

基于神经网络方法研究超重核的稳定性和衰变性质

陈海军^{1)†} 盛浩文¹⁾ 黄文豪¹⁾ 吴彬琪¹⁾ 赵天亮^{2)‡} 包小军^{2)††}

1) (湖南工商大学数字媒体工程与人文学院, 长沙 410205)

2) (湖南师范大学物理与电子科学学院, 长沙 410081)

(2025年6月4日收到; 2025年8月7日收到修改稿)

本文提出了一种用于计算原子核 α 衰变能(Q_α)的类液滴模型公式. 为了改进类液滴模型公式计算 Q_α 的精度, 我们发展了神经网络结合类液滴模型公式的方法, 计算了原子核的 Q_α 值. 通过分别对比类液滴模型计算的 Q_α 值和神经网络结合类液滴模型公式的方法计算的 Q_α 值与实验测量值的均方根偏差(RMSD), 发现类液滴模型计算的 Q_α 值与实验值之间的RMSD从663.5 keV下降到神经网络结合类液滴模型公式的89.2 keV. 进而采用改进的 Q_α 结合统一衰变公式计算了 α 衰变的半衰期. 虽然没有直接考虑原子核的壳效应, 但神经网络方法预测出了相应的超重核区双幻核的位置, 这与目前理论预测的超重双幻的位置非常接近, 从而给出了超重核区 α 衰变的稳定区域, 进一步证实了超重核稳定岛的存在.

关键词: 超重核, 神经网络, 原子核质量, α 衰变**PACS:** 23.60.+e, 21.10.Tg, 25.85.Ca**DOI:** 10.7498/aps.74.20250720**CSTR:** 32037.14.aps.74.20250720

1 引言

超重原子核研究一直处于核科学的前沿领域. 超重核产生机制是一项具有重大应用和理论意义的研究课题. 超重核合成与性质的研究对检验和完善现有原子核理论以及加深对核结构与核反应机制的认识具有重要的意义. 超重核 α 衰变是鉴定超重核合成的关键^[1-6]. 目前, 实验合成的最重原子核为²⁹⁴Og^[7]. 由于最近30多年来探测分离技术和加速器物理等实验条件的提高, 超重核合成的实验研究方面取得了一系列突破性进展. 国际著名核物理实验室利用低能重离子核反应合成了一系列的超重新核素及其同位素^[8].

近50年来超重核区域的持续研究, 目的是寻

找并确定超重稳定岛的位置, 该岛预计位于质子数 $Z = 114$ 和中子数 $N = 184$ 的位置^[9-13]. 直到最近几年才有实验数据表明, 当 $Z = 114-118$ 接近预测的闭壳数 $N = 184$ 时^[12], 原子核的稳定性得到了改善. 除了质子和中子的闭合壳层外, 还预测了质子和中子数为 $Z = 100$, $N = 152$ 和 $Z = 108$, $N = 162$ 变形核的稳定性^[10,13,14].

超重双幻数核的理论研究也受到高度重视. 幻数的出现是由于核子的自旋-轨道耦合^[15-17]. 对于已知的幻数, 目前的原子核结构模型可以给出很好的解释. 然而, 不同的核结构模型可能给出不同的双幻数超重核^[18-23]. 由此计算出的 α 衰变能在闭合壳层附近也会有显著差异. 为了消除幻数的模型依赖性, 本文提出了一种类液滴模型的 α 衰变能的计算公式, 并结合神经网络(NN)方法获得 α 衰变稳定岛的范围, 提高计算精度.

† 通信作者. E-mail: chj_yh@163.com‡ 通信作者. E-mail: zhaotl@hunnu.edu.cn†† 通信作者. E-mail: baoxiaojun@hunnu.edu.cn

不同于传统的从原子核质量计算 α 衰变能的思路. 在参考文献 [24] 中, 基于局部液滴模型, 提出了一个可用于计算重核和超重核 Q_α 值的公式, 表示为

$$Q_\alpha = a_1 + \frac{a_2}{A^{1/3}} + a_3 \frac{Z}{A^{1/3}} \cdot \left[1 - \frac{Z}{3A} + a_4 \left(\frac{N-Z}{A} \right)^2 \right] + a_5 \left[1 - \left(\frac{N-154}{a_6} \right)^2 \right] \cdot \exp \left[-\frac{1}{2} \left(\frac{N-154}{a_6} \right)^2 \right] + a_7 \left[1 - \left(\frac{N-164}{a_8} \right)^2 \right] \cdot \exp \left[-\frac{1}{2} \left(\frac{N-164}{a_8} \right)^2 \right]. \quad (1)$$

可以发现形变双幻核的中子幻数出现在 (1) 式中, 作为计算 Q_α 值的局部公式, 具有较高的精度. 但这样的局部公式很难推广到更轻或更重的区域. 因此, 为了拓展该方法的普适性, 修正了 (1) 式的表达形式. 具体而言, 去掉 (1) 式中的最后两项, 替换为正弦项和余弦项. 所以计算 Q_α (单位 MeV) 的公式可以写成:

$$Q_\alpha = a_1 + \frac{a_2}{A^{1/3}} + a_3 \frac{Z}{A^{1/3}} \left[1 - \frac{Z}{3A} + a_4 \left(\frac{N-Z}{A} \right)^2 \right] + a_5 \left[\cos \left(\frac{A}{a_6} \right) + \sin \left(\frac{A}{a_7} \right) \right]. \quad (2)$$

(2) 式中没有幻数信息, 所以在幻数附近的结果可能很差, 但可以对更广泛的核区进行预测.

