



**PREDIÇÃO DE INCRUSTAÇÕES EM DUTOS DE ESCOAMENTO DE PETRÓLEO
UTILIZANDO TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL**

Tâmara Porfiro Teixeira

Tese de doutorado apresentada ao Programa de Pós-graduação em Engenharia Nuclear, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Nuclear.

Orientador: Ricardo Tadeu Lopes

Rio de Janeiro
Fevereiro de 2025

**PREDIÇÃO DE INCRUSTAÇÕES EM DUTOS DE ESCOAMENTO DE PETRÓLEO
UTILIZANDO TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL**

Tâmara Porfiro Teixeira

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS EM ENGENHARIA NUCLEAR.

Orientador: Ricardo Tadeu Lopes

Aprovada por: Prof. Ricardo Tadeu Lopes

Prof. Davi Ferreira de Oliveira

Prof. Atila de Paiva Teles

Prof. Alan Miranda Monteiro de Lima.

Prof. Claudio Márcio do Nascimento Abreu Pereira

RIO DE JANEIRO, RJ – BRASIL

FEVEREIRO DE 2025

Teixeira, Tâmara Porfiro

Predição de incrustações em dutos de escoamento de petróleo utilizando técnicas de inteligência artificial/Tâmara Porfiro Teixeira. – Rio de Janeiro: UFRJ/COPPE, 2025.

IX, 126 p.: il.; 29,7 cm.

Orientador: Ricardo Tadeu Lopes

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia Nuclear, 2025.

Referências Bibliográficas: p. 112-126.

1. Espectrometria gama. 2. Petróleo e gás 3. Incrustações 4. Inteligência Artificial. I. Lopes, Ricardo Tadeu. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Nuclear. III. Título.

AGRADECIMENTOS

Primeiramente, agradeço à Deus. Sem a sua infinita graça, eu nada seria e teria.

Aos meus queridos pais, Maria José e Luiz Durval (in memoriam), por todo amor, dedicação e empenho não só comigo, mas com meus irmãos. Vocês, sem dúvida, são a maior razão e motivação para a conclusão deste trabalho.

À minha companheira Amanda, por me apoiar nos momentos mais delicados e difíceis, oferecendo força, ternura e a certeza de que sou capaz de alcançar qualquer objetivo. Sua presença foi essencial nesta jornada.

Ao meu orientador, Professor (e grande mestre) Ricardo, minha imensa gratidão. Seus ensinamentos, tanto profissionais quanto pessoais, serão levados comigo. Obrigada por confiar em mim, por me mostrar que era possível, pela paciência e pela escuta ativa nos momentos mais difíceis que enfrentei durante esta tese.

Aos meus irmãos, Aline e Júnior, que mesmo distantes fisicamente, sempre me confortaram e me apoiaram. O amor que nos une perpetua o maior legado que nosso pai nos deixou.

Aos meus queridos colegas, professores e funcionários do Laboratório de Instrumentação Nuclear (LIN), que não só contribuíram tecnicamente, com discussões enriquecedoras, mas também tornaram o dia a dia do laboratório mais leve e divertido. Em especial, agradeço ao Prof. Davi, ao Prof. Edgar (in memoriam), Luan, Caio, Olga, Eduardo, Alessandra, Aline, Osmar e Renata.

Agradeço também aos funcionários do Programa de Engenharia Nuclear/COPPE pela cooperação e apoio ao longo desta trajetória.

Por fim, expresso minha gratidão ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo suporte financeiro por meio da bolsa de pesquisa concedida durante a realização desta tese.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

**PREDIÇÃO DE INCRUSTAÇÕES EM DUTOS DE ESCOAMENTO DE PETRÓLEO
UTILIZANDO TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL**

Tâmara Porfiro Teixeira

Fevereiro/2025

Orientador: Ricardo Tadeu Lopes

Programa: Engenharia Nuclear

Este trabalho descreve, analisa e propõe soluções para predição de um dos principais problemas no que tange o transporte de petróleo, a saber, a formação de incrustações inorgânicas nas tubulações e equipamentos das indústrias petrolíferas. O método elaborado para a solução deste problema tem como núcleo a utilização de modelagens computacionais e o paradigma de Rede Neurais Profundas (RNP) para predição espessuras de incrustações, sendo elas concêntricas e/ou excêntricas. O princípio baseia-se no reconhecimento das distribuições de altura de pulsos fornecidas pelos detectores cintiladores que são utilizadas para alimentar diretamente as RNP. O sistema de detecção simulado é composto por três detectores NaI(Tl) e uma energia de raios gama de feixe largo. A geometria proposta leva em consideração as contribuições de espalhamento e transmissão dos fótons, tornando o sistema menos dependente de informações internas ao duto. Os padrões necessários para a alimentação e treinamento, e posterior avaliação das RNP, foram gerados fazendo o uso do código computacional MCNPX, baseado no Método de Monte Carlo, abrangendo modelos teóricos ideais e estáticos de regime de fluxo – homogêneo e anular. As RNP foram capazes de generalizar adequadamente os dados simulados com incrustações em diferentes formações sem a necessidade de conhecimento de informações internas ao duto. Identificaram de forma consistente as espessuras com predição satisfatória, indicando a potencialidade e possibilidade de aplicação desta técnica para este propósito.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

PREDICTION OF SCALE IN OIL PIPELINES USING ARTIFICIAL
INTELLIGENCE TECHNIQUES

Tâmara Porfiro Teixeira

February/2025

Advisor: Ricardo Tadeu Lopes

Department: Nuclear Engineering

This work describes, analyzes, and proposes solutions for predicting one of the main problems concerning oil transportation, namely, the formation of inorganic deposits in pipelines and equipment in the oil industry. The method developed to solve this problem centers around the use of computational modeling and the Deep Neural Networks (DNNs) paradigm to predict deposit thicknesses, whether concentric or eccentric. The principle is based on recognizing the pulse height distributions provided by scintillator detectors, which are used to directly feed the DNNs. The simulated detection system consists of three NaI(Tl) detectors and a wide beam gamma-ray energy. The proposed geometry considers the contributions of scattering and photon transmission, making the system less dependent on internal information within the pipeline. The patterns required for the feeding and training, and subsequent evaluation of the DNNs, were generated using the MCNPX computational code, based on the Monte Carlo Method, encompassing ideal theoretical models and static flow regimes—homogeneous and annular. The DNNs were able to generalize the simulated data with deposits in different formations without the need for knowledge of internal information within the pipeline. They consistently identified thicknesses with satisfactory predictions, indicating the potential and applicability of this technique for this purpose.

SUMÁRIO

CAPÍTULO 1	1
1.Introdução	1
CAPÍTULO 2	7
2. Revisão bibliográfica	7
1.2 Objetivo	16
1.3 Relevância e Originalidade.....	17
CAPÍTULO II.....	22
2 – FUNDAMENTOS TEÓRICOS.....	22
2.1 - Fundamentos da Radiação	22
2.1.1- Interação da Radiação Eletromagnética com a Matéria	22
2.1.2 Atenuação do feixe de fótons	28
2.1.3 Detecção da radiação ionizante	29
2.1.4 Detectores de NaI(Tl)	31
2.2 Fundamentos de formação da incrustação.....	33
2.3 O método de Monte Carlo e a modelagem matemática das incrustações em tubulações de petróleo.....	39
2.3.1 Código MCNP-X.....	40
2.3.2 Características dos materiais e modelagem matemática das incrustações	42
2.4 Redes Neurais Artificiais (RNAs).....	51
2.4.1 Rede Neural Perceptron Multicamadas (MLP).....	53
2.4.2 Rede Neural Profunda (DNN)	56
2.4.3 A questão do desaparecimento do gradiente e as Redes Neurais Profundas Retificadas (DRNN).....	57
2.5 Caracterização Química de amostras de incrustações	60
2.5.1 Espectrometria da Fluorescência de Raios X.....	61
2.5.2 Difratometria de Raios X.....	64

CAPÍTULO III	67
3- MATERIAIS E MÉTODOS.....	67
3.1 Etapas preliminares para a determinação das espessuras das incrustações.....	67
3.2 Modelos simulados simplificados e validação matemática	68
3.3 RNA na predição das espessuras de incrustações.....	70
3.3.1 Modelo 1 – Predição da espessura da incrustação com conhecimento prévio do tipo de deposição (concêntrica ou excêntrica).....	73
3.2.2 Modelo 2 – Predição da espessura de incrustações excêntricas	73
3.3 Predição das espessuras de incrustação usando DNN.....	78
3.3.1 O modelo DRNN	78
3.3.2 Dados simulados e treinamento/teste da DRNN	78
3.3.3 Projeto da DRNN.....	79
3.4 Caracterização das amostras de incrustação de um duto de petróleo descomissionado.....	81
3.4.1 Coleta e preparo das amostras	82
3.4.1.1 Fluorescência de Raios X	82
3.4.1.2 Difração de Raios X.....	84
3.5 Predição da incrustação independentemente do tipo de deposição	86
3.5.1 Geração dos modelos aleatórios para o MCNPX com Python	86
3.5.2 Mudança na geometria de medição – Novos ângulos de espalhamento Compton	87
3.5.3 A DRNN implementada e dados de treinamento e teste aplicados	89
3.5.4 Projeto da DRNN.....	90
CAPÍTULO IV.....	92
4- RESULTADOS.....	92
4.1 Validação do modelo matemático por meio de equações analíticas.....	92
4.2 Predição das espessuras de incrustações concêntricas e excêntricas	94

4.2.1 Modelo 1 – Predição da espessura de incrustação dependente da informação de localização da máxima incrustação (Modelo 1).	94
4.2.2 Modelo 2 – Predição da espessura de incrustação excêntrica (Modelo 2).....	96
4.3 Predição das espessuras de incrustação máximas por DRNN.....	98
4.4 Caracterização das amostras de incrustação	102
4.4.1 Caracterização das amostras por Fluorescência de raios X (FRX)	102
4.4.2 Caracterização das amostras por Difração de raios X (DRX)	104
4.5 Determinação das espessuras das incrustações independente de sua posição dentro do tubo.	107
CAPÍTULO V	110
5- CONCLUSÕES	110
REFERÊNCIAS BIBLIOGRÁFICAS	112

CAPÍTULO 1

1. Introdução

Na indústria do petróleo, o estudo de incrustações é de grande interesse em tubulações e equipamentos para o processamento primário de fluidos como gás, óleo e água. Apesar da água ser o subproduto indesejado durante o processo de produção do óleo, é normalmente inevitável produzir um tamanho consideravelmente alto de água junto com o óleo (*Oddo and Thonson, 1994; Zhang et al., 2019*). A extração do petróleo, portanto, é acompanhada por este volume de água e sedimentos, misturados ao óleo, que podem formar incrustações nas paredes das tubulações (*Martin et al., 1997; Coto et al., 2008; Kan e Thomson, 2012; Yan et al., 2017*).

Visando manter as condições de pressão na rocha reservatório, necessárias para a migração e consequente retirada do petróleo dos poços, pode ser efetuada uma operação de injeção de água (geralmente utiliza-se a água do mar, devido sua maior disponibilidade e baixo custo) nas camadas inferiores da rocha, favorecendo assim a migração e coleta do petróleo de interesse para os poços. A água associada ao poço de petróleo, chamada de “água de formação”, quando misturada com a água de injeção, forma a água de produção. Essa produção de água ocorre concomitante a produção de petróleo, cuja quantidade dependerá das características geoquímicas da rocha reservatório e dos mecanismos naturais e/ou artificiais de produção. Devido à sua natureza química e geológica, a água produzida normalmente apresenta uma salinidade muito alta contendo várias espécies catiônicas e anionicas (*Zhang et al., 2019*).

Um dos mais recorrentes problemas na produção óleo relacionado à água é formação de incrustações minerais (*Mady e Kelland, 2017; Zhang et al., 2019*). Na engenharia de petróleo, essas incrustações podem aderir aos metais e em algumas superfícies dos sistemas de produção de petróleo e gás natural, causando a redução de seu diâmetro interno, consequentemente impedindo a passagem de fluidos, e exigindo ações periódicas de manutenção, causando o aumento dos custos associados a extração do petróleo (*Cowan e Weintritt, 1976; Candeias et al., 2014; Bahadori et al., 2013*).

Incrustação mineral é um sal cristalino duro precipitado de uma solução aquosa (*Khormali et al., 2018; Zhang et al., 2019*). Em campos petrolíferos, a incrustação mineral é termodinamicamente favorável quando o limite de solubilidade é excedido devido à mudanças nas condições operacionais (*Mansoori et al., 2018*), viabilizando mudanças na

temperatura e pressão, além de parâmetros químicos como pH e força iônica. Parâmetros esses importantes para o controle da formação das incrustações (*Todd et al., 1992; Graham, 2002; Bhandari et al., 2016; Bukuaghagin et al., 2016; Naseri et al., 2015*). A formação de incrustações de sulfato é geralmente comum durante a recuperação secundária (inundação) da produção. Para otimizar o processo, a água do mar (contendo íons sulfato, SO_4^{2-}) é injetada no reservatório, misturando-se aos cátions presentes na água de formação (Ba^{2+} , Ca^{2+} , Mg^{2+} e Sr^{2+}), e levando a precipitação do mineral. A diminuição significativa em parâmetros cinéticos, principalmente temperatura e pressão ocorrerá durante o fluxo dos fluidos de produção com origem na rocha reservatório até a cabeça do poço e além das instalações de processamento (*Kan e Tomson, 2012*). Essas mudanças nas condições de fluxo podem influenciar a água produzida a alcançar a supersaturação com formação de precipitado. Por consequência, o mineral formado se depositará na superfície dos ambientes circundantes, desde espaços como poros da própria rocha ou nas tubulações e equipamentos da linha de fluxo utilizados na produção (*Jordan et al., 2008; Vazquez et al., 2016*).

A Figura 1 mostra um exemplo de incrustação em uma tubulação descomissionada já usada em uma plataforma de extração de petróleo.



Figura 1 - Tubulação descomissionada com incrustação, (LIN-UFRJ)

As incrustações de sulfato mais comuns encontradas pela indústria do petróleo são sulfato de bário (BaSO_4), sulfato de estrôncio (SrSO_4) e sulfato de cálcio (CaSO_4) (*Collins and Jordan, 2001; Vazirian et al., 2016; Vazquez et al., 2016; Khormali et al., 2016; Vetter, 1976; Kelland, 2014*). O sulfato de bário (BaSO_4) é particularmente resistente

devido à sua alta resistência a tratamentos químicos e mecânicos (*Graham et al., 2004; Ferreira, 2011; Bukuaghagin et al., 2016*).

Extensos estudos visam caracterizar e identificar incrustações em oleodutos para minimizar seus impactos na produção de óleo e gás. Particularmente dignos de nota são os depósitos de sulfato de bário (*Athikson and Mecik, 1996; Chen et al, 2005; Xiaoyan et al, 2009; Candeias et al., 2014; Yi et al; 2014; Olajire, 2015; Bukuaghagin et al; 2016; Vazirian et al, 2016; Al Rawahi et al. 2017; Rostron, 2018; Kamal et al, 2018; Oliveira et al; 2019, Bjornstad e Stamatakis, 2006a; Amari e Moghadasi , 2010; Khatami et al., 2010; Oliveira et al., 2014; Bukuaghagin et al., 2016; Teixeira et al., 2018; Salgado et al., 2019, Oliveira et al., 2019, Teixeira et al., 2020*), devido à sua baixa solubilidade em água e consequente maior probabilidade de deposição em relação a outros sais (*Godoy, 2003; Araújo, 2005; Ferreira, 2011; Beserra , 2012*).

Em alguns casos extremos, a deposição pode ocasionar o bloqueio completo da tubulação e até interdição do sistema produtivo para realização de manutenção corretivas. O mineral também pode se depositar no reservatório do poço, levando a uma redução substancial na porosidade da rocha reservatório ocasionando à uma queda significativa da produtividade no campo existente (*Haghtalab et al., 2015*). Além disso, a deposição de incrustações em campos petrolíferos, especialmente em tubulações e equipamentos de produção, pode também ser formada por substâncias que interagem quimicamente com os tubos e outras substâncias estranhas, como os produtos de corrosão, soldaduras/estresse, pontos na superfície metálica ou pequenas partículas de sólidos em suspensão (*Mansoori et al., 2017; Tavares et al., 2015; Crabtree et al., 1999; Olajire, 2015*). A presença desses outros elementos “não naturais” dificulta a predição e o entendimento da deposição de incrustações (*Oliveira et al., 2019*).

À luz das ameaças associadas à formação de incrustações e sua influência negativa no processo produtivo da indústria de óleo e gás, existe a necessidade de controle e monitoramento das espessuras dessas deposições nos processos que envolvem o transporte de óleo visando a minimização das manutenções corretivas nestas instalações sem, entretanto, interromper a planta operacional.

Numerosos trabalhos descrevem métodos que envolvem o estudo da cinética química para prever a formação de incrustações. Os métodos cinéticos são baseados na previsão do índice de saturação de sulfatos dissolvidos na água de produção e no monitoramento da mudança de pH, temperatura e concentração necessária para a precipitação de incrustações minerais (*Olajire , 2015; Bukuaghagin et al., 2016*) . Por

outro lado, os métodos não cinéticos baseiam-se em mudanças físicas em alguns pontos do sistema de transporte, como monitoramento de pressão e temperatura, que indicam apenas a ocorrência do problema em estágio avançado.

No entanto, no contexto de técnicas não cinéticas/termodinâmicas, técnicas radioativas estão sendo usadas para detectar depósitos em oleodutos usando radiotraçadores (*Bjornstad e Stamatakis, 2006b*), nêutrons (*Abdul-Majid et al., 1989, 1996, 2013*), radiografia computadorizada e microfluorescência de raios-X (*Candeias et al., 2014*), microtomografia de raios-X (*Oliveira et al., 2019*) e densitometria de raios gama (*Monno, 1985; Sowerby e Rogers, 2005; Oliveira et al., 2014; Teixeira, 2017; Beserra, 2012; Teixeira et al., 2018; Salgado et al., 2019, Teixeira et al., 2020*).

A técnica de densitometria de raios gama, um dos métodos de ensaios não destrutivos, tem sido aplicada e obteve resultados satisfatórios em diversas áreas como petroquímica, indústria de petróleo e mineração. Tem sido usada para estudos de medição de fluxo (*Mi et al., 1998, 2010; Roshani et al., 2015, 2017a, 2017b, 2018*) ; para previsão de densidade (*Achmad e Hussein, 2004; Roshani et al., 2013; Salgado et al., 2016*) , para o estudo de medições de espessura (*Berman e Harris, 1954*); para analisar deposições em tubulações usadas para transporte de petróleo (*Monno, 1985; Drake e Seward, 1989; Beserra, 2012; Oliveira et al., 2014; Teixeira, 2017; Teixeira et al., 2018, Salgado et al., 2019, Teixeira et al., 2020*).

Dentre as técnicas nucleares, a densitometria de raios gama é baseada na transmissão de um feixe de raios gama para determinar a densidade específica do material e sua espessura. Um detector de radiação registra o fluxo de raios gama transmitido através da tubulação, a incrustação e o(s) fluido(s) interno(s). A medição da transmissão permite a detecção da incrustação sem interferência operacional, e tem se mostrado uma solução potencial para o controle preventivo de incrustações (*Bjørnstad e Stamatakis, 2006a; Oliveira et al., 2014; Teixeira et al., 2018, Salgado et al., 2019, Teixeira et al., 2020*). Portanto, é uma técnica não invasiva (o detector usado na aquisição gama é instalado fora do tubo e não está em contato com os fluidos) que pode, em alguns casos, detectar e quantificar incrustações com uma única geometria de medição.

Em se tratando de tipo de deposição, ou seja, das formas que o material incrustante se deposita na tubulação, pode-se ter situações onde uma única medida com a técnica de densitometria não seja suficiente para determinar a espessura da deposição. Grande parte dos estudos citados fazem uso dessa técnica e são voltados para determinação das espessuras de incrustação do tipo concêntrica. No entanto, utilizando a

mesma técnica, informações internas ao duto seriam necessárias para se obter a espessura de deposições não uniformes. Uma dessas informações seria a exata localização da concentração máxima de deposição, ou seja, região interna de maior espessura de incrustação (sob visão radial da tubulação). Somente assim, um detector e uma fonte radioativa poderiam ser ajustados de forma a abranger essa região e, por fim, realizar a predição da espessura com precisão satisfatória.

Diante desse contexto, técnicas de transmissão com o adicional de espalhamento gama foram propostas nesse trabalho, a fim de estudar diferentes angulações de concentração de material incrustante e avaliar a possibilidade de determinação de espessuras de deposição concêntricas e excêntricas, sob auxílio do Método de Monte Carlo, mais precisamente o código MCNPX, e Redes Neurais Artificiais.

O Monte Carlo eXtended N-Particle (MCNPX) é uma ferramenta computacional que simula o transporte de radiação na matéria, como nêutrons, fótons e elétrons, e é usada em situações onde medições físicas são inconvenientes, difíceis ou mesmo impossíveis.

A simulação de raios gama com código MCNPX inclui espalhamento de Rayleigh e Compton, fluorescência de raios-X, produção de pares e *bremsstrahlung* (Pelowitz, 2005) e, portanto, pode ser aplicada em estudos de radioproteção, usinas de energia nuclear, modelagem de detector de radiação, aplicações nucleares na indústria e assim por diante. Os modelos desenvolvidos para este estudo, no código MCNPX, consideram os principais efeitos da interação da radiação com a matéria e as Distribuições de Altura de Pulso (DAPs) nos detectores simulados de NaI (Tl).

Por sua vez, as técnicas de Inteligência Artificial (IA) como Redes Neurais Artificiais (RNAs), especialmente em suas variantes mais modernas de aprendizado profundo, que nos últimos anos têm se mostrado um dos métodos de IA mais eficientes para reconhecimento de padrões, e pode fornecer subsídios para a determinação de espessuras de incrustações sem, no entanto, exigir tantas informações internas a tubulação.

As RNAs podem ser descritas como modelos matemáticos originalmente inspirados no funcionamento do cérebro, que podem aprender a partir de exemplos, extraíndo conhecimento dos dados brutos por meio dos padrões neles presentes (Haykin, 1999). Devido à capacidade dos modelos de RNAs de aprender os padrões nos dados e

generalizá-los, esses modelos foram acoplados a técnicas que utilizam fontes de radiação gama para interpretar as Distribuições de Altura de Pulso (DAPs) obtidas por detector de radiação para a identificação de regimes de fluxo e previsão de frações de volume em sistemas multifásicos (Salgado et al., 2010), para prever a densidade do petróleo e derivados (Salgado et al., 2016), para prever a espessura da escala inorgânica concêntrica em oleodutos (Teixeira, 2017; Teixeira et al., 2018, Salgado et al., 2019, Teixeira et al., 2020).

Os trabalhos citados mostram que as RNAs foram capazes de alcançar resultados satisfatórios, comprovando a viabilidade do uso desse tipo de abordagem para a solução dessa classe de problema. No entanto, nessas aplicações, conjuntos de dados relativamente pequenos foram usados, com apenas cerca de 100 exemplos, para treinar e testar as RNAs. Além disso, na maior parte desses trabalhos, modelos simples de RNA foram usados, mais especificamente arquiteturas de redes neurais rasas (do inglês, *Shallow Neural Networks* - SNNs) com poucas camadas de processamento interno. Como já mostrado na literatura (Srivastava et al., 2015), esses modelos de RNA rasas tendem a apresentar capacidade de aprendizagem e generalização inferior do que os modelos de aprendizagem profunda, que são arquiteturas de redes neurais profundas (do inglês, *Deep Neural Networks* - DNNs) com múltiplas camadas de processamento interno. A capacidade superior dos modelos de *deep learning* destaca-se especialmente em problemas mais complexos, onde um grande conjunto de dados, com milhares de exemplos, é necessário para cobrir todo o espaço de busca do problema (Gheisari et., 2017).

Sendo assim, a incrustação será analisada usando padrões contendo as informações de espessura e localização radial da espessura máxima (em casos de incrustações excêntricas). As DAPs são usadas para alimentar (treinar) a DNN, que pode aprender diferentes espessuras automaticamente e, assim, prever com mais precisão as espessuras de incrustações de novos padrões. O conjunto de padrões (diferentes espessuras e localizações) usado para treinamento e avaliação da capacidade de generalização da DNN foi obtido por simulação matemática usando um código computacional Monte Carlo (Abro et al., 1999a, 1999b). Devido às dificuldades inerentes à escolha dos dados experimentais para treinar a DNN nessa fase do trabalho, o simulador de radiação baseado no método de Monte Carlo foi utilizado nesta etapa do estudo

CAPÍTULO 2

2. Revisão bibliográfica

Dentre as técnicas de detecção e inspeção que se desenvolveram nos últimos anos, as técnicas de ensaios não destrutivos apresentam um papel de destaque, pois permitem realizar inspeções no interior das estruturas sem a necessidade de invadi-las. A análise da radiação transmitida e espalhada pelo objeto de estudo, além da aliança destes com o uso de técnicas de Inteligência Artificial (IA), vêm se desenvolvendo rapidamente na área industrial, paralelamente a evolução dos sistemas utilizados para detecção, possibilitando a obtenção de ferramentas com maior precisão, eficiência e rapidez.

Henry et al. (1951) desenvolveram um método gráfico que pode ser usado para prever a tendência das águas do campo petrolífero de precipitar sulfato de cálcio sob uma variedade de condições. Aplicação está na previsão da formação de incrustações de sulfato em tratadores de aquecimento, caldeiras, poços de petróleo, sistemas de refrigeração e poço de injeção de água. O método adotado pelos autores consiste em uma ferramenta de previsão puramente mecânica e bastante simples de usar, desde que análises confiáveis das águas estejam disponíveis. A questão da aplicabilidade do método é questionável, uma vez que muitos fatores podem afetar a solubilidade de sais em salmouras, tornando o método simplificado para a abrangência de soluções químicas possíveis em ambientes petrolíferos.

Fulham e Hulbert (1975) realizaram os primeiros ensaios experimentais sobre a utilização da técnica de transmissão gama em nos segmentos industriais com aplicação na mineração e no segmento de petróleo e gás. Seu trabalho objetivou a utilização da técnica de escoamento gama para inspeção em torres de grandes dimensões. Favoreceram, portanto, com o uso dessa técnica, a redução dos custos industriais quando comparada às demais técnicas, justificando a utilização de técnicas não-destrutivas nas medições.

Drake e Seward (1989) realizaram um estudo para detecção de corrosão em dutos com revestimento por meio de fonte emissoras de raios X ou radiação gama, o detector mantinha-se fixo a um anel móvel que possibilitava a avaliação radial do sistema estudado. Este conjunto utilizado para as medições foi montado em um trilho fixado ao

tubo, que proporcionava a varredura axial. Neste sistema, o anel da engrenagem era específico para a variedade de diâmetros dos dutos utilizados nas medidas.

Ramirez e Feliciano (1992) empregaram uma metodologia para determinar a espessura média de tubos metálicos na presença de isolamentos térmicos. Este sistema desenvolvido utilizava uma fonte de Césio-137 e um detector cintilador alinhados com deslocamento linear realizando a varredura da tubulação em inspeção, apresentando os dados da varredura em forma gráfica em tempo real, com auxílio de um microcomputador. A inspeção, portanto, pode ser realizada sem a retirada do isolamento térmico e com a planta em plena operação.

Roach et al. (1994) desenvolveram um medidor de vazão multifásico de raios gama (MFM) para a predição on-line das taxas dos três componentes de vazão (óleo, água e gás) em dutos de produção de petróleo. Este sistema é baseado em dois medidores de transmissão de raios gama montados em um tubo que orienta o fluxo total do fluido multifásico. Nos testes relatados pelos autores, dois desses MFMs foram montados em um oleoduto de teste ligando o manifold de teste ao separador de teste nas instalações de processamento de óleo na Ilha de Thevenard. Um MFM foi montado na seção vertical de fluxo ascendente do tubo e o outro foi montado na seção vertical de fluxo descendente e em duas seções horizontais com diferentes condições. O MFM montado no duto vertical (fluxo ascendente) determinou as taxas de vazão em 4,0% em relação aos líquidos, 7,5% para o óleo, 4,5% para a água e 7,9% para o gás. O corte de água foi determinado em 3,6% relativo. O MFM montado no duto vertical (fluxo descendente) determinou as taxas de vazão em 3,3% em relação aos líquidos, 6,1% para o óleo, 4,5% para a água e 7,7% para o gás. O corte de água foi determinado em 3,7%.

Astuto (1995) elaborou um estudo utilizando transmissão de raios gama que utiliza uma fonte de Césio-137 e um detector de cintilação alinhados sobre uma plataforma objetivando realizar a inspeção de dutos com pequenos diâmetros e suas integridades mediante processos corrosivos. O estudo consistiu no varrimento (perfilagem) da seção transversal da tubulação por meio da movimentação linear da plataforma. Apesar da

metodologia demonstrar eficiência ao alcançar o objetivo proposto, as condições realistas para medição não foram consideradas, como, por exemplo, as diferentes possibilidades de condições de transporte de materiais em seu interior como o óleo, gás e/ou água.

Thereska (2004) apresenta uma contextualização breve comparando aplicações de radioisótopos incluindo perfilagem por transmissão gama e radiotraçadores em plantas petroquímicas e de refinarias de petróleo visando diagnosticar causas específicas de ineficiência em fábricas ou operações de processo.

Carneiro (2006) realizou um estudo de um sistema de inspeção baseado na transmissão da radiação gama para aplicação em linhas de dutos flexíveis e colunas industriais. Este sistema descrito pelo autor utiliza uma fonte de radiação gama de ^{137}Cs (662 keV) e um detector cintilador $\text{NaI}(\text{Tl})$ alinhados e eletrônica associada. Os resultados apresentados demonstram que o sistema é eficiente para realizar detecção de obstruções em dutos e na verificação de níveis de volume no interior do mesmo. Na determinação da resolução do sistema na detecção de materiais sólidos e fluidos, os resultados mostram que a identificação fica comprometida para os materiais líquidos (água ou óleo) devido a pequena diferença entre os níveis de contagens médias, 35% para esses conteúdos. A maior eficácia do sistema está na determinação da posição de bandejas e identificação de desgaste e danos internos nas colunas, com valores de desvios percentuais médios menores que 1%

Abdullah (2005) publicou a contribuição da varredura por raios gama em processos de verificação de mau funcionamento e manutenção preventiva em colunas de destilação em refinarias de petróleo. Apresentam as vantagens do sistema de perfilagem online, como o fornecimento de dados essenciais para otimizar o desempenho das colunas, rastrear os efeitos de degradação do desempenho devido a formação de incrustações e depósitos sólidos nas bandejas, além de identificar os requisitos de manutenção com antecedência em relação as mudanças programadas. Destaca ainda a necessidade de periodicamente monitorar a evolução do aumento das incrustações e que o conhecimento proporcionado pela técnica pode reduzir o tempo de parada para reparos.

Oliveira et al. (2009) aplicaram a técnica de transmissão gama para detectar incrustações em oleodutos através de um sistema composto de fonte Cs-137 e detector de cintilador $\text{NaI}(\text{Tl})$. Os resultados foram processados em uma planilha para calcular a medida da

espessura da incrustação localizada em gasodutos. A planilha realiza simulações da interação da radiação com base nos dados conhecidos como o diâmetro, espessura e composição, fornecendo valores de intensidade que são comparados com aqueles obtido experimentalmente, e assim é capaz de determinar a existência e a espessura de uma camada de incrustação. Para a validação tanto da simulação como do sistema, alguns testes de laboratório foram realizados com uma amostra de tubos contendo peças com e sem incrustação. Os resultados mostraram que, apesar das limitações, o sistema foi suficiente para detectar incrustações, com a vantagem da dose reduzida, que é de grande importância em ambientes offshore.

No que se refere à composição química e mineralógica de incrustações provenientes da indústria offshore, *Cruz (2002) e Cruz e Godoy (2003)* apresentaram estudos sobre a composição química de borras e incrustações, sendo este último abrangendo estudos de caracterização radioquímica de incrustações radioativas, as TENORM. *Sena (2008)* realizou o estudo sobre análise química de produtos de incrustações por espectrometria de fluorescência de raios X.

Candeias (2010) realizou um estudo visando inicialmente a caracterização de incrustações por meio da técnica de microfluorescência de raios X (XRF) e a quantificação destas incrustações por meio da radiografia computadorizada e transmissão gama. As amostras de incrustações foram retiradas de testemunhos de tubulações usadas na exploração marítima de petróleo da Bacia de Campos. As medidas dos perfis e imagens bidimensionais, caracterizadas pela distribuição elementar em seções das amostras, foram realizadas na linha de Fluorescência de raios X do Laboratório Nacional de Luz Síncrotron (LNLS). Para a radiografia das amostras, foi usado o sistema de radiografia computadorizada da GE, o Pegasus CR50P. Em todas as amostras de incrustações foram encontrados os elementos Estrôncio, Bário, Cálcio e Ferro.

Abdul-majid (2013) desenvolveu um estudo para a determinação de incrustações formadas por parafinas, asfaltenos (frações pesadas do petróleo) e polietileno dentro de tubulações, além da avaliação da corrosão de tubulações usadas no transporte de petróleo. Para a predição das espessuras de deposição foram utilizadas técnicas de difusão e captura de raios gama, com tempo de determinação de 2 minutos para incrustações com menos

de 1 mm de espessura. Embora os experimentos tenham sido realizados em laboratório, o sistema demonstra portabilidade para aplicações de campo.

Soares (2014) propôs um sistema de inspeção móvel, que pode ser transportado por robôs submarinos para inspecionar linhas de tubulações nas saídas dos poços de petróleo. O método de medida adotado é o de transmissão de um feixe de raios gama e baseia-se em uma única medida do coeficiente de transmissão (obtido indiretamente pela taxa de contagem média). O cálculo da espessura é obtido por meio de uma corda de arco próxima a posição em um duto, e que é comparada com um valor de referência obtido na mesma posição em duto igual ao inspecionado, livre de incrustações e preenchido com água salgada (à 4% de NaCl). O parâmetro de referência para a determinação da presença das incrustações, para qualquer tipo de material transportado (gás, água, óleo, misturas) é a razão entre as taxas de contagens médias encontradas no duto inspecionado e no duto de referência. O sistema de medida foi ajustado para realizar medidas com precisão constante de $\pm 1\%$. Nos testes realizados durante o estudo ficou demonstrado a eficácia do método proposto com os resultados obtidos com uma seção de tubo de aço carbono de 270 mm de diâmetro, retirado do campo, com incrustações excêntricas (assimétricas) de BaSO₄.

Kamari et al (2014) propuseram um modelo usando uma abordagem robusta de *soft computing*, ou seja, modelagem de máquina de vetor de suporte de mínimos quadrados (LSSVM) otimizada com a abordagem de otimização de reconhecimento simulado acoplado (CSA). Os resultados indicam que há boa concordância entre as previsões baseadas no modelo CSA-LSSVM e dados da literatura sobre o produto de solubilidade da barita em salmouras de petróleo. Além disso, o desempenho do modelo desenvolvido é comparado com o desempenho de uma rede neural artificial, correlação disponível na literatura e software padrão (OLI Scalechem) para prever a deposição de barita. O modelo ajusta-se perfeitamente aos dados da literatura com um coeficiente de correlação ao quadrado de 0,999.

Candeias et al (2014) conduziram um estudo para qualificar e quantificar os elementos presentes em amostras de incrustação usando técnicas de microfluorescência de raios X de radiação síncrotron (SR μ XRF) e radiografia computadorizada (CR). Os resultados do SR μ XRF mostraram que os elementos encontrados nas amostras em escala foram

estrôncio, bário, cálcio, cromo, enxofre e ferro e a análise de CR mostrou que a espessura da camada da incrustação foi identificada e quantificada.

Oliveira et al. (2014) utilizaram da técnica de transmissão gama para determinação das espessuras de incrustações formadas por sulfato de bário em oleodutos de petróleo. Para isso foi desenvolvido um sistema composto por uma fonte de Césio-137 e um detector de cintilação de NaI(Tl). A fonte e o detector foram posicionados para realizar as medições de transmissão gama. Foi também desenvolvida uma rotina computacional para gerar dados simulados para realizar uma comparação posterior com os dados experimentais, e por fim calcular as espessuras das incrustações. Os resultados apresentaram concordância entre os dados simulados com os experimentais, levando a concluir que o procedimento é eficiente para predição de deposições no interior de dutos e que o sistema pode apresentar vantagens para a aplicação em um processo de extração de petróleo em operação. No entanto, o tempo de obtenção e processamento dos dados é alto e, devido à baixa atividade da fonte, as aberturas dos colimadores utilizados não poderiam ser menores, caso contrário, o tempo de inspeção seria maior. Apesar disso, a medida das espessuras através do método de simulação empregado demonstrou resultados consistentes.

Paz et al. (2017) trazem uma abordagem de avaliação de parâmetros físico-químicos na predição da formação de incrustações inorgânicas. Apesar da existência de tratamentos químicos e mecânicos para combater o problema das deposições, os autores abordam as circunstâncias particulares em que as incrustações ocorrerão. Sendo assim, parâmetros relacionados à termodinâmica e cinética química são temas abordados para prever e evitar o processo de deposição de Carbonato de Cálcio, mais especificadamente. O monitoramento das deposições é baseado na avaliação do Índice de Saturação (SI) que utiliza como medida os índices de pH da solução, temperatura, concentrações de íons, entre outros parâmetros químicos/físicos. A influência que a temperatura e a concentração inicial de íons têm sobre o pH da solução do sistema de deposição foi estudada utilizando um teste experimental em um reator de lote, isto permite acompanhar o processo de deposição em tempo real através de mudanças de pH. A previsão do processo de deposição do carbonato de cálcio representa outro objetivo neste estudo. Foram utilizadas análises numéricas baseadas em inteligência artificial como *MultiLayer Perceptron* (MLP) e Rede Neural Probabilística. Um bom processo de aprendizagem e um bom

modelo de previsão para os métodos de Rede Neural Artificial (RNA) foi mostrado quando o SI experimental e o SI previsto foram comparados. Foi possível confirmar a precisão dos métodos RNA usando testes experimentais externos.

