

INSTITUTO DE ENGENHARIA NUCLEAR

CAETANO SOARES FAJARDO

**PREDIÇÃO DE FLUXO TERMICO NORMALIZADO NO REATOR ARGONAUTA
ATRAVÉS DE REDES NEURAS ARTIFICIAIS**

**Rio de Janeiro
NOVEMBRO 2025**

CAETANO SOARES FAJARDO

**PREDIÇÃO DE FLUXO TERMICO NORMALIZADO NO REATOR ARGONAUTA
ATRAVÉS DE REDES NEURAIAS ARTIFICIAIS**

Dissertação apresentada ao Programa de Pós-graduação em Ciência e Tecnologia Nucleares do Instituto de Engenharia Nuclear da Comissão Nacional de Energia Nuclear como parte dos requisitos necessários para a obtenção do Grau de Mestre em Ciências e Tecnologias Nucleares.

Orientadores: Claudio Marcio N. A. Pereira
João Alberto Magalhães Gadelha

Rio de Janeiro
NOVEMBRO 2025

FAJARD Fajardo, Caetano Soares

Predição de fluxo térmico normalizado no reator argonauta através de redes neurais artificiais.

/ Caetano Soares Fajardo. – Rio de Janeiro: CNEN/IEN,2025.

63fl.; 31 cm.

Orientador: Cláudio Marcio N. A. Pereira

Co-orientador: João Alberto Magalhães Gadelha

**PREDIÇÃO DE FLUXO TERMICO NORMALIZADO NO REATOR ARGONAUTA
ATRAVÉS DE REDES NEURAS ARTIFICIAIS**

CAETANO SOARES FAJARDO

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA NUCLEARES DO INSTITUTO DE ENGENHARIA NUCLEAR COMO REQUISITO PARCIAL NECESSÁRIO PARA OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS E TECNOLOGIA NUCLEARES.

Aprovada por:

Prof. Cláudio Márcio do Nascimento Abreu. Pereira, D.Sc.

Prof. João Alberto Magalhães Gadelha, M.Sc.

Prof. Cláudio Henrique dos Santos Grecco, D. Sc.

Prof. Marcelo Carvalho dos Santos, D.Sc.

RIO DE JANEIRO, RJ – BRASIL
NOVEMBRO 2025

AGRADECIMENTOS

Ao engenheiro e professor João Alberto Magalhães Gadelha pelos ensinamentos, transmissões e estímulos na pesquisa e desenvolvimento no setor nuclear.

Ao professor e orientador Claudio M. N. A. Pereira pelos ensinamentos na área de inteligência artificial e redes neurais e por ter acreditado neste trabalho desempenhado.

Agradeço a todos os docentes do IEN pelos ensinamentos e sugestões de trabalhos futuros para doutorado e pesquisa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) pelo programa de bolsa aos estudantes de mestrado Programa de Pós-graduação em Ciência e Tecnologia Nucleares do Instituto de Engenharia Nuclear da Comissão Nacional de Energia Nuclear.

RESUMO

Neste trabalho uma rede neural artificial MLP foi programada, testada e validada visando à predição da razão do fluxo térmico normalizado, obtido nos experimentos de calibração de barra de controle pelo método de queda realizados no reator de pesquisa Argonauta. A influência da inserção de reatividade negativa pelas barras de controle de reatividade ao longo dos instantes de tempo, a geometria do núcleo e as potências foram avaliadas. O efeito das variáveis neutrônicas e cinéticas foram investigadas de modo a se obter melhor eficiência da rede neural artificial que fez a predição pelo algoritmo Adam como otimizador e pelo erro quadrático médio como função de custo para determinação da razão do fluxo térmico normalizado. Cinco tabelas dos experimentos de calibração de barra de controle pelo método de queda de inserção de diferentes faixas de reatividade negativa foram usadas para gerar os dados de teste e validação. As curvas analíticas foram lineares ($R^2=0,9999$) entre 0,1 e 0,9 de fluxo térmico normalizado e no treinamento da RNA, foi alcançado uma perda de 0,04 na época inicial e ao longo do treinamento esta perda foi reduzida a 0, sendo alcançado na predição das reatividades negativas um erro quadrático médio de $2,75 \times 10^{-5}$. A metodologia desenvolvida para predição da razão do fluxo térmico normalizado nos experimentos de calibração de barras de controle pelo método de queda em condição crítica do núcleo do reator Argonauta, apresentou concordância compatível com os dados do relatório de análise de segurança do reator Argonauta, com uma variação entre os resultados maior que $2,5 \times 10^{-5}$. O algoritmo da RNA MLP apresentou vantagens em relação as técnicas convencionais de predição, tais como: uso de ferramentas de inteligência artificial, maior eficiência computacional e maior custo-benefício computacional.

Palavras-chave: Aprendizado profundo, Redes neurais para avaliação de padrões, Nuclear.

ABSTRACT

In this work, an MLP artificial neural network was programmed, tested, and validated for predicting the normalized thermal flux ratio, obtained in the control rod calibration experiments using the rod drop method performed in the Argonauta research reactor. The influence of negative reactivity insertion by the reactivity control rods over time, the core geometry, and the power levels were evaluated. The effect of neutronic and kinetic variables were investigated in order to obtain better efficiency of the artificial neural network that performed the prediction using the Adam algorithm as an optimizer and the mean squared error as the cost function for determining the normalized thermal flux ratio. Five tables from the control rod calibration experiments using the rod drop method for inserting different ranges of negative reactivity were used to generate the test and validation data. The analytical curves were linear ($R^2=0.9999$) between 0.1 and 0.9 of normalized thermal flux and, in the ANN training, a loss of 0.04 was achieved in the initial epoch and throughout the training this loss was reduced to 0, achieving a mean squared error of 2.75×10^{-5} in the prediction of negative reactivities. The methodology developed for predicting the normalized thermal flux ratio in control rod calibration experiments using the rod drop method under critical conditions of the Argonauta reactor core showed compatible agreement with the data from the Argonauta reactor safety analysis report, with a variation between the results greater than 2.5×10^{-5} . The MLP ANN algorithm presented advantages over conventional prediction techniques, such as: the use of artificial intelligence tools, greater computational efficiency, and higher computational cost-benefit.

Keywords: Deep learning, Neural networks for pattern evaluation, Nuclear.

LISTA DE QUADROS

Quadro 1 - Termos referentes às seções de choques de um nêutron – Termos referentes às seções de choques de um nêutron	19
Quadro 2 - Unidades usuais para o cálculo de potência de um reator	23

LISTA DE ILUSTRAÇÕES

Figura 1 – Representação esquemática de uma TLU	32
Figura 2 – Arquitetura MLP com duas camadas intermediárias	35
Figura 3 – Função de ativação sigmoide e sua derivada	36
Figura 4 – Função de ativação de tangente hiperbólica e sua derivada.....	37
Figura 5 – Função de ativação relu(x) e sua derivada	38
Figura 6 – Função de ativação softmax	39
Figura 7 - Esquema em vista isométrica do núcleo do reator Argonauta com as barras de controle instaladas	41
Figura 8 – Distribuição do fluxo de nêutrons no sentido radial de reatores de pesquisa cilíndricos	49
Figura 9 – Curvas de reatividade negativa no núcleo do reator Argonauta na calibração das barras de controle pelo método de queda.....	51
Figura 10 – Análise da perda do modelo da RNA MLP	52
Figura 11 – Coeficiente de determinação(R^2) de valores reais e previstos	54
Figura 12 – Erro quadrático médio por reatividade negativa	55

LISTA DE TABELAS

Tabela 1 - Seções de choque para o U-235.....	20
Tabela 2 – Três principais combustíveis nucleares e suas seções de choque.....	20
Tabela 3 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.01 e 0.10	41
Tabela 4 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.10 e 0.20	42
Tabela 5 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.20 e 0.30	43

Tabela 6 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.30 e 0.40	43
Tabela 7 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.40 e 0.50	43
Tabela 8 – Pesos e saídas da rede neural artificial.....	46

LISTA ABREVIATURAS E SIGLAS

CNEN	-	Comissão Nacional de Energia Nuclear
IAEA	-	<i>International Atomic Energy Agency</i>
IEN	-	Instituto de Engenharia Nuclear
LABIHS	-	Laboratório de Interfaces Humano-Sistemas
MCTI	-	Ministério da Ciência, Tecnologia e Inovação
NEA	-	<i>Nuclear Energy Agency</i>
RNA	-	Rede Neural Artificial
MLP	-	<i>Mult Layer Perceptron</i>

SUMÁRIO

1 INTRODUÇÃO	11
1.1 OBJETIVOS DA PESQUISA	13
1.2 METODOLOGIA	14
1.3 ESTRUTURA DO TRABALHO E CONTRIBUIÇÕES	15
2 FUNDAMENTAÇÃO TEÓRICA	16
2.1 NEUTRÔNICA	16
2.1.1 CAPTURA RADIOATIVA	16
2.1.2 CAPTURA COM EJEÇÃO DE PARTICULAS	17
2.1.3 FISSÃO	17
2.1.4 SEÇÃO DE CHOQUE.....	18
2.1.5 FLUXO DE NÊUTRONS.....	21
2.1.6 POTÊNCIA PRODUZIDA EM UM REATOR	22
2.1.7 FATOR DE MULTIPLICAÇÃO.....	24
2.1.8 UNIDADES DE REATIVIDADE USADAS EM PESQUISA.....	26
3 CALIBRAÇÃO DE BARRA DE CONTROLE DO REATOR DE PESQUISA ARGONAUTA – MÉTODO DE QUEDA	28
3.1 REATIVIDADE PRONTO-SUBCRÍTICA	28
3.2 MÉTODO DE QUEDA	29
4 REDES NEURAS ARTIFICIAIS	31
4.1 REDE NEURAL ARTIFICIAL MLP (MULT LAYER PERCEPTRON).....	32
5 REATOR ARGONAUTA	39
6 REDE NEURAL ARTIFICIAL PARA PREDIÇÃO DO FLUXO TÉRMICO NORMALIZADO	41
7 RESULTADOS E DISCUSSÕES	49
8 CONCLUSÕES	56
8.1 SUGESTÕES PARA TRABALHOS FUTUROS	57
9 REFERÊNCIAS BIBLIOGRÁFICAS	59

1 INTRODUÇÃO

O reator de pesquisa Argonauta do Instituto de Engenharia Nuclear (IEN) foi projetado no *ARGONNE NATIONAL LABORATORY*, inicialmente na década de 60 em parceria com a CNEN (Comissão Nacional de Energia Nuclear), sendo modificado para atender as demandas e capacidades atuais de pesquisa nuclear em medicina nuclear, produção de radioisótopos, ciclo do combustível, física de reatores, formação de recursos humanos, e segurança nuclear (DANIEL, 2020). Conforme publicação do IEN, os resultados alcançados nos últimos anos foram divulgados em relatórios técnicos, revistas de pesquisa e relatórios do IEN, congressos científicos e periódicos nacionais e internacionais.

Os reatores nucleares de pesquisa constituem importantes componentes no desenvolvimento de novas tecnologias e formação de profissionais na área nuclear, pois oferecem flexibilidade, versatilidade operacional. Uma das linhas de investigações em reatores de pesquisa é a de implementação de tecnologias embarcadas para medição de fluxo de nêutrons. A importância do desenvolvimento destas tecnologias embarcadas está no objetivo de análise do comportamento da distribuição do fluxo de nêutrons, que sofre variações na operação ou movimento das barras de controle de reatividade, aos transientes gerados na queima de combustível e ao carregamento de combustível (MAZROU, LABABSA, MOKHTARI, 2023).

Para alcançar estes objetivos, são realizados experimentos de aproximação subcrítica em seu núcleo, evitando-se a geração de excursões de potência não controladas que representam um risco à segurança de operação. Estes experimentos visam determinar o fluxo de nêutrons adequado para diversos propósitos, como, por exemplo, a irradiação de materiais. Outro objetivo importante é a calibração das barras de controle do sistema de segurança, com vistas a atender aos requisitos previstos nas normas e regulamentações da CNEN (Comissão Nacional de Energia Nuclear), como a norma CNEN NN 3.01 (2014), que estabelece os requisitos básicos de proteção radiológica com monitoramento e controle de fontes de radiação, e CNEN NE 1.20 (1985), cujo escopo objetiva os requisitos para sistemas de resfriamento de emergência em reatores de água leve que dependem de instrumentação confiável.

O aumento significativo do desenvolvimento de novas aplicações que usam o aprendizado profundo para resolução de problemas ligados a distribuição de fluxo de nêutrons, pois com o avanço tecnológico e oferta de novas interfaces de controle e aquisição de dados as redes de aprendizado profundo tem aplicação na resolução de equações diferenciais complexas e na predição baseada em dados de validação (YANG, GUI, YANG, TU, JIANG, 2025).

Pelos excelentes resultados de eficiência computacional, pesquisas e publicações científicas exploram o uso de redes neurais artificiais com retroalimentação para prever e modelar a função ou comportamento da distribuição do fluxo de nêutrons no núcleo de um reator de pesquisa, o que pode ser aplicado com sucesso no reator de pesquisa Argonauta.

Neste contexto, as redes neurais artificiais (RNA) têm sido usadas pela sua versatilidade em resolver problemas de modelagens não lineares, em dados de alta dimensionalidade

Após uma recarga do núcleo de um reator de pesquisa são necessários testes na etapa de partida para que os requisitos de segurança operacional sejam atendidos. Registram-se medidas de variáveis da física nuclear como a reatividade, o fluxo de nêutrons e a determinação do regime de operação (subcrítico, crítico e supercrítico), obtidas pelos sistemas de instrumentação e aquisição de dados na sala de controle, para a validação com valores pré-estabelecidos em projetos e desenvolvimento de outras tecnologias que objetivam previsão e segurança operacional (STEFANI, CARVALHO, PALMA, SILVA, RAITZ, 2023).

A grande importância de pesquisas ligadas ao controle de reatividade e segurança operacional, em reatores de pesquisa, é comprovada na operação de troca e queima de combustível nuclear num reator térmico, onde ocorrem transientes em função do descontrole da pressão e temperatura, no seu circuito primário, que influem no regime da reatividade dos nêutrons no núcleo, o que pode causar fenômenos indesejáveis em sua estrutura como o ruído gaussiano e desgastes nos componentes das barras de controle, segundo dados publicados por (STEFANI, CARVALHO, PALMA, SILVA, RAITZ, 2023).

O método de queda de barras de controle é uma técnica bem conhecida com a vantagem de ser rápida e simples de executar quando comparada a outras técnicas como a “diluição de boro”, por exemplo. A ideia da técnica de “queda de barras de controle” é começar a atuar a partir do estado crítico, ou o mais próximo possível dele, e então controlar o motor dc que movimenta verticalmente a barra de controle em relação à posição na qual a reatividade integral será medida. O fluxo de nêutrons é monitorado e usado para obter a reatividade através das equações cinéticas de ponto inverso. Além disso, devido à grande inserção de reatividade negativa causada pelos bancos de controle, o fluxo de nêutrons tem sua forma de distribuição alterada, o que causa o efeito de sombreamento nos detectores de nêutrons, especialmente aqueles que estão ao redor da posição onde o banco de controle foi inserido (STEFANI, CARVALHO, PALMA, SILVA, RAITZ, 2023).

Técnicas de inteligência artificial podem otimizar a configuração e o arranjo de barras de controle de reatividade para controlar a reatividade do reator, a manobra de potência e o desligamento de emergência por *trip/scram*, além de constituir importantes ferramentas computacionais para validação e previsão da reatividade negativa inserida pela barra de controle, fator de pico de potência, bem como identificação de combustível nuclear que apresente melhor rendimento (PINEN, LUTHFI, HARTANTO, LIEM, 2023).

A distribuição de potência no núcleo, visualizada no gráfico de potência pelo percentual de queda da barra de controle de reatividade, está relacionada a queda das barras de controle (PINEN, LUTHFI, HARTANTO, LIEM, 2023).

O que visa atender requisitos de segurança operacional previstos na base de projeto e na segurança técnica nuclear, exigidos pela norma CNEN NE 1.26 (1997).

O escopo deste trabalho objetiva a criação de um modelo para previsão de fluxo térmico normalizado no núcleo do reator Argonauta do Instituto de Engenharia Nuclear, utilizando redes neurais artificiais (RNA), tendo como dados de validação as tabelas de

calibração de barra de controle pelo método de queda, fornecidas pelo Instituto de Engenharia Nuclear administrado pela CNEN (Comissão Nacional de Energia Nuclear). A sua utilização limita-se a reatores de água leve que tenham configuração igual ou semelhante ao reator Argonauta, onde são utilizadas as barras de controle durante todo o ciclo de funcionamento, pois os reatores de água pressurizada utilizam ácido bórico dissolvido no refrigerante do circuito primário e uma aplicação menor de barras de controle de reatividade (PINEN, LUTHFI, HARTANTO, LIEM, 2023).

