

专题: 柔性电子与智能可穿戴

# 基于因果机器学习温补的血管介入机器人 自适应力反馈策略\*

辛绍宗<sup>1) #</sup> 胡陟<sup>1) #†</sup> 宋爱国<sup>2) #</sup> 李树凡<sup>1) #</sup>

1) (上海工程技术大学, 机器人智能控制实验室, 上海 201620)

2) (东南大学仪器科学与工程学院, 生物电子国家重点实验室, 江苏远程测量控制重点实验室, 南京 210096)

(2026年1月3日收到; 2026年2月11日收到修改稿)

机器人辅助血管介入中, 导丝力感知易受温度应变交叉敏感性及血流引起的热扰动、漂移影响, 导致温度补偿与远端力估计偏差, 从而削弱术中反馈的可信度与操作安全性. 针对该问题, 本研究构建基于因果机器学习的双光纤布拉格光栅补偿框架, 将热-流-固耦合导丝多物理模型与结构因果推断融合. 显式分离热效应与机械效应, 结合反事实推理与自适应参数更新抑制不同血流条件下的非线性干扰, 降低远端的力反馈误差, 提高在动态环境下的稳定性. 体外实验在接近真实生理环境不同流速下验证: 温度补偿平均绝对误差较双FBG方法降低超过50%, 远端力估计误差最高降低70%. 结果表明, 该框架可在动态血流环境中提供更稳定、可重复的力反馈, 有助于医生更准确判断导丝与血管壁接触状态、降低过大接触力相关风险, 从而提升机器人介入操作的可靠性与一致性.

**关键词:** 温度应变敏感, 因果机器学习, 力反馈, 温度补偿**DOI:** 10.7498/aps.75.20260005**CSTR:** 32037.14.aps.75.20260005

## 1 引言

血管介入已成为心血管与脑血管疾病的重要微创治疗方式, 但临床疗效仍在很大程度上依赖术者在曲折血管内操控细长、柔顺导丝的经验与手感; 在感知受限且不可避免的辐射暴露条件下, 导丝导航到达病灶的难度进一步增加<sup>[1-3]</sup>. 在机器人辅助血管介入中, 远端交互力及器械形状/状态等关键信息的可靠获取, 直接决定主从透明度与闭环安全控制质量, 仍是提升安全裕度的关键瓶颈<sup>[4,5]</sup>. 因此, 面向血管机器人系统的力感知与力反馈受到广泛关注, 既往研究强调安全操作所需的力复现与力控制精度, 同时探索了学习驱动的力反馈策略<sup>[6,7]</sup>.

近年来, 国内外学者的研究指出, 提升“真实术中条件下”的稳定感知能力是迈向更高自主性与更强主从透明度的核心前提<sup>[8]</sup>. 除远端力之外, 导丝构型的准确估计同样关键. 血管壁接触、摩擦以及血流驱动扰动会引起复杂变形, 进而导致导航误差与主从透明度下降<sup>[9]</sup>. 基于物理的研究通常采用Kirchhoff/Cosserat杆力学对细长器械建模, 并结合仿真实现器械状态对齐<sup>[2,10]</sup>. 无监督学习的导丝形状配准可更好对齐主从导丝点集, 从而提升透明度与可靠性<sup>[11]</sup>.

在测量设备设计及其数据处理方面, 光纤布拉格光栅 (fiber Bragg grating, FBG) 传感器因尺寸微型、电磁免疫、易与长柔器械集成等优势, 成为血管内工具的有力候选<sup>[12-14]</sup>; 大量研究已验证其

\* 国家自然科学基金青年项目 (批准号: 62003207) 资助的课题.

# 同等贡献作者.

† 通信作者. E-mail: huzhi26@126.com

在医疗器械多轴力感知与形状感知中的潜力, 并提出了具有温度自补偿特性的结构设计<sup>[15-17]</sup>. 然而, 现有的温度补偿方法主要依赖简化热假设和回归模型, 但这些方法无法应对动态血流条件下的复杂扰动. 传统的双 FBG 传感方法通常在稳定环境中有效, 但术中由于温度变化、血流速度变化等因素的干扰, 其性能会退化<sup>[18,19]</sup>. 尽管已有温度补偿策略取得进展, 但许多方法仍依赖简化热假设、离线标定或相关性回归模型, 当流速、环境温度与接触状态在手术过程中并发变化时, 补偿性能易退化<sup>[16,19]</sup>. 与此同时, 其他导丝力检测路径(如递送过程的操作力检测)亦有探索, 但在动态血管内环境中实现稳健的远端交互力估计仍具有挑战<sup>[20]</sup>. 上述问题表明, 仅依赖相关性拟合难以充分处理热-力耦合感知中的潜在扰动与混杂因素, 迫切需要一种更具机理约束且能够在分布漂移下保持鲁棒性的“建模-学习”一体化框架. 因果学习近年来被认为是提升分布偏移条件下泛化能力的有效途径, 可通过聚焦不随环境变化的因果机制来减少伪相关带来的失效风险<sup>[21]</sup>.