Oliveira et al. (2018) apresentaram um método experimental que objetiva caracterizar amostras de petróleo bruto através de seus perfis de espalhamento de raios X, sem a necessidade de qualquer preparação química a ser realizada com antecedência, o que permitiu que este método fosse utilizado para analisar amostras imediatamente após a sua extração. Para o experimento, um sistema portátil de espalhamento de raios-X composto por um tubo de raios X com ânodo de prata e um detector de Si-PIN foi usado para analisar amostras de óleo de diferentes poços. O processo consistiu em estabelecer uma relação linear entre os números atômicos e a razão entre as intensidades de pico de Compton e Espalhamento de Rayleigh de amostras conhecidas. A função linear, verificada experimentalmente, foi então aplicada a amostras de óleo bruto, e os resultados mostraram que é possível caracterizá-los com base no Rayleigh para razão de espalhamento Compton. Após a análise, um teste de comparação foi realizado nas amostras demonstrando que esta metodologia possibilita identificar amostras de diferentes óleos e origens, além de verificar a compatibilidade de amostras extraídas do mesmo poço.

Teixeira et al. (2018) realizaram um estudo precursor na determinação de espessuras de incrustações inorgânicas a partir do treinamento de padrões, obtidos através de dados simulados e fornecidos a uma rede neural artificial simples. Para isso foi utilizada uma geometria para a detecção de incrustações num tubo de aço de 280 mm de diâmetro contendo de sulfato de bário (BaSO_4) variando de mínima (0,5 cm) a máxima (6 cm) deposição concêntrica. Uma fonte de radiação gama foi utilizada com feixe divergente e um detector de cintilação de $\text{NaI}(\text{Tl})$ com $2'' \times 2''$. A abertura do feixe colimado também foi avaliado (2-7 mm) para quantificar o erro associado no cálculo da incrustação. Essa geometria foi definida a partir de modelos baseados no método de Monte Carlo, fazendo uso do código MCNP-X, e os resultados foram validados por meio de equações analíticas. Os dados obtidos pela simulação foram usados para treinar uma rede neural artificial (RNA), tornando o sistema de estudo mais complexo e mais próximo do real. Os dados de entrada fornecidos para o treinamento e validação da rede consistiam em tubos com 4 diferentes diâmetros internos (D1, D2, D3 e D4) e 14 diferentes espessuras de incrustação (0,5 a 7 cm, com passos de 0,5 cm). A rede apresentou capacidade de generalização e boa

convergência, com 70% dos casos com menos de 10% erro relativo e coeficiente de correlação linear de 0,994, o que indica a possibilidade de utilização deste estudo para predição de incrustações.

Salgado et al. (2019) apresentaram uma metodologia para estudar a deposição de incrustações em dutos de sistemas multifásicos (óleo/água/gás), comumente encontrados na indústria de petróleo. A previsão de deposição é feita por meio de uma rede neural artificial, treinada usando dados simulados obtidos com o código MCNP6 e medições de transmissão. O modelo considerou apenas o sulfato de bário (BaSO_4) como incrustação principal. A configuração da transmissão é composta por uma fonte volumétrica de Césio-137(662 keV) e um detector de NaI(Tl) colocado ao redor do tubo. As distribuições de altura de pulso (DPAs) registradas nos detectores são usadas como dados de entrada da rede neural artificial (RNA). Os resultados mostraram que 94% do erro de previsão da espessura de incrustação estava dentro de $\pm 5\%$, e espessura da incrustação em tubulações de petróleo pode ser calculada pela RNA, independentemente da presença de fluidos com resultados satisfatórios em um sistema multifásico com regime de escoamento anular.

Oliveira et al. (2019) estudaram a composição de incrustações inorgânicas extraídas de tubulações de óleo obstruídas e descomissionadas. Essas incrustações foram caracterizadas por microfluorescência e microtomografia de raios X afim de analisar sua composição elementar e estrutural. Diferentes tipos de incrustações foram encontrados de acordo com suas distribuições elementares (principalmente BaSO_4 e CaCO_3) e a forma como foram depositadas no interior dos tubos. Os resultados de ambas as técnicas forneceram dados que podem ser usados para otimizar os métodos de prevenção e remoção de tais materiais de tubos e equipamentos usados em instalações de petróleo, além de filtrar os principais elementos formadores dessas incrustações inorgânicas.

Askari et al. (2019) desenvolveram uma tomografia de raios gama para determinação da espessura de cera no interior de dutos de ferro. O sistema é composto por um cintilador de haste CsI(Na) e fonte gama de Césio-13, com a finalidade de visualização da seção transversal de oleodutos. O sistema pode estimar a posição de interação de raios gama medindo a atenuação gama no cintilador de haste usando dois tubos fotomultiplicadores acoplado às suas extremidades. Apesar de apresentar uma estrutura simples do detector empregado, pode-se notar que é um instrumento sensível à posição. Para testar o sistema de tomografia proposto, uma seleção de peças de barra redonda de polietileno desejadas

(como diferentes espessuras de cera) foi preparada para ser colocados em dutos de ferro, e suas projeções em diferentes ângulos foram adquiridas para construir imagens transversais. Os resultados mostraram que o sistema projetado tinha a capacidade de escanear o interior dos dutos e determinar a espessura da cera com um erro entre 2,4% e 11,4%.

Teixeira et al. (2020) apresentam uma nova proposta para previsão de incrustações inorgânicas com deposição não uniforme (excêntrica) em tubulações utilizados na indústria de petróleo offshore. A abordagem é baseada nos princípios de densitometria gama e redes neurais artificiais profundas (DNNs). Para determinação das espessuras das deposições, um sistema de detecção foi desenvolvido. Este compreende um feixe estreito de 1 mm de abertura de colimação correspondente a uma fonte de Césio-137 e três detectores de NaI(Tl) de 2"x2" posicionados adequadamente ao redor do sistema formado por tubulação, incrustação e fluido. O petróleo bruto foi considerado neste estudo, bem como depósitos excêntricos formados essencialmente por sulfato de bário, BaSO₄. Os modelos teóricos adotaram um regime de fluxo estático e foram desenvolvidos por meio do código matemático MCNPX e, posteriormente, usado para o treinamento e teste do modelo DNN desenvolvido, uma rede neural retificadora de 7 camadas (DRNN). Os hiperparâmetros da DRNN foram definidos usando um método de otimização Bayesiana e seu desempenho foi validado por meio de 10 experimentos baseados na técnica de validação cruzada *K-Fold*. Seguindo a metodologia proposta, o DRNN foi capaz de atingir, para os conjuntos de teste (amostras não treinadas), um erro absoluto médio de 0,01734, erro relativo absoluto médio de 0,29803% e r^2 de 0,9998813 para a previsão da espessura da incrustação e uma precisão média de 100% para a predição da posição da incrustação. Portanto, os resultados mostram que a DRNN de 7 camadas apresenta uma boa capacidade de generalização e é capaz de prever a espessura da incrustação com grande precisão, independentemente de sua posição dentro do tubo.

Mais recentemente, *Carvalho et al. (2024)* apresentam um estudo para determinar a espessura de incrustações de CaCO₃ em tubulações de aço fazendo uso de RNAs, além de validações prévias baseadas em equações analíticas derivadas da densitometria gama e relações trigonométricas. A proposta se baseia numa combinação de arranjos geométricos compostos por tubulação de aço inoxidável AISI316L, incrustações concêntricas e excêntricas formadas essencialmente por carbonato de calcio, além de três detectores de NaI(Tl) distados à 120° para registrar as contagens de uma fonte de Cs -137

(662 keV) colimada em 8° e um de fluxo estático trifásico composto por óleo, gás metano e água salgada. Foram gerados um total de 997 simulações geradas com auxílio do MCNP6 e estas foram distribuídas em 37 simulações concêntricas e 960 simulações excêntricas. A variação das espessuras máximas das incrustações excêntricas, que compreende a geração de geometria mais complexa, foi variada em 15° dentro do tubo, resultando em 24 posições distintas para a espessura máxima. Com base nos resultados, o estudo obteve resultados eficazes para o que se propõe. Os resultados mostraram que as redes conseguiram prever com sucesso mais de 96% dos casos concêntricos e excêntricos de espessura de CaCO₃ com erro relativo inferior a 10%.

1.2 Objetivo

O principal objetivo deste estudo é o desenvolvimento de uma metodologia para predição das espessuras de incrustações inorgânicas concêntricas e excêntricas, encontradas em tubulações de transporte de petróleo, baseada na interpretação dos espectros registrados por detectores cintiladores simulados, por meio do método de Monte Carlo, com a inovação científica de empregar Redes Neurais Profundas (DNN).

Para a alcançar o objetivo proposto, fez-se necessária a execução das seguintes etapas:

1. Estudar os tipos de deposição, concêntrica e excêntrica, por meio de equações analíticas;
2. Validar teoricamente modelos elaborados com auxílio do código computacional MCNPX, levando-se em consideração diferentes tipos de deposição;
3. Projetar e desenvolver uma rede neural artificial rasa com modelos simples para predição das espessuras de incrustação independentemente do tipo de deposição;
4. Aperfeiçoar modelos simulados levando-se em consideração um modelo simulado mais complexo;
5. Projetar e desenvolver uma DRNN e gerar conjunto de dados simulados para alimentação da mesma;
6. Caracterizar incrustações reais provenientes de tubulações descomissionadas para trazer maior realidade às simulações;
7. Utilização dos dados de caracterização de incrustações reais para inserção em

- modelos do MCNPX;
8. Retreinar uma DNN com as informações reais das incrustações e incrementar complexidade de posicionamento das incrustações dentro da tubulação, retornando como predição o volume útil da tubulação.

1.3 Relevância e Originalidade

Na indústria petrolífera, incrustações vão se depositando nas paredes dos tubos, contribuindo para redução o diâmetro interno das tubulações e dificultando a passagem dos fluidos, podendo até mesmo obstruir a passagem dos fluidos, tornando necessárias ações periódicas de manutenção, como limpeza ou até mesmo troca dos tubos. Desta forma, a ocorrência de incrustações causa perdas econômicas devido ao impacto no aumento do custo operacional e no desempenho dos equipamentos em operações em solo marinho (*off-shore*). Esta situação mostra a necessidade de desenvolver metodologias para identificação precisa e evolução da camada de incrustação para aperfeiçoar a extração de petróleo reduzindo os custos da unidade industrial, bem como minimizar ou anular os riscos referentes a contaminação ambiental e exposição do trabalhador. Dispositivos e metodologias que permitam o controle em tempo real deste parâmetro é de grande interesse, independentemente da presença dos fluidos, tornando a operação mais segura e eficiente, minimizando custos e riscos.

Nesse contexto, este trabalho apresenta como método de estudo o emprego de três detectores cintiladores NaI(Tl) para registrar a atenuação e espalhamento gama, o que permite ser um dispositivo mais rápido e econômico no que se refere a obtenção das informações internas à tubulação, realizando somente uma medida no sistema almejado, descartando aparelhos mecânicos para tal. O sistema é pouco dependente do regime de fluxo devido à medição de feixes transmitidos e espalhados, que aumentam a inspeção da área total compreendida pela seção transversal do tubo, por onde fluem todas as fases, minimizando as possíveis variações do regime quando ocorrem fora do feixe principal. Além disso, apresenta uma abrangência quanto aos tipos estruturais de deposições, uma vez que considera as duas possíveis formações em tubulações de petróleo, as deposições concêntricas e excêntricas, sendo essa última, avaliada em posições de máxima deposição diferentes. O propósito da utilização desta geometria e esses parâmetros de medida é

adquirir a informação sobre a deposição presente e predizer a sua espessura e localização, minimizando a necessidade de informações internas ao duto.

Os dados obtidos pelos detectores são usados de forma direta e indireta na alimentação das DNNs, permitindo a utilização de um sistema de detecção simples, com três detectores cintiladores posicionados ortogonalmente à fonte de Césio-137. Este arranjo geométrico possibilitou uma predição satisfatória, dentro de uma faixa de erro de menos de 1%, da rede neural para obtenção da espessura, independentemente da localização da incrustação.

Para alimentar o treinamento e teste do modelo de DNN proposto foi utilizado um conjunto de dados gerados com auxílio do código MCNPX. Esse conjunto compreende exemplos teóricos estáticos e ideais de regime de fluxo anular, além de considerar as deposições inorgânicas excêntricas, facilitando o desenvolvimento da geometria mais adequada a ser utilizada, evitando assim a utilização de seções de teste representativas de cada regime de fluxo, fontes radioativas e detectores.

O sistema modelado desenvolvido no código computacional MCNPX leva em consideração os efeitos da interação da radiação nos meios presentes e as distribuições de altura de pulsos - DAPs, obtidas pelos três detectores cintiladores de NaI(Tl). A resolução em energia e eficiência, dimensões de todos os componentes e as características de um detector real foram também consideradas, aproximando-o o máximo do real.

As DNNs são do tipo Rede Neural Profunda Retificada (do inglês, *Deep Rectifier Neural Network - DRNN*). Os hiperparâmetros da DRNN foram definidos usando um método de otimização Bayesiana e seu desempenho foi validado por meio da técnica de validação cruzada *K-fold*.

Como forma de otimização de resultados, a metodologia proposta apresenta versatilidade ao utilizar o código computacional MCNPX, o que viabiliza mudanças necessárias nos modelos do sistema analisado de forma simplificada.

Os trabalhos de pesquisa de outros autores que mais se correlacionam com este estudo são os trabalhos de *Soares (2014)*, *Oliveira et al. (2014)* e *Salgado et al. (2019)*. As principais diferenças e inovações desta tese são expostas a seguir.

Assim como proposto nesta tese, *Soares (2014)* elaborou um sistema para detecção de incrustações através de medidas de atenuação gama. A proposta é a realização de apenas uma medida em uma tubulação descomissionada apresentando incrustação excêntrica (assimétrica) em seu interior e, a partir dessa única medida, prever a presença da incrustação. Para isso, foram feitas algumas considerações acerca das informações

internas ao duto incrustado como a imprecisão considerável nos coeficientes de atenuação dos materiais em casos em que a medida é feita no centro do duto. Nessa região, há uma grande variação de densidade, como no caso de uma mistura multifásica de óleo, água e gás com proporções aleatórias e variáveis ao longo do tempo. Por isso, optou-se por medidas mais próximas as bordas do duto, onde há menor sensibilidade às variações das densidades dos produtos transportados e a sensibilidade predominante no material de interesse, a incrustação.

Apesar de apresentar resultados consistentes, a metodologia proposta por *Soares (2014)* é aplicada apenas para a predição da presença ou não de deposições. Existem tubulações operacionais com incrustações em seu interior e a predição da espessura destas se faz necessária para determinação da continuidade no uso ou no descomissionamento da linha de operação. Essa é uma limitação do método. Além disso, a proposta necessita de informações internas ao duto, como a localidade de máxima espessura de incrustação, para aplicação da metodologia nessa região, preferencialmente. Em ambientes operacionais, a tubulação em uso, não é possível obter tais informações. É verdade que há casos em que o efeito da aceleração da gravidade atua sobre os sais precipitados, ocasionando a deposição em sua maior proporção em uma região, mas há casos em que a incrustação se deposita de forma simétrica dentro do duto, principalmente em tubulações verticais.

Neste trabalho, é proposta a “visualização” radial de todo diâmetro do duto por meio da atenuação e espalhamento gama, com o intuito de obter um conjunto mais completo de informações que tangem o sistema tubulação-incrustação-fluido. Esse conjunto aborda tanto as incrustações com deposição uniforme e não uniforme no interior do duto, partindo do pressuposto de que não se sabe o tipo de deposição presente no sistema incrustado. Além disso, os meios presentes foram levados em consideração. A própria composição da incrustação não foi idealizada pois, sabe-se que, a composição das incrustações apresenta um misto de contribuições inorgânicas. Todos esses dados e parâmetros de medidas foram usados para alimentar uma DNN capaz de predizer o tipo de deposição e sua espessura de incrustação.

Oliveira et al. (2014) apresentam uma configuração mecânica de inspeção capaz de realizar escaneamento no sistema incrustado. Dotado de uma fonte de Césio-137 e um detector cintilador de NaI(Tl) acoplados em hastes que se movimentam verticalmente ao duto, o sistema é capaz de realizar a varredura em passos de 5mm/minuto desde a borda

inicial, centro e borda final do duto com a deposição. Dessa forma, obtém-se, ao final do escaneamento, um perfil característico daquele duto.

A metodologia é eficaz no que se refere a identificação de tipos de deposição. Fica claro que esse era um dos objetivos do estudo, uma vez que os autores consideram tanto incrustações concêntricas como excêntricas na previsão das incrustações. Além disso, também considera meios como água e óleo como fluidos presentes na tubulação, o que é uma contribuição ao que foi desenvolvido por *Soares (2014)*. No entanto, o sistema demanda custos associados a construção de toda a configuração mecânica. Além disso, também necessita de muitas medidas para realizar um perfil característico do duto e assim, inferir no tipo e presença de incrustação. Diferentemente da metodologia proposta nesta tese, que apresenta um método de predição não só da presença, como tipo, e espessura da incrustação a partir de uma única medida. Otimizando a predição da incrustação, minimizando custos e tempo associados.

Salgado et al. (2019) apresentam uma proposta na determinação de espessuras de incrustação baseada no treinamento de redes neurais artificiais por meio de dados simulados de atenuação gama. O método leva em consideração os meios presentes, adotando um sistema multifásico com regime de fluxo anular no interior da tubulação e deposição do tipo concêntrica. Os autores fizeram estudos do coeficiente de atenuação de todos os materiais envolvidos no sistema, de forma a aproximar os dados simulados de dados teóricos/experimentais, com erros percentuais de menos de 3%. O detector cintilador simulado foi validado experimentalmente, sendo que suas dimensões foram determinadas por gamagrafia e utilizadas na inserção no ‘input’ das simulações.

No estudo há detalhamento no que se refere aos parâmetros adotados nos modelos simulados, e há uma boa justificativa na utilização de cada item. Entretanto, apresenta a limitação de abordar apenas um tipo de formação de deposição, não se aplicando às formações excêntricas, por exemplo. Além disso, a RNA apresenta poucos dados usados para treinamento e teste, limitando a RNA a um conjunto de dados de 32 casos, sendo 24 padrões utilizados para o conjunto de treinamento e 8 padrões para o conjunto de teste.

Um estudo mais recente proposto por *Carvalho et al. (2024)* apresentaram uma abordagem eficaz para prever a espessura de incrustações de CaCO₃ em pipelines offshore, utilizando simulações detalhadas de incrustações concêntricas e excêntricas, com um total de 997 simulações. As simulações foram baseadas em geometrias específicas e incrementos de espessura controlados, fornecendo um conjunto robusto de dados para o treinamento de redes neurais artificiais (RNAs).

Embora essa abordagem forneça dados bem estruturados e controlados, um aspecto importante a ser considerado é a representatividade dessas simulações para as condições reais de sistemas offshore, onde as incrustações podem se formar de maneira imprevisível, com variações tanto em termos de geometria quanto em termos de distribuição de material. As geometrias concêntricas e excêntricas utilizadas no estudo são úteis, mas podem não refletir todas as possíveis configurações de deposição que ocorrem em cenários práticos.

Nesse contexto, a utilização de dados gerados de forma randômica, o que é proposto nesse trabalho, para a predição das para incrustações, tanto concêntricas quanto excêntricas, poderia trazer uma vantagem significativa. Ao introduzir diversidade geométrica e aleatoriedade nas condições de deposição, seria possível ampliar a aplicabilidade do modelo em cenários mais variados e complexos. Essa abordagem pode simular uma gama mais ampla de possíveis situações, refletindo com maior precisão as condições imprevisíveis que são frequentemente observadas em sistemas reais de pipelines *offshore*.

CAPÍTULO II

2 – FUNDAMENTOS TEÓRICOS

Este capítulo tratará dos conhecimentos teóricos necessários para um bom entendimento da metodologia proposta nesta tese. Alguns assuntos serão abordados, como: Fundamentos da Radiação Gama e sua interação com a matéria, Incrustações Inorgânicas provenientes da Produção de Petróleo e Gás, Métodos de Caracterização Químico-Mineralógica de Incrustação utilizando Raios X, Cálculo de Espessura de Incrustações, Modelagem Matemática utilizando método de Monte Carlo e Redes Neurais Artificiais Profundas.

2.1 - Fundamentos da Radiação

No contexto da predição de incrustações baseada em técnica nuclear, mais especificadamente na atenuação de raios gama, se faz necessário o estudo da interação da radiação gama com os meios participantes do sistema em análise. Tradicionalmente, a instrumentação requerida consiste em fonte(s) de radiação e detector(es) alocados ao lado externo do duto. As radiações diretamente e indiretamente ionizantes provenientes da(s) fonte(s) radioativas são caracterizadas por sua capacidade de interagir com a matéria e, com isso, promover a transferência de energia da radiação para a matéria, provocando excitações atômicas ou moleculares, ionizações ou ativação do núcleo pelo caminho percorrido.

2.1.1- Interação da Radiação Eletromagnética com a Matéria

As radiações eletromagnéticas indiretamente ionizantes de maior interesse são as radiações X e gama. Por apresentar caráter ondulatório, ausência de carga e massa de repouso, essas radiações podem penetrar em um material, percorrendo grandes espessuras antes de sofrer a primeira interação. Esta capacidade de penetração depende da probabilidade ou secção de choque de interação para cada tipo de evento que pode absorver ou espalhar a radiação que incide. A penetrabilidade dos raios X e gama é muito

maior que a das partículas com cargas, e a probabilidade para que haja interação depende muito do valor de sua energia.

Os principais modos de interação da radiação com a matéria são: o *efeito fotoelétrico*, o *efeito Compton* e a *produção de pares*¹. Para a diferenciação e quantificação dos meios presentes nesse estudo, como água, gás, óleo e incrustação, a faixa de energia mais adequada é de 20 keV a 662 keV. Isto ocorre porque os coeficientes de atenuação linear total (μ) destes materiais apresentam diferenças significativas nesta faixa de energia, facilitando suas distinções e obtenção das espessuras de incrustação. Os valores dos coeficientes de atenuação linear total (μ) da água salinizada, óleo e incrustação (sulfato de bário) utilizados em diversos estudos nesta tese são apresentados na Figura 2. Estes valores iniciais de coeficiente para o gás, água salinizada e óleo foram calculados e obtidos em *Hubbel e Seltzer (1997)*.

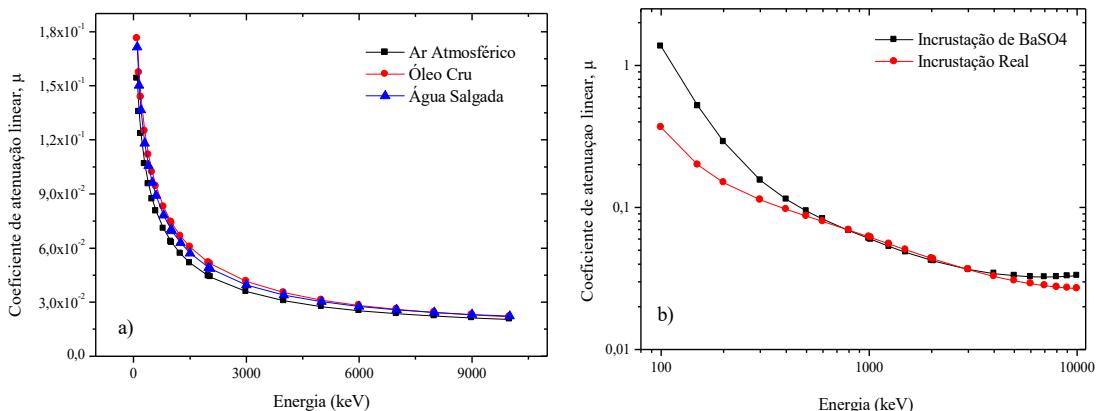


Figura 2 - Coeficientes de atenuação linear total para os fluidos (a) e incrustações (b).

i) *Efeito Fotoelétrico*

É a interação que ocorre quando o fóton interage com um elétron ligado fortemente ao átomo do material. Toda a energia do fóton é transferida para este elétron orbital que, por consequência, é ejetado da camada eletrônica com uma energia cinética E_c bem definida, conforme Equação 1:

¹ Como a energia mínima dos fótons incidentes para a produção de pares é de 1022 keV e a faixa de energia usada nesta tese é bem abaixo deste valor, este efeito não será considerado.

$$E_c = h \cdot v - B_e$$

Equação 1

onde h é a constante de Planck, v é a frequência da radiação e B_e é a energia de ligação do elétron orbital.

Como E_c difere da energia do fóton de um valor constante B_e , com a sua transferência para o material de um detector, pode ser utilizada como mecanismo de identificação do fóton e de sua energia (Knoll, 1989).

Por meio das leis de conservação de momento e energia e sabendo que a massa nuclear é grande, a energia de recuo do átomo é desprezível, desta forma conclui-se que a energia cinética do elétron ejetado é igual à energia incidente menos a energia de ligação do elétron orbital.

Este efeito possui maior probabilidade de ocorrência em baixas energias (energia de ligação dos elétrons) e em alvos com elevado número atômico Z . A predominância de ocorrência aumenta com $(Z)^4$ e decresce rapidamente com o aumento da energia. No entanto, a ejeção do elétron de uma determinada camada só ocorre se a energia do fóton incidente for superior a energia de ligação deste elétron com a camada, neste caso o elétron fica excitado e a vacância deixada por ele é preenchida por uma espécie de reorganização do orbital eletrônica, seguido da emissão de um raio X característico. O efeito fotoelétrico é ilustrado na Figura 3.

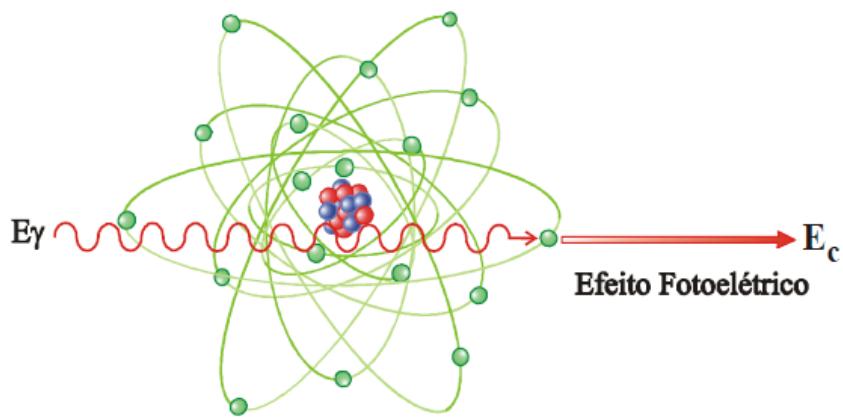


Figura 3- Representação do efeito fotoelétrico (Tauhata, 2013).

Como a transferência de energia do elétron de ionização para o meio material produz uma ionização secundária proporcional, a amplitude de pulso de tensão ou a intensidade de corrente proveniente da coleta dos elétrons ou íons, no final do processo, expressam a energia da radiação incidente.

ii) *Efeito Compton*

O efeito Compton, ou espalhamento incoerente, um fóton é espalhado por um elétron de baixa energia de ligação, recebendo somente parte de sua energia, seguindo com menor energia e em outra direção ao longo do material, conforme ilustrado na Figura 4. Como a transferência de energia depende da direção do elétron emergente e esta é aleatória, de um fóton de energia fixa podem resultar elétrons com energia variável, com valores de zero até um valor máximo.

Dessa forma, a informação associada ao elétron emergente é desinteressante sob o ponto de vista da detecção da energia do fóton incidente. Sua distribuição no espectro de contagem é aleatória, aproximadamente retangular. A energia do fóton espalhado $E'\gamma$ depende da energia do fóton incidente $E\gamma$ e do ângulo de espalhamento θ , em relação à direção do fóton incidente, dada pela Equação 2.

$$E' = \frac{E}{1 + \alpha(1 - \cos\theta)}$$

Equação 2

com,

$$\alpha = \frac{h\nu}{m_0 c^2}$$

Onde:

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

$m_0 c^2$ – Energia de repouso do elétron (eV);

– ângulo de espalhamento.

A energia do fóton espalhado é máxima para $\theta = 0^\circ$ e mínima para $\theta = 180^\circ$. A energia cinética do elétron ejetado é máxima para este caso, e igual a (Equação 3),

$$T = T_{max} = E \frac{2\alpha}{1 + 2\alpha}$$

Equação 3

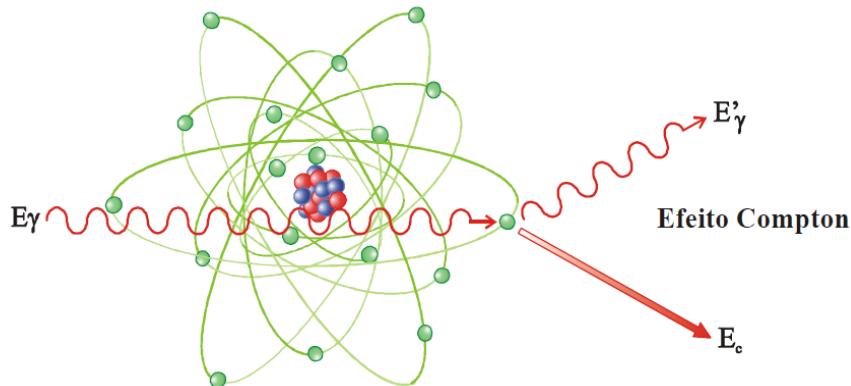


Figura 4 - Representação do efeito Compton (Tauhata, 2013).

O formalismo físico-matemático anteriormente descrito foi simplificado à semelhança de uma colisão mecânica e, assim, expressões para a energia do fóton espalhado com um ângulo θ e do elétron emergente, com um ângulo, puderam ser obtidas facilmente.

Nesta descrição, assim como para o efeito Fotoelétrico, considera-se que o fóton se comporta como um corpúsculo e o elétron como uma partícula livre. Entretanto, sabe-se que isto constitui aproximações pragmáticas, sem o tratamento quântico mais rigoroso (Tauhata, 2013).

Na descrição da Física Quântica, a interação do fóton com o elétron, é tratada no formato de probabilidades de interação, que nada mais são que as secções de choque microscópicas. Nesta descrição, são envolvidos o formalismo de Dirac (Cohen et al., 1998) e o modelo de Klein-Nishina (Klein e Nishina, 1929).

A probabilidade de ocorrer espalhamento Compton é diretamente proporcional à energia do fóton e inversamente ao número atômico. O número de fótons espalhados que são obtidos no detector pode ser obtido usando a Equação 4.

$$S = \Phi_o(E)\varepsilon(E)t \exp\left(-\int_{l_1} \mu(E_\gamma)dl\right) \frac{d_e\sigma^{KN}}{d\Omega} \frac{\rho N_A Z}{A} \exp\left(-\int_{l_2} \mu(E_\gamma)dl\right) dV d\Omega$$

Equação 4

onde:

t – Tempo de contagem (s);

$I_0(E)$ – Fluxo de fóton incidente com energia (E);

$d_e\sigma^{KN}/d\Omega$ – Seção de choque diferencial Klein-Nishina na energia (E) para um elétron livre, que é a probabilidade espalhamento de um fóton;

$d\Omega$ – Ângulo sólido subtendido pelo detector conforme visto do ponto de interação;

ρ – Densidade;

Z – Número atômico;

N_A – Número de Avogadro;

A – Número de massa do material sobre análise;

μ_1 e μ_2 – Coeficientes de atenuação linear para fótons primários e espalhados dentro da amostra;

ε – Eficiência de contagem de fotópico do detector na energia do fóton espalhado;

l_1 e l_2 – comprimentos dos caminhos dos fótons na amostra da fonte até o centro de espalhamento e de volta para o detector;

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

No caso de uma amostra homogênea e uma geometria com fonte puntiforme, os termos das integrais são constantes. Além disso, a seção de choque diferencial Klein-Nishina será constante para uma Geometria fixa e uma dada energia do fóton incidente e fluxo. Portanto, a taxa de contagem depende apenas da densidade do material examinado e informações obtidas por este técnica é fortemente dependente da densidade do material, de forma que a variação de densidade dentro da amostra poderia ser monitorada.

Quando a energia de ligação dos elétrons orbitais se torna desprezível face à energia do fóton incidente, a probabilidade de ocorrência de espalhamento Compton aumenta consideravelmente. O efeito Compton é ainda desprezível quando comparado ao efeito fotoelétrico para energia abaixo de 100 keV, o que pode ser visto na Figura 5(a) e há um aumento para energias mais altas, conforme observado na Figura 5(b) ([Seelentag e Panzer, 1979](#)).

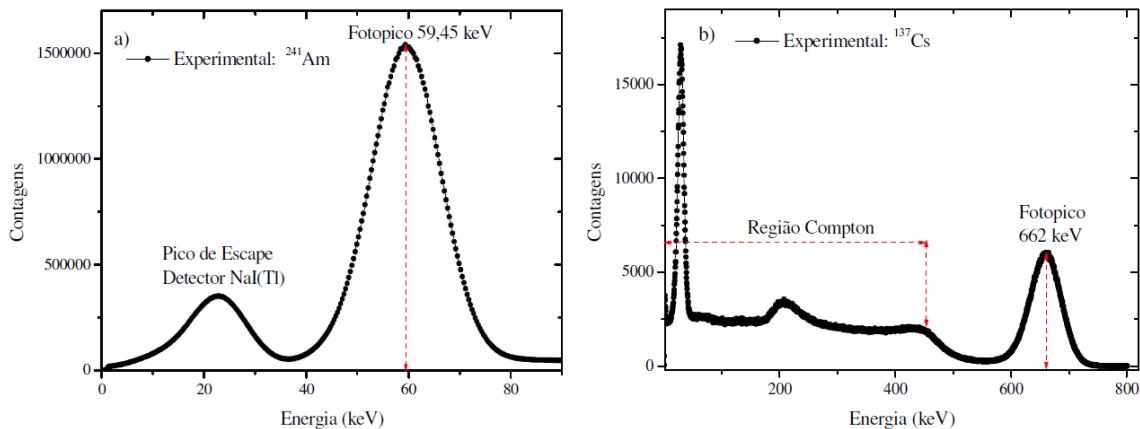


Figura 5- Distribuição de Altura de Pulso obtidas com detector cintilador de NaI(Tl) 1" x 1" para as fontes de Am-241(a) e Cs-137(b).

2.1.2 Atenuação do feixe de fótons

Quando um feixe de radiação gama ou X incide sobre um material de espessura x , parte do feixe é espalhada, parte é absorvida pelos processos já descritos e uma fração atravessa o material sem interagir. A intensidade I do feixe emergente está associada à intensidade I_0 do feixe incidente, pela equação 5:

$$I = I_0 \cdot e^{-\mu x}$$

Equação 5

onde μ é a probabilidade de o feixe sofrer atenuação devido a eventos de espalhamento Compton, absorção fotoelétrica ou formação de pares, sendo denominado de *Coeficiente de Atenuação Linear Total*.

O coeficiente de atenuação linear é a probabilidade do feixe “sofrer” atenuação devida a eventos de espalhamento, absorção ou formação de pares. Seu valor depende do meio absorvedor e é função da energia dos raios gama.

Vale ressaltar que os valores dos coeficientes de atenuação linear são normalmente utilizados como coeficiente de atenuação mássico, pois independe do estado físico do material e é definido pela razão do coeficiente de atenuação linear pela densidade do material, conforme Equação 6.

$$\mu_m = \frac{\mu}{\rho}$$

Equação 6

Onde:

μ_m – Coeficiente de atenuação mássico (cm^2/g);

μ – Coeficiente de atenuação linear (cm^{-1});

ρ – Densidade do material (g.cm^{-3}).

Na Figura 6 é ilustrado o processo de atenuação para um feixe de intensidade I_0 .

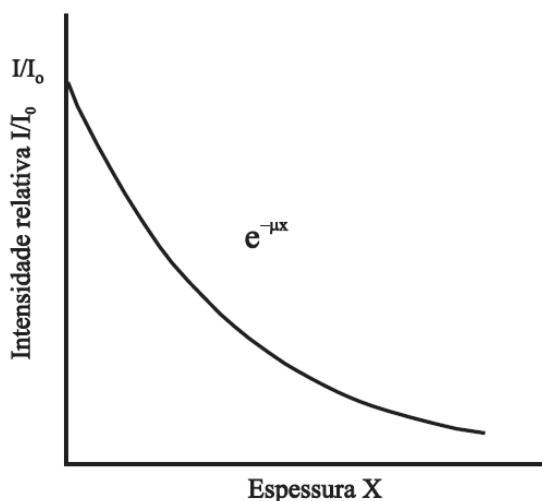


Figura 6 - Atenuação de um feixe de fótons por um material de espessura X
(Tauhata, 2013).

Para um absorvedor composto de ‘n’ camadas de elementos e espessuras diferentes, a intensidade I do feixe transmitido é dada pela Equação 7.

$$I = I_0 \cdot e^{-\sum_{i=1}^n \mu_i x_i}$$

Equação 7

2.1.3 Detecção da radiação ionizante

Detectores de radiação são dispositivos com capacidade de registrar e indicar a interação da radiação com o seu volume sensível. São constituídos, portanto, por um

material sensível à radiação e um sistema capaz de converter os sinais produzidos pela radiação em seu interior numa grandeza possível de ser detectada e mensurada.