通过拟合 AME2016^[25] 中的 α 衰变能, 可以获得 (2) 式中的参数. 我们选择了 369 个质子数大于或等于 82 的原子核. $a_1 - a_7$ 的拟合结果分别为 -3.7115 , -44.1784 , 1.6284 , -91.1755 , -0.8926 , -9.7947 , 5.1465 ; σ 的拟合结果为 663.5 keV. 可以看出, 拟合后的均方根偏差 (RMSD) 为 663.5 keV. 对于 α 衰变能量, 这样的偏差较大. 均方根偏差的计算公式为

$$\sigma = \sqrt{\frac{1}{N_{\text{total}}} \sum \left(Q_\alpha^{\text{Exp}} - Q_\alpha^{\text{Eq.(2)}} \right)^2}. \quad (3)$$

1911 年, Geiger 和 Nuttall^[26] 提出了 α 衰变半衰期 $T_{1/2}$ 与衰变能量 Q_α 关系的简单经验定律. 计算 α 衰变半衰期最简单的方法是:

$$\log T_{1/2} = a + b/\sqrt{Q_\alpha}. \quad (4)$$

虽然这种计算方法比较粗糙, 但可以看到 α 衰变半衰期与衰变能量之间的关系. 1 MeV 的 Q_α 变化会导致 α 衰变半衰期发生几个数量级的变化^[27]. 因此需要更精确的 α 衰变能. 本文采用神经网络结合我们提出的类液滴模型的方法来获得更精确的 α 衰变能.

2 神经网络方法

误差反向传播 (back propagation, BP) 算法是人工神经网络中的一种监督学习算法. BP 神经网络算法理论上可以逼近任意函数, 其基本结构由非线性变化单元组成, 具有较强的非线性映射能力. 实际上, Robert Hecht-Nielsen 在 1989 年证明了在任何封闭区间内的连续函数都可以用隐藏层 BP 网络来逼近, 这就是普适性的逼近定理. 因此, 3 层 BP 网络可以完成从 M 维到 N 维的任意映射. 换句话说, 这 3 层分别是输入层 (I)、隐藏层 (H) 和输出层 (O), 神经网络的结构如图 1 所示.




图 1 由两个输入神经元、一个隐藏层和一个输出神经元组成的前馈神经网络

Fig. 1. Feedforward neural network consisting of two input neurons, a hidden layer and an output neuron.

一般来说, 我们无法直接确定隐藏层神经元的数量. 通常情况下, 神经元数量越多, 训练结果越好, 但同时也存在过拟合的风险. 因此, 我们确定神经元数量的方案如下. 第 1 步是确保训练结果尽可能小, 所以选择一个较大的数值作为神经元的起始数量, 这会导致训练集和验证集的均方根偏差之间存在较大的差异. 然后逐步减少神经元数量, 直到验证集和训练集的均方根偏差之间的差异小于某一值 (本工作中取 20%). 这就确定了隐藏层神

经元的数量.

神经网络方法在原子核领域得到了广泛的应用 [28–36]. 在这项工作中, 输入神经元的数量为 2 个 (Z 和 A), 隐藏层的神经元数量为 21 个, 输出神经元只有 1 个 (δQ_α). 现在, 计算 α 衰变能量的公式变成:

$$Q_\alpha^{\text{NN}} = a_1 + \frac{a_2}{A^{1/3}} + a_3 \frac{Z}{A^{1/3}} \left(1 - \frac{Z}{3A}\right) + a_4 \left(\frac{N-Z}{A}\right)^2 + a_5 [\cos(A/a_6) + \sin(A/a_7)] + \delta Q_\alpha. \quad (5)$$

(5) 式与 (2) 式相比, 只是增加了神经网络方法提供的修正 δQ_α . 接下来将讨论如何训练神经网络. 采用一个函数来表示前馈神经网络 [34] 中输入 $x(x_1, x_2)$ 和输出 y (δQ_α) 之间的关系:

$$y = a + \sum_{j=1}^H b_j \tanh\left(c_j + \sum_{i=1}^n d_{ji} x_i\right), \quad (6)$$

其中, H 为隐藏层神经元数量, n 为输入层神经元数量, 模型参数为 $\omega_i = a, b_i, c_i, d_{ji}$. 神经元数量的选择决定了网络的复杂度, 并取决于数据集的大小. 为了更好地避免非活动网络权重, 这里只使用一个隐藏层. 网络的输入为 $x(Z, A)$, 包括质子数 Z 和核子数 A .

我们的目标是获得最小的 RMSD, 所以需要在训练的过程中调整权重和偏差. 接下来将确定神经网络中的参数. 在这项工作的学习阶段, 使用 Levenberg-Marquardt (LM) 反向传播算法来改变神经元之间的连接, 以获得神经网络输出与期望输出之间的一致性 [37–39]. 其是非线性回归中回归参数最小二乘估计的一种估计方法. NN 的权重计算公式如下:

$$\omega_{i+1} = \omega_i - (\mathbf{J}_i^T \mathbf{J}_i + \mu_i \mathbf{I})^{-1} \mathbf{J}_i^T e_i, \quad (7)$$

其中, ω_{i+1} 为第 i 次迭代解估计的试解. \mathbf{J} 是输出误差的雅可比矩阵, \mathbf{I} 是单位矩阵, μ 是学习参数. 由于 LM 参数具有更好的可操作性和可控性, 因此该算法更加稳定可靠. 有了这种方法, 下一步就是训练神经网络模型.

