

UNIVERSIDADE FEDERAL DO RIO GRANDE
CENTRO DE CIÊNCIAS COMPUTACIONAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO
CURSO DE MESTRADO EM ENGENHARIA DE COMPUTAÇÃO

Dissertação de Mestrado

Modelo Termográfico Não Invasivo para Inspeção de Obstrução de Dutos na Indústria de Fertilizantes

Marta dos Anjos Duarte

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal do Rio Grande, como requisito parcial para a obtenção do grau de Mestre em Engenharia de Computação

Orientador: Prof. Dr. Silvia Silva da Costa Botelho

Rio Grande, Novembro de 2020

Ficha Catalográfica

D812m Duarte, Marta dos Anjos.

Modelo termográfico não invasivo para inspeção de obstrução de dutos na indústria de fertilizantes / Marta dos Anjos Duarte. – 2020.
50 f.

Dissertação (mestrado) – Universidade Federal do Rio Grande – FURG, Programa de Pós-Graduação em Computação, Rio Grande/RS, 2020.

Orientadora: Dra. Silvia Silva da Costa Botelho.

1. Visão Computacional 2. Termografia 3. Laser Scanner 3D
4. Redes Neurais I. Botelho, Silvia Silva da Costa II. Título.

CDU 661.152

Catálogo na Fonte: Bibliotecário José Paulo dos Santos CRB 10/2344

ATA DE SESSÃO DE DEFESA DE DISSERTAÇÃO DE MESTRADO


Na data de 11 de novembro de 2020, às 14 horas e 30 minutos, ocorreu a Sessão de Defesa de Dissertação de Mestrado de Marta dos Anjos Duarte, que apresentou a dissertação intitulada "Modelo Termográfico Não Invasivo para Inspeção de Obstrução de Dutos na Indústria de Fertilizantes", realizada sob a orientação da Profa. Dra. Silvia Silva da Costa Botelho. A banca examinadora foi constituída pelos Profs. Dr. Carlos Rodrigues Rocha (IFRS), Dr. Paulo Lilles Jorge Drews Junior (FURG) e pelo Eng. Me. Cristiano Rodrigues Barcellos (YARA) e sob a presidência da orientadora. Após a apresentação do trabalho, a banca arguiu a candidata e, a seguir, deliberou pela

- () aprovação da Dissertação
- (x) aprovação da Dissertação, sugerindo modificações no texto
- () reprovação da Dissertação


Rio Grande, 11 de novembro de 2020.




Prof. Dr. Carlos Rodrigues Rocha (participação remota)



Eng. Me. Cristiano Rodrigues Barcellos (participação remota)



Prof. Dr. Paulo Lilles Jorge Drews Junior (participação remota)



Profa. Dra. Silvia Silva da Costa Botelho (participação remota)
Orientadora

RESUMO

DOS ANJOS DUARTE, Marta. **Modelo Termográfico Não Invasivo para Inspeção de Obstrução de Dutos na Indústria de Fertilizantes**. 2020. 49 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Computação. Universidade Federal do Rio Grande, Rio Grande.

Falhas em dutos na indústria, como obstruções, podem criar grandes problemas para engenheiros e perdas financeiras para a empresa. A detecção de bloqueios é necessária para o bom funcionamento de uma indústria e a segurança do meio ambiente. Este trabalho apresenta um modelo de inspeção não invasiva de tubulações. Propõe o uso de uma rede neural para identificar o estágio de obstrução em tubulações na indústria de fertilizantes, por meio de imagens térmicas externas obtidas dos dutos. A ideia é usar um conjunto de dados em escala capaz de mapear o comportamento térmico externo de uma maquete de tubo em um perfil do depósito interno usando um escâner 3D. Utiliza-se uma câmera térmica que adquire imagens associadas a temperatura emitida pela superfície externa da tubulação. Esta imagem será processada por uma rede neural que fornecerá como saída a altura de depósito da tubulação. A proposta utiliza redes neurais para mapear imagens térmicas em perfis de depósito, e assim, inferir a relação entre os pixels da imagem térmica obtida do exterior do tubo e o perfil de sedimento no seu interior. A rede neural Multilayer Perceptron foi capaz de aprender o mapeamento de pixel térmico em um perfil de depósito, obtendo resultados satisfatórios, mostrando ser possível detectar a sedimentação que está ocorrendo no interior de um duto a partir de uma imagem térmica obtida externamente.

Palavras-chave: Visão Computacional, Termografia, Laser Scanner 3D, Redes Neurais.

ABSTRACT

DOS ANJOS DUARTE, Marta. **Thermographic Non-Invasive Model for Obstruction Inspection of Pipelines in the Fertilizer Industry**. 2020. 49 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Computação. Universidade Federal do Rio Grande, Rio Grande.

In industry, obstruction-like pipeline faults can create major problems for engineers and financial loss for the company. The blockage detection is necessary for smooth functioning of an industry and safety of the environment. This work presents a model for non-invasive inspection of inhospitable pipes. It proposes the use of a neural network to identify the obstruction stage in fertilizer industry, using external thermal images obtained from the pipelines. The idea is to use a scaled dataset able to map the external thermal behavior of a pipe mockup in a profile of the internal deposit using a 3D scanner. A thermal camera acquires images associated with the temperature emitted by the external surface of the pipe. This image will be processed by a neural network that will provide the deposit height as an output. The proposal uses neural networks to map thermal images in deposit profiles, and thus, infer the relationship between the pixels of the thermal image obtained from the outside of the tube and the sediment profile inside. The Multilayer Perceptron neural network was able to learn the thermal pixel mapping in a deposit profile, obtaining satisfactory results, showing that it is possible to detect the sedimentation that is occurring inside a duct from an external thermal image.

Keywords: Computer vision, Thermography, Laser Scanner 3D, Neural Networks.

