

专题: 低温等离子体非平衡输运与主动调控

# 基于机器学习从单颗粒动力学中诊断 尘埃等离子体全局性质信息\*

梁晨 卢少瑜 黄栋 陈鑫 冯岩†

(苏州大学等离子体物理与技术研究所, 物理科学与技术学院, 前沿材料物理与器件省高校重点实验室, 苏州 215006)

(2025年8月22日收到; 2025年9月9日收到修改稿)

利用机器学习技术开发了一种全新的实验诊断方法, 纯粹基于单颗粒的位置涨落信息, 实现了对二维尘埃等离子体屏蔽参数  $\kappa$  和耦合参数  $\Gamma$  等全局性质信息的准确诊断, 并通过模拟和实验数据有效验证. 为了训练、验证和测试神经网络模型, 针对二维尘埃等离子体系统, 本文实施了不同  $\kappa$  和  $\Gamma$  数值下数百组独立的朗之万动力学模拟, 以获取大量的单颗粒动力学数据. 为了验证该诊断方法的可行性, 设计了三种不同的卷积神经网络模型, 用于实现对该系统屏蔽参数  $\kappa$  的诊断. 分析结果显示, 这三种模型对  $\kappa$  诊断结果和设定值几乎一致, 均方根误差分别为 0.081, 0.279 和 0.155, 表现达到预期. 而对实验数据, 诊断出的  $\kappa$  数值分布呈单峰分布, 且峰值位置与传统方法诊断出的  $\kappa$  数值高度一致. 在此基础上, 对该诊断方法进行了进一步的优化改进, 使其能同时确定二维尘埃等离子体系统的屏蔽参数  $\kappa$  和耦合参数  $\Gamma$ , 并通过模拟和实验数据确认其准确性. 本文设计的卷积神经网络, 其优异表现清楚地表明, 通过机器学习, 能够仅根据单颗粒动力学信息准确诊断尘埃等离子体系统的全局性质信息.

**关键词:** 机器学习, 卷积神经网络, 尘埃等离子体, 诊断**PACS:** 52.27.Gr, 52.27.Lw, 64.30.-t**DOI:** 10.7498/aps.74.20251129**CSTR:** 32037.14.aps.74.20251129

## 1 引言

对于任何物理系统, 其全局性质参数的有效量化是很多研究的基础. 基于统计力学理论, 系统微观组分的动力学信息是该系统宏观群体性的物理性质的根源<sup>[1]</sup>. 在统计力学理论中, 通过对大量颗粒的位置和速度等动力学信息进行系综分析, 就能给出描述所研究系统集体行为的全局性质参数. 但是, 在实际的物理研究中, 由于实验硬件条件或系统客观物理性质的限制, 准确获取足够进行系综分析的颗粒动力学信息一般很困难. 事实上, 实验中其实无法同时精确获得颗粒的位置和速度信息<sup>[2,3]</sup>.

尘埃等离子体, 也称复杂等离子体, 是由微米

级尘埃颗粒浸没于等离子体中形成的混合体系<sup>[4,5]</sup>. 由于等离子体中的自由电子和离子的存在, 浸没于其中的尘埃颗粒会受到等离子体环境的影响而被充电, 最终获得高达  $10^4$  数量级的负电荷<sup>[6]</sup>. 在地面实验条件下, 当带电尘埃坠落至下电极鞘层区域时, 鞘层中的强电场将提供向上的电场力, 这使得尘埃颗粒能悬浮在鞘层中并自组织形成单层结构, 即二维复杂等离子体<sup>[7-10]</sup>. 过去的研究确认, 尘埃颗粒间的相互作用可以用汤川排斥势描述, 即  $\phi_{ij} = Q^2 \exp(-r_{ij}/\lambda_D)/4\pi\epsilon_0 r_{ij}$ , 其中  $Q$  是颗粒电荷量,  $r_{ij}$  是颗粒  $i$  和  $j$  之间的距离,  $\lambda_D$  是由于自由电子和离子的屏蔽作用而产生的德拜长度<sup>[11]</sup>. 由于尘埃颗粒的电荷量通常非常高, 导致临近颗粒间势

\* 国家自然科学基金 (批准号: 12175159) 和江苏省高等学校重点学科建设项目资助的课题.

† 通信作者. E-mail: fengyan@suda.edu.cn

能远大于其动能, 颗粒间呈强耦合效应<sup>[12]</sup>, 大量颗粒的群体行为呈现出典型的固体或液体的性质<sup>[13,14]</sup>. 由于该系统亚毫米的颗粒间距和颗粒赫兹级的振动频率, 实验中可通过高速相机记录尘埃颗粒运动轨迹, 通过颗粒识别和追踪获得每个颗粒的位置和速度等动力学信息<sup>[15,16]</sup>, 由此从单颗粒动力学层面研究多种基础物理过程的微观机制<sup>[16-21]</sup>, 例如输运<sup>[17]</sup>、相变<sup>[18]</sup>和波动<sup>[16]</sup>等.

为了表征尘埃等离子体系统的物理性质, 一般使用两个无量纲全局性质参数, 即屏蔽参数  $\kappa = a/\lambda_D$  和耦合参数  $\Gamma = Q^2/4\pi\epsilon_0ak_B T$ <sup>[22]</sup>. 其中,  $T$  是尘埃颗粒的动理温度,  $a = (n\pi)^{-1/2}$  是二维系统的 Wigner-Seitz 半径,  $n$  是颗粒的面数密度<sup>[22]</sup>. 在尘埃等离子体实验中, 为了确定这两个参数, 一般使用声子谱拟合法. 首先, 基于该系统大量颗粒无规则热运动信息计算视野内的纵向流和横向流, 对其进行傅里叶变换获得声子谱, 进而得出纵波和横波色散关系<sup>[15]</sup>. 然后, 将从实验数据中获得的色散关系与不同参数下二维汤川势晶格的理论色散关系进行比较, 由此获得误差分布面  $\chi^2$ , 该面的两个轴分别为屏蔽参数  $\kappa$  和尘埃等离子体频率  $\omega_{pd} = \sqrt{Q^2/(2\pi\epsilon_0ma^3)}$ . 基于该误差分布面  $\chi^2$ , 可找到一个实验与理论色散关系差异最小的位置和相应的置信区间, 实现对  $\kappa$  和  $\omega_{pd}$  的实验诊断, 由此进一步计算得到  $\Gamma$  的值. 另一种更简单的方法是通过外加调制手段在系统内激发出纵波和横波, 进一步测量纵波和横波声速, 然后基于相关理论解析表达式就能够推出系统的  $\Gamma$  和  $\kappa$  的数值<sup>[23]</sup>. 但是, 上述方法都需要对系统中大量颗粒运动信息进行系统分析才能较为准确地诊断全局性质参数  $\Gamma$  和  $\kappa$ , 但是在很多实验中, 由于硬件条件的限制, 获取大量的颗粒动力学信息是很困难的, 甚至完全不可能.

