

## 国防科技大学建校 70 周年专题

## 基于深度学习的钻孔辐射压离子加速建模\*

张普渡<sup>1)</sup> 王伟权<sup>1)†</sup> 李哲民<sup>2)</sup> 张资旋<sup>1)</sup>王叶晨<sup>1)</sup> 周泓宇<sup>1)</sup> 银燕<sup>1)‡</sup>

1) (国防科技大学理学院物理系, 长沙 410073)

2) (国防科技大学理学院数学系, 长沙 410073)

(2023 年 4 月 29 日收到; 2023 年 5 月 31 日收到修改稿)

超短超强激光脉冲与固体靶相互作用可通过钻孔辐射压加速机制产生百 MeV 量级的离子束, 离子束的品质强烈依赖于激光和靶的作用参量. 本文以近 400 组激光驱动固体靶的粒子模拟结果作为数据集, 以激光强度、靶密度、靶厚和离子质量作为输入参量, 基于全连接神经网络建立了一个离子峰值能量和截止能量连续映射模型. 该模型用较为稀疏的参量取值获得了较大参量范围内的分析结果, 大大减少了多维参量大范围扫参的计算量. 基于连续映射模型的结果, 得到了钻孔辐射压加速机制下离子峰值能量的修正公式和截止能量的拟合公式, 可为激光离子加速的实验设计提供重要参考.

**关键词:** 激光离子加速, 神经网络**PACS:** 41.75.Jy, 87.85.dq**DOI:** 10.7498/aps.72.20230702

## 1 引言

随着超短超强激光脉冲与等离子体相互作用研究的不断深入, 基于超强激光驱动的离子加速逐渐成为激光等离子体领域的重要研究方向, 在离子束驱动快点火<sup>[1,2]</sup>、束靶中子源<sup>[3,4]</sup>、温稠密物质加热<sup>[5–7]</sup>、质子照相<sup>[8,9]</sup>等领域得到了广泛研究与应用. 常见的激光驱动的离子加速机制包含辐射压加速 (radiation pressure acceleration, RPA)<sup>[10,11]</sup>、靶背法向鞘层加速 (target normal sheath acceleration, TNSA)<sup>[12,13]</sup>、靶破烧蚀加速<sup>[14,15]</sup>、无碰撞激波加速<sup>[16,17]</sup>等. 其中, RPA 机制由于其能量转化效率高、离子束单能性好以及可加速重离子等特点, 在实验上备受关注. 根据固体靶厚度的不同, RPA

机制可分为薄靶条件下的光帆加速 (light-sail RPA, LS-RPA)<sup>[18,19]</sup>和厚靶条件下的钻孔加速 (hole-boring RPA, HB-RPA)<sup>[20,21]</sup>. 在 LS-RPA 机制下, 离子与电子将被压缩为“等离子体飞镜 (plasma mirror)”结构被激光脉冲整体推动加速, 但这种机制对激光脉冲对比度要求较高, 且靶厚度和激光脉冲强度之间有严格的匹配关系<sup>[18,19,22]</sup>. 而对于 HB-RPA 机制, 激光和靶的参数要求相对宽松, 更容易在实验中实现<sup>[23]</sup>, 且可在较高激光强度下对重离子实现有效加速<sup>[24]</sup>.

在基于 HB-RPA 机制的数值模拟和实验设计中, 分析研究对象与参量的关联时需进行参数扫描. 然而, 激光和靶参数的选取范围较为宽泛, 通过开展大量实验或数值模拟进行线性扫参的代价过于高昂. 同时, 不同扫描参量与目标参量间可能

\* 国家自然科学基金青年基金 (批准号: 12005298)、国家自然科学基金联合项目“叶企孙”科学基金 (批准号: U2241281)、湖南省自然科学基金 (批准号: 2022JJ30656)、湖南省自然科学基金青年基金 (批准号: 2021JJ40661) 和国防科技大学科研计划 (批准号: ZK19-25) 资助的课题.

† 通信作者. E-mail: [weiqian.wang@nudt.edu.cn](mailto:weiqian.wang@nudt.edu.cn)

‡ 通信作者. E-mail: [yyin@nudt.edu.cn](mailto:yyin@nudt.edu.cn)

存在一定映射关联, 而通过线性扫参只能得到有限的孤立数据点, 基于有限的数据建立较为可靠的连续映射关系存在较大困难. 因此, 有必要寻找新的研究参量映射规律的手段. 近几年内, 依赖于数据学习的神经网络算法<sup>[25,26]</sup>被逐渐应用在科研领域, 例如托卡马克装置中磁场的控制优化<sup>[27]</sup>、惯性约束聚变实验结果对实验参数的敏感度研究<sup>[28]</sup>、电子加速能谱的自动识别与分类<sup>[29]</sup>、高辐射环境下测得的电子能谱图的去噪分析<sup>[30]</sup>、预测粒子加速器内粒子束纵向相空间演化趋势<sup>[31]</sup>等. 在众多类型的神经网络算法中, 卷积神经网络 (convolutional neural network, CNN) 主要面向二维矩阵数据的处理, 在图像处理和识别等领域应用广泛<sup>[30]</sup>. 自组织映射神经网络 (self-organizing map, SOM) 的训练过程为无监督的竞争学习, 适用于高维数据的聚类分析<sup>[29]</sup>. 全连接构型人工神经网络 (fully connected neural network, FCNN) 可以建立起数个变量关于单一映射量的连续模型, 适用于数据回归类问题的建模分析. Djordjević等<sup>[32]</sup>基于 FCNN 神经网络算法对 TNSA 加速机制的多维参数进行了建模分析, 得到离子截止能量的连续映射模型, 并给出 TNSA 机制下离子能量增大速率的连续映射模型<sup>[33]</sup>.

本文所研究的 HB-RPA 机制下的参数映射也是一个数据回归类问题, 采用 FCNN 神经网络较为适合. 首先将有限的数值模拟结果整理为数据集输入 FCNN, 然后在数据迭代的过程中, 通过神经元权重的反向传递, 把目标参量关于输入参量的变化特征记录在神经网络中, 从而得到连续映射模型. 这一所得模型可较好反映出扫参空间中所有数据点的映射结果, 并可在训练范围外进行推广, 进而对更大范围的结果进行预测. 本文利用 FCNN 建立了 HB-RPA 机制下离子峰值能量和截止能量关于激光强度、靶密度、靶厚度和离子质量这 4 个输入参量的连续映射模型. 根据该模型与 HB-RPA 的理论公式及 PIC 数值模拟结果的对比结果, 对离子峰值能量公式进行修正, 同时给出离子截止能量的经验公式, 实现了对 HB-RPA 机制下离子峰值能量和截止能量的定量描述.

