

## CAPÍTULO 6

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

---

**César Marques Salgado**

**William Luna Salgado**

**Roos Sophia de Freitas Dam**

**Claudio de Carvalho Conti**

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

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

---

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

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

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

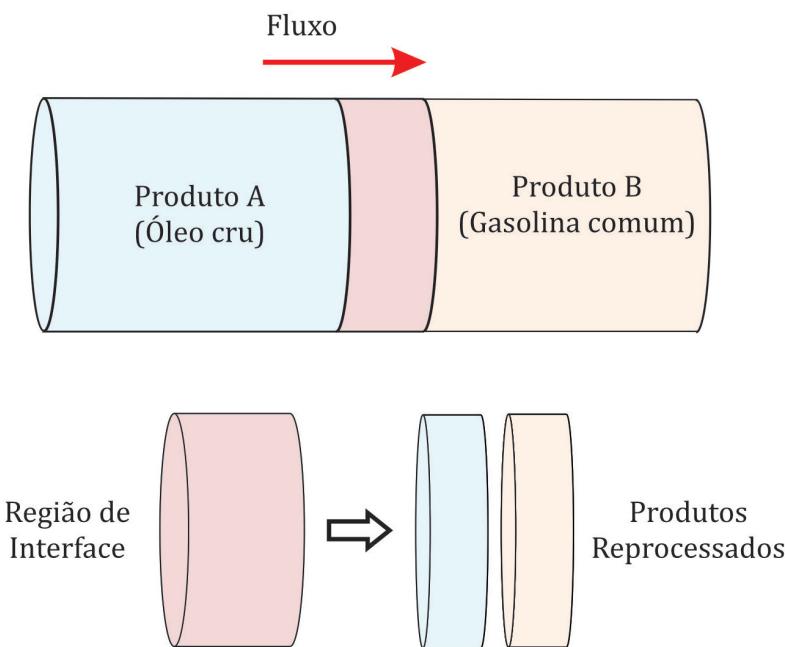


Figura 55 – Região de interface no poliduto.

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

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

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

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

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

---

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

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

## PROCEDIMENTOS ADOTADOS

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

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

### Geometria proposta do sistema de medição

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

Para a calibração, foram utilizados padrões radioativos com emissão gama no intervalo de 59,54 até 1332,49 <sup>6</sup> keV (Tabela 2). A curva de eficiência absoluta de fotópico foi determinada experimentalmente para validar a modelagem do detector<sup>[31]</sup>. Todas as medições foram realizadas com 60 minutos de duração, mantendo uma distância fonte-detector (DFD) de 28 mm. O suporte utilizado, desenvolvido em Ácido Polilático (PLA), assegurou a precisão do posicionamento axial do detector. Os parâmetros experimentais foram ajustados para minimizar o tempo morto, reduzir o Efeito Soma<sup>7</sup> e garantir que os erros associados à estatística de contagem fossem inferiores a 1%. Considerou-se também a radiação de fundo (BackGround – BG) e as múltiplas interações devido ao efeito Compton. Para determinar a resolução em energia, foi adotado o mesmo procedimento da curva de eficiência. Os picos de absorção identificados por meio do Analisador MultiCanal (AMC) permitiram calcular a largura à meia altura (FWHM) de cada fotópico, utilizando a Equação 9.

