



## 融合形态特征的基于GRU的介入机器人导丝轨迹预测建模

张任飞 董林杰 王兴松 田梦倩 苏浩波

### GRU-based Modeling for Predicting Guidewire Trajectories in Interventional Robotics With Morphological Feature Fusion

ZHANG Ren-Fei, DONG Lin-Jie, WANG Xing-Song, TIAN Meng-Qian, SU Hao-Bo

在线阅读 View online: <https://doi.org/10.16383/j.aas.c250506>

---

## 您可能感兴趣的其他文章

### 基于残差的门控循环单元

Residual Based Gated Recurrent Unit

自动化学报. 2022, 48(12): 3067–3074 <https://doi.org/10.16383/j.aas.c190591>

### 基于高仿生形态布局的仿鸽扑翼飞行机器人系统设计

System Design of Dove-like Flapping-wing Flying Robot Based on Highly Bionic Morphological Layout

自动化学报. 2024, 50(2): 308–319 <https://doi.org/10.16383/j.aas.c220836>

### 机器人运动轨迹的模仿学习综述

On Imitation Learning of Robot Movement Trajectories: A Survey

自动化学报. 2022, 48(2): 315–334 <https://doi.org/10.16383/j.aas.c210033>

### 基于语言视觉对比学习的多模态视频行为识别方法

Multi-modal Video Action Recognition Method Based on Language-visual Contrastive Learning

自动化学报. 2024, 50(2): 417–430 <https://doi.org/10.16383/j.aas.c230159>

### 基于多维度特征融合的云 workflow 任务执行时间预测方法

Multi-dimensional Feature Fusion-based Runtime Prediction Approach for Cloud Workflow Tasks

自动化学报. 2023, 49(1): 67–78 <https://doi.org/10.16383/j.aas.c210123>

### 双向建模增强TKAN和全局注意力机制融合的滚动轴承剩余寿命预测

Bidirectional Modeling-enhanced TKAN and Global Attention Mechanism Fusion for Rolling Bearing Remaining Useful Life Prediction

自动化学报. 2025, 51(8): 1857–1868 <https://doi.org/10.16383/j.aas.c250064>

# 融合形态特征的基于 GRU 的介入机器人导丝轨迹预测建模

张任飞<sup>1</sup> 董林杰<sup>1</sup> 王兴松<sup>1</sup> 田梦倩<sup>1</sup> 苏浩波<sup>2</sup>

**摘要** 针对介入导航场景中的导丝轨迹重建问题, 提出一种保持因果性的序列估计方法. 不同于通用循环基线模型, 所提方法将序列级常量特征 (包括导丝刚度、进入角度和有效摩擦描述符) 按时间步广播, 与动态几何量 (中心线坐标、直径等) 拼接, 经两层特征编码后由单向门控循环单元解码器逐时输出二维坐标. 为处理变长序列, 本文采用时间步长分类的训练策略, 并结合掩码损失函数, 以抑制填充引入的无效梯度, 在不改变网络结构的前提下提升训练与推理效率. 基于覆盖多类导丝与多进入角度的仿体实验平台, 所提方法在保持因果性的同时, 实现 0.40 ~ 0.54 mm 的位置误差范围 (平均误差为 0.46 mm); 相较于未采用时间步分类策略的基线模型, 收敛 epoch 降低 42%, 训练时间降低 52%, 单次推理时延降低 51%. 结果表明, 该方法可为导丝轨迹估计与术中导航提供可部署的算法基础.

**关键词** 介入机器人; 导丝轨迹预测; 门控循环单元; 形态特征融合; 时序建模

**引用格式** 张任飞, 董林杰, 王兴松, 田梦倩, 苏浩波. 融合形态特征的基于 GRU 的介入机器人导丝轨迹预测建模. 自动化学报, 2026, 52(3): 430-440

**DOI** 10.16383/j.aas.c250506 **CSTR** 32138.14.j.aas.c250506

## GRU-based Modeling for Predicting Guidewire Trajectories in Interventional Robotics With Morphological Feature Fusion

ZHANG Ren-Fei<sup>1</sup> DONG Lin-Jie<sup>1</sup> WANG Xing-Song<sup>1</sup> TIAN Meng-Qian<sup>1</sup> SU Hao-Bo<sup>2</sup>

**Abstract** We present a causality-preserving sequential estimator for guidewire trajectory reconstruction during interventional navigation. Unlike generic recurrent baselines, the proposed model time-broadcasts sequence-level constants (including guidewire stiffness, insertion angle, and an effective friction descriptor) and concatenates them with dynamic geometric tokens (centerline coordinates and local diameter) before a two-stage feature encoder and a unidirectional gated recurrent unit decoder that emits 2D positions stepwise. To cope with variable sequence lengths, we adopt a time-step length classification training strategy with mask-based loss function, which limits padding-induced invalid gradients and improves training and inference efficiency without altering the network architecture. On a phantom platform covering multiple guidewire types and insertion angles, the method achieves a 0.40 ~ 0.54 mm position-error range (mean 0.46 mm) while preserving strict causality; relative to a baseline without the time-step classification strategy, it reduces epochs-to-convergence by 42%, training time by 52%, and per-inference latency by 51%. These results indicate a deployable, real-time basis for guidewire trajectory estimation and intraoperative navigation.

**Keywords** interventional robotics; guidewire trajectory prediction; gated recurrent unit; morphological feature fusion; sequential modeling

**Citation** Zhang Ren-Fei, Dong Lin-Jie, Wang Xing-Song, Tian Meng-Qian, Su Hao-Bo. GRU-based modeling for predicting guidewire trajectories in interventional robotics with morphological feature fusion. *Acta Automatica Sinica*, 2026, 52(3): 430-440

在血管介入手术过程中, 导丝的引导路径直接关系到术中导航的精度与手术的安全性<sup>[1-2]</sup>. 即使是

经验丰富的术者, 在面对解剖结构复杂、血管走行不规则、视野信息受限的条件下, 仍可能面临操作困难与路径判断偏差<sup>[3]</sup>. 当前越来越多的研究致力于借助计算辅助技术实现导丝路径的建模与预测, 以提升术中操作的智能化水平, 尤其是在柔性器械广泛应用的介入机器人系统中<sup>[4-6]</sup>, 对导丝行为的感知与预判成为智能引导的重要基础<sup>[7-8]</sup>.

与刚性手术器械不同, 导丝作为一种被动柔性工具, 其在体内的运动轨迹受到本体刚度、摩擦力、血管形态等多种因素的耦合影响, 具有高度非线性

收稿日期 2025-09-29 录用日期 2025-12-19

Manuscript received September 29, 2025; accepted December 19, 2025

国家自然科学基金 (52175005) 资助

Supported by National Natural Science Foundation of China (52175005)

本文责任编辑 程龙

Recommended by Associate Editor CHENG Long

1. 东南大学机械工程学院 南京 211189 2. 南京市第一医院介入血管科 南京 210006

1. School of Mechanical Engineering, Southeast University, Nanjing 211189 2. Department of Interventional and Vascular Radiology, Nanjing First Hospital, Nanjing 210006

与动态性<sup>[9]</sup>. 在实际手术中, 术者无法实时掌握完整的血管结构信息, 常通过断续造影获取局部二维图像, 仅能观察导丝在局部血管区域内的行为<sup>[10]</sup>. 在传统介入手术中, 操作人员通过观察影像来确定手术路径, 如图 1(a) 所示. 介入机器人采用传统治疗中导丝、导管相互配合的前进方式, 导丝提供引导, 细长机器人提供锚点, 如图 1(b) 所示, 可以更灵活地通过规划好的路径. 图 1(c) 显示了手术进行时人体内的导丝. 该类系统可称为细长机器人辅助引导系统, 如图 1(d) 所示.