LISTA DE FIGURAS

1	Neurônio biológico adaptado de (Daniel, 2013).	13
2	Modelo de neurônio artificial adaptado de (Haykin, 2007).	14
3	Visão geral do método proposto para inferir grau de obstrução em tubulações.	17
4	Rede neural proposta para o mapeamento do comportamento térmico no perfil de depósito.	18
5	Procedimento para obtenção do <i>Dataset</i> Anotado: (a) Entrada: imagem térmica adquirida da maquete com perfil de depósito; (b) Dado anotado de altura de depósito: projeção 2D da nuvem de pontos capturada do perfil pelo laser	19
6	Exemplo de imagem térmica obtida num experimento com o duto vazio.	20
7	Exemplo de imagem térmica obtida num experimento com sedimentação no interior do duto.	20
8	Feições típicas de um sedimento.	21
9	Exemplo de fatia 2D obtida, os pontos vermelhos correspondem a vértices que pertencem ao objeto que estão sendo interceptados pelo plano que corresponde a fatia.	22
10	Fatias obtidas do objeto escaneado.	22
11	Intersecção das linhas verticais com a fatia para obter as alturas, . . .	23
12	Padrões de obstrução elaborados. A primeira coluna apresenta um desenho de como a obstrução ocupa o duto, a coluna central apresenta uma vista do escaneamento, e a terceira coluna apresenta a imagem final do modelo de depósito após o processamento do objeto escaneado.	24
13	O mapeamento é obtido a partir de uma câmera que capture a projeção no plano x, y da temperatura da superfície da tubulação.	25
14	Fertilizante no fundo do duto maquete.	27
15	Mapeamento obtido ao considerar uma janela 9×9	30
16	Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 1.	30
17	Resultados obtidos da predição o Padrão 1.	30
18	Mapeamento obtido ao considerar uma janela 9×9	31
19	Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 1.	31
20	Resultados obtidos da predição o Padrão 2.	31
21	Mapeamento obtido ao considerar uma janela 9×9	32
22	Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 3.	32
23	Resultados obtidos da predição o Padrão 3.	33
24	Mapeamento obtido ao considerar uma janela 9×9	33

25	Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 3.	34
26	Resultados obtidos da predição o Padrão 4.	34
27	Mapeamento obtido ao considerar uma janela 9×9	35
28	Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 5.	35
29	Resultados obtidos da predição o Padrão 5.	35
30	Mapeamento obtido ao considerar uma janela 9×9	36
31	Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 3.	36
32	Resultados obtidos da predição o Padrão 6.	36
33	Mapeamento obtido ao considerar uma janela 9×9 e todos os padrões.	37
34	Curvas de aprendizados obtidas ao considerar uma janela 9×9 e todos os padrões.	37
35	Histogramas dos resíduos considerando uma janela 9×9 e as intensidades dos pixels.	38
36	Histogramas dos resíduos considerando uma janela 9×9 e as intensidades dos pixels+altura.	38
37	Resultados obtidos com todos os padrões e considerando como entrada da rede neural as intensidades dos pixels, e os resultados filtrados . .	39
38	Resultados obtidos com todos os padrões e considerando como entrada da rede neural as intensidades dos pixels+altura, e os resultados filtrados	40

LISTA DE TABELAS

1	Subdivisão infravermelha genérica (Gade and Moeslund, 2014) . . .	10
2	Subdivisão infravermelha usada em câmeras termográficas (Gade and Moeslund, 2014)	10
3	Resultados obtidos do Padrão 1 e utilizando uma janela 9×9	29
4	Resultados obtidos do Padrão 2 e utilizando uma janela 9×9	31
5	Resultados obtidos do Padrão 3 e utilizando uma janela 9×9	32
6	Resultados obtidos do Padrão 4 e utilizando uma janela 9×9	33
7	Resultados obtidos do Padrão 5 e utilizando uma janela 9×9	34
8	Resultados obtidos do Padrão 6 e utilizando uma janela 9×9	36
9	Resultados obtidos do treinamento de todos os padrões em conjunto utilizando uma janela 9×9	37

LISTA DE ABREVIATURAS E SIGLAS

MLP	<i>Multi-layer Perceptron</i>
ROI	<i>Region of Interest</i>

SUMÁRIO

1	INTRODUÇÃO	2
1.1	Objetivos	4
1.1.1	Objetivo Geral	4
1.1.2	Objetivos Específicos	5
1.2	Estrutura do Trabalho	5
2	TRABALHOS RELACIONADOS	6
3	FUNDAMENTAÇÃO TEÓRICA	8
3.1	Computação Visual	8
3.1.1	Termografia	8
3.1.1.1	Conceitos Físicos	9
3.1.2	Laser escâner 3D	11
3.2	Redes Neurais	13
3.3	<i>Guided Filter</i>	15
4	METODOLOGIA	17
4.1	O <i>Dataset</i> em escala	19
4.1.1	Entrada do <i>Dataset</i> : A imagem térmica	19
4.1.2	Anotação do <i>Dataset</i> : O Perfil de Depósito	21
4.1.3	Perfis de Treinamento	23
4.1.4	Associação entre Imagens Térmicas e Perfis de Depósito	24
4.1.5	Um Modelo para Mapear Imagens Térmicas em Perfis de Depósito	25
5	RESULTADOS	26
5.1	O Setup e o Conjunto de Dados	26
5.2	O Treinamento da RNA	27
5.2.1	Padrão 1	29
5.2.2	Padrão 2	30
5.2.3	Padrão 3	32
5.2.4	Padrão 4	33
5.2.5	Padrão 5	34
5.2.6	Padrão 6	35
5.2.7	Treinamento com todos padrões	36
6	CONCLUSÕES E TRABALHOS FUTUROS	41
	REFERÊNCIAS	43

1 INTRODUÇÃO

O crescimento da população mundial tem sido responsável pelo aumento da demanda por alimentos. Os agricultores aumentaram a aplicação de fertilizantes visando aumentar a produtividade das culturas e melhorar a utilização da terra (PricewaterhouseCoopers Brasil Ltda, 2013).

No Brasil, um dos setores mais importantes da economia é o agronegócio. Este setor responde por quase 24% do PIB (Produto Interno Bruto) e cresceu cerca de 2,5% nos últimos dois anos, colocando-se em significativa vantagem em relação a outros setores da economia (Economics). Uma parcela significativa deste aumento se deve ao uso de fertilizantes.

A indústria de fertilizantes tem sido demandada não apenas por mais produção mas também por soluções de qualidade e customizadas. Neste cenário, um dos desafios para este setor é aumentar a confiabilidade exigida pelo mercado (vs Regulations, 2007).

A produção de fertilizantes ocorre basicamente em três etapas: produção de matérias-primas e materiais básicos, fertilizantes básicos e misturas. A última etapa é responsável por misturar os fertilizantes básicos, nitrogênio (N), fósforo (P) e potássio (K), de acordo com as exigências particulares de cada tipo de solo, compondo os fertilizantes conhecidos de mistura a granel (Miserque and Pirard, 2004).

A combinação dos componentes acontece dentro dos dutos da fábrica e os fertilizantes básicos estão sob a forma de pó. Uma indústria de fertilizantes possui muitas tubulações para a produção, transporte e processo de reciclo dos grãos de fertilizantes que não possuem o tamanho adequado.

As estruturas dos dutos são projetadas para resistir a diversas condições, de maneira a garantir uma distribuição segura e confiável para todos os pontos de produção. No entanto, falhas em dutos, como obstruções, podem resultar em sérios desastres ecológicos, mortes humanas e perdas financeiras.