目前, 以神经网络为代表的机器学习技术已经

发展成了一种强大的数据分析工具, 并已经在科学研究的各个领域得到了广泛的应用, 例如流体力学<sup>[24]</sup>、材料科学<sup>[25]</sup>和等离子体物理学<sup>[26]</sup>. 机器学习具有极强的数据分析处理能力, 能够通过对海量数据的分析学习, 发现数据中潜在的信息, 为解决复杂物理问题提供新的工具和方法. 在尘埃等离子体相关研究中, 机器学习技术也被引入到多项研究中<sup>[27-34]</sup>, 例如相变分析<sup>[27]</sup>、颗粒追踪<sup>[30]</sup>以及实验诊断<sup>[31]</sup>等. 最近, 基于机器学习技术, 一种全新的尘埃等离子体实验诊断方法被开发出来, 无需使用传统的统计力学理论, 而是纯粹从单颗粒动力学信息出发就能够实现对二维尘埃等离子体的全局性质参数  $\kappa$  和  $\Gamma$  的实验诊断, 即从单颗粒动力学信息中得出系统全局性质信息<sup>[33,34]</sup>. 本文将对这一诊断方法进行系统总结, 全文结构如下: 第 2 节简要介绍模拟二维尘埃等离子体的方法, 以及本文分析处理的二维尘埃等离子体实验; 第 3 节描述本文设计的卷积神经网络结构; 第 4 节利用设计的神经网络模型, 基于模拟和实验中单颗粒动力学信息, 给出对全局性质参数  $\kappa$  的诊断结果, 并衡量诊断的准确性, 对于实验数据, 本文诊断方法给出的  $\kappa$  数值与通过传统方法给出的结果高度一致; 第 5 节对设计的机器学习方法进行进一步优化改进, 使其能够从单颗粒动力学信息同时准确给出  $\kappa$  和  $\Gamma$  的值; 最后, 第 6 节进行总结.

## 2 数据获取

本文涉及对不同  $\kappa$  和  $\Gamma$  数值的尘埃等离子体模拟和实验中单颗粒动力学信息的分析处理, 空间和时间尺度的变化较大. 为了能衡量和比较不同时空尺度下的单颗粒动力学信息 (如图 1 所示的单颗粒位置涨落信息及其空间分布), 本文对使用




图 1 单颗粒位置涨落的 (a) 时序图和 (b) 空间分布图

Fig. 1. (a) Time series and (b) the space distribution of individual particle position fluctuations.

的单颗粒动力学信息的时空尺度进行了无量纲化. 使用 Wigner-Seitz 半径  $a$  和尘埃等离子体频率  $\omega_{pd}$  分别对所使用的单颗粒动力学信息的空间和时间尺度进行了归一化处理<sup>[22]</sup>.

## 2.1 模拟数据

为了模拟不同  $\kappa$  和  $\Gamma$  数值的二维尘埃等离子体, 使用 LAMMPS 实施了朗之万 (Langevin) 动力学模拟. 在模拟中, 尘埃颗粒的运动方程为

$$m\ddot{\mathbf{r}} = -\nabla \sum_{j \neq i}^N \phi_{ij} - \nu m \mathbf{v} + \xi_{\mathbf{r}}, \quad (1)$$

其中,  $\phi_{ij}$  是尘埃颗粒间的汤川排斥势<sup>[11]</sup>; 右侧第二项  $-\nu m \mathbf{v}$  为摩擦气体阻尼力, 形式为 Epstein 曳引模型, 阻尼系数为  $\nu$ <sup>[35]</sup>; 右侧最后一项  $\xi_{\mathbf{r}}$  对应于涨落耗散定理中的朗之万随机力<sup>[36]</sup>.

为了获取足够大量的数据用于训练神经网络模型, 在不同  $\kappa$  和  $\Gamma$  数值下进行了数百组相互独立的二维尘埃等离子体模拟. 在这些模拟中, 设置的屏蔽参数  $\kappa$  范围为  $0.25 \leq \kappa \leq 2.00$ , 而耦合参数  $\Gamma$  的范围为  $0.1 \leq \Gamma_m/\Gamma \leq 100$ , 这都是基于典型的二维尘埃等离子体实验参数范围<sup>[7-10]</sup>. 其中,  $\Gamma_m$  是在对应屏蔽参数  $\kappa$  情况下, 二维尘埃等离子体在固液转变点对应的耦合参数. 此外, 在模拟中, 积分时间步长被设置为  $\delta t \omega_{pd} = 0.001$ , 摩擦气体阻尼的阻尼系数设置为  $\nu = 0.027 \omega_{pd}$ , 模拟盒子的边界条件设置为周期性边界条件. 对于更多的模拟细节, 详见下文<sup>[33,34]</sup>.

## 2.2 实验数据

为了测试利用模拟数据训练完成的神经网络模型在处理实验数据上的表现, 使用了一组二维尘埃等离子体实验数据<sup>[33,34]</sup>. 该实验数据是从包含有 2058 幅连续帧的实验录像中提取出的颗粒动力学数据. 在该二维尘埃等离子体实验中, 使用的顶视相机分辨率为  $800 \times 600$  像素、帧率为每秒 55 帧, 对  $29.05 \text{ mm} \times 21.78 \text{ mm}$  的区域进行拍摄, 此视野内捕获了约 4400 个尘埃颗粒的动力学信息. 从这些图像中, 可以直接得到实验系统的面数密度, 进一步得到 Wigner-Seitz 半径  $a \approx 0.21 \text{ mm}$ . 这里, 使用了改进的矩量法从实验录像中获取颗粒的位置信息, 其典型的误差小于  $1/4$  个像素, 仅约为晶格常数 ( $b \approx 0.40 \text{ mm}$ ) 的 2%<sup>[2,10]</sup>.

正如在引言中所述, 为了实现对上述二维尘埃

等离子体中全局性质参数  $\kappa$  和  $\Gamma$  的诊断, 计算了初始高度有序晶格中颗粒无规则热运动对应的声子谱, 以获取相应的横波和纵波色散关系. 接下来, 将实验中获得的色散关系与不同参数  $\omega_{pd}$  和  $\kappa$  条件下推导出的汤川势晶格的理论色散关系进行比较, 得到其误差分布. 最后, 基于这个误差分布, 选择实验和理论色散关系之间差异最小最匹配的  $\omega_{pd}$  和  $\kappa$  数值作为实验诊断结果, 并进一步计算得到实验系统的  $\Gamma$  数值. 使用该声子谱拟合方法, 确定了实验中的屏蔽参数  $\kappa$  和耦合参数  $\Gamma$  的数值, 分别为  $\kappa \approx 0.50$  和  $\Gamma \approx 700$ . 此外, 该实验的尘埃等离子体频率符合以往经验, 即在类似的实验条件下, 二维尘埃等离子体实验的尘埃等离子体频率  $\omega_{pd}$  仅在  $70 \text{ s}^{-1} \leq t\omega_{pd} \leq 90 \text{ s}^{-1}$  的典型范围内略有变化<sup>[7-10]</sup>.

