

基于 NSGA-III 的小型模块化铅冷快堆 智能优化研究

张涵, 胡赞, 郭瑞阳, 庄毅, 乔鹏瑞*

(中国原子能科学研究院 核工程设计研究所, 北京 102413)

摘要: 反应堆设计中通常存在多个优化目标, 影响因素众多且不同因素之间相互耦合, 给方案优化造成较大困难, 本文针对小型模块化铅冷快堆型号 QJMF-S 开展方案智能优化研究。选取 BP 神经网络算法加速临界参数求解, 提出了预测临界堆芯参数的训练流程, 模型预测误差约 0.5%, 选取 NSGA-III 算法进行反应堆方案的多目标自动寻优, 开展了初始取值范围、种群规模等超参数的调优方法研究, 给出了多样化的优化解集, 能够同时满足全自然循环、可运输、低浓铀等要求, 部分解相对于初始方案, 在反应堆高度、直径、总功率 3 个目标上实现了全面提升。本文结果揭示了算法超越人工优化的全局搜索能力和收敛性, 可为反应堆方案论证提供重要参考。

关键词: 神经网络; 遗传算法; 小型模块化反应堆; 铅冷快堆

中图分类号: TL371

文献标志码: A

文章编号: 1000-6931(2026)02-0257-11

doi: 10.7538/yzk.2025.youxian.0613

NSGA-III Based Intelligent Optimization for Small Modular Lead-cooled Fast Reactor

ZHANG Han, HU Yun, GUO Ruiyang, ZHUANG Yi, QIAO Pengrui*

(Department of Nuclear Engineering Design, China Institute of Atomic Energy, Beijing 102413, China)

Abstract: This study focused on the intelligent optimization design of small modular lead-cooled fast reactors (SM-LFRs). Addressing the complex issue of mutual coupling among multiple variables, multiple constraints, and multiple objectives in reactor design, it proposed an optimization framework integrating the BP neural network and NSGA-III algorithm, with the initial scheme of QJMF-S as the research object for exploration. This reactor model was intended to provide energy support for scenarios such as digital intelligence centers and remote areas. Its initial design adhered to principles including full natural circulation, transportability, and the use of low-enriched uranium. However, there was room for optimization in terms of size adaptability and scheme diversity, requiring intelligent methods to achieve efficient optimization. To improve optimization efficiency and accuracy, a BP neural network was used to construct an enrichment prediction model and innovatively proposes an input-output exchange training method. This method inverted the process originally used for calculating critical eigenvalues, ensuring that the generated schemes always meet criticality requirements while

significantly reducing the time consumed by a single calculation, thus laying the foundation for large-scale scheme comparison and selection. During model training, measures such as data preprocessing and early stopping mechanism were adopted to control errors and ensure prediction reliability. In the multi-objective optimization phase, the NSGA-III algorithm was selected, and optimization was carried out focusing on three core objectives of the reactor including total height, total diameter, and total power. The first two objectives needed to be as small as possible to meet transportation requirements, while the last one needed to be as large as possible to enhance energy supply capacity. In the process, key efforts were made to optimize hyperparameters such as the initial value range and population size. The hypervolume indicator was used to evaluate the convergence and diversity of the population, ensuring uniform coverage of the solution space. At the same time, constraints such as coolant flow rate, fuel enrichment, and linear power peak were strictly followed to screen schemes that meet safety and performance requirements. The optimization results show that this intelligent method breaks through the limitations of manual optimization and obtains a variety of quasi-Pareto frontier schemes. Some schemes achieve comprehensive improvements in the three core objectives and exhibit core configuration characteristics different from the initial scheme, which are more in line with the needs of natural circulation. This study not only verifies the feasibility of the optimization framework and provides key references for the scheme demonstration of related series of reactors, but also confirms its versatility, which can be extended to other multi-objective optimization scenarios in the field of nuclear engineering.