A poeira, na presença de calor e umidade, reage quimicamente, formando um sedimento que pode obstruir os dutos e comprometer a produção. Uma limpeza periódica manual nos dutos é necessária para resolver este problema, o que faz com que a produção fique paralisada durante esse período. Essa parada reduz a produtividade das empresas e provoca

uma grande perda financeira para produtores e consumidores. Surge assim como uma importante demanda para este mercado o desenvolvimento de soluções tecnológicas não invasivas que permitam, de forma preventiva, estimar e evitar a sedimentação dentro das tubulações.

Diferentes atuadores mecânicos, pneumáticos poderiam compor engenhos que, controlados computacionalmente, permitiriam evitar ou mesmo dispersar o depósito formado e desta forma reduzir os prejuízos decorrentes das paradas. Porém, antes de escolher qual tecnologia será a melhor para cada caso, é importante desenvolver técnicas capazes de inferir o perfil de depósito ao longo de toda tubulação. Surge a tarefa de como avaliar a quantidade de pó depositado nos diferentes pontos da planta, indicando desta forma, ao longo do tempo e do espaço, quais seriam as melhores atitudes de limpeza.

A característica confinada e inóspita, a escala da planta e sua dinâmica, tornam esta tarefa um grande desafio. Recentemente, técnicas de visão computacional tem sido amplamente utilizadas na área de inspeção não invasiva das indústrias (Moreno et al., 2017), (Posada et al., 2015), (Stork, 2015). Tecnologias como câmeras digitais, câmeras térmicas, escâneres a laser 3D, soluções de realidade aumentada, entre outras, possibilitam a aquisição, análise e síntese de padrões visuais, através do uso de recursos computacionais (Stork, 2015).

Entretanto, neste problema, o uso de robôs, câmeras ou sensores internos tornam-se inviáveis devido a uma combinação de fatores como alta temperatura, umidade e principalmente ao excesso de pó, que tornam o ambiente inóspito para o seu emprego. Utilizar a mão de obra humana também é inexecutável, uma vez que por conta do calor e do processo de produção não é possível ter acesso ao interior do duto quando a indústria não está com a atividade paralisada.

Neste trabalho, pretende-se utilizar, de forma original, algumas tecnologias como: câmera térmica, escâner a laser 3D, e técnicas de Inteligência Artificial (IA) para obter uma solução de inspeção não invasiva do depósito de material em dutos. A proposta é averiguar como estas tecnologias combinadas podem fornecer, de forma não invasiva, o perfil de deposição de poeira na tubulação de forma a, no futuro, serem desenvolvidos atuadores para o seu tratamento.

A câmera térmica e o escâner utilizados são capazes de fornecer dados suficientemente confiáveis para obtenção da solução pretendida. Sob o ponto de vista de software, uma solução de IA utilizando redes neurais será proposta.

As principais hipóteses aqui adotadas são que o comportamento térmico externo dos dutos da planta pode ser mapeado em perfis de depósito de poeira tendo em vista que os materiais presentes no espaço confinado: ar, poeira, metal, apresentam diferentes coeficientes de condução térmica. Estas diferenças físicas na propagação do calor conduzirão a diferentes padrões de temperatura na superfície da tubulação que poderão ser capturadas por uma câmera térmica.

Por outro lado, admite-se que a variabilidade de perfis de imagens térmicas externas da tubulação e sua relação com os níveis de depósito de poeira sejam pouco dependentes da escala da planta. Desta forma, pode-se gerar, em laboratório, maquetes em escala da tubulação onde se consiga inferir com alguma precisão o perfil de depósito para determinada condição térmica imageada.

Dada a complexidade do fenômeno, inexistente uma solução analítica capaz de descrever o mapeamento da imagem térmica externa capturada em nível de depósito interno. Simulações capazes de reproduzir o fenômeno seriam de complexa execução, conduzindo a necessidade de simplificações, as distanciando do objetivo original. Assim, busca-se na Inteligência Artificial uma alternativa de solução. Espera-se que, a partir de um *dataset* de imagens térmicas (entrada) e espessuras de depósito (saída), uma Rede Neural Artificial - RNA consiga aprender o mapeamento existente, tendo em vista seu potencial para aprender complexos mapeamentos não lineares entre entrada e saída.

Esse treinamento seria realizado utilizando as informações de nível de depósito interno da maquete obtidas através de um escâner a laser (saída), a partir de perfis de acumulação elaborados em 3D, e das imagens térmicas por eles produzidas (entrada). Os perfis seriam manualmente elaborados utilizando o mesmo material transportado nos dutos da indústria e colocados em um tubo maquete capaz de reproduzir em escala reduzida o fenômeno que ocorre no tubo real. Propõe-se experimentos na maquete introduzindo ar quente no tubo, até que a sua temperatura atinja a temperatura de operação do tubo real. Nessa condição, imagens da maquete são obtidas com a câmera térmica. As características dimensionais dos perfis de acumulação e as imagens térmicas obtidas do tubo em que eles estão instalados são as informações utilizadas para obtenção dos parâmetros da rede neural capaz de inferir um perfil de deposição a partir de uma imagem térmica.

Tendo isso como base, neste trabalho é apresentada uma nova técnica de inspeção térmica não invasiva, usada para constatar o estado de obstrução de tubulações em fábricas de fertilizantes. A obstrução em questão corresponde a deposição do resultado da aglomeração de fertilizantes no interior dos dutos de transporte desse material.

Um modelo em escala será desenvolvido para permitir a obtenção dos dados de mapeamento entre o exterior de um duto e o perfil de depósito existente no seu interior. A partir disso uma rede neural será treinada a fim de aprender este *dataset*.

Esta dissertação insere-se no âmbito do projeto CleanBot junto a empresa Yara Brasil, que busca desenvolver soluções tecnológicas para limpeza de tubulações.

1.1 Objetivos

1.1.1 Objetivo Geral

Estudar e desenvolver um modelo para inspeção não invasiva de tubulações, utilizando câmera térmica, escâner a laser 3D e redes neurais, capaz de identificar o estágio de

obstrução em dutos da indústria de fertilizantes.

1.1.2 Objetivos Específicos

- Identificar e estudar o processo de produção de fertilizantes e como acontece o depósito de material dentro da tubulação;
- Desenvolver uma maquete em escala para reproduzir em laboratório os fenômenos de depósito encontrados na indústria;
- Propor um método para a obtenção de *datasets* associados aos perfis de depósito e térmicos;
- Estudar e implementar um modelo utilizando rede neurais artificiais para mapear o comportamento térmico em perfil de depósito;
- Testar e analisar o modelo em escala na maquete.

1.2 Estrutura do Trabalho

O trabalho está organizado em quatro capítulos. O Capítulo 2 aborda um levantamento bibliográfico das principais técnicas utilizadas para a inspeção de dutos. O Capítulo 3 apresenta conceitos das técnicas abordadas na proposta do trabalho; o Capítulo 4 descreve a metodologia utilizada para o desenvolvimento do projeto; no Capítulo 5 encontram-se os resultados obtidos; algumas considerações e sugestões para trabalhos futuros são feitas no Capítulo 6.