3 计算结果与讨论

首先简要描述采用神经网络方法结合类液滴模型公式计算 α 衰变能的方法. 本文以衰变母

核的质子数 Z 和质量数 A 作为输入量, α 衰变能的实验值与 (2) 式的差值作为输出的神经网络模型. 从本文使用的 369 个 α 衰变能实验数据中, 选择 50 个数据点作为验证集, 其余的数据作为训练集. 神经网络包含 $(2+i)H+1 = 85$ 个自由参数 (见补充材料 (online)). 训练完成后, 将根据 (2) 式计算所得的 Q_α 值的 RMSD 从 663.5 keV 降低到 89.2 keV.

图 2 采用黑色实心方块表示实验值与 (2) 式计算结果的差值, 用红色实心圆表示实验值与 (5) 式计算结果的差值. 可以看到, 由于 (2) 式中没有考虑原子核的壳效应, 在幻数附近的理论计算值与实验值偏差较大, 达到约 3 MeV. 这将导致 α 衰变半衰期出现巨大的偏差. 显然, 这样的结果对于指导实验是没有意义的. 然而, 经过神经网络方法的训练, 理论结果与实验值的偏差显著减小, 所有的差异都不超过 0.5 MeV, 76.7% 的差异小于 0.1 MeV, 这无疑是一个令人满意的结果. 据此可以预测超重核的 α 衰变能和半衰期.




图 2 α 衰变能量的实验值与理论值之差

Fig. 2. Difference between experimental and theoretical values of α decay energy.

除了需要可靠的 α 衰变能之外, 计算 α 衰变的半衰期还须有一个可靠的理论方法. 经过几十年的发展, 理论上发展了很多用于计算 α 衰变半衰期的方法, 其中包括密度依赖的结团模型 [40]、广义的液滴模型 [41]、相对论平均场理论 [42] 等. 基于 Geiger-Nuttall 定律扩展的解析公式也可用于计算 α 衰变半衰期, 如统一衰变 (UDL) 公式 [43–45]、Sobiczewski-Parkhomenko 公式 [46]、Royer 公式 [47] 等. 基于参考文献 [48] 的结果, 为减少模型依赖性, 本文采用 UDL 公式计算 α 衰变半衰期.

UDL 的具体表达式为

$$\log T_{1/2}(s) = aZ_a Z_d \sqrt{\frac{A_d A_a}{(A_d + A_a) Q_\alpha}} + b \sqrt{\frac{A_d A_a}{(A_d + A_a)} Z_a Z_d (A_d^{1/3} + A_a^{1/3})} + c. \quad (8)$$

UDL 公式是从 α 衰变的微观描述^[43,44] 或从量子力学第一性原理^[45] 推导出来的. 其中 a , b , c 是通过拟合偶偶核的 α 半衰期得到的具体参数值. 考虑奇核子的阻塞效应, 一个阻塞因子 h 用于奇 A 核, 双阻塞因子 $2h$ 用于奇奇核^[48]. (8) 式的输入量是子核 (Z_d, A_d) 的质子数和质量数, α 结团 (Z_a, A_a) 的质子数和质量数, 以及衰变能 (Q_α).

在 (2) 式中拟合参数时, 使用质子数大于或等于 82 的 369 个原子核的衰变能. 接下来使用这些原子核的 α 衰变半衰期来拟合 (8) 式中的参数, 拟合后参数的具体值为: $a = 0.4109$, $b = -0.4089$, $c = -22.9785$, $h = 0.5836$. 理论值与实验值之间的 RMSD 为 0.631. 为了获得更准确的半衰期, 同样使用 NN 方法来训练 UDL 公式的结果 (记为 UDL^{NN}). 神经网络的训练过程与之前一样. 用神经网络方法训练后, 理论结果与实验值的 RMSD 降至 0.423.

为了验证理论结果的可靠性, 选择具有代表性的 Po, Th 和 Rf 同位素链比较理论计算值和实验测量值, 具体对比结果如图 3 所示. 实验值用黑色叉号表示, 理论值用红色实心圆表示, 神经网络训练后的结果用蓝色实心三角形表示. 从图 3 可以看出, 对于 Po, Th 同位素链, 衰变能的理论值与实验值之间的差异随着中子数的增加先增大后减小, 尤其是在中子幻数 $N = 126$ 附近, (2) 式的计算结果与实验值的偏差越来越大. 这是由于目前的 (2) 式中没有包含壳修正的影响. 然而, 神经网络方法与 (2) 式结合之后, 神经网络的结果模拟出壳修正的特点. 因此, 壳结构有了明显的改善. α 衰变半衰期的计算结果令人满意, 且无论是否使用神经网络方法, UDL 公式给出的结果都接近实验值. 值得注意的是, 在接近中子幻数 $N = 126$ 时, NN 模型对这些偏差进行了校正. 这表明在计算 α 衰变能时, 使用神经网络方法进行修复是必要的, 并且结果是可靠的. 在计算 α 衰变半衰期时, 神经网络方法的修正较小, 但可以得到更准确的结果.




