

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),¹ podem ocorrer interações químicas que resultam na deposição de materiais inorgânicos nas paredes do tubo, formando a incrustação^[1].

Apresentando o processo de forma mais detalhada, a água do mar possui uma alta concentração de íons sulfato (SO_4^{2-}). Quando injetada na rocha do poço de petróleo, ela interage com cátions divalentes, como Ba^{2+} , Ca^{2+} , Mg^{2+} e 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 (BaSO_4), sulfato de cálcio (CaSO_4) e sulfato de estrôncio (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,² 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}Ir . A geometria desenvolvida com o MCNP6 leva em consideração diferentes espessuras e posições relativas das incrustações excêntricas de sulfato de bário (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}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 $8,21^\circ$, 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.

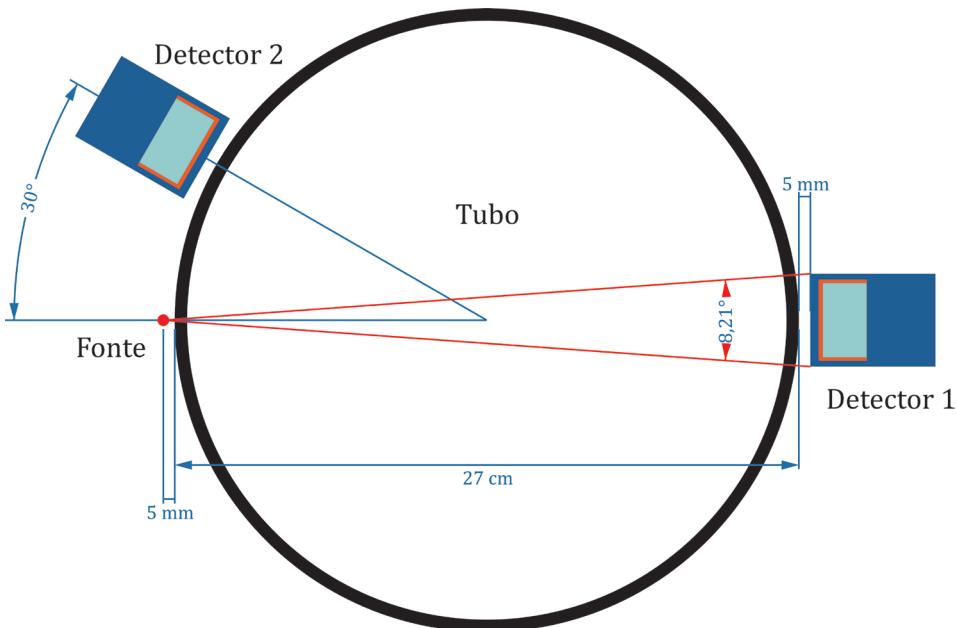


Figura 37 – Geometria de medição simulada no código MCNP6.

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; α para água e σ para óleo; fração volumétrica " α_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.

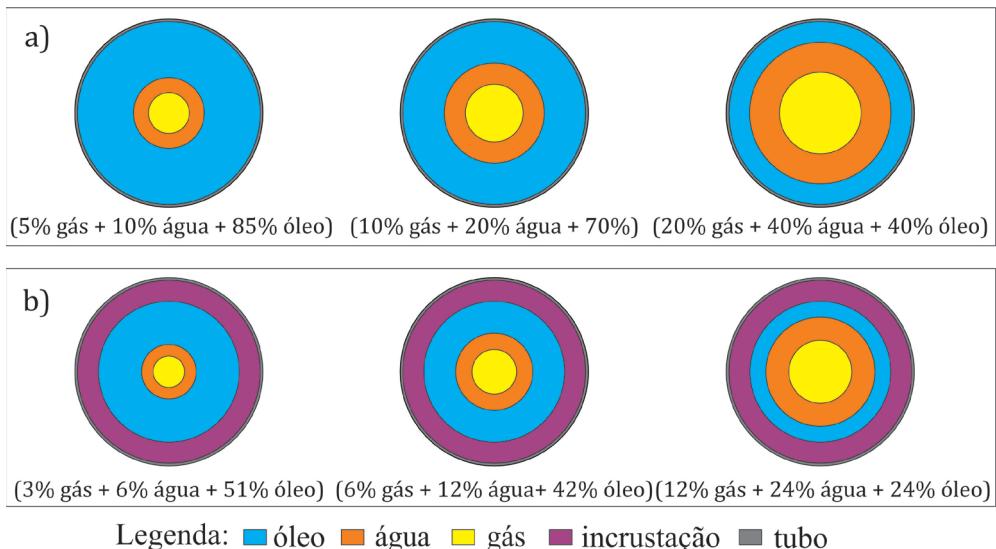


Figura 38 – Modelos estáticos desenvolvidos no código MCNP6 para o regime anular: a) Sem incrustação; b) Com espessura de incrustação de 3,0 cm.

