

# 基于 BP 神经网络的高通量铅铋反应堆 中子通量最大化设计方法研究

王 彤<sup>1,2</sup> 刘紫静<sup>1,2</sup> 赵鹏程<sup>1,2</sup> 肖英杰<sup>1,2</sup>

1(南华大学 核科学技术学院 衡阳 421001)

2(南华大学 湖南省数字化反应堆工程技术研究中心 衡阳 421001)

**摘要** 优化设计高通量铅铋反应堆对于缓解快中子研究堆辐照资源稀缺难题、支撑先进核能系统的发展具有重要意义。本文以提升堆芯中子通量水平为目标,针对高通量铅铋反应堆复杂的多维非线性约束优化问题,依托反应堆蒙特卡罗程序 RMC 和子通道程序 Subchanflow,构建了基于 BP 神经网络(Back Propagation Neural Network)算法的预测模型,并结合 Sobol 指数法开展堆芯设计参数的敏感性分析,提出了基于 BP 神经网络动态代理模型(Dynamic Surrogate Model, DSM)更新迭代的设计优化方法,开发了高通量铅铋反应堆设计优化平台。以多功能超高通量堆为例开展堆芯栅径比、燃料芯块直径、活性区高度、径向反射层厚度的多堆芯参数协同优化验证,结果表明:该优化方法对堆芯中子通量密度与有效增殖因数 $k_{eff}$ 的预测精度误差在 0.1% 之内,在 4 组堆芯设计变量单独作用和共同作用下对于最大中子通量的影响程度都按照反射层厚度<栅径比<活性区高度<燃料芯块直径的递增顺序排列,优化后的中子通量密度相比原始设计方案提高了 15.41%,表明开发的高通量铅铋反应堆设计优化平台有效可靠。

**关键词** 铅铋反应堆, 高通量堆, BP 神经网络, 动态代理模型, 优化方法, 中子通量密度

**中图分类号** TL411+.3

**DOI:** 10.11889/j.0253-3219.2024.hjs.47.100602

**CSTR:** 32193.14.hjs.CN31-1342/TL.2024.47.100602

## Design method of high-flux lead-bismuth cooled reactor neutron flux maximization based on BP neural network

WANG Tong<sup>1,2</sup> LIU Zijing<sup>1,2</sup> ZHAO Pengcheng<sup>1,2</sup> XIAO Yingjie<sup>1,2</sup>

1(College of Nuclear Science and Technology, University of South China, Hengyang 421001, China)

2(Hunan Digital Reactor Engineering and Technology Research Center, University of South China, Hengyang 421001, China)

**Abstract** [Background] The development of high-throughput reactors is of great significance for supporting the development of nuclear science and technology, improving the efficiency of nuclear energy utilization, meeting the needs of radioactive isotope production, and carrying out irradiation tests and performance tests of new nuclear fuels and structural materials in reactors. Due to the high power density of the core fuel and the large demand for thermal cooling, the nuclear-thermal coupling phenomenon in the high-throughput lead-bismuth reactor (HT-LBR) is more significant than that in conventional lead-bismuth reactor (LBR). When the design optimization of high flux LBR is carried out, it is necessary to carry out collaborative optimization of multiple core parameters, improve the neutron

装备预研教育部联合基金青年人才项目(No.8091B032243)资助

第一作者:王彤,女,1998年出生,2020年毕业于山东科技大学,现为硕士研究生,研究领域为先进核能系统设计分析

通信作者:刘紫静,E-mail:liuzijing1123@163.com

收稿日期:2024-01-31,修回日期:2024-03-21

Supported by Joint Fund of Ministry of Education for Equipment Pre-research (No.8091B032243)

First author: WANG Tong, female, born in 1998, graduated from Shandong University of Science and Technology in 2020, master student, focusing on advanced nuclear energy system design and analysis

Corresponding author: LIU Zijing, E-mail: liuzijing1123@163.com

Received date:2024-01-31, revised date: 2024-03-21

flux density, and meet the physical / thermal constraints such as core refueling period, fuel cladding temperature and coolant flow rate. Therefore, the design optimization of high flux lead-bismuth cooled reactor is a complex problem of multi-physics, multi-variable and multi-constraint coupling. **[Purpose]** This study aims to improve the neutron flux level of LBR and solve the optimization design problem of HT-LBR. **[Methods]** Firstly, a HT-LBR training database was constructed to contain different core design parameter combinations and corresponding objective function response values and constraint condition response values. Based on the reactor Monte Carlo code RMC and sub-channel Code Subchanflow, a Back-Propagation (BP) neural network prediction model was established as a proxy model for reactor physical calculation and analysis to achieve rapid prediction of core neutron flux density and effective multiplication factor using aforementioned training database. Secondly, an updated iterative optimization method based on BP neural network Dynamic Surrogate Model (DSM) was proposed to improve the optimization efficiency and global optimization ability, and search for the optimal HT-LBR core design parameter combination within the design range. Thirdly, based on the open-source machine learning platform TensorFlow, coupled with the reactor physical and thermal calculation and analysis program, an iterative optimization method based on BP neural network prediction model was proposed. Combined with the sensitivity analysis method of core design parameters based on Sobol index method, a HT-LBR optimization design platform was developed to cover five functional modules: training database generation, physical and thermal parameters calculation and analysis, BP neural network model construction, core parameters sensitivity analysis, and core parameters optimization analysis. Finally, a multi-functional ultra-high-throughput reactor was used as a prototype to establish a model to be optimized, collaborative optimization verification of multiple core parameters including core grid diameter ratio, fuel pellet diameter, active zone height, and radial reflector thickness, was conducted. **[Results]** Verification results show that the prediction accuracy errors for core neutron flux density and effective multiplication factor are maintained within 0.1%. The optimized neutron flux density is 15.41% higher than the original design. The influence degree of the four groups of core design variables on the maximum neutron flux is arranged in the order of reflector thickness < gate diameter ratio < active zone height < fuel pellet diameter. At the same time, the maximum temperature of the fuel pellet and the maximum temperature of the cladding are reduced by 23.57 °C and 8.20 °C, respectively. The optimized core design scheme has a larger steady-state thermal safety margin. **[Conclusions]** The HT-LBR optimization design platform developed in this paper is effective and reliable.

**Key words** Lead-bismuth cooled reactor, High flux reactor, BP Neural network, Dynamic surrogate model, Optimization methods, Neutron flux density

高通量堆的发展对于推动核科学技术的发展,提高核能利用效率,满足放射性同位素生产需求,开展新型核燃料及堆内结构材料辐照考验与性能测试等方面具有重要的意义,可为我国核事业的发展提供战略性支撑<sup>[1]</sup>。铅铋由于中子俘获截面小、非弹性散射阈能高以及流动换热能力强等特性使得铅铋反应堆具备高通量堆的设计潜力。目前,世界范围内多个国家针对高通量液态金属冷却快堆开展了一系列反应堆设计方案和分析方法研究:1969年,俄罗斯投入运行60 MW钠冷快堆(Borium-60, BOR-60),是全球在役运行时间最长的快中子研究堆,堆芯最大快中子通量为 $3.7 \times 10^{15} \text{ n} \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ <sup>[2-3]</sup>;2018年,俄罗斯开始建设150 MW多用途钠冷快中子研究堆(Multipurpose Fast-neutron Research Reactor, MBIR),堆芯最大快中子通量目标值可达到 $5.3 \times 10^{15} \text{ n} \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ ,其配备多条辐照测试回路,能够针对Pb、Pb-Bi、Na、He及熔盐等冷却剂环境进行试

验<sup>[4-5]</sup>;2015年,美国提出300 MW池式钠冷快堆(Fast Test Reactor, FASTER)设计方案,以提供高水平的快中子和热中子通量,其堆芯最大快中子通量值达 $5 \times 10^{15} \text{ n} \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ ,最大热中子通量值达 $1.0 \times 10^{15} \text{ n} \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ <sup>[6]</sup>;2019年,美国进一步提出300 MW多功能钠冷试验反应堆(Versatile Test Reactor, VTR)的概念设计方案,其堆芯最大快中子通量可达 $4.54 \times 10^{15} \text{ n} \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ ,能够满足液态金属快堆等先进核能系统结构材料的研发需求<sup>[7-8]</sup>。

