

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 ^[1] e ópticos ^[2]. Entre as técnicas nucleares, dispositivos que utilizam radiação, como raios X ^[3] e gama ^[4], 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 predições 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.¹ 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}Am e ^{137}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}Am , e de 661,66 keV, correspondentes ao ^{137}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.

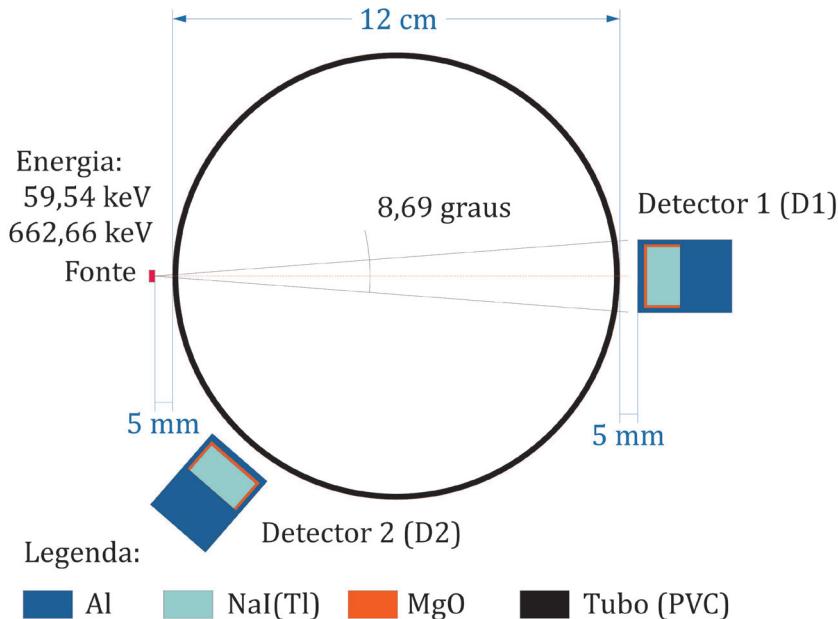


Figura 19 – Geometria do sistema de medição.

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 (CH_4), enquanto o óleo foi considerado como o hidrocarboneto C_5H_{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.

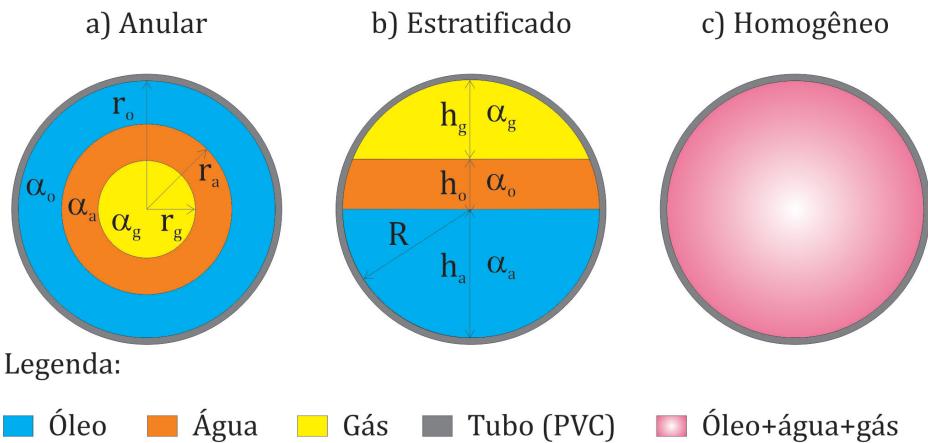


Figura 20 – Modelos de regime de fluxo: a) anular; b) estratificado; c) homogêneo.

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:

α_f – Fração do volume do fluido: g = gás, e α = 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 ⁻³)	Material	Fração mássica e Densidade (g.cm ⁻³)
Água salgada (4%) (H ₂ 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 ₅ H ₁₀	C: 0,856285 H: 0,143715	0,896	MgO O: 0,396964 Mg: 0,603036
Sulfato de Bário (BaSO ₄)	Ba: 0,588420 O: 0,137368 S: 0,137368	4,5	Carbonato de Cálcio (CaCO ₃) C: 0,120003 Ca: 0,400443 O: 0,479554
Gás Metano (CH ₄)	H: 0,251318 C: 0,748682	6,67×10 ⁻⁴	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 ₁₄ H ₃₀ H: 0,160000 C: 0,840000
Óleo	C: 0,853733 H: 0,104039 S: 0,042228	0,973	Glicerina (C ₃ H ₈ O ₃) H: 0,087554 C: 0,391262 O: 0,521185
Gasolina C ₈ H ₁₈	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 (S₃, S₂

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.