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 ($\text{y.cm}^{-2}.\text{s}^{-1}$);

α_m – Fração de volume do fluido m ;

μ_{ij} – Coeficiente de absorção linear(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 (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 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.

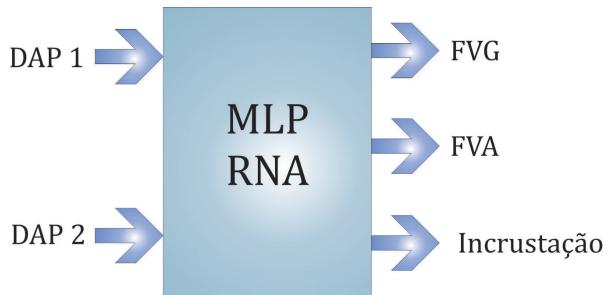


Figura 39 – Estrutura da RNA MLP desenvolvida.

RESULTADOS E DISCUSSÃO

Frações de Volume usando Equações Analíticas

Antes da implementação da geometria proposta utilizando uma fonte de ^{192}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}Am) e 661,66 keV (^{137}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].

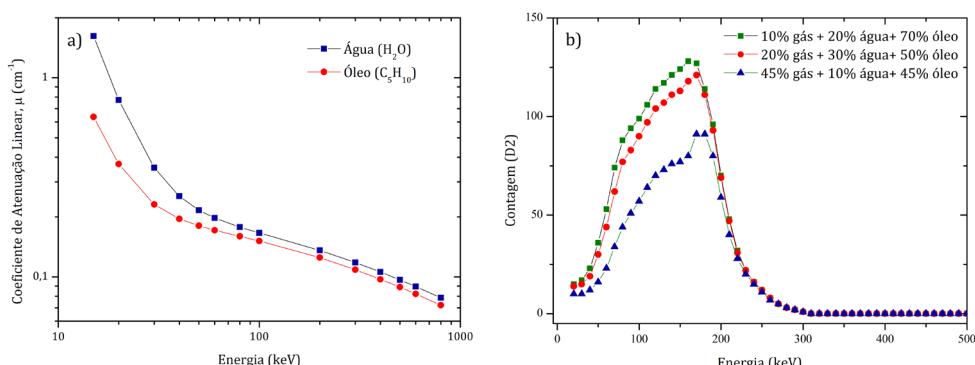


Figura 40 – Coeficientes de atenuação linear total: a) água e óleo; b) comparação entre resultados obtidos no MCNP6 e dados da literatura para água salgada.

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.

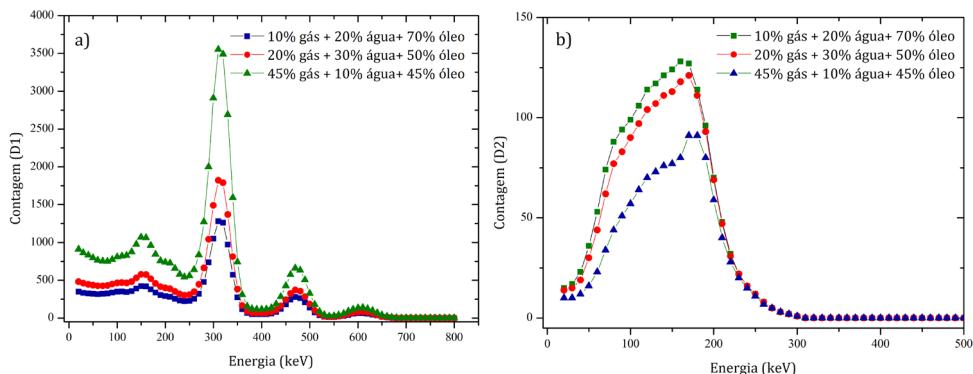


Figura 41– Espectros obtidos nos dois detectores para diferentes frações volumétricas de fluido sem incrustação: a) D1; b) D2.

