



**MELHORANDO A EFICIÊNCIA DOS PEQUENOS REATORES MODULARES
NUSCALE: UMA ABORDAGEM DE OTIMIZAÇÃO COM IA UTILIZANDO
CONFIGURAÇÃO SEED-BLANKET**

Marcelo V. da Silva¹, Diego Manoel E. Gonçalves¹, Anderson Patricio Reaende¹, João Victor S. A. Guimaraes², Alan Miranda M. de Lima¹, Andressa S. Nicolau¹, Claudio M.N.A. Pereira³, Giovanni L. de Stefani¹, Roberto Schirru¹

¹PEN/COPPE/Universidade Federal do Rio de Janeiro, Av. Horácio Macedo 2030, Rio de Janeiro, RJ, Brasil

² DNC/POLI/Universidade Federal do Rio de Janeiro, Av. Horácio Macedo 2030, Rio de Janeiro, RJ, Brasil

³ Instituto de Engenharia Nuclear-IEN/CNEN, Rio de Janeiro, RJ, Brasil

mvilela@coppe.ufrj.br

Palavras-Chave: Núcleo do Reator, Ciclo do Combustível, *NuScale*, SMR, *Seed-Blanket*

RESUMO

Os reatores modulares pequenos de água leve (LW-SMR) da *NuScale* são projetados para serem mais compactos, econômicos e seguros do que os grandes reatores nucleares convencionais, utilizando água leve como refrigerante e moderador de nêutrons. Este artigo investiga um reator SMR, baseado no conceito *seed-blanket* com combustível de tório, utilizando Inteligência Artificial (IA) para a otimização do projeto do reator. Os objetivos incluem a conversão do elemento combustível padrão para o conceito *seed-blanket*, a análise dos venenos queimáveis, o aumento do fator de conversão e a produção de U-233. Para isso, foram desenvolvidos modelos paralelos de IA multiobjetivo utilizando Otimização por Enxame de Partículas (PSO – Particle Swarm Optimization) acoplados com o código SERPENT para realizar cálculos com uma modelagem detalhada do núcleo. Os resultados mostram melhorias potenciais na eficiência em comparação com os projetos de núcleos convencionais.

1. INTRODUÇÃO

O avanço científico e tecnológico, e a busca por fontes de energia mais seguras e sustentáveis têm impulsionado o desenvolvimento de Pequenos Reactores Modulares (SMR, na sigla em inglês). Os SMRs representam uma nova geração de reatores nucleares que oferecem diversas vantagens em relação aos reatores nucleares tradicionais de grande escala. Além de serem caracterizados por sua modularidade e menor tamanho são flexíveis em suas aplicações, e estão se tornando uma alternativa viável para atender às crescentes demandas energéticas globais, especialmente em regiões remotas ou com infraestrutura limitada [1][2].

Estudos recentes exploram a viabilidade de conversão dos núcleos de reatores SMR, do tipo *NuScale* [3][1][4], de UO_2 para misturas de combustíveis contendo tório, como $(U, Th)O_2$ e $(Pu, Th)O_2$ no conceito de *seed-blanket* [5]. Este conceito envolve a utilização de zonas de semente (*seed*), compostas por combustíveis mais ativos, e zonas de cobertor (*blanket*), formadas por materiais férteis, promovendo uma queima mais eficiente e prolongada do combustível nuclear,



além de um ciclo de combustível mais sustentável. Trabalhos como o de Gonçalves, et. al., 2024 [3] exploram essa transição, oferecendo uma visão paramétrica detalhada dos benefícios desse rearranjo. Além disso, a integração de inteligência artificial em projetos nucleares, como proposto por Silva, et. al., 2024 [1], abre novas fronteiras para otimização automática de parâmetros do projeto do reator, maximizando a eficiência e a segurança do reator. A aplicação de algoritmos de inteligência artificial, como o *Particle Swarm Optimization* (PSO) [6], tem sido especialmente útil na otimização de núcleos de reatores, como no caso do IEA-RI, conforme detalhado em Santos, et. al., 2023 [7].