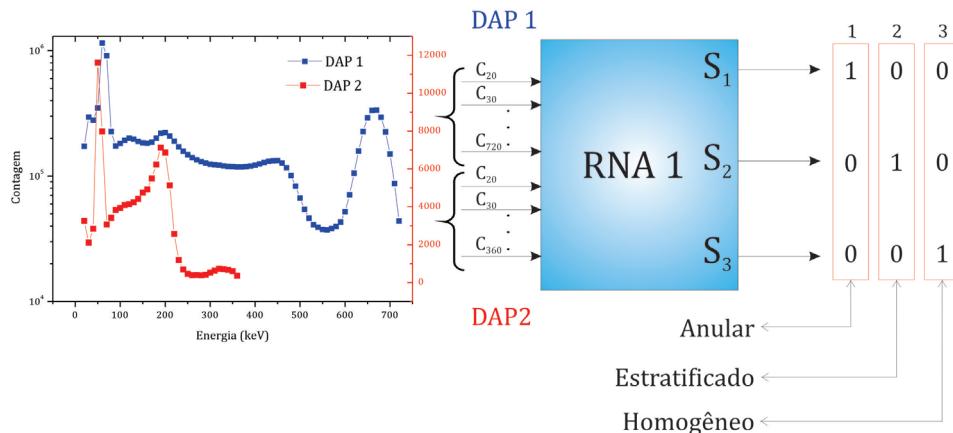


Figura 21 – Representação esquemática do treinamento da RNA.

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, α_g , α_a e α_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.

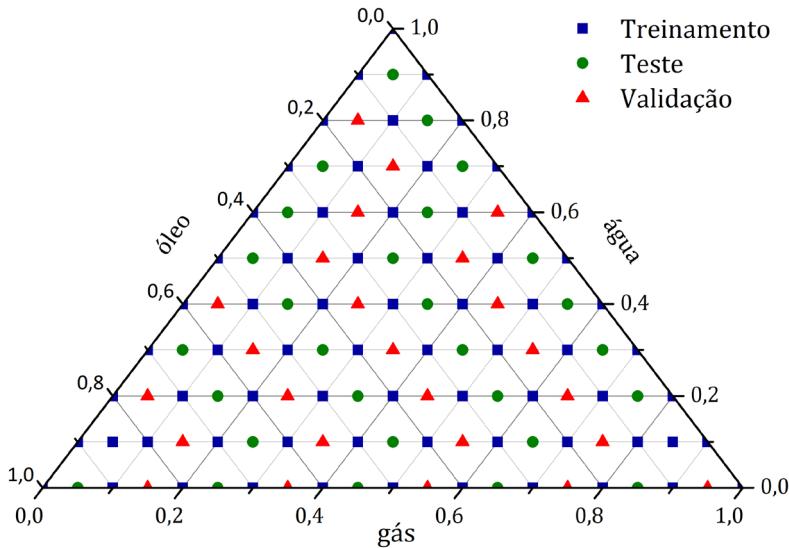


Figura 22 – Subconjuntos de Treinamento, Teste e Validação.

Assim, gerou-se um conjunto de 363 simulações (121×3) 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):

- DAP1:² 20-720³ 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.

