

# Um dataset de imagens térmicas e nuvens de pontos para análise de sedimentação em tubulações industriais

1<sup>st</sup> Jovania Menezes Dias

*Departamento de Informática*  
*Instituto Federal do Rio Grande do Sul*  
Vacaria, Brasil  
jovania.dias@vacaria.ifrs.edu.br

2<sup>nd</sup> Thiago Teixeira

*Centro de Ciências Computacionais*  
*Universidade Federal do Rio Grande*  
Rio Grande, Brasil  
teixo@furg.br

3<sup>rd</sup> Paulo Jefferson Dias de Oliveira Evald

*Grupo de Sistemas Inteligentes e Controle*  
*Universidade Federal de Pelotas*  
Pelotas, Brasil  
paulo.evald@ufpel.edu.br

4<sup>th</sup> Silvia Silva da Costa Botelho

*Grupo de Automação Inteligente e Robótica*  
*Universidade Federal do Rio Grande*  
Rio Grande, Brasil  
silviacb@furg.br

**Abstract**—A sedimentação em tubulações industriais é um desafio crítico, especialmente no setor de fertilizantes, pois pode afetar a eficiência operacional e aumentar os custos de manutenção. Este trabalho propõe a criação de um *dataset* inovador que utiliza imagens térmicas e reconstruções tridimensionais para a análise da sedimentação em tubulações. O *dataset* foi desenvolvido a partir de experimentos realizados com maquetes em escala, simulando condições industriais reais. A metodologia incluiu a coleta de dados térmicos e geométricos, bem como a aplicação de técnicas de aumento de dados para garantir a robustez do conjunto. A análise dos dados foi realizada utilizando redes neurais convolucionais, com o objetivo de prever o acúmulo de sedimentos com precisão. Os resultados indicam que o uso de imagens em tons de cinza, em comparação com imagens RGB, proporciona melhores resultados na reconstrução tridimensional das áreas de sedimentação. Além disso, o estudo destaca a relevância do *dataset* proposto para a implementação de soluções de monitoramento não invasivas e para futuras pesquisas em visão computacional aplicadas a esses processos industriais. Este trabalho contribui significativamente para o avanço das tecnologias de manutenção preditiva em tubulações industriais, especialmente na indústria de fertilizantes, e abre novas possibilidades para sua aplicação em outros setores.

**Index Terms**—Sedimentação, Tubulações Industriais, Imagens Térmicas, Redes Neurais Convolucionais, Visão Computacional.

## I. INTRODUÇÃO

A sedimentação em tubulações industriais é um problema que afeta a eficiência operacional na indústria de fertilizantes. A deposição de materiais no interior das tubulações pode levar à redução da capacidade de fluxo, aumento dos custos de manutenção e, em casos extremos, à interrupção total da produção [1], [2]. Métodos tradicionais para detecção de sedimentos, como inspeções físicas e sensores internos, apresentam limitações, incluindo a necessidade de interrupção do processo produtivo e riscos associados ao ambiente confinado e inóspito das tubulações [3]. Neste contexto, surge

a necessidade de métodos alternativos e não invasivos para monitoramento e análise de sedimentação.

A criação de um *dataset* especializado é fundamental para o desenvolvimento de soluções baseadas em inteligência artificial [4]–[9], como redes neurais convolucionais (*Convolutional Neural Networks* - CNNs), que podem ser utilizadas para identificar e analisar padrões de sedimentação. Um *dataset* bem estruturado e representativo é a base para o treinamento e validação de modelos de aprendizado profundo, permitindo que esses modelos aprendam a prever o acúmulo de sedimentos com precisão e robustez. Além disso, *datasets* desse tipo são escassos na literatura, o que ressalta a relevância científica e tecnológica de uma iniciativa desse porte.

O principal objetivo deste trabalho é apresentar o processo de elaboração de um *dataset* inovador para identificação de sedimentos no interior de tubulações industriais utilizando imagens térmicas e reconstruções tridimensionais. O *dataset* foi projetado para capturar variações nos padrões de sedimentação, garantindo a representatividade de diferentes condições industriais. Além disso, o trabalho busca documentar as etapas de coleta, anotação e aumento de dados, oferecendo um recurso valioso para a comunidade científica e para aplicações industriais.