细长机器人的控制与血管形态测量已有一些研究<sup>[11-13]</sup>. 目前, 前期工作已研制一种直径为 3 mm 的细长机器人用于介入手术应用. 因此, 建立一种能够在实时视觉反馈不完整的条件下仍能稳定应对柔性导丝高度非线性行为的形状预测机制, 对于增强介入式机器人在复杂血管结构中导航的能力具有关键意义.

传统方法如有限元建模可对柔性导丝进行力学仿真分析, 但难以满足实时性要求, 且对结构建模与参数设定依赖性<sup>[14]</sup>. 在已开展的研究中, 部分工作尝试对导丝头部轨迹进行控制或跟踪, 然而导丝头部轨迹与整体轨迹存在差异, 其预测结果无法

准确反映术中实际推进的导丝的完整走形<sup>[15]</sup>. 近年来, 深度学习在处理复杂非线性时空建模任务中的优势日益显现<sup>[16-17]</sup>, 尤其在序列建模领域, 循环神经网络在处理柔性器械的轨迹推理任务中展现出良好的学习能力与泛化性能<sup>[18]</sup>.

为解决上述问题, 本文提出一种基于多特征融合的 GRU (gated recurrent unit) 序列预测方法, 用于建模介入机器人系统中导丝引导器的二维整体轨迹. 该方法以导丝物理参数、血管形态特征与环境摩擦因素为输入, 输出不同时间步下导丝整体的连续坐标序列. 考虑到导丝轨迹长度变化较大, 本文设计一种基于时间步长的训练分类策略, 以提升模型在不同序列条件下的稳定性与收敛效率. 此外, 本文构建了完整的用户实验平台, 对模型在实际插入条件下的轨迹一致性与误差分布进行定量与可视化验证, 进一步评估所提方法的部署可行性与泛化能力.

本文的主要贡献如下:

- 1) 提出一种融合形态特征测量的多特征 GRU 预测模型, 用于介入机器人中引导器的整体轨迹建模任务, 具备可变时间步输入与连续轨迹输出能力.
- 2) 设计时间步分类训练机制, 解决不同序列长

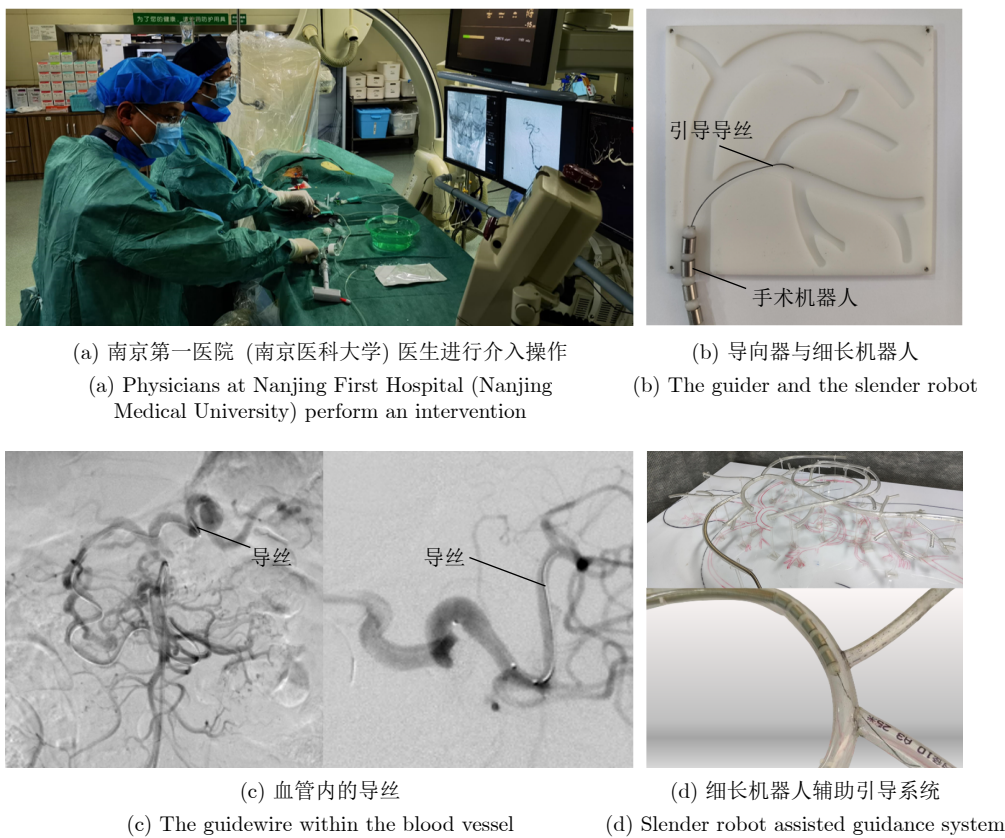


图 1 血管内介入与细长机器人辅助引导系统

Fig.1 Endovascular intervention and slender robot assisted guidance system

度带来的训练不稳定问题。

3) 在统一评测协议下, 报告训练开销与在线推理时延, 并以误差的最小值/均值/最大值等统计系统评估精度与稳定性. 结果从实时性与准确性两方面验证模型的实际预测能力与部署价值, 为柔性导丝智能引导与术中导航系统设计提供关键算法支持.

## 1 相关工作

### 1.1 导丝路径规划算法

路径规划是介入手术中支持导丝导航的关键技术, 早期方法多基于图搜索与采样策略, 在血管中心线基础上构建推进路径<sup>[10]</sup>. 然而, 这些工作没有考虑任何控制导管运动的运动学约束. 为增强模型的物理适应性, Qi 等<sup>[19]</sup>将路径规划表述为连续体机器人逆运动学下的优化问题, 但多采用局部解法, 未能考虑全局路径的长期代价. Li 等<sup>[20]</sup>引入曲率约束, 如利用局部遗传算法规划导丝路径, 提升了解剖匹配性, 但对血管模型的变形高度敏感. Gao 等<sup>[21]</sup>改进的蚁群算法则综合考虑了血管几何特征与导丝结构参数, 虽然路径更具合理性, 但算法开销大, 难以满足实时应用需求. 部分工作进一步引入深度强化学习策略, 通过模拟环境中训练智能代理实现策略学习, 有效提升了规划效率与泛化能力<sup>[22]</sup>. Kweon 等<sup>[23]</sup>将路径规划框架与图像引导技术相结合, 实现了在术中图像指导下导丝的自主导航.

尽管现有路径规划算法在导丝头部导航方面取得了一定成果, 但多数方法假设导丝能沿血管中心线顺利推进, 忽略了其在体内因柔性、摩擦等因素导致的复杂形变行为. 在高曲率或强接触等场景约束下, 其形变拟合误差或稳定性会显著波动, 性能对任务设定较为敏感. 真实术中导丝常贴附血管壁推进, 其整体形状与头部轨迹存在显著差异, 单纯依赖尖端路径规划难以反映回弹、滞留等局部形态问题.

### 1.2 导丝形状模拟算法

针对路径规划方法难以反映导丝整体形态的局限, 研究者逐步将关注焦点转向导丝全局形状的模拟. 早期研究主要采用基于物理建模的方法, 如有限元分析 (FEM)<sup>[24]</sup>与 Cosserat 梁模型<sup>[25]</sup>. 尽管这类方法具有较强的理论基础和建模解释力, 但受限于复杂的非线性微分方程求解, 计算效率低. 在需要快速决策的临床场景中, 其实际部署能力受限.