Key words: neural network; genetic algorithm; small modular reactor; lead-cooled fast reactor

反应堆的设计优化是典型的多变量、多约束和多目标的优化问题,由于目标与变量之间的逻辑链条较长、存在隐式关系以及不同参数之间的相互耦合,导致优化方向和多目标权衡的判断十分困难,依赖专家经验及人工试错,通常只能给出满意解而难以逼近最优解。对于高维目标优化问题,手动寻优难以遍历解空间而获得多样化的优解。同时单个方案的求解也需要较高计算成本,不具备大规模方案比选的条件。因此需要一种方案智能优化方法,在保证足够估算精度的前提下,自动高效地完成方案优化,且给出多样化的多目标权衡方案。

目前在核工程领域,已有一些基于人工智能算法赋能方案设计优化的研究^[1],一类是数据驱动的机器学习算法,通过构建代理模型加快预测和决策速度^[2-3];另一类是寻优算法,其基于经验规则或直观感受来寻找问题近似最优解,在复杂问题中能够在合理的时间内得到一个足够好的解,如基于 NSGA-III 算法实现反应堆三维屏蔽结构优化等^[4-8]。这两类算法也可结合使用,例如毛婕等^[9]耦合 NSGA-II 与神经网络优化中子- γ 屏蔽,

实现屏蔽智能优化;韦子豪等^[10]建立了自适应神经网络提供堆芯参数,结合遗传算法,通过给目标赋予权重间接实现多目标的换料方案优化;李琼等^[11]基于径向基代理模型与遗传算法实现反应堆堆芯的智能优化。目前关于全堆方案的多目标智能优化的研究还较少,本文受到这一思路启发,选择人工 BP 神经网络结合 NSGA-III 遗传算法开展全堆设计优化研究。

1 初始方案

小型模块化铅冷快堆“铅基魔方”瞄准数智中心或偏远地区能源供给等多元需求为其提供理想解决方案,目前已策划了一系列覆盖多个功率级别和技术路线的型号,本文选取其首个型号 QJMF-S 的初始方案作为优化对象。QJMF-S 的主要设计原则包括具备一回路全自然循环特性、可运输能力以及采用低浓铀。QJMF-S 初始设计方案中,反应堆主要参数列于表 1,堆本体示意图如图 1 所示。该方案采用纯铅冷却剂,热功率 50 MW,堆芯寿期 3 650 EFPD,采用一体化池式布置,动力转换搭配超临界二氧化碳布雷顿循环,采用二氧

表 1 QJMF-S 初始方案主要参数
Table 1 QJMF-S preliminary design key parameters

参数	数值	参数	数值
堆热功率, MW	50	堆芯出入口平均温度, °C	400/540
堆芯寿期, EFPD	3 650	堆本体尺寸($D \times H$)	3.5 m×6.84 m
换料周期, a	15	自然循环能力, %FP	100
堆芯直径, m	1.8	棒栅距/棒径(p/d)	1.35
活性区高度, m	0.9	燃料棒径, mm	9.6
冷却剂平均流速, m/s	0.263 8	富集度, %	18




图 1 堆本体示意图

Fig. 1 Reactor vessel schematic diagram

化铀燃料。

QJMF-S 初始方案中堆芯的直径为 3.5 m, 超出了标准集装箱的可运输尺寸, 需要进一步优化以增强灵活部署能力。此外, 瞄准“铅基魔方”

未来系列化的型号方案设计需求, 需要基于初始方案的反应堆构型设计不同尺寸、功率的多样化方案, 以适应不同场景的需求。因此有必要开发智能化的反应堆多目标优化方法, 以实现反应堆方案的智能化交付。

2 方案优化框架

图 2 为反应堆主要决策变量对目标、限值产生影响的逻辑网络。以全自然循环约束为例, 自然循环能力取决于冷热阱温差、一回路压降、反应堆高度, 其中一回路压降主要由堆芯压降和换热器压降构成, 堆芯压降则主要受到棒径、 p/d 、堆芯直径、堆芯高度 4 个因素影响。

决策变量有 7 个, 为了简化考虑, 其中冷热阱温差和均匀因子取常数, 因此实际变量为 5 个。约束条件为 5 个, 输入变量直接影响或通过中间变量间接影响约束参数。从中间变量中选取