As principais contribuições deste trabalho incluem:

- Criação de um *dataset* exclusivo que combina imagens térmicas e reconstruções 3D de sedimentos, proporcionando uma representação dos fenômenos observados;
- Uso de maquetes em escala, câmeras térmicas e *scanners* 3D, para simular as condições industriais de forma controlada;
- Processos de anotação e normalização que garantem a qualidade e a consistência dos dados, essenciais para o treinamento de modelos de aprendizado profundo;

- Aplicações potenciais, como o uso do *dataset* para desenvolvimento de modelos de visão computacional capazes de prever sedimentação em diferentes contextos industriais, além de contribuir para a criação de sistemas não invasivos de monitoramento de tubulações.

Ao abordar a necessidade de soluções tecnológicas no setor de fertilizantes, este artigo visa não apenas apresentar um recurso científico valioso, mas também abrir caminhos para futuras pesquisas e aplicações práticas na indústria. A seção 2 aborda a escassez de *datasets* industriais voltado para tubulações, a seção 3 descreve o *setup* do experimento e a aquisição do *dataset*, seção 4 apresenta os resultados e discussões relacionadas as interpolações da nuvem de pontos e as comparações do processamento das imagens RGB e tons de cinza, em seguida temos a conclusão e trabalhos futuros.

## II. TRABALHOS RELACIONADOS

A criação de *datasets* para visão computacional tem sido explorada em diferentes domínios, especialmente na indústria [10], onde a análise de imagens pode revelar padrões importantes para manutenção preditiva e melhoria de processos. Alguns dos principais *datasets* voltados para o monitoramento de tubulações industriais incluem dados obtidos por meio de imagens térmicas, ultrassom e análises espectroscópicas. Por exemplo, o *dataset* PipeDefectNet [11] foi desenvolvido para detecção de defeitos internos em tubulações e utiliza imagens RGB combinadas com varreduras a laser para identificar anomalias estruturais.

Embora esses *datasets* tenham contribuído para a área, apresentam limitações importantes. Muitos deles são específicos para detecção de defeitos estruturais, como rachaduras ou corrosão, e não incluem informações detalhadas sobre sedimentação interna. Além disso, não utiliza reconstruções 3D, o que limita sua aplicabilidade em estudos que requerem uma compreensão mais profunda das características volumétricas do material depositado. Outro ponto é que muitos *datasets* existentes não contemplam a combinação de dados térmicos e geométricos, o que poderia fornecer uma análise mais robusta de condições industriais complexas.

Em comparação, o *dataset* apresentado neste trabalho aborda lacunas importantes ao incluir tanto imagens térmicas quanto reconstruções tridimensionais de sedimentos. O processo de coleta de dados foi realizado em um ambiente controlado que simula condições industriais reais, utilizando maquetes em escala. Este método permite a geração de dados altamente padronizados e detalhados, otimizando o treinamento de modelos de aprendizado profundo. A integração de técnicas de aumento de dados também amplia a representatividade das condições simuladas, reduzindo o impacto de cenários pouco representados no *dataset*.

Uma das principais melhorias deste trabalho em relação aos *datasets* anteriores está na anotação dos dados. Cada imagem térmica foi pareada com sua respectiva nuvem de pontos do sedimento, garantindo uma correspondência exata entre as informações térmicas e geométricas. Isso é particularmente relevante para o treinamento de redes neurais convolucionais

que buscam prever perfis tridimensionais a partir de dados visuais. Além disso, o uso de técnicas de interpolação cúbica para normalizar os dados garante uma melhor consistência entre as amostras, otimizando o desempenho dos modelos desenvolvidos.

Outro aspecto inovador é o foco em sedimentação específica do setor de fertilizantes, uma área que carece de *datasets* públicos. Ao capturar as características térmicas e geométricas do NPK, este *dataset* oferece uma base única para modelos que buscam identificar e analisar a sedimentação em tubulações industriais. Essa abordagem não apenas atende a uma necessidade técnica específica, mas também fornece *insights* valiosos para aplicações em outros setores industriais, como petroquímica e tratamento de água.

