



OTIMIZAÇÃO DA RECARGA DE UM NÚCLEO PWR USANDO REDES NEURAIAS ARTIFICIAIS MLP E PSO

Edyene Oliveira, Wilmer Aruquipa, Patricia A. de L. Reis, Claubia Pereira

¹Departamento de Engenharia Nuclear, Programa de Pós-Graduação em Ciências e Técnicas Nucleares, Universidade Federal de Minas Gerais Av. Pres. Antônio Carlos, 6627 31270-901 Pampulha, Belo Horizonte, MG.
e-mail: edyene.oliveira@gmail.com

Palavras-Chave: Otimização, PWR, Redes Neurais Artificiais

RESUMO

Uma recarga é necessária geralmente a cada 18 meses nos reatores de água pressurizada, como os existentes no Brasil. Esse processo seria simples caso fosse similar à troca de peças em determinada máquina. Porém, recarga exige conhecimento devido a vários fatores, como quantidade elevada de elementos combustíveis no núcleo; no caso de Angra 2 são 193. As trocas não são de todas as posições, geralmente a tarefa é realizada em apenas 1/3 do total. A quantidade retirada constitui a que apresenta maior queima do combustível. Ao inserir novos elementos combustíveis, ocorre alteração em todo o núcleo. Isso acontece devido ao fato de que cada elemento combustível gera potência correspondente ao tipo de enriquecimento utilizado e posição disposta. Sendo assim, tais fatores influenciam na distribuição de potência no reator, que poderá alterar o desempenho esperado e/ou planejado para o próximo ciclo de funcionamento, alterando inclusive parâmetros importantes de segurança. Diversos estudos que utilizam algoritmos computacionais a fim de otimizar o núcleo do reator são propostos na literatura e tal pesquisa é ainda um campo aberto para novas propostas. Este trabalho pretende encontrar resultados que possam contribuir para a obtenção de melhores distribuições dos combustíveis no núcleo utilizando RNA (Redes Neurais Artificiais) MLP (*Multi Layer Perceptron*) com algoritmos de treinamento Backpropagation e PSO (*Particle Swarm Optimization*). Os dados usados no treinamento da RNA foram obtidos por meio do código PARCS v. 2.4 (*Purdue Advanced Reactor Core Simulator*), utilizando a modelagem do reator de Angra 2 cujos dados foram obtidos de seu respectivo Relatório Final de Análise de Segurança. Nos testes realizados, a RNA alcançou **acurácia de 98%**.

1. INTRODUÇÃO

Projetar um reator nuclear requer observações de determinados parâmetros. Entre eles, a quantidade de material fissil suficiente durante todo o período de operação, além de controle da reatividade [1]. O combustível utilizado no caso específico do PWR (*Pressurized Water Reactor*) é urânio levemente enriquecido, 2% a 4%. O controle da reatividade é realizado por meio de absorvedores de nêutrons e boro dissolvido no refrigerante. Além disso, é utilizado também veneno queimável, que no caso de Angra 2 é Gd_2O_3 [2]. Contudo, determinar o conjunto de variáveis para manter o reator seguro e ao mesmo tempo com massa fissil



suficiente para 18 ou 24 meses é tarefa complexa, incluindo, por exemplo, a distribuição dos elementos combustíveis no núcleo e posição das barras de controle.

Existem cálculos físicos e matemáticos que podem ser realizados com auxílio de computador no intuito de abranger maior quantidade de variáveis. Porém, trata-se de processo complexo, uma vez que a quantidade de possibilidades é grande. No caso de Angra 2, por exemplo, são 193 elementos combustíveis, sendo que em 61 delas, existem barras de controle. A distribuição é um problema exponencial, ou seja, são 193^{193} possibilidades. Logo, não pode ser realizado por algoritmos tradicionais [3].