2 TRABALHOS RELACIONADOS

O objetivo deste capítulo é apresentar o resultado de um levantamento bibliográfico envolvendo técnicas utilizadas para a inspeção e detecção de obstruções em dutos.

Como apresentado em Datta and Sarkar (2016), dois tipos de métodos podem ser utilizados para a detecção de obstruções em dutos. Os baseados em *hardware* e os baseados em *software*.

Nos métodos baseados em *hardware*, dispositivos especiais de detecção são usados para identificar bloqueios causados por obstruções na tubulação. Sistemas que utilizam métodos baseados em *hardware* também fazem uso de *software*. A principal diferença entre eles é que os baseados em *hardware* fazem uso de sensores exclusivos para detecção de falhas, enquanto os métodos baseados em *software* utilizam os sensores já existentes na tubulação para o acompanhamento operacional. Dentre os métodos baseados em *hardware*, destacam-se os acústicos, ópticos e ultrassônicos (Wegelin, 2014).

Já os métodos baseados em *software* utilizam programas que monitoram continuamente parâmetros da tubulação, como pressão, vazão, densidade e temperatura, para inferir se existe alguma falha, por exemplo uma obstrução (Wegelin, 2014). Algumas das abordagens utilizadas nos métodos de *software* são os baseados em ferramentas estatísticas, e os que utilizam onda de pressão negativa.

No trabalho (Lile et al., 2012) é utilizado o método de análise de vibrações para descrever os efeitos da obstrução em um duto circular, onde o gráfico da transformada rápida de Fourier é traçado para descrever a correlação entre os níveis de bloqueio e os sinais de vibração. Quando o fluxo de um fluido passa por uma obstrução, a área da seção transversal do fluxo reduz, aumentando a velocidade e diminuindo a pressão do fluido. Devido a esta variação de pressão e aumento da velocidade, a resposta da vibração proeminente é observada. Os parâmetros de vibração são medidos através de acelerômetros instalados nos diferentes pontos da tubulação onde podem ocorrer diferentes níveis de obstrução ao longo do seu comprimento. As variações de área e pressão alteram o padrão de vibração. Após comparar as frequências em vários pontos do tubo, observa-se que no local de espessura máxima de bloqueio, a velocidade é máxima. Faz-se necessário que os acelerômetros tenham um bom contato com a tubulação para obtenção de resultados

adequados. A acurácia do método depende do quão próximos os medidores estão das obstruções.

Em Duan et al. (2015) e Wang et al. (2009) a metodologia de reflectometria do pulso acústico é utilizada para determinar a presença de obstrução em dutos. O método se baseia na injeção de ondas acústicas que se propagam ao longo da tubulação. Toda mudança na seção do duto causa uma reflexão do sinal. Os sinais refletidos são captados e analisados em relação a velocidade do som, tornando possível a detecção das características da obstrução, como comprimento e área da seção transversal. Ambas as metodologias necessitam de técnicas para o processamento do sinal, devido à grande presença de ruídos.

Duan et al. (2014) propõe um outro método para detectar obstruções em dutos, observando as mudanças nas frequências de ressonância do sistema. O método analítico é usado para explicar as mudanças de frequência induzidas por bloqueios em tubulações. Para analisar o fenômeno de mudança de frequência induzido por um bloqueio prolongado, uma análise de perturbação de onda é conduzida. A metodologia não apresenta bons resultados quando as obstruções são extensas.

Uma ferramenta estocástica para detecção de bloqueios parciais de dutos é proposta em Massari et al. (2014). Um estimador estocástico linear usando medições de carga transitória foi desenvolvido para detectar bloqueios parciais em dutos de água. De acordo com Massari et al. (2014) o modelo fornece uma estimativa não enviesada da distribuição do diâmetro devido a bloqueios parciais e quantifica a incerteza associada a essas estimativas.

Em Robins (2005) é apresentada a tecnologia de radioisótopos que emitem raios gama para identificar obstruções presentes na tubulação. Os raios atravessam a matéria do duto e se mimetizam com a obstrução, tornando possível a identificação das mesmas através de sensores capazes de detectar este tipo de radiação. Apesar de apresentar resultados rápidos e satisfatórios, esta metodologia necessita de um operário especializado durante a medição, do contrário pode se tornar uma técnica perigosa ao ambiente.

Já o trabalho de Wuhua and Zongchang (2006) utiliza a abordagem do modelo de equilíbrio termodinâmico sólido-líquido para identificação de precipitação da cera que causa obstrução em oleodutos. A metodologia apresenta bons resultados, especialmente para dutos de petróleo bruto, porém não se mostra adequada para fluidos com características diferentes.

Essas foram as técnicas encontradas na bibliografia para tratamento do problema em questão, que não se mostraram adequadas ao caso a ser abordado. Assim sendo, cogitou-se a possibilidade de adotar um novo método. O método então adotado utiliza câmera termográfica e técnicas de inteligência artificial, mais precisamente redes neurais. Câmaras desse tipo são bastante acessíveis e o tratamento das imagens obtidas com o uso de redes neurais se mostrou adequado aos objetivos propostos, como será descrito nos capítulos que seguem.

3 FUNDAMENTAÇÃO TEÓRICA

O objetivo deste capítulo é apresentar uma fundamentação conceitual sobre as tecnologias utilizadas na metodologia proposta para a inspeção de obstruções em dutos. São abordados conceitos relacionados a métodos de captura de imagens por câmeras termográficas e sistemas a laser. Afora isso, outras referências a conceitos e métodos e suas aplicações, associados ao tema desta proposta, são também apresentados.

3.1 Computação Visual

A computação visual engloba as áreas de visão computacional, computação gráfica e processamento digital de imagens (Posada et al., 2015). Através do uso dessa tecnologia é possível desenvolver soluções completas em diferentes áreas de aplicação. Computação visual pode ser definida como o campo de aquisição, análise e síntese de dados visuais por meios computacionais (Posada et al., 2015).

Os conceitos de Termografia e Laser escaner 3D associados a computação visual são então enfocados.

3.1.1 Termografia

Imagens estão disponíveis em diferentes categorias, em função da faixa de frequência do espectro utilizado para capturá-las. A termografia é uma técnica para obtenção de imagens, na qual o espectro infravermelho é usado para medir o calor que está sendo emitido por um objeto (Acampora et al., 2011, Chen et al., 2015, Vollmer, 2018). A medição é realizada através de um sensor de raios infravermelhos da câmera termográfica que detecta esse tipo de radiação, emitida pelo objeto, e a converte em sinais eletrônicos. Esses sinais são então transformados em valores de temperatura e o conjunto destes valores forma a imagem térmica. Cada pixel da imagem térmica corresponde ao valor de temperatura medido numa região da superfície do objeto (Grosso, 2016, Maldague et al., 2001, Vollmer, 2018).

