

核物理主题数据: 实验、理论与应用专题

基于机器学习的原子核质量表探究*

刘亚琪¹⁾²⁾³⁾ 李志龙²⁾⁴⁾ 王永佳^{2)†} 李庆峰^{2)‡} 马春旺¹⁾³⁾

1) (河南师范大学物理学院, 新乡 453007)

2) (湖州师范学院理学院, 湖州 313000)

3) (河南省科学院, 核科学与技术研究所, 郑州 450046)

4) (中国原子能科学研究院, 北京 102413)

(2025年11月9日收到; 2025年12月4日收到修改稿)

原子核质量作为原子核的基本物理量之一, 对理解和研究原子核结构与核反应、核子-核子基本相互作用等有重要作用, 但是精确预测远离 β 稳定线的原子核质量依旧是一个巨大挑战. 本文基于机器学习优化的原子核质量表, 研究了自2022年以来新测量的原子核质量、剩余质子-中子相互作用(δV_{pn})和重核 α 衰变能. 研究表明: 1) 对于23个新测量原子核, 经机器学习优化后的质量表给出的均方根偏差在0.51—0.58 MeV之间, 远低于液滴模型(LDM)、Weizsäcker-Skyrme-4 (WS4)、有限力程小液滴模型(FRDM)、Duflo-Zucker (DZ) 质量表所给出的3.275, 1.058, 0.752, 0.785 MeV; 2) 机器学习优化后的质量表给出的 $N = Z$ 时原子核的 δV_{pn} 与最新的实验数据相符合; 3) 通过机器学习优化的原子核质量表计算得到的重核 α 衰变能的均方根偏差也大幅降低. 此外, 利用贝叶斯模型平均对四种机器学习优化后的质量模型进行加权平均, 可以得到更精确的预测. 这些结果表明, 经过机器学习方法优化后的原子核质量表具有良好的外推能力, 可以为相关研究提供有益的参考. 本文数据集可在<https://doi.org/10.57760/sciencedb.j00213.00246>中访问获取.

关键词: 机器学习, 原子核质量, 剩余质子-中子相互作用, α 衰变能

DOI: 10.7498/aps.75.20251526

CSTR: 32037.14.aps.75.20251526

1 引言

机器学习作为一种高效的数据处理和分析技术手段, 不仅正在改变人类的生产生活方式, 也影响了包括物理学在内的许多科学研究领域, 使数据驱动的科学成为继实验、理论、计算之后的第四种科学研究范式. 得益于机器学习对大量、复杂、高维度、深度关联数据的处理和分析能力, 它与核物理、核数据的交叉融合已经产生了许多有价值的研究成果^[1-9]. 如在核结构研究方面, 机器学习

方法被广泛应用于研究原子核质量^[10-16]、中子皮厚度^[17,18]和电荷半径^[19-23]、原子核能级^[24-26]; 在核衰变与反应研究领域, 机器学习方法被广泛地应用于研究原子核的半衰期^[27-31]、核物质相变^[32-34]、重离子熔合截面^[35,36]、裂变产额与放射性核素迁移^[37-39]、炮弹碎裂反应截面^[40]以及散裂反应截面^[41]等.

质量是原子核最基本的性质, 在研究原子核结构与核反应、核子-核子相互作用、核衰变与裂变过程以及超重核的合成与探测等方面具有重要意义. 由于原子核是由大量强相互作用核子构成的复杂

* 国家重点基础研究发展计划 (批准号: 2023YFA1606402)、国家自然科学基金 (批准号: 12335008, 12375123) 和河南省自然科学基金 (批准号: 242300421048) 资助的课题.

† 通信作者. E-mail: wangyongjia@zjhu.edu.cn

‡ 通信作者. E-mail: liqf@zjhu.edu.cn

量子多体系统,且核子间存在显著的关联效应,因此精确预测原子核质量尤其是远离 β 稳定线的原子核仍面临重大挑战.原子核质量模型一般可以分为两类:全局型和局域型.局域型质量公式考虑了相邻核素质量之间的特殊关系,以简洁的代数形式抵消核子间的相互作用,从而实现对某些原子核的质量进行预测^[42].全局型质量模型又可进一步细分为宏观模型、宏观-微观模型和微观模型.宏观-微观模型一般是由著名的Bethe-Weizsäcker(BW)核质量公式,通过引入各种微观修正发展而来,例如有限力程小液滴模型(FRDM)^[43]、Duflo-Zuker(DZ)模型^[44]和Weizsäcker-Skyrme(WS)模型^[45]等.常见的微观模型包括基于密度泛函理论的相对论平均场模型(relativistic mean-field model, RMF)^[46,47]、Skyrme-Hartree-Fock-Bogoliubov模型^[48]、Gogny-Hartree-Fock-Bogoliubov模型^[49]、形变相对论连续谱(deformed relativistic Hartree-Bogoliubov theory in continuum, DRHBc)理论模型^[50]等.基于第一性原理的微观计算目前只能对质量数较小的原子核进行可靠探究,而其他基于各类有效理论的计算往往依赖于模型参数的选取,因此十分有必要发展高精度的原子核质量计算方法.

目前已有近3000种核素的质量被测量,这些数据为构建基于机器学习的原子核质量表奠定了基础^[51-54].文献^[55]中利用AME2016^[56]给出的 ^{16}O — ^{270}Ds 之间2408个原子核质量作为训练集(占比80%)和测试集(占比20%),考虑了质子数、中子数、离最近幻数的距离等10个特征量,使用轻量梯度提升机方法(light gradient boosting machine, LightGBM)对质子数和中子数均大于8的原子核的质量表进行了优化,结果表明液滴模型(liquid-drop model, LDM)、Duflo-Zuker(DZ)模型、Weizsäcker-Skyrme-4模型(WS4)和有限力程小液滴模型(finite range droplet model, FRDM)四种模型在测试集上的预测值与实验值的均方根偏差(root mean square deviation, RMSD)分别为0.234, 0.213, 0.170和0.222 MeV,相比于修正前质量模型的RMSD值分别降低了约90%, 65%, 40%和60%^[55].

从2022年到2025年有20多个新的原子核质量被测量,这可以进一步检验机器学习优化后的原子核质量表的可靠性.超重核是当前核物理领域研究的热点课题之一, α 衰变是鉴别超重核的一个重

要手段.近年来,随着一系列重核与超重核 α 衰变能(Q_α)实验数据的积累,基于机器学习方法,如径向基函数(radial basis function, RBF)^[30]和极限梯度提升算法(extreme gradient boosting, XGBoost)^[57]预测的 Q_α 值,为系统评估各类原子核质量表的可靠性提供了新的检验手段.除此之外,剩余质子-中子相互作用(δV_{pn})描述了原子核与相邻原子核结合能之间的关系^[58],这与原子核的质量密不可分,同时也是检验机器学习优化的原子核质量表的一个重要手段.为了验证机器学习方法的可靠性以及外推的可行性,本文研究机器学习算法在预测最新测量的原子核的质量、剩余质子-中子相互作用以及 α 衰变能方面的可靠性.

2 方法

2.1 机器学习算法

LightGBM(轻量梯度提升机, light gradient boosting machine)是一种基于直方图思想的决策树算法,它对传统的梯度提升决策树(gradient boosting decision tree, GBDT)算法进行了多项改进并优化.与GBDT使用低效的按层生长(level-wise)的决策树生长策略不同,LightGBM使用了带有深度的按叶子生长(leaf-wise)算法,在分裂次数相同的情况下,leaf-wise可以降低误差,得到更好的精度.LightGBM使用基于直方图的决策树算法,将特征的连续值离散化为固定区间,这种方式不仅提高了计算效率,而且减少了内存的使用.为了防止过拟合,LightGBM提供了L1和L2正则化,允许用户通过调整正则化项来平衡模型的复杂度和拟合效果.与此同时LightGBM支持多线程并行计算,并且能够进行分布式训练,高效的特征分裂使其不需要对所有特征的所有可能的分裂点进行穷举,而是选择最优的分裂点,特别适用于大规模数据集.这些优点使得LightGBM具有更高的精确度、更快的计算速度和处理大规模数据的能力.在“梯度提升”过程中,模型每次迭代时预测的目标是前一次迭代结果与最终目标之间的残差.该算法适用于各种类型的特征量,并具备运行速度快、可解释性强等优点.