图 3 Po, Th, Rf 同位素 α 衰变能和半衰期的理论结果与实验值的比较

Fig. 3. Comparison of theoretical results and experimental values for Po, Th, Rf isotope α decay energy and half-life.

最近的实验合成了 ^{214}U , 并测量了其 α 衰变能和半衰期^[49]. 此外, 文献^[49] 给出了 ^{216}U 和 ^{218}U 更精确的 α 衰变能量和半衰期测量结果 (这些核未参与 NN 的训练). 表 1 列出了本文提出的模型和其他常见质量模型的实验结果和计算结果^[20,50]. 从表 1 可以看出, 本文提出的方法可以很好地计算文献^[49] 中铀核的 α 衰变能. 该模型包含了 NN 方法, 可以很好地计算出缺中子核素的 α 衰变能. α 衰变半衰期与实验值相差较小. 这可以为今后研究缺中子重核的衰变性质提供理论指导.

本文的主要目标之一是寻找超重核 α 衰变中的稳定岛, 因此有必要研究神经网络方法在超重核区域的修正结果是否可靠. 文献^[11] 列出了 40 个超重核 α 衰变的 α 衰变能和半衰期, 本文选取 F1 的同位素作为参考. 图 4 为 F1 同位素链的衰变能和

表 1 其他文献 α 衰变能和半衰期与本文工作的计算结果进行了比较

Table 1. The α decay energy and half-life of other reference are compared with the calculation results of the work in this paper.

		Q_α/MeV			
同位素	文献[49]	(2)式	NN	文献[50]	文献[20]
^{214}U	8.696	10.054	8.865	9.008	8.45
^{216}U	8.532	10.047	8.587	8.532	8.36
^{218}U	8.773	9.897	8.795	8.801	8.51
		$T_{1/2}/\text{ms}$			
同位素	文献[49]	UDL	UDL ^{NN}		
^{214}U	0.52+0.63 -0.21	0.77	0.40		
^{216}U	2.25+0.95 -0.4	2.12	1.93		
^{218}U	0.65+0.08 -0.07	0.34	0.40		

半衰期, 其中黑色实心方块表示文献 [11] 中的实验值, 红色实心圆表示神经网络学习前的理论值, 蓝色实心三角形表示神经网络学习后的修正结果, 绿色实心反三角形表示 AME2016 中的 α 衰变能量和 NUBASE2016 中的半衰期 [25]. 从图 3 和图 4 可以看出, 奇偶效应对于 α 衰变半衰期是显著的, 而对于衰变能则不显著. α 粒子在奇 A 核或奇奇核中比在偶偶核中更难形成, 这对衰变半衰期有影响. 而衰变能是母核、子核和 α 粒子结合能之差, 母核和子核是相同的奇 A 核或奇奇核, 因此它们不受奇核阻塞效应的影响. 从图 4 可以看出, 利用神经网络方法计算 α 衰变能可以显著提高计算结果. 对于 α 衰变半衰期的计算, 神经网络方法似乎并没有太大的提高, 可能是因为神经网络训练中涉及的超重核数量较少, 因而外推能力相对较差. 但总体结果还是令人满意的, α 衰变半衰期的理论值与实验值的最大偏差在 4 倍以内. 值得注意的是, 在 (2) 式中, 没有考虑原子核的壳效应. 但在修正后的神经网络方法给出的结果中, 在理论预测的中子幻数 $N = 184$ 附近出现了一个清晰的壳结构. 这是不可思议的, 神经网络方法确实具有强大的学习能力. 因此可以相信, 神经网络方法可以作为系统研究超重核稳定性的工具. 在计算 α 衰变半衰期时, 我们还可以看到, 中子数 $N = 184$ 附近的超重核具有较长的半衰期. 这是由于壳效应造成的. 此外, 超重核的壳层可能较弱, 因此 $N = 184$ 附近的奇 A 核由于奇核子阻塞效应而具有较长的半衰期是合理的.




图 4 Fl 同位素 α 衰变能和半衰期的理论结果与实验值比较
Fig. 4. Comparison of theoretical results and experimental values for Fl isotope α decay energy and half-life.

为了便于比较其他模型的进展, 参考文献 [51] 中基于宏观-微观质量模型结合径向基函数进行了两次校正, 再现了 AME2016 中的质量, 均方差偏差 (RMSD) 为 149 keV, 为了进一步测试神经网络方法的可靠性, 表 2 列出了质子数为 $Z = 120$ 的母核同位素 (偶偶核) 的衰变链. 将 α 衰变能与文献 [52] 中计算的 α 衰变能量进行比较. 可以看出, (2) 式计算的结果与宏观-微观质量模型结合径向基函数的结果 [51] 偏差较大, 但经过神经网络方法修正后, 偏差显著减小. 这也表明基于神经网络方法结合类液滴模型公式计算的 α 衰变能是合理的.

根据 (5) 式和 (8) 式, 可以给出超重核 α 衰变的稳定区域. 图 5 分别绘制了由 (2) 式和 (5) 式计算得到的超重核 α 衰变能. 可以看出, 用神经网络方法训练后, 已知中子幻数 $N = 152$ 和 162 的 Q_α 呈现了相应的壳结构. 除理论模型预测的双幻核 ^{298}Fl 外, 在 $Z = 126, N = 228$ 附近可能还存在另一个超重核稳定中心, 由于该区域距离目前的实验测量很远, 可靠性需要进一步验证. 此外, 发现随着中子数的增加, 衰变能量的变化不是逐渐减小, 而是再次增大. 这可能是由于训练过程中缺乏丰中子核 α 衰变的实验数据所致. 当然 α 衰变主要出现于缺中子的原子核中, 对于丰中子核, 则还有其他衰变模式, 比如 β 衰变、结团放射性和自发裂变等.