## 2 物理模型

当激光强度与靶厚度近似满足  $a < \pi dn/(n_c \lambda_0)$

关系时, HB-RPA 机制将占主导地位<sup>[34]</sup>, 其中,  $a$  为归一化激光强度, 与激光强度  $I_0$  的关系满足  $a = \sqrt{I_0 \lambda_0^2 / (1 \times 10^{18} \text{ W/cm}^2 \cdot \mu\text{m}^2)}$ ,  $\lambda_0 = 1 \mu\text{m}$  为激光波长,  $d$  为靶厚度,  $n_c = \frac{m_e \omega^2}{4\pi e^2}$  为等离子体临界密度,  $m_e$  为电子质量,  $\omega$  为激光频率,  $e$  为电子电荷量. 一维 (one-dimension, 1D) 情况下, 一束强度恒定为  $I_0$  的圆极化激光正入射到均匀密度为  $n$  的等离子体, 光束在等离子体表面被完全反射. 由稳态加速离子所满足的动量平衡方程, 可以得到实验室系中相对论条件下动量平衡的稳态离子能量表达式<sup>[20]</sup>:

$$E_p = m_i c^2 \left( \frac{2\xi}{1 + 2\sqrt{\xi}} \right), \quad (1)$$

式中, 无量纲参量  $\xi = \frac{I_0}{m_i n c^3}$ . 从 (1) 式可以看出, 一维 HB-RPA 机制下, 大量处于平衡态的离子的峰值能量  $E_p$  主要与激光强度  $I_0$ 、等离子体靶密度  $n$  和离子质量  $m_i$  相关.

本文通过 PIC 程序 EPOCH<sup>[35]</sup> 对 HB-RPA 过程进行了约 400 次 1D 数值模拟. 在模拟中改变激光脉冲的归一化激光强度  $a$ , 等离子体靶厚度  $d$ , 等离子体靶密度  $n$  和离子质量  $m_i$ , 模拟参数选取范围均满足 HB-RPA 离子加速机制要求. 由于靶厚度  $d$  是决定 HB-RPA 加速机制是否起效的重要参量, 将  $d$  作为输入参量加入到神经网络的训练中, 可以更好地保证训练所得模型的可靠性. 在 1D 数值模拟中, 激光时间脉冲设置为梯形包络, 如下式所示:

$$I(t) = \begin{cases} \frac{t}{5T_0} I_0, & 0 < t < 5T_0, \\ I_0, & t > 5T_0, \end{cases}$$

其中  $T_0$  为激光周期,  $I_0$  为激光峰值强度. 等离子体为单一离子组分的平面靶, 靶离子为完全电离. 模拟盒子范围为  $0 \leq x \leq 90\lambda_0$ , 靶前表面位置处于  $10\lambda_0$  处. 激光脉冲由左边界入射. 模拟空间分辨率为  $\Delta x = 0.01\lambda_0$ , 每个网格内各组分的宏粒子数目为 50 个.

图 1(a) 和图 1(c) 分别为  $\text{He}^{2+}$  离子和  $\text{C}^{6+}$  离子的  $x$ - $v$  相空间图, 其中,  $v$  为离子速度.  $x$ - $v$  相空间图展现了 HB-RPA 机制的典型振荡特征<sup>[20,21]</sup>. 在 HB-RPA 机制中, 激光推动电子形成压缩层, 由此产生的电荷分离场把大量靶内离子加速到稳态速度, 如红色虚线框所示. 加速电场的峰值位于电子

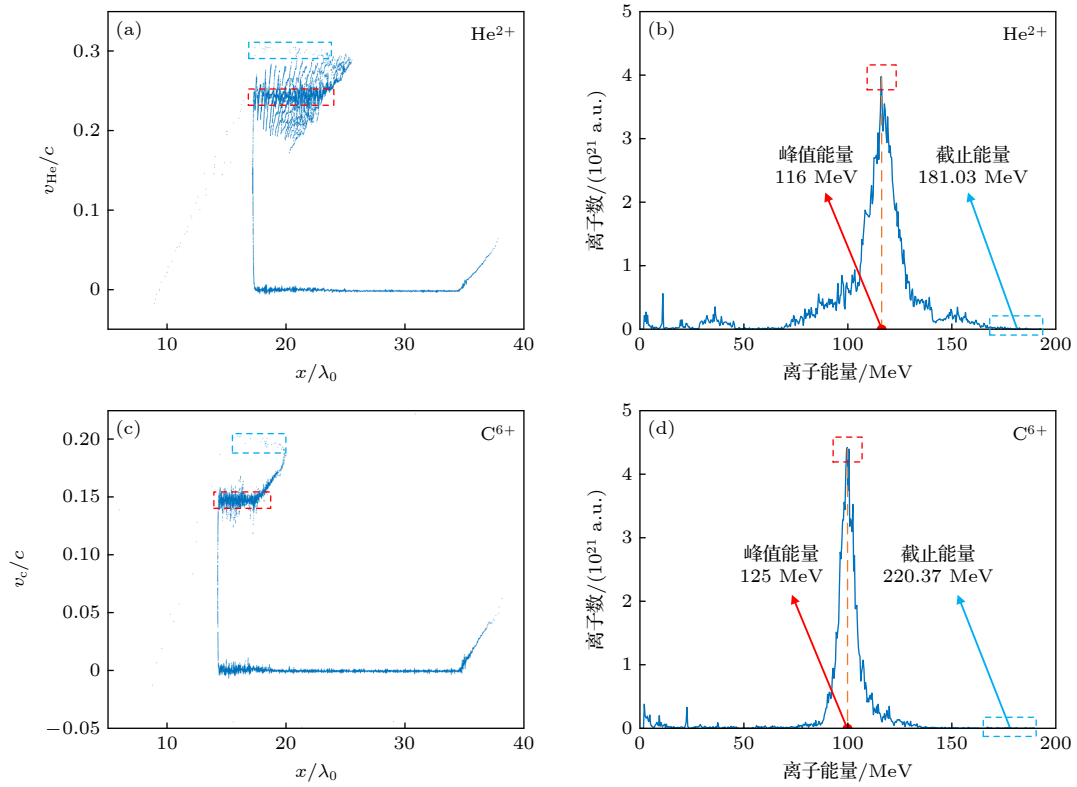


图 1 在  $t = 70T_0$  时刻, (a)  $\text{He}^{2+}$  离子的  $x$ - $v$  相空间分布, (b)  $\text{He}^{2+}$  离子的能谱分布, (c)  $\text{C}^{6+}$  离子的  $x$ - $v$  相空间分布, (d)  $\text{C}^{6+}$  离子的能谱分布. 其中, 激光强度  $a = 100$ , 靶密度  $n = 25n_c$ , 靶厚  $d = 25\lambda_0$ ; 红色虚线框内为峰值能量所对应的离子, 蓝色虚线框内为截止能量所对应的离子

Fig. 1. At  $t = 70T_0$ , (a) the  $x$ - $v$  phase space diagram of  $\text{He}^{2+}$ , (b) the energy spectrum of  $\text{He}^{2+}$ , (c) the  $x$ - $v$  phase space diagram of  $\text{C}^{6+}$ , (d) the energy spectrum of  $\text{C}^{6+}$ , with  $d = 25\lambda_0$ ,  $n = 25n_c$  and  $a = 100$ . The red dashed box circles the ions with peak energy, and the blue dashed box circles the ions with cutoff energy.