据此提出因果学习增强的双 FBG 温度补偿框架: 以热-流-固耦合模型刻画血流对流与摩擦生热导致的温度-应变非平稳耦合, 在双 FBG 解耦基础上引入结构因果建模与反事实校正以抑制潜在混杂, 结合异质性建模与在线自适应更新提升跨工况稳定性. 体外实验表明, 该方法相较传统双 FBG 显著降低温度补偿误差并抑制高流速下力估计退化, 为真实扰动条件下的可靠力反馈提供基础. 本文贡献如下: 1) 建立面向血流扰动的热-流-固耦合导丝建模与双 FBG 感知框架; 2) 提出结构因果推断与反事实补偿策略, 用于分离热效应与机械效应并控制潜在混杂; 3) 在三档流速体外实验中验证跨工况性能提升, 温度补偿误差与力估计误差显著下降, 且随流速增大的性能退化被抑制.

本文结构安排如下: 第 2 节介绍导丝建模、动态分析、温度补偿原理与因果机器学习框架; 第 3 节给出实验平台与评估结果; 第 4 节对结果进行讨论与分析; 最后总结全文并展望未来研究方向.

## 2 导丝建模与分析

血管介入导丝的动力学行为多基于 Cosserat 杆或 Kirchhoff 杆理论进行描述, 在假设材料参数

与环境条件稳定的前提下, 能够较好刻画导丝的弯曲、扭转及轴向变形特性. 然而, 在实际血管介入过程中, 导丝不可避免地受到血流冲击、血管壁接触及摩擦作用的影响, 相关研究表明, 血流-结构相互作用及摩擦生热会引起局部温度波动, 从而导致材料力学特性与传感响应发生变化<sup>[12,13]</sup>. 在此情况下, 若仍采用忽略温度与血流扰动的传统动力学模型, 或依赖静态标定建立力-应变映射关系, 易在不同工况下引入力估计偏差, 影响力反馈的稳定性与可靠性. 为此, 有必要在动力学建模中进一步考虑相关扰动因素, 为后续力估计与补偿方法提供合理的物理基础.

### 2.1 热-流-固耦合导丝动力学建模

导丝动力学的精确建模是高精度导航与远端力估计的前提. 针对传统模型忽略温度致材料漂移与血流-结构耦合而在体内工况下退化的问题, 本文提出热-流-固多场耦合导丝模型以提升预测保真度.

#### 2.1.1 基于 Cosserat 杆理论与有限元相结合的导丝几何描述

导丝是建立血管通路并完成微创诊疗操作的关键器械. 本文将导丝建模为可拉伸、可弯曲且可扭转的弹性 Cosserat 杆. 设导丝长度为  $L$ , 其中心线记为  $r(s, t)$ , 其中  $s \in [0, L]$  为弧长坐标、 $t$  为时间. 对每个截面引入随体正交基  $d_1(s, t), d_2(s, t), d_3(s, t)$  表征截面取向, 其中  $d_3$  与中心线切向一致, 如 (1) 式:

$$d_3(s, t) = r'(s, t) / |r'(s, t)|. \quad (1)$$

$[u, v, d_3]$  为参考坐标系, 相对于  $d_1$  和  $d_2$  具有旋转角  $\theta$ . 该坐标系适用于各个形心中心线的演化描述, 并用于在不发生拉伸的情况下表征弯曲与扭转, 如图 1 所示.




图 1 导丝的有限元与 Cosserat 结合建模

Fig. 1. Finite element and Cosserat wire combined model of the guidewire.

为适应导丝操控过程中出现的大变形, 将经典的胡克 (Hooke) 本构关系扩展为超弹性本构模型, 如 (2) 式:

$$W = C_{10}(I_1 - 3) + C_{01}(I_2 - 3) + \frac{1}{D}(J - 1)^2, \quad (2)$$

其中,  $W$  表示应变能函数, 其材料参数  $C_{10} = 0.1 \text{ MPa}$ ,  $C_{01} = 0.03 \text{ MPa}$ , 以及  $D = 0.001 \text{ MPa}^{-1}$ . 剪切应变记为  $\gamma(s, t)$ , 相应的剪切方向向量记为  $\mathbf{v}_{\text{shear}}(s, t)$ . 在同时考虑导丝的轴向拉伸应变  $\epsilon(s, t)$  与剪切应变  $\gamma(s, t)$  后, 中心线的修正切向方向可表示为

$$d_3(s, t) = \frac{r'(s, t) + \epsilon(s, t)r'(s, t) + \gamma(s, t)\mathbf{v}_{\text{shear}}(s, t)}{\|r'(s, t) + \epsilon(s, t)r'(s, t) + \gamma(s, t)\mathbf{v}_{\text{shear}}(s, t)\|}. \quad (3)$$

为更清晰地分析弯曲应力与剪切应力对导丝的影响, 将  $\Omega(s, t)$  分解到该坐标系的各个方向上, 如 (4) 式:

$$\Omega(s, t) = \Omega_1(s, t)\mathbf{d}_1 + \Omega_2(s, t) + \Omega_3(s, t). \quad (4)$$

对于给定的 Cosserat 曲线  $r(s, t)$ , 中心曲线的变化会引起  $[d_1, d_2, d_3]$  的相应变化. 根据微分几何理论, 材料坐标系  $\{d_k\}$  关于弧长坐标  $s$  的导数与  $\Omega(s, t)$  存在叉乘关系:

$$\mathbf{d}'_k(s, t) = \Omega(s, t) \times \mathbf{d}_k(s, t). \quad (5)$$

由于导丝在血管介入中的动态行为受到血流、摩擦以及温度变化等多因素的影响, 传统的力学模型通常无法全面捕捉这些复杂的相互作用. 为在复杂血管环境下更精确地刻画力学行为, 采用基于 Cosserat 杆理论和超弹性本构模型的几何描述, 能够更加精确地反映导丝在不同环境条件下的变形和响应, 尤其是在复杂血管环境中的力学行为. 这一建模方法为后续的温度补偿和力估计提供了更可靠的物理依据, 能够有效提升导丝在血流和温度扰动下的力反馈精度和稳定性.

