



使用深度学习与核碰撞判断中子皮类型的尝试

黄宇靖¹, 庞龙刚^{1*}, 王新年^{2*}

1. 华中师范大学粒子物理研究所夸克与轻子教育部重点实验室, 武汉 430079;

2. 劳伦斯伯克利国家实验室核理论组, 伯克利 94720, 美国

*联系人, 庞龙刚, E-mail: lgpang@mail.ccnu.edu.cn; 王新年, E-mail: xnwang@lbl.gov

收稿日期: 2021-11-15; 接受日期: 2022-02-08; 网络出版日期: 2022-04-06

国家自然科学基金(编号: 11861131009, 12075098)资助项目

摘要 中子在原子核内的分布对确定中子皮厚度、原子核的对称能、致密核物质状态方程以及中子星质量半径关系都极为重要. 但提取中子在原子核内的分布异常困难. 理论上, 重原子核的多体量子从头算方法遭遇维数灾难. 实验上, 中子不带电, 不像电荷分布(质子分布)那样可以直接测量. 杰佛逊实验室的宇称破缺电子散射实验, 通过宇称破缺测量弱荷(中子)分布. 我们尝试从重离子碰撞的末态强子分布提取中子在原子核内的分布. 原则上, 质子和中子在原子核内的分布对应着核碰撞的初态涨落和关联, 这些信息经过碰撞后的相对论流体力学演化和强子输运会最终转化为末态强子在动量空间的关联. 如何建立核结构的初态涨落与末态关联之间的映射, 是利用重离子碰撞确定初态核结构的关键. 正向过程中, 我们从halo类型、skin类型以及无中子皮(noskin)三种不同的中子分布抽样²⁰⁸Pb原子核, 并使用相对论分子动力学模型SMASH进行halo-halo, skin-skin以及noskin-noskin三类核碰撞模拟, 得到末态强子的动量信息. 人工智能技术中的深度学习拥有非常强大的模式识别能力和在不同数据类型之间建立映射的能力. 我们使用点云神经网络和卷积神经网络, 分别根据抽样出的初态核子分布和碰撞后的末态强子分布, 判断²⁰⁸Pb原子核的中子皮类型. 因为涨落效应的存在, 深度学习使用初态核子的坐标仅可在halo和skin类型两分类任务中达到62%的分类精度. 使用末态强子的动量信息无法在统计误差范围内成功分类halo-halo和skin-skin两种类型的核碰撞. 但在三分类任务中, 使用末态强子信息, 分类准确度达到37.47%, 超过3万个测试样本三分类随机猜测准确度(33.3%)约4个百分点. 即人工神经网络虽然无法区分中子皮的种类, 但能以一定的概率从核碰撞末态确定²⁰⁸Pb原子核中是否存在中子皮. 如果筛选出超级擦边碰撞事件, 使用多样本混合的方法和参与碰撞粒子的电荷信息, 人工神经网络在halo-halo和skin-skin分类中拥有大约56%的分类精度.

关键词 深度学习, 核碰撞, 中子皮

PACS: 21.10.Gv, 25.70.-z, 25.75.-q, 84.35.+i, 05.60.Gg

1 引言

最近杰佛逊实验室的²⁰⁸Pb原子核半径实验PREX-

2, 使用纵向极化的电子轰击²⁰⁸Pb靶, 通过测量宇称破缺不对称因子 A_{PV} , 给出了目前最为精确的²⁰⁸Pb原子核中子皮厚度 $R_n - R_p = (0.283 \pm 0.071) \text{ fm}$ ^[1,2]. 精确

引用格式: 黄宇靖, 庞龙刚, 王新年. 使用深度学习与核碰撞判断中子皮类型的尝试. 中国科学: 物理学 力学 天文学, 2022, 52: 252011
Huang Y-J, Pang L-G, Wang X-N. Determining the neutron skin types using deep learning and nuclear collisions: An attempt (in Chinese). Sci Sin-Phys Mech Astron, 2022, 52: 252011, doi: [10.1360/SSPMA-2021-0318](https://doi.org/10.1360/SSPMA-2021-0318)

测量中子皮厚度能够有效约束对称能 $E_s(\rho)$ 的大小, 从而对原子核结构、同位旋非对称的高密核物质状态方程、中子星的质量半径关系、原初宇宙的核合成等不同学科分支都有很大促进作用. 使用新的测量数据, 中子皮厚度的信息被用来更新饱和密度附近的核物质状态方程^[3], 也可被用来验证中子皮厚度与 α 衰变^[4]和中子盈余 $(N - Z)$ ^[5]存在的联系.

中子在原子核内的分布可以导致两种类型的中子皮结构, halo类型和skin类型. Halo类型对应着中子盈余以弥散的方式存在于原子核大半径处, skin类型对应着中子盈余以密度半径增大的方式分布在原子核中. 使用反质子与边缘中子和边缘质子的湮灭, 实验发现假设质子和中子满足两参数费米分布, 且质子的分布等于实验测量到的电荷分布, 则丰中子原子核中的中子分布为halo类型^[6].