图 2 设计因素影响逻辑网络

Fig. 2 Design factor influencing logical network

总高度、总直径及总功率3个总体性变量作为设计者进一步评价方案的优化目标,希望反应堆高度和直径尽量小而总功率尽量大,在约束条件下这三者相互竞争,且没有绝对的优先级关系,因此对于多目标问题,设计者希望能获得目标值更加多样化的解集,从而为不同场景需求匹配更合适的方案。

这一逻辑网络也是用于遗传算法寻优的反应堆模型的雏形,每个方案中的决策变量作为个体的染色体,约束及优化目标作为个体适应度评价依据。遗传算法优化流程如图3所示,从初始种群开始,通过交叉、变异、组合等遗传算子产生新的子代,通过求解方案参数,获得约束条件和优化目标的参数值,从而完成个体适应度的评价,再进行种群筛选及多样化选择,从而得到下一代种群。




图3 总体优化流程

Fig. 3 Overall optimization framework

群。通过不断进化,每一代种群的表现都优于上一代,最终种群逐渐接近最优解,得到优化方案的解集。

反应堆求解模型的具体架构如图4所示,包含参数解析求解模块、压降求解模块和富集度预测模块:参数解析求解模块用于完成基于解析关系式的参数求解,例如根据功率、流道面积、堆芯进出口温差求解冷却剂流速,根据功率、燃料棒数、活性区高度求解平均线功率等;压降求解模块首先采用牛顿迭代法完成主工艺参数匹配,具体而言,先假设1个初始化的换热器二次侧压降 Δp_0 ,通过热工水力学计算得到所需的换热器尺寸,再根据实际结构评估其二次侧压降 Δp_1 ,与初始假设 Δp_0 对比判断是否收敛,若不收敛则将换热器二次侧压降设定为 Δp_1 重新计算所需换热器尺寸,直至收敛,最后根据模型求解一回路压降,继而求得全自然循环所需高度差与反应堆总高度;富集度预测模块通过神经网络训练得到预测模型,获得临界堆芯方案的富集度快速准确预测。

3 富集度预测

3.1 BP神经网络

本文采用全连接的反向传播神经网络(BPNN),




图4 反应堆求解模型

Fig. 4 Reactor solution model

整个训练过程保持统一的网络结构。网络的超参数及结构设计已进行了调优。BP神经网络采用两层隐藏层架构,输入层节点数4,第一隐藏层节点数12,第二隐藏层节点数8,输出层节点数1。所有层均采用Sigmoid激活函数。输入参数包括堆芯高度、堆芯直径、 p/d 、富集度,初次训练的样本通过每个输入参数在给定初始范围内随机均匀分布的方式生成,各参数的分布范围如下:堆芯高度为40~200 cm、堆芯直径为40~200 cm、 p/d 为1.01~1.61、富集度为10%~30%。

在训练之前的数据预处理阶段,所有输入参数经过MIN-MAX标准化处置至[0, 1]区间,防止不同参数尺度差异导致的训练劣化。训练阶段,训练样本数量为1 000,按照训练集占比80%、测试集占比20%进行随机划分,即训练集800个,测试集200个,并重复多次训练以实现交叉验证的效果。每次训练的样本分批加载,1批样本数为16,每次加载时对样本进行洗牌,减少模型对输入数据的依赖性。采用早停机制判断是否收敛,防止训练过拟合,即如果在持续100代之内误差均未下降超过 1×10^{-5} 则退出训练。

3.2 交换训练法

本文的神经网络模型主要是用来代替蒙特卡罗程序的临界计算过程,由于蒙特卡罗计算得到的是 k_{eff} ,但在实际堆芯设计中, k_{eff} 偏离1的方案没有意义。如果随机选取堆芯参数进行 k_{eff} 计算并基于临界度评价方案的适应度,则会浪费大量的计算资源。如果能假定某一个反应堆参数 X 不确定,通过代理模型快速预测堆芯临界所需 X ,则可保证始终生成临界堆芯方案,便于开展下一步方案优化。