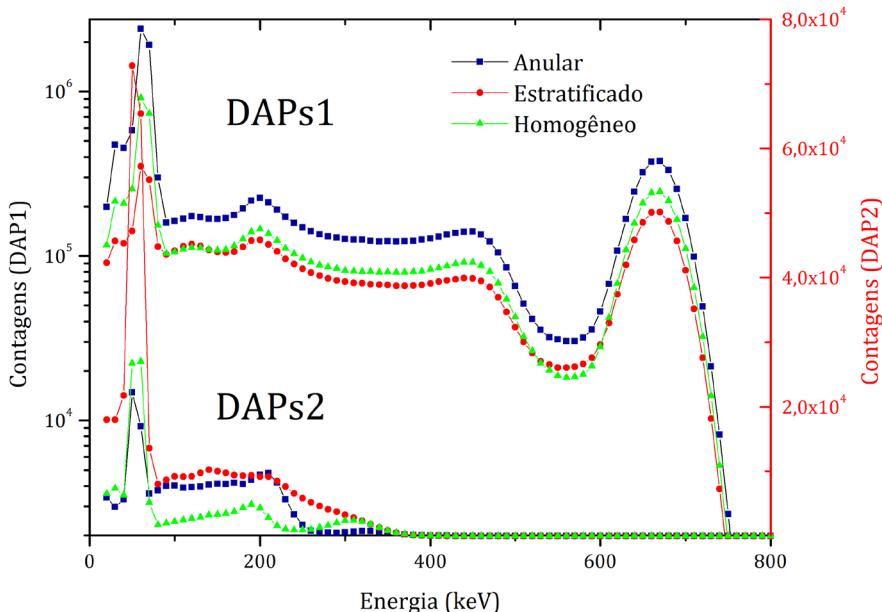


Figura 23 – DAPs obtidas pelo código MCNP6 para diferentes regimes de fluxo com frações de volume de 30% de gás, 20% de água e 50% de óleo.

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.

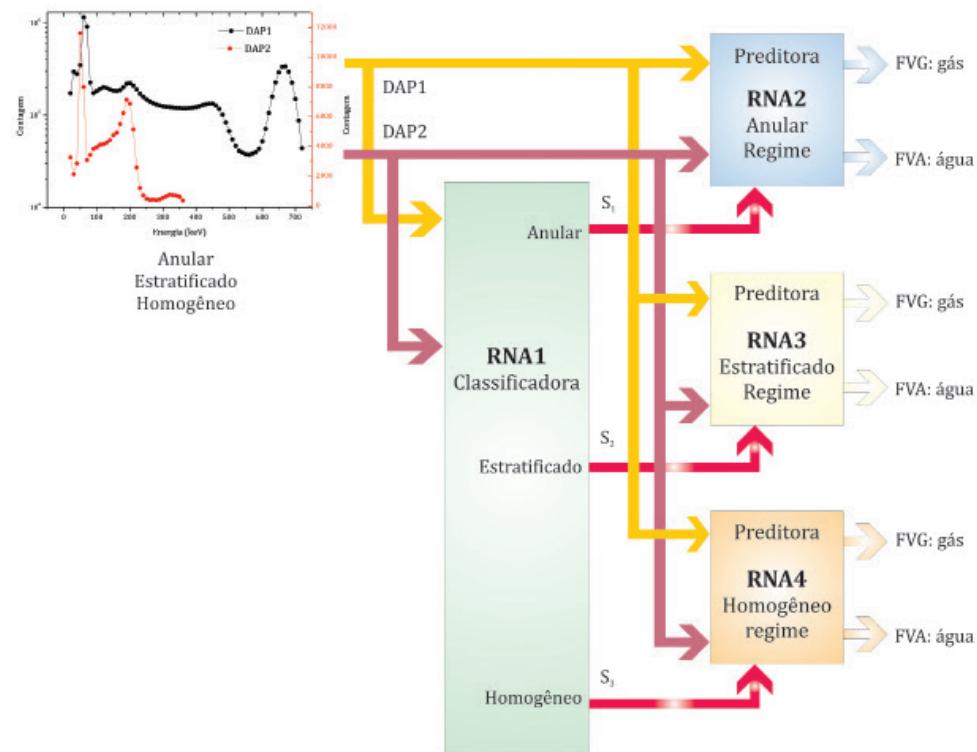


Figura 24 – Diagrama do sistema inteligente para identificação de regime de fluxo e predição das frações de volume.

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 prever 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.