超高通量堆的设计需求是尽可能提高最大中子通量/功率比,延长连续运行周期。由于堆芯燃料功率密度高和热工冷却需求大,致使高通量铅铋堆内的核-热耦合现象较常规铅铋堆更为显著。开展高通量铅铋反应堆设计优化时,需对多个堆芯参数开展协同优化,提高中子通量密度,并满足堆芯换料周期、燃料包壳温度,冷却剂流速等物理/热工约束条件,因此其设计优化是一个多物理、多变量、多约束

耦合影响的复杂问题。由于传统的优化设计方法存在计算成本高、搜索空间大等问题,而神经网络算法可在数据有限的情况下通过多层的非线性变换,进行快速精确的预测,能够有效解决反应堆传统优化设计过程中的上述问题。

国内外诸多学者基于神经网络算法对反应堆参数预测和优化设计开展研究<sup>[9-11]</sup>,如Hakim<sup>[12]</sup>采用人工神经网络对10 MW低浓缩铀堆芯研究堆的安全关键参数进行预测,得到最佳的人工神经网络体系结构并改善其对有效增殖因数及最大功率的预测精度;西南交通大学的张相文<sup>[13]</sup>通过GA-BP神经网络(Genetic Algorithm Backpropagation neural network)对控制棒组件落棒过程的最大冲击力进行预测并构建优化模型,获得了最优的控制棒水力缓冲器参数组合;哈尔滨工业大学的张海明<sup>[14]</sup>基于卷积神经网络(Convolutional Neural Network, CNN)建立了深度学习模型,用于预测反应堆堆芯不同燃料组件截面参数对应的有效增殖因数,可快速准确的求解中子扩散方程。上述研究结果均验证了神经网络算法预测精度高,计算效率高,具有较好的泛化能力和较高的可靠性,可以用于解决高通量铅铋反应堆堆芯设计优化问题。

为提高铅铋反应堆的快中子通量水平,解决高

通量铅铋堆优化设计问题,本文针对多功能超高通量铅铋反应堆概念设计方案,构建高通量铅铋堆待优化模型,然后采用拉丁超立方抽样(Latin Hypercube Sampling, LHS)技术,依托铅铋反应堆物理/热工计算分析程序,构建高通量铅铋堆反应堆数据库。基于该数据库,构建BP神经网络预测模型作为反应堆物理计算分析的代理模型,并采用Sobol指数法开展堆芯设计参数的敏感性分析,提出基于BP神经网络动态代理模型的更新迭代优化方法,开发高通量铅铋反应堆设计优化平台并进行验证,可为解决高通量堆的设计优化问题提供参考。

## 1 高通量铅铋堆待优化模型的构建

### 1.1 高通量铅铋反应堆堆芯基准方案

本研究以南华大学自主开发设计的多功能超高通量铅铋反应堆为原型建立待优化模型。多功能超高通量铅铋反应堆热功率为150 MW,换料周期为90 d。采用U-10Zr燃料,<sup>208</sup>Pb-Bi作冷却剂,固体<sup>208</sup>Pb作反射层材料,包壳材料是铁素体/马氏体钢T91。堆芯由109个燃料组件组成,燃料组件采用六角形开式设计,每个燃料组件包含91根燃料棒,燃料芯块和包壳间隙填充He。详细参数如表1所示。

表1 多功能超高通量铅铋反应堆设计参数  
Table 1 Multi-functional ultra high flux lead-bismuth cooled reactor design parameters

设计参数 Design parameters	数值 Numerical value
热功率 Thermal power / MW	150
换料周期 Refueling cycle / d	90
冷却剂材料 Coolant material	<sup>208</sup> Pb-Bi
反射层材料 Reflecting layer material	<sup>208</sup> Pb
包壳材料 Cladding material	T91
燃料棒间隙填充气体 Fuel rod gap filler gas	He
入口温度 Inlet temperature / °C	170
出口温度 Outlet temperature / °C	536.5
燃料装载量/ <sup>235</sup> U装载量 Fuel loads/ <sup>235</sup> U loads / kg	779/175.3
堆芯活性区等效直径 Equivalent diameter of active zone / cm	58.14
堆芯活性区高度 Height of active zone / cm	50
燃料棒内/外直径 Fuel rod inner/outer diameter / cm	4/4.6
燃料棒气隙宽度 Fuel rod gas gap width / mm	0.1
包壳厚度 Cladding thickness / mm	0.2
栅距 Grid pitch / mm	5.2
栅径比 P/D Grid diameter ratio P/D	1.130 4
反射层轴向/径向厚度 Reflective layer axial/radial thickness / cm	80/120

### 1.2 目标函数、设计变量和约束条件

高通量堆需具备高中子通量与高热负荷特性。针对高通量堆的设计目标,结合铅铋反应堆的物理、

热工设计准则,分析影响堆芯中子通量的关键因素,确定高通量铅铋反应堆设计优化的目标函数、设计变量和约束条件。

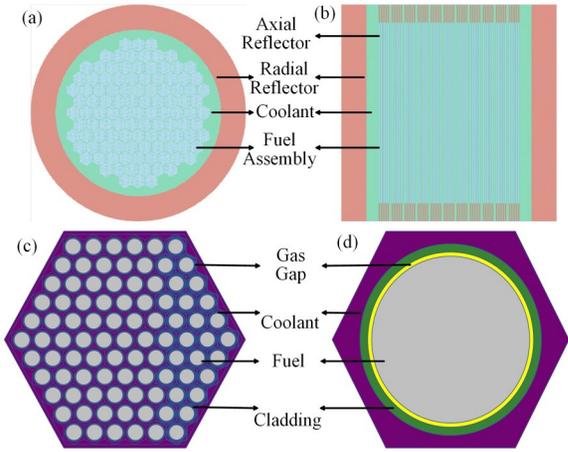


图1 多功能超高通量铅铋反应堆截面图  
(a) 堆芯 X-Y 轴截面, (b) 堆芯 X-Z 轴截面, (c) 燃料组件截面图, (d) 燃料棒截面图

Fig.1 Cross-sectional views of a multifunctional ultra-high flux lead-bismuth cooled reactor  
(a) Cross section of core along X-Y axis, (b) Cross section of core along X-Z axis, (c) Cross section of fuel assembly, (d) Cross section of fuel rod

反应堆堆芯平均中子通量密度  $\bar{\varphi}$  为:

$$\bar{\varphi} = \frac{AP}{Vn\sigma_f} \quad (1)$$

式中:  $A$  是反应堆产生 1 J 能量所需的易裂变核素裂变次数;  $P$  为反应堆热功率;  $V$  是堆芯活性区体积大小;  $n$  为单位体积内易裂变核素数量;  $\sigma_f$  是易裂变核素的微观裂变截面。

其中, 燃料芯块直径、栅距、活性区高度决定了活性区体积大小, 并影响堆芯热工特性。此外, 堆内中子的有害吸收与泄漏也会影响中子通量密度。本文主要研究以下 4 个重要设计参数对铅铋反应堆的中子通量密度的影响: 燃料芯块直径、栅距与燃料棒直径之比(简称栅径比,  $P/D$ )、堆芯活性区高度和反射层厚度。

①燃料芯块直径: 燃料芯块、气隙及包壳份额影响堆芯中子有害吸收, 引起中子通量密度和  $k_{\text{eff}}$  变化。燃料棒芯块直径是决定线功率密度的因素之一, 其显著影响堆芯输热特性。

②栅径比  $P/D$ :  $P/D$  通过调节堆芯中子能谱决定易裂变核素的  $\sigma_f$ , 中子通量密度与  $\sigma_f$  负相关。  $P/D$  还会显著影响燃料组件的热负荷特性。

③堆芯活性区高度: 改变堆芯活性区高度, 会引起中子泄漏、冷却剂流量变化。

④反射层厚度: 反射层增厚可以减少芯部中子泄漏, 提高反应堆的平均输出功率。

在额定堆芯热功率与燃料富集度的条件下, 本文选取燃料芯块直径( $x_1$ )、栅径比( $x_2$ )、活性区高度( $x_3$ )、反射层厚度( $x_4$ )作为高通量铅铋反应堆待优化