Esta dissertação explora o uso de modelos baseados em RNA na para predição de parâmetros de reatores de pesquisa, otimização de experimentos e análise de segurança. Além disso, discutem-se os desafios associados à implementação destes modelos, como a necessidade de dados de treinamento de alta qualidade e a interpretação física dos resultados.

1.1 OBJETIVOS DA PESQUISA

O presente trabalho tem como objetivo geral desenvolver um sistema de predição de padrões de fluxo térmico normalizado na geometria do núcleo do reator Argonauta, de modo a contribuir para a otimização da calibração de barras de controle e para o gerenciamento da potência funcional do reator.

Para atingir esse propósito, busca-se aplicar modelos de redes neurais artificiais baseados em perceptrons de múltiplas camadas (MLP) na predição de padrões de regressão em experimentos de física nuclear, particularmente na calibração de barras de controle pelo método de queda, em que a razão do fluxo térmico é observada em instantes de tempo sucessivos após a inserção de reatividade negativa em degrau.

Além disso, pretende-se analisar alternativas de controle de reatividade em reatores de pesquisa, conforme sugerido por (HOSSEINLLU, ABBASI, SAFARZADEH, DEGHANI, 2025), por meio da otimização da calibração por queda de barras de controle, sem a necessidade de inserção de boro no núcleo durante a operação. Também se objetiva identificar regiões do núcleo nas quais a razão do fluxo térmico normalizado se aproxime do valor adimensional igual a 1, o que representa maior rendimento e potência térmica do reator.

Por fim, busca-se explorar as vantagens das redes neurais MLP no reconhecimento de padrões matemáticos de regressão e predição, conforme discutido por Geron (2021), ressaltando sua aplicabilidade em sistemas de segurança e no desenvolvimento de metodologias de calibração e recarga em reatores de pesquisa.

1.2 METODOLOGIA

O desenvolvimento desta dissertação de mestrado utiliza uma pesquisa aplicada com simulações e tecnologias de inteligência artificial para o estudo e implementação de soluções nos processos do reator Argonauta, especialmente aqueles que envolvem o controle de reatividade pelas barras de controle. Estudos específicos, revisões bibliográficas e experimentos nos regimes de operação subcrítico e crítico do reator Argonauta, foram feitos para o desenvolvimento desta dissertação. A abordagem do problema estudado utiliza uma pesquisa quantitativa com coleta de dados e informações provindos de experimentos de calibração de barras de controle pelo método de queda e de aproximação subcrítica do complexo onde o reator Argonauta está instalado. A metodologia de controle da reatividade do núcleo radioativo segue as seguintes etapas:

1. Estudo e pesquisa das características neutrônicas e cinéticas das reações que ocorrem no núcleo radioativo do reator Argonauta com a inserção de combustível nuclear, na geração de energia e no controle de sua reatividade;
2. Estudo de bibliografia e revisão sistemática sobre sistemas de controle de pressão e temperatura presentes num reator de pesquisa nuclear;
3. Concepção dos modelos de aprendizado de máquina com variáveis coletadas do experimento de calibração de barras de controle de reatividade pelo método de queda;
4. Coleta de dados e elaboração de banco de dados dos experimentos de aproximação subcrítica e funcionamento em regime crítico;
5. Desenvolvimento dos modelos de aprendizado de máquina em linguagem de programação Python, (PYTHON SOFTWARE FOUNDATION, 2023), cujas as variáveis preditoras e de resposta estão no banco de dados;
6. Aplicar o modelo na predição do fluxo térmico normalizado, do experimento de calibração das barras de controle de reatividade pelo método de queda;
7. Validar o modelo, através da comparação dos resultados obtidos com os resultados experimentais reais.

1.3 ESTRUTURA DO TRABALHO E CONTRIBUIÇÕES

Esta dissertação está organizada em seis capítulos incluindo esta introdução, descritos, resumidamente, nesta seção. No capítulo 2, é apresentada a fundamentação teórica relativa à neutrônica, à geração de energia termonuclear no núcleo do reator de pesquisa Argonauta, à calibração de barra de controle de reatividade pelo método de queda e às redes neurais artificiais de *perceptron* de multicamadas.

No capítulo 3, é apresentado o método de calibração de barras de controle de reatividade pelo método de queda, no qual foram feitos os experimentos para determinação das curvas de fluxo térmico normalizado de acordo com a reatividade negativa inserida no núcleo do reator Argonauta.

No capítulo 4, é apresentado o estudo e fundamentação teórica sobre a rede neural *mult layer perceptron*.

No capítulo 5, são apresentadas a instalação e a estrutura do reator Argonauta no Instituto de Engenharia Nuclear, administrado pela Comissão Nacional de Energia Nuclear.

No capítulo 6, é apresentada a rede neural MLP desenvolvida para predição dos dados das curvas de fluxo térmico normalizado, dos experimentos de calibração de barra de controle de reatividade pelo método de queda.

No capítulo 7, são apresentados os resultados e discussões sobre a metodologia aplicada a predição do experimento de calibração de barras de controle de reatividade pelo método de queda.

No capítulo 8, são apresentadas a conclusão e a sugestão de trabalhos futuros de desenvolvimento de sistemas inteligentes de aprendizado de máquina para predição e otimização de calibração e segurança operacional no reator Argonauta.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 NEUTRÔNICA

A neutrônica ou análise neutrônica é o ramo da física de reatores que estuda as reações com nêutrons de baixas energias com núcleos de isótopos que são usados em experimentos num reator de pesquisa em áreas como medicina nuclear, ciclo do combustível nuclear, radiologia, aproximação subcrítica e produção de radioisótopos. As reações com nêutrons são as seguintes: captura radioativa, captura com ejeção de partículas, fissão e espalhamento (LAMARSH, 2001; DUDERSTADT, HAMILTON, 1976).

No Instituto de Engenharia Nuclear, aplica-se a técnica de ativação neutrônica por nêutrons retardados de fissão, usada na análise do Urânio, para determinar-se a concentração de diversos elementos químicos, da ordem de traços a porcentagem em amostras de tecidos humanos, geológicas e ambientais (DE AGUIAR, 2023).

O objetivo do estudo de neutrônica apresentado nesta dissertação de mestrado é o de definir a potência desenvolvida num reator de pesquisa e sua relação com a reatividade e o fluxo de nêutrons em seu núcleo.

2.1.1 CAPTURA RADIOATIVA

A reação de captura radioativa de um nêutron, importante para o controle de reatividade num reator de pesquisa, como a reação em que o nêutron após ser capturado, emite um raio γ , pois a emissão do raio γ ocorre pela quebra energética do nêutron (DUDERSTADT, HAMILTON, 1976).

Este fenômeno é descrito na equação 1:



No reator de pesquisa Argonauta, o processo de captura radioativa é usado para produção de radioisótopos, usados na medicina nuclear, análise de materiais por ativação de nêutrons e no controle da reatividade do núcleo. Este controle de reatividade do núcleo

é feito com barras absorvedoras de nêutrons, constituídas de boro ou cádmio, que ajustam a taxa de fissão do U-235, influenciando na potência gerada (AGUINA, 1989).

2.1.2 CAPTURA COM EJEÇÃO DE PARTICULAS


A captura com ejeção de partículas de um isótopo como a reação em que um isótopo captura um nêutron e emite outro isótopo diferente e uma partícula alfa. Esta reação ocorre com nêutrons de baixa energia e de energia maior, como a reação do boro que absorve um nêutron e emite um núcleo de lítio e uma partícula alfa (CURTISS, 1959). Na equação 2, é mostrada esta reação:



2.1.3 FISSÃO

No processo de produção de energia por reatividade no núcleo do reator Argonauta, o núcleo do U-235 absorve um nêutron e emite fragmentos de fissão, novos nêutrons (2 a 3 nêutrons rápidos), raios γ (fóton) e libera em média 200 MeV por fissão. Os nêutrons incidentes de alta energia possuem $E > 1$ MeV, entretanto os nêutrons incidentes de baixa energia possuem $E \cong 0.025$ eV (LAMARSH, 2001).

Na equação 3 está descrito este processo:



Na equação 3, X e Y são os fragmentos de fissão e os nêutrons prontos são os nêutrons gerados após a fissão.

Na reação de fissão do U-235, os nêutrons térmicos são mais eficientes do que os nêutrons rápidos para causarem novas fissões. Após a geração dos nêutrons rápidos, efetua-se no reator Argonauta a moderação com água leve para que estes nêutrons se tornem nêutrons térmicos e ocorram novas fissões num processo contínuo denominado reação em cadeia (TERREMOTO, 2004).

O espectro de fissão do U-235 é um gráfico cujo a função ou a curva refere-se à distribuição de energia dos nêutrons emitidos durante a fissão nuclear. Através dele pode-se escolher o moderador adequado (água leve, água pesada ou grafite) para moderar ou reduzir a energia dos nêutrons, avalia-se o material adequado para suportar a seção de

choque de nêutrons rápidos, projeta-se e opera-se o reator com segurança (DUDERSTADT, HAMILTON, 1976).

Com base nesse espectro, também se torna possível projetar e operar reatores nucleares com maior eficiência e segurança, uma vez que o comportamento da população de nêutrons é a variável central em qualquer cálculo de criticidade e de taxa de reação nuclear. A análise detalhada do espectro de fissão fornece subsídios não apenas para a seleção de moderadores, mas também para o dimensionamento de blindagens biológicas, definição de sistemas de resfriamento e escolha de materiais de controle, como as barras absorvedoras. Esse caráter multifuncional do espectro evidencia sua relevância em diferentes etapas do ciclo de projeto de reatores (COMISSÃO NACIONAL DE ENERGIA NUCLEAR, 1985).

2.1.4 SEÇÃO DE CHOQUE

A seção de choque é uma medida de probabilidade de uma interação ou reação nuclear entre um nêutron e um núcleo atômico, cuja a unidade é o barn equivalente a 10^{-24} cm^2 (STACEY, 2007).

A área de seção aproximada do núcleo é mostrada na equação 4.

$$A = \pi \cdot R^2 \quad (4)$$

Onde $R = 10^{-12} \text{ cm}$, definido como o raio do núcleo.

A seção de choque total de um nêutron é o somatório da seção de choque de absorção e da seção de choque de espalhamento, pois a seção de choque de absorção representa a probabilidade do nêutron ser absorvido pelo núcleo, resultando em reações como captura radioativa ou fissão nuclear, dependendo do núcleo alvo e da energia do nêutron, e a seção de choque de espalhamento é a probabilidade do nêutron colidir com o núcleo e ser espalhado, sem ser absorvido (CURTISS, 1959).

As importâncias do projeto da seção de choque total em reatores de pesquisa são a de prever a taxa de fissões do U-235, a de manter a criticalidade controlada e a de escolher materiais como combustíveis, moderadores, refletores e barras de controle (STEFANI, 2023).

Na tabela 1, são descritos os termos referentes as seções de choques de um nêutron. Na equação 5, é mostrada a equação da seção de choque total.

$$\sigma_t = \sigma_a + \sigma_s \quad (5)$$

Onde:

$$\sigma_a = \sigma_\gamma + \sigma_f + \sigma_p + \sigma_\alpha \quad (6)$$

$$\sigma_s = \sigma_{se} + \sigma_{si} \quad (7)$$

Quadro 1 - Termos referentes às seções de choques de um nêutron – Termos referentes às seções de choques de um nêutron

σ_a	Seção de choque de absorção
σ_γ	Seção de choque de captura
σ_f	Seção de choque de fissão
σ_p	Seção de choque de emissão de um próton
σ_α	Seção de choque de uma partícula alfa após a captura do elétron
σ_s	Seção de choque de espalhamento
σ_{se}	Seção de choque de espalhamento elástico
σ_{si}	Seção de choque de espalhamento inelástico

Fonte: Elaboração própria (2024).

A seção de choque macroscópica é definida como o produto entre a seção de choque individual de um nêutron e o número total de núcleos contidos no volume do alvo (STACEY, 2007).

Sua equação é mostrada na equação 8.

$$\Sigma = N \cdot \sigma \quad (8)$$

Onde:

N é nº total de núcleos contidos no volume do alvo, σ é a seção de choque microscópica (barns/núcleo) e Σ é a seção de choque macroscópica (barns/cm³ ou cm^{-1}). A equação da seção macroscópica total é mostrada na equação 9.

$$\Sigma_t = \Sigma_a + \Sigma_s \quad (9)$$

Onde:

Σ_a é a seção macroscópica de choque por absorção e Σ_s é a seção de choque macroscópica por espalhamento.

A relação entre a seção de choque e a energia do nêutron é inversamente proporcional, mostrada na equação 10. Esta relação mostra que quanto menor a energia do nêutron, maior a seção de choque, como o U-235 e núcleos fissionáveis térmicos (STACEY, 2007).

$$\sigma(E) = \frac{1}{\sqrt{E}} \quad (10)$$

Isto mostra que a seção de choque não é constante, mas varia com a energia do nêutron. Para o U-235, essa variação segue três regiões principais, mostradas na tabela 1:

Tabela 1 - Seções de choque para o U-235.

Região	Faixa de energia do nêutron	Comportamento da seção de choque
Térmica	$E < 0.5 \text{ eV}$	Muito alta (585 barns para a fissão 0.025 eV)
Ressonância	$1 \text{ eV} \leq E \leq 100 \text{ KeV}$	Variação brusca (picos de ressonância)
Rápida	$E > 100 \text{ KeV}$	Baixa ($1 \leq E \leq 2$ barns)

Fonte: Elaboração própria (2024).

Comparando-se três principais e diferentes combustíveis nucleares, suas seções de choque são mostradas na tabela 2:

Tabela 2 – Três principais combustíveis nucleares e suas seções de choque.

Isótopo	Seção de choque térmica (fissão)	Comportamento com energia
U-235	Alta (585 barns)	Alta em térmicos, decresce com aumento de energia
U-238	Muito baixa (0.02 barns)	Não fissiona com térmicos, só com nêutrons rápidos

Pu-239	Muito alta (750 barns)	Semelhante ao U-235, mas mais reativo
--------	------------------------	--

Fonte: Adaptado de Lamarsh (2001).

A eficiência de fissão é uma medida de quantos nêutrons incidentes resultam em uma fissão efetiva do combustível nuclear, pois ela depende da fissão de choque de fissão, do fluxo de nêutrons, da presença de absorvedores parasitas e dispersão, e o tipo e a densidade do combustível nuclear usado no carregamento do reator (LAMARSH, 2001).

A equação da taxa de fissões é mostrada na equação 11.

$$R_f = \phi \cdot N \cdot \sigma_f \quad (11)$$

Onde R_f é a taxa de fissões (fissões/s·cm³), ϕ é o fluxo de nêutrons (nêutrons/cm²·s), N é a densidade de núcleos fissionáveis (núcleos/cm³), e σ_f é a seção de choque por fissão (barns).

Pela análise da equação 11, comprova-se que quanto maior a seção de choque por fissão e o fluxo de nêutrons, maior será a taxa de fissões. No contexto do reator de pesquisa Argonauta, utiliza-se o U-235 por ser fissionável por nêutrons térmicos, possibilitando um rendimento energético adequado as suas necessidades de pesquisa, e pela sua alta seção de choque.

O controle e a eficiência de um reator dependem do ajuste do espectro de energia dos nêutrons e as seções de choque do combustível, o que é feito no reator de pesquisa por barras de controle de reatividade pelo método de queda. Entretanto, em reatores rápidos o U-238 e transurânicos se adequam ao núcleo por ser fissionável por nêutrons rápidos (AGUINA, 1989).

2.1.5 FLUXO DE NÊUTRONS

O fluxo de nêutrons como o produto da densidade de nêutrons (nêutrons/cm³) pela velocidade dos nêutrons (cm/seg). A unidade usada para o fluxo de nêutrons é [nêutrons/cm² · seg] (CURTISS, 1959).