通过使用LightGBM来训练实验结合能与理论模型给出的结合能的残差 $\delta(Z, A)$,从而对结合能进行预测.残差的公式表示为 $\delta(Z, A) = B_{\text{th}}(Z, A) -$

$B_{\text{exp}}(Z, A)$, B_{th} 表示模型理论值, B_{exp} 表示实验值. 使用的四种模型分别是 LDM, DZ, WS4, 以及 FRDM, 机器学习预测的未知原子核的结合能可以通过 $B_{\text{LightGBM}}(Z, A) = B_{\text{th}}(Z, A) - \delta(Z, A)$ 获得. 此外, 本文还使用贝叶斯模型平均 (Bayesian model averaging, BMA) 对四种机器学习优化后的质量模型进行加权, 给出 BMA 预测值. BMA 是一种通过贝叶斯推理结合多个模型来进行预测的技术. 它通过对所有候选模型进行加权平均, 以得到最终的预测结果, 从而减少单个模型可能带来的误差. 具体步骤是通过贝叶斯定理计算每个模型的后验概率来确定每个模型的权重, 并将这些模型的预测结果按照这些权重加权平均, 从而得到一个更为准确的预测. 该算法适用于多模型集成学习和回归分析, 具有减小过拟合、提高稳定性和适应性强的优点. 关于 BMA 的详细介绍可见文献 [59,60].

2.2 数据及输入特征

本文采用 AME2016 中 ^{16}O 和 ^{270}Ds 之间的 2408 个原子核的结合能用作训练集和 AME2020 新增 66 个结合能作为测试数据集, 所使用的 α 衰变能来自文献 [11,61]. 本文选用的 10 个输入特征量分别是质量数 A 、质子数 Z 、中子数 N 、中子质子之比 N/Z 、LDM 给出的理论值 B_{LDM} 、对效应的依赖性 $N_{\text{pair}} = 0, 1, 2$ (奇奇核, 奇偶核, 偶偶核)、最后一个质子壳层 $Z_m = 1, 2, \dots (8 \leq Z < 20, 20 \leq Z < 28, \dots)$ 、最后一个中子壳层 $N_m = 1, 2, \dots (8 \leq N < 20, 20 \leq N < 28, \dots)$ 、质子数与最近的幻数之间的距离 $|Z - m| (m \in \{8, 20, 28, 50, 82, 126\})$ 、中子数与最近的幻数之间的距离 $|N - m| (m \in \{8, 20, 28, 50, 82, 126\})$. 为确保模型评估的稳定性与有效性, 对模型的关键超参数进行了系统配置, 详见表 1, 模型中的其他超参数对模型性能影响较小, 因此均采用默认设置. 随机选择 AME2016 中 80% 的原子核数据作为训练集, 并对四种质量模型进行优化后, 给出未知核素的质量, 相关数据可见文献 [55] 的附件. BMA 则通过贝叶斯定理计算每个模型的后验概率, 并将这些模型的预测结果按照这些权重加权平均, 从而得到一个更为准确的预测. 文献 [62] 中使用了 BMA 对有限力程小液滴模型 2012 (FRDM12) 和 Hartree-Fock-Bogoliubov-31 (HFB-31) 质量模型进行加权, 得到了精度更高的质量表.

表 1 LightGBM 超参数配置

| 参数 | 描述 | 数值 |
|-----------------------|-------------------|-------|
| num_leaves | 每颗树最大叶子数 | 10 |
| min_data_in_leaf | 每个叶子中数据点的最小数量 | 20 |
| max_depth | 每棵树最大深度 (-1表示无限制) | -1 |
| learning_rate | 学习率 | 0.1 |
| lambda_l1 | l1正则化项 | 0.1 |
| num_boost_round | 提升迭代次数(树的数量) | 20000 |
| verbose_eval | 训练过程中日志记录频率 | 50 |
| early_stopping_rounds | 无改进的回合提前停止 | 100 |

本文采用均方根偏差来评价质量表与实验数据的符合程度, 计算方法由下式给出:

$$\sqrt{\sigma^2} = \sqrt{\frac{1}{\tilde{n}} \sum_{p=1}^{\tilde{n}} (Q^{\text{Expt},p} - Q^{\text{Theo},p})^2}, \quad (1)$$

其中 $Q^{\text{Expt},p}$ 为实验值, $Q^{\text{Theo},p}$ 为理论值.

3 结果与讨论

3.1 对新测量原子核质量的预测能力

自 2022 年以来, 实验上新测量了 23 个原子核的质量. 利用机器学习优化后的质量表计算得到的结合能与实验值的偏差展示在图 1 中. 图 1 表明, 23 个原子核在不同模型下经过机器学习修正后有不同程度的改进, 例如 LDM 中 ^{95}Ag 与 ^{152}La , DZ 中 ^{155}Ce 与 ^{154}Pr , WS4 中 ^{31}Ar 与 ^{152}Ce 以及 FRDM 中 ^{37}Sc 与 ^{30}F , 相比机器学习优化前, 优化后的原子核结合能大幅度靠近实验值, 特别是 ^{95}Ag , ^{152}La 和 ^{37}Sc , 机器学习修正后相比于修正前与实验值之差分别降低了 97.5%, 98.4% 和 99.0%. 其中 ^{95}Ag 位于接近 $N = Z = 50$ 的双幻数邻域, 该区域附近的核素靠近质子滴线并呈现 $N \approx Z$ 的特征, 其能级结构对核力的微妙平衡高度敏感, 因此更容易显现纯粹的量子壳结构效应. 对接近 $Z = N = 50$ 双幻数区域的核进行研究, 不仅有助于检验壳层闭合在极端同位旋不对称条件下的鲁棒性, 并理解其带来的结合能强化效应, 也能够深化对核壳结构起源的理解. 尤其重要的是, 这一类核的数据对于验证与发展核模型中的“壳效应”至关重要, 为进一步构建精确的原子核质量模型提供了关键的理论与实验依据 [63]. 以液滴模型为例, 传统的液滴模型仅包

含体积能、表面能、库仑能和配对能,并不包含壳效应. 在本文的机器学习研究过程中加入了一些与壳效应有关的物理量,如质子数与最近的幻数之差 v_p 、中子数与最近的幻数之差 v_n ,对预测原子核结合能具有良好作用. 还可以看到,利用 LightGBM 优化后 LDM, DZ, WS4, FRDM 的质量表给出的 RMSD 分别为 0.570, 0.558, 0.581, 0.512 MeV, 低于优化之前给出的 3.275, 1.058, 0.752, 0.785 MeV. 表明机器学习优化后的质量表在预测未知核区核素质量时仍然有较高的可靠性. 此外,还可以看到,这些 RMSD 值都大于我们在文献 [55] 中的研究结果,这是由于本文研究的原子核比先前研究的原子核更远离训练集. 为进一步评估性能,本研究采用 BMA 方法集成四种机器优化模型, RMSD 降低至 0.468 MeV. 该值优于集成学习与模型平均 (ensemble learning and model averaging, ELMA) [64]、序列最小二乘法 (sequential least squares programming, SLSQP) [65] 和贝叶斯神经网络 (Bayesian

neuron network, BNN) [52] 等现有方法的结果,验证了本文机器学习算法具有很强的泛化能力,相关数据见表 2.