本文的解决方案是将输入 X 和输出 k_{eff} 做交换再进行训练。首先随机抽取样本进行 k_{eff} 计算,然后将 k_{eff} 反过来作为输入参数,而将某一个输入参数 X 作为输出结果进行训练,这样得到的模型可以实现“给定 k_{eff} 预测参数 X ”,即令 k_{eff} 为1计算 X 。需要注意的是,输入参数 X 和 k_{eff} 之间可能非单射关系,即1个 k_{eff} 对应不止1个 X ,这种情况下的反向预测模型是无法收敛的,因此该方法只能用于 k_{eff} 随 X 单调变化的情形,例如 X 为富集度、活性区高度等。

本文将富集度作为该预测参数 X ,图5所示为

神经网络训练误差收敛曲线,预测的误差分布如图6所示,经过训练的神经网络模型能够在0.5%的平均误差范围内进行堆芯临界富集度的预测,单次计算耗时约2 ms,足以满足后续方案快速比选要求。




图5 神经网络训练误差收敛曲线

Fig. 5 Neural network training error convergence curve




图6 富集度预测误差分布

Fig. 6 Enrichment prediction error distribution

4 方案优化

4.1 NSGA-III算法

原始的遗传算法(GA)只能针对单个目标进行优化,对于多目标优化问题,非支配排序遗传算法(NSGA)更加适用。经过不断改良,Deb等^[12-14]提出第三代非支配排序遗传算法NSGA-III,其核心思想是通过引入1组覆盖整个目标空间的参考点,将种群中的个体与参考点相关联,用于在选择过程中引导搜索,以便更好地维持解在Pareto前沿上的均匀分布。本文采用NSGA-III算法进行多目标的反应堆方案寻优。

NSGA-III的算法流程如图7所示,种群规模为 N ,假设第 t 代开始,父代种群为 P_t ,经过交叉变异后生成子代 Q_t ,采用精英保留策略,将父代和子代组合为2倍大小的组合 R_t ,从中按照非支配层顺序依次挑选进入新种群,直至数量不小于 N ,形成新种群 S_t ,剩余的层级被丢弃。若 S_t 大小刚好满足则直接生成下一代种群 P_{t+1} ,更多情况下,需要从 F_1 层中选取部分个体进入 P_{t+1} ,所采用的选择策略为基于参考点连接的多样化保留策略。

对于约束项的处理参考了Deb提出的方法^[13],




图7 NSGA-III算法流程

Fig. 7 NSGA-III algorithm workflow

即对所有不符合约束项的样本,计算超出限值的幅度得到约束违反值 cvv ,按照 cvv 从小到大依次在可行解层级之后赋予非支配层级,即所有超出约束范围的样本层级都低于可行解。

NSGA-III的多样化保留策略如下:基于当前种群的目标值分布,进行动态归一化并构建归一化的超平面,如图8所示,从超平面中基于一定规则选取若干参考点,其分布应尽量均匀,并且能够覆盖整个解空间。参考点与理想点的连线为参考线,对所有个体计算与参考线点的投影距离,距离最近的参考线所对应的参考点则认为与该个体连接,也即该个体所覆盖的解空间可以用该参考点来表征。在多样化选择步骤中,对于当前种群尚未覆盖的参考点所连接的个体,赋予优先选择权,从而提供种群多样化的进化动力。




图8 3目标情况下的NSGA-III参考点示意图

Fig. 8 Reference point schematic diagram of NSGA-III for 3-objective case

图8中参考点的划分方式为超平面上每条边分为4段,内部则对应均匀分布,段数越多可以对应解空间更精细地刻画,同时也会带来计算成本的上升,需要结合目标数以及实际需求来确定。

4.2 QJMF-S设计优化

1) 优化问题

QJMF-S优化问题包括决策变量、约束条件和优化目标。

其中决策变量包含:堆芯直径、堆芯高度、燃料棒径、 p/d 、换热器宽度。

约束条件为:液态铅铋流速不大于1.8 m/s,燃料富集度不超过16%,线功率峰值不大于40 kW/m,反应堆总高度不超过10 m,反应堆总直径不超过2.5 m。需要说明的是,行业内一般认为流速控制在2.0 m/s以内可以有效降低铅铋的冲蚀效应,本研究取了一定的裕量,反应堆的尺寸限值参考了40英尺标准集装箱,但高度部分给堆顶盖上方的设备留出约2 m的空间。