### 2.1.2 多物理场耦合动力学建模

基于哈密顿变分原理, 导丝的动力学控制方程可表示为 (6) 式:

$$\rho A \frac{\partial^2 r}{\partial t^2} = \frac{\partial}{\partial s} (Nd_3 + Q_1 d_1 + Q_2 d_2) + f_{\text{ext}}, \quad (6)$$

其中  $\rho A \frac{\partial^2 r}{\partial t^2}$  表示导管因运动而产生的“抗拒加速度”的力,  $Q$  为表示导管延方向  $d$  的剪切力, 外力  $f_{\text{ext}}$  包括血流冲击力以及血管壁接触力. 基于导丝

位置  $r^n(s)$  求解当前血流速度场和压力场, 血流由不可压缩 Navier-Stokes 方程描述为 (7) 式:

$$\begin{cases} \rho \left( \frac{\mathbf{v}^{m+1} - \mathbf{v}^m}{\Delta t} + \mathbf{v}^m \cdot \nabla \mathbf{v}^m \right) \\ = -\nabla p^m + \mu \nabla^2 \mathbf{v}^m + \mathbf{f}_{\text{FSI}}^m, \\ \nabla \cdot \mathbf{v}^{m+1} = 0. \end{cases} \quad (7)$$

通过求解导丝与血液之间的共轭传热, 量化摩擦生热与对流冷却效应, 从而计算其温度场  $T^{n+1}$ . 血液与导丝的能量方程表示为

$$\begin{cases} \rho c_p \left( \frac{\partial T}{\partial t} + \mathbf{v} \cdot \nabla T \right) = k \nabla^2 T + \mu \Phi_v, \\ \rho_s c_{p,s} \frac{\partial T}{\partial t} = k_s \nabla^2 T + q_{\text{friction}}, \end{cases} \quad (8)$$

其中,  $\Phi_v$  为黏性耗散函数;  $q_{\text{friction}}$  为摩擦热源项. 根据  $T^{n+1}$  对其弹性模量  $E(T)$ 、摩擦系数  $\mu_d(T)$  以及黏性阻尼  $c(T)$  进行动态调整, 以反映温度相关效应, 分别如 (9) 式—(11) 式所示:

$$E(T) = E_0 e^{-\alpha T (T - T_0)}, \quad (9)$$

$$\mu_d(T) = \mu_{d0} \left[ 1 - \beta \tanh \left( \frac{T - T_{\text{trans}}}{T_{\text{scale}}} \right) \right], \quad (10)$$

$$c(T) = c_0 \left( 1 + \gamma \frac{T - T_{\text{ref}}}{T_{\text{ref}}} \right). \quad (11)$$

这一模型为导丝在动态环境下的行为提供了更加准确的描述, 能够有效模拟血流对导丝的力学响应以及温度对其材料特性的变化. 通过引入热-流-固耦合模型, 能够更精确地捕捉温度变化对导丝的影响, 并为后续的温度补偿和力反馈提供更强的理论基础.

## 2.2 双 FBG 传感信号的解耦与温度补偿

为解决 FBG 温度-应变交叉敏感, 本文采用 PS-FBG 与普通 FBG 级联, 并通过双通道响应差异构建解耦模型. 单段光栅的  $\Delta\lambda$  可近似写为  $\epsilon$  与  $\Delta T$  的线性组合; 级联结构中两段光栅对轴向力  $F$  的应变灵敏度不同, 从而实现温度/应变可分离估计, 其传感方程可写成矩阵形式:

$$\begin{bmatrix} \Delta\lambda_1 \\ \Delta\lambda_2 \end{bmatrix} = \begin{bmatrix} K_{1F} & K_{1T} \\ K_{2F} & K_{2T} \end{bmatrix} \begin{bmatrix} F \\ \Delta T \end{bmatrix}, \quad (12)$$

其中  $\begin{bmatrix} K_{1F} & K_{1T} \\ K_{2F} & K_{2T} \end{bmatrix}$  为灵敏度矩阵,  $K_{1F}$ ,  $K_{2F}$  为力灵

敏度系数,  $K_{1T}$ ,  $K_{2T}$  为对应的温度灵敏度系数. 当  $K_{e_1}K_{T_2} \neq K_{e_2}K_{T_1}$  时, 无法实现解耦. 考虑到两只传感器所处环境几乎一致、所经历的温度基本相同, 在消去温度项后可得到解耦后的接触力, 并进一步建立传感器测得的目标接触力与波长变化之间的关系, 如 (13) 式:

$$F = \frac{K_{2T}\Delta\lambda_1 - K_{1T}\Delta\lambda_2}{K_{2T}K_{1F} - K_{1T}K_{2F}}. \quad (13)$$

通过引入双 FBG 传感器解耦模型, 我们能够有效克服温度和应变之间的交叉敏感性问题, 通过级联结构和灵敏度矩阵的构建, 本文提出的双 FBG 解耦方法能够准确分离温度与应变对信号的影响, 减小了交叉敏感性所带来的误差. 这一方法为温度补偿提供了更为稳定的基础, 尤其是在血管介入过程中, 温度和血流速度的变化是不可避免的.