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.

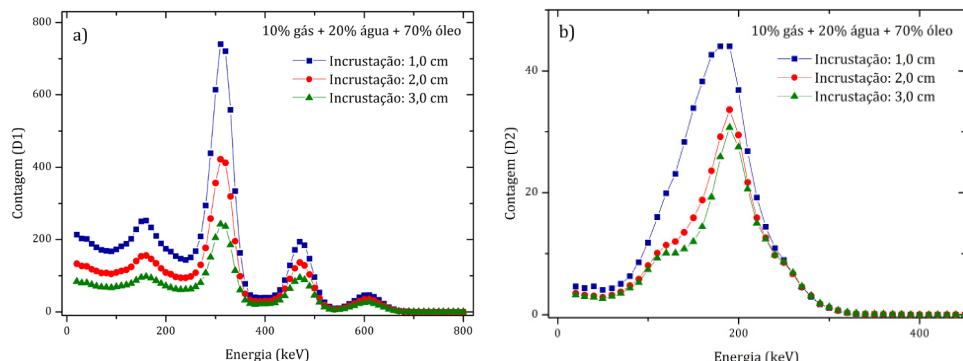


Figura 42 – Espectros para diferentes espessuras de incrustação registrados nos detectores: a) D1; b) D2.

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).

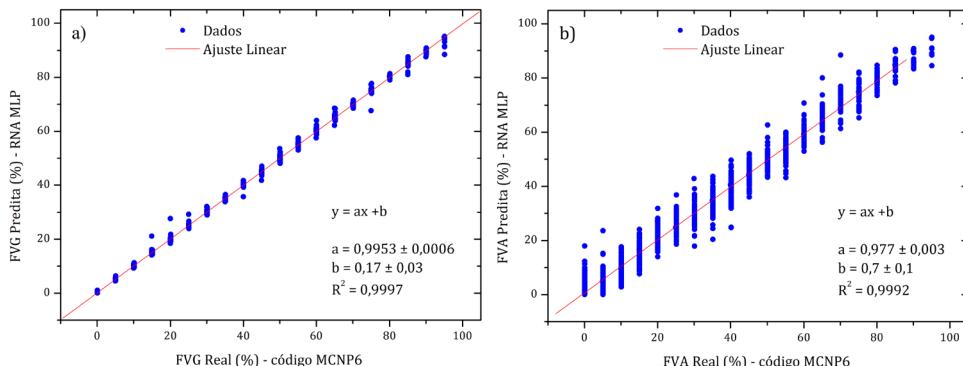


Figura 43 – Comparação dos resultados obtidos no treinamento da rede e pelo código MCNP6 para os fluidos: a) gás; b) água.

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.

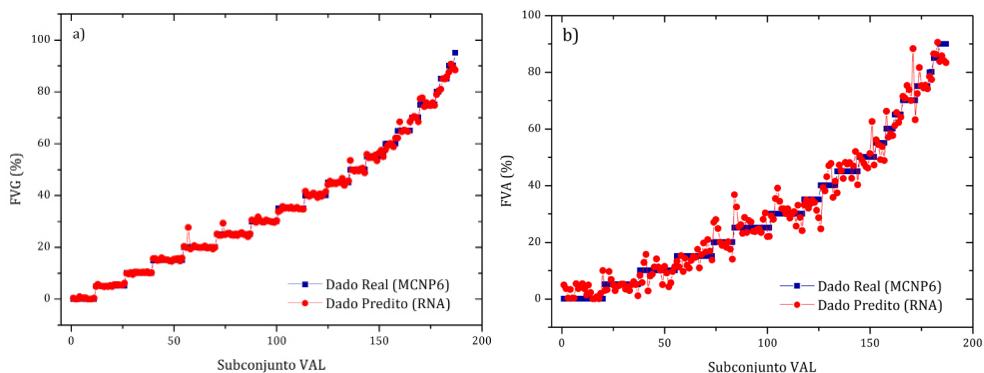


Figura 44 – Resultados da rede para o subconjunto de Validação considerando as frações de volume de: a) gás; b) água.

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.