模型的设计变量, 以堆芯最大中子通量密度作为评价指标建立目标函数, 开展堆芯多参数的协同优化, 获得全局最大中子通量密度堆芯方案, 并满足物理、热工约束条件。综上, 设计变量和目标函数可以表示为:

$$\begin{cases} \mathbf{X} = (x_1, x_2, x_3, x_4), \mathbf{X} \in R \\ L_i \leq x_i \leq H_i (i = 1, 2, 3, 4) \\ f(\mathbf{x}) = (x_1, x_2, x_3, x_4) \end{cases} \quad (2)$$

式中:  $x_1, x_2, x_3, x_4$  是一组待优化模型的设计变量;  $L_i$  和  $H_i$  分别对应设计变量取值范围的下限和上限;  $\mathbf{X}$  是对应设计方案的设计参数向量;  $R$  是由设计参数向量组成设计空间;  $f(\mathbf{x})$  是包含设计变量的目标函数。

高通量铅铋反应堆的优化设计还需要满足设计寿命要求, 冷却剂流速、最大燃料芯块和包壳温度不超过待优化模型的最大燃料芯块和包壳温度等约束条件。在参考超高通量堆原设计寿命周期的基础上, 防止温度过高导致堆芯烧毁, 并考虑到铅铋冷却剂高流速造成的腐蚀效应, 具体约束条件可表示如下:

$$\begin{cases} k_{\text{eff}} > 1.0 \\ R_c \geq 90 \text{ day} \\ q \leq 4 \text{ m} \cdot \text{s}^{-1} \\ T_{\text{fuel}}(x_1, x_2, x_3, x_4) \leq 992.67 \text{ }^\circ\text{C} \\ T_{\text{cladding}}(x_1, x_2, x_3, x_4) \leq 533.63 \text{ }^\circ\text{C} \end{cases} \quad (3)$$

式中:  $k_{\text{eff}}$  为有效增殖因数;  $R_c$  为换料周期;  $V_c$  为冷却剂流速;  $T_{\text{fuel}}$  为最大燃料芯块温度值;  $T_{\text{cladding}}$  为最大燃料包壳温度值。

## 2 高通量铅铋反应堆训练数据库构建

构建准确的高通量铅铋堆训练数据库是构建 BP 神经网络模型、开展堆芯多参数协同优化的基础。训练数据库包含不同的堆芯设计参数组合和对应的目标函数响应值、约束条件响应值。

### 2.1 堆芯关键设计变量取值范围

通过开展高通量铅铋反应堆中子通量影响因素研究, 参考美国多用途快中子研究堆 VTR, 俄罗斯钠冷快堆 MBIR、BOR-60 等国际具有代表性的液态金属高通量堆堆芯设计, 确定优化变量的选取区间如表 2 所示。

### 2.2 堆芯关键设计变量抽样

为获得数据均匀分布的高通量铅铋反应堆训练数据库, 本文采用拉丁超立方算法抽样生成样本点。拉丁超立方算法是 McKay 等<sup>[15]</sup>于 1979 年提出的一

表2 多功能超高通量铅铋反应堆优化变量取值区间  
Table 2 Multi-functional ultra-high flux lead-bismuth cooled reactor optimization variable value intervals

设计变量 Design variables	取值区间 Value interval
栅径比 Grid diameter ratio	[1.00, 1.50]
燃料芯块直径 Fuel diameter / cm	[0.3, 1.5]
堆芯活性区高度 Height of core active area / cm	[40, 200]
反射层厚度 Reflective layer thickness / cm	[20, 220]

种随机抽样算法,该算法可以降低计算消耗,具体步骤为分层、采样和乱序。通过均匀分层和等概率抽样,保证了每一个设计变量范围内的全覆盖。在保证相同精度的前提下,拉丁超立方方法比蒙特卡罗

方法使用的样本数量少,计算速度快<sup>[16-17]</sup>。本文采用拉丁超立方算法在设计参数区域内对4组设计变量进行抽样,生成1 600组设计参数组合,其数据分布如图2所示。

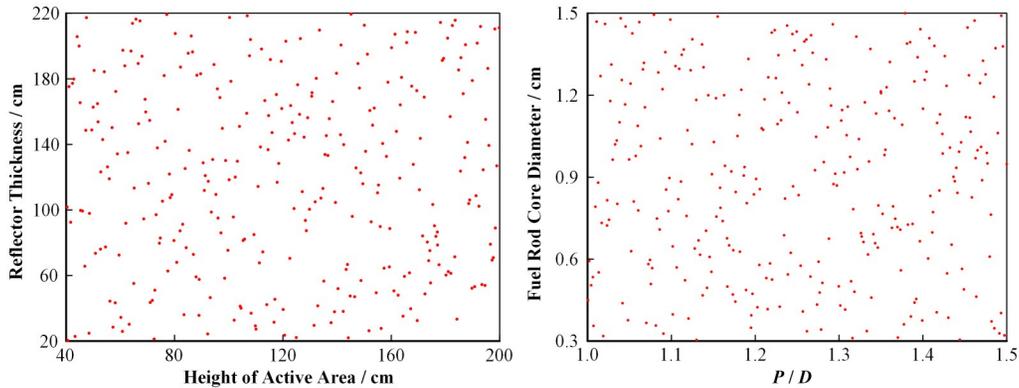


图2 1 600组设计变量的数据分布图  
Fig.2 Data distribution plot of 1 600 design variables

### 2.3 高通量铅铋堆物理/热工参数的计算

堆芯最大中子通量受反应堆的物理、热工特性的影响,因此需要对设计变量及对应的物理、热工程序计算结果进行约束限制。采用反应堆物理、热工分析程序对高通量铅铋反应堆的堆芯设计参数组合开展计算,得到对应的目标函数响应值、约束条件响应值。

反应堆物理程序采用由清华大学工程物理系反应堆工程计算分析实验室(Reactor Engineering Analysis Laboratory, REAL)自主研发的反应堆用蒙特卡罗模拟程序RMC<sup>[18]</sup>,用于计算堆芯中子通量、燃料、有效增殖因数 $k_{eff}$ 和功率分布等参数。随着燃料的加深,堆内的易裂变核素密度不断降低,堆芯中子通量水平逐渐升高,当寿期初的堆芯中子通量达到设计指标时,整个换料周期内的中子通量即满足设计要求。本文取寿期初的最大中子通量密度值作为堆芯中子通量水平的评价标准;开展燃料计算得到的堆芯换料周期和有效增殖因数 $k_{eff}$ ,作为物理约束条件;通过堆芯功率分布计算,得到堆芯最热组件的位置以及燃料棒束的轴向功率分布,进一步可用于计算堆芯最热组件的热工特性参数。

反应堆热工程序采用由德国卡尔斯鲁厄理工学

院(Karlsruhe Institute of Technology, KIT)开发的子通道程序Subchanflow<sup>[19]</sup>,用于计算堆芯组件最大包壳温度、最大芯块温度和冷却剂的流速等参数。其中,包壳温度和芯块温度的主要影响因素包括燃料棒束的功率分布和冷却剂流量分布。冷却剂的流量分布影响堆芯的热力学性能,包括压力、温度、密度等参数,限制冷却剂的流速可缓解铅铋腐蚀。

参考铅铋物性手册<sup>[20]</sup>,Subchanflow程序中铅铋合金的主要热物理性质数据如表3<sup>[20]</sup>所示。

Subchanflow程序采用的对流换热计算关系式为:

$$q'' = h_{coef}(T_w - T_b) \quad (4)$$

式中: $T_w$ 为壁面温度; $T_b$ 为流体温度;对流换热系数 $h_{coef}$ 根据不同换热模式下的经验关系式确定。液态金属换热的通用传热关系式:

$$Nu = a + bPe^c Pr^d \quad (5)$$

式中:贝克莱数 $Pe$ 为普朗特数 $Pr$ 和雷诺数 $Re$ 的乘积, $a$ 、 $b$ 、 $c$ 、 $d$ 为经验常数。液态铅铋的 $Pr$ 数约为0.022,意味着在液态铅铋冷却剂在对流换热时,不可忽略热传导机理对于动量热扩散传递机理的影响。程序选取Subbotion换热模型,其对流换热系数 $a$ 、 $b$ 、 $c$ 、 $d$ 分别取值为5、0.025、0.8、0。