3.2 剩余质子-中子相互作用 δV_{pn}

剩余质子-中子相互作用在原子核中起着至关重要的作用,显著影响着原子核的结合能、能级结构、核形状以及核反应过程等. 具体而言,这种相互作用决定了原子核的稳定性、激发态与基态的分布,以及核反应中的截面和产物分布. 研究 δV_{pn} 对于改进核结构模型 (如核壳模型和集体模型)、理解恒星中的核合成过程等具有重要的科学意义 [76]. 剩余质子-中子相互作用为相邻四个原子核结合能之间的双重差分,可以写为 [58]

$$\delta V_{pn}^{ee}(Z, N) = \frac{1}{4}[B(Z, N) - B(Z, N - 2) - B(Z - 2, N) + B(Z - 2, N - 2)]. \quad (2)$$

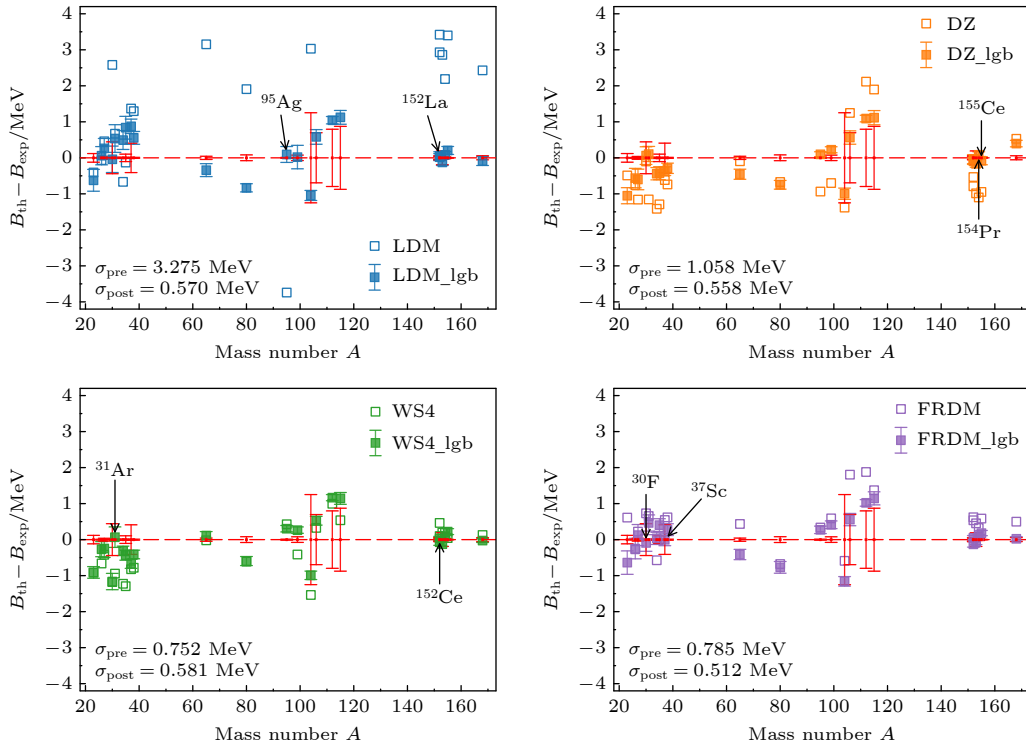


图 1 23 个新测量核素的结合能理论值与实验值之差. 红色误差棒表示实验值误差,空心正方形代表 4 种质量模型的结果与实验值之差,实心正方形代表 LightGBM 优化后的 4 种质量模型结果与实验值之差; σ_{pre} 和 σ_{post} 分别表示原始质量模型以及 LightGBM 优化后的理论值与实验值之间的 RMSD

Fig. 1. Difference between the theoretical and the experimental binding energies (red horizontal line) obtained using the LDM, DZ, WS4, and FRDM (open squares) and LightGBM-refined mass models (solid squares). The results show the differences between the theoretical values and the experimental values of the binding energies of 23 newly measured nuclides. σ_{pre} and σ_{post} denote the RMSD of the original and LightGBM-refined mass models on the newly measured nuclei, respectively. The error of the predictions obtained using the LightGBM-refined mass model is the standard deviation of the predicted binding energy. It is obtained by running LightGBM 500 times with randomly splitting AME2016 data into training and test sets with a ratio of 4:1.

表 2 对测试集中的预测结合能与 RMSD 值进行了对比分析. 通过系统性地比较三种成熟方法—ELMA, BNN 与 SLSQP—以及基于 BMA 获得的结果, 从而验证了不同方法在预测性能上的差异 (单位: MeV)

Table 2. A comparison is conducted of the predicted nuclear binding energies and RMSD on the test set. The results from three established approaches—ELMA, BNN and SLSQP — are systematically compared with those obtained using BMA, thus verifying the performance differences among the various methods (Unit: MeV).

| Z | A | EXP. | BMA (this work) | ELMA ^[64] | BNN ^[52] | SLSQP ^[65] | 参考文献 |
|------|-----|----------|-----------------|----------------------|---------------------|-----------------------|------|
| 9 | 30 | 186.399 | 186.361 | — | 186.672 | 185.995 | [66] |
| 14 | 23 | 151.148 | 150.381 | 151.085 | 150.302 | 150.494 | [67] |
| 15 | 26 | 187.118 | 187.043 | — | 187.196 | 184.879 | [67] |
| 16 | 27 | 187.987 | 187.987 | 188.253 | 187.902 | 187.165 | [67] |
| 18 | 31 | 224.835 | 224.977 | 224.973 | 225.230 | 224.764 | [67] |
| 19 | 34 | 261.043 | 261.043 | — | 260.911 | 260.219 | [68] |
| 20 | 35 | 262.068 | 262.068 | 262.098 | 262.223 | 263.655 | [69] |
| 21 | 37 | 278.705 | 278.694 | 278.389 | 279.114 | 280.240 | [68] |
| 21 | 38 | 294.932 | 294.932 | — | 294.832 | 296.323 | [68] |
| 24 | 65 | 534.055 | 533.934 | 533.901 | 534.267 | 534.566 | [70] |
| 39 | 104 | 864.099 | 863.056 | 862.352 | 862.650 | 863.113 | [71] |
| 40 | 80 | 669.528 | 668.803 | 669.026 | 668.824 | 668.710 | [72] |
| 40 | 106 | 882.356 | 882.912 | 882.482 | 883.037 | 883.728 | [71] |
| 42 | 112 | 927.662 | 928.739 | 928.188 | 928.767 | 929.627 | [71] |
| 43 | 115 | 949.638 | 950.770 | 950.182 | 950.490 | 951.570 | [71] |
| 47 | 95 | 789.734 | 789.878 | 790.124 | 789.819 | 786.780 | [63] |
| 49 | 99 | 822.140 | 822.208 | 822.779 | 821.989 | 816.991 | [73] |
| 57 | 152 | 1231.413 | 1231.383 | 1231.143 | 1231.716 | 1231.526 | [74] |
| 58 | 152 | 1240.329 | 1240.347 | 1240.087 | 1240.405 | 1240.048 | [75] |
| 58 | 153 | 1244.347 | 1244.235 | 1244.060 | 1244.471 | 1243.896 | [75] |
| 58 | 155 | 1253.265 | 1253.338 | 1252.975 | 1253.511 | 1252.757 | [74] |
| 59 | 154 | 1254.807 | 1254.896 | 1254.582 | 1254.884 | 1253.958 | [75] |
| 64 | 168 | 1354.051 | 1354.051 | 1354.027 | 1354.026 | 1353.073 | [74] |
| RMSD | | | 0.468 | 0.514 | 0.529 | 1.650 | |