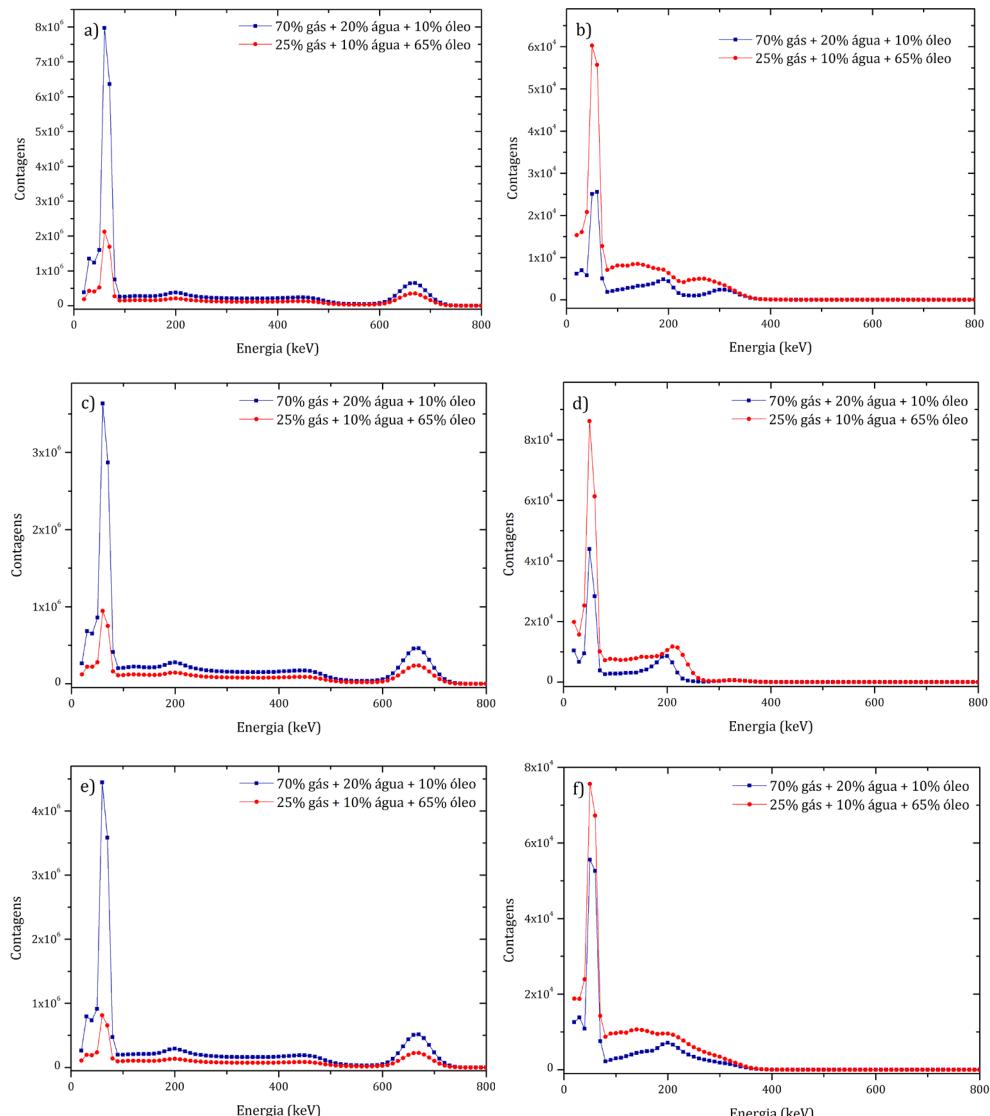


Figura 25 – DAPs obtidas pelo código MCNP6 para os regimes: anular: a) D1 e b) D2; estratificado: c) D1 e d) D2; homogêneo: e) D1 e f) D2.

