

专题: 低温等离子体非平衡输运与主动调控

基于物理信息神经网络求解 低温等离子体反问题*

李文凯 赵正 张远涛†

(山东大学电气工程学院, 济南 250061)

(2025年8月27日收到; 2025年10月13日收到修改稿)

低温等离子体的反问题是指根据等离子体的密度、电场等物理特性来反演电压幅值、频率等放电参数, 反问题的求解是对等离子体进行智能控制的重要前提, 在流体描述的框架下, 基于传统的离散化方法来求解反问题往往是非常困难的. 本文引入物理信息神经网络 (physics-informed neural networks, PINNs) 对大气压射频等离子体的反问题进行求解, 把连续性方程、泊松方程及漂移扩散近似等主要控制方程与作为待求解放电参数的电压幅值与频率, 及额外的电场数据这3部分作为约束嵌入PINNs的损失函数中. 经过训练后, PINNs可以实现对电压幅值与频率等放电参数的精确反演, 且可以保证误差均在1%以内, 同时也可以完整地输出密度、电场、通量等物理量的时空演化. 为进一步优化额外数据对PINNs计算的影响, 本文还深入分析了电场数据的采样位置、采样数量以及噪声水平对反演电压幅值与频率的效果. 本研究表明, PINNs能够在给定实验或计算数据条件下, 实现射频等离子体放电参数的精准反演及等离子体物理特性的精确计算, 从而为推进对等离子体的智能控制打下基础.

关键词: 低温等离子体, 流体模型, 机器学习, 物理信息神经网络

PACS: 52.27.Cm, 02.10.Yn, 33.15.Vb, 98.52.Cf, 78.47.dc

DOI: 10.7498/aps.74.20251159

CSTR: 32037.14.aps.74.20251159

1 引言

低温等离子体 (low-temperature plasma, LTPs) 在材料表面改性^[1]、微纳加工^[2]、半导体制造^[3]、环境污染治理^[4]、生物灭菌与医疗^[5]、航空航天^[6]推进等领域得到了广泛应用. 由于低温等离子体系统本质上是一个多时空尺度、多物理场强耦合的复杂体系, 特别是在较高气压下往往涉及复杂的多粒子反应, 其数值模拟一直具有一定的挑战^[7]. 目前主流的等离子体描述方法包括流体模型 (fluid models)^[8]、粒子模型 (particle-in-cell, PIC)^[9]和整体模型 (global models)^[10]. 这些模型通常依赖于传

统离散化方法进行求解, 例如有限差分法、有限元法及有限体积法等. 这些数值方法已较为成熟, 在求解低温等离子体正问题, 即根据给定放电参数获取等离子体物理特性方面表现出良好的效果, 其计算效率与精度基本能够满足实际需求. 不过, 面对高维或复杂位形问题时, 传统方法仍有待进一步发展.

在实际应用中, 低温等离子体往往需要满足特定的物理条件 (如达到一定的电子密度、电场强度或电子温度), 以符合特定的应用限制或生产工艺^[11,12]. 比如, 在许多应用场景中, 还会对放电空间的电场强度设定上限, 如果电场强度过高, 可能导致放电过于剧烈, 引发电弧烧蚀, 对实验设备及

* 国家自然科学基金 (批准号: 12375201) 资助的课题.

† 通信作者. E-mail: ytzhang@sdu.edu.cn

处理对象造成损害. 这就引出了一个重要问题, 当等离子体的目标物理特性已知时, 如何反推获得这些特性所需的放电参数, 这本质上是一个反问题的求解过程^[13].

在实践中, 反问题的求解通常依赖大量实验尝试与测量, 例如通过不断调整放电参数、采用二分法等手段来逼近目标特性, 即所谓的“调参数”过程. 与此同时, 等离子体反问题的研究对于实现等离子体的智能调控也具有重要意义. 例如, 可以基于电子密度或电场强度的变化实现放电参数的自适应校正, 以确保等离子体处理效果的一致性; 更进一步, 还可以利用可在线检测的等离子体作用效果 (如杀菌率、污染物去除率、反应物转化率、刻蚀效果等) 来实时调控放电参数, 从而保证等离子体应用效果的有效性、稳定性和一致性^[12].

然而, 从数值计算的角度来讲, 在流体描述下, 传统的离散化方法往往不能求解反问题^[13]. 作为多时空尺度、多物理场耦合的低温等离子体体系所对应的反问题往往是不适用的, 很难进行数值求解. 随着人工智能技术的发展, 新近发展的物理信息神经网络 (PINNs)^[14] 为求解低温等离子体反问题带来了新的希望.

PINNs 方法相较于传统的离散化算法具有无网格特性, 不需要对计算区域进行网格剖分. 其基本思想是将控制方程 (如连续性方程、泊松方程和动量方程) 以及已有的实验或数值数据以约束形式嵌入到神经网络的损失函数中, 通过优化过程求解未知物理量. 由于 PINNs 通过采样点近似方程的残差, 无需求解网格型高维积分, 因此在高维计算中能有效规避传统网格方法所面临的“维度灾难”^[15]. 此外, 其损失函数常采用蒙特卡罗采样方法进行数值积分, 提高了在高维空间中的训练效率. 因此, PINNs 在解决高维及复杂位形等离子体问题方面展现出潜在优势^[16,17], 可作为传统数值离散方法的有益补充.

与传统的离散化方法相同的是 PINNs 可以求解低温等离子体的正问题, 同时 PINNs 可以基于给定的额外数据, 结合控制方程, 并考虑初始条件与边界条件, 有效求解反问题^[14]. 正是利用这一特性, 可以借助于 PINNs 在给定密度、电场、通量等少量等离子体物理特性数据的基础上, 来反求电压幅值、频率、放电间隙等放电参数, 甚至求解某些输运系数与反应系数. 特别值得指出的是, PINNs

求解正问题与反问题采用相同的网络结构, 这极大地降低了求解反问题的复杂度, 也有望成为求解低温等离子体反问题的普适方法.

在低温等离子体领域, PINNs 已经被应用于多个场景. 在低温等离子体的正问题中, 已知系统的边界、初始条件以及相应的物理参数 (如碰撞频率、气体压力、外加电源等), 从而推断出等离子体的物理特性, 如电子密度、电位分布、电子温度以及反应速率系数等. 与传统数值方法相比, PINNs 通过在损失函数中引入等离子体控制方程 (如流体模型的连续性方程、动量方程、能量方程以及泊松方程) 和边界条件, 使得网络在训练过程中显式满足物理约束. 最早, 人工前馈神经网络用来学习电子速度分布函数 (electron velocity distribution function, EVDF)^[18], 其是由 Boltzmann 方程和边界条件共同控制, 不需要将 EVDF 展开为勒让德多项式, 也不需要 EVDF 和 Boltzmann 方程进行离散化. 此后, 元学习和自适应权重的方法被引入 PINNs 对 Boltzmann 方程的求解过程中^[19,20], 大幅度提高了 PINNs 的计算效率. Li 等^[16] 针对一类直流驱动的放电现象, 采用 PINNs 方法求解了描述该放电的流体模型, 完整地求解了泊松方程、连续性方程和漂移扩散近似方程. PINNs 方法也被应用于求解描述大气压射频放电的流体模型, 并通过迁移学习的方法将 PINNs 应用于其他放电条件下, 有效节约了计算成本^[17]. 另外针对等离子体的多粒子种类特性, 一种通用的源项解耦 PINNs 框架被提出^[21], 在低气压氩气辉光放电和大气压氩气辉光放电条件下, 实现了对重离子输运方程源项和电子密度、平均电子能量的解耦. 在低温等离子体反问题中, 通常由有限的实验测量数据 (如探针测量的电位、光谱反演得到的电子密度、射频功率吸收分布等) 来推断系统中未知参数或边界条件, 这在等离子体诊断和模型标定中尤为重要. PINNs 求解反问题的优势在于可以将未知参数 (如碰撞截面、反应速率系数、初始分布函数等) 作为网络的可训练变量, 同时利用物理方程作为正则化约束, 从而在小样本甚至稀疏测量条件下稳定反演. 例如, PS-PINNs (plasma-simulation physics informed neural networks) 被用于氯气的整体放电模型^[22], 在反问题求解中, PS-PINNs 很好地求解了未知反应速率系数并显示出对噪声数据的鲁棒性. 在热等离子体领域, 弗拉索夫-泊松方程正反问题被 PINNs

求解^[23], 对于反问题, 该模型可以使用少量粒子分布数据来预测完全未知的电场和方程系数. 基于 PINNs 使用包含磁学、汤姆逊散射和干涉仪-偏振计数据的多诊断方法对等离子体平衡进行重建^[24], 并在包含噪声测量数据上进行了测试, 结果表明加入干涉仪-偏振计数据显著提高了预测准确度. 另外, Rossi 等^[25]利用 PINNs 对托卡马克中等离子体平衡重建的基础上, 又将 PINNs 应用于干涉仪反演和辐射热计层析成像典型的反问题的求解中, 将重构结果与其他诊断和相关现象的测量结果进行比较, 结果表明 PINNs 可以轻松应用于此类问题. 目前 PINNs 在低温等离子体应用中还较少, 不论是正问题还是反问题, 但是上述研究表明, PINNs 为等离子体放电诊断、参数优化和实验数据分析提供了一种新的方法和思路.