对获得的原始实验数据进行一系列处理, 从而实现对其的充分利用. 首先, 以  $t = \nu^{-1} = 0.37 \text{ s}$  作为时间间隔, 从原始实验数据中分割提取出 72 个切片, 每个切片的持续时间为 10 s, 包含 550 帧数据. 在实验中, 一个颗粒位置的时间序列通常包含整体漂移, 这是由整个二维尘埃悬浮液的稳定旋转造成的. 这些总体漂移会影响颗粒位置涨落数据, 并进一步影响神经网络模型分析的准确性. 为了去除颗粒的漂移运动, 使用公式  $\mathbf{r}' = \mathbf{r} - \mathbf{v}_d t$  从颗粒所有时间点位置  $\mathbf{r}$  中去除其位置漂移. 式中的漂移速度  $\mathbf{v}_d$  直接由颗粒在切片中的总位移除以总时长 10 s 得出. 理论上, 对于无任何扰动的高度有序晶格, 颗粒位置涨落的分布非常集中, 远小于 Wigner-Seitz 半径  $a$ , 因此, 本文仅保留颗粒位置涨落对应的标准差小于等于  $a/4$  的实验数据. 最终, 从本实验中获得了总计约 6000 个颗粒的位置涨落数据. 每个颗粒位置涨落数据包含 550 帧的数据, 在后续神经网络分析中, 采用下采样方法, 在不改变持续时间的情况下将其减少到等时间间隔的 512 帧.

## 3 神经网络结构

参考典型的机器学习方法<sup>[37]</sup>, 设计了两套卷积神经网络 (CNN) 结构, 分别命名为 Model A 和 Model B, 如图 2 所示. 这两套卷积神经网络结构用于分析处理不同输入数据格式. 其中, Model A 被用于分析格式为时间序列的单颗粒位置涨落数据, 而 Model B 则被用于分析格式为图像或矩阵的单颗粒位置分布数据. 两种卷积神经网络结构均主要由连续 4 个部分组成, 如图 2 所示.

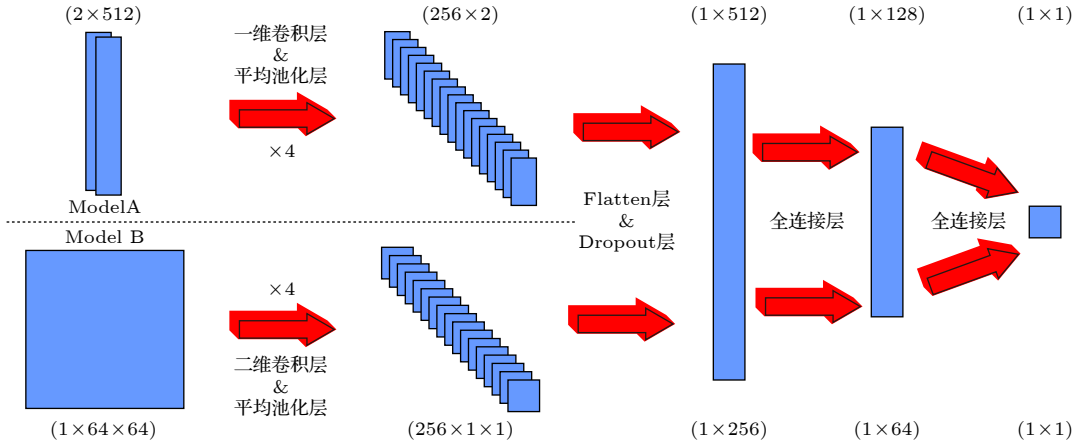


图 2 卷积神经网络结构图

Fig. 2. Structure of our convolutional neural networks.

在 Model A 中, 输入数据会被连续 4 个部分依次进行处理, 并最终给出一个输出. 首先, Model A 的第一部分由 4 组连续的一维卷积层和平均池化层组成, 其中一维卷积层使用 ReLu 函数作为激活函数. 该部分会基于颗粒  $x$  和  $y$  方向位置涨落的时间序列 ( $2 \times 512$ ), 生成 256 个特征向量 ( $256 \times 2$ ) 作为下一部分的输入. 其次, 由 flatten 层和 dropout 层组成的 Model A 第二部分, 会将上一部分生成的 256 个特征向量 ( $256 \times 2$ ) 转换为一个新的特征向量 ( $1 \times 512$ ), 这里 dropout 层的作用是防止神经网络过拟合. 然后, 使用一个具有 ReLu 激活函数的全连接层作为 Model A 的第三部分, 从特征向量 ( $1 \times 512$ ) 中进一步提取特征, 从而得到一个新的特征向量 ( $1 \times 128$ ). 最后, 应用一个不具有激活函数的全连接层作为 Model A 的第四部分, 从而得到最终输出 ( $1 \times 1$ ), 该输出即对应于本研究中预期的屏蔽参数  $\kappa_{\text{NN}}$ .

而对于 Model B, 其构造与 Model A 基本一致, 唯一的区别体现在 Model B 的第一部分. 与 Model A 不同, Model B 的第一部分由 4 组连续的二维卷积层和平均池化层组成, 该部分能够处理数据类型为单通道图像数据 ( $1 \times 64 \times 64$ ) 的单颗粒位置分布数据, 并最终给出 256 张特征图 ( $256 \times 1 \times 1$ ). 然后, 经过与 Model A 相同的 3 个部分后, 就得到了 Model B 的最终输出 ( $1 \times 1$ ), 该输出也对应于预期的  $\kappa_{\text{NN}}$ .

同样遵循典型的机器学习方法<sup>[37]</sup>, 对设计的 Model A 和 Model B 进行训练. 其中, 批量大小被设置为 128, 即每批包含 128 个不同颗粒的数据. 此外, 使用 Smooth L1 损失函数来量化神经网络

输出  $\kappa_{\text{NN}}$  与模拟中指定的  $\kappa$  的差异, 并使用 Adam 优化器来更新神经网络中所有的可学习参数<sup>[38]</sup>.

## 4 可行性验证与应用

本文对利用机器学习从单颗粒动力学信息诊断系统全局性质参数进行了一系列研究. 首先, 为了验证该方法的可行性, 设计了神经网络模型 CNN1, 实现基于模拟中单颗粒位置涨落信息的  $\kappa$  诊断; 进一步地, 针对实验数据分析处理过程中遇到的问题, 设计了神经网络模型 CNN2 和 CNN3, 这两个模型不仅能实现对模拟数据的分析处理, 还能实现对实验数据的分析处理. 上述神经网络模型 CNN1, CNN2 和 CNN3 在训练过程中对内存空间的需求分别为 0.5 GB, 2.1 GB 和 0.3 GB. 这里需要特别说明的是, 本文所有神经网络模型都能够基于任意一个颗粒的位置涨落信息诊断出尘埃等离子体系统全局性质参数, 如此处的  $\kappa$  数值, 因此称之为从单颗粒动力学中诊断全局性质信息; 如果拥有  $N$  个颗粒的动力学信息, 那么就能诊断出  $N$  个  $\kappa$  数值, 基于其平均值或分布峰值实现更为精准的诊断.