压缩层的前表面, 随时间振荡<sup>[20]</sup>, 离子在振荡电场作用下形成形似鱼骨的  $x$ - $v$  相空间结构. 少量滞后的离子被加速电场的上升沿推动至峰值电场区域, 进而被加速至更高能量, 如蓝色虚线框所示. 图 1(b) 和图 1(d) 分别为  $\text{He}^{2+}$  离子和  $\text{C}^{6+}$  离子在  $t = 70T_0$  时刻的能谱图, 此时离子相空间、离子峰值能量和最大离子能量都已趋于稳定. 在能谱图上略去了能量位于能谱中最低 0.5% 部分的低能离子, 呈现清晰的准单能结构. 对于每组数值模拟, 通过诊断离子的  $x$ - $v$  相空间分布来确定该组模拟中 HB-RPA 加速机制占主导地位, 通过离子能谱图统计离子束的峰值能量和截止能量. 舍弃掉不符合 HB-RPA 加速机制的数据点, 最终得到 400 组数据集样本数据点.

### 3 数据准备和搭建神经网络

#### 3.1 数据集生成

整体数据集的采样采用系统抽样方式, 在一定

的参数范围内均匀间隔取值, 通过离子种类将数据集划分为质子集、 $\text{He}^{2+}$  集、 $\text{C}^{6+}$  集、 $\text{O}^{8+}$  集和测试集共 5 个集合. 其中, 质子集合经过数据筛选后总共记录了 231 次数值模拟结果, 具体的输入参数取值为: 靶厚  $d$  在  $[7.5\lambda_0, 35\lambda_0]$  范围内间隔  $2.5\lambda_0$  均匀取值, 靶密度  $n$  在  $[12.5n_c, 40n_c]$  范围内间隔  $2.5n_c$  均匀取值, 激光强度分别取值  $4 \times 10^{21}$ ,  $6 \times 10^{21}$ ,  $8 \times 10^{21}$ ,  $1 \times 10^{22}$ ,  $2 \times 10^{22}$ ,  $3 \times 10^{22}$  W/cm<sup>2</sup>.  $\text{He}^{2+}$  离子集合包含 49 次数值模拟的结果,  $\text{C}^{6+}$  离子与  $\text{O}^{8+}$  离子分别包含 50 次数值模拟的结果, 3 种离子的靶厚  $d$  取值为  $15\lambda_0$  和  $25\lambda_0$ , 靶密度  $n$  在  $[10n_c, 30n_c]$  范围内间隔  $5n_c$  均匀取值, 激光强度取值为  $6 \times 10^{21}$ ,  $8 \times 10^{21}$ ,  $1 \times 10^{22}$ ,  $2 \times 10^{22}$ ,  $3 \times 10^{22}$  W/cm<sup>2</sup>. 最后一个集合为独立于其他数据的测试集, 离子种类包括  $\text{D}^+$ ,  $\text{T}^+$ ,  $\text{He}^{2+}$ ,  $\text{B}^{4+}$ ,  $\text{C}^{6+}$ ,  $\text{F}^{9+}$ ,  $\text{Mg}^{12+}$  和  $\text{Al}^{13+}$  离子, 在每组数值模拟中, 模拟参数  $d$ ,  $n$  和  $a$  均独立取值, 共 20 个数据点. 记录每组模拟结果的离子峰值能量  $E_p$  与截止能量  $E_m$  作为训练参量, 具体取值分布如表 1 所列. 图 2(a)—(d) 更直观地给出了

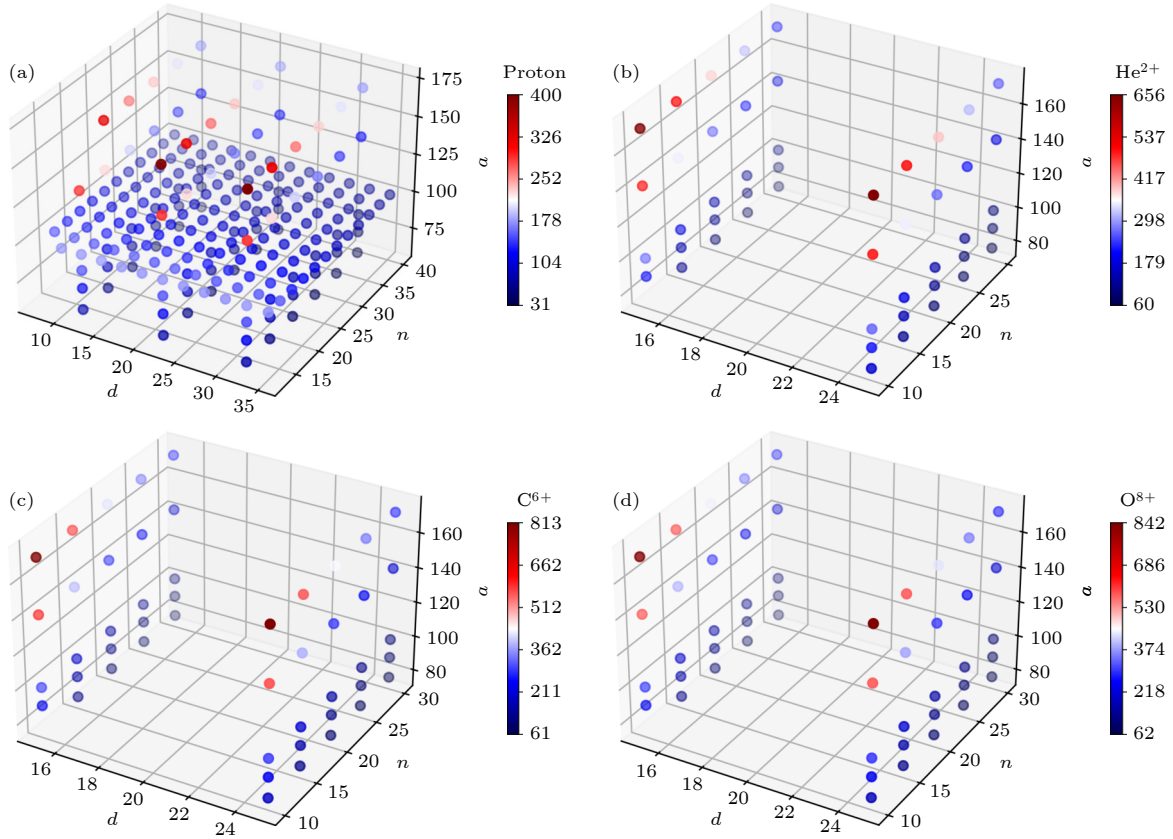


图 2 离子峰值能量随输入参数  $d$ ,  $n$  和  $a$  分布的三维散点图 (a) 质子; (b)  $\text{He}^{2+}$  离子; (c)  $\text{C}^{6+}$  离子; (d)  $\text{O}^{8+}$  离子

Fig. 2. Scatter plot depiction of ion peak energy data ensembles as a function of input parameters  $d$ ,  $n$  and  $a$ : (a) Proton case; (b)  $\text{He}^{2+}$ , (c)  $\text{C}^{6+}$ ; (d)  $\text{O}^{8+}$ .

4 种离子的参数取值分布, 并用散点颜色标注了该数据点所对应的离子峰值能量. 为控制输入参数的数量级相近, 靶厚参数  $d$  以  $\lambda_0$  归一化, 靶密度参数  $n$  以临界密度  $n_c$  归一化, 激光强度以归一化激光强度  $a$  输入, 离子质量以原子质量数  $A$  输入.

表 1 数值模拟数据集参数取值分布

Table 1. Simulation datasets prepared for neural network training.