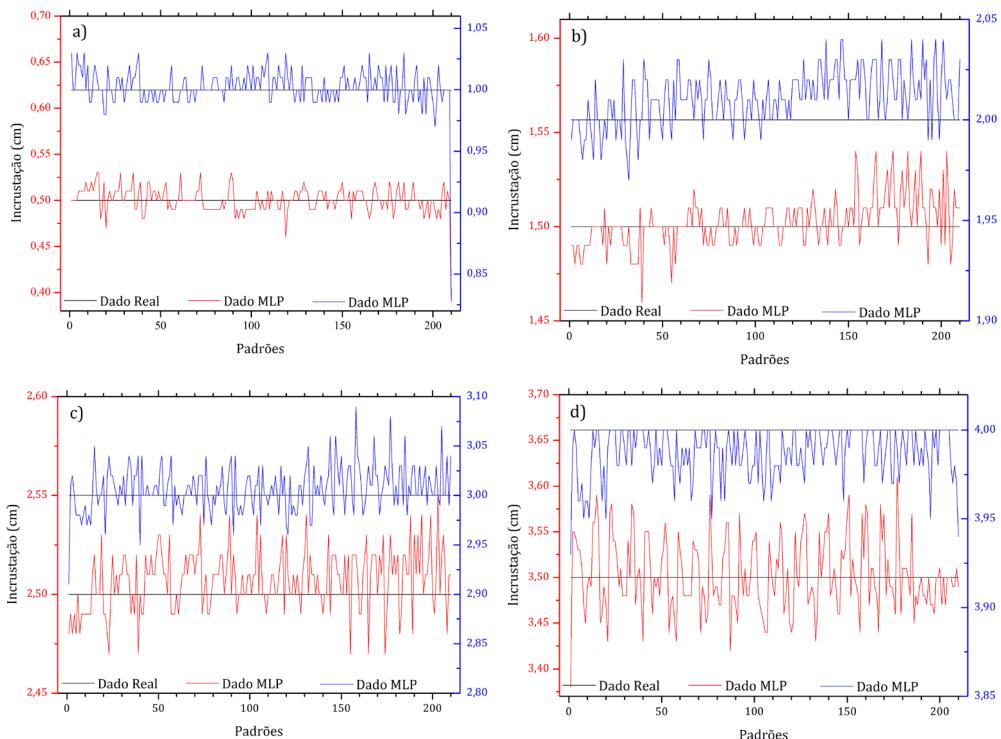


Figura 45 – Resultados de predição de espessura das incrustações: a) 0,5 cm e 1 cm; b) 1,5 cm e 2,0 cm; c) 2,5 cm e 3,0 cm; d) 3,5 cm e 4,0 cm. Os gráficos azuis utilizam a escala do eixo das ordenadas no lado direito.

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 ³	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}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 (σ) e a média (μ).

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° uns dos outros ao redor de um tubo de aço inoxidável. Uma fonte puntiforme de ^{137}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° e 15°) para o fluxo de fótons foram analisados., utilizando os cartões SI, SP e SB disponíveis no MCNP6. As DAPs registradas pelos detectores foram diretamente utilizadas no treinamento da RNA.

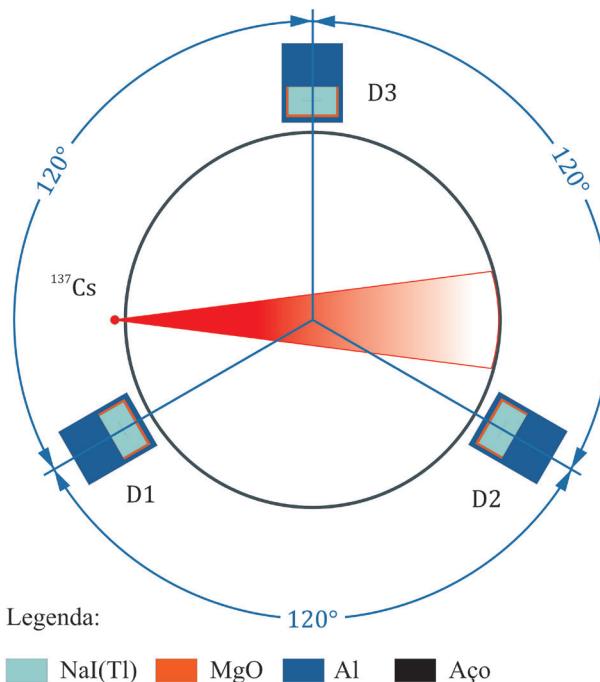


Figura 46 – Geometria de medição de incrustação.

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.