Os projetos modernos incorporam inovações tecnológicas que aumentam a segurança intrínseca dos reatores, incluindo sistemas passivos de resfriamento e menor quantidade de material fissil no núcleo, o que minimiza os riscos de acidentes nucleares. Ademais, a menor escala dos SMR facilita a implementação de melhorias contínuas e adaptações às regulamentações de segurança, tornando-os uma opção atrativa, tanto do ponto de vista técnico, quanto regulatório. Essas características tornam os pequenos reatores modulares competitivos economicamente com outras fontes energéticas. Dentre esses reatores, um dos mais promissores é o *NuScale*, com o conceito de projeto já licenciado pela *Nuclear Reactor Commission* (NRC) e com potencial para comercialização iminente.

No panorama energético atual, marcado pela necessidade de reduzir as emissões de gases de efeito estufa e encontrar soluções sustentáveis para a geração de eletricidade, os SMR emergem como uma solução promissora. A combinação entre esses combustíveis avançados e abordagens de otimização por IA propostas neste artigo visa não apenas melhorar a eficiência dos reatores nucleares, mas também contribuir para a evolução sustentável da energia nuclear, alinhando-se com as metas globais de redução de emissões e segurança energética.

Dentro deste contexto os principais objetivos deste trabalho são descritos abaixo:

- Desenvolver um modelo de otimização multiobjetivo baseado no algoritmo PSO para melhorar a eficiência dos SMR's do tipo *NuScale* com configuração *seed-blanket*.
- Avaliar o desempenho do núcleo com foco: no ciclo de vida do combustível, na queima e na produção de resíduos.

2. METODOLOGIA

Esta seção descreve brevemente os principais materiais e métodos utilizados na pesquisa, com foco no código SERPENT, um software de transporte de partículas baseado no Método de Monte Carlo e desenvolvido pelo *VTT Technical Research Centre of Finland* [9]. O SERPENT, inicialmente criado para física de reatores, evoluiu para um código abrangente com aplicações que incluem cálculos de criticidade, estudos do ciclo do combustível, modelagem de reatores de pesquisa, e simulações de multifísica acopladas com termo-hidráulica, *Computational Fluid Dynamics* (CFD), e códigos de desempenho de combustível.

2.1. Otimização por Enxame de Partículas

Uma abordagem para otimizar a configuração de reatores nucleares e mitigar a produção de resíduos, mantendo a eficiência, pode ser desenvolvida utilizando algoritmos de Inteligência Artificial (IA), tal como o algoritmo de otimização de Enxame de Partículas (PSO – Particle Swarm Optimization) [10]. Além disso, o algoritmo de IA permite que características do reator sejam personalizados para simulações específicas, ajustando aspectos tais como: a disposição das varetas



e os materiais utilizados. Desta forma, a Figura (1), apresenta um esquema ilustrativo de uma configuração *seed-blanket* de um elemento combustível, o qual é utilizado em diferentes posições no núcleo do reator.

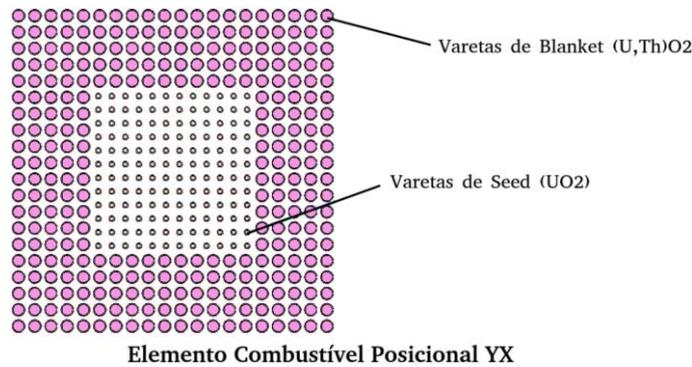


Figura 1. Esquema Posicional de Varetas de Combustível em Configuração *seed-blanket*.

A Figura (2) apresenta um esquema de configuração de um reator nuclear, mostrando a disposição de diferentes elementos combustíveis. A disposição do núcleo apresenta quatro regiões (A01, B01, C01 e D01), com propriedades semelhantes de enriquecimento e concentração de veneno queimável, como Gd_2O_3 . O lote D01 é composto inicialmente apenas por um elemento. As regiões A01 e D01 possuem o mesmo enriquecimento de UO_2 e Gd_2O_3 , enquanto as regiões B01 e C01 possuem níveis de enriquecimento diferentes. O enriquecimento de $A01 = D01 = 0,5 \cdot C01$ e $B01 = 0,75 \cdot C01$. Ao final de cada ciclo, as regiões A01 e D01 serão removidos para aumentar a taxa de fissão no núcleo e reduzir nas regiões externas. Essa configuração é preliminar, sendo que o objetivo final é o de permitir que um algoritmo de otimização busque regiões mais eficientes sem essas restrições.