### 3 方法

传统的双 FBG 解耦方法高度依赖精确的物理标定, 难以应对血管介入环境中常见的未观测混杂因素, 例如组织异质性、材料老化以及局部血流动力学波动等. 为克服这些局限性, 我们提出一种由因果推断驱动的补偿框架, 能够识别温度与应变之间的潜在因果关系, 并对患者特异性与环境特异性的变化进行动态自适应调整.

#### 3.1 结构因果模型建构与识别

为了解决温度与应变之间的交叉敏感问题, 我们引入了结构因果模型 (structural causal model, SCM) 来揭示温度变化和应变之间的潜在因果关系. SCM 通过对可观测变量 (如 FBG 波长漂移、导丝表面温度等) 和潜在变量 (如导丝材料老化程度、组织黏弹性) 进行建模, 识别变量之间的因果路径. 通过引入反事实推理方法, 可以预测温度干预下的应变变化, 从而补偿温度对 FBG 传感器测量结果的影响.

导丝-血管壁接触过程中, 摩擦与黏性作用会导致局部发热, 且受材料状态变化影响; 同时, 血流速度在导丝运动与心搏调制下呈非平稳变化, 使波长漂移同时受到温度波动、流体作用与潜在混杂的共同驱动. 基于上述关系, 本文构建如下结构方程模型:

$$\begin{cases} X_3 = \alpha_1 U_1 + \alpha_2 U_2 + \beta_1 X_4^2 + \epsilon_3, \\ X_1 = \gamma_1 X_3 + \gamma_2 X_5 + \delta_1 U_2 + \epsilon_1, \\ X_2 = \gamma_3 X_3 + \gamma_4 X_5 + \delta_2 U_1 + \epsilon_2, \\ X_5 = \eta_1 X_4 + \eta_2 \sin \frac{2\pi t}{T_{\text{heart}}} + \epsilon_5, \end{cases} \quad (14)$$

其中  $\epsilon_i N(0, \sigma_{\epsilon_i}^2)$  为相互独立同分布的噪声项. 与该方程组对应的有向无环图 (directed acyclic graph, DAG) 能够清晰揭示其中的混杂路径, 如图 2 所示.  $U_1$  同时影响温度  $X_3$  和信号  $X_2$ . 若不对  $U_1$  加以控制, 将导致  $X_3$  和  $X_2$  之间出现虚假相关.




图 2 基于因果机器学习的有向无环图  
Fig. 2. Directed acyclic graph based on causal machine learning.

潜在变量采用变分期望最大化 (expectation-maximization, EM) 算法对模型参数与隐状态进行联合估计. 在给定当前参数估计  $\theta^{(k)}$  的情况下, 利用卡尔曼滤波与平滑对潜在变量的后验分布进行推断, 得到其后验均值  $\mu_U$  与协方差  $\Sigma_U$ . 基于计算得到的后验统计量, 通过最大化完整数据似然来更新模型参数  $\theta = \{\alpha, \beta, \gamma, \delta, \eta, \sigma\}$ , 如 (15) 式:

$$\theta^{\text{new}} = \left( \sum_{i=1}^N \mathbb{E}[UU^T] \right)^{-1} \left( \sum_{i=1}^N \mathbb{E}[UX^T] \right)^T, \quad (15)$$

其中  $U$  包含所有父变量. 通过交替迭代执行 E 步与 M 步直至收敛, 从而实现了对模型参数的同时识别与对潜在混杂因素状态的推断. 通过引入结构因果模型刻画温度与应变之间的因果关系, 并识别血流扰动、材料状态变化等潜在混杂因素, 从而弥补传统基于相关性建模方法在动态工况下易失效的不足.

#### 3.2 用于干预效应计算的反事实推理

为评估温度对应变的因果效应, 我们引入一个

假想干预 do ( $T = 37^\circ\text{C}$ ), 在干预条件下进行反事实应变估计, 得到校正后的 FBG 信号为

$$\lambda_{\text{corrected}} = \lambda_{\text{measured}} - K_T(T - 37^\circ\text{C}). \quad (16)$$

随后将反事实应变信号  $X_2^{\text{CF}}$  代入双 FBG 解耦模型, 计算对应的反事实接触力, 从而得到在温度干预条件下应产生的力估计  $F^{\text{CF}}$  如 (17) 式, 该过程能够将真实的机械贡献与由温度变化引入的伪影效应分离开来。

$$F^{\text{CF}} = \frac{K_{2T}\Delta\lambda_1^{\text{CF}} - K_{1T}\Delta\lambda_2^{\text{CF}}}{K_{2T}K_{1F} - K_{1T}K_{2F}}. \quad (17)$$

为获得对处理效应的无偏估计, 采用逆概率加权估计量在加权样本中匹配处理组与对照组, 构造一个模拟的随机试验. 对每个个体  $i$  赋予权重得到 (18) 式:

$$\omega_i = \frac{T_i}{\pi(X_i)} + \frac{1 - T_i}{1 - \pi(X_i)}. \quad (18)$$

通过对观测结果进行加权以构造加权条件期望, 从而模拟随机对照试验. 通过构造能够平衡协变量  $X$  分布的权重, 进一步采用增广逆概率加权 (augmented inverse probability weighting, AIPW) 估计量, 如 (19) 式:

$$\hat{\tau}_{\text{AIPW}} = \frac{1}{n} \sum_{i=1}^n \left[ \frac{T_i Y_i}{\pi(X_i)} - \frac{T_i - \pi(X_i)}{\pi(X_i)} \hat{\mu}_1(X_i) \right] - \left[ \frac{(1 - T_i) Y_i}{1 - \pi(X_i)} - \frac{T_i - \pi(X_i)}{1 - \pi(X_i)} \hat{\mu}_0(X_i) \right]. \quad (19)$$