本文基于 PINNs 方法求解低温等离子体反问题, 以典型大气压射频氦气放电为研究对象, 研究 PINNs 反问题求解的完整过程与计算结果. 本文的结构安排如下. 第 2 部分将对所采用的物理模型与 PINNs 方法进行介绍, 其中第 2.1 节给出大气压射频氦气放电的流体模型及其基本方程; 第 2.2 节介绍 PINNs 的基本原理与构建方法; 第 2.3 节则阐述 PINNs 在低温等离子体反问题求解中的具体实现, 包括网络结构设计、损失函数构建以及数据与方程的预处理策略. 第 3 部分为数值结果与分析, 第 3.1 节展示了 PINNs 在反问题中的求解结果, 对电子密度、离子密度、电场、电势以及通量等多个物理场的预测精度进行了评估; 第 3.2 节则系统研究了在不同采样位置、不同采样数量以及不同噪声水平下的反演效果. 最后, 第 4 部分对全文工作进行总结.

2 物理模型

2.1 流体模型

本文采用一维流体模型来研究大气压射频放电的放电机理. 其中连续性方程描述各种粒子的产生和消失, 使用漂移扩散近似方程来描述粒子的运动, 具体的方程如下^[26]:

$$\frac{\partial N_{e,i}(x,t)}{\partial t} + \frac{\partial J_{e,i}(x,t)}{\partial x} = S_{e,i}(x,t), \quad (1)$$

$$J_{e,i}(x,t) = \mp \mu_{e,i} E(x,t) N_{e,i}(x,t) - D_{e,i} \frac{\partial N_{e,i}(x,t)}{\partial x}, \quad (2)$$

其中, $N(x,t)$ 和 $J(x,t)$ 分别代表各种粒子的密度和通量, $S(x,t)$ 指粒子的源项, μ 和 D 分别代表粒子的迁移率和扩散系数, e 和 i 分别代表电子和离子. 在本研究中, 为了清楚给出 PINNs 求解反问题的过程, 对电子和离子的迁移率分别简化处理, 取为常数, 分别为 $1131.6 \text{ m}^2/(\text{V}\cdot\text{s})$ 和 $14.82 \text{ m}^2/(\text{V}\cdot\text{s})$, 电子和离子的扩散系数分别取 $1697.3 \text{ m}^2/\text{s}$ 和 $0.5026 \text{ m}^2/\text{s}$, 这都是大气压氦气放电模拟中常用的数值. $E(x,t)$ 为放电间隙中的电场, 泊松方程用来描述电场和电荷密度的关系, 并且电场是由电势求导得到, 相应方程如下:

$$\frac{\partial E(x,t)}{\partial x} = \frac{q[N_i(x,t) - N_e(x,t)]}{\epsilon_0}, \quad (3)$$

$$\frac{\partial \varphi(x,t)}{\partial x} = -E(x,t), \quad (4)$$

其中, q 和 ϵ_0 分别代表基本电荷和真空介电常数, 电势的边界条件为外加两块极板的电压, 分别为射频电源和 0, 分别为

$$\varphi(0,t) = V_0 \sin(2\pi ft), \quad \varphi(d,t) = 0, \quad (5)$$

其中, V_0 和 f 分别为外加射频电压的幅值和频率, d 为放电空间的间隙.

本文使用的一维纯氦大气压射频放电流体模型所使用的参数包括放电间隙 d 为 0.25 cm , 外加射频电压的幅值 V_0 为 440 V , 频率 f 为 10 MHz , 需要说明的是, 本文之所以选择将频率取在射频频段 (当然最常用的射频频率是 13.56 MHz) 是为了确保放电过程中各个物理量在一个完整的电压周期内都是连续的, 这会给 PINNs 的训练与预测带来极大方便. 而大气压下常用的另一种放电方式——介质阻挡放电形式, 不论是正弦电压驱动还是脉冲电压驱动, 其在一个电压周期内总有放电发生与放电结束的阶段^[27,28], 在这种情况下为了使 PINNs 能做出更好的预测, 可能不得不提供更多的额外数据. PINNs 在处理射频放电与介质阻挡放电时的这种差别将另文讨论. 另外, 为了将研究焦点集中于 PINNs 的构建与计算, 本研究只考虑两种粒子 (电子和氦离子) 和直接碰撞电离反应, 考虑更多反应的计算将以后完成. 极板处的二次电子发射系数设置为 0.03 ^[29]. 一般说来, 使用有限差分法求解上述流体模型^[30], 通常可在进行 2000 个射频周期后放电达到稳定状态, 选取稳定之后的一个射频周期的放电情况作为研究对象. 另外由于在本研究中只考虑了碰撞电离反应, 方程 (1) 的源项

$S(x, t)$ 表示为

$$S_{e,i}(x, t) = Ap\mu_e N_e E e^{-B\sqrt{p/|E|}}, \quad (6)$$

其中 A 和 B 是和气体类型有关的量, 在氦气中分别为 4.4 和 14, p 是气压, 本文取为 760 torr (1 torr = 1.33×10^2 Pa)^[31].

2.2 PINNs 的架构

考虑包含初始条件和边界条件的偏微分方程 (partial differential equation, PDE) 形式如下^[14]:

$$\begin{aligned} u_t + \mathcal{N}(u(t, \mathbf{x}, \lambda)) &= 0, & \mathbf{x} \in \Omega, t \in [0, T], \\ \mathcal{I}(u) &= g(t, \mathbf{x}), & t = 0, \\ \mathcal{B}(u) &= h(t, \mathbf{x}), & \mathbf{x} \in \partial\Omega, \end{aligned} \quad (7)$$

其中, $\mathcal{N}(\cdot)$ 表示 PDE 的线性或非线形算子, $u(x, t)$ 为方程待求解, u_t 为函数 u 对时间 t 的偏导, λ 为方程中的参数, Ω 表示空间变量 x 的定义域, $\partial\Omega$ 表示空间域的边界, 时间 t 的定义域为 $(0, T)$, $\mathcal{I}(\cdot)$ 和 $\mathcal{B}(\cdot)$ 分别表示初始条件算子和边界条件算子, $g(t, \mathbf{x})$ 和 $h(t, \mathbf{x})$ 分别表示初始条件和边界条件.

首先, 建立一个全连接神经网络 $\hat{u}(x, t; \theta)$ 去近似待求解函数 $u(x, t)$, 并定义 PDE 的残差为

$$f(x, t, \lambda; \theta) := \frac{\partial}{\partial t} \hat{u}(x, t, \lambda; \theta) + \mathcal{N}(\hat{u}(t, \mathbf{x}, \lambda; \theta)), \quad (8)$$

其中 θ 为神经网络中的参数, 上述方程残差中的偏导由自动微分算法计算^[14]. 一般来说, PINNs 的损失函数 Loss 定义如下:

$$\text{Loss} = \text{Loss}_{\text{PDE}} + \text{Loss}_{\text{DATA}} + \text{Loss}_{\text{BC}} + \text{Loss}_{\text{IC}}, \quad (9)$$

其中 Loss_{PDE} 为损失函数中方程残差部分, $\text{Loss}_{\text{DATA}}$ 为其他数据驱动部分; Loss_{BC} 和 Loss_{IC} 分别是方程中边界条件和初始条件部分的约束. 损失函数各部分定义如下:

$$\begin{aligned} \text{Loss}_{\text{PDE}} &= f(x, t, \lambda; \theta), \\ \text{Loss}_{\text{DATA}} &= |\hat{u}_{\Omega} - u_{\text{data}}|, \\ \text{Loss}_{\text{BC}} &= |\hat{u}_{\partial\Omega} - u_{\text{BC}}|, \\ \text{Loss}_{\text{IC}} &= |\hat{u}_{\Omega, t_0} - u_{\text{IC}}|. \end{aligned} \quad (10)$$

在损失函数的约束下, 通过梯度下降算法更新神经网络的权重和偏置^[32], 使损失函数尽可能小, 从而使 PINNs 的输出同时满足方程的残差和数据的约束.