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

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

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

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

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

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

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

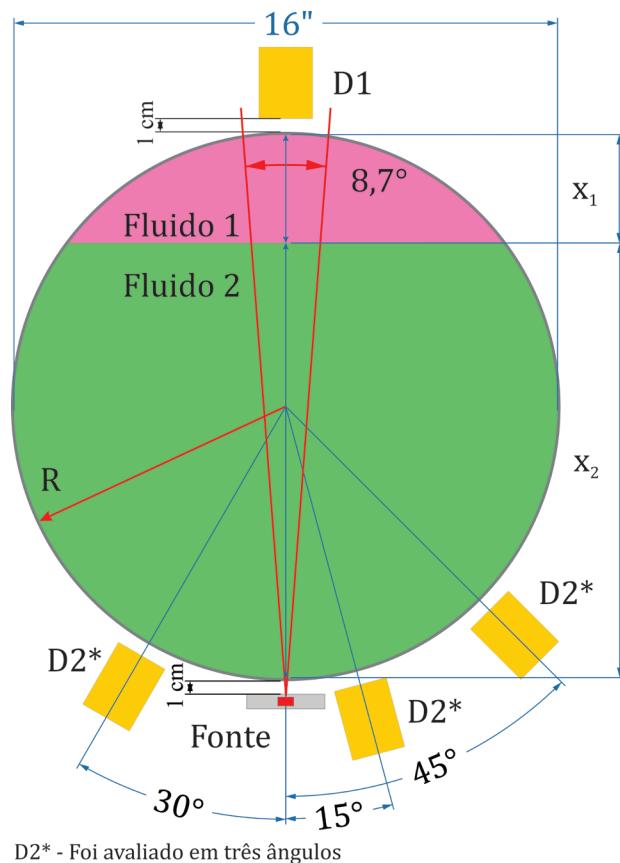


Figura 56 – Geometria de medição simulada proposta para cálculo do nível de pureza.

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

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

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

### **Predição da pureza dos fluidos por RNA**

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

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

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

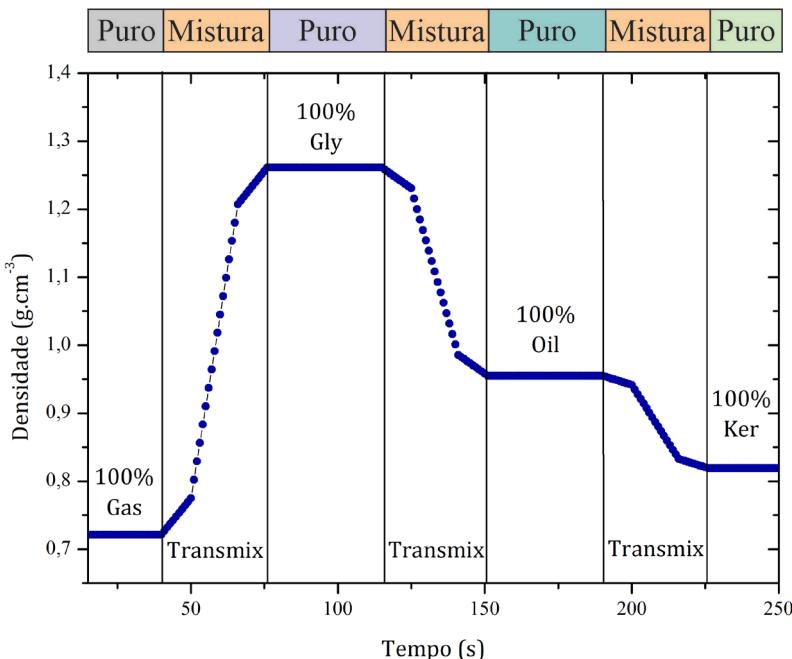


Figura 57 – Densidade de cada região de interface (transmix) simulada para os quatro fluidos.

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

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

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

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

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

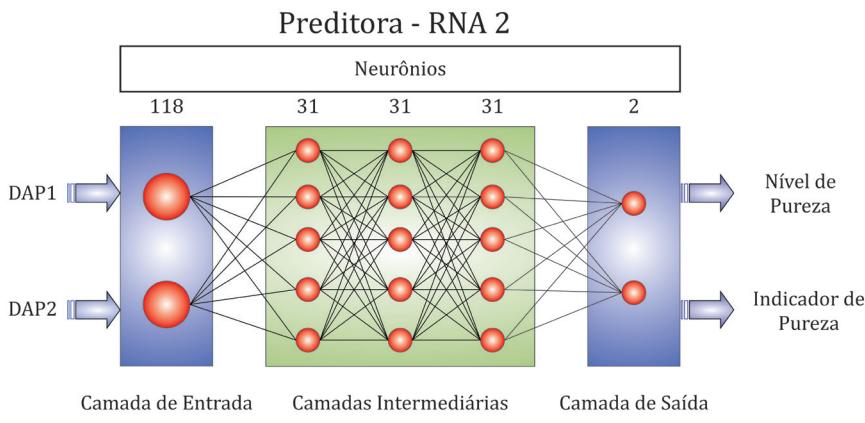


Figura 58 – Configuração da RNA desenvolvida neste estudo.