Schafer 等<sup>[26]</sup>首次提出一种基于图搜索的能量最小化导丝形状估计方法. 通过将血管划分为网格点并创建相应的图来识别最低能量路径, 从而对导

丝的形状进行模拟. Qiu 等<sup>[27]</sup>和 Li 等<sup>[28]</sup>也对此类方法做了大量工作, 并在能量方程、网格生成方法和图搜索技术等方面进行了显著改进. 这类方法大大降低了计算成本, 但由于其未能建模血管形态对导丝形变的影响, 导致预测结果仅具有几何平滑性, 难以反映真实推进过程中的物理行为特征. 同时, 不同范式在建模精度、计算开销与部署条件之间呈现可观察的权衡, 具体表现取决于数据形态与实现假设. 这些局限促使研究者逐步转向以数据驱动为核心的深度学习方法, 通过大规模数据学习导丝的形态分布规律, 以期实现更强的表达能力与更优的预测效率.

### 1.3 基于深度学习的导丝轨迹预测

近年来, 深度学习在导丝形状建模方向取得了显著进展. 一类代表性方法是基于深度学习对导丝图像或其显式表示进行回归建模, 通过从术中二维或三维图像中提取导丝结构信息, 重建中心线<sup>[29]</sup>. 这类方法具有良好的图像特征提取能力, 适合应用于实时图像引导的辅助操作中, 但其高度依赖图像质量与清晰度. 另一类研究采用深度学习与传感器结合的方式感知形状<sup>[30]</sup>, 该类方法不依赖图像输入, 但通常需要修改或定制标准导丝, 大大提高了成本和整合难度<sup>[31]</sup>. 且上述方法都无法预测导丝的未来走向.

Kuntz 等<sup>[32]</sup>通过深度神经网络构建了同轴管机器人的无传感形状学习模型, 可以预测完整的机器人轨迹序列, 但其忽略了本体参数、接触状态与环境干扰等关键影响因素, 且对血管形态特征的显式提取与量化尚不充分. 另一方面, 现有方法未针对不同长度的导丝轨迹序列在训练过程中的稳定性问题进行系统优化, 容易在训练过程中出现梯度震荡或收敛缓慢等现象, 影响最终模型的实用性与部署效率.

基于上述不足, 本文提出一种融合形态特征测量的多特征 GRU 预测模型, 用于建模介入机器人中导丝引导器的连续形变轨迹. 通过特征设计与训练机制优化, 本方法实现了对导丝行为的高效、鲁棒建模, 并具备在介入手术机器人系统中实时部署的潜力.

## 2 融合形态特征的 GRU 预测网络建模

### 2.1 问题定义

#### 2.1.1 研究目标

本研究旨在构建一种基于门控循环单元 GRU 的导丝二维形状预测模型, 用于辅助介入手术中导

丝的路径规划、形态预测和接触力估计. 该模型基于图像提取的导丝与血管几何结构特征以及时间序列输入, 实现导丝在图像坐标系中的未来形状预测, 如图 2 所示. 相较于有限元法等高计算量方法, 本方法具有实时性强、推理效率高的优势, 适用于术前模拟、术中导航等场景.

模型输入为导丝时间序列特征矩阵  $\mathbf{X}$ :

$$\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T\}, \mathbf{X} \in \mathbf{R}^{T \times d} \quad (1)$$

其中  $T$  表示时间步数;  $d = 9$  表示每个时间步的特征维度, 涵盖血管形态 (迂曲度、弯曲角度)、导丝参数 (直径、刚度)、环境参数 (进入角度、摩擦系数)、血管直径序列及中心线坐标.

目标输出为代表导丝形状的二维坐标序列:

$$\hat{\mathbf{Y}} = [\hat{\mathbf{y}}_1, \hat{\mathbf{y}}_2, \dots, \hat{\mathbf{y}}_T], \hat{\mathbf{y}}_t \in \mathbf{R}^2 \quad (2)$$

其中每个  $\hat{\mathbf{y}}_t$  为图像平面上的导丝位置坐标.

本研究的目标是学习从输入序列到输出坐标的

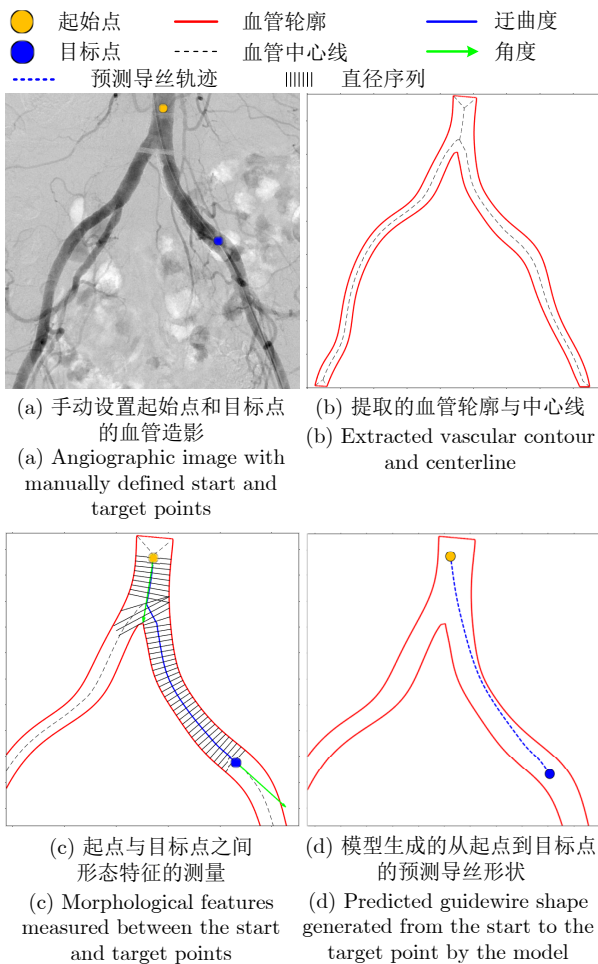


图 2 导丝形状预测流程示意图

Fig. 2 Schematic illustration of the guidewire shape prediction pipeline

映射函数:

$$\mathcal{F}: \mathbf{X} \rightarrow \hat{\mathbf{Y}} \quad (3)$$

### 2.1.2 假设与条件

1) 全局血管形态是已知的, 这可以通过实际血管介入中的血管造影获得, 如图 2(a) 所示, 导丝插入任务的起始点和目标点手动设置. 血管的轮廓和中心线被提取出来, 供后续测量形态特征使用, 如图 2(b) 所示. 在局部图像中, 可以测量从起始点到目标点之间的形态特征, 并通过预测模型获得导丝整体轨迹, 如图 2(c) 和 2(d) 所示. 在短时观测窗口内, 临床影像重建的中心线与直径可作为准静态几何先验输入.

2) 尽管三维解剖图像的完整性更好, 但具有良好实时性能的二维 DSA (digital subtraction angiography) 图像仍然是血管介入手术决策的金标准. 为了匹配当前的手术模式和习惯, 此处使用二维图像完成血管形态特征的测量.

3) 由于导丝的推进速度在  $1 \sim 3$  mm/s 之间, 本研究把导丝的运动看作准静态过程, 因此血液对导丝形状的影响可以忽略. 同时, 血液对导丝接触产生的影响体现在摩擦系数中, 在模型输入中已考虑这部分因素, 所以实际实验中模型并未添加液体. 摩擦系数通过稳态牵引试验完成一次性标定, 并结合厂商技术资料进行范围校核. 其临床迁移可通过少量条件标定完成, 与网络结构与训练流程解耦.

4) 由于更复杂的模型成本较高, 且在实际组织中测试还为时过早, 因此使用手动设计的刚性血管模型 (根据人体解剖结构和医学训练模型) 进行训练样本收集和算法测试, 具体细节详见第 2.3 节.

