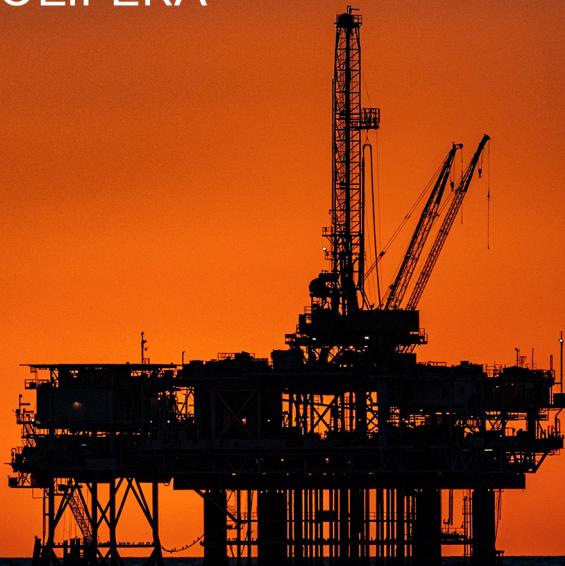




César Marques Salgado  
William Luna Salgado  
Roos Sophia de Freitas Dam  
Claudio de Carvalho Conti

# APLICAÇÃO DE **TÉCNICA NUCLEAR** E REDE NEURAL ARTIFICIAL NA INDÚSTRIA PETROLÍFERA

*Estudos de casos*

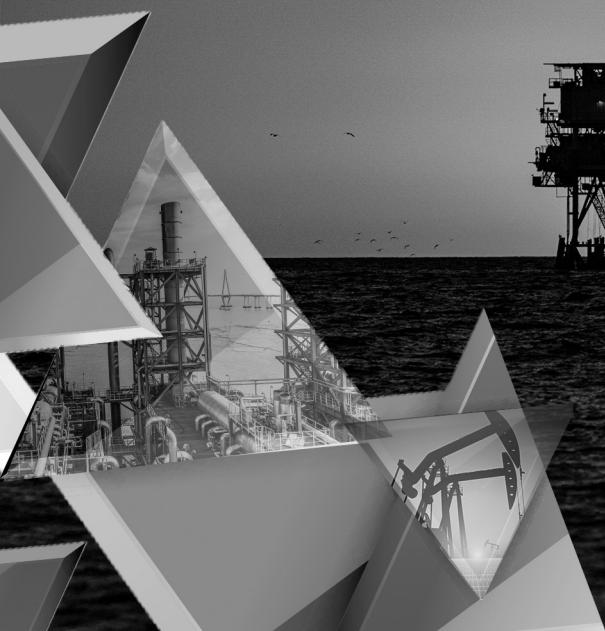




César Marques Salgado  
William Luna Salgado  
Roos Sophia de Freitas Dam  
Claudio de Carvalho Conti

# APLICAÇÃO DE **TÉCNICA NUCLEAR** E REDE NEURAL ARTIFICIAL NA INDÚSTRIA PETROLÍFERA

*Estudos de casos*



**Editora chefe**

Prof<sup>a</sup> Dr<sup>a</sup> Antonella Carvalho de Oliveira

**Editora executiva**

Natalia Oliveira Scheffer

**Assistente editorial**

Flávia Barão

**Bibliotecária**

Janaina Ramos

**Projeto gráfico**

Nataly Evilin Gayde

Thamires Camili Gayde

Vilmar Linhares de Lara Junior

**Imagens da capa**

iStock

**Edição de arte**

Yago Raphael Massuqueto Rocha

2025 by Atena Editora

Copyright © 2025 Atena Editora

Copyright do texto © 2025, o autor

Copyright da edição © 2025, Atena

Editora

Os direitos desta edição foram cedidos

à Atena Editora pelo autor.

*Open access publication by Atena*

Editora



Todo o conteúdo deste livro está licenciado sob a Licença Creative Commons Atribuição 4.0 Internacional (CC BY 4.0).

A Atena Editora mantém um compromisso firme com a integridade editorial em todas as etapas do processo de publicação, assegurando que os padrões éticos e acadêmicos sejam rigorosamente cumpridos. Adota políticas para prevenir e combater práticas como plágio, manipulação ou falsificação de dados e resultados, bem como quaisquer interferências indevidas de interesses financeiros ou institucionais. Qualquer suspeita de má conduta científica é tratada com máxima seriedade e será investigada de acordo com os mais elevados padrões de rigor acadêmico, transparência e ética.

O conteúdo da obra e seus dados, em sua forma, correção e confiabilidade, são de responsabilidade exclusiva do autor, não representando necessariamente a posição oficial da Atena Editora. O download, compartilhamento, adaptação e reutilização desta obra são permitidos para quaisquer fins, desde que seja atribuída a devida autoria e referência à editora, conforme os termos da Licença Creative Commons Atribuição 4.0 Internacional (CC BY 4.0).

Os trabalhos nacionais foram submetidos à avaliação cega por pares realizada pelos membros do Conselho Editorial da editora, enquanto os internacionais foram avaliados por pareceristas externos. Todos foram aprovados para publicação com base em critérios de neutralidade e imparcialidade acadêmica.

**Aplicação de técnica nuclear e rede neural artificial na indústria petrolífera: estudos de casos**

**Revisão:** Os autores  
**Diagramação:** Thamires Camili Gayde  
**Capa:** Yago Raphael Massuqueto Rocha  
**Indexação:** Amanda Kelly da Costa Veiga

**Dados Internacionais de Catalogação na Publicação (CIP)**

A642 Aplicação de técnica nuclear e rede neural artificial na indústria petrolífera: estudos de casos / César Marques Salgado, William Luna Salgado, Roos Sophia de Freitas Dam, et al. – Ponta Grossa - PR: Atena, 2025.

Outro autor  
Claudio de Carvalho Conti

Formato: PDF  
Requisitos de sistema: Adobe Acrobat Reader  
Modo de acesso: World Wide Web  
Inclui bibliografia  
ISBN 978-65-258-3442-9  
DOI <https://doi.org/10.22533/at.ed.429251806>

1. Indústria de petróleo. I. Salgado, César Marques. II. Salgado, William Luna. III. Dam, Roos Sophia de Freitas. III. Título.

CDD 331.7616

Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166

## **DECLARAÇÃO DO AUTOR**

Para fins desta declaração, o termo 'autor' é utilizado de forma neutra, sem distinção de gênero ou número, salvo indicação em contrário. Da mesma forma, o termo 'obra' refere-se a qualquer versão ou formato da criação literária, incluindo, mas não se limitando a artigos, e-books, conteúdos on-line, acesso aberto, impressos e comercializados, independentemente do número de títulos ou volumes. O autor desta obra declara, para todos os fins, que: 1. Não possui qualquer interesse comercial que constitua conflito de interesses em relação à publicação; 2. Participou ativamente da elaboração da obra; 3. O conteúdo está isento de dados e/ou resultados fraudulentos, todas as fontes de financiamento foram devidamente informadas e dados e interpretações de outras pesquisas foram corretamente citados e referenciados; 4. Autoriza integralmente a edição e publicação, abrangendo os registros legais, produção visual e gráfica, bem como o lançamento e a divulgação, conforme os critérios da Atena Editora; 5. Declara ciência de que a obra será publicada sob a Licença Creative Commons Atribuição 4.0 Internacional (CC BY 4.0), a qual permite o compartilhamento, armazenamento, reprodução, adaptação e disponibilização em repositórios digitais e outras plataformas, desde que sejam devidamente atribuídos a autoria e os créditos à editora; 6. Assume total responsabilidade pelo conteúdo da obra, incluindo originalidade, veracidade das informações, opiniões expressas e eventuais implicações legais decorrentes da publicação.

## **DECLARAÇÃO DA EDITORA**

A Atena Editora declara, para os devidos fins de direito, que: 1. A presente publicação está licenciada sob a Licença Creative Commons Atribuição 4.0 Internacional (CC BY 4.0), que permite copiar, distribuir, exibir, executar, adaptar e criar obras derivadas para quaisquer fins, inclusive comerciais, desde que sejam atribuídos os devidos créditos ao(s) autor(es) e à editora. Trata-se de uma forma alternativa de licenciamento autorizada pela Lei de Direitos Autorais (Lei nº 9.610/98), adotada com base nos princípios do acesso aberto, promovendo a livre circulação e reutilização do conteúdo acadêmico. 2. Os autores mantêm integralmente seus direitos autorais e são incentivados a divulgar esta obra em repositórios institucionais, plataformas digitais e outros meios, desde que haja a devida atribuição de autoria e menção à editora, conforme os termos da Licença Creative Commons Atribuição 4.0 Internacional (CC BY 4.0). 3. A editora reserva-se o direito de disponibilizar a publicação em seu site, aplicativo e demais plataformas, bem como de comercializar exemplares impressos ou digitais, quando aplicável. Nos casos de comercialização, seja por livrarias, distribuidores ou plataformas parceiras, o repasse dos direitos autorais será efetuado conforme as condições previstas em contrato específico firmado entre as partes. 4. Em conformidade com a Lei Geral de Proteção de Dados, a editora não cede, comercializa ou autoriza o uso de dados pessoais dos autores para finalidades que não tenham relação direta com a divulgação desta obra e seu processo editorial.

**Conselho Editorial**

**Ciências Exatas e da Terra e Engenharias**

- Prof<sup>a</sup> Dr<sup>a</sup> Alana Maria Cerqueira de Oliveira – Instituto Federal do Acre  
Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás  
Prof<sup>a</sup> Dr<sup>a</sup> Cristina Aledi Felsemburgh – Universidade Federal do Oeste do Pará  
Prof. Dr. Diogo Peixoto Cordova – Universidade Federal do Pampa, Campus Caçapava do Sul  
Prof. Dr. Douglas Gonçalves da Silva – Universidade Estadual do Sudoeste da Bahia  
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná  
Prof<sup>a</sup> Dr<sup>a</sup> Érica de Melo Azevedo – Instituto Federal do Rio de Janeiro  
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará  
Prof. Dr. Fabrício Moraes de Almeida – Universidade Federal de Rondônia  
Prof<sup>a</sup> Dr<sup>a</sup> Glécilla Colombelli de Souza Nunes – Universidade Estadual de Maringá  
Prof. Dr. Hauster Maximiler Campos de Paula – Universidade Federal de Viçosa  
Prof<sup>a</sup> Dr<sup>a</sup> Iara Margolis Ribeiro – Universidade Federal de Pernambuco  
Prof<sup>a</sup> Dr<sup>a</sup> Jéssica Barbosa da Silva do Nascimento – Universidade Estadual de Santa Cruz  
Prof<sup>a</sup> Dr<sup>a</sup> Jéssica Verger Nardeli – Universidade Estadual Paulista Júlio de Mesquita Filho  
Prof. Dr. Juliano Carlo Rufino de Freitas – Universidade Federal de Campina Grande  
Prof. Dr. Leonardo França da Silva – Universidade Federal de Viçosa  
Prof<sup>a</sup> Dr<sup>a</sup> Luciana do Nascimento Mendes – Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte  
Prof. Dr. Marcelo Marques – Universidade Estadual de Maringá  
Prof. Dr. Marco Aurélio Kistemann Junior – Universidade Federal de Juiz de Fora  
Prof. Dr. Marcos Vinicius Winckler Caldeira – Universidade Federal do Espírito Santo  
Prof<sup>a</sup> Dr<sup>a</sup> Maria Iaponeide Fernandes Macêdo – Universidade do Estado do Rio de Janeiro  
Prof<sup>a</sup> Dr<sup>a</sup> Maria José de Holanda Leite – Universidade Federal de Alagoas  
Prof<sup>a</sup> Dr<sup>a</sup> Mariana Natale Fiorelli Fabiche – Universidade Estadual de Maringá  
Prof<sup>a</sup> Dr<sup>a</sup> Natiéli Piovesan – Instituto Federal do Rio Grande do Norte  
Prof<sup>a</sup> Dr<sup>a</sup> Neiva Maria de Almeida – Universidade Federal da Paraíba  
Prof<sup>a</sup> Dr<sup>a</sup> Priscila Natasha Kinas – Universidade do Estado de Santa Catarina  
Prof<sup>a</sup> Dr<sup>a</sup> Priscila Tessmer Scaglioni – Universidade Federal de Pelotas  
Prof. Dr. Rafael Pacheco dos Santos – Universidade do Estado de Santa Catarina  
Prof. Dr. Ramiro Picoli Nippes – Universidade Estadual de Maringá  
Prof<sup>a</sup> Dr<sup>a</sup> Regina Célia da Silva Barros Allil – Universidade Federal do Rio de Janeiro  
Prof. Dr. Sidney Gonçalo de Lima – Universidade Federal do Piauí

## AGRADECIMENTOS

Este livro foi financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código Financeiro 001. Os autores agradecem o apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e da Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ). Agradecem também ao Instituto de Engenharia Nuclear (IEN) pelo suporte e colaboração.

## PREFÁCIO

No contexto da Física Nuclear Aplicada, há uma extrema dificuldade em encontrar material escrito na língua portuguesa que explore aplicações de técnicas nucleares na indústria. Essa é a principal motivação dos autores ao escreverem este livro, com o objetivo e apresentar um conteúdo que aborda, especialmente, a aplicação de densitometria de fótons (gama e raios X) em sistemas de fluxo multifásicos.

Este livro reúne uma série de trabalhos envolvendo simulações computacionais baseadas no Método de Monte Carlo e Redes Neurais Artificiais, no campo da Física Nuclear Aplicada. Antes de apresentar as aplicações, oferecemos uma introdução à física das radiações e às ferramentas necessárias para uma melhor compreensão do conteúdo. Sabemos que este é um nicho específico da Engenharia Nuclear, e nosso foco principal é alcançar estudantes e professores.

O livro foi idealizado por César Marques Salgado, pesquisador da área, e foi colocado em prática com o apoio de seus colegas de trabalho William Luna Salgado e Roos Sophia de Freitas Dam, além de seu orientador no curso de Mestrado e grande amigo Claudio de Carvalho Conti.

Esperamos que este livro seja de grande utilidade para todos os que o lerem.

Roos Sophia de Freitas Dam

# LISTA DE SIGLAS E ABREVIACOES

ADC:	Conversor Analógico-Digital
AIEA:	Agência Internacional de Energia Atômica ( <i>International Atomic Energy Agency – IAEA</i> )
AMC:	Analisador MultiCanal ( <i>MultiChannel Analyzer – MCA</i> )
CBPF:	Centro Brasileiro de Pesquisas Físicas
CDTN:	Centro de Desenvolvimento da Tecnologia Nuclear
CNEN:	Comissão Nacional de Energia Nuclear
COPPE:	Coordenação dos Programas de Pós-Graduação em Engenharia
DAP:	Distribuição de Altura de Pulso ( <i>Pulse height distribution – PHD</i> )
DFD:	Distância Fonte-Detector
DNN:	Rede neural Profunda ( <i>Deep Neural Network</i> )
DWT:	Transformada Discreta de Wavelet ( <i>Discrete Wavelet Transform</i> )
FVA:	Fração Volumétrica de Água
FVF:	Fração de Volume de Fluido
FVG:	Fração Volumétrica de Gás
FWHM:	Largura à meia altura do fotópico ( <i>Full Width at Half Maximum</i> )
Ge(Li):	Detector de Germânio dopado com Lítio
GEB:	<i>Gaussian Energy Broadening</i> (comando disponibilizado no MCNP6)
HPGe:	Detector semicondutor Hiperpuro de Germânio ( <i>High-Purity Germanium</i> )
IA:	Inteligência Artificial
IEN:	Instituto de Engenharia Nuclear
INP:	Arquivo de entrada ( <i>Input</i> )
IRD:	Instituto de Radioproteção e Dosimetria
LSTM:	Rede Neural Recorrente de Longa Memória ( <i>Long Short-Term Memory Neural Network</i> )
MAE:	Erro médio absoluto ( <i>Mean Absolute Error</i> )
MCNP:	Código de computador para transporte de nêutrons, elétrons e fôtons – <i>Monte Carlo N-Particle</i> ( <i>Computer code for neutron photon transport</i> )
MLP:	Arquitetura de rede <i>feed-forward Multilayer Perceptron</i>
MRE:	Erro relativo médio ( <i>Mean Relative Error</i> )
MSE:	Erro quadrático médio ( <i>Mean Square Error</i> )
Nal(Tl):	Detector cintilador de iodeto de sódio dopado com tálio
NPS:	Número de histórias ( <i>Number of Starting Particles</i> )
ONU:	Organização das Nações Unidas
PMT:	Fotomultiplicadora ( <i>PhotoMultiplier Tube</i> )
PEN:	Programa de Engenharia Nuclear
PLA:	Ácido Polilático
PSD:	Densidade Espectral de Potência ( <i>Power Spectral Density</i> )
PVC:	Policloreto de Vinila
RMSE:	Erro quadrático médio ( <i>Root Mean Squared Error</i> )
RNA:	Rede Neural Artificial
RXD:	Raio X Diagnóstico
SNN:	Rede neural rasa ( <i>Shallow Neural Network</i> )
UERJ:	Universidade do Estado do Rio de Janeiro
UFRJ:	Universidade Federal do Rio de Janeiro

# GLOSSÁRIO

**Algoritmo de Aprendizado:** conjunto de regras bem definidas utilizadas para ajustar os parâmetros de uma rede neural, permitindo que ela aprenda a resolver uma determinada função ou tarefa.

**Aprendizado Supervisionado:** estratégia de treinamento de modelos baseada em exemplos fornecidos por um “professor” ou procedimento sistemático, em que o modelo aprende a mapear entradas para saídas desejadas.

**Arquitetura Feedforward:** tipo de arquitetura de rede neural em que os dados fluem em uma única direção, sem a presença de conexões de retroalimentação.

**Colimador Pinhole:** dispositivo construído com material de alta densidade, projetado para controlar e direcionar feixes de raios X ou gama, por meio de pequenos orifícios. É amplamente utilizado para determinar a relação entre a emissão e a detecção de fóton em aplicações de espectrometria.

**Correlação Cruzada (Cross-Correlation):** técnica estatística que avalia entre duas séries temporais em diferentes pontos em um sistema. Em escoamento de fluidos, permite correlacionar flutuações de propriedades em diferentes locais de uma tubulação, auxiliando no estudo de vazão.

**Dinodo:** eletrodo em válvulas fotomultiplicadoras, responsável por emitir elétrons adicionais através do fenômeno de emissão secundária.

**Distribuição de Altura de Pulses (DAP):** representação gráfica ou numérica da frequência de pulsos eletrônicos detectados com diferentes amplitudes em sistemas de detecção de radiação. A DAP representa os processos de interação da radiação com um detector específico, com considerando a energia depositada pelos fótons e efeitos espúrios, como picos de escape e resolução energética. Portanto, é necessária uma análise cuidadosa com correções para obter o espectro “real” dos raios gama. Essa distribuição é essencial em aplicações de espectroscopia de raios X e gama, fornecendo dados sobre a energia e eficiência de detecção do sistema.

**Efeito Soma:** fenômeno em que dois ou mais fótons emitidos simultaneamente por um radionuclídeo são detectados com um único evento devido à limitação temporal do sistema. Isso resulta em uma contagem registrada no canal correspondente à soma das energias dos fótons.

**Eficiência de Detecção:** capacidade de um detector em registrar fótons emitidos por uma fonte. Influenciada por fatores, como número atômico, dimensões, densidade, geometria e energia dos fótons incidentes. Pode ser classificada como:

*i) Eficiência Absoluta:* razão entre os sinais detectados e os fótons emitidos pela fonte;

*ii) Eficiência Intrínseca:* razão entre os sinais detectados e os fótons incidentes no detector.

# GLOSSÁRIO

De um modo geral, a eficiência diminui com o aumento da energia dos fótons incidentes, devido à maior penetração dos fótons em altas energias e ao tamanho limitado do detector. A eficiência pode ser subdividida em total, que considera todos os pulsos registrados, e de fotopico, que considera apenas os pulsos relacionadas à absorção total da energia do fóton incidente.

**Fração de Vazio (Void Fraction):** razão entre o volume ocupado pela fase gasosa e o volume total da seção transversal do tubo, expressa em porcentagem.

**Holdup:** quantidade de líquido retido em um sistema após o escoamento. Depende de fatores, como geometria da tubulação, propriedades físicas do líquido e condições de operação. O holdup desempenha um papel crucial no dimensionamento e na operação eficiente de equipamentos, influenciando a transferência de massa e calor, a eficiência do processo e a qualidade do produto.

**Inteligência Artificial (IA):** área da computação que estuda métodos para simular ou reproduzir funções cognitivas humanas por meio de máquinas e algoritmos.

**Largura Total à Meia Altura (FWHM - Full Width at Half Maximum):** medida da largura de um fotopico na metade de sua altura máxima, usada em espectrometria para caracterizar a resolução energética de detectores.

**Offshore:** exploração e produção de petróleo e gás natural em ambientes marítimos, em contraste com operações em terra firme (onshore).

**Padrões de Treinamento:** subconjunto de dados fornecido a uma rede neural artificial durante o treinamento para ajustar os pesos e minimizar erros.

**Pencil Beam:** feixe extremamente estreito de radiação, emitido em única direção.

**Picos de Escape:** Quando um fóton de raios X característicos é emitido na direção contrária à do fóton incidente, há uma probabilidade de que esse fóton escape do volume sensível do detector sem ser absorvido. Esse fenômeno ocorre principalmente nas interações que acontecem nas superfícies do detector, especialmente para energias até 40 keV. Como resultado, a absorção total de energia não ocorre, gerando um pico no espectro localizado no canal correspondente à diferença entre a energia do fóton incidente e a energia do fóton de raios X característico que foi “perdido” durante a interação.

**Radiação Bremsstrahlung:** tipo de radiação eletromagnética emitida quando partículas carregadas, como elétrons, são desaceleradas ao interagir com núcleos atômicos. Seu nome, de origem alemã, significa “radiação de frenagem”. Esse tipo de radiação é observado em diversas de situações, como em tubos de raios X.

# GLOSSÁRIO

**Raios X Característicos:** esse fenômeno envolve átomos que foram ionizados, ou seja, interagiram com partículas incidentes com energia suficiente para remover um elétron de uma camada eletrônica mais interna, criando uma vacância e gerando uma condição de instabilidade no átomo. Para retornar à sua condição estável, um elétron de uma órbita mais externa, desloca-se para preencher a vacância, o que resulta em uma diminuição da energia potencial do elétron. O excesso de energia liberado durante esse processo é emitido na forma de radiação eletromagnética, cuja energia corresponde à diferença das energias de ligação entre as camadas envolvidas.

**Rede Neural Artificial (RNA):** modelo computacional inspirado no funcionamento do cérebro humano, composto por neurônios artificiais interconectados em camadas. A RNA aprende a partir de dados, ajustando as conexões ponderadas entre neurônios para minimizar os erros durante o treinamento. As RNAs são amplamente utilizadas em diversas aplicações, como reconhecimento de padrões, processamento de linguagem natural e previsão, sendo uma poderosa ferramenta na inteligência artificial.

**Resolução Energética:** está relacionada com a capacidade de um detector de separar (resolver) duas energias próximas. No caso de detectores NaI(Tl), a resolução energética é afetada principalmente por fatores, como: flutuações no número de cargas coletadas no ânodo do fotomultiplicador, que são causadas pelas flutuações no número de elétrons secundários produzidos nos díodos e no número de fotoelétrons liberados no fotocatodo; ruído eletrônico: tanto da eletrônica quanto do próprio detector, incluindo a corrente de fuga.

**Retropropagação (Backpropagation):** algoritmo fundamental utilizado no treinamento de redes neurais artificiais, especialmente em aprendizado supervisionado. Ele ajusta os pesos da rede de forma a minimizar uma função de custo ou erro sendo amplamente empregado em tarefas de classificação e regressão.

**Unidade Central de Processamento (Central Processing Unit – CPU):** componente principal de um computador, responsável por executar instruções de programas e realizar operações lógicas, aritméticas e de controle. É onde ocorre a maior parte do processamento de dados.

**Unidades de Processamento Gráfico (Graphic Processor Units – GPUs):** processadores especializados, focados principalmente em tarefas relacionadas a gráficos e processamento paralelo. Elas são amplamente utilizadas em jogos, design gráfico e renderização de vídeo, mas também são essenciais em áreas, como aprendizado de máquina, simulações científicas e mineração de criptomoedas. Com milhares de núcleos de processamento eficientes, as GPUs são altamente eficazes em lidar com grandes volumes de

# GLOSSÁRIO

dados simultaneamente, sendo ideais para tarefas que podem ser divididas em partes menores. Seu uso tem se expandido significativamente em aplicações de inteligência artificial, devido à sua capacidade de acelerar algoritmos de treinamento de redes neurais profundas.

**Validação Cruzada (Cross-Validation):** técnica estatística comumente utilizada para avaliar a capacidade de generalização de um modelo de aprendizado de máquina. Ela é especialmente útil quando se tem um conjunto de dados limitado e deseja-se estimar o desempenho do modelo em dados não vistos. O processo de validação cruzada envolve dividir o conjunto de dados em partes e realizar múltiplos experimentos, nos quais diferentes partes são usadas para treinamento e teste. As abordagens mais comuns de validação cruzada são a *K-fold* e a *leave-one-out (LOO)*.

## CAPÍTULO 1

Este capítulo apresenta a introdução às medições multifásicas aplicadas à indústria petrolífera *offshore*, destacando a importância dessas medições. São discutidos os parâmetros utilizados como variáveis em técnicas de inteligência artificial para a determinação da vazão das fases presentes no escoamento.

## CAPÍTULO 2

O conhecimento essencial para o entendimento dos estudos de caso será abordado neste capítulo. A teoria da interação da radiação gama e raios X com a matéria é apresentada, bem como os métodos utilizados para a detecção dessa radiação. Também são introduzidas as ferramentas utilizadas nos estudos, como as redes neurais artificiais (RNAs) e a simulação matemática do transporte da radiação, utilizando o código MCNP6. Além disso, são abordados os diferentes regimes de fluxo relevantes para as aplicações apresentadas neste livro.

## CAPÍTULO 3

Este capítulo é uma apresentação da metodologia desenvolvida para a identificação de regimes de fluxo e da predição de frações de volume em sistemas multifásicos água-gás-óleo. A abordagem se baseia no reconhecimento de padrões de distribuições de altura de pulso (DAPs) geradas pelos raios gama, utilizando redes neurais artificiais (RNAs). O sistema de detecção utiliza uma geometria com feixe divergente apropriada, composta por uma fonte de raios gama de dupla energia e dois detectores de NaI(Tl) posicionados para medir os feixes transmitidos e espalhados. São também apresentados os modelos teóricos ideais e estáticos para regimes anular, estratificado e homogêneo, desenvolvidos com o código MCNP6. O sistema é composto por quatro RNAs: a primeira identifica o regime de fluxo, enquanto as outras três RNAs são especializadas na predição de fração de volume para cada regime de fluxo específico. As RNAs propostas foram eficazes na identificação dos três regimes distintos e na predição satisfatória da fração de volume no sistema multifásico água-gás-óleo, mostrando-se uma abordagem promissora. Em uma fase posterior, avalia-se o potencial das redes neurais profundas.

## CAPÍTULO 4

A metodologia apresentada neste capítulo baseia-se na utilização de um feixe de raios X de 149,5 keV e dois detectores planares de germânio para medições de transmissão e espalhamento de raios X, visando à predição das frações de volume em um sistema trifásico. As frações de volume dos fluidos foram modeladas utilizando o código MCNP6 para um regime de fluxo anular. As

DAPs (espectros de energia) obtidas pelos detectores foram usadas como dados de entrada da RNA, que geram as frações de volume de gás e água. Uma RNA foi utilizada para correlacionar os espectros de energia de ambos os detectores com as frações de volume dos fluidos.

## CAPÍTULO 5

Esta abordagem será dividida em duas etapas. A primeira consiste na metodologia para o cálculo de frações volumétricas em medidores multifásicos de fluidos e a predição da espessura de incrustações de sulfato de bário ( $\text{BaSO}_4$ ). As DAPs obtidas com o código MCNP6, utilizando dois detectores de NaI(Tl), são usadas como dados de entrada para a RNA, sem a necessidade de métodos de parametrização. Na segunda etapa, é investigada uma metodologia para investigar a deposição de incrustações excêntricas de  $\text{BaSO}_4$ , frequentemente observadas na indústria do petróleo. Essas incrustações diminuem o diâmetro interno das tubulações, dificultando o escoamento.

## CAPÍTULO 6

Neste capítulo, a metodologia proposta é utilizada para identificar a região de interface (*transmix*) entre subprodutos de petróleo transportados em polidutos, utilizando densitometria gama e RNA para reduzir o volume de produtos contaminados durante o processo de transporte. A geometria de medição, composta por uma fonte de raios gama com energia de 661,66 keV (referente ao  $^{137}\text{Cs}$ ) e dois detectores NaI(Tl) de  $1\frac{1}{4}'' \times \frac{3}{4}''$ , foi simulada pelo código MCNP6. Um detector mede o feixe transmitido, enquanto o outro mede o feixe espalhado. As funções resposta dos detectores foram validadas experimentalmente. Gasolina, querosene, óleo combustível e glicerina foram utilizados para compor diversas combinações de níveis de pureza.

# SUMÁRIO

<b>CAPÍTULO 1.....</b>	<b>1</b>
REDE NEURAL ARTIFICIAL E MEDAÇÃO DE FLUXO MULTIFÁSICO	
César Marques Salgado	
 <a href="https://doi.org/10.22533/at.ed.4292518061">https://doi.org/10.22533/at.ed.4292518061</a>	
<b>CAPÍTULO 2 .....</b>	<b>12</b>
CONCEITOS BÁSICOS	
César Marques Salgado	
 <a href="https://doi.org/10.22533/at.ed.4292518062">https://doi.org/10.22533/at.ed.4292518062</a>	
<b>CAPÍTULO 3 .....</b>	<b>54</b>
IDENTIFICAÇÃO DO REGIME DE FLUXO E CÁLCULO DA FRAÇÃO DE VOLUME EM ESCOAMENTOS MULTIFÁSICOS BASEADOS EM RADIAÇÃO GAMA	
César Marques Salgado	
 <a href="https://doi.org/10.22533/at.ed.4292518063">https://doi.org/10.22533/at.ed.4292518063</a>	
<b>CAPÍTULO 4 .....</b>	<b>81</b>
CÁLCULO DE FRAÇÕES DE VOLUME EM SISTEMAS MULTIFÁSICOS BASEADOS EM RAIOS X	
César Marques Salgado	
 <a href="https://doi.org/10.22533/at.ed.4292518064">https://doi.org/10.22533/at.ed.4292518064</a>	
<b>CAPÍTULO 5 .....</b>	<b>90</b>
CÁLCULO DE FRAÇÕES DE VOLUME COM INCRUSTAÇÕES EM OLEODUTOS BASEADOS EM RADIAÇÃO GAMA	
César Marques Salgado	
 <a href="https://doi.org/10.22533/at.ed.4292518065">https://doi.org/10.22533/at.ed.4292518065</a>	
<b>CAPÍTULO 6 .....</b>	<b>115</b>
IDENTIFICAÇÃO DA REGIÃO DE INTERFACE PARA MONITORAMENTO NO TRANSPORTE DE SUBPRODUTOS DE PETRÓLEO EM POLIDUTOS BASEADO EM RADIAÇÃO GAMA	
César Marques Salgado	
 <a href="https://doi.org/10.22533/at.ed.4292518066">https://doi.org/10.22533/at.ed.4292518066</a>	
<b>ANÁLISE FINAL.....</b>	<b>133</b>
<b>SOBRE OS AUTORES .....</b>	<b>134</b>

# CAPÍTULO 1

## REDE NEURAL ARTIFICIAL E MEDAÇÃO DE FLUXO MULTIFÁSICO

---

**César Marques Salgado**

**William Luna Salgado**

**Roos Sophia de Freitas Dam**

**Claudio de Carvalho Conti**

O fluxo multifásico é amplamente observado em diversas áreas da engenharia e da ciência. Na indústria de petróleo e gás, em particular, há uma crescente demanda por técnicas precisas de medição das vazões de água, gás e óleo. Este livro foca na medição do fluxo multifásico de hidrocarbonetos, abordando tópicos, como fluxo em meios porosos [1, 2, 3, 4], o movimento de fluidos em poços [5, 6, 7], e transporte em tubulações [8, 9, 10]. Os fluidos, definidos como materiais que se deformam facilmente e se ajustam às condições em que estão inseridos, apresentam características distintas de compressibilidade. Embora todos os fluidos sejam tecnicamente compressíveis, na prática, gases são tratados como

compressíveis e líquidos como incompressíveis devido à insignificante variação de densidade dos líquidos sob condições normais.

A determinação das propriedades dos fluidos em fluxo monofásico é geralmente direta. No entanto, essa tarefa se torna mais complexa para gases, devido à sua natureza compressível, e ainda mais desafiadora para fluxos multifásicos, em que as propriedades da mistura não podem ser obtidas simplesmente pela soma das características individuais dos componentes. Além disso, em fluxos multifásicos pode ocorrer transferência de massa entre as fases [11]. A medição de vazões em fluxos multifásicos pode ser realizada por separação de fases ou pelo uso de medidores específicos. O método convencional envolve separadores, que dependem das diferenças físicas entre os componentes do fluxo. Em separadores bifásicos, gás e líquido se separam devido às diferenças de densidade e ao tempo de residência dentro do equipamento. Em separadores trifásicos, além do gás, a água e o óleo também se separam devido à imiscibilidade e às diferenças de

densidade e viscosidade. Uma vez separadas, as fases são medidas utilizando medidores monofásicos<sup>1</sup>. [12] Apesar de amplamente utilizados, separadores enfrentam desafios, como dificuldades na separação de emulsões e espuma, falhas na manutenção dos medidores e problemas na separação de microbolhas em líquidos viscosos. Além disso, não fornecem informações sobre o regime de fluxo ou a fração de gás/vapor (FVG). Por esse motivo, métodos alternativos, como medidores de fluxo multifásico vêm ganhando destaque [13]. Os medidores de fluxo multifásico, uma tecnologia mais recente, operam medindo a vazão total da mistura, determinando as frações das fases individuais e calculando as vazões de cada fase com base nessas informações. Para aumentar a precisão, esses medidores multifásicos frequentemente combinam diferentes tecnologias e possuem designs variados dependendo do fabricante [14, 15, 16].

Redes neurais artificiais têm se mostrado ferramentas poderosas para a classificação de regimes de fluxo e a previsão das vazões das fases individuais [17, 18, 19]. Essas redes neurais são amplamente utilizadas na determinação de parâmetros de fluxo multifásico, como vazão de óleo e gás, identificação de padrões de fluxo e estimativa de fração volumétrica de gás (FVG) ou de líquido (*holdup*). Para isso, as entradas da rede neural artificial são relacionadas às vazões e aos regimes de fluxo, sendo alimentadas por dados de sensores que podem ser categorizados em cinco grupos principais:

- I. Sinais de detectores de radiação (especialmente energia de raios gama);
- II. Sinais de impedância elétrica;
- III. Sinais ultrassônicos;
- IV. Sinais de pressão;
- V. Sinais provenientes de propriedades físicas dos fluidos em fluxo (como densidade, temperatura e velocidade).

Nas seções seguintes deste capítulo, serão detalhadas as aplicações de redes neurais artificiais em medições de fluxo multifásico. A organização segue os parâmetros a serem medidos (regime de fluxo, fração de vazio e vazão) e os métodos utilizados (radioativos, ultrassônicos, elétricos, baseados em pressão ou propriedades do fluxo).

## REGIMES DE FLUXO

Em tubulações verticais ou ligeiramente inclinadas, as misturas de gás e líquido frequentemente apresentam regimes de fluxo, como anular, estratificado e bolhas. Em tubulações horizontais, além desses regimes, podem ocorrer fluxos ondulados ou estratificados. Outros regimes, como *plug*, disperso e transição, também são relevantes, especialmente na análise de problemas em zonas de transição.

1. *Medidores:* i) Pressão Diferencial: Mede a velocidade média do fluido com base na perda de pressão provocada pela redução no tópico de passagem; ii) Turbina: Mede a vazão a partir da rotação de uma turbina, que é proporcional ao movimento causado pelo escoamento do fluido; iii) Placa: Determina a força exercida pelo fluido em uma placa disposta transversalmente ao escoamento, sendo esta força proporcional à sua velocidade.

Durante o monitoramento de fluxos multifásicos em tubulações, os medidores produzem sinais complexos, cuja interpretação é desafiadora devido à natureza não linear e multidimensional desses dados. Métodos tradicionais de processamento de sinal frequentemente enfrentam limitações para analisar adequadamente esses sinais. Entre os métodos já utilizados estão: Função de Densidade de Probabilidade, Espectros de Potência, *Wavelet*, *Hilbert-Huang*, *Gabor*, Dimensões Fractais e séries de *Markov* [20, 21, 22, 23]. Adicionalmente, técnicas, como a Transformada Discreta de Wavelet (DWT - *Discrete Wavelet Transform*) e Densidade Espectral de Potência (PSD - *Power Spectral Density*) também têm sido utilizadas por Hernandez et al., (2006) [24].

Além desses, outros métodos baseados em impedância elétrica (capacitância), técnicas nucleares (radiação gama e nêutrons), sinais de pressão e atenuação acústica têm sido aplicados para estimar parâmetros do fluxo multifásico. Contudo, esses métodos exigem uma identificação precisa de padrões de fluxo, o que motivou o uso crescente de técnicas de inteligência artificial para essa finalidade. As redes neurais artificiais (RNA) têm se mostrado promissoras na classificação de regimes de fluxo, sendo utilizadas em diferentes abordagens, como:

- I. Perceptron de múltiplas camadas com retropropagação, *nearest neighbor*, e *classification tree* [25];
- II. *Neuro-fuzzy* [26];
- III. Redes neurais auto-organizáveis [27];
- IV. Redes neurais probabilísticas [24];
- V. Redes neurais profundas [28];
- VI. Redes neurais convolucionais [29, 30, 31, 32];
- VII. Redes neurais LSTM [33];
- VIII. Redes neurais de funções de base radial [34, 35, 36].

A identificação do regime de fluxo pode ser realizada por meio da análise de sinais elétricos, considerando o fluido em escoamento como um condutor elétrico. Sensores baseados em capacidade e resistência elétrica são amplamente utilizados para estimar parâmetros do fluxo [37, 38]. Esses sensores capturam sinais que representam a resistência elétrica do fluido, permitindo a determinação de propriedades fundamentais da mistura, como capacidade e condutância entre as fases líquida e gasosa [39]. Situações que envolvem mudanças de fase, como transição entre óleo e água, exigem o uso de métodos alternativos, devido às diferenças nas propriedades dielétricas das fases. Além disso, variações de temperatura podem comprometer a precisão das medições elétricas, tornando indispensável o isolamento térmico da tubulação para minimizar interferências e assegurar resultados mais confiáveis [40, 41].

Uma ampla gama de parâmetros do sistema pode ser utilizada para a classificação dos regimes de fluxo. Entre eles, destacam-se a densidade, viscosidade, diâmetro do tubo, ângulo de inclinação, temperatura, pressão, gradiente de pressão, velocidade superficial dos fluidos, números de *Reynolds*, *Weber* e *Froude*. Outros fatores, como vibração induzida e tensão superficial, também desempenham um papel relevante. Esses parâmetros podem ser utilizados como variáveis de entrada em redes neurais artificiais, permitindo capturar os fenômenos hidrodinâmicos associados às variações nas propriedades do fluido. Essa abordagem é particularmente eficaz para modelar as complexas interações presentes nos regimes de fluxo multifásico [28, 42, 43].

Outra abordagem é o uso de sinais de pressão. A passagem de gás e líquido induz flutuações de pressão, uma característica atrativa para a caracterização de padrões de fluxo. Sensores, como transdutores de pressão diferencial e medidores de fluxo de vórtice são econômicos, duráveis, e adequados para aplicações industriais [44]. Estudos demonstram a eficácia da análise da densidade espectral de potência e função de densidade de probabilidade de flutuações de pressão para identificar padrões em fluxos bifásicos de gás/líquido [45, 46].

Técnicas ultrassônicas também têm destaque, sendo não invasivas, robustas e relativamente econômicas. Baseiam-se na atenuação de pulsos ultrassônicos na interface parede-líquido e no tempo de retorno do eco, permitindo a detecção de interfaces gás-líquido [47]. Sensores Doppler ultrassônicos são amplamente aplicados na medição não invasiva de velocidade de fluxo. No entanto, a calibração prévia do sinal ainda é uma limitação significativa, podendo ser mitigada com o uso de redes neurais artificiais.

Por fim, técnicas nucleares, como a densitometria gama, são amplamente utilizadas. Baseadas em princípios de atenuação e espalhamento de radiação, essas técnicas permitem calcular frações volumétricas e identificar os regimes de fluxo a partir de taxas de contagem medidas nos detectores [19, 48, 49, 50]. Estudos recentes destacam o uso de radioatividade na análise de fluxos multifásicos em diversas configurações de medição [51, 52, 53, 54, 55, 56].

As RNAs desempenham um papel fundamental na modelagem de relações complexas entre variáveis de entrada e saída, especialmente na identificação automática de padrões de fluxo. Sua capacidade de capturar comportamentos não lineares e dependências cruzadas entre variáveis reforça seu potencial em aplicações industriais e acadêmicas.

## VAZÃO

Medidores de fluxo multifásico desempenham um papel crucial em diversas etapas da produção de petróleo, fornecendo dados rápidos e precisos para testes dos poços. Esses dispositivos são particularmente úteis em ambientes remotos ou não tripulados, em instalações de superfície (*topside*) onde o espaço é limitado, e em implantações submarinas. Entre os principais parâmetros medidos estão as vazões das diferentes fases: óleo, gás e água.

A estimativa das vazões de óleo, no entanto, apresenta desafios significativos, especialmente em situações em que a medição direta não é possível. Nesses casos, engenheiros de petróleo frequentemente recorrem a correlações empíricas, que podem introduzir erros consideráveis e levar a resultados imprecisos.

Como alternativa, redes neurais artificiais (RNAs) têm sido amplamente aplicadas na análise de sinais elétricos e acústicos de fluidos captados por transdutores ultrassônicos [57]. Esses sinais, integrados a modelos físicos de escoamento multifásico, medições de pressão diferencial de tubos Venturi e sensores de pressão, possibilitam determinar com alta precisão a velocidade e a densidade de cada fase [58]. Estudos em poços *offshore*, como os localizados no North West Java e no norte do Golfo Pérsico, no Irã, demonstraram a eficácia das RNAs, alcançando erros relativos inferiores a 10% em 90% das medições [59, 60].

Nesse método, dados de pressão e temperatura dos oleodutos são usados como entradas para a RNA, enquanto a vazão de óleo é a variável de saída. A vazão multifásica depende diretamente das frações volumétricas, da velocidade superficial de cada fase e do regime de fluxo.

Os sensores Venturi são amplamente utilizados para medir a velocidade do fluxo multifásico. Nesses dispositivos, a vazão mássica é correlacionada à diferença de pressão entre duas seções monitoradas, enquanto a velocidade é estimada por técnicas de processamento de sinais, como a Correlação Cruzada (*Cross-Correlation*). Para isso, dois sensores idênticos são posicionados ao longo do tubo, e o padrão de sinal capturado pelo primeiro é replicado pelo segundo após um intervalo de tempo, conhecido como tempo de trânsito.

Medidores de fluxo multifásico oferecem a vantagem de medir diretamente as frações individuais de cada fase em uma tubulação, eliminando a necessidade de separação física ou amostragem dos fluidos.

Outra solução para a medição de vazões envolve o uso de programas de simulação de processos e técnicas de estimativa de parâmetros. Esses sistemas permitem o desenvolvimento de soluções de medição multifásica baseadas em dados de pressão e temperatura no ponto de chegada do oleoduto, dispensando hipóteses sobre o estado do fluido. As variáveis utilizadas incluem: velocidades superficiais de líquido e gás, temperatura, pressão, propriedades dos fluidos (viscosidade, tensão superficial e densidade), além de características do tubo (diâmetro e inclinação).

Os Métodos radioativos, como a densitometria gama, são amplamente utilizados para determinar frações de volume em sistemas multifásicos óleo-água-gás [19]. Esse método baseia-se nos princípios de atenuação e espalhamento de raios gama, utilizando uma geometria específica que consiste em uma fonte de radiação gama e detectores estrategicamente posicionados para captar as interações da radiação com as diferentes fases do fluxo.

Adicionalmente, sensores elétricos têm se mostrado eficientes na realização de medições tomográficas de capacidade elétrica possibilitando a análise detalhada da composição dos fluidos em processos de fluxo<sup>[61]</sup>. Por outro lado, os sensores ultrassônicos destacam-se na quantificação do *holdup*<sup>2</sup> em fluxos bifásicos água/óleo, utilizando princípios de difusão ultrassônica para avaliar as características das fases presentes no escoamento<sup>[62]</sup>.

Essas abordagens complementares oferecem soluções robustas para a caracterização de sistemas multifásicos, atendendo às demandas da indústria de óleo e gás com precisão e versatilidade.

## CONCLUSÃO

Neste capítulo, foram tratados temas relevantes da aplicação de RNAs na análise de parâmetros de fluxo multifásico. Foram abordados tópicos fundamentais, como a classificação do regime de fluxo, a investigação da fração de volume das fases e, por fim, a determinação da vazão das diferentes fases.

Diversos parâmetros de fluxo, incluindo pressão, temperatura, velocidade e viscosidade, foram destacados como variáveis frequentemente utilizadas no treinamento de RNAs. A literatura apresenta uma ampla gama de pesquisas sobre a medição de fluxo multifásico utilizando essas redes, empregando técnicas baseadas em ondas ultrassônicas, sinais elétricos e procedimentos com radiação gama. Os resultados indicam que RNAs bem desenvolvidas, especialmente aquelas com algoritmo de retropropagação de erro e configurações de uma ou duas camadas ocultas, são eficazes na determinação de parâmetros de fluxo, contribuindo para um aumento significativo na precisão dos resultados.

Contudo, foi enfatizada a importância de dispor de um volume expressivo de dados para que as RNAs possam ser aplicadas com eficácia a uma ampla variedade de cenários. Esses cenários incluem variáveis, como diâmetro dos tubos, viscosidades dos fluidos, densidades e razão gás-líquido. A identificação precisa dos padrões de fluxo em sistemas multifásicos continua sendo um desafio. No entanto, com dados adequados e o uso de técnicas robustas de normalização e escalonamento, a tarefa pode ser realizada com elevada precisão.

As RNAs possuem grande potencial de aplicação em várias indústrias, como a caracterização e simulação de reservatórios, recuperação avançada de petróleo, testes de poços, mecânica de rochas, limpeza de poços e o estudo do fluxo de fluidos em meios porosos. Apesar do potencial promissor dessas áreas, este capítulo não abordou tais tópicos em profundidade, visando evitar dispersão e manter o foco da discussão.

---

2. *Holdup do líquido* é definido como a razão entre o volume de um segmento de tubo ocupado por líquido e o volume total deste segmento.

Por fim, embora as técnicas de inteligência artificial, como as RNAs, tenham contribuído significativamente para o aprimoramento na obtenção de parâmetros multifásicos, é essencial continuar avaliando a eficácia dessas redes frente às variações nas propriedades dos fluidos produzidos, como petróleo e gás. Além disso, seria oportuno ampliar as discussões futuras para outras abordagens de inteligência artificial, como algoritmos genéticos, que podem complementar as RNAs na solução de problemas complexos e multidimensionais.

## REFERÊNCIAS

- [1] Tabzar, A.; Fathinasab, M.; Salehi, A.; Bahrami, B. Multiphase flow modeling of asphaltene precipitation and deposition. *Oil & Gas Science and Technology–Revue d'IFP Energies nouvelles*, v. 73, n. 3, p. 51, 2018.
- [2] Zhao, B.; MacMinn, C.W.; Primkulov, B.K.; Chen, Y.; Valocchi, A.J.; Zhao, J.; Kang, Q.; Bruning, K.; McClure, J.E.; Miller, C.T.; Fakhari, A.; Bolster, D.; Hiller, T.; Brinkmann, M.; Cueto-Felgueroso, L.; Co-gswell, D.A.; Verma, R.; Prodanović, M.; Maes, J.; Geiger, S.; Vassvik, M.; Hansen, A.; Segre, E.; Holtzman, R.; Yang, Z.; Yuan, C.; Chareyre, B.; Juanes, R. Comprehensive comparison of pore-scale models for multiphase flow in porous media. In: *Proceedings of the National Academy of Sciences*, v. 116, n. 28, p.13799-13806, 2019.
- [3] Haghi, A.H.; Chalaturnyk, R.; Talman, S. Stress-Dependent Pore Deformation Effects on Multiphase Flow Properties of Porous Media. *Scientific reports*, v. 9, n. 1, p. 1-10, 2019.
- [4] Bakhshian, S.; Hosseini, S.A.; Shokri, N. Pore-scale characteristics of multiphase flow in heterogeneous porous media using the lattice Boltzmann method. *Scientific reports*, v. 9, n. 1, 2019. Disponível em: <https://doi.org/10.1038/s41598-019-39741-x>
- [5] Al-Rbeawi, S. Pseudo-steady state inflow performance relationship of reservoirs undergoing multiphase flow and different wellbore conditions. *Journal of Natural Gas Science and Engineering*, v. 68, 2019. Disponível em: <https://doi.org/10.1016/j.jngse.2019.102912>
- [6] Hou, Z.; Yan, T.; Li, Z.; Feng, J.; Sun, S.; Yuan, Y. Temperature prediction of two phase flow in wellbore using modified heat transfer model: An experimental analysis. *Applied Thermal Engineering*, v. 149, p. 54-61, 2019.
- [7] Tariq, Z.; Mahmoud, M.; Abdulraheem, A. Real-time prognosis of flowing bottom-hole pressure in a vertical well for a multiphase flow using computational intelligence techniques. *Journal of Petroleum Exploration and Production Technology*, p. 1-18, 2019.
- [8] Chi, Y.; Sarica, C.; Daraboina, N. Experimental investigation of two-phase gas-oil stratified flow wax deposition in pipeline. *Fuel*, v. 247, p. 113-125, 2019.
- [9] Leporini, M.; Marchetti, B.; Corvaro, F.; di Giovine, G.; Polonara, F.; Terenzi, A. Sand transport in multiphase flow mixtures in a horizontal pipeline: An experimental investigation. *Petroleum*, v. 5, n. 2, p. 161-170, 2019.
- [10] Sultan, R.A.; Rahman, M.A.; Rushd, S.; Zendehboudi, S.; Kelessidis, V.C. Validation of CFD model of multiphase flow through pipeline and annular geometries. *Particulate Science and Technology*, v. 37, n. 6, p. 685-697, 2019.

- [11] Bruvik, E.; Hjertaker, B. Liquid characterization and measurement of fluid properties for reduced uncertainty in multiphase flow area fraction measurements. *Flow Measurement and Instrumentation*, v. 47, p. 10-18, 2016.
- [12] Seo, N.; Kharoua, N.; Khezzar, L.; Alshehhi, M. Multiphase Flow Simulation of In-Line Gas-Liquid Separator for Multiphase Metering. In: *Fluids Engineering Division Summer Meeting*. The American Society of Mechanical Engineers, 2019. Disponível em: <https://doi.org/10.1115/AJKFluids2019-4802>.
- [13] Dang, W.; Gao, Z.; Hou, L.; Lv, D.; Qiu, S.; Chen, G. A novel deep learning framework for industrial multiphase flow characterization. *IEEE Transactions on Industrial Informatics*, v. 15, n. 11, p. 5954-5962, 2019.
- [14] Falcone, G.; Hewitt, G.; Alimonti, C. *Multiphase flow metering: Principles and applications*. 2009: Elsevier.
- [15] Michaelides, E.; Crowe, C.T.; Schwarzkopf, J.D. *Multiphase flow handbook*. 2016: CRC Press.
- [16] Ma, L.; McCann, D.; Hunt, A. Combining magnetic induction tomography and electromagnetic velocity tomography for water continuous multiphase flows. *IEEE Sensors Journal*, v. 17, n. 24, p. 8271-8281, 2017.
- [17] Sheppard, C.; Russell, D. The application of artificial neural networks to non-intrusive multi-phase metering. *Control Engineering Practice*, v. 1, n. 2, p. 299-304, 1993.
- [18] Salgado, C.M.; Brandão, L.E.B.; Schirru, R.; Pereira, C.M.N.A.; Silva, A.X.; Ramos, R. Prediction of volume fractions in three-phase flows using nuclear technique and artificial neural network. *Applied Radiation and Isotopes*, v. 67, p. 1812-1818, 2009.
- [19] Salgado, C.M.; Pereira, C.M.N.A.; Schirru, R.; Brandão, L.E. Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks. *Progress in Nuclear Energy*, v. 52, p. 555-562, 2010.
- [20] Ding, H.; Huang, Z.; Song, Z.; Yan, Y. Hilbert–Huang transform based signal analysis for the characterization of gas–liquid two-phase flow. *Flow measurement and instrumentation*, v. 18, n. 1, p. 37-46, 2007.
- [21] Pai, M.G.; Subramaniam, S. A comprehensive probability density function formalism for multiphase flows. *Journal of Fluid Mechanics*, v. 628, p. 181-228, 2009.
- [22] Hu, L.-D.; Jin, N.-D.; Gao, Z.-K. Characterization of horizontal gas–liquid two-phase flow using Markov model-based complex network. *International Journal of Modern Physics C*, v. 24, n. 5, 2013. Disponível em: <https://doi.org/10.1142/S0129183113500289>
- [23] Zhang, K.; Hou, Y.D.; Tian, W.X.; Zhang, Y.P.; Su, G.H.; Qiu, S.Z. Theoretical prediction of single bubble motion in vertically upward two-phase flow across inclined tube bundles. *Annals of Nuclear Energy*, v. 128, p. 422-432, 2019.
- [24] Hernandez, L.; Juliá, J.E.; Chiva, S.; Paranjape, S.; Ishii, M. Fast classification of two-phase flow regimes based on conductivity signals and artificial neural networks. *Measurement Science and Technology*, v. 17, n. 6, 2006. Disponível em: <https://doi.org/10.1088/0957-0233/17/6/032>

- [25] Ozbayoglu, A.M.; Yuksel, H.E. Analysis of gas–liquid behavior in eccentric horizontal annuli with image processing and artificial intelligence techniques. *Journal of petroleum science and engineering*, v. 81, p. 31-40, 2012.
- [26] El-Sebakhy, E.A. Flow regimes identification and liquid-holdup prediction in horizontal multiphase flow based on neuro-fuzzy inference systems. *Mathematics and Computers in Simulation*, v. 80, n. 9, p. 1854-1866, 2010.
- [27] Mi, Y.; Ishii, M.; Tsoukalas, L. Flow regime identification methodology with neural networks and two-phase flow models. *Nuclear engineering and design*, v. 204, n. 1-3, p. 87-100, 2001.
- [28] Lin, Z.; Liu, X.; Lao, L.; Liu, H. Prediction of two-phase flow patterns in upward inclined pipes via deep learning. *Energy*, v. 210, 2020. <https://doi.org/10.1016/j.energy.2020.118541>
- [29] Kuang, B.; Nnabuife, S.G.; Sun, S.; Whidborne, J.F.; Rana, Z.A. Gas-liquid flow regimes identification using non-intrusive Doppler ultrasonic sensor and convolutional recurrent neural networks in an s-shaped riser. *Digital Chemical Engineering*, v. 2, 2022. Disponível em: <https://doi.org/10.1016/j.dche.2022.100012>
- [30] Khan, U.; Pao, W.; Sallih, N.; Hassan, F. Flow Regime Identification in Gas-Liquid Two-Phase Flow in Horizontal Pipe by Deep Learning. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, v. 27, n. 1, p. 86-91, 2022.
- [31] Nnabuife, S.G.; Kuang, B.; Whidborne, J.F.; Ran, A. Development of gas-liquid flow regimes identification using a noninvasive ultrasonic sensor, belt-shape features, and convolutional neural network in an S-shaped riser. *IEEE Transactions on Cybernetics*, v. 53, 1, p. 3-17, 2021.
- [32] Vahabi, N. *Machine learning algorithms for analysis of oil, gas and water well acoustic datasets*. UCL (University College London), 2019.
- [33] Boorboor, S.; Feghhi, S.; Jafari, H. Development of an intelligent dual-beam gamma densitometer for real-time recognition of two-phase flow regime in horizontal pipe. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 1054, 2023. Disponível em: <https://doi.org/10.1016/j.nima.2023.168412>
- [34] Jia, Z.-H.; Niu, G.; Wang, J. Flow regime identification in two-phase flow by using neural network. *Journal of Chemical Engineering of Chinese Universities*, v. 19, n. 3, p. 368-372, 2005.
- [35] Liang, F.; Hang, Y.; Yu, H.; Gao, J. Identification of gas-liquid two-phase flow patterns in a horizontal pipe based on ultrasonic echoes and RBF neural network. *Flow Measurement and Instrumentation*, v. 79, 2021. Disponível em: <https://doi.org/10.1016/j.flowmeasinst.2021.101960>
- [36] Rosa, E.S.; Salgado, R.M.; Ohishi, T.; Mastelari, N. Performance comparison of artificial neural networks and expert systems applied to flow pattern identification in vertical ascendant gas–liquid flows. *International Journal of Multiphase Flow*, v. 36, n. 9, p. 738-754, 2010.
- [37] Ghosh, S.; Pratihar, D.K.; Maiti, B.; Das, P.K. Identification of flow regimes using conductivity probe signals and neural networks for counter-current gas–liquid two-phase flow. *Chemical Engineering Science*, v. 84, p. 417-436, 2012.
- [38] Roman, A.J.; Kreitzer, P.J.; Ervin, J.S.; Hanchak, M.S.; Byrd, L.W. Flow pattern identification of horizontal two-phase refrigerant flow using neural networks. *International Communications in Heat and Mass Transfer*, v. 71, p. 254-264, 2016.