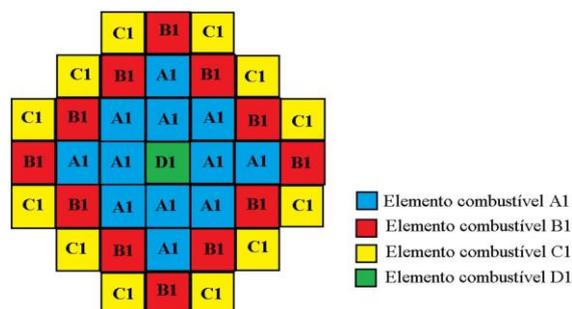


Figura 2. Núcleo completo e posicionamento dos elementos combustíveis.

2.1.1 Algoritmo de Otimização

O processo de otimização, com o algoritmo PSO, foi utilizado neste estudo para o projeto do reator SMR. Neste processo, as partículas, representadas por vetores de posição com dimensão correspondente ao número de parâmetros otimizados, são criadas aleatoriamente dentro do espaço de busca, ou seja, dentro do espaço possível de variação de cada parâmetro do projeto do reator a



ser otimizado. As posições e velocidades de cada partícula no PSO, também são inicializadas de forma aleatória. A evolução do PSO, na busca de um ótimo global, se dá pela atualização das equações de velocidade e posição de cada partícula, de acordo com as equações (1) e (2), respectivamente.

$$v_{i,j}^{t+1} = wv_{i,j}^t + c_1r_1^t(Pbest_{i,j} - x_{i,j}^t) + c_2r_2^t(Gbest_j - x_{i,j}^t) \quad (1)$$

$$x_{i,j}^{t+1} = x_{i,j}^t + v_{i,j}^{t+1} \quad (2)$$

Tabela 1. Siglas e significados.

| Sigla | Significado |
|---------------|---|
| W | Peso |
| $C_{1,2}$ | Constantes |
| $r_{1,2}^t$ | Variáveis randômicas para a iteração t |
| $v_{i,j}^t$ | Velocidade da partícula i , para a variável j , na iteração t |
| $x_{i,j}^t$ | Posição da partícula i , para a variável j , na iteração t |
| $Gbest_j$ | Melhor posição conhecida pelo enxame, na variável j |
| $Pbest_{i,j}$ | Melhor posição conhecida pela partícula i , na variável j |

A atualização das posições e velocidades das partículas do PSO, através das componentes individual (CI) e do grupo ($C2$), quando guiadas por uma função objetivo tendem a convergir para um ótimo global. A função objetivo, que neste artigo é multiobjetivo, representa a função a qual se quer maximizar ou minimizar, no caso em estudo o objetivo é maximizar, e deve levar em conta os objetivos do projeto do reator SMR. Esses objetivos são calculados pelo software de simulação SERPENT. A função objetivo é calculada para determinar a qualidade de cada solução. Na evolução do PSO, onde cada iteração é chamada de geração, o algoritmo calcula a função objetivo de cada partícula (*fitness*). A melhor posição global (*gbest*) e a melhor posição individual (*pbest*) são atualizadas, e as partículas ajustam suas posições e velocidades ao longo das gerações, até que um critério de parada seja atingido, neste caso o critério de parada utilizado foi o número máximo de gerações

2.1.2 Parâmetros do Projeto do Reator a serem otimizados (Entradas de Otimização)

O código do algoritmo PSO foi desenvolvido especificamente para gerar arquivos de entrada para simulações do reator do tipo NuScale utilizando o código SERPENT. O processo de simulação começa com a geração de 14 parâmetros aleatórios, incluindo valores como o número de varetas de *seed* e *blanket*, percentuais de diâmetro para diferentes regiões do reator, e enriquecimentos de materiais específicos. Esses parâmetros são essenciais para explorar diferentes configurações do reator e realizar simulações. A Tabela (2), representa os parâmetros de entrada relacionados ao combustível e à geometria do reator, e também representa o vetor solução do PSO (14 dimensões).