### 4.1 神经网络模型 CNN1

神经网络模型 CNN1 是基于第 3 节所述的 Model A 使用模拟数据训练得到的. 正如第 2.1 节所述, 这里使用的数据集均来自独立的数值模拟, 具体参数如下. 对于训练集, 进行了 8 个独立的数值模拟, 对应于从 0.25 到 2.00 的 8 个不同  $\kappa$  数值, 取值间隔为 0.25. 在这些模拟中,  $\Gamma$  数值均设置为 800, 且均包含  $2^{14}$  个颗粒. 而对于验证集和测试集,

则进行了另外 15 个独立的数值模拟, 对应于 15 个不同的  $\kappa$  数值, 这些设置的数值不仅包含之前训练集中所有的  $\kappa$  数值, 还额外有 7 个在  $0.25 \leq \kappa \leq 2.00$  范围内随机选取的数值. 同样地, 在这些模拟中,  $\Gamma$  数值也均设置为 800, 但是这里的每一个数值模拟中仅包含  $2^{10}$  个颗粒. 对于每一个数值模拟, 将得到的数据随机平分成两部分, 每部分分别包含  $2^9$  个颗粒的数据, 分别作为验证集和测试集. 这里, 每一个颗粒位置涨落数据的持续时间都为  $t\omega_{pd} = 819.2$ , 包含等时间间隔的 512 个数据点.

经过训练后, 对于模拟数据, 神经网络模型 CNN1 成功地基于单颗粒位置涨落数据实现了对系统全局性质参数  $\kappa$  的诊断. CNN1 对测试集数据的诊断结果如图 3(a) 所示, 其中  $\Delta\kappa = \kappa_{NN} - \kappa$  表示的是 CNN1 给出的屏蔽参数  $\kappa_{NN}$  和对应模拟中实际设置的  $\kappa$  的差异. 对于测试集中每一个单颗粒位置涨落数据, CNN1 都给出了一个  $\kappa_{NN}$  数值, 其对应的  $\Delta\kappa$  如图 3(a) 中圆点所示. 此外, 对于每个  $\kappa$ , 分别计算了相应  $\Delta\kappa$  的平均值和标准差, 如图 3(a) 中三角形及其误差棒所示. 从图 3(a) 中的直线可以清楚地看出, 对于每个设定的  $\kappa$  数值, CNN1 分析结果的  $\Delta\kappa$  平均值几乎都等于 0, 且标准差非常小. 简而言之, CNN1 对  $\kappa$  诊断结果和设定值几乎一致, 这充分证明了单颗粒动力学信息可以被用于准确诊断系统全局性质参数.

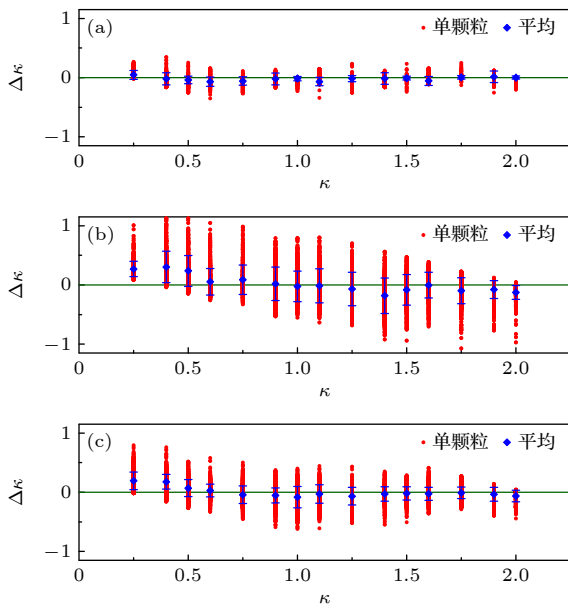


图 3 神经网络模型 (a) CNN1, (b) CNN2 和 (c) CNN3 对模拟数据的分析结果

Fig. 3. Analyzed results of the simulation data from (a) CNN1, (b) CNN2, and (c) CNN3.

为了量化 CNN1 诊断的  $\kappa_{NN}$  的准确性, 计算了对应的均方根误差. 作为衡量测量数据与真实值偏差的指标, 均方根误差可通过  $\sqrt{\frac{1}{N} \sum_{i=1}^N (\Delta\kappa)^2}$  进行计算, 其中  $N$  是诊断得到的  $\kappa_{NN}$  数值的总数. 基于 CNN1 诊断的  $\kappa_{NN}$  数值计算得到的均方根误差仅为 0.081. 如此低的均方根误差无疑表明 CNN1 的表现十分优异, 进一步证明了利用机器学习技术根据单颗粒动力学信息来确定系统全局性质参数的可行性.

尽管 CNN1 表现十分优异, 但是其不能直接用于实验数据分析处理. 具体原因为: 在神经网络的实际应用中, 待处理的数据需要与训练中使用的数据在格式上保持一致. 对于单颗粒位置涨落数据这种时间序列类型的数据, 就要求待处理的数据与训练数据具有相同的持续时间和相同的相邻帧时间间隔. 然而, 对于尘埃等离子体实验数据, 时间单位是秒 (s), 而模拟中使用的单位  $\omega_{pd}^{-1}$  与 s 之间的换算关系实际尚未确定. 其实  $\omega_{pd}^{-1}$  与 s 之间的关系会因不同的实验条件而发生变化. 为了解决这个问题, 设计了另外两个可以用于实验数据分析处理的神经网络模型 CNN2 和 CNN3, 具体如下所述.

## 4.2 神经网络模型 CNN2 和 CNN3

首先, 最直观地, 通过使用与时间无关的单颗粒位置分布数据作为神经网络模型的输入数据, 来解决时间单位换算带来的问题, 因此设计了神经网络模型 CNN2. 神经网络模型 CNN2 是基于第 3 节中所述的 Model B 使用模拟数据训练得到的. 这里使用的训练集、验证集和测试集数据与之前的 CNN1 一致, 只是数据的格式由单颗粒位置涨落时间序列转换成了单颗粒位置分布数据, 如图 1(b) 所示. 为了表征单颗粒位置分布数据, 对于一个颗粒, 在  $x-y$  平面内创建一个边长为  $2a$  的正方形, 并将其划分为  $64 \times 64$  个子区域, 即每个子区域的大小为  $a/32 \times a/32$ . 然后, 统计该颗粒在每个子区域中出现的次数, 以反映其位置涨落信息. 最后, 使用最大最小值归一化方法对得到的矩阵进行归一化, 从而得到每个颗粒的位置分布数据.

其次, 尽管在二维尘埃等离子体实验中的  $\omega_{pd}$  与 s 之间的换算关系尚未确定, 但其典型范围通常是已知的, 尤其是在相同装置上进行的实验, 这些

信息可以被纳入神经网络模型的训练中以拓展其应用范围. 对于本文分析的二维尘埃等离子体实验<sup>[9,10]</sup>, 根据之前的实验<sup>[7-10]</sup>可以知道  $\omega_{pd}$  与  $s$  之间的典型换算关系范围为  $70s^{-1} \leq \omega_{pd} \leq 90s^{-1}$ . 如果待分析的实验数据持续时间为 10 s, 则相应的模拟数据持续时间应为  $700 \leq t\omega_{pd} \leq 900$ . 为了实现对实验数据的分析, 接下来将这一可调持续时间的信息纳入神经网络模型的训练中, 由此设计了神经网络模型 CNN3.