- [39] Tsoukalas, L.H.; Ishii, M.; Mi, Y. A Neurofuzzy methodology for impedance-based multiphase flow identification. *Engineering Applications of Artificial Intelligence*, v. 10, n. 6, p. 545–555, 1998.
- [40] Mi, Y.; Tsoukalas, L.; Ishii, M. Application of multiple self-organizing neural networks: Flow pattern classification. *Transactions of the American Nuclear Society*, v. 77, p. 114-116, 1997.
- [41] Mi, Y.; Ishii, M.; Tsoukalas, L. Vertical two-phase flow identification using advanced instrumentation and neural networks. *Nuclear engineering and design*, v. 184, n. 2-3, p. 409-420, 1998.
- [42] Al-Dogail, A.; Gajbhiye, R.; AlNajim, A.; AlNaser, M. Dimensionless artificial intelligence-based model for multiphase flow pattern recognition in horizontal pipe. *SPE Production & Operations*, v. 37, n. 2, p. 244-262, 2022.
- [43] AlSaif, A.; Al-Sarkhi, A.; Ismaila, K.; Abdulkadir, M. Road map to develop an artificial neural network to predict two-phase flow regime in inclined pipes. *Journal of Petroleum Science and Engineering*, v. 217, 2022. <https://doi.org/10.1016/j.petrol.2022.110877>
- [44] Drahoš, J.; Zahradník, J.; Punčochář, M.; Fialová, M.; Bradka, F. Effect of operating conditions on the characteristics of pressure fluctuations in a bubble column. *Chemical Engineering and Processing: Process Intensification*, v. 29, n. 2, p. 107-115, 1991.
- [45] Franca, F.; Acikgoz, M.; Lahey, R.T.; Clausse, A. The use of fractal techniques for flow regime identification. *International Journal of Multiphase Flow*, v. 17, n. 4, p. 545-552, 1991.
- [46] Shim, W.J.; Jo, C.H. Analysis of pressure fluctuations in two-phase vertical flow in annulus. *Journal of Industrial and Engineering Chemistry*, v. 6, n. 3, p. 167-173, 2000.
- [47] Kuang, B.; Nnabuife, S.; Sun, S.; Whidborne, J. Gas-liquid flow regimes identification using non-intrusive Doppler ultrasonic sensor and convolutional recurrent neural networks in an s-shaped riser. *Digital Chemical Engineering*, v. 2, 2022. Disponível em: <https://doi:10.1016/j.dche.2022.100012>
- [48] Jeshvaghani, P.A.; Khorsandi, M.; Panahi, R. Flow regime identification and gas volume fraction prediction in two-phase flows using a simple gamma-ray gauge combined with parallel artificial neural networks. *Flow Measurement and Instrumentation*, 86, 2022. Disponível em: <https://doi.org/10.1016/j.flowmeasinst.2022.102190>
- [49] Zhu, J.H.; Munjal, R.; Sivaram, A.; Paul, S.R.; Tian, J.; Jolivet, G. Flow regime detection using gamma-ray-based multiphase flowmeter: A machine learning approach. *International Journal of Computational Methods and Experimental Measurements*, v. 10, n. 1, p. 26-37, 2022.
- [50] Boorboor, S.; Feghhi, S.; Jafari, H. Design and construction of an LSTM-powered high sampling rate dual-beam gamma densitometer for real-time measurement of the two-phase flow void fraction. *Nuclear Engineering and Design*, 411, 2023. Disponível em: <https://doi.org/10.1016/j.nucengdes.2023.112444>
- [51] Hosseini, S.; Taylan, O.; Abusurrah, M.; Akilan, T.; Nazemi, E.; Eftekhari-Zadeh, E.; Bano, F.; Roshani, G.H. Application of wavelet feature extraction and artificial neural networks for improving the performance of gas–liquid two-phase flow meters used in oil and petrochemical industries. *Polymers*, v. 13, n. 21, 2021. Disponível em: <https://doi.org/10.3390/polym13213647>
- [52] Sattari, M. A.; Roshani, G. H.; Hanus, R. Improving the structure of two phase flow meter using feature extraction and GMDH neural network. *Radiation Physics and Chemistry*, v. 171, 2020. Disponível em: <https://doi.org/10.1016/j.radphyschem.2020.108725>

- [53] Salgado, W.L.; Dam, R.S.F.; Salgado, C.M. Optimization of a flow regime identification system and prediction of volume fractions in three-phase systems using gamma-rays and artificial neural network. *Applied Radiation and Isotopes*, 169, 2021. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109552>
- [54] Mayet, A.M.; Ilyinichna, G.E.; Fouladnia, F.; Sh.Daoud, M.; Ilyas, V.P.T.; Shukla, N.K.; Habeeb, M.S.; Alhashim, H.H. An artificial neural network and a combined capacitive sensor for measuring the void fraction independent of temperature and pressure changes for a two- phase homogeneous fluid. *Flow Measurement and Instrumentation*, v. 93, 2023. <https://doi.org/10.1016/j.flowmeasinst.2023.102406>.pp. 102406
- [55] Chen, T.-C.; Taylan, O.; Alizadeh, S.M.; Yilmaz, M.T.; Nazemi, E.; Balubaid, M.; Roshani, G.H.; Karaboga, D. Investigation of Time-Domain Feature Selection and GMDH Neural Network Application for Determination of Volume Percentages in X-Ray-Based Two-Phase Flow Meters. *MAPAN*, v. 38, n. 1, p. 119-131, 2023.
- [56] Iliyasu, A.M.; Benselama, A.S.; Bagaudinovna, D.K.; Roshani, G.H.; Salama A.S. Using Particle Swarm Optimization and Artificial Intelligence to Select the Appropriate Characteristics to Determine Volume Fraction in Two-Phase Flows. *Fractal and Fractional*, v. 7, n. 4, 2023. Disponível em: <https://doi.org/10.3390/fractfrac7040283>
- [57] Roy, B.K. A practically validated intelligent calibration technique using optimized ANN for ultrasonic flow meter. *International Journal on Electrical Engineering and Informatics*, v. 7, n. 3, p. 379-393, 2015.
- [58] Shaban, H.; Tavoularis, S. Measurement of gas and liquid flow rates in two-phase pipe flows by the application of machine learning techniques to differential pressure signals. *International journal of multiphase flow*, v. 67, p. 106-117, 2014.
- [59] Hasanzadeh, M.; Bernetti, S. Predicting oil flow rate due to multiphase flow meter by using an artificial neural network. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, v. 37, n. 8, p. 840-845, 2015.
- [60] Al-Qutami, T.A.; Ibrahim, R.; Ismail, I.; Ishak, M.Z., 2017. Development of soft sensor to estimate multiphase flow rates using neural networks and early stopping. *International Journal on Smart Sensing & Intelligent Systems*, 10(1), p. 1-24.
- [61] Nazemi, E.; Feghhi, S.A.H.; Roshani, G.H. Void fraction prediction in two-phase flows independent of the liquid phase density changes. *Radiation measurements*, v. 68, p. 49-54, 2014.
- [62] Liu, J.; Wang, A. Application of RBF neural network to ultrasonic holdup measurement for water-oil two phase flow. Dynamics of Continuous, Discrete and Impulsive Systems Series B: Applications and Algorithms. In: Conference: International Conference on Complex Systems and Applications, v. 13, 2006.

## CAPÍTULO 2

# CONCEITOS BÁSICOS

---

**César Marques Salgado**

**William Luna Salgado**

**Roos Sophia de Freitas Dam**

**Claudio de Carvalho Conti**

## INTERAÇÃO DOS RAIOS GAMA COM A MATÉRIA

Os raios gama interagem com a matéria por meio de três processos principais: efeito fotoelétrico, espalhamento Compton e produção de pares.<sup>1</sup> A probabilidade relativa de ocorrência de cada um desses eventos depende da energia dos fótons e do número atômico do material alvo.

### Efeito Fotoelétrico

O efeito fotoelétrico ocorre quando um fóton interage com um átomo e desaparece completamente, transferindo

toda a sua energia para um elétron fortemente ligado ao átomo (geralmente da camada K). Como resultado, o elétron é ejetado de sua camada com uma energia cinética ( $E_c$ ), conforme descrito pela Equação 1.

$$E_c = h\nu - E_l \quad \text{Equação 1}$$

Em que:

$h\nu$  – Energia do fóton incidente;

$E_l$  – Energia de ligação do elétron orbital.

Para que o elétron seja ejetado, a energia do fóton incidente deve ser maior que a energia de ligação do elétron orbital, um valor conhecido como limiar de absorção. Após a ejeção do elétron, o orbital eletrônico é reorganizado,<sup>2</sup> um processo geralmente acompanhado pela emissão de raios X característicos.<sup>3</sup>

1. Esse modo de interação, conhecido como absorção, resulta na formação de um par elétron-pósitron quando fótons com energia superior a 1.022 MeV interagem com núcleos de número atômico elevado, influenciados pelo forte campo elétrico nuclear. Esse efeito não é considerado nestes estudos, uma vez que as energias envolvidas são inferiores ao limiar necessário para sua ocorrência.

2. A vacância criada durante esse processo é rapidamente preenchida por meio do rearranjo dos elétrons.

3. O termo “característico” refere-se ao fato de que os raios X emitidos serem monoenergéticos, revelando detalhes específicos da estrutura eletrônica do elemento químico.

Esse efeito é predominante em materiais de alto número atômico e em fótons de baixa energia. No entanto, sua probabilidade de ocorrência diminui rapidamente à medida que a energia do fóton aumenta, tornando outros efeitos mais relevantes.

## Efeito Compton

O espalhamento Compton ocorre quando um fóton incidente interage com um elétron fracamente ligado. Durante essa interação, parte da energia do fóton é transferida ao elétron, enquanto o restante é convertido em um fóton de menor energia que emerge em uma direção diferente. A energia transferida ao elétron e ao fóton dependem do ângulo de espalhamento. Como resultado, os elétrons ejetados possuem uma faixa de energias possíveis, criando um espectro contínuo [1]. A probabilidade dessa interação é proporcional à energia do fóton incidente e inversamente proporcional ao número atômico do material.

O espalhamento pode ser classificado em dois tipos principais:

- I. Espalhamento Coerente (Rayleigh): Não há transferência de energia, e o fóton espalhado mantém a energia ( $h\nu$ ) do fóton incidente;
- II. Espalhamento Incoerente (Compton): Uma fração da energia do fóton incidente é transferida para um elétron orbital, resultando em um fóton espalhado de menor energia  $h\nu'$ .

No espalhamento Compton, o fóton espalhado possui energia  $h\nu'$  e direção diferentes do fóton incidente. Sua energia pode ser calculada utilizando equações de conservação de momento e energia, descrita pela Equação 2.

$$h\nu' = \frac{h\nu}{1 + \frac{h\nu}{m_0 c^2} (1 - \cos \theta)} \quad \text{Equação 2}$$

Em que:

$h\nu$  – Energia do fóton incidente (keV);

$\theta$  – Ângulo de espalhamento em relação à direção inicial;

$m_0$  – Massa do elétron em repouso (kg);

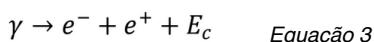
$c$  – Velocidade da luz (m.s<sup>-1</sup>);

$m_0 c^2$  – Energia de repouso do elétron (511 keV).

Nesse processo, o elétron inicialmente considerado estacionário é colocado em movimento, adquirindo energia cinética proporcional à fração da energia transferida pelo fóton incidente.

## Produção de Pares

Quando fótons de energia superior a 1022 keV interagem com o forte campo elétrico nuclear de átomos com número atômico elevado, a radiação eletromagnética é “absorvida” e um par elétron-pósitron é emitido. Esse fenômeno é descrito pela Equação 3.



A energia cinética ( $E_c$ ) do elétron e do pósitron criados é igual à energia do fóton incidente menos 1022 keV, que é a energia necessária para a criação do par de partículas. O espectro de distribuição de energia das partículas formadas é contínuo.

Nos estudos de caso apresentados neste livro, a faixa de energia utilizada está abaixo do limiar para a ocorrência desse fenômeno, e, portanto, o efeito não será abordado com mais detalhes ao longo do texto.

## Seção de Choque

Quando a radiação eletromagnética incide sobre material (atenuador), três processos básicos podem ocorrer:

- I. Espalhamento do fóton: Quando o fóton espalhado tem uma energia igual ou inferior à energia do fóton incidente, no entanto o fóton espalhando possui direção diferente do fóton incidente;
- II. Transmissão do fóton: Quando não ocorre nenhum tipo de interação e a energia do fóton transmitido é igual à do fóton incidente;
- III. Absorção total do fóton: Quando há transferência de toda a energia do fóton incidente para o meio alvo.

Esses três processos estão ilustrados na Figura 1.

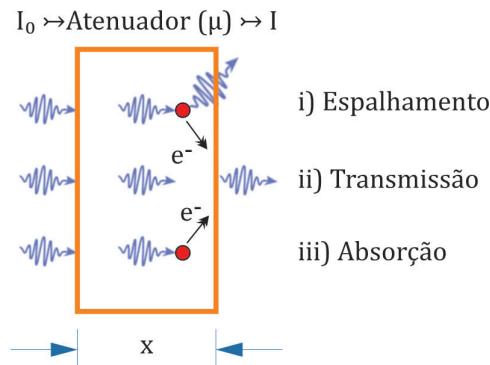


Figura 1 – Esquema ilustrativo dos processos que podem ocorrer quando fótons incidem sobre um atenuador (amostra).

Em que:

$I_0$  – Feixe incidente;

$I$  – Feixe transmitido;

$\mu$  – Coeficiente de atenuação da amostra;

$x$  – Espessura da amostra.

A probabilidade interação por meio do efeito Compton depende da seção de choque e pode ser obtida pela equação de *Klein-Nishina* [2]. O efeito Compton é insignificante quando comparado ao efeito fotoelétrico para energias abaixo de 100 keV, mas aumenta consideravelmente para energias mais altas.

Para energias de fótons incidentes muito maiores que a energia de ligação dos elétrons, o espalhamento Compton prevalece sobre o efeito fotoelétrico. Portanto, para fótons com energias variando de 100 keV a 10 MeV e materiais com número atômico efetivo abaixo de 40, o espalhamento Compton é o principal mecanismo de interação. A probabilidade de ocorrência do espalhamento Compton é diretamente proporcional à energia do fóton e inversamente proporcional ao número atômico. O número de fótons espalhados registrados em um detector pode ser obtido pela Equação 4 [2].

$$S = \Phi_0(E)\varepsilon(E)t \exp\left(-\int_{l_1} \mu(E_\gamma)dl\right) \frac{d_e\sigma^{KN}}{d\Omega} \frac{\rho N_A Z}{A} \exp\left(-\int_{l_2} \mu(E_{\gamma'})dl\right) dV d\Omega \quad \text{Equação 4}$$

Em que:

$t$  – Tempo de contagem (s);

$\Phi_0(E)$  – Fluxo de fótons na energia (E);

$\frac{d_e\sigma^{KN}}{d\Omega}$  – Seção de choque diferencial de *Klein-Nishina* em energia (E) para um elétron livre;

$d\Omega$  – Ângulo sólido do detector;

$\rho$  – Densidade física;

$Z$  – Número atômico;

$N_A$  – Número de Avogadro;

$A$  – Número de massa da amostra em análise;

$\frac{\rho N_A Z}{A}$  – Densidade do elétron, que é proporcional à densidade física;

$\mu(E_\gamma), \mu(E_{\gamma'})$  – Coeficientes de atenuação linear para fótons transmitidos e espalhados, respectivamente, dentro da amostra ( $\text{cm}^{-1}$ );

$\varepsilon$  – Eficiência de contagem do fotópico do detector na energia do fóton espalhado;

$l_1$  – Comprimento do caminho do fóton na amostra desde a fonte até o ponto onde ocorre o centro de espalhamento;

$l_2$  – Comprimento do caminho do fóton dentro da amostra desde o centro de espalhamento até o detector;

$dV$  – Volume diferencial considerado para a radiação e sua interação com a amostra.

No caso de amostras homogêneas e utilização de fonte de radiação puntiforme, os termos das integrais são constantes. Além disso, a seção de choque diferencial de *Klein-Nishina* será constante para uma geometria fixa, uma certa energia de fóton incidente e intensidade de fluxo de fótons. Portanto, a taxa de contagem depende fortemente da densidade da amostra em análise. A variação da densidade de diferentes fluidos, como água e óleo, no interior de tubos pode ser monitorada utilizando o espalhamento.

A faixa de energia de 20 keV a 662 keV é a mais adequada para diferenciar água de óleo, pois os coeficientes de atenuação linear total desses meios apresentam as maiores diferenças nesta faixa de energia, facilitando os cálculos de frações de volume. Em tubulações da indústria de petróleo, o tubo contendo os fluidos pode ser representado por um sistema composto por quatro camadas de amostras com diferentes espessuras e coeficientes de atenuação linear total. A intensidade de um feixe monoenergético de radiação gama transmitida pode ser calculada considerando um feixe *pencil beam* (feixe extremamente colimado), utilizando a Equação 5.

$$I = I_o \cdot \exp{-(\mu_T \cdot C_T + \mu_F \cdot C_F + \mu_S \cdot C_S)} \quad \text{Equação 5}$$

Em que:

$I$  – Feixe transmitido ( $\gamma \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ );

$I_o$  – Feixe incidente ( $\gamma \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ );

$\mu$  – Coeficiente de atenuação para as diferentes amostras ( $\text{cm}^{-1}$ );

$C$  – Espessura da amostra (cm) pela qual a radiação passa ( $T$  – Tubo,  $F$  – Fluidos,  $S$  – Incrustação).

Os coeficientes de atenuação linear total das amostras (materiais e fluidos),  $\mu$ , são calculados utilizando a Equação 6. A intensidade do feixe transmitido  $I$  quando a tubulação contém apenas o fluido “ $m$ ”, pode ser determinada por meio do código matemático Monte Carlo N-Particle, Versão 6 (MCNP6)<sup>4</sup>. Os valores de coeficientes de atenuação linear total, calculados pelo código MCNP6, são posteriormente comparados com dados da literatura<sup>[3]</sup> para validar a precisão dos resultados obtidos.

$$\mu = \ln(I_o/I) \cdot x^{-1} \quad \text{Equação 6}$$

Em que:

$I$  – Intensidade transmitida por raios gama para a amostra desejada ( $\gamma \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ );

$I_o$  – Intensidade inicial de raio gama ( $\gamma \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ );

$\mu$  – Coeficiente de atenuação para as diferentes amostras ( $\text{cm}^{-1}$ );

$x$  – Espessura da amostra (cm).

## DETECÇÃO DA RADIAÇÃO IONIZANTE

Quando a radiação gama interage com um detector, a energia do fóton pode ser totalmente ou parcialmente absorvida, dependendo do processo de interação (efeitos Fotoelétrico, *Rayleigh*, Compton ou Formação de Pares). Essa energia é utilizada para gerar sinais, como luz e portadores de carga, que são registrados eletronicamente como pulsos de carga. A altura de cada pulso é proporcional à energia transferida pelo fóton, e a contagem dos pulsos reflete o número de interações. O tratamento adequado desses

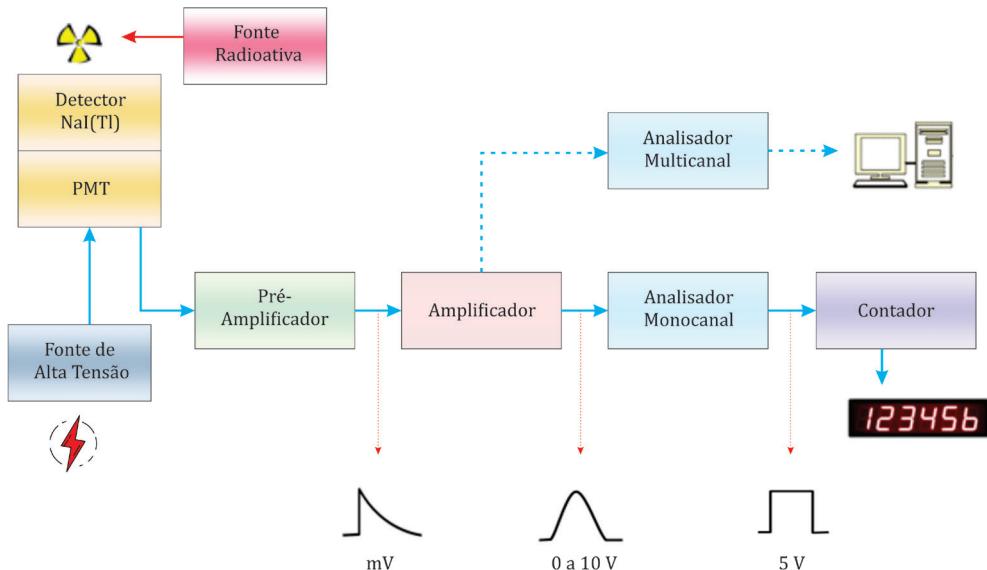
---

4. O método é uma ferramenta de simulação amplamente utilizada para o transporte de radiação, especialmente em situações em que medições físicas são impraticáveis ou inconvenientes.

pulsos permite a obtenção do espectro de energia incidente. Os principais módulos eletrônicos responsáveis por registrar o espectro em detectores cintiladores<sup>5</sup> NaI(Tl) ou em semicondutores formam um sistema de spectrometria composto por:

- I. Pré-amplificador: Sensível à carga, sua função é integrar a carga elétrica gerada pelo detector, convertendo-a em um sinal de tensão proporcional à carga integrada. Além disso, realiza o “casamento de impedâncias” entre o detector e o amplificador, assegurando que o sinal seja adequadamente transferido;
- II. Amplificador: Sua função básica é aumentar a amplitude do sinal proveniente do pré-amplificador, que normalmente é menor que 1,0 V, para faixas de tensão mais convenientes (geralmente de 0 a 10 V). O amplificador também realiza a conformação dos pulsos, otimizando a relação sinal-ruído;
- III. Analisador multicanal (MCA): Este módulo classifica e conta os pulsos de acordo com suas amplitudes, armazenando a contagem de pulsos em canais específicos. Isso é essencial para a spectrometria, quando é necessário categorizar e analisar os sinais gerados;
- IV. Analisador monocanal: Este módulo gera um sinal lógico padrão sempre que o sinal gerado pelo amplificador estiver dentro de uma faixa específica de valores. Pode operar no modo diferencial (janela), em que o sinal precisa estar dentro desta faixa de valores, ou no modo integral, onde o sinal é considerado acima de um valor mínimo, sendo usado para a contagem total de interações.

Uma representação esquemática de um sistema de spectrometria é apresentada na Figura 2.



1. Figura 2 – Esquema típico de detecção para um detector cintilador NaI(Tl).

5. Geralmente, o módulo do pré-amplificador, quando se utiliza detectores de NaI(Tl), tem como função realizar o casamento de impedância entre a saída do detector (de alta impedância) e o amplificador, fornecendo uma baixa impedância de saída para a entrada do amplificador.

## **Detektore de Nal(Tl)**

A radiação gama interage com o detector (Nal(Tl)), gerando cintilações de alta intensidade com uma duração na ordem de  $10^{-9}$  segundos, apresentando uma luminosidade excepcionalmente elevada em comparação a outros materiais orgânicos. Esse fenômeno é denominado fluorescência. Para converter a luz emitida em sinal elétrico, utiliza-se uma válvula fotomultiplicadora, composta por um photocatodo<sup>6</sup> que transforma os fótons de luz visível em elétrons, com energia na faixa de 1 a 2 eV. Esses elétrons são focalizados e acelerados em direção aos díodos,<sup>7</sup> colidindo com energia cinética suficiente ( $\sim 100$  eV) para gerar elétrons secundários. Esse processo de multiplicação em cascata resulta em um pulso de corrente quando os elétrons atingem o ânodo da fotomultiplicadora (*Photomultiplier – PMT*). O pulso é coletado com intensidade apropriada para processamento em um sistema de espectrometria gama, permitindo análises precisas da radiação incidente.

A produção dos fótons de luz visível no cristal de Nal(Tl) é proporcional à energia da radiação gama incidente. Essa proporcionalidade é mantida no número de elétrons convertidos, o que permite que o sinal de corrente gerado pela fotomultiplicadora seja razoavelmente linear em uma ampla faixa de energias de raios gama. Dessa forma, a amplitude do sinal elétrico produzido pode ser relacionada diretamente à energia pelo cristal. Entretanto, a eficiência de detecção varia conforme a energia da radiação incidente e o material cintilador utilizado.

Os sistemas de detecção baseados em cintiladores, como o Nal(Tl), oferecem várias vantagens importantes, destacando-se:

- I. Alta eficiência de contagem: O iodo, com número atômico elevado ( $Z = 53$ ) e densidade de  $3,667 \text{ g.cm}^{-3}$ , confere ao detector de Nal(Tl) uma alta eficiência de absorção de radiação. Isso resulta em uma boa relação entre os eventos de absorção total e Compton;
- II. Flexibilidade construtiva: O Nal(Tl) pode ser construído em cristais grandes e é fácil de usinar, permitindo sua adaptação a diferentes geometrias e aplicações específicas;
- III. Praticidade e baixo custo: Não exige refrigeração para operação e apresenta custos relativamente baixos, tanto de aquisição quanto de manutenção, o que o torna amplamente acessível para diversas aplicações.

## **Detektore de Germânio Planar (HPGe)**

Os detectores de germânio planar<sup>8</sup> (HPGe) representam o estado da arte em espectrometria de gama e raios X, especialmente em aplicações como raios X de diagnóstico (RXD). Sua estrutura esquemática é ilustrada na Figura 3 .

6. Uma película de semicondutor de espessura muito reduzida, da ordem de nanômetros.

7. Uma série de eletrodos que liberam um número maior de elétrons do que os que neles incidem. Uma diferença de potencial é aplicada entre díodos subsequentes.

8. A denominação planar refere-se ao campo elétrico gerado e não à forma física do detector.

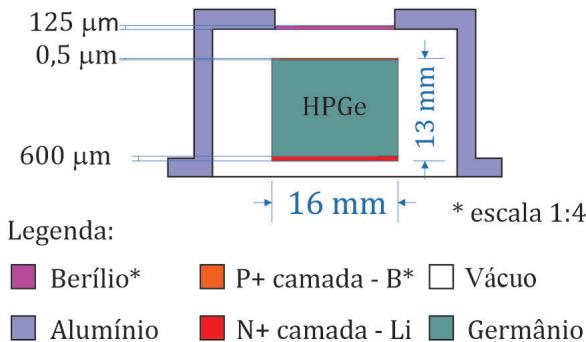


Figura 3 – Estrutura de um detector HPGe Planar.

A superfície superior do cristal de germânio contém uma camada fina e altamente dopada, denominada camada P+, com espessura aproximada de 0,5 mm. Essa camada é rica em buracos e geralmente obtida por implantação de íons de boro. A superfície oposta possui uma camada N+, rica em elétrons e obtida, normalmente, por difusão de lítio. Esta camada é significativamente mais espessa, cerca de 600 mm. Ambas as camadas atuam como contatos ôhmicos, permitindo a aplicação da tensão de polarização ao cristal.

Embora condutoras, essas camadas P+ e N+ não são sensíveis à radiação ionizante, sendo denominadas de “camadas mortas”. Logo abaixo delas encontra-se uma camada de transição, formada pelo próprio germânio intrínseco, onde o campo elétrico não alcança a intensidade necessária para a coleta eficiente de cargas. Nessa camada, a detecção é parcial e inconsistente. Devido ao número atômico elevado do germânio, essa camada tem uma probabilidade significativa de interação com a radiação incidente, contribuindo para o contínuo da região Compton [4]. As camadas mortas e de transição desempenham um papel crucial na detecção de radiações de baixa energia, pois atenuam o feixe incidente e diminuem a eficiência do sistema de detecção. Os detectores HPGe com geometria planar possuem:

- I. Excelentes propriedades de transporte de portadores de carga, permitindo a coleta eficiente das cargas geradas pelas interações da radiação;
- II. Alta eficiência para radiações de baixa energia, sendo ideais para raios X na faixa de 20 a 150 keV;
- III. Excelente resolução energética, alcançando valores como 0,9 keV em 122 keV, devido à baixa capacidade proporcionada por essa geometria em relação ao volume do detector.

A utilização de uma janela extremamente fina de berílio, aliada a camadas “mortas” delgadas, possibilita que os detectores de germânio planar (HPGe) sejam especialmente eficazes na medição de radiações de baixa energia, como os raios X utilizados em diagnósticos médicos, na faixa de 20 a 150 keV. Essa configuração aprimora a consistência dos resultados e reduz ligeiramente as incertezas quando comparada à geometria coaxial [1].

Apesar da necessidade de operar em temperaturas criogênicas utilizando nitrogênio líquido, os detectores HPGe podem ser armazenados à temperatura ambiente fora dos períodos de operação, sem prejuízo às características ou desempenho. Isso os torna robustos e confiáveis para aplicações em espectrometria de raios X de alta precisão.

## Eficiência de detecção

Nem todas as partículas emitidas por uma fonte radioativa emissora de fótons interagem com o volume sensível do detector. Por essa razão, é essencial estabelecer uma relação entre o número de pulsos registrados pelo detector e o número de pulsos efetivamente incidentes sobre ele.

A eficiência de detecção representa a capacidade de um detector em registrar fótons que incidem sobre sua superfície. Essa eficiência é influenciada por diversos fatores:

- I. Energia do fóton: Fótons de maior energia têm maior capacidade de penetração, o que reduz a probabilidade de interação com o volume sensível do detector;
- II. Características do sistema de contagem: Inclui a geometria e a distância entre a fonte e o detector;
- III. Propriedades físicas do cristal cintilador: Dimensões, densidade e opacidade do material cintilador são determinantes.

A eficiência de detecção diminui com o aumento da energia dos fótons devido à maior penetração e ao tamanho limitado do detector. Os principais tipos de eficiência em detectores de raios gama incluem:

- I. Eficiência absoluta: É a razão entre o número de sinais registrados pelo detector e o número de raios gama emitidos pela fonte;
- II. Eficiência intrínseca: É a razão entre o número de sinais registrados pelo detector e o número de raios gama que incidem diretamente no detector.

As eficiências também podem ser classificadas em dois tipos:

- I. Eficiência total: Considera todos os pulsos registrados pelo detector, independentemente de estarem relacionados à absorção total ou parcial da energia do fóton incidente;
- II. Eficiência de fotópico: Considera apenas os pulsos correspondentes à absorção total da energia do fóton incidente.

Quando a fonte radioativa é posicionada próxima ao detector, a eficiência absoluta de fotópico pode ser determinada utilizando a Equação 7.

$$\varepsilon(E) = \frac{C}{t \cdot A \cdot P \cdot k} \quad \text{Equação 7}$$

Em que:

C – Número de contagens registradas no detector na região de absorção total fotópico;

t – Tempo de contagem (s);

A – Atividade da fonte radioativa (Bq);

P – Probabilidade de emissão de raios gama na energia “E”;

k – Fator de correção da meia-vida.

A incerteza padrão da eficiência é calculada utilizando a Equação 8, desconsiderando as incertezas relacionadas ao tempo de contagem, à probabilidade de emissão e ao fator de correção de decaimento, visto que estes valores são muito pequenos para impactar significativamente o cálculo.

$$\sigma_{\varepsilon} = \sqrt{\left(\frac{\partial \varepsilon}{\partial C} \cdot \sigma_C\right)^2 + \left(\frac{\partial \varepsilon}{\partial A} \cdot \sigma_A\right)^2}$$

Equação 8

Em que:

$\sigma_C$  – Incerteza associada ao número de contagens;

$\sigma_A$  – Incerteza associada à atividade da fonte radioativa.

## Resolução em Energia

Uma das principais características de um detector de radiação é sua resolução energética,<sup>9</sup> ou seja, a capacidade de discriminar ou resolver duas ou mais energias próximas no espectro de energia. Quando há necessidade de identificar uma grande quantidade de fotópicos, os detectores de germânio hiper puros (HPGe) são os mais indicados, principalmente em altas energias, sendo discutidos em detalhes em seção posterior deste livro. A determinação da resolução energética é fundamental para simular detectores de forma mais realista. A resolução de um detector é influenciada principalmente pelos seguintes fatores:

- I. Flutuação estatística do número de cargas coletadas;
- II. Ruído eletrônico, tanto da eletrônica associada quanto no próprio detector (corrente de fuga);
- III. Corrente de fuga;
- IV. Coleta incompleta de cargas.

Nos detectores de NaI(Tl), as flutuações no número de cargas coletadas no ânodo da fotomultiplicadora decorrem de variações estatísticas, principalmente do número de elétrons liberados no fotocatodo durante a conversão dos fótons de luz visível em elétrons. Esse fenômeno é o principal responsável pelo alargamento do fotópico, resultando em uma linha espectral mais larga.

9. Possui baixa resolução energética em comparação com detectores de germânio, os quais são utilizados, por exemplo, na identificação de radionuclídeos.

A região de absorção total no espectro de energia apresenta, normalmente, uma distribuição Gaussiana.<sup>10</sup> Para maior precisão, a medição é realizada no pico de absorção total (fotopico), conforme ilustrado na Figura 4. Nesse exemplo, a resolução energética do detector para a energia de 50 keV é de 4,7%.

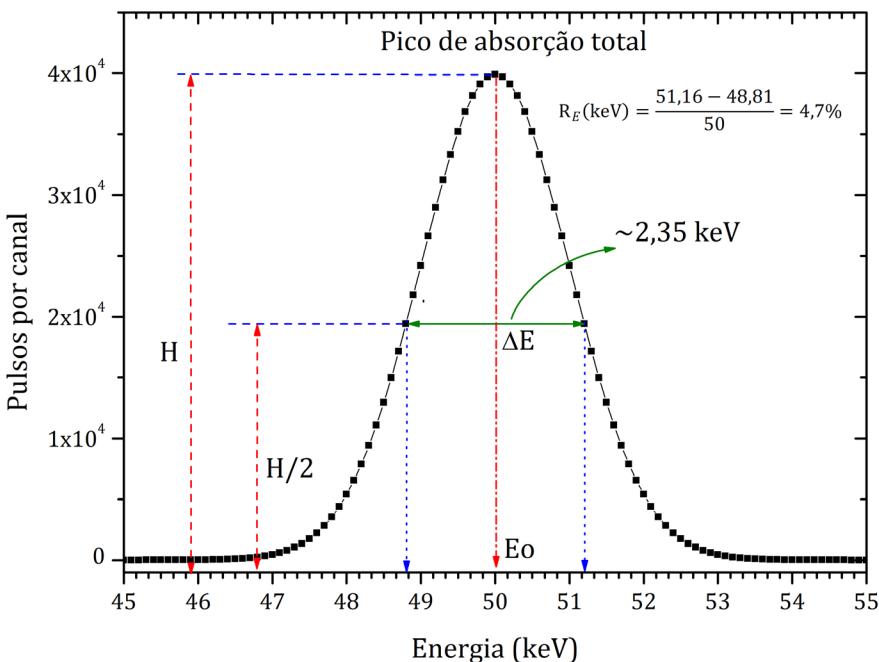


Figura 4 – Resolução em energia e simetria do fotopico.

Na prática, a resolução em energia ( $R_E$ ) de um pico de absorção total é determinada utilizando-se a largura total à meia altura (FWHM) do pico Gaussiano, acima da linha de base de radiação de fundo [5]. Essa largura já inclui todos os efeitos que causam o alargamento do pico, sendo dividida pela energia do fóton incidente, conforme a Equação 9.

$$R_E = \frac{\Delta E}{E_0} \Rightarrow R_E = \frac{FWHM}{E_0} \quad \text{Equação 9}$$

Em que:

FWHM – Largura total à meia altura do pico de absorção total (eV);

$E_0$  – Energia do fóton incidente (eV).

A resolução energética de detectores cintiladores de NaI(Tl) é usualmente reportada para raios gama de 661,66 keV, emitidos pela fonte de  $^{137}\text{Cs}$ . Para detectores cilíndricos de 3"x3", a resolução típica situa-se na faixa de 7,5% a 8,5%, valores facilmente alcançados por equipamentos comerciais [6].

10. Quando se representa o número de pulsos em função da energia de um feixe monoenergético, observa-se um pico gaussiano, centralizado na energia do feixe, denominado pico de absorção total. Isso ocorre porque a geração de cargas no detector segue a lei de Poisson, cuja média depende do número de cargas coletadas e das características do material do detector.

Em aplicações de campo, onde as condições ambientais podem ser adversas, é essencial utilizar detectores robustos e operáveis em temperatura ambiente. Além disso, a alta eficiência de detecção é desejável para permitir o uso de fontes de radiação menos intensas, minimizando os requisitos de blindagem e proteção radiológica. Por esses motivos, o detector cintilador de NaI(Tl) será o foco dos estudos de caso apresentados neste livro.

A resolução energética de um detector influencia diretamente o alargamento da Distribuição de Altura de Pulses (DAP) (*Pulse height distribution* – PHD), sendo mais evidente na região de absorção total (fotópico), como ilustrado na Figura 5.

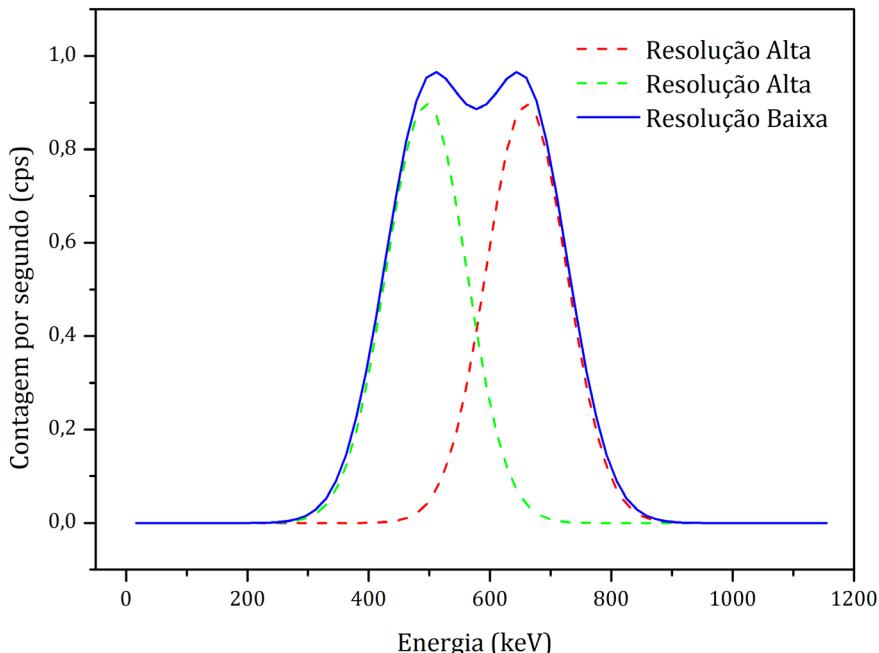


Figura 5 – Resolução típica de um detector de NaI(Tl) (curva azul) caracterizada pela baixa resolução, em comparação com um detector de alta resolução.

Detectores de alta resolução são recomendados para análises espectrométricas detalhadas. Especificamente em detectores de NaI(Tl), a resolução em energia é prejudicada por flutuações no número de cargas coletadas no ânodo da fotomultiplicadora, que, por sua vez, são influenciadas pelas variações no número de elétrons secundários gerados nos díodos e no número de fotoelétrons liberados no fotocatodo. A Figura 6 ilustra exemplos comparativos de fotópicos com alta e baixa resolução.

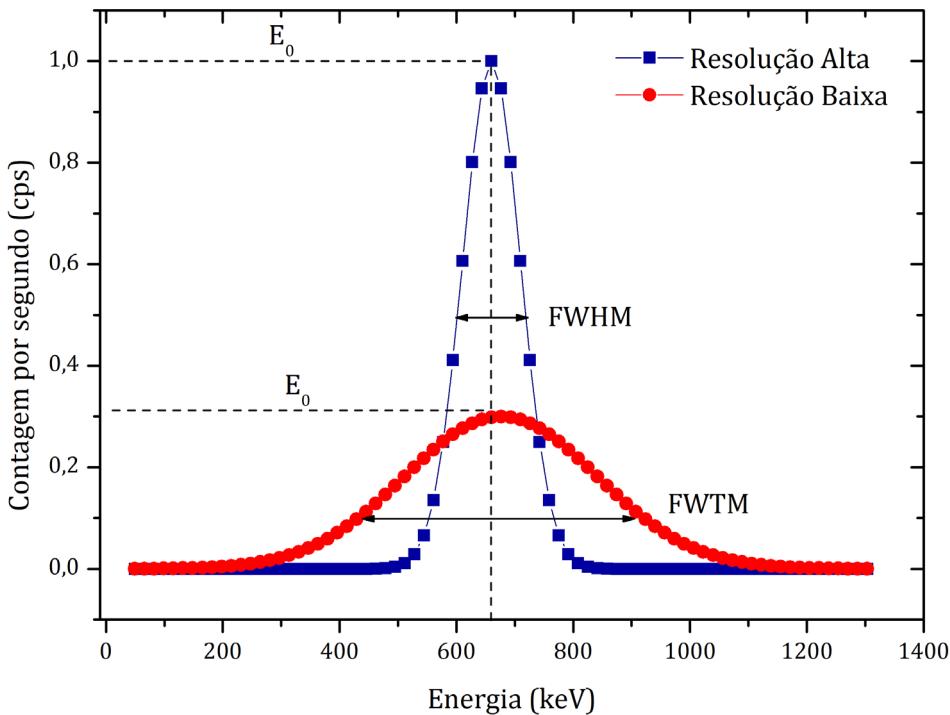


Figura 6 – Comparação de FWHM para detectores com diferentes resoluções.

## ESPECTROMETRIA DE FEIXES DE FÓTONS

A Distribuição de Altura de Pulses (DAP) representa os diferentes processos de interação da radiação com um detector específico. Durante a medição, efeitos indesejáveis podem ocorrer, especialmente quando a energia da radiação não é totalmente absorvida pelo detector, como é o caso dos picos de escape.<sup>11</sup> Além disso, a eficiência do detector varia com a energia da radiação incidente, o que requer a realização de correções na DAP para obter um espectro “real” de energia.

Na Figura 7, é apresentada uma DAP obtida por simulação com o código de computador MCNP6, que simula fótons monoenergéticos de 356 keV incidindo perpendicularmente à superfície de um detector de NaI(Tl) 1"×1". Nesse exemplo, a resolução energética não foi considerada. Caso um fóton de raios X característico seja produzido próximo à parede do cristal do detector, existe a probabilidade deste fóton escapar do volume sensível do detector sem ser absorvido. Esse fenômeno é denominado “efeito escape”. O escape ocorre principalmente nas interações que ocorrem nas superfícies do detector, especialmente para energias abaixo de 40 keV<sup>[7]</sup>. Como resultado, não há absorção total de energia, o que gera o aparecimento de um pico no canal correspondente à diferença entre a energia do fóton incidente e a energia do fóton de raio X característico que foi “perdido”.

11. A probabilidade de interação é maior em detectores com alto número atômico ( $Z$ ), devido ao aumento da probabilidade de interação da radiação na superfície do detector. Isso ocorre porque há uma menor penetração da radiação no cristal, e essa probabilidade não depende das dimensões do detector<sup>[8]</sup>.

A probabilidade do escape é maior em detectores com alto número atômico ( $Z$ ), devido ao aumento da probabilidade de interação da radiação na superfície do detector, o que resulta em uma menor penetração no cristal. Esse efeito não depende das dimensões do cristal [8]. Na Figura 7, pode-se observar o pico de absorção total em 356 keV, bem como os picos de escape localizados à direita da DAP, devido aos efeitos de fluorescência nos átomos do cristal do detector. Os raios X da camada K (a e b) para o iodo são aproximadamente 28 keV e 32 keV. É possível observar, também, um pico de menor intensidade com a energia do fóton incidente subtraída pela energia de 28 keV ( $356 \text{ keV} - 28 \text{ keV} = 328 \text{ keV}$ ), e outro pico de ainda menor intensidade correspondente à subtração de 32 keV ( $356 \text{ keV} - 32 \text{ keV} = 324 \text{ keV}$ ).

Na parte esquerda da DAP, as interações resultantes do efeito Compton. A probabilidade de interações pelo efeito Compton é desprezível para energias abaixo de 100 keV, aumentando consideravelmente à medida que a energia do fóton aumenta [9]. Entre o “joelho” Compton e o fotópico ocorrem os denominados “Compton sucessivos”, que são interações Compton subsequentes originadas por um fóton resultante de um efeito Compton.

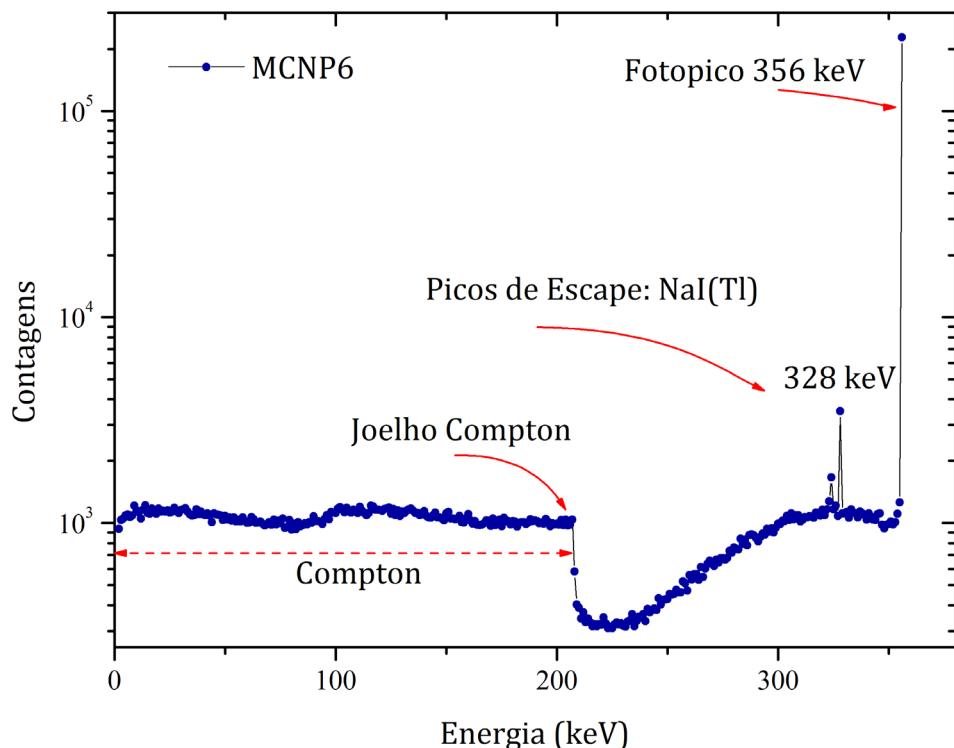


Figura 7 – DAP obtida por simulação com o código MCNP6 para fótons de 356 keV, incidindo perpendicularmente sobre um detector NaI(Tl)  $1'' \times 1''$ .

Outro aspecto importante a ser considerado é a variação de eficiência do detector com a energia da radiação incidente. Isso implica a necessidade de realizar correções na DAP medida para obter um espectro mais preciso. Para tal, é necessário utilizar curvas de resposta do detector e controlar a taxa de fluência incidente sobre o detector, utilizando, por exemplo, colimadores *pinhole*.<sup>12</sup>

Devido à dificuldade de obtenção de fontes padrões na geometria e na faixa de energia necessárias, e à subsequente dificuldade em obter as curvas experimentalmente, uma alternativa é a modelagem matemática do detector, das fontes e da geometria das medições, seguida de validação experimental. Esse procedimento foi utilizado nos estudos de caso neste livro e mostrou-se muito eficaz.

Com o modelo desenvolvido, é possível obter as curvas de resposta desejadas por meio das simulações de Monte Carlo. Com esses dados, a DAP pode ser corrigida utilizando a técnica de desmembramento (*stripping*), quando necessário. As principais correções que podem ser introduzidas na DAP incluem:

- I. Variação da eficiência;
- II. Contagens geradas pelo efeito Compton;
- III. Picos de escape.

## PROCESSO DE GERAÇÃO DOS RAIOS X

Os raios X são radiação eletromagnética que cobrem uma ampla faixa de energia (desde décimos de keV até alguns GeV) e pode ser gerada, basicamente, de duas formas:

- I. Desaceleração brusca de partículas carregadas (radiação de *bremsstrahlung*);<sup>13</sup>
- II. Reorganização da distribuição dos elétrons nas camadas eletrônicas dos átomos (raios X característicos).

### Radiação de freamento (*bremsstrahlung*)

Esse fenômeno envolve a emissão de radiação quando partículas carregadas aceleradas, em geral elétrons, se aproximam de núcleos de elementos com número atômico elevado e interagem com seus campos coulombianos.<sup>14</sup> Nessa interação, os elétrons podem reduzir sua energia cinética, emitindo a diferença de energia sob a forma de ondas eletromagnéticas, denominadas raios X de freamento ou *bremsstrahlung*. A energia destes raios X pode variar desde valores próximos a zero até um valor máximo, que é igual à energia cinética ( $E_c$ ) da partícula incidente. Portanto, o espectro de energia desses raios X é de natureza contínua.

12. Colimador Pinhole: trata-se de um tipo específico de colimador que estabelece a relação entre a emissão e a detecção dos fótons, controlando a fluência dos feixes de radiação que atingem o detector.

13. Do alemão *bremsen* (frear) + *strahlen* (irradiar).

14. Atração da carga do núcleo e repulsão dos elétrons dos átomos do material, resultando em interação com campos elétricos.

## Raios X característicos

Esse fenômeno envolve átomos que foram submetidos a um processo de ionização, isto é, interagiram com partículas ou fótons incidentes com energia suficiente para retirar um elétron de uma camada eletrônica mais interna, criando uma vacância e gerando uma condição de instabilidade no átomo. Como o átomo tende a retornar à sua condição estável, um elétron de uma órbita mais externa desloca-se para preencher a vacância, resultando numa diminuição da energia potencial do elétron. O excesso de energia do elétron é liberado por meio da emissão de radiação eletromagnética, cuja energia é igual à diferença das energias de ligação entre as camadas correspondentes. Essa radiação emitida é denominada raio X característico<sup>15</sup> e é conhecida também como fluorescência de raios X. Na Figura 8 é apresentada uma representação gráfica desse efeito. É interessante ressaltar que esses fótons podem ainda deslocar outro elétron do átomo, denominado elétron Auger. O preenchimento da vacância pode ocorrer por meio de uma única transição, resultando em um único fóton emitido, ou de múltiplas transições, com a emissão de vários fótons de raios X característicos de menor energia. Em um espectro, os raios X característicos são mostrados como linhas de energia discretas e, desta forma, o espectro de distribuição em energia dos raios X característicos é de natureza discreta e específica do elemento químico.

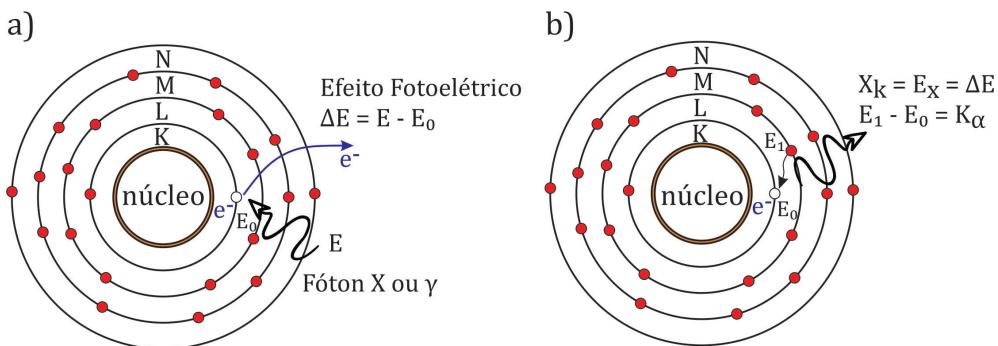


Figura 8 – Representação gráfica dos raios X característicos: a) Um elétron é ejetado; b) Um elétron de uma camada acima preenche a vacância.

Por se tratar de um fenômeno que ocorre pela transição dos elétrons de um átomo, a energia de um fóton de raios X característico é igual à diferença de energia entre os níveis eletrônicos, ou seja, a diferença das energias de ligação dos elétrons envolvidos na transição, que variam de alguns eV a dezenas de keV. Os fatores mais influentes na probabilidade de emissão de raios X característicos são o número atômico do elemento e a camada eletrônica preenchida na transição.

15. O termo “característico” refere-se ao fato de que os raios X emitidos serem monoenergéticos e fornecem detalhes sobre a estrutura eletrônica do elemento químico. Dessa forma, sua energia e intensidade relativa possibilitam a identificação do material por meio de uma amostra, sem que seja necessário destruí-la, já que cada material possui um conjunto exclusivo e específico de níveis de energia e intensidades relativas.