## 2.2 网络结构设计

鉴于本研究任务是术中导丝整体轨迹预测, 其输入为一段时间内的导丝参数、中心线几何及环境状态等特征, 目标是基于当前和历史信息生成导丝的完整二维形状. 因此, 该问题本质上属于单向的时间序列预测任务, 不能借助未来信息进行推理. 为满足术中实时性和因果性要求, 本文采用单向 GRU 网络结构, 避免模型在推理过程中依赖未来帧信息, 从而确保结构适配实际临床使用需求. 本文提出的导丝姿态预测模型采用典型的“特征提取-时序建模-输出回归”结构, 包含两层全连接层、一组堆叠式 GRU 单元及一层输出层, 如图 3 所示.

### 2.2.1 特征提取与预处理

首先提取并量化多个关键特征, 包括弯曲角度、迂曲度等. 这些特征组成结构化向量  $\mathbf{f}$ , 与直径序

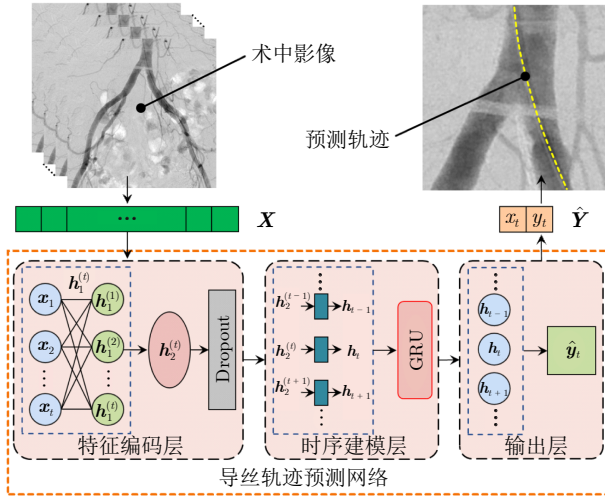


图 3 基于 GRU 的导丝整体轨迹预测模型

Fig.3 GRU-based model for whole guidewire trajectory prediction

列  $d_t$  和中心线坐标  $(x_t, y_t)$  拼接后构成模型每个时间步输入向量:

$$\mathbf{x}_t = [\mathbf{f}, d_t, x_t, y_t] \in \mathbf{R}^9 \quad (4)$$

最终输入矩阵为:

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T] \in \mathbf{R}^{T \times 9} \quad (5)$$

### 2.2.2 特征编码层

每个时间步的输入特征  $\mathbf{x}_t$  首先通过两层非线性全连接网络进行升维:

$$\mathbf{h}_1^{(t)} = \text{ReLU}(\mathbf{W}_1 \mathbf{x}_t + \mathbf{b}_1) \quad (6)$$

$$\mathbf{h}_2^{(t)} = \text{ReLU}(\mathbf{W}_2 \mathbf{h}_1^{(t)} + \mathbf{b}_2) \quad (7)$$

其中,  $\mathbf{h}_1^{(t)}$ 、 $\mathbf{h}_2^{(t)}$  为第  $t$  个时间步经两层全连接网络变换后的中间特征向量;  $\mathbf{W}_1$ 、 $\mathbf{W}_2$  为两层全连接网络的权重矩阵;  $\mathbf{b}_1$ 、 $\mathbf{b}_2$  为对应的偏置向量.

再经 Dropout 层防止过拟合, 得到输入序列特征张量:

$$\mathbf{H} = [\mathbf{h}_2^{(1)}, \dots, \mathbf{h}_2^{(T)}] \in \mathbf{R}^{T \times 64} \quad (8)$$

### 2.2.3 时序建模层

将特征序列输入双层 GRU 网络进行建模, 获得每个时间步的隐藏状态:

$$\mathbf{h}_t = \text{GRU}(\tilde{\mathbf{h}}_t, \mathbf{h}_{t-1}) \quad (9)$$

其中,  $\tilde{\mathbf{h}}_t$  为输入到 GRU 单元的第  $t$  个时间步特征向量 (由  $\mathbf{H}$  中对应时间步的特征提供);  $\mathbf{h}_t$  为 GRU 在第  $t$  个时间步输出的隐藏状态向量;  $\mathbf{h}_{t-1}$  为上一时间步的隐藏状态.

得到的输出序列为:

$$\mathbf{H}_{\text{GRU}} = [\mathbf{h}_1, \dots, \mathbf{h}_T] \in \mathbf{R}^{T \times 64} \quad (10)$$

### 2.2.4 输出层

每个时间步的隐藏状态向量映射为二维坐标点:

$$\hat{\mathbf{y}}_t = \mathbf{W}_{\text{out}} \cdot \mathbf{h}_t + \mathbf{b}_{\text{out}} \quad (11)$$

其中,  $\mathbf{W}_{\text{out}}$ 、 $\mathbf{b}_{\text{out}}$  分别为输出层的权重矩阵和偏置向量.

最终输出序列为:

$$\hat{\mathbf{Y}} = [\hat{\mathbf{y}}_1, \hat{\mathbf{y}}_2, \dots, \hat{\mathbf{y}}_T] \quad (12)$$

## 2.3 形态特征提取与数据收集

为增强模型对导丝与血管结构之间几何关系的建模能力, 本文设计了一个基于图像分析的形态特征提取与测量模块, 该模块不依赖医学图像语义分割, 而是通过边缘检测、骨架提取、多段路径排序与中心线重建等手段获得血管的结构轮廓与中心路径, 并测量从起始点到目标点之间的血管形态特征. 为统一不同采集源的尺度, 首先依据影像标定将像素坐标转换为物理尺度 (mm), 随后在中心线坐标上执行固定步长的等弧长重采样, 并在计算曲率、迂曲度等形态量前进行平滑、样条拟合以抑制量化误差与高频噪声. 图 4 给出了形态特征测量模块在血管结构上的应用示例, 展示了其工作界面与几种典型参数测量结果. 所有形态特征被编码为每步输入特征  $\mathbf{x}_t$  的组成部分.




图 4 血管结构的形态特征测量结果示意图

Fig.4 Illustration of morphological feature measurements results for vascular structures

受伦理的约束, 从临床环境中获取大规模训练数据在实践中存在较大困难. 为此, 本文构建了一套专用于训练与验证导丝形状预测模型的实验室数据采集平台. 该平台由血管模型、医用导丝、工业相机以及导丝稳定装置等模块组成, 能够在可控条件下持续采集高分辨率图像, 并对血管结构、中心线轨迹以及导丝形状等关键参数进行精确测量.

在统一实验平台(刚性)与单次插入任务的观测时窗内, 血管中心线与直径保持稳定, 因而被视作准静态几何先验并在各时间步输入到时序模型. 为保证样本多样性, 实验设计共使用了 3 种不同结构形态的血管模型, 其中两种用于模型训练, 另一种专用于后续的用户实验. 此外, 选用 8 种具有不同刚度和直径的导丝, 在 7 种不同的进入角度下分别进行插入操作. 该实验平台同时承担用户实验功能, 其具体装置构成与实验流程将在第 3.1 节中详细说明.

每一次导丝插入操作被定义为一个完整的演示, 每段演示轨迹大约采集 20 个时间步的数据. 每个时间步构成一个样本, 包含 11 维输入特征, 包括导丝参数、血管形态、中心线坐标以及当前导丝形状. 最终共采集 112 个演示样本 (7 角度  $\times$  8 导丝  $\times$  2 模型), 删除不合格样本后, 构建出一个包含 2000 个样本的数据集. 其中, 1600 个样本用于训练, 400 个样本用于验证.

需要注意的是, 在导丝插入过程中采样的时间步数量存在变动, 不同样本的序列长度并不一致. 时间步的差异可能导致固定批次训练中出现样本丢弃或无效填充等问题. 为兼顾训练效率与数据利用率, 同时准确模拟临床环境下导丝推进时间的个体差异, 本文在模型训练阶段引入了基于时间步长的样本分类与变长序列处理机制, 具体策略详见第 2.4.2 节.