表3 铅铋合金物性参数  
Table 3 Physical parameters of lead-bismuth alloy

参数 Parameters	值/计算式 Value/Equation
熔点 Melting point / K	$T_M=398.0$
沸点 Boiling point / K	$T_B=1\ 927.0$
表面张力 Surface tension / $N\cdot m^{-1}$	$\sigma=(448.5 - 0.08T)\times 10^{-3}$
密度 Density / $kg\cdot m^{-3}$	$\rho=11\ 065 - 1.293T$
等压比热 Constant pressure specific heat / $J\cdot(kg\cdot K)^{-1}$	$C_p=164.8 - 3.94\times 10^{-2}T+1.25\times 10^{-5}T^2 - 4.56\times 10^{-6}T^3$
动力粘度 Viscosity of dynamics / Pa·s	$\mu=4.94\times 10^{-4}\exp(754.1/T)$
热导率 Heat conduction / $W\cdot(m\cdot K)^{-1}$	$\lambda=3.284+1.617\times 10^{-2}T - 2.305\times 10^{-6}T^2$

本节构建的高通量铅铋反应堆训练数据库如表 4 所示。

表4 高通量铅铋反应堆训练数据库  
Table 4 High-flux lead-bismuth cooled reactor training database

样本 Sample size	设计变量 Design variable				目标函数响应值 Objective function response value	约束条件响应值 Constraint response value
	栅径比 Grid pitch ratio	燃料芯块直径 Fuel diameter / cm	堆芯活性区高度 Height of core active zone / cm	反射层厚度 Reflective layer thickness / cm	$\phi_{max} / n\cdot cm^{-2}\cdot s^{-1}$	$k_{eff}$
1	1.493 776	0.429 575	185.214 6	162.842 2	$1.662\ 1\times 10^{15}$	1.215 37
2	1.315 769	0.677 587	91.307 3	185.845 7	$1.548\ 1\times 10^{15}$	1.327 71
3	1.495 511	0.741 313	164.465 9	152.645 8	$7.189\ 8\times 10^{14}$	1.391 04
4	1.427 046	0.884 549	72.922 3	133.951 0	$1.218\ 5\times 10^{15}$	1.334 17
5	1.420 833	1.470 295	55.927 6	193.398 0	$6.153\ 2\times 10^{14}$	1.398 67
6	1.236 895	1.407 295	68.267 4	60.641 8	$5.943\ 2\times 10^{14}$	1.461 60
7	1.240 646	1.489 613	100.568 1	109.038 4	$3.461\ 9\times 10^{14}$	1.528 40
8	1.227 713	0.751 283	162.399 0	115.514 5	$7.351\ 6\times 10^{14}$	1.437 19
9	1.174 609	1.465 010	187.868 3	143.498 9	$1.858\ 2\times 10^{14}$	1.592 46
10	1.485 631	0.663 466	143.914 9	177.673 0	$9.966\ 5\times 10^{14}$	1.349 12
...	...	...	...	...	...	...
1 600	1.183 904	1.387 367	85.603 8	152.429 0	$4.558\ 4\times 10^{14}$	1.516 41

### 3 BP神经网络预测模型构建

本节构建了BP神经网络预测模型作为反应堆物理计算分析的代理模型,实现堆芯中子通量密度与 $k_{eff}$ 的快速预测,并开展堆芯多个设计变量在大设计范围内的协同优化。待优化的设计变量:燃料芯块直径、栅径比、活性区高度、反射层厚度作为全连接层的输入特征,堆芯最大中子通量 $\phi_{max}$ 、有效增殖因数 $k_{eff}$ 作为预测响应值,分别构建BP神经网络预测模型,以下简称为 $\phi_{max}$ 神经网络预测模型和 $k_{eff}$ 神经网络预测模型。高通量铅铋反应堆训练数据库中1 600组数据按照9:1的比例划分训练集和测试集,并进行标准化处理,标准化处理的公式为:

$$z = \frac{x - \mu}{\sigma} \quad (6)$$

式中: $z$ 为对应变量标准化后的值; $x$ 为待标准化的变

量; $\mu$ 为数据集的均值; $\sigma$ 为数据集的方差。

为应对特征学习过程中可能出现梯度消失和神经元饱和问题,将激活函数都设置为非线性激活函数ReLU(Rectified Linear Unit)。为提高模型的泛化能力、缓解过拟合现象,将每一层神经网络都添加L2正则化。采用Adam优化器(Adaptive Moment Estimation)进行权重更新。本文选择均方差误差(Mean Squared Error, MSE)、决定系数( $R^2$ )作为衡量预测精度的评估指标,具体公式如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

式中: $n$ 是样本数量; $y_i$ 是预测值; $\hat{y}_i$ 是真实值; $\bar{y}$ 是真

实值的均值。

BP神经网络中隐藏层层数、学习率、批处理样本数、正则化系数会对模型的精度产生较大影响,为获得最优BP神经网络模型,本文使用Scikit-Learn中的RandomizedSearchCV工具包开展了超参数寻优。首先分别设置超参数的数值,再从选定数值组成的超参数空间内,随机取20种超参数组合,交叉

验证3次。最终确定 $\varphi_{\max}$ 神经网络预测模型的隐藏层层数为1,学习率为0.001,批处理样本数为32,正则化系数为0.000 1; $k_{\text{eff}}$ 神经网络预测模型的隐藏层层数为3,学习率为0.01,批处理样本数为512,正则化系数为0.000 1。超参数空间设置、BP神经网络模型结构设置分别如表5、6所示。

表5 超参数空间设置  
Table 5 Hyperparameter space setting

超参数 Super-parameter	数值 Numerical value
隐藏层层数 Number of hidden layers	[1, 2, 3, 4, 5]
学习率 Learning rate	[ $1 \times 10^{-4}$ , $1 \times 10^{-3}$ , $1 \times 10^{-2}$ , $1 \times 10^{-1}$ ]
训练批次 Batch size	[32, 48, 96, 128, 256, 512, 1 024]
L2正则化系数 L2 regularizer coefficient	[ $1 \times 10^{-3}$ , $1 \times 10^{-2}$ , $1 \times 10^{-1}$ ]

表6 神经网络模型结构设置  
Table 6 Neural network model architecture setup

参数 Parameters	$\varphi_{\max}$ 神经网络模型 $\varphi_{\max}$ neural network model	$k_{\text{eff}}$ 神经网络模型 $k_{\text{eff}}$ neural network model
输入参数 Input parameters	燃料芯块直径、栅距、活性区高度、反射层厚度 Fuel diameter, grid pitch, active zone height, reflective layer thickness	
输出参数 Output parameters	堆芯最大快中子通量 Maximum fast neutron flux in the core	有效增殖因数 Effective multiplication factor
学习率 Learning rate	0.001	0.01
训练次数 Epochs	2 000	2 000
训练批次 Batch size	32	512
隐藏层层数 Number of hidden layers	1	3
隐藏层神经元个数 Number of neurons per hidden layer	100	100/100/100
激活函数 Activation function	ReLU	ReLU
损失函数 Loss function	Mean_squared_error	Mean_squared_error
优化器 Optimization algorithm	Adam	Adam
正则化 Regularization	L2(0.000 1)	L2(0.000 1)

为保证BP神经网络预测模型的精度,防止过拟合,在训练过程中,调用EarlyStopping函数,当模型精度于50次训练后不再提升时,终止训练。如图3所示,调用Modelcheckpoint保存最佳模型, $\varphi_{\max}$ 神经网络预测模型和 $k_{\text{eff}}$ 神经网络预测模型分别于711和373次训练后达到最佳预测精度。