Essa tecnologia utiliza o processamento de imagens pseudo-coloridas para descrever a distribuição da temperatura da superfície do objeto de interesse. As cores são obti-

das de acordo com a calibração adotada para representar as temperaturas no espectro infravermelho (Acampora et al., 2011). Trata-se de uma técnica não invasiva pois ela permite a medição sem que haja a necessidade de qualquer contato com o objeto alvo (Bagavathiappan et al., 2013, Maldague et al., 2001, Vollmer, 2018, Zadeh et al., 2016).

Em geral, um sistema IRTI (*Infrared thermal imaging*) é composto por uma câmera térmica equipada com detector infravermelho, uma unidade de processamento de sinais e um sistema de aquisição de imagens, geralmente na forma de um sistema embarcado (Santhi, 2017). Essas câmeras são utilizadas para aplicações tais como detecção de falhas em objetos fundidos, gerenciamento de irrigação e detecção de movimento, entre outras.

Segundo Santhi (2017), o processamento de imagens térmicas digitais é considerado uma área de pesquisa essencial no cenário atual. Com ele é possível analisar e interpretar informações significativas em diferentes áreas de aplicação. Existem muitas abordagens tradicionais para realizar o processamento térmico de imagens. No entanto, técnicas de inteligência computacional podem auxiliar na obtenção automática de resultados a partir de imagens térmicas.

Atualmente, os dispositivos para obtenção de imagens térmicas são capazes de capturar imagens com grande resolução espacial, possibilitando uma variedade de aplicações em engenharia, tanto básicas como avançadas. Da mesma forma, os atuais avanços nas técnicas de processamento de imagens permitem a obtenção de resultados de forma rápida e precisa (Chen et al., 2015). Assim, espera-se que, ao combinar técnicas de obtenção de imagens térmicas com técnicas de processamento de imagens, muitos problemas do mundo real, como por exemplo os de domínio industrial, possam ser tratados com menor esforço.

Como mencionado, a técnica de termografia pode ser usada em aplicações diversas, principalmente devido ao seu baixo custo. Sua aplicação na indústria pode ser capaz de auxiliar na melhoria da qualidade dos produtos, na segurança do trabalho, no aumento da produtividade, por exemplo, podendo identificar falhas em instalações elétricas e mecânicas. Em Bagavathiappan et al. (2013) são apresentadas técnicas de IRTI que são amplamente utilizadas em aplicações como monitoramento de estruturas civis, componentes elétricos e eletrônicos, deformação, corrosão e solda, bem como na inspeção de máquinas, nas indústrias nuclear e aeroespacial.

3.1.1.1 Conceitos Físicos

A temperatura é considerada como um parâmetro universal para o entendimento do conceito de energia interna que ocorre em corpos físicos, em decorrência de diferentes processos. Como, processos de geração, conversão, transporte e armazenamento de energia (Silva, 2019, Vavilov, 2014). Estudar e entender esses processos nos permite recuperar informações importantes sobre diversos comportamentos que ocorrem na natureza.

O calor pode ser transferido de três maneiras diferentes, sendo elas: por condução, por convecção e por radiação. Para a termografia, as mais importantes são a condução e a

Tabela 1: Subdivisão infravermelha genérica (Gade and Moeslund, 2014)

Nomenclatura	Abreviação	Comprimento de Onda(μm)
Próximo (Near-infrared)	NIR	0.7-1.4
Ondas Curtas (Short-wavelength)	SWIR	1.4-3
Ondas médias (Mid-wavelength)	MWIR	3-8
Ondas longas (Long-wavelength)	LWIR	8-15
Distante	FIR	15-1000

Tabela 2: Subdivisão infravermelha usada em câmeras termográficas (Gade and Moeslund, 2014)

Nomenclatura	Abreviação	Comprimento de Onda(μm)
Ondas Curtas (Short-wavelength)	SWIR	0.7-1.4
Ondas médias (Mid-wavelength)	MWIR	3-5
Ondas longas (Long-wavelength)	LWIR	8-14

radiação. Na condução, a transferência de calor se dá pela transferência de energia em um mesmo corpo sólido quando há diferença de temperatura, ou em corpos sólidos distintos que estão em contato e possuem diferentes temperaturas. A energia é transferida por condução da região que possui maior temperatura para a de menor temperatura (Maldague et al., 2001, Vollmer, 2018).

Na radiação a transferência de calor ocorre através de ondas eletromagnéticas. Todo objeto que possui uma temperatura maior do que zero absoluto (0 K ou -273°C) emite radiação eletromagnética (Bagavathiappan et al., 2013, Maldague et al., 2001, Vollmer, 2018). A radiação infravermelha, em relação a outros espectros eletromagnéticos, encontra-se entre a luz visível e as microondas, possuindo um comprimento de onda na faixa de 0,7-1000 μm (Bagavathiappan et al., 2013, Maldague et al., 2001, Vollmer, 2018). O espectro infravermelho pode ser dividido em diferentes faixas espectrais, sendo as mais comuns apresentadas na Tabela 1. A Tabela 2 apresenta as faixas espectrais mais utilizadas em câmeras termográficas.

A radiação emitida por um objeto com uma temperatura T é descrita pela lei de Planck, em função da distribuição do comprimento de onda, pela Equação 1:

$$I(\lambda, T) = \frac{2\pi hc^2}{\lambda^5 (e^{hc/\lambda k_B T} - 1)}, \quad (1)$$

onde λ corresponde ao comprimento de onda, h a constante de Planck ($6,626 \times 10^{-34} \text{Js}$), c a velocidade da luz ($299.792.458 \text{ m/s}$) e k_B é a constante de Boltzmann ($1,3806503 \times 10^{-23} \text{ J/K}$). A lei de Planck descreve a radiação emitida por um corpo negro (Planck, 1901).

O corpo negro é considerado um objeto ideal capaz de absorver ou emitir toda radiação

que incide sobre ele, portanto sua emissividade é igual a 1. Corpos reais possuem emissividade que varia de 0 a 1 e possuem diferentes capacidades de absorver, refletir e emitir radiação (Bergman et al., 2011, Maldague et al., 2001). Quanto maior for a emissividade de um material, menor será a quantidade de radiação que será refletida pelo mesmo.

A IRT (*Infrared Thermography*) pode ser dividida em duas categorias, baseadas na excitação térmica a que foi submetido o material em observação. Na termografia passiva a temperatura do objeto monitorado pode ser capturada sem que haja a necessidade de qualquer estímulo térmico externo. Ou seja, o objeto em si atua como uma fonte de calor, tornando possível a obtenção dos gradientes de temperatura para a detecção de possíveis efeitos anormais no objeto, sem a necessidade de uma análise temporal (Bagavathiappan et al., 2013, Maldague et al., 2001, Maldague, 2002, Vollmer, 2018).