Tab. 2. Parâmetros de entrada gerados para otimização.

| Parâmetro | Intervalo |
|-------------------------------------|---------------|
| Numero de varetas seed | 7-13 |
| Numero de varetas de blanket | 14-21 |
| % Diâmetro do seed | 0.2-0.9 |
| % Diâmetro do blanket | 0.3-0.9 |
| % seed UO ₂ | 14-20 |
| % blanket (U, Th)O ₂ | 5-15 |
| Al seed % | % seed |
| B1 seed % | 0.75 (% seed) |
| Cl seed % | 0.5 (% seed) |
| D1 seed % | % seed |
| % Gd ₂ O ₃ Al | 0.0-0.3 |
| % Gd ₂ O ₃ B1 | 0.0-0.3 |
| % Gd ₂ O ₃ Cl | 0.0-0.3 |
| % Gd ₂ O ₃ DI | 0.0-0.3 |

2.1.1. Função Objetivo da Otimização

A função objetivo da otimização gerencia o processo desde a inicialização até a gravação dos resultados, buscando a melhor solução. O código otimiza o desempenho do reator considerando as variáveis da Tabela (2), que são as entradas para o código SERPENT. Para cada entrada é calculada a sua *fitness* (função objetivo) que neste primeiro estudo considerou a maximização dos seguintes parâmetros de saída do SERPENT:

$$fitness = f('U-235_A01', 'U-235_B01', 'U-235_C01', 'U-235_D01', 'U-233/Th-232', 'Pu-239', 'Keff')$$

Sendo a *fitness* uma função multiobjetiva, considerando que todos os objetivos são de maximização, para uma análise inicial, consideramos a função descrita na equação (3).

$$fitness = A1 + A2 + A3 + A4 + A5 + A6 + A7 \quad (3)$$

onde:

$$A1 = (k1 * (F(k_{eff}))); A2 = (k2 * ['Pu-239']); A3 = (k3 * ['U-233/Th-232']); A4 = (k4 * ['U-235_D01']); A5 = (k5 * ['U-235_C01']); A6 = (k6 * ['U-235_B01']) e A7 = (k7 * ['U-235_A01'])$$

Os valores k_i foram selecionados para manter as saídas na mesma escala dimensional ($k2 = 100$; $k3 = 100$; $k4 = 1$; $k5 = 3$; $k6 = 3$; $k7 = 3$), exceto o $k1$ que é igual a 1 e o $F(k_{eff})$ assume a forma lógica descrita na equação 4, com o intuito de forçar uma solução, onde k_{eff} fique em torno do valor 1, ao final do ciclo. Esta configuração força o k_{eff} a se aproximar do valor 1 ao final do ciclo.

$$f(k_{eff}) = \begin{cases} 200 * k_{eff}, & se 0.90 \leq k_{eff} < 0.98 \\ 4000 * k_{eff}, & se 0.98 \leq k_{eff} < 0.99 \\ 5000 * k_{eff}, & se 0.99 \leq k_{eff} \leq 1 \\ 100 * k_{eff}, & se k_{eff} < 0.9 ou > 1 \end{cases} \quad (4)$$



3. RESULTADOS PRELIMINARES

Neste estudo, a principal ênfase foi verificar o comportamento do código PSO desenvolvido e seu acoplamento com o código SERPENT. Dessa forma, algumas simplificações iniciais foram feitas no modelo. A Figura (3) mostra o comportamento do fator de multiplicação k_{eff} ao longo de 550 dias, evidenciando a capacidade do reator de manter a reatividade durante esse ciclo otimizado pelo PSO, considerando os três melhores resultados de 100 interações distintas (56, 57 e 43) para um número de partículas igual a 30. Inicialmente, há um leve aumento no k_{eff} atingindo um pico em torno de 50 dias. Essa variação inicial pode ser explicada pelo consumo da maior parte do gadolínio contido no combustível, o que é um comportamento típico de veneno queimável, conforme evidenciado na literatura[11][12][13].