BP神经网络预测模型的精度如表7所示,均方差误差MSE用于度量模型预测值与实际值之间的误差,值越小表示模型的性能越好。决定系数 $R^2$ 用于衡量回归模型的拟合优度,值越接近1表示模型拟合得越好。 $\varphi_{\max}$ 神经网络预测模型的均方差误差MSE小于0.001%,决定系数 $R^2$ 达到99.9%; $k_{\text{eff}}$ 神经网络预测模型的均方差误差MSE小于0.001 1%,决定系数 $R^2$ 达到99.8%。结果表明,本文构建的 $\varphi_{\max}$ 神经网络预测模型和 $k_{\text{eff}}$ 神经网络预测模型可以准确地预测堆芯最大快中子通量 $\varphi_{\max}$ 有效增殖因数 $k_{\text{eff}}$ 。

表7 BP神经网络模型预测精度  
Table 7 Prediction accuracy of neural network models

神经网络预测模型 Neural network prediction model	MSE / $10^{-4}$ $R^2$ / $10^{-2}$	
$\varphi_{\max}$ 神经网络 $\varphi_{\max}$ neural network	9.974 4	0.999 1
$k_{\text{eff}}$ 神经网络 $k_{\text{eff}}$ neural network	1.093 9	0.998 5

## 4 基于Sobol指数法的堆芯设计参数敏感性分析

采用Sobol指数法探究高通量铅铋堆堆芯设计参数对优化目标的敏感度,确定最为敏感的因素及敏感性较低的因素,从而为高通量铅铋堆的优化设计提供理论支撑和参考。

### 4.1 Sobol指数敏感性分析方法的原理

由俄罗斯数学家Sobol I M提出的Sobol指数

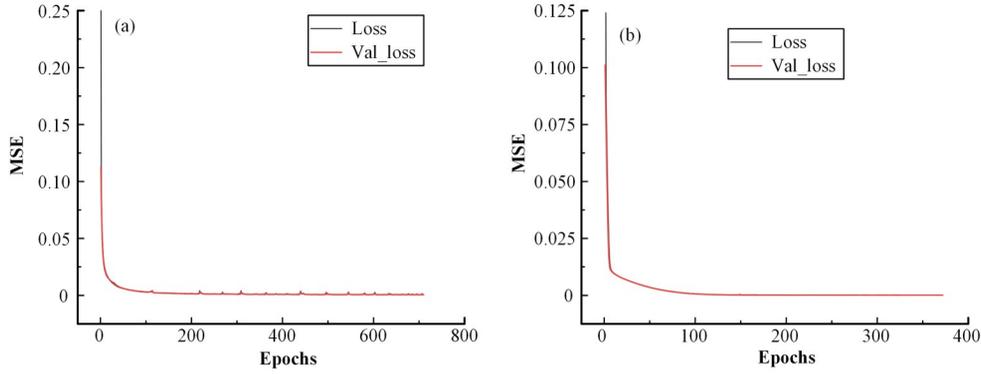


图3 BP神经网络预测模型学习曲线 (a)  $\varphi_{\max}$ 神经网络预测模型, (b)  $k_{\text{eff}}$ 神经网络预测模型

Fig.3 Learning curve of BP neural network prediction model

(a)  $\varphi_{\max}$  neural network prediction model, (b)  $k_{\text{eff}}$  neural network prediction model

法<sup>[21]</sup>,是一种基于方差分解的全局性敏感性分析方法。Sobol指数法把模型分解成单个输入参数和其他参数组合的函数,通过计算单个输入参数或输入参数集的方差对总输出参数方差的影响,量化每个参数以及不同参数之间的交互作用对输出结果的影响程度,可以有针对性地调整参数值进行优化,从而提高优化设计方法的效率。Sobol指数法的理论推导如下<sup>[22-23]</sup>:

假设函数模型为:

$$Y = F(x) = F(x_1, x_2, x_3, \dots, x_n)$$

其中: $x_1, x_2, x_3, \dots, x_n$ 表示输入参数, $n$ 表示输入参数的个数, $F(x)$ 平方可积。函数模型可以分解为:

$$F(x) = F_0 + \sum_i F_i(x_i) + \sum_{i < j} F_{ij}(x_i, x_j) + F_{1,2,\dots,n}(x_1, x_2, \dots, x_n) \quad (9)$$

函数模型的输出总方差 $V$ 表示所有输入变量对输出变量的影响,公式表示为:

$$V = \text{Var}(Y) = \int F^2(X) dX - F_0^2 \quad (10)$$

输入变量的一阶敏感性指数 $S_i$ 和总阶敏感性指数 $S_{T_i}$ 计算公式可以表示为:

$$S_i = \frac{\text{Var}(E(Y|x_i))}{\text{Var}(Y)} \quad (11)$$

$$S_{T_i} = \frac{E(\text{Var}(Y|x_{-i}))}{\text{Var}(Y)} \quad (12)$$

式中: $Y$ 是模型的输出; $x_i$ 是特定的输入参数; $E(Y|x_i)$ 表示在给定 $x_i$ 的条件下 $Y$ 的期望值; $\text{Var}$ 表示方差; $x_{-i}$ 表示除了输入参数 $x_i$ 之外的所有输入参数的组合; $\text{Var}(Y|x_{-i})$ 是在 $x_{-i}$ 的条件下 $Y$ 的条件方差的期望值。

## 4.2 基于Sobol指数法的堆芯设计参数敏感性分析方法

在搭建BP神经网络预测模型后,当进行堆芯设计参数对优化目标的敏感性分析时,为了进一步提高计算分析的可靠性和效率,本文将BP神经网络预测模型作为Sobol指数敏感性分析的目标函数,即BP神经网络预测模型的输入参数作为Sobol指数敏感性分析的输入参数,预测模型的输出值作为Sobol指数敏感性分析的目标结果,提出了基于Sobol指数法的堆芯设计参数敏感性分析方法,方法的流程如图4所示。

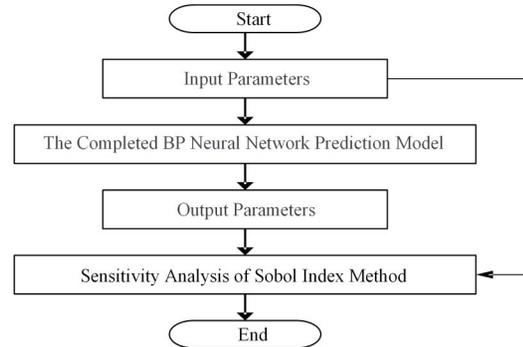


图4 基于Sobol指数法的堆芯设计参数敏感性分析方法流程图

Fig.4 Flow chart of sensitivity analysis method for core design parameters based on Sobol index method

## 5 基于BP神经网络动态代理模型的更新迭代优化方法

为了提升优化效率与全局寻优能力,提出了一种基于BP神经网络动态代理模型的更新迭代优化方法,用于搜索设计范围内最优的高通量铅铋反应堆堆芯设计参数组合。

首先,确定设计变量取值范围,采用拉丁超立方算法对设计变量抽样,获取堆芯设计参数组合,通过

铅铋反应堆物理/热工计算分析程序计算对应的物理/热工参数,构建初始训练数据库;其次,基于初始训练数据库进行超参数寻优建立BP神经网络预测模型;再次,采用Sobol指数法对堆芯设计参数进行敏感性分析,确定堆芯设计参数对目标函数的影响程度;然后,采用BP神经网络模型预测大量目标函数响应值,评估筛选优于上一代模型预测最优值的

样本点,调用堆芯物理/热工计算分析程序进行精度校验,验证通过后加入训练数据库,搜索设计变量的优化区间,更新神经网络预测模型的权重。最后,通过反复抽样和迭代收敛,得到满足精度要求和约束条件的全局最优堆芯参数组合。基于BP神经网络动态代理模型的更新迭代优化方法的流程如图5所示。