离子种类	模拟组数	$d/\lambda_0$	$n/n_c$	$a$
Proton	231	[7.5, 35]	[12.5, 40]	[63.2, 173.2]
$\text{He}^{2+}$	49	15, 25	[10, 30]	[77.5, 173.2]
$\text{C}^{6+}$	50	15, 25	[10, 30]	[77.5, 173.2]
$\text{O}^{8+}$	50	15, 25	[10, 30]	[77.5, 173.2]
其他	20	独立分布		

### 3.2 神经网络搭建

本文基于 Pytorch 中的 nn 模块来搭建深度神经网络, 所采用的网络类型为 FCNN, 通过测试与对比训练结果对神经网络结构与超参数的选取进行调整, 最终确定神经网络结构如图 3 所示. 经过

筛选和后处理的样本数据被输入到输入层, 4 个神经元分别对应输入参数  $d$ ,  $n$ ,  $a$ ,  $A$ . 经过 6 个隐藏层后, 结果收敛至输出层的单一输出量.  $E_p$  与  $E_m$  采用相同的神经网络结构.




图 3 训练所使用的神经网络结构

Fig. 3. Neural network architecture used in the following training.

神经网络训练参数的选取与所得到代理模型 (surrogates ensemble, SE)<sup>[36]</sup> 的泛化能力密切相关. 我们所使用的神经网络采用均方差损失



(mean square error, MSE) 函数, 采用 nn 模块默认的  $L_2$  正则化, 其中  $L_2 = 2 \times 10^{-5}$ . 神经元激活函数选取为 Sigmoid 与 PReLU, 这两种激活函数皆为单调函数, 模型映射曲线在有限的预测范围内保持缓慢平滑变化, 这一特征与 HB-RPA 理论公式相契合. 训练结果表明, 我们所确定的神经网络结构可使模型收敛至接近理论预测结果, 同时保持了较好的平滑程度和泛化性, 这使得分析参量的训练和预测结果都具有一定的可靠性.

### 3.3 训练与测试

针对模拟数据所展开的训练类型均为监督学习, 在给定输入数据上训练神经网络, 训练过程中优化器选择基于随机梯度下降的 Adam 优化器, 损失函数选择 MSE. 本文将数据集划分为 380 组数据的训练集和 20 组数据的测试集, 训练集与测试集皆为固定. 训练数据在神经网络上迭代次数固定为 8000 次, 学习率固定为  $1 \times 10^{-4}$ , 损失函数误差下降至  $1 \times 10^{-4}$  时, 模型趋于收敛, 且平滑程度与拟合程度良好.

## 4 研究结果

### 4.1 神经网络集合

在初始化权值的训练条件下, 每次的训练结果会略有不同. 由于本文所使用的参数空间相对稀疏, 每次训练所得模型的差异将会更加明显. 为此, 本文对 10 个神经网络同时进行训练, 得到一个神经网络集合, 并根据模型收敛时的损失函数取值对

训练结果做加权平均, 从而生成训练结果的代理模型. 取每个模型最后 2000 次迭代的损失函数均值的倒数作为该模型的权值, 对所有神经网络模型加权平均, 由模型权值进行归一化, 即可得到

$$SE(x) = \left[ \sum_{i=1}^N w_i S_i(x) \right] / \left[ \sum_{i=1}^N w_i \right], \quad (2)$$

式中, 代理模型 SE 是所有训练模型  $S_i$  的均值;  $w_i$  为每个训练模型的权值, 为最后 2000 次迭代损失函数均值的倒数;  $x$  为输入参数的取值;  $N = 10$  表示神经网络模型训练个数. 为了衡量代理模型在一定取值范围内的可变性, 定义了标准差  $\sigma$ :

$$\sigma = \sqrt{N \sum_{i=1}^N w_i (S_i - \bar{S})^2} / \sqrt{N \sum_{i=1}^N w_i}, \quad (3)$$

式中,  $\bar{S}$  为所有模型的均值. 在与测试数据进行比照时, 可将标准差  $\sigma$  作为模型可靠程度的参考值, 以红色色块标注在代理模型映射曲线两侧.

### 4.2 代理模型映射

利用神经网络训练结果和加权所得的代理模型, 在一定范围内的参数空间上对输入参数进行连续扫参, 可得到目标参量关于不同输入参数的映射关系, 并与测试集数据点进行比照.

图 4 为根据神经网络代理模型所绘出的离子峰值能量与截止能量关于靶密度  $n$  和激光强度  $a$  的二维连续映射图. 从图 4(a) 可看出, 当激光强度一定时, 峰值能量  $E_p$  随靶密度的增大而减小; 当靶密度固定时, 峰值能量  $E_p$  随激光强度的增大而增大. 当激光强度与靶密度满足  $\frac{a^2}{n/n_c}$  保持不变时,




图 4  $\text{He}^{2+}$  离子 (a) 峰值能量  $E_p$  与 (b) 截止能量  $E_m$  的二维连续映射图, 其中靶厚  $d = 15\lambda_0$ , 参数映射范围为  $63.2 \leq a \leq 173.2$  和  $10n_c \leq n \leq 40n_c$

Fig. 4. Two-dimensional continuous mapping of peak energy  $E_p$  (a) and cutoff energy  $E_m$  (b) for  $\text{He}^{2+}$  over  $63.2 \leq a \leq 173.2$  and  $10n_c \leq n \leq 40n_c$  with  $d = 15\lambda_0$ .

离子峰值能量接近为定值, 峰值能量  $E_p$  映射结果与 (1) 式理论结果符合很好. 同时, 图 4(b) 给出的截止能量  $E_m$  随靶密度增大而减小, 随激光强度增大而增大, 与峰值能量  $E_p$  呈现出一致的映射规律.

图 5 为离子峰值能量代理模型关于单个输入参数的映射曲线和峰值能量理论曲线 (由 (1) 式给出) 的比照结果. 图 5(a) 给出了  $\text{He}^{2+}$  离子峰值能量随靶密度  $n$  变化的连续映射曲线, 训练参数取值范围为  $10n_c \leq n \leq 30n_c$ , 预测参数取值范围为  $30n_c \leq n \leq 50n_c$ . 由图 5(a) 所示, 训练参数取值范围内, 代理模型与理论曲线和测试集数据吻合程度相当好; 在预测参数取值范围内, 模型映射值与测试集数据偏差小于 10%, 模型的可靠性可以得到保证. 而当  $n > 50n_c$  时, 模型映射值与理论值相差超

过 10%, 模型的可靠性不好, 所以这里没有给出映射结果. 若增大训练参数取值范围, 则可在更大范围内保证模型预测的可靠性.