Já na termografia ativa, o uso de um estímulo térmico externo é essencial para gerar um contraste térmico no objeto monitorado, realçando as regiões de interesse que não são possíveis de serem identificadas na temperatura ambiente. É necessário um monitoramento temporal para analisar a variação da temperatura na superfície do objeto (Bagavathiappan et al., 2013, Maldague, 2002, Vollmer, 2018). Dependendo do estímulo térmico utilizado, a abordagem ativa pode ser classificada em termografia ativa: Pulsada (*Pulse Thermography*), Modulada (*Lock-in Thermography*), Fase Pulsada (*Pulse Phase Thermography*), Pulsada Longa (*Step Heating Thermography*) (Bagavathiappan et al., 2013, Maldague, 2002).

Imagens térmicas são amplamente utilizadas em áreas como: medicina (Dey et al., 2017, Jones, 1998, Kennedy et al., 2009), agricultura e meio ambiente (Ishimwe et al., 2014, Khanal et al., 2017, Lee et al., 2014, Roopaei et al., 2017, Vadivambal and Jayas, 2011), cidades/casas inteligentes (Gade et al., 2016), inspeção de construção civil (Al-Kassir et al., 2005, Balaras and Argiriou, 2002, Ljungberg, 1994), aplicações militares e de segurança (Bhowmik et al., 2011, Kastek et al., 2010, MacDonald et al., 2003, Santhi, 2017, Siegel, 2002).

3.1.2 Laser escâner 3D

Um laser escâner 3D é um dispositivo capaz de analisar objetos ou ambientes do mundo real e coletar dados sobre sua forma e até mesmo sua cor. Com os dados coletados é possível construir modelos digitais tridimensionais (Ebrahim, 2016, Son et al., 2002).

Escâner a laser, bem como o escâner a laser de mão, pode ser descrito como uma estação total motorizada, que mede através da direção controlada dos raios laser todos os pontos horizontal e verticalmente. Onde, para cada ponto medido são registrados a sua distância e os ângulos horizontal e vertical em relação ao escâner (Ebrahim, 2016, Pfeifer and Briese, 2007, Son et al., 2002). Isso possibilita que as coordenadas do espaço em relação à posição do escâner possam ser facilmente calculadas. As coordenadas de distância da superfície 3D do objeto são medidas na medida em que o pulso da luz é refletido, gerando nuvens de pontos 3D que representam as estruturas espaciais do objeto

(Paulus et al., 2014).

A tecnologia de escaneamento 3D a laser é usada principalmente para identificar e modelar a superfície do objeto em estudo e é considerada uma forma de aquisição de dados rápida e adequada (Boehler and Marbs, 2002, Paulus et al., 2014, Pfeifer and Brieese, 2007). O escâner a laser 3D é uma tecnologia não invasiva pois não necessita contato físico com o objeto que está sendo analisado. A técnica de escaneamento 3D não invasiva conta com duas diferentes abordagens para escanear um objeto, sendo elas, técnica ativa e técnica passiva.

Os escâneres passivos dependem da detecção da radiação refletida no ambiente pois eles não emitem nenhum tipo de radiação. A maioria dos escâneres deste tipo detecta luz visível, que é uma radiação disponível no ambiente. Outros tipos de radiação como o infravermelho também podem ser usados (Ebrahim, 2016).

Já técnica ativa emite radiação ou luz e através da detecção do seu reflexo realiza a digitalização do objeto ou ambiente. O tipo de emissão utilizada pode ser ultrassom, raio-x ou luz (Ebrahim, 2016).

O escaneamento 3D a laser é comumente dividido em três principais categorias: tempo de voo (*time-of-flight* - TOF), mudança de fase (*phase shift*) e triangulação (*triangulation*) (Boehler and Marbs, 2002, Boehler et al., 2003, Ebrahim, 2016, Pfeifer and Brieese, 2007).

Na tecnologia de escaneamento realizado por um sensor do tipo hora de voo, o laser é utilizado para emitir um pulso de luz ao objeto e a distância entre o transmissor e a superfície refletora é calculada a partir do tempo de viagem entre a transmissão e a recepção do sinal. Sistemas do tipo TOF são capazes de medir longas distâncias e possuem uma taxa de aquisição baixa (Boehler and Marbs, 2002, Ebrahim, 2016).

O escaneamento por mudança de fase é realizado através da emissão de lasers modulados com ondas constantes de diferentes comprimentos. A distância é calculada através da mudança de fase obtida entre os sinais emitidos e refletidos. O sistemas de mudança de fase possuem uma alta taxa de aquisição (Ebrahim, 2015).

No sistema de triangulação as coordenadas são obtidas através da projeção de um laser sobre a superfície de um objeto e o feixe refletido é detectado pelas câmeras do escâner. Essa técnica é chamada triangulação porque o ponto do laser que incide no objeto, a câmera e o emissor do laser formam um triângulo (Boehler and Marbs, 2002, Ebrahim, 2015, Son et al., 2002). Os escâneres 3D portáteis utilizam o sistema de triangulação.

No setor industrial, o escaneamento a laser tem sido amplamente usado para realização de engenharia e inspeção reversa, como em motores, produtos eletrônicos, moldes, análise de engenharia e inspeção de superfície (Bokhabrine et al., 2012, Chang and Chang, 2002, Ebrahim, 2016, Geng and Bidanda, 2017, Herráez et al., 2016, Lee et al., 2017, Son et al., 2002).

3.2 Redes Neurais

Os primeiros estudos sobre redes neurais foram propostos em 1943 pelo psiquiatra Warren McCulloch e o matemático Walter Pitts (McCulloch and Pitts, 1943). Os autores descreveram, através de expressões lógicas, as redes neurais, unificando conhecimentos de neurofisiologia e de lógica matemática (Haykin, 2007, McCulloch and Pitts, 1943). A ideia das RNAs (Redes Neurais Artificiais) é utilizar os conhecimentos sobre o sistema biológico de redes neurais para resolver problemas computacionais complexos (Haykin, 2007, Jain et al., 1996).

Uma rede neural biológica é composta por células nervosas, denominadas neurônios, ver Figura 1. Um neurônio é composto por dendrito, axônio, corpo celular e sinapse, que serão descritos a seguir, conforme (Daniel, 2013, Haykin, 2007):




Figura 1: Neurônio biológico adaptado de (Daniel, 2013).