我们希望研究质子和中子在原子核内的分布如何影响重离子碰撞末态强子的分布, 通过重离子碰撞末态强子的分布是否能够反推初态核结构中中子皮的信息. 最近, 湖州师范大学和布鲁克海文国家实验室^[7,8], 以及德国法兰克福高等研究中心^[9], 分别提出中子皮的厚度可能影响同质异位素碰撞实验的手征磁效应信号. 但两个研究给出完全相反的结论, 后一个研究表明中子皮的厚度不会带来明显差异. 我们尝试使用人工智能的方法, 建立末态强子分布与初态核结构之间的映射. 使用实验上测量到的质子(电荷)分布抽样质子在 ^{208}Pb 原子核内的位置, 使用两种中子皮类型抽样中子在 ^{208}Pb 原子核内的分布, 作为对比, 另外按照电荷分布抽样一组中子在 ^{208}Pb 原子核内的位置. 使用法兰克福高等研究中心开发的SMASH相对论分子动力学模拟程序^[10], 我们得到两种不同中子皮类型的 ^{208}Pb 原子核在质心系能量为 $\sqrt{s_{NN}} = 2$ 和3 GeV碰撞下的末态强子分布, 以及一组没有中子皮时核碰撞的末态强子分布. 最后尝试从核碰撞末态强子分布反推初态核结构中的中子皮类型.

重离子碰撞是一个复杂的动力学演化过程, 它会将初态核子在原子核内的分布转化为末态强子在动量空间、同位旋空间的关联. 此关联可能帮助我们构建提取核子(尤其是中子)在原子核内分布的新方法. 但从初态到末态的转化过程中, 整个系统的熵在增加, 信息在减少, 最极端的情形是达到热平衡, 初态的大部分信息被抹掉. 如果初态核结构的信息在复杂的动力学

演化过程中幸存下来, 保留在末态强子的关联中, 则我们希望有一种方法, 可以把这些关联与初态的核结构做一个映射. 如果初态核结构的信息已经完全损失掉, 我们也希望有一种人工智能的方法探明这一点, 减少无用的人工搜索. 深度神经网络^[11-13]是目前最好的模式识别工具, 被广泛应用于物理学以及核物理的研究中, 更详细的信息请参考综述文章^[14-16]. 它能够在诸多不同领域数据之间建立非线性映射^[17]. 比如, 在图像与语义、文字之间, 在不同风格的图像或文字之间建立映射. 这种以自动发现模式来建立非线性映射的能力是做交叉学科研究最需要的功能. 将抽样出的 ^{208}Pb 原子核内的核子位置以及核碰撞末态强子分别作为点云神经网络的输入, 将中子皮类型作为神经网络的输出, 训练模型, 观察其是否能够判断中子皮的种类.

2 方法: 相对论分子动力学与深度学习

从核碰撞末态强子分布提取初态核结构是典型的反问题. 为了求解此反问题, 我们使用深度神经网络建立末态与初态的映射. 这属于深度学习(Deep Learning)中的监督学习范畴, 需要输入数据与明确的标签. 在我们的任务中, 神经网络的标签为halo类型、skin类型以及无中子皮的noskin类型. 神经网络的输入为: (1) 使用两种中子皮类型抽样出的 ^{208}Pb 原子核内核子的坐标和同位旋信息; (2) 分别使用一对halo-halo ^{208}Pb 原子核碰撞以及skin-skin ^{208}Pb 原子核碰撞得到的末态强子分布, 做中子皮种类的两分类预测. (3) 使用三种核碰撞的末态强子分布和标签, 做三分类预测.

2.1 抽样核碰撞初态 ^{208}Pb 原子核内核子分布

质子和中子在 ^{208}Pb 原子核内的径向分布近似表示为两参数费米分布,

$$\rho(r) = \frac{\rho_0}{\exp\left(\frac{r-r_0}{d}\right) + 1}, \quad (1)$$

其中, ρ_0 为归一化的核子密度, r_0 是半密度半径, d 为弥散因子. Skin和halo类型的中子皮对应两种不同的情形. Skin类型质子和中子的弥散因子相等 $d_p = d_n$, 质子的半密度半径小于中子 $r_{p0} < r_{n0}$. Halo类型质子和中子的半密度半径相等 $r_{p0} = r_{n0}$, 但质子的弥散

因子小于中子 $d_p < d_n$. 两种类型使用同样的质子密度归一化因子 $\rho_{p0} = 0.080 \text{ (fm}^{-3}\text{)}$ 和中子密度归一化因子 $\rho_{n0} = 0.063 \text{ (fm}^{-3}\text{)}$, 以及实验测量得到的质子(电荷)半密度半径和质子弥散因子. 这些参数的数值与JLAB实验测量结果保持一致 [1,2]. 作为对比, 我们构造了第三类无中子皮的noskin类型, 质子和中子都服从 ^{208}Pb 原子核内的电荷分布.