图 5(b) 给出了  $\text{He}^{2+}$  离子峰值能量与激光强度  $a$  的模型连续映射曲线. 激光强度的训练参数取值范围为  $77.5 < a < 173.2$ , 预测参数取值范围为  $63.2 < a < 77.5$ , 模型映射曲线在所观测范围内与理论曲线保持了较好的吻合程度. 由于 HB-RPA 机制的参数限制, 在较低的激光强度下, 模拟结果将与理论出现偏差 [37], 而过高的激光强度将破坏离子相空间的振荡结构, 转为“不完全钻孔加速”机制 [38]. 因此, 这里未对激光强度在更大的范围内做外推预测. 图 5(c) 和图 5(d) 分别为  $\text{He}^{2+}$  离子峰值能量与靶厚  $d$  和离子质量  $A$  的模型映射曲线. 由

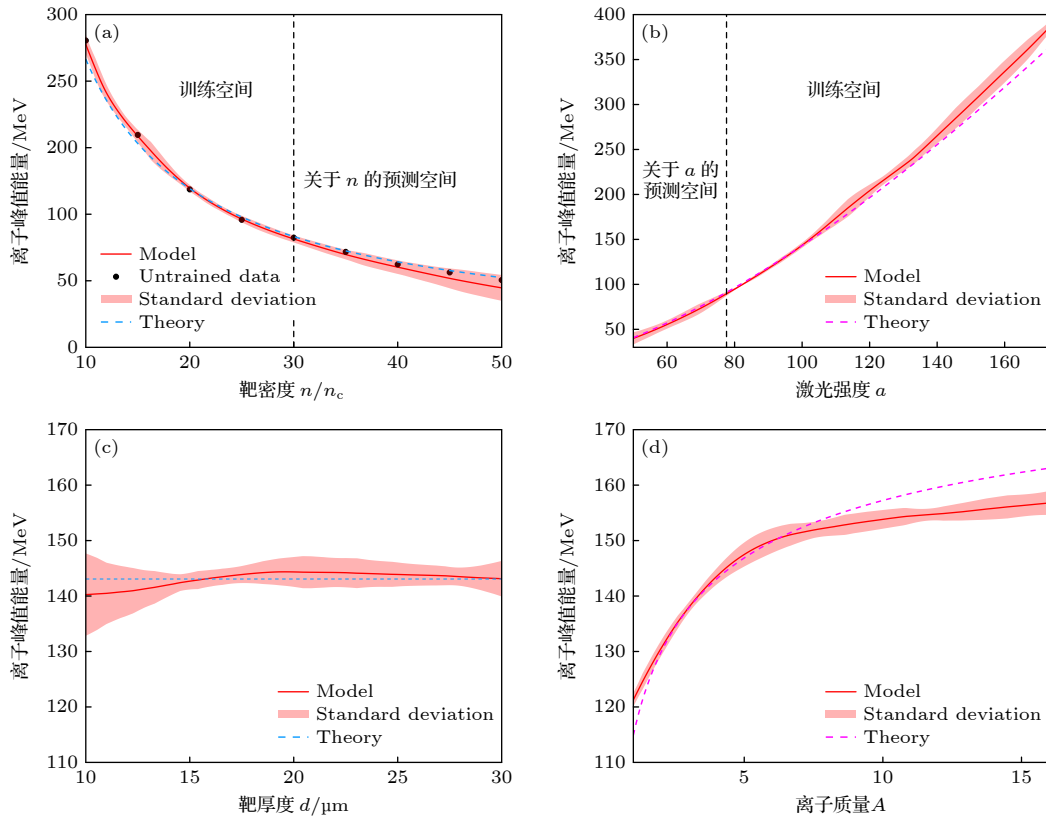


图 5 (a)  $\text{He}^{2+}$  离子峰值能量  $E_p$  关于靶密度  $n$  的映射曲线, 其中靶厚  $d = 15\lambda_0$ , 激光强度  $a = 100$ ; (b)  $\text{He}^{2+}$  离子峰值能量  $E_p$  关于激光强度  $a$  的映射曲线, 其中靶厚  $d = 15\lambda_0$ , 靶密度  $n = 20n_c$ ; (c)  $\text{He}^{2+}$  离子峰值能量  $E_p$  关于靶厚  $d$  的映射曲线, 其中靶密度  $n = 20n_c$ , 激光强度  $a = 100$ ; (d) 离子峰值能量  $E_p$  关于离子质量数  $A$  的映射曲线, 其中靶厚  $d = 15\lambda_0$ , 靶密度  $n = 20n_c$ , 激光强度  $a = 100$ . 图中红色实线为代理模型的映射曲线, 模型标准差用红色色块填充于代理模型曲线两侧. 蓝色虚线给出的是根据 HB-RPA 机制理论公式所绘出的离子峰值能量随离子密度变化的曲线, 黑色实心数据点为测试集数据点, 参数取值范围与模型预测范围用黑色虚线分隔

Fig. 5. (a) Parameter scan of  $\text{He}^{2+}$  peak energy  $E_p$  over target density  $n$  with  $d = 15\lambda_0$ ,  $a = 100$ ; (b) parameter scan of  $\text{He}^{2+}$  peak energy  $E_p$  over laser intensity  $a$  with  $d = 15\lambda_0$ ,  $n = 20n_c$ ; (c) parameter scan of  $\text{He}^{2+}$  peak energy  $E_p$  over target thickness  $d$  with  $a = 100$ ,  $n = 20n_c$ ; (d) parameter scan of ion peak energy  $E_p$  over ion mass number  $A$  with  $a = 100$ ,  $n = 20n_c$  and  $d = 15\lambda_0$ . The SE mapping curves are drawn with red solid, the theoretical curves are drawn with dashed, the red filled region indicates the standard deviation, and the untrained data from test subset are drawn with black dot.

图 5(c) 可知,  $\text{He}^{2+}$  离子峰值能量的代理模型映射值在观测范围内几乎不变. 根据 (1) 式, 离子峰值能量与靶厚度无明显依赖关系, 模型映射结果与理论基本一致. 由图 5(d) 可知, 离子质量较低时, 映射曲线与理论曲线吻合程度较好; 而在离子质量较高时, 映射曲线与理论曲线出现一定程度的偏差. 训练神经网络所使用的数据集源自 PIC 数值模拟结果, 能够很好地描述激光驱动离子加速过程中的相对论和非线性效应. 而理论公式是在辐射压与静电电压达到动量平衡的理想稳态条件下得到的, 在实际加速条件下这种理想稳态有可能被破坏. 因此, 可认为代理模型的映射结果相比理论结果更符合实际加速情况, 需要结合数值模拟结果对 HB-RPA 机制中的峰值能量公式进行修正.

### 4.3 离子的峰值能量和截止能量

#### 4.3.1 峰值能量修正

图 5(d) 展现出映射曲线与理论曲线存在偏差, 离子峰值能量在质量较低时略高于理论值, 而在质量较高时略低于理论值, 模型曲线与理论曲线于离子质量数  $A = 5$  附近相交. 对比了更大范围的数值模拟结果与理论值, 发现这一偏差仍然存在. 结合代理模型所给出的模型和测试集所得模拟数据, 对原理论公式进行修正, 修正后的公式可描述离子质量对离子峰值能量的影响:

$$E_p' = m_i c^2 \left[ \frac{2\xi}{1 + 2\sqrt{\xi}} \right] \times [1 + 0.001(5 - A)]^2, \quad (4)$$

式中,  $A$  为离子质量数. 经过修正的模型曲线与测试集数据点对比如图 6 所示.




图 6 在  $d = 15\lambda_0$ ,  $n = 20n_c$  和  $a = 100$  下, 离子峰值能量随离子质量的变化

Fig. 6. Ion peak energy scan with ion mass number  $A$  with  $d = 15\lambda_0$ ,  $n = 20n_c$  and  $a = 100$ .