上式要求原子核质子数与中子数相等且均为偶数 (δV_{pn}^{ee}). 对于奇奇核要求原子核质子数与中子数相等且均为奇数 (δV_{pn}^{oo}), 它的定义为

$$\delta V_{pn}^{oo}(Z, N) = [B(Z, N) - B(Z, N - 1) - B(Z - 1, N) + B(Z - 1, N - 1)]. \quad (3)$$

最近兰州重离子加速器采用同位素质谱法测量了 ^{62}Ge , ^{64}As , ^{66}Se 等原子核质量, 用这些新测量的数据可以计算 $Z = N$ 的原子核 δV_{pn} , 对于 $Z \geq 28$ 的偶偶核 (奇奇核) 其大小随质量数 A 的增加而减少 (增加)^[58], 相关结果显示在图 2. 可以看到, 四种质量模型给出的奇奇核的 δV_{pn} 都远低于实验值, 而偶偶核的结果与实验值十分接近. 对于这种 $Z = N$ 的原子核 δV_{pn} 异常分叉的情况, 有研究指出三体力对 δV_{pn} 有重要影响^[58]. 文献 [77] 通过

建立统一考虑中子-中子和质子-质子以及中子-质子对关联、严格处理堵塞效应、保持粒子数守恒的相对论多体理论方法, 微观自洽处理了中子-质子对关联, 成功地再现了这种异常行为, 指出这种现象是由在奇奇核中增强的质子-中子对关联而导致的. 从图 2 可以看到, 经过机器学习优化后的质量模型给出的结果能够与实验值更靠近. 这里需要指出的是, 训练集中使用的 ^{70}Br 和 ^{65}As 原子核的结合能分别是 589.03752 和 545.755 MeV, 利用这两个值计算出 ^{70}Br 和 ^{66}As 原子核的 δV_{pn} 的值分别为 2.923 和 2.925 MeV. 而图中 ^{70}Br 和 ^{66}As 原子核的 δV_{pn} 是基于文献 [58] 给出的结合能 (589.630 和 546.397 MeV) 计算得到的, 基于这两个值得到的 δV_{pn} 值为 3.515 和 3.066 MeV. 因此利用机器学习优化后的质量表给出的这两个原子核的 δV_{pn} 小于

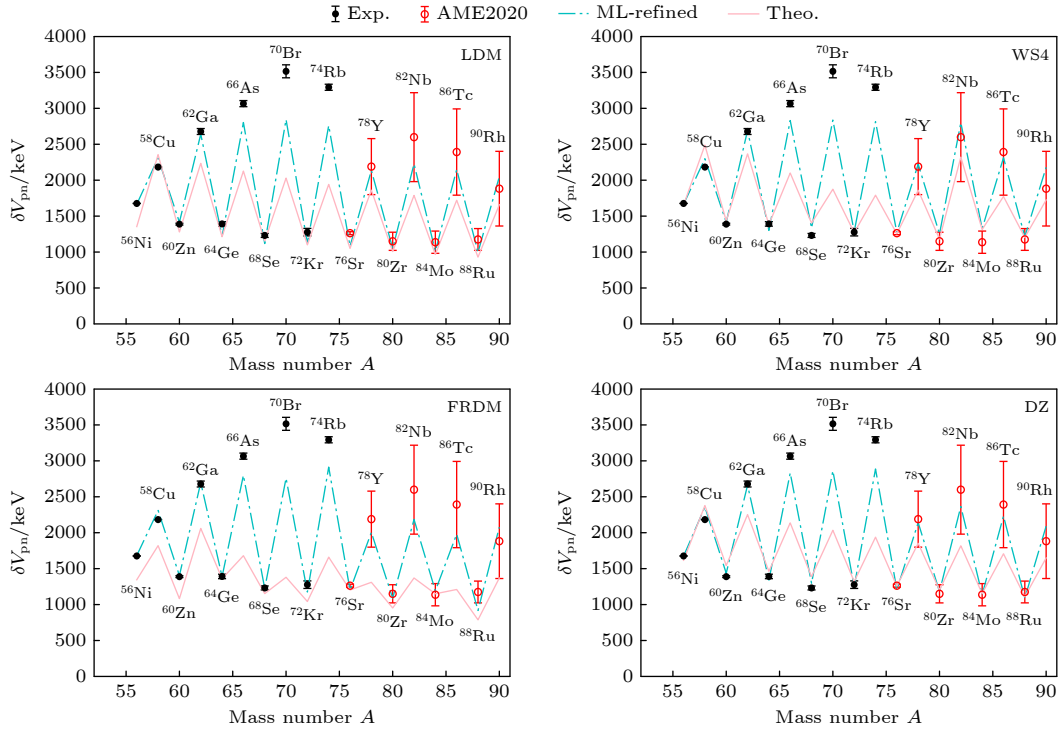


图 2 质量数 $A \geq 56$ 满足 $Z = N$ 原子核的 δV_{pn} 与不同质量模型的预测值比较. 黑色实心圆点表示实验值, 数据取自文献 [51,58], 红色空心圆圈代表从 AME2020 评估数据得到的结果, 实线代表四种质量模型给出的结果, 虚线表示机器学习优化后四种模型给出的结果

Fig. 2. Experimental δV_{pn} for $Z = N$ nuclei beyond $A = 56$ and comparison to different mass model predictions. Solid black dots represent experimental value, the data taken from literature [51,58]. The red hollow circles represent the results obtained from the AME2020 evaluation data. The solid lines represent the results given by the four mass models, while the dashed lines indicate the results provided by the four models after machine learning optimization.

实验值. 在计算 ^{64}Ge , ^{68}Se , ^{72}Kr , ^{74}Rb 这几个原子核的 δV_{pn} 时, 需要用到 ^{62}Ge , ^{66}Se , ^{70}Kr , ^{73}Rb 这几个核的质量, 而这几个核的数据并没有包含在训练集中. 这展示出机器学习方法对原子核质量模型有很强的优化能力. 利用 BMA 方法给出的结果显示在图 3, 可以看到, BMA 的结果与实验值更加靠近. 当质量数大于 76 时, 目前还没有 δV_{pn} 相关的实验数据, 根据 AME2020 中的评估值计算出的结果显示, 在 ^{82}Nb 处有一个峰值. 机器学习优化后的 LDM, WS4 和 DZ 模型也在这里出现了明显的峰值, 机器学习优化后的 FRDM 模型以及 BMA 的结果出现较弱的峰值. 这些地方目前还缺少相关的实验数据来约束模型参数, 未来相关实验上对这些核的测量, 可以进一步提供检验原子核质量表的机会.

3.3 原子核 α 衰变能

精确预言超重原子核的 α 衰变能对实验室合成和探测超重核意义重大. 利用原子核结合能与 α

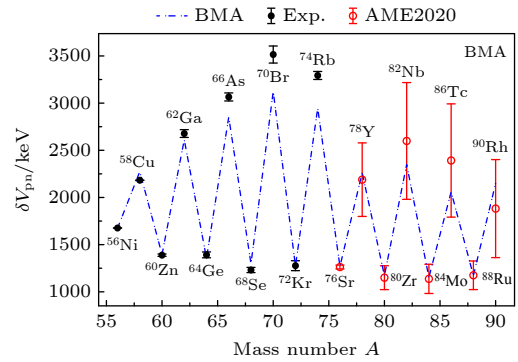


图 3 质量数 $A \geq 56$ 满足 $Z = N$ 原子核的 δV_{pn} 与 BMA 预测值的比较. 黑色实心圆点表示实验值, 红色空心圆圈代表从 AME2020 评估数据得到的结果, 蓝色虚线代表通过 BMA 预测的结果, 该图所用实验数据与图 2 一致

Fig. 3. The δV_{pn} of nuclei with $A \geq 56$ and $Z = N$ is compared with the results of BMA. The black solid dots represent the experimental values, the red hollow circles represent the results obtained from the AME2020 evaluation data, and the blue dashed lines represent the prediction through BMA. The experimental data used in this figure is consistent with that in Fig. 2.