为了进行核碰撞模拟, 我们首先从两种中子皮类型和一种无中子皮设置下核子在 ^{208}Pb 原子核内的分布抽样. ^{208}Pb 原子核是双幻数核, 核子分布是比较完美的球形. 如果忽略两核子关联, 我们可以分别对质子和中子的径向坐标 r , 极角 θ 和方位角 ϕ 满足的概率分布抽样, 得到skin和halo两种分布下中子在 ^{208}Pb 原子核内的坐标:

$$r \sim P(r) = 4\pi r^2 \rho(r)/N, \quad r \in [0, \infty], \quad (2)$$

$$\theta \sim P(\theta) = \frac{\sin \theta}{2}, \quad \theta \in [0, \pi], \quad (3)$$

$$\phi \sim P(\phi) = \frac{1}{2\pi}, \quad \phi \in [0, 2\pi], \quad (4)$$

其中 N 是质子或中子个数. 径向坐标 $r \sim P(r)$ 的抽样使用舍选法, $\theta \sim P(\theta)$ 使用直接法抽样. 随机选取82个质子与分别满足三种分布的126个中子, 构成三组 ^{208}Pb 原子核.

如图1所示, 使用skin类型和halo类型抽样得到的中子, 其径向坐标的多事件统计分布与质子(电荷)分布的差异极小. Halo类型抽样得到的中子盈余更多聚集于大半径处, 对应两费米分布中更大的弥散因子.

三组 ^{208}Pb 原子核对应不同的初态核结构, 每一组入射粒子和靶粒子各抽样50000个, 放入SMASH相对论强子输运程序, 进行每对核子质心系能量 $\sqrt{s_{NN}} = 2 \text{ GeV}$ 的 $^{208}\text{Pb}+^{208}\text{Pb}$ 碰撞模拟, 得到skin类型、halo类型以及noskin类型的碰撞结果各50000组. 质心能量

表 1 两种中子皮类型以及一种无中子皮核子分布对应的参数

类型	r_{p0} (fm)	r_{n0} (fm)	d_{p0} (fm)	d_{n0} (fm)
Skin	6.70	6.84	0.56	0.56
Halo	6.70	6.70	0.56	0.63
Noskin	6.70	6.70	0.56	0.56

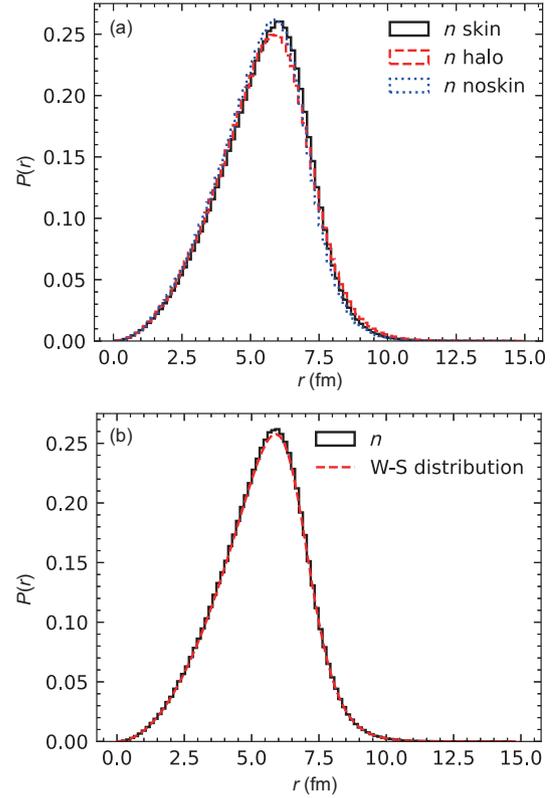


图 1 (网络版彩图) (a) 三种中子皮类型的 ^{208}Pb 原子核中子的抽样分布结果. 三种类型的质子分布都与noskin类型的中子分布保持一致. (b) Noskin类型的中子抽样结果与对应参数的核子分布函数比较

Figure 1 (Color online) (a) The distributions of sample neutrons for 3 different neutron-skin types of ^{208}Pb nucleus. The proton distributions in 3 cases are the same as the neutron distribution in noskin type. (b) The comparison between the distribution of sampled neutrons from noskin type and the corresponding nucleon distribution function.

$\sqrt{s_{NN}} = 3 \text{ GeV}$ 的 $^{208}\text{Pb}+^{208}\text{Pb}$ 碰撞各10000组. SMASH默认碰撞为对心碰撞. 我们另外生成碰撞参数范围为 $[0, 18] \text{ fm}$ 的150000个事件, 观察预测结果对中心度的依赖.