No entanto, a simplificação feita neste estudo inicial, na qual o gadolínio foi misturado em todas as varetas de combustível, em diferentes frações para cada zona de enriquecimento, minimizou a quantidade de gadolínio e reduziu o crédito de reatividade em função da queima do gadolínio. Enquanto em outros estudos, como o do SMART[12], o crédito de reatividade alcança a ordem de centenas de dias (550 dias), no presente caso, observou-se uma redução para cerca de 50 dias, com uma taxa de crescimento do k_{eff} muito mais acelerada do que o desejado. Isso pode comprometer a preservação dos lotes de combustível que permaneceriam em uso por mais ciclos.

No caso clássico, conforme visto na referência [12], um número discreto de varetas contém gadolínio, e não uma mistura em todas. Assim, nota-se que, para uma melhor preservação dos elementos combustíveis, é desejável que o gadolínio não seja misturado em todas as varetas.

Após o pico inicial de reatividade, observa-se uma queda gradual no k_{eff} , que está relacionada tanto à queima do material físsil (como o U-235) quanto ao consumo dos venenos queimáveis, como o gadolínio. À medida que o gadolínio é queimado, sua capacidade de absorver nêutrons diminui, o que inicialmente aumenta k_{eff} . No entanto, conforme o combustível U-235 é depletado e o Pu-239 e U-233 são gerados por captura de nêutrons, a reatividade é sustentada. Esse equilíbrio entre a queima de combustível e a produção de novos isótopos físsis permite uma operação mais longa do reator sem a necessidade de reabastecimento frequente, o que é um dos benefícios principais da configuração *seed-blanket*. Essa queda é suavizada pela produção de plutônio-239, resultante da captura de nêutrons pelo urânio-238, e de U-233, proveniente da captura de nêutrons pelo Th-232, o que temporariamente compensa a perda de reatividade. Essa compensação demonstra uma queda mais suave ao longo do tempo, comparada com reatores de potência tradicionais ou mesmo um SMR em ciclo de urânio [11][12][13].

Essa contribuição decresce suavemente ao longo do tempo, levando o k_{eff} a valores próximos de 1, após aproximadamente 500 dias, comportamento típico de um reator a tório. Essa análise parcial revela que o ciclo otimizado permite um uso eficiente do combustível, mantendo a operação segura e controlada, com a reatividade sustentada pelos mecanismos de produção de Pu-239 até o final do ciclo. A queda gradual reflete o esgotamento da capacidade físsil do núcleo, sugerindo a necessidade de reposição ou reconfiguração do combustível após 550 dias.

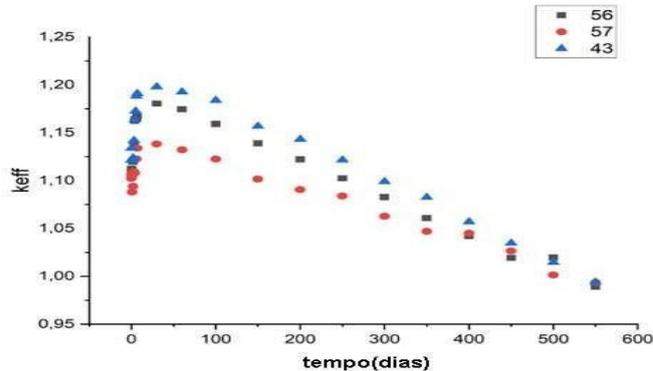


Fig. 3. Gráfico do k_{eff} em função do tempo.

Na Tabela (3), nota-se que a elevada razão de conversão no caso 56 está associada à maior produção de Pu-239, enquanto nos casos 57 e 43 observa-se uma maior produção de U-233. Essa é uma das características que deve ser ajustada na função de *fitness* para obter resultados mais refinados. A queima nos três casos foi similar, com valores acima de 70% nas regiões A01 e D01, mais próximas ao centro, conforme desejado, já que essas serão as primeiras regiões a serem removidas do núcleo. A função de *fitness* utilizada na otimização multiobjetivo leva em consideração diversos parâmetros, como a produção de U-233 e Pu-239, o consumo de U-235, e o controle da reatividade através da queima dos venenos queimáveis. O gadolínio, sendo um veneno queimável, desempenha um papel crucial no controle da reatividade excessiva nas fases iniciais do ciclo de queima. Ajustar a concentração de gadolínio nas regiões C01 e B01 pode melhorar ainda mais o controle da reatividade, evitando picos indesejados no início do ciclo e permitindo que o combustível físsil seja utilizado de forma mais eficiente ao longo do tempo. A função de *fitness*, portanto, busca não apenas maximizar a produção de isótopos físsis, mas também garantir um ciclo de queima mais estável e seguro, equilibrando a reatividade inicial e a sustentação da reatividade nas fases avançadas do ciclo.