衰变能之间的关系可以计算原子核的 α 衰变能. 本文用优化后的质量表对 89—120 号元素的 α 衰变

表 3 不同质量表给出的 α 衰变能与实验值的 RMSD(单位: MeV)
Table 3. The RMSD of the α -decay energy given by different mass tables and the experimental value (Unit: MeV).

| 模型 Model | $89 \leq Z \leq 118$ | $89 \leq Z \leq 102$ | $103 \leq Z \leq 118$ | $103 \leq Z \leq 118$ |
|----------|---------------------------------------|---------------------------------------|---------------------------------------|---------------------------------------|
| | ^{203}Ac — ^{294}Og | ^{203}Ac — ^{264}No | ^{251}Lr — ^{294}Og | ^{251}Lr — ^{294}Og |
| | 371个核素 | 276个核素 | 95个核素 | 非训练集核素 |
| LDM | 0.856 | 0.946 | 0.510 | 0.540 |
| DZ | 0.510 | 0.331 | 0.836 | 0.838 |
| WS4 | 0.253 | 0.238 | 0.291 | 0.307 |
| FRDM | 0.366 | 0.253 | 0.581 | 0.615 |
| LDM_lgb | 0.230 | 0.091 | 0.427 | 0.459 |
| DZ_lgb | 0.419 | 0.189 | 0.763 | 0.800 |
| WS4_lgb | 0.153 | 0.086 | 0.265 | 0.286 |
| FRDM_lgb | 0.263 | 0.098 | 0.493 | 0.530 |
| BMA | 0.135 | 0.079 | 0.230 | 0.245 |

能进行了计算, 相关的数据见电子表格 [78]. 各个质量模型得到的 α 衰变能与实验值的 RMSD 列在表 3 中. 可以看到, 机器学习优化后的质量表给出的 RMSD 远小于优化前质量模型给出的结果, 尤其对于 $89 \leq Z \leq 102$ 的核素, 机器学习优化后的质量表给出的 α 衰变能的 RMSD 可以小于 100 keV, 这对在实验上研究这一区域核素有重要价值. 对于倒数第二列 $103 \leq Z \leq 118$ 的核素, 计算这 95 个核素的 α 衰变能所涉及的核素只有大约 14.6% 的核素包含在训练集内, 而机器学习修正之后的质量模型相比于修正前其 RMSD 值分别降低了约 7.5%, 8.7%, 8.9% 和 15.1%, 这也说明了机器学习模型优化原子核质量模型的可靠性. 为进一步验证, 表格最后一列列出了 81 个未包含在训练集核素的 α 衰变能与实验值的 RMSD, 可以看到机器学习修正之后的质量模型相比于修正前均有不同程度的改善. 此外, 从表格的最后一行可以看出, 使用 BMA 方法的结果都小于其他质量模型给出的结果, 表明 BMA 方法在预测原子核质量方面具有优势.

图 4 展示了从 Am 到 Og 同位素的 α 衰变能随中子数 N 的变化情况. 8 个子图分别展示了 4 种质量模型下原子核 α 衰变能经过机器学习优化后与优化前以及实验测量的结果, 上面 4 幅子图表示偶质子原子核 α 衰变能, 下面 4 幅子图表示奇质子原子核 α 衰变能. 每种模型选取元素相同, 这里仅标注在 WS4 模型上. 可以看到, 机器学习优化后的质量表给出的结果与实验值更加靠近. 例如 ^{294}Og 原子核的 α 衰变能的实验值为 11.874 MeV, 基于机器学习优化后的 WS4 给出的结果为

12.017 MeV, 基于 BMA 给出的结果为 12.092 MeV, 都比 WS4 质量表给出的 12.198 MeV 更加靠近实验值.

目前, 国内外多个实验室都在聚焦合成 $Z = 119$ 和 $Z = 120$ 号元素, 十分有必要对相应核素的 Q_α 值进行精准预测. 图 5 展示了各个质量模型给出的 $Z = 119, 120$ 核素的 Q_α 随中子数的变化情况. 文献 [61] 中, 通过把现有实验数据原子核的 Q_α 值引入到拟合扩展的 Skyrme 能量密度泛函的参数中, 可以高精度地计算原子核的 Q_α 值, 相关的结果也显示在图 5. 可以看到不同的模型给出的结果有很大差异, 例如在中子数为 170 左右, 各个质量模型给出的 Q_α 值相差可以达到 1 MeV. 这会导致利用预测的原子核 α 衰变半衰期有 1—2 个数量级的差异 [79,80]. 因为超重核区的实验数据十分有限, 所以机器学习优化后质量表给出的结果与优化前的结果十分靠近.

中国科学院近代物理研究所的实验团队正在计划以 ^{54}Cr 为弹核、 ^{243}Am 为靶核进行 119 号元素合成实验 [81]. 基于目前的理论预测 [82], 中子数为 178 质量数为 297 的原子核合成概率较大, 该原子核的 Q_α 理论值在不同的质量模型下分别为 12.454 MeV(LDM), 12.020 MeV(DZ), 12.424 MeV(WS4), 12.896 MeV(FRDM), 经过机器学习修正后其 Q_α 预测值分别为 12.377 MeV(LDM-lgb), 11.911 MeV(DZ-lgb), 12.353 MeV(WS4-lgb), 12.824 MeV(FRDM-lgb), 而基于 BMA 模型的结果为 12.503 MeV. 可以看到上述结果与文献 [61] 中所预测的 11.286 MeV 存在一定差异. 在未来几年,