与传统数值方法相比, PINNs 能够将物理约束直接嵌入神经网络的损失函数中, 通过自动微分

精确计算方程所需的高阶导数, 从而在有限或稀疏数据条件下同时保证预测结果满足 PDE 及其初边值条件. 这一特性使得 PINNs 在模拟正问题中, 可以直接从已知物理参数与边界条件出发, 直接获得各个物理场的时空分布, 避免了网格划分与显式时间推进的限制; 而在反问题中, 只需要对 PINNs 的网络结构进行微调, 将未知参数 (如物理系数、源项、驱动信号等) 作为可训练变量, 与网络权重一并优化, 就能在拟合观测数据的同时自动反演出系统的隐含物理信息.

2.3 PINNs 求解低温等离子体反问题

在低温等离子体正向问题求解中, PINNs 通过最小化连续性方程、漂移扩散近似和泊松方程的残差 (即流体模型中包含的方程), 在适当的初始条件和边界条件下, 求解关键等离子体物理量 (如电子密度、离子密度、电势和电场等) 的时空演化^[16,17]. 对于反问题, 通过将这些放电参数作为可训练参数嵌入神经网络的损失函数, PINNs 可以利用有限的实验或者计算数据 (例如电场数据) 反演边界条件或某些输运系数, 同时自洽地计算密度、通量、电场等完整的物理特性.

在方程 (1)–(4) 中, 由于粒子密度、粒子通量、电场和电势, 其数量级具有显著的差异 (如在大气压射频放电中: $N_e \sim 10^{10} \text{ cm}^{-3}$, $N_i \sim 10^{10} \text{ cm}^{-3}$, $J_e \sim 10^{16} \text{ cm}^{-3}$, $J_i \sim 10^{14} \text{ cm}^{-3}$, $E \sim 10^3 \text{ V/cm}^3$, $\varphi \sim 10^2 \text{ V}$), 直接输入神经网络进行训练很容易导致权重失衡, 从而引发训练不稳定或难收敛等问题. 为此, 本文对所有物理量和控制参数进行无量纲化处理, 基于基础的气体放电理论, 选择以下特征量来无量纲化各物理量^[14]:

$$\begin{aligned} x_0 &= \frac{1}{Ap}, \quad E_0 = Bp, \quad t_0 = \frac{x_0}{\mu_e E_0}, \\ N_0 &= \frac{\varepsilon_0 E_0}{q x_0}, \quad J_0 = \frac{N_0 x_0}{t_0}, \quad \varphi_0 = E_0 x_0. \end{aligned} \quad (11)$$

因此, 无量纲化之后的各物理量表示为

$$\begin{aligned} \hat{x} &= \frac{x}{x_0}, \quad \hat{t} = \frac{t}{t_0}, \quad \hat{E} = \frac{E}{E_0}, \quad \hat{N}_e = \frac{N_e}{N_0}, \\ \hat{N}_i &= \frac{N_i}{N_0}, \quad \hat{J}_e = \frac{J_e}{J_0}, \quad \hat{J}_i = \frac{J_i}{J_0}, \quad \hat{\varphi} = \frac{\varphi}{\varphi_0}. \end{aligned} \quad (12)$$

在这种无量纲的形式中, 所有的输出都被缩放到 $O(1)$ 阶, 实际上这与传统的离散化方法的通常做法也是一致的. 这种无量纲化过程有利于物理信息

神经网络的训练. 为了提高数值稳定性并确保 PINNs 在训练过程中的收敛性, 无量纲的电场和电势被归一化. 归一化后的电势和电场如下:

$$\hat{E} = \frac{\hat{E} - \hat{E}_{\min}}{\hat{E}_{\max} - \hat{E}_{\min}}, \quad \hat{\phi} = \frac{\hat{\phi} - \hat{\phi}_{\min}}{\hat{\phi}_{\max} - \hat{\phi}_{\min}}. \quad (13)$$

$$\begin{aligned} \text{Loss}_{\text{res}_{1,2}}(\hat{x}, \hat{t}; \theta) &:= \frac{1}{N_f} \sum_{i=0}^{N_f} \left(\frac{\partial \hat{N}_{e,i}}{\partial \hat{t}} + \frac{\partial \hat{J}_{e,i}}{\partial \hat{x}} - A p \mu_e E_0 \hat{N}_e \hat{E} e^{-\sqrt{B/\hat{E}}} \right)^2, \\ \text{Loss}_{\text{res}_{3,4}}(\hat{x}, \hat{t}; \theta) &= \frac{1}{N_f} \sum_{i=0}^{N_f} \left(\hat{J}_{e,i}(x, t) \pm \frac{\mu_{e,i}}{\mu_e} \hat{E} \hat{N}_{e,i} + \frac{D_{e,i} t_0}{x_0^2} \frac{\partial \hat{N}_{e,i}}{\partial x} \right)^2, \\ \text{Loss}_{\text{res}_5}(\hat{x}, \hat{t}; \theta) &:= \frac{1}{N_f} \sum_{i=0}^{N_f} \left[\frac{\partial \hat{E}}{\partial \hat{x}} - (\hat{N}_i - \hat{N}_e) \right]^2, \quad \text{Loss}_{\text{res}_6}(\hat{x}, \hat{t}; \theta) := \frac{1}{N_f} \sum_{i=0}^{N_f} \left(\frac{\partial \hat{\phi}}{\partial \hat{x}} + \hat{E} \right)^2. \end{aligned} \quad (14)$$

并将方程 (13) 中归一化之后的 \hat{E} 和 $\hat{\phi}$ 代入上述残差方程中, 总的方程残差部分的损失函数为

$$\begin{aligned} \text{Loss}_{\text{PDE}} = \text{Loss}_{\text{res}_1} + \text{Loss}_{\text{res}_2} + \text{Loss}_{\text{res}_3} + \text{Loss}_{\text{res}_4} \\ + \text{Loss}_{\text{res}_5} + \text{Loss}_{\text{res}_6}. \end{aligned} \quad (15)$$

因此, 有关方程的损失函数包括上述 6 项, 分别为电子与离子的连续性方程损失项 (第 1 项与第 2 项)、电子与离子的漂移-扩散近似损失项 (第 3 项与第 4 项) 及泊松方程损失项 (第 5 项约束电场与第 6 项约束电势). 正是在损失函数中包含了这些方程项, 才能确保最终给出的物理量满足等离子体的流体描述, 也能保证计算结果具有一定的物理可解释性, 这明显区别于基于深度神经网络的纯数据驱动计算方式 [33,34].