Entretanto, na próxima etapa deste estudo, será acoplada uma análise térmica para garantir que os picos de potência não prejudiquem a integridade física do combustível.

Tab. 3 Análise Paramétrica de Configurações de Núcleo para Casos Otimizados.

| Parâmetro | Caso 56 | Caso 57 | Caso 43 |
|---|---------|---------|---------|
| Matriz do blanket | 16x16 | 20x20 | 15x15 |
| Matriz do seed | 9x9 | 12x12 | 8x8 |
| Pitch blanket (cm) | 1,344 | 1,075 | 1,433 |
| Raio da vareta do blanket (cm) | 0,5501 | 0,4247 | 0,5084 |
| Pitch seed (cm) | 1,493 | 0,896 | 1,612 |
| Raio da vareta do seed (cm) | 0,2941 | 0,2007 | 0,2961 |
| Enriquecimento do seed da região C01 (%) | 16.96 | 18.83 | 19.46 |
| UO ₂ no MOX do blanket de (Th, U)O ₂ (%) | 13.77 | 14.86 | 14.38 |
| Gd ₂ O ₃ no MOX do seed de UO ₂ + Gd ₂ O ₃ na região A01 (%) | 0.10 | 0,17 | 0,18 |
| Gd ₂ O ₃ no MOX do seed de UO ₂ + Gd ₂ O ₃ na região B01 (%) | 0.09 | 0,024 | 0,06 |
| Gd ₂ O ₃ no MOX do seed de UO ₂ + Gd ₂ O ₃ na região C01 (%) | 0.22 | 0,25 | 0,19 |
| Gd ₂ O ₃ no MOX do seed de UO ₂ + Gd ₂ O ₃ na região D01 (%) | 0.09 | 0,09 | 0,25 |
| Razão V_f/V_m no blanket | 1,11 | 0,96 | 0,65 |
| Razão V_f/V_m no seed | 0,14 | 0,19 | 0,12 |
| Razão de Conversão (EOC) | 0,55 | 0,62 | 0,51 |



| | | | |
|--------------------------------|---------|---------|---------|
| U-233(EOC)/Th-232(BOC) (%) | 0,75 | 0,78 | 0,84 |
| Pu-239(EOC)/U-238(BOC) (%) | 0,85 | 0,75 | 0,56 |
| Consumo de U-235 na região A01 | 75,07 | 69,71 | 73,66 |
| Consumo de U-235 na região B01 | 61,38 | 55,78 | 60,44 |
| Consumo de U-235 na região C01 | 45,00 | 39,52 | 44,06 |
| Consumo de U-235 na região D01 | 79,93 | 74,70 | 77,08 |
| Fitness | 5727,69 | 5709,31 | 5727,21 |

Na tabela 4, pode-se observar que a conversão mais elevada ocorre no caso da 3ª melhor *fitness*, que, no entanto, acaba por produzir uma quantidade significativa, tanto de Pu-239, quanto de U-233, proporcionalmente em relação ao U-238 e Th-232 presentes inicialmente no núcleo. Há a necessidade de ajustar os pesos da função de *fitness* para aprimorar os resultados, maximizando ainda mais a conversão, que está abaixo do valor esperado, e atribuindo prioridade adequada aos parâmetros. Devido a uma alteração no espectro para a faixa epitérmica é possível observar também que a razão entre combustível e moderador é maior para o *blanket* nos melhores casos e menor para o *seed*, indicando que os nêutrons produzidos no *seed* já devem sair quase totalmente moderados, perdendo pouca energia ao atravessarem o *blanket*.