该双重稳健方法在倾向评分模型或结果回归模型中只要有一个设定正确, 就能保持统计一致性, 从而在真实手术环境中提升估计的稳定性与可靠性。

### 3.3 因果机器学习的温度补偿

为刻画不同导丝材料、传感器布置引起的处理效应异质性, 本文采用因果森林估计条件平均处理效应, 在不同操作条件下实现温度干预对测量信号影响的差异化校正, 并支持按工况自适应的补偿策略. 模型分裂以处理效应异质性增益为准则, 定义为 (20) 式:

$$\Delta = L(S_{\text{parent}}) - [L(S_L) + L(S_R)]. \quad (20)$$

当误差差值出现明显上升时, 就将这一临界点设为分割阈值. 为提升模型在不同运行工况下的泛化能力, 引入域自适应, 并使用平方最大均值差异指标来衡量数据集  $P$  与  $Q$  之间的分布差异如

(21) 式:

$$\text{MMD}^2 = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n k(x_i, x_j) + \frac{1}{m^2} \sum_{i=1}^m \sum_{j=1}^m k(y_i, y_j) + \frac{1}{mn} \sum_{i=1}^n \sum_{j=1}^m k(x_i, y_j). \quad (21)$$

采用一种混合的 RBF-多项式核, 以同时刻画局部非线性结构和高阶的全局交互作用, 从而提升对异质性处理效应估计的鲁棒性。

#### 3.3.1 适应学习与动态适应算法

血管介入中的生理与力学条件具有显著非平稳性. 为适应工况持续变化, 本文引入基于在线学习的自适应模块 (FTRL), 在手术数据流到达时对模型参数进行增量更新. FTRL 通过维护累积梯度及其平方项, 可利用闭式解 (22) 式直接更新参数, 避免迭代优化, 从而满足数值稳定性要求:

$$\omega_j^{(t+1)} = \frac{\eta_j^{(t)}}{\lambda + \eta_j^{(t)} H_j^{(t)}} \left( C_j^{(t)} - \sum_{s=1}^t \sigma_j^{(s)} \omega_j^{(s)} \right). \quad (22)$$

我们构建了一个两阶段机器学习模型: 第一阶段进行温度预测, 采用 Transformer 时间序列模型, 在滑动窗口内处理 FBG 波长序列. 第二阶段进行补偿与解耦, 在 SCM 约束下通过反事实推断消除温度相关混杂, 并利用因果森林刻画工况异质性, 结合在线自适应更新实现跨工况稳定补偿。

## 4 实验验证

为全面评估所提出的基于因果机器学习的温度补偿与力感知框架的性能, 我们在自建的血管介入手术仿真平台上开展了系统的体外实验. 实验旨在验证三个关键方面: 1) 集成的热-流-固耦合动力学模型是否能够提升导丝行为预测的准确性; 2) 因果机器学习框架是否能够有效解耦温度与应变, 从而增强温度补偿效果; 3) 在动态血流条件下, 所提方法是否能够保持稳定的力估计. 本节将给出导丝形状感知精度、温度补偿性能、力估计精度以及系统整体鲁棒性的定量结果, 并在此基础上进行详细分析。

### 4.1 实验设置

实验平台如图 3 所示. 基于 Cosserat 杆与有限元耦合模型生成导丝构型与运动轨迹, 用于构建

因果学习数据集. 在 3 种流速 (5, 10, 20 cm/s) 下, 采用搭建的血管介入仿真平台, 驱动导丝执行 10 组标准化运动序列 (恒速插入、周期性横向摆动、受控血管壁接触), 每组重复 5 次以保证数据的稳定, 共获得 150 组同步样本. 每组样本包含 FBG 波长、视觉轨迹、接触力真值、温度与流量信息. 采集到的实验数据经过信号预处理, 并采用相同的标定参数进行补偿校正. 为确保模型评估的公正性, 数据按 80%/20% 随机划分为训练集与测试集, 采用均方根误差 (RMSE) 和平均绝对误差 (MAE) 等指标对传统方法与本文提出的方法进行对比分析, 以用于模型辨识与评估.




图 3 基于 UR-5 的实验平台, 用于方法验证和性能评估 (a) 导丝推进端; (b) 环境模拟端  
Fig. 3. UR-5-based experimental platform for method validation and performance evaluation: (a) Guidewire pushing end; (b) environment simulation end.

## 4.2 温度补偿与力反馈结果

血管内环境中温度变化与血流热扰动会引起双 FBG 测量漂移, 降低温度补偿与力估计可靠性. 为此, 本文在体外平台中显式引入温度-血流耦合效应, 评估动态工况下的温度补偿精度. 本文对比传统双 FBG 补偿与所提因果学习框架: 通过因果温度校正抑制不可观测混杂带来的偏差, 并利用因果森林刻画工况异质性以自适应调整补偿参数, 从而提升不同血流条件下的补偿稳定性.

本文计算了热-流体-固体耦合仿真结果与相应实验测量之间的 RMSE, 取 (9) 式—(11) 式中  $E_0 = 2.1 \text{ MPa}$ ,  $\mu_{d0} = 0.2$ ,  $\beta = 0.1$ ,  $T_{\text{trans}} = 37 \text{ }^\circ\text{C}$ ,  $T_{\text{scale}} = 5 \text{ }^\circ\text{C}$ ,  $\gamma = 0.05$ . 此外, 在恒定插入力 0.15 N 条件下, 导丝在不同血流速度下穿越曲线血管段时的轴向力与应力分布如图 4 所示.