优化目标包括:总高度、总直径、总功率。其中前2个目标的优化方向为尽量小,总功率的优化方向为尽量大,因此在模型中实际取负的总功率作为优化目标。

2) 超参数设置

首先根据Deb等^[14]提出的推荐值,在3个优化目标下选取91个参考点,对应每个目标的分段数12,种群数应不少于参考点且为4的倍数,取为92。交叉算子采用模拟二进制交叉SBX,适用于连续取值的变量,交叉系数 $\eta_c=20$ 。变异算子采用均匀变异策略,变异幅度 $\text{amp}=1$ 、变异概率 $p_m=15\%$ 。

3) 初始取值范围

首先按照核工程设计经验确定较宽的初始随机取值范围,经过少量的迭代计算后,决策变量的实际分布如图9所示,图中绿色线代表初始取值范围下限,橙色线代表上限。存在堆芯直径的上限取值太高,而堆芯高度下限取值过低等问题,不利于种群的全局多样化搜索,因此根据实际的染色体分布范围调整初始取值,使得能够覆盖解空间并且不超出太多。需要说明,堆芯高度的上限无法再增加,这是因为在富集度预测模块中,训练样本的堆芯高度只取到200 cm,因此如果对更高的堆芯进行富集度预测,将无法保证结果预测精




图9 根据经验选取初始取值范围及实际分布

Fig. 9 Selection of initial value range based on experience and actual distribution

度。最终确定的初始随机取值范围列于表2,该取值范围有部分未落在神经网络训练的样本范围内,可能存在一定程度的外推误差,后续工作需要改进。


表2 经过优化的初始取值范围
Table 2 Optimized initial value range

染色体	堆芯直径/cm	堆芯高度/cm	棒径/cm	p/d	换热器宽度/cm
初始最小	29.50	31.41	0.40	1.01	17.93
初始最大	128.11	200.00	1.85	1.76	116.51

4) 种群数调整

虽然理论上种群数应接近并不低于参考点数,尽量保证个体和参考点一一对应,但经过尝试发现,对于该反应堆设计问题,在通过理想点和极值点确定的参考平面中,只有45%左右的解空间是实际可覆盖区域,因此种群数应尽量匹配这一比例。通过固定91个参考点,调整种群数量,最

终目标值分布情况的变化如图10所示。当种群数为12、22、32时,目标值无法均匀覆盖解空间,种群数42时能基本一一对应,而当种群数为52、62时,有部分个体之间距离较近,超出了所需的种群规模。如图11所示,对比不同种群规模的计算耗时,时间复杂度近似为 $O(n)$ 。综合考虑结果多样性与计算效率,并留出裕量,最终选取44个



种群数: a——12; b——22; c——32; d——42; e——52; f——62

图10 不同种群规模的解空间覆盖情况

Fig. 10 Solution space coverage under different population sizes




图 11 种群规模对计算耗时的影响

Fig. 11 Impact of population size on computation time

体的种群规模。

5) 优化过程

采用超体积指标表征种群的收敛情况,其通过事先指定一个所有维度上均大于样本极大值的参考点,评估所有参考点与样本点之间所构成超立方体共同覆盖的区域体积,适用于理论前沿未知问题,可综合评估收敛性与多样性。本问题选取的参考点为 [10 m, 2.5 m, 18 MW], 并将各维度上的值归一化至 [0, 1] 再进行超体积计算。QJMF-S 超体积指标收敛情况示于图 12, 由图 12 可知, 在 100 代左右, 超体积指标已接近稳定。




图 12 QJMF-S 超体积指标收敛情况

Fig. 12 Convergence status of objective values for QJMF-S

6) 优化结果

图 13 为最终代种群染色体分布。图 13 由数据点分布和核密度曲线组成, 反映了最终代的染色体归一化分布特性。所有个体均处于初始随机分布范围内 (0~1), 代表初始范围设置合理。图 14 为最终代归一化目标值路径, 可看到 3 个优化目标的分布均匀度较理想。