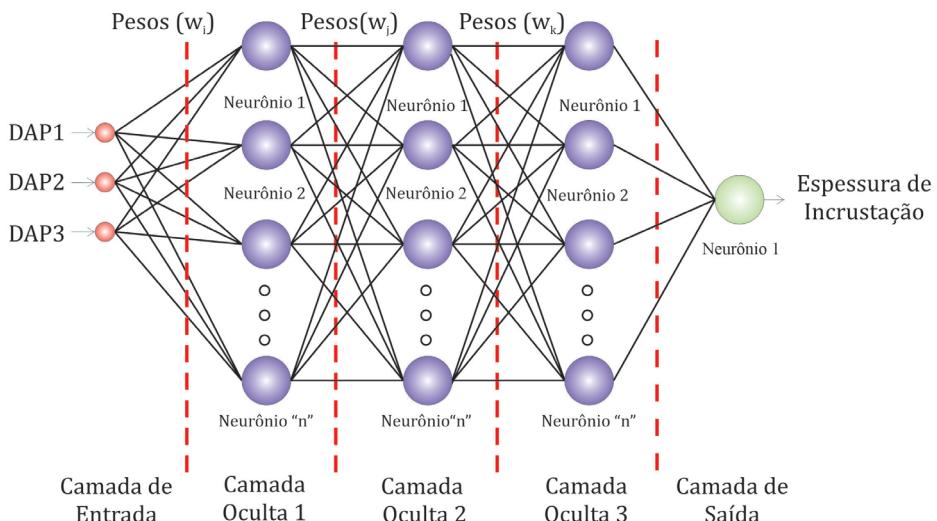


Figura 47 – Arquitetura da RNA proposta para predição de espessura de incrustação.

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.

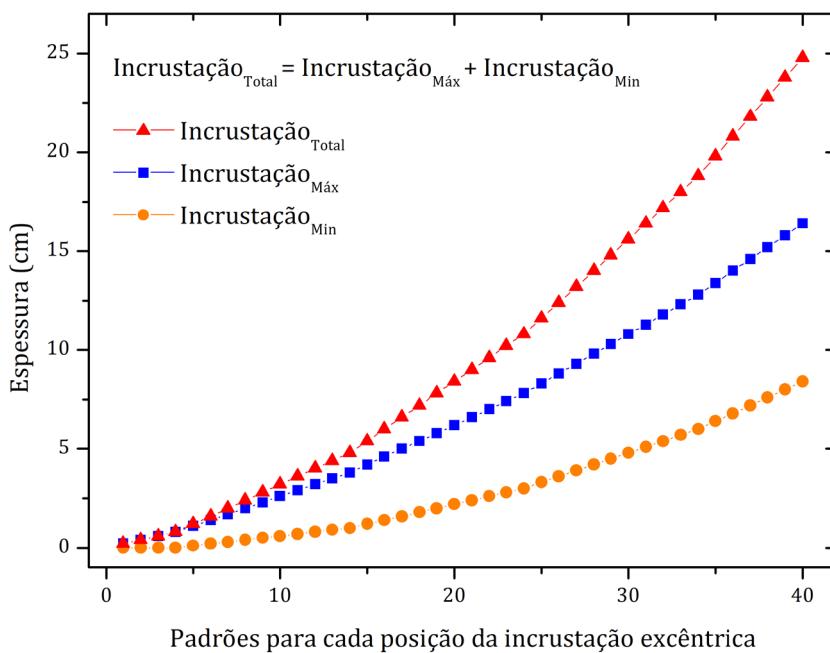


Figura 48 – Formação das posições de incrustação excêntrica.

Para melhor entendimento, os parâmetros de incrustação máxima (Incrustação_{Max}) e mínima (Incrustação_{Min}) são apresentados na Figura 49. A soma desses parâmetros define a incrustação total (Incrustação_{Total}).

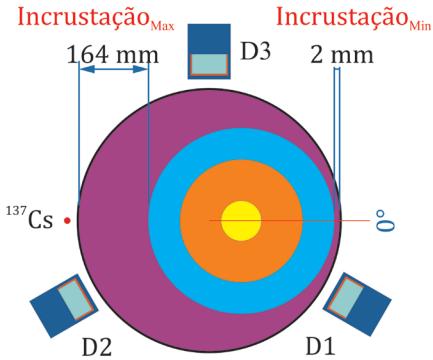


Figura 49 – Detalhes dos parâmetros de incrustação máxima e mínima.