Por fim, o trabalho apresentado busca preencher uma lacuna crítica na literatura ao fornecer um *dataset* completo e detalhado, que pode ser utilizado como referência para futuras pesquisas em visão computacional. Além disso, ao documentar os processos de coleta, anotação e aumento de dados, este estudo oferece um guia prático para a criação de *datasets* em ambientes industriais, contribuindo para o avanço da área e fomentando o desenvolvimento de novas soluções baseadas em inteligência artificial.

## III. METODOLOGIA

Este estudo utilizou uma maquete em escala de uma tubulação industrial para investigar a identificação do volume de sedimento no interior de uma tubulação industrial.

### A. Setup

Durante o experimento, amostras de sedimentos NPK úmidos foram introduzidas no interior da maquete de tubulação industrial. O aquecimento foi realizado por meio de uma pistola de ar quente, permitindo que a assinatura térmica externa da tubulação fosse capturada por uma câmera termográfica, conforme apresentado na Fig. 1.

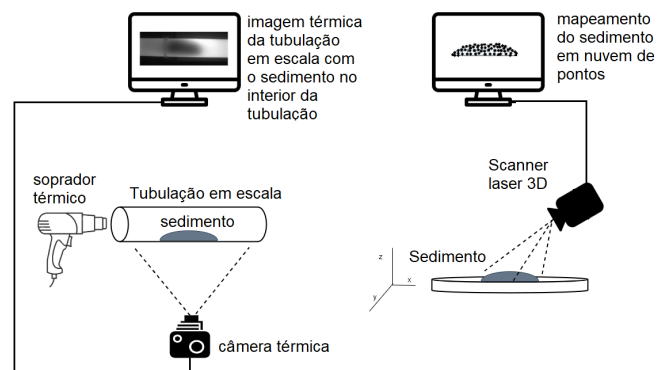


Fig. 1. Setup - Visão Geral. Fonte: Elaborada pela autora.

Os componentes do sistema foram especificados para garantir a eficácia do experimento.

- A câmera termográfica InfiRay P2 Pro foi utilizada para a captura de imagens térmicas, apresentando resolução

de 256×192 *pixels*, alta sensibilidade térmica e faixa de medição de temperatura entre -20°C e 550°C;

- A tubulação em escala tendo 1 m de comprimento, com 10 cm de diâmetro foi construída em aço galvanizado e revestida com tinta térmica preta para minimizar reflexões e garantir a confiabilidade das medições;
- Soprador térmico modelo Skil 8003 para estabelecer o fluxo de ar quente dentro da tubulação. Ele pode operar em 3 níveis de temperatura e conta com uma variedade de acessórios para acoplamento na saída de ar;
- *Scanner* a laser 3D foi utilizada para obter o perfil do sedimento em formato digital 3D. O equipamento é composto por um laser de varredura, um sensor de deslocamento e uma câmera. Sua precisão no mapeamento da profundidade do objeto depende da distância entre o *scanner* e o objeto.

Inicialmente, todos os materiais foram mantidos em temperatura ambiente. A câmera termográfica foi posicionada a 80 cm da maquete, enquanto uma pistola de ar quente foi acoplada a uma das extremidades da tubulação, conforme apresentado na Fig. 2.



Fig. 2. Setup real. Fonte: Elaborada pela autora.

O sedimento presente na maquete causou alterações no fluxo de calor, refletidas nas imagens térmicas adquiridas, conforme a Fig. 3 e a Fig. 4.




Fig. 3. Visualização térmica da tubulação em escala vazia. Fonte: Elaborada pela autora.

A imagem térmica de uma tubulação sem sedimentos no interior apresenta uma continuidade uniforme de cores ao longo de toda a superfície. Isso ocorre porque o calor flui de maneira homogênea pela tubulação, resultando em um padrão térmico uniforme e sem variações significativas. A ausência de obstruções ou materiais de condutividade térmica diferente permite que a distribuição de temperatura permaneça estável em toda a extensão da tubulação.




Fig. 4. Visualização térmica da tubulação em escala com sedimento no interior da tubulação. Fonte: Elaborada pela autora.

Por outro lado, a imagem térmica de uma tubulação contendo sedimentos apresenta variações de cores significativas na região onde o sedimento está localizado. Essas variações se devem às propriedades térmicas distintas do material sedimentado em comparação com o material da tubulação e o ar. O sedimento, por possuir uma condutividade térmica mais baixa, interfere na propagação do calor, criando um padrão térmico diferenciado que pode ser identificado na imagem. Essa diferença nas cores permite a detecção visual das áreas onde o sedimento está acumulado, evidenciando sua localização e extensão.