O princípio básico de funcionamento de qualquer detector de radiação é a dissipação de energia pela partícula incidente no volume sensível do detector. Dependendo do tipo de interação que possa ocorrer entre o feixe de radiação e o detector (efeitos Fotoelétrico, Rayleigh, Compton ou Formação de Pares), toda ou parte de sua energia é absorvida pelo volume sensível (cristal, líquido, etc) e utilizada para geração de luz, portadores de cargas etc., dependendo do tipo de detector utilizado. Para cada fóton detectado, um pulso de carga é gerado, cuja altura fornece a energia transferida pelo fóton e a contagem destes pulsos corresponde ao número de interações.

A distribuição da energia depositada é informação primária obtida e, assim, após um tratamento, é possível obter informações do espectro de energia. Para efetuar a espectrometria, o sinal proveniente do detector necessita de um processamento. Um esboço representativo de um sistema de medição para os detectores cintiladores de Na(Tl) é ilustrado na Figura 7.

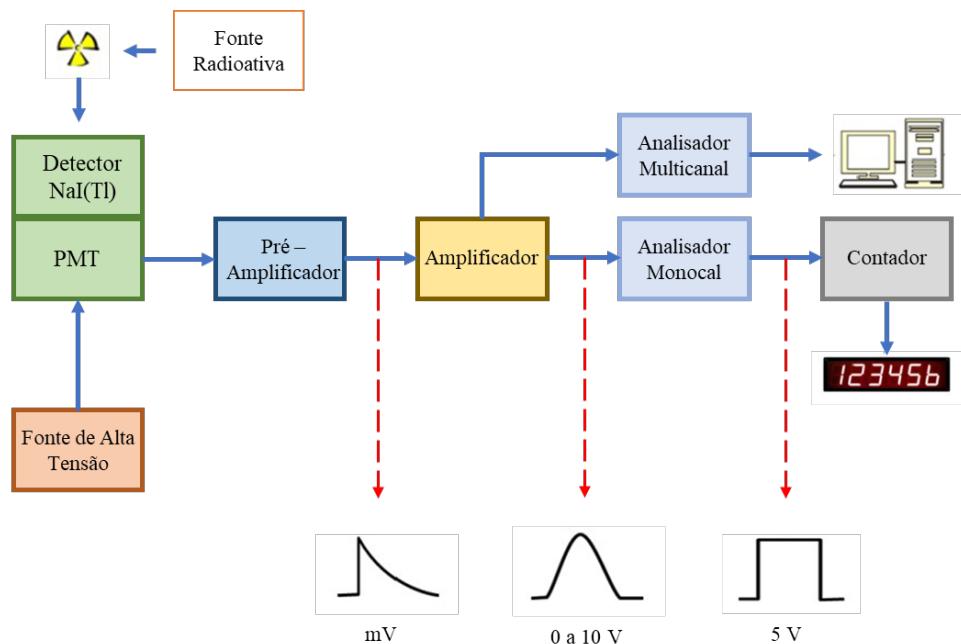


Figura 7 - Esquema de detecção para um detector cintilador NaI(Tl).

Os módulos principais que compõe um sistema de medição de espectrometria são:

- a) *Pré-amplificador*: sensível à carga cuja função é integrar a carga elétrica, gerando um sinal de tensão cuja amplitude é proporcional à carga integrada, realizando, ainda, o “casamento de impedâncias” entre o detector e o amplificador;
- b) *Amplificador*: cuja finalidade básica é modelar a forma do pico de sinal e aumentar a amplitude do sinal proveniente do pré-amplificador (normalmente menor que 1,0 V) para faixas de tensão mais convenientes (de 0 a 10 V) para análise posterior e, por meio de conformação dos pulsos, maximizar a relação sinal-ruído;
- c) *Analizador multicanal (AMC)*: que classifica e conta os pulsos conforme suas amplitudes e armazena a contagem dos pulsos em canais;
- d) *Analizador monocanal*: capaz de gerar um sinal lógico padrão, cada vez que o sinal gerado pelo amplificador estiver entre determinados valores (modo diferencial ou janela) ou acima de um valor mínimo (modo integral).

2.1.4 Detectores de NaI(Tl)

Dispositivos cintiladores são aqueles em que o tempo de vida do estado excitado é inferior a 10^{-9} segundos e o processo desexcitação ocorre com a emissão de um fóton de luz visível (cintilação). A radiação gama ao interagir com o cristal do detector cintilador, como o iodeto de sódio - NaI(Tl), produz cintilações com uma intensidade luminosa muito elevada, quando comparada com outros materiais, num fenômeno designado por fluorescência. Para aumentar a probabilidade de emissão de fótons de cintilação e reduzir os efeitos de auto-absorção de luz no cristal, são introduzidas impurezas em pequenas quantidades, também chamadas de ativadores, neste caso o ativador é o Tálio (Tl) (Tsoulfanidis, 1995).

A transformação desta luz em sinal elétrico, geralmente utiliza-se uma válvula fotomultiplicadora constituída de um fotocatodo² capaz de converter o fóton de luz visível em elétrons com energia situada entre 1 a 2 eV. Tais elétrons são devidamente focalizados e acelerados pelos dinodos³ com energia cinética suficiente (~100 eV) para colidirem e gerar elétrons secundários. Uma cascata de elétrons é formada, resultante de um processo

² Película de semicondutor de pouca espessura na ordem de nanômetros.

³ Série de eletrodos que liberam um número maior de elétrons do que os que neles incidem. Uma diferença de potencial (DDP) é aplicada entre os dinodos em sequência.

de multiplicação, produzindo um pulso de corrente ao atingir o ânodo⁴ da fotomultiplicadora, sendo coletado e processado pelo sistema de espectrometria gama. Um esquema da geração de um pulso elétrico a partir da interação da radiação gama num detector cintilador NaI(Tl), bem como a consequente produção de um pulso elétrico pode ser observado na Figura 8.

O número de elétrons convertidos é proporcional à energia da radiação incidente no cristal e é razoavelmente linear para uma faixa significativa de energias de raios gama. Isto permite relacionar a amplitude do sinal de corrente à energia absorvida pelo cristal. Assim, a produção dos fôtons é proporcional à energia da radiação e a eficiência de detecção provavelmente irá variar com a radiação e com o tipo de material usado como cintilador.

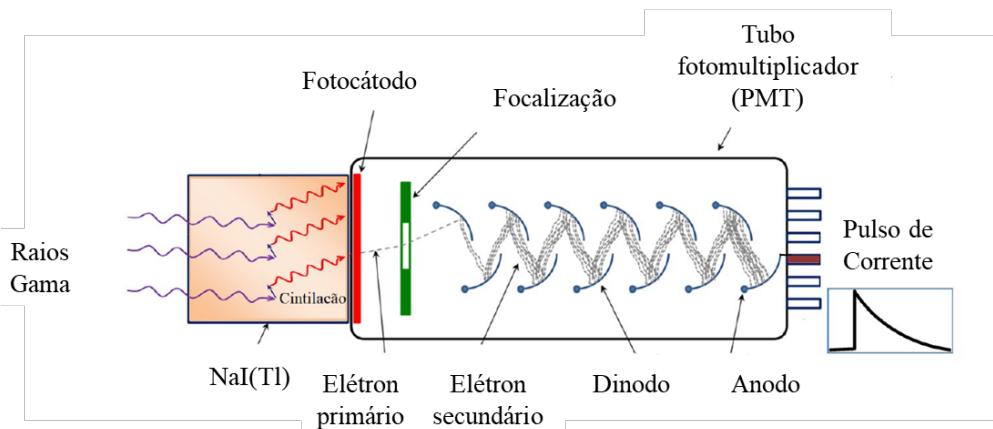


Figura 8- Geração de um pulso elétrico em um detector cintilador NaI(Tl).

Os detectores cintiladores NaI(Tl) apresentam como principais vantagens:

- Alta eficiência de contagem, devido a sua densidade ($3,67 \text{ g.cm}^{-3}$) e seu elevado número atômico ($Z = 53$);
- Facilidade de usinagem, possibilitando a obtenção de cristais grandes e formatos específicos;

⁴ Onde a chegada dos elétrons aparece sob a forma de um pulso de corrente acentuado.

- c) Não necessita de um sistema de refrigeração para operação, por isso possui baixo custo de operação.

2.2 Fundamentos de formação da incrustação

Incrustações geralmente são definidas como compostos químicos de natureza orgânica, inorgânica e mista, que precipitam principalmente pela supersaturação e nucleação devido a incompatibilidade de águas, podendo acumular na parede interna de dutos, equipamentos de superfície e/ou partes de componentes envolvidos na produção de petróleo. Alguns processos de extração de petróleo resultam no aparecimento de incrustações no interior de dutos utilizados para o transporte. Dentre os tipos de incrustação, as mais comuns para a deposição orgânica são as parafinas e asfaltenos (fração pesada do petróleo), para a deposição inorgânico são os sulfatos e os carbonatos de metais alcalinos terrosos.

As parafinas, normalmente presentes na mistura de hidrocarbonetos que formam o petróleo, são alcanos diluídos que precipitam com mudanças físicas significativas, como diminuição da temperatura e pressão. Quando a temperatura da mistura fica inferior à temperatura do ponto de precipitação da parafina há uma tendência na formação destes depósitos orgânicos. Este fenômeno ocorre principalmente pelo resfriamento da mistura extraída do poço que, ao passar pelos dutos em contato com as águas profundas e frias do oceano, tem a sua temperatura diminuída. A precipitação da parafina, por um processo de afinidade química, começa a se acumular na parede interna do duto de transporte do óleo. Esse processo proporciona a redução significativa do volume útil do duto, favorecendo o aumento de pressão no sistema e diminuição da vazão do poço. (*Burger et.al, 1981*).

A causa primeira da deposição de sais pode ser a supersaturação. Uma solução supersaturada é definida pela quantidade de soluto dissolvido apresentar maior valor que o requerido para a respectiva solução saturada, nas mesmas condições de temperatura, pressão e pH. Segundo *Zhang et al., (2019)*, a supersaturação de um sistema também pode ser influenciada pela incompatibilidade de águas. A supersaturação, segundo autores, ocorre devido a influência dos cristais submicroscópicos, os primeiros a precipitar, por apresentarem maior solubilidade do que as partículas maiores do mesmo cristal, poupando o processo de cristalização para dadas condições de equilíbrio do sistema. No entanto, o equilíbrio pode ser interrompido por alterações nas condições iniciais

(temperatura, pressão, pH, entre outros), favorecendo a precipitação dos sais em suspensão.

A nucleação também favorece a formação de precipitados e depósitos de minerais. É caracterizada pela formação inicial do precipitado e ocorre geralmente quando o sistema é agitado, se apresenta partículas suspensas, bolhas de gás e corrosão nas paredes das tubulações (*Sena, 2008*).

A mistura da água injetada, geralmente do mar, com a água da formação, rica em íons divalentes de metais alcalinos terrosos, pode favorecer a formação de sulfatos e carbonatos de metais alcalinos terrosos. Sendo os precipitados mais comumente encontrados nos equipamentos/tubulações devido as suas maiores proporções na água de formação são: o carbonato de cálcio (CaCO_3), Sulfato de Cálcio (Gipso – $\text{CaSO}_4 \cdot 2\text{H}_2\text{O}$; Emi-hidratado - $\text{CaSO}_4 \cdot 1/2\text{H}_2\text{O}$; Anidrita – CaSO_4), Sulfato de Bário (BaSO_4), Sulfato de Estrôncio (SrSO_4), compostos de ferro (Carbonato de Ferro – FeCO_3 ; Culfeto Ferroso FeS ; Hidróxido Ferroso - Fe(OH)_2 ; Óxido Férrico – Fe_2O_3 ; Hidróxido Férrico - Fe(OH)_3) (*Reis, et al., 2011; Chen, Neville e Yuan, 2005*). A ocorrência de depósitos de Carbonato de Cálcio (CaCO_3), por exemplo, deve-se principalmente à despressurização da água presente nos reservatórios petrolíferos, que desloca o equilíbrio dos íons $\text{HCO}_3^-/\text{CO}_3^{2-}$ para eliminação do Dióxido de Carbono (CO_2) dissolvido. Por isso, este tipo de incrustação ocorre principalmente onde há maior queda de pressão e/ou aumento de temperatura (*Duarte e Araújo, 2010*).

As principais incrustações relacionadas aos poços produtores de petróleo são listadas na Tabela 1, segundo a *American Standard Test Method* (ASTM).

Tabela 1- Incrustações mais comuns associadas a produção de petróleo (Silva, 2007).

Tipo de Incrustante	Fórmula Química	Nome do Mineral
Cloreto de Sódio	NaCl (Solúvel em Água)	Halita
Carbonato de Cálcio	CaCO ₃ (Solúvel em Ácido)	Calcita
Carbonato de Ferro	FeCO ₃	Siderita
Sulfeto de Ferro	FeS	Trolita
Óxido de Ferro	Fe ₃ O ₄	Magnetita
Hidróxido de Magnésio	Mg(OH) ₂	Brucita
Sulfato de Cálcio	CaSO ₄ .2H ₂ O (Insolúvel em Ácido)	Gipsita
Sulfato de Cálcio	CaSO ₄	Anidrita
Sulfeto de Bário	BaSO ₄	Barita
Sulfato de Estrôncio	SrSO ₄	Celestita
Sulfato de Bário e Estrôncio	BaSr(SO ₄) ₂	Sulfato de Bário e Estrôncio

Dentre as principais incrustações, o Sulfato de Cálcio (CaSO₄) é o tipo de incrustante de maior dificuldade de remoção, associada à sua característica inerente de insolubilidade em soluções ácidas. Sua solubilidade em água pura (25°C) apresenta um valor relativamente alto, comparado aos demais sais, com valor igual a 2000 mg.L⁻¹. Enquanto que o sulfato apresenta maior insolubilidade em água em temperatura ambiente, conforme mostrado na Tabela 2.

Tabela 2- Solubilidade de alguns sais orgânicos associadas a produção de petróleo (Oliveira, et al., 2014).

Precipitado	Solubilidade (mg.L ⁻¹) em H ₂ O, a 25 °C
Sulfato de Bário (BaSO ₄)	2
Carbonato de Cálcio (CaCO ₃)	53
Sulfato de Estrôncio (SrSO ₄)	114
Sulfato de Cálcio (CaSO ₄)	2000

A formação química e reações envolvidas na formação das incrustações ocorre por meios adotados desde o princípio do processo de extração do óleo. Durante a produção de petróleo, a perfuração e o consequente transporte do óleo pode ser feitos por meio da injeção de água. Esse método tem como objetivo principal a otimizar máxima recuperação do petróleo e proporcionar estabilidade da pressão na rocha reservatório selecionada para a prospecção. Em plataformas, a água utilizada é essencialmente a água do mar, rica em ânions de sulfato (SO_4^{2-}), devido a sua maior disponibilidade na localidade, o que reduz os custos totais associados à produção.

No leito rochoso, onde está acomodado o óleo e demais materiais (gás, sedimentos, etc), há também a presença da água de formação ou conata (aquele naturalmente existente no meio poroso junto ao petróleo ou aquífero). Quando no processo de produção se dá a mistura da água de injeção com a água de formação, forma-se a água de produção (Candeias, 2010; Zhang et al., 2019). Devido à afinidade química entre os elementos químicos dessas águas, há o favorecimento de reações químicas entre estes, levando à formação de sais inorgânicos, as incrustações de metais alcalinos terrosos (Collins e Jordan, 2001; Vazirian et al., 2016; Vazquez et al., 2016; Khormali et al., 2016; Vetter, 1976; Kelland, 2014).

A formação do Sulfato de Bário (BaSO_4), um dos sais que apresenta menor solubilidade em água, ocorre na chamada zona de mistura como mostrada na Figura 9. Nesta região, a água de formação (presente no leito rochoso), com elevada concentração de íons de bário (Ba^{2+}), entra em contato com a água de injeção, com elevada concentração de íons sulfato (SO_4^{2-}), proporcionando a mistura dessas duas águas. Por apresentar condições termodinâmicas favoráveis, esses elementos químicos interagem e se associam, formando as incrustações de sulfato de bário (Sorbie, 2000; Bertero et al., 1986; Candeias, 2010; Teixeira et al., 2018 e 2020).

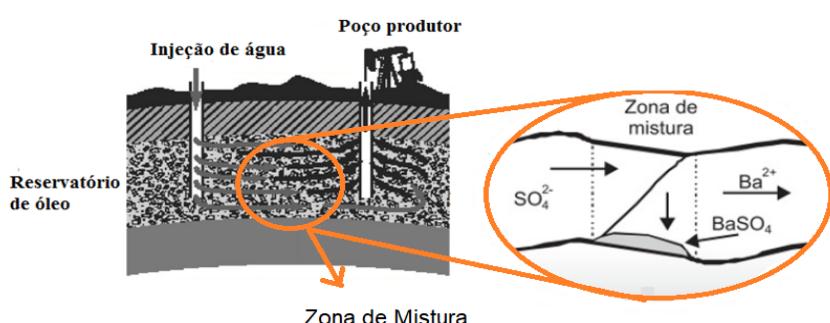
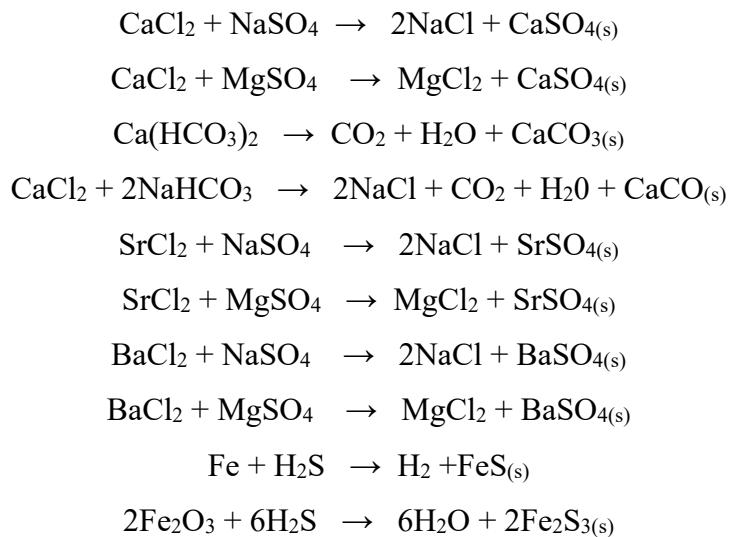


Figura 9- Demonstração do processo de precipitação de BaSO_4 (Teixeira, 2018)

Dentre as reações mais comuns no ambiente petrolífero, além do sulfato de bário, destacam-se:



E os principais impactos gerados diretamente pelas incrustações na produção petrolífera são:

1. Falha do equipamento levando a parada emergencial da produção, aumento do custo de manutenções e diminuição geral da eficiência de produção (*Oliveira, et al., 2014*);
2. Comprometimento dos dutos dos poços de petróleo no mar, bem como na superfície de equipamentos como membranas usadas em filtração, tratamento e unidade de remoção de sulfato da água do mar (*Reis, et al., 2011*);
3. Diminuição da seção reta do duto levando ao aumento das perdas de carga ao longo da linha de extração de óleo, o que é também a causa da diminuição da vazão do óleo produzido no poço (*Soares, 2014*);
4. Acúmulo de depósitos pode criar condições favoráveis para extrema destruição microbiológica influenciando a corrosão do duto (*IAEA, 2005*);
5. A precipitação e formação das incrustações podem estar associadas com a presença de íons de rádio que podem também precipitar com o bário e estrôncio, gerando precipitados radioativos, cuja a remoção e descarte são perigosos e dispendiosos (*Garcia, 2010*).

Existem outros parâmetros como a variação das condições cinético-químicas e termodinâmicas que também podem viabilizar a precipitação de sais com consequente

deposição nas tubulações e equipamentos. A pressão, temperatura, concentração, pH e força iônica, por exemplo, podem sofrer alterações ao longo do processo de produção favorecendo a formação das incrustações (Todd *et al.*, 1992; Graham, 2002; Bhandari *et al.*, 2016; Bukuaghagin *et al.*, 2016; Naseri *et al.*, 2015). Na Figura 10 são apresentadas duas amostras de incrustações de dutos descomissionados com deposição concêntrica e excêntrica, da esquerda para a direita, respectivamente.

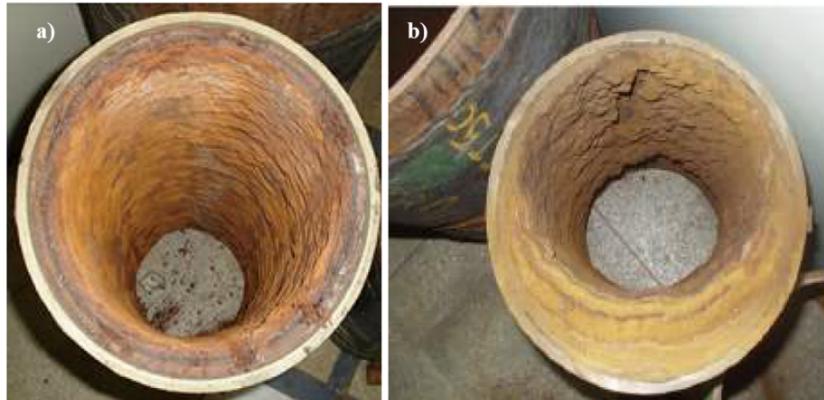


Figura 10- Incrustações em tubulações descomissionadas com formação do tipo concêntrica (a) e excêntrica (b) - (LIN-UFRJ).

Levando em consideração a gama de processos envolvidos nas fases iniciais do processamento do petróleo e outros materiais provenientes da rocha, e que a precipitação dos sais ocorre nessas fases, nota-se que a precipitação desses sais tem impacto considerável na indústria, não limitando apenas à redução do volume útil dos fluidos nas tubulações, mas acarretando significativamente em uma série de problemas operacionais associados. Sendo assim, se faz necessárias contramedidas para evitá-los ou minimizá-los. Algumas medidas corretivas e preventivas podem ser uma opção positiva; como a remoção química/mecânica das incrustações (Cruz, 2002) e/ou adição de substâncias químicas capazes de inibir a sua formação (Reis, *et.al*, 2011), analisar as condições de precipitação, desenvolvendo assim um intervalo operacional seguro e avaliar a tendência grave de deposição (Yan *et al.*, 2015; Steel *et al.*, 2018; Hu *et al.*, 2018). e ainda a detecção do início do processo de incrustação ou a incrustação em fase avançada por meio de técnicas nucleares não invasivas (Besserra, 2010; Candeias, 2010; Teixeira, 2018; Teixeira *et al.*, 2018 e 2020).

2.3 O método de Monte Carlo e a modelagem matemática das incrustações em tubulações de petróleo

O método de Monte Carlo (MC) é uma ferramenta computacional baseada em um método estatístico de compreensão de sistemas físicos e/ou matemáticos complexos usando números criados de forma aleatória que alimentam esses sistemas para gerar uma gama de soluções. A probabilidade de uma solução específica pode ser encontrada dividindo o número de vezes que a solução foi gerada pelo número total de testes. Ao usar um número maior de testes, a probabilidade de soluções pode ser determinada com uma maior precisão. É usado principalmente em problemas em que determinar uma solução analítica seria difícil ou até impossível. Pode ser facilmente aplicado para estudos que envolvam transporte da radiação, simulando as trajetórias das partículas de forma individual, e os processos inerentes à interação da radiação com a matéria pela geração de números pseudo-aleatórios, em função da distribuição da probabilidade que rege os processos físicos de espalhamento, absorção, captura, etc. ([Pelowitz, 2005](#)).

Por meio de um grande número de eventos, ou histórias, é possível obter informações sobre o valor médio de grandezas macroscópicas como o fluxo de partículas, a dose, a energia depositada em uma determinada superfície ou volume pré-definido.

O código MCNP (Monte Carlo N-Particle), um dos códigos computacionais que utiliza o método de MC, foi desenvolvido por Fermi, Von Neumann, Ulam, Metropolis e Richtmyer e frequentemente passa por revisões e manutenções sob supervisão do grupo de Física Aplicada do Laboratório Nacional de Los Alamos (Novo México, EUA), grupo este responsável por métodos, códigos e aplicativos de Monte Carlo. O código apresenta algumas versões de manuais, onde está detalhado todo o processo de funcionamento, dividido em quatro capítulos que abrange noções básicas à obtenção e interpretação dos resultados por meio de um arquivo resposta final ([LANL, 2003](#)).

Algumas versões do código MCNP foram desenvolvidas, em 1983 o código Monte Carlo N- Particle versão 3 (MCNP3) foi inteiramente reescrito utilizando FORTRAN 77 padrão ANSI e liberado para a comunidade científica ([Beserra, 2012](#)). No desenvolvimento dessa dissertação será utilizado o código Monte Carlo *N-Particle* Versão *eXtended* (MCNPX).

Em códigos computacionais utilizados para algumas simulações, os meios materiais são definidos como homogêneos e com densidade constante. Os átomos e moléculas estão

distribuídos de forma estática. Desse modo, efeitos dinâmicos do meio são desconsiderados

2.3.1 Código MCNP-X

O código computacional Monte Carlo *N-Particle eXtended* - MCNPX baseado no método de Monte Carlo (MC) é um código versátil e largamente utilizado no estudo do transporte da radiação e interação com a matéria, envolvendo nêutrons, fótons, elétrons e combinação entre eles, além de outras partículas ([LANL, 2003](#); [Beserra, 2012](#); [Teixeira, 2017](#); [Teixeira et al., 2018](#); [Teixeira et al., 2020](#), [Salgado et al., 2019](#)). Apresenta capacidade para o tratamento de sistemas com geometrias complexas tridimensionais e uma variedade de opções de comandos de entrada, tornando-se uma ferramenta multifuncional e poderosa quando aplicada na área de proteção radiológica, modelagens de equipamentos de medição da radiação, instalações nucleares, etc.

A faixa de energia para os fótons, elétrons e nêutrons que pode ser representado no código MCNP-X para cada tipo de radiação é ([LANL, 2003](#)):

1. Fótons: 1 keV a 100 GeV;
2. Elétrons: 1 keV a 1 GeV;
3. Nêutrons: 10^{-11} a 20 MeV para todos os isótopos e até 150 MeV para alguns isótopos.

Os dados de entrada do MCNP-X permitem ao usuário criar um arquivo de entrada de dados (INP), que é processado pelo código, contendo o detalhamento da geometria do problema a ser analisado, e é definido pelas seguintes etapas:

- a) *Descrição das células*: Contém as informações sobre o tipo de material e densidade de que cada célula é composta. Para esta representação, utilizam-se operadores booleanos (tais como: união e intersecção) com combinações de formas geométricas pré-definidas, tais como esferas e planos.
- b) *Descrição das Superfícies*: As formas geométricas básicas que compõem cada célula são definidas por caracteres mnemônicos indicando o tipo de superfície seguido de parâmetros que caracterizam seu posicionamento no espaço.
- c) *Descrição dos Dados Físicos*: A fonte de radiação é definida de acordo com sua geometria (pontual, plana, volumétrica), posicionamento no espaço, direção, tipo (isotrópica, *pencil beam*) e energia da radiação.

Os materiais utilizados na simulação são definidos, também neste bloco. É possível selecionar que tipos de partículas se deseja simular e a forma de como são analisadas pode ser modificada utilizando os comandos disponíveis que fornecem as grandezas de interesse (*tallies*), tais como: corrente de partículas, fluxo de partículas, deposição de energia e distribuição de altura de pulsos (DAP).

Algumas vantagens tornam este código uma ferramenta extremamente conveniente, versátil e poderosa, como:

1. A capacidade de tratamento de geometrias complexas tridimensionais;
2. Não requer do usuário conhecimento de linguagens de programação, tais como: FORTRAN, MORTTRAN, C++, etc;
3. O código MCNP-X apresenta novos modelos físicos de simulação e de técnicas de redução de variância foram adicionados, além de atualizações da extensa coleção de bibliotecas de seção de choque.

O processo de interação simplificada ocorre da seguinte forma, tomando como exemplo o evento de um fóton:

1. A seleção da distância (d) percorrida pelos fótons entre interações é aleatoriamente selecionada pela distribuição de probabilidade exponencial (ou logarítmica), por meio da Equação 8:

$$d = \frac{-1}{\mu (\ln \ln R)}$$

Equação 8

Onde:

μ – Coeficiente de atenuação linear total;

A – Número aleatório.

2. A seleção do tipo de interação, com números aleatórios, proporcional às seções de choque totais dos processos possíveis de ocorrer. Dependendo da interação, a escolha de uma nova trajetória da amostragem da seção de choque diferencial correspondente ao processo de interação selecionado anteriormente;

3. Se o código seguir também os elétrons gerados, para cada interação de um fóton é também gerada uma história para o elétron liberado;

4. Esta história terminará quando o fóton ultrapassar os limites das regiões que descrevem a geometria de contagem (escape), ou quando a energia do fóton ou do

elétron alcançar um valor mínimo (energia de corte) ou ainda quando a energia do fóton ou elétron for completamente absorvida.

O número de histórias especificado no código define a precisão e a flutuação estatística dos resultados. As respostas calculadas também são acompanhadas por um número que é o erro relativo estimado e é definido pela Equação 9 ([Pelowitz, 2005](#)).

$$R \equiv \frac{S_{\underline{x}}}{\underline{x}}$$

Equação 9

Onde:

$S_{\underline{x}}$: Desvio padrão estimado da média;

\underline{x} : Média estimada.

Em termos simples, este parâmetro pode ser usado para formar intervalos de confiança sobre o principal valor estimado. O erro relativo é utilizado para a avaliação da qualidade dos resultados e é proporcional ao número de eventos, conforme a Equação 10.

$$R = \frac{\sqrt{N}}{N}$$

Equação 10

Onde,

N : Número de eventos

Assim, para a redução do erro relativo à metade se faz necessário aumentar numa proporção de quatro vezes o número de eventos ou utilizar técnicas de redução de variância, quando o tempo computacional se tornar inviável.

2.3.2 Características dos materiais e modelagem matemática das incrustações

A modelagem pelo Método de Monte Carlo requer informações dos elementos formadores do sistema a ser analisado, com características mais próximas possível da realidade, que envolve a composição química dos materiais, conformação geométrica, inserindo-os nos dados de entrada do código computacional. Essas informações realísticas visam uma melhor qualidade na elaboração dos modelos matemáticos, aproximando os resultados teóricos dos reais. Na Tabela 3 estão descritos os materiais

selecionados nesse estudo, possibilitando obter as informações necessárias para atender os requisitos do código MNCP. As composições químicas estão expressas em fração mássica dos elementos que formam o sistema simulado. Esses materiais compreendem: Aço Inoxidável (*Beserra, 2012*), Água salgada à 4% de NaCl (*Hubbell e Seltzer, 1997*), Ar atmosférico, BaSO₄ como incrustação, Óleo cru (*Beserra, 2012; Teixeira et al., 2020*).

Tabela 3- Fração mássica e densidade dos materiais utilizados nas simulações

Elemento, Z	Ar	H ₂ O (4% NaCl)	Óleo	BaSO ₄	Duto
Argônio (Ar = 18)	0.012827	-	-	-	-
Nitrogênio (N = 7)	0.755268	-	-	-	-
Oxigênio (O = 8)	0.231781	0.852577	-	0.274212	-
Carbono (C = 6)	0.000124	-	0.3333	-	0.000410
Enxofre (S = 16)	-	-	-	0.137368	0.000150
Bário (Ba = 56)	-	-	-	0.588420	-
Silício (Si = 14)	-	-	-	-	0.005070
Fósforo (P = 15)	-	-	-	-	0.000230
Cromo (Cr = 24)	-	-	-	-	0.170000
Manganês (Mn = 25)	-	-	-	-	0.010140
Ferro (Fe = 26)	-	-	-	-	0.669000
Níquel (Ni = 28)	-	-	-	-	0.120000
Molibdênio (Mo = 42)	-	-	-	-	0.025000
Sódio (Na = 11)	-	0.015735	-	-	-
Hidrogênio (H = 1)	-	0.107423	0.6667	-	-
Cloro (Cl = 17)	-	0.024265	-	-	-
Densidade (g.cm ⁻³)	0.00123	1.0466	0.973	4.5	8

Para predição das espessuras das incrustações em uma tubulação pode-se utilizar um método matemático baseado em relações trigonométricas. Este método correlaciona informações internas do duto com diferentes posições do sistema de medição adotado, composto basicamente por fonte-detector cintilador. Os caminhos da radiação são imprescindíveis para a obtenção da espessura da incrustação e também são usados no cálculo matemático.

A disposição da geometria fundamental para o cálculo da espessura de incrustações concêntricas por meio de equações é exemplificada na Figura 11, indicando as posições dos elementos formadores do sistema fonte-detector e incrustação-fluido-tubulação (Beserra, 2012).

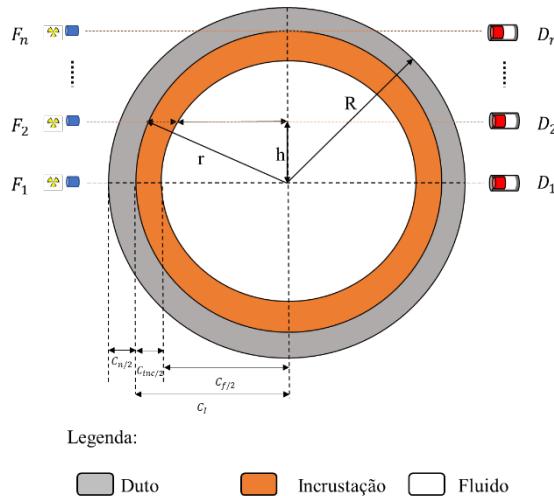


Figura 11 - Seção transversal do duto com as referências utilizadas para o cálculo do caminho da incrustação concêntrica.

Onde,

R : raio Externo do duto;

r : raio Interno do duto;

h : altura do passo de varredura do sistema fonte-detector determinado pelo raio de colimação da fonte;

F_n : Posição n fonte;

D_n : Posição n do detector;

C_d : caminho da parede do duto para a posição n da fonte/detector;

C_{inc} : caminho da incrustação para a posição n da fonte/detector;

C_f : caminho do fluido para a posição n da fonte/detector;

C_i : caminho na incrustação e fluido.

O duto, juntamente com os materiais que estão em seu interior, podem ser adotados como um sistema absorvedor composto de n camadas de materiais com diferentes espessuras e coeficientes de atenuação. A intensidade de I um feixe monoenergético de radiação γ transmitido pode ser estimado pela Equação 11.

$$I = I_0 * e^{-(\mu_d.C_d + \mu_f.C_f + \mu_{inc}.C_{inc})}$$

Equação 11

Onde,

I : Feixe transmitido;

I_0 : Feixe incidente;

n : Camadas de diferentes materiais absorvedores;

μ : Coeficiente de atenuação para os diferentes materiais absorvedores (cm^{-1});

C_d : Caminho da radiação no duto;

C_f : Caminho da radiação no fluido;

C_{inc} : Caminho da radiação na incrustação;

C_I : Caminho da radiação na incrustação e no fluido.

O cálculo para o caminho percorrido pela radiação em cada material que compõe o sistema estudado, em cada posição n do sistema fonte-detector segue as seguintes etapas:

1. Cálculo do caminho da radiação na parede do duto

O caminho que a radiação irá atravessar na parede do duto para cada posição n do sistema fonte detector, pode ser determinado por relação trigonométricas pela Equação 10.

$$C_d = 2 * [\sqrt{(R^2 - h^2)} - \sqrt{(r^2 - h^2)}]$$

Equação 10

2. Cálculo do caminho da radiação no fluido no interior do duto

O caminho que a radiação irá percorrer na incrustação e no fluido, correspondendo a C_I , dada pela Equação 11.

$$C_I = 2 * [\sqrt{(r^2 - h^2)}]$$

Equação 11

Logo, o caminho percorrido pela radiação no fluido para cada posição n do sistema fonte-detector pode ser obtido pela Equação 12.

$$C_f = (C_I - C_{inc})$$

$$\text{Equação 12}$$

Realizando a substituição das Equações 10 e 11 na Equação 13, temos:

$$C_{INC} = \frac{\ln \ln (K) + \mu_d \cdot C_d + \mu_f \cdot C_f}{-\mu_{inc} + \mu_f}$$

$$\text{Equação 13}$$

Onde:

K : refere-se a transmissão gama, dada pela razão I/I_0 , obtido tanto por medidas experimentais como por simulação no MCNP.

Na Figura 13 são os segmentos utilizados para o cálculo da espessura da incrustação com deposição concêntrica. O segmento AB representa a espessura da incrustação para uma determinada posição do sistema fonte-detector.

Vale ressaltar que em alguns pontos acima ou abaixo do eixo (0,0) do duto não haverá coincidência entre o caminho da incrustação com a espessura da incrustação, logo essas relações se fazem necessárias para medidas fora desse eixo central, caso haja essa coincidência, somente a Equação 8 pode ser utilizada.

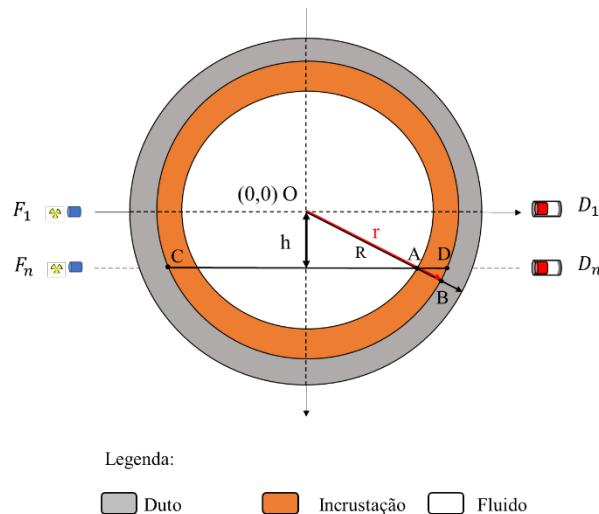


Figura 12 - Representação do cálculo da espessura da incrustação para deposição concêntrica.