Os raios X característicos são rotulados pelas letras K, L, M ou N que denotam a camada para a qual o elétron se “moveu”, seguidas das letras gregas  $\alpha$ ,  $\beta$ ,  $\gamma$ , que definem a camada onde se ocorreu a transição de um elétron. Consequentemente, um fóton de raios X  $K\alpha$  é produzido por uma transição de um elétron da camada L para a camada K, e um fóton de raios X  $K\beta$  é produzido por uma transição de um elétron da camada M para uma camada K. Visto que dentro das camadas existem múltiplas órbitas (exceto na camada K) com elétrons de maior e menor energia de ligação, a designação  $\alpha_1$ ,  $\alpha_2$  ou  $\beta_1$ ,  $\beta_2$  etc., é feita para denotar transições de elétrons dessas órbitas para uma mesma camada mais interna. Na Figura 9, é apresentada de forma esquemática a sequência dos níveis energéticos dos elétrons, com algumas transições eletrônicas permitidas.

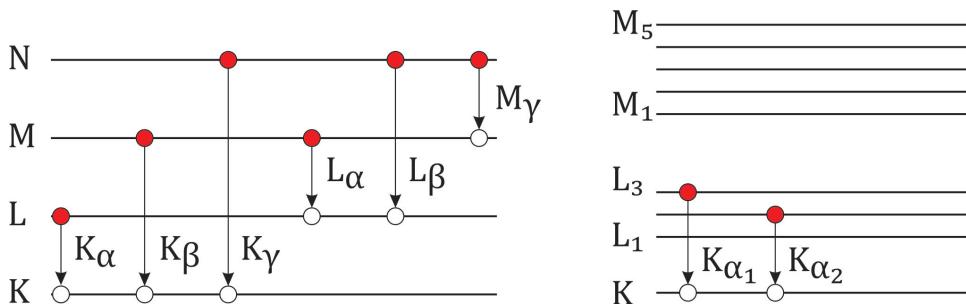


Figura 9 – Diagrama dos níveis de energia com as transições eletrônicas geradoras de raios X característicos.

## Máquina de Raios X

Uma máquina de raios X é constituída basicamente por um tubo de raios X e uma fonte de alta tensão. O tubo é composto por um ânodo, um alvo metálico, um cátodo e um filamento de tungstênio em forma de espiral, tudo dentro de um recipiente lacrado sob alto vácuo. Os raios X são produzidos quando um feixe de elétrons é acelerado por um campo elétrico intenso da alta voltagem aplicada entre os terminais do tubo de raios X. Os elétrons são gerados por emissão termo iônica, através do aquecimento do filamento pela corrente elétrica. Esses elétrons são acelerados proporcionalmente à tensão aplicada e colidem com o alvo<sup>16</sup> metálico, convertendo energia cinética em radiação térmica e eletromagnética. De 95% a 99% da energia cinética dos elétrons incidentes é convertida em calor e o restante é convertido em radiação eletromagnética. Desses, 10% é raio X característico e 90% é *bremsstrahlung*. É importante ressaltar que quanto maior a tensão aplicada ao tubo, maior será energia dos raios X gerados, e maior será o aquecimento do material alvo. Um diagrama esquemático de um tubo de raios X com seus principais componentes é mostrado na Figura 10.

16. Geralmente, utiliza-se o tungstênio, pois a eficiência na produção de raios X está relacionada ao elevado número atômico ( $Z=74$ ). Além disso, o tungstênio possui um alto ponto de fusão ( $3370^{\circ}\text{C}$ ), o que lhe confere resistência ao calor intenso gerado no alvo durante o bombardeio eletrônico.

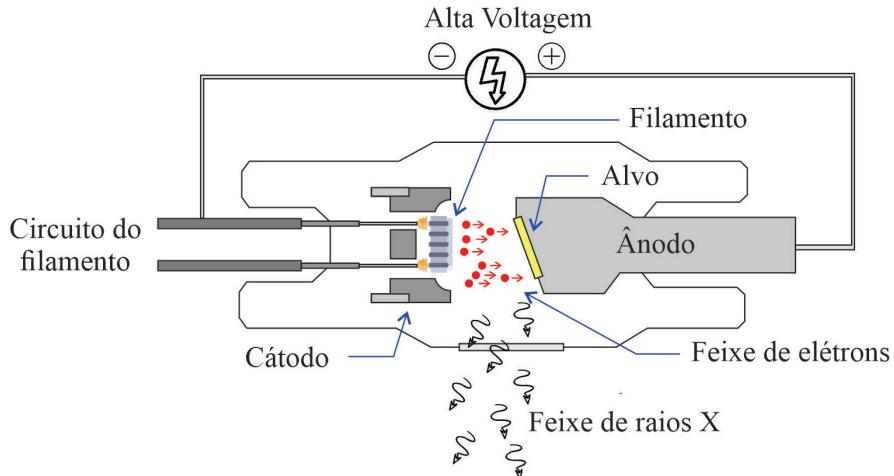


Figura 10 – Diagrama esquemático básico de uma máquina de raios X.

A faixa de energia dos raios X produzidos dessa maneira pode variar de valores próximos a zero até um máximo correspondente à alta tensão aplicada, resultando em um espectro contínuo. A intensidade do fluxo de fôtons de raios X gerada é influenciada pelo número atômico do alvo, pela corrente elétrica e pela tensão de pico aplicada ao tubo, sendo descrita pela fórmula de Beatty<sup>[10]</sup>. Essa fórmula indica que a intensidade do fluxo de fôtons de raios X aumenta proporcionalmente com o aumento do número atômico do alvo, da corrente elétrica e do quadrado da tensão aplicada. Na Figura 11, é apresentado um espectro de um alvo de tungstênio, com angulação do alvo de 20°, filtração inerente de 1,0 mm de berílio e 1,0 mm de tubo de raios X de alumínio. É possível observar a radiação *bremsstrahlung* e os raios X característicos. O espectro de energia mostra as linhas K de 57,97 keV ( $K\alpha_2$ ), 59,31 keV ( $K\alpha_1$ ), 67,23 keV ( $K\beta_1$ ) e 69,09 keV ( $K\beta_2$ ) e a linha L de 11,28 keV<sup>[11]</sup>.

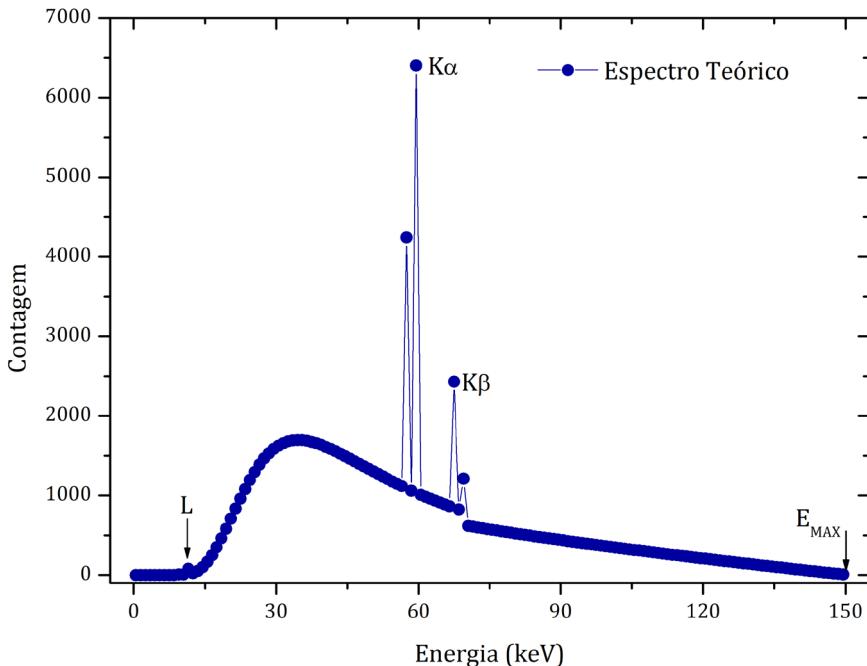


Figura 11 – Espectro teórico de um feixe de raios X.

## FUNDAMENTOS DO ESCOAMENTO MULTIFÁSICO

O escoamento multifásico<sup>17</sup> é definido como o movimento simultâneo de dois ou mais fluidos imiscíveis com propriedades distintas em uma tubulação, duto etc. Quando as fases líquida e gasosa escoam juntas, organizam-se em configurações interfaciais características, ou seja, ocorre uma distribuição<sup>18</sup> espacial específica das fases no interior da tubulação. Essa organização é influenciada por três fatores principais:

- I. Condições operacionais: Vazão, pressão, temperatura, velocidade, entre outros;
- II. Geometria da tubulação: Dimensão, inclinação, forma, entre outros;
- III. Propriedades das fases: Densidade, viscosidade entre outras características.

Essas variáveis determinam padrões específicos de configurações interfaciais, conhecidos como regimes de fluxo, que influenciam diretamente o comportamento predominante do escoamento. No caso de fluxos bifásicos (líquido e gás) em tubulações horizontais, os principais regimes de fluxo, descritos por Taitel e Dukler (1976)<sup>[12]</sup> e ilustrados na Figura 12, são:

17. A definição de fase não está relacionada ao estado da matéria (sólido, líquido, gasoso, plasma), mas sim ao número de interfaces presentes no escoamento multifásico. Por exemplo, um escoamento bifásico implica a presença de uma interface, que pode ser do tipo líquido-líquido imiscível ou líquido-gás.

18. O padrão de fluxo depende principalmente das velocidades do gás e do líquido, bem como da relação entre o conteúdo de gás e líquido.

- I. Estratificado (*stratified flow*): Ocorre em baixas velocidades de líquido e gás. Caracteriza-se pela separação gravitacional das fases, com escoamento contínuo e separado de cada uma;
- II. Estratificado ondulado (*stratified wavy flow*): Com o aumento da velocidade do gás, ondas se formam na interface entre o líquido e o gás, gerando o regime ondulado;
- III. Golfadas (*slug flow*): Com o aumento adicional da velocidade do gás, bolhas ocupam toda a seção transversal da tubulação, formando golfadas, alternadas de gás e líquido, sendo que a fase líquida frequentemente transporta pequenas bolhas dispersas;
- IV. Bolhas alongadas (*elongated bubble flow*): Velocidades ainda maiores do gás promovem a coalescência<sup>19</sup> de bolhas, resultando em bolhas alongadas que escoam na parte superior da tubulação;
- V. Bolhas (*bubbly flow*): Para altas velocidades do líquido e baixas proporções de gás, o gás se dispersa em pequenas bolhas dentro do líquido, concentrando-se no topo devido à gravidade;
- VI. Anular (*annular flow*): Em velocidades muito mais altas de gás, o líquido forma um filme na superfície interna da tubulação, enquanto o gás flui pelo centro, arrastando gotículas de líquido.

---

19. O fenômeno de crescimento de uma gotícula de líquido ocorre pela incorporação de outras gotículas com as quais entra em contato, aumentando sua massa.

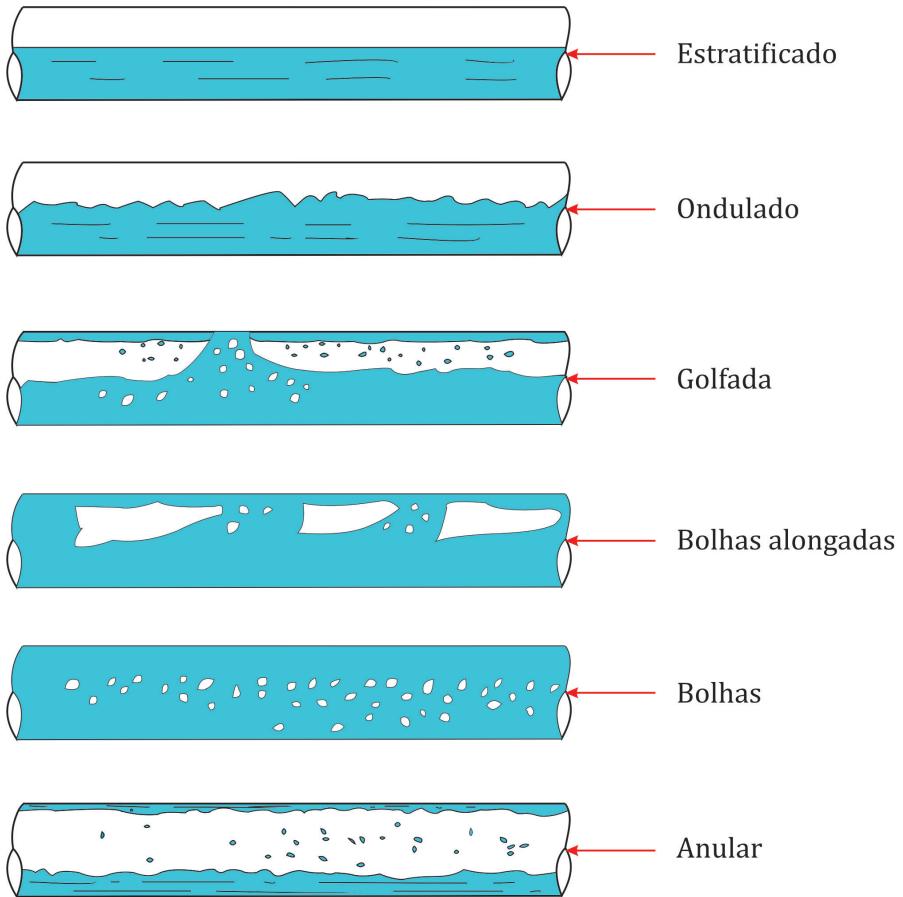


Figura 12 – Regimes de fluxo multifásico em tubulações horizontais.

No caso de escoamento vertical ascendente (*upward*), o regime estratificado desaparece, e surgem novos padrões, incluindo o regime transição ou caótico. Os principais regimes de fluxo vertical ascendente também descritos por Taitel e Dukler (1976) <sup>[12]</sup> e ilustrados Figura 13, são:

- I. **Bolhas (bubbly flow)**: O gás se dispersa em pequenas bolhas na fase líquida contínua, tipicamente em baixas velocidades superficiais de gás;
- II. **Golfada: (slug flow)**: Com o aumento da velocidade do gás, as bolhas pequenas coalescem, formando grandes (bolhas de Taylor) que ocupam quase toda a seção da tubulação, gerando uma sucessão de golfadas de gás e líquido;
- III. **Caótico ou Transição (churn flow)**: Com velocidades maiores de gás e líquido, o padrão torna-se instável e desordenado, caracterizado por movimentos oscilatórios do líquido para cima e para baixo;
- IV. **Anular (annular flow)**: O líquido forma um filme na periferia da tubulação, enquanto o gás escoa pelo centro, arrastando gotículas de líquido.

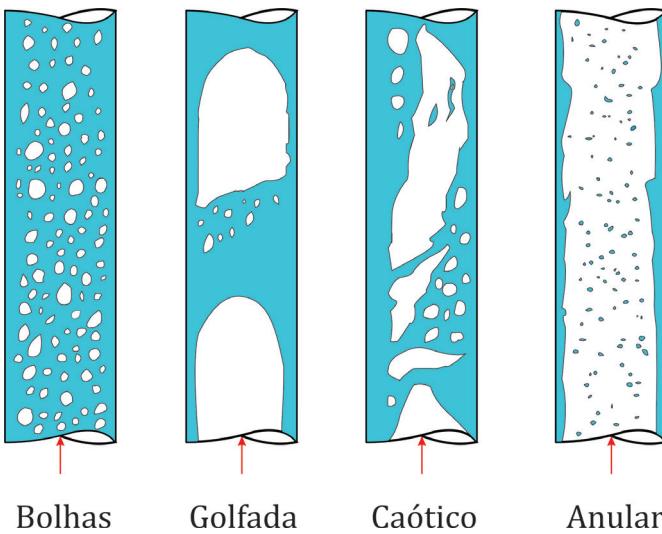


Figura 13 – Regimes de escoamento em tubulações verticais.

Os padrões observados em sistemas multifásicos que envolvem óleo, água e gás são qualitativamente semelhantes aos sistemas líquido-gás. Contudo, as condições específicas para o estabelecimento de cada regime podem variar em função das propriedades dos fluídos envolvidos [13].

O escoamento multifásico é comum em diversas aplicações industriais, como na geração de energia elétrica e na indústria petrolífera. Por exemplo, em usinas termelétricas, a mistura de vapor e água ocorre durante a geração de vapor. Na produção de petróleo *offshore*, que geralmente envolve água salgada e gás, o escoamento multifásico está presente em todo o percurso dos fluidos produzidos, desde o reservatório às unidades de separação e refino.

## O MÉTODO DE MONTE CARLO

O Método de Monte Carlo<sup>20</sup> é amplamente utilizado em simulações computacionais para o transporte da radiação, especialmente em situações em que medições experimentais são inconvenientes, impraticáveis, difíceis ou impossíveis de serem realizadas. Por meio de algoritmos matemáticos, esse método permite a simulação de processos estatísticos na área de transporte de radiação, incluindo trajetórias de partículas e interações com a matéria. Essa abordagem utiliza números pseudoaleatórios gerados a partir das distribuições de probabilidade que regem os processos físicos envolvidos, como interação, espalhamento e captura [14].

<sup>20</sup>. O desenvolvimento do Método de Monte Carlo é geralmente atribuído aos cientistas que trabalharam no desenvolvimento das bombas atômicas na década de 1940, no Los Alamos National Laboratory (LANL). O nome “Monte Carlo” faz referência aos cassinos, pois o método envolve a geração aleatória de valores com base em distribuições estatísticas, de maneira análoga a jogos de azar.

Ao simular muitos eventos (ou histórias), o método permite calcular valores médios de grandezas macroscópicas, como fluência de partículas, dose, corrente e energia depositada em superfícies ou regiões específicas da geometria modelada. A literatura oferece uma vasta quantidade de informações sobre o Método de Monte Carlo, abrangendo tópicos, como geração de números randômicos, modelos e simulações [15, 16].

## Código MCNP6

O Monte Carlo *N-Particle versão 6* (MCNP6) [14] é um código computacional robusto baseado no Método de Monte Carlo. Ele é amplamente utilizado na simulação do transporte de radiação, permitindo modelar interações de nêutrons, fôtons e elétrons em diferentes materiais e geometrias. É especialmente útil em aplicações, como proteção radiológica, modelagem de instalações nucleares, detectores e blindagem de radiação. O MCNP6 suporta interações complexas, considerando, por exemplo:

- I. Fôtons: Espalhamento Coerente (*Rayleigh*), Incoerente (Compton), fluorescência de raios X após absorção fotoelétrica, produção de pares com emissão de radiação de aniquilação e radiação de frenagem (*bremssstrahlung*);<sup>21</sup>
- II. Elétrons: Simulação de pósitrons, raios X de captura K e *bremssstrahlung*.

Com sua capacidade de modelar geometrias tridimensionais complexas e sua ampla variedade de opções de entrada, o MCNP6 é reconhecido como ferramenta poderosa, bem documentada e validada. Suas atualizações incorporam o transporte de 34 novos tipos de partículas (prótons, íons leves etc.), ampliam a faixa de energia das partículas simuladas e introduzem novos modelos físicos e técnicas de redução de variância. Além disso, o código inclui atualizações na extensa coleção de seção de choque, ampliando sua precisão e abrangência em simulações de interação entre radiação e matéria [14]. Os intervalos de energia simulados pelo MCNP6 incluem [17]:

- I. Fôtons: 1 keV a 100 GeV;
- II. Elétrons: 1 keV a 1 GeV;
- III. Nêutrons:  $10^{-11}$  a 20 MeV para todos os isótopos e até 150 MeV para alguns isótopos.

A simulação de uma história de fóton segue as etapas descritas por Pani et al., (1987) [18]:

- I. Determinação da distância ( $x$ ) entre interações: Selecionada aleatoriamente conforme a distribuição exponencial de probabilidade (Equação 10);

---

21. Esse fenômeno envolve a emissão de radiação quando partículas carregadas aceleradas se aproximam de núcleos de elementos com número atômico elevado e interagem com seus campos coulombianos. Durante essa interação, os elétrons podem perder energia cinética, emitindo a diferença de energia na forma de ondas eletromagnéticas, conhecidas como raios X de *bremssstrahlung*.

- II. Definição do tipo de interação: Determinada aleatoriamente, com base nas seções de choque dos processos físicos possíveis. Após a interação, uma nova trajetória é calculada;
- III. História do elétron: Se um elétron é gerado, sua trajetória também é simulada.

$$x = \frac{-1}{\mu(\ln A)} \quad \text{Equação 10}$$

Em que:

$\mu$  – Coeficiente de atenuação linear total;

$A$  – Número aleatório.

Cada história termina quando:

- IV. O fóton ultrapassa os limites das regiões da geometria simulada;
- V. A energia do fóton ou do elétron atinge o valor mínimo (energia de corte);
- VI. Toda a energia é completamente absorvida.

O número de histórias especificado no arquivo de entrada determina a precisão e a flutuação estatística dos resultados. A precisão é avaliada pelo erro relativo ( $R$ ), definido como a razão entre o desvio padrão estimado ( $S_{\bar{x}}$ ) e a média ( $\bar{x}$ )<sup>[14]</sup>, ver Equação 11. Em termos simples,  $R$  permite estimar intervalos de confiança sem torno do valor médio. Para reduzir  $R$  pela metade, é necessário quadriplicar o número de histórias ou utilizar técnicas de redução de variância para otimizar o tempo de simulação.

$$R \approx \frac{\sqrt{N}}{N} \quad \text{Equação 11}$$

Em que:

$N$  – Número de histórias.

O MCNP6 também realiza testes estatísticos para avaliar a confiabilidade dos resultados, tornando a análise mais robusta.

O MCNP6 utiliza um arquivo de entrada estruturado em cartões que definem:

- I. Células: Descrevem as regiões geométricas, permitem especificar materiais;
- II. Superfícies: Delimitam as fronteiras entre células (dimensões e posicionamento);
- III. Dados físicos: Configuram as fontes de radiação, parâmetros de interação e condições de simulação.

## Modelo Matemático do Detector NaI(Tl)

O modelo matemático do detector NaI(Tl) foi desenvolvido com base nas características físicas e materiais de um detector real, para utilização no código MCNP6. O cristal de NaI(Tl) foi modelado como um cilindro homogêneo, com dimensões de 31 mm de diâmetro e 19 mm de espessura<sup>[19, 20, 21, 22, 23, 24, 25]</sup>.

Além do cristal, com densidade de  $3,667 \text{ g.cm}^{-3}$ <sup>[19, 21]</sup>, o modelo inclui uma camada refletora de óxido de magnésio ( $\text{MgO}$ ), utilizada para minimizar a perda de luz. Todo o conjunto é encapsulado por uma capa de alumínio, a qual protege o cristal contra danos e impede a absorção de água, dada sua alta hidroscopicidade. A densidade do material refletor foi considerada como  $3,58 \text{ g.cm}^{-3}$ <sup>[22, 23]</sup>, enquanto a do alumínio foi definida como  $2,6989 \text{ g.cm}^{-3}$ <sup>[26]</sup>. Esses materiais são fundamentais no modelo, pois atuam como atenuadores especialmente para fótons de baixa energia. Uma representação esquemática do modelo do detector pode ser vista na Figura 14.

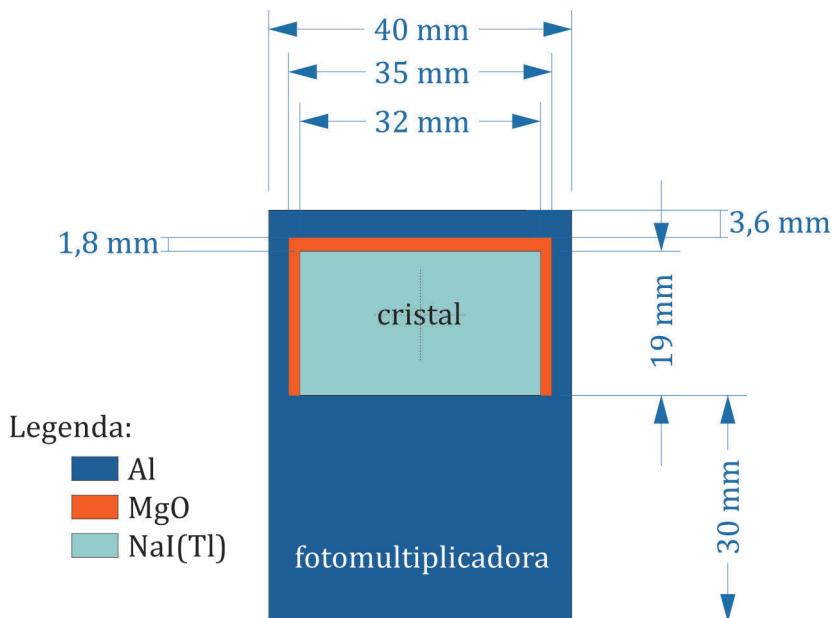


Figura 14 – Diagrama esquemático do modelo matemático do detector NaI(Tl) para o MCNP6.

Além das características já descritas, o modelo matemático do detector NaI(Tl) inclui as seguintes especificidades:

- I. Fotomultiplicadora: Representada como um disco de alumínio de 30 mm de espessura, posicionado atrás do cristal<sup>[24, 27]</sup>;
- II. Transporte de elétrons: Os elétrons gerados no cristal pelo impacto da radiação gama foram desconsiderados na simulação, pois a espessura do cristal garante sua completa absorção;
- III. Interações em baixa energia: Materiais ao redor do cristal foram tratados como atenuadores para fótons de baixa energia<sup>[28]</sup>.

Para tornar o modelo mais realista, foi implementada a resolução energética utilizando o comando *Gaussian Energy Broadening* (GEB) do MCNP6, associado ao cartão de contagem FTn<sup>[14]</sup>. O alargamento espectral foi representado por uma função gaussiana (Equação 12), cujos parâmetros foram determinados experimentalmente.

$$f(E) = C \cdot \exp - \left( \frac{E - E_0}{FWHM/2\sqrt{\ln 2}} \right)^2$$

Equação 12

Em que:

$E$  – Energia “alargada” (MeV);

$E_0$  – Energia “não alargada” (MeV);

$C$  – Constante de normalização (MeV);

$FWHM/2\sqrt{\ln 2}$  – Largura de Gauss (MeV).

Os parâmetros GEB ( $a$ ,  $b$ ,  $c$ ) foram ajustados pela Equação 13 [14], utilizando medições experimentais com fontes calibradas [20, 27]. As interações da radiação de fundo e o espalhamento Compton foram subtraídos para os cálculos corretos.

$$FWHM = a + b\sqrt{E + cE^2}$$

Equação 13

Em que:

$E$  – Energia dos raios gama incidentes (MeV);

$a$ ,  $b$ ,  $c$  – Constantes fornecidas pelo usuário a partir da função de ajuste.

Os valores ajustados para o detector representado na Figura 14 estão apresentados na Tabela 1.

Coeficiente	Valor	Incerteza
$a$	-0,007 MeV	0,002
$b$	0,09 MeV <sup>1/2</sup>	0,02
$c$	-0,18 MeV <sup>-1</sup>	0,04

Tabela 1 – Valores dos coeficientes de ajuste da Resolução

Quando as características físicas do detector não estão documentadas ou conhecidas, a técnica de gamagrafia<sup>22</sup> pode ser utilizada para estimar as dimensões do cristal [20, 27]. No entanto, há diferenças entre o volume real e o ativo do cristal, o que exige ajustes iterativos para determinar sua eficiência. Esses ajustes foram realizados utilizando fontes puntiformes de <sup>241</sup>Am (59,54 keV) e <sup>137</sup>Cs (661,66 keV), conforme descrito por Conti et al. (1999) [4] e Salgado et al. (2012, 2022) [20, 27].

Para a validação do modelo, foi utilizada a curva de eficiência absoluta de fotópico, comparando os resultados simulados com dados experimentais. As simulações utilizaram o comando *F8*<sup>23</sup> do MCNP6, configurado com um número de histórias (NPS) de  $2 \times 10^8$ , resultando em erros relativos inferiores a 5% por canal espectral. A modelagem do detector, conduzida com alta precisão no MCNP6, permitiu calcular a função resposta do sistema com boa concordância com os dados experimentais [4, 29, 30]. As fontes radioativas utilizadas, calibradas pelo Laboratório de Metrologia por Radiação Ionizante (LNMRI) do Instituto de Radioproteção e Dosimetria (IRD), Brasil, estão descritas na Tabela 2. Os dados dessas fontes foram obtidos no aplicativo *Isotope Browser*, versão 5.15.74 Android, IAEA, Nuclear Data Section [31].

22. A gamagrafia é um método de ensaio não destrutivo que consiste na realização de uma radiografia utilizando a radiação gama.

23. Representa uma DAP gerada pelos fótons e elétrons na região sensível do cristal.

Fonte	Energia (keV) **	Meia-vida (ano)	Probabilidade de Emissão (%)	Atividade (Bq)*
<sup>241</sup> Am	59,54	432,60	35,92	28,15
	80,99		33,31	
<sup>133</sup> Ba	302,85	10,55	18,31	17,80
	356,01		62,05	
<sup>137</sup> Cs	661,66	30,08	84,99	22,98
<sup>60</sup> Co	1173,23	5,27	99,85	
	1332,49		99,98	46,078

Tabela 2 – Características das fontes utilizadas para avaliação da resposta do detector

\*Atividade corrigida para a data dos experimentos.

\*\* Valores arredondados para duas casas decimais.

#### *Validação da modelagem do detector de NaI(Tl)*

A modelagem matemática do detector cintilador NaI(Tl) de 1¼" × ¾" foi validada experimentalmente utilizando fontes de calibração listadas na Tabela 2. Desenvolvido no código MCNP6, o modelo foi avaliado com base na curva de eficiência absoluta de fotópico, enquanto a resolução de energia permitiu comparações qualitativas entre as distribuições de altura de pulsos (DAPs) simuladas e experimentais, adotando a mesma geometria experimental.

Para garantir uma modelagem precisa, foi necessário determinar as dimensões reais do cristal por meio da técnica de gamagrafia, ferramenta fundamental para estimar o volume sensível do detector. Após um processo iterativo, as dimensões do cristal que melhor concordaram com os resultados experimentais foram de 11,30 mm de espessura e 26,75 mm de diâmetro, incluindo a representação do disco de alumínio no modelo para considerar os efeitos do tubo fotomultiplicador [24, 27].

Os valores experimentais e simulados da eficiência são apresentados na Figura 15. A incerteza associada à eficiência foi calculada usando a Equação 8, e os resultados mostraram valores abaixo de 0,11% levando em conta a flutuação das contagens e a atividade da fonte.

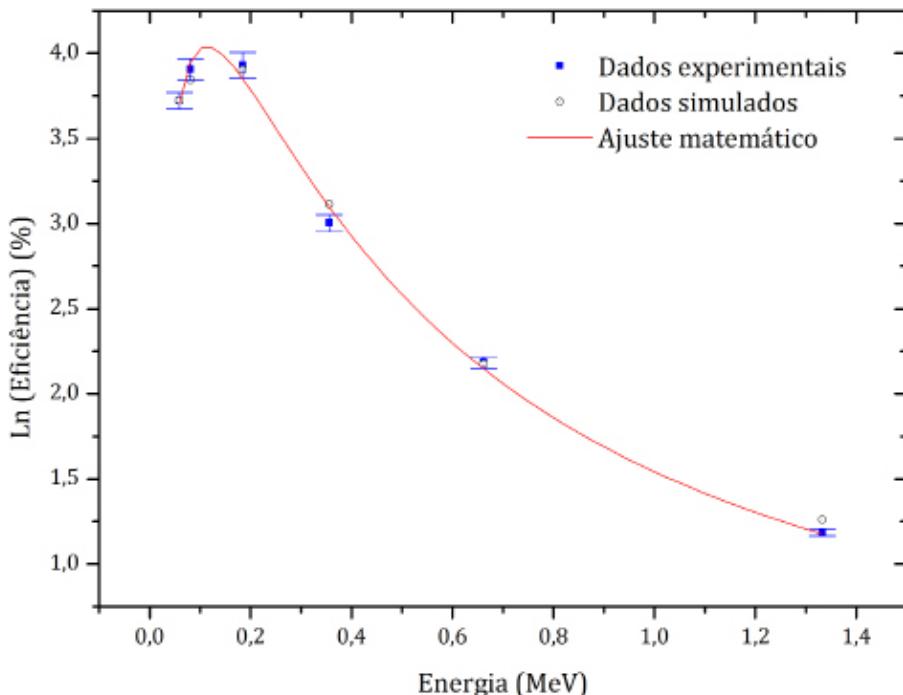


Figura 15 – Curva de eficiência obtida por modelagem matemática, com validação experimental.

Os coeficientes da curva de eficiência foram determinados utilizando o método dos mínimos quadrados com base na Equação 14. Os valores dos coeficientes obtidos estão apresentados na Tabela 3. Os valores experimentais e os obtidos pela modelagem mostraram boa concordância, com um coeficiente de determinação ( $R^2$ ) de 0,997.

$$\varepsilon = x + y \cdot \ln(E) + z \cdot \ln(E)^2 \quad \text{Equação 14}$$

Em que:

$\varepsilon$  – Eficiência (%);

$E$  – Energia (keV);

$x, y, z$  – Coeficientes de ajuste.

Coeficiente	Valor	Incerteza
x	-3,74	0,28
y	-3,76	0,33
z	-0,83	0,08

Tabela 3 – Valores para os coeficientes de ajuste da curva de eficiência

O modelo mostrou um erro relativo máximo de 5,64% para a energia de 80,998 keV do  $^{133}\text{Ba}$ , indicando boa concordância entre os resultados experimentais e simulados.

A resolução de energia foi determinada pela largura total à meia altura (FWHM) dos picos de absorção total para as fontes da Tabela 2. Na Figura 16 é apresentada a curva FWHM em função da energia, ajustada pela função *Gaussian Energy Broadening* (GEB) descrito no tópico "Modelo Matemático do Detector NaI(Tl)", página 35.

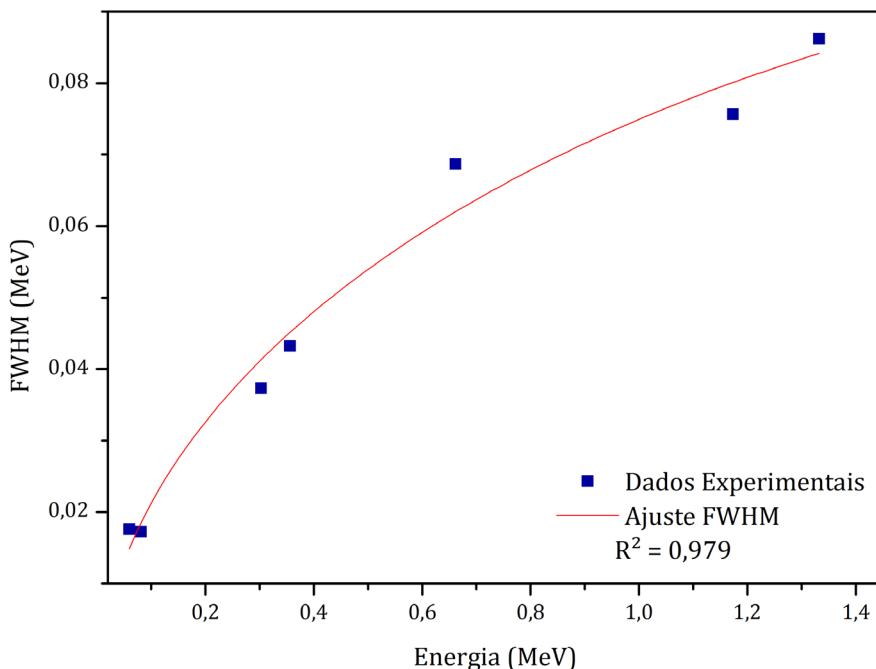


Figura 16 – Curva de resposta FWHM em função da energia.

Com esses resultados, foi possível realizar o ajuste da função GEB, tornando o modelo matemático mais realista. Os valores dos coeficientes “a”, “b” e “c” do ajuste estão listados na Tabela 4.

Coeficiente	Valor	Incerteza
a	-0,007	0,002
b	0,09	0,02
c	-0,18	0,04

Tabela 4 – Coeficientes de ajuste da função GEB

A validação experimental quantitativa e qualitativa foi concluída após o ajuste de eficiência e resolução de energia do sistema de detecção simulado (cristal + fotomultiplicadora), como mostrado na Figura 17, que compara os espectros simulados e experimentais para as fontes de  $^{137}\text{Cs}$  e  $^{241}\text{Am}$ .

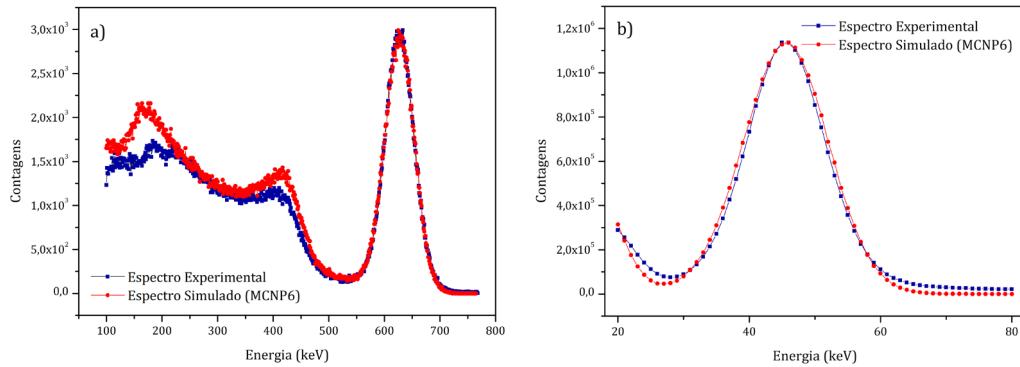


Figura 17 – Comparação da forma dos espectros experimental e simulado no código para fonte de: a)  $^{137}\text{Cs}$ ; b)  $^{241}\text{Am}$ .

Uma boa concordância foi observada nos picos de absorção total, embora discrepâncias tenham sido identificadas na de baixa energia (região Compton) da DAP do  $^{137}\text{Cs}$ . Essas diferenças são atribuídas à precisão limitada na simulação de elétrons de baixa energia e ao espalhamento de fótons no suporte do detector que não foram considerados nas simulações, efeitos geralmente relatados na literatura [20].

De forma geral, com base nas medições e simulações realizadas, o modelo do detector NaI(Tl) apresentou alta fidelidade em relação ao caso real, reforçando sua aplicabilidade em aplicações industriais envolvendo espectrometria de raios gama.

## REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais<sup>24</sup> (RNAs) são modelos computacionais inspirados na capacidade do cérebro humano de aprender por meio de exemplos. Elas têm a habilidade de identificar comportamentos e reconhecer padrões a partir de um conjunto de informações, denominado conjunto de treinamento, e de generalizar o conhecimento adquirido durante o processo de aprendizado (treinamento). Em outras palavras, uma RNA é capaz de responder a novas situações que não estavam incluídas no processo de treinamento.

O reconhecimento de padrões por uma RNA é realizado por meio de unidades de processamento interconectadas, chamadas neurônios artificiais. Cada ligação entre os neurônios possui peso que é associado aos sinais de entrada. Quando ajustados de forma apropriada, esses pesos permitem que a RNA se adapte corretamente a uma função específica e produza um sinal de saída. Cada neurônio é responsável por mapear os dados de entrada e saída por meio de funções matemáticas, geralmente funções não lineares complexas, e pode generalizar o conhecimento adquirido durante o treinamento para situações não contidas nas amostras originais [32].

<sup>24</sup>. O termo “rede” em rede neural artificial refere-se às interconexões entre os neurônios distribuídos em várias camadas do sistema.

As RNAs são de fácil implementação, tanto por software quanto por hardware, e são poderosas, especialmente em situações que não existem soluções analíticas. Não necessitam de conhecimento prévio sobre a distribuição das variáveis e são eficazes em cenários nos quais as condições do problema mudam ao longo do tempo. O funcionamento de uma RNA pode ser descrito em duas fases distintas:

- I. Fase de treinamento: A RNA recebe informações de um banco de dados como entrada e, por meio do algoritmo de treinamento, realiza o processo de aprendizagem e reconhecimento de padrões para fornecer respostas como saída. Durante essa fase, ocorre um ajuste iterativo de ajuste dos parâmetros da rede neural – pesos das conexões entre os neurônios – que armazenam o conhecimento adquirido;
- II. Fase de operação: Após o treinamento, a RNA aplica o conhecimento adquirido para responder a novas situações que não foram vistas durante a fase de treinamento.

Uma RNA típica é caracterizada por três categorias de variáveis:

- I. O padrão de conexões entre as várias camadas de neurônios;
- II. O procedimento de aprendizado, que envolve a atualização dos pesos das conexões;
- III. A conversão da entrada ponderada de um neurônio em sua ativação de saída, utilizando a função de ativação.

Ao contrário dos métodos de computação tradicionais, que dependem de programação explícita para resolver problemas, as redes neurais funcionam de maneira distinta. Elas não necessitam de um conjunto de regras programadas; em vez disso, adquirem a capacidade de classificar entradas por meio de um procedimento de treinamento, no qual são expostas a um conjunto de entradas e às saídas-alvo correspondentes. A partir da análise dos dados de treinamento, a rede estabelece um mapeamento entre entradas e saídas. Dessa forma, quando apresentada a novos dados de entrada, a rede utiliza o relacionamento aprendido para produzir saídas correspondentes.

O processo de aprendizado das redes neurais baseia-se em dados e experiências. Ao ser exposta a um conjunto diversificado de entradas e suas saídas correspondentes, a RNA ajusta seus parâmetros internos, permitindo-lhe reconhecer padrões, realizar regressões em novos dados.

Diversos modelos de redes neurais foram desenvolvidos, cada uma com arquitetura, método de treinamento, capacidade e campo de aplicação distintos. Três paradigmas principais de aprendizado são comumente utilizados em modelos de redes neurais: aprendizado por reforço, não supervisionado e supervisionado.

- I. Aprendizado por reforço (RL): A tomada de decisão ocorre de forma autônoma, adaptando-se a ambientes dinâmicos e desconhecidos para alcançar resultados ideais. Inspirado no aprendizado humano por tentativa e erro, o RL utiliza um paradigma baseado em recompensas e punições

para orientar o processo de decisão. Ações que aproximam o sistema de seus objetivos são recompensadas, enquanto aquelas que o afastam são penalizadas ou descartadas. Por meio das respostas obtidas a cada interação com o ambiente, os algoritmos de RL ajustam suas estratégias, aprendendo de forma incremental os caminhos mais eficientes para alcançar suas metas. Esse processo dinâmico torna o RL uma ferramenta poderosa para resolver problemas em cenários complexos e imprevisíveis;

- II. Aprendizado não supervisionado: Nesse tipo de aprendizado, a rede neural analisa os dados apresentados sem o auxílio de rótulos ou classificações predefinidas, organizando-os de forma autônoma com base em suas características intrínsecas. Esse processo permite que o modelo detecte propriedades coletivas emergentes, como padrões ocultos, relações entre variáveis ou distribuições internas, agrupando os dados em categorias semelhantes ou clusters. Essa abordagem é amplamente utilizada em áreas, como análise de imagens e detecção de anomalias<sup>[33]</sup>;
- III. Aprendizado supervisionado: Na abordagem supervisionada, a RNA é apresentada a um conjunto de entradas de exemplo e suas respectivas saídas, permitindo que seja treinada para estabelecer uma função que explique a correlação entre as variáveis.

As RNAs podem ser categorizadas em três tipos de topologias: de camada única, múltiplas camadas e recorrente. Uma RNA de camada única não possui camadas ocultas. Já uma RNA de múltiplas camadas compreende uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A RNA recorrente (RNNs – *Recurrent Neural Network*) processa dados sequenciais, tornando-as especialmente útil para tarefas em que o contexto ou a dependência temporal é crucial. Diferente das redes com arquitetura *feedforward*, as RNNs possuem conexões recorrentes que permitem que informações de etapas anteriores sejam preservadas e reutilizadas, criando uma memória interna. Isso as torna capazes de analisar sequências de dados, como séries temporais, texto ou sinais de áudio.

Muitos estudos sobre fluxo multifásico utilizam redes neurais multicamadas com propagação do sinal, como as redes *Feedforward Multilayer Perceptron – MLP* além de outras abordagens, como redes de base radial. As RNAs MLP têm sido aplicadas com sucesso em diversas classes de problemas, incluindo reconhecimento e classificação de padrões de imagens, voz e sinais gerais, bem como na identificação de comportamentos e tendências<sup>[32]</sup>. A rede MLP é o tipo mais utilizado para tarefas de classificação de padrões e regressão de dados<sup>[34 - 65]</sup>. No contexto deste livro, também foi utilizada para predizer parâmetros de regimes de fluxo em sistemas trifásicos<sup>[66, 67]</sup>.

A representação de uma rede neural artificial MLP é apresentada na Figura 18, onde os neurônios de entrada na primeira camada transmitem dados por sinapses para os neurônios na segunda camada e, a partir daí, para a camada de saída por meio de mais sinapses que alteram os dados nos cálculos<sup>[33]</sup>.

Neste livro, será mantido o foco em redes neurais supervisionadas, frequentemente utilizadas para classificar padrões e predizer valores em diversas áreas da engenharia.

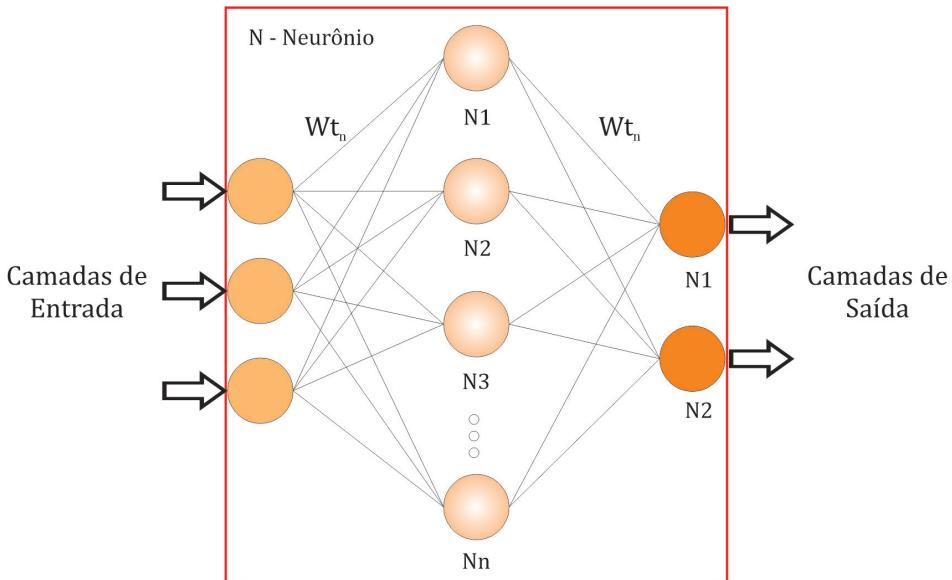


Figura 18 – Estrutura de uma rede neural artificial MLP.

### Algoritmo de Retropropagação

Durante o processo de treinamento supervisionado, os dados de treinamento são apresentados à rede neural, permitindo a criação de um mapeamento que possibilita a determinação de uma resposta a esses dados. A partir do erro entre a resposta gerada pela rede e o valor esperado, os pesos das sinapses são ajustados para minimizar esse erro.

A maior parte dos estudos de caso apresentados neste livro utiliza redes neurais com o tipo de aprendizado conhecido como algoritmo de retropropagação dos erros (*Backpropagation*)<sup>[68, 69]</sup>. Esse algoritmo realiza aproximações locais para o mapeamento entre a entrada e a saída, sendo amplamente utilizado em tarefas, como classificação, regressão (aproximação de funções) e previsão de tendências. Em essência, o algoritmo de retropropagação dos erros é baseado no método do gradiente descendente, que calcula as derivadas parciais da função de erro em relação aos pesos para um determinado vetor de entrada. O objetivo é minimizar a função de erro entre a saída da rede neural e a saída desejada<sup>[32]</sup>. De forma simplificada, o treinamento da rede neural com o algoritmo de retropropagação dos erros pode ser dividido em duas fases principais<sup>[70]</sup>.

- I. Fase de propagação direta: Os estímulos apresentados à rede fluem da entrada para a saída, camada por camada, até que a resposta da rede seja gerada. Essa resposta é, então, comparada com a saída desejada, e o erro entre as duas é calculado;
- II. Fase de retropropagação do erro: O erro calculado é retropropagado pelas camadas da rede, da saída para a entrada. Durante esse processo, os pesos das conexões das unidades das camadas internas são ajustados de modo a reduzir o erro, para que a saída desejada seja gerada a partir da entrada correspondente.

O processo de treinamento é iterativo, terminando quando um critério de parada é atingido. Cada vez que um padrão é apresentado à rede, os pesos são ajustados na direção que minimiza o menor no momento seguinte, quando o mesmo padrão novamente for apresentado.

O vetor que contém todos os valores dos pesos sinápticos após o treinamento representa o conhecimento adquirido pela rede sobre o ambiente (conhecimento prévio). Esse conhecimento está associado à capacidade da rede de generalizar, ou seja, de calcular com precisão a saída a partir de entradas que não foram apresentadas durante o treinamento. A escolha de um conjunto representativo de pares conhecidos de valores de entrada e saída, que formam os dados de treinamento, é crucial para garantir boa capacidade de generalização da rede após o processo de treinamento.

## Validação cruzada

O processo de treinamento de uma RNA é iterativo e termina após o cumprimento de um critério preestabelecido, quando o valor do erro se torna suficientemente pequeno, ou quando a função objetivo atinge um valor estacionário. À medida que o treinamento avança, o erro tende a diminuir, mas há o risco de que a RNA se sobreajuste (*overfitting*) aos dados do conjunto de treinamento, perdendo sua capacidade de generalizar para novos dados. Para evitar esse problema, utiliza-se a técnica de Validação Cruzada (*Cross-Validation*), que começa com a divisão do conjunto de dados em dois subconjuntos: Treinamento e Teste.

Durante o treinamento, a RNA é periodicamente avaliada para ambos os subconjuntos, mas apenas o subconjunto de Treinamento é utilizado para ajustar os pesos sinápticos. O subconjunto de Teste é utilizado para verificar a generalização da RNA, ou seja, para avaliar sua capacidade de fazer previsões precisas em dados não vistos durante o treinamento, evitando o sobreajuste (*overfitting*). Além disso, um terceiro subconjunto de dados, denominado de Validação, é utilizado para avaliar se a RNA está produzindo resultados com erros menores do que o desejado ao final do treinamento. A importância desse subconjunto reside no fato de que ele não foi utilizado previamente pela RNA durante o treinamento, o que mede diretamente sua capacidade de generalização.

A avaliação do desempenho da RNA é realizada por meio de métricas de erro, aplicadas a cada subconjunto de dados (Treinamento, Teste e Validação) até atingir um valor suficientemente pequeno ou quando a função objetivo se torne estacionária. A resposta da RNA para uma grandeza específica, tal como a predição das frações de volume, para os diferentes subconjuntos de dados é avaliada utilizando as seguintes métricas de erro: erro relativo médio (MRE), erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro absoluto médio (MAE), erro absoluto (EA) e erro relativo (ER).

O MRE (%) é uma medida da incerteza da medição em relação ao valor real (referência) para um dado conjunto de dados. Ele quantifica a magnitude do erro relativo entre os valores preditos pela rede neural e os valores reais, expresso como uma porcentagem do valor real, e é calculado pela Equação 15.

$$MRE(\%) = \frac{1}{n} \sum_1^n \frac{|(y_{real} - y_{RNA})|}{|y_{real}|} \times 100$$
Equação 15

O MSE é um dos índices de erro mais utilizados para medir as diferenças entre os valores preditos pela rede e os valores reais (referência). Ele é amplamente utilizado de forma mais significativa para os erros maiores, já que a quadratura de números maiores resulta em um impacto maior no valor final. Isso faz com que o MSE seja útil quando se deseja evitar grandes discrepâncias entre as previsões e os valores reais. O MSE é calculado pela soma dos erros quadráticos (a diferença entre os valores preditos e os reais elevada ao quadrado) dividida pelo número total de observações. A fórmula para calcular o MSE é dada pela Equação 16.

$$MSE = \frac{1}{n} \sum_1^n (y_{real} - y_{RNA})^2$$
Equação 16

O RMSE é uma medida usada para quantificar as diferenças entre os valores preditos pela rede e os valores reais, e pode ser calculado pela a Equação 17. O RMSE atribui um peso maior a erros maiores, uma vez que, ao tirar a raiz quadrada do MSE, ele retorna ao mesmo intervalo dos dados originais, facilitando a interpretação. Isso significa que o RMSE penaliza de forma mais significativa grandes discrepâncias, o que torna essa métrica particularmente útil para identificar e reduzir erros substanciais nas previsões.

$$RMSE = \sqrt{\frac{1}{n} \sum_1^n (y_{real} - y_{RNA})^2}$$
Equação 17

A MAE é a soma das diferenças absolutas entre o valor real e a previsão, dividida pelo número de observações, conforme a Equação 18. A MAE fornece uma medida direta da magnitude do erro, sem considerar a direção do desvio, e é útil para avaliar o erro médio absoluto de um modelo de previsão. Ela é uma métrica simples e intuitiva, pois expressa a média dos erros de previsão em unidades da variável de interesse.

$$MAE = \frac{1}{n} \sum_1^n |y_{real} - y_{RNA}|$$
Equação 18

O EA mede a diferença direta entre o valor predito e o valor real e pode ser calculado pela Equação 19. Ele é útil para entender o desvio em unidades absolutas, sem considerar o tamanho relativo do valor. Ao contrário de outras métricas, como o MRE ou o ER, o EA não normaliza o erro em relação ao valor real, tornando-se uma medida direta da discrepância entre a previsão e a realidade.

$$EA = y_{real} - y_{RNA}$$

Equação 19

O ER representa a magnitude da diferença entre o valor real e o valor predito, normalizada em relação ao valor real. Ele expressa o erro como uma porcentagem do valor real e pode ser calculado pela Equação 20. Esse método mede a proximidade os valores real e predito, permitindo uma comparação do erro em diferentes escalas ou tamanhos de valores, o que facilita a avaliação da predição em contextos variados.

$$ER = \frac{|y_{real} - y_{RNA}|}{y_{real}} \times 100$$

Equação 20

Enquanto o EA fornece a magnitude da diferença entre os valores preditos e reais, o ER normaliza essa diferença em relação ao valor real, permitindo comparações de erro em diferentes escalas ou tamanhos de valores.

O coeficiente de determinação ( $R^2$ ) é uma medida que indica a proporção da variabilidade na variável dependente que é explicada pelo modelo. Quanto mais próximo de 1 for o valor de  $R^2$ , melhor será o ajuste do modelo aos dados. O  $R^2$  é calculado pela Equação 21. Essa métrica é fundamental para avaliar a qualidade do modelo, pois mostra o quanto das flutuações nos dados podem ser preditas pelo modelo desenvolvido. Quanto maior o  $R^2$ , maior é a explicação do comportamento dos dados pela regressão.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{RNA} - \bar{y}_{real})^2}{\sum_{i=1}^n (y_{real} - \bar{y}_{real})^2}$$

Equação 21

Em que:

$n$  – Número total de dados;

$y_{real}$  – Valor real (referência);

$y_{RNA}$  – Valor predito pela RNA;

$\bar{y}_{real}$  – Média dos valores reais.