## 2.4 模型训练与推理过程

### 2.4.1 输入构建与标准化

每个时间步的原始输入向量由序列级常量  $\mathbf{f}$  (迂曲度、弯曲角度、导丝直径、刚度、进入角度、摩擦系数) 和动态几何量 (直径  $d_t$ 、中心线坐标  $(x_t, y_t)$ ) 构成, 维度为 9. 将  $\mathbf{f}$  在时间维度上复制  $T$  次, 并与动态特征拼接后形成:

$$\mathbf{x}_t = [\mathbf{f}, d_t, x_t, y_t] \in \mathbf{R}^9 \quad (13)$$

所有几何量均在物理尺度 (mm) 下计算, 并在等弧长重采样与平滑后加入特征向量, 随后按式 (14) 进行标准化. 其中, 摩擦系数 (见第 2.1.2 节) 由“导丝-介质”材料组合一次性标定获得, 标准化后在序列内按时间步广播并与动态几何量拼接.

对前 6 维特征进行标准化:

$$\tilde{x}_t^{(j)} = \frac{x_t^{(j)} - \mu_j}{\sigma_j}, \quad j = 1, 2, \dots, 6 \quad (14)$$

其中,  $x_t^{(j)}$  为第  $t$  个时间步的第  $j$  维原始特征值;  $\mu_j$  为第  $j$  维特征在训练集上的均值;  $\sigma_j$  为第  $j$  维特征在训练集上的标准差;  $\tilde{x}_t^{(j)}$  为经均值-标准差归一化后的第  $t$  个时间步第  $j$  维标准化特征.

拼接标准化特征和原始几何特征后构成最终输入张量:

$$\tilde{\mathbf{X}}_{\text{tensor}} \in \mathbf{R}^{1 \times T \times 9} \quad (15)$$

### 2.4.2 模型训练方法

#### 1) 训练流程与损失函数设计

以导丝坐标序列的均方误差 (mean squared error, MSE) 作为损失函数:

$$\mathcal{L}_{\text{MSE}} = \frac{1}{T} \sum_{t=1}^T \|\hat{\mathbf{y}}_t - \mathbf{y}_t\|_2^2 \quad (16)$$

训练使用 Adam 优化器, 参数更新如下:

$$\theta_{t+1} = \theta_t - \eta \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (17)$$

其中,  $\theta_t$  为第  $t$  次迭代时的模型参数;  $\eta$  为学习率;  $\hat{m}_t$  为 Adam 中梯度一阶矩 (动量) 的偏差校正估计;  $\hat{v}_t$  为 Adam 中梯度二阶矩 (平方梯度均值) 的偏差校正估计;  $\epsilon$  为防止分母为零的数值稳定项常数.

初始学习率设置为  $\eta = 5 \times 10^{-4}$ , 当验证损失停滞时触发学习率衰减:

$$\eta_{\text{new}} = \gamma \cdot \eta_{\text{old}}, \quad \gamma = 0.5 \quad (18)$$

其中  $\eta_{\text{new}}$  表示衰减后学习率,  $\eta_{\text{old}}$  表示衰减前学习率.

引入早停机制, 当验证集损失在连续 10 个 epoch 内无明显下降时提前终止训练.

#### 2) 基于时间步长的样本划分与掩码优化

本文在模型训练阶段引入了基于时间步长的样本分类与变长序列处理机制, 以提升模型在训练过程中的稳定性与泛化能力, 支持多样化的数据结构输入.

本文根据时间步数将样本划分为短序列  $\mathcal{S}_{\text{short}}$  与长序列  $\mathcal{S}_{\text{long}}$ , 并分别设定训练批量大小 Batch size. 记时间步阈值为  $T_{\text{thresh}}$ , 分类与批量配置如下:

$$\begin{cases} \mathcal{S}_{\text{short}} = \left\{ \mathbf{X}^{(i)} \mid T^{(i)} \leq T_{\text{thresh}} \right\}, \\ \quad \text{Batch size} = m \\ \mathcal{S}_{\text{long}} = \left\{ \mathbf{X}^{(i)} \mid T^{(i)} > T_{\text{thresh}} \right\}, \\ \quad \text{Batch size} = n \end{cases} \quad (19)$$

其中,  $m, n$  分别为短序列组与长序列组对应的训练批量大小.

在构造数据加载器时, 先按时间步数  $T$  对数据进行升序排序. 设第  $i$  个批次包含  $N$  个样本, 其各自时间步为  $T_1^{(i)}, T_2^{(i)}, \dots, T_N^{(i)}$ , 该批次的最大时间步定义为:

$$T_{\max}^{(i)} = \max(T_1^{(i)}, T_2^{(i)}, \dots, T_N^{(i)}) \quad (20)$$

对该批次中的所有样本统一填充至长度  $T_{\max}^{(i)}$ , 可构造输入张量如下:

$$\mathbf{X}^{(i)} \in \mathbf{R}^{N \times T_{\max}^{(i)} \times d} \quad (21)$$

其中,  $d$  表示每步的输入特征维度.

为保证训练过程中仅在真实时间步上进行有效学习, 引入掩码张量  $M^{(i)} \in \{0, 1\}^{N \times T_{\max}^{(i)}}$ , 其第  $n$  行第  $t$  列元素定义为:

$$M_{n,t}^{(i)} = \begin{cases} 1, & t \leq T_n^{(i)} \\ 0, & t > T_n^{(i)} \end{cases} \quad (22)$$

最终, 在损失函数计算过程中仅对有效时间步进行误差累积, 定义如下:

$$\mathcal{L}_{\text{masked}} = \frac{\sum_{i=1}^N \sum_{j=1}^{T_{\max}^{(i)}} M_{i,j} (\hat{y}_{ij} - y_{ij})^2}{\sum_{i=1}^N \sum_{j=1}^{T_{\max}^{(i)}} M_{i,j}} \quad (23)$$

其中,  $M_{i,j}$  表示掩码张量  $M$  在第  $i$  个样本、第  $j$  个时间步的元素;  $\hat{y}_{ij}$  和  $y_{ij}$  分别表示第  $i$  个样本、第  $j$  个时间步的预测输出与真实输出.

该机制可有效避免填充值参与梯度计算所带来的噪声, 从而提升模型的收敛速度与训练稳定性.

### 2.4.3 推理过程与输出生成

模型训练完成后加载最优参数, 并进入推理模式. 输入特征包括标准化后的导丝参数、局部直径序列及中心线坐标, 拼接成三维张量:

$$\tilde{\mathbf{X}}_{\text{tensor}} \in \mathbf{R}^{1 \times T \times 9} \quad (24)$$

$\mathcal{M}_{\text{trained}}(\cdot)$  为训练完成并固定参数的导丝形状预测模型, 输入模型进行预测:

$$\hat{\mathbf{Y}} = \mathcal{M}_{\text{trained}}(\tilde{\mathbf{X}}_{\text{tensor}}, \text{lengths} = T) \quad (25)$$

输出为导丝尖端在图像平面中的轨迹序列,  $\hat{x}_t$ 、 $\hat{y}_t$  分别为轨迹的横、纵坐标:

$$\hat{\mathbf{y}}_t = [\hat{x}_t, \hat{y}_t] \quad (26)$$

最终结果导出为 Excel 文件, 并可在图像中可视化, 用于术前评估或术中导航. 本研究基于 PyTorch 和工作站 (配备 NVIDIA GTX-4090Ti GPU) 完成所提出的导丝形状预测模型的训练与测试.