Onde:

h : altura da posição n do sistema fonte-detector;

CD : segmento de reta para a posição n do sistema fonte-detector;

R : raio externo do duto;

r : raio interno do duto

AD : caminho da radiação da incrustação para a posição n do sistema fonte-detector;

AB : espessura da incrustação para a posição n do sistema fonte-detector;

F_n : Posição n fonte;

D_n : Posição n do detector NaI(Tl).

O ponto A pode ser obtido por coordenadas cartesianas, representadas por x_a e y_a . A coordenada y_a corresponde à altura 'h' que é o deslocamento do sistema fonte-detector. Assim, a coordenada x_a pode ser obtida para cada posição n por meio da Equação 14.

$$x_a = \left(\sqrt{R^2 - h^2} \right) - C_{inc}$$

Equação 14

Obtido o ponto A, pode-se obter as coordenadas cartesianas do ponto B por meio de um sistema. Onde sabe-se que:

$$y_a = (m \cdot x_a) + b$$

Equação 15

O coeficiente angular da reta AB é dado por m , e tomando como referência o centro da circunferência, a coordenada x_b pode ser obtida através de um sistema contendo as seguintes variáveis:

$$\left\{ \begin{array}{l} R^2 = x_b^2 + y_b^2 \quad (1) \\ y_b = m \cdot x_b \quad (2) \end{array} \right.$$

Substituindo (2) em (1), tem-se que:

$$x_b = \sqrt{\frac{R^2}{(1 + m^2)}}$$

Uma vez obtidas todas as coordenadas relacionadas a espessura da incrustação para uma determinada posição i do detector, o segmento AB pode ser obtido pela Equação 17.

$$AB_{concêntrica} = \sqrt{(x_a - x_b)^2 + \sqrt{(y_a - y_b)^2}}$$

Equação 17

A disposição da geometria fundamental para o cálculo da espessura de incrustações excêntricas por meio de equações também pode ser utilizada e é exemplificada na Figura 14, indicando as posições dos elementos formadores do sistema fonte-detector e incrustação-fluido-tubulação (Beserra, 2012).

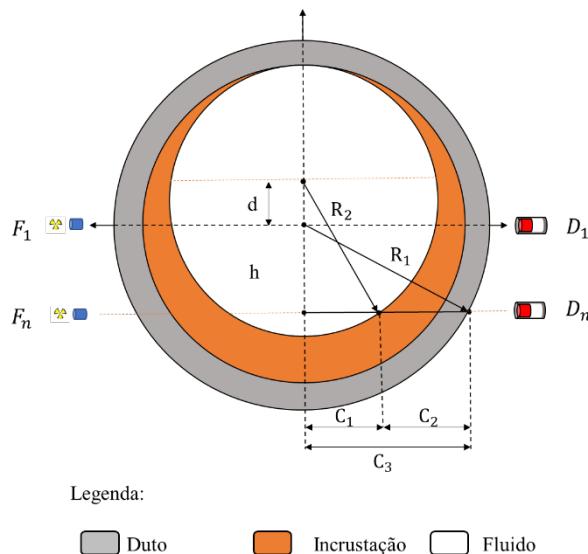


Figura 13 - Seção transversal do duto com as referências utilizadas para o cálculo do caminho da incrustação excêntrica.

Onde,

d : Deslocamento da circunferência referente ao fluido, que determinará a espessura máxima da incrustação;

h : Altura do deslocamento para posição n do sistema fonte-detector;

R_1 : Raio interno do duto;

R_2 : Raio interno da circunferência que limita a incrustação;

C_1 : Metade do caminho no fluido;

C_2 : Metade do caminho na incrustação;

C_3 : Metade do segmento do diâmetro interno do duto para a posição n do sistema fonte detector.

Pela Figura 18 é possível inferir:

$$h^2 = C_3^2 + R_1^2$$

Equação 18

Em que,

$$C_3 = \sqrt{R_1^2 - h^2}$$

Equação 19

e,

$$C_1 = \sqrt{R_2^2 - (h^2 + d)^2}$$

Equação 20

Sendo que C_2 , referente ao caminho da incrustação, pode ser obtido:

$$C_2 = (C_3 - C_1)$$

Equação 21

Logo,

$$C_{inc} = (C_2) * 2$$

Equação 22

e,

$$C_f = (C_1) * 2$$

Equação 23

Sendo,

$$C_d = (C_f - C_{inc})$$

Equação 24

Essas relações obtidas para a deposição do tipo excêntrica podem ser usadas para validação dos dados simulados obtidos por meio da Equação 13.

A espessura máxima da incrustação excêntrica pode ser obtida por meio das relações demonstradas na Figura 15 (*Beserra, 2012*).

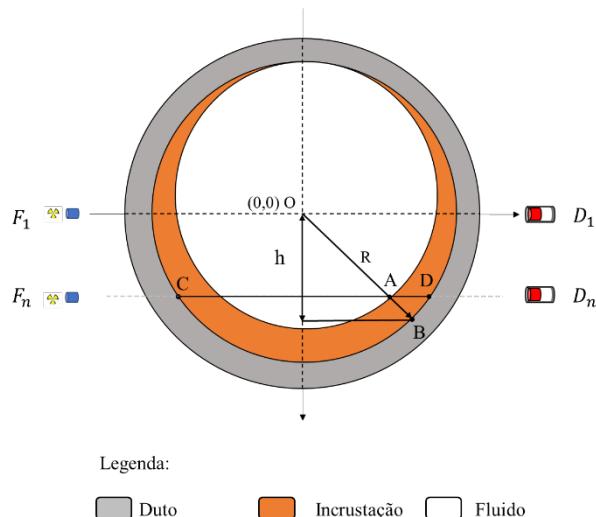


Figura 14 - Representação do cálculo da espessura da incrustação para deposição excêntrica.

Onde,

h : altura da posição n do sistema fonte-detector;

CD : segmento de reta para a posição n do sistema fonte-detector;

R : raio interno do duto;

AD : caminho da radiação da incrustação para a posição n do sistema fonte-detector;

AB : espessura da incrustação para a posição n do sistema fonte-detector;

F_n : Posição n da fonte;

D_n : Posição n do detector NaI(Tl).

Assim como para a incrustação concêntrica, o ponto A pode ser obtido por duas coordenadas, representadas por x_a e y_a . A coordenada y_a corresponde à altura 'h' referente ao deslocamento do sistema fonte-detector. Assim, a coordenada x_a pode ser obtida para cada posição n por meio da Equação 25.

$$x_a = \frac{CD}{2} - AD$$

Equação 25

Tomando o segmento AD, que é o caminho da radiação na incrustação, para a posição n do sistema fonte-detector, pode-se obter:

$$\frac{CD}{2} = \sqrt{R^2 - h^2}$$

Equação 26

De forma semelhante a obtenção das Equações 14 a 16, chega-se a mesma relação para obtenção do segmento AB, correspondendo a espessura da incrustação com deposição excêntrica:

$$AB_{excêntrica} = \sqrt{(x_a - x_b)^2 + \sqrt{(y_a - y_b)^2}}$$

Equação 27

2.4 Redes Neurais Artificiais (RNAs)

A transmissão do sinal de um neurônio a um outro no cérebro é um processo químico muito complexo, onde substâncias específicas são liberadas pelo neurônio transmissor. Esse processo é possível por meio do aumento ou queda do potencial elétrico no corpo da célula receptora que se alcançar o limite de ativação da célula, um pulso é enviado para outros neurônios. Logo, o neurônio está *ativo*. De forma semelhante uma RNA possui um sistema de neurônios artificiais, conhecido como unidades de processamento. Cada unidade realiza a computação baseada nas demais unidades que

estão conectadas a ela. Assim, uma RNA constitui-se de unidades de processamento interconectadas, chamadas neurônios artificiais. Cada neurônio é responsável pelo mapeamento de dados de “entradas e saídas” por meio de funções matemáticas (normalmente não-lineares).

As RNAs têm-se mostrado de fácil aplicação e eficientes, especialmente em problemas onde não há uma formulação analítica ou onde não é requerido um conhecimento prévio da distribuição das variáveis, ou ainda, quando o próprio problema se modifica constantemente com o tempo. O funcionamento de uma RNA pode ser descrito em duas etapas distintas:

- 1) Etapa de treinamento, chamada de fase *off-line*, é realizada pelo uso de um algoritmo de aprendizagem, onde é necessário que a RNA aprenda os padrões de um conjunto finito de exemplos previamente fornecidos;
- 2) Etapa de operação, chamada de fase *on-line*, na qual a RNA é usada para responder a novas situações. Nesta fase a RNA não precisa mais do conjunto de treinamento.

Devido à capacidade dos modelos de RNAs em aprender os padrões nos dados e generalizá-los, esses modelos foram acoplados a técnicas que utilizam fontes de radiação gama para interpretar as Distribuições de Altura de Pulsos (DAP) obtidas por detector de radiação para a identificação de regimes de fluxo e previsão de frações de volume em sistemas multifásicos (*Salgado et al., 2010*), para prever a densidade do petróleo e derivados (*Salgado et al., 2016*), para prever a espessura da incrustação inorgânica concêntrica em oleodutos (*Teixeira, 2017; Teixeira et al., 2018, Salgado et al., 2019*).

Os trabalhos citados mostram que as RNAs foram capazes de alcançar resultados satisfatórios, comprovando a viabilidade do uso desse tipo de abordagem para a solução dessa classe de problema. No entanto, nessas aplicações, conjuntos de dados relativamente pequenos foram usados, com apenas cerca de 100 exemplos, para treinar e testar as RNAs do tipo MLP (do inglês, *Multilayer Perceptron*). Além disso, na maior parte desses trabalhos, modelos simples de RNA foram usados, mais especificamente arquiteturas de Redes Neurais Rasas (do inglês, *Shallow Network Neural - SNN*) com poucas camadas de processamento interno. Conforme já mostrado na literatura (*Srivastava et al., 2015*), esses modelos de RNA rasas tendem a apresentar capacidade de aprendizagem e generalização inferior do que os modelos de aprendizagem profunda, que

são arquiteturas de redes neurais profundas (do inglês, *Deep Neural Networks* - DNNs) com múltiplas camadas de processamento interno. A capacidade superior dos modelos de redes neurais profundas destaca-se especialmente em problemas mais complexos, onde um grande conjunto de dados, com milhares de exemplos, é necessário para cobrir todo o espaço de busca do problema (Gheisari et., 2017).

2.4.1 Rede Neural Perceptron Multicamadas (MLP)

No século XX, foi proposto o primeiro modelo matemático do comportamento do neurônio natural por *McCulloch e Pitts em 1943*. Em 1949, o psicólogo Hebb apresenta um estudo detalhado sobre como os neurônios se adaptam para a percepção, memória e para o aprendizado (Hebb, 1949). O trabalho de Hebb sugere que a conexão entre os neurônios é favorecida pela repetição de estímulos persistentes a célula, fornecendo uma base neurobiológica para os novos paradigmas de aprendizado de rede neurais artificiais (Evsukoff, 2020).

O modelo matemático McCulloch e Pitts e a base teórica do aprendizado de Hebb foram base para o primeiro modelo de rede neural artificial em 1957, chamado Perceptron, desenvolvido em hardware para reconhecimento de padrões (Rosenblatt, 1957). O Perceptron introduz um algoritmo de ajuste de parâmetros com base na teoria de Hebb e é a uma das mais simples arquiteturas de RNA. Ela é baseada em um neurônio artificial (ver Figura 15) em que as entradas e a saída são números e cada conexão de entrada está associada a um peso. Dessa forma, seu cálculo é realizado por meio da soma ponderada de suas entradas ($w_1x_1 + w_2x_2 + \dots + w_nx_n = w^t \cdot x$), então aplica-se uma função degrau a esta soma e exibe-se o resultado: $h_w(x) = \text{step}(w^t \cdot x)$.

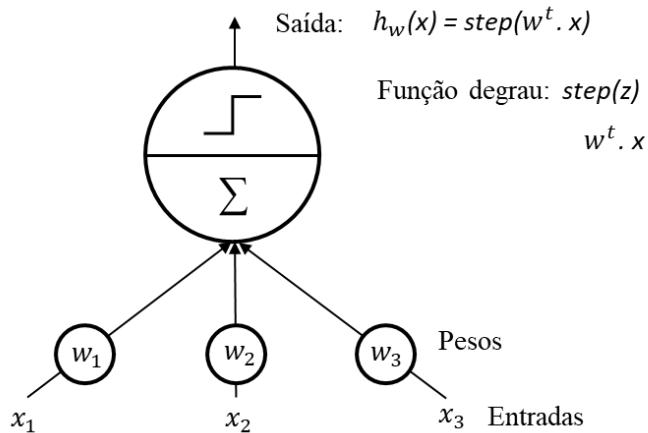


Figura 15– Rede Neural Perceptron.

Posteriormente, o algoritmo do Perceptron foi aprimorado por [Widrow e Hoff \(1961\)](#) para o modelo ADALINE (do inglês, *Adaptive Linear Neuron*), em que o ajuste dos parâmetros é obtido em função do erro da saída por meio da resolução dos mínimos quadrados iterativa (do inglês, *Least Mean Squares* – LMS). Esse algoritmo, o LMS, foi amplamente utilizado em projetos de filtros lineares e como solução iterativa de sistemas lineares em uma época limitada pela capacidade de processamento dos computadores ([Evsukoff, 2020](#)).

Em sua monografia intitulada *Perceptrons*, [Minsky e Papert \(1969\)](#) destacaram uma série de fraquezas dos Perceptrons, em particular o fato de serem incapazes de resolver alguns problemas triviais, demonstrando que o Perceptron só poderia ajustar funções lineares, salientando o problema de classificação XOR. Argumentaram, para que o Perceptron fosse capaz de lidar com funções não lineares seria necessário múltiplas camadas de Perceptrons. Assim, o livro teve um impacto negativo no desenvolvimento de redes neurais durante toda a década de 1970.

Durante toda a década de 1980, modelos de redes neurais e novos paradigmas de aprendizado foram estudados e desenvolvidos. Em 1982 aparecem os mapas autoajustáveis que inspiraram o desenvolvimento de uma gama de redes neurais ([Kohonen, 1982 e 1989](#)). Somente em 1986, após por muitos anos os pesquisadores se esforçarem para encontrar uma forma de treinar os Perceptrons de múltiplas camadas (do inglês, *Multilayer Perceptron* - MLP), [Rumelhart et al, \(1986\)](#) publicaram um trabalho inovador, apresentando o algoritmo de treinamento da Retropropagação.

O seu funcionamento consiste em alimentar cada instância de treinamento para a rede e calcular a saída de cada neurônio em cada camada consecutiva (*forward pass*). Após isto, o algoritmo mede o erro de saída da rede (diferença entre a saída desejada e a saída real da rede) e calcula o quanto cada neurônio contribui para o erro de cada neurônio de saída na última camada oculta. Em seguida, passa a medir a quantidade dessas contribuições de erro provenientes de cada neurônio na camada oculta anterior, e assim por diante, até o algoritmo alcançar a camada de entrada. Esta passagem reversa calcula de forma eficiente o gradiente de erro em todos os pesos de conexão na rede, propagando para trás o gradiente de erro na rede. Como último passo, o algoritmo de retropropagação é um incremento do Gradiente Descendente com o uso dos gradientes de erro medidos anteriormente em todos os pesos de conexão (Geron, 2019).

Para que o algoritmo de retropropagação funcione adequadamente, os autores fizeram uma mudança significativa na arquitetura MLP, substituindo a função degrau pela função logística, $\sigma(z) = 1/(1 + \exp(-z))$. Tal feito foi essencial porque a função degrau contém apenas segmentos planos, portanto não há gradiente com o qual realizar os ajustes (o Gradiente Descendente não pode me mover sobre uma superfície plana). No entanto, a função logística possui uma derivada não zero bem definida em todos os lugares, o que permite que o Gradiente Descendente faça seu progresso em cada uma das etapas. Além da função logística, o algoritmo de retropropagação pode ter seus neurônios ativados com outras funções, como a função sigmoide e sua variante tangente hiperbólica, $\tanh(z) = 2\sigma(2z) - 1$; a função linear, que é a mais simples em que o valor de ativação é igual ao potencial de ativação e mais recentemente proposta e a função linear retificada ReLU ($z = \max(0, z)$), que tem sido amplamente utilizada em redes neurais profundas (do inglês, *Deep Neural Network – DNN*) (Lecun et al, 2015).

A Figura 16 demonstra os elementos que compõe a arquitetura mais comum de uma RNA. Esta rede neural é conhecida como Rede Neural Progressiva (*Feedforward Neural Network*) em que um grafo é direcionado. A camada receptora dos dados é a camada de entrada e a que produz o resultado final é chamada de camada de saída. Entre as camadas de entrada e saída ocorre o processamento dos dados e é realizado pelos elementos internos chamados de camada oculta. Após o processamento (treinamento), a rede é capaz de realizar um mapeamento de vetores no espaço D-dimensional para vetores no espaço C-dimensional (Bezerra, 2016).

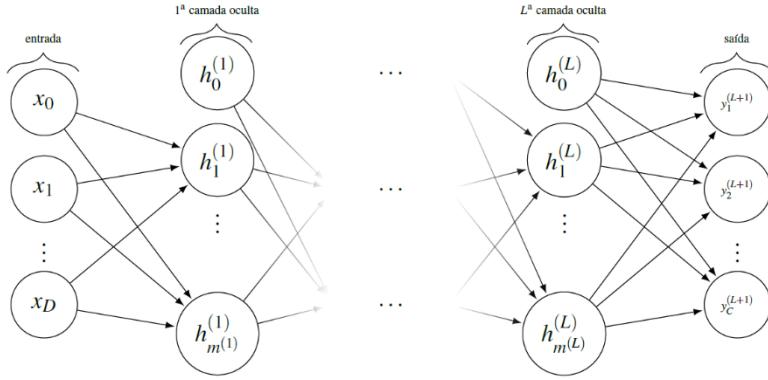


Figura 16 - Esquema de uma RNA com $(L+1)$ camadas, D unidades na camada de entrada e C unidades na saída. A L -ésima camada oculta contém $M^{(L)}$ unidades (Bezerra, 2016)

2.4.2 Rede Neural Profunda (DNN)

A aprendizagem profunda é uma subárea da Aprendizagem de Máquina (do inglês, *Machine Learning*) que se dedica à investigação de técnicas para simular o cérebro humano submetido a tarefas complexas como reconhecimento visual, reconhecimento de fala e processamento de linguagem natural. Objetivo dos algoritmos de aprendizagem de profunda é reproduzir representações hierárquicas de alto nível dos dados de entrada, com auxílio de camadas de processamento sequencial em uma rede neural artificial.

No ambiente de aprendizagem de máquina, uma característica (*feature*) é uma propriedade mensurável de um fenômeno de interesse (Bishop, 2006). Diante disso, transformações de uma representação de dados para outra com um conceito mais alto e que possa ser aproveitada por algoritmos de aprendizado são úteis. Tradicionalmente, os algoritmos de aprendizado de máquina inferem que o conjunto de dados usados no treinamento foi primeiramente construído com auxílio de um processo de engenharia de características. Neste processo, os atributos (características) que compõe o conjunto de dados são selecionados manualmente pelo operador. A escolha de características relevantes e discriminativas é substancial para que se gere modelos de aprendizado adequados. No entanto, esse processo está suscetível a erros quando não se tem domínio no estudo em questão, sendo fundamental selecionar adequadamente os atributos para compor o conjunto de dados de treinamento. Técnicas de *aprendizado de representação* (Bengio et al., 2013) são possíveis soluções para solucionar esse problema, uma vez que

o próprio algoritmo de aprendizado identifica automaticamente um subconjunto de características adequado.

As DNNs têm o mesmo conceito básico de suas contrapartes superficiais, tendo a capacidade de aprender com os exemplos e modelar relações não lineares complexas entre esses exemplos. No entanto, a principal diferença e vantagem das DNNs é que esses modelos têm muitas camadas de unidades de processamento parametrizadas não lineares (chamadas de camadas ocultas) separando as camadas de entrada e saída, enquanto, em contraste, as SNNs têm poucas camadas ocultas. Além disso, o maior número de camadas permite que o processo de aprendizagem dos DNNs opere com base no conceito de aprendizagem hierárquica (mais comumente chamada de aprendizagem profunda), que é mais semelhante à como funciona o córtex visual do cérebro, ou seja, hierarquicamente (Lewis *et al.*, 2000). Assim, neste conceito de aprendizagem, as representações das características complexas de um problema são expressas em termos de representações mais simples, uma vez que cada camada sucessiva de uma DNN usa a saída da camada anterior como entrada. Essa abordagem permite que as DNNs sejam capazes de lidar com problemas extremamente complexos (Benuwa *et al.*, 2016).

2.4.3 A questão do desaparecimento do gradiente e as Redes Neurais Profundas Retificadas (DRNN)

O principal impasse para que redes de aprendizagem profunda pudessem ser treinadas com algoritmos consolidados de retropropagação de gradiente (Haykin, 2007) é o problema chamado de desaparecimento do gradiente. Este impedimento ficou tão conhecido que foi intitulado de “o problema fundamental do *Deep Learning*” (Schmidhuber, 2015). Apesar da problemática real que as redes neurais profundas enfrentavam, esse problema só foi contornado de maneira eficaz com a utilização das *redes neurais progressivas*⁵ (do inglês, *Feedforward*) com a introdução de funções de ativação retificadas (Glorot *et al.*, 2011).

O problema do gradiente surge quando, no treinamento das redes neurais profundas, que faz uso de métodos baseados em gradiente para o aprendizado das redes, os valores de pré-ativação neural tornam-se elevados e o gradiente, calculado por meio da derivada

⁵ *Redes Neurais que utilizam como fundamento sinais que se propagam pelos neurônios em apenas um sentido, fundamentalmente da entrada para a saída.*

do erro, nas camadas tornam-se baixos (saturação do neurônio). Dessa forma, o gradiente, usado para o cálculo e ajuste de pesos, tende a zero, à medida que o erro vai sendo retropropagado pelas camadas. Assim, as primeiras camadas ocultas da DNN terão gradiente muito baixo, desprezível, e sua influência no ajuste dos pesos será pequena, tornando o processo de aprendizagem lento e impraticável (Pinheiro, 2020). Consequentemente, essas redes são bastante afetadas pelo desaparecimento de gradiente à medida que se desenvolvem em profundidade (observar Figura 17), saturando muito rapidamente em 0 (retardando todo o processo de aprendizagem), mas, em seguida, dessatura lentamente por volta da época 100.

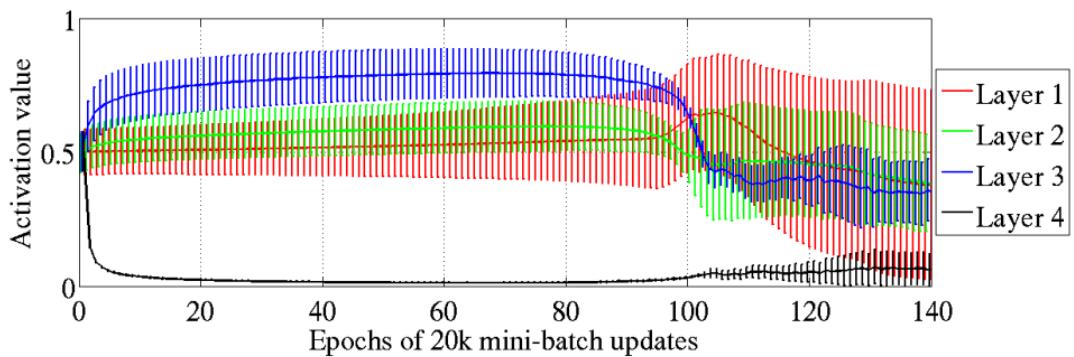


Figura 17 - Média e desvio padrão (barras verticais) dos níveis de ativação (saída: função sigmoide) durante a aprendizagem supervisionada para as diferentes camadas ocultas de uma arquitetura profunda (Glorot e Bengio, 2010).

Glorot & Bengio (2010) demonstram por meio de um estudo extenso a respeito de redes neurais profundas com funções de ativação sigmoides que, de fato, a ativação de neurônios nas camadas mais profundas da rede tende a zero (Figura 18), mostrando que a partir da camada 4 o valor da ativação fica próximo de zero muito rapidamente. Quando isso ocorre, se está efetivamente minimizando o efeito do peso no neurônio, zerando o aprendizado dos pontos ligados àquele neurônio saturado, tornando o desempenho ruim, com treinamento prejudicado que converge tipicamente para mínimos locais (Pinheiro, 2020).

Com o intuito de contornar o problema do desaparecimento do gradiente, um novo tipo de arquitetura de aprendizagem, portanto, foi proposto por Glorot et al. (2011). Eles a intitularam de Rede Neural Profunda Retificada (do inglês, *Deep Rectifier Neural*

*Network – DRNN) que fundamentalmente utiliza uma função de ativação retificada linear, conhecida como ReLU (do inglês, *Rectified Linear Unit*) (Glorot e Bordes, 2010).*

Na Figura 18 são apresentados três gráficos das três funções de ativação e seus gradientes mais comumente encontrados em algoritmos de aprendizagem. Conforme já explanado, a função ReLU apresenta comportamento linear no domínio positivo, não sofrendo com o problema do desaparecimento do gradiente, favorecendo o bom desempenho do mesmo durante a retropropagação.

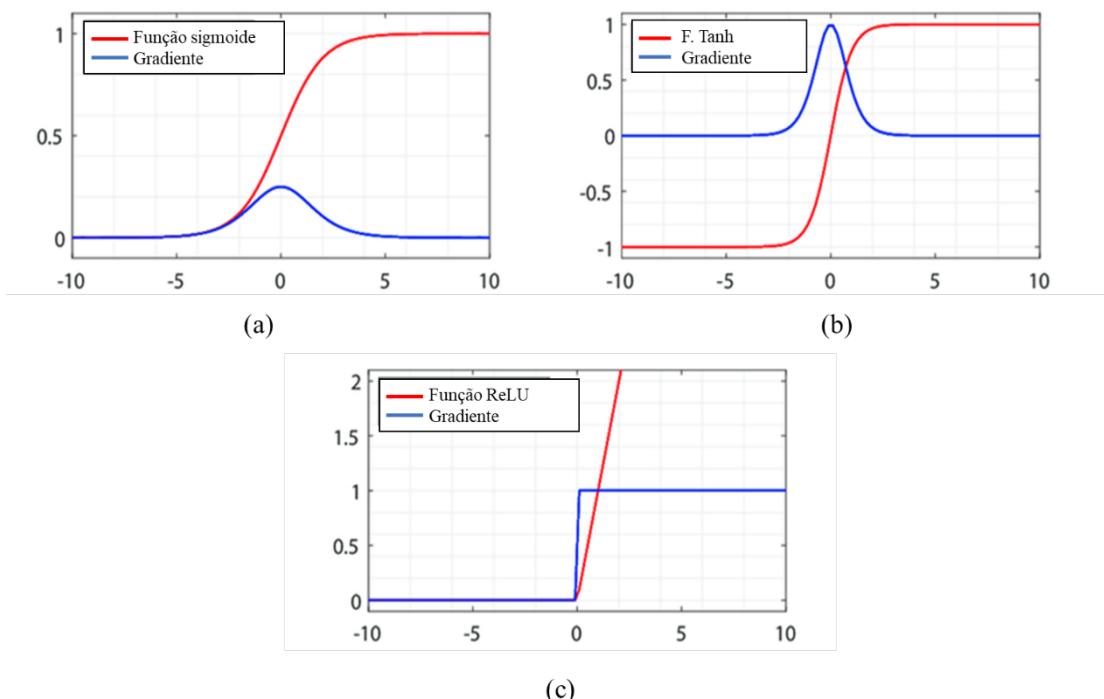


Figura 18 – Funções de ativação mais comumente usadas em algoritmos de aprendizagem.

Os autores ainda afirmam que a função de ativação ReLU é esparsiva, o que se assemelha ao funcionamento do neurônio biológico, ao computar o funcionamento do cérebro humano. Argumentam que uma esparsividade biológica é de 95% a 99% e que a ReLU apresentou resultados bastante esparsos, de 50% a 80% de dispersão para os melhores modelos de generalização, o que pode explicar alguns dos benefícios do uso de retificadores.

Portanto, as DRNN são redes neurais profundas progressivas ativadas nas camadas internas por funções retificadas, como a ReLU (Pinheiro, 2020). Naturalmente, devido ao sucesso na aplicação dessa função de ativação, outras funções retificadoras similares

foram propostas na literatura como a ELU (do inglês, *Exponential Linear Units*) ([Clevert et al., 2015](#)), SELU (do inglês, *Scaled Exponential Linear Units*) ([Klambauer et al., 2017](#)), LReLU (do inglês, *Leaky-Rectified Linear Units*) ([Maas et al., 2013](#)), PReLU (do inglês, *Parametric Rectified Linear Units*) ([He et al., 2015](#)), Swish ([Ramachandran et al., 2017](#)), etc. ([Nwankpa, 2018](#)). Apesar da aplicabilidade específica destas na resolução de problemas pontuais, a maioria das aplicações para resolução de aprendizagem profunda utiliza a ReLU, por apresentar resultados consistentes e satisfatórios.

Estudos comparativos conduzidos por [Glorot et al.](#) demonstrou que as DRNNs têm melhor treinamento e capacidade de generalização do que as DNNs ativadas pela função sigmoide. Os resultados alcançados foram considerados pelos autores um novo marco na o desempenho das DNNs quando aplicado a problemas de aprendizagem supervisionada. Ao longo destes estudos, trabalhos mais recentes ([Pedamonti, 2018; Santos et., al 2019; Desterro et., 2020; Pinheiro et al., 2020](#)) ratificam os resultados de [Glorot et al.](#), mostrando que as DRNNs são capazes de alcançar maior precisão de predição e menor taxa de erro do que as DNNs ativadas pela função sigmóide em diferentes tarefas de aprendizagem supervisionada.

Levando em consideração os aspectos discutidos, neste estudo, a DRNN foi o modelo de DNN selecionado para lidar com a tarefa de prever a espessura e localização da incrustação.

2.5 Caracterização Química de amostras de incrustações

A análise química de minerais e rochas, incluindo borras e incrustações inorgânicas da indústria petrolífera, pode ser realizada por várias técnicas analíticas. A análise química quantitativa de minerais, na primeira metade do século XX, era feita apenas por técnicas analíticas por via úmida, onde o material era dissolvido adequadamente e a determinação dos elementos em solução era realizada por calorimetria, por análises gravimétricas ou volumétricas.

Atualmente, é raro encontrar tais procedimentos em laboratórios comerciais ou indústrias. Estes procedimentos vêm sendo substituídos cada vez mais por técnicas instrumentais modernas, tais como espectrometria de absorção atômica, espectrometria de massa, fluorescência e difração de raios X, cromatografia de íons, entre outros. Em todos esses métodos de análise são apresentados os resultados dos percentuais em peso

dos elementos ou dos óxidos que compõe o mineral analisado. Técnicas instrumentais são geralmente mais eficazes, principalmente quando se tem um número elevados de amostras a serem analisadas com um número específico de elementos presentes (Nadkarni, 1991; Klein e Hulbert, 1999)

A determinação da composição química de borras e incrustações pode ser realizada por fluorescência de raios X (Schmidt, 1998; Zielinski et al., 2001; Hamlat et al., 2003, Gazineu, 2005; Sena, 2008; Candeias, 2014; Oliveira, 2019) e por difração de raios X (Iyengar, 2000; Gazineu, 2005). Nos dois métodos, as amostras são trituradas, prensadas (no caso da fluorescência de raio X) e levadas para a medida no equipamento. O objetivo da análise está na identificação dos elementos e compostos presentes nas incrustações e borras, além da investigação de sua natureza e origem.

As principais vantagens dessas duas técnicas para esta finalidade, em comparação a técnicas de análise convencionais, estão na pouca preparação da amostra, tempo curto de análise, facilidade na análise de amostras sólidas, dispensando a necessidade de preparos longos com solventes ou materiais quimicamente danosos.

2.5.1 Espectrometria da Fluorescência de Raios X

O princípio físico para a obtenção de um fóton de raio X por fluorescência baseia-se na emissão de energia por partículas excitadas. Esse processo ocorre quando essas partículas perdem energia na forma de fótons durante a transição de um nível energético mais alto para um de menor energia (relaxação), conforme ilustrado na Figura 19.

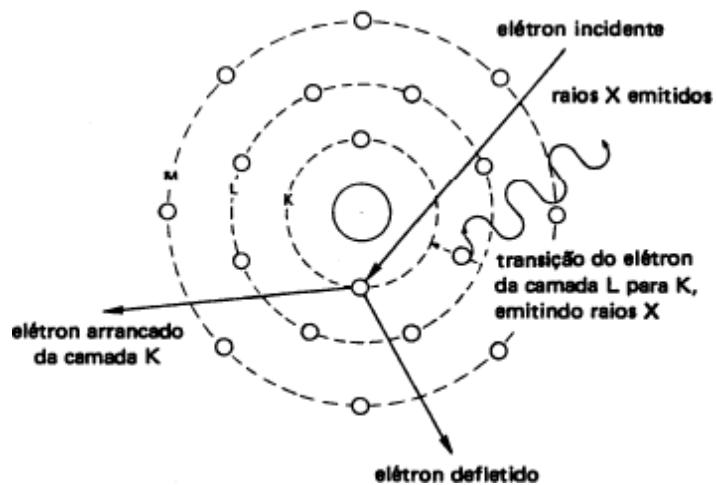


Figura 19 - Representação de salto quântico de um elétron (Padilha, 2000)

Para que ocorra o fenômeno da fluorescência de raios X, o corpo deve ser excitado por uma fonte de energia. Isto pode ocorrer através de partículas aceleradas como elétrons, prótons ou íons, raios X, partículas alfa, partículas beta negativas ou raios gama emitidos por radionuclídeos, além de raios X gerados em tubos. Com o desenvolvimento do detector semicondutor de Si(Li), capaz de discriminar raios X de energias próximas, foi possível o surgimento da fluorescência por dispersão de energia (ED-XRF, energy dispersive X ray fluorescence), também conhecida como fluorescência de raios X não dispersiva, com instrumentação menos dispendiosa e emprego mais prático. (Nascimento Filho, 1999)

Os equipamentos que utilizam a técnica de fluorescência de raio X atualmente utilizam tubos que geram fótons de raios X nos quais bombardeiam a amostra fazendo com que “floresçam” os raios X característicos de cada elemento, como podemos ver representado na Figura 20.

A presença de um elemento é identificada pelo comprimento de onda ou energia de emissão de raio X característico do elemento. O teor de um elemento presente é quantificado pela medição da intensidade dessa emissão de raio X característica do mesmo.

O processo de EDXRF começa quando o tubo de raio X ou fontes radioativas emissoras de raios X ou raios gama que sejam capazes de fornecer energias adequadas para provocar o efeito fotoelétrico irradia uma amostra. Os átomos na amostra são atingidos com raios X de energia suficiente, por exemplo, maiores que a energia de ligação dos átomos nas camadas K ou L (camadas mais comuns), causando a ejeção de um elétron da camada K ou L do átomo (Figura 20). Um elétron em uma camada superior preenche o espaço na camada K ou L emitindo energia e “pulando” para esse nível energético mais baixo. Quando o elétron cai para a camada K ou L inferior ele emite um fóton em um comprimento de onda específico para a estrutura do átomo (uma característica do raio X). O fóton emitido (raios X) são medidos um detector de energia dispersiva no Espectrômetro XRF Portátil. O detector e a eletrônica associada medem a energia de cada raio X e conta o número de raios X por segundo nessa energia. Um espectro de raio X consiste em energia ao longo do eixo horizontal e a intensidade (contagens/s) ao longo do eixo vertical.

(Parreira, 2006)

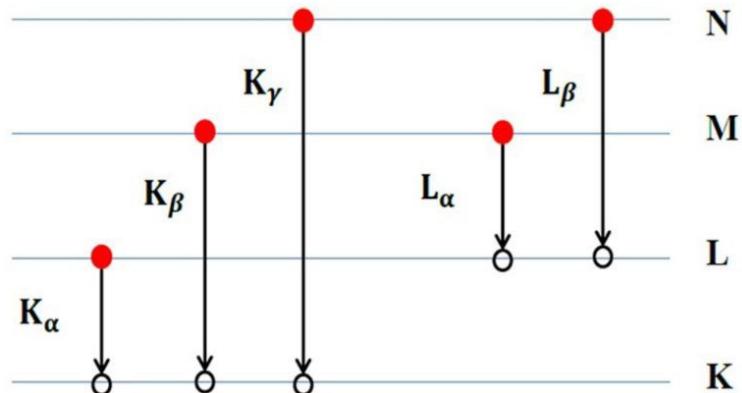


Figura 20 - Diagrama de energia para as camadas das linhas K e L.

(dos Anjos e Dias, 2017)

A base da espectroscopia de fluorescência de raios X é a caracterização de elementos químicos através de sua emissão característica de fótons de raios X quando são excitados com energias apropriadas. Esse projeto utilizou dos tipos de espectrômetros de fluorescência de raio X para a caracterização de amostras. A

Figura 21 mostra um exemplo de um esquema de espetrômetro acoplado a um computador para gerar um resultado (espectro).