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).

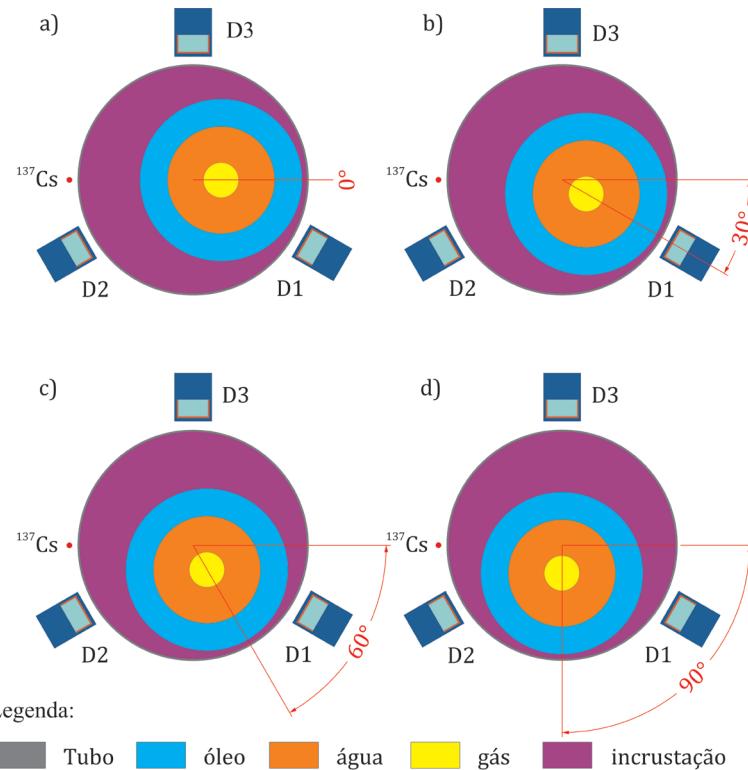


Figura 50 – Posições relativas da espessura máxima no interior do tubo: a) 0°; b) 30°; c) 60°; d) 90°.

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.

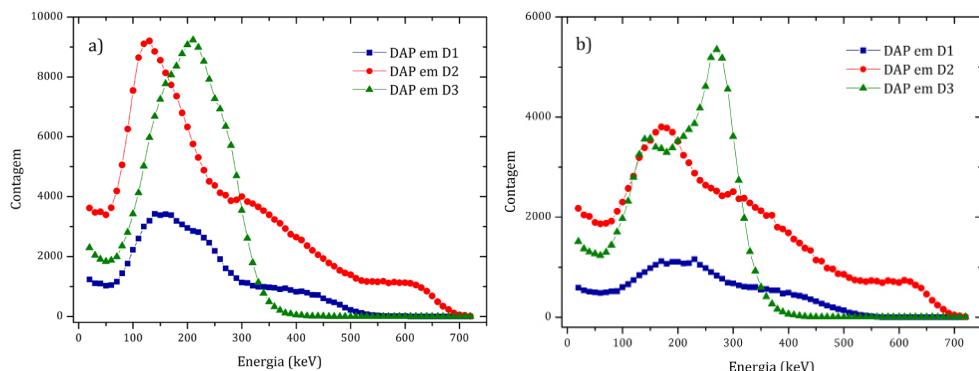


Figura 51 – DAPs registradas pelos três detectores para diferentes espessuras máximas de incrustação: a) 4 mm; b) 20 mm.

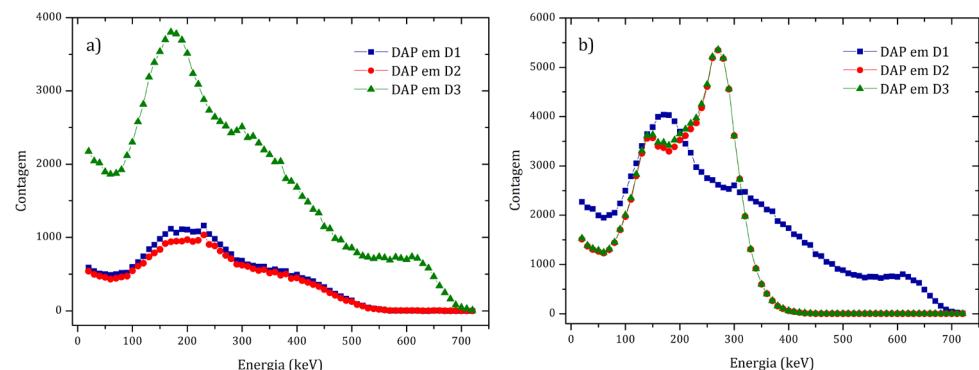


Figura 52 – DAPs registradas para diferentes posições angulares da espessura máxima: a) 0°; b) 15°.