2.2 相对论分子动力学仿真程序SMASH

SMASH是德国法兰克福高等研究中心Hannah课题组 [10]开发的一款相对论分子动力学程序, 主要用来模拟高能核碰撞末态强子的共振散射和衰变, 以及低能核碰撞的整个动力学过程. SMASH使用C++语言开发, 遵循现代的代码开发规范, 使用版本管理系统, 拥有大量细致的单元测试和物理测试, 详细考虑了相

对论情况下大量粒子碰撞的因果律, 细致平衡条件, 并对比了模型中强子-强子散射截面与实验测量数据. SMASH模拟程序通过分子动力学的方法求解相对论玻尔兹曼方程, 主要包含自由飞行、弹性碰撞、衰变和共振态产生4个物理过程. 在SMASH中, 关闭核平均场且粒子未散射时, 粒子按之前的轨迹做匀速直线运动(自由飞行), 如果开启核平均场, 粒子的坐标和动量根据平均场势下的运动方程更新,

$$\frac{d\mathbf{r}_i}{dt} = \frac{\partial H_i}{\partial \mathbf{p}_i}, \quad \frac{d\mathbf{p}_i}{dt} = -\frac{\partial H_i}{\partial \mathbf{r}_i}, \quad (5)$$

其中 $H_i = \sqrt{p_i^2 + m_i^2} + U_i(r)$, $U_i(r)$ 为平均场势能. 一个共振态粒子, 在 Δt 的小时间区间内衰变的概率为

$$P(\text{decay in } \Delta t) = \frac{\Delta t}{\tau} = \Gamma(m)\Delta t, \quad (6)$$

其中 $\tau = \frac{1}{\Gamma(m)}$ 表示共振态粒子寿命, $\Gamma(m)$ 为质量依赖的衰变宽度. 据此关系, 可得到粒子在 t 时刻发生衰变的概率为

$$P(\text{decay at } t) = 1 - \exp(-\Gamma(m)t). \quad (7)$$

当粒子a与粒子b之间的横向距离小于相互作用距离时, 则发生一次碰撞,

$$d_{ab} < d_{\text{int}} = \sqrt{\frac{\sigma_{\text{total}}}{\pi}}, \quad (8)$$

其中, σ_{total} 为a与b之间的总的散射截面, d_{ab} 是相对论情形下a与b的横向距离:

$$d_{ab}^2 = (\mathbf{r}_a - \mathbf{r}_b)^2 - \frac{((\mathbf{r}_a - \mathbf{r}_b) \cdot (\mathbf{p}_a - \mathbf{p}_b))^2}{(\mathbf{p}_a - \mathbf{p}_b)^2}, \quad (9)$$

其中 \mathbf{r} 与 \mathbf{p} 分别为a和b在两者质心系中的坐标和动量.

SMASH有几种运行模式, 我们使用对撞模式从外部读入skin类型、halo类型和noskin类型 ^{208}Pb 原子核, 分别进行同种类型之间的 $^{208}\text{Pb}+^{208}\text{Pb}$ 碰撞模拟. 本研究忽略碰撞之前核子的费米动量以及平均场势能的影响, 保留了自由飞行、弹性碰撞、共振衰变与产生过程. 如果碰撞能量足够高, 还会激活强子之间的弦形成以及弦碎裂强子化的过程, 此过程调用Pythia程序库处理. 在这样的设置中, 碰撞前 ^{208}Pb 原子核中的核子横向动量为零, $(p_x, p_y) = (0, 0)$ GeV/c, 纵向动量分量 p_z 依赖于束流能量 $\sqrt{s_{NN}}$. 碰撞后横向动量为0的粒子被识别为旁观者, 未参与碰撞, 不进入最终的数据分析.

2.3 点云神经网络

点云神经网络一开始用于分析三维激光雷达扫描仪从物体表面扫描到的大量三维坐标数据. 我们发现这种网络架构天然适合分析高能核碰撞或粒子碰撞实验产生的数据, 这类数据的每个样本都包含大量强子在动量空间的坐标以及强子本身的量子数信息. 传统的卷积神经网络输入为图片, 将强子的动量 (p_x, p_y, p_z) 制备成三维分布图时信息非常稀疏, 也损失了精确的粒子动量信息. 而点云神经网络可直接处理多个粒子的动量构成的列表类数据. 本研究中点云网络的输入为每个事件粒子的动量信息列表, 内容包含 $(E, p_x, p_y, p_z, \text{charge}, \text{pid})$. 其中pid为强子的编码, 我们发现末态有5种不同的强子, 分别为 π^+ , π^- , π^0 , p , n . 使用one-hot编码, 将pid一列数据换成5列, 比如 π^+ 粒子表示为 $[1, 0, 0, 0, 0]$, 质子表示为 $[0, 0, 0, 1, 0]$, 特定强子对应的列标记为1, 其他列标记为0. 这是大数据分析的特定技巧. 每个事件末态粒子个数不同, 我们选取448作为最大粒子数, 数目小于此数的事件用0补齐缺少的粒子. 最后添加一列, 用1表示粒子为填充的补齐粒子, 0表示SMASH产生的粒子. 因此, 点云网络的每个输入样本相当于 448×11 个浮点数构成的矩阵. 当使用抽样出的 ^{208}Pb 原子核作为神经网络输入时, 每个样本相当于 208×4 个浮点数构成的矩阵. 其中, 208表示 ^{208}Pb 原子核中核子的个数, 每个核子拥有 (x, y, z) 三维坐标和同位旋信息.