神经网络模型 CNN3 也是基于第 3 节中所述的 Model A 使用模拟数据训练得到的, 但是其使用的是全新的训练集、验证集和测试集数据, 与之前的 CNN1 存在较大的差异. 对于训练集, 同样进行了 8 个独立的数值模拟, 持续时间均设定为  $900\omega_{pd}^{-1}$ , 并且只包含  $2^{10}$  个颗粒, 其余参数与 CNN1 所用训练集一致. 对每一个独立的数值模拟, 从模拟数据中提取了持续时间分别为  $700\omega_{pd}^{-1}$ ,  $750\omega_{pd}^{-1}$ ,  $800\omega_{pd}^{-1}$ ,  $850\omega_{pd}^{-1}$ ,  $900\omega_{pd}^{-1}$  的单颗粒位置涨落数据作为训练集数据. 对于验证集和测试集, 同样进行了 15 个独立的数值模拟, 持续时间同样设定为  $900\omega_{pd}^{-1}$ , 其余参数与 CNN1 一致. 为了模拟分析实验数据持续时间未知的情况, 对于每一个独立的数值模拟, 使用  $700\omega_{pd}^{-1}$ — $900\omega_{pd}^{-1}$  之间的 4 个随机的持续时间来提取单颗粒位置涨落数据, 并将这些数据随机平分成两部分, 每部分均包含  $2^9$  个颗粒的数据, 分别作为验证集和测试集数据. 这里, 无论持续时间多长, 对于每一个单颗粒位置涨落的时间序列, 都会使用下采样方法, 在不改变持续时间的情况下将其减少到等时间间隔的 512 个数据点.

对于模拟数据, 如图 3(b), 图 3(c) 所示, 神经网络模型 CNN2 和 CNN3 都能够较为准确地实现对全局性质参数  $\kappa$  的诊断. 对于神经网络模型 CNN2 和 CNN3, 分别计算了 CNN2 和 CNN3 分析结果对应的  $\Delta\kappa$  值. 如图 3(b) 所示, 和 CNN1 相比, 由 CNN2 得到的  $\Delta\kappa$  数值的分布范围要宽很多, 这是因为 CNN2 使用的单颗粒位置分布数据中完全不含时间相关的物理信息. 但是,  $\Delta\kappa$  数值的平均值依旧基本与 0 一致, 即 CNN2 对  $\kappa$  诊断结果和设定值非常接近. 这种一致性表明, 即使没有时间信息, CNN2 也能够提取出不同屏蔽参数下颗粒位置涨落的分布特征. CNN2 得到的  $\Delta\kappa$  的均方根

误差约为 0.279, 约是 CNN1 的 3.5 倍. CNN3 的结果如图 3(c) 所示, 可以看出, CNN3 的表现明显优于 CNN2, 其  $\Delta\kappa$  的平均值更接近于 0, 而且分布更集中, 这是由于 CNN3 使用的数据中包含时间相关的物理信息. 同时还计算了 CNN3 得到的  $\Delta\kappa$  的均方根误差, 约为 0.155, 明显小于 CNN2 的结果. 这些结果清楚地表明, CNN2 和 CNN3 能够基于模拟中单颗粒的位置涨落或空间分布实现对  $\kappa$  的准确诊断, 且 CNN3 的性能优于 CNN2.

神经网络模型 CNN2 和 CNN3 均能够直接被用于分析实验数据, 如图 4 所示. 如第 2.2 节所述, 从二维尘埃等离子体实验中提取了约 6000 个颗粒的位置涨落数据<sup>[9,10]</sup>, 对于每一个单颗粒位置涨落数据, 神经网络模型 CNN2 和 CNN3 都能对应给出一个可能的  $\kappa_{NN}$  数值. 图 4 中分别绘制了由 CNN2 和 CNN3 给出的约 6000 个可能的  $\kappa_{NN}$  数值的分布. 可以看出, 无论是 CNN2 还是 CNN3, 给出的  $\kappa_{NN}$  的分布都呈现一个显著的单峰分布, 峰值出现的位置分别为  $\kappa_{NN} \approx 0.455$  和  $\kappa_{NN} \approx 0.498$ , 这就是由 CNN2 和 CNN3 分别诊断出的  $\kappa$  数值. 正如第 2.2 节所述, 对于本文使用的实验数据, 通过传统声子谱拟合方法, 诊断得出的  $\kappa$  数值为 0.47. 由此可见, 由 CNN2 和 CNN3 诊断给出的  $\kappa$  数值与传统方法得到的  $\kappa$  数值基本一致, 这充分证明了 CNN2 和 CNN3 能够基于单颗粒位置涨落或




图 4 神经网络模型 (a) CNN2 和 (b) CNN3 对实验数据的分析结果

Fig. 4. Analyzed results of the experiment data: (a) CNN2; (b) CNN3.

空间分布实现对尘埃等离子体实验  $\kappa$  值的准确诊断, 即从单颗粒动力学信息可以准确诊断尘埃等离子体的全局性质信息. 这里需要注意的是, 在实际应用时, 如果待分析的实验数据中包含的位置信息少于 512 个, 则需要使用插值的方法增加位置信息的数量, 这样 CNN3 才能进行分析处理.

## 5 方法拓展

通常情况下, 为了表征尘埃等离子体, 一般使用两个全局性质参数, 即屏蔽参数  $\kappa$  和耦合参数  $\Gamma$ . 上文中已经利用机器学习技术, 成功地基于单颗粒位置涨落或空间分布实现了对  $\kappa$  的准确诊断. 但是, 仅仅确定  $\kappa$  不足以对尘埃等离子体系统的物理性质进行全面表征, 还需要同时确定  $\Gamma$  值. 为此, 对上文中的机器学习方法进行了进一步的改进, 使其能从单颗粒位置涨落信息中同时准确诊断  $\kappa$  和  $\Gamma$  值, 即实现对尘埃等离子体全局性质信息的有效诊断. 鉴于上文中神经网络模型 CNN3 的性能较好, 这里主要在其基础上进行改进, 得到了神经网络模型 CNN3', 改进主要体现在以下两点.

第一, 对卷积神经网络结构 Model A 进行了一系列调整改进, 以提升其分析处理数据的能力, 由此设计了卷积神经网络结构 Model A', 如图 5 所示. 在 Model A' 中的改进主要包括两部分. 首先, 在第一部分中, 除了已经在 Model A 中使用过的平均池化层外, 还并行地利用了最大池化层来分析输入数据. 与先前的 Model A 相比, Model A' 能够更容易地学习输入数据中更高频率的信息, 从而能从输入数据中提取出更完整详细的物理信息. 其次, 为了提升神经网络的性能, 在 Model A' 的第一部分和第三部分中每一个池化层和全连接层之后

都增加了一个批归一化层. 这里, 由于批归一化层和 dropout 层存在冲突, 所以在 Model A' 的第二部分中移除了 dropout 层. 此外, Model A' 的规模被进一步扩大, 其隐藏层数量相比 Model A 大约增加了 4 倍.