Essas métricas são essenciais para avaliar o desempenho de modelos de regressão, verificando sua precisão e capacidade de generalização. Elas indicam o quanto bem a rede neural se ajusta aos dados de treinamento e teste, evitando sobreajuste (*overfitting*) ou subajuste (*underfitting*). Avaliar essas métricas durante e após o treinamento é fundamental para validar a eficácia do modelo e garantir previsões precisas para novos dados.

## Redes Neurais Profundas

Durante a década de 1940, pesquisadores começaram a desenvolver modelos matemáticos conhecidos como RNAs. Com o tempo, surgiram limitações nas soluções dos problemas, principalmente devido às restrições de hardware da época. Além disso, com a adição de camadas ocultas nas redes neurais multicamadas (MLP), o treinamento com algoritmos clássicos de retropropagação de erro passou a apresentar um problema conhecido como desaparecimento do gradiente, que resultou na saturação do neurônio.

Com os avanços na área de ciência da computação, os modelos baseados em aprendizagem de máquina tornaram-se capazes de processar grandes volumes de dados com precisão e eficiência, aproveitando unidades gráficas de processamento (*Graphic Processor Units – GPUs*). As GPUs foram desenvolvidas e continuam sendo otimizadas para realizar a mesma operação repetidamente de forma rápida, o que as tornam ideais para processos iterativos, como ocorre durante o treinamento de algoritmos de aprendizado de máquina.

Durante o treinamento de uma RNA, muitos cálculos são realizados, especialmente na fase de atualização dos pesos. Além disso, há uma grande quantidade de hiperparâmetros que precisam ser analisados e otimizados para encontrar a melhor rede para um problema específico, como a predição de incrustação. Esse processo de otimização demanda um alto tempo computacional, especialmente quando se utiliza apenas a Unidade Central de Processamento (Central Processing Unit – CPU). Nesse contexto, o uso de GPUs se torna essencial, principalmente para grandes volumes de dados, pois elas permitem reduzir significativamente o tempo de processamento. Outro fator limitante pode ser o tamanho da memória RAM (*Random Access Memory*) do computador ou da memória VRAM (*Video Random Access Memory*) da GPU.

A complexidade do problema a ser resolvido determina a profundidade do modelo, ou seja, a quantidade de camadas ocultas e o número de neurônios na RNA. Redes neurais mais modernas podem ter centenas ou até milhares de camadas intermediárias sucessivas, todas utilizadas no processo de aprendizagem, sendo então chamadas de redes neurais profundas (*Deep Neural Networks – DNNs*)<sup>[71]</sup>. As redes neurais tradicionais e mais simples, por sua vez, são conhecidas como redes rasas (*Shallow Neural Networks – SNNs*), e no contexto deste livro, são referenciadas simplesmente como RNAs.

O maior número de camadas ocultas nas DNNs permite que o processo de aprendizagem opere com base no conceito de aprendizagem hierárquica ou aprendizado profundo<sup>[72, 73]</sup>. Nesse conceito, representações complexas de um problema são expressas por meio de representações mais simples, já que cada camada sucessiva de uma DNN utiliza a saída da camada anterior como entrada. Essa abordagem possibilita que as DNNs lidem com problemas extremamente complexos, uma vez que a aprendizagem ocorre em múltiplos níveis. Recursos de nível mais alto e complexo do problema são aprendidos a partir dos recursos de nível inferior e mais simples, previamente adquiridos.

Com o advento das DNNs, os pesquisadores trabalharam para superar o problema do desaparecimento do gradiente, o qual foi solucionado com a proposição de novas funções de ativação retificadas, como ReLu<sup>[74]</sup>. Além disso, variações da função ReLu, como ELU<sup>[75]</sup> e SELU<sup>[76]</sup>, também têm sido usadas com sucesso, oferendo melhor desempenho, menor tempo de treinamento e maior capacidade de generalização<sup>[77, 78]</sup>. Nos últimos anos, outras melhorias foram implementadas em modelos de DNNs para aprimorar a propagação do gradiente, como esquemas de generalização de pesos, normalização de bateladas e novos algoritmos de treinamento<sup>[79]</sup>.

Em projetos de aprendizado profundo, a quantidade de hiperparâmetros, como o número de camadas ocultas, o número de neurônios em cada camada e as funções de ativação, é consideravelmente grande. A busca pelo modelo ideal, portanto, representa uma das tarefas mais desafiadoras e demoradas na área. Nesse sentido, diversas técnicas têm sido desenvolvidas para ajudar os engenheiros de aprendizado de máquina e pesquisadores a selecionar o melhor conjunto de hiperparâmetros para seus projetos. Uma dessas ferramentas é a biblioteca Optuna<sup>[80]</sup>, desenvolvida para otimização de hiperparâmetros em Python<sup>[81]</sup>.

Optuna utiliza a otimização Bayesiana<sup>[82]</sup> e o *Tree-Structured Parzen Estimator* (TPE)<sup>[83]</sup> para explorar eficientemente e de forma dinâmica os espaços de hiperparâmetros. Além disso, a biblioteca integra-se com diversas bibliotecas populares de aprendizado de máquina, como *TensorFlow*<sup>[84]</sup> e *scikit-learn*<sup>[85]</sup>.

## REFERÊNCIAS

- [1] Knoll, G.F. *Radiation Detection and Measurement*. 2. ed. John Wiley & Sons, 11989.
- [2] Klein, O.; Nishina, Y. On the scattering of radiation by free electrons according to Dirac's new relativistic quantum dynamics. *Z. Phys.*, v. 52, n. 853, 1929. Reproduzido com permissão da Springer-Verlag. Traduzido do alemão por Dr. Lars Bergström. Disponível em: [https://doi.org/10.1142/9789814571616\\_0015](https://doi.org/10.1142/9789814571616_0015)
- [3] Hubbell, J.H.; Seltzer, S.M., 1997. Tables of X-ray mass attenuation coefficients and mass energy-absorption coefficients from 1 keV to 20 MeV for elements Z=1 to 92 and 48 additional substances of dosimetric interest. *NIST Standard Reference Database 126*, julho 2004. Disponível em: <https://www.nist.gov/pml/x-ray-mass-attenuation-coefficients>
- [4] Conti, C.C.; Sachet, I.A.; Bertelli, L.; Lopes, R.T. Ge detectors calibration procedure at IRD/CNEN for in situ measurements, *In: II International symposium on technologically enhanced natural radiation*, 1999, Rio de Janeiro.
- [5] Debertin, K.; Helmer, R.G. *Gamma- and X-ray Spectrometry with Semiconductor Detectors*. Amsterdam: North-Holland, 1988.
- [6] Heath, R.L. Scintillation Spectrometry: *Gamma-ray Spectrum Catalogue*. Revised edition of report IDO – 16880-1. Original issued: August 1964, Rev. Electronic update: February 1997. New version of 2nd edition compilation of gamma-ray spectra and related nuclear decay data. v. 1 de 2.
- [7] Fewell, T.R.; Weaver, K.E. *The Measurement of Diagnostic X-Ray Spectra with a High Purity Germanium Spectrometer*. Bureau of Radiological Health food and Drug Administration, Columbia, Maryland, v. 56. *Medical X-RAY – Photo-Optical Systems Evaluation*, 1974.
- [8] Di Castro, E.; Pani, R.; Pellegrini, R.; Bacci, C. The Use of Cadmium Telluride Detectors for the Qualitative Analysis of Diagnostic X-ray Spectra. *Physics in Medicine and Biology*, v. 29, n .9, p. 1135-1149, 1984.
- [9] Seelentag, W.W.; Panzer, W. Stripping of X Ray Bremsstrahlung spectra up to 300 kVp on desk type computer, *Physics in Medicine and Biology*, v. 24, p. 767-780, 1979.
- [10] Berzin, E.P. *Introduction to X-Ray Spectrometric Analysis*. New York: Plenum Press, 1978.

- [11] Cranley, K.; Gilmore, J.B.; Fogarty, A.W.G.; Desponds, L. *Catalogue of diagnostic X-ray spectra and other data*. Report n. 78. The Institute of Physics and Engineering in Medicine, 1997.
- [12] Taitel, Y.; Dukler, A.E. A Model for predicting flow regime transitions in horizontal and near horizontal gas-liquid flow. *AIChE Journal*, v. 22, n. 1, p. 47-54, 1976.
- [13] Paladino, E.E. *Estudo do Escoamento Multifásico em Medidores de Vazão do tipo Pressão Diferencial*, 2005. Tese (Doutorado em Ciências) – Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil.
- [14] Goorley, T.; James, M.; Booth, T.; Brown, F.; Bull, J.; Cox, L.J.; Durkee, J.; Elson, J.; Fensin, M.; Forster, R.A.; Hendricks, J.; Hughes, H.G.; Johns, R.; Kiedrowski, B.; Martz, R.; Mashnik, S.; McKinney, G.; Pelowitz, D.; Prael, R.; Sweezy, J.; Waters, L.; Wilcox, T.; Zukaitis, T. Features of MCNP6. *Annals of Nuclear Energy*, v. 87, p. 772-783, 2016.
- [15] Rubinstei, R.Y. *Simulation and the Monte Carlo Method*. New York: John Wiley & Sons, 1981. Disponível em: <https://doi.org/10.1002/9780470316511>
- [16] Kalos, M.H.; Whitlock, P.A. *Monte Carlo methods: Basics*. New York: Wiley-Interscience Publication, 1986. Disponível em: <http://dx.doi.org/10.1002/9783527617395>
- [17] LANL. MCNP - *A general Monte Carlo n-particle transport code*. Los Alamos National Laboratory, version 5, I: Overview and theory, U.S.A, 2003.
- [18] Pani, R.; Laitano, R.F.; Pellegrini, R. Diagnostic X-ray Spectra Measurements Using a Silicon Surface Barrier Detector, *Physics in Medicine & Biology*, v. 32, p. 1135-1149, 1987.
- [19] Salgado, C.M.; Brandão, L.E.B.; Schirru, R.; Pereira, C.M.N.A.; Ramos, R.; Silva, A.X. *Modelagem de detector NaI(Tl) usando MCNPX*. XI Encontro de Modelagem Computacional, n 0189, Volta Redonda, RJ, 2008.
- [20] Salgado, C.M.; Brandão, L.E.B.; Schirru, R.; Pereira, C.M.N.A.; Conti, C.C. Validation of a NaI(Tl) detector's model developed with MCNPX code. *Progress in Nuclear Energy*, v. 59, p. 19-25, 2012.
- [21] Berger, M.J.; Seltzer, S.M. Response functions for sodium iodide scintillation detectors. *Nuclear Instruments. Methods*, v. 104, p. 317-332, 1972.
- [22] Saito, K.; Moriuchi, S. Monte Carlo Calculation of accurate response functions for a NaI(Tl) detector for gamma rays. *Nuclear Instruments and Methods*, v. 185, p. 299-308, 1981.
- [23] Orion, I.; Wilopolski, L. Limitations in the PHOTON Monte Carlo gamma transport code. *Nuclear Instruments and Methods in Physics Research A* 480, p. 729-733, 2002.
- [24] Shi, Hu-Xia; Chen, Bo-Xian; Li, Ti-Zhu; Yun, D.I. Precise Monte Carlo simulation of gamma-ray response functions for a NaI(Tl) detector. *Applied Radiation and Isotopes*, v. 57, p. 517-524, 2002.
- [25] Sood, A.; Gardner, R.P. A new Monte Carlo assisted approach to detector response functions. *Nuclear Instruments and Methods in Physics Research Section B: Beam Interactions with Materials and Atoms*, v. 213, p. 100-104, 2004.
- [26] McConn Jr., R.J.; Gesh, C.J.; Pagh, R.T.; Rucker, R.A.; Williams III, R.G. *Compendium of Material Composition Data for Radiation Transport Modeling*, Radiation portal monitor project, Pacific Northwest, National Laboratory. PIET-43741-TM-963 PNNL-15870 Rev. 1, 2011.

- [27] Salgado, W.L.; Dam, R.S.F.; Ramos, L.L.; Silva, A.X.; Conti, C.C.; Salgado, C.M. Experimental and simulated methods to characterize the response of a scintillator detector. *Radiation Physics and Chemistry*, v. 192, 2022. Disponível em: <https://doi.org/10.1016/j.radphyschem.2021.109895>
- [28] Ewa, I.O.B.; Bodzis, D.; Czifrus, S.Z.; Molnar, Z.S. Monte Carlo determination of full energy peak efficiency for a HPGe detector. *Applied Radiation and Isotopes*, v. 55, n. 1, p. 103-108, 2001.
- [29] Nakamura, T. Monte Carlo Calculation of Peak Efficiencies of Ge(Li) and Pure Ge Detectors to Volymal Sources and Comparison with Environmental Radioactivity Measurement. *Nuclear Instruments and Methods in Physics Research*, v. 205, n. 1-2, p. 211-218, 1983.
- [30] Sima, O. Monte Carlo Simulation Versus Semiempirical Calculation of Autoabsorption Factors for Semiconductor Detector Calibration in Complex Geometries. *Progress in Nuclear Energy*, v. 24, p. 327-336, 1990.
- [31] IAEA. *Data from the gamma calibrated radioactive sources were obtained on Isotope Browser app, version 5.15.74 Android*, IAEA, Nuclear Data Section, 2017.
- [32] Haykin, S. *Neural Networks – A Comprehensive Foundation*. Macmillan College Publishing Company, 1994.
- [33] Hagan, M.T.; Demuth, H.B.; Beale, M.H.; Jesús, O. *Neural network design*. 2nd Edition, eBook, 2014. Disponível em: <https://hagan.okstate.edu/NNDesign.pdf>
- [34] Dang, Z.; M. Ishii. *Two-phase flow regime prediction using LSTM based deep recurrent neural network*. arXiv preprint arXiv:1904.00291, 2019.
- [35] Yang, Z.; Dang, Z.; Yang, X.; Ishii, M.; Shan, J. Downward two phase flow experiment and general flow regime transition criteria for various pipe sizes. *International Journal of Heat and Mass Transfer*, 125: p. 179-189, 2018.
- [36] Zheng, Q.; Xu, Y.; Zhang, P.; Bian, J.; Wanget, F. Identification of gas-liquid two-phase flow regime in pipelines with low liquid holdup based on ResNet1D-34. *Flow Measurement and Instrumentation*, v. 88, 2022. Disponível em: <https://doi.org/10.1016/j.flowmeasinst.2022.102249>
- [37] OuYang, L.; Jin, N.; Ren, R. A new deep neural network framework with multivariate time series for two-phase flow pattern identification. *Expert Systems with Applications*, v. 205, 2022. Disponível em: <https://doi.org/10.1016/j.eswa.2022.117704>
- [38] Wang, X.; Yangzheng, C.; Wang, B.; Tang, K.; Hu, H. Sectional void fraction measurement of gas-water two-phase flow by using a capacitive array sensor. *Flow Measurement and Instrumentation*, v. 74, 2020. Disponível em: <https://doi.org/10.1016/j.flowmeasinst.2020.101788>
- [39] Zhao, C.; Wu, G.; Li, Y. Measurement of water content of oil-water two-phase flows using dual-frequency microwave method in combination with deep neural network. *Measurement*, v. 131: p. 92-99, 2019.
- [40] Khayat, O.; Afarideh, H. Performance evaluation of multilayer perceptron, radial basis function, fuzzy inference system, and an adaptively tuned fuzzy wavelet neural network in parameter prediction of multiphase flow measurement instrumentation. *Expert Systems*, v. 36, n. 3, 2019. Disponível em: <https://doi.org/10.1111/exsy.12386>
- [41] Hanafizadeh, P.; Eshraghi, J.; Taklifi, A.R.; Ghanbarzadeh, S. Experimental identification of flow regimes in gas–liquid two phase flow in a vertical pipe. *Meccanica*, v. 51, n. 8, p. 1771-1782, 2016.

- [43] Al-Naser, M.; Elshafei, M.; Al-Sarkhi, A. Artificial neural network application for multiphase flow patterns detection: A new approach. *Journal of Petroleum Science and Engineering*, 145: p. 548-564, 2016.
- [44] Mayet, A.M.; Ilyinichna, F.E.; Fouladinia, F.; Sh.Daoud, M.; Ijyas, V.P.T.; Shukla, N.K.; Habeeb, M.S.; Alhashim, H.H. An artificial neural network and a combined capacitive sensor for measuring the void fraction independent of temperature and pressure changes for a twophase homogeneous fluid. *Flow Measurement and Instrumentation*, v. 93, 2023. Disponível em: <https://doi.org/10.1016/j.flowmeasinst.2023.102406>
- [45] Chen, T.C.; Alizadeh, S.M.; Alanazi, A.K.; Guerrero, J.W.G.; Abo-Dief, H.M.; Eftekhari-Zadeh, E.; Fouladinia, F. Using ANN and combined capacitive sensors to predict the void fraction for a two-phase homogeneous fluid independent of the liquid phase type. *Processes*, v. 11, n. 3, 2023. Disponível em: <https://doi.org/10.3390/pr11030940>
- [46] Ansari, A.; Sina, S.; Boosari, H.; Mohaghegh, S.; Hosseini, S. Successful Implementation of Artificial Intelligence and Machine Learning in Multiphase Flow: Two Case Studies of CFD Problems. *Journal of Petroleum & Environmental Biotechnology*, v. 11, p. 1-8, 2020. Disponível em: <https://doi.org/10.35248/2157-7463.20.11.401>
- [47] Seong, Y.; Park, C.; Choi, J.; Jang, I.I.S. Surrogate Model with a Deep Neural Network to Evaluate Gas–Liquid Flow in a Horizontal Pipe. *Energies*, v. 13, n. 4, 2020. Disponível em: <https://doi.org/10.3390/en13040968>
- [48] Peyvandi, R.G. Precise volume fraction measurement for three-phase flow meter using  $^{137}\text{Cs}$  gamma source and one detector. *Radiochimica Acta*, v. 108, n. 2, p. 159-164, 2020.
- [49] Khayat, O.; Afarideh, H. Performance evaluation of multilayer perceptron, radial basis function, fuzzy inference system, and an adaptively tuned fuzzy wavelet neural network in parameter prediction of multiphase flow measurement instrumentation. *Expert Systems*, v. 36, n. 3., 2019. Disponível em: <https://doi.org/10.1111/exsy.12386>
- [50] Azizi, S.; Karimi, H.; Darvishi, P. Flow pattern and oil holdup prediction in vertical oil–water two–phase flow using pressure fluctuation signal. *Iranian Journal of Chemistry & Chemical Engineering-International*, v. 36, n. 2:17, 2017.
- [51] Peikani, A.F.; G. Roshani; Feghhi. S. Volume fraction measurement and flow regime recognition in dynamic gas–liquid two phase flow using gamma ray radiation technique. *Instruments and Experimental Techniques*, v. 60, n. 5, p. 752-758, 2017.
- [52] Peyvandi, R.G.; Rad, S.I. Application of artificial neural networks for the prediction of volume fraction using spectra of gamma rays backscattered by three-phase flows. *The European Physical Journal Plus*, v. 132, n. 511, 2017. Disponível em: <https://doi.org/10.1140/epjp/i2017-11766-3>
- [53] Han, D.; Kwon, S. Application of machine learning method of data-driven deep learning model to predict well production rate in the shale gas reservoirs. *Energies*, v. 14, n. 12, 2021. Disponível em: <https://doi.org/10.3390/en14123629>
- [54] Bahrami, B.; Mohsenpour, S.; Noghabi, H.R.S.; Hemmati, N.; Tabzar, A. Estimation of flow rates of individual phases in an oil-gas-water multiphase flow system using neural network approach and pressure signal analysis. *Flow Measurement and Instrumentation*, v. 66, p. 28-36, 2019.
- [55] Jeshvaghani, P.A.; Feghhi, S.A.H.; Khorsandi, M. Temperature independent flow-rate prediction in two-phase flow loop using gamma-ray attenuation and Artificial Neural Networks. *Radiation Measurements*, 128, 2019. Disponível em: <https://doi.org/10.1016/j.radmeas.2019.106175>

- [56] Rashid, S.; Ghamartale, A.; Abbasi, J.; Darvish, H.; Tatar, A. Prediction of critical multiphase flow through chokes by using a rigorous artificial neural network method. *Flow Measurement and Instrumentation*, v. 69, 2019. Disponível em: <https://doi.org/10.1016/j.flowmeasinst.2019.101579>
- [57] AL-Qutami, T.A.; Ibrahim, R.; Ismail, I.; Ishak, M.A. Virtual multiphase flow metering using diverse neural network ensemble and adaptive simulated annealing. *Expert Systems with Applications*, v. 93, p. 72-85, 2018.
- [58] Hasanvand, M.; Bernetti, S. Predicting oil flow rate due to multiphase flow meter by using an artificial neural network. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, v. 37, n. 8, p. 840-845, 2015.
- [59] Shaban, H.; Tavoularis, S. Measurement of gas and liquid flow rates in two-phase pipe flows by the application of machine learning techniques to differential pressure signals. *International journal of multiphase flow*, v. 67, p. 106-117, 2014.
- [60] Kuang, B.; Nnabuife, S.G.; Sun, S.; Whidborne, J.F.; Rana, Z.A. Gas-liquid flow regimes identification using non-intrusive Doppler ultrasonic sensor and convolutional recurrent neural networks in an s-shaped riser. *Digital Chemical Engineering*, v. 2, 2022. Disponível em: <https://doi.org/10.1016/j.dche.2022.100012>
- [61] Dang, Z.; Ishii, M. Two-phase flow regime prediction using LSTM based deep recurrent neural network. *Computer Science, Computer Vision and Pattern Recognition*. arXiv preprint arXiv:1904.00291, 2019. Disponível em: <https://doi.org/10.48550/arXiv.1904.00291>
- [62] Boorboor, S.; Feghihi, S.; Jafari, H. Design and construction of an LSTM-powered high sampling rate dual-beam gamma densitometer for real-time measurement of the two-phase flow void fraction. *Nuclear Engineering and Design*, v. 411, 2023. Disponível em: <https://doi.org/10.1016/j.nucengdes.2023.112444>
- [63] Tanaka, K.; Kawashima, D.; Takakura, Y.; Takei, M. Accurate void fraction estimation by plural long short term memory applying to multiple voltage current system in gas-liquid flows. *IEEE Sensors Journal*, 2021. Disponível em: <https://doi.org/10.1109/JSEN.2021.3058156>
- [64] Fichera, A.; Pagano, A. A neural tool for the prediction of the experimental dynamics of two-phase flows. *International Journal of Heat and Technology*, v. 35, n. 2, p. 235-242.
- [65] Temirchev, P.; Simonov, M.; Kostoev, R.; Burnaev, E.; Oseledets, I.; Akhmetov, A.; Margarit, A.; Sitenikov, A.; Koroteev, D. Deep neural networks predicting oil movement in a development unit. *Journal of Petroleum Science and Engineering*, v. 184, p. 667-672, 2010.
- [66] Salgado, C.M.; Brandão, L.E.B.; Schirru, R.; Pereira, C.M.N.A.; Silva, A.X.; Ramos, R. Prediction of volume fractions in three-phase flows using nuclear technique and artificial neural network. *Applied Radiation and Isotopes*, v. 67, n. 10, p. 1812-1818, 2009.
- [67] Salgado, C.M.; Pereira, C.M.N.A.; Schirru, R.; Brandão, L.E.B. Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks. *Progress in Nuclear Energy*, v. 52, n. p. 555-562, 2010.
- [68] Werbos, P. *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. Tese de D.Sc., Harvard University, Cambridge, MA, 1974.
- [69] Rumelhart, D.E.; Hinton, G.E.; Williams, R. J., 1986. Learning representations by back-propagating errors. *Nature*, 323, n. 6088, p. 533-536.

- [70] Widrow, B.; Hoff, M.E. Adaptative Switching Circuits. Western Electronic Show and Convention, Institute of Radio Engineers, 4, p. 96-104, 1960.
- [71] Chollet, F. *Deep Learning with Python*, Second Edition. Manning, 2021. ISBN 9781617296864
- [72] LeCun, Y.; Bengio, Y.; Hinton, G. Deep learning. *Nature*, v. 521, p. 436-444, 2015.
- [73] Goodfellow, I.; Bengio, Y.; Courville, A. *Deep learning*, Cambridge: MIT Press, 2016.
- [74] Glorot, X.; Bengio, Y. Understanding the difficulty of training deep feedforward neural networks. In: *Proc. AISTATS*, v. 9. p. 249-256, 2010.
- [75] Clevert, D.A.; Unterthiner, T.; Hochreiter, S. Fast and accurate deep network learning by exponential linear units (ELUs). In: *International Conference on Learning Representations at ICLR 2016*. arXiv: 1511.07289, 2015.
- [76] Klambauer, G.; Unterthiner, T.; Mayr, A.; Hochreiter, S. Self-normalizing neural networks. *Advances in Neural Information Processing Systems*, v. 30, p. 972-981, 2017.
- [77] Desterro, F.S.M.; Santos, M.C.; Gomes, K.J.; Heimlich, A.; Schirru, R.; Pereira, C.M.N.A. Development of a Deep Rectifier Neural Network for dose prediction in nuclear emergencies with radioactive material releases. *Progress in Nuclear Energy*, v. 118, 2020. Disponível em: <https://doi.org/10.1016/j.anucene.2019.103110>
- [78] Pinheiro, V.H.; Santos, M.C.; Desterro, F.S.M.; Schirru, R.; Pereira, C.M.N.A. Nuclear Power Plant accident identification system with “don’t know” response capability: novel deep learning-based approaches. *Annals of Nuclear Energy*, v. 137, 2020. <https://doi.org/10.1016/j.anucene.2019.107111>
- [79] Glorot, X.; Bordes, A.; Bengio, Y. Deep Sparse Rectifier Neural Networks. In: *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, v. 15, p. 315-323, 2011.
- [80] Akiba, T.; Sano, S.; Yanase, T.; Ohta, T.; Koyama, M. Optuna: A Next-generation Hyperparameter Optimization Framework. In: *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD ’19)*, Association for Computing Machinery, New York, NY, USA, 2623-2631, 2019.
- [81] Van Rossum, G.; Drake, F.L. *Python 3 Reference Manual*, Scotts Valley, CA: CreateSpace, 2009.
- [82] Snoek, J.; Larochelle, H.; Adams, R.P., 2012. Practical Bayesian optimization of machine learning algorithms. *Advances in Neural Information Processing Systems*, 25, p. 2951-2959.
- [83] Bergstra, J.; Bengio, Y. Random Search for Hyper-Parameter Optimization. *Journal of Machine Learning Research*, v. 13, p. 281-305, 2012.
- [84] Abadi, M.; Agarwal, A.; Barham, P.; Brevdo, E.; Chen, Z.; Citro, C.; Corrado, G. S.; Davis, A.; Dean, J.; Devin, M.; Ghemawat, S.; Goodfellow, I.; Harp, A.; Irving, G.; Isard, M.; Jozefowicz, R.; Jia, Y.; Kaiser, L.; Kudlur, M.; Levenberg, J.; Mané, D.; Schuster, M.; Monga, R.; Moore, S.; Murray, D.; Olah, C.; Shlens, J.; Steiner, B.; Sutskever, I.; Talwar, K.; Tucker, P.; Vanhoucke, V.; Vasudevan, V.; Viégas, F.; Vinyals, O.; Warden, P.; Wattenberg, M.; Wicke, M.; Yu, Y.; Zheng, X. TensorFlow: Large-scale machine learning on heterogeneous systems, Software available from tensorflow.org, 2015.
- [85] Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R.; Dubourg, V.; Vanderplas, J.; Passos, A.; Cournapeau, D.; Brucher, M.; Perrot, M.; Duchesnay, E. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825-2830, 2011.

## CAPÍTULO 3

# IDENTIFICAÇÃO DO REGIME DE FLUXO E CÁLCULO DA FRAÇÃO DE VOLUME EM ESCOAMENTOS MULTIFÁSICOS BASEADOS EM RADIAÇÃO GAMA

---

**César Marques Salgado**

**William Luna Salgado**

**Roos Sophia de Freitas Dam**

**Claudio de Carvalho Conti**

Na indústria petrolífera *offshore*, a produção de petróleo e gás natural envolve a coexistência de fases líquida (petróleo e água) e gasosa, resultando em um fluxo multifásico de significativa importância. Para determinar a vazão de cada componente que escoa pelos poços de petróleo em sistemas de medição trifásica (gás, água e óleo), é essencial determinar a fração volumétrica (FVF), parâmetro crucial para o monitoramento do escoamento. Nos últimos anos, a exploração *offshore* avançou para águas cada vez mais profundas, elevando significativamente os custos operacionais e demandando estudos de viabilidade técnica, bem como a otimização de equipamentos e processos para o transporte de fluidos multifásicos. Monitorar escoamentos multifásicos em oleodutos é uma tarefa desafiadora devido à complexa interação entre as fases presentes.

Técnicas de medição multifásica, que realizam as medições simultâneas sem a de separação das fases, permitem monitoramento em tempo real e contínuo sem interferir nas condições operacionais. Essas técnicas têm se mostrado uma solução eficaz para a eficiência da produção, reduzir custos e aumentar a produtividade. Dada sua importância, medidores de vazão multifásicos têm sido amplamente investigados, especialmente para aplicações fiscais, onde sua precisão é indispensável para minimizar perdas econômicas em razão do alto volume diário de fluidos transferidos.

Diferentes princípios físicos são utilizados na medição de parâmetros, como fração volumétrica e velocidade interfacial, utilizando sensores convencionais elétricos<sup>[1]</sup> e ópticos<sup>[2]</sup>. Entre as técnicas nucleares, dispositivos que utilizam radiação, como raios X<sup>[3]</sup> e gama<sup>[4]</sup>, destacam-se por sua aplicação em predições de frações volumétricas de fluidos em sistemas multifásicos. Embora algumas técnicas sejam invasivas e apresentem altos

custos de instalação e manutenção, outras, não invasivas podem comprometer a precisão das medições. Esse cenário tem incentivado a pesquisa por soluções não invasivas que equilibrem precisão e custo. Nesse contexto, métodos baseados na atenuação de raios gama têm recebido especial atenção. Trata-se de uma técnica não invasiva, onde os detectores são posicionados externamente aos tubos, evitando o contato com os fluidos. Apesar das considerações de segurança radiológica, a técnica se destaca pela confiabilidade e resposta em tempo real, sendo adequada para aplicações práticas que demandam monitoramento contínuo [5]. Com sucesso em setores, como petroquímico, petróleo e mineração, em estudos de densidade [6, 7], detecção de incrustações [8, 9], frações volumétricas [1, 10, 11, 12, 13, 14, 15], detecção de zonas de mistura em polidutos [16], e predição de trajetórias usando rastreamento de partículas radioativas [17, 18]. Utilizando fontes de raios gama [19, 20, 21, 22, 23, 24], é possível realizar o monitoramento do escoamento sem a necessidade de alterar as condições operacionais da planta industrial. No entanto, a predição de fração volumétrica por meio de medições de raios gama geralmente requer a correta identificação do regime de fluxo para garantir maior precisão.

A obtenção de informações sobre o regime de fluxo líquido-gás frequentemente depende de observações visuais, que podem ser subjetivas e imprecisas, especialmente em fluxos de alta velocidade ou sistemas opacos, onde a visualização direta é inviável [25, 26]. Alterações espaciais e temporais no regime de fluxo podem introduzir grandes erros ao utilizar modelos baseados em equações analíticas empíricas, que são específicas para determinadas condições geométricas e regimes. Portanto, um sistema não invasivo que possa fornecer previsões de FVF independentemente do conhecimento a priori do regime de fluxo, sem avaliação subjetiva, é uma grande contribuição. Para superar essas limitações, foi desenvolvida uma metodologia que utiliza redes neurais artificiais (RNAs) para interpretar as distribuições de altura de pulso (DAPs) obtidas por detectores de radiação de raios gama, permitindo a identificação do regime de fluxo [25, 26, 27, 28] e a predição das FVFs [1, 29, 30, 31, 22, 32, 33].

No estudo de caso descrito neste capítulo, os padrões de treinamento e teste para rede neural foram gerados com base em modelos matemáticos estáticos e ideais, representando os regimes de fluxo anular, estratificado e homogêneo.<sup>1</sup> Diferentes frações volumétricas (FVF) associadas a cada regime de fluxo investigado foram utilizadas como dados de entrada para as RNAs. Devido às dificuldades inerentes à obtenção de dados experimentais para a aplicação nas RNAs, o código computacional Monte Carlo N-Particle versão 6 (MCNP6) foi utilizado para gerar o conjunto de amostras necessário ao treinamento e à avaliação da capacidade de generalização das redes neurais. O modelo desenvolvido no MCNP6 considera os efeitos da interação da radiação com os materiais e fluidos envolvidos, além das distribuições de altura de pulso (DAPs) registradas pelos

1. *Tipo de escoamento onde todas as fases estão uniformemente distribuídas no tópico transversal do tubo, com velocidades superficiais ( $v_s$ ) iguais (sem deslocamento entre si). O regime de fluxo bubbly é um exemplo aproximado ( $V_{Mistura} = V_{sGás} + V_{sLíquido}$ ). Pode ser obtido com auxílio de um misturador.*

detectores de cintilação NaI(Tl). Também são incorporadas ao modelo as curvas de resposta do detector, como a resolução energética e eficiência, bem como suas dimensões e características físicas reais. Em geral, o esse modelo apresenta uma boa aproximação em relação ao comportamento esperado em condições reais.

A geometria de detecção incluiu dois detectores NaI(Tl): o primeiro, posicionado diametralmente oposto às fontes de  $^{241}\text{Am}$  e  $^{137}\text{Cs}$ , e o segundo, a 45° em relação à fonte. O uso combinado dos feixes transmitido e espalhado aumentou a representatividade dos dados, reduzindo a dependência dos resultados em relação ao regime de fluxo. O sistema foi estruturado com quatro RNAs: uma dedicada à identificação do regime de fluxo dominante e as outras três voltadas à predição das FVFs nos regimes específicos. A qualidade do treinamento das RNAs foi avaliada utilizando padrões adicionais, não utilizados durante a fase de treinamento, os quais também foram gerados por meio de código matemático. Para garantir ampla cobertura dos diferentes cenários possíveis, os padrões de treinamento foram uniformemente distribuídos no espaço de busca.

Como resultado, o estudo demonstrou a eficácia da metodologia na identificação precisa de regimes de fluxo e no cálculo das frações volumétricas, sem a necessidade de conhecimento prévio sobre o regime ou interpretações subjetivas. Tal abordagem representa um avanço significativo na caracterização de escoamentos multifásicos na indústria petrolífera.

## PREDIÇÕES DE FRAÇÃO DE VOLUME COM REDES RASAS (RNA)

### Geometria Proposta

A medição precisa da fração volumétrica (FVF) em sistemas multifásicos é essencial para diversas aplicações industriais, como na otimização de processos em dutos. Neste capítulo, o desenvolvimento da geometria de medição baseia-se na combinação dos princípios da radiação transmitida e espalhada, uma técnica conhecida como densitometria de modo duplo. Essa abordagem foi selecionada para ampliar a inspeção da área da seção transversal do tubo, onde as fases fluem, reduzindo a dependência do cálculo da FVF em relação a possíveis variações no regime de fluxo [24, 34]. Tal procedimento busca adquirir informações suficientes sobre o regime de fluxo.

Em todas as simulações, foi adotada uma geometria com feixe estreito divergente (*narrow beam*) e dois detectores de NaI(Tl). O primeiro detector (D1) está alinhado diretamente com a fonte (180°), enquanto o segundo (D2) está posicionado a um ângulo de 45°. A simulação do sistema de medição é representada na Figura 19. Para a simulação, utilizou-se uma fonte puntiforme colimada de raios gama, com energias de 59,5445 keV, correspondentes ao  $^{241}\text{Am}$ , e de 661,66 keV, correspondentes ao  $^{137}\text{Cs}$ . As simulações foram conduzidas no código MCNP6. O procedimento completo para a modelagem matemática e a validação experimental do detector está detalhado no tópico "Modelo Matemático do Detector NaI(Tl)" página 35.

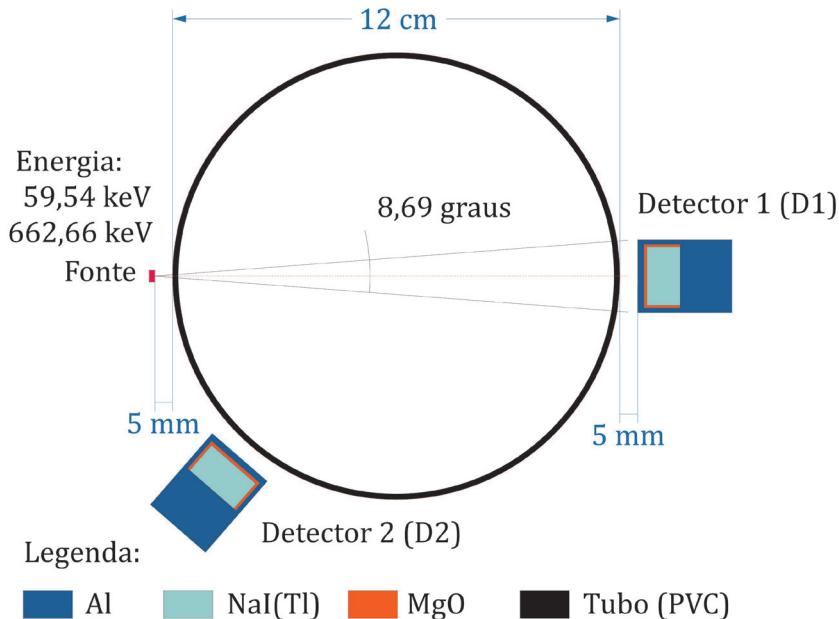


Figura 19 – Geometria do sistema de medição.

No interior da tubulação, foi considerado um regime de fluxo multifásico composto por gás, água salgada e óleo. A água do mar foi simulada com uma concentração de 4% de NaCl e densidade de  $1,0466 \text{ g.cm}^{-3}$  [34]. A fase gasosa foi representada por gás Metano ( $\text{CH}_4$ ), enquanto o óleo foi considerado como o hidrocarboneto  $\text{C}_5\text{H}_{10}$ , com densidade de  $0,896 \text{ g.cm}^{-3}$  [35]. A seção de teste consiste em um tubo de Policloreto de Vinila (PVC) com 1,8 cm de espessura e 25,0 cm de diâmetro interno. Mais detalhes sobre os materiais e fluidos estão disponíveis na Tabela 5. Os modelos representativos dos diferentes regimes de fluxo estão ilustrados na Figura 20.

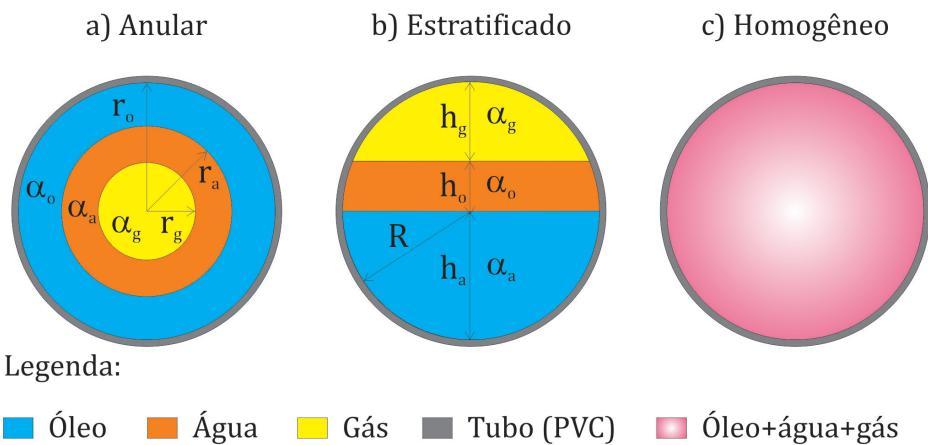


Figura 20 – Modelos de regime de fluxo: a) anular; b) estratificado; c) homogêneo.

Para reduzir o tempo computacional das simulações, foi desenvolvida uma fonte puntiforme colimada divergente, utilizando um ângulo sólido máximo de 8,84° com auxílio dos cartões SI, SP e SB disponíveis no código MCNP6. A *tally* F8, também disponível no código, foi utilizada para fornecer a distribuição de altura de pulsos (DAP) registrada no volume sensível do detetor de NaI(Tl) após a interação com o sistema tubo-fluidos. O número de histórias (NPS) foi determinado para obter estatísticas aceitáveis, mantendo valores de erro relativo (R) abaixo de 3% para todas as subdivisões de energia do espectro, conforme recomendado pelo manual do código MCNP6 [36].

A elaboração do modelo matemático do regime anular, apresentado na Figura 20, requer o conhecimento das frações volumétricas reais, de modo a fornecer o valor da composição percentual correta de cada fluido no arquivo INP do código MCNP6. O cálculo das frações volumétricas reais foi efetuado considerando a razão entre o volume ocupado por cada fluido e o volume total da seção transversal. Uma vez que o comprimento do tubo inspecionado é constante, a área ocupada por cada fluido é determinada. Assim, a fração volumétrica do gás é calculada conforme a Equação 22.

$$\alpha_g = \frac{r_g^2}{r_t^2}$$

Equação 22

Utilizando o mesmo procedimento, a fração volumétrica de água é determinada pela Equação 23.

$$\alpha_a = \frac{(r_a^2 - r_g^2)}{r_t^2}$$

Equação 23

Já a fração volumétrica de óleo pode ser obtida pela Equação 24 ou pelo complemento das frações volumétricas dos fluidos utilizando a Equação 25.

$$\alpha_o = \frac{(r_o^2 - r_a^2)}{r_o^2}$$

Equação 24

$$\alpha_o = 1 - \alpha_g - \alpha_a$$

Equação 25

Em que:

$\alpha_f$  – Fração do volume do fluido:  $g$  = gás, e  $\alpha$  = água;

$r_t$  – Raio interno do tubo;

$r_f$  – Raio de cada circunferência.

Para o regime estratificado, as equações disponíveis na literatura geralmente consideram tubos com seção reta quadrada. Neste trabalho, foi necessário desenvolver uma equação para tubos com seção circular. O procedimento adotado para cálculo da fração volumétrica utiliza espessuras equivalentes ( $h_g$  e  $h_a$ ) de cada fluido, correspondentes ao caminho percorrido pela radiação. Para um feixe tipo *pencil beam*, essas espessuras são obtidas pela Equação 26 [19] e Equação 27 [19].

$$h_g = \frac{\ln(I/I_a)}{\mu_a - \mu_g} \quad \text{Equação 26}$$

$$h_a = \frac{\ln(I/I_g)}{\mu_g - \mu_a} \quad \text{Equação 27}$$

Em que:

$h_{g,a}$  – Espessuras dos fluidos gás e água;

$\mu_{g,a}$  – Coeficientes de atenuação linear dos fluidos gás e água;

$I$  – Intensidade transmitida com múltiplos fluidos;

$I_{a,g}$  – Intensidade para fluidos isolados.

A partir das espessuras calculadas, a área ocupada pelos fluidos é determinada integrando a seção circular do tubo, conforme a Equação 28.

$$S(h_n) = 2 \int_0^h \sqrt{R^2 - (y - R)^2} dy \quad \text{Equação 28}$$

Em que:

$R$  – Raio do tubo (cm);

$h_n$  – Espessura do fluido, gás ( $n=1$ ), água ( $n=3$ ); óleo ( $n=2$ , por complemento);

$y$  – Parâmetro matemático utilizado para calcular a integral.

Por meio de manipulação matemática e utilizando o método trigonométrico, o cálculo da fração volumétrica é dado pela Equação 29 [9].

$$\alpha(h_n) = \frac{\pi R^2}{2} + R^2 \cdot \sin^{-1} \left( \frac{h_n - R}{R} \right) + (h_n - R) \cdot \sqrt{R^2 - (h_n - R)^2} \quad \text{Equação 29}$$

Substituindo o valor de  $h_n$  na Equação 29, obtém-se a Equação 30, que pode ser utilizada na densitometria gama com um feixe monoenergético em um tubo cilíndrico.

$$\alpha(h_n) = \frac{1}{2} + \frac{R^2 \arcsen \left\{ \frac{[\ln(I/I_3)/(\mu_3 - \mu_1)] - R}{R} \right\}}{\pi R^2} + \frac{[\ln(I/I_3)/(\mu_3 - \mu_1)] - R \cdot \sqrt{R^2 - [\ln(I/I_3)/(\mu_3 - \mu_1)] - R}^2}{\pi R^2} \quad \text{Equação 30}$$

Vale notar que a fração volumétrica do Fluido 3 ( $n=3$ ) pode ser obtida pelo complemento, ou seja,  $\alpha_3 = 2 - \alpha_1 - \alpha_2$ . Os coeficientes de atenuação linear dos fluidos foram obtidos por simulação matemática e validados teoricamente com dados disponíveis na literatura [37].

A Equação 26, Equação 27 e Equação 30 foram desenvolvidas para um feixe *pencil beam* e validadas por meio de modelagem com o MCNP6. A geometria proposta, apresentada na Figura 19, utiliza um feixe divergente de  $8,69^\circ$ , escolhido com o objetivo de capturar informações mais detalhadas sobre os fluidos e o regime de fluxo. Nesta análise, os dados gerados são utilizados em uma rede neural artificial para a predição das frações de volume.

Na geometria de medição desenvolvida, a abordagem de densitometria de modo duplo permite uma análise detalhada do fluxo. Para o regime homogêneo, isso envolve o cálculo da composição das frações mássicas de cada fluido, o que é fundamental para uma determinação precisa da fração de volume de fluido (FVF).

Além de informações sobre a geometria, a modelagem do problema pelo código MCNP6, visando uma melhor qualidade na elaboração dos modelos matemáticos, requer informações sobre a constituição química dos materiais. As composições químicas em fração mássica e a densidade dos materiais e fluidos utilizados nas simulações, abrangendo todos os estudos de caso descritos neste livro, estão apresentadas na Tabela 5 [38].

Material	Fração mássica e Densidade (g.cm <sup>-3</sup> )	Material	Fração mássica e Densidade (g.cm <sup>-3</sup> )
Água salgada (4%) (H <sub>2</sub> O+NaCl)	Na: 0,015735 O: 0,852577 H: 0,107423 Cl: 0,024265	1,0466	Aço inoxidável 316L  C: 0,000300 Si: 0,001000 P: 0,000450 S: 0,000300 Cr: 0,170000 Mg: 0,020000 Fe: 0,653950 Ni: 0,120000 Mo: 0,025000
Óleo C <sub>5</sub> H <sub>10</sub>	C: 0,856285 H: 0,143715	0,896	MgO  O: 0,396964 Mg: 0,603036
Sulfato de Bário (BaSO <sub>4</sub> )	Ba: 0,588420 O: 0,137368 S: 0,137368	4,5	Carbonato de Cálcio (CaCO <sub>3</sub> )  C: 0,120003 Ca: 0,400443 O: 0,479554
Gás Metano (CH <sub>4</sub> )	H: 0,251318 C: 0,748682	6,67×10 <sup>-4</sup>	Ar seco (Air dry)  C: 0,000124 N: 0,755268 O: 0,231781 Ar: 0,012827
Petróleo, Bruto (Leve, Texas)	O: 0,123246 C: 0,852204 N: 0,007014 S: 0,017535	0,8750	Querosene C <sub>14</sub> H <sub>30</sub>  H: 0,160000 C: 0,840000
Óleo	C: 0,853733 H: 0,104039 S: 0,042228	0,973	Glicerina (C <sub>3</sub> H <sub>8</sub> O <sub>3</sub> )  H: 0,087554 C: 0,391262 O: 0,521185
Gasolina C <sub>8</sub> H <sub>18</sub>	H: 0,157000 C: 0,843000	0,721	Óleo Combustível  H: 0,125878 C: 0,862308 S: 0,011814
Nal(Tl)	Na: 0,8449 I: 0,1531 Tl: 0,0020	3,667	

Tabela 5 – Composição química em fração mássica e densidade utilizadas no código MCNP6

## Identificação do Regime de Fluxo

A metodologia consiste em utilizar as DAPs registradas nos detectores (D1 e D2) para alimentar a RNA1 com o objetivo de identificar automaticamente o regime de fluxo do sistema. Para o treinamento da RNA, foram utilizados como entradas os conjuntos de dados extraídos das DAPs (DAP 1 e DAP 2) obtidas pelos detectores D1 e D2, e as saídas foram classificadas considerando uma RNA com três neurônios na camada de saída (S<sub>3</sub>, S<sub>2</sub>,

e  $S_1$ ). Dessa forma, para realizar a classificação dos regimes, a rede ajusta o maior valor entre as saídas da RNA para “1”, correspondente ao tipo de regime em questão, e atribui “0” às demais saídas. Supondo que as DAPs 1 e 2 pertençam ao regime anular, a RNA deverá ajustar as saídas para  $S_1=1$ ,  $S_2=0$  e  $S_3=0$ . Os dados de entrada e de saída utilizados para treinamento da RNA são apresentados de forma esquemática na Figura 21.

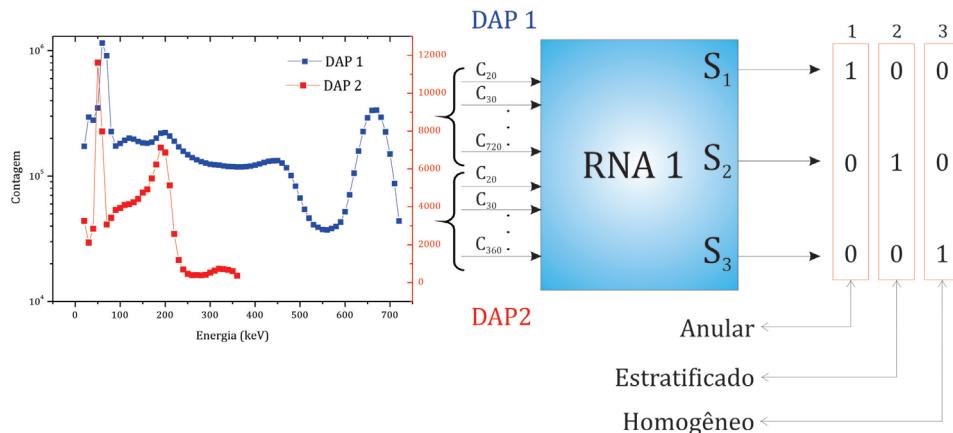


Figura 21 – Representação esquemática do treinamento da RNA.

Para essa etapa, a RNA utilizada foi uma MLP de 3 camadas, treinada pelo algoritmo de retropropagação [39]. Vale ressaltar que os padrões contendo apenas um fluido (por exemplo, 100% de gás) foram removidos do conjunto de treinamento, uma vez que representam um regime de fluxo monofásico. Caso fossem considerados, poderiam interferir negativamente no treinamento da RNA. As variáveis de entrada são as mesmas descritas no tópico "Geometria Proposta", página 57.

## Dados de Treinamento de RNA

O primeiro passo desta investigação consistiu em realizar as simulações matemáticas para os diferentes tipos de regimes de fluxo (anular, estratificado e homogêneo), conforme ilustrado na Figura 20, utilizando o código MCNP6. Essas simulações foram responsáveis pela geração dos conjuntos de dados de treinamento e teste para as RNAs.

Nos regimes anular e estratificado, variou-se as espessuras de cada fluido no código MCNP6 utilizando os parâmetros  $r_g$ ,  $r_a$  e  $r_o$  para o modelo anular (Figura 20a), e  $h_g$ ,  $h_a$  e  $h_o$  para o modelo estratificado (Figura 20b). Com isso, diversas combinações de FVFs,  $\alpha_g$ ,  $\alpha_a$  e  $\alpha_o$ , foram geradas.

No regime homogêneo, variaram-se as frações de volume de cada fluidos, permitindo a análise de diferentes cenários de fluxo. Para cada uma dessas combinações, que variaram de 0% a 100%, foram calculadas as contagens relativas de feixes transmitidos e espalhados. A distribuição das frações de volume para os subconjuntos de dados de Treinamento, Teste e Validação está ilustrada na Figura 22.

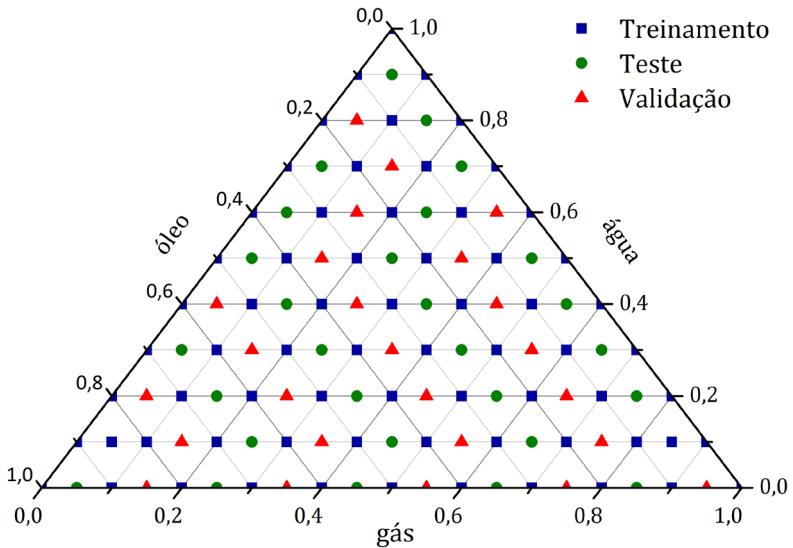


Figura 22 – Subconjuntos de Treinamento, Teste e Validação.

Assim, gerou-se um conjunto de 363 simulações ( $121 \times 3$ ) para diferentes combinações de FVF's e três regimes de fluxo (anular, estratificado e homogêneo), com o objetivo de criar subconjuntos distintos para o treinamento (TRT) (204 simulações), teste (TST) (84 simulações) e validação (VAL) (75 simulações) das RNAs utilizadas neste estudo. O subconjunto de Teste foi utilizado como critério de parada, utilizando Validação cruzada [39], para evitar o *overtraining*. O subconjunto de Validação foi utilizado para a avaliação final após o treinamento da RNA.

Para o cálculo da fração de volume, foram utilizadas três redes neurais (RNA2, RNA3 e RNA4), tipo *perceptron* multicamada com propagação do sinal adiante (MLP) com três camadas [39]. O algoritmo de aprendizado utilizado foi o de retropropagação [40]. As entradas e saídas das RNAs foram definidas da seguinte forma:

I. Entradas de RNA (106 neurônios):

- DAP1:<sup>2</sup> 20-720<sup>3</sup> keV, com passos de 10 keV ( $C_{20}, C_{30}, \dots, C_{720}$ );
- DAP2: 20-360 keV, com passos de 10 keV ( $C_{20}, C_{30}, \dots, C_{350}$ ).

II. Saídas da RNA (2 neurônios):

- Fração de volume água ( $H_2O+NaCl$ );
- Fração de volume de gás.

2. A DAP1 e a DAP2 correspondem à distribuição de altura de pulsos obtida pelos detectores 1 e 2, respectivamente.

3. A escolha da faixa de energia de cada DAP utilizada no treinamento foi baseada no valor de erro relativo ( $R$ ) inferior a 10% nas contagens, percentual considerado aceitável de acordo com o manual do MCNP6.