点云神经网络的第一部分是一个全连接网络, 将每个粒子的11个特征转化为潜变量空间的高维特征. 我们尝试过(11, 256, 128×8)架构, 表示第一隐藏层256个神经元, 后接8个128神经元的隐藏层, 这种架构将每个粒子的11个特征转化为潜变量空间的128个特征. 另一种是(11, 32×8)架构, 将每个粒子的11个特征转化为潜变量空间的32个特征. 这两种架构并未带来最终分类准确度的显著区别. 此网络被所有粒子共享, 因此也称一维卷积. 在这一步, 一个事件中的每个粒子相当于被独立地变换到高维潜变量空间, 尚不具备粒子-粒子之间的关联. 使用末态强子的动量信息时, 我们使用深度学习中的全局最大池化技术, 计算所有粒子高维潜变量沿每个维度的最大值. 对于128维潜变量, 得到每个事件128个浮点数, 表示粒子-粒子之间的长程关联. 接下来, 这些潜变量的均值(或最大

值)被送入另一个全连接网络(32, 32, n), 在两分类任务中, 有 $n=2$ 个输出神经元, 分别表示中子皮为skin类型或halo类型的概率. 在三分类任务中, 有 $n=3$ 个输出神经元, 分别表示skin类型、halo类型和无中子皮类型的概率. 注意, 输出层使用softmax激活函数而其他层都使用relu激活函数. 为了使得学习到的函数空间收敛, 拥有较好的泛化能力, 每一层网络后面都加入了批量归一化层(Batch Normalization Layer). 训练时使用Adam^[18]优化器对神经网络参数进行更新, 它集成了适配学习率和动量机制两者的优点, 是深度学习领域最流行的优化器.

3 结果与讨论

3.1 Prex-2对中子皮类型的预测

反质子湮灭实验的文章里定义了一个halo因子的等效表达式, 该式与定义的误差不超过10%–15%^[6], 形式如下:

$$f_{\text{halo}} = \frac{Z \rho_n}{N \rho_p}, \quad (10)$$

其中 Z 和 N 为质子数和中子数, ρ_p 和 ρ_n 为质子密度和中子密度. 此halo因子对质子和中子在²⁰⁸Pb原子核内的分布比较敏感. 使用PREX-2的最新实验结果, 我们计算了halo因子的数值, 并与两费米子分布给出的skin与halo类型中子皮的halo因子理论预言进行对比. 如图2所示, 在径向半径 r 较大的区域, skin, halo类型的曲线有明显区别, halo类型曲线上升速度远快于skin类型曲线, 而使用PREX-2实验结果计算得到的halo因子曲线更接近于halo类型曲线. 这表明²⁰⁸Pb原子核中的中子分布会更接近于halo类型.

3.2 深度神经网络的分类结果

如果使用抽样得到的²⁰⁸Pb原子核内中子和质子的三维坐标信息以及它们的同位旋信息预测中子皮类型, 我们得到图3(a)的训练精度和验证精度变化曲线, 精度最高分别达到63%和62%. 图3(b)是随机选取10个²⁰⁸Pb原子核, 将他们所有核子信息组合成一个新的数据样本, 每个样本包含820个质子和1260个中子, 然后放入点云神经网络, 训练和验证的最终精度都达到73%. 图3(c)是随机选取100个²⁰⁸Pb原子核组合成

一个新数据样本放入卷积神经网络训练的结果, 最终训练和验证精度分别达到96%和90%. 可以看到, 随着每组数据包含的核子数增加, 神经网络的分类精度会提高. 多样本组合的方法减小了涨落效应对单次抽样结果的影响,

如果使用两个不同束流能量下SMASH仿真得到的强子, 并去掉其中未参与碰撞的旁观者, 训练上述点云神经网络, 对skin-skin和halo-halo中子皮类型做两分类, 则预测准确度总在50%附近, 统计误差之内可以判定神经网络并没有学到从末态到初态中子皮类型的映射关系. 为了防止神经网络的表示能力不够, 我们也尝试了另一种在喷注分类任务以及临界现象寻找任务中表现出很强分类能力的动态图神经网络^[19,20], 并应用之前能够提高预测精度的多样本组合方法, 均未表现出对不同中子皮类型的分辨能力. 虽然我们怀着很好的预期, 希望深度神经网络强大的模式识别能力和非线性映射能力能够帮助建立核碰撞末态强子分布与初态核结构的映射, 但数据科学中有一句名言: “如果魔术师的帽子中没有兔子, 则我们不可能从中抓出一只兔子.” 虽然中子皮的信息存在初态核结构中, 我们构造的点云神经网络也的确能从抽样出的铅原子核内质子和中子的位置坐标出发, 以62%的准确度区分碰撞初态单个²⁰⁸Pb原子核的中子皮类型, 但质子和中子在位置空间的分布向动量空间转化时, ²⁰⁸Pb+²⁰⁸Pb碰