表 2 母核质子数为 $Z = 120$ 的同位素 α 衰变链的预测. 第 1 列为母核, 第 2 列为文献 [52] 计算的 α 衰变能量, 第 3 列为 (2) 式计算的 α 衰变能量, 第 4 列为神经网络学习后的衰变能量, 第 5 列为使用 (8) 式计算的 α 衰变半衰期, 第 6 列为使用神经网络学习后的 α 衰变半衰期

Table 2. Prediction of the α decay chains of isotopes with proton number $Z = 120$ in the parent nucleus. The first column in the table shows the parent nucleus, the second column shows the α decay energy calculated in Ref. [52], the third column shows the decay energy calculated in Eq. (2), the fourth column shows the decay energy after neural network learning, the fifth column shows the α decay half-life calculated using the Eq. (8), and the sixth column shows the α decay half-life after learning using the neural network.

核素	Q_{α}^{LZU}	$Q_{\alpha}^{\text{Eq. (2)}}$	Q_{α}^{NN}	UDL	UDL ^{NN}
³⁰⁰ 120	13.05	9.83	13.03	-5.45	-5.59
²⁹⁶ 118	11.89	9.85	11.75	-3.21	-3.35
²⁹² 116	10.64	10.34	10.08	-1.44	-1.57
²⁸⁸ 114	9.82	10.92	10.03	0.03	-0.09
²⁸⁴ 112	10.18	11.14	9.61	0.59	0.47
²⁸⁰ 110	10.04	10.74	10.63	-2.88	-3.19
³⁰² 120	12.81	9.63	13.31	-6.05	-6.43
²⁹⁸ 118	11.86	9.34	11.85	-3.48	-3.86
²⁹⁴ 116	10.59	9.62	10.66	-1.12	-1.49
²⁹⁰ 114	9.56	10.20	9.69	0.99	0.63
²⁸⁶ 112	9.23	10.64	9.01	2.45	2.10
²⁸² 110	9.52	10.56	10.34	-2.16	-2.74
³⁰⁴ 120	12.66	9.57	13.64	-6.73	-7.25
³⁰⁰ 118	11.75	8.97	12.04	-3.94	-4.46
²⁹⁶ 116	10.56	8.98	10.62	-1.03	-1.54
²⁹² 114	9.18	9.45	9.39	1.91	1.43
²⁸⁸ 112	8.95	10.01	8.43	4.43	3.99
²⁸⁴ 110	8.48	10.21	9.94	-1.09	-1.84
³⁰⁶ 120	13.29	9.61	13.99	-7.41	-8.01
³⁰² 118	11.65	8.76	12.29	-4.54	-5.13
²⁹⁸ 116	10.63	8.45	10.66	-1.17	-1.74
²⁹⁴ 114	8.85	8.72	9.14	2.67	2.16
²⁹⁰ 112	8.49	9.28	7.91	6.41	6.00
²⁸⁶ 110	8.12	9.71	9.43	0.35	-0.51
³⁰⁸ 120	13.07	9.73	14.32	-8.05	-8.68
³⁰⁴ 118	12.36	8.69	12.59	-5.20	-5.82
³⁰⁰ 116	10.57	8.08	10.77	-1.49	-2.06
²⁹⁶ 114	8.53	8.07	8.97	3.21	2.77
²⁹² 112	8.30	8.52	7.49	8.17	7.87
²⁸⁸ 110	7.68	9.06	8.86	2.16	1.12
³¹⁰ 120	11.61	9.85	14.60	-8.57	-9.21
³⁰⁶ 118	12.61	8.73	12.89	-5.86	-6.46
³⁰² 116	11.37	7.85	10.93	-1.94	-2.44
²⁹⁸ 114	8.32	7.53	8.89	3.47	3.18
²⁹⁴ 112	7.96	7.78	7.20	9.44	9.26
²⁹⁰ 110	7.56	8.33	8.26	4.24	2.91

图 6 分别列出了使用 UDL 公式和 UDL^{NN} 计算的 α 衰变半衰期. 可以看出, 两种方法计算出的 α 衰变半衰期除了在 $N = 126$ 附近和极丰中子核区存在较大差异外, 差别不大. 这是因为神经网络

方法的学习过程中缺少丰中子核 α 衰变的数据, 所以给出的结果不同. 值得注意的是, 两种方法给出的稳定区域几乎相同. 因此可以预测超重核稳定岛的位置, 这可能为未来的实验提供理论帮助.

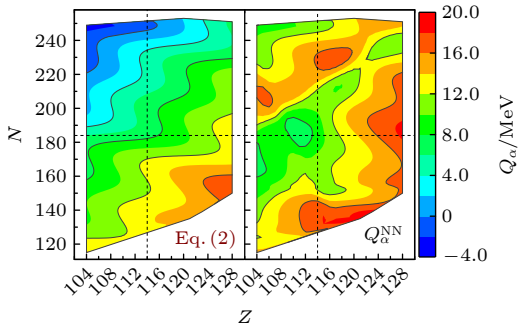


图 5 利用 (2) 式(左)和神经网络模型修正(右)预测超重核 α 衰变能量

Fig. 5. Prediction of α decay energy of superheavy nuclei using Eq. (2) (left) and neural network model correction (right).