A equação do fluxo de nêutrons é mostrada na equação 12.

$$\phi = n \cdot v \quad (12)$$

No reator de pesquisa Argonauta, existem duas regiões onde ocorrem os fluxos de neutros térmico e rápido, denominadas núcleo e refletor. Na região do núcleo, onde ocorre a fissão, encontra-se alta densidade de U-235, que é o combustível físsil usado. A região do refletor, localizada ao redor do núcleo, tem como finalidade refletir o fluxo de nêutrons de volta ao núcleo pelo material não físsil por espalhamento, que no reator Argonauta são utilizadas barras de grafite (AGUINA, 1989).

O refletor aumenta a eficiência do reator, devolvendo parte dos nêutrons que escapariam. O uso do refletor de grafite eleva a eficiência global do reator, permitindo operar com menor quantidade de combustível e favorecendo a uniformidade espacial do fluxo neutrônico. Além disso, essa configuração possibilita maior estabilidade nos experimentos de irradiação, uma vez que a presença do refletor contribui para reduzir gradientes bruscos de fluxo entre diferentes regiões (SOARES, 2019).

Assim, o arranjo núcleo-refletor do Argonauta representa não apenas uma solução de otimização energética, mas também um recurso de segurança e de economia de combustível, características que justificam seu emprego em reatores de pesquisa ao redor do mundo (DE AGUIAR, SOUTO, AFONSO, FIGUEIREDO, 2023).

2.1.6 POTÊNCIA PRODUZIDA EM UM REATOR

A taxa de colisão de um nêutron é calculada em função da distância total percorrida por segundo pelo nêutron no átomo alvo e do fluxo neutrônico, pois é a multiplicação da densidade dos átomos do alvo (átomos alvo/cm³), diretamente proporcional ao espaçamento dos átomos do alvo, e do fluxo de nêutrons (nêutrons/cm² · segundo) (CURTISS, 1959).

Logo, quanto maior a densidade dos átomos do alvo, maior será a probabilidade de colisões e a taxa de colisão. A equação da taxa de colisão é mostrada na equação 13.

$$\text{Taxa de colisão} = \phi \cdot N \quad (13)$$

A partir da taxa de colisão pode-se determinar a taxa de reação em um material físsil, pois é a multiplicação taxa de colisão pela seção de choque microscópica. A equação da taxa de reação em função da seção de choque microscópica é mostrada na equação 14.

$$\text{Taxa de reação} = \phi \cdot N \cdot \sigma \quad (14)$$

A taxa de reação em função da seção de choque macroscópica é mostrada na equação 15.

$$RR \left(\frac{\text{reações}}{\text{cm}^2} \cdot \text{segundo} \right) = \phi \cdot \Sigma \quad (15)$$

Ao longo de um ciclo de operação, a taxa de reação total é calculada pela equação mostrada na equação 16.

$$TRR = \phi \cdot \Sigma \cdot V \text{ [reações/segundo]} \quad (16)$$

A potência térmica do reator é proporcional à energia liberada por fissão e à taxa total de fissões no núcleo. Cada fissão libera, em média, uma energia E_f (cerca de 200 MeV por fissão para U-235) (LAMARSH, 2001).

A equação que descreve a potência de um reator é mostrada na equação 18.

$$P = \int_{V_o}^{V_f} R_f(\vec{r}) \cdot E_f \partial V \quad (17)$$

$$P = \int_{V_o}^{V_f} N(\vec{r}) \cdot \sigma_f \cdot \phi(\vec{r}) \cdot E_f \cdot \partial V \quad (18)$$

No quadro 2, são mostradas as unidades usuais para o cálculo de potência de um reator.

1 Mev	$1.602 \times 10^{-13} \text{ J}$
1 Watt	$3.12 \times 10^{10} \text{ fissões/segundo}$

Quadro 2 - Unidades usuais para o cálculo de potência de um reator.

Fonte: Adaptado de Duderstadt (1976).

Reescrevendo a equação 18 para um volume de um material físsil, obtém-se a equação 19.

$$P = \phi \cdot \Sigma \cdot V \text{ [fissões/segundo]} \quad (19)$$

A equação análoga à equação 19 para o cálculo da potência em watts é mostrada na equação 20.

$$P = \frac{\phi \cdot \Sigma V}{3.12 \times 10^{10}} \text{ watts} \quad (20)$$


Em reatores de pesquisa, o fluxo não é uniforme devido à geometria e à presença de refletores e moderadores. A potência é maior onde o fluxo é mais alto (no centro do núcleo). A potência é controlada ajustando o fluxo de nêutrons, por meio de barras de controle (que absorvem nêutrons) ou refletores móveis. Sua utilidade é importantíssima no experimento de aproximação subcrítica num reator de pesquisa.

2.1.7 FATOR DE MULTIPLICAÇÃO

O fator de multiplicação relaciona a variação do número de neutros de uma geração e o número de nêutrons da geração anterior. Através deste fator, pode-se analisar a estabilidade e a criticalidade da reatividade e do fluxo de nêutrons no núcleo do reator.

Um nêutron rápido, que teve origem na fissão do U-235, entra em reação com um núcleo do U-238 e provoca fissão, liberando 200 MeV de energia. A energia média deste nêutron incidente é de $\cong 2.0$ MeV. Os fragmentos de fissão instáveis liberam nêutrons retardados por decaimento beta, em cerca de menos de 1%, na fissão do U-238. Estes nêutrons retardados são essenciais para o controle de um reator, pois aumentam o tempo de resposta do sistema (CURTISS, 1959).

Na equação 21 é mostrada a formação de fragmentos de fissão na fissão do U-235.



Na equação 22, é mostrada a formação do nêutron retardado a partir do decaimento β^- do núcleo ${}_{35}^{94}\text{Br}$, liberando um nêutron retardado no seu estado excitado para se estabilizar.



Após a fissão do ^{235}U , são formados nêutrons rápidos e o fator de fissão rápida prevê a formação destes nêutrons enquanto $E \geq 1 \text{ MeV}$. A equação do fator de fissão rápida é mostrada na equação 23.

$$N = \epsilon \cdot N \quad (23)$$

No processo de fissão do ^{235}U , a probabilidade de nêutrons rápidos não fugirem do núcleo é denominada L_f . A equação da fração do nº total de nêutrons rápidos que iniciam o processo de frenagem no moderador é mostrada na equação 24.

$$F_{total} = N \cdot \epsilon \cdot L_f \quad (24)$$

A probabilidade de escape à ressonância é a probabilidade (p) de um nêutron não ser capturado na ressonância do ^{238}U , pois estes nêutrons alcançarão a energia térmica. A equação desta quantidade da população de nêutrons é mostrada na equação 25.

$$n^{\circ} \text{ neutrons} = N \cdot \epsilon \cdot L_f \cdot p \quad (25)$$

A probabilidade dos nêutrons térmicos que não fogem do núcleo do reator é denominada probabilidade de não fuga térmica (L_t) e sua equação é mostrada na equação 26.

$$n^{\circ} \text{ de neutrons térmicos} = N \cdot \epsilon \cdot L_f \cdot p \cdot L_t \quad (26)$$

A reação em cadeia é sustentada pelos nêutrons que serão absorvidos pelo combustível nuclear ou material fissionável, cuja a probabilidade denomina-se fator de utilização térmica (f) (CURTISS, 1959).

A equação que calcula esta população é mostrada na equação 27.

$$\text{População de nêutrons} = N \cdot \epsilon \cdot L_f \cdot p \cdot L_t \cdot f \quad (27)$$

A população de nêutrons na reação em cadeia, uma percentual causa fissão e outro causa captura radioativa. O percentual de nêutrons de fissão originados da captura de nêutrons térmicos no material físsil é denominado fator de reprodução (η) e sua equação que calcula o nº de nêutrons rápidos para a próxima geração é mostrada na equação 28 (STACEY, 2007).

$$N^{\circ} \text{ de nêutrons rápidos} = N \cdot \epsilon \cdot L_f \cdot p \cdot L_t \cdot f \cdot \eta \quad (28)$$

A razão entre o nº de nêutrons rápidos e o número original de nêutrons é o fator de multiplicação K e sua equação é mostrada na equação 29.

$$K = \frac{N \cdot \epsilon \cdot L_f \cdot p \cdot L_t \cdot f \cdot \eta}{N} \quad (29)$$

Da simplificação da equação 29, obtém-se a equação da formula de seis fatores, mostrada na equação 30.

$$K_{eff} = \epsilon \cdot L_f \cdot p \cdot L_t \cdot f \cdot \eta \quad (30)$$

O reator infinito é o reator em que os nêutrons não fogem ou nunca alcançarão suas bordas de contorno. Em um sistema finito, os nêutrons alcançam a superfície externa do núcleo do reator, o que se denomina fuga neutrônica. Neste caso K é denominado K efetivo. Entretanto, em um reator infinito, onde as probabilidade de não fuga rápida e lenta totalizam 1, $K = K_{\infty}$, o que se denomina K infinito (CURTISS, 1959).

A soma das probabilidades de fuga e não fuga é igual a 1, logo a equação 30 torna-se a equação 31 que se denomina formula dos quatro fatores.

$$K_{\infty} = \epsilon \cdot p \cdot f \cdot \eta \quad (31)$$

2.1.8 UNIDADES DE REATIVIDADE USADAS EM PESQUISA

A reatividade (ρ) é uma medida adimensional que indica o desvio da condição de criticalidade de um reator nuclear. Ela é frequentemente expressa em diferentes unidades, como porcentagem (%) ou pcm, dependendo do contexto. A porcentagem (%) representa a reatividade como uma fração do número de nêutrons efetivos multiplicado por 100. É uma unidade relativa ao desvio percentual da criticalidade, em que 1 pcm equivale a 10^{-5} da reatividade adimensional, ou seja, 1% dividido por 1000. É uma unidade mais fina, usada para pequenas variações (STACEY, 2007; CURTISS, 1959).

Para converter-se reatividade percentual (%) para reatividade em *pcm*, considera-se que 1% de reatividade corresponde a 10000 *pcm* (porque 1% = 0.01 em termos adimensionais, e $0.01 \times 10^{-5} = 10000 \text{ pcm}$).

Desta forma, a formula da conversão é mostrada na equação 32. Se a reatividade é negativa, o sinal é preservado na conversão, ou seja, uma reatividade negativa em % resulta em uma reatividade negativa em *pcm*. Por exemplo, $\rho_{pcm} = -0.01 \times 10000 = -100 \text{ pcm}$.

$$\rho_{pcm} = \rho\% \times 10000 \quad (32)$$

Onde ρ_{pcm} é a reatividade em *pcm* e $\rho\%$ é a reatividade em porcentagem (%).

A unidade de reatividade $\Delta K/K$ é usada em experimentos de aproximação subcrítica, e relaciona a reatividade ρ com a criticalidade do fluxo de nêutrons no núcleo. O fator de multiplicação ΔK indica numericamente o excesso ou redução de K, em relação ao valor de K=1 no regime crítico. A equação desta unidade é mostrada na equação 33.

$$\rho = \frac{\Delta K}{K} = \frac{K - 1}{K} \quad (33)$$

É o valor numérico da unidade $\Delta K/K$ multiplicado por 100. Um exemplo de conversão desta unidade para reatividade ρ é mostrado na equação 34.

$$\rho \% = \frac{\Delta K}{K} \% \quad (34)$$

A unidade de reatividade dólar é o cálculo da unidade de reatividade ρ em função do β efetivo do reator. Sua equação é mostrada na equação 35.

$$\rho(\$) = \frac{\rho}{\beta} \quad (35)$$

3 CALIBRAÇÃO DE BARRA DE CONTROLE DO REATOR DE PESQUISA ARGONAUTA – MÉTODO DE QUEDA

O reator de pesquisa Argonauta, localizado e instalado no Instituto de Engenharia Nuclear na Ilha do Fundão, têm mecanismos de segurança e monitoramento dos níveis de radiação das operações de produção de rádio fármacos e experimentos de física nuclear envolvendo elementos combustíveis nucleares, como o experimento de aproximação subcrítica, e estes mecanismos de controle de reatividade são os seguintes: Barras de controle, circuito de refrigeração, monitoramento da potência, proteções neutrônicas, sistema de segurança passiva, controle por moderador, sistemas de detecção de radiação, procedimentos operacionais, sistemas de *backup* e redundância (COMISSÃO NACIONAL DE ENERGIA NUCLEAR, 1985; AGUINA, 1989; DE AGUIAR, SOUTO, AFONSO, FIGUEIREDO, 2023).

No reator de pesquisa Argonauta usa-se água leve (H_2O) como moderador, pois reduz a energia cinética dos nêutrons rápidos tornando-os nêutrons térmicos para causarem fissão nuclear no urânio-235. Pois o reator Argonauta utiliza placas de U^{235} enriquecido a 20%, denominado urânio altamente enriquecido (*HEU Highly Enriched Uranium*) e devido aos níveis potência e aumento de temperatura que poderiam causar corrosão ou prejuízos nas barras de controle de reatividade. As placas de combustível são revestidas com uma liga de alumínio anticorrosiva e propiciadora de troca de calor com o refrigerante e as barras de controle foram projetadas e construídas com Boro, Cádmio e ligas contendo Háfnio. Estes materiais que constituem as barras de controle têm alta seção de choque absorvedora de nêutrons térmicos, o que contribui para o controle da reatividade (DE AGUIAR, SOUTO, AFONSO, FIGUEIREDO, 2023).

Nesta dissertação de mestrado foi escolhido o estudo de calibração das barras de controle de reatividade do reator Argonauta pelo método de queda.

3.1 REATIVIDADE PRONTO-SUBCRÍTICA

O estado pronto-subcrítico ocorre quando a reatividade inserida no sistema é insuficiente para manter uma reação em cadeia autossustentável. A dinâmica de nêutrons em um reator é influenciada tanto pelos nêutrons prontos (emitidos em menos de 10^{-14} segundos após a fissão) quanto pelos nêutrons retardados (emitidos por produtos de fissão com tempos de decaimento que variam de milissegundos a minutos) (STACEY, 2007).

Enquanto os nêutrons retardados são vitais para o controle do reator na criticalidade, na subcriticalidade, a resposta do reator a qualquer perturbação de reatividade é dominada pela dinâmica dos nêutrons prontos, especialmente quando o grau de subcriticalidade é alto (CURTISS, 1959).

Aumentando-se a temperatura do combustível nuclear, causa-se a reatividade pronto-subcrítica, com aumento na seção de choque efetiva de absorção de ressonância, o que provoca um aumento na absorção de nêutrons térmicos e uma redução correspondente na reatividade. Este efeito é conhecido como efeito *Doppler* (SUESCÚN-DÍAZ, ESPINOSA-PAREDES, 2020).

Um aumento na temperatura do moderador causa uma diminuição na densidade do moderador/refrigerante, alterando suas propriedades e uma diminuição na sua capacidade de absorção. Os nêutrons recebem uma distribuição energética mais alta, alterando as seções de choque de absorção média de energia efetiva, aumentando sua difusão, o que causa uma expansão do reator. O efeito do aumento da difusão de nêutrons é a produção de reatividades negativas e positivas compensatórias, o que deve ser planejado para o controle e segurança do reator através de sistemas passivos de realimentação de reatividade negativa (SUESCÚN-DÍAZ, ESPINOSA-PAREDES, 2020).

No reator de pesquisa Argonauta, usa-se o método da curva de ruído (*noise analysis*) para medir-se a subcriticalidade, cuja a análise das flutuações estatísticas na população de nêutrons (ruído) tem como objetivo inferir parâmetros cinéticos, incluindo a reatividade. A dinâmica de um reator nuclear é governada pela equação de balanço de nêutrons, que considera a produção e perda de nêutrons. A criticalidade é alcançada quando o fator de multiplicação de nêutrons efetivo, K_{eff} , é igual a 1. Crucialmente, os nêutrons produzidos na fissão são classificados em nêutrons prontos, emitidos quase instantaneamente, e nêutrons retardados, emitidos após um atraso por produtos de fissão. A contribuição dos nêutrons retardados é fundamental para o controle do reator, pois eles conferem um "tempo de resposta" que permite a atuação dos sistemas de controle (IEN, 1990).

Quando a reatividade do reator excede a fração de nêutrons retardados efetivos, β_{eff} (em inglês, *effective delayed neutron fraction*), o reator se torna pronto crítico. Nesta condição, a criticalidade é mantida exclusivamente pelos nêutrons prontos, resultando em um tempo de dobramento de potência extremamente curto. Eventos de prontidão crítica podem ser desencadeados por inserções excessivas e rápidas de reatividade, falhas nos sistemas de controle, ou remoção acidental de elementos absorvedores de nêutrons (IEN, 1990; TERREMOTO, 2004).