如图 6 所示, 当质量数  $A > 5$  时, 数值模拟结果与理论曲线开始出现偏移. 当质量数  $A > 10$  时, 模拟结果与理论结果差异逐渐增大, 误差率接近 10% 左右. 当采用基于离子质量数的修正公式时, 理论结果与数值模拟结果及模型映射结果符合很好. 对于质量数  $A > 30$  的中高  $Z$  离子, 其较为复杂的电离过程将对离子的加速过程产生影响. 在电离度较低的情况下, 重离子将滞后于电子被推动形成的钻孔活塞结构, 此时 HB-RPA 模型不再适用, 离子峰值能量将显著低于理论值<sup>[21]</sup>. 因此, 这里基于映射结果给出的修正模型仅适用于  $A < 30$  的靶材料. 在质量数  $A > 30$  时, 需增大数据集的质量数取值范围, 并考虑靶材料的离化过程对加速过程的影响.

#### 4.3.2 截止能量映射

当离子截止能量作为目标参量时, 重复与离子峰值能量相同的训练和扫参操作, 可以得到连续映射曲线, 如图 7 所示.

图 7 给出了  $\text{He}^{2+}$  离子的截止能量关于靶密度  $n$ 、激光强度、靶厚和离子质量的映射关系. 结果表明, 离子截止能量随  $n$  的增大而减小, 随激光强度的增强和离子质量的增大而上升, 而与靶厚无明显关联. 离子截止能量的映射结果与离子峰值能量的映射结果呈现出一致的单调性变化规律. 因此, 将结合离子峰值能量  $E_p$  与离子截止能量  $E_m$  的比值映射模型给出 HB-RPA 机制下离子截止能量的经验公式.

#### 4.3.3 能量比值关系

将每组模拟截止能量  $E_m$  和峰值能量  $E_p$  的比值记为  $k = E_m/E_p$ . 将  $k$  作为建模参量, 神经网络结构与超参数设置均与训练  $E_p$  和  $E_m$  时保持一致, 损失函数阈值设为  $2 \times 10^{-4}$ , 重复与  $E_p$ ,  $E_m$  类似的训练和代理模型加权平均操作, 得到  $k$  关于不同输入参量的映射模型.

图 8 为质子、 $\text{He}^{2+}$ 、 $\text{C}^{6+}$ 、 $\text{O}^{8+}$  四种离子的截止能量  $E_m$  与峰值能量  $E_p$  的比值  $k$  的二维连续映射图. 由图 8(a) 所示, 质子的能量比值  $k$  随靶密度  $n$  增大而增大, 随激光强度  $a$  增大而减小,  $k$  值在较小范围内缓慢变化且近似均匀. 在  $a < 90$ ,  $n > 25n_c$  的部分区域,  $k$  变化幅度增大, 呈现出一定非线性变化趋势. 图 8(b)—(d) 显示, 其他 3 种离子的  $k$




图 7 (a)  $\text{He}^{2+}$  离子截止能量  $E_m$  关于靶密度  $n$  的映射曲线, 其中靶厚  $d = 15\lambda_0$ , 激光强度  $a = 100$ ; (b)  $\text{He}^{2+}$  离子截止能量  $E_m$  关于激光强度  $a$  的映射曲线, 其中靶厚  $d = 15\lambda_0$ , 靶密度  $n = 20n_c$ ; (c)  $\text{He}^{2+}$  离子截止能量  $E_m$  关于靶厚  $d$  的映射曲线, 其中靶密度  $n = 20n_c$ , 激光强度  $a = 100$ ; (d) 离子截止能量  $E_m$  关于离子质量数  $A$  的映射曲线, 其中靶厚  $d = 15\lambda_0$ , 靶密度  $n = 20n_c$ , 激光强度  $a = 100$

Fig. 7. (a) Parameter scan of  $\text{He}^{2+}$  cutoff energy  $E_m$  over target density  $n$  with  $d = 15\lambda_0$ ,  $a = 100$ ; (b) parameter scan of  $\text{He}^{2+}$  cutoff energy  $E_m$  over laser intensity  $a$  with  $d = 15\lambda_0$ ,  $n = 20n_c$ ; (c) parameter scan of  $\text{He}^{2+}$  cutoff energy  $E_m$  over target thickness  $d$  with  $a = 100$ ,  $n = 20n_c$ ; (d) parameter scan of ion cutoff energy  $E_m$  over ion mass number  $A$  with  $a = 100$ ,  $n = 20n_c$  and  $d = 15\lambda_0$ .

值变化趋势与质子相同, 且  $k$  值的变化范围随离子质量数  $A$  的增大而增大.

图 9 为能量比值  $k$  随激光强度和靶密度变化的映射曲线. 图 9(a) 显示,  $k$  随着激光强度  $a$  的增大近似以线性规律减小, 其斜率随靶密度增大而增大. 图 9(b) 显示, 当  $n < 25n_c$  时,  $k$  随着靶密度  $n$  的增大而近似线性增大; 当靶密度  $n > 25n_c$  时,  $k$  的上升幅度显著变大, 呈现非线性变化趋势. 前面图 1 中关于离子相空间的分析已给出: 峰值能量对应的离子主要在电荷分离场的峰值区域内被加速;

而截止能量对应的离子先被电荷分离场的上升沿预加速, 再进入峰值区域被加速, 所以具有更高的能量. 当激光强度较大或靶密度较低时, 电荷分离场峰值强度增加, 导致离子峰值能量增大, 截止能量与峰值能量差距减小. 当激光强度较小或靶密度较高时, 电荷分离场峰值强度降低, 离子受电荷分离场上升沿加速所获得的能量占比增大, 导致截止能量与峰值能量差距增大. 综合上述映射模型特征和物理过程分析, 给出了能量比值  $k$  关于输入参量的拟合公式:

$$k = \begin{cases} -2.0625 \times 10^{-3}a[1 + 0.02A + 0.1667(n/n_c)] \\ + 0.01389(n/n_c) + 0.01A + 1.62 & (n < 25n_c), \\ -2.0625 \times 10^{-3}a[1 + 0.02A + 0.0278(n/n_c - 21.127)^2] \\ + 5.787 \times 10^{-8}(n/n_c - 2.3207)^5 + 0.01A + 1.62 & (n > 25n_c). \end{cases} \quad (5)$$






图 8 (a) 质子, (b)  $\text{He}^{2+}$ , (c)  $\text{C}^{6+}$  和 (d)  $\text{O}^{8+}$  的能量比值  $k = E_m/E_p$  的二维连续映射图, 其中靶厚  $d = 20\lambda_0$ , 参数映射范围为  $63.2 \leq a \leq 173.2$  和  $10n_c \leq n \leq 30n_c$

Fig. 8. Two-dimensional continuous mapping of  $k = E_m/E_p$  over  $63.2 \leq a \leq 173.2$  and  $10n_c \leq n \leq 30n_c$  with  $d = 20\lambda_0$ : (a) Proton case; (b)  $\text{He}^{2+}$ ; (c)  $\text{C}^{6+}$ ; (d)  $\text{O}^{8+}$ .