O aquecimento gerado pelo soprador foi mantido a uma temperatura constante de 60°C, e a estabilização térmica foi monitorada pelo software da câmera. Após 15 minutos, a temperatura na tubulação estabilizou, permitindo a captura das imagens térmicas em intervalos regulares de 10 minutos ao longo de 45 minutos.

A metodologia adotada possibilitou a análise detalhada da relação entre as assinaturas térmicas externas e o perfil geométrico dos sedimentos. As imagens térmicas capturadas, aliadas aos dados obtidos pelo *scanner* 3D, foram importantes para o desenvolvimento de um sistema inteligente de análise de sedimentos, possibilitando futuras aplicações no monitoramento não invasivo de tubulações industriais.

### B. Aquisição de Dados

Um conjunto de dados foi criado manualmente utilizando uma mistura de 300 g de fertilizante NPK e 200 ml de água. A mistura foi introduzida na tubulação em escala, reproduzindo a sedimentação que ocorre devido ao acúmulo de material em áreas de baixa circulação no interior de tubulações industriais. Essa configuração inicial foi fundamental para garantir que as condições experimentais refletissem cenários reais de sedimentação, conforme Fig. 5. As amostras simulam a aglutinação de NPK no interior das tubulações industriais.



Fig. 5. Amostras de sedimentos NPK. Fonte: Elaborada pela autora.

Foram criados 22 perfis de sedimentos, eles foram projetados para refletir as condições observadas no ambiente industrial real, baseando-se em relatos fornecidos por trabalhadores da indústria de fertilizantes. Esses relatos destacaram padrões típicos de sedimentação, como acúmulos em áreas de baixa

circulação, formação de camadas compactas e distribuições irregulares ao longo do comprimento da tubulação. Essa abordagem permitiu reproduzir cenários de sedimentação, da diversidade dos perfis encontrados em operações industriais, proporcionando uma base para o desenvolvimento de métodos de análise e predição baseados em visão computacional.

Após a introdução da mistura, um soprador térmico foi ativado em uma das extremidades da tubulação para gerar fluxo de calor no sistema. O sistema foi monitorado até que a temperatura no interior da tubulação estabilizasse, um processo observado em tempo real por meio do software da câmera térmica. Essa estabilização térmica foi indispensável para assegurar a consistência e a confiabilidade dos dados coletados, eliminando variações indesejadas que poderiam comprometer a análise posterior. Enquanto uma câmera térmica foi posicionada para capturar a visualização da parte inferior da tubulação, onde os sedimentos tendem a se acumular. Foram capturadas imagens em RGB e imagens em tons de cinza. O posicionamento da câmera foi planejado para maximizar a captura de informações térmicas relevantes, permitindo a identificação de diferenças de temperatura associadas à presença de sedimentos.

Depois do resfriamento da tubulação, os sedimentos foram removidos e escaneados para gerar representações 3D das estruturas, conforme Fig.6,




Fig. 6. Escaneamento da amostra de sedimento. Fonte: Elaborada pela autora.

A sequência desses passos foi elaborada para criar um ambiente experimental controlado, garantindo que os dados obtidos representem com as condições industriais para a validação de métodos computacionais na predição de sedimentação.

1) *Pré-processamento dos Dados*: Os dados coletados passaram por um pré-processamento para garantir consistência e usabilidade. As imagens térmicas foram normalizadas, e ruídos reduzidos para melhorar a visibilidade das características relevantes. Nos escaneamentos 3D, apenas as coordenadas dos vértices dos perfis de sedimentos foram mantidas, representando a altura do sedimento dentro da tubulação. Esse processo assegurou o alinhamento adequado entre os dados térmicos e os perfis geométricos.

2) *Aumento de Dados*: O aumento de dados foi utilizado para melhorar a generalização e o desempenho da CNN. Inicialmente, cada uma das 22 amostras foi dividida em 15 partes menores, conforme apresentado na Figura 7, resultando em 330 amostras (fatias) Fig 8. Essas imagens foram processadas com o ESRGAN, aumentando a resolução para  $1120 \times 208$  pixels. Para ampliar ainda mais o conjunto de dados, foram aplicados quatro filtros (ruído, desfoque, ruído branco, interferência), conforme as figuras 9, 10, 11 e 12 respectivamente, cada um com três intensidades.