图 15 为各目标值在二维的分布情况, 左下角为 3 个目标的相关性分析, 虚线为线性拟合的直线, 右上角对称位置显示了拟合度。对角线位置展示了各目标自身分布的直方图。图 16 为最终代目标值三维分布, 实现了对解空间较为均匀的




图 13 最终代种群染色体分布

Fig. 13 Final generation population chromosome distribution




图 14 QJMF-S 最终代归一化目标值路径

Fig. 14 Normalized objective value path of final generation for QJMF-S




图 15 QJMF-S 最终代目标相关性分析

Fig. 15 Objective correlation analysis of final generation for QJMF-S

覆盖, 构成帕累托前沿的逼近。

最终代方案中, 与初始方案相比, 3 个优化目标均更优的方案数量有 6 个, 如表 3 所列, 这 6 个解均构成初始方案的支配解。此外, 可以看到优




图 16 QJMF-S 最终代优化结果
Fig. 16 Final optimization result for QJMF-S

化方案中普遍采用“瘦长”堆芯而非初始方案的“矮胖”堆芯,推测其原因是缩小堆芯直径带来的堆芯沿程阻力压降上升相对于换热器的阻力压降的下降更少,从而更有利于实现自然循环,且均采用更粗棒径,这揭示了人工优化的局限性,相对而言,启发式算法不会受到以往经验的干扰。

此外,对最优的 44 个方案按照潜在的应用场景需求进行方案权衡,选出了 3 种偏好下的推荐方案,如表 4 所列,其中:方案 A 的总功率最大,适用于数智中心大功率供电;方案 B 的尺寸最紧凑,满足 20 英尺集装箱运输条件,可作为偏远地区灵

活部署的可移动核电源;方案 C 的冷却剂流速和最大线功率均较低,安全性最佳,可作为首堆进行示范验证。这表明遗传算法具有较强的全局多目标优化能力。

需要注意,从全面更优以及典型场景的最优方案来看,参数都落入了初始神经网络训练样本范围,其精度是可以保证的。

7) 计算效率

本研究代码实现语言为 Python3.0, 基于 AMD Ryzen 74800U 型号 CPU 完成优化计算,不依赖显卡。平均每代耗时为 12.8 s,共执行 500 代,总耗时约 1.78 h。平均每代计算的耗时统计列于表 5,遗传算法及神经网络预测部分均用时极少,而压降求解模块占了 95% 以上的计算时间,这是未来需要重点优化的方向。

5 结论

本文基于 BP 神经网络算法提出了堆芯临界参数输入输出交换训练法,可快速生成堆芯临界方案,在此基础上构建了反应堆快速求解框架。基于小型模块化铅冷快堆 QJMF-S 初始方案,采用 NSGA-Ⅲ 算法开展了反应堆多目标优化研究,对种群数量及初始取值范围进行了优化,基于超体积指标综合评估收敛性和多样性。相对于初始方案得到了多样化的解集,构建了准帕累托前沿,

表 3 最终代中全面更优的方案
Table 3 Comprehensively superior solutions in final generation

序号	堆芯高度/cm	堆芯直径/cm	棒径/cm	p/d	富集度/%	总高度/m	总直径/m	总功率/MW
初始方案	90.0	180.0	0.96	1.35	18.0	6.84	3.50	50.0
1	119.6	89.4	1.41	1.23	12.8	5.38	2.50	58.8
2	147.5	85.4	1.47	1.22	12.1	6.80	2.50	67.4
3	199.9	77.5	1.52	1.36	12.9	6.60	2.41	61.2
4	161.2	71.3	1.36	1.22	12.9	4.06	2.50	50.6
5	152.5	73.9	1.47	1.22	12.7	5.08	2.37	52.1
6	162.0	75.6	1.48	1.30	13.2	6.59	2.21	51.3