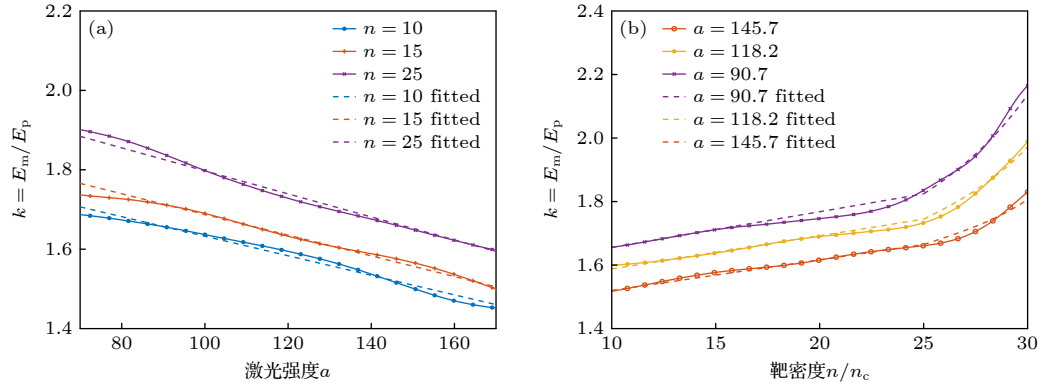


图 9  $\text{C}^{6+}$  离子能量比值  $k$  随 (a) 激光强度和 (b) 靶密度的映射曲线 (实线) 和拟合公式结果 (虚线), 其中参数范围分别为  $63.2 \leq a \leq 173.2$ ,  $10n_c \leq n \leq 30n_c$ , 靶厚  $d = 15\lambda_0$

Fig. 9. Parameter scan (solid) and fitted formula (dashed) of  $k$  over (a)  $63.2 \leq a \leq 173.2$  and (b)  $10n_c \leq n \leq 30n_c$  for  $\text{C}^{6+}$  with  $d = 15\lambda_0$ .

在  $n < 25n_c$  时, (5) 式中第 1 项描述了  $k$  关于激光强度  $a$  的线性变化趋势, 以及靶密度  $n$  和离子质量数  $A$  对激光强度映射的影响; 第 2 项和第 3 项反映了靶密度  $n$  和离子质量数  $A$  对  $k$  值整体取值分布的影响.  $n > 25n_c$  时, 第 1 项与第 2 项中靶密度  $n$  增加了高次项, 描述了在较大密度下能量比值关于  $n$  变化的非线性趋势, 此时上升幅度增大. 离

子截止能量  $E_m$  可以由下式给出:

$$E_m = k \cdot E'_p, \quad (6)$$

其中,  $E'_p$  为修正后的离子峰值能量.

## 5 结论与展望

本文基于 FCNN 算法对粒子模拟所生成的数

数据集展开了分析,建立了 HB-RPA 机制下离子峰值能量和截止能量关于激光强度、靶密度、靶厚度和离子质量的连续映射模型. 该模型在与测试集数据和理论公式的比对中表现良好,且具有一定参数范围内的预测能力. 研究发现,当离子质量数较大时,HB-RPA 机制下的峰值能量公式与数值模拟结果存在差异. 基于映射模型和数值模拟结果,给出了离子峰值能量的修正公式和离子截止能量的经验公式. 在基于 HB-RPA 的激光加速离子实验设计中,我们的映射模型和经验公式可为激光和靶参数的选取提供重要参考. 本工作也可以拓展到更多样化的目标参量,对离子束产额、单能性和准直度等束流品质进行分析.

## 参考文献

- [1] Roth M, Cowan T E, Key M H, et al. 2001 *Phys. Rev. Lett.* **86** 436
- [2] Fernandez J C, Honrubia J J, Albright B J, Flippo K A, Gautier D C, Hegelich B M, Schmitt M J, Temporal M, Yin L 2009 *Nucl. Fusion* **49** 065004
- [3] Roth M, Jung D, Falk K, et al. 2013 *Phys. Rev. Lett.* **110** 044802.
- [4] Jiang X R, Shao F Q, Zou D B, Yu M Y, Hu L X, Guo X Y, Huang T W, Zhang H, Wu S Z, Zhang G B 2020 *Nucl. Fusion* **60** 076019
- [5] Patel P K, Mackinnon A J, Key M H, Cowan T E, Foord M E, Allen M, Price D F, Ruhl H, Springer P T, Stephens R 2003 *Phys. Rev. Lett.* **91** 125004
- [6] Mancic A, Levy A, Harmand M, Nakatsutsumi M, Antici P, Audebert P, Combis P, Fourmaux S, Mazevet S, Peyrusse O, Recoules V, Renaudin P, Robiche J, Dorchies F, Fuchs J 2010 *Phys. Rev. Lett.* **104** 035002
- [7] Pelka A, Gregori G, Gericke D O, et al. 2010 *Phys. Rev. Lett.* **105** 265701
- [8] Faenov A Y, Pikuz T A, Fukuda Y, et al. 2009 *JETP Lett.* **89** 485
- [9] Faenov A Y, Pikuz T A, Fukuda Y, et al. 2009 *Appl. Phys. Lett.* **95** 101107
- [10] Esirkepov T, Borghesi M, Bulanov S V, Mourou G, Tajima T 2004 *Phys. Rev. Lett.* **92** 175003
- [11] Pegoraro F, Bulanov S V. 2007 *Phys. Rev. Lett.* **99** 065002
- [12] Snavely R A, Key M H, Hatchett S P, et al. 2000 *Phys. Rev. Lett.* **85** 2945
- [13] Mackinnon A J, Borghesi M, Hatchett S, Key M H, Patel P K, Campbell H, Schiavi A, Snavely R, Wilks S C, Willi O 2001 *Phys. Rev. Lett.* **86** 1769
- [14] Yin L, Albright B J, Hegelich B M 2006 *Laser Part. Beams* **24** 291
- [15] Yin L, Albright B J, Hegelich B M, Bowers K J, Flippo K A, Kwan T J T, Fernández J C 2007 *Phys. Plasmas* **14** 056706
- [16] Silva L O, Marti M, Davies J R, Fonseca R A, Ren C, Tsung F S, Mori W B 2004 *Phys. Rev. Lett.* **92** 015002
- [17] Chen M, Sheng Z M, Dong Q L, He M, Li Y T, Bari M A, Zhang J 2007 *Phys. Plasmas* **14** 053102
- [18] Simmons J F L, McInnes C R 1993 *Am. J. Phys.* **61** 205
- [19] Macchi A, Veghini S, Pegoraro F 2009 *Phys. Rev. Lett.* **103** 085003
- [20] Robinson A P L, Gibbon P, Zepf M, Kar S, Evans R G, Bellei C 2009 *Plasma Phys. Controlled Fusion* **51** 024004
- [21] Robinson A P L, Kwon D H, Lancaster K 2009 *Plasma Phys. Controlled Fusion* **51** 095006
- [22] Yan X Q, Lin C, Sheng Z M, Guo Z Y, Liu B C, Lu Y R, Fang Y R, Fang J X 2008 *Phys. Rev. Lett.* **100** 135003
- [23] Kar S, Kakolee K F, Qiao B, et al. 2012 *Phys. Rev. Lett.* **109** 185006
- [24] Nishiuchi M, Dover N P, Hata M, Sakaki H, Kondo K, Lowe H F, Miyahara T, Kiriyaama H, Koga J K, Iwata N, Alkhimova M A, Pirozhkov A S, Faenov A Y, Pikuz T A, Sagisaka A, Watanabe Y, Kando M, Kondo K, Ditter E J, Ettlinger O C, Hicks G S, Najmudin Z, Ziegler T, Zeil K, Schramm U, Sentoku Y 2020 *Phys. Rev. Res.* **2** 033081
- [25] LeCun Y, Bengio, Hinton G 2015 *Nature* **521** 436
- [26] Abadi M, Agarwal A, Barham P, et al. 2016 *arXiv: 1603.04467 [cs.DC]*
- [27] Degraeve J, Felici F, Buchli J, et al. 2022 *Nature* **602** 414
- [28] Nakhleh J B, Fernandez G M G, Grosskopf M J, Wilson B M, Kline J, Srinivasan G 2021 *IEEE Trans. Plasma Sci.* **49** 2238
- [29] Volkova T M, Nerush E N, Kostyukov I Y 2021 *Quantum Electron.* **51** 854
- [30] Miyatake T, Shiokawa K, Sakaki H, Dover N P, Nishiuchi M, Lowe H F, Kondo K, Kon A, Kando M, Kondo K, Watanabe Y 2021 *Nucl. Instrum. Methods in Phys. Res. Sect. A* **999** 165227
- [31] Emma C, Edelen A, Hogan M J, Shea B O, White G, Yakimenko V 2018 *Phys. Rev. Accel. Beams* **21** 112802
- [32] Djordjević B Z, Kemp A J, J Kim 2021 *Phys. Plasmas* **28** 043105
- [33] Djordjević B Z, Kemp A J, J Kim Ludwig J, Simpson R A, Wilks S C, Ma T, Mariscal D A 2021 *Plasma Phys. Controlled Fusion* **63** 094005
- [34] Qiao B, Zepf M, Borghesi M, Dromey B, Geissler M, Karmakar A, Gibbon P 2010 *Phys. Rev. Lett.* **105** 155002
- [35] Arber T D, Bennett K, Brady C S, Lawrence D A, Ramsay M G, Sircombe N J, Gillies P, Evans R G, Schmitz H, Bell A R, Ridgers C P 2015 *Plasma Phys. Controlled Fusion* **57** 113001
- [36] Zhou Z H, Wu J X, Tang W 2002 *Artif. Intell.* **137** 239
- [37] Robinson A P L 2011 *Phys. Plasmas* **18** 056701
- [38] Weng S M, Murakami M, Mulser P, Sheng Z M 2012 *New J. Phys.* **14** 063026