Durante o estudo, certas variáveis foram definidas para caracterizar um núcleo de reator PWR. Foram elas: composição do elemento combustível, quantidade de boro dissolvido na água do reator (concentração em ppm), refletor utilizado, posição radial (x,y) e moderador. Tais características foram usadas para treinar o modelo de RNA (Rede Neural Artificial) MLP (*Multi_Layer Perceptron*) utilizando algoritmos de treinamento *Backpropagation* e PSO (*Particle Swarm Optimization*). Tal ferramenta tem sido utilizada com êxito na solução de vários problemas da atualidade [4,5].

1.1. Estado da arte

Os trabalhos relacionados ao tema realizados nos últimos 3 anos, concentraram-se em utilização de algoritmos evolutivos e heurísticos. Os autores [6] desenvolveram um código de gerenciamento de combustível combinando os algoritmos PSO e *Simulated Annealing*. Além disso, a ferramenta conta com outra técnica, um modelo de física baseado na teoria da perturbação generalizada precisa de segunda ordem.

Já os autores do documento [7] utilizaram o método de entropia cruzada, porém diferente dos existentes, este foi baseado em estatística e teoria da informação. O objetivo foi otimizar o 7º ciclo da usina Angra 1. O trabalho consistiu em conduzir o algoritmo passo a passo na busca pela distribuição ótima. Segundo os autores, este método obteve resultado favorável comparado aos tradicionais heurísticos.

Seguindo a mesma linha, os autores do documento [8] utilizaram o algoritmo Busca Tabu em comparação com outros algoritmos evolutivos como Genético e *Simulated Annealing*. Segundo os autores, a Busca Tabu superou os dois algoritmos em várias funções objetivos diferentes, além de duas geometrias do núcleo do PWR.

Ainda na linha dos algoritmos heurísticos, os autores do documento [9] propuseram uma técnica de recarga de reatores PWR baseado nos algoritmos ABC (*Artificial Bee Colony*) e PSO (*Particle Swarm Optimization*). Segundo os autores, a simulação mostrou que o método ABC proposto apresentou vantagens sobre o ABC original como baixo custo, método rápido e solução razoavelmente precisa.

Embora exista poucos trabalhos especificamente utilizando RNA desenvolvidos nos últimos anos, os artigos publicados usando as técnicas citadas, seguem a mesma linha do presente trabalho. As variáveis bem como as funções objetivos, além da modelagem do problema utilizado auxiliaram no entendimento e comparação deste trabalho.



2. METODOLOGIA

As características usadas para entrada da RNA foram identificadas a partir do arquivo Entrada/Saída gerado pela configuração BOL (*Begin Of Life*) do núcleo de Angra 2 [10] (FSAR) para o código de análise neutrônica PARCS [11]. Na Fig. 3 pode ser visto exemplo de dados utilizados.



Fig.1 – Exemplo de núcleo padrão PWR.

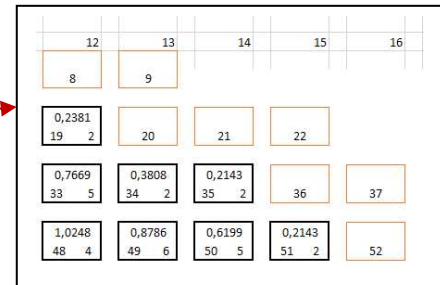


Fig.2 – Detalhe do núcleo.

Legenda:




Fig.3 – Dados de entrada da RNA

A RNA utilizada neste projeto foi a MLP (*Multi_Layer_Perceptron*), com 2 camadas ocultas variando a quantidade de neurônios. A configuração que obteve os resultados deste trabalho foi: 15 – 100-100- 1, onde 15, refere-se às características de entrada. O par 100-100 representa a quantidade de neurônios distribuídos nas duas camadas ocultas e, por fim, uma camada de saída com apenas 1 neurônio. Foram usados os algoritmos de treinamento *Backpropagation* e PSO (*Particle Swarm Optimization*).