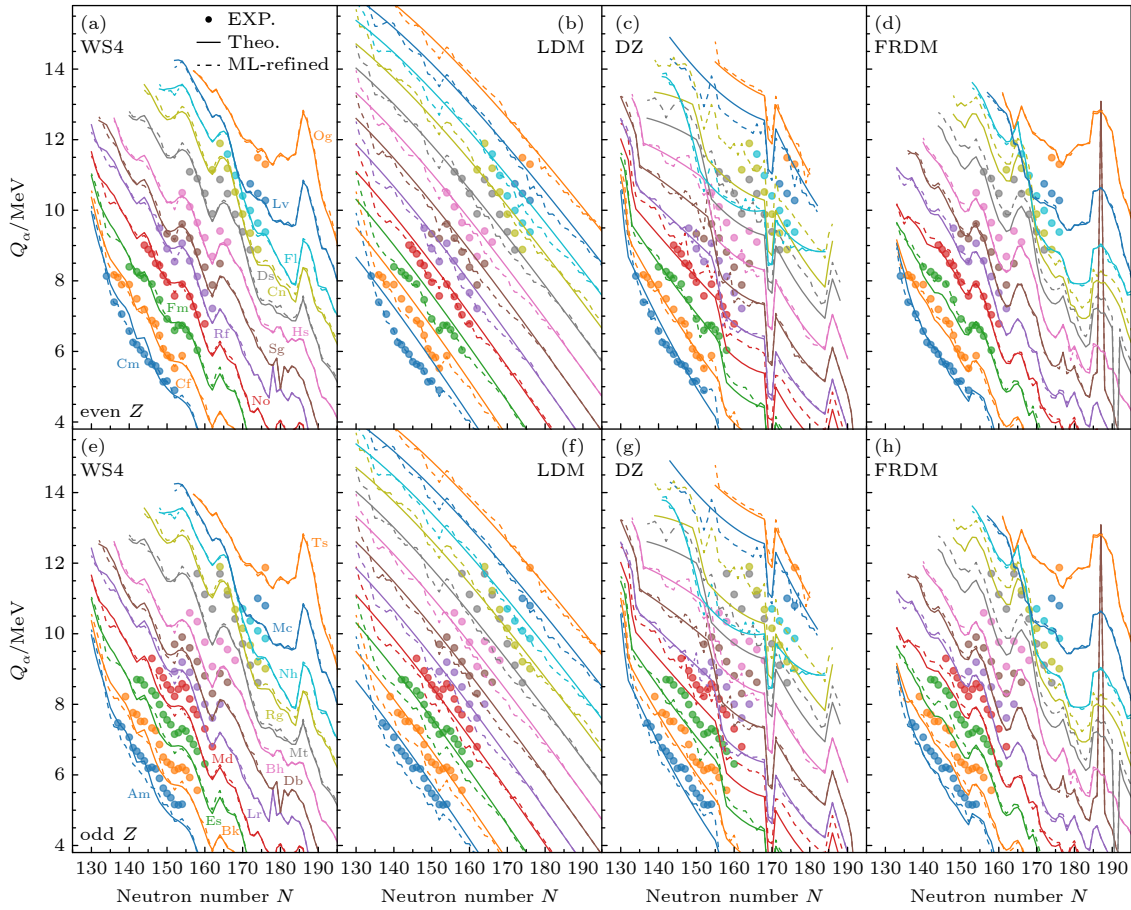


图 4 四种质量模型给出的从 Am 到 Og 同位素的 α 衰变能随中子数 N 的变化情况. 彩色实心圆点代表实验值, 实线表示质量模型的理论值, 虚线表示机器学习优化后的结果. (a)–(d) 偶 Z 核的 α 衰变能; (e)–(h) 奇 Z 核的 α 衰变能

Fig. 4. The variation of α -decay energy from Am to Og isotopes with neutron number N in the four mass model. The colored solid dots represent experimental values, the solid lines indicate theoretical values of the mass model, and the dashed lines show the results after machine learning optimization: (a)–(d) α -decay energy of even Z nuclei; (e)–(h) α -decay energy of odd Z nuclei.




图 5 各种质量模型给出的 $Z = 119$ 与 $Z = 120$ 号同位素链上 Q_α 随中子数的变化情况. 图中实线代表四种质量模型的预测值, 虚线表示机器学习优化之后的质量模型给出的结果数据, BMA 代表贝叶斯模型平均预测结果, DFT 指文献 [61] 中给出的结果

Fig. 5. The variation of Q_α along the $Z = 119$ and $Z = 120$ isotopic chains with the change in neutron number. The solid curves in the figure represent the predicted values from the four mass models, while the dashed curves represent the results given by the LightGBM-refined mass model. BMA stands for the results of BMA, and DFT refers to the results presented in the Ref. [61].

随着多个重离子核物理大科学装置的建成运行,将在超重核区域积累越来越多的数据,这些数据可以优化原子核质量模型,从而为精确预言 119 号元素的 Q_α 奠定基础.

4 总 结

本文利用 2022 年以来新测量的原子核质量数据、剩余质子-中子相互作用、重原子核的 α 衰变能对机器学习优化后的质量表进行了检验,发现机器学习优化后的质量表给出的平均偏差都小于优化前的质量表,表明机器学习模型在预测原子核质量方面具有优越性. 对于 23 个新测量质量的原子核,利用 LightGBM 优化后 LDM, DZ, WS4, FRDM 的质量表给出的 RMSD 分别为 0.570, 0.558, 0.581, 0.512 MeV, 都低于优化之前给出的 3.275, 1.058, 0.752, 0.785 MeV. 基于贝叶斯模型平均方法给出的 RMSD 值为 0.480 MeV, 也小于机器学习优化后的四种质量表给出的结果. 利用机器学习优化后的质量表计算得到的 δV_{pn} 能够再现 $Z = N$ 原子核的 δV_{pn} 异常分叉现象,还预测在 ^{82}Nb 处 δV_{pn} 有一个峰值,未来相关实验上对这些核的测量,可以进一步提供检验各种原子核质量表的机会. 关于重核 Q_α 的预测,尤其对于 $89 \leq Z \leq 102$ 的核素,机器学习优化后的质量表给出的 α 衰变能的 RMSD 可以小于 100 keV, 这对在实验上研究这一区域核素有重要价值. 而对于 $103 \leq Z \leq 118$ 的核素,机器学习修正之后的质量模型相比于修正前其 RMSD 值分别降低了约 7.5%, 8.7%, 8.9% 和 15.1%, 这也说明了机器学习的可靠性,从而可以广泛应用于分析更庞大的核数据.

数据可用性声明

支撑本研究成果的数据集可在科学数据银行 <https://doi.org/10.57760/sciencedb.j00213.00246> 中访问获取.