SPECIAL TOPIC—The 70th anniversary of National University of Defense Technology

# Modeling of ion accelerated by borehole radiation pressure based on deep learning\*

Zhang Pu-Du<sup>1)</sup> Wang Wei-Quan<sup>1)†</sup> Li Zhe-Min<sup>2)</sup> Zhang Zi-Xuan<sup>1)</sup>  
 Wang Ye-Chen<sup>1)</sup> Zhou Hong-Yu<sup>1)</sup> Yin Yan<sup>1)‡</sup>

1) (*Department of Physics, National University of Defense Technology, Changsha 410073, China*)

2) (*Department of Mathematics, National University of Defense Technology, Changsha 410073, China*)

( Received 29 April 2023; revised manuscript received 31 May 2023 )

## Abstract

Laser-driven ion acceleration has potential applications in high energy density matter, ion beam-driven fast ignition, beam target neutron source, warm dense matter heating, etc. Ultrashort relativistic laser interacting with solid target can generate ion beam with several hundreds of MeV in energy, and the quality of the ion beam depends strongly on the interaction parameters between the laser and the target. Development in deep learning can provide new method of analyzing the relationship between parameters in physics system, which can significantly reduce the computational and experimental cost. In this paper, a continuous mapping model of ion peak and cutoff energy is developed based on a fully connected neural network (FCNN). In the model, the dataset is composed of nearly 400 sets of particle simulations of laser-driven solid targets, and the input parameters are laser intensity, target density, target thickness, and ion mass. The model uses sparse parameter values to obtain the analysis results in a large range of parameters, which greatly reduces the computational amount of multi-dimensional parameters sweeping in a wide range. Based on the results of this model mapping, the correction formula for the ion peak energy is obtained. Furthermore, the ratio of ion cutoff energy to peak energy of each set of particle simulation is calculated. Repeating the same training process of ion peak energy and cutoff energy, the continuous mapping model of energy ratio is developed. According to the energy ratio model mapping results, the quantitative description of the relationship between ion cutoff energy and peak energy is realized, and the fitting formula for the cutoff energy of the hole-boring radiation pressure acceleration (HB-RPA) mechanism is obtained, which can provide an important reference for designing the laser-driven ion acceleration experiments.

**Keywords:** laser-driven ion acceleration, neural Networks

**PACS:** 41.75.Jv, 87.85.dq

**DOI:** [10.7498/aps.72.20230702](https://doi.org/10.7498/aps.72.20230702)

\* Project supported by the Young Scientists Fund of the National Natural Science Foundation of China (Grant No. 12005298), the “Ye Qisun” Science Fund of the National Natural Science Foundation of China (Grant No. U2241281), the Natural Science Foundation of Hunan Province, China (Grant No. 2022JJ30656), the Young Scientists Fund of the National Natural Science Foundation of Hunan Province, China (Grant No. 2021JJ40661), and the Research Programm of NUDT (Grant No. ZK 19-25).

† Corresponding author. E-mail: [weiquan.wang@nudt.edu.cn](mailto:weiquan.wang@nudt.edu.cn)

‡ Corresponding author. E-mail: [yyin@nudt.edu.cn](mailto:yyin@nudt.edu.cn)



## 基于深度学习的钻孔辐射压离子加速建模

张普渡 王伟权 李哲民 张资旋 王叶晨 周泓宇 银燕

## Modeling of ion accelerated by borehole radiation pressure based on deep learning

Zhang Pu-Du Wang Wei-Quan Li Zhe-Min Zhang Zi-Xuan Wang Ye-Chen Zhou Hong-Yu Yin Yan

引用信息 Citation: *Acta Physica Sinica*, 72, 184103 (2023) DOI: 10.7498/aps.72.20230702

在线阅读 View online: <https://doi.org/10.7498/aps.72.20230702>

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

#### 激光加速高能质子实验研究进展及新加速方案

Experimental progress of laser-driven high-energy proton acceleration and new acceleration schemes

物理学报. 2021, 70(8): 084102 <https://doi.org/10.7498/aps.70.20202115>

#### 基于物理信息神经网络的光斑质心计算

Calculation of spot centroid based on physical informed neural networks

物理学报. 2022, 71(20): 200601 <https://doi.org/10.7498/aps.71.20220670>

#### 识别Z玻色子喷注的卷积神经网络方法

Tag Z boson jets via convolutional neural networks

物理学报. 2021, 70(6): 061301 <https://doi.org/10.7498/aps.70.20201557>

#### 利用神经网络识别高分子链在表面的吸附相变

Recognition of adsorption phase transition of polymer on surface by neural network

物理学报. 2019, 68(20): 200701 <https://doi.org/10.7498/aps.68.20190643>

#### 基于深度学习的光学表面杂质检测

Deep-learning-assisted micro impurity detection on an optical surface

物理学报. 2021, 70(16): 168702 <https://doi.org/10.7498/aps.70.20210403>

#### 长短脉冲联合驱动双层结构靶优化伽马射线的产生

Gamma-ray generation optimized by long and short pulses jointly driving double-layer target

物理学报. 2022, 71(21): 215201 <https://doi.org/10.7498/aps.71.20212042>