下文给出 PINNs 训练过程中数据部分的约束, 对于反问题, 假设外加射频电源是未知的, 我们给出了电子密度、离子密度的初始条件和边界条件以及电势的一个边界条件 (阴极极板电势为 0), 并结合少量的实验数据或者仿真数据, 实现对幅值和频率的反演. 其中各个场初始条件和边界条件处的损失函数定义为

$$\begin{aligned} \text{Loss}_{\text{BC}} &= \frac{1}{N_{\text{BC}}} \sum_{i=0}^{N_{\text{BC}}} \left[(\hat{N}_{e_BC} - N_{e_BC})^2 \right. \\ &\quad \left. + (\hat{N}_{i_BC} - N_{i_BC})^2 + (\hat{\phi}_{\text{BC}} - \phi_{\text{BC}})^2 \right], \\ \text{Loss}_{\text{IC}} &= \frac{1}{N_{\text{IC}}} \sum_{i=0}^{N_{\text{IC}}} \left[(\hat{N}_{e_IC} - N_{e_IC})^2 \right. \\ &\quad \left. + (\hat{N}_{i_IC} - N_{i_IC})^2 \right]. \end{aligned} \quad (16)$$

各种粒子密度、通量、电场和电势通过泊松方程、连续性方程和漂移扩散近似方程的耦合, 将无量纲化和归一化之后的各个物理量代入方程 (1)–(4) 并定义为 PINNs 损失函数中控制方程部分的约束, 形式如下:

其中, N_{BC} 和 N_{IC} 分别是边界条件和初始条件处采样点的个数. 对于反问题, 总的损失函数如下:

$$\begin{aligned} \text{Loss}_{\text{inverse}} = \omega_1 \text{Loss}_{\text{PDE}} + \omega_2 \text{Loss}_{\text{BC}} \\ + \omega_3 \text{Loss}_{\text{IC}} + \omega_4 \text{Loss}_{\text{data}}, \end{aligned} \quad (17)$$

其中 Loss_{BC} 和 Loss_{IC} 表示为电子密度、离子密度和电势的边界条件和初始条件的约束, 其中电势的边界条件处幅值和频率是未知的. 需要指出的是, 二次电子发射过程体现在电子密度的边界条件中并被包含在边界条件的损失函数中. 另外 $\text{Loss}_{\text{data}}$ 在本研究中采用的是电场的数据点作为额外的约束. $\omega_{1,2,3,4}$ 分别是各部分损失项的权重, 上文已经将所有物理场数据进行无量纲化和归一化处理, 各项损失在数值上处于可比的量级, 在一定程度上缓解了不同物理量因量纲和原始数值尺度差异巨大而导致的梯度失衡问题, 因此在本研究中采用固定的权重, 将其分别设置为 2, 1, 1 和 1.

这样, 在反问题求解的损失函数的数据项中, 包含了待求物理量的初始条件与边界条件, 与正问题求解不同, 其中边界条件中有一部分是未知的 (即电势的时间演化); 还包含了 $\text{Loss}_{\text{data}}$ 项, 即额外数据项. 正是由于包含等离子体物理特性的额外数据项的存在 (本研究以电场数据为例), PINN 可以反演未知的边界条件 (本研究中的电势), 体现了“由果溯因”的思路.

概括地讲, 在基于 PINNs 求解等离子体反问题的研究中, 对求解至关重要的损失函数由 3 部分组成, 第 1 部分为方程项, 体现了流体模型对等离子体的约束, 第 2 部分为初始条件与边界条件, 第 3

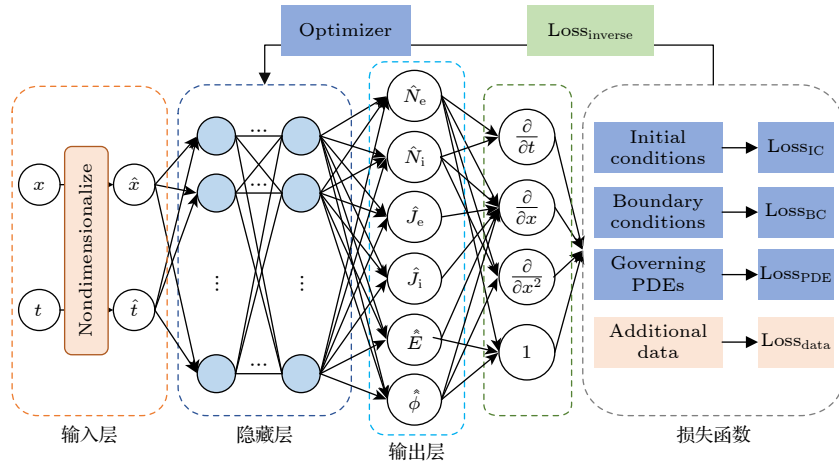


图 1 PINNs 求解流体模型反问题结构图

Fig. 1. Schematic of PINNs for solving forward problem and inverse problem.

部分为额外数据项, 即诊断或者计算获得的等离子体的部分数据. 对于求解反问题而言, 其中第 1 部分中可以有一些未知参数, 比如某些运输系数或者反应系数; 第 2 部分也可以有一些未知条件, 比如电压或相应的表面系数; 这些未知参数或者系数, 需要根据第 3 部分的额外数据 (体现了等离子体的物理特性) 基于 PINNs 来反演获得, 因此, 第 3 部分的额外数据是非常关键的, 数据选取的位置与数量等对于最终反演的精度非常重要.

对于 PINNs 求解流体模型反问题的结构如图 1 所示, 图中展示了基于 PINNs 求解大气压射频氦等离子体流体模型反问题的总体框架. 输入变量为空间坐标和时间, 首先经过无量纲化和归一化的处理, 以消除不同物理量间的数量级差异, 随后作为特征输入到共享相同结构的前馈神经网络中. 网络输出 6 个关键物理场的无量纲化预测值: 电子密度、离子密度、电子通量、离子通量、电势以及电场. 利用神经网络的可微性, 通过自动微分计算输出场对输入变量的偏导数, 进而构建连续性方程、泊松方程和漂移扩散近似方程的残差项, 并结合初始条件与边界条件及额外数据项形成总损失函数.

该 PINNs 网络包含 2 个输入, 6 个输出, 包含 6 个隐藏层且每个隐藏层包含 40 个神经元, 在模型表达能力与计算成本之间取得的平衡, 使得 PINNs 能够充分捕捉放电等离子体中复杂的多尺度物理现象. 每层节点的激活函数选择双弦正切 (Tanh) 函数, 其是二次可微的, 且其导数处处光滑连续, 这为优化过程提供了稳定的梯度流, 对于收敛至关重要. 当然, 需要指出的是 PINNs 网络自身

的构建并不是唯一的, 根据放电等离子体的特点, 可以在隐藏层层数、神经元个数、激活函数组合等方面进一步的调整优化. 这有点类似于在用传统的有限差分法求解流体模型的过程中, 差分格式、空间网格剖分、时间步长选取等方面在收敛的前提下也都不是唯一的.

从数据选取的角度看, 本研究中在一个稳定的射频周期内采用 200 个离散的空间点与其 246 个时间步长构成的时空域内采样点, 其中有 692 个采样点用于电子密度与离子密度的边界和初始条件处的约束, 以及 492 个电势边界处的采样点被加入到损失函数之中. 对于计算域内采用伪随机离散取点方式随机采样 10000 个点用于计算方程残差^[15]. 并将额外一定数量和分布的电场采样点作为数据约束来反演外加电压的幅值和频率, 关于额外电场采样点的取法将在后文专门讨论. 采用 Adam 优化器并设置学习率为 0.001 对 PINNs 迭代训练 30000 次, 然后再采用 L-BFGS 优化器继续训练直到 PINNs 收敛^[35]. Adam 具有自适应学习率, 在优化初期能够快速降低损失函数, 远离初始点, 当接近最优解时, L-BFGS 利用二阶信息可以更精确地找到最小值, 这种双优化器协调训练的策略, 既能够保证计算效率, 又能获得物理上合理的精确解.

3 结果讨论

3.1 PINNs 求解流体模型反问题

以大气压射频氦气放电为例, 将电压的幅值与频率作为可训练参数加入到神经网络之中, 即电势

边界条件. 同时, 将阳极极板 $E(d, t)$ 处电场数值作为额外的数据代入损失函数之中进行训练. 为高效求解物理场中的优化问题, 本研究采用了一种混合优化策略, 依次使用 Adam 与 L-BFGS 优化器以兼顾收敛速度与求解精度. 图 2 给出了 PINNs 在反问题训练过程中的总损失及各分量损失随迭代次数的变化曲线. 在初始阶段, 采用 Adam 优化器进行全局探索, 损失函数从初始值快速下降了 3 个数量级, 快速逼近最优解, 说明网络在短时间内捕捉到了流体模型的主要物理特征; 随后损失函数在 30000 步迭代之后开始由 L-BFGS 优化, 使损失函数进一步平稳下降并最终收敛在 1×10^{-5} 的量级附近. 整个优化过程在单一 NVIDIA GeForce RTX 4060Ti GPU 平台上完成, 总计算时间约为 20 min, 体现了该混合优化策略在保证高求解精度的同时, 具有良好的计算效率.