A Figura (4), apresenta a evolução das densidades de massa de diferentes isótopos de plutônio (Pu-238, Pu-239, Pu-241 e Pu-242) ao longo do ciclo de queima do núcleo otimizado. A análise desse comportamento é essencial para compreender a dinâmica do consumo do combustível nuclear, pois a razão de conversão elevada reflete a eficiência na conversão de U-238 em Pu-239, o que pode prolongar a sua vida útil. O aumento inicial, principalmente do Pu-239, ocorre devido à captura de nêutrons pelo U-238, resultando em sua formação em grandes quantidades, o que contribui para a reatividade ao longo do ciclo. O Pu-238, por outro lado é produzido em pequenas quantidades e não tem um impacto significativo na fissão. O Pu-241 é importante para a reatividade a longo prazo, pois contribui para a fissão nas fases avançadas do ciclo. Já o Pu-242 é produzido pela captura de nêutrons pelo Pu-241, mas não contribui diretamente para a fissão.

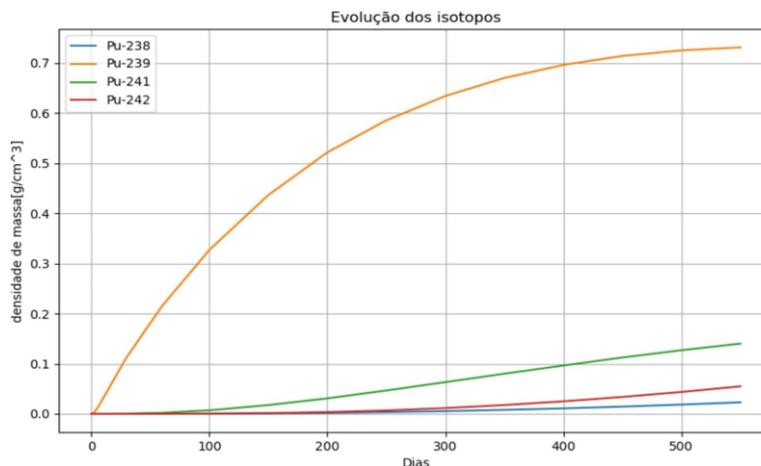


Fig. 4. Resultado da produção de Plutônio da melhor configuração.



4. CONCLUSÕES

A integração da IA no processo de otimização do projeto SMR aumenta a eficiência, o desempenho e a segurança, além de abrir caminho para futuros avanços no projeto e na engenharia de reatores nucleares. O combustível à base de tório na configuração *seed-blanket* apresenta uma relação significativamente maior entre a captura de nêutrons férteis pelo Th-232 e a produção de U-233, em comparação ao combustível de UO₂ puro. Esse processo é particularmente vantajoso, pois o U-233 é um material físsil que contribui diretamente para a manutenção da reatividade do reator ao longo do ciclo de queima. Essa conversão eficiente possibilita o melhor aproveitamento do material fértil, prolongando a vida útil do núcleo, uma característica crucial para reatores modulares pequenos (SMRs). O U-233 produzido compensa a depleção de U-235 nas fases intermediárias e avançadas do ciclo, promovendo uma queima mais eficiente e sustentada. Do ponto de vista da física de reatores, a maior taxa de conversão entre nêutrons férteis e a produção de isótopos físsis (como U-233 e Pu-239) no combustível *seed-blanket* demonstrou-se vantajosa ao melhorar o potencial de acumulação de materiais físsis e sustentar a reatividade ao longo do ciclo de queima. A integração dos venenos queimáveis, como o gadolínio, na configuração otimizada garantiu que a reatividade inicial fosse controlada de forma eficiente, o que, combinado com a função de *fitness*, otimizou o desempenho do reator ao longo do tempo. Esses resultados indicam que o uso de tório em reatores SMR pode ser uma solução promissora para a geração de energia nuclear sustentável, com ciclos de combustível mais longos e maior segurança operacional. Para um próximo trabalho alguns parâmetros devem ser adicionados a esse estudo, como uma distribuição discreta de varetas de MOX de gadolínio e urânio na região de *seed* e alguns pesos devem ser alterados na *fitness*, além um disso será testado um *blanket* axial na região de *seed* e *blanket* com o objetivo de aumentar ainda mais a conversão e inserir na modelagem um melhor refletor. Dessa forma, com esses parâmetros espera-se alcançar valores de conversão mais altos, além de permitir a otimização dos enriquecimentos de cada região de combustível.

AGRADECIMENTOS

Os autores agradecem o financiamento e o apoio concedidos pelas agências de pesquisa brasileiras: Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Fundação de Amparo à Pesquisa do Rio de Janeiro (FAPERJ) e ao INCT de Reatores Inovadores.