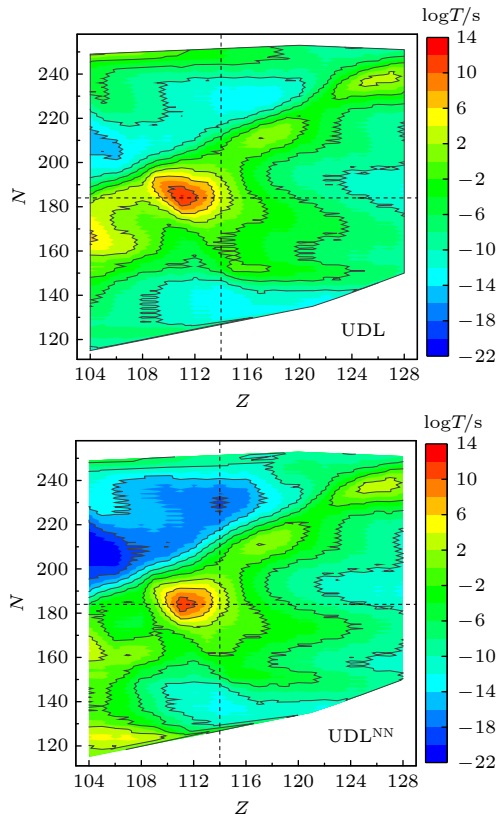


图 6 利用 UDL 公式和 UDL^{NN} 计算 α 衰变半衰期

Fig. 6. Calculated α decay half-life using the UDL formula and the UDL^{NN} .

4 结 论

本工作的主要目标是探索超重核的稳定区域. 采用原子核液滴模型计算 α 衰变能量, 并使用 NN 方法进行校正. 质子数大于等于 82 的原子核 α 衰变能的实验值与理论值的 RMSD 从 663.5 keV 减小到 89.2 keV. 然后用 UDL 公式计算 α 衰变的

半衰期, 再用神经网络方法进行校正. 最近的实验结果证明了我们提出的方法的可靠性. 在此基础上, 我们预测了超重稳定岛的位置.

参考文献

- [1] Akrawy D T, Poenaru D N 2017 *J. Phys. G: Nucl. Part. Phys.* **44** 105105
- [2] Pahlavani M R, Joharifard M 2019 *Phys. Rev. C* **99** 044601
- [3] Deng J G, Zhang H F 2020 *Phys. Rev. C* **102** 044314
- [4] Khuyagbaatar J, Heßberger F P, Hofmann S, Ackermann D, Burkhard H G, Heinz S, Kindler B, Kojouharov I, Lommel B, Mann R, Maurer J, Nishio K 2020 *Phys. Rev. C* **102** 044312
- [5] Olesen E, Nazarewicz W 2019 *Phys. Rev. C* **99** 014317
- [6] Zhao T L, Bao X J 2018 *Phys. Rev. C* **98** 064307
- [7] Oganessian Y T, Utyonkov V K, Lobanov Yu V, Abdullin F Sh, Polyakov A N, Sagaidak R N, Shirokovsky I V, Tsyganov Yu S, Voinov A A, Gulbekian G G, Bogomolov S L, Gikal B N, Mezentsev A N, Iliev S, Subbotin V G, Sukhov A M, Subotic K, Zagrebaev V I, Vostokin G K, Itkis M G 2006 *Phys. Rev. C* **74** 044602
- [8] Inauguration of the factory of superheavy elements, <http://www.jinr.ru/posts/inauguration-of-the-factory-of-superheavy-elements/>, accessed: 2019-05-25.
- [9] Hofmann S, Mnzenberg G 2000 *Rev. Mod. Phys.* **72** 733
- [10] Sobiczewski A, Pomorski K 2007 *Prog. Part. Nucl. Phys.* **58** 292
- [11] Oganessian Y T, Sobiczewski A, Ter-Akopian G M 2017 *Phys. Scr.* **92** 023003
- [12] Oganessian Y T, Utyonkov V K 2015 *Nucl. Phys. A* **944** 62
- [13] Möller P, Nix J R, Kartz K L 1997 *At. Data Nucl. Data Tables* **66** 131
- [14] Chasman R. R., Ahmad I, Friedman A M, Erskine J R 1977 *Rev. Mod. Phys.* **49** 833
- [15] Mayer M G 1948 *Phys. Rev.* **74** 235
- [16] Haxel O, Jensen J H D, Suess H E 1949 *Phys. Rev.* **75** 1766
- [17] Mayer M G 1949 *Phys. Rev.* **75** 1969
- [18] Koura H, Tachibana T, Uno M, Yamada M 2005 *Prog. Theor. Phys.* **113** 305
- [19] Wang N, Liu M 2010 *Phys. Rev. C* **81** 044322
- [20] Möller P, Sierk A J, Ichikawa T, Sagawa H 2016 *At. Data Nucl. Data Tables* **109** 1
- [21] Goriely S, Chamel N, Pearson J M 2009 *Phys. Rev. Lett.* **102** 152503
- [22] Goriely S, Hilaire S, Girod M, Péru S 2009 *Phys. Rev. Lett.* **102** 242501
- [23] Zhao P W, Li Z P, Yao J M, Meng J 2010 *Phys. Rev. C* **82** 054319.
- [24] Dong T, Ren Z 2010 *Phys. Rev. C* **82** 034320
- [25] Wang M, Audi G, Kondev F G, Huang W J, Naimi S, Xu X 2017 *Chin. Phys. C* **41** 030003
- [26] Geiger H, Nuttall J 1911 *London Edinburgh Dublin Philos. Mag. J. Sci.* **22** 613
- [27] Wang Y Z, Wang S J, Hou Z Y, Gu J Z 2015 *Phys. Rev. C* **92** 064301
- [28] Gazula S, Clark J, Bohr H 1992 *Nucl. Phys. A* **540** 1
- [29] Gernoth K, Clark J, Prater J, Bohr H 1993 *Phys. Lett. B* **300** 1
- [30] Gernoth K, Clark J 1995 *Neural Netw.* **8** 291
- [31] Athanassopoulos S, Mavrommatis E, Gernoth K A, Clark J W 2004 *Nucl. Phys. A* **743** 222
- [32] Bayram T, Akkoyun S, Kara S O 2014 *Ann. Nucl. Energy* **63**