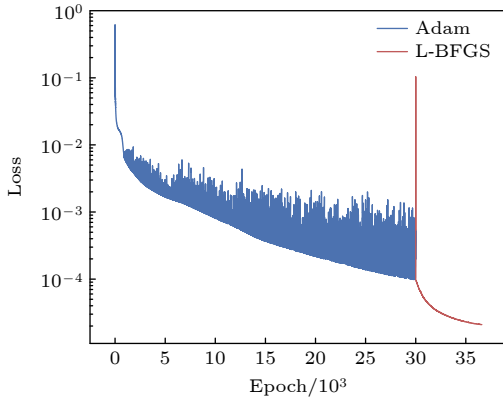


图 2 PINNs 训练过程中损失函数的变化曲线

Fig. 2. Variation curve of loss function in PINNs training process.

在训练过程中, PINNs 对电压幅值和频率这两个可训练参数进行逐步优化. 从图 3 可以看出, 初始阶段预测参数与真实值存在明显偏差, 随着训练步长的增大, 两个参数均逐渐向目标值收敛. 如图 3 所示, 电压幅值和频率在训练前期波动较大, 但在后期逐渐稳定在约 440 V 和 10 MHz 附近, 最终反演的幅值和频率分别为 437.01 V 和 10.010 MHz, 与实际电源参数的相对误差分别为 0.68% 和 0.1%. 图 4 进一步对比了在给定位置为 $x = d$ 处, 外加电势边界条件的实际分布与 PINNs 反演结果. 两者曲线几乎重合, 表明 PINNs 反演得到的幅值和频率与真实值高度一致. 从本质上讲, PINNs 反演出来的是作为边界条件的电势随时间的演化, 因此可以同时得到电压幅值与频率. 这表

明 PINNs 能够在神经网络训练的迭代优化中, 有效利用流体模型物理方程的约束与额外数据的信息, 实现对放电参数的反演. 该过程验证了 PINNs 在等离子体反问题求解中的可行性与可能的精度.

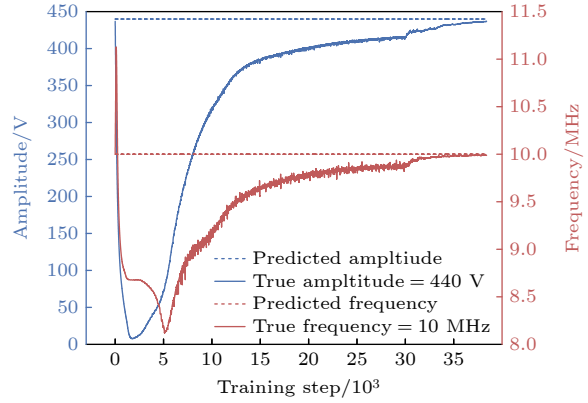


图 3 训练过程中可训练参数幅值和频率的变化曲线

Fig. 3. Variation curve of amplitude and frequency of trainable parameters during training.

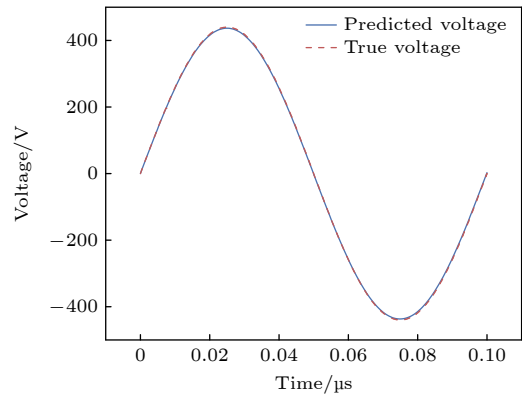


图 4 由 PINNs 反演得到的边界条件和实际电压边界条件的比较

Fig. 4. Comparison between boundary conditions obtained by PINNs inversion and actual power supply boundary conditions.

图 5 所示为 PINNs 与离散化方法求解流体模型在电子密度、离子密度和电场强度分布上的结果对比. 从图 5 可以看出, PINNs 完全可以再现传统数值方法得到的结果, 对于电子密度误差主要出现在鞘层区域, 此时电子密度的变化梯度较大, 另外电子密度和电场强度的误差主要体现在阳极极板处, 因为在本研究中并未考虑离子的消失反应, 在离子到达边界处时, 强制将粒子密度等于边界处设置的密度, 因此在此位置离子密度会有个突变, 同时在此位置叠加电子密度在鞘层附近的误差, 使得电场在此位置误差较大. 总的来说误差主要集中在

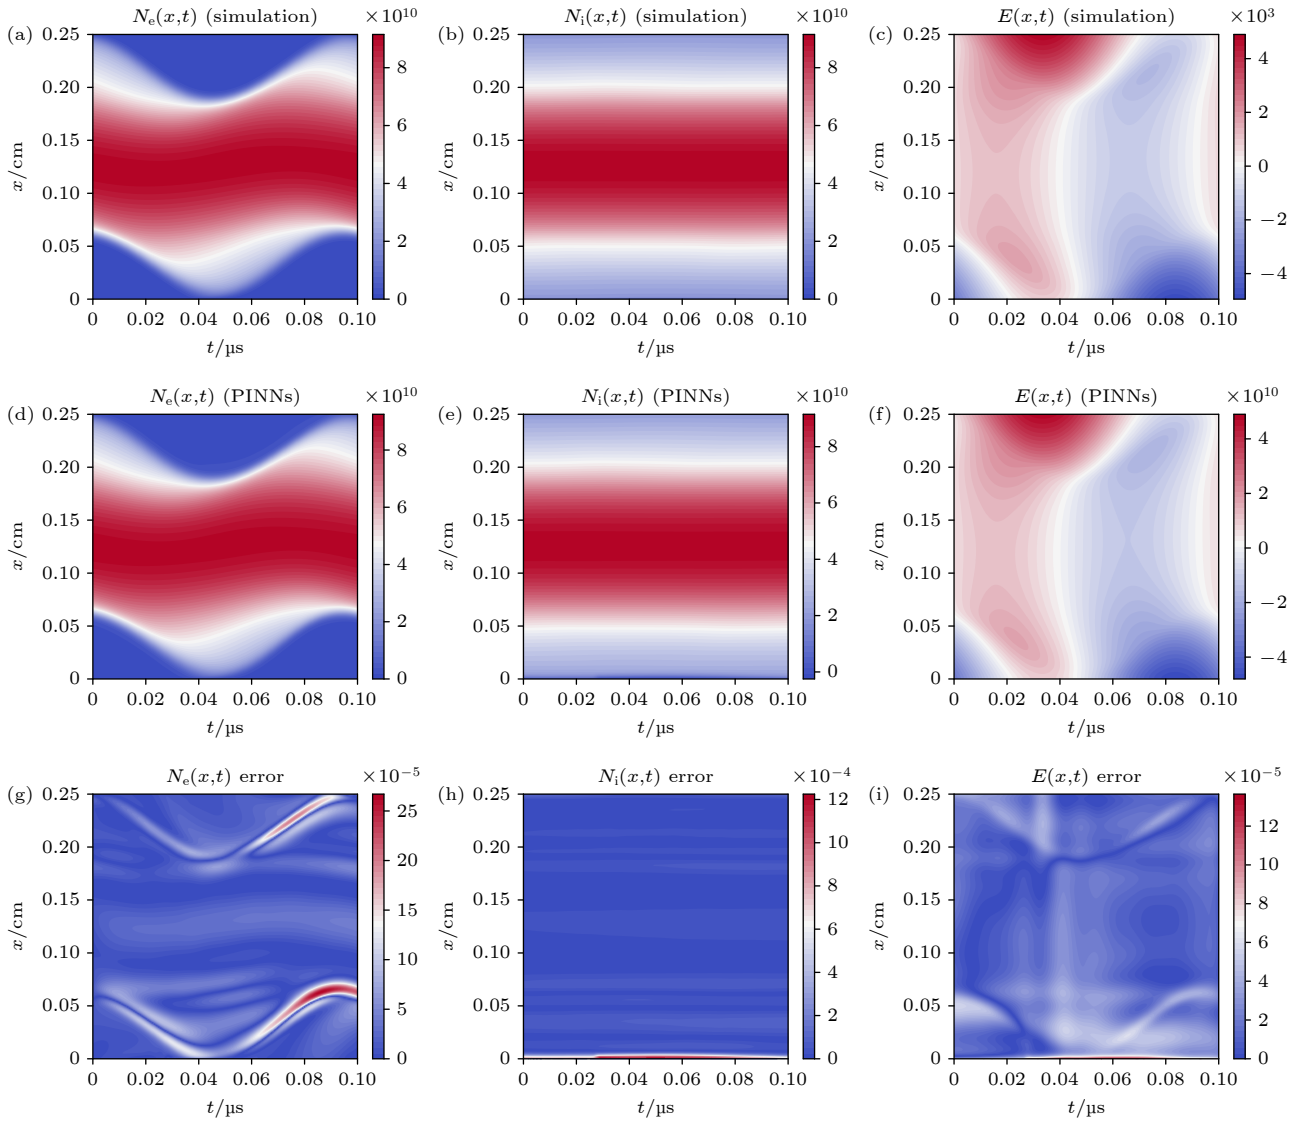


图5 PINNs与传统流体模型在电子密度、离子密度和电场强度分布的对比结果 (a)–(c)数值模拟结果; (d)–(f) PINNs 预测结果; (g)–(i) 误差分布