A função de ativação utilizada nos testes com *Backpropagation* foi Relu, taxa de aprendizagem 0.00010. Além disso, foram usados o SGD (*Stochastic Gradient Descendent*), Adam e BFGS Quasi-Newton *Backpropagation*. O critério de parada utilizado para ambos algoritmos foram iterações (2.500 épocas) e erro mínimo (0,001). Quanto ao teste e validação, foram analisados a validação cruzada e exemplos randômicos. No caso de exemplos randômicos, o arquivo de entrada foi dividido em 80% para treinamento, 10% para validação e 10% para testes.

A Fig. 4 mostra a distribuição de potência de um exemplo de núcleo padrão usado como referência para treinamento da RNA. O k efetivo da distribuição foi k_{eff} : 1.16. Variação da distribuição de potência: 0.2143 a 1.9102.

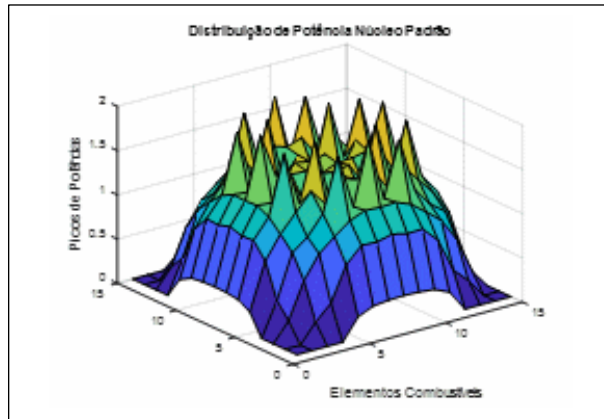


Fig.4 - Distribuição da potência do núcleo de referência.

3. RESULTADOS

O primeiro teste consistiu em treinar a RNA a fim de analisar as características e indicar a distribuição de potência para cada posição. Nos testes realizados, a RNA obteve 99% de acurácia, conforme pode ser verificado na Fig. 5.

A imagem representada na Fig. 5 indica o resultado obtido pela RNA para a fase de treinamento e teste. Na fase de treinamento, a RNA obteve 99% de acertos, ou seja, diante do padrão (conjunto de características de entrada) e da saída esperada (fator de potência). Esse comportamento era esperado, uma vez que a arquitetura de RNA usada foi do tipo supervisionado. Isso significa que a RNA tem a resposta para realizar comparação com o resultado encontrado.

Na fase de testes, Fig. 6, a RNA alcançou 98% de acurácia. Esta fase indica o funcionamento do modelo onde ele recebe uma entrada desconhecida e, diante do treino recebido anteriormente, emite uma saída. E, nesta fase, a RNA além de não conhecer a entrada, também não conhece a resposta. Para este caso, a indicação da distribuição dos fatores de potência foi satisfatório. Em ambas as imagens, o eixo das abcissas indica a distribuição de densidades de potência, enquanto o eixo das ordenadas o comportamento do modelo de RNA.

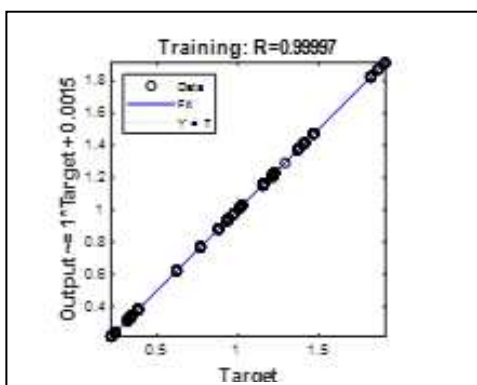


Fig. 5- Resultado da RNA para Distribuição de Potência - Fase de treinamento.

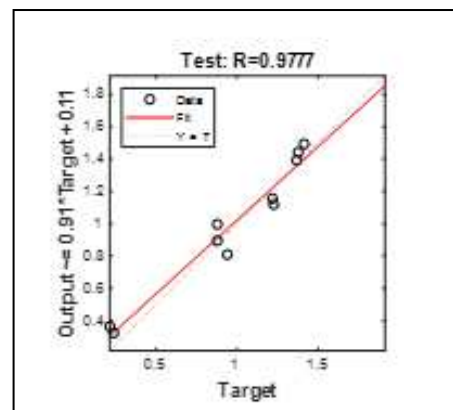


Fig. 6- Resultado da RNA para Distribuição de Potência - Fase de testes.