Vale destacar que, embora a RNA tenha duas saídas, a fração de volume da terceira fase é obtida por complemento. Esse conjunto de frações de volume foi escolhido empiricamente após a investigação de diversas combinações possíveis, incluindo a utilização de três frações de volume.

Como métricas de erro, foram utilizados o erro absoluto médio (MAE), o erro quadrático médio (MSE), o erro quadrático médio da raiz (RMSE), e o erro relativo médio percentual (MRE %), conforme descrito no tópico "Validação Cruzada", página 45 sobre Validação cruzada.

## IMPLEMENTAÇÃO E APLICAÇÃO METODOLÓGICA

### Identificação do Regime de Fluxo

Para ilustrar as diferenças nas DAPs conforme os regimes de fluxo, foram realizadas simulações de feixe gama transmitido e espalhado para as frações de volume de 30% de gás, 20% de água e 50% de óleo, nos regimes anular, estratificado e homogêneo. As DAPs obtidas para essas condições estão apresentadas na Figura 23.

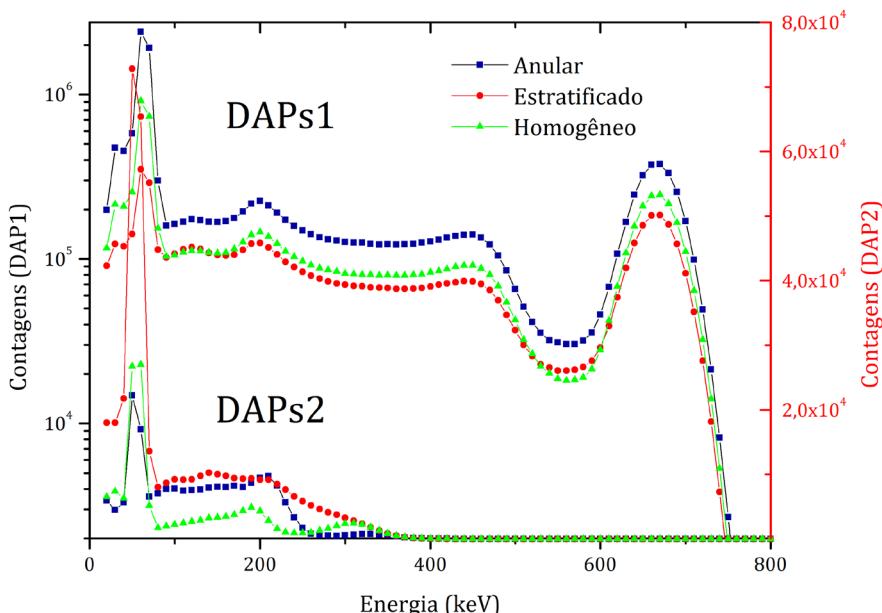


Figura 23 – DAPs obtidas pelo código MCNP6 para diferentes regimes de fluxo com frações de volume de 30% de gás, 20% de água e 50% de óleo.

A RNA proposta demonstrou um desempenho excepcional, alcançando 100% de precisão na identificação de todos os regimes de fluxo testados, com um total de 354 padrões. O subconjunto de Validação, composto por 75 padrões, também resultou em 100% de classificação correta, evidenciando a robustez do modelo.

É importante ressaltar que as redes neurais (RNA2, RNA3 e RNA4) foram adequadamente treinadas para os regimes anular, estratificado e homogêneo, conforme descrito no tópico "Geometria Proposta", página 57. As informações utilizadas no treinamento da RNA1, que foi responsável pela identificação do regime de fluxo, são as mesmas DAPs (DAP1 e DAP2) utilizadas para calcular as frações de volume.

Para o regime anular, as frações de volume foram calculadas por meio da Equação 22, Equação 23 e Equação 24. Para o regime de fluxo estratificado, utilizou-se a Equação 30, enquanto, para o regime homogêneo, as frações mássicas dos fluidos foram determinadas conforme descrito no tópico "Geometria Proposta", página 57. Na Figura 24 é apresentado um diagrama simplificado do sistema proposto para a identificação de regimes de fluxo com predição de FVFs.

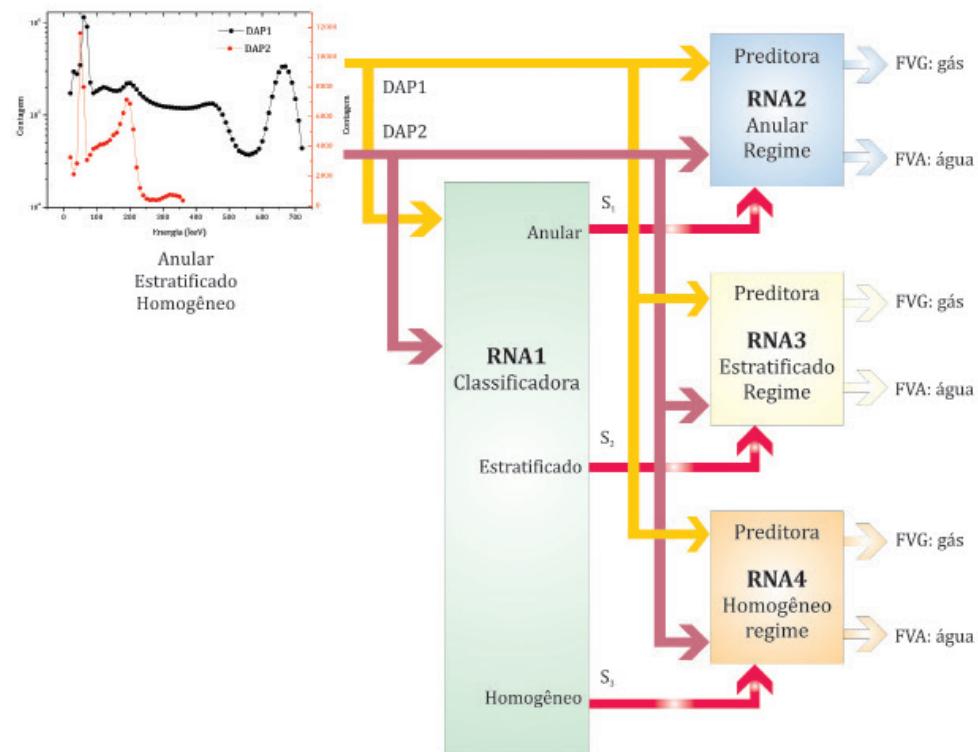


Figura 24 – Diagrama do sistema inteligente para identificação de regime de fluxo e predição das frações de volume.

Foi desenvolvido um sistema inteligente baseado em redes neurais artificiais, no qual a RNA1 é inicialmente responsável pela classificação do regime de fluxo. Com base nessa classificação, uma das redes RNA2, RNA3 ou RNA4 é ativada para predizer as frações volumétricas com maior precisão. O treinamento adequado dessas redes é fundamental para garantir a acurácia da predição das frações de volume.

## Determinação da Fração Volumétrica

Para ilustração das diferenças entre as DAPs para cada fração de volume, algumas simulações de feixe transmitido e espalhado obtidas pelos detectores 1 e 2, respectivamente, para os três regimes de fluxo com duas configurações diferentes de fração de volume são mostradas na Figura 25. A faixa de energia da DAP considerada foi de 20-800 keV.

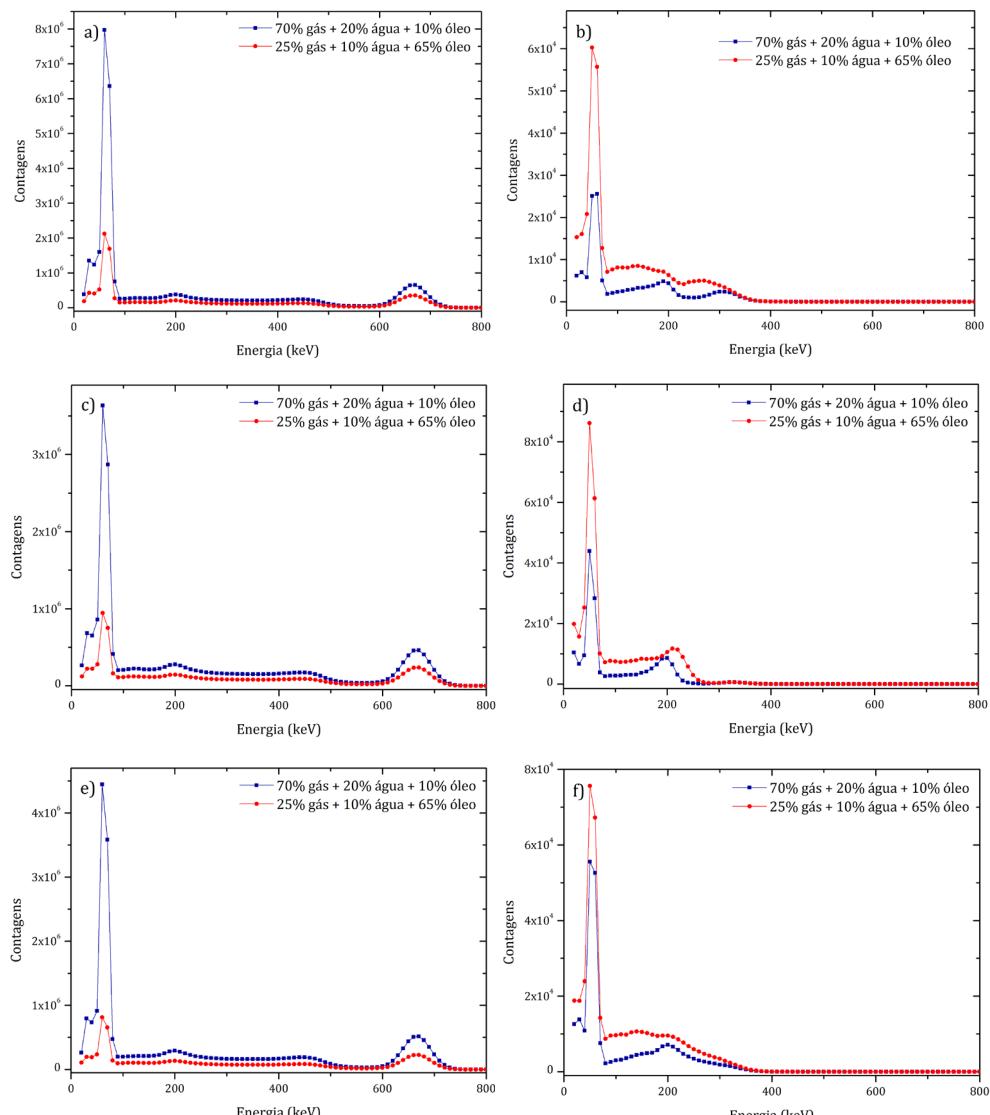


Figura 25 – DAPs obtidas pelo código MCNP6 para os regimes: anular: a) D1 e b) D2; estratificado: c) D1 e d) D2; homogêneo: e) D1 e f) D2.

A predição para o subconjunto de Teste dos regimes anular, estratificado e homogêneo é apresentada na Figura 26.

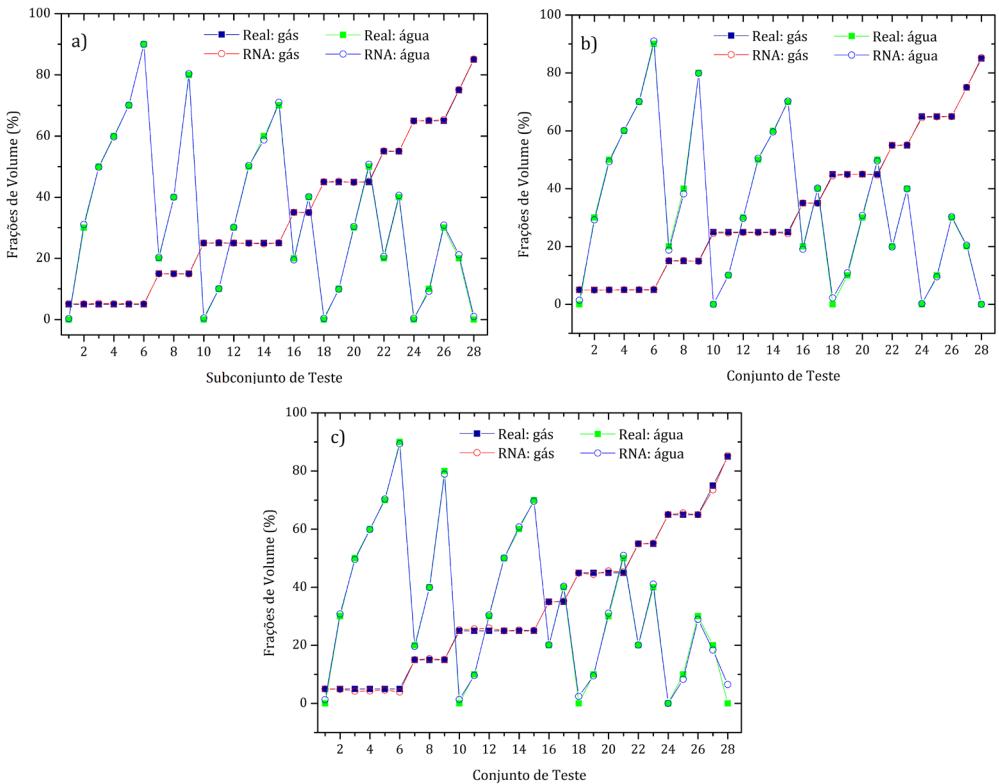


Figura 26 – Resultados obtidos para o subconjunto Teste nos regimes: a) anular; b) estratificado; c) homogêneo.

Os resultados indicam que as RNAs podem predizer adequadamente as frações de volume. Nota-se muito boa concordância entre a fração volumétrica real e predita pelas RNAs, demonstrando a capacidade de generalização das redes.

O subconjunto de Teste verifica a capacidade do modelo conseguir predizer com precisão os dados que não foram expostos durante a fase de aprendizado. Dessa forma, a análise dos resultados no subconjunto de Teste garante que o modelo não esteja excessivamente ajustado (*overfitting*) aos dados de treinamento, demonstrando sua eficácia em cenários reais e sua capacidade de predizer corretamente as frações volumétricas nos diferentes regimes de fluxo. As mesmas frações de volume foram implementadas nos três regimes de fluxo.

O desempenho das RNAs nas predições de FVF's está resumido na Tabela 6.

Faixa de erros relativos	Anular		Estratificado		Homogêneo	
	gás	água	gás	água	gás	água
≤ 5%	90,08	76,03	90,91	72,73	85,95	70,25
5% - 10%	0,85	4,96	0	9,09	1,65	9,09
10% - 20%	0	1,66	0	0,83	2,48	2,48
20% - 30%	0	0	0	0	0,83	0,83
> 30%	0	0	0	0	0	0
R2	1,0000	0,9998	1,0000	0,9996	0,9999	0,9992

Tabela 6 – Resumo do reconhecimento de padrões para os resultados da predição

Como pode ser visto, as RNAs puderam predizer mais de 70% de todos os padrões com erros inferiores a 5% (pior caso) para o gás e cerca de 80% com erros inferiores a 10% (pior caso) para frações de volume de água. Os padrões sem gás (0%) (9,09% do total) e sem água (17,35% do total) não foram considerados. As RNAs classificaram 95% de todos os dados para frações de volume de ar e água com erro de  $\pm 10\%$  para todos os regimes estudados.

Na Tabela 7, são apresentados os resultados obtidos para o conjunto de validação nas três redes treinadas: anular, estratificado e homogêneo. Esses resultados demonstram uma boa generalização das RNAs, indicando sua capacidade de predição de frações de volume em cada um desses regimes de fluxo.

Padrões	Anular				Estratificado				Homogêneo			
	gás (%)		água (%)		gás (%)		água (%)		gás (%)		água (%)	
	Real	RNA	Real	RNA	Real	RNA	Real	RNA	Real	RNA	Real	RNA
1	5	5,00	20	19,58	5	4,97	20	18,85	5	5,04	20	20,67
2	5	5,24	40	40,67	5	4,97	40	40,02	5	5,12	40	41,07
3	5	5,12	80	79,69	5	5,08	80	80,50	5	4,44	80	80,14
4	15	15,02	0	0,51	15	14,90	0	0,00	15	15,21	0	0,00
5	15	15,03	10	9,80	15	15,02	10	9,31	15	15,19	10	10,05
6	15	14,98	30	29,37	15	15,08	30	28,82	15	15,70	30	30,03
7	15	14,79	50	49,44	15	15,08	50	49,50	15	14,56	50	49,72
8	15	14,86	60	59,41	15	15,16	60	60,26	15	14,86	60	59,38
9	15	14,76	70	68,83	15	15,23	70	68,50	15	14,58	70	69,80
10	25	25,17	20	19,10	25	24,82	20	19,14	25	25,70	20	21,28
11	25	24,76	40	39,93	25	24,64	40	41,09	25	24,69	40	38,98
12	35	34,83	0	0,07	35	34,35	0	0,45	35	34,68	0	0,76
13	35	34,98	10	9,95	35	34,75	10	9,83	35	34,81	10	10,28
14	35	34,52	30	29,82	35	35,01	30	30,39	35	34,88	30	29,97
15	35	34,95	50	49,01	35	35,03	50	50,11	35	35,23	50	49,63
16	35	34,92	60	61,06	35	34,77	60	60,26	35	34,64	60	59,36
17	45	44,78	20	19,92	45	45,08	20	20,38	45	45,16	20	19,57
18	45	44,80	40	39,74	45	45,05	40	39,46	45	45,21	40	39,06
19	55	55,15	0	0,65	55	54,55	0	2,14	55	54,72	0	1,53
20	55	54,75	10	9,35	55	55,10	10	10,71	55	54,95	10	8,09
21	55	54,93	30	30,31	55	55,00	30	30,10	55	55,81	30	28,25
22	65	64,97	20	20,58	65	64,68	20	18,93	65	65,55	20	18,33
23	75	75,04	0	0,00	75	75,15	0	0,17	75	75,21	0	4,59
24	75	74,94	10	9,79	75	75,11	10	9,01	75	73,15	10	8,43
25	95	95,63	0	0,67	95	94,78	0	3,84	95	95,75	0	0,00

Tabela 7 – Predição de RNA para o conjunto de validação nos regimes anular, estratificado e homogêneo

Modelos lineares foram ajustados aos dados a partir da correlação entre as frações de volume real e previsto pelas RNAs para todos os padrões e para o conjunto de validação usando um procedimento de mínimos quadrados e coeficientes de determinação ( $R^2$ ). Os resultados estão resumidos na Tabela 8, demonstrando uma boa convergência das RNAs (RNA2, RNA3 e RNA4) sobre todos os dados do conjunto de predição de FVFs para os três regimes estudados.

Regime de Fluxo	$R^2$ (Todos os padrões)		Erro Relativo <sup>4</sup> (%) (Subconjunto VAL)	
	gás	água	gás	água
Anular	1,0000	0,9998	0,73	1,48
Estratificado	1,0000	0,9996	0,61	2,56
Homogêneo	0,9998	0,9989	1,73	3,31

Tabela 8 – Resultados do treinamento das RNAs

## Desenvolvimento de uma Rede Neural Profunda para a predição da fração de volume de fluidos

Este estudo propõe uma nova abordagem para a predição de fração de volume de fluidos, utiliza um modelo simulado baseado em densitometria de raios gama acoplado a uma rede neural profunda (DNN). O objetivo é predizer simultaneamente as três frações de volume dos fluidos (gás, água e óleo), com intuito de aprimorar a precisão das respostas da rede.

Embora a busca manual de hiperparâmetros por tentativa e erro, quando guiada por um especialista, possa gerar bons resultados, a avaliação de cada configuração de hiperparâmetros é demorada e o número de combinações avaliadas é limitado. Em virtude disso, diversos trabalhos na literatura têm se dedicado ao desenvolvimento de métodos que realizam automaticamente a busca de hiperparâmetros. Alguns dos métodos mais comuns incluem: Busca Aleatória (Random Search) [41]; Projeto Robusto de Redes Neurais Artificiais (*Robust Design of Artificial Neural Networks – RDANN*) [42] e Otimização Bayesiana (*Bayesian Optimization*) [43].

O algoritmo de otimização com taxa de aprendizagem adaptativa, conhecido como Adam [44], foi utilizado para o treinamento de DNN. O código MCNP6 foi utilizado para simular a transmissão e o espalhamento de raios gama em regime de fluxo anular. Os espectros foram registrados com detectores cintiladores. No entanto, diferentemente da abordagem apresentada no tópico "Implementação e Aplicação Metodológica", deste capítulo, página 63, uma DNN foi desenvolvida e treinada com um banco de dados significativamente maior do que o utilizado com a rede neural rasa (RNA).

Na geometria de medição ilustrada na Figura 19 (descrito no tópico "Geometria Proposta", página 58), o Detector 2 teve sua posição investigada em 90° e 135°. Pequenas modificações foram realizadas no sistema, que é composto por um tubo de aço inoxidável 316 L, com 27,0 cm de diâmetro externo e 0,4 cm de espessura e densidade de 8,0 g.cm<sup>-3</sup>. Neste estudo, foi utilizada água salgada (4% de fração mássica de NaCl) para simular a salinidade média da água nos mares do mundo [20].

4. Os padrões que não apresentaram a presença de qualquer fluido (por exemplo, 0% de gás) foram desconsiderados no cálculo do erro relativo.

## Treinamento da DNN

A geração do conjunto de dados para treinamento da rede foi realizada de forma semelhante à descrita no tópico "Geometria Proposta", página 57. No entanto, neste caso, apenas o regime de fluxo anular foi investigado, e os valores das espessuras  $r_g$ ,  $r_\alpha$  e  $r_\theta$  (ver Figura 20a) foram ajustados, já que o objetivo era avaliar o potencial da DNN.

Para gerar um conjunto de dados significativamente maior que o utilizado na rede rasa, foram realizadas várias combinações de FVFs, variando de 2,1 a 99,8%, com passos de 2%. Esse procedimento gerou um total de 1225 padrões. Para cada um desses 1225 padrões, o código MCNP6 foi utilizado para obter as DAPs (espectros) relativas aos feixes transmitidos e espalhados. Neste estudo, a rede neural utilizada é do tipo DNN de 8 camadas, e foi treinada através de aprendizado supervisionado utilizando o algoritmo de otimização Adam e retropropagação de erros.

Para avaliar o desempenho do modelo DNN na predição de FVFs, o conjunto de dados original foi aleatoriamente dividido em três subconjuntos, utilizando o método de Validação cruzada, conforme mostrado na Figura 27.

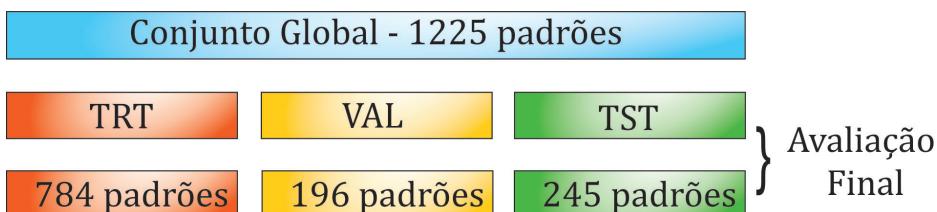


Figura 27 – Validação cruzada utilizada nesta investigação.

- I. Subconjunto de treinamento (TRT): 784 padrões, correspondentes a 64% do conjunto original, utilizados para treinar o modelo DNN;
- II. Subconjunto de Validação (VAL): 196 padrões, correspondentes a 16% do conjunto original, utilizados para avaliar a capacidade de generalização do modelo durante o treinamento, prevenindo o *overtraining*;
- III. Subconjunto de Teste (TST): 245 padrões, correspondentes a 20% do conjunto original, utilizados para a avaliação final do desempenho do modelo.

Em redes neurais profundas, o conjunto de Teste (TST) é utilizado para a avaliação final da rede, enquanto o conjunto de validação (VAL), comumente utilizado em redes neurais rasas, é destinado à validação do modelo durante o treinamento. É importante destacar que, para as RNAs, foram utilizados subconjuntos de Treinamento, Teste e Validação, enquanto nas DNNs, os subconjuntos são chamados de Treinamento, Validação e Teste. Embora a nomenclatura seja diferente, as funções desses subconjuntos são equivalentes, com a única distinção sendo a terminologia adotada.

Além disso, para melhorar o desempenho da DNN durante a aprendizagem, as amostras de dados foram normalizadas conforme a Equação 31, utilizando o método de normalização *Layer Normalization* [45]. Esse método é utilizado para aumentar a velocidade de treinamento e a estabilidade da DNN, normalizando as atividades dos neurônios.

$$X_N = \frac{(X - X')}{S}$$

Equação 31

Em que:

$X_N$  – Valor normalizado;

$X$  – Valor original;

$X'$  – Média dos valores;

$S$  – Desvio padrão.

A resposta da rede às frações de volume para cada subconjunto foi avaliada utilizando as métricas MSE, MRE, MAE e RMSE.

Depois do treinamento e da validação da DNN, ela pode ser utilizada para predizer as frações de volume de fluidos sem a necessidade de ajustes adicionais, sendo capaz de realizar medições em tempo real.

## RESULTADOS E DISCUSSÃO

Os subconjuntos de padrões utilizados para o treinamento, validação e teste da DNN foram selecionados aleatoriamente a partir do conjunto principal de dados. Para ilustrar a distribuição dos padrões nos diferentes subconjuntos, foi utilizado um ternário,<sup>5</sup> apresentado na Figura 28. Nesse diagrama, cada ponto representa um padrão específico, com combinações distintas de frações de volume dos fluidos gás, água e óleo.

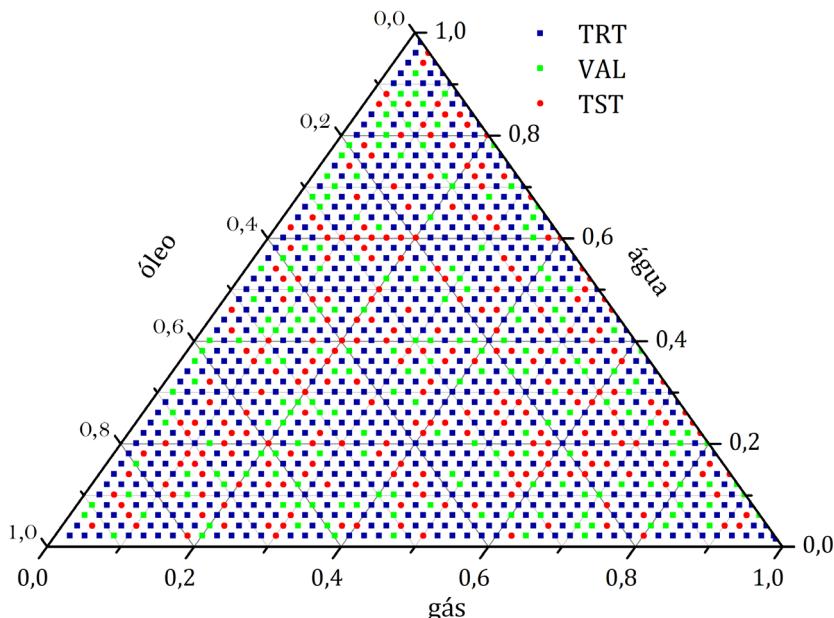


Figura 28 – Diagrama ternário representando os subconjuntos de Treinamento, Validação e Teste selecionados aleatoriamente.

5. É utilizado para mostrar as proporções de um sistema composto de variáveis cuja soma é igual a 100%. Ele retrata graficamente as proporções de três variáveis, como água, gás e óleo (petróleo), em um triângulo equilátero.

## O processo de concepção do modelo DNN

A definição dos hiperparâmetros de uma DNN, como o número de camadas, neurônios, e a escolha das funções de ativação, representa um dos maiores desafios no projeto de redes DNN para tarefas específicas. Tradicionalmente, esse processo é realizado por tentativa e erro, com base no conhecimento do especialista, levando em consideração fatores, como o tipo de problema (classificação, regressão ou previsão) e as características do conjunto de dados (quantidade de amostras, dimensões de entrada e número de saídas).

Neste estudo, a otimização bayesiana foi utilizada para tornar o processo de ajuste de hiperparâmetros mais eficiente, reduzindo o esforço manual. A biblioteca Hyperas [46] foi utilizada para implementar a otimização, com o seguinte conjunto de hiperparâmetros e seus respectivos intervalos definidos para a busca automatizada:

1. Número de camadas ocultas: de 1 a 10, com incremento de 1;
2. Número de neurônios por camada oculta: de 100 a 1000, com incremento de 100;
3. Função de ativação das camadas ocultas: ReLu, ELU e SELU.

Os hiperparâmetros restantes foram definidos manualmente:

- I. Otimizador: Adam;
- II. Função de erro: MSE;
- III. Número de épocas: 5500;
- IV. Tamanho do lote (*batch size*): 32.

Para a busca de hiperparâmetros, apenas os subconjuntos de Treinamento e Validação foram utilizados. Após o processo de otimização, o modelo DNN que apresentou o menor erro no subconjunto de Validação foi selecionado. Esse modelo final, denominado 8-DNN, é composto por oito camadas, cuja configuração de hiperparâmetros está apresentada na Tabela 9.

Número	Camada	Número de neurônios	Função de Ativação
1	Entrada	106	-
2		400	ELU
3		400	ELU
4	Ocultas	500	SELU
5		100	SELU
6		500	ELU
7		900	SELU
8	Saída	2	ReLu

Tabela 9 – Configuração da arquitetura da DNN

As entradas da DNN consistem nas DAPs, normalizadas conforme a Equação 31, sendo registradas nos detectores D1 e D2. Essas DAPs foram mapeadas para 106 neurônios de entrada da seguinte forma:

- I. DAP1: Contagens de energia de 20 a 720 keV ( $C_{20}, C_{30}, \dots, C_{720}$  – totalizando 71 canais);
- II. DAP2: Contagens de energia de 20 a 360 keV ( $C_{20}, C_{30}, \dots, C_{330}$  – totalizando 35 canais).

As saídas da DNN foram representadas por 2 neurônios, correspondendo às frações volumétricas de gás e água. A fração volumétrica do óleo foi calculada a partir do complemento utilizando a Equação 25. Na Figura 29 é ilustrada a arquitetura da DNN utilizada neste estudo.

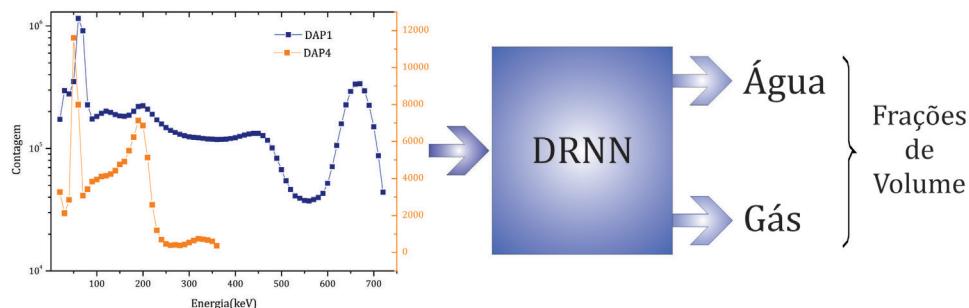
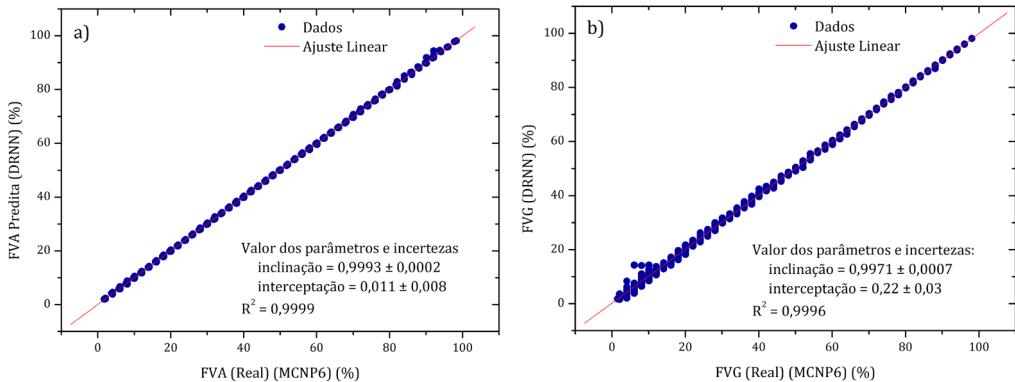


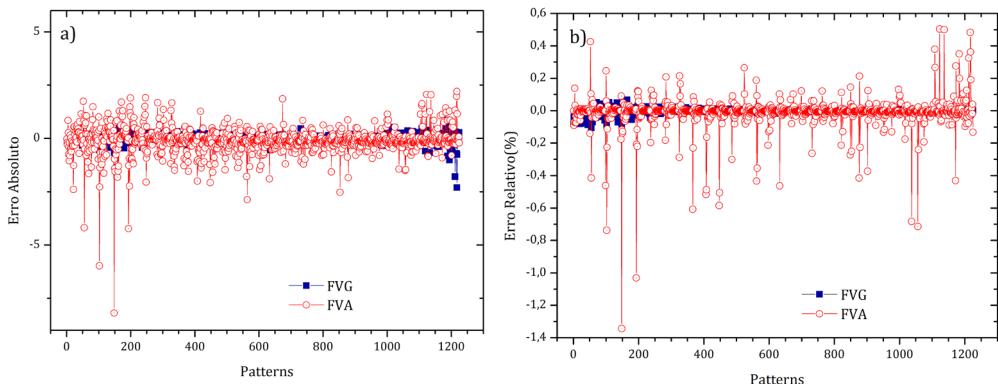
Figura 29 – Representação esquemática da DNN projetada para o treinamento.

## Desempenho do modelo DNN

Para avaliar o desempenho do modelo DNN com 8 camadas, foi utilizado o subconjunto de Teste, composto por 245 padrões que não foram apresentados ao modelo durante o treinamento. Na Figura 30, são apresentados os diagramas de regressão que compararam os dados simulados e os valores preditos pela DNN para as frações volumétricas de gás e água. Os diagramas evidenciam uma boa concordância entre os dados reais e os valores preditos pela rede neural. Essa concordância é corroborada pelo elevado valor do coeficiente de determinação ( $R^2$ ), que reflete a capacidade do modelo de explicar a variabilidade nos dados.



Na Figura 31, são apresentados os resultados dos erros absoluto (EA) e relativo (ER) em função das frações volumétricas dos fluidos. O EA é definido como a diferença entre o valor predito pela DNN e o valor real, sendo utilizado como métrica de exatidão dos valores calculados.



**Figura 31 – Métricas de avaliação da predição da rede DNN: a) EA; b) ER.**

Observa-se que a maioria dos desvios está, razoavelmente, centrada em torno de zero, indicando uma boa precisão do modelo. Embora alguns padrões apresentem erros mais elevados, especialmente associados a valores baixos de FVF, a maioria das amostras apresenta erros inferiores a 5%. O erro relativo médio calculado para todos os padrões foi de 0,99% para o gás e 4,54% para a água.

Para ilustrar o desempenho do modelo implementado, os dados reais e os calculados pela DNN para o subconjunto de Teste são apresentados na *Figura 32*.

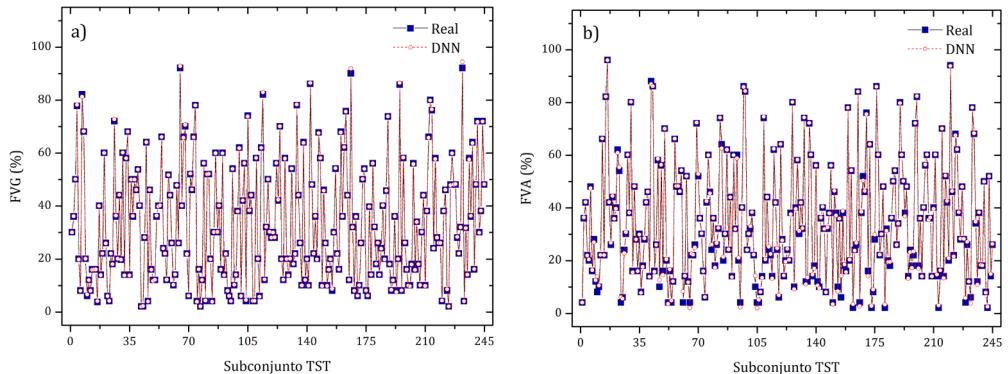


Figura 32 – Desempenho da rede neural DNN para subconjunto de Teste: a) gás; b) água.

Diversas métricas matemáticas foram utilizadas para medir a exatidão do modelo em variáveis contínuas durante o treinamento da rede neural, como MAE, MSE, RMSE e MRE%. Na Tabela 10 é resumido os resultados obtidos para essas métricas, considerando o conjunto global e os subconjuntos de Treinamento, Validação e Teste.

FVF (%)				
Conjunto Global		Subconjunto de Teste (TST)		
Métrica	gás	água	gás	água
MAE	0,10642	0,36959	0,16234	0,58073
MSE	0,02858	0,40147	0,07675	1,06123
RMSE	0,16904	0,63362	0,27704	1,03016
MRE (%)	0,64	3,33	0,91	5,82
Número de padrões	1225		245	
Subconjunto de Treinamento (TRT) Subconjunto de Validação (VAL)				
Métrica	gás	água	gás	água
MAE	0,08147	0,27054	0,13635	0,501911
MSE	0,01064	0,16126	0,04011	0,537622
RMSE	0,10314	0,40157	0,20027	0,73227
MRE (%)	0,52	2,17	0,8	4,87
Número de padrões	784		196	

Tabela 10 – Critérios de desempenho do modelo DNN

Os resultados mostram que a metodologia proposta é capaz de estimar, com alta precisão, as frações volumétricas de gás, água e óleo em sistemas multifásicos encontrados na indústria do petróleo e gás. O modelo apresentou valores de RMSE inferiores a 1,18, indicando um bom desempenho na minimização das diferenças entre os valores preditos e os reais. Além disso, o MRE% máximo observado foi inferior a 5%, reforçando a robustez da abordagem utilizada.

## CONCLUSÕES

Este estudo de caso promoveu avanços significativos nas metodologias para identificação de regime de fluxo e predição de frações volumétricas. Foi demonstrado que um sistema de detecção compacto, composto por apenas dois detectores, pode fornecer medições confiáveis e adequadas para essas finalidades. A utilização de DAPs não parametrizadas, embora normalizadas antes de serem utilizadas como dados de entrada, contribuiu para informações mais detalhadas sobre os espectros medidos.

O uso do código MCNP6 mostrou-se eficaz para modelar o sistema de detecção e os efeitos de interação da radiação com a matéria, resultando em uma representação próxima da realidade. Isso permitiu a geração de dados para treinamento das RNAs por meio de simulações, eliminando a necessidade inicial de dados experimentais, especialmente em etapas preliminares do projeto.

A arquitetura das RNAs apresentou a capacidade de predizer frações volumétricas sem a necessidade de conhecimento prévio sobre o regime de fluxo. Esse resultado foi possível devido à alta precisão da RNA1, que identificou corretamente 100% dos regimes de fluxos avaliados. As RNAs específicas para os regimes anular (RNA2), estratificado (RNA3) e homogêneo (RNA4) também obtiveram desempenho destacado, com erros relativos máximos inferiores a 3,5%.

Adicionalmente, foi avaliada a aplicação de DNN em um conjunto de dados mais extenso, visando aprimorar o desempenho de medidores multifásicos. O conjunto de amostras variou de 2,1% a 98% de fração volumétrica, com incrementos de 2%, totalizando 1.225 amostras para o treinamento e 196 para testes operacionais. A DNN demonstrou ser ferramenta robusta na predição das frações volumétricas de gás, água e óleo. No caso de escoamentos trifásicos em regime anular, os resultados obtiveram valores de RMSE inferiores a 1,05 e MRE abaixo de 6% para o subconjunto de Teste. Embora o MRE da DNN tenha sido superior ao das RNAs, destaca-se que o uso de um banco maior confere maior estabilidade aos resultados. Além disso, a faixa de frações volumétricas utilizada na DNN foi mais ampla, iniciando em 2,1%, enquanto, nas RNAs, o início foi em 5%. A sensibilidade do MRE a valores pequenos pode explicar os índices mais elevados.

O desenvolvimento de DNN, entretanto, apresenta desafios adicionais, como a otimização de numerosos hiperparâmetros. A ausência de técnicas de regularização, como *dropout*<sup>6</sup> [47] ou normalização de *batch*, pode ter influenciado os resultados ao favorecer o sobreajuste. Entretanto, a experiência deste estudo revelou que, embora essas técnicas sejam eficazes na redução do sobreajuste, seu uso pode, em alguns casos, comprometer ligeiramente a precisão do modelo. Isso ressalta a importância de avaliar cuidadosamente a aplicação dessas estratégias em função das características específicas do problema. Além disso, as RNAs enfrentam problemas e bancos de dados extensos, o que pode estagnar o treinamento (perda do gradiente).

6. *O dropout é um método amplamente utilizado para evitar o overfitting em RNAs. Ele baseia-se no desligamento aleatório de uma fração dos neurônios durante o treinamento.*

Em resumo, a metodologia proposta demonstrou avanços importantes na caracterização de escoamentos multifásicos, com as seguintes melhorias destacadas:

- I. Desenvolvimento de um sistema de detecção mais compacto;
- II. Melhoria na precisão da RNA;
- III. Predição automática de frações volumétricas sem conhecimento prévio do regime de fluxo.

A precisão alcançada pela DNN na predição de frações volumétricas é particularmente relevante para a indústria petrolífera. Apesar do sucesso, futuras investigações em fluxos dinâmicos, que exigem adaptações e aprimoramentos na metodologia, são necessárias para as aplicações práticas. Nesse sentido, uma instalação experimental está em fase de desenvolvimento, consolidando a aplicabilidade da abordagem proposta.

## REFERÊNCIAS

- [1] Mosorov, V.; Zych, M.; Hanus, R.; Sankowski, D.; Saoud, A. Improvement of Flow Velocity Measurement Algorithms Based on Correlation Function and Twin Plane Electrical Capacitance Tomography, *Sensors*, v. 20, n. 1:306, 2020. Disponível em: <https://doi.org/10.3390/s20010306>
- [2] Faia, P.; Silva, R.; Rasteiro, M.G.; Garcia, F. Electrical Tomography: A Review of Configurations, and Application to Fibre Flow Suspensions Characterisation. *Applied Sciences*, v. 10, n. 7, 2020. Disponível em: <https://doi.org/10.3390/app10072355>
- [3] Song, K.; Liu, Y. A compact x-ray system for two-phase flow measurement. *Measurement Science and Technology*, v. 29, n. 2, 2018. Disponível em: <https://doi.org/10.1088/1361-6501/aaa283>
- [4] Chuong, H.D.; Hai Yen, N.T.; My Le, N.T.; Duc Tam, H. Determining the density of liquid using gamma scattering method. *Applied Radiation and Isotopes*, v. 163, 2020. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109197>
- [5] Zhao, Y.; Bi, Q.; Yuan, Y.; Lv, H. Void fraction measurement in steam–water two phase flow using the gamma ray attenuation under high pressure and high temperature evaporating conditions. *Flow Measurement and Instrumentation*, v. 49, p. 8-30, 2016.
- [6] Roshani, G.H.; Hanus, R.; Khazaei, A.; Zych, M.; Nazemi, E.; Mosorov, V. Density and velocity determination for single-phase flow based on radiotracer technique and neural networks. *Flow Measurement and Instrumentation*, 61, p. 9-14, 2018.
- [7] Salgado, C.M.; Brandão, L.E.B.; Conti, C.C.; Salgado, W.L. Density prediction for petroleum and derivatives by gamma-ray attenuation and artificial neural networks. *Applied Radiation and Isotopes*, v. 116, p. 143-149, 2016.
- [8] Oliveira, D.F.; Nascimento, J.R.; Marinho, C.A.; Lopes, R.T. Gamma transmission system for detection of scale in oil exploration pipelines. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 784, p. 616-6220, 2015. Disponível em: <https://doi.org/10.1016/j.nima.2014.11.030>

- [9] Salgado, W.L.; Dam, R.S.F.; Teixeira, T.P.; Conti, C.C.; Salgado, C.M. Application of artificial intelligence in scale thickness prediction on offshore petroleum using a gamma-ray densitometer. *Radiation Physics and Chemistry*, v. 168, 2020a. Disponível em: <https://doi.org/10.1016/j.radphyschem.2019.108549>
- [10] Affonso, R.R.W.; Dam, R.S.F.; Salgado, W.L.; Silva, A.X.; Salgado, C.M. Flow regime and volume fraction identification using nuclear techniques, artificial neural networks and computational fluid dynamics. *Applied Radiation and Isotopes*, v. 159, 2020. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109103>
- [11] Faghihi, R.; Nematollahi, M.; Erfaninia A.; Adineh, M. Void fraction measurement in modeled two-phase flow inside a vertical pipe by using polyethylene phantoms. *International Journal of Hydrogen Energy*, v. 40, n. 44, 26 p. 15206-15212, 2015.
- [12] Hanus, R.; Petryka, L.; Zych, M. Velocity measurement of the liquid–solid flow in a vertical pipeline using gamma-ray absorption and weighted cross-correlation. *Flow Measurement and Instrumentation*, v. 40, p. 58-63, 2014.
- [13] Hanus, R. Application of the Hilbert Transform to measurements of liquid–gas flow using gamma ray densitometry. *International Journal of Multiphase Flow*, v. 72, p. 210-217, 2015.
- [14] Hanus, R.; Zych, M.; Kusy, M.; Jaszczur, M.; Petryka, L. Identification of liquid-gas flow regime in a pipeline using gamma-ray absorption technique and computational intelligence methods. *Flow Measurement and Instrumentation*, v. 60, p. 17-23, 2018.
- [15] Mosorov, V. Improving the accuracy of single radioactive particle technique for flow velocity measurements. *Flow Measurement and Instrumentation*, v. 66, p. 150-156, 2019.
- [16] Salgado, W.L.; Dam, R.S.F.; Barbosa, C.M.; Silva, A.X.; Salgado, C.M. Monitoring system of oil by-products interface in pipelines using the gamma radiation attenuation. *Applied Radiation and Isotopes*, v. 160, 2020b. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109125>
- [17] Dam, R.S.F.; Teixeira, T.P.; Salgado, W.L.; Salgado, C.M. A new application of radioactive particle tracking using MCNPX code and artificial neural network. *Applied Radiation and Isotopes*, v. 149, p. 38-47, 2019.
- [18] Yadav, A.; Gaurav, T.K.; Pant, H.J.; Roy, S. Machine learning based position-rendering algorithms for radioactive particle tracking experimentation. *American Institute of Chemical Engineers*, v. 66, n. 6, 2020. Disponível em: <https://doi.org/10.1002/aic.16954>
- [19] Abouelwafa, M.S.A.; Kendall, E.J.M., 1980. The measurement of component ratios in multiphase systems using gamma-ray attenuation. *Journal of Physics E: Scientific Instruments*, 13, p. 341-345.
- [20] Johansen, G.A.; Froystein, T.; Hjertaker, B.T.; Isaksen, Ø.; Olsen, Ø.; Strandos, S.K.; Olsen, T.S.; Åbro, E.; McKibben, B.; Heggstad, S.; Hammer, E. The design of a dual mode tomography for three-component flow imaging. In: Proceedings of European Concerted Action of Process Tomography (ECAPT), Oporto, Portugal, March, p. 24-27, 1994.
- [21] Åbro, E.; Johansen G. A.; Opedal, H. A radiation transport model as a design tool for gamma densitometers. *Nuclear Instruments and Methods in Physics Research*, A431, p. 347-355, 1998.

- [22] Åbro, E.; Khoryakov, V.A.; Johansen, G.A.; Kocbach, L. Determination of void fraction and flow regime using a neural network trained on simulated data based on gamma-ray densitometry. *Measurement Science and Technology*, v. 10, p. 619-630, 1999.
- [23] Tjugum, S.A.; Johansen, G.A.; Holstad, M.B. The use of gamma radiation in fluid flow measurements. *Radiation Physics and Chemistry*, v. 61, p. 797-798, 2001.
- [24] Tjugum, S.A.; Frieling, J.; Johansen, G.A.A. Compact low energy multibeam gamma-ray densitometer for pipe-flow measurements. *Nuclear Instruments and Methods in Physics Research, B* 197, p. 301-309, 2002.
- [25] Wu, H.; Zhou, F.; Wu, Y. Intelligent identification system of flow regime of oil-gas-water multiphase flow. *International Journal of Multiphase Flow*, v. 27, p. 459-475, 2001.
- [26] Jin, N. D.; Nie, X. B.; Ren, Y.Y.; Liu, X.B. Characterization of oil/água two-phase flow patterns based on nonlinear time series analysis. *Flow Measurement and Instrumentation*, v. 14, p. 169-175, 2003.
- [27] Mi, Y.; Tsoukalas, L.H.; Ishii, M. Application of multiple self-organizing neural networks: Flow pattern classification. *Transactions of the American Nuclear Society*, v. 77, p. 114-116, 1997.
- [28] Mi, Y.; Ishii, M.; Tsoukalas, L. Vertical two-phase flow identification using advanced instrumentation and neural networks. *Nuclear engineering and design*, v. 184, n. 2-3, p. 409-420, 1998.
- [29] Salgado, C.M.; Brandão, L.E.; Schirru, R.; Pereira, C.M.N.A.; Ramos, R.; Silva, A.X. Study of volume fractions for stratified and annular regimes in multiphase flows using gamma-rays and artificial neural network. In: 5<sup>th</sup> International Nuclear Atlantic Conference - INAC, Santos, SP, BR, 2007.
- [30] Salgado, C.M.; Brandão, L.E.B.; Schirru, R.; Pereira, C.M.N.A.; Xavier, A.S.; Ramos R. Prediction of volume fractions in three-phase flows using nuclear technique and artificial neural network. *Applied Radiation and Isotopes*, v. 67, p. 1812-1818, 2009.
- [31] Bishop, C.M.; James, G.D. Analysis of multiphase flows using dual-energy gamma densitometry and neural networks. *Nuclear Instruments and Methods, A*, v. 327, p. 580-593, 1993.
- [32] Adineh, M.; Nematollahi, M.; Erfaninia, A. Experimental and numerical void fraction measurement for modeled two-phase flow inside a vertical pipe. *Annals of Nuclear Energy*, v. 83, p. 188-192, 2015.
- [33] Karami, A.; Roshani, G.H.; Khazaei, A.; Nazemi, E.; Fallahi, M. Investigation of different sources in order to optimize the nuclear metering system of gas-oil-water Annular flows. *Neural Computing and Applications*, v. 32, p. 3619-3631, 2018.
- [34] Johansen, G.A.; Jackson, P., 2000. Salinity independent measurement of gas volume fraction in oil/gas/water pipe flows. *Applied Radiation and Isotopes*, 53, p. 595-601.
- [35] Hussein, E.M.A.; Han, P. Phase volume-fraction measurement in oil-water-gas flow using fast neutrons. *Nuclear Geophysics*, v. 9, n. 3, p. 229-234, 1995.
- [36] Goorley, T.; James, M.; Booth, T.; Brown, F.; Bull, J.; Cox, L.J.; Durkee, J.; Elson, J.; Fensin, M.; Forster, R.A.; Hendricks, J.; Hughes, H.G.; Johns, R.; Kiedrowski, B.; Martz, R.; Mashnik, S.; McKinney, G.; Pelowitz, D.; Prael, R.; Sweezy, J.; Waters, L.; Wilcox, T.; Zukaitis, T. Features of MCNP6. *Annals of Nuclear Energy*, v. 87, p. 772-783, 2016.

- [37] Hubbell, J.H.; Seltzer, S.M., 1997. Tables of X-ray mass attenuation coefficients and mass energy-absorption coefficients from 1 keV to 20 MeV for elements Z=1 to 92 and 48 additional substances of dosimetric interest. *NIST Standard Reference Database 126*, julho 2004. Disponível em: <https://www.nist.gov/pml/x-ray-mass-attenuation-coefficients>
- [38] McConn Jr., R.J.; Gesh, C.J.; Pagh, R.T.; Rucker, R.A.; Williams III, R.G. *Compendium of Material Composition Data for Radiation Transport Modeling*, Radiation portal monitor project, Pacific Northwest, National Laboratory. PIET-43741-TM-963 PNNL-15870 Rev. 1, 2011.
- [39] Haykin, S. *Neural Networks – A Comprehensive Foundation*. Macmillan College Publishing Company, 1994.
- [40] Chauvin, Y.; Rumelhart, D.E. *Back-propagation Theory, Architectures and Applications*, 1995.
- [41] Bergstra, J.; Bengio, Y. Random Search for Hyper-Parameter Optimization. *Journal of Machine Learning Research*, v. 13, p. 281-305, 2012.
- [42] Ortiz-Rodriguez, J.M.; Martínez-Blanco, M.D.R.; Viramontes, J.M.C.; Vega-Carrillo, H.R. Robust Design of Artificial Neural Networks Methodology in Neutron Spectrometry. *Artificial Neural Networks - Architectures and Applications*, 2013. Disponível em: <https://doi.org/10.5772/3409>
- [43] Snoek, J.; Larochelle, H.; Adams, R.P. Practical Bayesian optimization of machine learning algorithms. *Advances in Neural Information Processing Systems*, 25, p. 2951-2959, 2012.
- [44] Kingma, D.P.; Ba, J.L. Adam: a method for stochastic optimization. In: Proceedings of 3rd International Conference for Learning Representations, 2015. San Diego. arXiv:1412.6980.
- [45] Ba, J.L.; Kiros, J.R.; Hinton, G.E. *Layer Normalization*. Machine Learning, 2016. <https://doi.org/10.48550/arXiv.1607.06450>
- [46] Pumperla, Max. *Hyperas: Simplified hyperparameter optimization for Keras*, 2017. Disponível em: <https://github.com/maxpumperla/hyperas>. Acesso em: 22 dez. 2024.
- [47] Srivastava, N.; Hinton, G.E.; Krizhevsky, A.; Sutskever, I.; Salakhutdinov, R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *The Journal of Machine Learning Research*, v. 15, n. 1, p. 1929-1958, 2014.

## CAPÍTULO 4

# CÁLCULO DE FRAÇÕES DE VOLUME EM SISTEMAS MULTIFÁSICOS BASEADOS EM RAIOS X

**César Marques Salgado**

**William Luna Salgado**

**Roos Sophia de Freitas Dam**

**Claudio de Carvalho Conti**

A formação do petróleo ocorre ao longo de milhões de anos em rochas sedimentares, tanto em áreas marinhas quanto terrestres. Considerado a principal fonte de energia do mundo moderno, o petróleo está presente em diversos produtos de uso diário, como diesel, gasolina, óleo combustível, gás liquefeito de petróleo e querosene de aviação, além de compostos utilizados na fabricação de plásticos, tintas e borrachas, entre outros produtos. Devido à crescente demanda global, há um esforço contínuo para expandir a capacidade produtiva por meio do desenvolvimento de novos processos de extração e produção. No Brasil, grande parte das reservas de petróleo encontrase em campos *offshore* em

águas profundas, o que tem impulsionado a exploração em locais cada vez mais desafiadores. A descoberta de novas reservas requer pesquisas extensivas e o desenvolvimento de tecnologias avançadas para identificar bacias promissoras e determinar os melhores locais para perfuração. Antes da fase de produção, realiza-se a perfuração para confirmar a presença de hidrocarbonetos e avaliar a viabilidade comercial do poço de petróleo. Durante a extração, o petróleo é extraído juntamente com gás e água. Nas plataformas, esses fluidos são separados e enviados a terminais na costa brasileira, de onde seguem para as refinarias. O monitoramento da vazão de cada fase que escoa nas tubulações é essencial para o controle e otimização da produção. Tradicionalmente, separadores de teste gravitacionais são utilizados, mas esses equipamentos envolvem custos elevados, operação complexa e grande consumo de tempo.