Fig. 5. The comparison results of electron density, ion density and electric field intensity distribution between PINNs and traditional fluid model: (a)–(c) Numerical simulation results; (d)–(f) prediction results of PINNs; (g)–(i) error distribution.

鞘层区域和梯度变化较大的位置, 这与这些区域存在较强的非线性变化有关. 各个物理场整体误差低于 0.001, 表明 PINNs 能够准确捕捉等离子体放电的主要特征.

图6所示为 PINNs 与传统流体模型在电子通量、离子通量和电势分布上的结果对比, PINNs 与流体模型结果都非常一致, 尤其在鞘层边界和放电中心区域, PINNs 能准确再现电荷输运特性和电势分布. 误差主要集中在鞘层和边界附近, 与边界条件的强约束及有限采样造成的局部拟合误差有关, 当然, 这也部分是由鞘层及边界处的物理特点决定的.

图7对比了峰值电流时刻的电场分布 (图7(a)) 以及电子密度和离子密度的空间分布 (图7(b)). 结果表明, 在电流峰值时刻, PINNs 预测的空间分布与传统离散化方法计算结果完全一致. 这表明 PINNs 不仅能够预测稳态或周期性分布, 还能准确捕捉瞬态的等离子体分布. 另外需要指出, 在大气压下等离子体区会存在电场来克服频繁碰撞以推进带电粒子的定向输运, 同时欧姆加热也是大气压下电子的主要加热方式, 因此等离子体区有一定的电场存在 (图7(a)), 电子密度与离子密度也有一些差别, 这是大气压放电区别于低气压放电的重要特征之一^[30].




图 6 PINNs 与传统流体模型在电子通量、离子通量和电势分布的对比结果 (a)–(c) 流体模型结果; (d)–(f) PINNs 预测结果; (g)–(i) 误差分布

Fig. 6. Comparison of electron flux, ion flux and potential distribution: (a)–(c)The result of fluid model; (d)–(f) the prediction result of PINNs; (g)–(i) the error.




图 7 电流峰值时刻 PINNs 与传统流体模型计算得到的 (a) 电场、(b) 电子密度和离子密度的对比

Fig. 7. Comparison of (a) electric field, (b) electron density and ion density calculated by current peak time PINNs and traditional fluid model.

上述结果显示, PINNs 在全域范围内能够同时计算多个物理场, 给出传统流体模型所能给出的全部待求物理量, 并且可以通过额外的数据以极高的精度反演放电参数. 这得益于 PINNs 将流体模型包含的方程约束直接嵌入损失函数, 使网络在拟合给定额外数据的同时, 满足物理方程和边界条件, 从而增强了泛化能力. 这与以神经网络为代表的纯数据驱动的模拟研究只能给出部分物理场且计算结果泛化性较差是明显不同的 [32,33].

3.2 采样点对 PINNs 反演的影响

在利用 PINNs 进行等离子体反问题求解时, 未知参数的反演往往依赖于有限的额外数据, 因为数据中可以提供关键的物理信息, 从而可以部分地为反演放电参数指明优化的方向. 然而, 在实际诊断条件下, 观测数据不仅数量有限, 而且其分布位置、采样点的多少以及不可避免的噪声干扰, 都会显著影响反演的稳定性与精确性. 若采样点分布不合理, 可能导致网络在关键区域缺乏有效约束; 若采样点数量不足, 数据无法提供足够的关键物理信息, 则可能造成方程与数据约束之间失衡, 降低学

习效果; 而观测噪声则会进一步干扰损失函数的优化过程, 影响模型对物理参数的识别能力. 因此, 有必要系统研究采样位置、采样数量及噪声水平对 PINNs 反演性能的影响, 以明确其不同实验条件下的适用性和鲁棒性, 同时也为实验中应该获得数据的位置和数据数量提供理论参考.

表 1 所示为不同电场采样点位置下反演出的幅值和频率及其相对误差. 结果显示, 大多数位置的幅值误差在 1%—2% 之间, 频率误差小于 1%. 其中, 阳极附近位置 $E(d, t)$ 的反演效果最佳 (幅值误差 0.68%, 频率误差 0.099%). 部分原因在于由于射频放电的连续性, 任何位置的电场演化都可以提供外加电压的变化信息. 给定电场的空间分布和粒子密度的时间分布无法成功完成训练, 原因是对电势的约束不足, 缺乏有效信息, 导致神经网络无法提取有用特征完成参数反演.

表 2 在采样位置 $E(d, t)$ 固定的情况下, 研究了不同采样点数量对反演精度的影响. 结果表明, 当采样点数从 200 减少到 30 时, 反演精度几乎不受影响, 幅值和频率误差均保持在约 1% 和 0.1%. 但当采样点减少到 20 或 10 时, 幅值和频率误差显

表 1 在不同采样点位置条件下 PINNs 反演的幅值和频率
Table 1. Amplitude and frequency of PINNs inversion at different sampling points.

数据集	采样点位置	幅值 \hat{V}_0	幅值相对误差/%	频率 \hat{f}	频率相对误差/%
1	$E(0, t)$	435.83	0.94811	10.046	0.46051
2	$E\left(\frac{1}{4}d, t\right)$	434.03	1.3559	9.981	0.18646
3	$E\left(\frac{1}{2}d, t\right)$	431.73	1.88	10.023	0.23
4	$E\left(\frac{3}{4}d, t\right)$	432.65	1.67	10.015	0.15
5	$E(d, t)$	437.01	0.68	10.010	0.099
6	$E(x, 0)$	—	—	—	—
7	$N_e\left(\frac{1}{2}d, t\right) + N_i\left(\frac{1}{2}d, t\right)$	—	—	—	—

表 2 在不同采样点数量条件下 PINNs 反演的幅值和频率
Table 2. Amplitude and frequency of PINNs inversion with different sampling points.

数据集	采样点数量	幅值 \hat{V}_0	幅值相对误差/%	频率 \hat{f}	频率相对误差/%
1	200	436.27	0.847	10.010	0.10
2	150	437.50	0.569	10.011	0.12
3	100	437.01	0.679	10.011	0.10
4	50	436.83	0.720	10.013	0.13
5	30	436.21	0.860	10.011	0.11
6	20	434.92	1.154	10.010	0.10
7	10	429.58	2.368	10.019	0.19

著上升,尤其是采样点为 10 时,幅值误差为 2.368%,频率误差为 0.19%. 并且可以看出,采样点数量减少对于频率的影响较小,因为对于 PINNs 来说,所给的边界条件的约束已经能够给出各个场随射频电源在极板间来回变化的演化特性,因此 PINNs 比较容易就能够准确的反演出电压频率. 图 8 所示为不同数量采样点条件下 PINNs 反演的幅值和频率相对误差的变化曲线,可以看出, PINNs 反演的幅值和频率的相对误差整体上随着采样点数量的减少而增大,这说明在采样数量过少的情况下,约束不足会降低参数反演的稳定性和准确性.