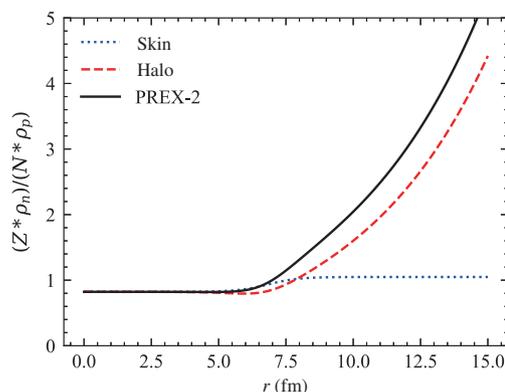


图2 (网络版彩图)使用PREX-2实验测量数据计算出的halo因子(黑色实线)与两参数费米分布预测的halo类型(红色虚线)和skin类型(蓝色点线)中子皮对应的halo因子

Figure 2 (Color online) The halo factor calculated using data measured at PREX-2 experiment (black solid line), as compared with that from halo type neutron distribution (red dashed line) and skin type neutron distribution (blue dotted line).

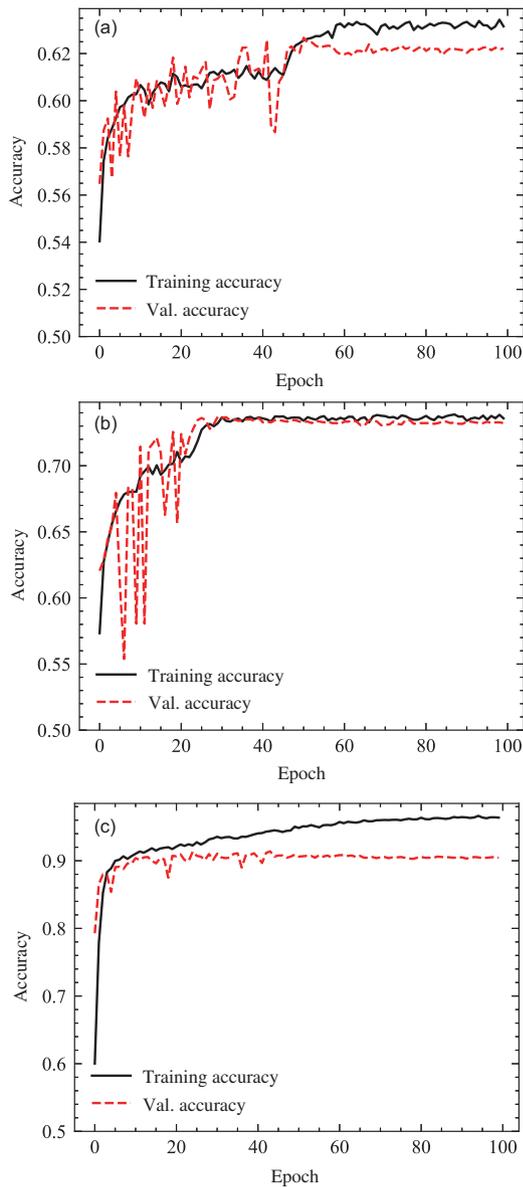


图3 (网络版彩图)使用skin和halo两种中子皮类型抽样得到的 ^{208}Pb 原子核作为神经网络的输入,得到的单样本分类准确度(a), 10个混合样本的分类准确度(b)和100个混合样本的分类准确度(c). (a), (b)样本使用点云神经网络训练, (c)样本使用卷积神经网络训练. 黑色实线对应训练准确度, 红色虚线对应验证准确度

Figure 3 (Color online) The binary classification accuracy of the neural network for ^{208}Pb nucleus sampled from the skin and the halo neutron-skin types, for (a) a single sample, (b) 10 mixed samples, and (c) 100 mixed samples. (a) and (b) use point cloud network, while (c) uses convolution neural network. The solid-black lines correspond to the training accuracy and the red-dashed lines correspond to validation accuracy.

撞复杂的动力学过程可能完全消灭了初态的微小差异. 初态的多样本混合可以增大分类成功率, 但末态的

多样本混合并没有增加分类成功率. 这也表明末态信号非常微弱. 在使用深度神经网络尝试之前, 我们并不能以人力方式确认物理信号是否在复杂的动力学演化过程中幸存, 并编码在末态强子中. 很多时候大家都希望深度神经网络能够成功分类, 从数据中发现物理信号, 而忽略了它的一个重要功能, 即它可以在监督学习任务中, 以试图建立映射的方式自动搜索物理信号是否存在于数据中, 来验证“魔术师的帽子中是否有兔子”. 如果这种使用监督学习自动化搜索物理信号的尝试失败, 则说明要么物理信号非常微弱, 超出了使用的深度神经网络架构所拥有的表示能力, 要么物理信号在动力学演化过程中因为熵的增加, 信息的减少而湮灭.

