic ultrasound imaging system based on reinforcement learning. *IEEE Transactions on Biomedical Engineering*, 2021, **68**(9): 2787–2797
- 8 Luo C W, Chen Y H, Cao H Z, Al Sibahee M A, Xu W T, Zhang J. Multi-modal autonomous ultrasound scanning for efficient human-machine fusion interaction. *IEEE Transactions on Automation Science and Engineering*, 2025, **22**: 4712–4723
- 9 Hu Y, Tavakoli M. Autonomous ultrasound scanning towards standard plane using interval interaction probabilistic movement primitives. In: Proceedings of the 2023 IEEE/RSJ International Conference on Intelligent Robots and Systems. Detroit, USA: IEEE, 2023. 3719–3727
- 10 Wang Z H, Shi D H, Yang C G, Si W Y, Li Q C. Autonomous liver ultrasound examination based on imitation learning and stiffness estimation. In: Proceedings of the 2024 IEEE International Conference on Industrial Technology. Bristol, UK: IEEE, 2024. 1–6
- 11 Deng X T, Jiang J N, Cheng W, Yang C G, Li M. Learning freehand ultrasound through multimodal representation and skill adaptation. *IEEE Transactions on Automation Science and Engineering*, 2025, **22**: 5117–5130
- 12 Campbell J, Stepputtis S, Amor H B. Probabilistic multimodal modeling for human-robot interaction tasks. In: Proceedings of the 15th Robotics: Science and Systems. Freiburg im Breisgau, Germany: 2019. 1–9
- 13 Campbell J, Hitzmann A, Stepputtis S, Ikemoto S, Hosoda K, Amor H B. Learning interactive behaviors for musculoskeletal robots using Bayesian Interaction Primitives. In: Proceedings of the 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems. Macao, China: IEEE, 2019. 5071–5078
- 14 Clark G, Amor H B. Learning ergonomic control in human-robot symbiotic walking. *IEEE Transactions on Robotics*, 2023, **39**(1): 327–342
- 15 Huang Q H, Lan J L, Li X L. Robotic arm based automatic ultrasound scanning for three-dimensional imaging. *IEEE Transactions on Industrial Informatics*, 2019, **15**(2): 1173–1182
- 16 Wu R K, Liu Y H, Ning G C, Liang P C, Chang Q. UltraLight VM-UNet: Parallel Vision Mamba significantly reduces parameters for skin lesion segmentation. *Patterns*, 2025, **6**(11): Article No. 101298


- 17 Mustafa A S B, Ishii T, Matsunaga Y, Nakadate R, Ishii H, Ogawa K, et al. Development of robotic system for autonomous liver screening using ultrasound scanning device. In: Proceedings of the 2013 IEEE International Conference on Robotics and Biomimetics. Shenzhen, China: IEEE, 2013. 804–809
- 18 Huang Y L, Abu-Dakka F J, Silvério J, Caldwell D G. Toward orientation learning and adaptation in cartesian space. *IEEE Transactions on Robotics*, 2021, **37**(1): 82–98
- 19 Zeestraten M J A, Havoutis I, Silvério J, Calinon S, Caldwell D G. An approach for imitation learning on Riemannian manifolds. *IEEE Robotics and Automation Letters*, 2017, **2**(3): 1240–1247
- 20 Wang Z W, Zhao B L, Zhang P, Yao L, Wang Q, Li B, et al. Full-coverage path planning and stable interaction control for automated robotic breast ultrasound scanning. *IEEE Transactions on Industrial Electronics*, 2023, **70**(7): 7051–7061
- 21 Jiang Z L, Grimm M, Zhou M C, Hu Y, Esteban J, Navab N. Automatic force-based probe positioning for precise robotic ultrasound acquisition. *IEEE Transactions on Industrial Electronics*, 2021, **68**(11): 11200–11211
- 22 Zhang Li-Jian, Hu Rui-Qin, Yi Wang-Min. Research on force sensing for the end-load of industrial robot based on a 6-axis force/torque sensor. *Acta Automatica Sinica*, 2017, **43**(3): 439–447  
(张立建, 胡瑞钦, 易旺民. 基于六维力传感器的工业机器人末端负载受力感知研究. 自动化学报, 2017, **43**(3): 439–447)
- 23 Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. In: Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich, Germany: Springer, 2015. 234–241



马骥 哈尔滨工业大学航天学院博士研究生. 主要研究方向为医疗机器人智能控制.

E-mail: [23b904055@stu.hit.edu.cn](mailto:23b904055@stu.hit.edu.cn)

(MA Ji Ph.D. candidate at the School of Astronautics, Harbin Institute of Technology. His main research interest is intelligent control of medical robots.)




赵悦 哈尔滨工业大学航天学院教授. 主要研究方向为医学图像处理, 医疗机器人智能控制和超声成像算法. 本文通信作者.

E-mail: [yue.zhao@hit.edu.cn](mailto:yue.zhao@hit.edu.cn)

(ZHAO Yue Professor at the School of Astronautics, Harbin Institute of Technology. Her research interests include medical image processing, intelligent control of medical robots, and ultrasound imaging algorithms. Corresponding author of this paper.)

ponding author of this paper.)



刘壮 哈尔滨工业大学航天学院副研究员. 主要研究方向为自适应控制, 滑模控制和机器人系统.

E-mail: [zliu@hit.edu.cn](mailto:zliu@hit.edu.cn)


(LIU Zhuang Associate research fellow at the School of Astronautics, Harbin Institute of Technology. His research interests include adaptive control, sliding mode control, and robot system.)



胡悦 哈尔滨工业大学电子与信息工程学院教授. 主要研究方向为医学图像处理, 计算磁共振成像和磁共振指纹成像.

E-mail: [huyue@hit.edu.cn](mailto:huyue@hit.edu.cn)

(HU Yue Professor at the School of Electronics and Information Engineering, Harbin Institute of Technology. Her research interests include medical image processing, computational magnetic resonance imaging, and magnetic resonance fingerprinting.)



刘健行 哈尔滨工业大学航天学院教授. 主要研究方向为滑模控制, 非线性控制和工业电子.

E-mail: [jx.liu@hit.edu.cn](mailto:jx.liu@hit.edu.cn)

(LIU Jian-Xing Professor at the School of Astronautics, Harbin Institute of Technology. His research interests include sliding mode control, nonlinear control, and industrial electronics.)



沈毅 哈尔滨工业大学航天学院教授. 主要研究方向为仪器仪表与测量, 超声信号处理和现代检测技术.

E-mail: [shen@hit.edu.cn](mailto:shen@hit.edu.cn)

(SHEN Yi Professor at the School of Astronautics, Harbin Institute of Technology. His research interests include instrumentation and measurement, ultrasound signal processing, and modern detection techniques.)