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

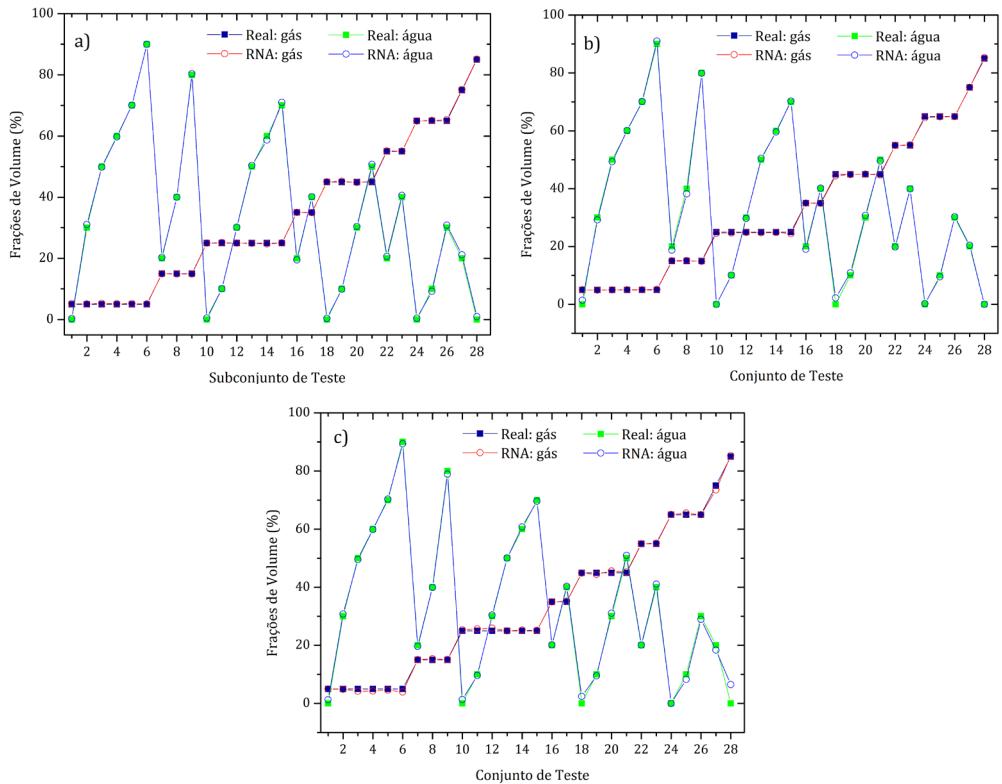


Figura 26 – Resultados obtidos para o subconjunto Teste nos regimes: a) anular; b) estratificado; c) homogêneo.

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		Erro Relativo ⁴ (%)	
	(Todos os padrões)	gás	(Subconjunto VAL)	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⁻³. 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_α e r_θ (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.

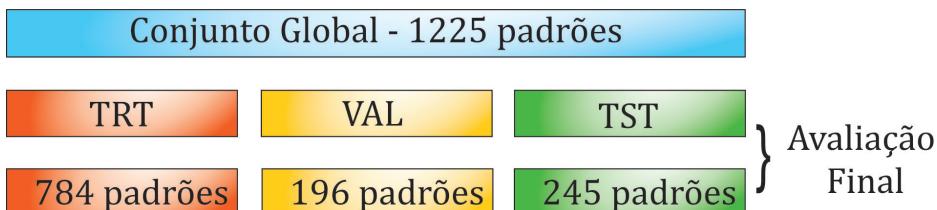


Figura 27 – Validação cruzada utilizada nesta investigação.

- 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,⁵ 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.

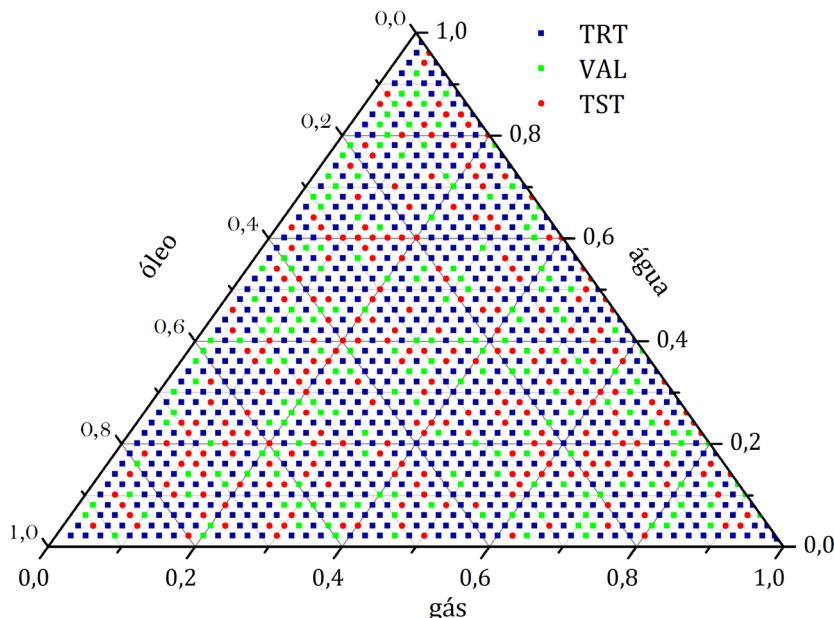


Figura 28 – Diagrama ternário representando os subconjuntos de Treinamento, Validação e Teste selecionados aleatoriamente.

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.

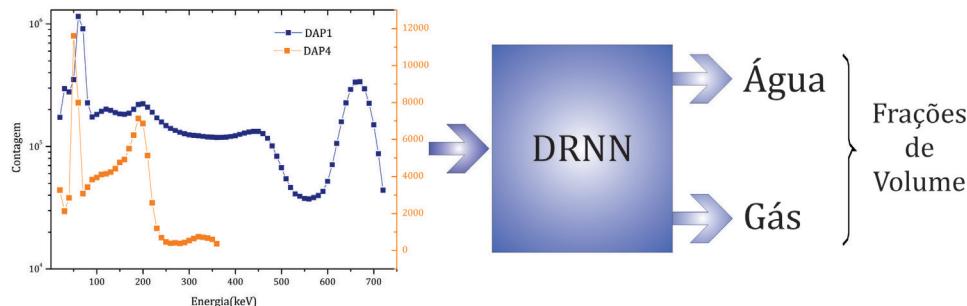


Figura 29 – Representação esquemática da DNN projetada para o treinamento.