如图 5 所示, 经改进后的卷积神经网络结构 Model A' 也主要由 4 个部分组成. Model A' 的第一部分由两组不同的隐藏层集合构成, 能够同时对输入的颗粒  $x$  和  $y$  位置涨落数据 ( $2 \times 512$ ) 进行分析处理, 并分别给出两个不同的输出, 各包含 1024 个特征向量 ( $1024 \times 1$ ). 每个隐藏层集合都包含 9 个连续的子集, 每个子集由一个一维卷积层、一个最大池化层或平均池化层和一个批归一化层组成. Model A' 的第二部分是一个 flatten 层, 该层能将第一部分输出的 2048 个特征向量 ( $2048 \times 1$ ) 转换为一个新的特征向量 ( $1 \times 2048$ ). 接着, 使用 9 组连续的全连接层和批归一化层作为 Model A' 的第三部分, 对上一步给出的特征向量 ( $1 \times 2048$ ) 进行进一步的分析处理, 并给出一个新的特征向量 ( $1 \times 4$ ). 最后, 在 Model A' 的第四部分中, 应用一个不具有激活函数的全连接层得到最终的输出 ( $1 \times 2$ ). 该输出中的两个元素分别是预期的  $\kappa_{NN}$  和  $\lg(\Gamma_m^{NN}/\Gamma_{NN})$  数值, 其中  $\Gamma_m^{NN}$  是在  $\kappa_{NN}$  参数下二维尘埃等离子体固液相变点对应的耦合参数. 在 Model A' 第一和第三部分中, 所用的卷积层和全连接层都使用 ReLU 函数作为激活函数. 同时, 为了避免  $\kappa$  和  $\Gamma$  之间显著的数值差异对神经网络模型造成不利影响, 利用公式  $\lg(\Gamma_m/\Gamma)$ , 将  $\Gamma$  的数值缩放到与  $\kappa$  数值相同的数量级.

第二, 为了训练 Model A', 构建了规模更加庞大的数据集. 对于训练集, 进行了 104 次不同参数下独立的二维尘埃等离子体系统数值模拟. 在二维




图 5 经改进后的卷积神经网络结构 Model A' 的结构图

Fig. 5. Structure of our convolutional neural network Model A'.

尘埃等离子体实验中  $\kappa$  和  $\Gamma$  的典型范围内, 指定了 8 个  $\kappa$  数值和 13 个  $\Gamma$  数值. 正如前文 CNN3 使用的训练集, 对于每一个独立的数值模拟, 从其模拟数据中分别提取了持续时间为  $700\omega_{pd}^{-1}$ ,  $750\omega_{pd}^{-1}$ ,  $800\omega_{pd}^{-1}$ ,  $850\omega_{pd}^{-1}$ ,  $900\omega_{pd}^{-1}$  的单颗粒位置涨落数据作为 CNN3' 的训练集数据. 而对于验证集和测试集, 进行了另外 375 次不同参数下独立的数值模拟. 为了验证和测试训练好的 CNN3' 的泛化能力, 不仅使用了之前训练集中的所有 8 个  $\kappa$  数值和 13 个  $\Gamma$  数值, 另外还在  $\kappa$  和  $\Gamma$  典型范围内选取了 7 个新的  $\kappa$  数值和 12 个新的  $\Gamma$  数值, 作为模拟时使用的参数. 此外, 除了上述训练集中选择的 5 个持续时间外, 还在  $700 \leq t\omega_{pd} \leq 900$  的范围内随机选择了另外 4 个不同的持续时间. 从每次模拟中, 提取了这 9 个不同持续时间对应的模拟数据, 并将其随机平分成两部分, 分别包含  $2^9$  个颗粒的数据, 作为验证集和测试集. 这里, 与前文一致, 无论持续时间多长, 对于每一个单颗粒位置涨落的时间序列, 都会使用下采样方法, 在不改变持续时间的情况下将其减少到等时间间隔的 512 个数据点. 由于使用了规模更大的数据集, CNN3' 在训练时需要的内存空间提高到了约 40 GB.

二维尘埃等离子体模拟中使用的参数设置如下: 对于训练集, 全局性质参数  $\kappa$  和  $\Gamma$  的取值分别为  $\kappa \in \{0.25, 0.50, 0.75, 1.00, 1.25, 1.50, 1.75, 2.00\}$ ,  $\Gamma_m/\Gamma \in \{0.01, 0.02, 0.04, 0.08, 0.1, 0.2, 0.4, 0.8, 1.0, 2.0, 4.0, 8.0, 10.0\}$ , 并且每个模拟中包含  $2^{14}$  个颗粒; 对于验证集和测试集, 全局性质

参数  $\kappa$  和  $\Gamma$  的取值分别为  $\kappa \in \{0.25, 0.40, 0.50, 0.60, 0.75, 0.90, 1.00, 1.10, 1.25, 1.40, 1.50, 1.60, 1.75, 1.90, 2.00\}$ ,  $\Gamma_m/\Gamma \in \{0.01, 0.015, 0.02, 0.03, 0.04, 0.06, 0.08, 0.09, 0.1, 0.15, 0.2, 0.3, 0.4, 0.6, 0.8, 0.9, 1.0, 1.5, 2.0, 3.0, 4.0, 6.0, 8.0, 9.0, 10.0\}$ , 并且每个模拟中包含  $2^{10}$  个颗粒.

对于模拟数据, CNN3' 成功地基于单颗粒位置涨落数据以极高的精度实现了对  $\kappa$  和  $\Gamma$  的同时诊断. 为了量化 CNN3' 的表现, 计算了 CNN3' 对模拟数据给出的  $\kappa_{NN}$  和  $\Gamma_{NN}$  数值的平均相对误差, 如图 6 所示. 由 CNN3' 给出的  $\kappa_{NN}$  和  $\Gamma_{NN}$  数值的平均相对误差普遍非常得小, 通常小于 30%, 这清楚地证明了 CNN3' 可以从单颗粒位置涨落数据中以较高的精度同时诊断  $\kappa$  和  $\Gamma$  值. 其中, 对于  $\kappa < 1.00$  的情况, 由于  $\kappa$  数值较小,  $\kappa_{NN}$  数值的绝对误差并不像图 6 中的平均相对误差那样变化显著. 事实上,  $\kappa_{NN}$  数值的绝对误差主要在 0.1—0.2 之间, 只有少数数据点超出此范围, 但仍小于 0.3.