O aumento abrupto de potência, gerada nesta condição, pode levar a danos no combustível nuclear, danos estruturais, e liberação radiológica de material radioativo, causando danos ao meio ambiente e a saúde pública. A análise de riscos em reatores de pesquisa, incluindo a avaliação de acidentes de reatividade, é uma parte integrante do programa de licenciamento e da operação segura (TERREMOTO, 2004).

3.2 MÉTODO DE QUEDA

A operação segura e eficiente de reatores de pesquisa depende fortemente do controle preciso da reação nuclear em cadeia. As barras de controle são componentes essenciais nesse processo, atuando como reguladores da taxa de fissão nuclear ao

absorver nêutrons. A calibração dessas barras é, portanto, uma etapa crítica para garantir a confiabilidade e a segurança do reator (PINEM, LUTHFI, HARTANTO, LIEM, 2023).

Este trabalho aborda o método de queda para a calibração de barras de controle, destacando sua aplicação em reatores de pesquisa, seus fundamentos teóricos e as práticas recomendadas para sua execução.

Os testes físicos de partida em um reator de pesquisa ocorrem após a recarga do núcleo ou outras mudanças tais como manutenção, instalação de novos componentes, alteração do inventário (quantidade total de combustível físsil e fértil, produtos de fissão e elementos transurânicos alocados no núcleo do reator em determinado momento) para que as garantias operacionais estejam de acordo com suas especificações de segurança e operação (Stefani et al., 2023).

Uma das etapas dos testes físicos é a calibração das barras de controle de reatividade pelo método de queda. Existem outros testes físicos em que são desenvolvidas pesquisas científicas e desenvolvimento de tecnologias embarcadas: método de multiplicação de fonte de nêutrons, método de oscilação da barra de controle, diluição de boro, e calibração de barras de controle de reatividade pelo método de queda (STEFANI, CARVALHO, PALMA, SILVA, RAITZ, 2023).

A calibração da barra de controle de reatividade pelo método de queda tem a vantagem de ser executada num intervalo de tempo menor e ser menos onerosa. Neste método, o reator é operado até alcançar o estado crítico e a partir deste instante começa-se a calibração, liberando a barra até a posição desejada, em que a reatividade integral será medida (ZHI HUI, SYAZWANI MOHD ALI, SABRI MINHAT, ZAINAL, ARIF SAZALI, SYAHIR SARKAWI, JAMALUDDIN, AFIFAH BASRI, KHAIR ALANG MD RASHID, 2024).

No reator Argonauta, são utilizados como instrumentação para medir o fluxo de nêutrons câmaras de ionização e detectores de fissão, que integrados aos sistemas de controle permitem o ajuste das barras de controle e segurança operacional (IEN, 1990; IEN, 1991).

A calibração de barras de controle pelo método de queda baseia-se na medição do tempo de queda livre da barra no núcleo do reator. Esse tempo está diretamente relacionado à eficiência da barra em interromper a reação em cadeia. A eficiência de uma barra de controle é definida como a fração de nêutrons que ela é capaz de absorver, influenciando diretamente a taxa de reação nuclear (DUDERSTADT & HAMILTON, 1976).

O método de queda consiste em liberar a barra de controle de uma posição elevada e medir o tempo que ela leva para percorrer a distância até o núcleo. Esse tempo é então correlacionado com a eficiência da barra, considerando fatores como a velocidade de queda, a densidade do meio e as propriedades materiais da barra (LAMARSH, BARATTA, 2001).

A calibração pelo método de queda envolve várias etapas, que incluem a preparação do reator, a execução do teste e a análise dos dados. Inicialmente, o reator deve ser levado a uma condição subcrítica, garantindo que a liberação da barra não cause uma reação em cadeia descontrolada. Em seguida, a barra de controle é posicionada em uma altura pré-determinada e liberada, enquanto sensores registram o tempo de queda (AGUINA, 1989).

Os dados coletados são então analisados para determinar a eficiência da barra. Essa análise considera a relação entre o tempo de queda e a eficiência, que pode ser modelada por equações diferenciais que descrevem o movimento da barra no meio do reator. A calibração é finalizada com a validação dos resultados, comparando-os com valores de referência ou com medições realizadas por outros métodos (KNIEF, 2008).

A calibração das barras de controle do reator Argonauta pelo método de queda tem como objetivo aumentar a segurança de operação e o controle de reatividade nos regimes de operação subcrítico, crítico e supercrítico. Através da sala de controle, o operador faz a inserção das barras de controle no núcleo do reator, inserindo reatividade negativa e registrando a taxa de potência e o fluxo de nêutrons tendo como parâmetro a corrente proporcional medida pela instrumentação (IEN, 1991).

4 REDES NEURAIS ARTIFICIAIS

Géron (2021) em sua referência bibliográfica define redes neurais artificiais como um modelo de aprendizado de máquina inspirado nas técnicas do sistema nervoso humano na geração de padrões de compreensão e aprendizado de problemas e identificação de soluções. Ela segue a topologia de neurônios humanos, que se comunicam através dendritos por sinapses, formando redes integradas que supervisionam erros e acertos, alterando termos como pesos que interagem com os dados em suas entradas para alcançar a saída desejada.

O seu desenvolvimento começou em 1943 pelo neurofisiologista Warren McCulloch e pelo matemático Walter Pitts, conforme citado por GÉRON (2021) com base nos artigos destes estudiosos (<https://homl.info/43>) “*A Logical Calculus of Ideas Immanent in Nervous Activity*” (Um Cálculo Lógico das Ideias Imanentes à Atividade Nervosa, em tradução livre). A primeira arquitetura de rede neural artificial foi desenvolvida com base na lógica proposicional, em que neurônios biológicos podem trabalhar em redes para solucionar problemas de cálculos computacionais.

Na década de 1960, centros de pesquisa e desenvolvimento de tecnologia, nos Estados Unidos da América, careciam de recursos e estruturas computacionais robustas o suficiente para aplicação das redes neurais artificiais em interfaces de comunicação e controle com outros sistemas, como médicos, industriais, militares, e de pesquisa e ensino, provocando uma paralisação em seu desenvolvimento e pesquisa (AYODEJI, AMIDU, OLATUBOSUN, ADDAD, AHMED, 2022).

A partir da década de 1990, novas tecnologias baseadas no algoritmo do gradiente descendente, como as máquinas de vetores de suporte foram desenvolvidas (GÉRON, 2021), alcançando melhores resultados computacionais em previsões e validação de dados.

Atualmente, com a oferta e produção de computadores e *datacenters* mais modernos e robustos, a comunidade científica e industrial acelerou desenvolvimento de arquiteturas de redes neurais profundas para resolução de problemas computacionais ainda mais complexos, que envolvem processamento de imagem, inteligência artificial ligada a mobilidade em redes celulares de telecomunicação, solução de problemas de cálculos complexos de engenharia, automação de sistemas inteligentes, e sistemas

bancários de atendimento ao cliente (AYODEJI, AMIDU, OLATUBOSUN, ADDAD, AHMED, 2022; Cho et al., 2022).

Essa rápida evolução tecnológica tem impulsionado um ciclo contínuo de inovação, em que novos algoritmos demandam maior capacidade de processamento e, ao mesmo tempo, estimulam a criação de hardware especializado, como as unidades gráficas de processamento (GPUs) e os processadores neurais dedicados. Assim, o cenário atual evidencia uma tendência de expansão constante, na qual pesquisa acadêmica e aplicação industrial caminham de forma integrada para atender desafios cada vez mais sofisticados (Ayodeji et al., 2022; Zhou et al., 2020).

4.1 REDE NEURAL ARTIFICIAL MLP (MULT LAYER PERCEPTRON)

Frank Rosenblatt inventou em 1957 uma arquitetura de RNA conhecida como Perceptron. Nesta arquitetura, um neurônio artificial chamado TLU (*threshold logical unit*). Este neurônio possui entradas e saídas de números, em que pesos estão associados as entradas (GERON, 2021; Cho et al., 2022).

Através da equação de soma ponderada, mostrada na equação 36, uma TLU, de 3 entradas, mostrada na Figura 8, aplica uma função degrau a essa soma e gera o resultado, mostrado na equação 37.




Figura 1 – Representação esquemática de uma TLU

Fonte: ICMC-USP (s.d.). Retirado de <https://sites.icmc.usp.br/andre/research/neural/>.

$$z = w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 \cdot x_3 \quad (36)$$

$$h_w(x) = \text{degrau}(z) \quad (37)$$

Uma TLU pode ser usada para classificação binária linear simples, em que se o resultado não atingir a condição de ativação do limiar, gera-se uma regressão logística ou um classificador de máquina de suporte vetorial linear. A composição de TLU's em paralelo em uma camada é o perceptron (GERON, 2021; Wu et al., 2021).

Na equação, é mostrada a equação do cálculo das saídas de uma camada de perceptron conectada.

$$h_{w,b}(X) = \phi(xw + b) \quad (38)$$

Onde X representa a matriz característica das entradas, w é a matriz dos pesos das conexões entre os neurônios, b é o vetor de vies que contém os pesos de conexão entre o neurônio de vies e os neurônios artificiais na camada oculta e ϕ é a função de ativação adotada de acordo com a configuração do neurônio artificial.

O treinamento de um perceptron foi proposto por Rosenblatt com base na regra de Hebb ou aprendizado hebbiano, em que os perceptrons são treinados com base no erro, reforçando suas conexões com alteração dos pesos de conexão até que o erro seja reduzido (GERON, 2021; Wu et al., 2021).

Esta regra é utilizada no cálculo numérico e conhecida como predição. Esta regra de predição é mostrada na equação 39.

$$w_{(i,j)próximo} = w_{i,j} + \eta(y_j - \hat{y}_j)x_i \quad (39)$$

Onde $w_{i,j}$ é o peso da conexão entre o i -ésimo neurônio de entrada e o j -ésimo neurônio de saída, x_i é o i -ésimo valor de entrada da instância de treinamento atual, y_j é a saída da j -ésima saída do neurônio para a instância de treinamento atual, \hat{y}_j é a saída alvo do j -ésimo neurônio de saída para a instância de treinamento atual e η é a taxa de aprendizado.

A fronteira de decisão de cada neurônio de saída é linear; assim sendo, as perceptrons não conseguem aprender padrões complexos (como os classificadores de regressão logística). Contudo, se as instâncias de treinamento forem linearmente

separáveis, Rosenblatt demonstrou que esse algoritmo convergiria para uma solução. Isto se chama teorema da convergência do perceptron (GERON, 2021; Fleck et al., 2016).

Os perceptrons não geram uma saída de probabilidade de classe (como os classificadores de regressão logística), pois suas previsões são feitas com base numa função degrau, incapazes de resolver problemas que envolvem não linearidade, o que se mostrou uma grave deficiência (GERON, 2021; Wu et al., 2021).

Em 1982, Paul Werbos apresentou o algoritmo de retropropagação do erro (*backpropagation*), considerado um dos maiores avanços na área de redes neurais artificiais. Esse desenvolvimento foi decisivo para superar uma limitação histórica enfrentada pelos pesquisadores da época: a dificuldade das redes neurais clássicas, como o perceptron de camada única, em resolver problemas de natureza não linear (GERON, 2021).

A introdução da retropropagação permitiu que modelos computacionais passassem a ajustar seus parâmetros internos de forma mais eficiente, tornando-se capazes de representar relações complexas entre variáveis e de aprender padrões em bases de dados de alta dimensionalidade (BISONG, 2019; Wu et al., 2021).

Segundo Fleck et al. (2016), uma Rede Neural Artificial do tipo MLP (*Multilayer Perceptron*) caracteriza-se por possuir uma camada de entrada, uma ou mais camadas ocultas intermediárias e uma camada de saída. A estrutura é organizada de modo que cada camada processa as informações recebidas e transmite o resultado para a camada seguinte. É importante ressaltar que todas as camadas, com exceção da camada de saída, possuem um neurônio de viés (bias), cuja função é melhorar a flexibilidade da rede ao ajustar os limiares de ativação dos neurônios subsequentes. Essa característica garante maior capacidade de modelagem para fenômenos não lineares, tornando a MLP uma arquitetura robusta para aplicações em diversas áreas do conhecimento.

As redes MLP treinadas por retro propagação distinguem-se pelo processo de aprendizado supervisionado. Inicialmente, o padrão de ativação de entrada é propagado camada por camada até a saída, em um processo denominado *feedforward*. Quando o resultado chega à camada final, ocorre a etapa de correção de erro, baseada no algoritmo de gradiente descendente estocástico. Nesse mecanismo, calcula-se a diferença entre a saída obtida e a saída desejada, gerando-se uma medida de erro. Esse erro é então retro propagado pela rede, ajustando os pesos sinápticos em cada camada, de modo a reduzir progressivamente a discrepância entre o resultado previsto e o esperado. O ciclo se repete até que o desempenho atinja um nível aceitável, definido por critérios de convergência estabelecidos pelo pesquisador (BISONG, 2019; Ayodeji et al., 2022).

A retro propagação tornou-se, desde então, um dos métodos mais difundidos no treinamento de redes neurais, sendo aplicada em problemas de classificação, regressão e reconhecimento de padrões. Exemplos incluem o diagnóstico médico por imagens, a previsão de séries temporais financeiras, o processamento de linguagem natural e até mesmo experimentos em física nuclear e engenharia, onde fenômenos altamente não lineares precisam ser modelados (Ayodeji et al., 2022).

Na Figura 2, apresenta-se uma arquitetura típica de uma rede MLP contendo duas camadas ocultas. Esse exemplo ilustra como a informação percorre as diferentes camadas até a saída, enquanto os pesos são ajustados dinamicamente durante o processo de aprendizado. Quanto maior o número de camadas ocultas e de neurônios em cada camada, maior será a capacidade de representação da rede. Entretanto, esse aumento de

complexidade também exige maior poder computacional e estratégias de regularização para evitar problemas de sobre ajuste (*overfitting*).

O equilíbrio ideal reside entre um modelo muito simples (*underfitting*), que não captura a complexidade de dados, e um modelo excessivamente complexo (*overfitting*) que se ajusta demais aos desvios ou ruídos. A profundidade da rede neural MLP, determinada pelo número de camadas ocultas e neurônios por camadas, deve ser ajustada por meio de validação cruzada, buscando o ponto em que o erro no conjunto de validação comece a aumentar. Técnicas de regularização como L1, L2 ou *Dropout* e a parada antecipada (*Early Stopping*) são mecanismos essenciais para restringir a complexidade do modelo, penalizando pesos excessivamente altos ou interrompendo o treinamento no momento ótimo. O objetivo é garantir que a rede mantenha um desempenho consistentemente alto tanto nos dados de treino quanto nos de teste, assegurando a robustez preditiva (BISONG, 2019; Wu et al., 2021; Zhou et al., 2020; Cho et al., 2022).

Assim, o equilíbrio entre profundidade da rede e generalização do modelo torna-se um aspecto central no projeto de arquiteturas de aprendizado baseadas em MLP (Wu et al., 2021; BISONG, 2019).

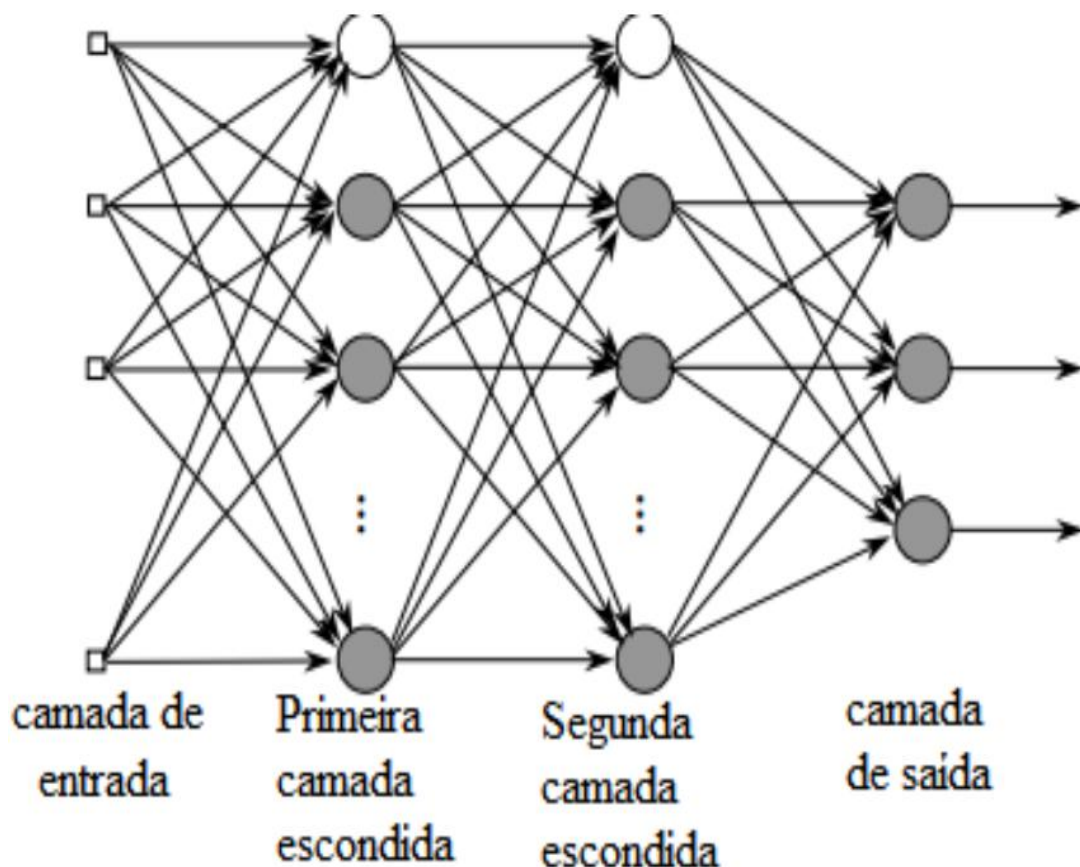


Figura 2 – Arquitetura MLP com duas camadas intermediárias

Fonte: ICMC-USP (s.d.). Retirado de <https://sites.icmc.usp.br/andre/research/neural/>.