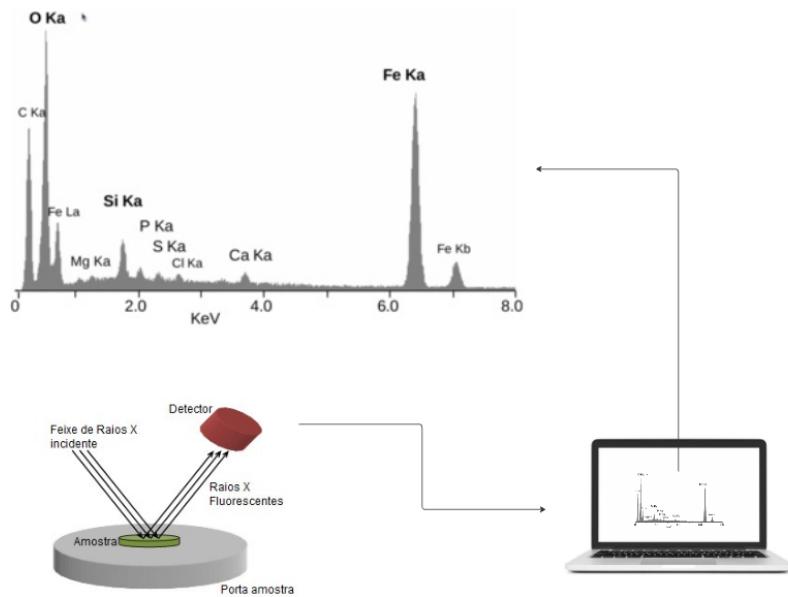


Figura 21 – Exemplo de esquema de um conjunto Espectrômetro + computador

2.5.2 Difratometria de Raios X

A difração de raio X é a principal técnica para determinação da estrutura cristalina de materiais de engenharia. Essa técnica consiste em caracterizar a microestrutura de materiais cristalinos identificando estrutura principal da mistura de seus compostos. Sua aplicação tem extrema importância no campo de ciência dos materiais, metalurgia, química dos materiais etc.

Os raios X ao atingirem o material podem ser espalhados elasticamente, sem perda de energia pelos elétrons de um átomo, conhecido como espalhamento coerente (Espalhamento Rayleigh). O fóton de raio X após a colisão com o elétron muda sua trajetória, mantendo, porém, a mesma fase e energia do fóton incidente. Sob o ponto de vista da física ondulatória, pode-se dizer que a onda eletromagnética é instantaneamente absorvida pelo elétron e reemitida: cada elétron atua, portanto, como centro de emissão de raio X, como podemos ver na Figura 22 (Cullity, 1956).

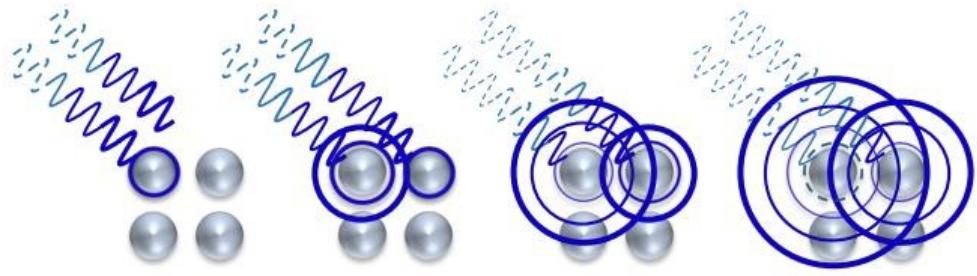


Figura 22 – Fenômeno de difração de raio X em um material cristalino ([Dhanjal; Young; Storer, 2006](#))

Sabemos que a maioria dos materiais possuem um arranjo cristalino periódico em sua estrutura, com isso seus átomos estão dispostos em um padrão onde apresentam distâncias próximas ao comprimento de onda da radiação incidente verificando uma relação de fase entre os espalhamentos. Essa relação é periódica e torna a difração de raio X possível de ser observada em vários ângulos.

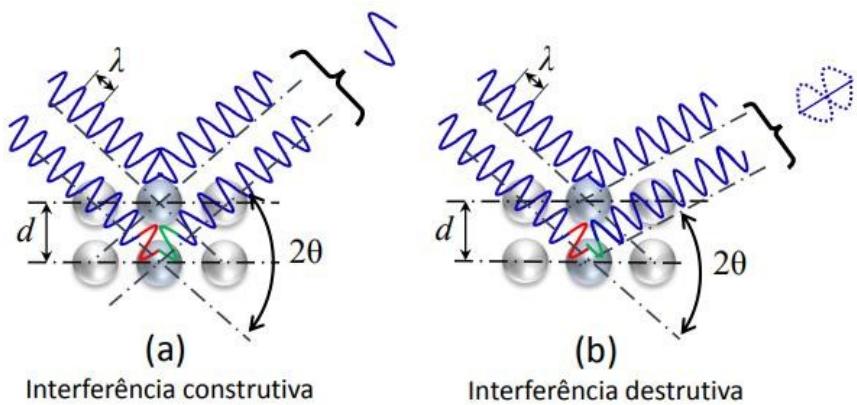
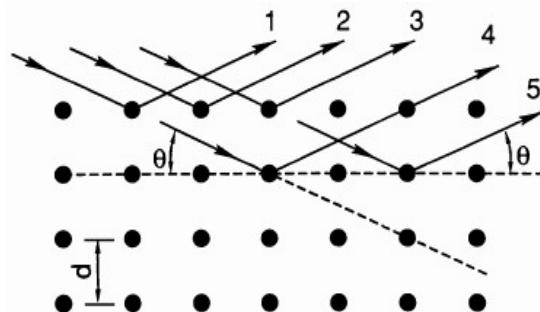


Figura 23 - Fenômeno de interferência em raios X ([Dhanjal; Young; Storer, 2006](#))

Tomando dois ou mais planos de uma estrutura cristalina então é possível entender que haverá difração de raio X quando as reflexões produzem interferências construtivas (Figura 23a) ou de mesma fase formando assim os feixes difratados. Outro fator importante é o comprimento de onda da radiação incidente e a diferença de caminho percorrido pelo raio X. *William Lawrence Bragg* demonstrou a relação

que passou a ser conhecida como *Lei de Bragg*, fundamental para o estudo de estruturas cristalinas com o uso da difração de raios X.



Equação da Lei de Bragg

$$n \lambda = 2 d \sin \theta$$

Figura 24 – Representação da lei de Bragg

(Padilha, 2000 - adaptado)

Como podemos ver na equação da figura 24, o λ corresponde ao comprimento de onda da radiação incidente, d é a distância interplanar para o conjunto de planos hkl (*Índice de Miller*) para dada estrutura cristalina, e θ é o ângulo de incidência dos raios X (que é medido entre o feixe incidente e os planos cristalinos) e n é um número inteiro referente a interferência construtiva.

CAPÍTULO III

3- MATERIAIS E MÉTODOS

Neste capítulo será apresentada as etapas seguidas para obter os objetivos propostos. Será abordada a descrição da modelagem dos tipos de incrustações levando em consideração os perfis mais comuns de deposição, além do detalhamento teórico do cálculo analítico das espessuras desses depósitos. Em seguida, será realizada a validação matemática dos modelos e a avaliação da potencialidade do MCNPX como ferramenta computacional para auxiliar a predição das incrustações. Após isto, bancos de dados contendo informações dos modelos de incrustação serão gerados para alimentar redes neurais projetadas.

Os bancos de dados contemplam duas subetapas, um com dados de simulações simplificadas, onde o intuito é a avaliação do uso da RNA para predição de incrustações; e um outro com dados de simulações mais complexas. O objetivo deste último é obter informações com maior grau de confiabilidade, em condições que se aproximam das condições reais de operação em ambientes petrolíferos.

Além disso, foram estudadas e aplicadas técnicas para caracterização e quantificação de elementos formadores de uma amostra de incrustação real, obtida por meio de uma tubulação descomissionada. As informações obtidas pelas técnicas foram inseridas nos arquivos de entrada (*input* do MCNPX) da modelagem final, visando trazer mais realismo para o material que compõe a incrustação nos modelos MCNP.

3.1 Etapas preliminares para a determinação das espessuras das incrustações

Alguns estudos preliminares foram realizados com o objetivo de avaliar a potencialidade do código MCNPX e das RNAs na solução dos problemas de cálculo de espessuras de incrustações em sistemas com diferentes regimes de fluxo; algumas geometrias foram avaliadas objetivando a obtenção de um sistema que balanceie o menor número de detectores e potencialize o tempo de medida, além de apresentar uma boa estatística de erro nos cálculos e identifique corretamente as possíveis espessuras de incrustações presentes.

Portanto, para atingir o sucesso do objetivo proposto neste trabalho, foram seguidos os seguintes passos:

- i. Desenvolvimentos de modelos simulados com regime de fluxo simplificado (homogêneo) utilizando o código computacional MCNPX para calcular as espessuras de incrustações concêntricas e excêntricas a partir de equações analíticas;
- ii. Validação matemática dos modelos simulados, levando-se em consideração diferentes tipos de deposição;
- iii. Desenvolvimento e aprimoramento de uma metodologia para predição de espessuras de incrustações baseada em RNAs utilizando uma geometria simulada pré-definida (04 posicionamentos internos da incrustação), tornando a solução do problema um pouco menos dependente de parâmetros internos ao duto;
- iv. Desenvolvimento de uma metodologia para prever as espessuras da incrustação e predizê-las por meio de DNNs;
- v. Aprimorar o modelo anterior por meio da junção de geometrias com incrustações concêntricas e excêntricas geradas de forma randômica (aleatória) com as informações reais de composição da incrustação.

3.2 Modelos simulados simplificados e validação matemática

Utilizou-se o código MCNPX (conforme mencionado este código é apropriado para simular a absorção e espalhamento de raios gama a partir de uma fonte de radiação em diversas geometrias) para o desenvolvimento de modelos simulados aproximado e representativo da espessura da incrustação visando calcular as espessuras destas em sistemas com regime de fluxo homogêneos e anulares. Nessa geometria considerou-se uma fonte de radiação gama e um detector homogêneo de NaI com 2”x2” (polegadas) posicionado a 1,0 cm do tubo, entre eles uma tubulação de ferro medindo 1,0 cm de espessura e 27,0 cm de diâmetro externo.

Foi utilizado um feixe de fôtons pontual com emissão unidirecional (*pencil beam*), como pode ser observado na Figura 24. Os materiais empregados nesses modelos foram sulfato de bário e como fluídos: ar atmosférico, água salgada e óleo cru. Na Figura 23 (a) e (b), o fluido presente é o óleo cru e este foi escolhido porque os coeficientes de atenuação linear total são tabelados apresenta características semelhantes ao petróleo.

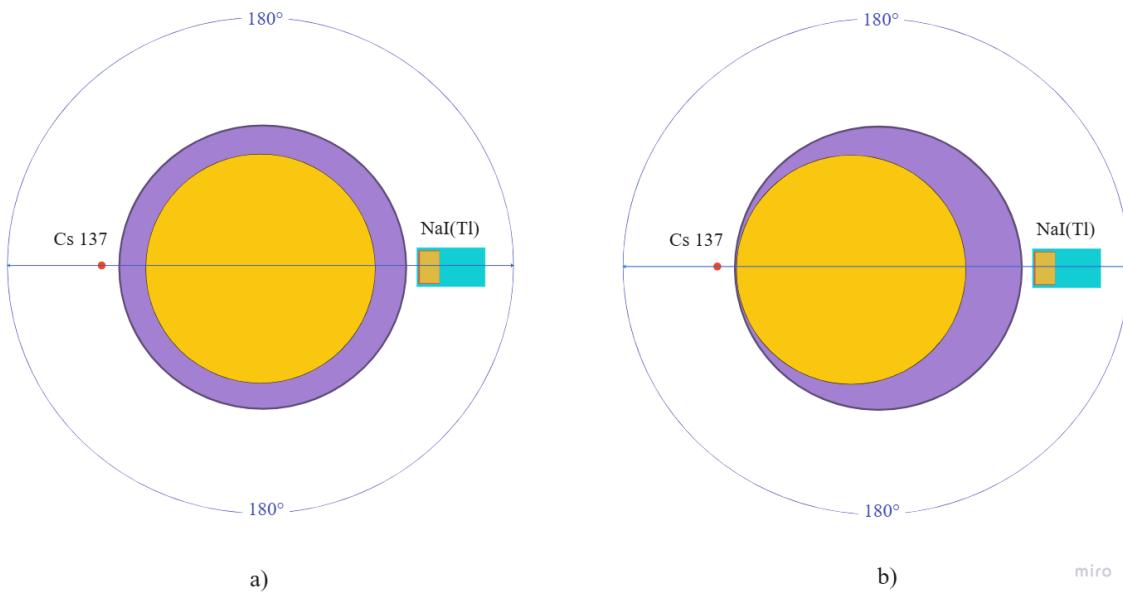


Figura 24 – Geometria simulada para incrustações com regimes de fluxo:
 a) homogêneo (concêntrica), b) homogêneo (excêntrica)

Regime homogêneo para validação matemática: a geometria de medição utilizou a energia de 662 keV (energia normalmente usada nas medidas tradicionais de incrustações em tubulações), conforme Figura 24 (a) e (b). As variações utilizadas nos modelos foram as espessuras de incrustações de 0 cm a 13 cm, contemplando casos de nenhuma incrustação e tubo quase totalmente incrustado. Essa variação das espessuras propõe uma diminuição proporcional do raio de fluxo do óleo, sendo estes inseridos diretamente na simulação por meio do arquivo de entrada (INP) desenvolvido no código MCNPX. As espessuras das incrustações, pertinentes para cada meio de interesse descritos na seção 2.3.2 e, podem ser obtidas pelo código MCNPX e a partir das equações 13 e 17 (incrustação concêntrica) e 13 e 27 (incrustação excêntrica) também descritas na mesma seção.

Os valores dos coeficientes de atenuação linear total, μ , para cada meio na energia de 662 keV foram calculados pela Equação 11, a partir dos dados de contagem obtidos no volume sensível do detector fornecidos pelo código MCNP ([Salinas, 2006](#)) com a tubulação preenchida com apenas um dos materiais: incrustação, água salgada, ar ou óleo. As intensidades dos raios gama foram obtidas por meio do código MCNPX e a

partir das equações mencionadas (13, 17 e 27) foi possível obter as espessuras de incrustação, tanto concêntrica como excêntrica.

Essas etapas são necessárias para que se possa validar os modelos desenvolvidos no código MCNPX aplicando as equações analíticas específicas para o cálculo das espessuras da incrustação com feixe unidirecional (*pencil beam*).

3.3 RNA na predição das espessuras de incrustações

Após validação matemática dos modelos mostrados e descritos na seção 3.1, e de forma a analisar a resposta da RNA na predição das espessuras das incrustações, foram realizadas simulações tendo como base a geometria apresentada nas Figuras 24. Essas geometrias, geradas a partir do código MCNPX, foram utilizadas para obtenção dos conjuntos de treinamento e teste das RNAs projetadas nesta etapa. Ambas são alimentadas com dados que representam casos mais realísticos de regime de fluxo em tubulações de petróleo.

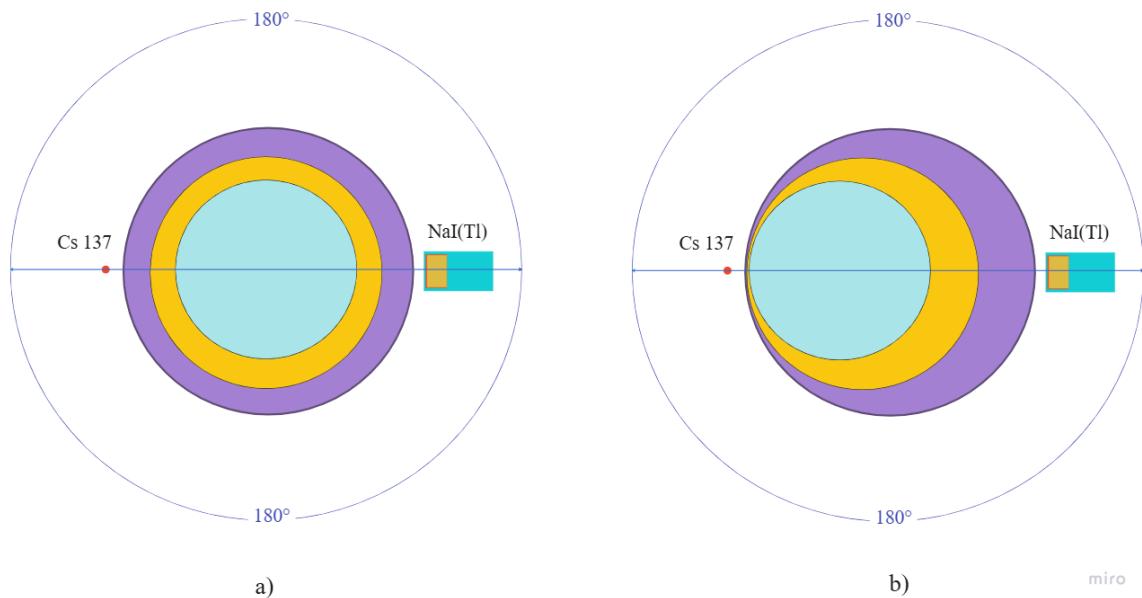
O sistema de medida adotado nos modelos de simulação contempla uma geometria mais complexa, incluindo outros fluidos (Água à 4% de NaCl e ar atmosférico, além do óleo cru), tornando o número de variáveis (3 meios) maior do que o sistema homogêneo (apenas um meio). Desta maneira, a solução analítica incluiria mais dois procedimentos de cálculo também descritos na seção 2.3.2.

De forma a analisar gradualmente o desempenho da RNA na predição das incrustações e tornar a predição das espessuras menos dependente de cálculos analíticos e informações internas da tubulação, dois modelos foram elaborados: o modelo 1 e o modelo 2. O modelo 1 foi projetado de forma a representar os dois tipos mais comuns de deposição, excêntrica e concêntrica, conforme Figura 24 (a). Nesse modelo, é avaliada somente a contribuição da transmissão gama no detector, localizado à 180° da fonte radioativa. Dessa forma, a posição da deposição máxima (no caso da incrustação excêntrica) é conhecida, possibilitando o ajuste geométrico da fonte e detector na região de medida desejada.

A deposição do tipo excêntrica se caracteriza por apresentar uma região de maior espessura de incrustação e, em casos reais, é um parâmetro indefinido, acarretando na complexidade de sua determinação e medida. Visando contornar esse problema, o modelo 2 é baseado somente no estudo da incrustação do tipo excêntrica, contemplando contribuições de transmissão e espalhamento gama em todo o sistema (duto, incrustação

e fluidos) a ser medido, com detectores distados à 90° , 180° e 270° da fonte radioativa, conforme mostrado na Figura 24 (b).

Modelo 01



Modelo 02

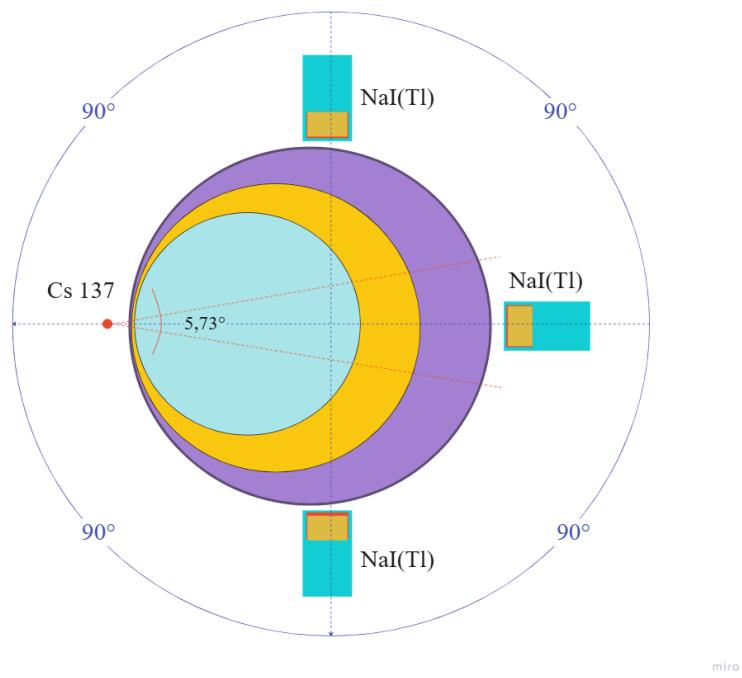


Figura 25 – Geometria de simulação para o modelo 1 (a) e modelo 2 (b)

Assim, visando a melhoria do modelo 1, o modelo 2 obteve a inclusão dos princípios de medidas de radiação transmitida e espalhada adotando um feixe divergente (*fan beam*) como tentativa de maximizar a “visualização” da área da seção transversal do tubo, tornando a obtenção da espessura da incrustação menos dependente de informações internas ao duto.

Para isso, foi realizada simulações com auxílio do código MCNPX considerando detectores homogêneos (*Sood e Gardner, 2004; Salgado et al., 2008, Oliveira et al., 2014, Bessera, 2012*) de iodeto de sódio ativado com tálio (NaI(Tl)) na forma de um cilindro equilátero medindo 5,08 cm x 5,08 cm (2”x2” polegadas) e divergência do feixe de radiação de 5,73°, correspondendo a uma colimação de 2mm (*Teixeira et al., 2018*). Vale ressaltar que a divergência da fonte foi matematicamente desenvolvida com a emissão desejada, sem a utilização de colimador real, fazendo uso de comandos disponibilizados no código MCNPX, onde a fonte adota a forma cônica com normalização da emissão 4π .

A geometria de medição conta com três detectores cintiladores localizados ortogonalmente a uma fonte divergente de raios gama com energia de 662 keV (^{137}Cs). Um dos detectores, posicionado a 180° e diametralmente alinhado à fonte, obterá as contribuições referentes a transmissão gama, enquanto os posicionados a 90° e 270°, obterão as contribuições de espalhamento gama, conforme Figura 25- Modelo 02.

A divergência estabelecida da fonte é de 5,73°, correspondendo a uma abertura de colimação de 2 mm (simulada no código MCNPX). O duto é essencialmente formado por Ferro ($\rho = 7,874 \text{ g.cm}^{-3}$) com diâmetro externo de 28 cm (*Bessera, 2012; Teixeira, 2018*) e espessura de 1 cm, com incrustações excêntricas formadas essencialmente por sulfato de bário ($\rho = 4,5 \text{ g.cm}^{-3}$) variando de 0,5 cm a 13,5 cm com passos de 0,1 cm. O sistema, ainda, é composto por fluidos como óleo bruto ($\rho = 0,973 \text{ g.cm}^{-3}$ assumido como petróleo) (*Bessera, 2012; Teixeira, 2018; Teixeira et al., 2018; Teixeira et al., 2019*), água salgada com 4% de fração mássica de cloreto de sódio ($\rho = 1,04666 \text{ g.cm}^{-3}$) para simular a salinidade média das águas nos mares mundiais (*Johansen e Jackson, 2000*) e ar atmosférico ($\rho = 0,00123 \text{ g.cm}^{-3}$) como a fase gasosa.

A obtenção de todos os dados de simulação para ambos os modelos foi possível por meio de comandos de saída disponíveis no código MCNPX.

Para calcular a distribuição de altura de pulsos (DAP) obtida nos detectores (keV) e estudar as espessuras das incrustações, foi utilizado o comando F8 (*tally card*). Esse comando apresenta um erro relativo devido às contagens em cada faixa de energia do

espectro. O número de histórias (NPS) usado foi determinado para obter uma estatística coerente e aceitável, com valores de erros relativos inferiores a 5% para energia de 662 keV, conforme especifica o manual do código MCNPX (*Pelowitz, 2005*).

De forma simplificada, os modelos adotados e as respectivas configurações adotadas para alimentar e extrair os resultados desejados das RNAs estão descritos a seguir.

Vale ressaltar que a linguagem de programação utilizada para conduzir a próxima etapa do trabalho foi o Python (*Van Rossum, 2007*), adotando as versões habilitadas de algumas de suas bibliotecas (frameworks) de código aberto especializadas em aprendizado de máquina: TensorFlow (*Abadi et al., 2016*) e Keras (*Chollet, 2016*), além das bibliotecas auxiliares NumPy (*Walt et al., 2011*), Pandas (*Mckinney, 2010*), Scikit-learn (*Pedregosa et al., 2011*) e Matplotlib (*Hunter, 2007*).

3.3.1 Modelo 1 – Predição da espessura da incrustação com conhecimento prévio do tipo de deposição (concêntrica ou excêntrica).

A camada de entrada do modelo é alimentada com dados simulados de incrustação concêntrica e excêntrica com regime de fluxo anular e variação das espessuras das incrustações de 0,5 a 10,5 com passos de 0,1 cm. Por consequência, há a diminuição proporcional dos fluidos (ar, água e óleo) presentes. Total de 200 simulações, 100 com deposição concêntrica e 100 com deposição excêntrica. Como resposta, a camada de saída informará as espessuras preditas pelo modelo. A geometria utilizada para a obtenção do banco de dados utilizados nesta etapa está demonstrada na Figura 24 (a).

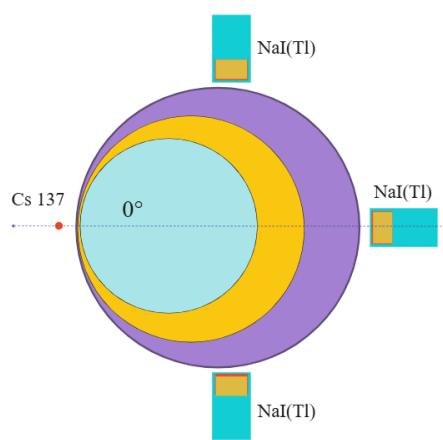
Os padrões de treinamento do modelo 1 para as previsões das incrustações são apresentados a seguir:

- *Entradas da RNA*: Contagens obtidas pelo detector relativas às energias de 20 a 670 keV obtidas no canal 67, numa distribuição de altura de pulsos com 10 keV por canal, para cada tipos de formação de deposição (concêntrica e excêntrica)
- *Saídas da RNA*: Espessura da incrustação.

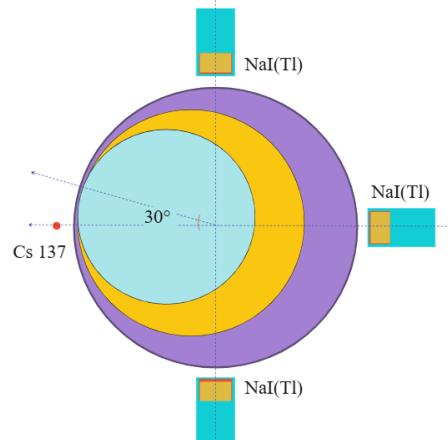
3.2.2 Modelo 2 – Predição da espessura de incrustações excêntricas

A camada de entrada recebe dados simulados obtidos para incrustações excêntricas com variação de localização da máxima concentração de depósito em 0° , 30° , 60° e 90° , com regime de fluxo anular, conforme Figura 24 (b). Somente esses ângulos foram adotados pois, sob uma visão radial do duto, o mesmo pode ser dividido em quadrantes. Partindo do pressuposto de simetria entre esses quadrantes e que a fonte radioativa e os três detectores estão dispostos ortogonalmente ao redor da tubulação, uma incrustação localizada à 0° e à 180° da fonte radioativa, terá contribuição de fótons transmitidos/espalhados similares obtidas em cada detector, de forma semelhante, uma incrustação localizada à 30° terá contribuição de fótons semelhante a uma incrustação localizada à 210° . Logo, adotando essa teoria, é possível obter, de forma simplificada, várias possibilidades de posição da máxima incrustação na tubulação em estudo, ver Figura 26.

Incrustação à 0° da fonte

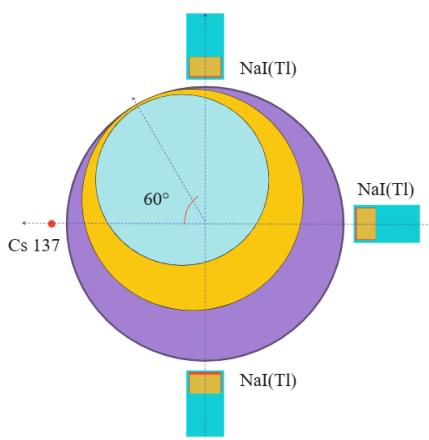


Incrustação à 30° da fonte

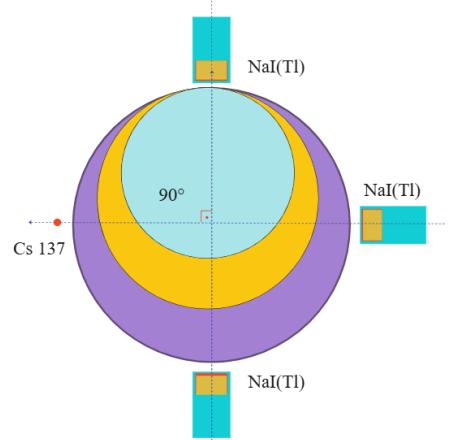


míro

Incrustação à 60° da fonte



Incrustação à 90° da fonte



míro

Figura 26 – Geometria de simulação para as posições 0°, 30°, 60° e 90° do modelo 2.

A variação da espessura da incrustação ocorre de 0,5 a 13,5 com passos de 0,01 cm, e contempla a mínima e máxima espessura de incrustação no interior do duto. Por consequência, há a diminuição proporcional dos fluidos (ar, água e óleo) presentes até o preenchimento total do duto pelo depósito. Nesse sentido, foram geradas 5204 simulações totais, sendo 1301 diferentes espessuras para cada posição da incrustação.

Os padrões de treinamento do modelo 2 para as predições das espessuras das incrustações são apresentados a seguir:

- *Entradas da RNA*: Contagens obtidas pelos três detectores relativas às energias de 20 a 670 keV obtidas no canal 67, numa distribuição de altura de pulsos com 10 keV por canal, para cada localização da deposição e excêntrica (0° , 30° , 60° e 90°);
- *Saídas da RNA*: Espessura da incrustação

Um dos principais desafios na utilização de redes neurais de retropropagação, é a determinação correta de seus hiperparâmetros. Estes serão parâmetros que são definidos antes do treinamento e de fundamental importância para a boa generalização da rede como, por exemplo, o número de neurônios e camadas. Habitualmente, os hiperparâmetros são definidos de forma manual, usando uma abordagem de tentativa e erro guiada pelo conhecimento de um especialista, no entanto, essa estratégia é entediante e muitas vezes falha e impraticável. Diante disso, recentemente, algumas abordagens automatizadas buscaram solucionar esse problema e têm sido estudadas a fundo pelos pesquisadores da área de IA. Alguns métodos automatizados que podem ser citados: GridSearch ([Pedregosa et al., 2011](#)); Random Search ([Bergstra e Bengio, 2012](#)); Projeto Robusto de Redes Neurais Artificiais (RDANN) ([Ortiz-Rodríguez, et al., 2013](#)); Otimização Bayesiana ([Snoek et al., 2012](#); [Dewancker et al., 2015](#); [Shahriari et al., 2016](#)).

Nesse sentido, uma busca em grade (*GridSearch*) foi realizada de forma a encontrar qual a melhor combinação de hiperparâmetros em cada um dos modelos. Para isso, primeiramente, o conjunto de dados original foi dividido em: Conjunto de Treinamento e Teste, com cerca 80% e 20% do total dos dados para cada conjunto em cada modelo, respectivamente.

Assim, o seguinte conjunto de hiperparâmetros e seus intervalos foram estudados para avaliar o melhor desempenho de cada modelo:

- *Número de camadas ocultas*: 1 a 5, em passos de 1;
- *Número de neurônios nas camadas ocultas*: de 100 a 500, com passos de 100;
- *Batelada*: 32 a 128, com passos de 32;
- *Número de épocas*: 5000 a 10000, com passos de 1000;
- *Função de ativação de camadas ocultas*: Sigmoid ou Tangente Hiperbólica.

Por outro lado, os seguintes hiperparâmetros foram definidos manualmente, sem intervalos:

- *Função de erro/perda:* Erro Quadrático Médio;
- *Função de ativação das camadas de saída:* Linear;
- *Otimizador:* Stochastic Gradient Descendent (SGD).

Diferentemente do modelo 1, o modelo 2 passou por um processo de validação de desempenho do treinamento por meio da técnica de validação cruzada *K-Fold*. Esta técnica consiste em dividir aleatoriamente o conjunto total de dados em K grupos distintos (dobras) com tamanho aproximadamente igual, e cada dobra é, por sua vez, usada para testar o modelo induzido a partir das outras dobras K-1 ([Wong, 2015](#)).

A implementação do K-Fold neste estudo pode ser resumida da seguinte forma:

1. O conjunto de dados original (com amostras já normalizadas) foi dividido em 10 vezes ($K = 10$), com cada dobra correspondendo a 10% do tamanho do conjunto de dados original;
2. Por 10 vezes, uma das 10 dobras foi usada como conjunto de teste para avaliar o desempenho do modelo e as outras $K-1$ dobras foram agrupadas para formar um conjunto de treinamento para treinar o modelo;
3. No final do processo, o erro médio para os 10 experimentos foi calculado.

Os hiperparâmetros que serão utilizados, após estudo automatizado de desempenho para os modelos 1 e 2 estão apresentados na Tabela 6.

Tabela 6 – Hiperparâmetros utilizados nos Modelos 1 e 2.

Hiperparâmetros	Modelo 1	Modelo 2
Nº de Camadas Ocultas	2	5
Nº de Neurônios nas Camadas Ocultas	400	300
Função de Ativação (Oculta)	Sigmoide	Sigmoide
Função de Ativação (Saída)	Linear	Linear
Épocas	5000	10000
Tamanho do Lote	32	32

Vale ainda ressaltar que, antes de realizar o treinamento, ambos os modelos passaram pela etapa de pré-processamento de dados. Ela consistiu em fazer uso principalmente de técnicas de transformação dos dados. Sendo assim, a espessura da incrustação passou por uma normalização de seus dados, ou seja, transformação dos atributos de forma a deixá-los na mesma escala, em um determinado intervalo.

Diante dessas análises, foi possível obter resultados satisfatórios. No entanto, visando a melhoria do modelo (etapas futuras) e, por consequência, melhoria dos resultados, uma nova abordagem será realizada, adotando uma DNN.

3.3 Previsão das espessuras de incrustação usando DNN.

3.3.1 O modelo DRNN

Baseado em estudos já realizados em que se compara as potencialidades das DNNs em relação as SNNs (*Glorot et al., 2011, Pedamonti, 2018, Santos et al., 2019, Desterro et al., 2020, Pinheiro et al., 2020*), foi introduzida uma abordagem mais eficiente no aspecto da utilização de funções de ativação não lineares e diferenciáveis nas camadas ocultas, uma vez que estas funções que ditam a transformação não linear do sinal de entrada. Segundo estudos recentes, as DRNN têm melhor treinamento e capacidade de generalização, além de alcançar maior precisão com uma taxa de erro menor do que as RNAs ativadas pela função sigmoide. Levando em consideração os aspectos discutidos, neste estudo, foi proposta uma nova arquitetura DNN que substitui as funções sigmoides tradicionais utilizadas para ativar os neurônios das camadas ocultas da rede para funções retificadas (RELU), devido a isso o nome deste tipo de modelo DNN é *Deep Rectifier Neural Network* (DRNNs).

O tempo de treinamento é um fator relevante para as DNNs. Portanto, foi utilizada uma unidade de processamento gráfico (GPU) modelo NVIDIA® GeForce® GTX 1060 para acelerar o treinamento dos modelos através da computação paralela.

3.3.2 Dados simulados e treinamento/teste da DRNN

Os mesmos dados simulados obtidos para alimentar o modelo 2 foi usado nessa fase de treinamento e teste da DRNN. Dessa forma, um total de 5204 simulações foram

utilizadas adotando essa nova abordagem, sendo 1301 diferentes espessuras máximas para cada posição radial da incrustação no interior do duto (0° , 30° , 60° e 90°). Ao se adotar um plano cartesiano onde o centro do plano (posição 0,0) é o centro do duto e subdividindo o duto em 4 quadrantes iguais, as localidades das máximas incrustações adotadas nesse estudo podem ser correspondidas em valor pelos ângulos suplementares. Logo, as medidas realizadas nesses ângulos são suficientes para obter informações de todo o duto.

Dessa forma, as amostras do conjunto de dados têm a seguinte estrutura de entrada e saída:

- *Entradas da RNA*: Contagens obtida pelos três detectores relativas às energias de 20 a 670 keV obtidas no canal 67, numa distribuição de altura de pulsos com 10 keV por canal, para cada localização da deposição e excêntrica (0° , 30° , 60° e 90°);
- *Saídas da RNA*: Espessura da incrustação.

3.3.3 Projeto da DRNN

De forma semelhante aos modelos 1 e 2, um método automatizado foi utilizado para auxiliar no projeto da DRNN sob a tarefa de predição da espessura máxima das incrustações. Assim, o método de otimização Bayesiana foi implementado nesta etapa usando a biblioteca de otimização de hiperparâmetros *python Hyperas* (*Pumperla, 2017*).

Sendo assim, o seguinte conjunto de hiperparâmetros e seus intervalos foram definidos para o estudo:

- *Número de camadas ocultas*: de 1 a 10, com passos de 1;
- *Número de neurônios nas camadas ocultas*: de 100 a 1000, com passos de 100;
- *Função de ativação de camadas ocultas*: ReLu (*Glorot e Bengio, 2010*) ou Elu (*Clevert et al., 2015*);
- *Batelada*: de 32 a 128, com passos de 32;
- *Otimizador*: Stochastic Gradient Descendent (SGD), RMSprop (*Tieleman e Hinton, 2012*) ou Adam (*Kingma e Ba, 2014*]).

Por outro lado, os seguintes hiperparâmetros foram definidos manualmente

- *Número de épocas:* 1000;
- *Função de erro/perda:* Erro quadrático médio (MSE);
- *Função de Ativação da camada de saída:* Linear.

Além disso, para realizar esta pesquisa de hiperparâmetros, o conjunto de dados original com 5204 foi dividido em dois conjuntos:

- *Conjunto de Treinamento:* composto por 80% do conjunto de dados original, contendo 4.163 amostras (1.040 para a posição 60° e 1.041 para as posições 0°, 30°, 90°);
- *Conjunto de Teste:* Consistindo em 20% do conjunto de dados original, contendo 1.041 amostras (261 para a posição 60° e 260 para as posições 0°, 30°, 90°).