基于二维尘埃等离子体实验中获得单颗粒位置涨落数据, 训练后的 CNN3' 能够同时实现对  $\kappa$  和  $\Gamma$  的高精度诊断. 为了测试 CNN3' 对实验数据的分析处理能力, 使用 CNN3' 对第 2.2 节中的实验数据进行了分析, 结果如图 7 所示. 对于实验中获取的每一个颗粒的位置涨落数据, CNN3' 都给出了一对可能的  $\kappa_{NN}$  和  $\Gamma_{NN}$  数值, 对应的分布分别被绘制在了图 7(a) 和图 7(b) 中. 从图 7 可以明确地看到, 无论是对于  $\kappa_{NN}$  还是  $\Gamma_{NN}$ , 均呈现单峰分布的形式. 并且, 二者分别在  $\kappa_{NN} \approx 0.50$  和  $\Gamma_{NN} \approx$




图 6 神经网络模型 CNN3' 对模拟数据  $\kappa_{NN}$  (a) 和  $\Gamma_{NN}$  (b) 的诊断结果图

Fig. 6. Determined  $\kappa_{NN}$  (a) and  $\Gamma_{NN}$  (b) results of the simulation data from CNN3'.

780 的位置出现一个显著峰值,这正是 CNN3' 对该实验中  $\kappa$  和  $\Gamma$  的诊断结果. 该结果与传统声子谱拟合方法确定的  $\kappa \approx 0.50$  和  $\Gamma \approx 700$  非常符合. 这清楚地验证了, 基于单颗粒位置涨落信息, 可以同时实现对  $\kappa$  和  $\Gamma$  的高精度诊断, 即尘埃等离子体的全局性质信息可以从单颗粒动力学信息推断出来. 在后续研究中, 通过设计相应的数据集并对神经网络模型进行相应的调整以及重新训练, 本文中的机器学习方法在理论上应该也适用于其他全局性质参量的实验诊断, 例如系统的阻尼系数  $\nu$  等.




图 7 神经网络模型 CNN3' 对实验数据 (a)  $\kappa_{NN}$  和 (b)  $\Gamma_{NN}$  的诊断结果  
Fig. 7. Determined (a)  $\kappa_{NN}$  and (b)  $\Gamma_{NN}$  results of the experiment data from CNN3'.

## 6 总结

综上所述, 基于机器学习技术, 开发了一种全新的诊断方法, 纯粹通过对单颗粒位置涨落数据的分析, 实现对二维尘埃等离子体的全局性质参数  $\kappa$  和  $\Gamma$  的同时高精度诊断. 为了获取用于训练、验证和测试神经网络模型的单颗粒动力学数据, 进行了不同  $\kappa$  和  $\Gamma$  参数下的数百组独立的二维尘埃等离子体系统的朗之万动力学模拟. 首先, 为了验证诊断方法的可行性, 设计了神经网络模型 CNN1, 能够从模拟数据中高精度地诊断出相应的  $\kappa$  数值,

均方根误差仅为 0.081. 然后, 对于在实验数据分析时遇到的时间单位换算关系未知的问题, 本文提出了两种方案: 一种方法是将颗粒位置涨落数据转换为颗粒位置分布数据, 从而完全忽略未知时间信息的影响, 由此得到了神经网络模型 CNN2; 另一种方法是将二维尘埃等离子体实验中振动频率的典型范围上下限纳入神经网络的学习范围内, 由此基于可调持续时间的单颗粒位置涨落数据设计出了神经网络模型 CNN3. 对于模拟数据, CNN2 和 CNN3 都能够实现准确的  $\kappa$  诊断, 均方根误差分别为 0.279 和 0.155. 对于实验数据, 无论是 CNN2 还是 CNN3 得到的  $\kappa_{NN}$  数值的分布都是一个单峰分布, 且峰值位置对应的  $\kappa_{NN}$  数值与传统声子谱拟合的方法诊断出的  $\kappa$  数值高度一致. 最后, 对性能更好的 CNN3 进行了进一步的优化改进, 使其能以极高的精度同时实现对二维尘埃等离子体模拟和实验中  $\kappa$  和  $\Gamma$  的诊断. 上述结果清楚地表明, 利用机器学习方法, 纯粹根据单颗粒位置涨落信息, 能同时准确确定二维尘埃等离子体两个全局特征参数  $\kappa$  和  $\Gamma$ , 即能从单颗粒动力学中有效诊断出尘埃等离子体全局性质信息.

## 参考文献

- [1] Pathria R K, Beale P D 2021 *Statistical Mechanics* (London: Academic) pp1-22
- [2] Feng Y, Goree J, Liu B 2007 *Rev. Sci. Instrum.* **78** 053704
- [3] Feng Y, Goree J, Liu B 2011 *Rev. Sci. Instrum.* **82** 053707
- [4] He Y F, Ai B Q, Dai C X, Song C, Wang R Q, Sun W T, Liu F C, Feng Y 2020 *Phys. Rev. Lett.* **124** 075001
- [5] Beckers J, Berndt J, Block D, Bonitz M, Bruggeman P J, Couëdel L, Delzanno G L, Feng Y, Gopalakrishnan R, Greiner F, Hartmann P, Horányi M, Kersten H, Knappek C A, Konopka U, Kortshagen U, Kostadinova E G, Kovačević E, Krasheninnikov S I, Mann I, Mariotti D, Matthews L S, Melzer A, Mikikian M, Nosenko V, Pustyl'nik M Y, Ratynskaia S, Sankaran R M, Schneider V, Thimsen E J, Thomas E, Thomas H M, Tolias P, van de Kerkhof M 2023 *Phys. Plasmas* **30** 120601
- [6] Goree J 1994 *Plasma Sources Sci. Technol.* **3** 400
- [7] Feng Y, Goree J, Liu B 2008 *Phys. Rev. Lett.* **100** 205007
- [8] Feng Y, Goree J, Liu B 2010 *Phys. Rev. Lett.* **105** 025002
- [9] Lu S, Huang D, Feng Y 2021 *Phys. Rev. E* **103** 063214
- [10] Huang D, Lu S, Shi X Q, Goree J, Feng Y 2021 *Phys. Rev. E* **104** 035207
- [11] Konopka U, Morfill G, Ratke L 2000 *Phys. Rev. Lett.* **84** 891
- [12] Ichimaru S 1982 *Rev. Mod. Phys.* **54** 1017
- [13] Khrapak S, Couëdel L 2020 *Phys. Rev. E* **102** 033207
- [14] Bajaj P, Khrapak S, Yaroshenko V, Schwabe M 2022 *Phys. Rev. E* **105** 025202
- [15] Nunomura S, Goree J, Hu S, Wang X, Bhattacharjee A, Avinash K 2002 *Phys. Rev. Lett.* **89** 035001