- Dendrito: receptor de sinais, entrada do neurônio;
- Axônio: responsável por transmitir o sinal disparado pelo corpo celular;
- Sinapse: região onde ocorre a troca de sinal do axônio de um neurônio (pré-sináptico) para dendrito (pós-sináptico) de outro. Converte um sinal elétrico pré-sináptico em sinal químico, que é então convertido para um sinal elétrico pós-sináptico. Os sinais podem ser excitatórios ou inibitórios;
- Corpo Celular: realiza o processamento dos sinais e os dispara. Quando o neurônio recebe um determinado número de estímulos elétricos, um pulso elétrico é disparado através do axônio até as sinapses.

É importante entender que um neurônio pode conter centenas de sinapses, podendo estar conectado a centenas de outros neurônios, recebendo e enviando sinais de forma simultânea. Porém essas interconexões não possuem prioridades (pesos) iguais, algumas possuem prioridades mais altas do que outras (Daniel, 2013).

Uma rede neural artificial pode ser vista como um grafo direcionado com pesos, onde os neurônios artificiais são os nodos e as arestas, com pesos, são as conexões entre os neurônios de entrada e os neurônios de saída (Basheer and Hajmeer, 2000, Jain et al., 1996). A Figura 2 apresenta o modelo de um neurônio artificial, o modelo apresentado é uma evolução do proposto por McCulloch & Pitts em (McCulloch and Pitts, 1943). O primeiro modelo proposto considerava apenas a função de ativação limiar. Já o aqui apresentado considera a utilização de diferentes tipos de função de ativação (Daniel, 2013, Haykin, 2007), assim como o acréscimo de um *bias* (b_k) responsável por ajudar o modelo de maneira que ele possa se adaptar melhor aos dados fornecidos.




Figura 2: Modelo de neurônio artificial adaptado de (Haykin, 2007).

Matematicamente, o neurônio pode ser descrito pelas seguintes equações:

$$v_k = \sum_{j=1}^m w_{kj} \cdot x_j + b_k \quad (2)$$

$$y_k = \varphi(v_k) \quad (3)$$

Onde: j índice das entradas do neurônio; b_k bias aplicado ao neurônio; v_k saída do somador dos x_j sinais de entrada do neurônio; w_{kj} pesos sinápticos; $\varphi()$ função de ativação; y_k saída do neurônio.

As funções de ativação são extremamente importantes para o aprendizado das redes neurais artificiais. Elas implementam a transformação não linear do sinal de entrada na saída calculada, que é então enviada para a próxima camada de neurônios como entrada. Exemplos de função de ativação podem ser sigmoideal, linear ou tangente hiperbólica.

O Perceptron de Múltiplas Camadas (MLP - *Multi Layer Perceptron*) consiste em um sistema simples de neurônios interconectados capaz de realizar o mapeamento não linear entre variáveis de entrada em uma saída (Haykin, 2007). MLP é descrita como uma rede totalmente conectada onde cada nodo é conectado em todos os nodos da próxima camada e da anterior (Gardner and Dorling, 1998).

Uma rede MLP possui neurônios conectados por pesos e sinais de saída, que são a soma das entradas no nodo, modificada por uma função de ativação. O resultado obtido da função de ativação é então passado como sinal de entrada para os neurônios da próxima camada. Por possuir essa direção no processamento da informação, a MLP é conhecida por ser uma rede neural *feedforward* (Jain et al., 1996).

Uma rede MLP tem seu aprendizado realizado através do treinamento. Na fase de treinamento, um conjunto de dados é apresentado para a rede repetidamente e os pesos são ajustados até que o mapeamento desejado entre entrada e saída seja encontrado (Gardner and Dorling, 1998). O objetivo é ajustar os pesos até encontrar o menor valor para o erro calculado entre a saída desejada e a calculada pela rede.

O algoritmo *backpropagation* (Rumelhart et al., 1986) é amplamente utilizado para ajustar os pesos sinápticos para minimizar o erro. O algoritmo de retropropagação (*back-propagation*) busca encontrar o erro mínimo global através da retropropagação do erro da saída da rede até a sua entrada (Gardner and Dorling, 1998, Haykin, 2007). Os passos do algoritmo são descritos como:

1. Inicialização dos pesos sinápticos;
2. Apresentação dos dados de treinamento para a rede;
3. Propagar as entradas pela rede para obter uma saída;
4. Calcular o erro através da comparação entre a saída obtida e a saída desejada;
5. Retropropagar o erro pela rede;
6. Ajustar os pesos para minimizar o erro global;
7. Repetir o processo a partir do 2º passo até o erro mínimo.

O processo é realizado iterativamente para cada vetor de entrada, até que todos os dados sejam apresentados à rede neural.

As redes neurais perceptron multicamadas são amplamente utilizadas em diferentes áreas (Duan et al., 2019, Paliwal and Kumar, 2009), tais como: financeira (Yoon et al., 1993), medicina (Gaudart et al., 2004, Subasi and Ercelebi, 2005), *marketing* (Gan et al., 2005), construção civil (Pandey and Barai, 1995), meio ambiente (Boznar et al., 1993) e na indústria (Cavaliere et al., 2004, Duran et al., 2009, Sola and Sevilla, 1997).

3.3 *Guided Filter*

A maioria das aplicações em visão computacional e computação gráfica envolve o conceito de filtragem de imagem para reduzir o ruído e/ou extrair estruturas de imagens.

O Filtro Guiado (He et al., 2012) é um tipo de filtro de suavização que preserva a borda. Da mesma forma que o filtro bilateral, este filtro de imagem também pode filtrar ruídos ou texturas, mantendo nítidas as bordas. A saída de filtragem é localmente uma transformação linear da imagem âncora. Este filtro tem a propriedade de preservar as bordas como o filtro bilateral, entretanto não sofre com os artefatos de reversão de gradiente (Kao et al., 2013).

O filtro guiado executa a suavização de preservação de bordas em uma imagem, usando o conteúdo de uma segunda imagem, chamada de imagem âncora, para influenciar a filtragem. A imagem âncora pode ser a própria imagem, uma versão diferente da imagem ou uma imagem completamente diferente. A filtragem de imagem guiada é uma operação de vizinhança, como outras operações de filtragem, mas leva em consideração as estatísticas de uma região na vizinhança espacial correspondente na imagem âncora ao calcular o valor do pixel de saída.

Se a âncora for igual à imagem a ser filtrada, as estruturas serão as mesmas - uma borda na imagem original é a mesma na imagem âncora. Se a imagem âncora for diferente, as estruturas na imagem âncora terão impacto na imagem filtrada, com efeito, imprimindo essas estruturas na imagem original. Este efeito é denominado transferência de estrutura

Experimentos mostram que o filtro guiado tem um desempenho muito bom em termos de qualidade e eficiência em uma grande variedade de aplicações, como redução de ruído (Zhang et al., 2016), suavização/aprimoramento de detalhes (Rajendran et al., 2016), embaçamento/difusão de imagem (He et al., 2012), remoção de neblina (Pang et al., 2011).