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

I. Entradas da RNA (118 neurônios):

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

II. Saídas da RNA (2 neurônios):

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

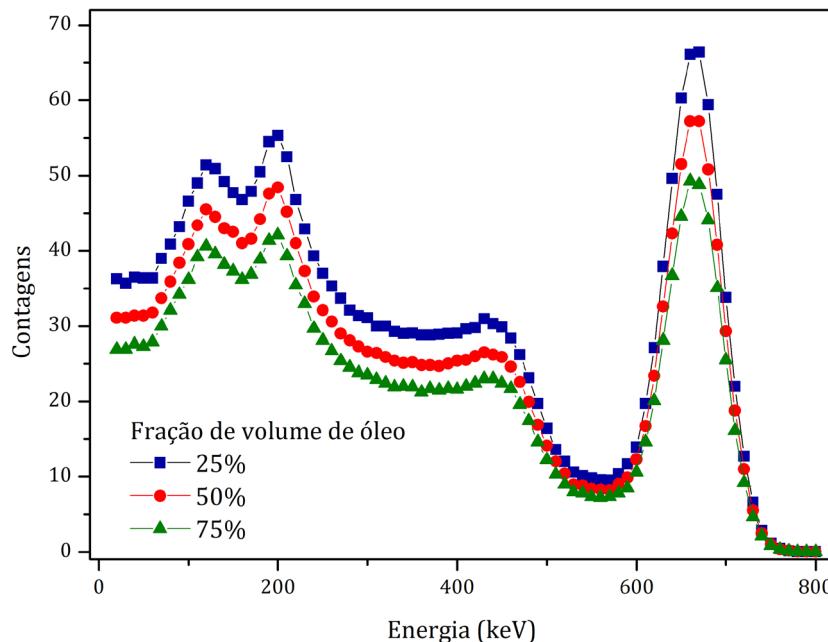
Vale ressaltar que uma única rede neural foi treinada para predizer esses parâmetros, independentemente da combinação de fluidos sendo transportada. A resposta da rede para cada subconjunto de padrões (TRT, TST e VAL) foi avaliada usando diversas métricas matemáticas, conforme descrito na Secção 2.7.2.

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

## RESULTADOS E DISCUSSÕES

### Validação teórica da geometria proposta

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



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

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

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

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

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

## Predição do Nível de Pureza

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

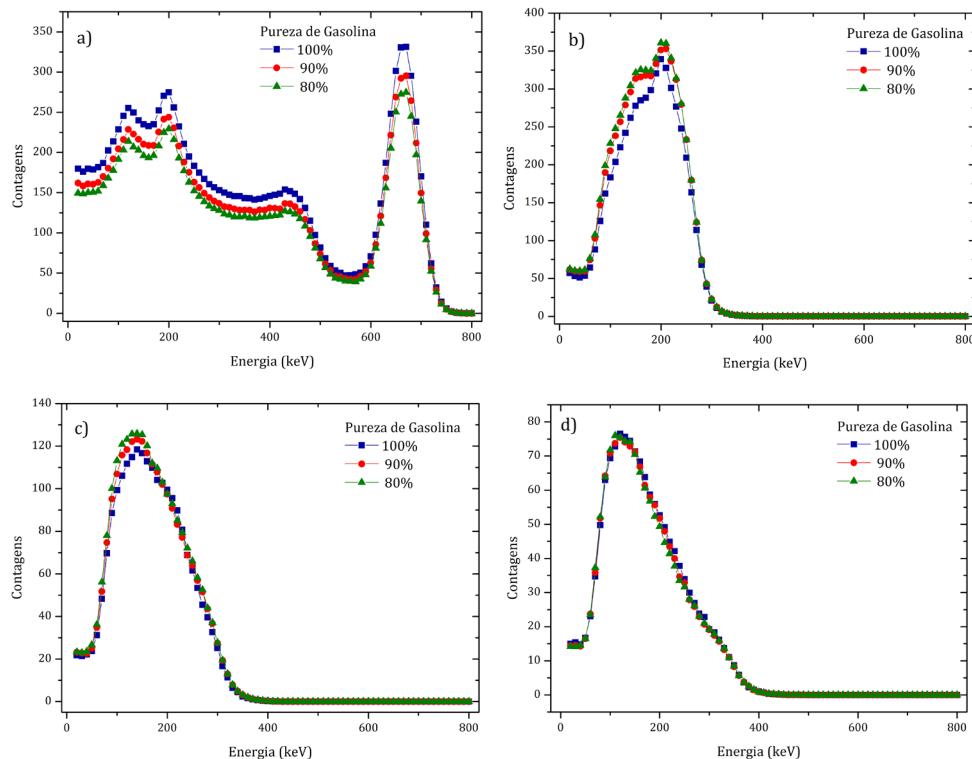


Figura 60 – DAPs obtidas pelo código MCNP6 para o detector: a) de transmissão (D1); b) de espalhamento D2 a 15°; c) D2 a 30° e d) D2 a 45°.