Referências

- [1] M. V. Silva, R. Schirru, G. L. de Stefani et al., «Optimized modular nuclear reactor project utilizing artificial intelligence: Seed-blanket concept», *Nuclear Engineering and Design*, v. 423, p. 113 187, jul. de 2024. doi: 10.1016/j.nucengdes.2024.113187.
- [2] R. Akbari, M. Aghili Nasr, F. D'Auria, A. Cammi, J. Maiorino e G. de Stefani, «Analysis of thorium-transuranic fuel deployment in a LW-SMR: A solution toward sustainable fuel supply for the future plants», *Nuclear Engineering and Design*, v. 421, p. 113 090, mai. de 2024. doi: 10.1016/j.nucengdes.2024.113090.
- [3] D. M. E. Gonçalves, M. V. da Silva, C. J. C. da Cunha, D. A. Palma e G. L. de Stefani, «Feasibility of Converting NuScale SMRs from UO₂ to Mixed (Pu, Th)O₂ and (U, Th)O₂ Cores: A Parametric Study of the Seed-Blanket Fuel Assembly», *Nuclear Engineering and Design*, v. 424, p. 113 230,



- ago. de 2024. doi: 10.1016/j.nucengdes.2024.113230.
- [4] NuScale, *NuScale: Small Modular Reactor*, <https://www.nuscatpower.com/en>, Accessed: 2024-07-07, 2024.
 - [5] A. Radkowsky, «The Seed-Blanket Core Concept», *Nuclear Science and Engineering*, v. 90, n. 4, pp. 381-387, 1985.
 - [6] J. Kennedy e R. Eberhart, «Particle swarm optimization», em *Proceedings of ICNN'95-international conference on neural networks*, iee, vol. 4, 1995, pp. 1942-1948.
 - [7] T. A. dos Santos, F. A. Genezini e G. L. de Stefani, «Optimization of IEA-R1 reactor core parameters using the particle swarm algorithm», *Nuclear Engineering and Design*, v. 415, p. 112-113, dez. de 2023. doi: 10.1016/j.nucengdes.2024.113230
 - [8] R. Schirru, A. M. M. De Lima e M. D. Machado, «Parallel evolutionary methods applied to a pwr core reload pattern optimization», em *Applied Artificial Intelligence*, world Scientific, jul. de 2006, pp. 915-921. doi: 10.1142/9789812774118_0128.
 - [9] J. Leppänen, M. Pusa, T. Viitanen, V. Valtavirta e T. Kaltiaisenaho, (2015). «The Serpent Monte Carlo code: Status, development and applications in 2013». *Annals of Nuclear Energy*, 82, 142-150.
 - [10] C. M. N. A. Pereira, R. Schirru e A. S. Martinez, «Genetic Algorithms Applied to Nuclear Reactor Design Optimization», em *Fuzzy Systems and Soft Computing in Nuclear Engineering*. Physica-Verlag HD, 2000, pp. 315-334, isbn: 9783790818666.
 - [11] R. Akbari, M. Aghili Nasr, F. D'Auria, A. Cammi, J.R. Maiorino, G.L. de Stefani. Analysis of thorium-transuranic fuel deployment in a LW-SMR: A solution toward sustainable fuel supply for the future plants, *Nuclear Engineering and Design*, Volume 421,113090, 2024. <https://doi.org/10.1016/j.nucengdes.2024.113090>.
 - [12] Reza Akbari-Jeyhouni, Dariush Rezaei Ochbelagh, Jose R. Maiorino, Francesco D'Auria, Giovanni Laranjo de Stefani. The utilization of thorium in Small Modular Reactors – Part I: Neutronic assessment, *Annals of Nuclear Energy*, Volume 120, Pages 422-430,2018. <https://doi.org/10.1016/j.anucene.2018.06.013>.
 - [13] Giovanni Laranjo de Stefani, João Manoel Losada Moreira, José Rubens Maiorino, Pedro Carlos Russo Rossi. Detailed neutronic calculations of the AP1000 reactor core with the Serpent code, *Progress in Nuclear Energy*, Volume 116, Pages 95-10, 2019. <https://doi.org/10.1016/j.pnucene.2019.03.030>.