表 4 方案权衡矩阵
Table 4 Trade-off matrix

序号	堆芯高度/cm	堆芯直径/cm	p/d	富集度/%	冷却剂流速/(m/s)	最大线功率/(kW/m)	总高度/m	总直径/m	总功率/MW	适应场景
A	196.4	90.5	1.367	12.2	1.35	37.7	10.00	2.50	80.9	大功率
B	152.5	73.9	1.224	12.7	1.70	35.9	5.08	2.37	52.1	可移动
C	129.5	68.9	1.236	14.9	1.25	15.1	5.00	2.00	34.4	高安全

表5 各模块计算用时统计

Table 5 Statistics on computation time of each module

模块	每代用时/s
交叉	0.001 1
变异	0.000 0
解析参数求解	0.230 1
压降求解	12.374 8
富集度预测	0.093 5
组合	0.000 0
非支配层排序	0.015 5
多样化选择	0.070 7
总计	12.785 7

选取典型方案开展了典型场景的需求匹配分析。研究证明了反应堆快速求解框架及智能优化方法的可行性,为“铅基魔方”方案论证提供了重要参考。同时该智能优化方法具有通用性,可拓展应用于屏蔽优化、可燃毒物优化等其他的核工程多目标优化问题^[15-17]。后续工作需要改进神经网络的样本训练范围,避免预测外延误差以及加速压降求解过程,从而获得算法精度和效率上的进一步提升。

参考文献:

- [1] 谭思超,程家豪,李桐,等.核能领域智能设计优化的需求与应用分析[J].原子能科学技术,2025,59(7):1373-1385.
TAN Sichao, CHENG Jiahao, LI Tong, et al. Demand and application analysis of artificial intelligence in nuclear design optimization[J]. Atomic Energy Science and Technology, 2025, 59(7): 1373-1385(in Chinese).
- [2] 王端,王威策,潘翠杰,等.基于自适应BP神经网络的压水堆堆芯换料关键参数的预测方法[J].原子能科学技术,2020,54(1):112-118.
WANG Duan, WANG Weice, PAN Cuijie, et al. Prediction of key core parameter of PWR by adaptive BP neural network[J]. Atomic Energy Science and Technology, 2020, 54(1): 112-118(in Chinese).
- [3] 蔡宛睿,夏虹,杨波.基于BP神经网络的堆芯三维功率重构方法研究[J].原子能科学技术,2018,52(12):2130-2135.
CAI Wanrui, XIA Hong, YANG Bo. Research on three-dimensional power reconfiguration method of core based on BP neural network[J]. Atomic Energy Science and Technology, 2018, 52(12): 2130-2135(in Chinese).
- [4] 张华健,陈珍平,刘程伟,等.基于遗传算法的反应堆三维屏蔽结构高维多目标优化方法研究[J].核技术,2022,45(11):110603.
ZHANG Huajian, CHEN Zhenping, LIU Chengwei, et al. Study on many-objective optimization method for reactor 3D shielding structure based on genetic algorithm[J]. Nuclear Techniques, 2022, 45(11): 110603(in Chinese).
- [5] 胡彬和,刘兴民,孙征,等.基于NSGA-III算法的泳池式低温供热堆最优临界棒位搜索方法[J].原子能科学技术,2022,56(3):492-497.
HU Binhe, LIU Xingmin, SUN Zheng, et al. Optimal critical rod position search method based on NSGA-III for pool-type low-temperature heating reactor[J]. Atomic Energy Science and Technology, 2022, 56(3): 492-497(in Chinese).
- [6] 王晓坤,王端,齐少璞,等.基于遗传算法的钠冷快堆堆芯流量分区优化设计方法[J].原子能科学技术,2020,54(9):1660-1665.
WANG Xiaokun, WANG Duan, QI Shaopu, et al. Optimized design method for core flow zoning of sodium-cooled fast reactor based on genetic algorithm[J]. Atomic Energy Science and Technology, 2020, 54(9): 1660-1665(in Chinese).
- [7] 郑静,阎昌琪,王建军.基于复合-遗传算法的汽轮机组初步优化设计[J].原子能科学技术,2011,45(7):833-841.
ZHENG Jing, YAN Changqi, WANG Jianjun. Preliminary optimal design of turbine unit based on complex-genetic algorithm[J]. Atomic Energy Science and Technology, 2011, 45(7): 833-841(in Chinese).
- [8] 刘程伟,陈珍平,杨超,等.基于多目标进化算法的反应堆辐射屏蔽优化方法研究[J].原子能科学技术,2024,58(6):1261-1270.
LIU Chengwei, CHEN Zhenping, YANG Chao, et al. Research on reactor radiation shielding optimization method based on multi-objective evolutionary algorithm[J]. Atomic Energy Science and Technology, 2024, 58(6): 1261-1270(in Chinese).
- [9] 毛婕,宋英明,张泽寰,等.基于非支配排序遗传算法的核动力堆中子- γ 混合射线屏蔽智能优化[J].原子能科学技术,2021,55(5):892-900.
MAO Jie, SONG Yingming, ZHANG Zehuan, et al. Intelligent optimization for shielding of nuclear power reactor neutron- γ mixed radiation based on non-dominated sorting genetic algorithm[J]. Atomic Energy Science and Technology, 2021, 55(5): 892-900(in Chinese).
- [10] 韦子豪,王端,王东东,等.神经网络-遗传复合算法在压水堆堆芯换料设计中的应用[J].原子能科学技术,