Fig. 7. Aumento de dados. Fonte: Elaborada pela autora.



Fig. 8. Aumento de dados - Uma Fatia da imagem térmica do sedimento. Fonte: Elaborada pela autora.




Fig. 9. Aumento de dados - Uma Fatia da imagem térmica do sedimento (com ruído). Fonte: Elaborada pela autora.




Fig. 10. Aumento de dados - Uma Fatia da imagem térmica do sedimento (com desfoque). Fonte: Elaborada pela autora.

Esse processo expandiu o conjunto de dados para 4.290 amostras distintas, melhorando a robustez e reduzindo o risco de *overfitting*.

3) *Rotulagem dos Dados*: As amostras foram rotuladas para estabelecer correspondência entre as imagens térmicas e seus respectivos perfis 3D de sedimentos. Os sedimentos foram segmentados para manter a proporção entre as fatias térmicas e as fatias da nuvem de pontos gerada pelo *scanner*. Cada fatia da nuvem de pontos foi interpolada para um tamanho fixo de 800 pontos, padronizando os dados e garantindo alinhamento entre os conjuntos. Esses rótulos serviram como *ground truth*, permitindo o treinamento da rede neural na tarefa de mapear características das imagens térmicas às alturas dos sedimentos.




Fig. 11. Aumento de dados - Uma Fatia da imagem térmica do sedimento (com ruído branco). Fonte: Elaborada pela autora.



Fig. 12. Aumento de dados - Uma Fatia da imagem térmica do sedimento (com interferencia). Fonte: Elaborada pela autora.

#### IV. RESULTADOS E DISCUSSÕES

Foram usados três métodos de interpolação: *linear*, *cubic* e *nearest* para os 800 pontos da nuvem de pontos que representam a cota *z*, altura do sedimento, conforme apresentado na Fig. 13.




Fig. 13. Interpolações (alturas das fatias dos sedimentos). Fonte: Elaborada pela autora.

Esse gráfico ilustra os perfis de altura de 330 fatias, comparando as alturas originais (linha vermelha) com alturas interpoladas usando três métodos: *Linear* (linha tracejada azul), *Cubic* (linha tracejada roxa) e *Nearest* (linha tracejada verde). Nesse gráfico, a alturas originais (linha vermelha) representa os dados de altura reais e inalterados das fatias. A interpolação *linear* (linha azul) mostra um alinhamento próximo com os dados originais, mantendo uma tendência consistente com pequenos desvios em picos e vales. A interpolação *cubic* (linha roxa) segue de perto os dados originais, oferecendo uma curva mais suave, particularmente nos pontos de inflexão. Ou seja, reduz o ruído e fornecer uma aproximação mais refinada. A interpolação *nearest* (linha verde) introduz mudanças perceptíveis em etapas, especialmente em torno de picos e vales, devido à sua natureza discreta de atribuição de valores com base no ponto mais próximo.

A interpolação *cubic* fornece o ajuste mais suave aos dados originais, tornando-a adequada para aplicações que exigem continuidade e precisão. A interpolação *linear* também se alinha bem, mas exibe menos suavidade em comparação à cúbica. Já a interpolação *nearest*, embora computacionalmente simples, desvia mais dos dados originais, particularmente

em torno de transições bruscas. Este gráfico demonstra visualmente a eficácia e as diferenças entre os métodos de interpolação na aproximação do perfil de altura de fatias de sedimento, destacando a interpolação cúbica como o método mais preciso.

A Fig. 14 mostra as diferenças percentuais ( $\Delta\%$ ) entre os valores de altura originais e aqueles obtidos de três métodos de interpolação: *Linear* (linha azul), *Cubic* (linha tracejada roxa) e *Nearest* (linha tracejada verde) em 330 fatias. O eixo *y* representa o desvio percentual dos valores interpolados dos valores originais. Os valores positivos indicam que a interpolação superestimou as alturas originais, enquanto valores negativos indicam subestimação.




Fig. 14. Interpolações  $\Delta\%$ . Fonte: Elaborada pela autora.