Por outro lado, os medidores multifásicos oferecem uma solução mais eficiente, permitindo a medição de forma contínua e em tempo real, sem a necessidade de separar as fases. Essa tecnologia possibilita o gerenciamento dinâmico do desempenho dos poços, aumentando a eficiência e reduzindo os custos operacionais. Os medidores multifásicos fornecem parâmetros para o controle da produção, como a fração volumétrica de cada fase (líquida, gasosa ou sólida) e a velocidade superficial, otimizando a operação e garantindo maior segurança.

Diversas técnicas têm sido usadas para determinar frações volumétricas, incluindo métodos elétricos, ópticos, ultrassônicos e baseados em fótons. Entre essas, técnicas que utilizam transmissão e espalhamento de fótons se destacam por sua confiabilidade e caráter não invasivo. Estudos prévios demonstram o uso bem-sucedido da atenuação de raios gama para determinar frações de volume em sistemas multifásicos, utilizando simulações matemáticas validadas e técnicas de Inteligência Artificial para identificar regimes de fluxo e predizer a fração de volume [1, 2, 3, 4, 5, 6]. Outros trabalhos abordaram a medição de velocidade das fases [7, 8] e a visualização de características do fluxo multifásico utilizando raios X [9].

A determinação da fração de volume e da velocidade é crucial para calcular a vazão de cada fase em tubulações. Métodos baseados em raios gama e raios X, com detectores de cintilação NaI(Tl), são amplamente utilizados para esse propósito, apresentando resultados satisfatórios, especialmente na medição de fração de vazio e distribuição de velocidade [10]. Geometrias de medição e radionuclídeos variados, como <sup>137</sup>Cs, <sup>60</sup>Co, <sup>241</sup>Am, <sup>133</sup>Ba e <sup>152</sup>Eu, têm sido explorados em sistemas baseados em radiação. Essas fontes permitem a identificação de regimes de fluxo, determinação de frações volumétricas e medições de velocidade [11, 12, 13, 14, 15, 16, 17, 18]. No entanto, este estudo utiliza raios X provenientes de um tubo de raios X e detectores planares de germânio (HPGe). O tubo de raios X apresenta vantagens significantes em relação às fontes de raios gama: a energia dos raios X<sup>1</sup> pode ser ajustada conforme a voltagem aplicada ao tubo e, a intensidade do feixe pode ser controlada pela corrente elétrica aplicada. Além disso, o tubo pode ser desligado, reduzindo os requisitos de proteção radiológica, o que torna essa abordagem especialmente atraente para aplicações industriais.

Este estudo investiga o uso de um feixe de raios X em um regime de fluxo multifásico anular. A geometria de medição foi projetada e simulada no código MCNP6 [19]. Os dados obtidos foram utilizados para treinar uma rede neural *perceptron* multicamadas (MLP) com quatro camadas [20], capaz de predizer frações volumétricas. O modelo simulado no MCNP6 considera interações da radiação com os fluidos, distribuições de altura de pulso (DAPs) registrados por detectores planares HPGe, bem como suas resoluções em energia e curvas de eficiência. Além disso, as características e dimensões de detectores HPGe reais foram incorporadas no modelo [21].

1. Os raios X gerados em um tubo de raios X são produzidos quando um feixe de elétrons é acelerado por um intenso campo elétrico criado pela aplicação de alta voltagem entre os terminais do tubo. Ao colidir com um alvo metálico, esses elétrons acelerados transferem sua energia cinética, convertendo-a em radiação eletromagnética, predominante na faixa dos raios, além de emitir radiação térmica.

## SIMULAÇÃO DA GEOMETRIA

O código MCNP6 foi utilizado para simular a transmissão e o espalhamento de um feixe de raios X incidente em uma tubulação preenchida com fluidos típicos da indústria petrolífera, com objetivo de calcular a fração volumétrica em regime trifásico. O modelo geométrico simulado da geometria inclui dois detectores planares de HPGe, uma fonte de raios X de energia máxima de 149,5 keV e uma tubulação de policloreto de vinila (PVC) com diâmetro interno de 266 mm de espessura de parede de 4 mm. Um diagrama esquemático do sistema é apresentado na Figura 33. O modelo do detector incorpora tanto o cristal quanto os materiais estruturais [21]. As propriedades das fases líquida e gasosa simuladas são descritas na Tabela 5.

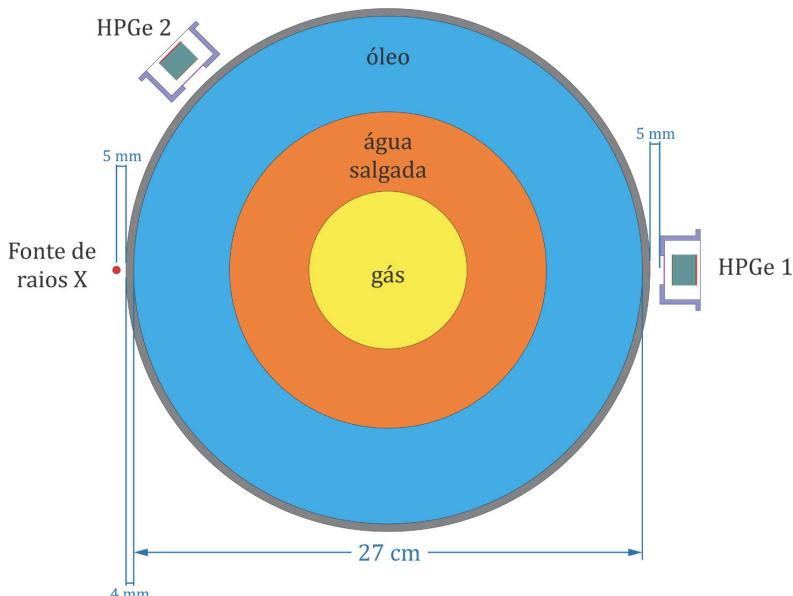


Figura 33 – Representação esquemática da geometria do sistema de detecção modelado no MCNP6.

Nas simulações, foi considerado o regime de fluxo anular, variando as frações volumétricas 0,1% a 97%, em incrementos de 5%. No total, 210 simulações foram realizadas, gerando o conjunto para o treinamento e avaliação de uma RNA.

O volume sensível de cada detector planar HPGe foi modelado como um cilindro de 16 mm de diâmetro e 13 mm de espessura, sendo particularmente eficaz para espectrometria de raios X. Na Figura 3, é mostrada a estrutura do detector HPGe considerada nas simulações.

O cristal de germânio inclui camadas mortas em ambas as superfícies planas do cilindro, que atuam como contatos ôhmicos e permitem a polarização elétrica. Essas camadas são compostas por:

- I. Camada P+: Implante de íons de boro com 0,5 µm na face frontal;
- II. Camada N+: Difusão de lítio com 600 µm na face posterior.

Essas camadas mortas, juntamente com a janela de berílio extremamente fina no encapsulamento frontal foram consideradas devido à sua influência significativa na eficiência do sistema de detecção, causada pela forte atenuação do feixe de radiação incidente. Essas características tornam os detectores planares adequados para medições na faixa de energia utilizada neste estudo.

No MCNP6, o comando *Tally F8* foi utilizado para registrar os fótons que atingiram o cristal do detector. Para garantir a precisão, foram simulados  $1 \times 10^8$  fótons, resultando em um erro relativo inferior a 10% para cada canal do espectro de energia. Além disso, a resolução de energia do detector foi incorporada, usando o comando GEB (*Gaussian energy broadening*), que utiliza os coeficientes de calibração descritos na Equação 13.

O espectro de raios X de entrada para as simulações foi gerado por software específico [22] e reflete as propriedades do tubo de raios X, com as seguintes características:

- Alvo de tungstênio inclinado a 20 graus;
- Filtração inerente de 1 mm de Be;
- Filtração adicional de 1 mm de Al;
- Fótons de energia máxima de 149,5 keV.

Para melhorar a precisão das simulações, foi incluída uma colimação estreita no feixe de raios X.

## TREINAMENTO DE REDES NEURAIS ARTIFICIAIS

A fase de treinamento utilizou uma RNA do tipo MLP com o algoritmo de retropropagação de erros. Os dados de entrada para a RNA consistiram nos espectros obtidos pelos detectores HPGe, divididos em 150 canais de 1 keV. A saída foi definida como a fração volumétrica de gás e água, sendo a fração da terceira fase calculada como o complemento necessário para totalizar 100%.

Para a construção do conjunto de dados, 210 padrões diferentes foram simulados utilizando o código MCNP6. Eses padrões foram distribuídos em três subconjuntos: 147 (70%) para o treinamento, 42 casos (20%) para teste e 21 (10%) para validação (10%). O subconjunto de validação foi usado para avaliar a eficiência da RNA após o processo de treinamento.

## RESULTADOS E DISCUSSÃO

Os espectros registrados nos detectores a partir das simulações permitem que a RNA calcule as frações volumétricas dos fluidos (FVF) – gás, água e óleo – no regime de fluxo anular. Como exemplo, na Figura 34 são apresentados os espectros registrados para duas condições distintas de FVF:

- FVF1 - 12% gás + 25,1% água + 62,9% óleo;
- FVF2 - 32% gás + 50,1% água + 17,9% óleo.

Os espectros abrangem uma faixa de energia de 0,5 keV a 149,5 keV, dividida em 150 canais de 1 keV.

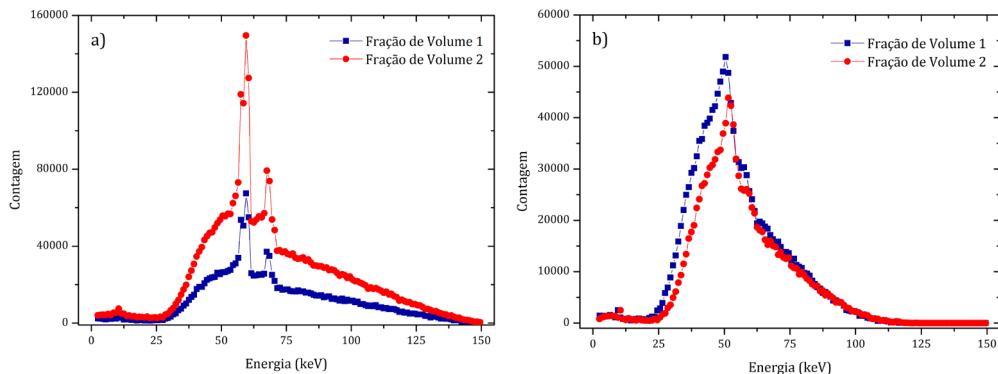


Figura 34 – Espectros de energia obtidos em detectores HPGe para duas frações volumétricas distintas de gás, água e óleo: a) Detector 1; b) Detector 2.

A RNA que apresentou os melhores resultados possui 4 camadas: uma camada de entrada, duas camadas ocultas e uma camada de saída. Os parâmetros otimizados da RNA estão apresentados em Tabela 11.

PARÂMETRO	CAMADA			
	Entrada	Oculta	Gaussiano Comp.	Saída
Funções de ativação	Linear [-1, 1]*	Gaussiano	Gaussiano Comp.	Logística
Neurônios	300	76	76	2

Tabela 11 – Parâmetros que forneceram os melhores resultados na configuração da RNA

\* A função linear foi utilizada como normalizadora dos dados de entrada.

Os diagramas de regressão entre os dados simulados e preditos para frações volumétricas de gás e água são apresentados em Figura 35, indicando boa concordância com altos coeficientes de regressão.

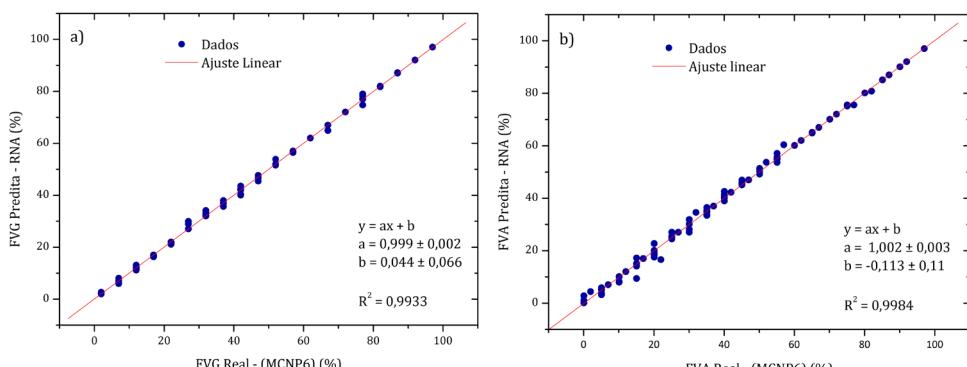


Figura 35 – Diagrama de regressão comparando os resultados simulados e os valores preditos pela RNA para a fração volumétrica de: a) gás; b) água.

Na Figura 36 é apresentada a comparação entre os dados simulados e preditos para o subconjunto Validação (VAL). Observa-se que a RNA conseguiu boa convergência mesmo com dados não utilizados durante o treinamento.

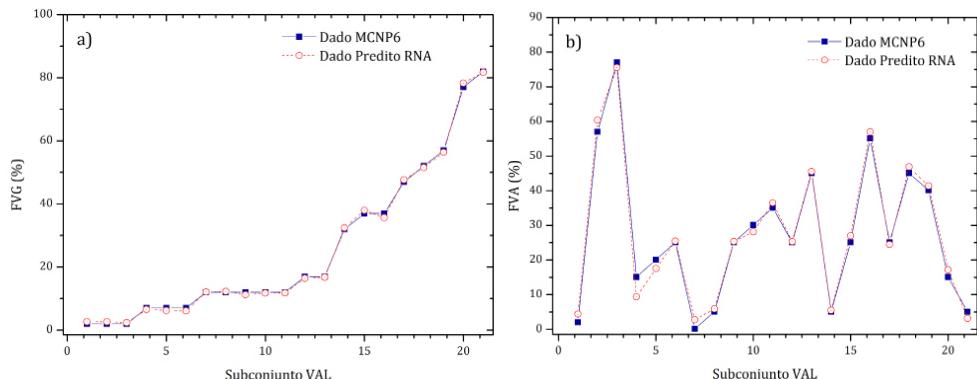


Figura 36 – Comparação entre dados simulados e as previsões da RNA para o subconjunto Validação considerando as frações de volume de: a) gás; b) água.

Na Tabela 12 é apresentado um resumo da comparação entre os valores reais (obtidos por simulação) e os valores preditos pela RNA. A análise mostra que, para a maioria dos casos, a RNA obteve resultados com boa precisão, com mais que 87% dos resultados apresentando erros relativos abaixo de 5%.

Faixa de classificação de erro	Fração de volume (%)	
	gás	água
≤ 5%	91,44	87,62
5%-10%	3,33	5,24
10%-20%	3,33	3,33
20%-30%	0,95	1,43
>30%	0,95	2,38

Tabela 12 – Classificação de erro relativo dos padrões preditos pela RNA para as frações volumétricas de gás e água

Uma análise estatística final do desempenho da RNA é apresentada na Tabela 13. Os valores de MRE (%) para todos os dados foram de 1,72% para gás e 2,48% para água, respectivamente. A comparação entre RMSE e MAE revela que a grande maioria dos resultados apresenta pequenos desvios, já que os valores de RMSE são superiores aos de MAE. Os poucos padrões com erros significativos ocorrem, principalmente, para frações de volume muito baixas, o que impacta negativamente a qualidade dos resultados no subconjunto de Validação. Esse efeito é refletido no aumento do valor do MRE.

Conjunto de dados	Métrica							
	FVG				FVA			
	MAE	MSE	RMSE	MRE	MAE	RMSE	MSE	MRE
Todos os dados	0,2349	0,3112	0,5578	1,72%	0,4080	0,9367	0,9678	2,48%
TRT	0,2370	0,2904	0,9678	2,48%	0,4702	1,1656	1,0796	2,76%
TST	0,8846	1,3351	1,1555	5,21%	1,1929	2,4645	1,5699	5,51%
VAL	0,5746	0,4414	0,6643	6,80%	1,6901	4,4381	2,1067	13,68%

Tabela 13 – Análise de predição de rede usando parâmetros estatísticos

## CONCLUSÕES

Neste estudo de caso, um sistema de medição de frações volumétricas de fluidos em um sistema trifásico foi proposto, utilizando um feixe de raios X com fótons de 149,5 keV e detectores HPGe. O sistema foi simulado com o código MCNP6, e uma RNA MLP foi utilizada para interpretar os espectros registrados nos detectores. O regime de escoamento anular foi considerado com diferentes frações volumétricas de fluido.

Os espectros registrados nos detectores foram utilizados diretamente como dados de entrada na RNA. Os resultados obtidos mostraram-se satisfatórios, com mais de 87% dos padrões apresentando erro relativo abaixo de 5% para ambas as fases investigadas. Os valores de MRE (%) para gás e água foram 1,72% e 2,48%, respectivamente.

De maneira geral, os resultados das métricas indicam que a metodologia proposta é aplicável para medir frações volumétricas em sistemas trifásicos, especialmente em regime de fluxo anular, utilizando um feixe de raios X. Além disso, a possibilidade de desligar a fonte de radiação, reduzindo assim os critérios de proteção radiológica, é um diferencial significativo dessa abordagem.

## REFERÊNCIAS

- [1] Åbro, E.; Khoryakov, V.A.; Johansen, G.A.; Kocbach, L. Determination of void fraction and flow regime using a neural network trained on simulated data based on gamma-ray densitometry. *Measurement Science and Technology*, v. 10, p. 619-630, 1999.
- [2] Salgado, C.M.; Pereira, C.M.N.A.; Schirru, R.; Brandão, L.E. Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks. *Progress in Nuclear Energy*, v. 52, p. 555-562, 2010.
- [3] Nazemi, E.; Roshani, G.H.; Feghhi, S.A.H.; Gholipour Peyvandi, R.; Setayeshi, S. Precise Void Fraction Measurement in Two-Phase Flows Independent of the Flow Regime using gamma-ray attenuation. *Nuclear Engineering and Technology*, v. 48, p. 64-71, 2016.
- [4] Karami, A.; Roshani, G.H.; Khazaei, A.; Nazemi, E.; Fallahi, M. Investigation of different sources in order to optimize the nuclear metering system of gas–oil–water Annular flows. *Neural Computing and Applications*, p. 1-13, 2018.

- [5] Rad Islami, S.Z.; Gholipour Peyvandi, R. Precise volume fraction measurement for three-phase flow meter using  $^{137}\text{Cs}$  gamma source and one detector. *Radiochimica Acta*, v. 108, n. 2, p. 159-164, 2019.
- [6] Sattari, M.A.; Roshani, G.H.; Hanus, R. Improving the structure of two phase flow meter using feature extraction and GMDH neural network. *Radiation Physics and Chemistry*, v. 171, 2020. Disponível em: <https://doi.org/10.1016/j.radphyschem.2020.108725>
- [7] Mosorov, V. Improving the accuracy of single radioactive particle technique for flow velocity measurements. *Flow Measurement and Instrumentation*, v. 66, p. 150-156, 2019.
- [8] Mosorov, V.; Zych, M.; Hanus, R.; Sankowski, D.; Saoud, A. Improvement of Flow Velocity Measurement Algorithms Based on Correlation Function and Twin Plane Electrical Capacitance Tomography, *Sensors*, v. 20, n. 1:306, 2020. Disponível em: <https://doi.org/10.3390/s20010306>
- [9] Heindel, T.J., 2011. A review of X-ray flow visualization with applications to multiphase flows. *Journal of Fluids Engineering*, v. 133, n. 7, 2011. Disponível em: <https://doi.org/10.1115/1.4004367>
- [10] Song, K.; Liu, Y. A compact x-ray system for two-phase flow measurement. *Measurement Science and Technology*, v. 29, n. 2, 2018. Disponível em: <https://doi.org/10.1088/1361-6501/aaa283>
- [11] Halstensen, M.; Amundsen, L.; Arvohm, B.K. Three-way PLS regression and dual energy gamma densitometry for prediction of total volume fractions and enhanced flow regime identification in multiphase flow. *Flow Measurement and Instrumentation*, v. 40, p. 133-141, 2014.
- [12] Hanus, R. Application of the Hilbert Transform to measurements of liquid–gas flow using gamma ray densitometry. *International Journal of Multiphase Flow*, v. 72, p. 210-217, 2015.
- [13] Hanus, R.; Zych, M.; Petryka, L.; Swisulski D.; Strzepowicz, A. Application of RNA and PCA to two-phase flow evaluation using Radioisotopes, EPJ Web of Conferences, v. 143, 2017. Disponível em: <https://doi.org/10.1051/epjconf/201714302033>
- [14] Hanus, R.; Zych, M.; Kusy, M.; Jaszczur M.; Petryka, L. Identification of liquid-gas flow regime in a pipeline using gamma-ray absorption technique and computational intelligence methods. *Flow Measurement and Instrumentation*, v. 60, p. 17-23, 2018.
- [15] Mosorov, V.; Zych, M.; Hanus, R.; Petryk, L. Modelling of dynamic experiments in MCNP5 environment. *Applied Radiation and Isotopes*, v. 112, p. 136-140, 2016.
- [16] Zych, M.; Hanus, R.; Vlasák, P.; Jaszczur, M.; Petryka, L. Radiometric methods in the measurement of particle-laden flows. *Powder Technology*, v. 318, p. 491-500, 2017.
- [17] Falahati, M.; Rashidian Vaziri, M.R.; Beigzadeh, A.M.; Afarideh, H. Design, modelling and construction of a continuous nuclear gauge for measuring the fluid levels. *Journal of Instrumentation*, v. 13, 2018. Disponível em: <https://doi.org/10.1088/1748-0221/13/02/P02028>
- [18] Hosseini, S.; Roshani, G.H.; Setayeshi, S. Precise gamma based two-phase flow meter using frequency feature extraction and only one detector. *Flow Measurement and Instrumentation*, v.72, 2020. Disponível em: <https://doi.org/10.1016/j.flowmeasinst.2020.101693>

[19] Goorley, T.; James, M.; Booth, T.; Brown, F.; Bull, J.; Cox, L.J.; Durkee, J.; Elson, J.; Fensin, M.; Forster, R.A.; Hendricks, J.; Hughes, H.G.; Johns, R.; Kiedrowski, B.; Martz, R.; Mashnik, S.; McKinney, G.; Pelowitz, D.; Prael, R.; Sweezy, J.; Waters, L.; Wilcox, T.; Zukaitis, T. Features of MCNP6. *Annals of Nuclear Energy*, v. 87, p. 772-783, 2016.

[20] Haykin, S. Neural Networks – A Comprehensive Foundation. Macmillan College Publishing Company, 1994.

[21] Salgado, C.M.; Conti, C.C.; Becker, P.H.B. Determination of HPGe detector response using MCNP5 for 20–150 keV X-rays. *Applied Radiation and Isotopes*, v. 64, p. 700-705, 2006.

[22] Cranley, K.; Gilmore, J.B.; Fogarty, A.W.G.; Desponds, L. Catalogue of Diagnostic X-ray Spectra and Other Data. *The Institute of Physics and Engineering in Medicine*. Report n. 78, 1997.

# CÁLCULO DE FRAÇÕES DE VOLUME COM INCRUSTAÇÕES EM OLEODUTOS BASEADOS EM RADIAÇÃO GAMA

---

**César Marques Salgado**

**William Luna Salgado**

**Roos Sophia de Freitas Dam**

**Claudio de Carvalho Conti**

Nos últimos anos, as operações de produção *offshore* têm se expandindo a profundidades cada vez maiores, o que eleva os custos e torna essencial os estudos de viabilidade e otimização de equipamentos utilizados para o transporte de fluidos multifásicos. A previsão de escoamentos multifásicos é complexa devido às interações físico-químicas entre as diversas fases presentes. Como discutido anteriormente, o fluxo multifásico é de grande importância na indústria de petróleo *offshore*. Durante a extração do petróleo, a injeção de água do mar nas camadas inferiores da rocha reservatório ajuda a manter a pressão, facilitando

a migração do óleo para os poços e aumentado a eficiência da extração. No entanto, devido à afinidade química entre os elementos solúveis na água do mar e na água de formação (mistura destas águas forma a água de produção),<sup>1</sup> podem ocorrer interações químicas que resultam na deposição de materiais inorgânicos nas paredes do tubo, formando a incrustação<sup>[1]</sup>.

Apresentando o processo de forma mais detalhada, a água do mar possui uma alta concentração de íons sulfato ( $\text{SO}_4^{2-}$ ). Quando injetada na rocha do poço de petróleo, ela interage com cátions divalentes, como  $\text{Ba}^{2+}$ ,  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$  e  $\text{Sr}^{2+}$ , presentes na água de formação. Sob condições termodinâmicas favoráveis, essa interação provoca a precipitação e deposição de sais de sulfato, resultando na formação de incrustações. Esse processo torna a determinação da fração volumétrica dos fluidos (FVF) mais complexa. Além disso, as incrustações nas paredes

1. A água de produção possui características inerentes à geologia do reservatório, como a composição da rocha reservatório e a estratégia de exploração do campo. Ela pode ser descrita com base em sua composição química e nas propriedades físico-químicas resultantes. A água de produção, formada na rocha do reservatório, é identificada pela sua salinidade e composição química.

dos tubos reduzem o diâmetro interno livre disponível para o escoamento, diminuindo a produção de petróleo e gás natural [2, 3, 4]. Em casos graves, a formação de incrustações pode até obstruir completamente a passagem dos fluidos no interior das tubulações.

Portanto, são necessárias ações de manutenção periódica, como limpeza ou até mesmo a troca de trechos das tubulações. As incrustações podem também causar a corrosão e, dependendo do grau, perfurações na tubulação e/ou nos equipamentos, além de aumentarem o consumo de energia devido à redução do desempenho e da vida útil dos equipamentos da instalação [5]. A consequência direta desses efeitos é a falha dos equipamentos de produção, paradas emergenciais da planta, aumento do custo de manutenção e diminuição da eficiência da produção. Diante disso, é de extrema importância o desenvolvimento de metodologias e dispositivos capazes de monitorar e identificar com precisão a evolução da espessura das incrustações nas tubulações. O controle em tempo real possibilita uma operação mais segura e eficiente, além de minimizar os custos operacionais.

Os depósitos de incrustação mais comuns na indústria de petróleo *offshore* são sulfato de bário ( $\text{BaSO}_4$ ), sulfato de cálcio ( $\text{CaSO}_4$ ) e sulfato de estrôncio ( $\text{SrSO}_4$ ) [5]. Os depósitos de sulfato de bário são particularmente difíceis de tratar, pois apresentam menor solubilidade em água, tornando a remoção física mais desafiadora [6, 7]. Diversos estudos buscam identificar e minimizar o impacto das incrustações na produção de óleo e gás. O monitoramento das incrustações pode ser feito por meio de tecnologias convencionais, como a cinética química [8] e métodos não cinéticos baseados em mudanças físicas. No entanto, os métodos que envolvem cinética química exigem sensores caros, que estão expostos a fluidos abrasivos e/ou corrosivos e altas temperaturas, o que pode levar a falhas e à necessidade de substituições frequentes dos sensores. Além disso, sistemas de monitoramento invasivos podem afetar a operação da planta e envolver altos custos. Por outro lado, no entanto, no contexto de métodos não cinéticos, técnicas nucleares têm sido aplicadas para detectar incrustações em tubos. Ativação de nêutrons [9] e a densitometria de raios gama [10] são exemplos de tecnologias que utilizam sensores posicionados fora da tubulação, sem contato com os fluidos, permitindo medições online sem alterar as condições operacionais. Essas técnicas têm se mostrado ferramentas importantes para o controle preventivo e o monitoramento da evolução da espessura das incrustações [11].

Uma solução eficiente é a medição multifásica, que permite realizar medições simultâneas sem a necessidade de separar as fases e, sem alterar as condições operacionais. Essa abordagem possibilita a medição contínua e em tempo real da vazão, o que contribui para o gerenciamento eficiente da produção de um poço, tornando-se uma solução ideal para aumentar a produtividade. Tais vantagens tornam os medidores de vazão multifásicos extremamente importantes na indústria do petróleo, especialmente em aplicações fiscais,<sup>2</sup> e têm sido objeto de diversos estudos. Portanto, é essencial que esses medidores, com alta precisão, contribuam para a minimização de perdas econômicas, dado que uma grande quantidade de fluidos é transferida diariamente.

2. Em contextos fiscais, o termo geralmente se refere a questões relacionados à tributação, arrecadação de impostos, regulamentações e obrigações legais aplicáveis a empresas e indivíduos.

Diferentes princípios físicos são utilizados para medir diversos parâmetros e propriedades de fluxo multifásico, como fração volumétrica e velocidade interfacial. Sensores convencionais baseados em eletricidade [12] e óptica [13], bem como as técnicas nucleares que utilizam raios X [14, 15], raios gama [16, 17] ou nêutrons [18], são aplicados para predizer FVFs em sistemas multifásicos. Técnicas nucleares não invasivas podem ser utilizadas em momentos específicos, sem a necessidade de interromper as operações, oferecendo uma solução eficaz para o controle preventivo e o monitoramento dos depósitos de incrustação [19]. Além disso, a resposta instantânea das medições por radiação permite a caracterização online para muitas aplicações práticas [20]. Dentre as técnicas nucleares, destaca-se a densitometria gama, que investiga feixes de raios gama transmitidos e/ou espalhados. Essa técnica tem apresentado resultados satisfatórios e é amplamente utilizada em diversas áreas, como predição de densidade [21]; detecção de incrustações em tubos de extração de óleo [22], medição de frações de volume [23, 24, 25, 26, 27, 28, 29, 30], medição de fluxo [31], monitoramento do transporte de petróleo [32], identificação da região de interface em polidutos [33], investigações em fluxos bifásicos [34, 35], rastreamento de partículas radioativas [36, 37, 38] e detecção de incrustações [10, 11].

A densitometria gama baseia-se na interação dos raios gama com materiais, seja por transmissão e/ou espalhamento. No entanto, existem desafios associados a esse tipo de medição. Os fluidos, como gás, água e óleo podem interferir na precisão da avaliação da espessura das incrustações, uma vez que as interações predominantes dos raios gama com os materiais – o espalhamento Compton e a absorção fotoelétrica – variam de acordo com a densidade do material e o número atômico efetivo. Outro fator que influencia a análise é a determinação precisa da espessura da incrustação, especialmente ao tentar localizar e quantificar seu valor máximo em uma posição específica dentro do tubo. Isso é ainda mais desafiador devido à não uniformidade da formação excêntrica. Embora equações analíticas possam ser aplicadas para investigar a espessura das incrustações, frequentemente essas soluções requerem informações sobre o tubo. Em casos reais, essas informações nem sempre estão disponíveis. Além disso, a metodologia de equações analíticas é específica para determinados regimes de fluxo e geometria de medição. Muitas vezes, são necessárias simplificações baseadas em dados experimentais, o que pode levar a grandes erros devido às variações nos regimes de fluxo ao longo do tempo e do espaço.

Como uma alternativa, as redes neurais artificiais (RNAs) têm se mostrado um dos métodos mais eficientes de inteligência artificial para resolver problemas de reconhecimento de padrões, como a predição de frações de volume [13, 39], identificação de regimes de fluxo em sistemas multifásicos [27, 40], rastreamento de partículas radioativas [36, 37, 38] e predição de incrustações inorgânicas [11]. Diversos tipos de redes neurais têm sido aplicados em sistemas multifásicos, como o Método de grupo de manipulação de dados (GMDH – *Group Method of Data Handling*) [41], a técnica de função de base radial (RBF – *Radial Basis Function*) [42] e a rede neural artificial de multicamadas com propagação do sinal

adiante (MLP) [40]. No entanto, a obtenção de dados experimentais precisos em sistemas multifásicos apresenta desafios significativos. Para superar essas dificuldades, o estudo de caso em questão utilizou o código computacional MCNP6 [43].

Este estudo propõe uma abordagem inovadora que combina um modelo simulado baseado em densitometria de raios gama com uma RNAMP para identificar automaticamente as frações volumétricas de gás, água e óleo, além de predizer a espessura das incrustações excêntricas presentes no interior do tubo. A geometria de medição foi projetada para detectar e quantificar a espessura máxima da incrustação excêntrica por meio de uma única medição, em uma posição específica no tubo. A metodologia de medição inclui dois detectores cintiladores de NaI(Tl) e uma fonte de  $^{192}\text{Ir}$ . A geometria desenvolvida com o MCNP6 leva em consideração diferentes espessuras e posições relativas das incrustações excêntricas de sulfato de bário ( $\text{BaSO}_4$ ) em tubulações. Os dados obtidos pelos detectores, por meio da distribuição de altura de pulso (DAP), foram utilizados para treinar uma RNA, capaz de predizer a espessura máxima da incrustação independentemente da presença de fluidos, utilizando apenas uma medição.

## CÁLCULOS DE INCRUSTAÇÃO CONCÊNTRICA

### Geometria de Medição

A configuração da simulação envolve uma fonte puntiforme do radioisótopo  $^{192}\text{Ir}$ , que emite raios gama. As energias simuladas para os raios gama foram: 201,31, 205,79, 295,96, 308,45, 316,51, 374,48, 468,07, 484,57, 489,06, 588,58, 604,41 e 612,46 keV. Os dados relativos à fonte radioativa foram obtidos no aplicativo *Isotope Browser*, versão 5.15.74 Android, IAEA, Seção de Dados Nucleares [44]. A fonte de radiação gama foi colimada para formar um feixe divergente com uma abertura de 8,21°, sendo a colimação realizada matematicamente utilizando os comandos SP, SI e SB do código MCNP6.

O modelo matemático contempla dois detectores de NaI(Tl) de dimensões  $1\frac{1}{4}'' \times \frac{3}{4}''$ . O primeiro detector (D1) foi posicionado no mesmo eixo da fonte (180° em relação à fonte), com uma distância de 28 cm entre a fonte e o detector. Este detector tem a função de registrar os fôtons transmitidos. O segundo detector (D2) foi colocado a 30° em relação à fonte, sendo responsável pela detecção dos fôtons espalhados. Ambos os detectores foram posicionados a 0,5 cm de distância de um tubo de policloreto de vinila (PVC), com diâmetro externo de 27 cm e espessura de 4 mm.

Os fluidos utilizados nas simulações incluem gás, água salgada e óleo, com densidades de  $1,205 \times 10^3 \text{ g.cm}^{-3}$ ,  $1,0466 \text{ g.cm}^{-3}$  e  $0,896 \text{ g.cm}^{-3}$ , respectivamente. A fase gasosa foi representada por ar seco. Uma representação gráfica da geometria de medição proposta está ilustrada na Figura 37.

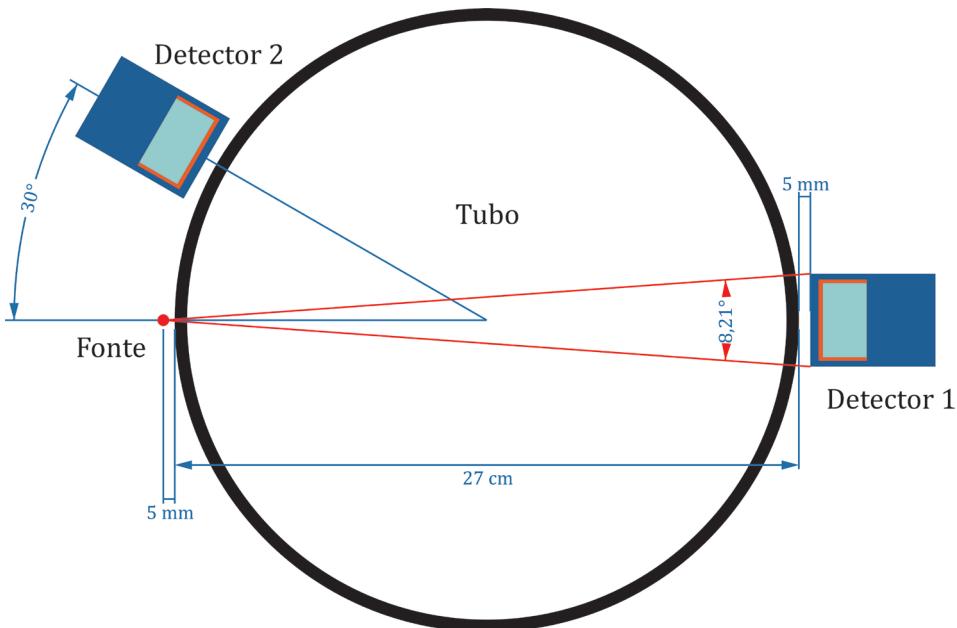


Figura 37 – Geometria de medição simulada no código MCNP6.

Os dados registrados pelos detectores foram obtidos utilizando o cartão Tally F8 do código MCNP6. A função descrita pela Equação 13 foi ajustada aos dados registrados pelos detectores, com o objetivo de calcular os parâmetros do cartão GEB. Os coeficientes de resolução de energia ajustados para os detectores de NaI(Tl) estão detalhados no tópico "Modelo Matemático do Detector NaI(Tl)", página 35.

### Modelos Matemáticos do Regime Anular

Após o desenvolvimento da geometria de medição, o regime de fluxo estático anular com diferentes frações de volume (de um sistema trifásico composto por gás, água e óleo) foi modelado matematicamente utilizando o código MCNP6. O cálculo das frações de volume para os três fluidos pode ser realizado utilizando a Equação 22, Equação 23 e Equação 24, respectivamente. Nessas equações, os parâmetros são: " $m$ " representa o fluido:  $g$  para gás;  $\alpha$  para água e  $\sigma$  para óleo; fração volumétrica " $\alpha_m$ " do fluido " $m$ "; e " $r_m$ " é o raio correspondente à fração volumétrica do fluido " $m$ ".

Um fator que pode complicar a determinação das frações de volume é a presença de incrustações na parede interna do tubo, o que pode alterar significativamente as frações de volume. Como exemplo, considere um tubo sem incrustação, com frações de volume de 5% de gás, 10% de água e 85% de óleo. Quando este tubo apresenta uma incrustação de 3 cm de espessura, as frações de volume se alteram para aproximadamente 3% de gás, 6% de água e 51% de óleo, devido à redução do diâmetro interno útil do tubo. Isso demonstra a extrema importância de avaliar o impacto das incrustações nas frações volumétricas.

Para ilustrar, são mostradas na Figura 38a, três diferentes frações de volume sem incrustação e na Figura 38b, as frações correspondentes considerando uma espessura de incrustação de 3 cm.

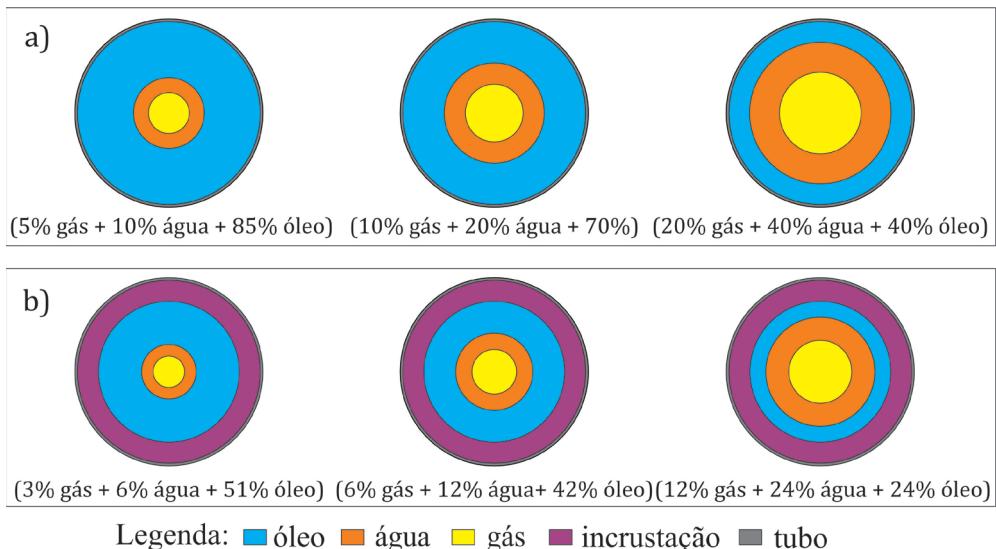


Figura 38 – Modelos estáticos desenvolvidos no código MCNP6 para o regime anular: a) Sem incrustação; b) Com espessura de incrustação de 3,0 cm.

### Solução Analítica para o Cálculo de Frações de Volume em Sistemas Trifásicos usando Radiação Gama

A determinação das frações de volume em sistemas de escoamento multifásico, especialmente quando há mais de duas fases, apresenta uma grande complexidade. Isso ocorre devido à inconsistência nos regimes de fluxo, tornado a análise através de equações analíticas uma tarefa difícil. As equações analíticas são geralmente específicas para um conjunto de parâmetros em um sistema particular. Quando ocorrem variações nesses parâmetros, a solução analítica pode apresentar grandes erros ou se tornar-se impraticável. Esse desafio é ainda mais acentuado quando se trata de um sistema com quatro fases, como é o caso investigado neste estudo.

Para sistemas trifásicos com regime de fluxo anular, a solução analítica requer três equações. Esse problema pode ser resolvido utilizando uma fonte de raios gama que emite duas energias diferentes  $E_1$  e  $E_2$ . Nesse contexto, a Equação de Bee-Lambert é resolvida para cada uma das energias, gerando uma matriz cujos elementos são determinados considerando o tubo preenchido com cada uma das fases (100% gás, água ou óleo) e outras frações de volume conhecidas. Mais especificamente, as expressões matemáticas para determinação das frações volumétricas de fluido em sistemas multifásicos no regime anular é dada pela Equação 32, Equação 33 e Equação 34 [45].

$$\alpha_g = \frac{1}{(\mu_{12} - \mu_{11})} \left\{ \frac{\ln(I_{o1}/I_{\gamma 2})}{D} - \mu_{11} \right\} - (\mu_{13} - \mu_{11}).$$

$$\cdot \frac{(\mu_{12} - \mu_{11}) \left\{ \frac{\ln(I_{o2}/I_{\gamma 2})}{D} - \mu_{12}\mu_{21} \right\} - (\mu_{22} - \mu_{21}) \left\{ \frac{\ln(I_{o1}/I_{\gamma 1})}{D} - \mu_{11}\mu_{22} \right\}}{(\mu_{12} - \mu_{11})(\mu_{23} - \mu_{21}) - (\mu_{22} - \mu_{21})(\mu_{13} - \mu_{11})}$$
Equação 32

$$\alpha_a = \frac{(\mu_{12} - \mu_{11}) \left\{ \frac{\ln(I_{o2}/I_{\gamma 2})}{D} \right\} - \mu_{21}\mu_{12} - (\mu_{22} - \mu_{21}) \left\{ \frac{\ln(I_{o1}/I_{\gamma 1})}{D} \right\} + \mu_{22}\mu_{11}}{(\mu_{12} - \mu_{11})\mu_{23} - \mu_{12}\mu_{21} - (\mu_{22} - \mu_{21})\mu_{13} + \mu_{22}\mu_{11}}$$
Equação 33

$$\alpha_o = 1 - \alpha_g - \alpha_a$$
Equação 34

Em que:

$I_{\gamma i}$  – Intensidade de raios gama transmitida para os três fluidos dentro do tubo ( $\text{y.cm}^{-2}.\text{s}^{-1}$ );

$I_{oi}$  – Incidente intensidade ( $\text{y.cm}^{-2}.\text{s}^{-1}$ );

$\alpha_m$  – Fração de volume do fluido  $m$ ;

$\mu_{ij}$  – Coeficiente de absorção linear( $\text{cm}^{-1}$ );

$i$  – Referente à energia  $E_i$ , sendo  $i=1$  para energia 1 e  $i=2$  para a energia 2;

$j$  – Referente ao fluido: gás, água e óleo.

Vale ressaltar que essa solução analítica é válida apenas para o regime de fluxo anular com feixe unidirecional (*pencil beam*). Por isso, a solução é altamente dependente do regime de fluxo, já que a maior parte da seção transversal não é inspecionada pelo feixe de radiação.

A situação se complica ainda mais quando se tem um sistema com quatro fases (três fluidos e incrustação), que é o foco deste estudo. As interações entre as fases tornam-se mais complexas, e as equações analíticas já não são adequadas para esse tipo de sistema. Portanto, redes neurais foram utilizadas na busca por uma solução mais precisa, garantindo maior acurácia na estimativa das frações volumétricas e na identificação de depósitos de incrustação.

## Treinamento da Rede Neural

Foram realizadas 1680 simulações para o regime de fluxo anular, abrangendo frações volumétricas entre 0,1% e 95,8%, com incrementos de 5%. Em cada simulação, foram adicionadas incrustações de sulfato de bário ( $\text{BaSO}_4$ ) aos modelos, com densidade de  $2,62 \text{ g.cm}^{-3}$  e espessuras variando de 0,5 cm a 4,0 cm, em incrementos de 0,5 cm. Adicionalmente, um conjunto de 190 simulações foi desenvolvido sem a presença de incrustações, com o objetivo de avaliar a resposta da rede neural em um modelo ideal.

A RNA MLP foi implementada para determinar as frações de volume de um sistema multifásico composto por gás, água e óleo sem a necessidade de informações prévias sobre a presença de incrustação de  $\text{BaSO}_4$ . Os espectros registrados pelos detectores de NaI(Tl) foram utilizados como dados de entrada, enquanto as frações de volume de gás

(FVG) e de água (FVA), juntamente com a espessura da incrustação, foram utilizadas como dados de saída. A RNA foi projetada para predizer as frações de volume e a incrustação, garantindo maior eficiência no processo de análise. A estrutura da rede desenvolvida é apresentada na Figura 39. Ressalta-se que a fração volumétrica de óleo foi calculada por diferença, conforme a Equação 25.

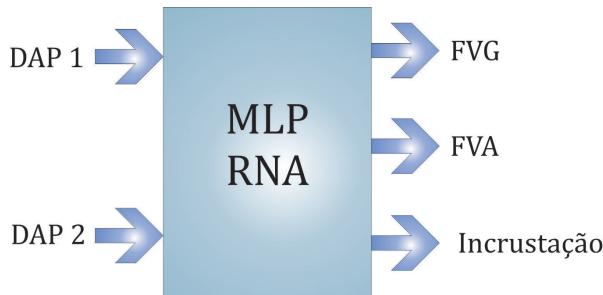


Figura 39 – Estrutura da RNA MLP desenvolvida.

## RESULTADOS E DISCUSSÃO

### Frações de Volume usando Equações Analíticas

Antes da implementação da geometria proposta utilizando uma fonte de  $^{192}\text{Ir}$ , foi conduzido um estudo de caso para avaliar a aplicabilidade das equações analíticas em combinação com o código MCNP6. O estudo considerou os fluidos gás, água e óleo, bem como duas fontes emissoras de fótons com energias de 59,54 keV ( $^{241}\text{Am}$ ) e 661,66 keV ( $^{137}\text{Cs}$ ). Os valores dos coeficientes de atenuação linear total da água e do óleo utilizados nos cálculos, estão apresentados na Figura 40a. Para validar os resultados obtidos no MCNP6, uma comparação foi realizada com dados disponíveis na literatura. Na Figura 40b é exibida a comparação entre os coeficientes de atenuação linear total simulados para água salgada a 4% de NaCl e os dados tabulados por Hubbell e Seltzer (1997) [46].

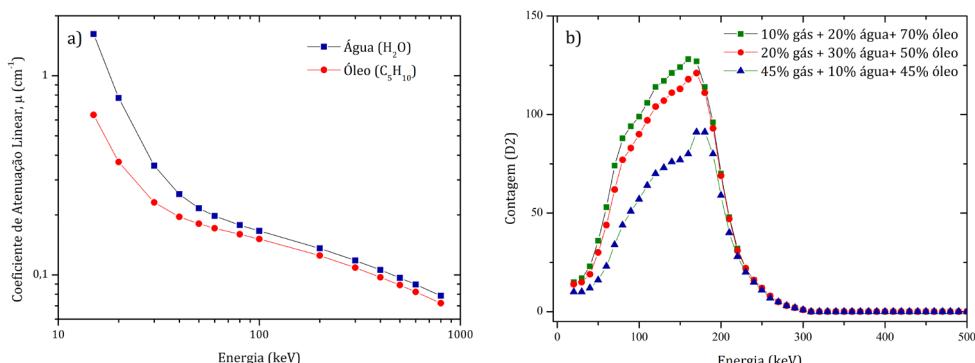


Figura 40 – Coeficientes de atenuação linear total: a) água e óleo; b) comparação entre resultados obtidos no MCNP6 e dados da literatura para água salgada.

Para o sistema trifásico, os valores das frações de volume de cada fluido foram calculados com base nos dados simulados pelo código MCNP6, conforme demonstrados na Tabela 14, e utilizando as equações analíticas derivadas na Figura 22, Equação 23 e Equação 24. As intensidades relativas estimadas no detector D1 foram obtidas por meio de simulações computacionais, enquanto os coeficientes de atenuação linear total foram calculados utilizando a Equação 6.

Fluido	Fração de Volume	
	Real (MCNP6)	Equações Analíticas
gás	40%	39,8%
água	40%	39,6%
óleo	20%	20,6%

Tabela 14 – Validação do modelo desenvolvido no código MCNP6 a partir das equações analíticas para cálculo de frações de volume

Apesar dos resultados obtidos ao aplicar as equações analíticas, esta abordagem possui limitações, sendo válida apenas para condições específicas e previamente conhecidas, como o regime de fluxo anular e a utilização de um feixe unidirecional e extremamente colimado (*pencil beam*). Além disso, a aplicação prática demandaria uma fonte de radiação com atividade significativamente alta. Os resultados apresentados na Tabela 14 destacam uma excelente concordância entre os valores de frações de volume simulados no MCNP6 e aqueles calculados pelas equações analíticas, validando tanto a precisão do modelo geométrico quanto a exatidão no cálculo dos coeficientes de atenuação linear.

É importante observar que, embora tenha sido conduzido com um sistema trifásico, o estudo proposto envolve um sistema ainda mais complexo, considerando a inclusão de uma quarta fase representada pela incrustação. Essa complexidade adicional limita a aplicação prática das equações analíticas, tornando algoritmos baseados em inteligência artificial uma alternativa promissora, especialmente para casos em que incrustações estão presentes.

## Frações de Volume de Fluidos e Espessura de Incrustação usando Rede Neural Artificial

Foi realizado um estudo de caso para avaliar a aplicação de RNAs na determinação de diferentes frações volumétricas de fluidos (FVF) na presença de incrustações concêntricas no interior do tubo. Para esse objetivo, foi gerado um conjunto de 1870 padrões utilizando o código MCNP6. Esse conjunto de dados foi usado para treinar e avaliar uma RNA com capacidade de calcular as FVF independentemente da espessura das incrustações.

O conjunto de dados foi dividido em três subconjuntos, definidos com base na proporção de 70% para Treinamento (TRT), 20% para Teste (TST) e 10% para Validação (VAL). A divisão foi realizada de forma aleatória.

- I. O subconjunto TRT, com 1309 padrões, foi utilizado para ajustar os pesos sinápticos da rede, ou seja, para o treinamento da RNA;

- II. O subconjunto TST, contendo 374 padrões, serviu para avaliar a capacidade de generalização da rede e prevenir *overtraining* por meio do método de Validação cruzada;
- III. Para avaliação final, após o treinamento da RNA, foi utilizado um subconjunto VAL, composto por 187 padrões.

A geometria de medição considerou dois detectores: um para registrar os feixes de transmissão (D1) e o outro para os feixes de espalhamento (D2). Como exemplo, os espectros obtidos nos dois detectores para três diferentes frações volumétricas de fluido, sem a presença de incrustação estão ilustrados na Figura 41.

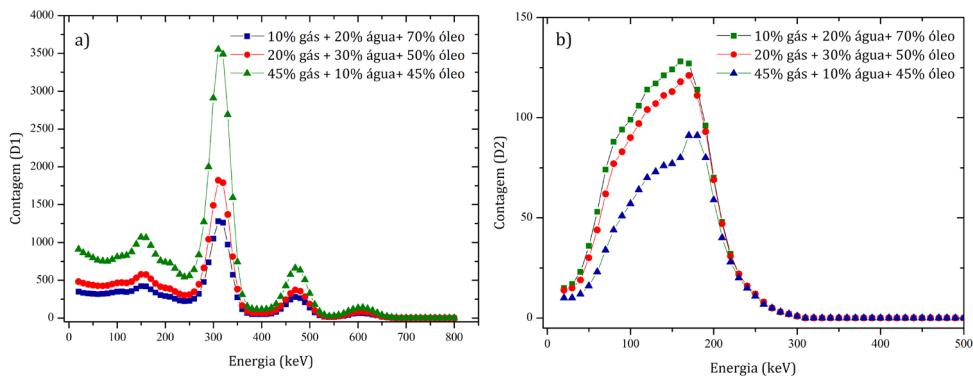


Figura 41– Espectros obtidos nos dois detectores para diferentes frações volumétricas de fluido sem incrustação: a) D1; b) D2.

Por outro lado, na Figura 42, são apresentados os espectros considerando diferentes valores de espessura de incrustação para uma fração volumétrica composta por 10% de gás, 20% de água e 70% de óleo.

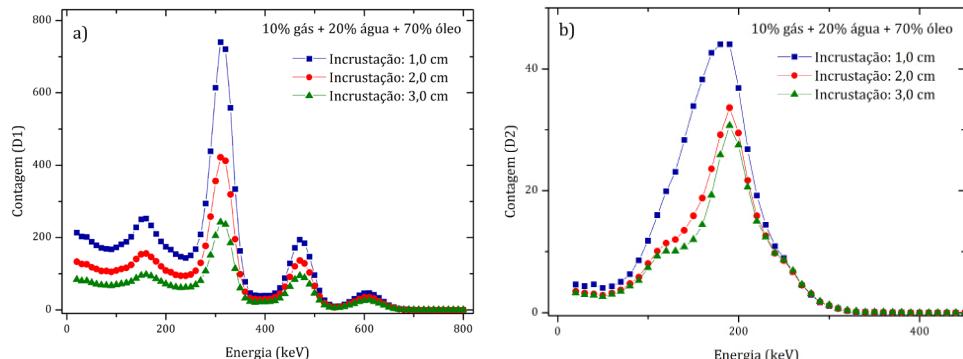


Figura 42 – Espectros para diferentes espessuras de incrustação registrados nos detectores: a) D1; b) D2.

Ao comparar visualmente a Figura 41 e a Figura 42, é possível observar as diferenças significativas nos espectros. Essas diferenças sugerem que a RNA pode obter uma boa convergência na RNA na predição das frações volumétricas e espessuras de incrustação.

Os diagramas de regressão foram utilizados para avaliar a precisão da rede, sendo que um coeficiente de determinação próximo a “1” indica alta precisão. Os dados preditos pela RNA para as frações de volume dos fluidos foram ajustados a uma função linear pelo método dos mínimos quadrados, obtendo-se os seguintes coeficientes de regressão:

- 0,9997 para a fração de volume de gás (FVG);
- 0,9992 para a fração de volume de água (FVA).