参考文献

- [1] Alhassan E, Rochman D, Vasiliev A, Hursin M, Koning A J, Ferroukhi H 2022 *Nucl. Sci. Tech.* **33** 50
- [2] Wang X H, Zhu L, Su J 2021 *Phys. Rev. C* **104** 034317
- [3] He J J, He W B, Ma Y G, Zhang S 2021 *Phys. Rev. C* **104** 044902
- [4] Xu J, Xie W J, Li B A 2020 *Phys. Rev. C* **102** 044316
- [5] Zhang Z, Feng X B, Chen L W 2021 *Chin. Phys. C* **45** 064104
- [6] Li X Z, Zhang Q X, Tan H Y, Cheng Z Q, Ge L Q, Zeng G Q, Lai W C 2021 *Nucl. Sci. Tech.* **32** 143
- [7] Pang L G, Zhou K, Su N, Petersen H, Stöcker H, Wang X N 2018 *Nat. Commun.* **9** 210
- [8] Li Y Y, Zhang F, Su J 2022 *Nucl. Sci. Tech.* **33** 135
- [9] Song Y D, Wang R, Ma Y G, Deng X G, Liu H L 2021 *Phys. Lett. B* **814** 136084
- [10] Wu X H, Zhao P W 2024 *Sci. China Phys. Mech.* **67** 272011
- [11] Yuan Z Y, Bai D, Wang Z, Ren Z Z 2024 *Nucl. Sci. Tech.* **35** 105
- [12] Xu X Y, Deng L, Chen A X, Yang H, Jalili A, Wang H K 2024 *Nucl. Sci. Tech.* **35** 91
- [13] Yüksel E, Soydaner D, Bahtiyar H 2024 *Phys. Rev. C* **109** 064322
- [14] Li M K, Sprouse T M, Meyer B S, Mumpower M R 2024 *Phys. Lett. B* **848** 138385
- [15] Yiu T C, Liang H Z, Lee J 2024 *Chin. Phys. C* **48** 024102
- [16] Liu G P, Wang H L, Zhang Z Z, Liu M L 2025 *Phys. Rev. C* **111** 024306
- [17] Zhou J, Xu J 2024 *Sci. China Phys. Mech.* **67** 282011
- [18] Wei H L, Zhu X, Yuan C 2022 *Nucl. Sci. Tech.* **33** 111
- [19] Ma Y F, Su C, Liu J, Ren Z Z, Xu C, Gao Y H 2020 *Phys. Rev. C* **101** 014304
- [20] Li Z L, Wang Y J, Li Q F, Lv B F 2025 *Phys. Rev. C* **112** 014312
- [21] Wu D, Bai C L, Sagawa H, Zhang H Q 2020 *Phys. Rev. C* **102** 054323
- [22] Ye W H, Wan N 2025 arXiv:2507.17357 [nucl-th]
- [23] Tang L, Zhang Z H 2024 *Nucl. Sci. Tech.* **35** 19
- [24] Li Z L, Lv B F, Wang Y J, Petrache C M 2026 *Chin. Phys. C* **50** 014107
- [25] Lv B F, Wang Y J, Li Z L, Petrache C M 2025 *Phys. Rev. C* **111** 064324
- [26] Lv B, Li Z, Wang Y, Petrache C 2024 *Phys. Lett. B* **857** 139013
- [27] Li C Q, Tong C N, Du H J, Pang L G 2022 *Phys. Rev. C* **105** 064306
- [28] Zhao T L, Zhang H F 2022 *J. Phys. G: Nucl. Part. Phys.* **49** 105104
- [29] Fan J N, Shi S H, Xiang H, Fu L, Duan Y J, Cao D S, Lu H W 2024 *J. Chem. Inf. Model.* **64** 3080
- [30] Li T, Wang N, Li C, Liu M 2025 *Phys. Rev. C* **112** 024306
- [31] Wei K W, Shang T S, Tian R H, Yang D, Li C J, Chen J, Li J, Huang X L, Zhu J L 2025 *Acta Phys. Sin.* **74** 182901 (in Chinese) [魏凯文, 尚天帅, 田榕赫, 杨东, 李春娟, 陈军, 李剑, 黄小龙, 朱佳丽 2025 物理学报 **74** 182901]
- [32] Ma Y G, Pang L G, Wang R, Zhou K 2023 *Chin. Phys. Lett.* **40** 122101
- [33] He W B, Ma Y G, Pang L G, Song H C, Zhou K 2023 *Nucl. Sci. Tech.* **34** 88
- [34] He W B, Li Q F, Ma Y G, Niu Z M, Pei J C, Zhang Y X 2023 *Sci. China Phys. Mech.* **66** 282001
- [35] Li Z L, Gao Z P, Liu L, Wang Y J, Zhu L, Li Q F 2024 *Phys. Rev. C* **109** 024604
- [36] Gao Z P, Liu S Y, Wen P W, Liao Z H, Yang Y, Su J, Wang Y J, Zhu L 2024 *Phys. Rev. C* **109** 024601
- [37] Qiao C Y, Pei J C, Wang Z A, Qiang Y, Chen Y J, Shu N C, Ge Z G 2021 *Phys. Rev. C* **103** 034621
- [38] Feng Z Y, Tian J L, Wu T, Wei G J, Li Z L, Shi X Q, Wang Y J, Li Q F 2024 *Nucl. Sci. Tech.* **35** 93
- [39] Tian J L, Feng J X, Shen J C, Yao L, Wang J Y, Wu T, Zhao Y L 2025 *Nucl. Sci. Tech.* **36** 1
- [40] Ma C W, Wei X B, Chen X X, Peng D, Wang Y T, Pu J,

- Cheng K X, Guo Y F, Wei H L 2022 *Chin. Phys. C* **46** 074104
- [41] Ma C W, Peng D, Wei H L, Niu Z M, Wang Y T, Wada R 2020 *Chin. Phys. C* **44** 014104
- [42] Bao M, Jiang H, Zhao Y M 2023 *Nucl. Phys. Rev.* **40** 141 (in Chinese) [鲍曼, 姜慧, 赵玉民 2023 原子核物理评论 **40** 141]
- [43] Möller P, Myers W D, Sagawa H, Yoshida S 2012 *Phys. Rev. Lett.* **108** 052501
- [44] Duflo J, Zuker A P 1995 *Phys. Rev. C* **52** R23
- [45] Wang N, Liu M, Wu X Z, Meng J 2014 *Phys. Lett. B* **734** 215
- [46] Geng L S, Toki H, Meng J 2005 *Prog. Theor. Phys.* **113** 785
- [47] Xia X W, Lim Y, Zhao P W, Liang H Z, Qu X Y, Chen Y, Liu H, Zhang L F, Zhang S Q, Kim Y, Meng J 2018 *At. Data Nucl. Data Tables* **121** 1
- [48] Goriely S, Chamel N, Pearson J M 2009 *Phys. Rev. Lett.* **102** 152503
- [49] Goriely S, Hilaire S, Girod M, Péru S 2009 *Phys. Rev. Lett.* **102** 242501
- [50] Zhang K Y, He X T, Meng J, Pan C, Shen C W, Wang C, Zhang S Q 2021 *Phys. Rev. C* **104** L021301
- [51] Kondev F, Wang M, Huang W, Naimi S, Audi G 2021 *Chin. Phys. C* **45** 030001
- [52] Niu Z M, Liang H Z 2022 *Phys. Rev. C* **106** L021303
- [53] Niu Z M, Liang H Z 2018 *Phys. Lett. B* **778** 48
- [54] Wu X H, Lu Y Y, Zhao P W 2022 *Phys. Lett. B* **834** 137394
- [55] Gao Z P, Wang Y J, Lü H L, Li Q F, Shen C W, Liu L 2021 *Nucl. Sci. Tech.* **32** 109
- [56] Kondev F G, Naimi S 2017 *Chin. Phys. C* **41** 030003
- [57] Yuan Q N, Qi P P, Xiao X P, Wang X, He J, Long G M, Duan Z W, Dai Y Y, Yan R C, Yu G M, Yang H T, Qiang H 2025 arXiv: 2508.03155 [nucl-th]
- [58] Wang M, Zhang Y H, Zhou X, et al. 2023 *Phys. Rev. Lett.* **130** 192501
- [59] Hinne M, Gronau Q F, Van Den Bergh D, Wagenmakers E J 2020 *Adv. Methods Pract. Psychol. Sci.* **3** 200
- [60] Hoeting J A, Madigan D, Raftery A E, Volinsky C T 1999 *Stat. Sci.* **14** 382
- [61] Guan D W, Pei J C 2024 *Phys. Lett. B* **851** 138578
- [62] Zhang X Y, Li W F, Fang J Y, Niu Z M 2024 *Nucl. Phys. A* **1043** 122820
- [63] Ge Z, Reponen M, Eronen T, Hu B, Kortelainen M, Kankainen A, Moore I, Nesterenko D, Yuan C X, Beliuskina O, Cañete L, Groote R, Delafosse C, Dickel T, Roubin A, Geldhof S, Gins W, Holt J D, Hukkanen M, Jaries A, Jokinen A, Koszorús ff, Kripkó-Konec G, Kujanpää S, Lam Y H, Nikas S, Ortiz-Cortes A, Penttilä H, PitmanWeymouth D, Plaß W, Pohjalainen I, Raggio A, Rinta-Antila S, Romero J, Stryjczyk M, Vilen M, Virtanen V, Zadornaya A 2024 *Phys. Rev. Lett.* **133** 132503
- [64] Agrawal S, Chandnani N, Ghosh T, Saxena G, Agrawal B K, Paar N 2025 arXiv: 2508.21771 [nucl-th]
- [65] Yang H, Chen C Y, Xu X Y, Wang H K, Wang Y B 2025 *Nucl. Sci. Tech.* **36** 129
- [66] Collaboration S N 2024 *Phys. Rev. Lett.* **133** 082501
- [67] Yu Y, Xing Y M, Zhang Y H, et al. 2024 *Phys. Rev. Lett.* **133** 222501
- [68] Dronchi N, Charity R J, Sobotka L G, Brown B A, Weisshaar D, Gade A, Brown K W, Reviol W, Bazin D, Farris P J, Hill A M, Li J, Longfellow B, Rhodes D, Paneru S N, Gillespie S A, Anthony A K, Rubino E, Biswas S 2024 *Phys. Rev. C* **110** L031302
- [69] Lalanne L, Sorlin O, Poves A, Assié M, Hammache F, Koyama S, Suzuki D, Flavigny F, Girard-Alcindor V, Lemasson A, Matta A, Roger T, Beaumel D, Blumenfeld Y, Brown B, De Oliveira Santos F, Delaunay F, de Séréville N, Franchoo S, Gibelin J, Guillot J, Kamalou O, Kitamura N, Lapoux V, Mauss B, Morfouace P, Pancin J, Saito T Y, Stodel C, Thomas J C 2023 *Phys. Rev. Lett.* **131** 092501
- [70] Silwal R, Andreoiu C, Ashrafkhani B, Bergmann J, Brunner T, Cardona J, Dietrich K, Dunling E, Gwinner G, Hockenbery Z, Holt J D, Izzo C, Jacobs A, Javaji A, Kootte B, Lan Y, Lunney D, Lykiardopoulou E M, Miyagi T, Mougeot M, Mukul I, Murböck T, Porter W S, Reiter M, Ringuette J, Dilling J, Kwiatkowski A A 2022 *Phys. Lett. B* **833** 137288
- [71] Wang K L, Estrade A, Famiano M, Schatz H, Barber M, Baumann T, Bazin D, Bhatt K, Chapman T, Dopfer J, Famiano B, George S, Giles M, Ginter T, Jenkins J, Jin S, Klankowski L, Liddick S, Meisel Z, Nepal N, Pereira J, Rijal N, Rogers A M, Tarasov O, Zimba G 2024 *Phys. Rev. C* **109** 035806
- [72] Hamaker A, Leistenschneider E, Jain R, Bollen G, Giuliani S A, Lund K, Nazarewicz W, Neufcourt L, Nicoloff C R, Puentes D, Ringle R, Sumithrarachchi C S, Yandow I T 2021 *Nat. Phys.* **17** 1408
- [73] Mougeot M, Atanasov D, Kartheim J, Wolf R N, Ascher P, Blaum K, Chrysalidis K, Hagen G, Holt J D, Huang W J, Ascher P, Blaum K, Jansen G R, Kulikov I, Litvinov Y A, Lunney D, Manea V, Miyagi T, Papenbrock T, Schweikhard L, Schwenk A, Steinsberger T, Stroberg S R, Wilkins S G, Zuber K 2021 *Nat. Phys.* **17** 1099
- [74] Ray D, Vassh N, Liu B, Valverde A A, Brodeur M, Clark J A, McLaughlin G C, Mumpower M R, Orford R, Porter W S, Savard G, Sharma K S, Surman R, Buchinger F, Burdette D P, Callahan N, Gallant A T, Hoff D E M, Kolos K, Kondev F G, Morgan G E, Rivero F, Santiago-Gonzalez D, Scielzo N D, Varriano L, Weber C M, Wilson G E, Yan X L 2024 arXiv: 2411.06310 [nucl-ex]
- [75] Spătaru A, Kripkó-Konec G, Dickel T, Hornung C, Plaß W R, Constantin P, Amanbayev D, Ayet San Andrés S, Balabanski D L, Beck S, Bergmann J, Geissel H, Kalantar-Nayestanaki N, Kehat J, Mardor I, Minkov N, Mollaebrahimi A, Scheidenberger C, Wasserheß M, Wilsenach H, Zhao J W 2025 *Phys. Rev. C* **111** 054307
- [76] Schatz H, Bildsten L, Cumming A, Ouellette M 2003 *Nucl. Phys. A* **718** 247
- [77] Wang Y P, Wang Y K, Xu F F, Zhao P W, Meng J 2024 *Phys. Rev. Lett.* **132** 232501
- [78] <https://github.com/lzl888-afk/Further-exploration-of-the-machine-learning-based-nuclear-mass-table> [2025-10-20]
- [79] Xing F Z, Yue X K, Wang N, Wang Y Z 2025 *Acta Phys. Sin.* **74** 112301 (in Chinese) [邢凤竹, 乐先凯, 王楠, 王艳召 2025 物理学报 **74** 112301]
- [80] Chen H J, Sheng H W, Huang W H, Wu B Q, Zhao T L, Bao X J 2025 *Acta Phys. Sin.* **74** 192301 (in Chinese) [陈海军, 盛浩文, 黄文豪, 吴彬琪, 赵天亮, 包小军 2025 物理学报 **74** 192301]
- [81] Xing Y M, Zhang D D, Zhou S G 2025 *Physics* **54** 599 [姜义铭, 张丹丹, 周善贵 2025 物理 **54** 599]
- [82] Fang Y P, Gao Z P, Zhang Y N, Liao Z H, Yang Y, Su J, Zhu L 2024 *Phys. Lett. B* **858** 139069