图 4 导丝在不同血流速度下的轴向力/应力分布 (a) 导丝轴向力分布的跟踪; (b) 导丝应力分布的跟踪  
Fig. 4. Axial force distributions of the guidewire under different blood-flow velocities: (a) Tracking of axial-force distribution along the guidewire; (b) tracking of stress distribution along the guidewire.

将因果学习算法与反事实推理的神经网络相结合, 实现了对与变量相关偏差的实时补偿. 如图 5 所示, 模型准确地跟踪了应变差异的时间




图 5 动态补偿比较: 在离散时间步长下的实际与预测应变差异曲线  
Fig. 5. Dynamic compensation: Ground-truth and predicted strain-disparity trajectories.




图 6 采用传统双 FBG 与基于因果机器学习的补偿方法在不同流速下的温度补偿性能比较 (a) 5 cm/s 时的力反馈; (b) 10 cm/s 时的力反馈; (c) 20 cm/s 时的力反馈

Fig. 6. Comparison of temperature compensation performance under varying flow rates using conventional dual FBG and causal ML: (a) Force feedback at 5 cm/s; (b) force feedback at 10 cm/s; (c) force feedback at 20 cm/s.

演化, 其预测值与真实值紧密匹配, 并稳定地保持在临床可接受范围内. 因果学习算法有效捕捉变量间的因果关系, 反事实推理则通过模拟不同情境下的潜在结果, 提高了模型的准确性和稳定性. 该方法避免了传统模型的误差累积问题, 为临床预测提供了更精确的补偿机制.

由于血流速度对 FBG 测量有显著影响, 所提出的方法在代表性的 3 种流速 (5, 10 和 20 cm/s) 下进行进一步验证, 并将其温度补偿性能与传统双 FBG 方案进行了比较. 图 6 中详细的实验结果表明, 所提出的方法在不同流速下均能够保持较高的温度补偿精度, 显著优于传统双 FBG 方案. 该实验验证了该方法在实际应用中的有效性, 尤其是在动态变化的血流环境下, 能够提供更加稳定和精确的温度补偿性能.

相应的平均误差总结如表 1 所示. 与传统双 FBG 方案相比, 所提出的 Causal ML 方法在流速为 5, 10 和 20 cm/s 的情况下, 分别将温度的 MAE 从 0.34 °C, 0.48 °C 和 0.68 °C 降至 0.16 °C, 0.19 °C 和 0.28 °C, 改进幅度分别为 52.78%, 60.04% 和 58.82%. 这些结果表明, 所提方法在温度补偿上的显著优势, 能够在不同血流速率条件下提供更为精确和稳定的温度测量.

图 7 比较了传统方法与因果学习的方法在不同流速下的温度误差分布. 该方法得到的分布更紧凑, 四分位距减小了 57%—67%, 且所有数据点均低于临床安全阈值 0.9 °C, 而传统方法在较高流速下存在明显的离群值. 此外, 因果 ML 方法的中位误差显著较低, 且随着流速增大, 误差增长的速率大幅减缓. 这些分布特性表明, 因果 ML 框架能够

有效补偿非线性热-流体耦合效应, 并为血管介入手术提供更可靠的安全保障.

表 1 不同血流速度下, 传统双 FBG 方法与因果机器学习方法温度补偿比较

Table 1. Comparison of temperature compensation at different blood-flow velocities: traditional dual-FBG method versus causal machine learning method.

| 血流速度/(cm·s <sup>-1</sup> ) | 双FBG补偿误差/°C | 因果机器学习误差/°C | 效果提升/% |
|----------------------------|-------------|-------------|--------|
| 5                          | ±0.42       | ±0.19       | 55     |
| 10                         | ±0.51       | ±0.24       | 53     |
| 20                         | ±0.64       | ±0.28       | 56     |




图 7 传统双 FBG 与因果机器学习补偿方法在不同流速下温度误差分布比较

Fig. 7. Comparison of temperature error distribution under different flow rates between dual-FBG and causal ML.




图 8 基于因果机器学习的补偿方法在不同流速下误差更低且更稳定 (a) 5 cm/s 时的力反馈误差; (b) 10 cm/s 时的力反馈误差; (c) 20 cm/s 时的力反馈误差

Fig. 8. The causal ML compensation achieves lower and more stable errors across flow velocities: (a) Temperature compensation error distribution at 5 cm/s; (b) temperature compensation error distribution at 10 cm/s; (c) temperature compensation error distribution at 20 cm/s.

在 5, 10, 20 cm/s 下对比传统双 FBG 与因果 ML 补偿, 如图 8 所示, 平均力反馈误差由 0.08, 0.10, 0.11 N 降至 0.02, 0.04, 0.05 N, 且传统方法随流速升高的退化更明显, 因果 ML 抑制了误差增长. 更小且更集中的误差表明反馈一致性提升, 有助于降低工况变化下的误判风险.

为定量评估两种方法的性能差异, 表 2 给出了在不同血流速度条件下, 传统双 FBG 方法与因果机器学习 (Causal ML) 方法在温度补偿误差和力反馈误差方面的详细对比数据. 可以清楚地看到, 因果机器学习方法在温度补偿误差和力反馈误差上均表现出显著的优势, 尤其是在不同流速下, 表现出了更高的精度和稳定性.