- 2020(5): 825-834.
- WEI Zihao, WANG Duan, WANG Dongdong, et al. Application of neural network-genetic algorithm in refueling design of PWR core[J]. Atomic Energy Science and Technology, 2020(5): 825-834(in Chinese).
- [11] 李琼, 刘紫静, 王维嘉, 等. 基于径向基代理模型与小生境遗传算法的铅铋反应堆堆芯智能优化[J]. 核动力工程, 2022, 43(6): 93-100.
- LI Qiong, LIU Zijong, WANG Weijia, et al. Intelligent optimization of lead-bismuth reactor core based on radial basis function surrogate model and niche genetic algorithm[J]. Nuclear Power Engineering, 2022, 43(6): 93-100(in Chinese).
- [12] DEB K, JAIN H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, Part I: Solving problems with box constraints[J]. *IEEE Transactions on Evolutionary Computation*, 2014, 18(4): 577-601.
- [13] JAIN H, DEB K. An evolutionary many-objective optimization algorithm using reference-point based nondominated sorting approach, Part II: Handling constraints and extending to an adaptive approach[J]. *IEEE Transactions on Evolutionary Computation*, 2014, 18(4): 602-622.
- [14] DEB K, THIELE L, LAUMANN M, et al. Scalable multi-objective optimization test problems[C]//Proceedings of the 2002 Congress on Evolutionary Computation. USA: IEEE, 2002.
- [15] 杨寿海, 陈义学, 王伟金, 等. 多目标辐射屏蔽优化设计方法[J]. 原子能科学技术, 2012, 46(1): 79-83.
- YANG Shouhai, CHEN Yixue, WANG Weijin, et al. Multi-objective optimization design method of radiation shielding[J]. Atomic Energy Science and Technology, 2012, 46(1): 79-83(in Chinese).
- [16] 肖鹏, 王健, 刘仕倡, 等. 基于遗传算法的可燃毒物设计优化方法研究[J]. 原子能科学技术, 2021, 55(8): 1456-1463.
- XIAO Peng, WANG Jian, LIU Shichang, et al. Optimization method of burnable poison design based on genetic algorithm[J]. Atomic Energy Science and Technology, 2021, 55(8): 1456-1463(in Chinese).
- [17] 王梦琪, 郑征, 梅其良, 等. 基于非支配排序遗传算法NSGA-Ⅲ的多目标屏蔽智能优化研究[J]. 原子能科学技术, 2025, 59(2): 422-428.
- WANG Mengqi, ZHENG Zheng, MEI Qiliang, et al. Research on intelligent optimization of multi-objective shielding based on nondominated sorting genetic algorithm NSGA-Ⅲ[J]. Atomic Energy Science and Technology, 2025, 59(2): 422-428(in Chinese).