A interpolação *Linear* (Linha Azul) mostra o comportamento mais estável, com desvios firmemente agrupados em torno de 0%. Isso sugere que a interpolação linear aproxima os dados originais com erros mínimos. Já a interpolação *Cubic* (Linha Tracejada Roxa) mostra pequenos desvios, mas com transições mais suaves em comparação à interpolação linear. Os desvios permanecem mais próximos de 0%, indicando precisão, especialmente em torno de transições complexas. Interpolação *Nearest* (linha tracejada verde) exibe desvios maiores e mais abruptos em comparação com os outros métodos. Ela tem picos e vales mais altos, particularmente perceptíveis em torno de mudanças abruptas nos dados originais, devido à sua natureza discreta. As interpolações linear e cúbica mostram os menores desvios, sugerindo sua eficácia na aproximação dos dados originais. A interpolação *nearest* próximo mostra os maiores desvios, tornando-a menos adequada para aplicações que exigem precisão. As interpolações linear e cúbica são melhores para manter a precisão, com a cúbica superando ligeiramente a linear em suavidade. Já a interpolação *nearest* introduz mais variabilidade e é menos confiável para previsão de altura. O gráfico destaca a importância de selecionar o método de interpolação apropriado dependendo da precisão desejada e dos requisitos da aplicação.

A Fig. 15 ilustra as diferenças percentuais absolutas ( $|\Delta\%|$ ) entre os valores de altura originais e aqueles interpolados usando três métodos: *Linear* (linha azul), *Cubic* (linha tracejada roxa) e *Nearest* (linha tracejada verde) em 330 fatias. O eixo *y* representa a magnitude das diferenças percentuais, independentemente da direção (positiva ou negativa), enfatizando a

escala de desvio dos valores originais.




Fig. 15. Interpolação  $|\Delta\%|$ . Fonte: Elaborada pela autora.

A interpolação *linear* (linha azul) demonstra desvios consistentes e relativamente pequenos, com a maioria dos valores permanecendo abaixo de 10%. Ele mantém uma tendência suave, mostrando variação mínima entre as fatias. A interpolação *cubic* (linha tracejada roxa) exibe desvios pequenos, sobrepondo-se ao método linear, em regiões com dados estáveis. O método cúbico também fornece transições ligeiramente mais suaves, destacando sua precisão na captura de detalhes mais finos. Já a interpolação *nearest* (linha tracejada verde) mostra os maiores desvios, com picos pronunciados excedendo 20% em algumas fatias. Isso indica que essa interpolação tem dificuldade para aproximar os dados originais com precisão, particularmente em regiões com transições abruptas ou alta variabilidade.

As interpolações lineares e cúbicas exibem desvios significativamente menores, demonstrando sua eficácia para manter a precisão. Além disso, o método *nearest* tem desempenho pior, com desvios maiores e mais abruptos, tornando-o menos confiável para aplicações que exigem precisão. O gráfico confirma que as interpolações lineares e cúbicas são adequadas para tarefas que exigem precisão, com a cúbica fornecendo resultados ligeiramente mais suaves. A interpolação *nearest*, embora computacionalmente simples, introduz erros significativos, especialmente em regiões de alta variabilidade, e é menos apropriada para previsões precisas. Esses resultados reforçam a preferência pela interpolação linear ou cúbica em aplicações onde a precisão e a suavidade são críticas.

A tabela I apresenta as médias das diferenças percentuais e também dos erros de interpolação (*mean squared error* - MSE, *root mean squared error* - RMSE e *mean absolute error* - MAE) de todas as cotas para as 330 fatias.

A arquitetura da rede neural foi projetada para realizar a reconstrução tridimensional de superfícies a partir de dados visuais. Nesse contexto, a rede recebe como entrada uma imagem térmica RGB ou tons de cinza e processa suas informações para gerar, na saída, uma nuvem de pontos correspondente à geometria representada pela imagem. A saída da rede é um vetor que contém os valores das coordenadas  $z$  (cotas), responsáveis por descrever a altura de cada ponto na representação tridimensional, mantendo a correspondência entre os dados bidimensionais da imagem e o modelo 3D reconstruído. Essa abordagem permite a tradução eficiente de

TABLE I  
ERROS DE INTERPOLAÇÃO.