## 3 实验与分析

本节围绕所提出的基于形态特征测量的导丝轨迹预测模型展开实验设计与性能评估, 旨在验证其在二维图像条件下的建模能力及其在真实应用场景中的可行性与稳定性. 通过用户实验验证, 考察所提方法在实际导丝操作任务中的适应能力与误差表现.

为验证所提出导丝轨迹预测模型在统一实验平台中的应用潜力与泛化性能, 本文设计并实施了一组用户实验, 对模型在实际条件下的形状预测能力进行系统评估. 本节包括三方面内容: 实验平台构建与任务配置、预测轨迹的可视化对比分析以及预测误差的定量分析.

### 3.1 实验平台构建与任务配置

为保障实验的可控性与数据的可重复性, 本文构建了一套集图像采集、导丝插入固定与轨迹测量于一体的用户实验平台, 如图 5 所示. 该平台由工业相机 (a)、导丝 (b)、导丝固定模块 (c)、血管模型 (d) 与形态特征测量模块组成, 可在标准化环境下持续采集导丝插入过程中的高分辨率图像, 提取血管结构、中心线轨迹及实际导丝形状等关键参数.

实验所用血管模型与采集数据使用的血管模型完全不同, 目的是测试模型在新型结构条件下的泛化能力. 平台支持多种导丝型号与插入角度设定, 便于构建多样化任务场景. 用户实验共选取 4 种代表性导丝类型, 设置 4 个典型插入角度, 每种组合下执行 20 个目标点插入任务, 其中导丝伸出的长度在 65 ~ 170 mm 之间, 模型中各分叉的直径在 3 ~




图 5 用户实验平台的组成结构示意图

Fig. 5 Schematic diagram of the user experiment platform and its components

15 mm 之间. 由于不同采样密度对模型预测精度和系统计算效率产生综合影响, 本研究选择表现出较优平衡效果的采样密度 (2 点/mm) 进行实验. 实验过程中, 用户根据模型预测轨迹进行操作, 平台记录实际导丝形状与系统预测结果, 所采集数据用于后续的可视化展示与误差分析.

### 3.2 实验结果可视化

为从视觉角度评估模型在真实任务中的预测效果, 本文采用两种可视化方式: 多目标轨迹对比图用于展示模型在多个目标点下的整体趋势与稳定性; 实拍图像叠加图则更贴近实际操作, 突出模型在视觉层面的形状一致性与感知效果. 两者分别从全局形态和局部贴合两个层面反映模型性能, 互为补充.

图 6 展示了多个目标任务下, 模型预测轨迹与真实导丝轨迹的整体重叠效果. 从整体趋势观察, 模型所预测的导丝轨迹在多数任务中与真实形变路径保持较高的一致性, 能够准确捕捉导丝的弯曲趋势与主干走向, 验证了其良好的全局形状建模能力.

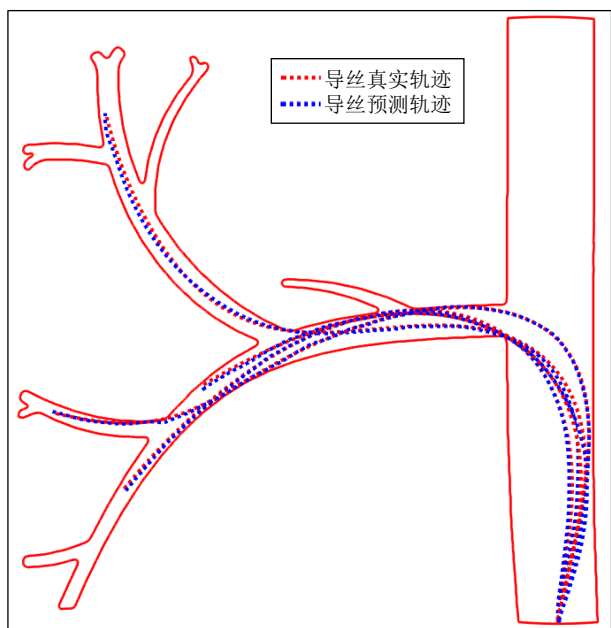


图 6 多目标任务中导丝轨迹真实与预测对比图  
Fig.6 Comparison of actual and predicted guidewire trajectories in multi-target tasks

图 7 展示了 4 组导丝插入任务中, 实际采集的导丝图像与模型预测形状的重叠效果, 误差统计分析见第 3.3 节. 结果表明, 模型能够在实际图像背景下有效复现导丝形变形态, 大多数预测轨迹均与图像中真实轮廓高度重合, 视觉一致性良好, 具备实际部署可行性.




图 7 导丝插入任务中实拍图像上模型预测轨迹可视化  
Fig.7 Visualization of model-predicted trajectories overlaid on real captured images in guidewire insertion tasks

### 3.3 实验结果分析

本节进一步对模型在不同任务配置下的预测性能进行了量化评估, 评估主要关注两个部分: 实时性与准确性.

为评估实时性, 统计了达到稳定收敛所需的 epoch 数、训练用时以及单序列前向推理时延, 并比较是否采用时间步分类策略的影响. 结果如表 1 所示: 与未采用该策略的基线相比, 采用时间步分类策略可使收敛 epoch 数下降 42%, 使训练与推理效率提升约 2 倍. 结果表明, 在不改变网络结构的前提下, 该策略能够同时提升训练效率与在线推理效率.

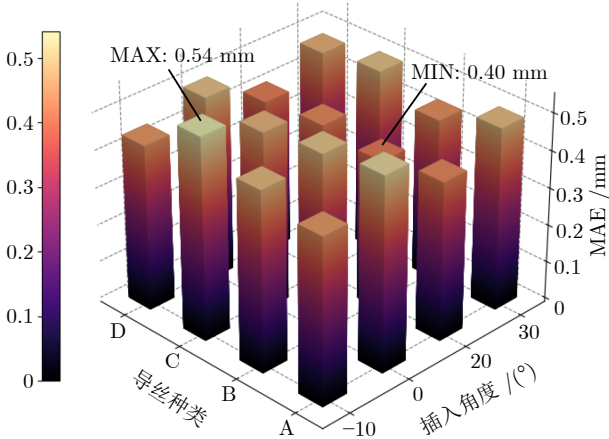
表 1 时间步分类策略对模型实时性的影响

Table 1 Impact of the time-step classification strategy on model real-time performance

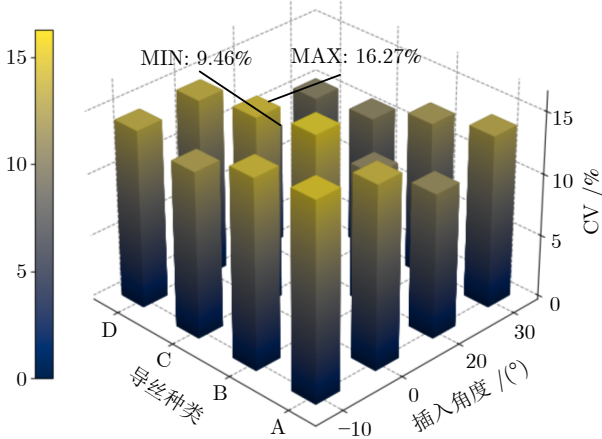
是否使用时间步分类策略	epoch 数量	训练用时 (h)	单次推理时延 (ms)
是	377	0.221	11.571
否	653	0.457	23.783

每组任务采用平均绝对误差 (mean absolute error, MAE) 衡量预测精度, 并以变异系数 (coefficient of variation, CV) 评估预测结果的稳定性. 具体而言, 每组导丝-角度组合包含 20 个目标任务, 分别计算其 MAE 与 CV, 最终共获得 16 组误差指标用于分析.