Além disso, antes do treinamento, com o objetivo de melhorar a eficiência dos modelos DRNNs, os dados de entrada nestes conjuntos foram normalizados de acordo com a Equação 30.

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

Equação 30

Onde: X_N é o valor normalizado, X é o valor real, X' é a média e S é o desvio padrão.

A DRNN que obteve o melhor resultado no estudo automatizado de hiperparâmetros tem as seguintes características:

- *Número de camadas ocultas:* 5;
- *Número de neurônios nas camadas ocultas:* [700, 800, 300, 600, 800];
- *Função de ativação de camadas ocultas:* ReLu;
- *Função de ativação das camadas de saída:* Linear
- *Tamanho do lote:* 32;
- *Otimizador:* Adam.

Para validar o desempenho da DRNN proposta nesta etapa, a técnica de validação cruzada K-Fold foi também implementada.

3.4 Caracterização das amostras de incrustação de um duto de petróleo descomissionado

Foram coletadas amostras de incrustação excêntrica (distribuição de deposição não uniforme no interior do tubo, apresentando maior espessura em uma localidade) de uma tubulação obstruída e descomissionada de uma plataforma de petróleo contendo deposição por todo seu interior. A coleta foi dividida em regiões, sendo que cada região corresponde à um perfil de deposição. Buscando-se obter maiores informações acerca desses perfis de deposição e suas composições, a coleta foi realizada para cada região desde o começo da formação da deposição (próxima a superfície do duto) até onde a incrustação finaliza (região central ao duto), a Figura 27 mostra as três regiões selecionadas.



Figura 27 – Regiões (1, 2 e 3) de coleta das amostras de incrustação de uma tubulação obstruída.

3.4.1 Coleta e preparo das amostras

As amostras de incrustações foram colocadas na estufa a uma temperatura de aproximadamente 60°C para secagem até massa constante. Em seguida, as folhas secas foram trituradas, mecanicamente, usando um moinho de ágata. O processo de controle da granulometria foi feito através de peneiras com malha em nylon (75 µm).

3.4.1.1 Fluorescência de Raios X

Para as análises de XRF as amostras foram preparadas em pastilhas. Uma massa de aproximadamente 600 mg de cada amostra foi bem misturada com 200 mg de ácido bórico (H_3BO_3). O H_3BO_3 foi escolhido como material ligante devido, principalmente, a sua pureza e o baixo número atômico de seus constituintes. Posteriormente, toda a mistura foi colocada em um compactador e prensada em forma de pastilhas a uma pressão de 2.32×10^8 Pa por, aproximadamente, 15 minutos. O produto final é uma pastilha fina, com diâmetro de 2.54 cm, e densidade superficial de 150 mg/cm^2 . As amostras foram preparadas em triplicatas. A Figura 28 mostra as etapas da confecção das pastilhas.



(a)



(b)

Figura 28 – Compactador de pastilhas e prensa ((a) e (b), respectivamente)

As condições experimentais de cada pastilha estão apresentadas na Tabela 5.

Tabela 5 – Condições experimentais das pastilhas

Condições experimentais	Amostras		
	1	2	3
Massa da pastilha (g)	0,5740	0,5763	0,5826
Diâmetro (cm)	2,54	2,54	2,54
Área (mm ²)	506,7	506,7	506,7
Densidade (g/cm ³)	1,5438	1,6089	1,6989
Espessura (mm)	0,7670	0,7360	0,6970

As análises de XRF foram realizadas utilizando o equipamento comercial Epsilon 1 (Malvern Panalytical) (Figura 28). O Epsilon é composto por um tubo de raios X com anodo de Prata (Ag) e um detector SDD (Silicon Drift Detector).

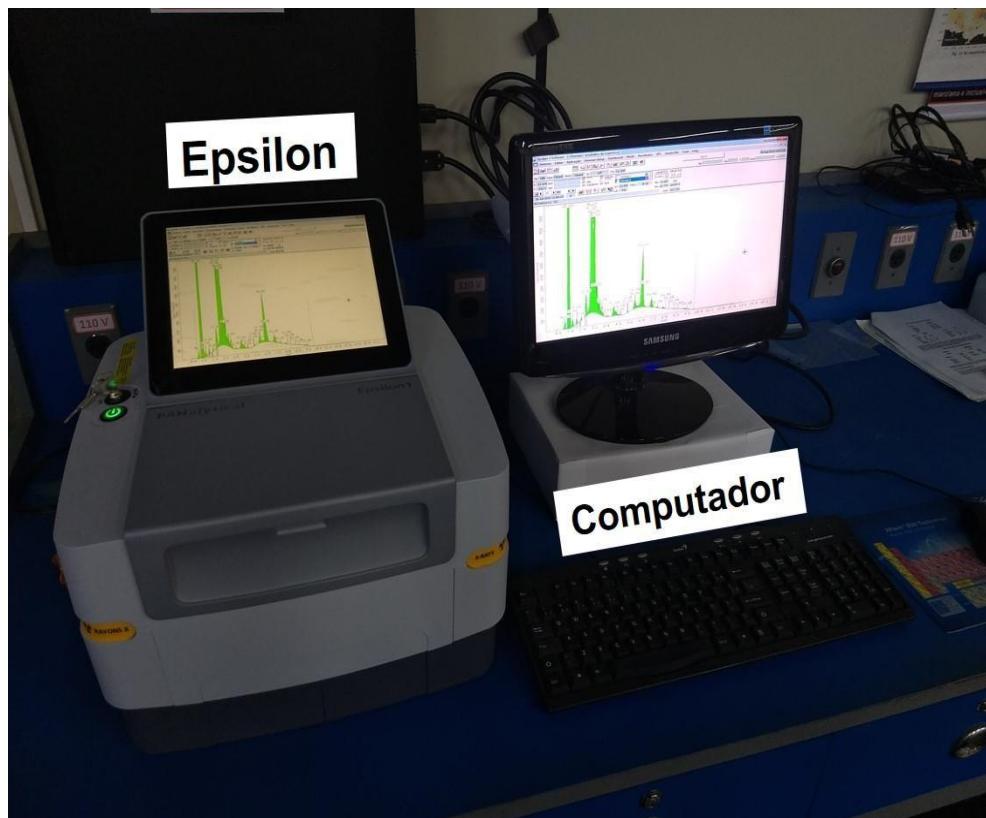


Figura 29 – Epsilon 1 (Malvern Panalytical)

A análise de XRF foi realizada utilizando a aplicação “Omnian” do equipamento Epsilon 1 (Figura 29). Esta aplicação possui uma análise com 4 configurações diferentes, cada configuração utiliza uma tensão, corrente, filtro e tempo de aquisição diferentes para favorecer a excitação de uma faixa de elementos químicos específicos. A Tabela 6 mostra as configurações experimentais das 4 análises realizadas na aplicação “Omnian”. A concentração elementar foi calculada no próprio software utilizando os parâmetros fundamentais da fluorescência de raios X.

Tabela 6 – Configurações experimentais da aplicação “Omnian”

	Tensão (kV)	Corrente (μ A)	Filtro	Tempo de aquisição (s)
Análise 1	50	100	Ag (100 μ m)	120
Análise 2	50	100	Cu (500 μ m)	300
Análise 3	12	416	Al (50 μ m)	180
Análise 4	10	336	-a)	600

a) Sem filtro

3.4.1.2 Difração de Raios X

O perfil de difração de raios X (DRX) foi obtido a partir de 03 amostras de incrustação que foram trituradas em um almofariz e passadas em uma peneira de malha de nylon com abertura de 75 μ m para garantir que sua granulometria máxima ficasse bem definida e dessa forma não gerar orientação preferencial. Depois o pó foi acomodado na porta amostra e posto para realizar as medidas.

O perfil de difração de raio X foi obtido utilizando-se o equipamento comercial de bancada D2Phaser da BRUKER (Figura 30), localizado no laboratório LIETA/UERJ (Laboratório de Instrumentação Eletrônica e Técnicas Analíticas).

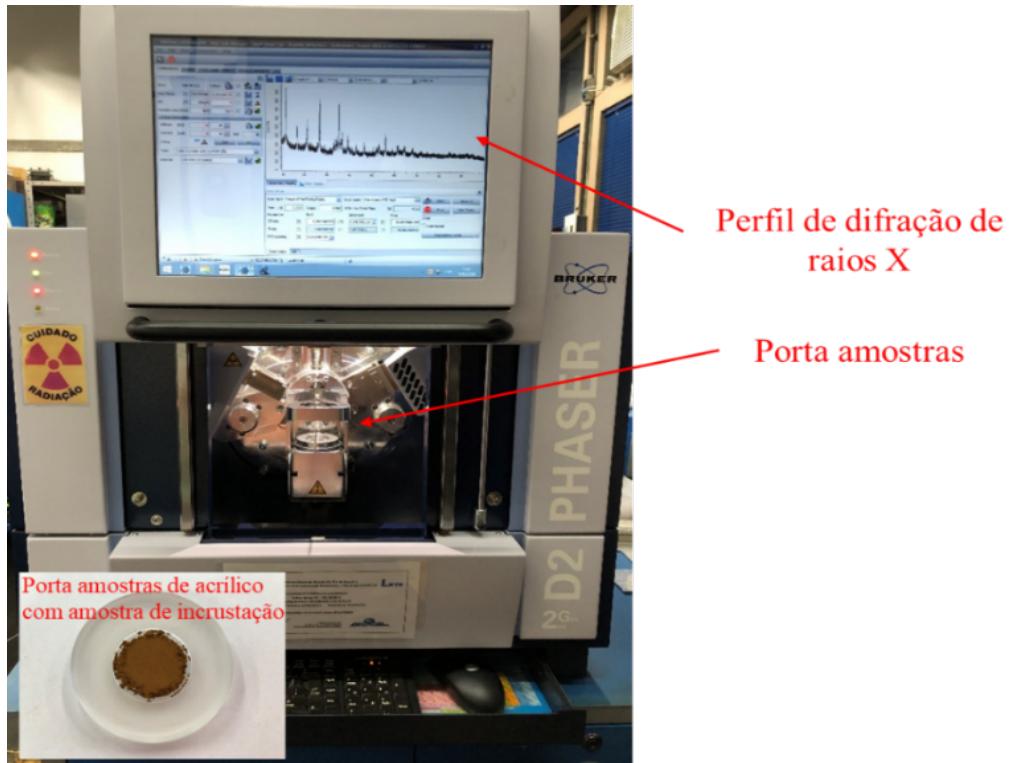


Figura 30 – Equipamento de D2Phaser utilizado nas análises por DRX.

O D2Phaser é um difratômetro de pó que opera na geometria Bragg-Brentano. É equipado com um detector linear (1D) rápido do tipo LYNXEYE, que também pode funcionar no modo cintilador (0D), um tubo de raios X com ânodo de cobre, que tem linha de emissão característica de 1,541 Å / 8,047 keV (Cu-K_{α1}), potência máxima de 300 W (30 kV x 10 mA) e varredura com precisão angular de $\pm 0,002^\circ$ no intervalo de -3° a 160° em 20. O porta amostras é fixado em um sistema *Spinner*, com velocidade de rotação definida pelo usuário, para aumentar a estatística e diminuir os efeitos de orientação preferencial. Possui monitor, teclado e mouse integrados, e software de coleta de dados DIFFRAC.SUITE™. Para a identificação de fases, foi utilizado o software DIFFRAC. EVATM da BRUKER, o qual além de identificar as fases contidas nas amostras também fornece um gráfico semiquantitativo delas para indicar suas proporções.

Para cada varredura ficou estipulada a seguinte condição operacional usada na medida de difração:

- Tensão de 30 kV e Corrente de 10 mA;

- b) Slit de 0,6 mm e Soller = $2,5^\circ$;
- c) Filtro $K\beta$ de Ni;
- d) Tempo de medida de 0,5 s;
- e) Ângulo inicial: 10° ;
- f) Ângulo final: 90° ;
- g) Incremento angular: $0,01^\circ$;
- h) Abertura do detector (PSD opening): $4,767^\circ$.

3.5 Predição da incrustação independentemente do tipo de deposição

O método desenvolvido nesta etapa representa uma evolução em relação a modelos preditivos anteriores citados nesse trabalho, pois considera a distribuição real da incrustação dentro da tubulação. Diferentemente de abordagens anteriores que assumiam padrões mais simplificados, o modelo atual leva em conta a concentração efetiva do depósito ao longo da superfície interna da tubulação. Além disso, a geração dos dados de treinamento foi aprimorada para incluir não apenas incrustações concêntricas ou excêntricas, mas distribuídos aleatoriamente nos quatro quadrantes da tubulação (casos de incrustação excêntrica), também a aleatoriedade de casos de distribuição das incrustações concêntricas. Essa abordagem garante maior representatividade dos padrões reais de incrustação, aumentando a robustez do modelo preditivo.

3.5.1 Geração dos modelos aleatórios para o MCNPX com Python

A geração dos casos de incrustação foi realizada de forma automatizada utilizando Python e MCNPX. O processo envolveu a criação de 2.000 cenários representando diferentes padrões de incrustação na tubulação. Para garantir diversidade e realismo, os parâmetros de incrustação foram definidos aleatoriamente dentro de limites físicos possíveis, considerando tanto incrustações concêntricas quanto excêntricas distribuídas nos quatro quadrantes da tubulação.

O algoritmo em Python gerou os casos variando três parâmetros principais:

- ***Raio interno da tubulação pós-incrustação (R)***, que determina a redução do espaço útil devido aos depósitos.
- ***Deslocamento horizontal e vertical da incrustação (Dx e Dy)***, que define a distribuição espacial dos depósitos dentro da tubulação.

Os valores foram gerados aleatoriamente respeitando limites físicos, assegurando que as incrustações pudessem ocorrer de maneira assimétrica, simulando condições reais de operação. Esses parâmetros foram então incorporados automaticamente em arquivos de entrada do MCNPX, que foi responsável por realizar as simulações das interações físicas.

O código MCNPX gerado para cada cenário incluía a definição de materiais, geometrias e condições de simulação para avaliar o impacto da posição da incrustação na performance da RNA. Essa abordagem permitiu a criação de um conjunto de dados representativo das diferentes configurações de incrustação, garantindo maior robustez ao modelo preditivo treinado posteriormente.

3.5.2 Mudança na geometria de medição – Novos ângulos de espalhamento

Compton

A geometria utilizada nos modelos MCNPX foi configurada para simular uma fonte de radiação monoenergética emitindo fótons na direção da tubulação. O sistema foi modelado com detectores cintiladores de NaI(Tl) posicionados a 30° e 60° em relação à direção da fonte, garantindo a captação dos fótons espalhados por diferentes ângulos. Essa configuração permitiu avaliar a influência das incrustações sobre a intensidade dos fótons espalhados, possibilitando a extração de informações sobre a espessura e distribuição dos depósitos internos.

A estrutura do modelo incluiu:

- **Fonte de Cs-137:** modelada com uma distribuição direcional para garantir a incidência dos fótons sobre a tubulação de maneira controlada;
- **Tubulação de aço:** representada com materiais compatíveis com sistemas industriais, considerando a presença de incrustações com características variadas (concêntricas e excêntricas);
- **Detectores:** 03 cintiladores de NaI(Tl) posicionados a 30°, 60° e 180° da fonte, permitindo uma análise detalhada das interações Compton e efeito fotoelétrico;
- **Blindagens e colimadores:** empregados para reduzir ruídos indesejados e garantir que a radiação detectada fosse proveniente das interações com a incrustação, otimizando a qualidade dos dados simulados.

Vale ressaltar que, a justificativa para a escolha dos ângulos de 30° e 60° para os detectores, em vez da disposição ortogonal (90°) utilizada no modelo anterior, foi embasada sob alguns aspectos técnicos e metodológicos, incluindo melhoria da sensibilidade à variação da incrustação, otimização da interação Compton e redução de incertezas na detecção, conforme detalhado a seguir:

1. Maior Sensibilidade às Variações da Incrustação

- No estudo anterior, a configuração ortogonal (90°) privilegiava a detecção de fótons espalhados com maior componente perpendicular à tubulação. No entanto, essa abordagem pode reduzir a capacidade de detectar variações mais sutis na distribuição espacial da incrustação, especialmente em casos de incrustação excêntrica.
- Com detectores a 30° e 60° , o sistema se torna mais sensível às diferenças de espessura da incrustação ao longo do perfil da tubulação, melhorando a distinção entre as incrustações.

2. Otimização da Probabilidade de Espalhamento Compton

- O espalhamento Compton segue uma distribuição angular dependente da energia do fóton incidente. Em energias típicas de radiação utilizadas nesses experimentos (~ 662 keV para Cs-137, por exemplo), a dispersão ocorre com maior probabilidade em ângulos intermediários, em vez de 90° , onde a eficiência do espalhamento pode ser reduzida.
- A escolha de 30° e 60° aumenta a chance de detectar fótons espalhados com energias ainda suficientes para diferenciação da interação com as incrustações.

3. Melhoria na Relação Sinal-Ruído

- A configuração ortogonal pode estar mais suscetível a ruídos indesejados, como fótons retroespalhados de componentes estruturais ou da própria tubulação.
- Os ângulos de 30° e 60° foram escolhidos para reduzir interferências dessas contribuições e melhorar a qualidade dos sinais captados pelos detectores, facilitando a interpretação dos espectros obtidos.

Dessa maneira, segue representação da geometria utilizada nessa etapa, (Figura 31)

Modelo 3

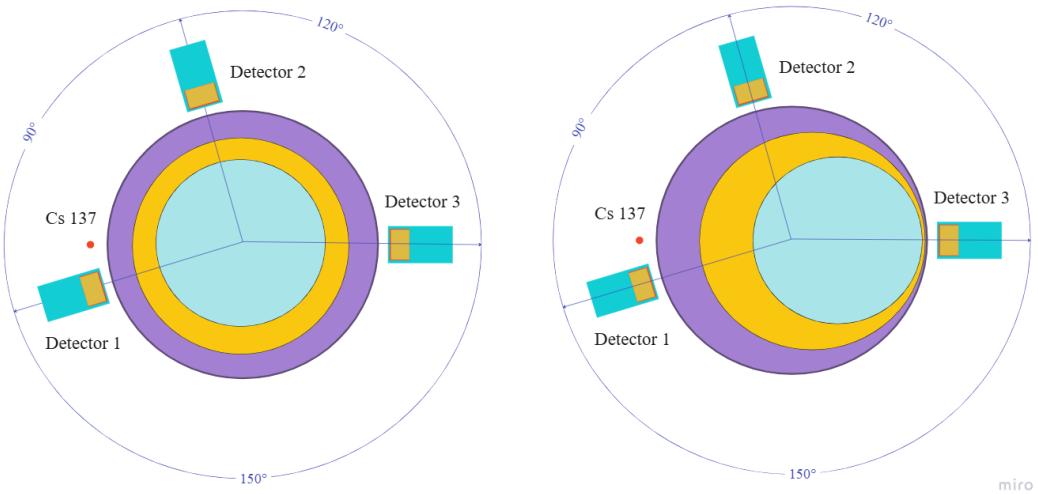


Figura 31 – Geometria de simulação para incrustações concêntricas e excêntricas usadas no modelo 3.

Portanto, de forma resumida essa etapa consistiu em:

- 03 detectores cintiladores, formados pelo cristal de NaI(Tl) 2x2”, além de MgO (densidade de 3,58 g/cm³) e Al (densidade de 2,69 g/cm³) que compõe sua estrutura real do detector;
- Tubulação formada aço galvanizado (densidade de 7,82 g/cm³), com 1 cm de espessura e 27 cm de diâmetro externo;
- Fonte de Césio 137 com divergência da fonte de 5,73° (2 mm);
- Incrustações concêntricas e excêntricas geradas de forma aleatória, com a composição obtida pelas caracterizações usando fluorescência e difração de raios X, sem predefinição de passos de espessuras, apenas a garantia de que estariam fisicamente alocadas dentro da tubulação de forma consistente com o fluido (nesse caso, usou-se óleo cru: 0,973 g/cm³).

3.5.3 A DRNN implementada e dados de treinamento e teste aplicados

Os dados simulados compreendem um total de 4000 modelos simulados com diferentes posições e espessuras das incrustações dentro da tubulação que foram usadas

no treinamento e teste da DRNN. A arquitetura e as configurações seguem o padrão do modelo anterior (modelo 02), contando com as seguintes entradas e saídas:

- *Entradas da RNA*: Contagens obtida pelos três detectores relativas às energias de 20 a 670 keV obtidas no canal 67 para o detector posicionado à 180° , 20 a 500 keV para o detector posicionado à 60° e 20 a 600 keV para o detector posicionado à 30° . Todos eles ajustados para uma distribuição de altura de pulsos com 10 keV por canal.
- *Saídas da RNA*: Volume útil da tubulação.

3.5.4 Projeto da DRNN

De forma semelhante aos modelos anteriores, foi utilizado um método automatizado para auxiliar no projeto da DRNN sob a tarefa de predição da espessura das incrustações, o *Optuna*. Este é um framework *Open Source* voltado para automatizar a busca pelos melhores hiperparâmetros, realizando combinações para potencializar os resultados obtidos pela rede neural.

Dessa forma, o seguinte conjunto de hiperparâmetros e seus intervalos foram definidos para o estudo:

- *Número de camadas ocultas*: de 1 a 5, com passos de 1;
- *Número de neurônios nas camadas ocultas*: de 64 a 256, com passos de 32;
- *Função de ativação de camadas ocultas*: ReLu ([Glorot e Bengio, 2010](#)) ou Elu ([Clevert et al., 2015](#));
- *Batelada*: de 32, 64, 128 ou 256;
- *Otimizador*: Stochastic Gradient Descendent (SGD), RMSprop ([Tieleman e Hinton, 2012](#)) ou Adam ([Kingma e Ba, 2014](#)).

Por outro lado, os seguintes hiperparâmetros foram definidos manualmente

- *Número de épocas*: 1000;
- *Função de erro/perda*: Erro quadrático médio (MSE);
- *Função de Ativação da camada de saída*: Linear.

Para realizar esta pesquisa de hiperparâmetros, o conjunto de dados original com 4000 foi dividido em dois conjuntos:

- *Conjunto de Treinamento*: composto por 80% do conjunto de dados original, contendo 3.200 amostras;
- *Conjunto de Teste*: Consistindo em 20% do conjunto de dados original, contendo 800 amostras.

Além disso, antes do treinamento, com o objetivo de melhorar a eficiência dos modelos DRNNs, os dados de entrada nestes conjuntos foram normalizados de acordo com a Equação 30.

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

Equação 30

Onde: X_N é o valor normalizado, X é o valor real, X' é a média e S é o desvio padrão.

A DRNN que obteve o melhor resultado no estudo automatizado de hiperparâmetros tem as seguintes características:

- *Número de camadas ocultas*: 4;
- *Número de neurônios nas camadas ocultas*: 288
- *Função de ativação de camadas ocultas*: ReLu;
- *Função de ativação das camadas de saída*: Linear
- *Tamanho do lote*: 32;
- *Otimizador*: Adam.

Para validar o desempenho da DRNN, assim como no modelo anterior, a técnica de validação cruzada K-Fold (com número de splits = 10) foi também implementada.

CAPÍTULO IV

4- RESULTADOS

Conforme descrito no capítulo 3, primeiramente serão apresentados os resultados da validação matemática elaborados para incrustações concêntricas e excêntricas utilizando equações analíticas e o código MCNPX, bem como resultados os para o cálculo das espessuras de incrustação utilizando o código MCNPX e uma RNA, a fim de avaliar a potencialidade dessas duas técnicas. Em seguida, serão apresentados os resultados para a geometria mais complexa utilizada para treinamento e teste de uma DRNN com intuito de prever incrustações independentemente da sua localização de deposição.

Pré-resultados experimentais serão apresentados a partir da seção 4.4. Esses resultados se referem a caracterização da amostra de incrustação por meio das técnicas de fluorescência e difração de raios X. Esses resultados serão utilizados na segunda etapa deste trabalho, visando a inclusão da incrustação caracterizada nos modelos simulados e inserção desses modelos em uma DRNN, bem como medidas experimentais obtidas por meio do sistema automatizado, conforme detalhado na seção 3.5.

4.1 Validação do modelo matemático por meio de equações analíticas

Na seção 3.1.2 é salientada a importância do coeficiente de atenuação linear (μ) para o cálculo da espessura das incrustações concêntricas e excêntricas. Diante disso, foram realizados estudos de transmissão gama nos materiais selecionados para a inserção nos modelos como fluídos constituintes do sistema além do tubo e incrustação, a saber: ar atmosférico, água salgada com 4% de NaCl em sua composição e óleo cru.

Os dados obtidos para os coeficientes μ dos materiais selecionados foram confrontados com dados teóricos dos mesmos materiais pertencentes ao banco de dados do *National Institute of Standards and Technology (NIST)*, e apresentados na Tabela 7, com valores de erro relativo máximo de 7,54% comparado ao valor teórico.

Tabela 7 – Coeficientes de atenuação lineares para os fluidos utilizados nas simulações.

Materiais	Coef. Atenuação - μ (cm ⁻¹)		
	NIST (Teórico)	MCNPX	Erro Relativo
Aço	5,78E-01	5,89E-01	1,77%
Incrustação de BaSO ₄	1,97E-01	2,02E-01	2,40%
Ar Atmosférico	9,49E-05	9,49E-05	0,00%
Água Salgada	8,86E-02	8,93E-02	0,78%
Óleo Cru	7,75E-02	8,38E-02	7,54%

Seguindo a descrição das etapas mencionadas na seção 3.1.2, foram utilizadas as estimativas do feixe transmitido (I_o) dos raios gama, obtidas no volume sensível do detector simulado pelo código MCNPX, e calculadas as espessuras das incrustações para os diferentes tipos de deposição.

Os resultados da predição da espessura por meio de equações analíticas para a incrustação do tipo concêntrica e excêntrica em um sistema de fluxo homogêneo, considerando como fluido somente o óleo cru, estão mostrados na Tabela 8.

Tabela 8 – Espessura de incrustações concêntricas e excêntricas em regime homogêneo.

Padrões	Incrustação Concêntrica			Incrustação Excêntrica		
	Real	Solução Analítica	Erro Relativo	Real	Solução Analítica	Erro Relativo
1	0,00	0,01	-0,59%	0,00	0,01	0,00%
2	1,00	1,00	-0,25%	1,00	1,00	0,29%
3	2,00	1,99	0,37%	2,00	2,00	0,13%
4	3,00	2,98	0,68%	3,00	2,99	-0,38%
5	4,00	3,98	0,46%	4,00	3,98	-0,43%
6	5,00	4,97	0,55%	5,00	4,98	-0,41%
7	6,00	5,97	0,54%	6,00	5,98	-0,33%
8	7,00	6,95	0,70%	7,00	6,98	-0,35%
9	8,00	7,93	0,85%	8,00	7,98	-0,28%
10	9,00	8,92	0,88%	9,00	8,98	-0,22%
11	10,00	9,90	1,06%	10,00	9,96	-0,39%
12	11,00	10,92	0,77%	11,00	10,94	-0,59%
13	12,00	11,91	0,72%	12,00	11,95	-0,45%
14	13,00	12,91	-0,68%	13,00	12,91	-0,68%

Estes valores calculados obtidos para as espessuras de incrustação concêntrica e excêntrica mostram uma boa concordância com os valores das espessuras reais, demonstrando que as informações essenciais para a solução das equações analíticas foram obtidas de forma correta pelo código MCNPX, validando assim os modelos desenvolvidos.

4.2 Predição das espessuras de incrustações concêntricas e excêntricas

Com o objetivo de tornar a predição das espessuras concêntricas e excêntricas menos dependentes das informações internas ao duto e, consequentemente, de cálculos analíticos extensos, dois modelos baseados em RNAs foram utilizados. Visando avaliar a potencialidade desse método, os dados simulados obtidos para os diferentes tipos de incrustação foram divididos em padrões de treinamento e teste e, seguidamente, avaliados em performance com o uso dessas RNAs, previamente detalhadas como *Modelo 1* e *Modelo 2*. Os resultados são apresentados a seguir, seguindo as etapas detalhadas na 3 deste trabalho.

4.2.1 Modelo 1 – Predição da espessura de incrustação dependente da informação de localização da máxima incrustação (Modelo 1).

Um conjunto de Treinamento composto por 150 padrões foi utilizado para alimentar as camadas de entrada da RNA, cujos dados de saída foram comparados com os valores pré-estabelecidos (obtidos por meio dos modelos simulados detalhados na seção 3.1) das espessuras. Os dados de treinamento podem ser visualizados na Figura 32, bem como os dados preditos pela RNA.

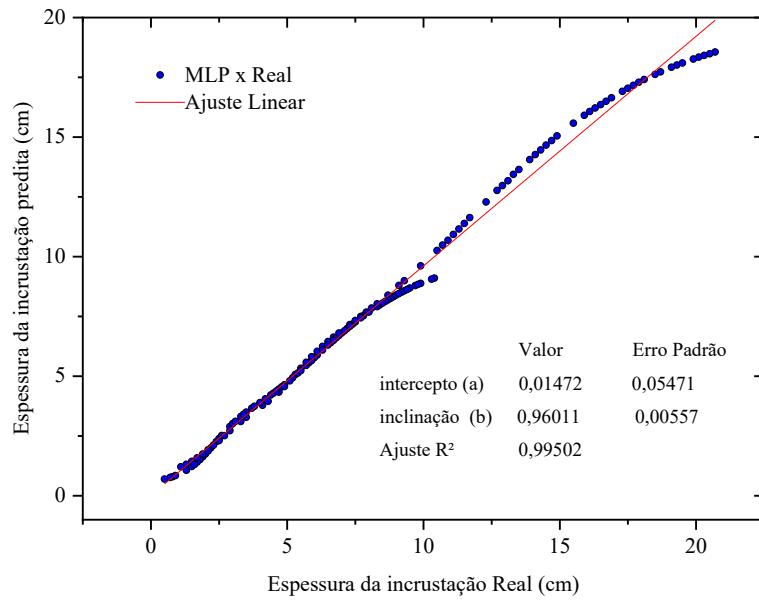


Figure 32 – Resultados obtidos pela modelo 1 para o conjunto de Treinamento para incrustações concêntricas e excêntricas.

Em uma segunda etapa, utilizou-se outro conjunto de dados denominado de Teste composto por 50 padrões, visando medir a capacidade de generalização do modelo, ou seja, a qualidade pelo qual o treinamento da RNA foi submetido. O resultado dessa previsão é apresentado na Figura 33.

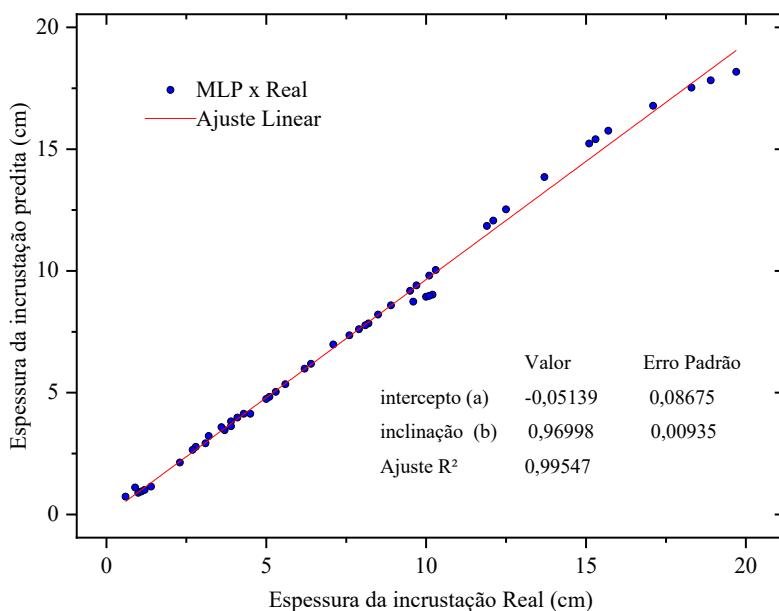


Figure 33 – Resultados obtidos pelo modelo 1 para o conjunto de Teste para incrustações concêntricas e excêntricas.

O conjunto de teste, que apresenta 50 padrões de diferentes espessuras não treinadas, obteve valores médios ($MAE = 0,19172043$, $MSE = 0,07085159$ e $R^2 = 0,99547$) que mostram a boa capacidade de generalização do modelo. Os resultados apresentam uma boa capacidade para predição das incrustações, apesar da “idealização” de alguns parâmetros nos modelos obtidos pelo MCNPX. Um deles é a localização das deposições do tipo excêntrica. Este modelo de rede neural considerou a localização do depósito conhecida (o que não ocorre na realidade), logo, a disposição da fonte-detector no mesmo eixo de medida, distados a 180° , seria suficiente para medições de fótons transmitidos pelos materiais e detectador no volume sensível do detector cintilador, e a consequente predição da incrustação excêntrica. Outro fator relevante seria se este modelo seria suficiente para a predição da incrustação levando-se em consideração modelos mais complexos. Para isso, foi avaliada a capacidade de generalização de outra rede neural, com mesma topologia (*feedforward*), agora sendo alimentada com dados simulados mais complexos, mostrada no tópico a seguir.

4.2.2 Modelo 2 – Predição da espessura de incrustação excêntrica (Modelo 2).

Este modelo leva em consideração dados simulados mais complexos, abordando incrustações excêntricas e a resolução da dificuldade de determinação da localização destas e consequente medida de incrustação máxima. Dados obtidos para diferentes localizações da incrustação máxima foram avaliadas com este método, bem como a determinação da espessura destas incrustações.

Um conjunto de Treinamento composto por 4163 padrões foram utilizados para alimentar as camadas de entrada da RNA cujos dados de saída foram também comparados com os valores pré-estabelecidos (obtidos por meio dos modelos simulados detalhados na seção 3.1) das espessuras.

A fonte básica para a avaliação de progresso do processo de aprendizagem de uma RNA é a função de perda (*loss function*). Ela basicamente informa o quanto longe se está da solução ‘ideal’. Por meio da Figura 35 é possível notar a diminuição da função de perda à medida que o aprendizado da RNA ocorre. Portanto, para que se tenha uma boa capacidade de generalização da rede neural, este valor de perda deve se aproximar o máximo de zero, inferindo na diminuição do erro calculado para as predições do modelo. Portanto, conforme observa-se na Figura 34, o valor da função de perda se estabiliza em

0 quando se aproxima de 5000 épocas, mostrando que a RNA tende ao erro mínimo, conferindo-a uma boa convergência.

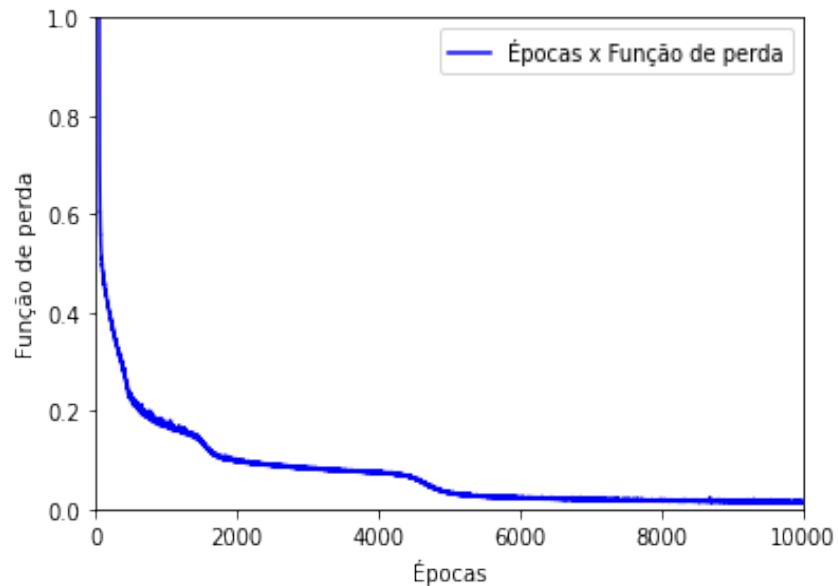


Figure 34 – Progresso para o processo de aprendizado para o modelo 2.

Na Figura 35 são mostrados os dados para o conjunto de treinamento obtidos pelo modelo 2 em comparação aos dados reais, obtidos pelas simulações com o código MCNPX.

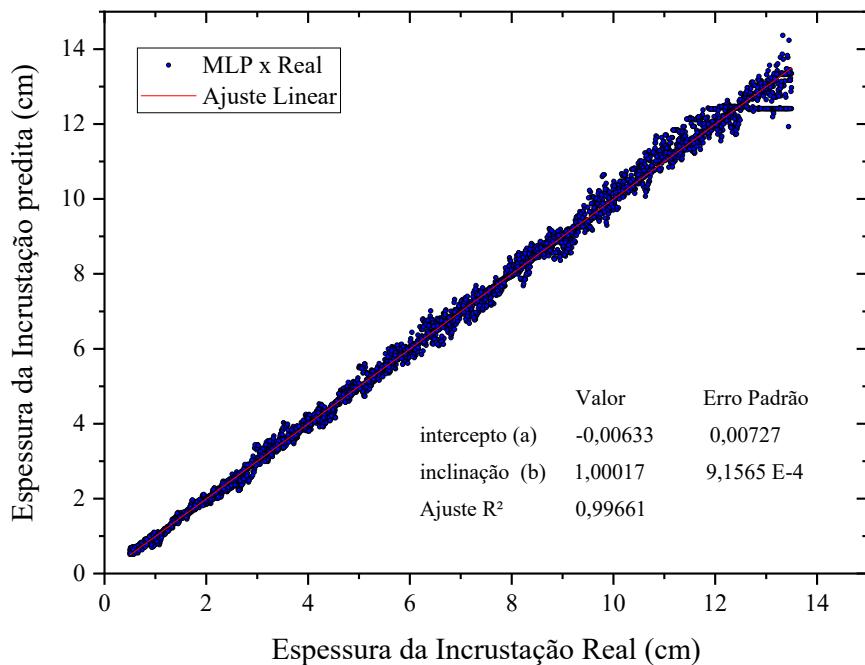


Figure 35 – Resultados obtidos pelo modelo 2 para o conjunto de Treinamento considerando incrustações excêntricas

Na Figura 36 estão mostrados dados para o conjunto de teste obtidos pelo modelo 2 em comparação aos dados reais.