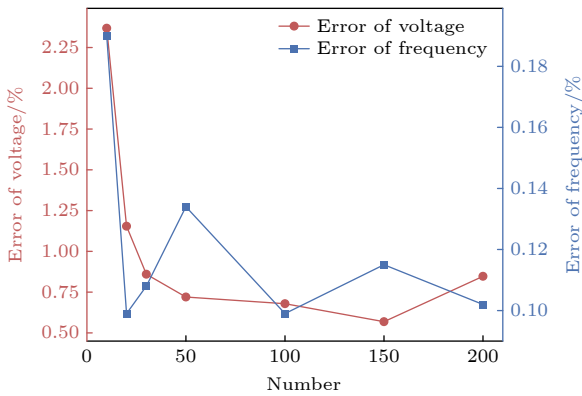


图 8 不同数量采样点条件下 PINNs 反演电压幅值与频率相对误差的变化曲线
Fig. 8. Variation curves of amplitude and frequency relative errors of PINNs inversion under different number of sampling points.

表 3 在 $E(d, t)$ 位置采样的基础上,分析了不同噪声水平下的反演精度. 在本研究中,对电场的数据添加高斯噪声,其由均值 (μ , 设为 0) 和标准差 (σ , 控制噪声强度) 两个参数描述,因此只需要一个参数 (标准差 σ) 就能定义噪声水平. 在数据预处理阶段,对电场进行了无量纲化和归一化的处理,因此将噪声的标准差 σ 范围设置为 0—0.12,来探究 PINNs 在不同噪声水平下的反演精度. 结果显示,在噪声水平 0.01—0.06 时,幅值误差维持在 0.3% 以内,频率误差维持在 0.01% 以内. 另外值得注意的是,在噪声水平为 0.06 时,幅值误差最小,此时仅为 0.345%,可能是因为添加的边界电场的噪声数据,在极板处产生一个较大的波动,使得 PINNs 反而在较高的噪声水平下得到的结果更准确. 但当噪声水平达到 0.06 及以上时,误差显著增大,尤其在 0.12 噪声水平下,幅值误差达到 2.716%,频率误差接近 3%. 图 9 给出了不同噪声水平下 PINNs

反演的幅值和频率相对误差的变化曲线,可以看出, PINNs 反演的幅值和频率的相对误差对中低噪声情况下有一定的抑制作用,当噪声过大时,反演的整体误差会随着噪声的增大而增大,这说明 PINNs 对中低噪声具有较强鲁棒性而高噪声会严重干扰网络对有效物理特征的提取能力.

表 3 不同噪声水平条件下 PINNs 反演的幅值和频率
Table 3. Amplitude and frequency of PINNs inversion under different noise levels.

数据集	噪声水平	幅值 \hat{V}_0 /V	幅值 相对误差/%	频率 \hat{f} /MHz	频率 相对误差/%
1	0.01	438.34	0.378	10.010	0.098
2	0.02	438.48	0.345	10.008	0.078
3	0.04	439.37	0.144	10.002	0.021
4	0.06	439.78	0.051	10.009	0.092
5	0.08	434.44	1.263	9.934	0.646
7	0.1	432.09	1.797	9.915	0.850
8	0.12	428.05	2.716	9.8873	1.127

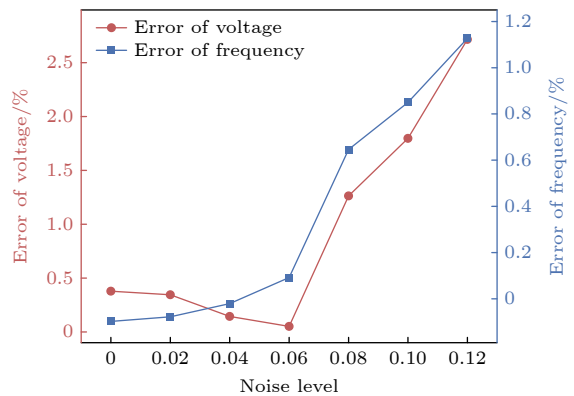


图 9 不同采样点噪声条件下 PINNs 反演的幅值和频率相对误差的变化曲线
Fig. 9. Variation curves of amplitude and frequency relative errors of PINNs inversion under different noise level of sampling points.

上述结果表明, PINNs 能够在有限实验数据条件下准确反演放电关键参数,在实际应用中,应优先选择高信噪比、物理特征明显的位置进行数据诊断,并结合降噪方法提高 PINNs 反演的准确性.

4 结 论

等离子体反问题的求解,即基于等离子体的物理特性反演放电参数,是对等离子体进行智能控制的前提与基础. 在实践中,反问题的解决,即目标等离子体物理特性的实现往往是通过放电参数“逼

近”的方式来实现. 而借助于传统离散化方法, 在等离子体的流体描述下直接求解反问题往往面临巨大的困难, 随着深度学习技术的不断发展, 物理信息神经网络的引入为流体框架下求解等离子体反问题带来新的思路. 本文提出了一种基于物理信息神经网络的反问题求解方法, 用于大气压射频放电流体模型的反问题研究. 在 PINNs 框架中, 将连续性方程、泊松方程及漂移扩散近似等控制方程, 及初始条件与边界条件作为约束嵌入神经网络的损失函数, 将外加射频电压的电压幅值与频率作为可训练参数, PINNs 能够在给定电场数据 (实验诊断或者数值计算) 的情况下成功反演出电压幅值与频率, 并且能够同时预测电子密度、离子密度、电子通量、离子通量、电场和电势等物理场的时空分布, 其结果与数值模拟结果展现出良好的一致性, 验证了 PINNs 在反演未知参数方面的可行性与有效性. 同时研究了不同采样点与噪声水平对反演精度的影响, 研究表明合理选择数据的分布与数量能显著提升反演精度; 一般说来, 在中低噪声水平下, PINNs 仍能精确地反演放电参数, 显示出一定的噪声鲁棒性, 这表明在大气压射频放电计算中, PINNs 求解过程对数据质量的要求并不特别高. 本文的研究表明在流体描述下, 结合实验诊断数据或计算数据, PINNs 方法可以用来求解等离子体反问题, 基于等离子体的物理特性推知各种放电参数, 甚至有望求解或修正等离子体计算中的一些输运系数与反应系数, 实现数值模拟与实验诊断的高度一致, 为等离子体的智能控制打下基础.