使用同样的点云神经网络和末态强子信息, 对中心碰撞中skin-skin, halo-halo以及noskin-noskin $^{208}\text{Pb}+^{208}\text{Pb}$ 碰撞做三分类预测, 使用12万个样本做训练与验证, 使用30000个样本做测试, 得到测试样本上37.47%的预测准确度. 对于三分类任务, 神经网络随机预测的准确度为33.3%, 30000个测试样本对应统计误差相对值为0.6%. 三分类预测准确度高于随机预测约4个百分点. 虽然点云网络无法通过 $^{208}\text{Pb}+^{208}\text{Pb}$ 碰撞末态强子信息区分skin和halo两种中子皮类型, 但能够以一定的准确度通过末态强子信息确定初态原子核中是否存在中子皮. 如表1所示, noskin设置下中子密度半径等于质子, 对应的原子核半径小于skin和halo两种情形. 在对心碰撞中, 神经网络能够捕获此差异.

一种验证末态粒子中是否存在中子皮信号的极限方法是考虑超级擦边碰撞. 假设中子皮厚度存在微小差异, 超级擦边碰撞中参与碰撞的中子数可能多于质子数. 图4统计了末态粒子个数小于10的事件中, 带电粒子占比的事件数分布. 可以看到, 对于三种不同的中子分布, 末态粒子中带电粒子占比的分布会有区别. 带电粒子占比为0.5的区域halo类型碰撞事件多, 而带电粒子占比小于0.1的区域skin类型碰撞事件多. 如果选取超级偏心碰撞产生的末态粒子, 深度神经网络可能会表现出一定的预测能力.

如果使用碰撞参数 b 取值区间为 $[0, 18]$ fm的所有碰撞事件训练, 对于skin和halo两种中子皮类型的碰撞结果, 神经网络未表现出明显的识别能力. 图4启发我们筛选超级偏心碰撞事件, 只使用参与碰撞粒子数小于10的事件. 这种事件两种类型各有9200个左右, 我们

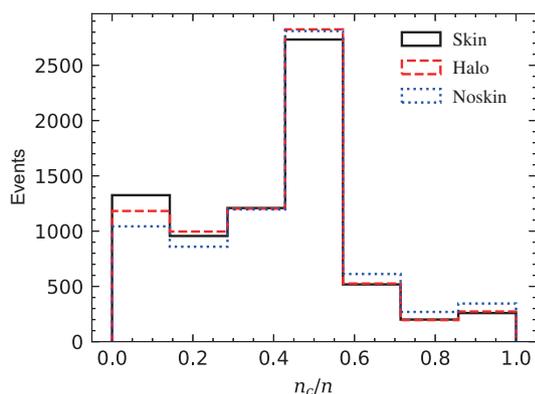


图 4 (网络版彩图)三种中子皮类型在偏心碰撞条件下(末态粒子数小于10的事件)带电粒子占比的事件数分布. 黑色实线对应skin类型, 红色虚线对应halo类型, 蓝色点线对应无中子皮情形

Figure 4 (Color online) The ratio of charged particles for ultra peripheral collisions (total multiplicity smaller than 10), with 3 different neutron distributions, skin-type (black solid line), halo-type (red dashed line) and noskin-type (blue dotted line).

把9200个事件分为三份, 分别用来随机产生训练、验证和测试样本, 划分比例分别为70%, 15%和15%. 对每组样本, 随机不放回抽取50个事件组成一个新数据样

致谢 感谢专题的组织者李庆峰老师. 庞龙刚感谢华为科技公司对前沿交叉学科研究的支持.

参考文献

- Adhikari D, Albatineh H, Androic D. Accurate determination of the neutron skin thickness of ^{208}Pb through parity-violation in electron scattering. *Phys Rev Lett*, 2021, 126: 172502
- Piekarewicz J. Implications of PREX-2 on the electric dipole polarizability of neutron-rich nuclei. *Phys Rev C*, 2021, 104: 024329
- Behera D, Tripathy S K, Routray T R. Nuclear symmetry energy and neutron skin thickness of ^{208}Pb using a finite range effective interaction. *Phys Scr*, 2020, 95: 105301
- Ni D, Ren Z. Effects of differences between neutron and proton density distributions on α -decay half-lives. *Phys Rev C*, 2015, 92: 054322
- Zhang J T, Tu X L, Sarriguren P. Systematic trends of neutron skin thickness versus relative neutron excess. *Phys Rev C*, 2021, 104: 034303
- Trzcińska A, Jastrzębski J, Lubiński P. Neutron density distributions deduced from antiprotonic atoms. *Phys Rev Lett*, 2001, 87: 082501
- Xu H, Li H, Wang X. Determine the neutron skin type by relativistic isobaric collisions. *Phys Lett B*, 2021, 819: 136453
- Xu H, Li H, Zhou Y. Measuring neutron skin by grazing isobaric collisions. *Phys Rev C*, 2022, 105: L011901
- Hammelmann J, Soto-Ontoso A, Alvioli M. Influence of the neutron-skin effect on nuclear isobar collisions at energies available at the BNL Relativistic Heavy Ion Collider. *Phys Rev C*, 2020, 101: 061901
- Weil J, Steinberg V, Staudenmaier J. Particle production and equilibrium properties within a new hadron transport approach for heavy-ion collisions. *Phys Rev C*, 2016, 94: 054905
- LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521: 436–444
- Schmidhuber J. Deep learning in neural networks: An overview. *Neural Networks*, 2015, 61: 85–117
- Goodfellow I, Bengio Y, Courville A. Deep Learning. Cambridge: MIT Press, 2016
- Albertsson K, Altoe P, Anderson D. Machine learning in high energy physics community white paper. *J Phys-Conf Ser*, 2018, 1085: 022008
- Carleo G, Cirac I, Cranmer K. Machine learning and the physical sciences. *Rev Mod Phys*, 2019, 91: 045002

本, 只使用新样本的电荷信息, 放入神经网络进行分类. 训练和验证精度分别达到57%和56%.