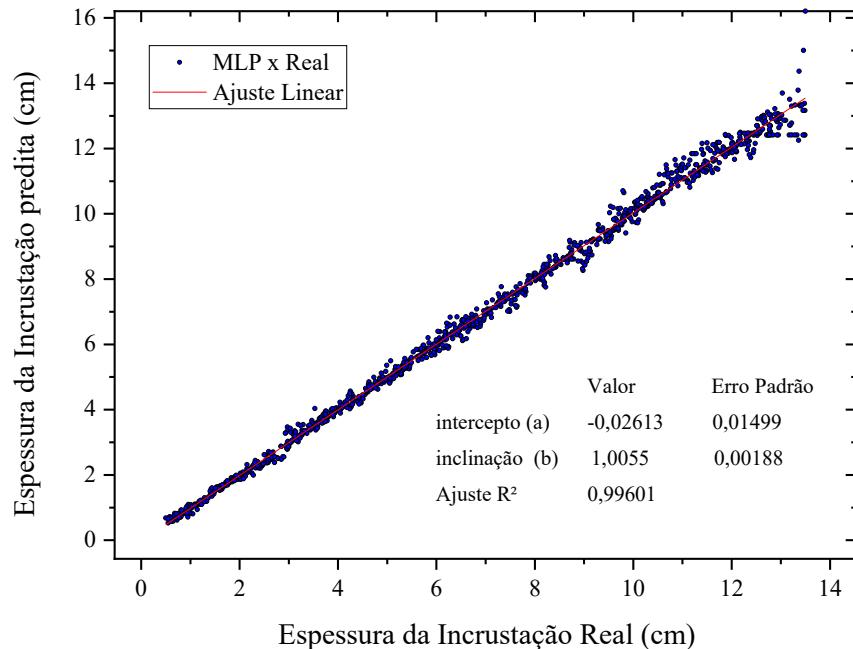


Figure 36 – Resultados obtidos pelo modelo 2 para o conjunto de Teste considerando incrustações excêntricas

O conjunto de teste, que apresenta 1041 padrões de diferentes espessuras e posições de deposição, obteve valores médios (MAE = 0,154794, MSE = 0,058111, RMSE = 0,241063, MARE = 2,816095% e R^2 = 0,995907) que mostram a boa capacidade de generalização do modelo, inferindo que o modelo 2 é capaz de realizar a predição da espessura máxima de encrustação para padrões não treinados apresentando erros com valores baixos.

Visando um modelo mais eficiente para a determinação das espessuras e localização das encrustações, optou-se por abordar uma DRNN como possível solução para obter uma predição das encrustações com resultados ainda mais consistentes.

4.3 Predição das espessuras de encrustação máximas por DRNN

Visto que um modelo de rede neural artificial é capaz de predizer encrustações concêntricas e excêntricas, sendo esta última com a limitação do conhecimento de sua

localização, uma nova abordagem foi elaborada como tentativa de melhoria para essa última informação.

Vale ressaltar que, apesar dos resultados da última configuração de rede neural serem suficientes para predição da espessura máxima da incrustação, nessa etapa buscou-se, de forma prévia, um modelo mais robusto já vislumbrando uma maior complexidade de abordagens de medida futuras, ou seja, de posse um modelo suficiente e um modelo mais robusto, testar qual performaria melhor diante da alimentação de banco de dados gerados de medidas experimentais e/ou simulados.

A Tabela 9 mostra a performance do modelo de DRNN utilizado para esse propósito, em que faz uso da validação cruzada *K-Fold*.

Espessura máxima da incrustação										
	MAE		MSE		RMSE		MARE		R ²	
	Treinamento	Teste	Treinamento	Teste	Treinamento	Teste	Treinamento	Teste	Treinamento	Teste
1	0,01650	0,01749	0,00159	0,00176	0,03994	0,04194	0,26723%	0,28868%	0,9998873	0,9998735
2	0,01727	0,01668	0,00165	0,00141	0,04065	0,03752	0,30672%	0,31830%	0,9998831	0,9998991
3	0,01728	0,01725	0,00163	0,00179	0,04038	0,04230	0,35294%	0,33352%	0,9998839	0,9998750
4	0,01697	0,01752	0,00161	0,00200	0,04012	0,04468	0,28384%	0,29008%	0,9998858	0,9998591
5	0,01647	0,01850	0,00158	0,00199	0,03970	0,04466	0,28145%	0,31236%	0,9998876	0,9998617
6	0,01697	0,01672	0,00175	0,00136	0,04180	0,03692	0,26913%	0,25806%	0,9998763	0,9999026
7	0,01644	0,01650	0,00165	0,00141	0,04061	0,03754	0,26381%	0,27662%	0,9998840	0,9998970
8	0,01633	0,01693	0,00155	0,00181	0,03935	0,04255	0,26343%	0,27813%	0,9998901	0,9998722
9	0,01753	0,01882	0,00161	0,00204	0,04011	0,04521	0,30641%	0,31857%	0,9998846	0,9998614
10	0,01636	0,01696	0,00161	0,00128	0,04017	0,03580	0,26545%	0,30596%	0,9998853	0,9999118
Média	0,01681	0,01734	0,00162	0,00169	0,04028	0,04091	0,28604%	0,29803%	0,9998848	0,9998813

Tabela 9 – Performance da DRNN na validação cruzada K-Fold

*MAE - Mean Absolute Error; MSE - Mean Squared Error; RMSE - Root Mean Squared Error; MARE - Mean Absolute Relative Error

É possível notar, por meio das métricas apresentadas na Tabela 9, que a DRNN foi capaz de obter resultados satisfatórios para ambos os padrões (treinamento e teste). O conjunto de teste, que apresenta 1041 padrões de diferentes espessuras e posições, obteve valores médios ($MAE = 0,01734$, $MSE = 0,00169$, $RMSE = 0,04091$, $MARE = 0,29803\%$ e $R^2 = 0,9998813$) que mostram a boa capacidade de generalização do modelo, inferindo que a DRNN é capaz de realizar a predição da espessura máxima de incrustação para padrões não treinados apresentando erros muito pequenos.

Nesse contexto, a Figura 37 mostra os valores de espessura de incrustação para o conjunto de Treinamento previstos pela DRNN em comparação com os dados reais simulados.

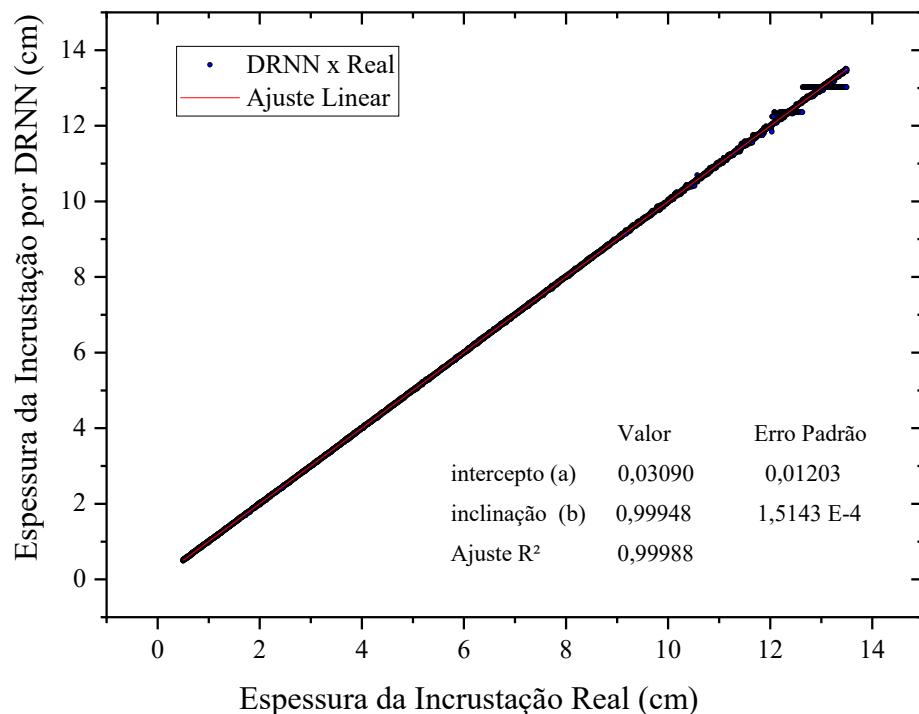


Figura 37 - Resultados obtidos pela DRNN para o conjunto de Treinamento considerando incrustações excêntricas.

Por outro lado, de forma a visualizar o desempenho da DRNN na predição dos padrões, obteve-se o resultado para o conjunto de Teste, ver Figura 38.

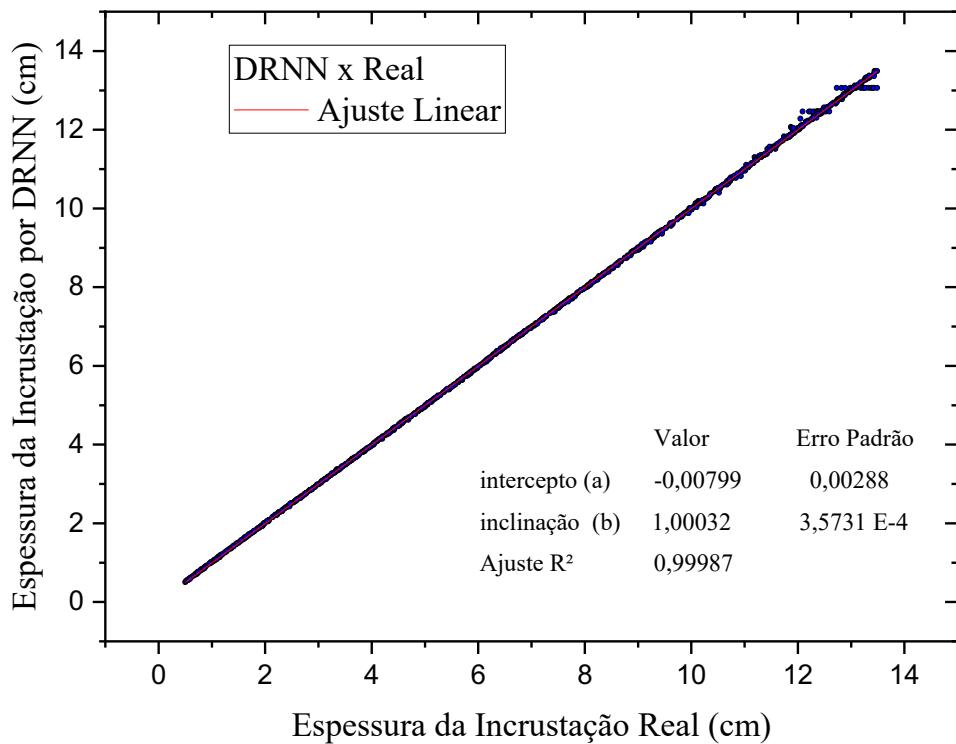


Figura 38 – Resultados obtidos pela DRNN para o conjunto de Treinamento considerando incrustações excêntricas.

Nota-se que todos os padrões foram classificados com precisão para as posições 0°, 30°, 60° e 90°. Estes resultados mostram que a DRNN é capaz de atingir uma boa capacidade de generalização para esses casos.

4.4 Caracterização das amostras de incrustação

4.4.1 Caracterização das amostras por Fluorescência de raios X (FRX)

As Figuras 39 a 41 mostram os espectros de FRX obtidos para cada amostra de incrustação (amostras 1, 2 e 3) nas análises 1 e 4 (aplicação *Omnian*), respectivamente.

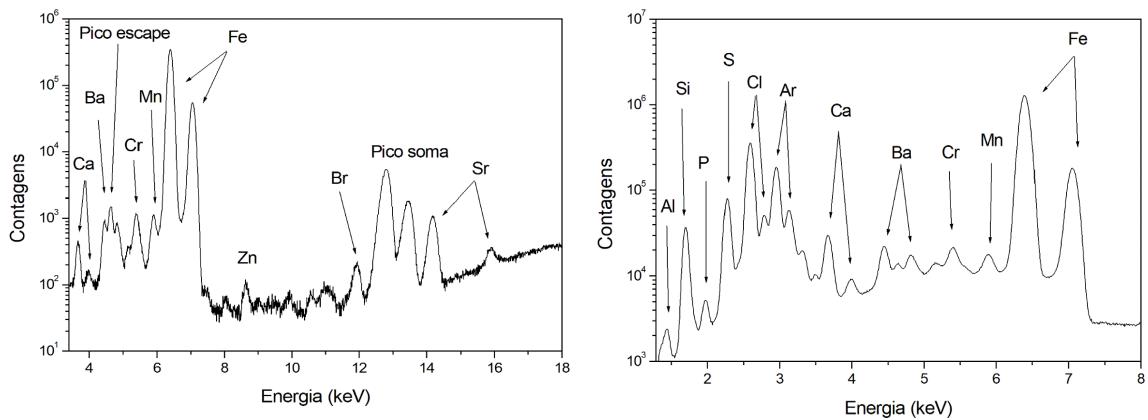


Figura 39 – Espectro de FRX da amostra de incrustação 1 (conf.: Análise 1 e 4)

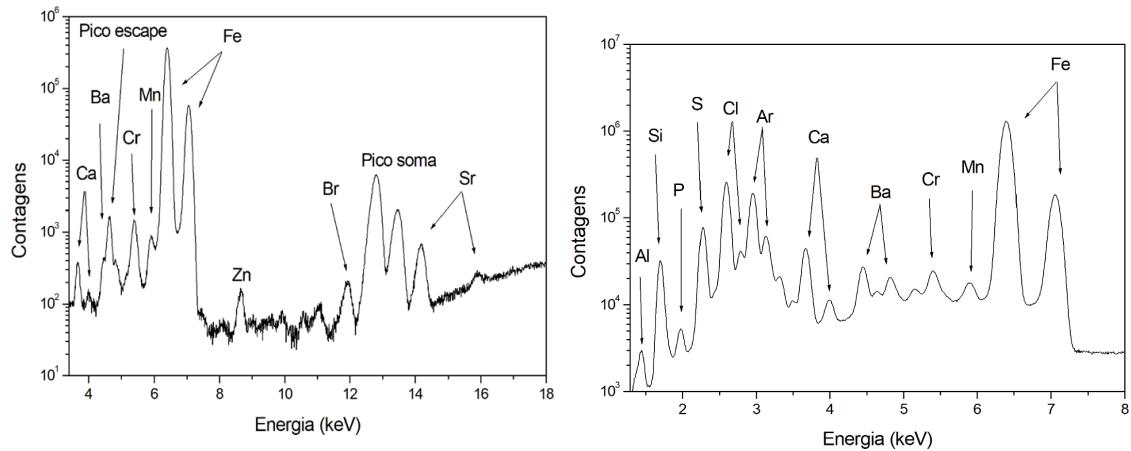


Figura 40 – Espectro de FRX da amostra de incrustação 2 (conf.: Análise 1 e 4)

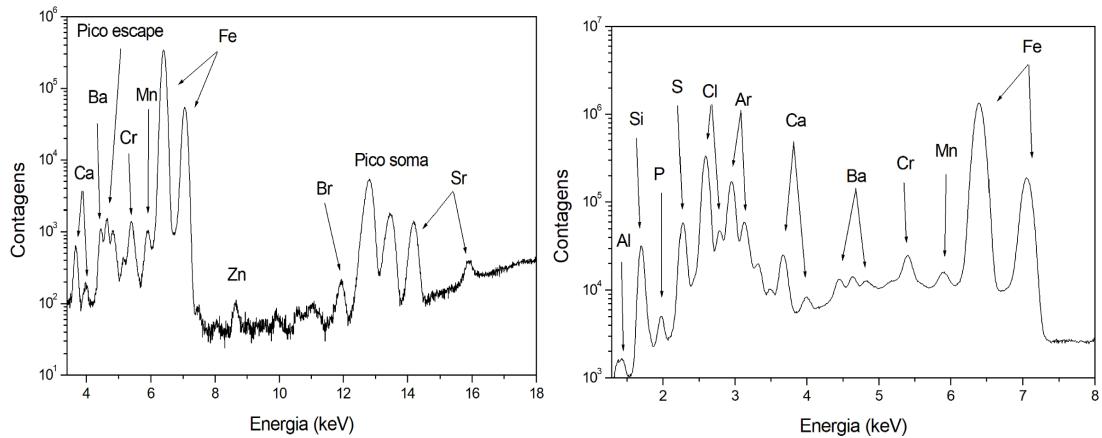


Figura 41 – Espectro de FRX da amostra de incrustação 3 (conf.: Análise 1 e 4)

A Figuras 42 mostra a comparação entre a concentração média dos elementos formadores das amostras A1, A2 e A3.

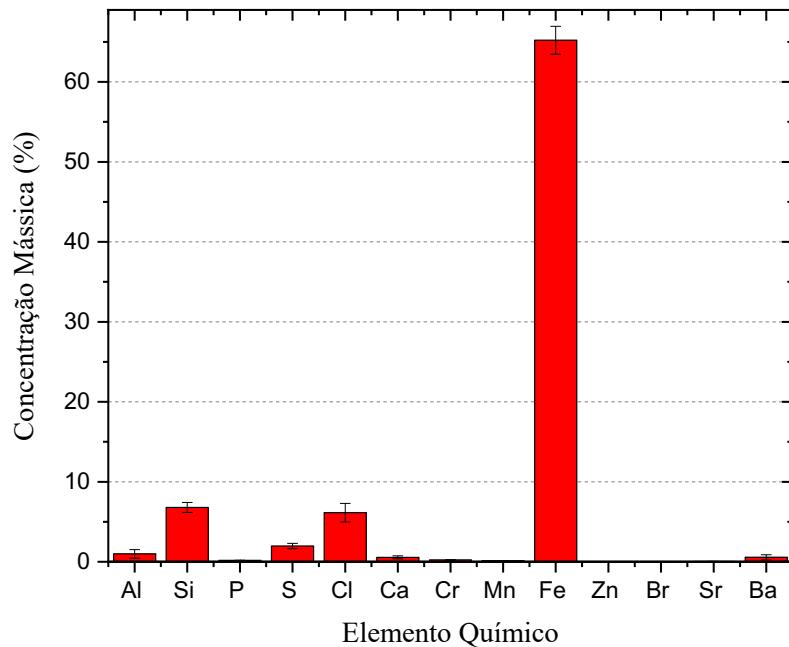


Figura 42 – Comparação da concentração elementar média entre as amostras medidas por FRX.

Foi possível obter as concentrações elementares dos elementos Al, Si, P, S, Cl, Ca, Cr, Mn, Fe, Zn, Br, Sr e Ba. Além disso, nos espectros de FRX aparecem o elemento Ar, devido o experimento ter sido realizado no ar.

É possível notar que em todas as amostras há a presença significativa de Ferro, caracterizado pelos picos mais pronunciados nos espectros demonstrados pelas Figuras 42 a 44. Através da comparação realizada entre os elementos presentes mostrada na Figura 45, é consideravelmente superior a concentração do elemento Ferro nessas amostras, com média de 65,21% de contribuição em relação aos demais elementos.

4.4.2 Caracterização das amostras por Difração de raios X (DRX)

Nas Figuras 43 a 45 são apresentadas as fases presentes nas amostras de incrustação analisadas por difração de raios X através de seus respectivos difratogramas, bem como o percentual mássico semiquantitativo de cada fase.

Na Figura 46 são apresentados os valores médios de composição das três amostras. É possível ter uma avaliação qualitativa da fração mássica dos componentes elementares e suas contribuições na incrustação estudada.

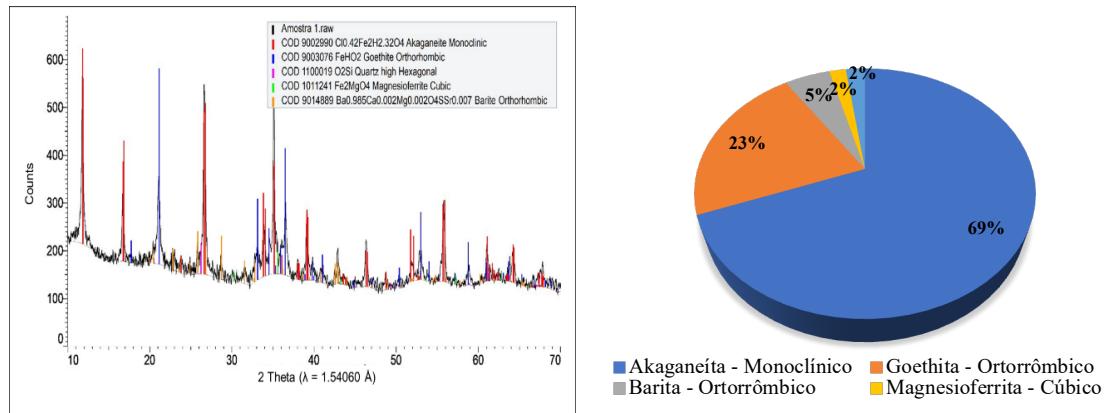


Figure 43 - Perfil de difração e análise semiquantitativo para a amostra A1.

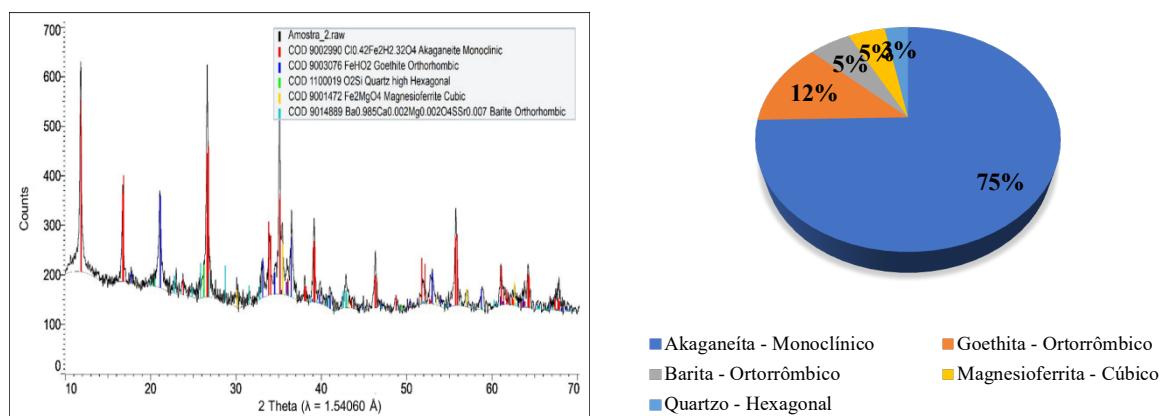


Figure 44 - Perfil de difração e análise semiquantitativo para a amostra A2.

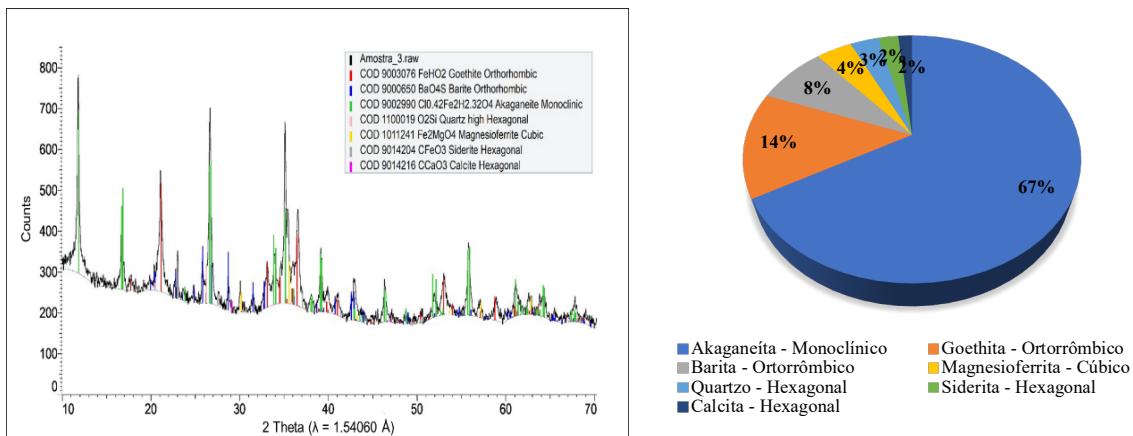


Figure 45 - Perfil de difração e análise semiquantitativo para a amostra A3.

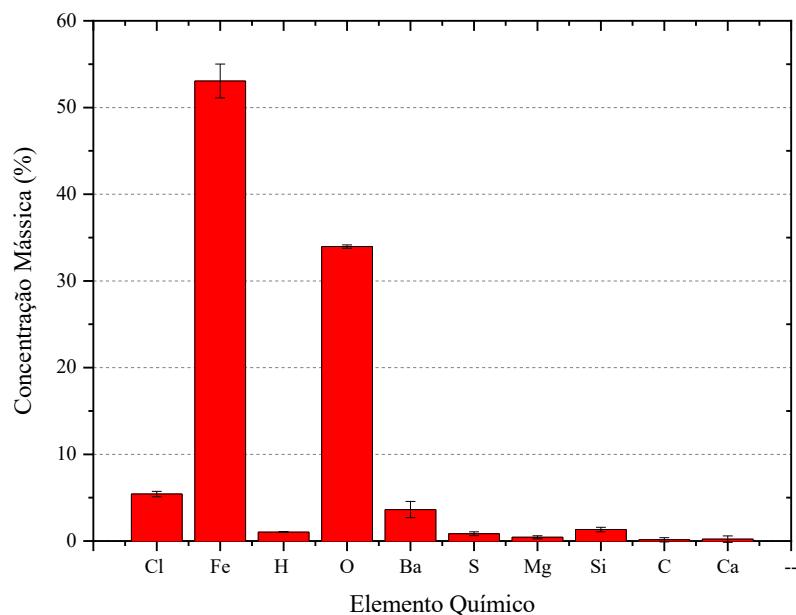


Figure 46 - Valor médio e desvio padrão para as frações mássicas dos elementos contidos nas amostras A1, A2 e A3 por DRX.

Em todas as amostras foram encontrados compostos de Akaganeita, Goethita, Quartz, Magnesioferrita e Barita, mas na amostra 3, além dos compostos já citados, foram encontrados os minerais Siderita e Calcita. A matriz principal de todas as amostras é Akaganeita ($\text{Cl}_{0,42}\text{Fe}_{2,32}\text{O}_4$) no sistema cristalino monoclinico, apresentando uma

concentração de 69,2% na amostra 1, 74,7% na amostra 2 e 66,9% na amostra 3. A segunda maior concentração está relacionada ao mineral Goethita (FeHO_2) no sistema cristalino ortorrômbico, com concentração de 21,5% na amostra 1, 12,4% na amostra 2 e 13,9% na amostra 3. A barita se apresenta em duas fases distintas nas 3 amostras, mas todas no sistema cristalino ortorrômbico. Nas amostras 1 e 2, a barita é apresentada com impurezas de Ca, Mg e S, enquanto na amostra 3 ela é apresentada na forma pura (BaSO_4). Suas concentrações são de 5,2% na amostra 1, 5,3% na amostra 2 e 8,0% na amostra 3. Os demais compostos apresentam concentrações abaixo de 5,0% cada.

Tanto a Akaganeíta quanto a Goethita são compostos que possuem Ferro em sua composição, de modo que o local de onde as amostras foi extraído contém este elemento em abundância. Esses dois compostos são apresentados na literatura como um produto de corrosão. A Akaganeíta é formada em um ambiente com alto teor de cloreto (*Antunes et al, 2003; Morcillo et al, 2015*).

4.5 Determinação das espessuras das incrustações independente de sua posição dentro do tubo.

Conforme mencionado na sessão 3.5, essa etapa do trabalho se dedicou ao treinando e teste de uma rede neural alimentada por dados simulados para 4000 casos de incrustações geradas de forma aleatória dentro do tubo.

Assim como nos modelos anteriores, o parâmetro base para a avaliação do progresso ou não de aprendizagem da rede neural foi o acompanhamento da função de perda. Ela quantifica numericamente o erro do modelo, permitindo acompanhar a evolução da aprendizagem durante o treinamento. Nos modelos anteriores, esse critério já havia sido utilizado para avaliar ajustes nos pesos da rede e a capacidade de generalização. Portanto, manter essa métrica como referência garante consistência na avaliação do desempenho da RNA, permitindo comparações diretas entre diferentes configurações e estratégias de otimização. Além disso, a redução da função de perda ao longo das épocas indica que a rede está aprendendo padrões nos dados e melhorando sua capacidade preditiva, conforme pode ser observado na Figura 47.

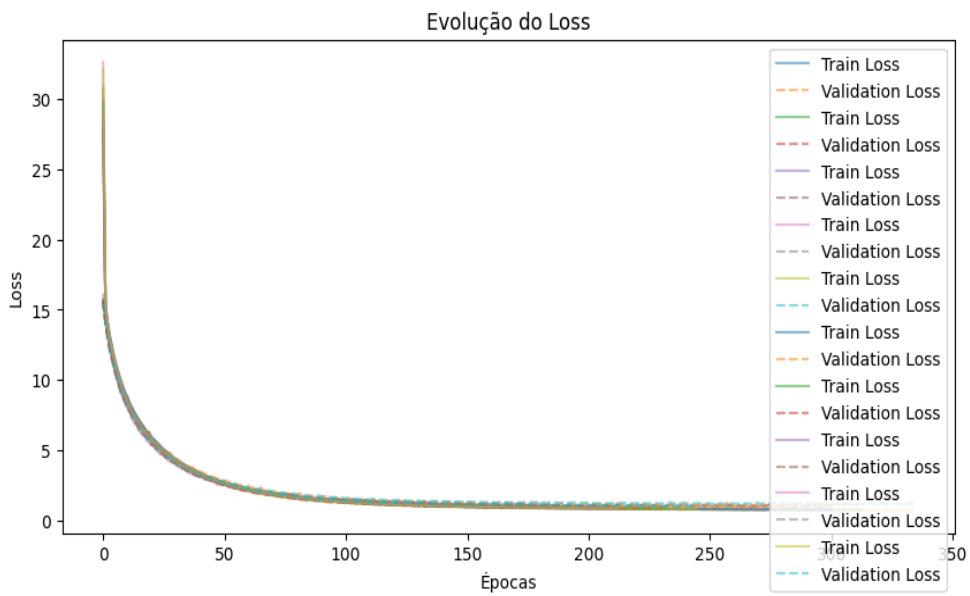


Figure 47 – Progresso para o processo de aprendizado para o modelo 3

Na Figura 48 são mostrados os dados para o conjunto de treinamento obtidos pelo modelo 3 em comparação aos dados reais, obtidos pelas simulações com o código MCNPX.

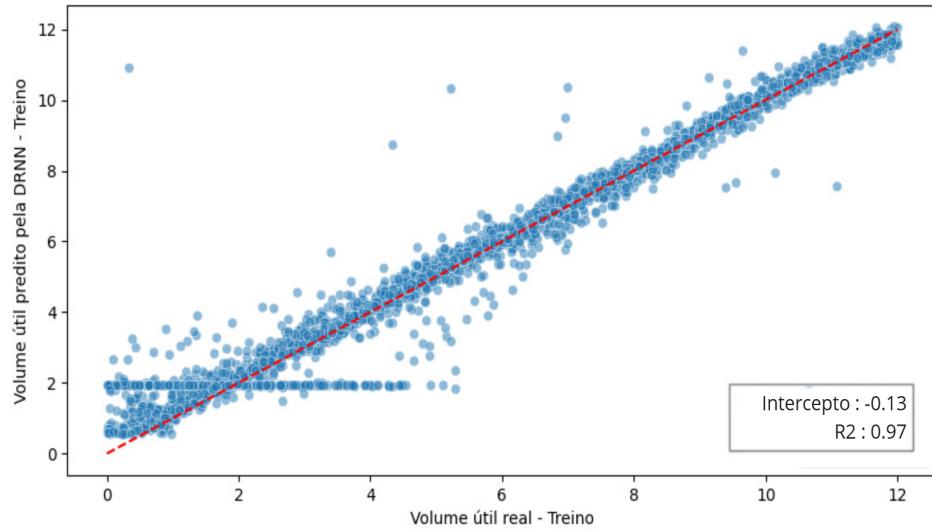


Figura 48 - Resultados obtidos pela DRNN para o conjunto de Treinamento considerando incrustações independentes de sua localização

Por outro lado, na Figura 49 podemos observar a predição da rede neural para os dados de testes, dados completamente novos, em comparação aos dados reais obtidos pelas simulações com o código MCNPX.

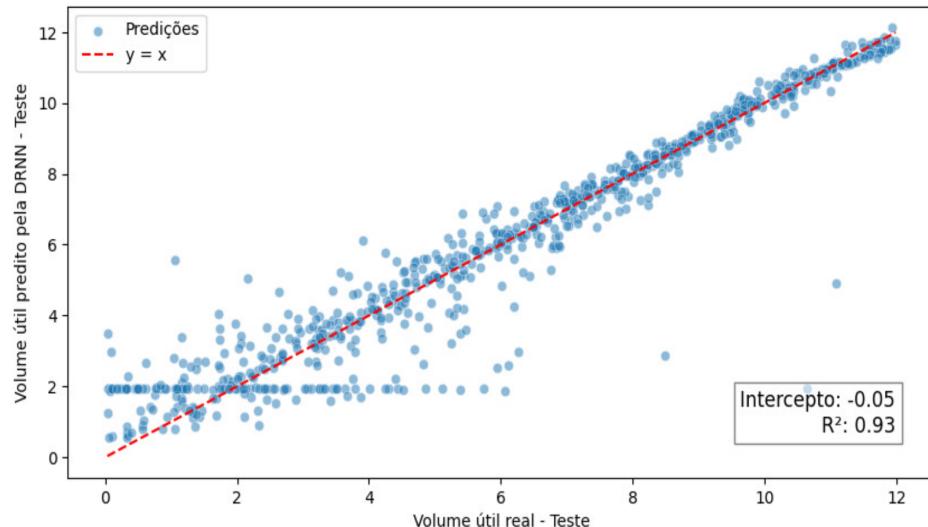


Figura 49 - Resultados obtidos pela DRNN para o conjunto de Teste considerando incrustações independentes de sua localização

Conforme pode ser observado pelos resultados, a introdução de incrustações geradas de forma aleatória adicionou uma maior variabilidade aos dados, tornando o problema mais complexo para a rede neural artificial (RNA). Esse aumento na complexidade resultou em um leve decréscimo no coeficiente de determinação ($R^2 = 0.94$ quando comparado aos cenários mais simplificados (modelos anteriores, com $R^2 = 0.999$). Esse comportamento era esperado, pois a presença de padrões menos estruturados e de características estocásticas nos dados desafia a capacidade do modelo de aprender relações determinísticas.

CAPÍTULO V

5- CONCLUSÕES

Resumidamente, até esta etapa da tese, foi apresentado um trabalho inovador (até onde foram as pesquisas deste autor) que aplicam o uso de redes neurais profundas ao problema complexo de determinação de incrustações em tubulações usadas no transporte de petróleo.

A metodologia adotada consistiu em elaborar de forma gradual, até que se chegasse a um modelo robusto e eficaz, uma rede neural profunda retificada para servir como previsor capaz de, alimentado por distribuições de altura de pulsos, provenientes de modelos simulados com diferentes posições radiais de deposição, fornecesse um diagnóstico acerca da espessura da incrustação em uma tubulação incrustada de interesse. Para isso, foram estudados os dois tipos de deposição de incrustação recorrente na indústria petrolífera com auxílio de simulações baseadas no método de Monte Carlo, e avaliadas as espessuras e localizações radiais dessas deposições no interior do duto. Dessa forma, o modelo inteligente foi capaz de predizer as espessuras com valores de $R^2 = 0,999$. Esses valores mostram a boa capacidade de generalização do modelo.

Para uma etapa seguinte, foi realizado um estudo químico e mineralógico de amostras de incrustações reais, provenientes de tubulações descomissionadas. Essas amostras passaram por um processo de caracterização através das técnicas de Fluorescência e Difração de raios X. Por meio delas, foi possível analisar, de forma quantitativa, a contribuição química de cada elemento que forma a matriz da incrustação. O principal elemento presente nas amostras é o Ferro e seus derivados, sendo possível inferir que a tubulação promoveu um processo corrosivo em seu interior, favorecendo a migração e formação de elementos ferrosos para a incrustação. Essas informações acerca da composição da incrustação, serão de suma relevância, uma vez que serão acrescentados nos próximos modelos simulados, a fim de viabilizar a validação experimental dos mesmos.

Adicionalmente, ao considerar os modelos com incrustações geradas aleatoriamente, foi possível observar uma ligeira redução no desempenho do modelo, com um valor de $R^2 = 0.934$, em comparação com o cenário de incrustações com distribuições mais estruturadas ($R^2 = 0.999$). Este decréscimo no desempenho é atribuível à maior variabilidade nos dados de entrada, decorrente da aleatoriedade nas incrustações,

o que torna o problema mais desafiador para a rede neural. Contudo, o valor de R^2 ainda se mantém elevado, o que indica que o modelo possui uma boa capacidade de generalização, mesmo quando enfrenta maior complexidade. Esses resultados sugerem que o modelo desenvolvido é robusto e suficiente para lidar com cenários variados, representando uma significativa melhoria em relação aos modelos anteriores que não consideravam a variabilidade aleatória nas incrustações.