参考文献

- [1] Massines F, Gouda G 1998 *J. Phys. D: Appl. Phys.* **31** 3411
- [2] Huang X, Li Y, Zhong X 2014 *Nanoscale Res. Lett.* **9** 572
- [3] Jüstel T, Krupa J C, Wiechert D U 2001 *J. Lumin.* **93** 179
- [4] Magureanu M, Bradu C, Piroi D, Mandache N B, Parvulescu V 2013 *Plasma Chem. Plasma Process.* **33** 51
- [5] Whittaker A G, Graham E M, Baxter R L, Jones A C, Richardson P R, Meek G, Campbell G A, Aitken A, Baxter H C 2004 *J. Hosp. Infect.* **56** 37
- [6] Santhanakrishnan A, Reasor D A, Lebeau R P 2009 *Phys. Fluids* **21** 043602
- [7] Shukla P K, Mamun A 2015 *Introduction to Dusty Plasma Physics* (Boca Raton: CRC Press)
- [8] Zhang X, Zhang X F, Li H P, Wang L Y, Zhang C, Xing X H, Bao C Y 2014 *Appl. Microbiol. Biotechnol.* **98** 5387
- [9] Chen Z Q, Liu M H, Xia G Q, Huang Y R 2012 *IEEE Trans. Plasma Sci.* **40** 2861
- [10] Munro J J, Tennyson J 2008 *J. Vac. Sci. Technol. A* **26** 865
- [11] Lu X P, Reuter S, Laroussi M, Liu D W 2019 *Nonequilibrium Atmospheric Pressure Plasma Jets: Fundamentals, Diagnostics, and Medical Applications* (Boca Raton: CRC Press)
- [12] Kong M G, Kroesen G, Morfill G, Nosenko T, Shimizu T, VanDijk J, Zimmermann J L 2009 *New J. Phys.* **11** 115012
- [13] Ames W F 2014 *Numerical Methods for Partial Differential Equations* (Cambridge, MA: Academic Press)
- [14] Raissi M, Perdikaris P, Karniadakis G E 2019 *J. Comput. Phys.* **378** 686
- [15] Wu C X, Zhu M, Tan Q Y, Kartha Y, Lu L 2023 *Comput. Methods Appl. Mech. Eng.* **403** 115671
- [16] Li W K, Zhang Y T 2025 *J. Appl. Phys.* **137** 20
- [17] Li W, Zhang Y 2025 *Phys. Fluids* **37** 077159
- [18] Kawaguchi S, Takahashi K, Ohkama H, Makabe T 2020 *Plasma Sources Sci. Technol.* **29** 025021
- [19] Wu B, Zhong L 2022 *Frontier Academic Forum of Electrical Engineering* (Beijing: Chinese Society of Electrical Engineering) p1083
- [20] Zhong L L, Wu B Y, Wu Q 2024 *Trans. China Electrotechn. Soc.* **39** 3457 (in Chinese) [仲林林, 吴冰钰, 吴奇 2024 电工技术学报 **39** 3457]
- [21] Fang Z, Pan Y Q, Dai D, Zhang J B 2024 *Acta Phys. Sin.* **73** 145201 (in Chinese) [方泽, 潘泳全, 戴栋, 张俊勃 2024 物理学报 **73** 145201]
- [22] Kwon H, Kim E, Cho S, Kwon D C, Choe H, Choi M 2024 *East Asian J. Appl. Math.* **14** 636
- [23] Zhang B Y, Cai G B, Weng H Y, Wang W Z, Liu L H, He B J 2023 *Mach. Learn. Sci. Technol.* **4** 045015
- [24] Rutigliano N, Rossi R, Murari A, Gelfusa M, Craciunescu T, Mazon D, Gaudio, P 2025 *Plasma Phys. Control. Fusion* **67** 065029
- [25] Rossi R, Gelfusa M, Murari A 2023 *Nucl. Fusion* **63** 126059
- [26] Zhang Y T, Li Q Q, Lou J, Lou J and Li Q M 2010 *Appl. Phys. Lett.* **97** 14
- [27] Massines F, Rabehi A, Decomps P, Gadri R B, Ségur P, Mayoux C 1998 *J. Appl. Phys.* **83** 2950
- [28] Vanraes P, Nikiforov A, Bogaerts A, Leys C 2018 *Sci. Rep.* **8** 10919
- [29] Shi J J, Kong M G 2005 *J. Appl. Phys.* **97** 023306
- [30] Yuan X H, Raja L L 2003 *IEEE Trans. Plasma Sci.* **31** 495
- [31] Chen C Q, Yang Y H, Xiang Y, Hao W R 2025 *J. Sci. Comput.* **104** 54
- [32] Tian Y J, Zhang Y Q, Zhang H B 2023 *Mathematics* **11** 682
- [33] Wang X C, Li W K, Ai F, Liu Z B, Zhang Y T 2023 *Chin. J. Theor. Appl. Mech.* **55** 2900 (in Chinese) [王绪成, 李文凯, 艾飞, 刘志兵, 张远涛 2023 力学学报 **55** 2900]
- [34] Zhang Y T, Gao S H, Zhu Y Y 2023 *J. Appl. Phys.* **133** 5
- [35] Moritz P, Nishihara R, Jordan M 2016 *Artif. Intell. Stat.* **1** 249

SPECIAL TOPIC—Non-equilibrium transport and active control strategy in low-temperature plasmas

Solving inverse problems of low-temperature plasmas by physics-informed neural networks*

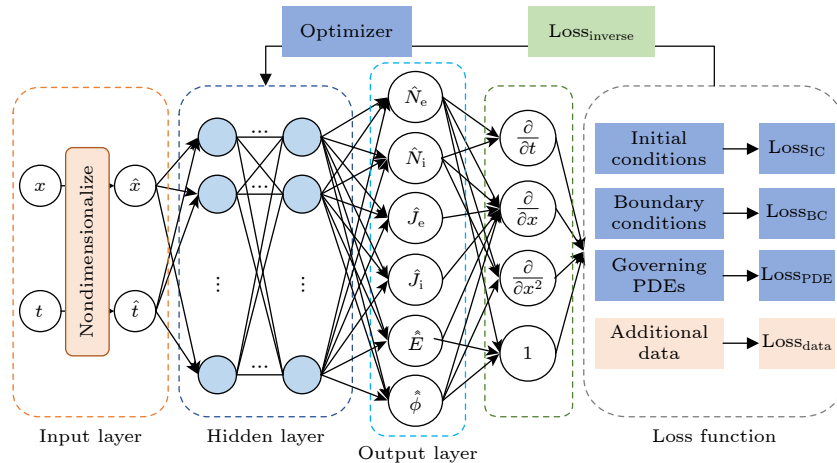
LI Wenkai ZHAO Zheng ZHANG Yuantao[†]

(School of Electrical Engineering, Shandong University, Jinan 250061, China)

(Received 27 August 2025; revised manuscript received 13 October 2025)

Abstract

The inverse problem of low-temperature plasmas refers to determining discharge parameters such as voltage amplitude and frequency from plasma characteristics, including plasma density, electric field and electron temperature. Within the framework of fluid description, it is usually very challenging to address inverse problems by using traditional discretization methods. In this work, physics-informed neural networks (PINNs) are introduced to solve the inverse problem of atmospheric-pressure radio-frequency plasmas. The loss function of the PINNs is constructed by embedding three components: the main governing equations (continuity equation, Poisson equation, and drift–diffusion approximation), the discharge parameters to be inferred (voltage amplitude and frequency in this study), and additional electric field data. The well-trained PINNs can accurately recover the discharge parameters with errors within about 1%, while providing the full spatiotemporal evolution of plasma density, electric field, and flux. Furthermore, the effects of sampling positions, sampling sizes, and noise levels of the electric field data on the inversion accuracy of voltage amplitude and frequency are systematically investigated. The results demonstrate that PINNs are capable of achieving precise inversions of discharge parameters and accurate prediction of plasma characteristics under given experimental or computational data, thereby laying a foundation for the intelligent control of low-temperature plasmas.



Keywords: low-temperature plasma, fluid model, machine learning, physics-informed neural networks

PACS: 52.27.Cm, 02.10.Yn, 33.15.Vb, 98.52.Cf, 78.47.dc

DOI: 10.7498/aps.74.20251159

CSTR: 32037.14.aps.74.20251159

* Project supported by the National Natural Science Foundation of China (Grant No. 12375201).

[†] Corresponding author. E-mail: ytzhang@sdu.edu.cn

基于物理信息神经网络求解低温等离子体反问题

李文凯 赵正 张远涛

Solving inverse problems of low-temperature plasmas by physics-informed neural networks

LI Wenkai ZHAO Zheng ZHANG Yuantao

引用信息 Citation: *Acta Physica Sinica*, 74, 235207 (2025) DOI: 10.7498/aps.74.20251159

CSTR: 32037.14.aps.74.20251159

在线阅读 View online: <https://doi.org/10.7498/aps.74.20251159>

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

基于源项解耦的物理信息神经网络方法及其在放电等离子体模拟中的应用

Physics-informed neural networks based on source term decoupled and its application in discharge plasma simulation

物理学报. 2024, 73(14): 145201 <https://doi.org/10.7498/aps.73.20240343>

基于梯度优化物理信息神经网络求解复杂非线性问题

Solving complex nonlinear problems based on gradient-optimized physics-informed neural networks

物理学报. 2023, 72(10): 100202 <https://doi.org/10.7498/aps.72.20222381>

基于扩展混合训练物理信息神经网络的非线性薛定谔方程求解和参数发现

Solving nonlinear Schrödinger equations and parameter discovery via extended mixed-training physics-informed neural networks

物理学报. 2025, 74(16): 160201 <https://doi.org/10.7498/aps.74.20250422>

信息表征-损失优化改进的物理信息神经网络求解偏微分方程

allaPINNs: A physics-informed neural network with improvement of information representation and loss optimization for solving partial differential equations

物理学报. 2025, 74(18): 188701 <https://doi.org/10.7498/aps.74.20250707>

结合机器学习的大气压介质阻挡放电数值模拟研究

Numerical study of discharge characteristics of atmospheric dielectric barrier discharges by integrating machine learning

物理学报. 2022, 71(24): 245201 <https://doi.org/10.7498/aps.71.20221555>

基于深度物理启发神经网络的微波波导器件逆设计方法

Inverse design of microwave waveguide devices based on deep physics-informed neural networks

物理学报. 2023, 72(8): 080201 <https://doi.org/10.7498/aps.72.20230031>