图 8(a) 与图 8(b) 分别展示了 MAE 与 CV 在不同导丝类型与插入角度组合下的柱状图。结果显示, 在多数组合条件下, 模型预测误差维持在较低水平, 误差波动较小, 表现出良好的稳定性与可靠性。当插入角度为  $20^\circ$  时, 导丝形状最为平滑, 预测误差最小 (0.40 mm); 随着插入角度变化, 导丝形状在固定端开始出现突变, 当插入角度为  $-10^\circ$  时, 预测误差最大 (0.54 mm), 提示模型在面对导丝形状突变时仍有优化空间。整体来看, 模型的平均预测误差为 0.46 mm, 在面对未见结构与新型导丝时仍保持较强的预测一致性与泛化能力。



(a) 不同导丝与插入角度组合下的 MAE  
(a) MAE across different guidewire and insertion angle configurations



(b) 不同导丝与插入角度组合下的 CV  
(b) CV across different guidewire and insertion angle configurations

图 8 不同导丝与插入角度组合下的 MAE 和 CV

Fig. 8 MAE and CV across different guidewire and insertion angle configurations

## 4 结束语

本文围绕导丝在术中复杂空间环境下的路径建

模问题, 提出一种融合多物理参数的 GRU 序列预测方法, 实现对导丝在二维空间中的轨迹连续预测。模型以导丝本体参数、接触特征与环境因素为输入, 输出任意时间步长的坐标序列, 适应手术中导丝形变轨迹的高度动态变化特性。在模型设计方面, 引入基于时间步长的分类训练策略, 以提升不同序列长度条件下的训练稳定性与收敛速度。与未采用该策略的基线相比, 采用时间步分类策略可使训练和推理速度提高 2 倍; 同时设置采样密度为 2 点/mm, 平衡预测精度与计算效率, 为模型的临床部署提供了参数依据。在用户实验验证中, 模型在真实导丝插入图像中的预测轨迹与实测轮廓高度一致, 最小平均误差为 0.40 mm, 表现出良好的视觉重合度和预测稳定性。在多组导丝类型与插入角度的组合下, 模型整体误差控制良好, 验证了其在统一实验平台中的可用性与鲁棒性。

本研究为柔性导丝的术中形状建模提供新的解决思路, 并为介入手术机器人导航系统提供了可部署的算法基础。对于临床迁移问题, 本文输入为介入导航通用的形态量与操作学量, 不依赖仿体的图像外观, 因此从仿体到临床的主要差异体现在血管顺应性与接触条件。迁移时: 形态量可由临床 DSA/CCTA (computed tomography angiography)/MRA (magnetic resonance angiography) 等提取并作为准静态几何先验输入; 针对临床影像与相机采集在分辨率与成像链路上存在差异的问题, 本文通过尺度标定-重采样-平滑-标准化, 使这类差异以输入噪声的形式被门控时序模型所吸收; 摩擦系数可按所用导丝与临床润湿条件进行一次性标定/范围校核, 并执行与训练阶段一致的标准化与广播拼接; 必要时采用短窗平滑或心动门控以减小形态抖动。在上述配置下, 本文 GRU 模型可在不依赖未来帧的前提下进行在线推理, 满足实时部署需求。临床迁移仅需完成形态量的常规提取与摩擦系数的一次性标定, 网络结构与推理流程保持不变, 具有良好的工程落地性。同时, 在强顺应性、剧烈搏动或病变导致的显著几何时变场景下, 需进一步引入时变几何通道/域自适应等扩展, 并探索将轻量物理先验(几何可行域约束、接触一致性约束等) 融入训练以增强稳健性与可解释性, 该方向已在后续工作中规划。

未来研究将进一步拓展模型至更真实、复杂的预测任务, 结合图像识别与图神经网络增强特征学习能力, 构建端到端的图像引导式形状预测框架。同时也探索将该模型与智能机器人系统深度融合, 推动其在智能介入手术、术前评估和术中导航等关键任务中的应用。