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

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

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

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

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

Tabela 23 – Parâmetros de treinamento da RNA

\*Função normalizadora

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

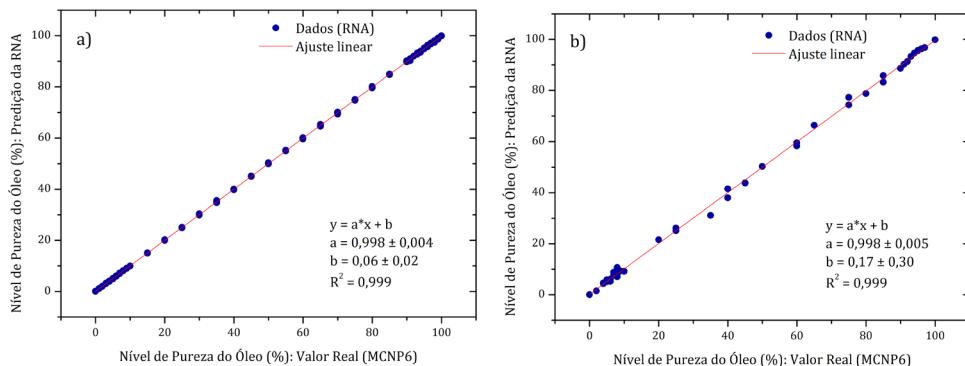


Figura 61 – Correlação entre resultados da RNA e os padrões reais, considerando os subconjuntos: a) Treinamento; b) Teste.

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

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

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

Tabela 24 – Predição da RNA para o conjunto de Validação

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

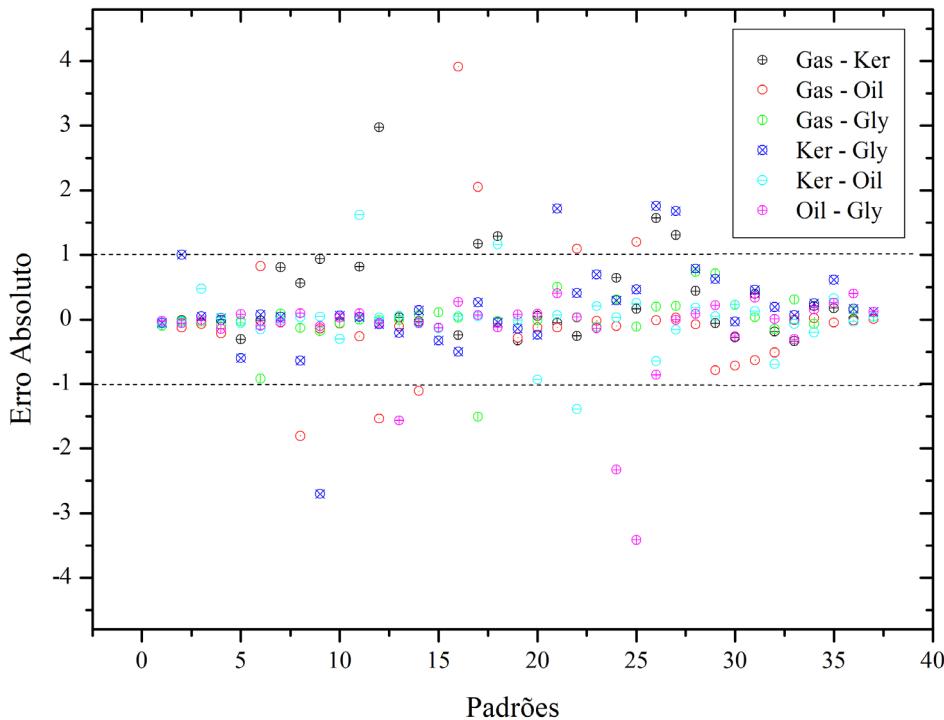


Figura 62 – Erros absolutos de todos os padrões para cada par de fluidos.