A RNA MLP por retro propagação pode gerar padrões não lineares na sua saída pela função de ativação do tipo sigmoide, pois é uma função crescente que possibilita a

logística em suas regiões linear e não linear no intervalo $[0,1]$, isto é, transformando números reais em probabilidades. Sua derivada é diferente de zero em todos os pontos do intervalo $[0,1]$, possibilitando o gradiente descendente em todos os pontos (Fleck et al., 2016).

A equação da função sigmoide (logística) é mostrada na equação 40.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (40)$$

Onde x é a entrada da função (número real) e $\sigma(x)$ é a probabilidade da entrada x

A derivada da equação 40 é mostrada na equação 41. Na figura 3, é mostrado o gráfico da função de ativação sigmoide.

$$\sigma'(x) = \sigma(x) \cdot (1 - \sigma(x)) \quad (41)$$




Figura 3 – Função de ativação sigmoide e sua derivada

Fonte (FACURE, 2017). Retirado de <https://matheusfacure.github.io/2017/07/12/activ-func/>.

O algoritmo de retro propagação foi implementado com outras funções de ativação conhecidas como função de tangente hiperbólica ($\tanh(z)$) e função de unidade linear retificada ($\text{relu}(z)$).

A função de ativação de tangente hiperbólica é contínua e diferenciável, gerando valores de saída no intervalo $[-1,1]$, o que no início do treinamento centraliza a saída de cada camada em torno de 0, balanceando as ativações dos neurônios, acelerando a convergência (Taloba et al., 2023; Alam et al., 2021).

A equação desta função de ativação é mostrada na equação 42. Na figura 4, é mostrado o gráfico da função de ativação de tangente hiperbólica.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (42)$$

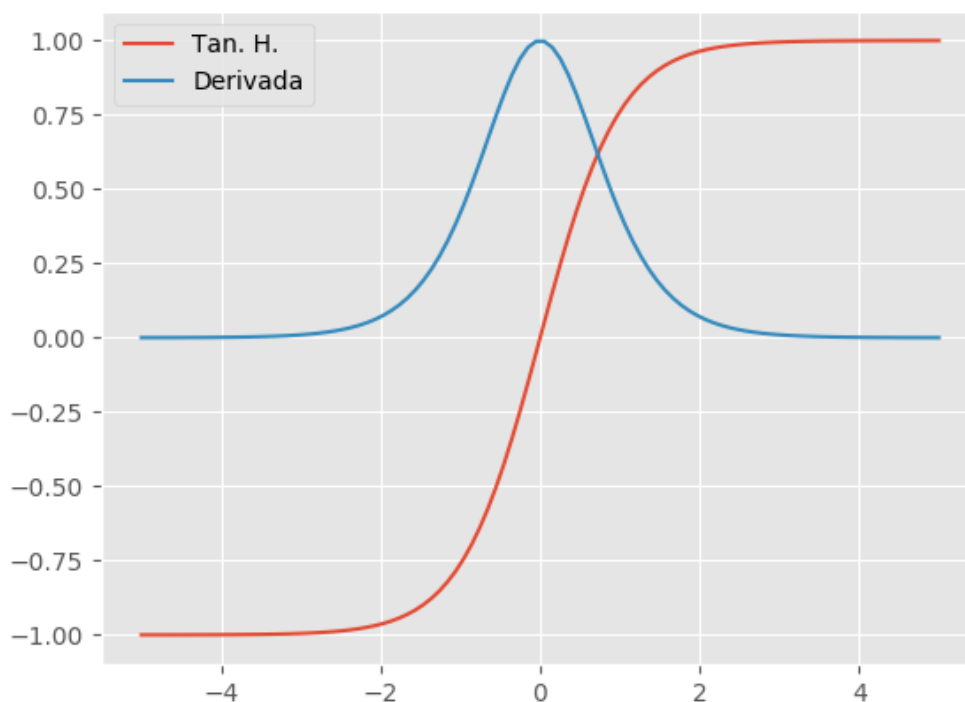


Figura 4 – Função de ativação de tangente hiperbólica e sua derivada

Fonte: (FACURE, 2017). Retirado de <https://matheusfacure.github.io/2017/07/12/activ-func/>.

A função de ativação de unidade linear retificada ($\text{ReLU}(z)$) dentre as funções de ativação apresentadas neste trabalho é considerada a mais eficiente, pois suas derivadas são estáveis e de fácil cálculo computacional. A partir de $x \geq 0$, sua derivada assume valor igual a 1, e quando $x \leq 0$ ela se anula, sendo igual a 0. Essa simplicidade reduz o custo computacional em comparação com funções mais complexas, como a sigmoide e a tangente hiperbólica, que apresentam derivadas mais custosas e suscetíveis ao

problema do gradiente desaparecendo. Uma desvantagem importante da ReLU é a ausência de atualização do gradiente descendente quando $x \leq 0$, fenômeno conhecido como *dying ReLU*, que pode levar parte dos neurônios a permanecerem inativos durante o treinamento (Taloba et al., 2023; Alam et al., 2021).

A ReLU é amplamente utilizada em arquiteturas modernas de aprendizado profundo, justamente por favorecer a convergência mais rápida e permitir o treinamento de redes com muitas camadas sem perda significativa de desempenho. Como alternativas para mitigar suas limitações, variantes como *Leaky ReLU* e *Parametric ReLU* foram propostas, introduzindo um pequeno gradiente na região negativa para evitar a completa inatividade de neurônios (Alam et al., 2021; Kotsiopoulos et al., 2021).

A equação matemática desta função de ativação é mostrada na Equação 43, enquanto o seu comportamento característico pode ser visualizado no gráfico da Figura 5, evidenciando a linearidade para valores positivos e a saturação nula para valores negativos.

$$relu(x) = \max(0, x) \quad (43)$$

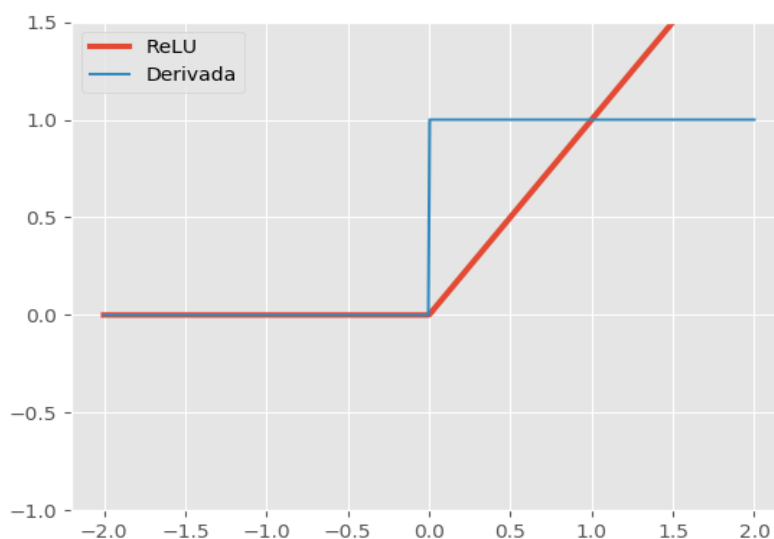


Figura 5 – Função de ativação $relu(x)$ e sua derivada

Fonte: (FACURE, 2017). Retirado de <https://matheusfacure.github.io/2017/07/12/activ-func/>.

A função de ativação softmax, conhecida como função exponencial normalizada, calcula a probabilidade de cada classe pelo *score* atribuído a cada classe k . Este modelo de regressão logística é conhecido como regressão softmax (GERON, 2021; Alam et al., 2021).

A equação da função de ativação softmax é mostrada na equação 44.

$$\widehat{P}_k = \sigma(s(x))_k = \frac{\exp(s_k(x))}{\sum_{j=1}^k \exp(s_j(x))} \quad (44)$$

Onde:

$$s_k(x) = x^T \cdot \theta^{(k)} \quad (45)$$

O termo $s_k(x)$ é o vetor de *scores* de uma classe k e instância x, $\theta^{(k)}$ é o vetor de parâmetro dedicado de uma classe k, $\sigma(s(x))_k$ é a probabilidade estimada de que a instância x pertença a classe k com base nos *scores* de cada classe para esta instância. Na figura 6, é mostrada o gráfico da função de ativação softmax.




Figura 6 – Função de ativação softmax

Fonte: (ABHIRAMI, 2023). Retirado de <https://medium.com/@AbhiramiVS/softmax-vs-logsoftmax-eb94254445a2>.

As RNA's MLP podem ser usadas para tarefa de identificação de padrões e predição de padrões e variáveis, como as usadas num reator de pesquisa que indicam o quão crítico está o núcleo em quanto o combustível nuclear sofre fissões. Por exemplo, para predizer o percentual de retirada de barra de controle de reatividade no núcleo do reator Argonauta e o nível de reatividade, em seu núcleo, seriam necessários dois neurônios de saída (YANG, GUI, YANG, TU, JIANG, 2025).

5 REATOR ARGONAUTA

O reator de pesquisa Argonauta do Instituto de Engenharia Nuclear (IEN) foi projetado no *ARGONNE NATIONAL LABORATORY*, inicialmente na década de 60 em parceria com a CNEN (Comissão Nacional de Energia Nuclear), sendo modificado para

atender as demandas e capacidades atuais de pesquisa nuclear na medicina nuclear, produção de radioisótopos, no ciclo do combustível, física de reatores, formação de recursos humanos, e na segurança nuclear. Conforme publicação do IEN, os resultados alcançados nos últimos anos foram divulgados em relatórios técnicos, revistas de pesquisa e relatórios do IEN, congressos científicos e periódicos nacionais e internacionais (AGUINA, 1989; WNA, 2024; IAEA, 2024).

A produção de radioisótopos visa sua utilização como traçadores radioativos em pesquisas e aplicações industriais que envolvem estudos sobre a contaminação do meio ambiente como: otimização de unidades de tratamento de água residuais urbanas e industriais, estudo da cinética de absorção de selênio em algas e estudo da cinética do manganês em manguezais (WNA, 2024; IAEA, 2024).

Os principais radioisótopos produzidos no reator Argonauta são os seguintes: Au-198, La-140, Mn-56, Br-82 e Na-24. Estes elementos são analisados com diversas técnicas de ativação neutrônica que tem o recurso de detecção de diversos elementos, logo possuem potencial de sensibilidade em relação as técnicas analíticas convencionais (TERREMOTO, 2004).

O reator Argonauta possui um fluxo nos principais locais de irradiação que possibilita a verificação de concentração de elementos da ordem de ppm (parte por milhão), sendo que para fluxo maiores esta técnica consegue detectar concentrações ainda mais baixas (AGUINA, 1989).

Uma placa de combustível que alimenta o reator Argonauta contém uma mistura de alumínio com U_3O_8 , ambos em pó, sendo o urânio enriquecido em 19.91 % em U-235. A placa de combustível é obtida após a laminação do quadro prensado de 12 mm que contém a mistura e tem as dimensões (2.43 x 73 x 610) mm. São utilizadas 17 placas de combustível fixadas por dois pinos de alumínio (IEN, 1990; IEN, 2023).

Em sua montagem estrutural, o reator Argonauta utiliza como moderador água deionizada, entre as placas; e grafite em forma de cunha entre os elementos combustíveis. Como refletor dos nêutrons gerados pela fonte de Am-Be, na direção radial e azimutal utiliza-se o grafite e na direção vertical utiliza-se a água. Em sua blindagem para proteção, estão presentes blocos de concreto empilhados em torno do refletor para proteção lateral, blocos de concreto revestidos com uma chapa de aço para proteção no plano superior e um tanque de blindagem cheio de água no lado oposto da coluna térmica externa (IEN, 1990; IEN, 2023).

O controle da população de nêutrons é realizado com um motor que desloca, no sentido vertical, seis barras de cádmio em espaços reservados no refletor externo de grafite, as quais absorvem os nêutrons (IEN, 1990; IEN, 1991).

Na figura 7, é mostrado o esquema em vista isométrica do núcleo do reator Argonauta com as barras de controle instaladas.




Figura 7 - Esquema em vista isométrica do núcleo do reator Argonauta com as barras de controle instaladas

Fonte: Extraído de (DANIEL, 2020).

6 REDE NEURAL ARTIFICIAL PARA PREDIÇÃO DO FLUXO TÉRMICO NORMALIZADO

No desenvolvimento do modelo da RNA MLP, os dados relativos a reatividade negativa, razão do fluxo térmico normalizado e intervalos de tempo de operação foram gerados com base nas tabelas de calibração de barra de controle pelo método de queda desenvolvidas por (AGUINA, 1989), mostradas nas tabelas 3, 4, 5, 6 e 7.

Tabela 3 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.01 e 0.10

$T_{seg} \setminus -\rho\%$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1
5	0.974	0.949	0.925	0.902	0.880	0.859	0.839	0.82	0.802	0.784
10	0.965	0.932	0.901	0.872	0.844	0.818	0.793	0.77	0.748	0.726
15	0.958	0.919	0.882	0.848	0.816	0.786	0.757	0.731	0.706	0.682
20	0.951	0.907	0.865	0.827	0.791	0.758	0.727	0.698	0.671	0.646

25	0.946	0.896	0.850	0.808	0.769	0.733	0.700	0.669	0.640	0.614
30	0.940	0.885	0.835	0.790	0.748	0.710	0.675	0.643	0.613	0.585
35	0.934	0.875	0.822	0.773	0.729	0.689	0.652	0.618	0.587	0.559
40	0.929	0.866	0.809	0.758	0.711	0.669	0.631	0.596	0.564	0.535
45	0.924	0.857	0.796	0.742	0.694	0.650	0.610	0.575	0.542	0.512
50	0.919	0.848	0.784	0.728	0.677	0.632	0.591	0.554	0.521	0.491
55	0.914	0.839	0.772	0.713	0.661	0.614	0.573	0.535	0.501	0.471
60	0.909	0.830	0.761	0.700	0.646	0.598	0.555	0.517	0.483	0.452

Fonte: AGUINA (1989).

Tabela 4 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.10 e 0.20

$T_{seg} \setminus -\rho\%$	0.10	0.11	0.12	0.13	0.14	0.15	0.16	0.17	0.18	0.19	0.20
5	0.784	0.767	0.751	0.735	0.720	0.706	0.692	0.678	0.665	0.653	0.641
10	0.726	0.706	0.687	0.669	0.651	0.635	0.619	0.603	0.589	0.575	0.562
15	0.682	0.660	0.639	0.619	0.600	0.582	0.565	0.549	0.534	0.519	0.506
20	0.646	0.622	0.600	0.579	0.559	0.540	0.523	0.506	0.491	0.476	0.462
25	0.614	0.589	0.566	0.544	0.524	0.505	0.487	0.470	0.454	0.439	0.425
30	0.585	0.559	0.536	0.513	0.493	0.473	0.455	0.438	0.422	0.408	0.394
35	0.559	0.533	0.508	0.486	0.465	0.445	0.427	0.410	0.394	0.380	0.366
40	0.535	0.508	0.483	0.460	0.439	0.420	0.402	0.385	0.369	0.355	0.341
45	0.512	0.485	0.460	0.437	0.416	0.396	0.378	0.362	0.346	0.332	0.318
50	0.491	0.463	0.438	0.415	0.394	0.375	0.357	0.340	0.325	0.311	0.298
55	0.471	0.443	0.418	0.395	0.374	0.355	0.337	0.321	0.306	0.292	0.279
60	0.452	0.424	0.399	0.376	0.355	0.336	0.318	0.302	0.287	0.274	0.261

Fonte: AGUINA (1989).