## 参考文献

- 1 Robertshaw H, Karstensen L, Jackson B, Granados A, Booth T C. Autonomous navigation of catheters and guidewires in mechanical thrombectomy using inverse reinforcement learning. *International Journal of Computer Assisted Radiology and Surgery*, 2024, **19**(8): 1569–1578
- 2 Feng Zhen-Qiu, Hou Zeng-Guang, Bian Gui-Bin, Xie Xiao-Liang, Zhou Xiao-Hu. Master-slave interactive control and implementation for minimally invasive vascular interventional robots. *Acta Automatica Sinica*, 2016, **42**(5): 696–705  
(奉振球, 侯增广, 边桂彬, 谢晓亮, 周小虎. 微创血管介入手术机器人的主从交互控制方法与实现. *自动化学报*, 2016, **42**(5): 696–705)
- 3 Li L, Li X J, Yang S L, Ding S, Jolfaei A, Zheng X. Unsupervised-learning-based continuous depth and motion estimation with monocular endoscopy for virtual reality minimally invasive surgery. *IEEE Transactions on Industrial Informatics*, 2021, **17**(6): 3920–3928
- 4 Chen T, Zhao X W, Zhang Y H, Zheng G, Hou L C, Ling Q, et al. Ultrasound-guided robotic autonomous operation based on real-time deformation tracking and prediction. *IEEE Transactions on Industrial Informatics*, 2025, **21**(2): 1369–1378
- 5 Zhang Tian, Liu Jian-Hua, Tang Cheng-Tong, Liu Shao-Li. 3D reconstruction technique of pipe based on centerline matching. *Acta Automatica Sinica*, 2015, **41**(4): 735–748  
(张天, 刘检华, 唐承统, 刘少丽. 基于中心线匹配的导管三维重建技术. *自动化学报*, 2015, **41**(4): 735–748)
- 6 Jin Chao-Yong, Geng Guo-Hua, Li Ji-Jun-Nan, Zhou Ming-Quan, Zhu Xin-Yi. A new automatic navigation path generation approach to virtual angiography. *Acta Automatica Sinica*, 2015, **41**(8): 1412–1418  
(金朝勇, 耿国华, 李姬俊男, 周明全, 朱新懿. 一种新的虚拟血管镜自动导航路径生成方法. *自动化学报*, 2015, **41**(8): 1412–1418)
- 7 Zhang Ming-Yang, Bian Gui-Bin, Li Zhen, Ye Qiang. Real-time shape reconstruction of flexible multi-segment continuum robot based for bronchial intervention. *Science Technology and Engineering*, 2025, **25**(1): 245–251  
(张名洋, 边桂彬, 李桢, 叶强. 支气管介入的多段柔性连续体机器人实时形状重建. *科学技术与工程*, 2025, **25**(1): 245–251)
- 8 Pore A, Li Z, Dall'Alba D, Hernansanz A, de Momi E, Menciassi A, et al. Autonomous navigation for robot-assisted intraluminal and endovascular procedures: A systematic review. *IEEE Transactions on Robotics*, 2023, **39**(4): 2529–2548
- 9 Li P, Feng J, Zhang X, Fang D L, Zhang J X, Liang C M. Modeling and experimental study of the intervention forces between the guidewire and blood vessels. *Medical Engineering & Physics*, 2024, **127**: Article No. 104166
- 10 Ravigopal S R, Brumfiel T A, Sarma A, Desai J P. Fluoroscopic image-based 3-D environment reconstruction and automated path planning for a robotically steerable guidewire. *IEEE Robotics and Automation Letters*, 2022, **7**(4): 11918–11925
- 11 Zhang R F, Dong L J, Wang X S, Tian M Q, Su H B. A sensorless guider contact force estimation approach for endovascular slender robot-assisted guidance system. *IEEE Transactions on Instrumentation and Measurement*, 2025, **74**: 1–9
- 12 Zhang R F, Dong L J, Wang X S, Tian M Q, Su H B. Morphological feature measurement of specific locations using image processing. In: Proceedings of the 8th International Conference on Machine Vision and Applications (ICMVA 2025). Melbourne, Australia: SPIE, 2025, **13734**: 9–17
- 13 Shen D H, Zhang Q, Han Y L, Tu C L, Wang X S. Design and development of a continuum robot with switching-stiffness. *Soft Robotics*, 2023, **10**(5): 1015–1027
- 14 Sharei H, Alderliesten T, van den Dobbelsteen J J, Dankelman J. Navigation of guidewires and catheters in the body during intervention procedures: A review of computer-based models. *Journal of Medical Imaging*, 2018, **5**(1): Article No. 010902
- 15 Beasley R A, Howe R D. Increasing accuracy in image-guided robotic surgery through tip tracking and model-based flexion correction. *IEEE Transactions on Robotics*, 2009, **25**(2): 292–302
- 16 Jiang Yun, Tan Ning. Retinal vessel segmentation based on conditional deep convolutional generative adversarial networks. *Acta Automatica Sinica*, 2021, **47**(1): 136–147  
(蒋芸, 谭宁. 基于条件深度卷积生成对抗网络的视网膜血管分割. *自动化学报*, 2021, **47**(1): 136–147)
- 17 Tai Y H, Qian K, Huang X Q, Zhang J, Jan M A, Yu Z T. Intelligent intraoperative haptic-AR navigation for COVID-19 lung biopsy using deep hybrid model. *IEEE Transactions on Industrial Informatics*, 2021, **17**(9): 6519–6527
- 18 Zhao Y, Wang Y X, Zhang J H, Liu X K, Li Y X, Guo S X, et al. Surgical GAN: Towards real-time path planning for passive flexible tools in endovascular surgeries. *Neurocomputing*, 2022, **500**: 567–580
- 19 Qi F, Ju F, Bai D M, Wang Y Y, Chen B. Kinematic analysis and navigation method of a cable-driven continuum robot used for minimally invasive surgery. *The International Journal of Medical Robotics and Computer Assisted Surgery*, 2019, **15**(4): Article No. e2007
- 20 Li Z, Dankelman J, de Momi E. Path planning for endovascular catheterization under curvature constraints via two-phase searching approach. *International Journal of Computer Assisted Radiology and Surgery*, 2021, **16**(4): 619–627
- 21 Gao M K, Chen Y M, Liu Q, Huang C, Li Z Y, Zhang D H. Three-dimensional path planning and guidance of leg vascular based on improved ant colony algorithm in augmented reality. *Journal of Medical Systems*, 2015, **39**(11): Article No. 133
- 22 Scarponi V, Duprez M, Nageotte F, Cotin S. A zero-shot reinforcement learning strategy for autonomous guidewire navigation. *International Journal of Computer Assisted Radiology and Surgery*, 2024, **19**(6): 1185–1192
- 23 Kweon J, Kim K, Lee C, Kwon H, Park J, Song K, et al. Deep reinforcement learning for guidewire navigation in coronary artery phantom. *IEEE Access*, 2021, **9**: 166409–166422
- 24 Vy P, Auffret V, Castro M, Badel P, Rochette M, Haigron P, et al. Patient-specific simulation of guidewire deformation during transcatheter aortic valve implantation. *International Journal for Numerical Methods in Biomedical Engineering*, 2018, **34**(6): Article No. e2974
- 25 Cheng X R, Song Q K, Xie X L, Cheng L, Wang L, Bian G B, et al. A fast and stable guidewire model for minimally invasive vascular surgery based on Lagrange multipliers. In: Proceedings of the 7th International Conference on Information Science and Technology (ICIST). Da Nang, Vietnam: IEEE, 2017. 109–114
- 26 Schafer S, Singh V, Noël P B, Walczak A M, Xu J, Hoffmann K R. Real-time endovascular guidewire position simulation using shortest path algorithms. *International Journal of Computer Assisted Radiology and Surgery*, 2009, **4**(6): 597–608
- 27 Qiu J P, Zhang L B, Yang G Y, Chen Y, Zhou S J. An improved real-time endovascular guidewire position simulation using activity on edge network. *IEEE Access*, 2019, **7**: 126618–126624
- 28 Li N, Wang Y W, Zhao H, Ding H. Sensor-free strategy for estimating guidewire/catheter shape and contact force in endovascular interventions. *IEEE Robotics and Automation Letters*, 2025, **10**(1): 264–271
- 29 Chen K, Qin W J, Xie Y Q, Zhou S J. Towards real time guidewire shape extraction in fluoroscopic sequences: A two phase deep learning scheme to extract sparse curvilinear structures.

*Computerized Medical Imaging and Graphics*, 2021, **94**: Article No. 101989

- 30 Ha X T, Wu D, Ourak M, Borghesan G, Dankelman J, Mencias A, et al. Shape sensing of flexible robots based on deep learning. *IEEE Transactions on Robotics*, 2023, **39**(2): 1580–1593
- 31 Li Ding-Jia, Guo Yu-Qi, Yang Yong-Ming, Li Rui, Liu Lian-Qing, Liu Hao. Embodied morphological perception for flexible robots with interactive constraints in luminal intervention. *Robot*, 2025, **47**(4): 497–507  
(黎定佳, 郭钰琪, 杨永明, 李锐, 刘连庆, 刘浩. 腔道介入交互约束下的柔性机器人具身形态感知方法. *机器人*, 2025, **47**(4): 497–507)
- 32 Kuntz A, Sethi A, Webster R J, Alterovitz R. Learning the complete shape of concentric tube robots. *IEEE Transactions on Medical Robotics and Bionics*, 2020, **2**(2): 140–147




**张任飞** 东南大学机械工程学院博士研究生. 主要研究方向为介入手术机器人的导航与控制.

E-mail: [230218562@seu.edu.cn](mailto:230218562@seu.edu.cn)

**(ZHANG Ren-Fei Ph.D. candidate at the School of Mechanical Engineering, Southeast University. His**

main research interest is navigation and control of interventional surgical robots.)



**董林杰** 东南大学机械工程学院博士研究生. 主要研究方向为基于深度学习的图像处理与人工智能.

E-mail: [230228047@seu.seu.cn](mailto:230228047@seu.seu.cn)

**(DONG Lin-Jie Ph.D. candidate at the School of Mechanical Engineering, Southeast University. His**

research interests include deep-learning-based image processing and artificial intelligence.)



**王兴松** 博士, 东南大学机械工程学院教授. 主要研究方向为机器人动力学及其控制, 先进医疗器械. 本文通信作者.

E-mail: [xswang@seu.edu.cn](mailto:xswang@seu.edu.cn)

**(WANG Xing-Song Ph.D., professor at the School of Mechanical Engineering, Southeast University. His research interests include robot dynamics and control, and advanced medical devices. Corresponding author of this paper.)**




**田梦倩** 博士, 东南大学机械工程学院副教授. 主要研究方向为智能机器人, 控制技术, 机电控制及自动化.

E-mail: [Tianmq@seu.edu.cn](mailto:Tianmq@seu.edu.cn)

**(TIAN Meng-Qian Ph.D., associate professor at the School of Mechanical Engineering, Southeast**

University. Her research interests include intelligent robots, control technology, and mechatronic control and automation.)



**苏浩波** 博士, 南京市第一医院介入血管科副主任医师. 主要研究方向为脑血管疾病及良恶性肿瘤的介入诊疗.

E-mail: [doctorsuhaobo@163.com](mailto:doctorsuhaobo@163.com)

**(SU Hao-Bo Ph.D., associate chief physician in the Department of Interventional and Vascular Radiology, Nanjing First Hospital. His research interests include**

interventional diagnosis and treatment of cerebrovascular diseases and benign and malignant tumors.)