Esses resultados demonstram uma boa concordância entre os valores preditos pela RNA e os resultados simulados com o MCNP6, validando a capacidade de generalização da rede, mesmo na presença de incrustações concêntricas de sulfato de bário. Na Figura 43 é apresentada a comparação dos resultados obtidos pela RNA e pelo código MCNP6 para ambas as saídas da rede, considerando todos os padrões (TRT + TST + VAL).

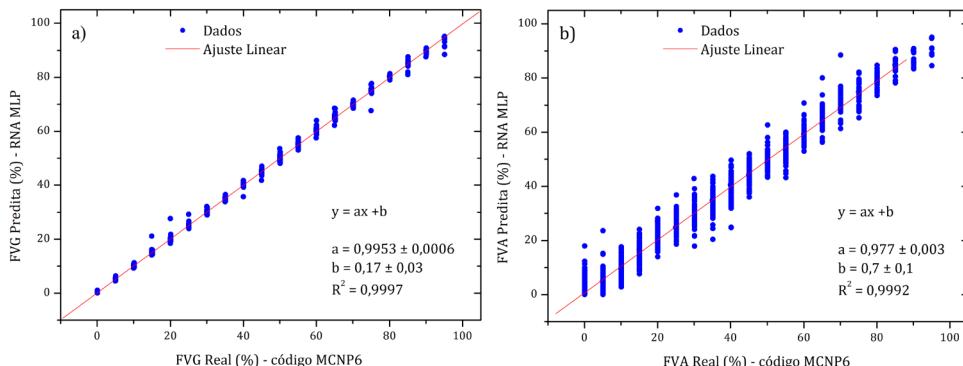


Figura 43 – Comparação dos resultados obtidos no treinamento da rede e pelo código MCNP6 para os fluidos: a) gás; b) água.

Na Tabela 15 é apresentada a porcentagem de predições realizadas pela rede neural para o experimento, distribuídas em intervalos de erros relativos para todos os padrões analisados nesta investigação. Esses resultados demonstram que a rede neural é capaz de prever frações volumétricas em sistemas multifásicos, independentemente da espessura das incrustações concêntricas. Destaca-se, que mais de 88% dos padrões foram preditos com erro relativo inferior a 5% para FVG e FVA, evidenciando uma satisfatória capacidade de generalização do modelo.

Fração de Volume	Probabilidade de classificação correta				
	≤ 5%	5%-10%	10%-20%	20%-30%	>30%
Gás	89,25	5,48	1,05	1,05	3,17
Água	88,98	5,14	1,55	0,27	4,06

Tabela 15 – Resumo do reconhecimento de padrões para predição da rede neural

Os poucos casos com erros superiores a 30% são devidos a valores muito baixos de frações volumétricas, especialmente para FVA. Nesses cenários, pequenas diferenças nos valores geram erros relativos significativamente maiores. Esses resultados confirmam a qualidade do treinamento realizado, incluindo padrões não utilizados durante o aprendizado da rede, ou seja, na fase de validação.

Os parâmetros de aprendizado da RNA de cinco camadas foram ajustados empiricamente, com base no menor erro médio relativo observado nas previsões da rede. Foram testadas várias arquiteturas, quantidades de neurônios e funções de ativação. A configuração do modelo que apresentou os melhores resultados é mostrada na Tabela 16.

Parâmetro	Camada			Saída
	Entrada	Oculta		
Função de Ativação	Linear* [-1,1]	Gaussiana	Tan15	Gaussiana complementar
Neurônio	110	31	31	31

Tabela 16 – Parâmetros que forneceram os melhores resultados para a rede neural

\*Função normalizadora

O resultado do subconjunto de validação (VAL) confirma a capacidade do método de predizer satisfatoriamente as frações volumétricas de gás e água, independentemente da espessura de incrustação. Na Figura 44 é apresentada uma boa correspondência entre os valores reais, simulados no MCNP6, e os preditos pela RNA, destacando a boa capacidade de treinamento e generalização, principalmente para a fase gasosa.

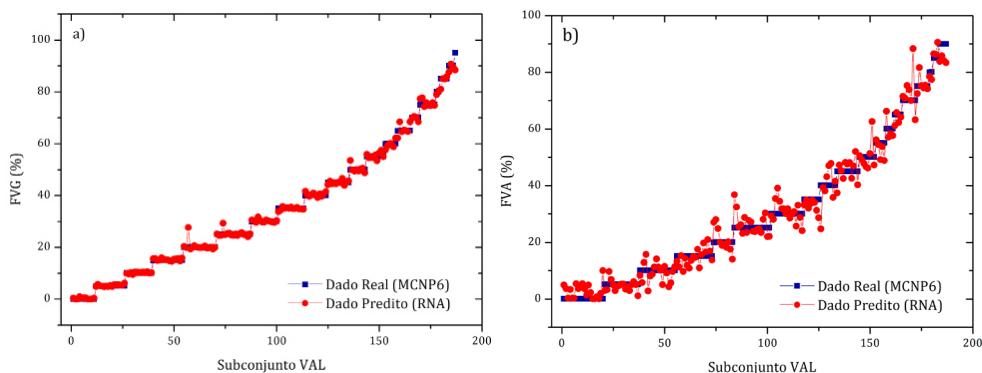


Figura 44 – Resultados da rede para o subconjunto de Validação considerando as frações de volume de: a) gás; b) água.

A abordagem de validação cruzada demonstrou resultados satisfatórios para padrões não utilizados na fase de treinamento. Outras métricas, como MAE, MSE, RMSE e MRE% foram utilizadas para avaliar a eficácia do modelo no subconjunto VAL, conforme apresentado na Tabela 17.

Fluido	Métrica			
	MAE	MSE	RMSE	MRE (%)
Gás	0,4092	0,4634	0,6807	1,89
Água	2,1523	9,6534	3,1070	10,68

Tabela 17 – Métricas para o subconjunto VAL

Mesmo nos piores cenários de desempenho, a rede neural manteve bons resultados. Além disso, avaliou-se a capacidade do modelo em predizer a espessura das incrustações concêntricas de sulfato de bário, cujos resultados são apresentados na Figura 45. Observa-se que a rede predisse adequadamente as espessuras no intervalo de 0,5 a 4 cm, com alta precisão.

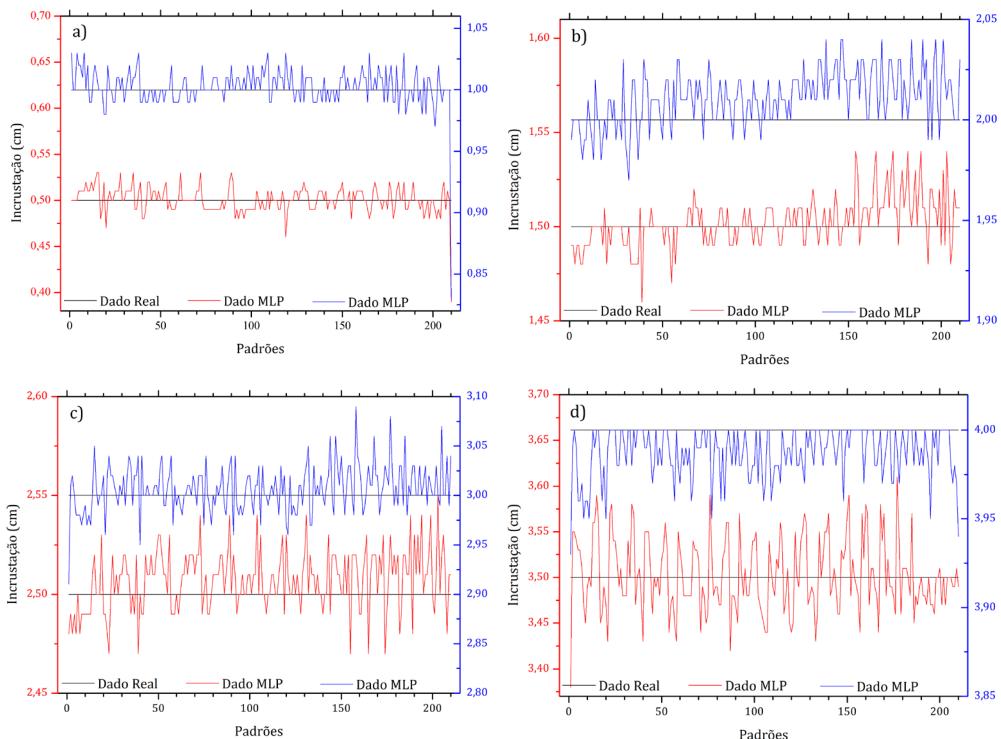


Figura 45 – Resultados de predição de espessura das incrustações: a) 0,5 cm e 1 cm; b) 1,5 cm e 2,0 cm; c) 2,5 cm e 3,0 cm; d) 3,5 cm e 4,0 cm. Os gráficos azuis utilizam a escala do eixo das ordenadas no lado direito.

As análises estatísticas das previsões para as espessuras das incrustações estão resumidas na Tabela 18.

Estatística	Incrustação (cm)							
	0,5	1,0	1,5	2,0	2,5	3,0	3,5	4,0
Média	0,501	1,002	1,503	2,011	2,507	3,007	3,502	3,986
Variância	0,0002	0,0003	0,0002	0,0002	0,0002	0,0006	0,0016	0,0002
Desvio padrão	0,014	0,017	0,013	0,013	0,015	0,024	0,040	0,014
Coeficiente de Variação <sup>3</sup>	2,81%	1,66%	0,85%	0,67%	0,61%	0,79%	1,14%	0,35%

Tabela 18 – Flutuações estatísticas para a previsão da espessura das incrustações

Os baixos valores de desvio padrão e coeficiente de variação indicam alta consistência nas predições, evidenciando pouca variabilidade em relação à média. Esses resultados demonstram que o modelo apresenta boa capacidade de generalização, permitido a predição precisa da espessura máxima de incrustação para amostras não treinadas, com erros desprezíveis.

## CONCLUSÕES

Os métodos de inteligência artificial, com destaque para as RNAs, vêm sendo amplamente explorados como ferramentas para estimar incrustações e frações de volume de gás, água e óleo em medidores multifásicos.

Neste estudo, foi desenvolvida uma metodologia baseada em dados gerados por simulações realizadas com o código MCNP6, integrados a uma RNA, para estabelecer uma geometria de medição de alto desempenho. Essa abordagem possibilitou a determinação precisa das frações de volume dos fluidos e a predição da espessura de incrustações concêntricas, utilizando tecnologia de densitometria gama. A RNA foi projetada para explorar características espectrais de uma fonte de  $^{192}\text{Ir}$ , registradas por dois detectores cintiladores de NaI(Tl).

Os resultados demonstraram que a metodologia proposta é capaz de estimar as frações de volume em sistemas trifásicos com regime de fluxo anular de gás-água-óleo, mesmo em situações com incrustações equivalentes a até 30% do diâmetro do tubo avaliado. O MRE (%) apresentou valores inferiores a 2% para o gás e próximos de 10% para água, independentemente do aumento na espessura das incrustações de sulfato de bário. Adicionalmente, o MSE e a RMSE para a água foram de 9,6534 e 3,1070, respectivamente, valores atribuídos a 4,06% dos padrões com erro superior a 30%. Mais de 88% das predições apresentaram erros inferiores a 5% evidenciando a robustez do modelo.

A precisão alcançada por esta metodologia na predição de frações de volume possui grande relevância para a indústria do petróleo. Além disso, a metodologia demonstrou ser capaz de identificar e quantificar a espessura máxima de incrustações concêntricas de sulfato de bário, com MRE (%) de apenas 0,83%, considerando todos os padrões investigados.

3. O coeficiente de variação é uma medida estatística que expressa a dispersão relativa de um conjunto de dados em porcentagem. Ele é definido como a razão entre o desvio padrão ( $\sigma$ ) e a média ( $\mu$ ).

# CÁLCULO DE INCRUSTAÇÃO EXCÊNTRICA

## Geometria de Detecção e Simulação

O código MCNP6 foi utilizado para desenvolver uma geometria de medição e registrar as DAPs em três detectores cintiladores posicionados ao redor do tubo. Essa geometria é baseada no espalhamento de raios gama de uma fonte de radiação que interage com os materiais presentes em um regime de fluxo estático. Além disso, o código foi utilizado para gerar um banco de dados adequado ao treinamento de uma RNA.

O sistema é composto por três detectores de NaI(Tl) dispostos a  $120^\circ$  uns dos outros ao redor de um tubo de aço inoxidável. Uma fonte puntiforme de  $^{137}\text{Cs}$ , que emite raios gama de 661,66 keV, está localizada em um ponto específico do arranjo. Os detectores e a fonte estão posicionados a 3 mm de distância do tubo de aço inoxidável tipo 316L, com densidade de  $8,0 \text{ g.cm}^{-3}$ , diâmetro externo de 252 mm e espessura de parede de 2 mm. Essa configuração foi projetada para medir a radiação gama espalhada em diferentes direções, possibilitando detectar a incrustação, que pode atingir seu valor máximo em qualquer posição dentro do tubo. A configuração do sistema é apresentada na Figura 46.

Dois ângulos divergentes ( $8^\circ$  e  $15^\circ$ ) para o fluxo de fôtons foram analisados., utilizando os cartões SI, SP e SB disponíveis no MCNP6. As DAPs registradas pelos detectores foram diretamente utilizadas no treinamento da RNA.

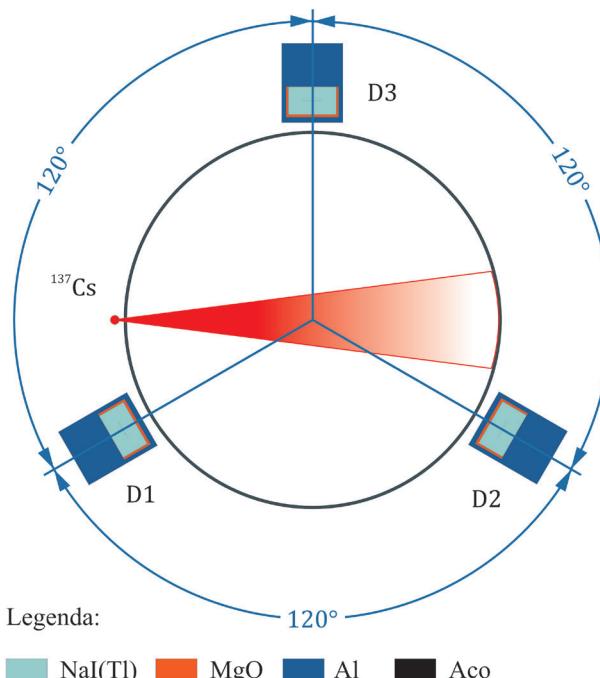


Figura 46 – Geometria de medição de incrustação.

O detector de NaI(Tl) foi modelado considerando um cristal com 31 mm de diâmetro e 19 mm de espessura, revestido por uma camada refletora de óxido de magnésio (MgO) e encapsulado em alumínio. A representação dessa simulação é apresentada na Figura 14. Além das informações geométricas, a modelagem no MCNP6 requer dados detalhados sobre a estrutura, composição química e densidade dos materiais presentes no sistema. Quanto maior a precisão desses dados de entrada, mais confiáveis serão os resultados obtidos. A fração mássica e a densidade dos materiais simulados são apresentadas na Tabela 5. Os materiais considerados incluem:

- I. Fase aquosa: Água salgada 4%, com densidade de  $1,0466 \text{ g.cm}^{-3}$ ;
- II. Fase líquida: Petróleo bruto, com densidade de  $0,973 \text{ g.cm}^{-3}$ ;
- III. Fase gasosa: De metano, com densidade de  $6,67 \times 10^{-4} \text{ g.cm}^{-3}$ .

Os dados coletados em cada detector foram registrados por meio do comando F8 do MCNP6, que fornece o erro relativo associado às estatísticas de contagem em cada faixa de energia do DAP. O número de histórias simuladas (NPS) foi ajustado para garantir um erro relativo inferior a 5% em toda a DAP [43].

## Dados de Treinamento de RNA

Para o treinamento da RNA, foi utilizado um modelo *perceptron* multicamadas com propagação do sinal adiante (MLP). O critério de parada adotado foi o método de Validação cruzada, para evitar o sobreajuste (*overfitting*). O algoritmo de aprendizado foi o retropropagação dos erros [47]. A arquitetura da RNA proposta está ilustrada na Figura 47.

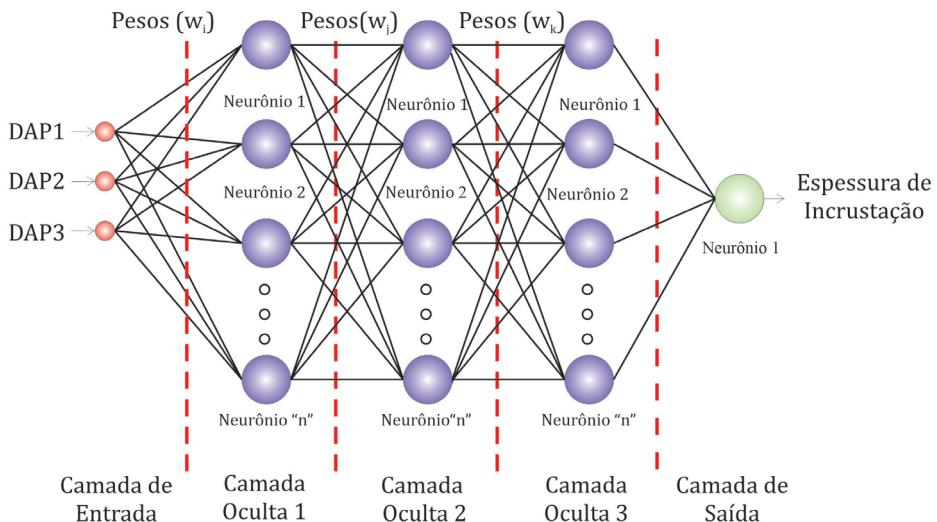


Figura 47 – Arquitetura da RNA proposta para predição de espessura de incrustação.

Os dados de entrada da RNA consistem nas DAPs registradas nos três detectores simulados (D1, D2 e D3) para cada espessura máxima simulada e a respectiva posição

relativa. Os dados de saída são as espessuras máximas de incrustação preditas. Cada DAP varia de 20 a 720 keV, com intervalos de 10 keV por canal.

As simulações consideraram incrustações excêntricas compostas de sulfato de bário. O regime de fluxo anular foi composto por 60% de óleo, 30% de água e 10% de gás. Essa fração volumétrica foi mantida constante, independentemente da espessura da incrustação.

Embora no mundo real o regime de fluxo anular forme misturas parciais de líquidos, como bolhas, gotículas e ondas nas interfaces, o modelo teórico idealizado em investigações de incrustação considerou uma mistura uniforme dos compostos. Isso ocorre porque o parâmetro mais relevante na densitometria de raios gama é a densidade e essa técnica busca especificamente informações sobre as camadas de incrustação, não sobre outros aspectos do regime de fluxo.

A espessura máxima da incrustação considerada variou de 2 mm a 164 mm, conforme ilustrado na Figura 48. Como em condições reais, a posição relativa da incrustação máxima é desconhecida, várias simulações foram realizadas, variando a localização da espessura máxima, sendo posicionada em 24 ângulos diferentes, em incrementos de 15°, em relação ao sistema de medição.

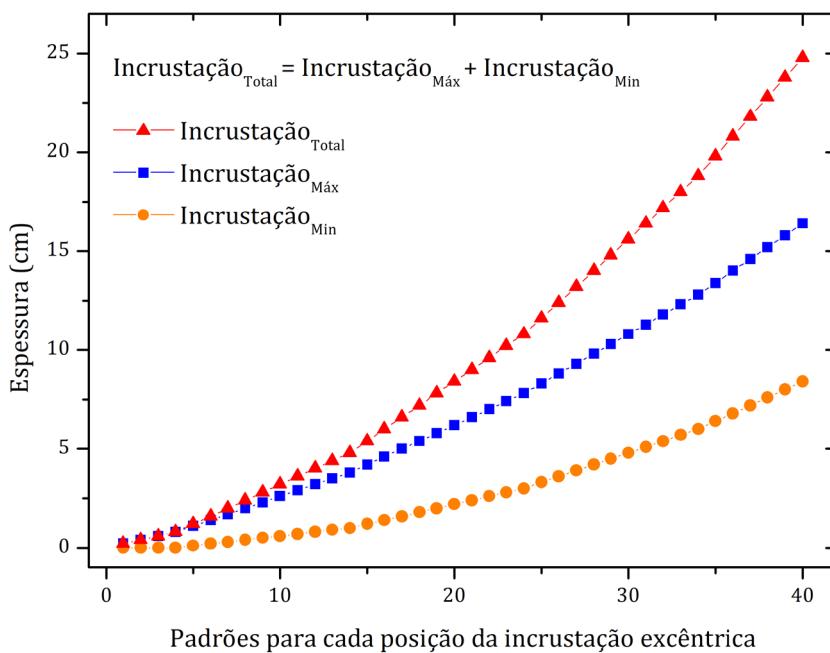


Figura 48 – Formação das posições de incrustação excêntrica.

Para melhor entendimento, os parâmetros de incrustação máxima (Incrustação<sub>Max</sub>) e mínima (Incrustação<sub>Min</sub>) são apresentados na Figura 49. A soma desses parâmetros define a incrustação total (Incrustação<sub>Total</sub>).

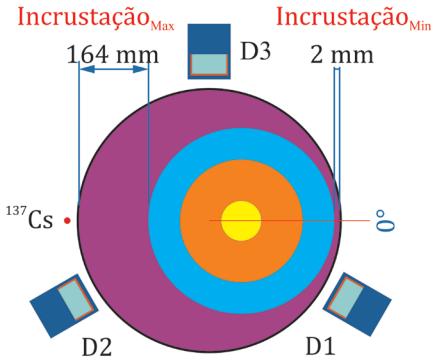


Figura 49 – Detalhes dos parâmetros de incrustação máxima e mínima.

Na Figura 50 é demonstrado o procedimento para quatro posições relativas. Esse método resultou em 960 padrões (40 espessuras × 24 ângulos). Os padrões foram então aleatoriamente distribuídos nos subconjuntos da RNA:

- Treinamento: 60% (576 padrões);
- Teste: 30% (288 padrões);
- Validação: 10% (96 padrões).

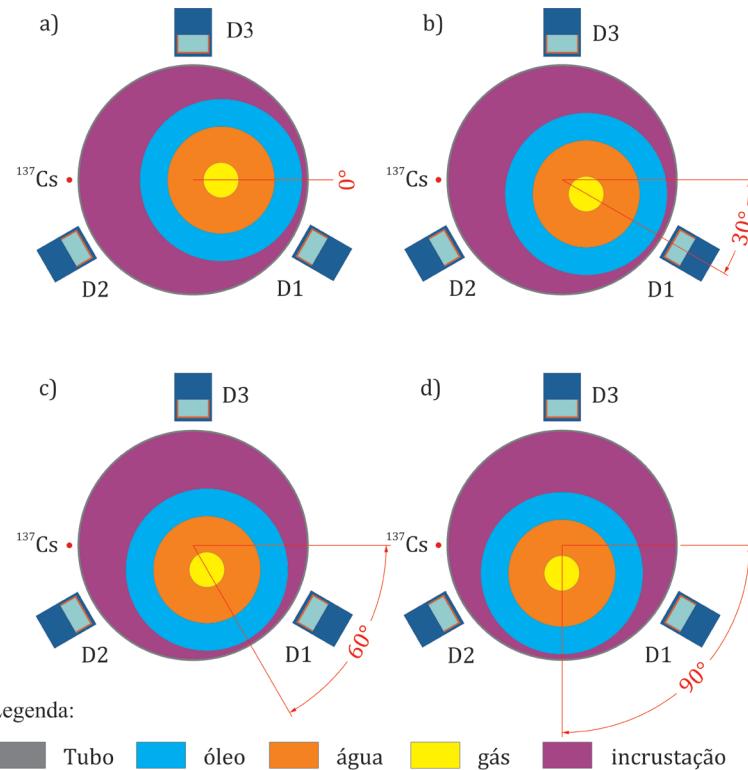


Figura 50 – Posições relativas da espessura máxima no interior do tubo: a) 0°; b) 30°; c) 60°; d) 90°.

## RESULTADOS E DISCUSSÃO

Nas simulações realizadas, as espessuras máximas de incrustação foram posicionadas em 24 ângulos diferentes, com incrementos de 15°. Essa abordagem permitiu analisar a capacidade da RNA de predizer a espessura máxima de incrustação excêntrica, independentemente de sua posição relativa ao sistema de medição. A configuração experimental consistiu em três detectores de NaI(Tl), dispostos a 120° entre si, para registrar o feixe espalhado. As DAPs registradas pelos três detectores para espessuras máximas de incrustação de 4 mm e 20 mm, ambas localizadas em 0°, são apresentadas na Figura 51. Já a Figura 52 ilustra as DAPs para espessuras máximas localizadas em 0° e 15°, considerando a mesma amplitude de incrustação.

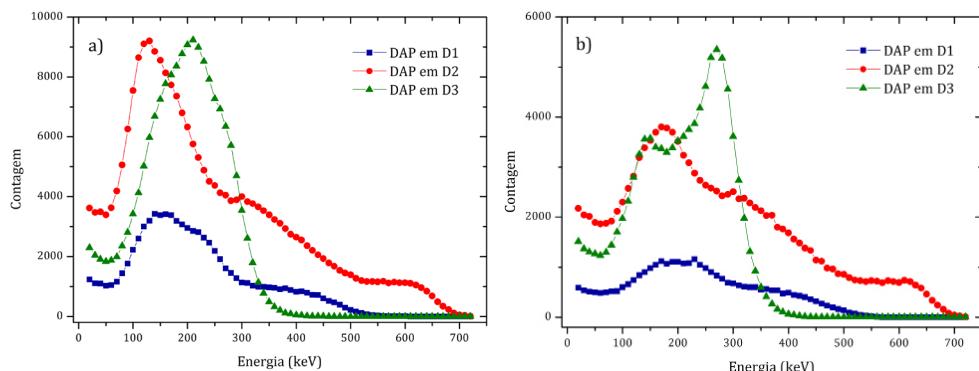


Figura 51 – DAPs registradas pelos três detectores para diferentes espessuras máximas de incrustação: a) 4 mm; b) 20 mm.

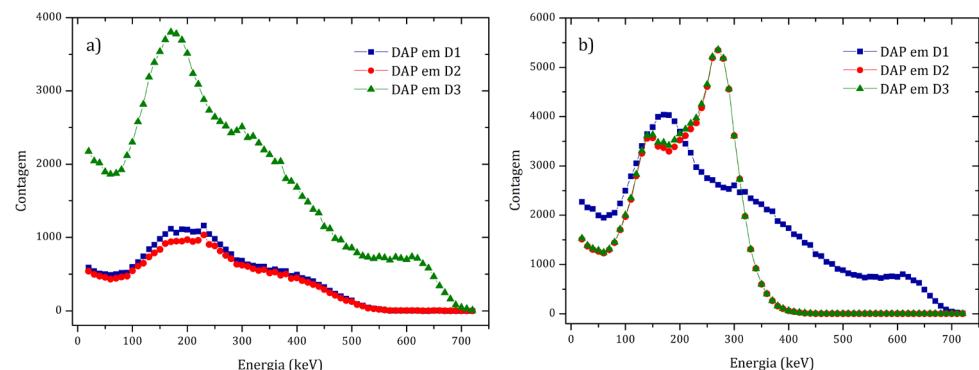


Figura 52 – DAPs registradas para diferentes posições angulares da espessura máxima: a) 0°; b) 15°.

Na Figura 51 e na Figura 52 são evidenciadas diferenças significativas nas DAPs, dependendo tanto da espessura quanto da posição angular da incrustação máxima. Essas variações foram fundamentais para o treinamento eficaz da RNA, resultando em boa convergência. Essa diferença possibilitou que a RNA fosse adequadamente treinada.

A RNA foi avaliada por meio de uma regressão linear ajustada aos dados preditos para incrustações excêntricas. O coeficiente de determinação ( $R^2$ ) obtido foi de 0,9959, considerando todos os padrões de simulação. A boa concordância entre os valores preditos pela RNA e os valores simulados pelo MCNP6 demonstra a robustez do modelo treinado e sua capacidade de generalização. Esses resultados estão ilustrados na Figura 53.

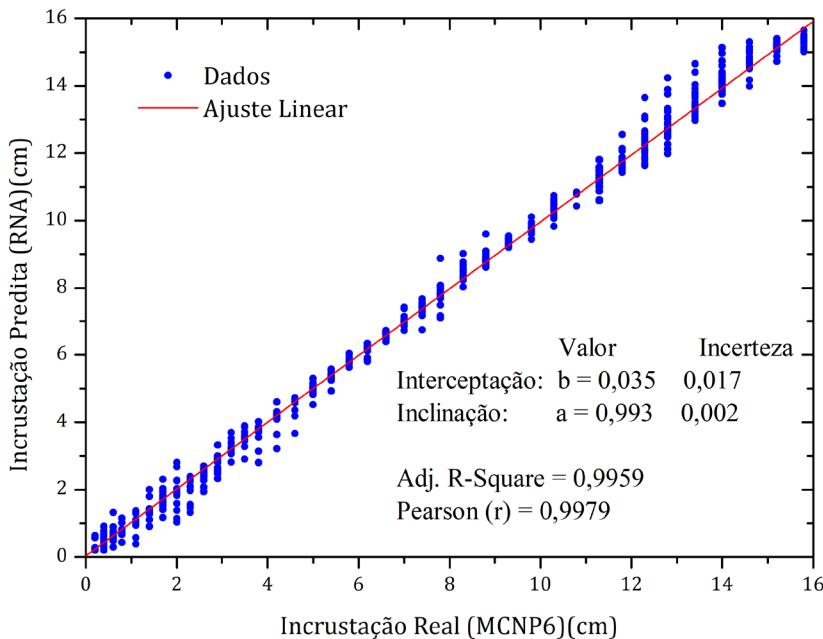


Figura 53 – Comparaçāo entre os resultados obtidos pela RNA e os simulados pelo código MCNP6.

Na Tabela 19 é apresentada a distribuição de predições da RNA em diferentes intervalos de erro relativo. Mais de 82% dos padrões apresentaram erros relativos inferiores a 5%, indicando um desempenho satisfatório na generalização do modelo.

Intervalo de erro relativo	Percentual de padrões (Espessura da Incrustação)
≤5%	82,71
5%-10%	9,06
10%-20%	3,23
20%-30%	1,56
>30%	3,44
$R^2$	0,9959

Tabela 19 – Distribuição dos erros relativos nas predições da RNA

Os erros superiores a 30% estão associados a incrustações com espessuras máximas inferiores a 10 mm, onde pequenos desvios absolutos resultam em valores maiores de erro relativo. Os hiperparâmetros foram definidos empiricamente, buscando

minimizar o erro médio relativo. Na Tabela 20 são resumidos os hiperparâmetros que resultaram no melhor desempenho.

Hiperparâmetros	Camada				
	Entrada	Oculta	Gaussiana Complementar	Saída	
Função de Ativação	Linear * [-1,1]	Gaussiana	Gaussiana	Gaussiana Complementar	Logística
Neurônio	180 **	38	38	38	1

Tabela 20 – Hiperparâmetros otimizados da RNA

\*Essa função retorna diretamente os valores de entrada, sem aplicar qualquer transformação.

\*\* Os intervalos de energia sem contagens registradas foram excluídos do processo de treinamento.

A análise do subconjunto VAL foi realizada com 96 padrões selecionados aleatoriamente, não utilizados no treinamento, e os resultados estão representados na Figura 54. Essa análise confirma a convergência entre as espessuras simuladas pelo MCNP6 e as preditas pela RNA, evidenciando sua capacidade de generalização mesmo em condições extremas de formação de incrustação.

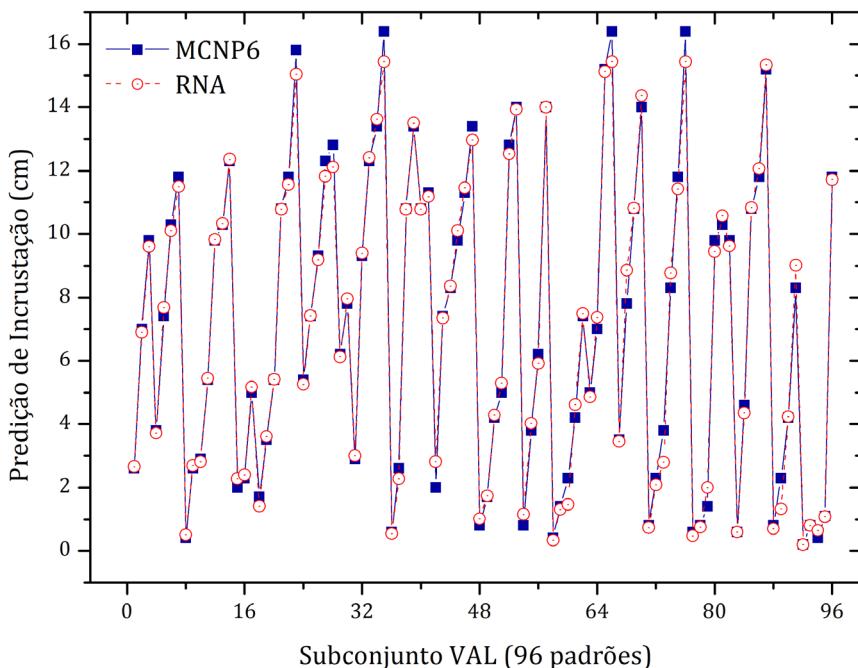


Figura 54 – Resultados obtidos pela RNA para o subconjunto de Validação.

As métricas estatísticas utilizadas, como MAE, MSE, RMSE e MRE, corroboram a eficácia da RNA. Os valores obtidos para o subconjunto VAL são apresentados na Tabela 21, demonstrando que o modelo foi capaz de prever a espessura máxima de incrustação com erros mínimos para padrões não treinados.

Métrica	Padrão	
	Todos (960)	Validação (VAL) (96)
MAE	0,177	0,241
MSE	0,095	0,129
RMSE	0,308	0,359
MRE (%)	4,51	0,27

Tabela 21 – Métricas estatísticas para avaliação da RNA

## CONCLUSÕES

Foi desenvolvida uma configuração de medição composta por três detectores de NaI(Tl), estrategicamente posicionados, para registrar fótons espalhados e utilizar uma RNA na análise dos registros obtidos. Esse arranjo permitiu predizer, com elevada precisão, a espessura máxima de incrustação em sistemas multifásicos, independentemente de sua posição relativa no interior do tubo ou da presença de fluidos. Os dados gerados por simulações no código MCNP6 serviram como base para treinar uma RNA de cinco camadas, utilizando o método de validação cruzada, no qual os subconjuntos de Treinamento, Teste e Validação foram selecionados de forma aleatória. Os resultados obtidos apresentaram métricas de desempenho satisfatórias, incluindo RMSE de 0,308, MRE de 4,51 e coeficiente de determinação ( $R^2$ ) de 0,9959. A avaliação da RNA com o subconjunto de Validação revelou erros relativos médios de apenas 0,27%, evidenciando a concordância entre os valores reais das espessuras máximas de incrustação e as previsões realizadas pela RNA. Mais de 90% dos padrões analisados foram classificados com erros relativos inferiores a 10%, independentemente da posição da incrustação dentro do tubo.

Esses resultados são promissores, indicam o potencial desta metodologia para o monitoramento e quantificação do crescimento de incrustações de sulfato de bário em seções específicas de tubos utilizados na indústria de petróleo. A abordagem permite determinar, de forma precisa e eficiente, a espessura máxima de incrustação no tópico investigada por meio de uma única medição.

## REFERÊNCIAS

- [1] Bahadori, A.; Al-Haddabi, M.; Vuthaluru, H. B. The Estimation of Reservoir Brine Properties During Crude Oil Production Using a Simple Predictive Tool. *Petroleum Science and Technology*, v. 31, p. 691-701, 2013.
- [2] Coto, B.; Martos, C.; Peña, J.L.; Espada, J.J.; Rosbutillo, M.D. A new method for determination of wax precipitation from non-diluted oils by fractional precipitation. *Fuel*, v. 87, n. 10-11, p. 2090-2094, 2008.
- [3] Kan, A.T.; Tomson, M.B. Scale prediction for oil and gas production. In: International Oil and Gas Conference and Exhibition in China, Beijing, China, June 2010. *Society of Petroleum Engineers*, 2010. Disponível em: <https://doi.org/10.2118/132237-MS>.
- [4] Yan F. Y.; Dai, Z.; Ruan, G.; Alsaiari, H.; Bhandari, N.; Zhang, F.; Liu, Y.; Zhang, Z.; Kan, A.; Tomson, M. Barite scale formation and inhibition in laminar and turbulent flow: A rotating cylinder approach. *Journal of Petroleum Science and Engineering*, v. 149, p. 183-192, 2004.

[5] Garcia, J.P.C. *Analysis of Fouling by Atomic/Nuclear Techniques*. 2010. 43 p. Tese (Doutorado em Engenharia Nuclear) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.

[6] Amiri, M.; Moghadasi, J. Prediction the amount of Barium Sulfate scale formation in Siri oilfield using OLI ScaleChem software. *Asian Journal of Scientific Research*, v. 3, p. 230-239, 2010.

[7] Khatami, H.R.; Ranjbar, M.; Schaffie, M.; Emady, M.A. Development of a fuzzy saturation index for sulfate scale prediction. *Journal of Petroleum Science and Engineering*, v. 71, p. 13-18, 2010.

[8] Bukuaghangin, O.; Sanni, O.; Kapur, N.; Huggan, M.; Neville, A.; Charpentier, T. Kinetics study of barium sulfate surface scaling and inhibition with a once-through flow system. *Journal of Petroleum Science and Engineering*, v. 147, p. 699-706, 2016.

[9] Osman, A.M.; Abdel-monem, A.M. Measurement of void fraction in pipes by nuclear transmission-based techniques. *Annals of Nuclear Energy*, v. 152, 2020. Disponível em: <https://doi.org/10.1016/j.anucene.2020.107994>

[10] Oliveira, D.F.; Nascimento, J.R.; Marinho, C.A.; Lopes, R.T. Gamma transmission system for detection of scale in oil exploration pipelines. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 784, p. 616-6220, 2015. Disponível em: <https://doi.org/10.1016/j.nima.2014.11.030>

[11] Salgado, W.L.; Dam, R.S.F.; Teixeira, T.P.; Conti, C.C.; Salgado, C.M. Application of artificial intelligence in scale thickness prediction on offshore petroleum using a gamma-ray densitometer. *Radiation Physics and Chemistry*, v. 168, 2020a. Disponível em: <https://doi.org/10.1016/j.radphyschem.2019.108549>

[12] Mosorov, V.; Zych, M.; Hanus, R.; Sankowski, D.; Saoud, A. Improvement of flow velocity measurement algorithms based on correlation function and twin plane electrical capacitance tomography. *Sensors*, v. 20 n. 1, p. 306. 2020. Disponível em: <https://doi.org/10.3390/s20010306>

[13] Faia, P.; Silva, R.; Rasteiro, M.G.; Garcia, F. Electrical Tomography: A Review of Configurations, and Application to Fibre Flow Suspensions Characterisation. *Applied Sciences*, v. 10, n. 7, 2020. Disponível em: <https://doi.org/10.3390/app10072355>

[14] Song, K.; Liu, Y. A compact x-ray system for two-phase flow measurement. *Measurement Science and Technology*, v. 29, n. 2, 2018. Disponível em: <https://doi.org/10.1088/1361-6501/aaa283>

[15] Candeias, J.P.; Oliveira, D.F.; Anjos, M.J.; Lopes, R.T. Scale analysis using X-ray microfluorescence and computed radiography, *Radiation Physics and Chemistry*, v. 95, p. 408-411, 2014.

[16] Heindel, T.J. A review of X-ray flow visualization with applications to multiphase flows. *Journal of Fluids Engineering*, v. 133, n. 7, 2011. Disponível em: <https://doi.org/10.1115/1.4004367>

[17] Sowerby, B.D.; Rogers, C.A. Gamma-ray density and thickness gauges using ultra-low activity radioisotope sourcesfillin. *Applied Radiation and Isotopes*, v. 63, p. 789-793, 2005. Disponível em: <https://doi.org/10.1016/j.apradiso.2005.05.031>

[18] Abdul-Majid, S. Determination of wax deposition and corrosion in pipelines by neutron back diffusion collimation and neutron capture gamma-rays. *Applied Radiation and Isotopes*, v. 74, p. 102-108, 2013. Disponível em: <http://dx.doi.org/10.1016/j.apradiso.2013.01.012>

[19] Bjørnstad, T.; Stamatakis, E. Scaling studies with gamma transmission technique. *Oil Field Chemistry*, p. 19-22, Geilo, NORWAY, 2006.

- [20] Zhao, Y.; Bi, Q.; Yuan, Y.; Lv, H. Void fraction measurement in steam–water two phase flow using the gamma ray attenuation under high pressure and high temperature evaporating conditions. *Flow Measurement and Instrumentation*, v. 49, p. 18-30, 2016.
- [21] Chuong, H.D.; Hai Yen, N.T.; My Le, N.T.; Tam, H.D. Determining the density of liquid using gamma scattering method. *Applied Radiation and Isotopes*, v. 163, 2020. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109197v>
- [22] Roshani, M.; Phan, G.T.; Ali, P.J.M.; Roshani, G.H.; Hanus, R.; Duong, T.; Corniani, E.; Nazemi, E.; Kalmoun, E.M. Evaluation of flow pattern recognition and void fraction measurement in two phase flow independent of oil pipeline's scale layer thickness. *Alexandria Engineering Journal*, v. 60, n. 1, p. 1955-1966, 2020.
- [23] Hanus, R.; Zych, M.; Kusy, M.; Jaszcjur, M.; Petryka, L. Identification of liquid-gas flow regime in a pipeline using gamma-ray absorption technique and computational intelligence methods. *Flow Measurement and Instrumentation*, v. 60, p. 17-23, 2018.
- [24] Salgado, C.M.; Brandão, L.E.B.; Schirru, R.; Pereira, C.M.N.A.; Xavier, A.S.; Ramos, R. Prediction of volume fractions in three-phase flows using nuclear technique and artificial neural network. *Applied Radiation and Isotopes*, v. 67, p. 1812-1818, 2009.
- [25] Salgado, C.M.; Brandão, L.E.B.; Pereira, C.M.N.A.; Salgado, W.L. Salinity independent volume fraction prediction in annular and stratified (water-gas-oil) multiphase flows using artificial neural networks. *Progress in Nuclear Energy*, v. 76, p. 17-23, 2014.
- [26] Salgado, C.M.; Dam, R.S.F.; Salgado, W.L.; Werneck, R.R.A.; Pereira, C.M.N.A.; Schirru, R. The comparison of different multilayer perceptron and General Regression Neural Networks for volume fraction prediction using MCNPX code. *Applied Radiation and Isotopes*, v. 162, 2020a. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109170>
- [27] Affonso, R.R.W.; Dam, R.S.F.; Salgado, W.L.; Silva, A.X.; Salgado, C.M. Flow regime and volume fraction identification using nuclear techniques, artificial neural networks and computational fluid dynamics. *Applied Radiation and Isotopes*, v. 159, 2020. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109103>
- [28] Faghihi, R.; Nematollahi, M.; Erfaninia, A.; Adineh, M. Void fraction measurement in modeled two-phase flow inside a vertical pipe by using polyethylene phantoms. *International Journal of Hydrogen Energy*, v. 40, n. 44, p. 15206-15212, 2015.
- [29] Nazemi, E.; Roshani, G.H.; Feghhi, S.A.H.; Gholipour Peyvandi, R.; Setayeshi, S. Precise Void Fraction Measurement in Two-Phase Flows Independent of the Flow Regime using gamma-ray attenuation. *Nuclear Engineering and Technology*, v. 48, p. 64-71, 2016.
- [30] Zhang, K.; Hou, Y.D.; Tian, W.X.; Zhang, Y.P.; Su, G.H.; Qiu, S.Z. Theoretical prediction of single bubble motion in vertically upward two-phase flow across inclined tube bundles. *Annals of Nuclear Energy*, v. 128, p. 422-432, 2019.
- [31] Roshani, G.H.; Karami, A.; Nazemi, E. An intelligent integrated approach of Jaya optimization algorithm and neuro-fuzzy network to model the stratified three-phase flow of gas–oil–water. *Computational and Applied Mathematics*, v. 38, n. 5, 2019. Disponível em: <https://doi.org/10.1007/s40314-019-0772-1>
- [32] Khorsandi, K.; Feghhi, S.A.H.; Salehzadeh, A.; Roshani, G.H. Developing a gamma ray fluid densitometer in petroleum products monitoring applications using Artificial Neural Network. *Radiation Measurements*, v. 59, p. 183-187, 2013.

- [33] Salgado, W.L.; Dam, R.S.F.; Barbosa, C.M.; Silva, A.X.; Salgado, C.M. Monitoring system of oil by-products interface in pipelines using the gamma radiation attenuation. *Applied Radiation and Isotopes*, v. 160, 2020b. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109125>
- [34] Hanus, R. Application of the Hilbert Transform to measurements of liquid–gas flow using gamma ray densitometry. *International Journal of Multiphase Flow*, v. 72, p. 210-217, 2015.
- [35] Hanus, R.; Petryka, L.; Zych, M. Velocity measurement of the liquid–solid flow in a vertical pipeline using gamma-ray absorption and weighted cross-correlation. *Flow Measurement and Instrumentation*, v. 40, p. 58-63, 2014.
- [36] Dam, R.S.F.; Barbosa, C.M.; Lopes, J.M.; Thalhofer, J.L.; Silva, L.B.; Salgado, C.M.; Silva, A.X. Radioactive particle tracking methodology to evaluate concrete mixer using MCNPX code. *Radiation Physics and Chemistry*, v. 160, p. 26-29, 2019b.
- [37] Dam, R.S.F.; Teixeira, T.P.; Salgado, W.L.; Salgado, C.M. A new application of radioactive particle tracking using MCNPX code and artificial neural network. *Applied Radiation and Isotopes*, v. 149, p. 38-47, 2019a.
- [38] Yadav, A.; Gaurav, T.K.; Pant, H.J.; Roy, S. Machine learning based position-rendering algorithms for radioactive particle tracking experimentation. *American Institute of Chemical Engineers*, v. 66, n. 6, 2020. Disponível em: <https://doi.org/10.1002/aic.16954>
- [39] Karami, A.; Roshani, G.H.; Khazaei, A.; Nazemi, E.; Fallahi, M. Investigation of different sources in order to optimize the nuclear metering system of gas–oil–water Annular flows. *Neural Computing and Applications*, p. 1-13, 2018.
- [40] Salgado, C.M.; Pereira, C.M.N.A.; Schirru, R.; Brandão, L. E. Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks. *Progress in Nuclear Energy*, v. 52, p. 555-562, 2010.
- [41] Sattari, M.A.; Roshani, G.H.; Hanus, R. Improving the structure of two phase flow meter using feature extraction and GMDH neural network. *Radiation Physics and Chemistry*, v. 171, 2020. Disponível em: <https://doi.org/10.1016/j.radphyschem.2020.108725>
- [42] Roshani, G.H.; Hanus, R.; Khazaei, A.; Zych, M.; Nazemi, E.; Mosorov, V. Density and velocity determination for single-phase flow based on radiotracer technique and neural networks. *Flow Measurement and Instrumentation*, v. 61, p. 9-14, 2018.
- [43] Goorley, T.; James, M.; Booth, T.; Brown, F.; Bull, J.; Cox, L.J.; Durkee, J.; Elson, J.; Fensin, M.; Forster, R.A.; Hendricks, J.; Hughes, H.G.; Johns, R.; Kiedrowski, B.; Martz, R.; Mashnik, S.; McKinney, G.; Pelowitz, D.; Prael, R.; Sweezy, J.; Waters, L.; Wilcox, T.; Zukaitis, T. Features of MCNP6. *Annals of Nuclear Energy*, v. 87, p. 772-783, 2016.
- [44] IAEA. Data from the gamma calibrated radioactive sources were obtained on Isotope Browser app, version 5.15.74 Android, IAEA, Nuclear Data Section, 2017.
- [45] Abouelwafa, M.S.A.; Kendall, E.J.M. The measurement of component ratios in multiphase systems using gamma-ray attenuation. *Journal of Physics E: Scientific Instruments*, v. 13, p. 341-345, 1980.
- [46] Hubbell, J.H.; Seltzer, S.M., 1997. Tables of X-ray mass attenuation coefficients and mass energy-absorption coefficients from 1 keV to 20 MeV for elements Z=1 to 92 and 48 additional substances of dosimetric interest. *NIST Standard Reference Database 126*, julho 2004. Disponível em: <https://www.nist.gov/pml/x-ray-mass-attenuation-coefficients>
- [47] Chauvin, Y.; Rumelhart, D.E. *Back-propagation Theory, Architectures and Applications*, 1995.

## CAPÍTULO 6

# IDENTIFICAÇÃO DA REGIÃO DE INTERFACE PARA MONITORAMENTO NO TRANSPORTE DE SUBPRODUTOS DE PETRÓLEO EM POLIDUTOS BASEADO EM RADIAÇÃO GAMA

---

**César Marques Salgado**

**William Luna Salgado**

**Roos Sophia de Freitas Dam**

**Claudio de Carvalho Conti**

O petróleo é uma matéria-prima amplamente utilizada em diversas atividades industriais, sendo transformado em produtos, como diesel, gasolina, óleo combustível, gás liquefeito de petróleo (GLP), querosene e nafta. Além disso, está presente em fertilizantes, plásticos, tintas, borrachas, entre outros. Devido à sua importância econômica, a demanda pelo transporte eficiente dessas *commodities*, bem como as atividades de extração, refino e distribuição, tornam-se essenciais para a economia de um país.

O transporte de grandes quantidades de derivados de petróleo é frequentemente realizado por meio de dutovias,<sup>1</sup> um sistema de dutos interconectados. Tradicionalmente, as dutovias são projetadas para transportar um único produto, como as linhas que conectam plataformas *offshore* à costa. Contudo, visando aperfeiçoar o uso deste modal, que exige altos investimentos para instalação, há a possibilidade de transportar diferentes produtos em um único duto, formando o que é chamado de poliduto. Esse modelo é amplamente utilizado por refinarias e terminais, permitindo o transporte sequencial de múltiplos produtos pela mesma infraestrutura [1]. Na indústria petrolífera, o transporte por polidutos é comum na distribuição de derivados e apresenta vantagens significativas em relação a outros modais, como a redução da necessidade de estocagem, menores perdas de produto, maior segurança operacional e, consequentemente maior economicidade [2, 3, 4].

---

1. Segmentos consecutivos de tubos, fabricados em materiais, como aço, concreto, plásticos, entre outros, são conectados para interligar pontos de origem e destino de materiais. Esses sistemas, conhecidos como dutovias, transportam substâncias sólidas (minerodutos), líquidas (oleodutos) e gasosas (gasodutos).

No Brasil, destaca-se o poliduto OSBRA (São Paulo–Brasília), localizado na região Sudeste. Entre suas principais instalações, destacam-se os terminais de armazenamento de combustíveis, destinados à distribuição, e as estações de bombeamento<sup>[5]</sup>. Com 964 km de extensão e tubulação com 12 polegadas de diâmetro, transporta óleo diesel, gasolina, gás liquefeito de petróleo (GLP) e querosene de aviação (QAV), atingindo uma capacidade máxima mensal de 920.793 m<sup>3</sup> e um volume anual 7.293.039 m<sup>3</sup> em 2018<sup>[6]</sup>.

O transporte em polidutos é realizado em bateladas<sup>2</sup> sequenciais, exigindo decisões sobre a sequência de produtos a serem transportados. Essa operação considera variáveis, como a disponibilidade e as características físico-químicas dos produtos. Em geral, o transporte ocorre sem o uso de separadores físicos, como *pigs*,<sup>3</sup> resultando na formação de uma região de interface entre as bateladas consecutivas, composta por uma mistura dos dois produtos. Na Figura 55, um fluxograma esquemático ilustra um poliduto transportando produtos A e B, evidenciando a formação da região de interface no ponto em que o bombeamento de B é interrompido para iniciar o transporte de A. Essa região de interface é normalmente incorporada ao produto menor valor agregado ou, em casos de incompatibilidade, destinado a tratamento específico<sup>[7]</sup>. Por exemplo, uma sequência de bateladas em um poliduto transportando gasolina e GLP resulta em uma interface que requer separação e tratamento. Já em uma batelada entre gasolina comum e gasolina premium, a mistura gerada na região de interface pode ser incorporada à gasolina comum, uma vez que esta mistura não atende às especificações da gasolina premium.

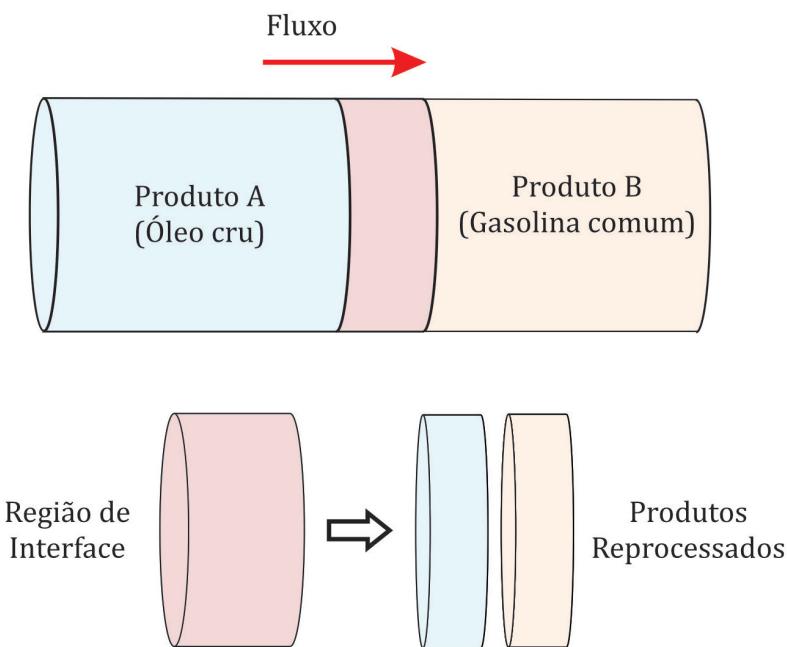


Figura 55 – Região de interface no poliduto.

2. O termo batelada é usado na indústria para designar uma determinada quantidade de um produto.

3. Pigs instrumentados são ferramentas para a inspeção interna em dutos que transportam óleo e seus derivados.

A extensão da região de interface aumenta ao longo do trajeto devido a fatores, como velocidade, regime do fluxo, viscosidade dos fluidos e turbulência, sendo diretamente dependente das condições operacionais. Estimativas incorretas da interface podem levar à perda de bateladas inteiras, com impacto significativo no custo operacional<sup>[8]</sup>. Além dos custos associados ao tratamento ou reprocessamento<sup>4</sup> da mistura formada, erros de identificação da interface resultam em perdas econômicas para as empresas. Assim, torna-se essencial desenvolver métodos que estimem de forma precisa e minimizem o tamanho dessa região<sup>[9, 10]</sup>. Essa situação evidencia a necessidade de desenvolver metodologias capazes de identificar, com precisão, a região de interface em diferentes combinações de produtos, visando o aperfeiçoamento do transporte em polidutos e a redução dos custos operacionais.