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.

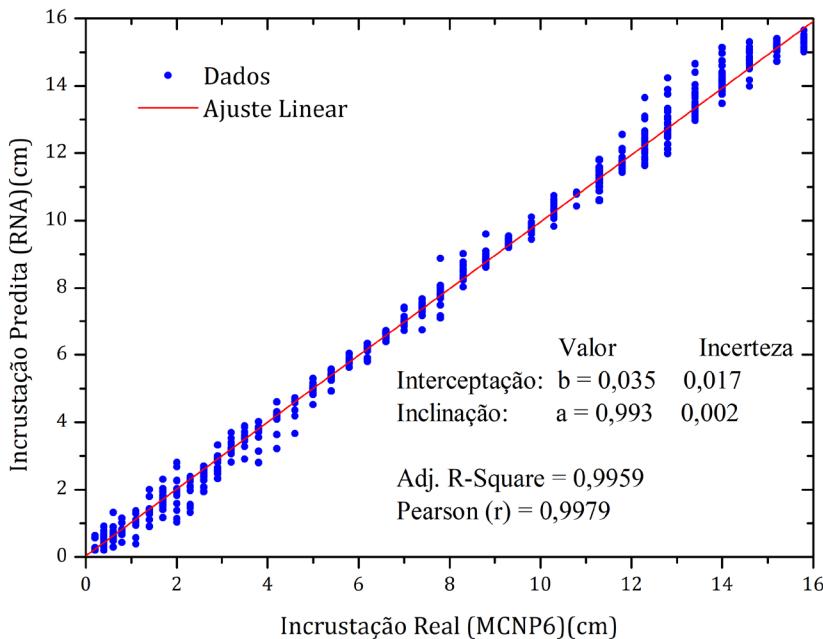


Figura 53 – Comparaçāo entre os resultados obtidos pela RNA e os simulados pelo código MCNP6.

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.

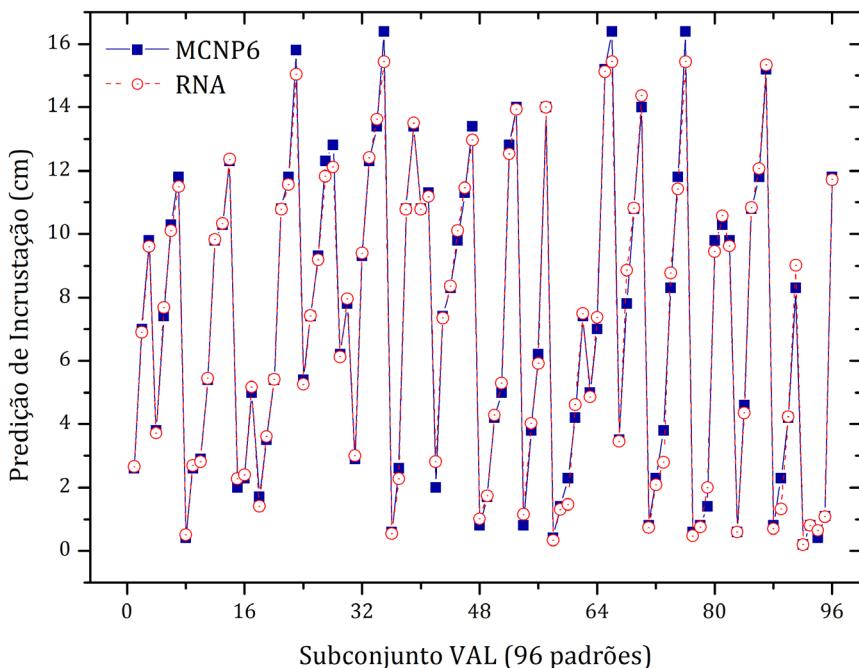


Figura 54 – Resultados obtidos pela RNA para o subconjunto de Validação.

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.