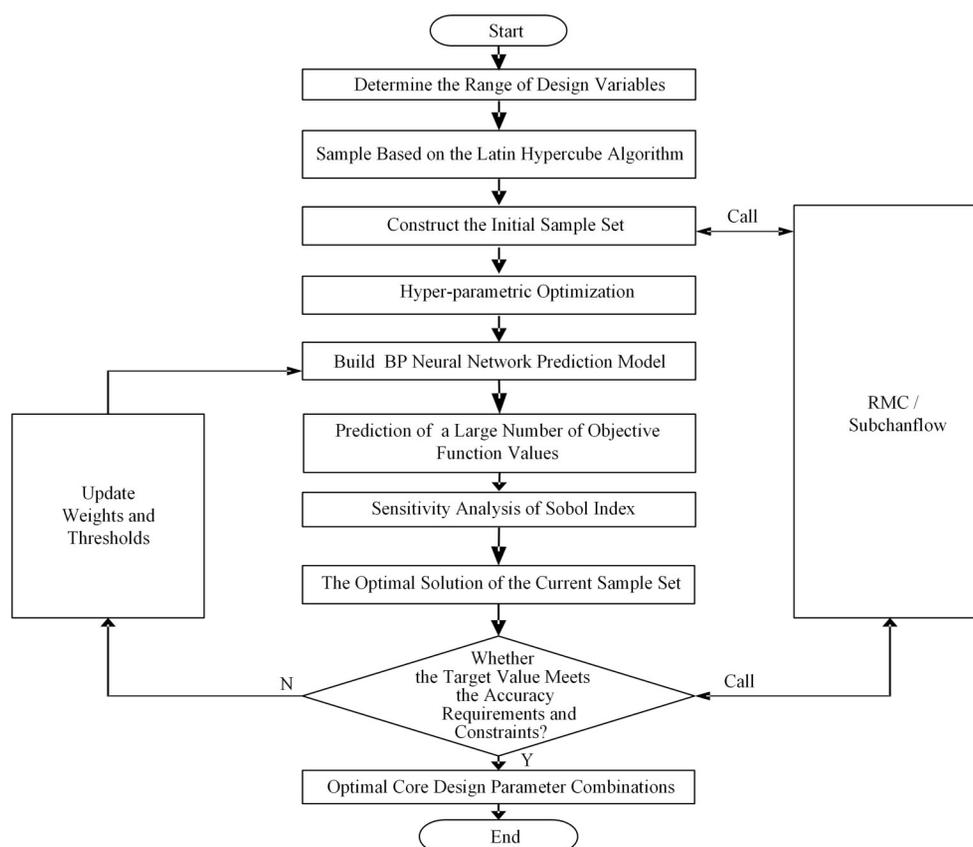


图5 基于BP神经网络动态代理模型的优化方法流程图

Fig.5 Flowchart of optimization method based on BP neural network dynamic surrogate model

## 6 高通量铅铋堆优化设计平台开发及验证

依托开源机器学习平台TensorFlow,基于BP神经网络动态代理模型的更新迭代优化方法,耦合反应堆物理、热工计算分析程序,开发高通量铅铋堆优化设计平台。用户可以通过自定义优化目标函数、设计变量和取值区间、约束条件,调用拉丁超立方提抽样方法和铅铋反应堆物理热工计算分析程序生成训练数据库;开展超参数优化构建和更新BP神经网络预测模型;搜索全局最优堆芯设计参数组合。

### 6.1 高通量铅铋堆优化设计平台简介

高通量铅铋堆优化设计平台主要包含训练数据库生成、物理热工参数计算分析、BP神经网络模型

构建、堆芯参数敏感性分析、堆芯参数优化分析5个功能模块。

1)训练数据库生成模块:用户可以自定义优化目标函数、设计变量和取值区间、约束条件,采用拉丁超立方抽样获取堆芯设计参数组合,调用铅铋反应堆物理热工参数计算分析模块,自动生成输入文件、处理输出结果,建立训练数据库。

2)物理热工参数计算分析模块:根据样本点信息,调用蒙特卡罗程序RMC、子通道程序SubChanFlow计算堆芯相关物理、热工特性参数。

3)神经网络模型构建模块:根据优化目标函数,确定神经网络预测模型的输入特征和输出特征,学习训练数据库内的样本点,通过超参数寻优构建基于BP神经网络预测模型,用于预测堆芯最大中子通量和有效增殖因数。

4)堆芯参数敏感性分析模块:采用拉丁超立方抽样对设计变量取值范围进行抽样,调用神经网络模型构建模块生成目标响应值,使用Sobol指数法对堆芯设计参数进行敏感性分析。

5)堆芯参数优化分析模块:预测评估大量目标函数响应值,开展预测精度与约束条件验证,依据择

优加点原则补充训练数据库,搜索设计变量的优化区间,更新BP神经网络预测模型的权重,反复迭代至收敛,直至获得最优堆芯设计变量组合。

高通量铅铋堆优化设计平台的运行流程如图6所示。

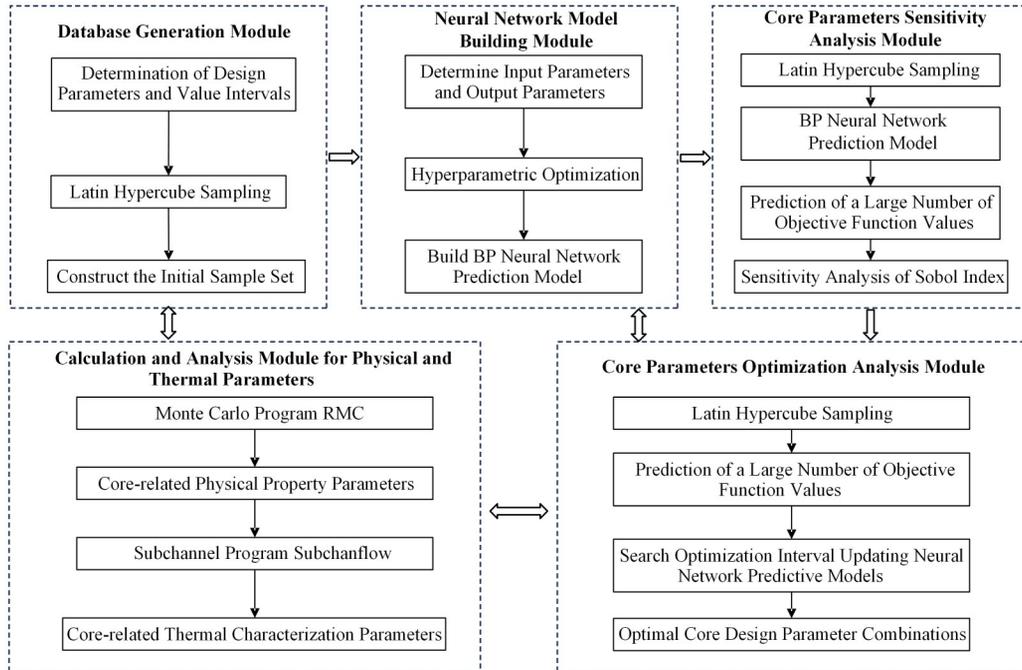


图6 高通量铅铋堆优化设计平台运行流程

Fig.6 Operation flow of high-flux lead-bismuth cooled reactor optimization design platform

## 6.2 BP神经网络模型预测精度评估

为保证BP神经网络模型的预测精度,在每次迭代输出最优解时进行预测精度的校验。随机抽取3次迭代结果,根据BP神经网络预测结果、RMC计算的寿期初最大中子通量 $\varphi_{\max}$ 和有效增殖因数 $k_{\text{eff}}$ 结果对比(表8)可知,BP神经网络模型预测的 $\varphi_{\max}$ 和 $k_{\text{eff}}$

的相对误差满足均小于0.1%,满足堆芯设计的精度要求。

## 6.3 基于Sobol指数法堆芯设计参数敏感度计算

本文选取燃料芯块直径、栅径比、活性区高度、反射层厚度作为高通量铅铋反应堆待优化模型的设计变量,选择最大中子通量 $\varphi_{\max}$ 作为评价指标,采用

表8 神经网络预测值和RMC计算值的结果对比

Table 8 Comparison of results between neural network predicted values and RMC calculated values