Na prática, a identificação da região de interface é realizada através de curvas de densidade obtidas por densímetros.<sup>5</sup> No entanto, sensores convencionais apresentam custos elevados de instalação e manutenção, sendo suscetíveis a danos causados por abrasão ou corrosão do produto<sup>[11]</sup>. Nesse contexto, a aplicação de densitometria gama surge como uma solução viável e eficiente, sendo amplamente utilizada em medições de fluxo<sup>[12]</sup>, monitoramento de derivados de petróleo<sup>[13, 14]</sup>, cálculos de frações de volume<sup>[15, 16, 17, 18, 19, 20]</sup>, predição das densidades de produtos<sup>[21, 22]</sup> e rastreamento de partículas radioativas<sup>[23, 24]</sup>. A técnica, baseada na interação de raios gama com o material, permite medições confiáveis, em tempo real e sem contato direto com o fluido, reduzindo custos e riscos associados. A densitometria gama se destaca pela capacidade de medir flutuações de densidade com alta precisão, sem alterar as condições operacionais, tornando-se uma ferramenta essencial na indústria<sup>[25, 26, 27, 28]</sup>. O uso de detectores sensíveis como o NaI(Tl) possibilita operar com fontes de baixa atividade, minimizando os riscos radiológicos para os trabalhadores.

A análise das regiões de interface pode ser realizada por métodos analíticos ou pela comparação de dados experimentais com tabelas de calibração. Contudo, equações analíticas frequentemente apresentam limitações para condições de contorno específicas, e tabelas de calibração são sensíveis a parâmetros, como raio e espessura das paredes do duto, temperatura e pressão, além de erros no processo de calibração<sup>[29]</sup>. Nesse cenário, redes neurais artificiais (RNAs) oferecem uma alternativa promissora, permitindo a análise de dados experimentais de densitometria gama para predizer a pureza dos produtos e identificar a região de interface. O uso de RNAs requer um conjunto robusto de padrões de calibração, mas apresenta potencial para superar as limitações dos métodos convencionais.

4. Além do custo associado ao reprocessamento, somam-se os custos relacionados ao transporte até a refinaria e outros encargos decorrentes da logística reversa.

5. O início da região de interface é definido pela variação na medição de um densímetro instalado em um dos extremos do poliduto, enquanto o término é determinado quando a leitura do densímetro estabiliza, indicando uma densidade constante correspondente ao segundo produto.

## PROCEDIMENTOS ADOTADOS

O método proposto baseia-se na transmissão de um feixe de raios gama através de uma tubulação contendo fluidos em um sistema multifásico. As densidades dos fluidos são determinadas utilizando a equação de *Beer-Lambert*, permitindo calcular o nível de pureza. Para o espalhamento, a energia dos fótons é calculada pela equação de Compton, enquanto o número de fótons espalhados que atingem o detector é estimado com base no tópico de choque diferencial de *Klein-Nishina*.

Uma geometria de medição foi desenvolvida para avaliar esse método, considerando um regime de fluxo estratificado com gasolina e óleo. A técnica de densitometria gama de dupla modalidade foi implementada no código MCNP6<sup>[30]</sup>, permitindo a medição tanto de feixes transmitidos quanto de feixes espalhados, o que aumenta a sensibilidade na predição do nível de pureza dos fluidos.

### Geometria proposta do sistema de medição

O modelo matemático foi simulado no código MCNP6 e consiste em uma fonte de <sup>137</sup>Cs, que emite raios gama com energia de 661,66 keV, e dois detectores cintiladores de NaI(Tl). A calibração dos detectores requer a determinação experimental das curvas de eficiência em função da energia incidente e de resolução em energia.

Para a calibração, foram utilizados padrões radioativos com emissão gama no intervalo de 59,54 até 1332,49 keV (Tabela 2). A curva de eficiência absoluta de fotópico foi determinada experimentalmente para validar a modelagem do detector<sup>[31]</sup>. Todas as medições foram realizadas com 60 minutos de duração, mantendo uma distância fonte-detector (DFD) de 28 mm. O suporte utilizado, desenvolvido em Ácido Polilático (PLA), assegurou a precisão do posicionamento axial do detector. Os parâmetros experimentais foram ajustados para minimizar o tempo morto, reduzir o Efeito Soma<sup>7</sup> e garantir que os erros associados à estatística de contagem fossem inferiores a 1%. Considerou-se também a radiação de fundo (BackGround – BG) e as múltiplas interações devido ao efeito Compton. Para determinar a resolução em energia, foi adotado o mesmo procedimento da curva de eficiência. Os picos de absorção identificados por meio do Analisador MultiCanal (AMC) permitiram calcular a largura à meia altura (FWHM) de cada fotópico, utilizando a Equação 9.

Para os tubos, uma colimação matemática foi desenvolvida para utilizar um feixe largo, com divergência suficiente para obter boa estatística de contagem em ambos os detectores de NaI(Tl). Para reduzir o tempo computacional, a fonte colimada foi configurada como um cone utilizando os cartões SI, SP e SB do MCNP6. O ângulo sólido máximo entre a fonte e o detector D1 foi de 8,7°, assegurando boa estatística de contagem. Ambos os detectores foram posicionados em torno do tubo.

O detector D1 foi posicionado diametralmente oposto à fonte para medir o feixe

6. Embora a energia de 661,66 keV do <sup>137</sup>Cs tenha sido utilizada, a calibração foi expandida para abranger um intervalo mais amplo, permitindo o ajuste da linearidade do detector para fontes de maior energia. Essa abordagem garante medições precisas em uma ampla faixa energética, indispensável para diversas aplicações.

7. Ocorre quando o radionuclídeo emite dois ou mais fótons dentro de um intervalo de tempo muito curto, de forma que o sistema de detecção é incapaz de separar os dois eventos considerando-os como um só. Ocorre também quando a taxa de emissão dos fótons é muito elevada.

transmitido, enquanto o detector D2<sup>8</sup> foi ajustado para medir o feixe espalhado. O posicionamento deste detector D2 foi avaliado em três ângulos ( $15^\circ$ ,  $30^\circ$  e  $45^\circ$ ) a ser selecionado com base nos valores de MRE e RMSE e casos com erros inferiores a 5%, obtidos pelas RNAs. Os fluidos analisados foram Gasolina (Gas) ( $C_8H_{18}$ ,  $0,721\text{ g.cm}^{-3}$ ), Óleo combustível (Oil) ( $0,955\text{ g.cm}^{-3}$ ), Querosene (Ker) ( $0,819\text{ g.cm}^{-3}$ ) e Glicerina (Gly) ( $1,2613\text{ g.cm}^{-3}$ ), como descrito na Tabela 5 [32]. Diversas combinações desses fluidos foram utilizadas para investigar a atenuação e o espalhamento dos raios gama.

O cartão *tally* F8 do MCNP6 foi utilizado para estimar a DAP registrada nos detectores, com uma classificação de 20 a 800 keV em intervalos de 10 keV. Essa faixa foi escolhida em função da energia da fonte (661,66 keV, emitida pelo  $^{137}\text{Cs}$ ).

O detector foi validado experimentalmente para uma faixa de até 1,3 MeV, permitindo o uso de outras fontes como o  $^{60}\text{Co}$ , ampliando a versatilidade do método. Na Figura 56 é apresentado um esquema da geometria proposta.

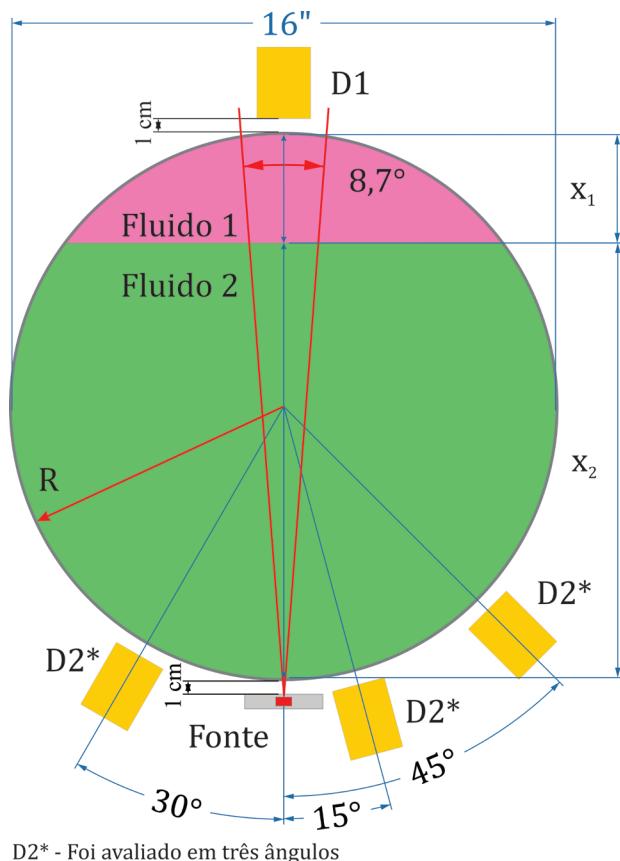


Figura 56 – Geometria de medição simulada proposta para cálculo do nível de pureza.

O procedimento adotado para o cálculo da fração de volume de fluido (FVF) utilizando a técnica de atenuação gama baseia-se na determinação das espessuras (e) de

8. Vale destacar que o segundo detector objetiva aumentar a área de visualização da seção transversal inspecionada do tubo, além de fornecer um conjunto mais completo de informações sobre os fluidos para inferência da RNA.

cada fluido, que correspondem ao caminho percorrido pela radiação. Para uma abordagem analítica, considerando um feixe tipo *pencil beam*, os valores das frações de volume podem ser obtidos pela Equação 30 [33]. Vale destacar que o nível de pureza abordado neste capítulo está intimamente relacionado à fração volumétrica dos fluidos. As equações apresentadas visam calcular essa fração, o que possibilita, por consequência, a determinação do nível de pureza. Esse vínculo é essencial para compreender a aplicação das equações na análise da pureza dos fluidos.

### Predição da pureza dos fluidos por RNA

Os padrões de treinamento da RNA foram formados a partir das DAPs obtidas pelos detectores D1 e D2, com base nas diversas combinações do nível de pureza dos fluidos. A geração dos subconjuntos de dados para treinamento e teste da rede neural é uma etapa crucial deste estudo. Para isso, os valores das espessuras dos fluidos ( $h_1$  e  $h_2$ ) no regime de fluxo estratificado foram modificados, conforme ilustrado na Figura 56. Uma validação teórica das frações de volume foi realizada por meio da Equação 30.

O modelo de medição proposto, conforme ilustrado na Figura 56, foi testado com quatro fluidos diferentes: Gasolina (Gas), Querosene (Ker), Óleo combustível (Oil) e Glicerina (Gly). As principais características desses fluidos estão apresentadas na Tabela 5 [32]. Para essa etapa, considerou-se uma tubulação de aço 316L com raio de 20,32 cm (8") e espessura de 0,2 cm. Como o objetivo do estudo é identificar a região de interface no transporte em polidutos, foram formados seis grupos para investigação: Gas–Ker, Gas–Oil, Gas–Gly, Ker–Gly, Ker–Oil, Oil–Gly. Os padrões com diferentes frações de volume foram calculados utilizando a Equação 30.

Na Figura 57, a título de ilustração, apresenta-se a curva de transporte em função da densidade para quatro diferentes combinações de fluidos: Gas – Gly – Oil – Ker.

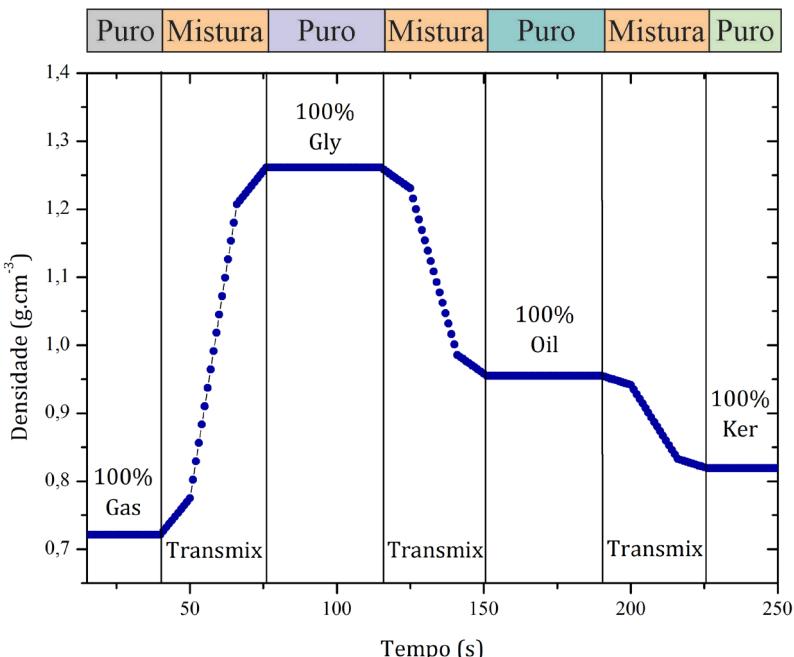


Figura 57 – Densidade de cada região de interface (transmix) simulada para os quatro fluidos.

A região de interface, também denominada de *transmix*, corresponde à mistura resultante de contato entre dois fluidos. Nessa região, a quantidade do segundo fluido é gradualmente aumentada à medida que se move na direção do primeiro fluido.

Foi desenvolvida uma RNA, que consiste em uma rede multicamadas com propagação do sinal adiante (MLP), composta por 5 camadas, utilizando o algoritmo de aprendizagem por retropropagação do erro. Para compor os padrões de treinamento da RNA, foram geradas várias combinações de pureza dos fluidos, variando de 1% até 10% e de 90% a 100% com incrementos de 1%, além de variações de 10% a 90% com incrementos de 5%. Isso totalizou 37 padrões para cada combinação de dois fluidos analisados. É importante destacar que, para identificar a região de interface, é necessário determinar quando um fluido é puro, motivo pelo qual os limites inferior e superior da região de interface são mais detalhados.

Neste estudo, foram utilizados quatro fluidos, e as combinações de dois em dois resultaram em seis possibilidades de investigação. Assim, gerou-se um conjunto de simulações com 222 padrões ( $37 \times 6$ ), cobrindo diferentes níveis de pureza dos fluidos e suas combinações. Esse conjunto de padrões foi dividido em três subconjuntos: o subconjunto de Treinamento (TRT), com 156 padrões (70%); o subconjunto de Teste (TST), com 44 padrões (20%); e o subconjunto de Validação (VAL), com 22 padrões (10%)<sup>[34]</sup>. O subconjunto de Teste foi usado para avaliar a generalização do treinamento da RNA, com o objetivo de evitar o sobreajuste (*overfitting*), utilizando o critério de parada por Validação cruzada<sup>[35]</sup>. Após o treinamento da RNA, a validação foi realizada utilizando o subconjunto de Validação, com objetivo testar o desempenho da rede na fase operacional.

Uma vez treinada e validada, a RNA pode ser utilizada para predizer a pureza dos fluidos sem a necessidade de ajustes adicionais para medições *online*, tornando-se independente dos dados utilizados na fase de treinamento. Cada um dos subconjuntos foi escolhido e distribuído aleatoriamente. Para cada um dos 222 padrões simulados no código MCNP6, as DAPs foram calculadas. O número de partículas simuladas (NPS) foi ajustado para garantir estatísticas aceitáveis, com erro relativo (ER) inferior a 3% para todas as subdivisões de energia das DAPs, conforme as diretrizes do manual do MCNP6.

Para o desenvolvimento da rede neural, foram utilizados como dados de entrada as DAPs obtidas pelos detectores de transmissão (D1) e de espalhamento (D2). As saídas consistem em dois neurônios: um para o Nível de Pureza de cada fluido transportado e o outro como Indicador de Pureza,<sup>9</sup> considerando o limite de 99% de pureza. A configuração do modelo de rede, incluindo dados de entrada e saída, está esquematicamente apresentada na Figura 58.

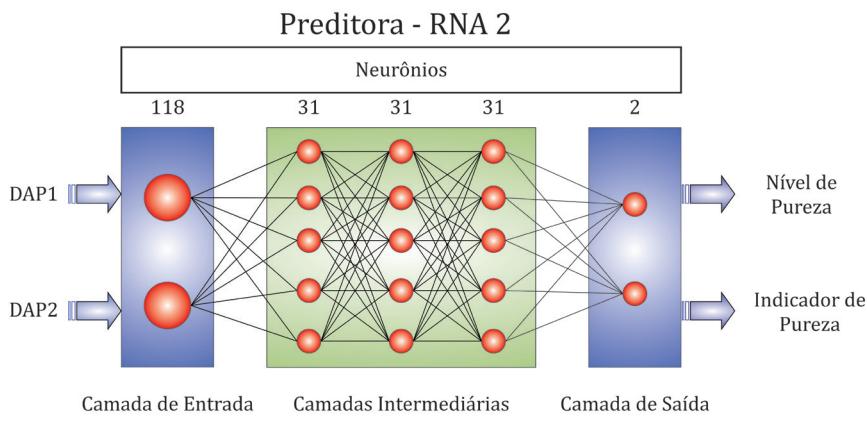


Figura 58 – Configuração da RNA desenvolvida neste estudo.

De forma simplificada, os padrões utilizados pela RNA são compostos pelas seguintes informações:

I. Entradas da RNA (118 neurônios):

- Detector D1: Contagens relativas às energias de 20 a 800 keV;
- Detector D2: Contagens relativas às energias de 20 a 300 keV.

II. Saídas da RNA (2 neurônios):

- Nível de Pureza dos fluidos;
- Indicador de pureza do fluido.

Vale ressaltar que uma única rede neural foi treinada para predizer esses parâmetros, independentemente da combinação de fluidos sendo transportada. A resposta da rede para cada subconjunto de padrões (TRT, TST e VAL) foi avaliada usando diversas métricas matemáticas, conforme descrito na Secção 2.7.2.

9. Quando a pureza atinge um valor predeterminado pelo operador, nesse caso, 99%, a saída da rede, rotulada como “Indicador de Pureza”, é ativada. Isso pode gerar um alerta para o operador da linha de transporte.

## RESULTADOS E DISCUSSÕES

### Validação teórica da geometria proposta

As DAPs obtidas pelo detector de transmissão (D1) para as frações de volume de fluido de óleo iguais a 25%, 50% e 75% no sistema bifásico sob regime de fluxo estratificado são apresentadas na Figura 59.

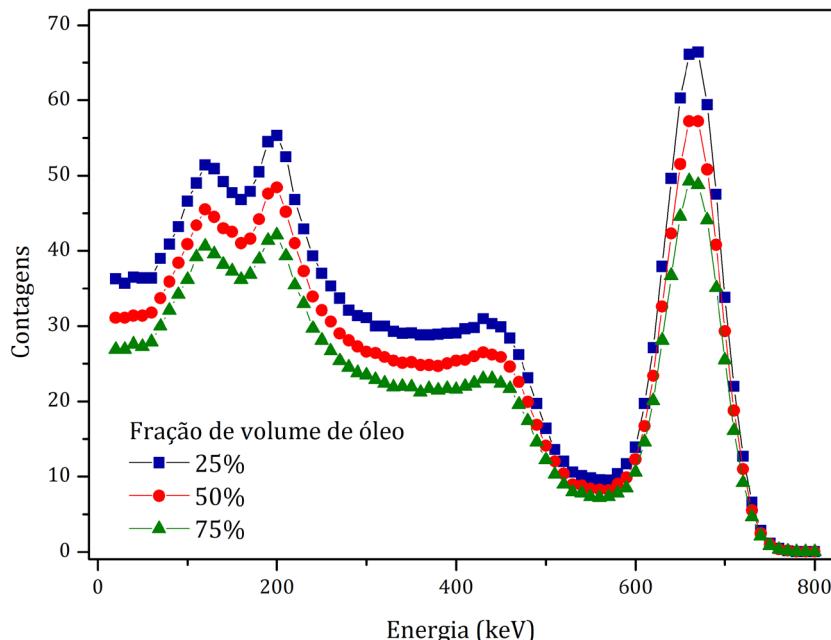


Figura 59 – DAPs obtidas com a simulação de gasolina e óleo.

O cálculo da fração de volume, utilizando a solução analítica pela Equação 30, foi realizado a partir da integral da área correspondente à região de absorção total, obtida pelo detector de transmissão (D1), com os modelos desenvolvidos no código MCNP6. Esse procedimento foi adotado devido à boa caracterização da região de absorção total de energia. Os resultados obtidos para a fração de volume de gasolina, calculados por equação analítica foram comparados com os valores obtidos por meio do MCNP6, conforme apresentado na Tabela 22.

FVF Real de Óleo (%) (MCNP6)	Equação Analítica (Equação 30)	
	FVF (%)	ER (%)
25,00	24,87	0,52
50,00	49,87	0,26
75,00	74,56	0,59

Tabela 22 – Comparação dos resultados obtidos pela solução analítica e código MCNP6

Observa-se que, ao utilizar a equação analítica desenvolvida, o erro relativo ER (%) máximo é de apenas 0,59%. Com o modelo validado, foi possível gerar o conjunto de dados necessário para o treinamento da rede neural artificial.

Cabe ressaltar que o sistema de detecção simulado foi validado por meio de uma configuração experimental para o feixe transmitido, conforme descrito no trabalho de Salgado et al., (2020b) [14].

## Predição do Nível de Pureza

Como ilustração, as DAPs do feixe transmitido e espalhado obtidas pelos detectores D1 e D2, respectivamente, para três distintos níveis de pureza de gasolina em uma tubulação de 8 polegadas de raio são apresentadas na Figura 60. As DAPs foram classificadas na faixa de energia de 20 a 800 keV, em canais de 10 keV cada.

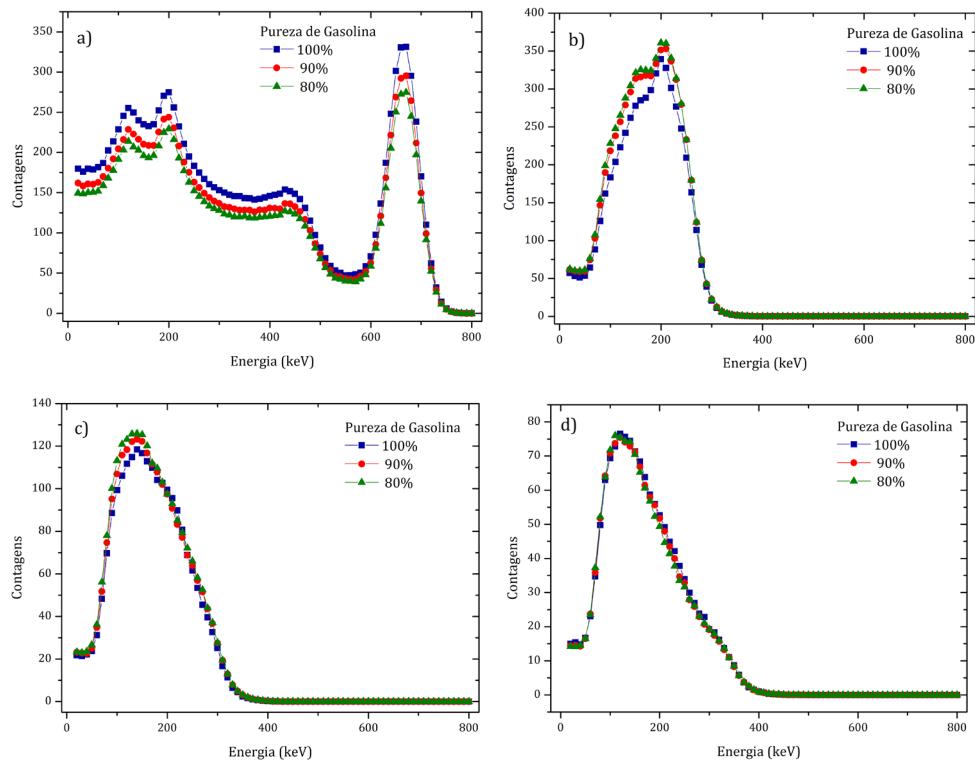


Figura 60 – DAPs obtidas pelo código MCNP6 para o detector: a) de transmissão (D1); b) de espalhamento D2 a 15°; c) D2 a 30° e d) D2 a 45°.

Após testes empíricos, a posição do detector D2 a 15° em relação à fonte foi a que proporcionou a melhor resposta da RNA, otimizando a captura do sinal e melhorando a acurácia das previsões.

Para a geração do conjunto de dados para treinamento e avaliação da rede neural, foram elaborados modelos representativos do regime de fluxo estratificado, considerando as combinações de purezas entre os fluidos (Gas–Ker, Gas–Oil, Gas–Gly, Ker–Gly, Ker–Oil, Oil–Gly). Em seguida, realizou-se a simulação matemática do transporte da radiação gama utilizando o código MCNP6, cujas respostas foram usadas como dados de entrada para a rede neural.

As simulações realizadas com o código MCNP6 geraram um total de 203 padrões, que foram distribuídos aleatoriamente nos subconjuntos de Treinamento (143 padrões, 70%), Teste (40 padrões, 20%) e Validação (20 padrões, 10%).

Os hiperparâmetros da rede neural foram ajustados empiricamente com base no maior valor do coeficiente de determinação ( $R^2$ ), do MRE e no maior percentual de acertos dentro de uma faixa de erro relativo de até 5%. Os parâmetros que apresentaram a melhor resposta são listados na Tabela 23.

Parâmetro	Entrada	Camada Oculta		Saída
Função de Ativação	Linear [-1, 1]	Gaussiana	Tanh	Gaussiana Complementar
Neurônio	119 *	24	24	1

Tabela 23 – Parâmetros de treinamento da RNA

\*Função normalizadora

As correlações entre os níveis de pureza reais, obtidos pelo MCNP6, e os preditos pela RNA para os subconjuntos de Treinamento e Teste são apresentadas na Figura 61.

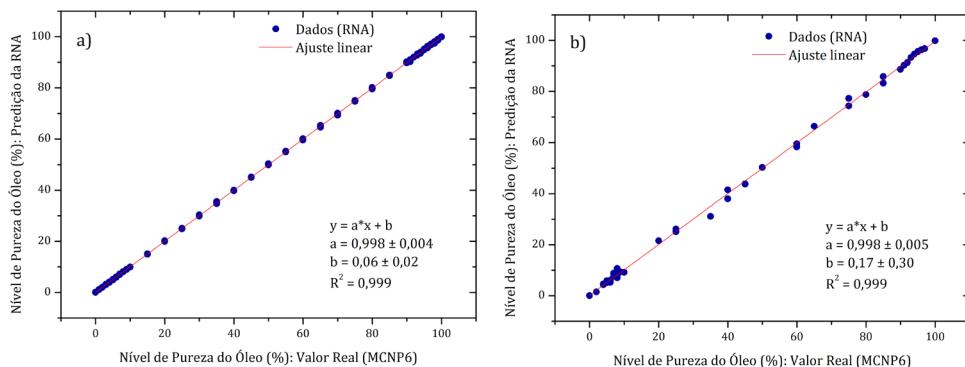


Figura 61 – Correlação entre resultados da RNA e os padrões reais, considerando os subconjuntos: a) Treinamento; b) Teste.

Funções polinomiais de primeiro grau foram ajustadas utilizando o método dos mínimos quadrados, o que forneceu coeficientes de determinação ( $R^2$ ) de 0,9999 para o subconjunto de Treinamento e 0,9989 para o subconjunto de Teste. Esses resultados indicam que os valores preditos pela RNA possuem boa concordância com os valores reais, evidenciando a capacidade de generalização do treinamento da rede.

Uma avaliação final do desempenho da rede foi realizada com o subconjunto de Validação, que apresentou respostas muito próximas aos valores reais, exceto no caso 3, que apresentou um erro absoluto de 2,97, conforme mostrado na Tabela 24.

Padrões	Nível de Pureza (%)		Erro Absoluto
	Real	RNA	
1	0	0,10	-0,10
2	7	6,44	0,56
3	15	12,03	2,97
4	40	38,83	1,17
5	80	79,83	0,17
6	85	83,43	1,57
7	5	4,18	0,82
8	10	10,26	-0,26
9	15	16,54	-1,54
10	65	63,91	1,09
11	92	92,79	-0,79
12	93	93,71	-0,71
13	96	96,01	-0,01
14	8	8,18	-0,18
15	1	0,00	1,00
16	90	88,32	1,68
17	10	8,38	1,62
18	55	55,93	-0,93
19	85	85,64	-0,64
20	99	99,03	-0,03
21	80	80,42	-0,42
22	92	91,78	0,22

Tabela 24 – Predição da RNA para o conjunto de Validação

Os erros absolutos para todos os padrões presentes nos subconjuntos de Treinamento, Teste e Validação são apresentados na Figura 62.

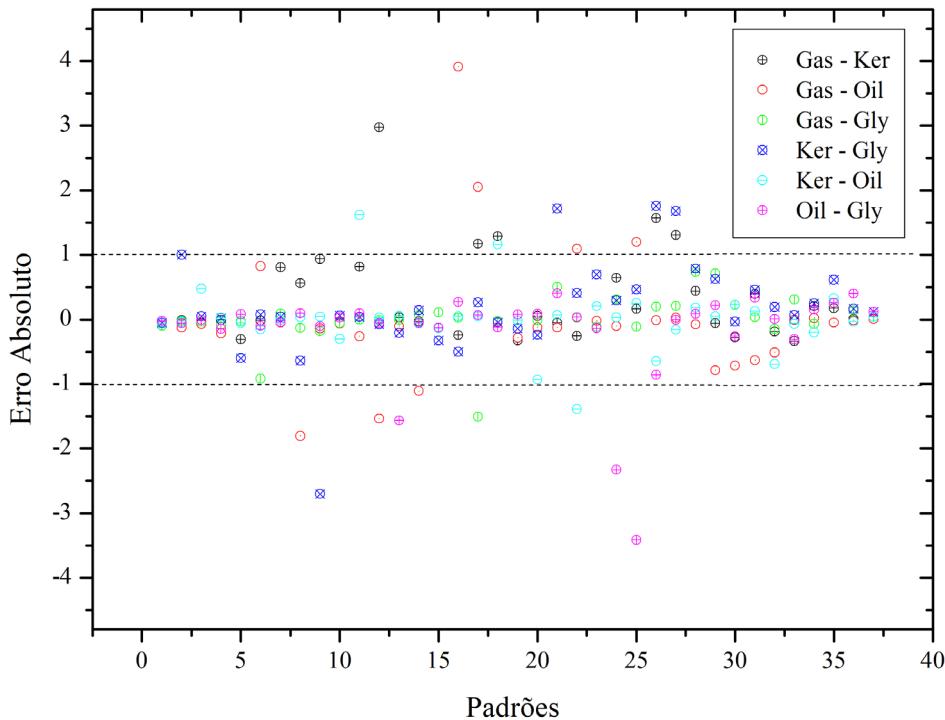


Figura 62 – Erros absolutos de todos os padrões para cada par de fluidos.

Observa-se que maioria dos padrões apresenta valores de erro absoluto dentro da margem de  $\pm 1$ , indicando que foram preditos com boa precisão, aproximando-se dos valores reais. Esses resultados sugerem que o treinamento da RNA foi satisfatório, o que confirma a viabilidade de usar essa técnica para predizer o nível de pureza de fluidos de petróleo em um regime estratificado. No entanto, vale ressaltar que, embora alguns padrões estejam dentro da margem de 1%, isso pode resultar em erros relativos significativos. Uma análise mais aprofundada do erro relativo poderia fornecer uma avaliação mais robusta da precisão das previsões.

Outras métricas de erro, como MAE, MSE, RMSE e MRE, também foram utilizadas para avaliar o comportamento da resposta da rede neural para cada subconjunto de padrões (TRT, TST, VAL). Os resultados das métricas calculadas estão apresentados na Tabela 25.

Métrica	Padrões			
	Total	TRT	TST	VAL
	222	156	44	22
MAE	0,371	0,132	0,915	0,977
MSE	0,485	0,036	1,458	1,725
RMSE	0,697	0,190	1,207	1,313
MRE (%)	2,40	0,68	5,32	8,77

Tabela 25 – Análise da predição da RNA usando parâmetros estatísticos

Os valores de MAE, MSE e RMSE estão na mesma ordem de grandeza para todos os padrões, indicando que a maioria dos padrões apresenta erros pequenos. Além disso, os resultados apresentados pela RNA foram classificados em faixas de erros, conforme mostrado na Tabela 26. Observa-se que erros relativos menores que 5% foram obtidos para mais de 87% de todos os padrões, com coeficientes de determinação ( $R^2$ ) de 0,9997, indicando excelente predição da rede neural.

Faixa de Erro Relativo	Quantidade de Padrões (%)
< 5%	87,39
5 – 10%	3,60
10 – 20%	4,50
20 – 30%	0,90
> 30%	0,90

Tabela 26 – Classificação das faixas de erro relativo para a predição da RNA

Esses resultados demonstram que a metodologia proposta é capaz de predizer as quantidades de fluidos com até 10% de erro relativo para mais de 90% dos padrões utilizados nesta investigação. O coeficiente de determinação obtido também indica que a predição da rede apresenta resultados muito próximos aos dados reais, especialmente nos limites da escala, que devem ser monitorados e que indicam a presença de impurezas. Como exemplo, a resposta da RNA para uma tubulação de raio 8 polegadas é apresentada na Figura 63, mostrando uma comparação entre os dados reais (MCNP6) e os dados preditos (RNA). É possível observar que a curva apresenta excelente concordância entre os dados de treinamento (pontos em verde e em azul) e os dados do subconjunto de Validação (pontos em vermelho).

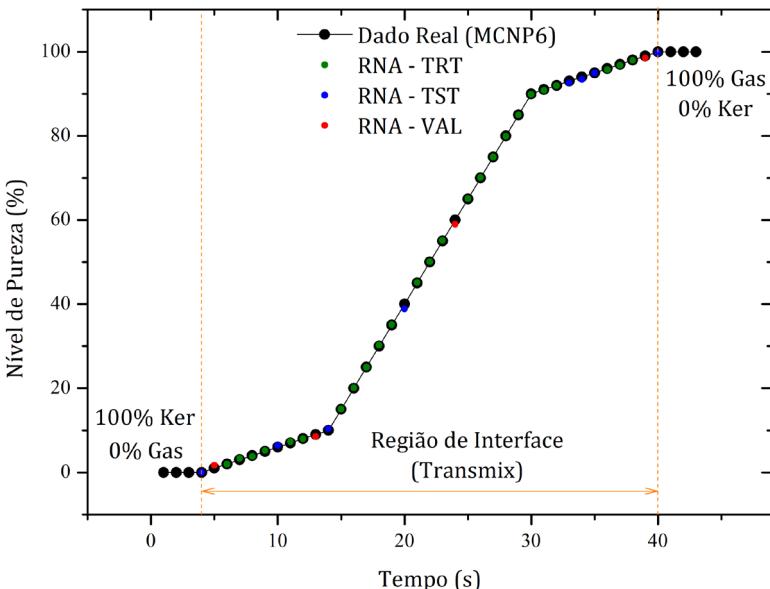


Figura 63 – Curva representativa da região de interface considerando o transporte do par gasolina e querosene.

A análise da Figura 63 revela que a região da interface se inicia com uma variação na medição da densidade do primeiro fluido (óleo), registrada pelos detectores. Essa variação persiste até que a resposta dos detectores se estabilize, alcançando um valor constante correspondente à densidade do segundo fluido (gasolina), indicando o término da região de interface. É importante ressaltar que os valores extremos de 0% e 100 % de pureza de óleo e gasolina foram inseridos no gráfico apenas para simbolizar leituras constantes dos detectores, demonstrando o transporte exclusivo de um dos fluidos. A partir dos resultados, observa-se que a rede neural conseguiu predizer de forma satisfatória a curva representativa da interface. Cada ponto nessa curva representa diferentes níveis de pureza de óleo, permitindo identificar com boa precisão a transição entre os fluidos. A metodologia proposta se mostrou capaz de determinar níveis de pureza de até 99%.

Adicionalmente, a segunda saída da RNA apresentou desempenho excelente, atingindo 100% de acurácia na classificação do indicador de pureza dos fluidos, com valores que incluem purezas de até 99%. Na Figura 64 é ilustrado o desempenho do indicador de pureza da RNA para o subconjunto de Validação, corroborando a eficácia do treinamento aplicado.

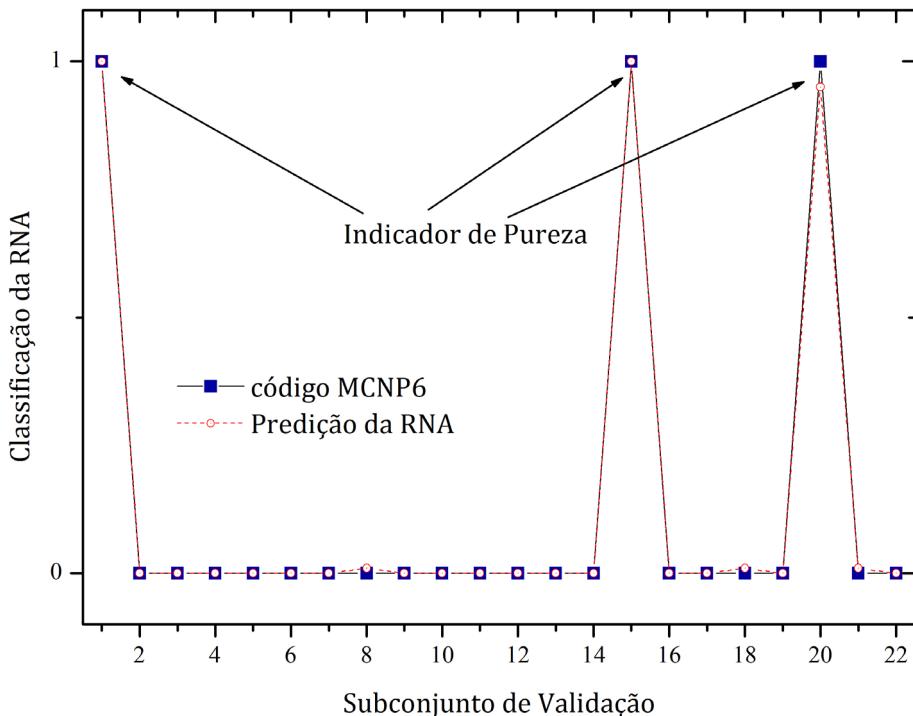


Figura 64 – Resposta do indicador de pureza da RNA para o subconjunto de Validação.

Esses resultados evidenciam a capacidade do modelo em operar com padrões que não foram incluídos na fase de aprendizado, validando a precisão na determinação da região da interface e a robustez do modelo para diversas combinações de fluidos, aproximando-se de condições reais.

Assim, a RNA demonstrou sua habilidade em predizer a pureza dos fluidos e identificar a região de interface de maneira satisfatória, com margens de impureza inferiores a 1%.

## CONCLUSÕES

Simulações realizadas no código MCNP6 permitiram gerar um conjunto de dados abrangente, utilizado no treinamento e avaliação da rede neural voltada à predição da pureza dos fluidos transportados. A geometria de medição proposta, baseada em feixes transmitidos, foi validada experimentalmente através da curva de eficiência absoluta de fotópico e pela resolução em energia de detector real, conferindo maior realismo às respostas obtidas. A utilização do MCNP6 foi crucial na definição da geometria de medição, oferecendo confiabilidade à metodologia desenvolvida para identificar a região de interface em sistemas bifásicos de escoamento estratificado. O modelo apresentou um erro relativo médio de 2,22% nos padrões na RNA, evidenciando sua eficácia. Além disso, o uso de simulações elimina a necessidade de construir protótipos físicos na fase inicial de um projeto.

Os resultados das frações de volume do regime de fluxo estratificado, obtidos pela equação desenvolvidas, apresentaram um erro relativo máximo de 0,59% para as frações de 25%, 50% e 75%, demonstrando excelente convergência com valores teóricos. A partir disso, foi possível gerar 203 padrões para o treinamento e validação da RNA.

A combinação de técnicas de transmissão e espalhamento de radiação gama, aliada ao uso do MCNP6 e RNAs, resultou em uma metodologia capaz de identificar a região de interface em polidutos com purezas de até 99%, destacando a eficiência da RNA. No subconjunto de Teste, o modelo também mostrou grande capacidade de generalização, com os dados do subconjunto de Teste apresentando MRE de 5,32% e RMSE de 1,207. Mais de 87% dos padrões apresentaram erros relativos inferiores a 5%. Os padrões de Validação apresentaram erro relativo médio de 8,77%, com valores de MAE, MSE e RMSE permanecendo na mesma ordem de grandeza, evidenciando a robustez do modelo.

Os resultados obtidos são promissores, indicando que a metodologia proposta é adequada para o transporte de fluidos em polidutos, especialmente na indústria petrolífera. O desenvolvimento de um dispositivo compacto, de alta velocidade e precisão, é viável e representa uma contribuição significativa para a área.

## REFERÊNCIAS

- [1] Mohitpour, M.; Szabo, J.; Hardeveld, T.V. *Pipeline operations and maintenance: A Practical Approach*. American Society of Mechanical Engineers, 2005. ISBN 9780791802328. Disponível em: <https://books.google.com.br/books?id=OihfyvP5r2YC>
- [2] Souza, T.C. *Distribuição de derivados de petróleo por redes de polidutos: uma abordagem através de algoritmos evolucionários híbridos para um problema triobjetivo*. 2015. Tese (Doutorado em Ciência da Computação) – Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, 2015.
- [3] Cafaro, D.C.; Cerdá, J. Dynamic scheduling of multiproduct pipelines with multiple delivery due dates. *Computers and Chemical Engineering*, v. 32, p. 728-753, 2008.
- [4] Freire, J.L.F. *Engenharia de dutos*. Rio de Janeiro: ABMC, 2009.
- [5] Kotchetkoff, A.P. 2009. *Estudo de tratamento de interface proveniente de polidutos*. 2009. Dissertação (Mestrado em Engenharia Química) –Universidade Federal de Uberlândia, Uberlândia, 2009.
- [6] Transpetro. *Informações em atendimento à ANP – Terminais e oleodutos*. Disponível em: [http://www.transpetro.com.br/pt\\_br/fale-conosco/canal-do-cliente/informacoes-em-atendimento-a-anp/terminais-e-oleodutos.html](http://www.transpetro.com.br/pt_br/fale-conosco/canal-do-cliente/informacoes-em-atendimento-a-anp/terminais-e-oleodutos.html). Acesso em: 27 jan. 2018.
- [7] Vincent-Genod, J. *Fundamentals of pipeline engineering*. Gulf Publishing Co., Houston, TX, 1984.
- [8] Fowler, F.C.; Brown, G.G. Contamination by successive flow in pipe lines, *American institute of chemical engineers*, v. 39, p. 491-516, 1943.
- [9] Jones, W.M.; Paddock, K.F. Transport by pipeline, In: Hobson, G.D. (Ed.). *Modern petroleum technology*. Nova Jersey: John Wiley & Sons, 1982.
- [10] Techo, R.; Holbrook, D.L. Computer scheduling the world's biggest product pipeline. *Pipeline Gas Journal*, p. 4-27, 1974.

- [11] Carvalho, H.P.; Medeiros, J.L.; Araújo, O.D. *Modelagem Maxwell-Stefan para predição de propriedades e volume de mistura na região de interface de bateladas em sistemas polidutos*. Boletim Técnico da Petrobras, p. 78-133, 2003.
- [12] Mi, Y.; Ishii, M.; Tsoukalas, L. Vertical two-phase flow identification using advanced instrumentation and neural networks. *Nuclear engineering and design*, v. 184 n. 2-3, p. 409-420, 1998.
- [13] Khorsandi, M.; Feghhi, S.A. Design and construction of a prototype gamma-ray densitometer for petroleum products monitoring applications. *Measurement*, 44, p. 1512-1515, 2011.
- [14] Salgado, W.L.; Dam, R.S.F.; Teixeira, T.P.; Conti, C.C.; Salgado, C.M. Application of artificial intelligence in scale thickness prediction on offshore petroleum using a gamma-ray densitometer. *Radiation Physics and Chemistry*, v. 168, 2020a. Disponível em: <https://doi.org/10.1016/j.radphyschem.2019.108549>
- [15] Abouelwafa, M.S.A.; Kendall, E.J.M. The measurement of component ratios in multiphase systems using gamma-ray attenuation. *Journal of Physics E: Scientific Instruments*, v. 13, p. 341-345, 1980.
- [16] Nazemi, E.; Roshani, G.H.; Feghhi, S.A.H.; Gholipour, P.R.; Setayeshi, S. Precise Void Fraction Measurement in Two-Phase Flows Independent of the Flow Regime using gamma-ray attenuation. *Nuclear Engineering and Technology*, v. 48, p. 64-71, 2016.
- [17] Salgado, C.M.; Brandão, L.E.B.; Schirru, R.; Pereira, C.M.N.A.; Xavier, A.S.; Ramos R. Prediction of volume fractions in three-phase flows using nuclear technique and artificial neural network. *Applied Radiation and Isotopes*, v. 67, p. 1812-1818, 2009.
- [18] Salgado, C.M.; Pereira, C.M.N.A.; Shirru, R.; Brandão, L.E. Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks. *Progress in Nuclear Energy*, v. 52, p. 555-562, 2010.
- [19] Salgado, W.L.; Dam, R.S.F.; Barbosa, C.M.; Silva, A.X.; Salgado, C.M. Monitoring system of oil by-products interface in pipelines using the gamma radiation attenuation. *Applied Radiation and Isotopes*, 160, 2020b. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109125>
- [20] Hanus, R.; Zych, M.; Kusy, M.; Jaszcjur, M.; Petryka, L. Identification of liquid-gas flow regime in a pipeline using gamma-ray absorption technique and computational intelligence methods. *Flow Measurement and Instrumentation*, v. 60, p. 17-23, 2018.
- [21] Abdulrahman, A.A.; Shokir, E.M. Artificial neural networks modeling for hydrocarbon gas viscosity and density estimation. *Journal of King Saud University - Engineering Sciences*, v. 23, p. 123-129, 2011.
- [22] Salgado, C.M.; Brandão, L.E.B.; Conti, C.C.; Salgado, W.L. Density prediction for petroleum and derivatives by gamma-ray attenuation and artificial neural networks. *Applied Radiation and Isotopes*, v. 116, p. 143-149, 2016.
- [23] Dam, R.S.F.; Barbosa, C.M.; Lopes, J.M.; Thalhofer, J.L.; Silva, L.B.; Salgado, C.M.; Silva, A.X. Radioactive particle tracking methodology to evaluate concrete mixer using MCNPX code. *Radiation Physics and Chemistry*, v. 160, p. 26-29, 2019b.
- [24] Dam, R.S.F.; Teixeira, T.P.; Salgado, W.L.; Salgado, C.M. A new application of radioactive particle tracking using MCNPX code and artificial neural network. *Applied Radiation and Isotopes*, v. 149, p. 38-47, 2019a.
- [25] Moosavi, M.; Soltani, N. Prediction of hydrocarbon densities using an artificial neural network-group contribution method up to high temperatures and pressures. *Thermochimica Acta*, v. 556, p. 89-96, 2013.

- [26] Sabzevari, S.; Moosavi, M. Density prediction of liquid alkali metals and their mixtures using an artificial neural network method over the whole liquid range. *Fluid Phase Equilibria*, v. 361, p. 135-142, 2014.
- [27] Hassan, A.M.; Alrashdan, A.; Hayajneh, M.T.; Mayyas, A.T. Prediction of density, porosity and hardness in aluminum–copper-based composite materials using artificial neural network. *Journal of materials processing technology*, v. 209, p. 894-899, 2009.
- [28] Chuong, H.D.; Hai Yen, N.T.; My Le, N.T.; Tam, H.D. Determining the density of liquid using gamma scattering method. *Applied Radiation and Isotopes*, v. 163, p. 109197, 2020. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109197>
- [29] Maucec, M.; Denijs, I. Development and calibration of a gamma-ray density meter for sediment-like materials. *Applied Radiation and Isotopes*, v. 67, p. 1829-1836, 2009.
- [30] Goorley, T.; James, M.; Booth, T.; Brown, F.; Bull, J.; Cox, L.J.; Durkee, J.; Elson, J.; Fensin, M.; Forster, R.A.; Hendricks, J.; Hughes, H.G.; Johns, R.; Kiedrowski, B.; Martz, R.; Mashnik, S.; McKinney, G.; Pelowitz, D.; Prael, R.; Sweezy, J.; Waters, L.; Wilcox, T.; Zukaitis, T. Features of MCNP6. *Annals of Nuclear Energy*, v. 87, p. 772-783, 2016.
- [31] Ewa, I.O.B.; Bodizs, D.; Czifrus, S.Z.; Molnar, Z.S. Monte Carlo determination of full energy peak efficiency for a HPGe detector. *Applied Radiation and Isotopes*, v. 55, n. 1, p. 103-108, 2001.
- [32] McConn Jr., R.J.; Gesh, C.J.; Pagh, R.T.; Rucker, R.A.; Williams III, R.G. Compendium of Material Composition Data for Radiation Transport Modeling. *Radiation portal monitor project*, Pacific Northwest, National Laboratory. PIET-43741-TM-963 PNNL-15870 Rev. 1, 2011.
- [33] Salgado, W.L.; Dam, R.S.F.; Salgado, C.M. Development of analytical equations for void fraction in biphasic systems using gamma radiation and MCNP6 code. *Applied Radiation and Isotopes*, v. 214, 2024. Disponível em: <https://doi.org/10.1016/j.apradiso.2024.111549>
- [34] Zadeh, E.E.; Feghhi, S.A.H.; Roshani, G.H.; Rezaei, A. Application of artificial neural network in precise prediction of cement elements percentages based on the neutron activation analysis. *The European Physical Journal Plus*, v. 131, n. 167, 2016. Disponível em: <https://doi.org/10.1140/epjp/i2016-16167-6>
- [35] Haykin, S. *Neural Networks –A Comprehensive Foundation*. New York: Macmillan College Publishing Company, 1994.

Neste livro, foram discutidos assuntos relacionados à aplicação de redes neurais artificiais e técnicas nucleares em parâmetros de fluxo, como a fração de volume e incrustação em sistemas multifásicos, com apresentação de exemplos práticos. Um pequeno resumo sobre o regime de fluxo, os estudos que investigam a fração de volume dos fluidos e, por fim, aqueles que analisaram a vazão das diferentes fases. Diversos parâmetros de fluxo, como pressão, temperatura, velocidade e viscosidade, são frequentemente utilizados como variáveis no treinamento de redes neurais. No entanto, não utilizamos esses parâmetros diretamente na rede neural; em vez disso, trabalhamos com as contagens registradas pelos detectores. Deve-se destacar uma grande quantidade de pesquisas relacionadas à medição de fluxo multifásico com uso de redes neurais artificiais, utilizando técnicas, como densitometria de raios gama e raios X, além de ondas ultrassônicas e elétricos. Os resultados mostram que a utilização de redes neurais devidamente desenvolvidas, especialmente aquelas com o algoritmo de retropropagação, incluindo uma ou duas camadas ocultas, é adequada para determinar os parâmetros de fluxo, levando a um aumento na precisão dos resultados. Entretanto, é necessário grande quantidade de dados, permitindo sua aplicação em uma gama mais ampla de diâmetros de tubos, viscosidades de fluidos, densidades e razões gás-líquido. Identificar com precisão padrões de fluxo na análise de fluxo multifásico é uma tarefa desafiadora; com dados adequados e técnicas apropriadas de normalização, essa tarefa torna-se viável com alta precisão. As redes neurais acopladas com as técnicas nucleares têm grande potencial para aplicações em diversas indústrias, incluindo caracterização e simulação de reservatórios, recuperação avançada de petróleo, teste de poços, mecânica de rochas, limpeza de poços, fluxo de fluidos em meios porosos, entre outras. A Inteligência artificial vem aprimorando a obtenção de parâmetros multifásicos, mas é sempre importante avaliar a eficácia das redes neurais diante das mudanças nas propriedades dos fluidos de petróleo e gás produzidos, ampliando a pesquisa para explorar diversas outras técnicas de inteligência artificial, como algoritmos genéticos. Para aumentar a confiabilidade dos resultados, está em andamento a construção de estrutura adequada para a validação completamente experimental, que será aplicada às redes neurais previamente treinadas nos estudos de caso.

**César Marques Salgado:** Doutor em Engenharia Nuclear pela UFRJ (2010), mestre em Radioproteção e Dosimetria pela CNEN (2003) e engenheiro elétrico com especialização em eletrônica (1994). Atua como Tecnologista da CNEN e professor no programa de pós-graduação do IEN. Tem experiência em detectores de radiação, instrumentação nuclear, aceleradores cílicos e medição de escoamentos multifásicos. Possui treinamento no código MCNP6 e redes neurais artificiais.

**William Luna Salgado:** Doutor com pós-doutorado em Engenharia Nuclear pelo IEN/CNEN, doutor pela COPPE/UFRJ (2021), mestre em Ciência e Tecnologia Nucleares pelo IEN (2018) e mestre em Proteção Radiológica pelo IRD/CNEN (2019). É graduado em Física e cursa Engenharia Nuclear na UFRJ. Atua em modelagem matemática de transporte de radiação, transporte de fluidos, inteligência artificial e uso de radiação gama e nêutrons.

**Roos Sophia de Freitas Dam:** Doutora em Engenharia Nuclear pela COPPE/UFRJ (2024), mestre em Ciência e Tecnologia Nucleares pelo IEN (2018) e bacharela em Física pela UERJ (2015). Atua como bolsista de capacitação no IEN, com pesquisa em modelagem de transporte de radiação, espectrometria gama, fluxos multifásicos e redes neurais profundas. Possui experiência com Monte Carlo, proteção radiológica.

**Claudio de Carvalho Conti:** Doutor em Engenharia Nuclear pela UFRJ (1999), pós-doutorado em Física pela UERJ, mestre em Engenharia Nuclear pelo IME (1995). Atuou na AIEA/ONU como Inspetor de Salvaguardas e no IRD/CNEN como Tecnologista Sênior e professor de Instrumentação Nuclear e Monte Carlo. Especialista em proteção radiológica, Monte Carlo, calibração de detectores para geometrias não convencionais e rastreamento radiométrico.



# APLICAÇÃO DE **TÉCNICA NUCLEAR** E REDE NEURAL ARTIFICIAL NA INDÚSTRIA PETROLÍFERA

*Estudos de casos*

- 🌐 [www.atenaeditora.com.br](http://www.atenaeditora.com.br)
- ✉️ [contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)
- ⌚ [@atenaeditora](https://www.instagram.com/atenaeditora)
- FACEBOOK [www.facebook.com/atenaeditora.com.br](https://www.facebook.com/atenaeditora.com.br)



# APLICAÇÃO DE **TÉCNICA NUCLEAR** E REDE NEURAL ARTIFICIAL NA INDÚSTRIA PETROLÍFERA

*Estudos de casos*

- 🌐 [www.atenaeditora.com.br](http://www.atenaeditora.com.br)
  - ✉️ [contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)
  - ⌚ [@atenaeditora](https://www.instagram.com/atenaeditora)
  - FACEBOOK [www.facebook.com/atenaeditora.com.br](https://www.facebook.com/atenaeditora.com.br)
- 