- 172
- [33] Utama R, Piekarewicz J 2017 *Phys. Rev. C* **96** 044308
- [34] Utama R, Piekarewicz J, Prosper H B 2016 *Phys. Rev. C* **93** 014311
- [35] Zhang H F, Wang L H, Yin J P, Chen P H, Zhang H F 2017 *J. Phys. G* **44** 045110
- [36] Niu Z M, Liang H Z 2018 *Phys. Lett. B* **778** 48
- [37] Levenberg K 1944 *Quart. Appl. Math* **2** 164
- [38] Marquardt D 1963 *SIAM J. Appl. Math* **11** 431
- [39] Press W, Teukolsky S, Vetterling W, Flannery B 1992 *Numerical Recipes in Fortran 77* (2nd Ed.) (Cambridge: Cambridge University Press) p678
- [40] Xu C, Ren Z Z 2006 *Phys. Rev. C* **74** 014304
- [41] Bao X J, Zhang H F, Zhang H F, Royer G, Li J Q 2014 *Nucl. Phys. A* **921** 85
- [42] Long W H, Meng J, Zhou S G 2002 *Phys. Rev. C* **65** 047306
- [43] Qi C, Xu F R, Liotta R J, Wyss R 2009 *Phys. Rev. Lett.* **103** 072501
- [44] Qi C, Xu F R, Liotta R J, Wyss R, Zhang M Y, Asawatangtrakuldee C, Hu D 2009 *Phys. Rev. C* **80** 044326
- [45] Ni D D, Ren Z Z, Dong T K, Xu C 2008 *Phys. Rev. C* **78** 044310
- [46] Parkhomenko A, Sobiczewski A 2005 *Acta Phys. Pol. B* **36** 1363
- [47] Royer G 2000 *J. Phys. G* **26** 1149
- [48] Zhao T L, Bao X J, Guo S Q 2018 *J. Phys. G* **45** 025106
- [49] Zhang Z Y, Yang H B, Huang M H, Gan Z G, Yuan C X, Qi C, Andreyev A N, Liu M L, Ma L, Zhang M M, Tian Y L, Wang Y S, Wang J G, Yang C L, Li G S, Qiang Y H, Yang W Q, Chen R F, Zhang H B, Lu Z W, Xu X X, Duan L M, Yang H R, Huang W X, Liu Z, Zhou X H, Zhang Y H, Xu H S, Wang N, Zhou H B, Wen X J, Huang S, Hua W, Zhu L, Wang X, Mao Y C, He X T, Wang S Y, Xu W Z, Li H W, Ren Z Z, Zhou S G 2021 *Phys. Rev. Lett.* **126** 152502
- [50] Wang N, Liu M, Wu X Z, Meng J 2014 *Phys. Lett. B* **734** 215
- [51] Ma N N, Zhang H F, Bao X J, Zhang H F 2019 *Chin. Phys. C* **43** 044105
- [52] Audi G, Kondev F G, Wang M, Huang W J, Naimi S 2017 *Chin. Phys. C* **41** 030001

Research on stability and decay properties of superheavy nuclei based on neural network method

CHEN Haijun ^{1)†} SHENG Haowen ¹⁾ HUANG Wenhao ¹⁾ WU Binqi ¹⁾
 ZHAO Tianliang ^{2)‡} BAO Xiaojun ^{2)††}

1) (School of Digital Media Engineering and Humanities, Hunan University of Technology and Business, Changsha 410205, China)

2) (School of Physics and Electronic, Hunan Normal University, Changsha 410081, China)

(Received 4 June 2025; revised manuscript received 7 August 2025)

Abstract

This study aims to develop a highly accurate method of predicting α -decay energy (Q_α) of superheavy nuclei (SHN) and to identify the region of enhanced stability (the “island of stability”) based on α -decay properties. Improving the accuracy of Q_α calculations is crucial for reliably predicting α -decay half-lives, which are essential for identifying newly synthesized superheavy elements.