4 总结与展望

我们尝试使用深度学习与核碰撞仿真从重离子碰撞末态强子分布反推初态核结构中的中子皮类型信息. 在 $\sqrt{s_{NN}} = 2$ 和 3 GeV 碰撞能量下, 使用末态强子的动量信息, 点云神经网络并未在 skin-skin 和 halo-halo 两分类任务中表现出明显的判断能力. 但是, 在三分类任务中, 点云神经网络表示出对有中子皮和无中子皮 $^{208}\text{Pb}+^{208}\text{Pb}$ 碰撞的部分识别能力. 将抽样出的初态原子核作为输入, 使用质子和中子的坐标信息, 点云神经网络能够以62%的准确度判断出中子皮类型. 如果筛选出擦边碰撞事件, 使用末态粒子的电荷信息和多样本混合技术, 神经网络可以达到56%的分类精度. 本研究表明, 如果存在信号的样本个数远小于总的样本个数, 神经网络的自动模式识别能力极有可能失效. 基于物理分析, 事先筛选出信号可能存在的区域, 并使用多样本混合技术, 会帮助机器学习的训练.

- 16 Bedaque P, Boehnlein A, Cromaz M. A.I. for nuclear physics. *Eur Phys J A*, 2021, 57: 100
- 17 Hornik K. Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 1991, 4: 251–257
- 18 Kingma D P, Ba J. Adam: A method for stochastic optimization. arXiv: [1412.6980](https://arxiv.org/abs/1412.6980)
- 19 Qu H, Gouskos L. Jet tagging via particle clouds. *Phys Rev D*, 2020, 101: 056019
- 20 Huang Y, Pang L G, Luo X. Probing criticality with deep learning in relativistic heavy-ion collisions. *Phys Lett B*, 2022, 827: 137001

Determining the neutron skin types using deep learning and nuclear collisions: An attempt

HUANG Yu-Jing¹, PANG Long-Gang^{1*} & WANG Xin-Nian^{2*}

¹*Institute of Particle Physics and Key Laboratory of Quark and Lepton Physics (MOE), Central China Normal University, Wuhan 430079, China;*

²*Nuclear Science Division, Lawrence Berkeley National Laboratory, Berkeley 94720, USA*

The distribution of neutrons inside the nucleus is essential for determining the neutron skin thickness, symmetry energy, equation of state of dense nuclear matter, and the mass-radius relationship of neutron stars. However, obtaining the neutron distribution is extremely challenging. Theoretically, the quantum many-body *ab-initio* calculations of heavy nucleus suffer the curse of dimensionality. Experimentally, measuring neutrons is not as easy as protons because protons explicitly carry electric charges. Parity violating electron scattering experiment at Jefferson laboratory determines the neutron distribution through the weak charge distribution. We tried to extract the neutron distribution inside the nucleus from the final state hadrons of heavy ion collisions. In principle, the proton and neutron distributions inside the nucleus correspond to the initial state fluctuations and correlations. The initial state fluctuations are converted to correlations of the final state hadrons in momentum space. Mapping the final state to the initial state is the key to determining nuclear structure from heavy ion collision. We sampled ²⁰⁸Pb nucleons from halo-type, skin-type, and no-neutron-skin distributions and performed halo-halo, skin-skin, and noskin-noskin heavy-ion-collision simulations using the relativistic molecular dynamics program SMASH. Artificial intelligence and deep neural networks have powerful pattern recognition abilities, which can map data from two different domains. Using a point cloud network and convolutional neural network, we classified the neutron skin types using the initially sampled nuclei and final state hadrons after the collision. Because of the strong fluctuations from Monte Carlo sampling, the deep neural network only attained 62% prediction accuracy on the initial state. It failed to predict the neutron skin types using the final state hadrons. However, the network achieved a prediction accuracy of 37.47% on the 3-types classification, which was 4% higher than the random-guess accuracy of 33.3% with 30000 testing samples. This study shows that the network might not determine the neutron skin types from the final state hadrons. However, it can identify whether there is a neutron skin using the final state hadrons with non-zero probability. If ultraperipheral collisions are selected, the network can classify the halo-halo and skin-skin types with a testing accuracy of 56%, using the charge information and multi-event mixing method.

deep learning, nuclear collisions, neutron skin

PACS: 21.10.Gv, 25.70.-z, 25.75.-q, 84.35.+i, 05.60.Gg

doi: [10.1360/SSPMA-2021-0318](https://doi.org/10.1360/SSPMA-2021-0318)