SPECIAL TOPIC—Thematic data in nuclear physics: Experimental, theoretical and applied research

Further exploration of the machine-learning-based nuclear mass table*

LIU Yaqi¹⁾²⁾³⁾ LI Zhilong²⁾⁴⁾ WANG Yongjia^{2)†}

LI Qingfeng^{2)‡} MA Chunwang¹⁾³⁾

1) (*College of Physics, Henan Normal University, Xinxiang 453007, China*)

2) (*School of Science, Huzhou University, Huzhou 313000, China*)

3) (*Institute of Nuclear Science and Technology, Henan Academy of Sciences, Zhengzhou 450046, China*)

4) (*China Institute of Atomic Energy, Beijing 102413, China*)

(Received 9 November 2025; revised manuscript received 4 December 2025)

Abstract

The mass of the atomic nucleus, as one of the fundamental physical quantities of the atomic nucleus, plays an important role in understanding and researching the structure of the atomic nucleus and nuclear reactions, and the basic interactions between nucleons. However, accurately predicting the mass of nuclei far from the β stability line remains a huge challenge. Based on the machine-learning-refined mass model, we investigate the newly measured atomic nucleus masses since 2022, along with the residual proton-neutron interaction (δV_{pn}) and the α -decay energy of heavy nucleus. It is found that: 1) For the 23 newly measured atomic nuclei, the root mean square deviations obtained by the machine-learning-refined mass models are between 0.51 and 0.58 MeV, which are significantly lower than 3.275, 1.058, 0.752, and 0.785 MeV given by the liquid droplet model (LDM), Weizsäcker-Skyrme-4 (WS4), finite-range droplet model (FRDM), and Duflo-Zucker (DZ), respectively. 2) The δV_{pn} of the atomic nucleus with $N = Z$ obtained from machine-learning-refined mass models is consistent with the latest experimental data. 3) The root mean square deviations of the α -decay energy of heavy nuclei obtained from the machine-learning-refined mass models have also been significantly reduced. Furthermore, by employing the Bayesian model average approach to combine the results from different machine-learning-refined mass models, we obtain more accurate predictions. These findings demonstrate that such models have good extrapolation capabilities and provide useful insight for further research. The datasets presented in this paper are openly available at <https://doi.org/10.57760/sciencedb.j00213.00246>.

Keywords: machine learning, atomic nucleus mass, residual proton-neutron interaction, α -decay energy

DOI: [10.7498/aps.75.20251526](https://doi.org/10.7498/aps.75.20251526)

CSTR: [32037.14.aps.75.20251526](https://cstr.cn/32037.14.aps.75.20251526)

* Project supported by the National Basic Research Program of China (Grant No. 2023YFA1606402), the National Natural Science Foundation of China (Grant Nos. 12335008, 12375123), and the Natural Science Foundation of Henan Province, China (Grant No. 242300421048).

† Corresponding author. E-mail: wangyongjia@zjhu.edu.cn

‡ Corresponding author. E-mail: liqf@zjhu.edu.cn