Métricas	Interpolação		
	<i>Linear</i>	<i>Cubic</i>	<i>Nearest</i>
<b>Erros de interpolação (em altura)</b>			
MAE	2.58271	2.57999	3.11618
MSE	11.46077	11.36087	15.65578
RMSE	3.38538	3.37059	3.95674
<b>Erros de interpolação (em porcentagem)</b>			
MAE	3.83262%	3.82610%	4.62127%
MSE	17.00727%	16.84807%	23.21740%
RMSE	5.02374%	4.99856%	5.86781%

informações visuais em dados geométricos tridimensionais, com aplicações em diversas áreas industriais. No processamento da rede neural foi utilizado as cotas com a interpolação cúbica, por apresentarem melhores resultados em relação a nuvem de pontos original.

No processamento das imagens RBG e tons de cinza, o modelo retornou as seguintes métricas, conforme apresentado na Tabela II.

TABLE II  
MÉTRICAS DE AVALIAÇÃO PARA PROCESSAMENTO DAS IMAGENS RGB E TONS DE CINZA.

Métrica	RGB (%)	Tons de cinza (%)
MAE	6.22637	5.69617
MSE	0.57511	0.51323
RMSE	7.56994	7.14359

O modelo treinado com imagens RGB exibiu métricas de erro ligeiramente maiores em comparação ao modelo em tons de cinza. Esses resultados indicam que o modelo RGB tem menor precisão na previsão de alturas de sedimentos, o que pode ser atribuído a variações nas informações contidas em imagens coloridas em comparação a imagens em tons de cinza.

Os gráficos de representação 3D das imagens térmicas, gerados a partir dos modelos de reconstrução, permitem uma análise detalhada da relação entre os dados visuais e a geometria dos sedimentos acumulados no interior da tubulação. Neste estudo, foram utilizadas imagens térmicas em duas variações: RGB representado na Fig 16 e tons de cinza, na Fig 17, com o objetivo de avaliar o impacto dos diferentes canais de cor na precisão da reconstrução tridimensional. A representação 3D resultante, composta pela nuvem de pontos, destaca a correspondência entre os valores de temperatura capturados pelas imagens térmicas e os perfis geométricos dos sedimentos. Essa análise comparativa entre as representações RGB e em tons de cinza busca identificar a melhor abordagem para modelar os sedimentos, contribuindo para a aplicação de técnicas de visão computacional no monitoramento industrial.

No processamento da imagem RBG, a distribuição da nuvem de pontos predita (vermelha) apresenta maior dispersão em relação ao *ground truth* (azul), indicando que o modelo tem dificuldade em capturar com precisão o perfil geométrico dos sedimentos. No alinhamento com o *ground truth*, embora as




Fig. 16. Reconstrução em nuvem de pontos da imagem RGB. Fonte: Elaborada pela autora.




Fig. 17. Reconstrução em nuvem de pontos da imagem em tons de cinza. Fonte: Elaborada pela autora

tendências gerais sejam capturadas, as diferenças em algumas regiões são mais pronunciadas, evidenciando que o modelo RGB pode estar sendo influenciado por informações de cor que não contribuem significativamente para a identificação de padrões térmicos relevantes.

No processamento com imagens em tons de cinza, a distribuição da nuvem de pontos predita (vermelha) apresenta uma maior proximidade e alinhamento com o *ground truth* (azul), demonstrando melhor precisão em capturar o perfil geométrico dos sedimentos. Comparada à imagem RGB, a dispersão é consideravelmente menor, indicando que o modelo treinado com tons de cinza é mais eficiente em identificar as características térmicas essenciais, sem ser afetado por informações redundantes de cor.

O modelo baseado em tons de cinza mostra maior capacidade de generalização e precisão, alinhando-se mais consistentemente com os dados do *ground truth*. O modelo RGB

apresenta uma maior variação nas predições, sugerindo que as informações adicionais de cor podem estar introduzindo ruídos que afetam a performance do modelo. Essas diferenças refletem a vantagem de simplificar os dados de entrada ao utilizar tons de cinza, o que reduz a interferência de características irrelevantes e melhora a eficácia do aprendizado para essa aplicação específica.