A modified liquid-drop model (LDM) formula for calculating Q_α is proposed, eliminating explicit dependence on magic numbers to improve universality. However, the initial LDM formula alone yields a high root-mean-square deviation (RMSD) of 663.5 keV compared with experimental Q_α values from the AME2016 database for 369 nuclei with $Z \geq 82$. In order to significantly improve accuracy, a neural network (NN) method is combined with the LDM formula. For a feedforward backpropagation (BP) neural network with a 2-21-1 architecture (2 input neurons: proton number Z and mass number A ; 21 hidden neurons; 1 output neuron), the correction term δQ_α is developed. The network is trained using the Levenberg-Marquardt algorithm on a dataset of 369 nuclei (319 training, 50 validation). The final Q_α prediction is given by $Q_\alpha^{\text{NN}} = Q_\alpha^{\text{Eq. (2)}} + \delta Q_\alpha$. The unified decay law (UDL) formula is then used to calculate α -decay half-lives ($T_{1/2}$), with and without NN correction (denoted as UDL and UDL^{NN}). The main results obtained are listed below.

† Corresponding author. E-mail: chj_yh@163.com

‡ Corresponding author. E-mail: zhaotl@hunnu.edu.cn

†† Corresponding author. E-mail: baoxiaojun@hunnu.edu.cn

1) Improved Q_α accuracy: The NN correction dramatically reduces the RMSD between calculated and experimental Q_α values from 663.5 keV (LDM alone) to 89.2 keV.

2) Capturing shell effects: Remarkably, although there is no explicit input of nuclear shell information, the NN-corrected Q_α predictions clearly reproduce known shell structures, including the expected shell closure near $N = 184$ for superheavy nuclei. This is evident in the systematic lowering of predicted Q_α values (implying increased stability) around the predicted doubly magic nucleus ^{298}Fl ($Z = 114$, $N = 184$) and other known shell closures (e.g., $N = 152$, $N = 162$).

3) Half-life predictions: Using the NN-corrected Q_α in the UDL formula (UDL^{NN}) further refines $T_{1/2}$ predictions, reducing the RMSD from 0.631 (UDL alone) to 0.423. The method reliably reproduces experimental half-lives and shell-related features, such as a significant increase in $T_{1/2}$ near shell closure (e.g. $N = 126$) and odd-A/odd-odd nuclei due to blocking effects.

4) Validation: Predictions for recently synthesized neutron-deficient uranium isotopes $^{214,216,218}\text{U}$ agree well with new experimental data of Q_α and $T_{1/2}$. Predictions for Fl isotopic chains also show good agreement with experimental trends.

5) Stability island prediction: Maps of predicted Q_α and $T_{1/2}$ in the superheavy region consistently identify minimum value (indicating maximum stability) near the theoretically predicted double magic nucleus ^{298}Fl . A potential secondary stability center near $Z = 126$ and $N = 228$ is suggested, but further verification is needed. The longest predicted region of $T_{1/2}$ coincides with the $N = 184$ shell closure.

The conclusions drawn from the above findings are as follows. Integrating a neural network with a modified liquid-drop model formula provides a powerful and accurate method for predicting α -decay energies (Q_α) of heavy and superheavy nuclei. The NN successfully learns and corrects complex shell effects implicitly, significantly improving prediction accuracy (RMSD reduced by $\sim 85\%$). By combining the UDL formula, this method yields reliable α -decay half-lives. The results strongly confirm the existence and location of the predicted “island of stability” centered on the double magic nucleus ^{298}Fl , providing valuable theoretical guidance for future experiments on the synthesis and identification of superheavy elements.

Keywords: superheavy nuclei, neural network, nuclear masses, α decay

PACS: 23.60.+e, 21.10.Tg, 25.85.Ca

DOI: [10.7498/aps.74.20250720](https://doi.org/10.7498/aps.74.20250720)

CSTR: [32037.14.aps.74.20250720](https://cstr.cn/32037.14.aps.74.20250720)

基于神经网络方法研究超重核的稳定性和衰变性质

陈海军 盛浩文 黄文豪 吴彬琪 赵天亮 包小军

Research on stability and decay properties of superheavy nuclei based on neural network method

CHEN Haijun SHENG Haowen HUANG Wenhao WU Binqi ZHAO Tianliang BAO Xiaojun

引用信息 Citation: *Acta Physica Sinica*, 74, 192301 (2025) DOI: 10.7498/aps.74.20250720

CSTR: 32037.14.aps.74.20250720

在线阅读 View online: <https://doi.org/10.7498/aps.74.20250720>

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

Z = 118—120超重核 α 衰变性质的研究

Research on α decay properties of superheavy nuclei with Z = 118120

物理学报. 2025, 74(11): 112301 <https://doi.org/10.7498/aps.74.20240907>

基于神经网络方法研究 β 衰变释放粒子的平均能量数据

Average energy data of β decay nuclei based on neural networks

物理学报. 2025, 74(18): 182901 <https://doi.org/10.7498/aps.74.20250655>

基于神经网络的粒子输运问题高效计算方法

An efficient calculation method for particle transport problems based on neural network

物理学报. 2024, 73(7): 072802 <https://doi.org/10.7498/aps.73.20231661>

光谱诊断中神经网络快速分析模型及外推方法

Rapid analysis model and extrapolation method of neural network in spectral diagnostic

物理学报. 2025, 74(7): 078901 <https://doi.org/10.7498/aps.74.20241739>

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>

量子混合态的两种神经网络表示

Two types of neural network representations of quantum mixed states

物理学报. 2023, 72(11): 110301 <https://doi.org/10.7498/aps.72.20221905>