表 2 采用传统双 FBG 方法与因果机器学习方法不同流速下温度补偿与力反馈误差的比较

Table 2. Comparison of temperature compensation and force feedback errors at different flow velocities using traditional dual-FBG method *vs.* causal machine learning method.

| 血流速度/(cm·s <sup>-1</sup> ) | 双FBG补偿误差/N | 因果机器学习误差/N | 效果提升/% |
|----------------------------|------------|------------|--------|
| 5                          | ±0.082     | ±0.024     | 71     |
| 10                         | ±0.103     | ±0.042     | 60     |
| 20                         | ±0.114     | ±0.051     | 55     |

表 2 显示, 在 5—20 cm/s 下, 因果学习将温补偿误差降低 53%—56%, 并将力反馈误差降低 55%—71%, 表明其可有效抑制热-流耦合扰动并提升动态稳定性. 对血管介入手术而言, 更低且更集中的误差意味着远端反馈在不同工况下更一致, 便于术者更可靠地区分贴壁与卡顿摩擦等状态, 从而降低

温漂/噪声引起的误判风险并为闭环安全控制提供更可靠观测.

### 4.3 讨论

三档流速体外实验表明, 本文方法相较传统双 FBG 补偿, 所提方法显著降低温度补偿误差并抑制高流速下力反馈误差退化, 提高了不同血流条件下反馈一致性, 为闭环安全控制提供更可靠观测基础. 在温度补偿与远端力估计上具有更好的跨工况一致性: 误差随流速升高的退化趋势得到抑制, 且误差分布更集中. 其原因在于, 血流对流换热与摩擦生热引起的温度波动会同时影响传感信号与导丝力学响应, 传统基于固定灵敏度/静态标定的双 FBG 补偿在工况变化时易产生参数失配并放大系统偏差; 本文将温度扰动相关效应纳入统一建模与校正流程, 从而提升了动态血流条件下的稳定性.

## 5 结论与展望

本文针对血流热扰动与温度-应变交叉敏感引起的远端力估计偏差, 提出因果学习的双 FBG 温度补偿框架. 该方法融合热-流-固机理建模与结构因果推断, 通过反事实校正削弱温度扰动的非机械贡献, 并结合异质性建模与在线自适应更新提升跨工况稳定性. 能够为术者提供一种更准确且更稳定的远端力触觉反馈, 有助于医生区分导丝与血管壁之间的相互状态, 从而降低血管壁损伤风险并提升主从操作的可控性与安全性.

尽管实验结果验证了所提方法在体外环境中

的有效性,但仍存在一定局限.当前限于体外平台实验,尚未覆盖脉动流、血管顺应性与体温梯度等生理复杂性;同时,端到端延迟与算力开销需在实时部署场景下进一步量化与优化.未来将开展更接近生理条件的离体/体内验证,并进行模型轻量化与实时性评估,以明确泛化边界并满足临床实时需求.

## 参考文献

- [1] Belikov N V, Khaydukova I V, Poludkin 2024 *Eng. Sci. Technol.* **57** 101789
- [2] Pescio M, Li C H, Kundrat D, Casadio M, Dagnino G 2025 *Int. J. Comput. Ass. Rad.* **20** 2259
- [3] Peng Y S, Liu X R, Chan K F, Song X, Zhang L 2025 *SmartBot* **1** e12009
- [4] Song Y, Tian Y, Liutao L, Gao Q, Li Z 2025 *Med. Biol. Eng. Comput.* **63** 3067
- [5] Wang K D, Liu J Y, Yan W Y, Lu Y S, Nie S D 2021 *Int. J. Comput. Ass. Rad.* **16** 179
- [6] Jin X L, Song A G, Zhu J J, Wang C, Zhang Y, Zhu L F 2025 *IEEE Sens. J.* **25** 34491
- [7] Wang S, Shen H, Liu Z, Xie L 2024 *IEEE Sens. J.* **24** 4120
- [8] Pescio M, Kundrat D, Dagnino G 2025 *Minimally Invasive Therapy and Allied Technologies* **34** 123
- [9] Luo M S, Xie H Z, Xie L, Cai P, Gu L X 2014 *Comput. Med. Imag. Grap.* **38** 735
- [10] Wang H Y, Wu J H, Wei M Q, Ma X 2015 *Comput. Med. Imag. Grap.* **40** 160
- [11] Liu Y L, Hu Z 2025 *Comput. Method. Biomech.* **28** 2446
- [12] Floris I, Adam J M, Calderón P A, Sales S 2021 *Opt. Lasers Eng.* **139** 106508
- [13] Zhang L F, Li C L, Dong H J, Liu X J, Sun T, Grattan K T V, Zhao J 2023 *Measurement* **206** 112251
- [14] Idrisov R, Floris I, Rothhardt M, Bartelt H 2021 *Opt. Fiber Technol.* **61** 102319
- [15] Gan L, Wang J B, Xie L H, Zhou Y T 2024 *IEEE Trans. Instrum. Meas.* **73** 7001511
- [16] Gan L, Wang J B, Zhou Y T 2023 *Sensor. Actuat. A: Phys.* **364** 114833
- [17] Li J Y, Dong Z J, Zhang J H, Shi W H, Zheng J J, Wei W 2023 *Acta Phys. Sin.* **72** 144206 (in Chinese) [李建宇, 董忠级, 张吉宏, 史雯慧, 郑加金, 韦玮 2023 物理学报 **72** 144206]
- [18] He C J, He Y L, Yu C X, Luo F, Zhu L Q 2022 *Opt. Fiber Technol.* **74** 103123
- [19] Lou Y Y, Yang T Y, Luo D, Wu J W, Dong Y M 2023 *Sensors* **23** 2866
- [20] Ren B Z, Zhao Y, Zhang J H, Wang C, Li H, Zhang J J 2025 *Sensor. Actuat. A: Phys.* **382** 116128
- [21] Scholkopf B, Locatello F, Bauer S, Ke N R, Kalchbrenner N, Goyal A, Bengio Y 2021 *Proceed. IEEE* **109** 612