A Fig. 7 mostra a distribuição de potência apresentada pela RNA versus a distribuição original de um núcleo padrão PWR. Tal resultado era esperado, uma vez que a Fig. 6 mostrou que a RNA alcançou 98% de acurácia, ou seja, apenas 2% dos fatores de potência apresentados, não puderam ser identificados pelo modelo. As linhas em amarelo na Fig. 7 sobrepõem aos originais em azul.




Fig. 7- Distribuição de Potência Original X Saída da RNA

4. CONCLUSÃO

Este estudo teve como foco a extração e entendimento dos dados que fazem parte do núcleo do reator nuclear, especificamente, Angra 2.

Modelos de redes neurais artificiais precisam de dados que tem algum significado, além de relação entre características e resultados esperados. Assim, a distribuição espacial dos elementos combustíveis depende de vários fatores, porém é difícil relacionar para o entendimento de uma máquina.

Neste primeiro trabalho, a distribuição de potência foi utilizada como variável de saída para a RNA. Então, um núcleo padrão foi gerado e, além das variáveis conhecidas, cada fator de potência também conhecido foi utilizado a fim de treinar a RNA. O modelo é supervisionado e, desta forma, durante o treinamento para que ele fizesse comparação do resultado previsto com o real, a saída também foi passada no conjunto de entrada.

Para um trabalho de regressão, como foi este primeiro teste, a RNA alcançou 98% de acurácia nos testes. Dando sequência ao projeto, outro modelo será desenvolvido e o conhecimento do modelo atual será repassado para a RNA.

Devido à complexidade do problema este trabalho terá continuidade.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) que direta ou indiretamente contribuíram para a pesquisa e aos patrocinadores e voluntários doadores pelo apoio à realização deste evento.



REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Cacuci, D.G., Handbook of Nuclear Engineering, Springer Verlag, Alemanha (2013).
- [2] Cochran, Robert G. Tsoufanidis, Nicholas. The Nuclear Fuel Cycle: Analysis and Management, American Nuclear Society (1999).
- [3] Cormen, C. Leiserson, R. Rivest, C. Stein, “Algoritmos - Teoria e Prática” (2002).
- [4] Russell, Stuart; Norvig, Peter., Artificial Intelligence - A Modern Approach, Third Edition, New Jersey, Prentice Hall Series em Inteligência Artificial (2010).
- [5] Silva, I.N., Spatti, D.H., Flauzino, R.A., Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas - Curso Prático, Brasil (2016).
- [6] Ammar, Ahmad Sirajul-Islam Ahmad, “Optimization of fuel loading pattern for a material test reactor using swarm intelligence”, Institute of Engineering and Applied Sciences, Department of Physics, Pakistan (2017).
- [7] Moura, Anderson; Schirru, Roberto. “A cross-entropy method applied to the In-core fuel management optimization of a Pressurized Water Reactor”, Federal University of Western Pará, Institute of Geosciences and Engineering, Brazil (2015).
- [8] Natasha J.Hill, Geoffrey T.Parks, “Pressurized water reactor in-core nuclear fuel management by tabu search”, University of Cambridge, Cambridge, United Kingdom (2014).
- [9] O. Safarzadeh, A. Zolfaghari, M. Zangian, O. Noori-kalkhoran, “Pattern optimization of PWR reactor using hybrid parallel Artificial Bee Colony”, Annals of Nuclear Energy, Volume 63, 2014, pp. 295-301, China, (2014).
- [10] FSAR, 2013. “Final Safety Analysis Report – Central Nuclear Almirante Alvaro Alberto – Unit 2”, Eletrobrás-Eletronuclear, Brazil.
- [11] <https://engineering.purdue.edu/PARCS>