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

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

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

Tabela 25 – Análise da predição da RNA usando parâmetros estatísticos

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

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

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

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

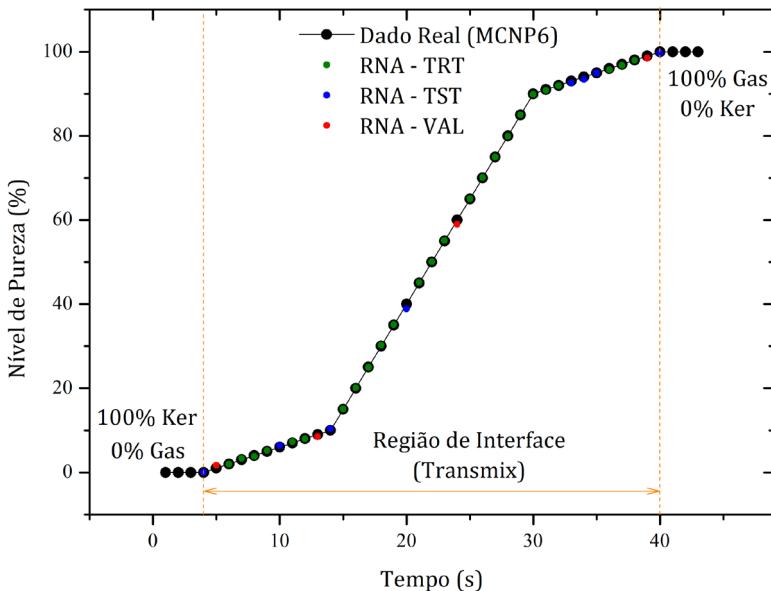


Figura 63 – Curva representativa da região de interface considerando o transporte do par gasolina e querosene.

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

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

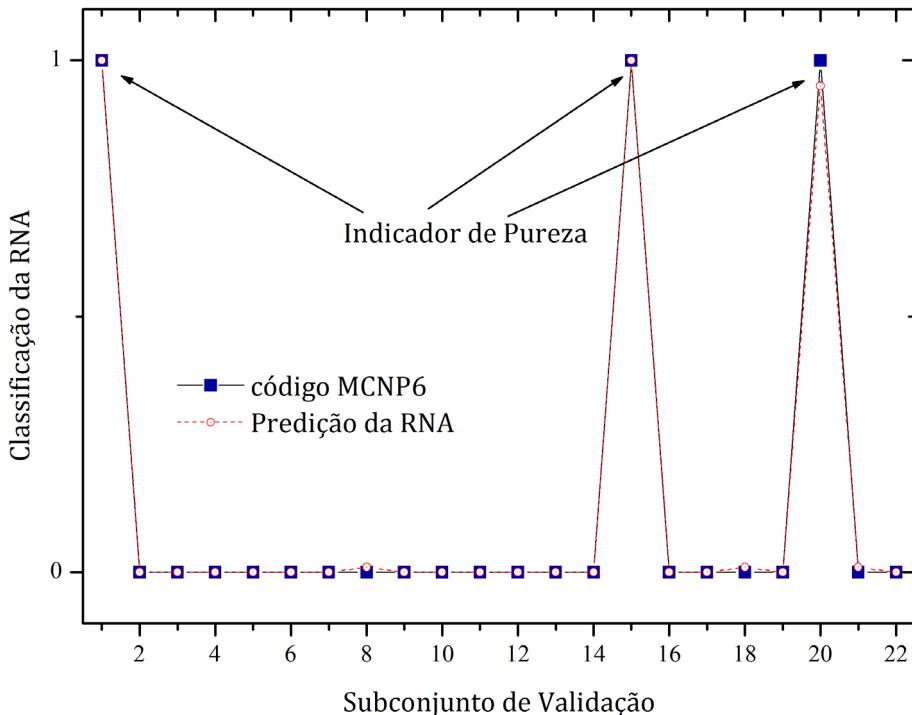


Figura 64 – Resposta do indicador de pureza da RNA para o subconjunto de Validação.

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

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

## CONCLUSÕES

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

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

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

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

## REFERÊNCIAS

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

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

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