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 comparam 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.

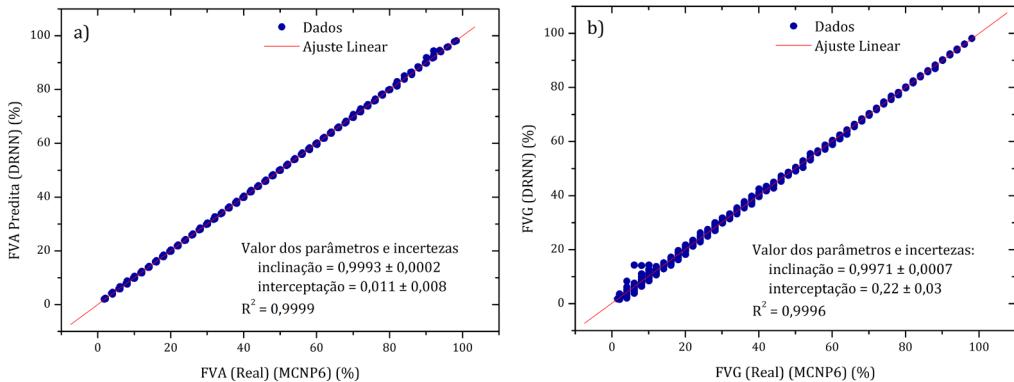


Figura 30 – Diagrama de regressão dos resultados simulados e preditos pela DNN para o subconjunto de Teste considerando a fração volumétrica de: a) gás; b) água.

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.

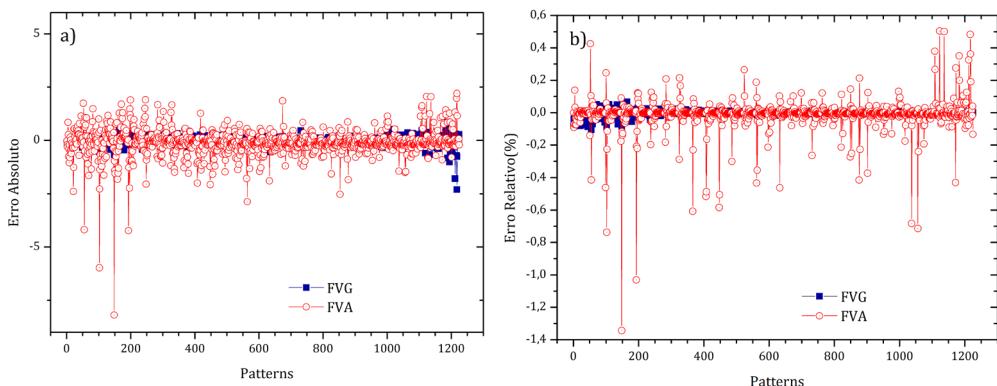


Figura 31 – Métricas de avaliação da predição da rede DNN: a) EA; b) ER.

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*.

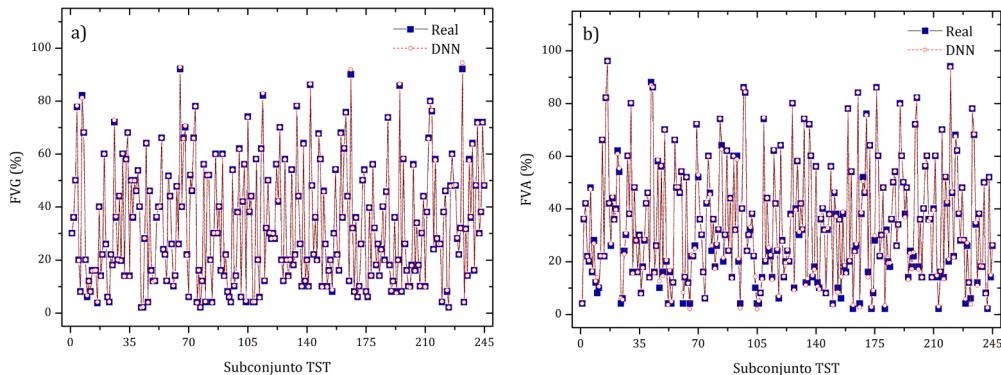


Figura 32 – Desempenho da rede neural DNN para subconjunto de Teste: a) gás; b) água.

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*⁶ [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: 5th 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.