Tabela 5 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.20 e 0.30

$T_{seg} \setminus -\rho\%$	0.20	0.21	0.22	0.23	0.24	0.25	0.26	0.27	0.28	0.29	0.30
5	0.641	0.629	0.618	0.607	0.596	0.586	0.576	0.566	0.557	0.548	0.539
10	0.562	0.549	0.537	0.525	0.513	0.503	0.492	0.482	0.472	0.463	0.454
15	0.506	0.492	0.480	0.468	0.456	0.445	0.434	0.424	0.415	0.405	0.396
20	0.462	0.448	0.435	0.423	0.412	0.401	0.390	0.380	0.371	0.362	0.353
25	0.425	0.412	0.399	0.387	0.376	0.365	0.355	0.345	0.336	0.327	0.318
30	0.394	0.380	0.368	0.356	0.345	0.334	0.324	0.315	0.306	0.297	0.289
35	0.366	0.353	0.340	0.329	0.318	0.308	0.298	0.289	0.280	0.272	0.264
40	0.341	0.328	0.316	0.305	0.294	0.284	0.275	0.266	0.257	0.250	0.242
45	0.318	0.306	0.294	0.283	0.273	0.263	0.254	0.245	0.237	0.230	0.222
50	0.298	0.285	0.274	0.263	0.253	0.244	0.235	0.227	0.219	0.212	0.205
55	0.279	0.267	0.256	0.245	0.236	0.227	0.218	0.210	0.203	0.196	0.189
60	0.261	0.250	0.239	0.229	0.219	0.211	0.203	0.195	0.188	0.181	0.175

Fonte: AGUINA (1989).

Tabela 6 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.30 e 0.40

$T_{seg} \setminus -\rho\%$	0.30	0.31	0.32	0.33	0.34	0.35	0.36	0.37	0.38	0.39	0.40
5	0.539	0.531	0.523	0.515	0.507	0.499	0.492	0.485	0.478	0.471	0.464
10	0.454	0.445	0.437	0.429	0.421	0.413	0.406	0.399	0.392	0.385	0.379
15	0.396	0.388	0.379	0.371	0.364	0.356	0.349	0.342	0.336	0.329	0.323
20	0.353	0.345	0.337	0.329	0.322	0.315	0.308	0.301	0.295	0.289	0.283
25	0.318	0.310	0.303	0.295	0.288	0.281	0.275	0.269	0.263	0.257	0.251
30	0.289	0.281	0.274	0.267	0.260	0.254	0.248	0.242	0.236	0.231	0.226
35	0.264	0.257	0.250	0.243	0.236	0.230	0.224	0.219	0.214	0.208	0.204
40	0.242	0.235	0.228	0.222	0.216	0.210	0.204	0.199	0.194	0.189	0.184
45	0.222	0.216	0.209	0.203	0.197	0.192	0.186	0.181	0.177	0.172	0.168
50	0.205	0.198	0.192	0.186	0.181	0.176	0.171	0.166	0.161	0.157	0.153
55	0.189	0.183	0.177	0.171	0.166	0.161	0.156	0.151	0.148	0.144	0.140
60	0.175	0.169	0.163	0.158	0.153	0.148	0.144	0.139	0.135	0.132	0.128

Fonte: AGUINA (1989).

Tabela 7 – Razão do fluxo térmico do reator Argonauta para reatividades negativas entre 0.40 e 0.50

$T_{seg} \setminus \rho\%$	0.40	0.41	0.42	0.43	0.44	0.45	0.46	0.47	0.48	0.49	0.50
5	0.464	0.460	0.452	0.446	0.440	0.434	0.428	0.423	0.417	0.412	0.407
10	0.379	0.372	0.366	0.360	0.355	0.349	0.344	0.338	0.333	0.328	0.324
15	0.323	0.317	0.312	0.306	0.301	0.295	0.290	0.286	0.281	0.276	0.272
20	0.283	0.277	0.272	0.267	0.262	0.257	0.252	0.248	0.243	0.239	0.235
25	0.251	0.246	0.241	0.236	0.231	0.227	0.223	0.218	0.214	0.210	0.206
30	0.226	0.221	0.216	0.211	0.207	0.202	0.198	0.194	0.191	0.187	0.183
35	0.204	0.199	0.194	0.190	0.186	0.182	0.178	0.174	0.171	0.167	0.164
40	0.184	0.180	0.176	0.172	0.168	0.164	0.161	0.157	0.154	0.151	0.148
45	0.168	0.164	0.160	0.156	0.152	0.149	0.145	0.142	0.139	0.136	0.133
50	0.153	0.149	0.145	0.142	0.138	0.135	0.132	0.129	0.126	0.123	0.121
55	0.140	0.136	0.133	0.129	0.126	0.123	0.120	0.117	0.115	0.112	0.110
60	0.128	0.125	0.121	0.118	0.115	0.112	0.109	0.107	0.104	0.102	0.100

Fonte: AGUINA (1989).

Considerando a concatenação das 5 tabelas, lado a lado, obtém-se uma tabela única de 12 linhas por 50 colunas, onde se tem os valores de fluxo normalizado para 12 instantes de tempo (5s, 10s, 15s, ... 60s) e 50 valores de reatividade percentual (0,01%, 0,02%, 0,03%. ... 0,50%). Desta tabela obtida, considerou-se as colunas ímpares (iniciando pela coluna 1, com reatividade igual a 0,01%) como padrões de treinamento e separou-se as colunas pares (iniciando pela coluna 2, com reatividade igual a 0,02% e terminando na coluna 48, com reatividade igual a 0,48%) como padrões de validação. Ou seja, colunas intermediárias de reatividade foram utilizadas inteiramente para validação.

Antes do treinamento da rede neural do tipo *Multilayer Perceptron* (MLP), foi aplicada a etapa de normalização dos dados de entrada e saída. Esse procedimento tem como objetivo reduzir discrepâncias de escala entre variáveis, evitando que atributos com valores absolutos mais elevados exerçam influência desproporcional durante o processo de ajuste dos pesos sinápticos. Além disso, a normalização contribui para a estabilidade numérica dos cálculos, acelera a convergência do algoritmo de treinamento e reduz a probabilidade de a rede ficar presa em mínimos locais durante o processo de otimização.

No presente trabalho, adotou-se a normalização do tipo min-max, na qual todos os valores do conjunto de dados são reescalados para o intervalo [0,1]. Esse procedimento assegura que a entrada da rede neural esteja compatível com as funções de

ativação utilizadas, especialmente aquelas que apresentam sensibilidade a intervalos de magnitude distintos. A fórmula matemática da transformação é apresentada na equação

$$x_{norm} = \frac{x - x_{mínimo}}{x_{máximo} - x_{mínimo}} \quad (46)$$

Em que x representa o valor original do dado, $x_{mínimo}$ é o menor valor observado da variável, $x_{máximo}$ é o maior valor observado da variável, x_{norm} é o valor resultante da normalização, reescalado no intervalo definido.

A escolha desse procedimento justifica-se pelo fato de que os dados experimentais analisados apresentam variação contínua e não contêm valores extremos que possam distorcer o reescalamento. Dessa forma, a normalização min-max mostrou-se adequada para manter as relações proporcionais entre as observações e, ao mesmo tempo, garantir compatibilidade com as funções de ativação sigmoideal e hiperbólica, amplamente empregadas em redes MLP.

A rede neural artificial, desenvolvida para a modelagem do comportamento dinâmico do fluxo de nêutrons, foi configurada com uma arquitetura de múltiplos perceptrons (MLP) de topologia sequencial.

A estrutura consistiu em uma camada de entrada, uma camada oculta e uma camada de saída. Essa configuração, em linha com as práticas usuais para problemas de regressão não linear, permitiu que a rede capturasse as complexas relações entre as variáveis de entrada e a variável de saída.

Os parâmetros internos da rede, detalhados na Tabela 8, são fundamentais para o processo de inferência. A camada oculta, composta por 32 neurônios e utilizando a função de ativação ReLU (*Rectified Linear Unit*), foi a responsável pela extração das características não lineares dos dados.

A matriz de pesos sinápticos da camada oculta, $W1$, com dimensões (2,32), e o vetor de viés, $b1$, com 32 elementos, foram otimizados durante a fase de treinamento para mapear a entrada bidimensional (reatividade e tempo) em um espaço de 32 dimensões.

Na camada de saída, um único neurônio com uma função de ativação linear foi utilizado para gerar a previsão final. Os pesos sinápticos, $W2$, de dimensão (32,1), e o viés, $b2$, um escalar, convertem a representação de 32 dimensões da camada oculta em uma única previsão de fluxo de nêutrons.

A Tabela 8 também ilustra as saídas (ativações) de cada camada para um conjunto de 288 amostras de validação. A saída da camada de entrada corresponde aos dados brutos. A saída da camada oculta, uma matriz (288,32), revela a representação interna dos dados após a aplicação dos pesos, viés e da função de ativação ReLU. Por fim, a saída da camada de saída, uma matriz (288,1), representa o conjunto de previsões geradas pela rede.

A análise desses dados é crucial para entender como a rede processa e transforma as informações, validando seu desempenho e sua capacidade de modelagem.

A tabela 8 apresenta os pesos sinápticos e os valores de saída (ativações) de cada camada da sua rede neural, com base nos dados de validação.

A rede possui uma arquitetura sequencial com uma camada de entrada (*InputLayer*), uma camada densa oculta com 32 neurônios e uma camada de saída com 1 neurônio.

Tabela 8 – Pesos e saídas da rede neural artificial

Camada	Tipo	Pesos (W)	Viés (b)	Saída (Ativações)
0	InputLayer	-	-	Matriz de entrada (288, 2)
1	Dense (Oculta)	W1: Matriz de (2, 32)	b1: Vetor de (32,)	Matriz de (288, 32)
2	Dense (Saída)	W2: Matriz de (32, 1)	b2: Vetor de (1,)	Matriz de (288, 1)

Fonte: Elaboração própria (2025).

Análise detalhada dos parâmetros da tabela 8:

- Camada de Entrada (*InputLayer*): Recebe os dados brutos. A matriz de entrada tem 288 linhas (amostras de dados de validação) e 2 colunas (atributos de entrada). Esta camada não possui pesos ou viés, pois atua apenas como um receptor dos dados.
- Camada Densa Oculta (*Dense*): Possui 32 neurônios e utiliza a função de ativação ReLU. O vetor de pesos sinápticos (W1) conecta cada uma das 2 entradas a cada um dos 32 neurônios, resultando em uma matriz (2, 32). O viés (b1) é um vetor de 32

elementos, um para cada neurônio. A saída desta camada é uma matriz (288, 32), representando as ativações dos 32 neurônios para cada uma das 288 amostras.

- Camada de Saída (*Dense*): Possui 1 neurônio. O vetor de pesos sinápticos (W_2) conecta a saída dos 32 neurônios da camada oculta a este único neurônio, formando uma matriz (32, 1). O viés (b_2) é um único valor. A saída final da rede é uma matriz (288, 1), que corresponde às 288 previsões de fluxo para os dados de entrada.

A eficácia do treinamento da rede neural foi assegurada pela escolha criteriosa de um algoritmo de otimização e de uma função de custo, elementos cruciais para a minimização do erro e a convergência do modelo. Para este trabalho, foi utilizado o algoritmo Adam (*Adaptive Moment Estimation*) como otimizador e a Erro Quadrático Médio (MSE) como a função de custo (ou *loss function*).

O otimizador Adam é uma extensão do algoritmo clássico do gradiente descendente estocástico. Sua principal vantagem reside na sua capacidade de adaptar individualmente a taxa de aprendizado para cada parâmetro da rede (pesos sinápticos e vieses). Ele faz isso combinando as melhores características dos algoritmos RMSProp e AdaGrad, calculando médias móveis exponenciais do gradiente e do gradiente quadrado. Essa adaptação permite que o Adam navegue de forma mais eficiente pelo espaço complexo de otimização, convergindo mais rapidamente para os mínimos locais ou globais. A sua robustez e eficiência o tornaram a escolha padrão para uma vasta gama de problemas de otimização em aprendizado de máquina, incluindo a modelagem de séries temporais não lineares como a do fluxo de nêutrons.

A função de erro escolhida, o Erro Quadrático Médio (MSE), quantifica a diferença entre as previsões da rede e os valores reais. É definida como a média dos quadrados das diferenças entre os valores previstos (y_{pred}) e os valores reais (y_{real}), conforme a equação:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{real(i)} - y_{pred(i)})^2 \quad (47)$$

O MSE penaliza mais severamente erros grandes, incentivando a rede a corrigir desvios significativos com maior prioridade durante o treinamento. A escolha do MSE foi particularmente adequada, pois o objetivo do modelo é prever valores numéricos contínuos (o fluxo de nêutrons), tornando-o uma medida direta e interpretável do desempenho de regressão. O treinamento da rede foi, portanto, um processo iterativo de

ajuste dos pesos e vieses para minimizar o valor de MSE, culminando nos parâmetros finais que resultaram nas previsões mais precisas.

A combinação do otimizador Adam com a função de custo MSE mostrou-se uma estratégia eficaz, permitindo que a rede neural alcançasse um alto grau de acurácia na previsão do fluxo, conforme evidenciado pelos resultados de desempenho obtidos.

Para garantir que o modelo de rede neural obtido ao final do treinamento apresentasse a melhor capacidade de generalização para dados não vistos, foi implementada uma estratégia de salvamento condicional dos pesos da rede. Esta técnica visa combater o fenômeno de *overfitting*, onde o modelo se ajusta excessivamente aos dados de treinamento, perdendo sua capacidade de performar bem em novos dados de validação ou teste.

A abordagem consistiu em monitorar o desempenho da rede no conjunto de validação ao final de cada época de treinamento. Utilizou-se como métrica de monitoramento a função de custo, o Erro Quadrático Médio (MSE), calculada especificamente sobre este conjunto. O modelo foi configurado para salvar seus pesos sinápticos e vieses em um arquivo apenas quando o valor do MSE no conjunto de validação atingisse um novo mínimo histórico.

Essa prática é crucial porque o melhor desempenho no conjunto de treinamento (representado pela diminuição contínua da perda de treinamento) nem sempre corresponde ao melhor desempenho no mundo real. Ao focar no conjunto de validação, uma métrica de desempenho independente e imparcial, o processo de treinamento se concentra em encontrar o ponto em que o modelo atinge o equilíbrio ideal entre ajuste e generalização.

Dessa forma, o arquivo de *checkpoint* contém os parâmetros do modelo que foram obtidos na época em que o erro de validação foi o menor. Isso assegura que o modelo final carregado para as previsões é a versão mais otimizada para a aplicação, minimizando o risco de *overfitting* e fornecendo resultados mais confiáveis para a previsão do fluxo de nêutrons.

O programa desenvolvido, portanto, configura e treina uma rede neural densa para um problema de regressão, utilizando normalização de dados e um *callback* para salvar o melhor modelo com base na perda de validação.

7 RESULTADOS E DISCUSSÕES

Pelas tabelas 3, 4, 5, 6 e 7, constata-se que o fluxo térmico normalizado, diretamente proporcional ao fluxo de nêutrons, não é um uniforme em todo o núcleo do reator. Ele atinge um máximo no centro do núcleo e diminui à medida que se aproxima das bordas, devido a fuga de nêutrons para fora do volume físsil e à absorção dos materiais estruturais e pelo moderador/refrigerante. O perfil do fluxo de nêutrons na geração de potência tem uma curva no gráfico em função da geometria do núcleo e da difusão dos nêutrons, o que no reator de pesquisa Argonauta a curva gráfica tem o perfil de uma função de Bessel no sentido radial, pois a maior parte da potência é gerada no núcleo. No gráfico mostrado na Figura 8, é ilustrada a distribuição do fluxo de nêutrons no sentido radial do reator como uma função de Bessel.