堆芯设计参数 Core design parameters	数值 Value		
	第一组 Group 1	第二组 Group 2	第三组 Group 3
栅径比 Grid pitch ratio	1.096 2	1.095 4	1.091 5
燃料芯块直径 Fuel diameter / cm	0.391 4	0.405 4	0.405 1
堆芯活性区高度 Height of core active zone / cm	44.313 8	40.340 9	40.381 1
反射层厚度 Reflective layer thickness / cm	212.711 1	207.437 4	211.449 3
$\varphi_{\max}$ /10 <sup>15</sup> n·cm <sup>-2</sup> ·s <sup>-1</sup>	BP神经网络预测值 BP NN predicted value	8.832 0	9.107 0
	RMC计算值 RMC calculated value	8.827 3	9.105 0
	相对误差 Relative error / %	0.053 3	0.021 8
$k_{\text{eff}}$	BP神经网络预测值 BP NN predicted value	1.008 2	1.003 0
	RMC计算值 RMC calculated value	1.008 7	1.002 8
	相对误差 Relative error / %	0.047 0	0.022 5

拉丁超立方抽样对设计变量的取值范围进行524 288次抽样,得到堆芯设计参数对最大中子通量的一阶敏感性指数 $S_i$ 和总阶敏感性指数 $S_{T_i}$ 如图7所示。

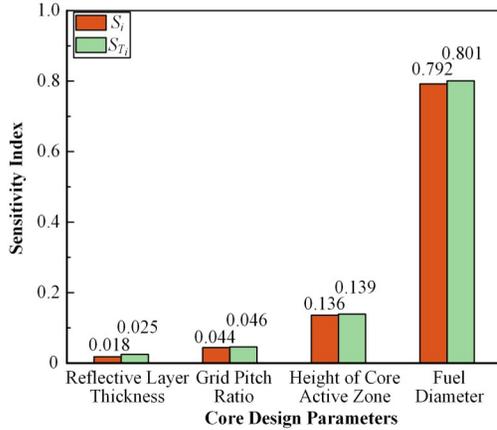


图7 堆芯设计参数对最大中子通量的敏感度指数 (彩色见网络版)

Fig.7 Sensitivity index of core design parameters to maximum neutron flux (color online)

由图7可以看出,对于最大中子通量,4组堆芯设计变量单独作用和共同作用下的影响程度都按照反射层厚度<栅径比<活性区高度<燃料芯块直径的递增顺序排列。燃料芯块直径是敏感性最强的变量,对最大中子通量的影响最为显著,其一阶敏感性指数是0.792,总阶敏感性指数是0.801;其次是活性区高度,对最大中子通量有较大影响,其一阶敏感性指数是0.136,总阶敏感性指数是0.139;随后是栅径比,对最大中子通量的影响略低,其一阶敏感性指数是0.044,总阶敏感性指数是0.046;反射层厚度是敏感度最低的变量,对最大中子通量的影响相对较小,

其一阶敏感性指数是0.018,总阶敏感性指数是0.025。在进行高通量铅铋反应堆中子通量最大化设计方法研究中,根据堆芯设计参数的敏感度,可以优先调节燃料芯块直径,再调节活性区高度、栅径比,最后调节反射层厚度。

#### 6.4 高通量铅铋反应堆优化设计平台验证

依托高通量铅铋反应堆优化设计平台,抽样生成1 600组堆芯参数组合并采用反应堆物理程序计算得到目标函数响应值建立初始训练数据库。使用基于BP神经网络动态代理模型的更新迭代优化方法开展堆芯最大中子通量密度设计参数寻优,每次预测10 000组新的目标函数响应值进行评估筛选,BP神经网络模型共更新迭代46次,获得最优的堆芯设计参数组合,堆芯最大中子通量密度寻优迭代结果如图8所示。通过RMC、Subchanflow程序校验计算,有40组满足约束条件。

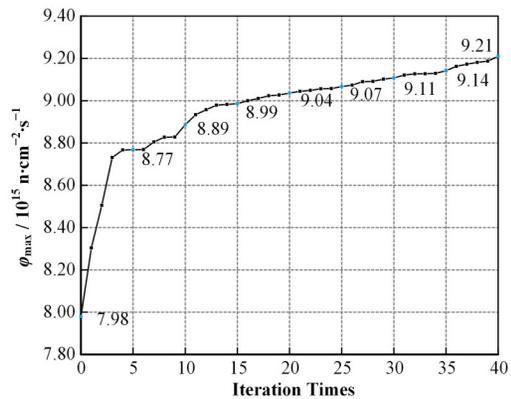


图8 堆芯最大中子通量密度寻优迭代结果  
Fig.8 Iterative optimization results of maximum neutron flux density in the core

表9 最优方案设计参数  
Table 9 Optimal program design parameters

堆芯方案及参数 Core program and parameters	初始方案 Initial program	优化方案 Optimization solutions
最大中子通量密度 Maximum neutron flux density / $\text{n}\cdot\text{cm}^{-2}\cdot\text{s}^{-1}$	$7.9798 \times 10^{15}$	$9.2098 \times 10^{15}$
栅径比 Grid pitch ratio	1.108 7	1.090 6
燃料芯块直径 Fuel diameter / cm	0.4	0.402 7
堆芯活性区高度 Height of core active zone / cm	50	40.477 7
反射层厚度 Reflective layer thickness / cm	80	214.182 0
初始 $k_{eff}$ Initial $k_{eff}$	1.005 9	1.001 5
换料周期 Refuel cycle / d	>90	>90
包壳最高温度 Maximum cladding temperature / $^{\circ}\text{C}$	533.63	525.43
芯块最大温度 Maximum fuel pellet temperature / $^{\circ}\text{C}$	992.67	969.10

最终搜索得到的最优堆芯方案的设计参数如表9所示,优化后的燃料芯块直径增大,增加了燃料芯块与冷却剂的接触面积,提升了燃料芯块与冷却剂的传热效率,有效降低了燃料芯块的温度,增强了燃

料组件的热负荷能力;优化后的活性区高度降低,堆芯压降减小,同一流速下,冷却剂温度降低,堆芯出口温度和最大包壳温度降低;优化后的栅径比减小,意味着相对于燃料棒的体积,冷却剂的体积减小,使

得中子能谱硬化,有助于提高最大中子通量密度;优化后的反射层厚度增大,增大反射层厚度可以减少中子泄漏,提高反应堆的平均输出功率,从而提高最大中子通量密度。结果表明:在满足堆芯初始有效增殖因数、换料周期、反应堆热工安全限值条件下,高通量铅铋反应堆寿期初的最大中子通量密度为  $9.2098 \times 10^{15} \text{ n} \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ , 相比初始方案提升 15.41%; 同时燃料芯块最高温度、包壳最高温度分别下降了  $23.57^\circ\text{C}$ 、 $8.20^\circ\text{C}$ , 优化的堆芯设计方案具备更大的稳态热工安全余量。上述验证结果和分析表明开发的高通量铅铋反应堆优化设计平台有效可靠。

## 7 结语

本文以提升堆芯中子通量为目标,针对高通量铅铋反应堆堆芯多因素相互影响、非线性物理/热工特性、多重设计约束的复杂问题,提出了基于BP神经网络动态代理模型的更新迭代优化方法,开发了高通量铅铋反应堆优化设计平台,以多功能超高通量堆为对象进行了验证,得到以下结论:

1)对于数据量有限的样本集,BP神经网络预测模型对于4组优化设计变量耦合影响下的最大中子通量和有效增殖因数预测结果,满足相对误差在0.1%内的精度要求,且预测10 000个数据仅需0.7 s,与蒙特卡罗程序RMC相比,极大提高了计算效率。

2)以多功能超高通量铅铋反应堆建立待优化模型,使用基于BP神经网络动态代理模型的更新迭代优化方法,进行4组堆芯设计参数的协同优化。在满足堆芯物理/热工约束条件下,优化堆芯方案的寿期初最大中子通量密度由  $7.9798 \times 10^{15} \text{ n} \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$  提升至  $9.2098 \times 10^{15} \text{ n} \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ , 燃料芯块最高温度、包壳最高温度分别下降了  $23.57^\circ\text{C}$ 、 $8.20^\circ\text{C}$ , 具备更大的稳态热工安全余量。证明提出的优化方法与开发的高通量铅铋反应堆优化设计平台有效可靠。

**致谢** 感谢清华大学反应堆工程计算分析实验室 (REAL 团队)提供的堆用蒙特卡罗分析程序RMC。

**作者贡献声明** 王彤负责BP神经网络程序设计,起草文章;刘紫静负责论文整体设计,数据分析;赵鹏程负责研究经费支持,思想知识指导;肖英杰负责对文章知识性内容作审阅和修正。

## 参考文献

1 蔡云,王连杰,汪量子,等. 超高通量快中子试验堆堆芯初步概念设计[J]. 核动力工程, 2023, 44(2): 222 - 226. DOI: 10.13832/j.jnpe.2023.02.0222.