## V. CONCLUSÃO

Este trabalho apresentou o desenvolvimento de um *dataset* inovador, que combina imagens térmicas e reconstruções tridimensionais para análise de sedimentação em tubulações industriais, uma área importante no setor de fertilizantes. O objetivo foi fornecer uma *dataset* robusto para o treinamento de modelos de aprendizado profundo, especificamente redes neurais convolucionais, para a predição do acúmulo de sedimentos nas tubulações. A abordagem adotada neste estudo não só oferece uma solução não invasiva para monitoramento, mas também preenche lacunas importantes em termos de dados especializados para esse tipo de aplicação. A metodologia empregada, que inclui o uso de maquetes em escala e a combinação de diferentes tecnologias, como câmeras térmicas e *scanners* 3D, permitiu a criação de um *dataset* diversificado e representativo. A coleta e anotação dos dados seguiram um processo de normalização e aumento de dados, garantindo a qualidade e a robustez dos mesmos. Esses passos são fundamentais para treinar modelos que podem generalizar de maneira eficiente para condições industriais reais, minimizando os riscos de *overfitting*. Em resumo, este estudo não só contribui com a criação de um recurso valioso para a análise de sedimentação em tubulações industriais, mas também abre portas para o uso de tecnologias emergentes no monitoramento e na manutenção preditiva. O *dataset* desenvolvido tem o potencial de ser utilizado como um padrão para a pesquisa em áreas semelhantes, como a indústria petroquímica e o tratamento de água, impactando positivamente a inovação tecnológica e a eficiência operacional nesses setores.

## ACKNOWLEDGMENT

## REFERENCES

- [1] O.-W. Achaw and E. Danso-Boateng, "Fertilizer technology," in *Chemical and Process Industries*. New York, USA: Springer, 2021, pp. 107–133. [Online]. Available: <https://doi.org/10.1007/978-3-030-79139-1>
- [2] I. Madanhire, K. Mugwindiri, and C. Mbohwa, "Enhancing cleaner production application in fertilizer manufacturing: case study," *Clean Technologies and Environmental Policy*, vol. 17, no. 3, pp. 667–679, 2015. [Online]. Available: <https://doi.org/10.1007/s10098-014-0823-7>
- [3] D. C. Cone, "Confined space and limited access situations," in *Emergency Medical Services*. John Wiley & Sons, Ltd, 2015, pp. 373–376. [Online]. Available: <https://doi.org/10.1002/9781118990810.ch115>
- [4] A. X. Chang, T. Funkhouser, L. Guibas, P. Hanrahan, Q. Huang, Z. Li, S. Savarese, M. Savva, S. Song, H. Su, J. Xiao, L. Yi, and F. Yu, "Shapenet: An information-rich 3d model repository," 2015, available online at <https://www.shapenet.org/>.
- [5] V. Panayotov, G. Chen, D. Povey, and S. Khudanpur, "Librispeech: An asr corpus based on public domain audio books," in *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2015, pp. 5206–5210.

- [6] K. Soomro, A. R. Zamir, and M. Shah, "Ucf101: A dataset of 101 human actions classes from videos in the wild," *arXiv preprint arXiv:1212.0402*, 2012. [Online]. Available: <https://arxiv.org/abs/1212.0402>
- [7] A. Wang, A. Singh, J. Michael, F. Hill, O. Levy, and S. R. Bowman, "Glue: A multi-task benchmark and analysis platform for natural language understanding," in *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2018. [Online]. Available: <https://gluebenchmark.com/>
- [8] Z. Wu, S. Song, A. Khosla, F. Yu, L. Zhang, X. Tang, and J. Xiao, "3d shapenets: A deep representation for volumetric shapes," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2014, pp. 1912–1920. [Online]. Available: <https://doi.org/10.1109/CVPR.2015.7298801>
- [9] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *2009 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2009, pp. 248–255. [Online]. Available: <https://doi.org/10.1109/CVPR.2009.5206848>
- [10] C. A. Akar, J. Tekli, D. Jess, M. Khoury, M. Kamradt, and M. Guthe, "Synthetic object recognition dataset for industries," in *2022 35th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. Natal, Brazil: IEEE, 2022, pp. 150–155. [Online]. Available: <https://doi.org/10.1109/SIBGRAPI55357.2022.9991784>
- [11] M. M. M. U. Shaik, "Pipeline defect dataset," <https://www.kaggle.com/datasets/simplexitypipeline/pipeline-defect-dataset>, 2025, accessed: 2025-01-22.