O sistema resultante, portanto, extensível à solução dos problemas da indústria de petróleo, avança o estado da arte apresentado em trabalhos anteriores no qual a metodologia adotada neste trabalho se baseou e supera demais trabalhos similares aplicando DRNN ao problema, seja em taxa de acerto, abrangência e complexidade do conjunto de dados considerado.

REFERÊNCIAS BIBLIOGRÁFICAS

- A. G. EVSUKOFF. Inteligência Computacional: Fundamentos e Aplicações. 1. ed. Rio de Janeiro: e-papers, 2020. v. 1. 526 p.
- A. MAAS, A. HANNUN, AND A. NG, “Rectifier Nonlinearities Improve Neural Network Acoustic Models,” in International Conference on Machine Learning (icml), 2013.
- ABADI, M. et al. TensorFlow: A system for large-scale machine learning. In: Usenix Symposium on Operating Systems Design and Implementation. Proceedings... pp. 265-283, 2016.
- ABDULLAH, J. Gamma ray scanning for troubleshooting, optimization and predictive maintenance of distillation columns. Hydrocarbon Asia, p. 62-65, 2005.
- ABDUL-MAJID S., 2013. “Determination of wax deposition and corrosion in pipelines by neutron back diffusion collimation and neutron capture gamma-rays”. Applied Radiation and Isotopes, 74, pp. 102–108.
- ABDUL-MAJID S., DAWOOD O., 1989. “Neutron-capture gamma ray technique for scale identification inside pipes”. Desalination, 75 (1989), pp. 199-210.
- ABDUL-MAJID S., MELAIBARI A., MALKI B., 1996. “Hydrocarbon scale deposit measurements by neutron moderation and capture gamma method”. Nucl. Instrum. Methods Phys. Res. B, 119 (1996), pp. 433-437.
- ABDUL-MAJID, Samir. 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.
- ABRO, E., JOHANSEN, G.A. e OPEDAL, H., A radiation transport model as a design tool for gamma densitometers, Nuclear Instruments and Methods in Physics Research, A431, pp.347-355, 1999.
- ABRO, E., KHORYAKOV, V. A., JOHANSEN, G.A. e KOCBACH L., Determination of void fraction and flow regime using a neural network trained on simulated data based on gamma-ray densitometry, Meas. Sci. Technol, 10, pp.619-630, 1999.
- ACHMAD B. E HUSSEIN E.M.A., An X-ray Compton scatter method for density measurement at a point within an object”, Applied Radiation and Isotopes, 60, pp. 805-814, 2004.

- AL RAWAHI, Y. M., SHAIK, F., RAO, L. N., Studies on Scale Deposition in Oil Industries & Their Control. IJIRST –International Journal for Innovative Research in Science & Technology, 3, pp. 2349-6010, 2017.
- AMIRI M. AND MOGHADASI J., 2010. “Prediction the amount of Barium Sulfate scale formation in Siri oilfield using OLI ScaleChem software”. Asian Journal of Scientific Research, vol. 3, pp. 230-239.
- ANJOS, M. J.; LOPES, R. T.; DE JESUS, E. F. O.; ASSIS, J. T.; CESAREO, R.; BARRADAS, C. A. A.; Quantitative Analysis of Metals in Soil Using X-ray Fluorescence. *Spectrochimica Acta. B*, v. 55, p. 1189-1194, 2000.
- ANTUNES, R. A.; COSTA, I.; FARIA, D. L. A.; Characterization of corrosion products formed on steels in the first months of atmospheric exposure. *Materials Research*, v. 6 (3), p. 403-408, 2003.
- ARAÚJO A. A., 2005. “Determinação radioquímica de ^{210}Pb e ^{226}Ra em borras e incrustações de petróleo”. M.S. thesis, Universidade Federal de Pernambuco, Recife, PE, Brasil.
- ASKARI, Mojtaba et al. A gamma-ray tomography system to determine wax deposition distribution in oil pipelines. *Review of Scientific Instruments*, v. 90, n. 7, p. 075103, 2019.
- ASTUTO, A., Desenvolvimento de um Sistema de Inspeção de Tubos usando a técnica de Transmissão Gama, M.Sc, COPPE/UFRJ, Rio de Janeiro, Brasil, 1995.
- ATKINSON, G. AND MECIK, M., CaCO_3 scale formation: How do we deal with the effects of pressure? *Conf. Corrosion* 94. 610, 12 pp, 1994.
- BENGIO, Yoshua; COURVILLE, Aaron; VINCENT, Pascal. Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, v. 35, n. 8, p. 1798-1828, 2013.
- BENUWA, B.B., ZHAN, Y.Z., GHANSAH, B., WORNYO, D.K., BANASEKA KATAKA, F., 2016. “A review of deep machine learning”. *International Journal of Engineering Research in Africa.*, vol. 24, pp 124–136.
- BERGSTRA, J., BENGIO, Y., 2012. Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, vol.13, pp 281–305.
- BERMAN A. I., AND HARRIS J. N., 1954. “Precision measurement of uniformity of materials by gamma-ray transmission”. *Review Scientific Instruments*, vol. 25, no. 1, pp. 21-29.

- BERTERO, L., CHIERICI, G.L., GOTTARDI, G., MESINI, E. and MORMINO, G., Chemical Equilibrium Models: Their Use in Simulating the Injection of Incompatible Waters, SPE paper 14126 presented at the SPE International Meeting on Petroleum Engineering held in Beijing, China, 1986.
- BESERRA, M. T. F., Avaliação da espessura de incrustações em dutos de extração de petróleo, M.Sc, Instituto de radioproteção e dosimetria, Comissão Nacional de Energia Nuclear, IRD-RJ, Rio de Janeiro, RJ, Brasil, 2012.
- BEZERRA, Eduardo. Introdução à aprendizagem profunda. Artigo–31º Simpósio Brasileiro de Banco de Dados–SBBD2016–Salvador, 2016.
- BHANDARI, N., KAN, A.T., ZHANG, F., DAI, Z., YAN, F., RUAN, G., ZHANG, Z., LIU, Y., RUDI, E., TOMSON, M.B., 2016. Mineral precipitation kinetics: assessing the effect of hydrostatic pressure and its Implication on the nucleation mechanism. *Cryst. Growth Des.* 16, 4846–4854.
- BISHOP, Christopher M. Pattern recognition and machine learning. Springer, 2006.
- BJØRNSTAD T., AND STAMATAKIS E., 2006a. “Scaling studies with gamma transmission technique”. *Oil Field Chemistry*, pp.19-22, Geilo, NORWAY.
- BJØRNSTAD T. AND STAMATAKIS E., 2006b. “Applicability and Sensitivity of Gamma Transmission and Radiotracer Techniques for Mineral Scaling Studies”. Institute for Mineral Scaling Studies, Institute for Energy Technology, NORWAY
- BUKUAGHANGIN, O., SANI, O., KAPUR, N., HUGGAN, M., NEVILLE, A., CHARPENTIER, T., 2016. Kinetics study of barium sulphate surface scaling and inhibition with a once-through flow system. *J. Pet. Sci. Eng.* 147, 699–706.
- BURGER, E. D., PERKINS, T.K., STRIEGLER, J.H., Studies of Wax Deposition in the Trans Alaska Pipeline. In: *Journal of Petroleum Technology*, v. 33, n. 06, pp 1075-1086, Society of Petroleum Engineers, 1981.
- CANDEIAS, J.P., Análise de Incrustações por Técnicas Atômicas/Nucleares. Tese D.Sc, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2010.
- CANDEIAS, J.P., OLIVEIRA, D.F., ANJOS, M.J., LOPES, R.T., 2014. Scale analysis using X-ray microfluorescence and computed radiography. *Radiat. Phys. Chem.* 95, 408–411.
- CARNEIRO, JÚNIOR. C, Desenvolvimento de um Sistema de Inspeção baseado em Transmissão Gama para Aplicação em Dutos Flexíveis e Colunas Industriais. M.Sc, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2005.

- CHEN, T., NEVILLE, A., YUAN, M., 2005. Calcium carbonate scale formation—assessing the initial stages of precipitation and deposition. *J. Pet. Sci. Eng.* 46, 185–194.
- CHOLLET, F. Keras. Versão 2.2.4. [S.I.]: 2018. Disponível em: <<https://github.com/fchollet/keras>>.
- CLEVERT, D.A., UNTERTHINER, T., HOCHREITER, S., 2015. Fast and accurate deep network learning by exponential linear units (elus). *arXiv preprint arXiv:1511.07289*.
- COHEN-TANNOUDJI, Claude; DIU, Bernard; LALOË, Franck. Mécanique quantique. Hermann, EDP Sciences, 1998.
- COLLINS, R. I, JORDAN, M.M., 2001. Occurrence, prediction and prevention of zinc sulfide scale within gulf coast and North Sea high temperature/high salinity production wells. *The SPE Third International Symposium on Oilfield Scale*, Aberdeen, UK. SPE 68317, 1–17.
- COTO B., MARTOS C., PEÑA J.L., ESPADA J.J., ROBUSTILLO M.D., 2008. “A new method for determination of wax precipitation from non-diluted oils by fractional precipitation”. *Fuel*, vol. 87, pp. 2090–2094.
- COWAN J.C., WEINTRITT D.J., 1976. *Water-Formed Scale Deposits*, Gulf Publishing.
- CRABTREE, M., ESLINGER, D., FLETCHER, P., JOHNSON, A., KING, G., 1999. Fighting scale-removal and prevention. *Oilfield Rev.* 11, 30–45.
- CRUZ, R. P, Estudo da Composição Química de Borras e Incrustações oriundas das atividades de produção de petróleo e sua correlação com a Radioatividade Natural – Estudo de Caso: Bacia de Campos-Brasil. M.Sc, PUC/RJ, Rio de Janeiro, RJ, Brasil, 2002.
- CULLITY, B. D. *Elements of X-Ray Diffraction*. Addison-Wesley Publishing Company, Inc., 1956.
- CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, v. 2, n. 4, pp. 303-314, 1989.
- D. A. Clevert, T. Unterthiner, and S. Hochreiter, “Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs),” *arXiv*, 2015. [Online]. Available: <http://arxiv.org/abs/1511.07289>
- DESTERRO, F.S.M., SANTOS, M.C., GOMES, K.J., HEIMLICH, A., SCHIRRU, R., PEREIRA, C.M.N.A., 2020. Development of a Deep Rectifier Neural Network for

- dose prediction in nuclear emergencies with radioactive material releases. *Progress in Nuclear Energy*. vol. 118.
- DEWANCKER, I., MCCOURT, M., CLARK, S., 2015. “Bayesian Optimization for Machine Learning: A Practical Guidebook”. SigOpt, San Francisco, CA 94108. arXiv:1612.04858.
- DRAKE, S. G.; SEWARD, J. C., Radiographic Detection of Pipe Corrosion Under Lagging, GB Patent Document, UK., July. 1989.
- FERREIRA V. F., REIS M. I. P., SILVA F. C., ROMEIRO G. A., ROCHA A. A., “Deposição Mineral em Superfícies: Problemas e Oportunidades na Indústria do Petróleo”, 2011. *Revista Virtual de Química*, vol. 3, pp. 2-13.
- FULHAM, M. J.; HULBERT, V. G., Gamma Scanning of Large Towers, *Chem. Eng. Prog.*, 1975,71, p. 73-77.
- G. KLAMBAUER, T. UNTERTHINER, A. MAYR, AND S. HOCHREITER, “Self-Normalizing Neural Networks,” arXiv, 2017. [Online]. Available: <https://arxiv.org/pdf/1706.02515v5.pdf>
- GAZINEU, M. H. P., Teores de radionuclídeos em processos de extração e de produção de petróleo no Nordeste do Brasil. Tese D.Sc, UFPE, Recife, PE, Brasil, 2005.
- GERON, A. Mão à Obra: Aprendizado de Máquina com Scikit-Learn TensorFlow, 2019.
- GHEISARI, M., WANG, G., BHUIYAN, M. Z. A., "A Survey on Deep Learning in Big Data," 2017 IEEE International Conference on Computational Science and Engineering (CSE) and IEEE International Conference on Embedded and Ubiquitous Computing (EUC), Guangzhou, 2017, pp. 173-180.
- GLOROT, X., BENGIO, Y., 2010. Understanding the difficulty of training deep feedforward neural networks. In: Proc. AISTATS, vol. 9. pp. 249–256.
- GLOROT, X., BORDES, A., BENGIO, Y., 2011. Deep sparse rectifier neural networks. Proceedings of the fourteenth international conference on artificial intelligence and statistics. In: PMLR, vol. 15. pp. 315–323.
- GLOROT, Xavier; BENGIO, Yoshua. Understanding the difficulty of training deep feedforward neural networks. In: Proceedings of the thirteenth international conference on artificial intelligence and statistics. 2010. p. 249-256.
- GODOY J. M., CRUZ R. P., 2003. “ ^{226}Ra and ^{228}Ra in scale and sluge samples and their correlation with the chemical composition”. *Journal Environmental Radioactivity*, vol. 70, pp. 199-206.

- GODOY, José Marcus; DA CRUZ, Rosana Petinatti. 226Ra and 228Ra in scale and sludge samples and their correlation with the chemical composition. *Journal of Environmental Radioactivity*, v. 70, n. 3, p. 199-206, 2003.
- GRAHAM G.M., DYER S.J., 2002. The effect of temperature and pressure on oilfield scale formation, *Journal of Petroleum Science and Engineering*. 35, 95– 107.
- GRAHAM, A.L., VIEILLE, E., NEVILLE, A., BOAK, L.S., SORBIE, K.S., 2004. “Inhibition of BaSO₄ at a Hastelloy Metal Surface and in Solution: The Consequences of Falling Below the Minimum Inhibitor Concentration (MIC)”. Society of Petroleum Engineers.
- HAGHTALAB, A., KAMALI, M.J., SHAHRABADI, A., GOLGHANDDASHTI, H., 2015. Investigation of the Precipitation of Calcium Sulfate in Porous Media: Experimental and Mathematical Modeling. *Chemical Engineering Communications*. 202, 1221-1230.
- HAMLAT, M. S.; KADI, H.; FELLAG, H. Precipitate containing norm in the oil industry: modelling and laboratory experiments. *Applied radiation and isotopes*, v. 59, n. 1, p. 95-99, 2003.
- HAYKIN, S. *Redes neurais: princípios e prática*. 2. ed. Bookman Editora, 2007.
- HAYKIN, S., 1994. “Neural Networks – A Comprehensive Foundation”, Macmillan College Publishing Company.
- HEBB, D. O. *The Organization of Behavior*. John Wiley & Sons, 1949.
- HENRY, A. S. Jr; DAVIS, E. L. A method for predicting the tendency of oil field waters to deposit calcium sulfate. *Journal of Petroleum Technology*, v. 4, n. 02, p. 25-28, 1952.
- HU, Y., MACKAY, E., VAZQUEZ, O., & ISHKOV, O. Streamline simulation of barium sulfate precipitation occurring within the reservoir coupled with analyses of observed produced-water-chemistry data to aid scale management. *SPE Production & Operations*, v. 33, n. 01, p. 85-101, 2018.
- HUBBELL, J. H. e SELTZER, S. M., 1997. “Tables of X-ray Mass Attenuation Coefficients and Mass Energy-Absorption Coefficients” (version 1.03). [Online] Available: <http://physics.nist.gov/xaamdi> [2004, July 26]. National Institute of Standards and Technology, Gaithersburg, MD.
- HUBBELL, J. H. Seltzer, SM. Tables of X-Ray Mass Attenuation Coefficients and Mass Energy-Absorption Coefficients (version 1.02) [Online]. Available, 1997.

- HUNTER, J. D. Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, v. 9, n. 3, pp. 90-95, 2007.
- HURLBUT, C. S., & KLEIN, C. Manual of mineralogy (after James D. Dana). Wiley, 1977.
- IYENGAR, S.S. Petroleum Exploration and Production. In: Chung F.H. & Smith D. K. Industrial Applications of X-Ray Diffraction. New York: Marcel Dekker, 2000, p. 193-205, 2000.
- JOHANSEN, G. A. e JACKSON, P., 2000. “Salinity independent measurement of gas volume fraction in oil/gas/water pipe flows”, *Applied Radiation and Isotopes*, 53, pp. 595–601.
- JORDAN, M.M., COLLINS, I.R., MACKAY, E.J., 2008. Low sulfate seawater injection for barium sulfate scale control: a life- of-field solution to a complex challenge. *SPE Prod. Oper.* 23, 192–209.
- K. HE, X. ZHANG, S. REN, AND J. SUN, “Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,” arXiv, 2015. [Online]. Available: <http://arxiv.org/abs/1502.01852>
- KAMAL, M. S., HUSSEIN, I., MAHMOUD, M., SULTANC, A. S., SAAD, M. A. S., 2018. Oilfield scale formation and chemical removal: A review. *Journal of Petroleum Science and Engineering*. 171, 127–139.
- KAMARI, Arash et al. Rigorous modeling for prediction of barium sulfate (barite) deposition in oilfield brines. *Fluid Phase Equilibria*, v. 366, p. 117-126, 2014.
- KAN, A.T., TOMSON, M.B., 2012. Scale prediction for oil and gas production. *SPE J.* 17, 362–378.
- KELLAND, M.A., 2014. Production Chemicals for the Oil and Gas Industry, second ed. CRC Press.
- KHATAMI H.R. RANJBAR M., SCHAFFIE M., AND EMADY M.A., 2010. “Development of a fuzzy saturation index for sulfate scale prediction”. *Journal of Petroleum Science and Engineering*, vol.71, pp.13–18.
- KHORMALI, A., SHARIFOV, A.R., TORBA, D.I., 2018. Increasing efficiency of calcium sulfate scale prevention using a new mixture of phosphonate scale inhibitors during waterflooding. *J. Pet. Sci. Eng.* 164, 245–258.
- KHORMALI, Azizollah; PETRAKOV, Dmitry G.; MOEIN, Mohammad Javad Afshari. Experimental analysis of calcium carbonate scale formation and inhibition in

- waterflooding of carbonate reservoirs. *Journal of Petroleum Science and Engineering*, v. 147, p. 843-850, 2016.
- KINGMA, D. P., & BA, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*
- KLEIN, Oskar; NISHINA, Yoshio. Über die Streuung von Strahlung durch freie Elektronen nach der neuen relativistischen Quantendynamik von Dirac. *Zeitschrift für Physik*, v. 52, n. 11-12, p. 853-868, 1929.
- KLOCKENKAMPER, R.; VON BOHLEN, A.; Elemental analysis of environmental samples by Total Reflection Fluorescence: a Review. *X-ray Spectrum*. v. 25, p. 156-162, 1996.
- KNOLL, Glenn F. "Radiation Detection and Measurement", Second Edition, John Wiley & Sons Inc., 1989.
- KOHONEN, T. *Self-Organization and Associative Memory*. Berlim: Springer, 1989.
- KOHONEN, T. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, v. 43, p. 59-69, 1982.
- Lachance, G. R.; Claisse, F. Quantitative X-ray Fluorescence analysis: Theory and Application. 1 ed., New York: John Wiley & Sons, 1995.
- LANL, 2003, "MCNP - A general Monte Carlo n-particle transport code", Los Alamos National Laboratory, version 5, I: Overview and theory, U.S.A.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, p. 436-444, 2015.
- LEWIS, J. W., VAN ESSEN, D. C. Mapping of architectonic subdivisions in the macaque monkey, with emphasis on parieto- occipital cortex. *Journal of Comparative Neurology*, v. 428, n. 1, pp. 79-111, 2000.
- LEWIS, J. W., VAN ESSEN, D. C. Mapping of architectonic subdivisions in the macaque monkey, with emphasis on parieto- occipital cortex. *Journal of Comparative Neurology*, v. 428, n. 1, pp. 79-111, 2000.
- MADY, M.F., KELLAND, M.A., 2017. Study on various readily available proteins as new green scale inhibitors for oilfield scale control. *Energy Fuels*, vol. 31, pp. 5940–5947.
- MANSOORI, H., MIRZAEE, R., ESMAEILZADEH, F., VOJODI, A., DOWRANI, A.S., 2017. Pitting corrosion failure analysis of 2017 of a wet gas pipeline. *Eng. Fail. Anal.* 82, 16–25.

- MANSOORI, H., YOUNG, D., BROWN, B., SINGER, M., 2018. Influence of calcium and magnesium ions on CO₂ corrosion of carbon steel in oil and gas production systems – a review. *J. Nat. Gas Sci. Eng.* 59, 287–296.
- MARTIN A., MEAD S., WADE B. O., “Materials, Containing Natural Radionuclides in Enhanced Concentrations”, European Commission Report EUR 17625, 1997.
- MCCULLOCH, W.; PITTS, W. A logical calculus of ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, p. 115-133, 1943.
- MCKINNEY, W. Data structures for statistical computing in Python. In: PYTHON IN SCIENCE CONFERENCE. Proceedings... pp. 51-56, 2010.
- MI, Y., ISHII, M. E TSOUKALAS, L.H., Vertical two-phase flow identification using advanced instrumentation and neural networks”. *Nuclear Engineering and Design*, 184, 1998, pp.409-420.
- MINSKY, M.; PAPERT, S. *Perceptrons: An Introduction to Computational Geometry*. 2. ed. The MIT Press, 1972.
- MONNO, A., Pipe Wall Thickness, GB Patent Document 2146115/A/, GB Patent Application, 8323913, Int. Cl. G01B 15/02, 9 p., April, 1985.
- MORCILLO, M.; GONZÁLEZ-CALBET, J. M.; JIMÉNEZ, J.A.; DÍAZ, I.; ALCÁNTARA, J.; CHICO, B.; MAZARÍO- FERNÁNDEZ, A.; GÓMEZ-HERRERO, A.; LLORENTE, I.; DE LA FUENTE, D.; Environmental Conditions for Akaganeite Formation in Marine Atmosphere Mild Steel Corrosion Products and Its Characterization. *Corrosion*. v. 71(7), p. 872-886, 2015.
- NADKARNI, Ramachandra A. Modern instrumental methods of elemental analysis of petroleum products and lubricants. ASTM International, 1991.
- NASERI, S., MOGHADASI, J., JAMILAHMADI, M., 2015. Effect of temperature and calcium ion concentration on permeability reduction due to composite barium and calcium sulfate precipitation in porous media. *J. Nat. Gas Sci. Eng.* 22, 299–312.
- NWANKPA, Chigozie et al. Activation functions: Comparison of trends in practice and research for deep learning. arXiv preprint arXiv:1811.03378, 2018.
- ODDO, E., THONSON, M. B., Why Scale Forms and How to Predict It, E. Oddo, SPE, Water Research Inst. Inc., SPE, Rice U., 1994.
- OLAJIRE, A.A., 2015. A review of oilfield scale management technology for oil and gas production. *J. Pet. Sci. Eng.* 135, 723–737.
- OLIVEIRA D. F., NASCIMENTO J. R., MARINHO C. A., LOPES R. T., Gamma transmission system for detection of incrustation in oil exploration pipelines,

Nuclear Instruments and Methods in Physics Reserch A, Rio de Janeiro, RJ, Brazil, 2014.

OLIVEIRA, D. F.; NASCIMENTO J. R.; MARINHO C. A.; LOPES R. T., Gamma transmission system for detection of incrustation in oil exploration pipelines, Nuclear Instruments and Methods in Physics Reserch A, Rio de Janeiro, RJ, Brazil, 2014.

OLIVEIRA, D. F.; Santos R. S.; Machado A. S.; Silva A. S.S.; Anjos M. J.; Lopes R. T., 2019. "Characterization of scale deposition in oil pipelines through X-Ray Microfluorescence and X-Ray microtomography". Applied Radiation and Isotopes, vol. 151, p. 247-255.

OLIVEIRA, D.F., SANTOS, R.S., MACHADO, A.S., SILVA, A.S.S., ANJOS, M. J., LOPES, R. T.; 2019. Characterization of scale deposition in oil pipelines through X-Ray Microfluorescence and X-Ray microtomography. Applied Radiation and Isotopes. 151, 247–255.

OLIVEIRA, Davi F. et al. Crude oil analysis by X-ray scattering technique. X-Ray Spectrometry, v. 48, n. 3, p. 195-201, 2018.

OLIVEIRA, Davi F. et al. Development of a system based on transmission of gamma radiation for detection of incrustations in pipelines used for oil extraction. 2009.

ORTIZ-RODRIGUEZ, J. M., MARTINEZ-BLANCO, M. R., VARAMONTES, VEGA-CARRILLO, J. M., H. R. 2013. Robust Design of Artificial Neural Networks Methodology in Neutron Spectrometry. (K. Prof. Suzuki, Ed.) Artificial Neural Networks - Architectures and Applications

P. RAMACHANDRAN, B. ZOPH, AND Q. V. LE, "Searching for Activation Functions," ArXiv, 2017. [Online]. Available: 1710.05941; <http://arxiv.org/abs/1710.05941>

PEDAMONTI, D., 2018. Comparison of Non-linear Activation Functions for Deep Neural Networks on MNIST Classification Task. CoRR - Computing Research Repository.

PEDREGOSA, F. et al. Scikit-learn: machine learning in Python. Journal of Machine Learning Research, v. 12, pp. 2825-2830, 2011.

PELOWITZ, D. B. MCNP-X Tm User's Manual (2.5 ed.). New Mexico: Los Alamos National Laboratory, 2005. PETROBRÁS, 2013, disponível em: .Acesso em: 08/09/2017.

- PINHEIRO, V.H.C., SANTOS, M.C., DESTERRO, F.S.M., SCHIRRU, R., PEREIRA, C.M.N.A., 2020. Nuclear Power Plant accident identification system with “don’t know” response capability: Novel deep learning-based approaches. *Annals of Nuclear Energy*. vol. 137.
- PUMPERLA, M.: Hyperas: a very simple convenience wrapper around hyperopt for fast prototyping with keras models (2017). <https://maxpumperla.com/hyperas/>. Accessed 27 Mar 2020.
- RAMIREZ, G. F.; FELICIANO, H. J. Methodology to calculate wall thickness in metallic pipes. 1992.
- REIS, M. I. P., DA SILVA, F. C.; ROMEIRO, G. A.; ROCHA, A. A.; FERREIRA, V. F. Deposição Mineral em Superfícies: Problemas e Oportunidades na Indústria do Petróleo. In: Rev. Virtual de Química, v. 3, n. 1, pp 2-13, 2011.
- RENNA, R. B. et al. **Introdução ao kit de desenvolvimento arduino**. Niterói: UFF, 2013. 80p. Apostila.
- ROACH, G. J., WATT, J. S., ZASTAWNÝ, H. W., HARTLEY, P. E. e ELLIS, W. K., 1995. “Field trial of a gamma-ray multiphase flow meter on Thevenard Island”, *Nuclear Geophysics*, v. 9, n. 1, pp. 1–17.
- ROSENBLATT, F. The Perceptron, A Perceiving and Recognizing Automaton. Cornell Aeronautical Laboratory (CAL), 1957. (Project Report N. 85-460-1).
- ROSHANI G.H, NAZEMI E., ROSHANI M.M., 2017A. “A novel method for flow pattern identification in unstable operational conditions using gamma ray and radial basis function”. *Applied Radiation and Isotopes*, vol. 123, pp. 60-68.
- ROSHANI G.H., FEHHI, S.A.H., ADINEH-VAND A., AND KHORSANDI, M., 2013. “Application of adaptive neuro-fuzzy inference system in prediction of fluid density for a gamma-ray densitometer in petroleum products monitoring”. *Measurement*, vol. 46, pp. 3276-3281.
- ROSHANI G.H., KARAMI A., KHAZAEI A., OLFATEH A., NAZEMI E., OMIDI M., 2018. “Optimization of radioactive sources to achieve the highest precision in three-phase flow meters using Jaya algorithm”. *Applied Radiation and Isotopes*, vol. 139, pp. 256–265.
- ROSHANI G.H., KARAMI A., SALEHIZADEH A., NAZEMI E., 2017B. “The capability of radial basis function to forecast the volume fractions of the annular three-phase flow of gas-oil-water”. *Applied Radiation and Isotopes*, vol. 129, pp. 156–162.

- ROSHANI G.H., NAZEMI E., FEHHI S.A.H., 2015. "Flow regime identification and void fraction prediction in two-phase flows based on gamma ray attenuation". Measurement, vol.62, pp. 25-32.
- ROSTRON, P. Critical Review of Pipeline Scale Measurement Technologies. MOJ Mining Met 1 (1): 00004. Critical Review of Pipeline Scale Measurement Technologies, v. 2, p. 14, 2018.
- ROSTRON, P., 2018., Critical Review of Pipeline Scale Measurement Technologies, MOJ Mining and Metallurgy.
- SALGADO W. L., DAM R. S. F., TEIXEIRA T. P., CONTI C.C., SALGADO C.M., 2019. "Application of artificial intelligence in scale thickness prediction on offshore petroleum using a gamma-ray densitometer". Radiation Physics and Chemistry, vol. 168, 108549.
- SALGADO, C. M., BRANDÃO L. E., SCHIRRU R., PEREIRA C. M. N. A. E RAMOS R., SILVA A. X., 2008. "Modelagem de detector NaI(Tl) usando MCNP-X", XI Encontro de Modelagem Computacional, n. 0189, Volta Redonda, RJ.
- SALGADO, C. M., BRANDÃO, L. E., CONTI, C. C., & SALGADO, W. L. Density prediction for petroleum and derivatives by gamma-ray attenuation and artificial neural networks. Applied Radiation and Isotopes, 116, pp. 143-149, 2016. 63
- SALGADO, C. M., PEREIRA, C. M., 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 ,52, pp. 555-562, 2010.
- SALINAS, I. C. P., 2006. Determinação dos fatores de blindagem para construções tipicamente brasileiras. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- SANTOS, M. C., PINHEIRO, V. H. C., DO DESTERRO, F. S. M., DE AVELLAR, R. K., SCHIRRU, R., DOS SANTOS NICOLAU, A., & DE LIMA, A. M. M., Deep rectifier neural network applied to the accident identification problem in a PWR nuclear power plant. Annals of Nuclear Energy, v. 133, p. 400-408, 2019.
- SCHMIDHUBER, J., 2015. Deep learning in neural networks: an overview. Neural Netw. Off. J. Int. Neural Netw. Soc. 61, 85–117.
- SCHMIDT, A. P. Lead precipitates from natural gas production installations. Journal of Geochemical Exploration, v. 62, n. 1-3, p. 193-200, 1998.

- SEELENTAG, W. W.; PANZER, W. Stripping of X-ray bremsstrahlung spectra up to 300 kVp on a desk type computer. *Physics in Medicine & Biology*, v. 24, n. 4, p. 767, 1979.
- SENA, Caio Patrício de Souza. Análise química de produtos de incrustação em dutos de petróleo por espectrometria de fluorescência de raios X. 2008. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte.
- SHAHRIARI, B., SWERSKY, K., WANG, Z., ADAMS, R. P., DE FREITAS, N., 2016. "Taking the Human Out of the Loop: A Review of Bayesian Optimization," in Proceedings of the IEEE, vol. 104, no. 1, pp. 148-175.
- SILVA, R.M.P., BEDRIKOVETSKY, P.G., Previsão da perda da produtividade e de injetividade na Bacia de Campos devido à incrustação de sulfatos, Boletim Técnico da Produção, Rio de Janeiro, volume 2, número 2, pp. 341 – 371, 2007.
- SNOEK, J., LAROCHELLE, H., ADAMS, R., 2012. "Practical Bayesian optimization of machine learning algorithms". In *Advances in Neural Information Processing Systems 25*, pages 2960-2968, 2012.
- SOARES, M., Sistema de detecção de incrustações em dutos de transporte de petróleo pela técnica de transmissão gama, M.Sc., COPPE-UFRJ, Rio de Janeiro, Brasil, 2014.
- SOOD, A. e GARDNER, R. P., 2004. "A new Monte Carlo assisted approach to detector response functions", *Nuclear Instruments Methods Physics, Res. B213*, pp. 100–104.
- SORBIE, K. S.; MACKAY, E. J. Mixing of injected, connate and aquifer brines in waterflooding and its relevance to oilfield scaling. *Journal of Petroleum Science and Engineering*, v. 27, n. 1-2, p. 85-106, 2000.
- SOWERBY B.D., ROGERS C.A., 2005. Gamma-ray density and thickness gauges using ultra-low activity radioisotope sourcefillin. *Applied Radiation and Isotopes*, 63 (2005), pp. 789-793.
- SOWERBY, B. D.; ROGERS, C. A. Gamma-ray density and thickness gauges using ultra-low activity radioisotope sourcesfillin. *Applied radiation and isotopes*, v. 63, n. 5-6, p. 789-793, 2005.
- SRIVASTAVA, R.K., GREFF, K., SCHMIDHUBER, J., 2015. Training Very Deep Networks. The Swiss AI Lab IDSIA / USI / SUPSI, *Neural Information Processing Systems (NIPS)*.

- SRIVASTAVA, R.K., GREFF, K., SCHMIDHUBER, J., 2015. Training Very Deep Networks. The Swiss AI Lab IDSIA / USI / SUPSI, Neural Information Processing Systems (NIPS).
- STEEL, Luc; MACKAY, Eric; MAROTO-VALER, M. Mercedes. Experimental investigation of CO₂-brine-calcite interactions under reservoir conditions. *Fuel Processing Technology*, v. 169, p. 122-131, 2018.
- TAUHATA, L., SALATI, I.P.A., PRINZIO, R.DI., PRINZIO, M.A.R.R.DI., Radioproteção e Dosimetria: Fundamentos, Instituto de Radioproteção e Dosimetria, Comissão Nacional de Energia Nuclear, 10^a revisão, Rio de Janeiro, 2013.
- TAVARES, L.M., COSTA, E.M., ANDRADE, J.J.O., HUBLER, R., HUET, B., 2015. Effect of calcium carbonate on low carbon steel corrosion behavior in saline CO₂ high pressure environments. *Appl. Surf. Sci.* 359, 143–152.
- TEIXEIRA et al. Determination of eccentric deposition thickness on offshore horizontal pipes by gamma-ray densitometry and artificial intelligence technique. *Applied Radiation and Isotopes*, v. 165, p. 109221, 2020.
- TEIXEIRA T.P., SALGADO C.M., DAM R.S.F., AND SALGADO W.L., 2018. “Inorganic scale thickness prediction in oil pipelines by gamma-ray attenuation and artificial neural network”. *Applied Radiation and Isotopes*, vol. 141, pp. 44-50.
- TEIXEIRA, T.P., Use of transmission gamma for study of calculation of scale in oil pipelines, INTERNATIONAL NUCLEAR ATLANTIC CONFERENCE - INAC, Belo Horizonte, MG, Brazil, 2017.
- THERESKA, J. Radioisotope applications for troubleshooting and optimizing industrial processes. In: *Analytical applications of nuclear techniques*. 2004.
- TIELEMAN, Tijmen; HINTON, Geoffrey. Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. COURSERA: Neural networks for machine learning, v. 4, n. 2, p. 26-31, 2012.
- TODD, C.A., YUAN, D.M., 1992. Barium and strontium sulfate solid-solution scale formation at elevated temperatures. *SPE Prod. Eng.*, SPE 19762, 85–92.
- VAN ROSSUM, G. Python Programming Language. In: *Usenix Annual Technical Conference. Proceedings...* v. 41, p. 36, 2007.
- VAZIRIAN, M.M., CHARPENTIER, T.V.J., OLIVEIRA PENNA, M., NEVILLE, A., 2016. Surface inorganic scale formation in oil and gas industry: as adhesion and deposition processes. *J. Pet. Sci. Eng.* 137, 22–32.

- VAZQUEZ, O., FURSOV, I., MACKAY, E., 2016. Automatic optimization of oilfield scale inhibitor squeeze treatment designs. *J. Pet. Sci. Eng.* 147, 302–307.
- VETTER, O.J., 1976. Oilfield scale - can we handle it? *Pet. Technol.* 28 (12), 1402–1408.
- WALT, S. V. D.; COLBERT, S. C.; VAROQUAUX, G. The NumPy array: a structure for efficient numerical computation. *Computing in Science & Engineering*, v. 13, n. 2, pp. 22-30, 2011.
- WIDROW, B.; HOFF JR., M. E. Adaptive switching circuits. In: *IRE WESCON Conf. Rec. Proceedings. part 4.* 1960. p. 96-104.
- WONG, T-T. 2015. “Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern Recognition.* vol. 48, issue. 9, pp. 2839-2846
- XIAOYAN ET AL, 2009. The analysis and prediction of scale accumulation for water-injection pipelines in the Daqing Oilfield, *Journal of Petroleum Science and Engineering.* 66, 161–164
- YAN, Chao et al. Systematic study of barite nucleation and inhibition with various polymeric scale inhibitors by novel laser apparatus. *SPE Journal*, v. 20, n. 03, p. 642-651, 2015.
- YAN, F., DAI, Z., RUAN, G., ET AL., 2017. Barite scale formation and inhibition in laminar and turbulent flow: a rotating cylinder approach. *J. Pet. Sci. Eng.* 149, 183–192.
- YI, T., JIN, Z., CHUAN-LI, X., WEI-YING, W., 2014. A Bohai Sea SZ36-1 oilfield formation scaling experimental study and scale inhibitor optimization. *Pet. Sci. Technol.* 32 (20), 2512–2519.
- ZHANG, P., LIUA, Y., KUOKA, S. C., KANB, A. T., TOMSON, M. B., 2019. Development of modeling approaches to describe mineral scale deposition kinetics in porous medium and pipe flow system, *Journal of Petroleum Science and Engineering.* 178, 594-601.
- ZHANG, Y. e RONG, X. L., 1996. “Hybrid Training of RBF Networks with Application to Nonlinear Systems Identification”, In: *Proceedings of the 35th Conference on Decision and Control*, Kobe, Japan.
- ZIELINSKI, R. A.; OTTON, J. K.; BUDAHN, J. R. Use of radium isotopes to determine the age and origin of radioactive barite at oil-field production sites. *Environmental Pollution*, v. 113, n. 3, p. 299-309, 2001.