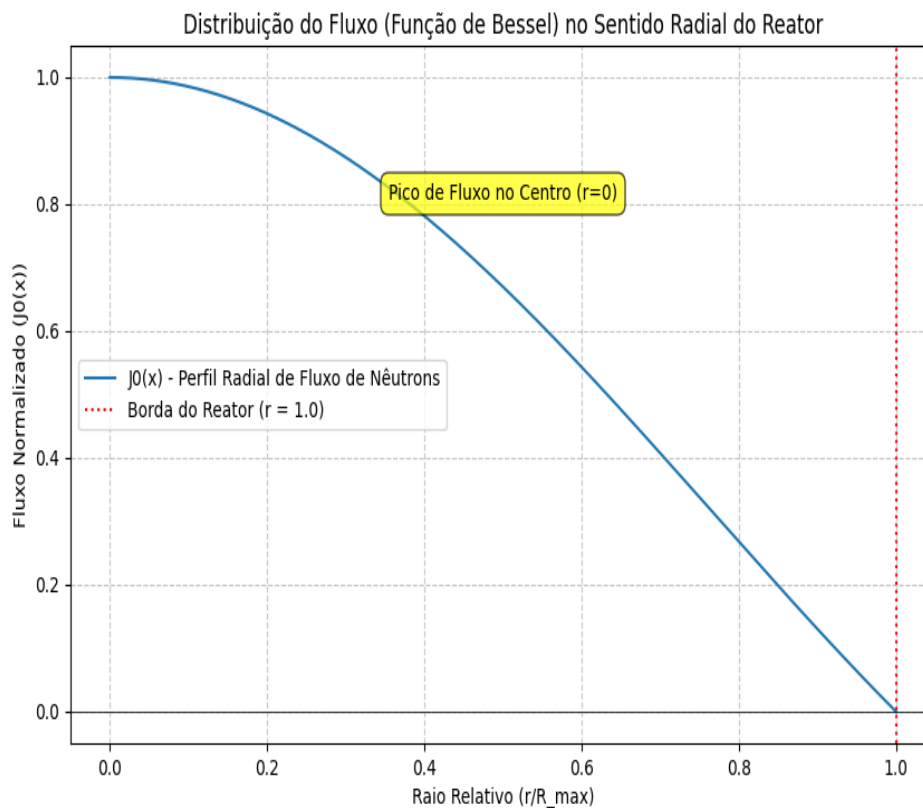


Figura 8 – Distribuição do fluxo de nêutrons no sentido radial de reatores de pesquisa cilíndricos

Fonte: Elaboração própria (2024).

O fluxo térmico normalizado, proporcional ao fluxo de nêutrons, refere-se à taxa de transferência de calor por unidade de área da superfície do combustível nuclear para o refrigerante. No reator de pesquisa Argonauta, que opera em baixa potência, o calor gerado pela fissão nuclear é transferido predominantemente por convecção da superfície do elemento combustível para o refrigerante em movimento. Esse mecanismo de remoção de energia é suficiente para manter a estabilidade térmica, uma vez que as densidades de potência nesse tipo de reator são relativamente baixas quando comparadas às de reatores de potência comercial.

Na distribuição do fluxo de nêutrons no sentido radial do reator, mostrada na Figura 8, a função de Bessel de primeira espécie e ordem zero desempenha papel fundamental na representação matemática do perfil de fluxo. Essa função alcança seu valor máximo no centro do núcleo, em $R = 0$, refletindo a maior densidade de nêutrons e, conseqüentemente, a maior taxa de geração de calor nessa região. À medida que o valor do raio aumenta, a função de Bessel diminui gradualmente, resultado da fuga de nêutrons para as bordas do reator e da absorção adicional de nêutrons pelas barras de controle de reatividade.

Essa variação espacial do fluxo térmico é um aspecto essencial para o dimensionamento seguro do núcleo, pois permite prever as regiões de maior densidade de potência e, portanto, de maior exigência em termos de remoção de calor. Além disso, o comportamento descrito pela função de Bessel é utilizado em cálculos de criticidade e em análises de estabilidade, fornecendo subsídios tanto para o projeto quanto para a operação experimental do Argonauta.

Com isso, torna-se possível compreender como a geometria do núcleo, o arranjo dos elementos combustíveis e a posição das barras de controle influenciam diretamente o perfil de fluxo de nêutrons e a distribuição de calor dentro do reator.

A curva da função de Bessel de primeira espécie e ordem zero representa matematicamente o comportamento do fluxo de nêutrons no núcleo de um reator de pesquisa. No centro do núcleo, a função atinge seu valor máximo, correspondendo à maior densidade de nêutrons e, conseqüentemente, à maior taxa de geração de calor. À medida que a distância radial aumenta, a curva decresce devido à fuga de nêutrons para as extremidades e às interações com materiais presentes no núcleo.

Nesse cenário, as barras de controle de reatividade exercem influência direta sobre a forma da curva, uma vez que sua inserção aumenta a absorção de nêutrons em determinadas regiões. Quanto maior a profundidade de inserção das barras, mais acentuada é a queda da curva de Bessel nas proximidades de sua posição, reduzindo a densidade local de fluxo. Assim, a análise conjunta da função de Bessel e da ação das barras fornece uma base matemática e física para entender o equilíbrio da criticidade do reator.

Na figura 9, é mostrada a resposta da RNA MLP quanto ao fluxo normalizado predito em função do instante de tempo.

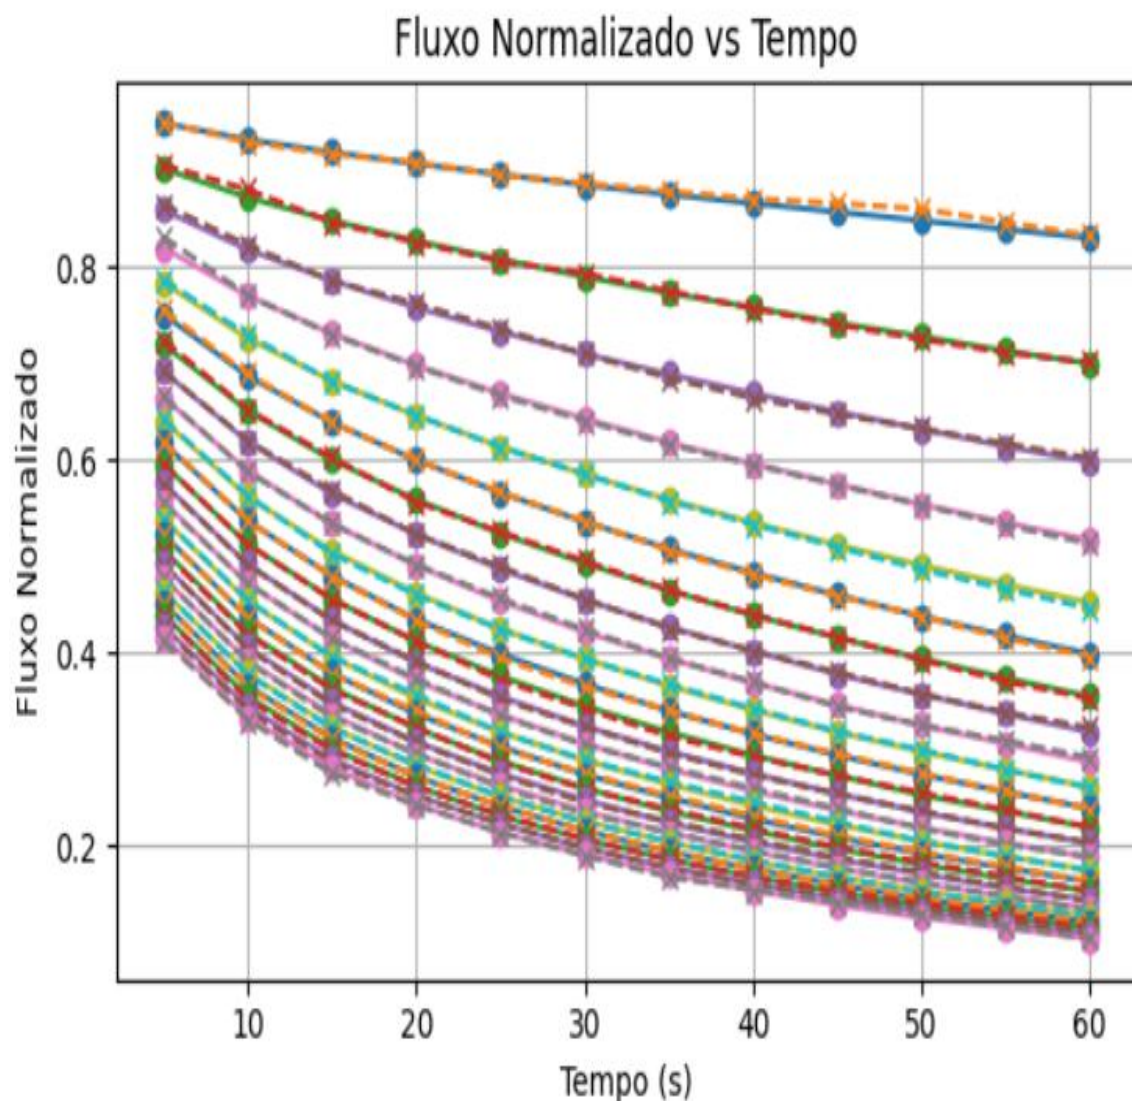


Figura 9 – Curvas de reatividade negativa no núcleo do reator Argonauta na calibração das barras de controle pelo método de queda.

Fonte: Elaboração própria (2024).

O gráfico exibe a evolução temporal do fluxo normalizado, demonstrando padrões de decaimento distintos para cada curva, o que sugere a capacidade de uma RNA MLP em aprender essas trajetórias complexas. A correlação visual entre os dados pontuais e as linhas de ajuste indica que os modelos treinados conseguiram capturar a dinâmica de decaimento com boa precisão. A diversidade de curvas representa diferentes cenários operacionais ou configurações experimentais, cada um com sua assinatura de decaimento única. Uma MLP treinada poderia prever o fluxo futuro com base em estados iniciais e padrões aprendidos. A análise sugere que a rede seria capaz de modelar a relação entre tempo e fluxo em múltiplos cenários.

Na figura 10, é mostrada a análise da perda do modelo (*model loss*) gerada na aplicação da RNA MLP na previsão do fluxo térmico normalizado.




Figura 10 – Análise da perda do modelo da RNA MLP

Fonte: Elaboração própria (2024).

No gráfico da figura 16, é ilustrada a evolução da perda (erro) do modelo durante o processo de treinamento e validação. Observa-se uma rápida queda na perda, tanto para o conjunto de treinamento (*train*) quanto para o de validação (*valid*), nas épocas iniciais.

Essa diminuição acentuada demonstra a capacidade inicial do modelo em ajustar seus parâmetros aos dados apresentados.

Subsequentemente, as curvas de perda exibem uma notável estabilização em valores muito baixos. Essa fase indica que o modelo atingiu um ponto onde as melhorias na minimização do erro se tornaram marginais. A convergência e a proximidade entre as curvas de treinamento e validação são fortes indicadores de que a rede neural aprendeu efetivamente os padrões presentes nos dados. Mais importante ainda, essa similaridade sugere que o modelo não apresentou overfitting significativo, o que é crucial para a sua aplicabilidade em novos dados. Assim, o resultado aponta para uma boa generalização do modelo, validando sua eficácia para tarefas futuras.

No gráfico apresentado na Figura 11, a precisão do modelo, para o conjunto de validação, é ilustrada através do coeficiente de determinação (R^2). É notável a boa sobreposição dos pontos de dados em relação à linha de 45 graus, que simboliza a igualdade entre as previsões do modelo e os valores reais.

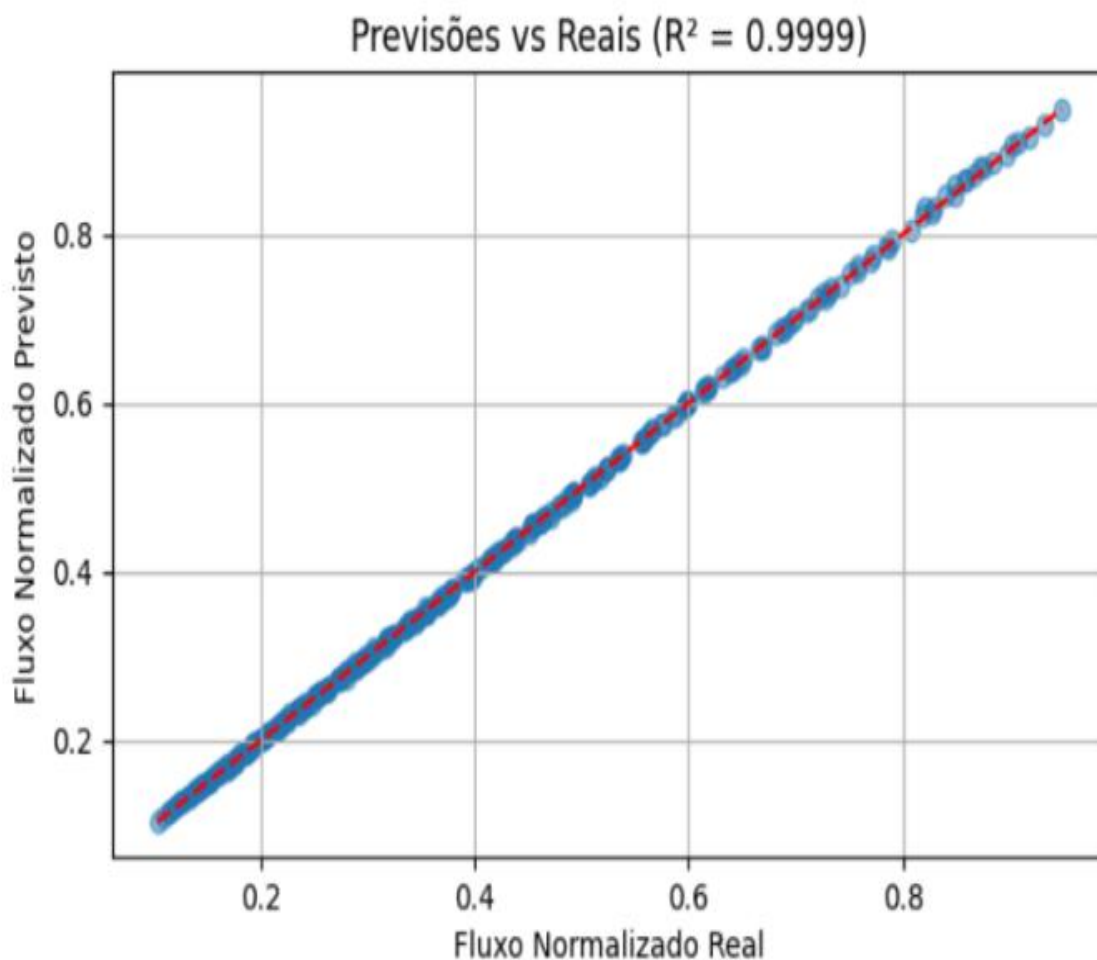


Figura 11 – Coeficiente de determinação(R^2) de valores reais e previstos

Fonte: Elaboração própria (2024).

Os resultados obtidos não apenas validam a precisão do modelo, mas também corroboram sua robustez e confiabilidade em cenários práticos. A alta acurácia sugere que a rede neural é uma ferramenta poderosa para análise e previsão em sistemas onde o fluxo térmico é um parâmetro crítico. A consistência observada reforça a qualidade do treinamento e a adequação da arquitetura empregada. Este desempenho é um indicativo claro de que o modelo está pronto para ser aplicado em aplicações que exigem previsões precisas e detalhadas.

No gráfico da Figura 12, é apresentada uma análise detalhada do Erro Quadrático Médio (MSE) em sua relação direta com a reatividade negativa do reator, para o conjunto de validação. Observa-se uma clara concentração dos maiores valores de erro nas faixas de reatividade negativa que se aproximam do ponto de zero. Esses erros tendem a

diminuir progressivamente à medida que a reatividade se torna mais negativa, indicando uma tendência de maior precisão em cenários de subcriticalidade mais acentuada.