# Causal machine learning-based temperature compensation for adaptive force feedback in robot-assisted vascular interventions\*

XIN Shaozong<sup>1) #</sup> HU Zhi<sup>1) # †</sup> SONG Aiguo<sup>2) #</sup> LI Shufan<sup>1) #</sup>

1) (*Laboratory of Intelligent Control and Robotics, Shanghai University of Engineering Science, Shanghai 201620, China*)

2) (*Jiangsu Key Lab of Remote Measurement and Control, State Key Laboratory of Bioelectronics, School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China*)

( Received 3 January 2026; revised manuscript received 11 February 2026 )

## Abstract

Reliable distal force feedback is essential for safe guidewire manipulation in robot-assisted endovascular interventions. However, fiber Bragg grating (FBG) sensors suffer from inherent temperature-strain cross-sensitivity, and blood-flow-induced thermal disturbances further introduce measurement drift under realistic intraoperative conditions. These effects lead to inaccurate temperature compensation and biased distal force estimation, thereby degrading the stability and reliability of force feedback.

This study proposes a causal machine learning-based temperature compensation framework for dual-FBG sensing. A thermo-fluid-solid coupled guidewire model is established to describe the interaction among blood flow, structural deformation, and temperature variation, providing a physics-informed representation of thermal-mechanical coupling. Structural causal modeling is introduced to characterize the causal relationships between temperature variation, sensor signals, and mechanical strain while accounting for latent confounding factors. Counterfactual inference is employed to estimate strain under temperature intervention, enabling effective separation of thermal disturbances from mechanical effects. Heterogeneous treatment effects under different operating conditions are captured using a causal forest model, and an online adaptive learning strategy based on Follow-the-Regularized-Leader (FTRL) is adopted to improve robustness under dynamic environments.

In vitro experiments were conducted on a vascular intervention simulation platform at flow velocities of 5, 10, 15 and 20 cm/s. Compared with the conventional Dual-FBG method, the proposed approach reduces temperature-compensation mean absolute error by more than 50% and decreases distal force estimation error by up to 70%, while suppressing performance degradation at higher flow velocities.

The proposed framework improves the stability and consistency of distal force feedback in dynamic vascular environments, enabling more reliable assessment of guidewire-vessel wall interaction and enhancing the safety of robot-assisted endovascular interventions.

**Keywords:** temperature-strain cross-sensitivity, causal machine learning, force feedback, temperature compensation

DOI: [10.7498/aps.75.20260005](https://doi.org/10.7498/aps.75.20260005)

CSTR: [32037.14.aps.75.20260005](https://cstr.cn/32037.14.aps.75.20260005)

\* Project supported by the National Natural Science Foundation of China (Youth Science Fund Project) (Grant No. 62003207).

# These authors contributed equally.

† Corresponding author. E-mail: [huzhi26@126.com](mailto:huzhi26@126.com)

## 基于因果机器学习温补的血管介入机器人自适应力反馈策略

辛绍宗 胡陟 宋爱国 李树凡

### Causal machine learning–based temperature compensation for adaptive force feedback in robot–assisted vascular interventions

XIN Shaozong HU Zhi SONG Aiguo LI Shufan

引用信息 Citation: *Acta Physica Sinica*, 75, 100004 (2026) DOI: 10.7498/aps.75.20260005

CSTR: 32037.14.aps.75.20260005

在线阅读 View online: <https://doi.org/10.7498/aps.75.20260005>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于优化粒子群–反向传播的温度补偿型空芯光纤法珀应变传感器

Temperature–compensated hollow–core fiber Fabry–Perot strain sensor based on optimized particle swarm optimization–back propagation algorithm

物理学报. 2025, 74(16): 160702 <https://doi.org/10.7498/aps.74.20250524>

#### 具有温度自补偿的保偏光纤布拉格光栅多参量传感器的设计与制备

Temperature–independent multi–parameter sensor based on polarization maintaining fiber Bragg grating

物理学报. 2023, 72(14): 144206 <https://doi.org/10.7498/aps.72.20230478>

#### 基于机器学习与第一性原理计算的高居里温度Janus预测

Prediction of high Curie temperature Janus materials based on machine learning and first–principles calculations

物理学报. 2025, 74(22): 220201 <https://doi.org/10.7498/aps.74.20251026>

#### 基于机器学习的激光匀光整形方法

Machine learning based laser homogenization method

物理学报. 2024, 73(16): 164205 <https://doi.org/10.7498/aps.73.20240747>

#### 机器学习的量子动力学

Quantum dynamics of machine learning

物理学报. 2025, 74(6): 060701 <https://doi.org/10.7498/aps.74.20240999>

#### 蛋白质计算中的机器学习

Machine learning for *in silico* protein research

物理学报. 2024, 73(6): 069301 <https://doi.org/10.7498/aps.73.20231618>