CAI Yun, WANG Lianjie, WANG Liangzi, *et al.* Preliminary conceptual design of ultra-high flux fast neutron test reactor core[J]. Nuclear Power Engineering, 2023, 44(2): 222 - 226. DOI: 10.13832/j.jnpe.2023.02.0222.

2 Antipina M M, Bibilashvili Y K, Golovnin I S, *et al.* Testing of experimental BN-600-type fuel elements in the BOR-60 reactor up to different burnups[J]. Soviet Atomic Energy, 1976, 40(1): 14 - 25. DOI: 10.1007/BF01119387.

3 Izhutov A L, Krashennnikov Y M, Zhemkov I Y, *et al.* Prolongation of the BOR-60 reactor operation[J]. Nuclear Engineering and Technology, 2015, 47(3): 253 - 259. DOI: 10.1016/j.net.2015.03.002.

4 Gulevich A V, Klinov D A. Multilateral research program international research center MBIR proposal on R&D activities (fuels and materials) for the Ten Year Period 2025-2035[R].

5 Eliseev V A, Korobeynikova L V, Maslov P A, *et al.* ON feasibility of using nitride and metallic fuel in the MBIR reactor core[J]. Nuclear Energy and Technology, 2016, 2(3): 179 - 182. DOI: 10.1016/j.nucet.2016.07.009.

6 Heidet F, Grandy C, Sumner T, *et al.* FAST TEst Reactor (FASTER) design overview[J]. Progress in Nuclear Energy, 2018, 108: 465 - 473. DOI: 10.1016/j.pnucene.2018.06.008.

7 Roglans-Ribas J, Pasamehmetoglu K, O'Connor T J. The versatile test reactor project: mission, requirements, and description[J]. Nuclear Science and Engineering, 2022, 196(sup1): 1 - 10. DOI: 10.1080/00295639.2022.2035183.

8 Balderrama S, Sabharwall P, Wachs D. Versatile test reactor for advanced reactor testing[J]. Transactions of the American Nuclear Society, 2018, 119(1): 942.

9 冀南, 易金豪, 赵鹏程, 等. 基于自适应RBF神经网络预测堆芯热工水力参数的方法研究[J]. 核技术, 2022, 45(9): 090601. DOI: 10.11889/j.0253-3219.2022.hjs.45.090601.

JI Nan, YI Jinhao, ZHAO Pengcheng, *et al.* Research on adaptive RBF neural network prediction method for core thermal-hydraulic parameters of fast reactor[J]. Nuclear Techniques, 2022, 45(9): 090601. DOI: 10.11889/j.0253-3219.2022.hjs.45.090601.

10 Ridluan A, Manic M, Tokuhira A. EBaLM-THP - a neural network thermohydraulic prediction model of advanced nuclear system components[J]. Nuclear Engineering and Design, 2009, 239(2): 308 - 319. DOI:

- 10.1016/j.nucengdes.2008.10.027.
- 11 靳爽, 刘晓晶, 程旭. 基于神经网络的CFD粗网格模拟优化方法研究[J]. 核技术, 2021, **44**(6): 060601. DOI: 10.11889/j.0253-3219.2021.hjs.44.060601.  
JIN Shuang, LIU Xiaojing, CHENG Xu. Optimization method of CFD coarse grid numerical simulation based on neural network[J]. Nuclear Techniques, 2021, **44**(6): 060601. DOI: 10.11889/j.0253-3219.2021.hjs.44.060601.
- 12 Mazrou H. Performance improvement of artificial neural networks designed for safety key parameters prediction in nuclear research reactors[J]. Nuclear Engineering and Design, 2009, **239**(10): 1901 - 1910. DOI: 10.1016/j.nucengdes.2009.06.004.
- 13 张相文, 范晨光, 何安, 等. 基于GA-BP神经网络对控制棒水力缓冲器的性能预测和结构参数优化[J]. 核动力工程, 2023, **44**(6): 162 - 169. DOI: 10.13832/j.jnpe.2023.06.0162.  
ZHANG Xiangwen, FAN Chenguang, HE An, *et al.* Performance prediction and structural parameter optimization of control rod hydraulic buffer based on GA-BP neural network[J]. Nuclear Power Engineering, 2023, **44**(6): 162 - 169. DOI: 10.13832/j.jnpe.2023.06.0162.
- 14 张海明, 张昊春. 基于卷积神经网络模型的堆芯有效增殖因数预测方法研究[J]. 现代应用物理, 2022, **13**(2): 61 - 66. DOI: 10.12061/j.issn.2095-6223.2022.020209.  
ZHANG Haiming, ZHANG Haochun. Prediction method of effective multiplication factor of reactor core based on convolution neural network model[J]. Modern Applied Physics, 2022, **13**(2): 61 - 66. DOI: 10.12061/j.issn.2095-6223.2022.020209.
- 15 McKay M D, Beckman R J, Conover W J. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code[J]. Technometrics, 2000, **42**(1): 55 - 61. DOI: 10.2307/1271432.
- 16 宋孟燕, 张超琦, 孙晓颖. 基于拉丁超立方抽样的某核岛厂房概率SSI分析研究[J]. 核科学与工程, 2021, **41**(2): 306 - 312. DOI: 10.3969/j.issn.0258-0918.2021.02.016.  
SONG Mengyan, ZHANG Chaoqi, SUN Xiaoying. Probability SSI analysis of a nuclear island building based on Latin hypercube sampling[J]. Nuclear Science and Engineering, 2021, **41**(2): 306 - 312. DOI: 10.3969/j.issn.0258-0918.2021.02.016.
- 17 王群. 基于对称拉丁超立方设计的多目标进化算法[D]. 西安: 西安电子科技大学, 2011.  
WANG Qun. Multiobjective evolutionary algorithm based on symmetric Latin hypercube designs[D]. Xi'an: Xidian University, 2011.
- 18 Wang K, Li Z G, She D, *et al.* RMC - a Monte Carlo code for reactor core analysis[J]. Annals of Nuclear Energy, 2015, **82**: 121 - 129. DOI: 10.1016/j.anucene.2014.08.048.
- 19 Sánchez V, Imke U, Ivanov A, *et al.* SUBCHANFLOW: a thermal-hydraulic sub-channel program to analyse fuel rod bundles and reactor cores[C]. 17th Pacific Basin Nuclear Conference, 2010: 1 - 18.
- 20 OECD, Agency N E. Handbook on lead-bismuth eutectic alloy and lead properties, materials compatibility, thermalhydraulics and technologies[M]. OECD, 2015. DOI: 10.1787/42dcd531-en.
- 21 Sobol I. Sensitivity estimates for nonlinear mathematical models[J]. Matematicheskoe Modelirovanie, 1993, **2**(1): 112 - 118.
- 22 刘天怡, 李小明. 基于Sobol指数法的电磁阀参数敏感性分析[C]. 第七届空天动力联合会议暨中国航天第三专业信息网第四十三届技术交流会论文集(第四册). 苏州, 2023: 2 - 9.  
LIU Tianyi, LI Xiaoming. Sensitivity analysis of solenoid valve parameters based on Sobol index method[C]. Proceedings of the 7th Joint Conference on Aerospace Power and the 43rd Technical Exchange Conference of China Aerospace Third Professional Information Network (Volume 4). Suzhou, China, 2023: 2 - 9.
- 23 尹文进, 张静远, 饶喆, 等. 基于Sobol指数法作战能力全局敏感性分析方法[J]. 船电技术, 2015, **35**(12): 19 - 21, 25. DOI: 10.13632/j.meee.2015.12.005.  
YIN Wenjin, ZHANG Jingyuan, RAO Zhe, *et al.* Global sensitivity analysis method based on sobol index method [J]. Marine Electric & Electronic Engineering, 2015, **35**(12): 19 - 21, 25. DOI: 10.13632/j.meee.2015.12.005.