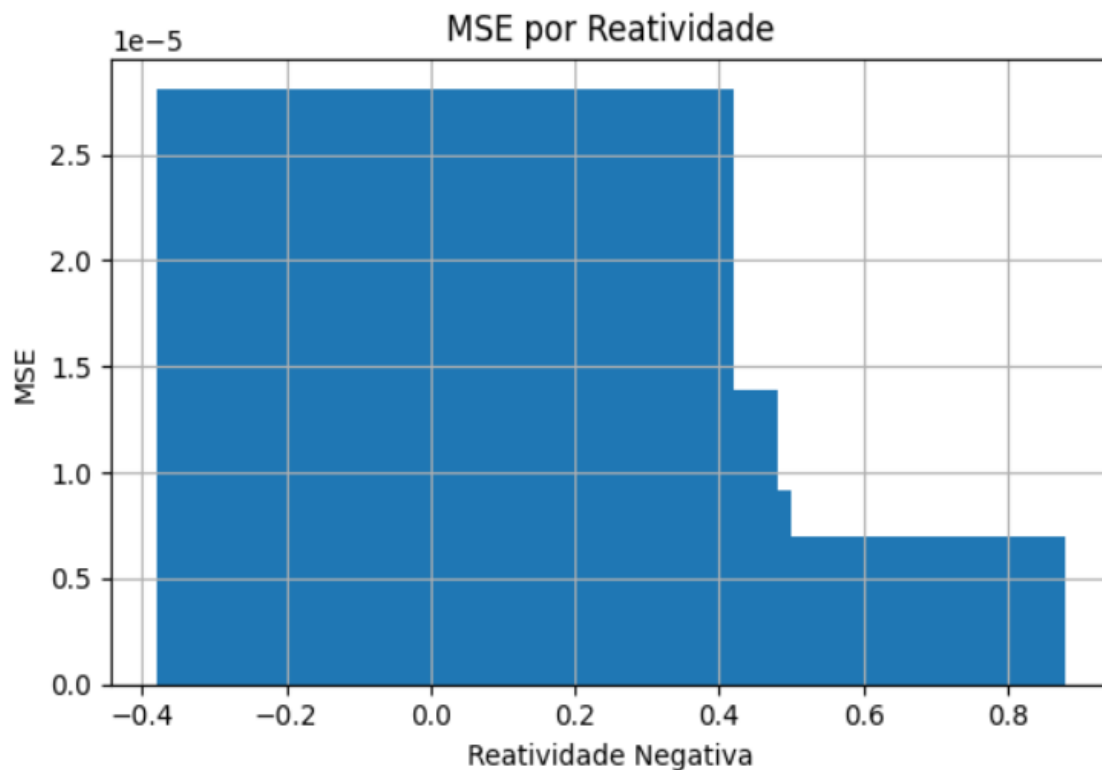


Figura 12 – Erro quadrático médio por reatividade negativa

Fonte: Elaboração própria (2024).

Este comportamento pode sugerir que o modelo empregado exibe um desempenho ligeiramente menos robusto em condições operacionais que se encontram próximas à criticalidade. Alternativamente, essa concentração de erros pode refletir uma maior variabilidade inerente aos dados coletados nessas regiões específicas de reatividade.

É importante notar, contudo, que os valores absolutos de MSE apresentados no gráfico são notadamente baixos. Mesmo nas condições onde os erros são mais elevados, próximos à criticalidade, a precisão geral do modelo permanece em um patamar elevado e confiável. Isso corrobora a eficácia do modelo em capturar as dinâmicas do reator, mesmo em situações operacionais mais sensíveis.

A análise do MSE em função da reatividade negativa oferece *insights* valiosos sobre os limites e a robustez do modelo. Permite identificar áreas onde o desempenho pode ser otimizado, garantindo maior segurança e eficiência. A diminuição do erro com

o aumento da reatividade negativa reforça a capacidade preditiva do modelo em diferentes estados do reator.

As regiões de maior erro, embora presentes, não comprometem significativamente a acurácia geral. O modelo demonstra, portanto, uma boa capacidade de generalização diante de variações na reatividade. O MSE baixo em todas as faixas de reatividade é um indicativo da boa qualidade da previsão do modelo. Em suma, a Figura 18 ilustra um modelo com boa precisão, embora com uma ligeira queda de desempenho em proximidade à criticalidade, mas mantendo alta acurácia geral.

A capacidade da RNA MLP de prever com alta precisão esses perfis temporais de fluxo normalizado, como evidenciado pelo R^2 de 0.9999, demonstra que a RNA MLP aprendeu a complexa relação dinâmica entre as variáveis de entrada reatividade negativa, tempo e a resposta do reator em fluxo térmico normalizado. Isso é um avanço significativo, pois permite simular e prever o comportamento do reator Argonauta em tempo real ou para cenários hipotéticos, complementando os modelos físicos existentes.

8 CONCLUSÕES

O presente trabalho teve como objetivo avaliar a aplicabilidade de redes neurais artificiais do tipo *Multilayer Perceptron* (MLP) na predição do fluxo térmico normalizado e na calibração de barras de controle pelo método de queda no reator de pesquisa Argonauta. Os resultados obtidos demonstraram que a arquitetura MLP apresentou desempenho satisfatório, tanto em termos de precisão preditiva quanto de eficiência computacional, mostrando-se uma alternativa robusta às metodologias convencionais utilizadas em análises desse tipo. A implementação da MLP permitiu reproduzir com elevada confiabilidade o comportamento experimental do fluxo térmico, evidenciando a capacidade do modelo em identificar padrões complexos entre as variáveis envolvidas no processo. Esses resultados corroboram estudos recentes, como os de Hosseinllu et al. (2025), que reforçam o potencial das técnicas de aprendizado de máquina no aprimoramento da segurança e da eficiência operacional de reatores nucleares de pesquisa.

Conclui-se, portanto, que o uso de redes neurais artificiais representa uma ferramenta promissora para o apoio à calibração de mecanismos de controle e para o desenvolvimento de estratégias de monitoramento e operação segura em sistemas nucleares. A versatilidade da arquitetura MLP, aliada a diferentes algoritmos de otimização e funções de ativação não lineares, amplia suas possibilidades de aplicação em outras áreas da engenharia nuclear e de ciências aplicadas.

Como continuidade deste trabalho, recomenda-se a investigação de modelos híbridos que integrem técnicas de otimização por enxame de partículas (PSO) e aprendizado profundo (*Deep Learning*), a fim de potencializar a capacidade preditiva e reduzir o erro associado à modelagem de parâmetros nucleares em condições experimentais complexas.

8.1 SUGESTÕES PARA TRABALHOS FUTUROS

A presente pesquisa abre espaço para o desenvolvimento de estudos complementares voltados à integração entre sistemas inteligentes e aplicações na área nuclear. Uma das possibilidades de continuidade consiste na implementação de sistemas de aprendizado supervisionado e adaptativo, com capacidade de auxiliar pesquisadores em experimentos de física nuclear. Tais sistemas poderiam atuar tanto na coleta e análise de dados experimentais quanto na identificação de amostras de materiais radioativos, oferecendo suporte às atividades de caracterização e controle em laboratório.

Aplicações de redes neurais, como a aqui proposta, poderia contribuir significativamente para o aprimoramento do controle preditivo utilizado em servomecanismos empregados em processos nucleares, fornecendo maior precisão e confiabilidade nas respostas de controle. A utilização desses modelos permitiria que operações em plantas nucleares fossem conduzidas de maneira mais eficiente, guiadas por algoritmos de automação capazes de lidar com cenários de alta complexidade e sensibilidade.

Portanto, como sugestão de trabalhos futuros, propõe-se a exploração de sistemas inteligentes híbridos, que integrem aprendizado supervisionado, adaptativo e mecanismos

de automação avançada, voltados à área nuclear. Essa linha de pesquisa não apenas contribuiria para o aprimoramento do controle de reatores e servomecanismos, como também representaria um avanço significativo na construção de estratégias mais seguras e eficazes para a operação de plantas nucleares.

9 REFERÊNCIAS BIBLIOGRÁFICAS

ABHIRAMI, V. S. Softmax vs LogSoftmax. Medium, 2023. Disponível em: <https://medium.com/@AbhiramiVS/softmax-vs-logsoftmax-eb94254445a2>. Acesso em: 1 jul. 2025.

AGUINA, L. O. B. Relatório de Análise de Segurança do Reator Argonauta. Vol I, II e III, 1989.

ALAM, T. M. *et al.* A novel method for performance measurement of public educational institutions using machine learning models. **Applied Sciences**, v. 11, n. 19, 9296, 2021.

AYODEJI, A. *et al.* Deep learning for safety assessment of nuclear power reactors: reliability, explainability, and research opportunities. **Progress in Nuclear Energy**, v. 151, 104339, 2022. Disponível em: <https://doi.org/10.1016/j.pnucene.2022.104339>. Acesso em: 8 dez. 2024.

BISONG, E. The multilayer perceptron (MLP). Building Machine Learning and Deep Learning Models on Google Cloud Platform: A Comprehensive Guide for Beginners, **Apress, Berkeley, CA**, p. 401–405, 2019. Disponível em: https://doi.org/10.1007/978-1-4842-4470-8_31. Acesso em: 3 dez. 2024.

CHO, E. *et al.* A neural network model for free-falling condensation heat transfer in the presence of non-condensable gases. **International Journal of Thermal Sciences**, v. 171, 107202, 2022. Disponível em: <https://doi.org/10.1016/j.ijthermalsci.2021.107202>. Acesso em: 7 nov. 2024.

COMISSÃO NACIONAL DE ENERGIA NUCLEAR. NE 1.20: **Aceitação de sistemas de resfriamento de emergência de reatores a água leve**. Rio de Janeiro: CNEN, 1985.

COMISSÃO NACIONAL DE ENERGIA NUCLEAR. NE 1.26: **Segurança na operação de usinas nucleoeletricas**. Rio de Janeiro: CNEN, 1997.

COMISSÃO NACIONAL DE ENERGIA NUCLEAR. NN 3.01: **Diretrizes básicas de proteção radiológica**. Rio de Janeiro: CNEN, 2014.

CURTISS, L. F. **Introduction to neutron physics**. Princeton, N. J.: Van Nostrand, 1959.

DANIEL, J.H. Medição da Altura do Nível de Água no Reator Nuclear Argonauta Utilizando o Sensor Ultrassônico do Dispositivo Eletrônico Arduíno / João Henrique Daniel. -- Rio de Janeiro: CNEN/IEN,2020.

DE AGUIAR, A. E. et al. Análise do coeficiente de temperatura do moderador do Reator Argonauta. **Brazilian Journal of Development**, v. 9, n. 4, p. 14074–14084, 2023.

DUDERSTADT, J. J.; HAMILTON, L. J. **Nuclear reactor analysis**. New York: John Wiley & Sons, 1976.

FACURE, M. Activation Functions: Por que precisamos de funções não lineares?, 2017. Disponível em: <https://matheusfacure.github.io/2017/07/12/activ-func/>. Acesso em: 11 jul. 2025.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. D. M. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, Medianeira, PR: Universidade Tecnológica Federal do Paraná, v. 1, n. 13, p. 47–57. ISSN: 2175-1846, 2016.

GÉRON, Aurélien. Mãos à obra: aprendizado de máquina com Scikit-Learn, Keras & TensorFlow: conceitos, ferramentas e técnicas para a construção de sistemas inteligentes. 2. ed. rev. e atual. Tradução de Cibelle Ravaglia. São Paulo: **Alta Books**, 2021. ISBN 978-85-5081-548-0.

HOSSEINLLU, M. et al. An intelligent control rod movement strategy for boron-free reactor core using multi-layer perceptron machine learning model. **Annals of Nuclear Energy**, v. 218, p. 111405, 1 ago. 2025.

IAEA, Project on Enhanced Utilization and Applications of Research Reactors. Disponível em: http://www-naweb.iaea.org/napc/physics/research_reactors/. Acesso em: 5 de nov. 2024.

ICMC-USP. Esquema de Redes Neurais Artificiais. s.d. Disponível em: <<https://sites.icmc.usp.br/andre/research/neural/>>. Acesso em: 10 jan. 2025.

IEN – INSTITUTO DE ENGENHARIA NUCLEAR – Reator Argonauta. Disponível em: < <http://www.ien.gov.br> >. Acesso em: 26 de outubro de 2023.

IEN – INSTITUTO DE ENGENHARIA NUCLEAR – Relatório Técnico. Manual de Operação do Reator Argonauta. Rio de Janeiro: **IEN/CNEN**, 1990.

IEN – INSTITUTO DE ENGENHARIA NUCLEAR – Relatório Técnico. Manutenção do Reator Argonauta. Rio de Janeiro: **IEN/CNEN**, 1991.

KNIEF, R. A. Nuclear Engineering: Theory and Technology of Commercial Nuclear Power. 2nd ed. La Grange Park: **American Nuclear Society**, 2008.

KOTSIPOULOS, T., SARIGIANNIDIS, P., IOANNIDIS, D., TZOVARAS, D., Machine learning and deep learning in smart manufacturing: The smart grid paradigm, **Computer Science Review**, v. 40, 100341, 2021. Disponível em: <https://doi.org/10.1016/j.cosrev.2020.100341>. Acesso em: 6 jun. 2024.

LAMARSH, J. R.; BARATTA, A. J.. Introduction to Nuclear Engineering. 3. ed. Upper Saddle River: Prentice Hall, 2001.

MAZROU, H.; LABABSA, D.; MOKHTARI, O. Assessment of the safety impact caused by the variations of the critical position of control rods and by the presence of an in-core flux trap on the power peaking factors in an MTR-type research reactor. **Nuclear Engineering and Design**, v. 414, p. 112553, 2023. Acesso em: 1 dez. 2024.

NING, K. et al. Modelling research on the control scheme and control characteristic of a small gas-cooled reactor. **Progress in Nuclear Energy**, v. 147, p. 104189, 1 maio 2022.

PINEM, S. et al. Control rods' position history effect on the Indonesian multipurpose research reactor RSG-GAS operation and safety parameters. **Progress in Nuclear Energy**, v. 156, p. 104552, 1 fev. 2023.

PYTHON SOFTWARE FOUNDATION. **Python Language Reference**, version 3.12. Wilmington, DE: Python Software Foundation, 2023. Disponível em: <https://python.org>. Acesso em: 11 out. 2024.

SOARES, A. A. V. Aplicação da cinética pontual inversa para o cálculo da reatividade no reator Argonauta / André Augusto Vidal Soares. Rio de Janeiro: **UFRJ/ ESCOLA POLITÉCNICA**, 2019.

STACEY, W. M. **Nuclear reactor physics**. 2 ed. Weinheim: Wiley-VCH, 2007.

STEFANI, G. L. et al. Study of neutron flux redistribution and shadowing effect in rod worth measurements with the rod drop experiment. **Nuclear Engineering and Design**, v. 415, p. 112672, 15 dez. 2023.

SUESCÚN-DÍAZ, D.; ESPINOSA-PAREDES, G. On the numerical solution of the point reactor kinetics equations. **Nuclear Engineering and Technology**, v. 52, p. 1340-1346, 2020.

TALOBA, A. I. *et al.* A blockchain-based hybrid platform for multimedia data processing in IoT-Healthcare. **Alexandria Engineering Journal**, v. 65, p. 263-274, 2023.

TERREMOTO, Luís A. A. Fundamentos de Tecnologia Nuclear de Reatores, **IPEN**, 2004.

WNA, World Nuclear Association, Disponível em: <https://www.world-nuclear.org/information-library/non-power-nuclear-applications/radioisotopes-research/research-reactors.aspx>. Acesso em: 5 de nov. 2024.

WU, Z., PAN, S., CHEN, F., LONG, G., ZHANG, C., YU, P.S., A comprehensive survey on graph neural networks, **IEEE Transactions in Neural Networks Learn Systems**, vol. 32, p. 4–24, 2021. Disponível em: <https://doi.org/10.1109/TNNLS.2020.2978386>. Acesso em: 3 abr. 2024.

YANG, Q. et al. Predicting neutron flux density distribution in HTR-10 using U-Net based on DEM-MC coupled simulations. **Nuclear Engineering and Technology**, v. 57, n. 6, p. 103425, 2025. Disponível em: <https://doi.org/10.1016/J.NET.2024.103425>. Acesso em: 15 jan. 2025.

ZHI HUI, T. et al. A control rod worth prediction using Adaptive Neuro-Fuzzy Inference System for Pre-Calibration Method at TRIGA PUSPATI Reactor. **Annals of Nuclear Energy**, v. 200, p. 110410, 1 jun. 2024.

ZHOU, L., GARG, D., QIU, Y., KIM, S.-M., MUDAWAR, I., KHARANGATE, C.R. Machine learning algorithms to predict flow condensation heat transfer coefficient in mini/ micro-channel utilizing universal data. *International Journal of Heat and Mass Transfer*, v. 162, 120351, 2020. Disponível em: <https://doi.org/10.1016/j.ijheatmasstransfer.2020.120351>. Acesso em: 5 mai. 2024.