- [16] Nunomura S, Zhdanov S, Morfill G E, Goree J 2003 *Phys. Rev. E* **68** 026407
- [17] Nosenko V, Goree J 2004 *Phys. Rev. Lett.* **93** 155004
- [18] Melzer A, Homann A, Piel A 1996 *Phys. Rev. E* **53** 2757
- [19] Zhang S X, Wang S, Liu X , Wang X Z, Liu F C, He Y F 2025 *Acta Phys. Sin.* **74** 075202 (in Chinese) [张顺欣, 王硕, 刘雪, 王新占, 刘富成, 贺亚峰 2025 物理学报 **74** 075202]
- [20] Tian M, Yao T Y, Cai Z M, Liu F C, He Y F 2024 *Acta Phys. Sin.* **73** 115201 (in Chinese) [田淼, 姚廷昱, 才志民, 刘富成, 贺亚峰 2024 物理学报 **73** 115201]
- [21] Huang Y F, Jia W Z, Zhang Y Y, Song Y H 2024 *Acta Phys. Sin.* **73** 085202 (in Chinese) [黄渝峰, 贾文柱, 张莹莹, 宋远红 2024 物理学报 **73** 085202]
- [22] Kalman G J, Hartmann P, Donkó Z, Rosenberg M 2004 *Phys. Rev. Lett.* **92** 065001
- [23] Nosenko V, Goree J, Ma Z W, Piel A 2002 *Phys. Rev. Lett.* **88** 135001
- [24] Brunton S L, Noack B R, Koumoutsakos P 2020 *Annu. Rev. Fluid Mech.* **52** 477
- [25] Butler K T, Davies D W, Cartwright H, Isayev O, Walsh A 2018 *Nature* **559** 547
- [26] Degraeve J, Felici F, Buchli J, et al. 2022 *Nature* **602** 414
- [27] Huang H, Nosenko V, Huang-Fu H X, Thomas H M, Du C R 2022 *Phys. Plasmas* **29** 073702
- [28] Huang H, Schwabe M, Du C R 2019 *J. Imaging* **5** 36
- [29] Wang Z, Xu J, Kovach Y E, Wolfe B T, Thomas E, Guo H, Foster J E, Shen H W 2020 *Phys. Plasmas* **27** 033703
- [30] Dormagen N, Klein M, Schmitz A S, Thoma M H, Schwarz M 2024 *J. Imaging* **10** 40
- [31] Ding Z, Yao J, Wang Y, Yuan C, Zhou Z, Kudryavtsev A A, Gao R, Jia J 2021 *Plasma Sci. Technol.* **23** 095403
- [32] Yu W, Cho J, Burton J C 2022 *Phys. Rev. E* **106** 035303
- [33] Liang C, Huang D, Lu S, Feng Y 2023 *Phys. Rev. Res.* **5** 033086
- [34] Liang C, Huang D, Lu S, Feng Y 2024 *Phys. Plasmas* **31** 113702
- [35] Liu B, Avinash K, Goree J 2003 *Phys. Rev. Lett.* **91** 255003
- [36] Feng Y, Liu B, Goree J 2008 *Phys. Rev. E* **78** 026415
- [37] LeCun Y, Bengio Y, Hinton G 2015 *Nature* **521** 436
- [38] Kingma D P, Ba J 2014 arXiv: 1412.6980 [cs.LG]

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

# Diagnosing global properties of dusty plasma based on machine learning from single particle dynamics\*


LIANG Chen LU Shaoyu HUANG Dong CHEN Xin FENG Yan †

(*Jiangsu Key Laboratory of Frontier Material Physics and Devices, School of Physical Science and Technology, Institute of Plasma Physics and Technology, Soochow University, Suzhou 215006, China*)

( Received 22 August 2025; revised manuscript received 9 September 2025 )

### Abstract

Currently, it is a great challenge to accurately diagnose global properties of dusty plasmas from limited data. Based on machine learning, a novel diagnostic method for various global properties in dusty plasma experiments is developed from single particle dynamics. It is found that for both two-dimensional (2D) dusty plasma simulations and experiments, the global properties such as the screening parameters  $\kappa$  and the coupling parameter  $\Gamma$  can be accurately determined purely from the position fluctuations of individual particles. Hundreds of independent Langevin dynamical simulations are performed with various specified  $\kappa$  and  $\Gamma$  values, resulting in a great number of individual particle position fluctuation data, which can be used for training, validating, and testing various convolutional neural network (CNN) models. To confirm the feasibility of this diagnostic method, three different CNN models are designed to determine the  $\kappa$  value. For the simulation data, all these CNN models perform excellently in determining the  $\kappa$  value, with the averaged determined  $\kappa$  value almost equal to the specified  $\kappa$  value. For the experiment data, the distribution of the determined  $\kappa$  values always exhibits one prominent peak, which is very consistent with the  $\kappa$  value obtained from the widely accepted phonon spectra fitting method. Furthermore, this diagnostic method is extended to simultaneously determining both the  $\kappa$  and  $\Gamma$  values, achieving satisfactory results by using 2D dusty plasma data from both simulations and experiments. The excellent performance of the CNN models developed here clearly indicates that through machine learning, the global properties of 2D dusty plasmas can be fully characterized purely from single particle dynamics.



**Keywords:** machine learning, convolutional neural network, dusty plasma, diagnosis

**PACS:** 52.27.Gr, 52.27.Lw, 64.30.-t

**DOI:** [10.7498/aps.74.20251129](https://doi.org/10.7498/aps.74.20251129)

**CSTR:** [32037.14.aps.74.20251129](https://cstr.cn/32037.14.aps.74.20251129)

\* Project supported by the National Natural Science Foundation of China (Grant No. 12175159) and the Priority Academic Program Development (PAPD) of Jiangsu Higher Education Institutions, China.

† Corresponding author. E-mail: [fengyan@suda.edu.cn](mailto:fengyan@suda.edu.cn)



基于机器学习从单颗粒动力学中诊断尘埃等离子体全局性质信息

梁晨 卢少瑜 黄栋 陈鑫 冯岩

**Diagnosing global properties of dusty plasma based on machine learning from single particle dynamics**

LIANG Chen LU Shaoyu HUANG Dong CHEN Xin FENG Yan

引用信息 Citation: *Acta Physica Sinica*, 74, 205202 (2025) DOI: 10.7498/aps.74.20251129

CSTR: 32037.14.aps.74.20251129

在线阅读 View online: <https://doi.org/10.7498/aps.74.20251129>

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

尘埃等离子体金属直棘轮中尘埃颗粒的整流

Rectification of dust particles in a dusty plasma metal straight ratchet

物理学报. 2025, 74(7): 075202 <https://doi.org/10.7498/aps.74.20241740>

卷积神经网络辅助无机晶体弹性性质预测

Machine learning-driven elasticity prediction in advanced inorganic materials via convolutional neural networks

物理学报. 2025, 74(12): 120702 <https://doi.org/10.7498/aps.74.20250127>

基于Fokker-Planck-Landau碰撞模型的非均匀尘埃等离子体目标散射特性

Scattering characteristics of non-uniform dusty plasma targets based on Fokker-Planck-Landau collision model

物理学报. 2023, 72(6): 060201 <https://doi.org/10.7498/aps.72.20222113>

尘埃等离子体棘轮中颗粒分离的三维模拟

Three-dimensional numerical simulation of particle separation using a dusty plasma ratchet

物理学报. 2024, 73(11): 115201 <https://doi.org/10.7498/aps.73.20240319>

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>

一种基于图像融合和卷积神经网络的相位恢复方法

Phase retrieval wavefront sensing based on image fusion and convolutional neural network

物理学报. 2021, 70(5): 054201 <https://doi.org/10.7498/aps.70.20201362>