4 METODOLOGIA

Este trabalho propõe um método não invasivo baseado em visão computacional para inferir o grau de obstrução de tubulações em indústrias de adubo. Uma visão geral do método pode ser vista na Figura 3.




Figura 3: Visão geral do método proposto para inferir grau de obstrução em tubulações.

A ideia é utilizar uma câmera térmica que adquire imagens associadas a temperatura emitida pela superfície externa da tubulação. Esta imagem será processada por uma rede neural que fornecerá como saída a altura de depósito normal a curvatura da seção da tubulação. A proposta utiliza redes neurais para mapear imagens térmicas em perfis de depósito. A ideia é usar uma rede neural para inferir a relação entre os pixels da imagem térmica obtida do exterior do tubo e o perfil de sedimento no seu interior.

A hipótese adotada é que o fertilizante é um material menos termoquímico que o aço da tubulação e o ar em seu interior, tornando possível capturar na imagem o acúmulo do sedimento a partir do comportamento térmico do exterior do duto.

É possível observar na Figura 7 que a temperatura do tubo diminuiu com a adição de material sedimentado, o que leva a perceber que o fertilizante atua como uma barreira térmica. Isto indica que, quando a temperatura no duto diminui, um acúmulo indesejável de sedimento está ocorrendo. E isso pode levar a uma situação adversa a ponto de afetar toda a operação da produção de fertilizantes.

Pela complexidade de um modelo analítico que descreva as não linearidades deste fenômeno, parte-se para a adoção de técnicas da IA capazes de aprender, a partir de dados, complexas relações de mapeamento (Haykin, 2007). Assim, para mapear a imagem térmica em nível de obstrução opta-se por utilizar uma rede neural Multi-layer Perceptron

(MLP). Uma MLP requer menor número de parâmetros para uma boa generalização quando comparada a uma CNN (*Convolutional Neural Network*) que é mais complexa e requer maior número de parâmetros e amostras de dados para um bom desempenho e generalização (O'Mahony et al., 2019, Sato et al., 2017).

A rede analisará a imagem em pequenas janelas de $n \times n$ pixels (entrada) fornecendo o perfil de depósito associado ao centro (a, b) da janela (saída). A Figura 4 apresenta a arquitetura da rede neural utilizada. A rede possui uma camada de entrada com n^2 neurônios (máscara $n \times n$), uma camada escondida e uma camada de saída com um neurônio escalar (altura z do perfil de depósito).




Figura 4: Rede neural proposta para o mapeamento do comportamento térmico no perfil de depósito.

Isto posto, torna-se necessário construir um *dataset* (conjunto de dados) para treinar a rede. Obter tal *dataset* preciso, *in situ*, não é uma tarefa simples. Essa dificuldade é devida a que o interior do duto apresenta um ambiente altamente inóspito aos equipamentos de medição. O grande fluxo de poeira e as altas temperaturas impossibilitam que se obtenha um *ground truth* adequado do depósito. Para contornar essa dificuldade propõe-se adotar um *dataset* obtido em um experimento controlado. Uma maquete do tubo, em escala, é então utilizada. Possíveis modelos de deposição do sedimento capazes de definir o *ground truth* são manualmente elaborados e suas formas e dimensões obtidas com um escâner 3D. Esses modelos são instalados no interior do duto maquete. Fluxos de ar quente são forçados no interior do tubo maquete e as temperaturas que ocorrem no seu exterior são captadas

por câmeras termográficas. Com os dados obtidos nesses experimentos é então construído o *ground truth* desejado. Na seção que segue detalha-se melhor esse procedimento.

4.1 O Dataset em escala

A Figura 5 ilustra a proposta de geração de *dataset* desenvolvida. Cada amostra do *dataset* é obtida por uma imagem térmica (entrada) e um perfil 3D de depósito (rótulo).




Figura 5: Procedimento para obtenção do *Dataset* Anotado: (a) Entrada: imagem térmica adquirida da maquete com perfil de depósito; (b) Dado anotado de altura de depósito: projeção 2D da nuvem de pontos capturada do perfil pelo laser

4.1.1 Entrada do Dataset: A imagem térmica

A imagem térmica é obtida apontando a câmera termográfica para o duto em escala, que possui um soprador térmico e um exaustor nele instalados. O processamento necessário é então realizado na região de interesse (*ROI - Region of Interest*) da imagem térmica obtida do exterior do duto em estudo. Dessa forma obtém-se o comportamento térmico do exterior do duto maquete, nas condições típicas de funcionamento do duto real.

A Figura 6 mostra um exemplo de uma imagem termográfica capturada num experimento, onde o duto em escala estava vazio. Já a Figura 7 apresenta o mesmo duto, porém com sedimentação de fertilizante no seu interior.




Figura 6: Exemplo de imagem térmica obtida num experimento com o duto vazio.




Figura 7: Exemplo de imagem térmica obtida num experimento com sedimentação no interior do duto.

4.1.2 Anotação do *Dataset*: O Perfil de Depósito

A sedimentação do fertilizante ocorre na parte inferior do tubo, em tubos horizontais. O perfil de depósito $z(x, y)$ é obtido com um escâner a laser 3D portátil. Uma vista do perfil escaneado é apresentado na Figura 8. Com o objeto escaneado, é possível obter as dimensões da pedra e associar cada posição da imagem térmica a um perfil de depósito.




Figura 8: Feições típicas de um sedimento.

O resultado gerado do escaneamento do acúmulo é um arquivo exportado do software próprio do escâner 3D. O arquivo de saída é uma estrutura de dados contendo uma lista de vértices e uma lista de faces do objeto. Cada vértice é um ponto no espaço tridimensional, e cada face é um triângulo formado por três pontos, ou seja, a superfície escaneada é formada por polígonos. Os vértices são coordenadas (x, y, z) e as faces são listas de três vértices cada.

São realizadas fatias transversais ao longo do comprimento do objeto. As fatias são intersecções de planos com o objeto 3D. Cada intersecção resulta em conjuntos de pontos que formam um polígono. Cada polígono corresponde a uma fatia 2D do modelo do depósito. A Figura 9 apresenta um exemplo de uma fatia realizada no objeto escaneado.




Figura 9: Exemplo de fatia 2D obtida, os pontos vermelhos correspondem a vértices que pertencem ao objeto que estão sendo interceptados pelo plano que corresponde a fatia.




Figura 10: Fatias obtidas do objeto escaneado.

As alturas das fatias são medida através da intersecção de linhas verticais ao longo da largura do objeto com o polígono que forma a fatia, como ilustrado na Figura 11. Cada

intersecção resulta em um par de pontos, a distância entre esses pontos corresponde a altura do acúmulo em determinado ponto na fatia. As alturas calculadas são armazenadas em um vetor associado a cada fatia. A imagem final do modelo de depósito é então gerada onde o valor da coordenada z no ponto x, y representa a espessura do fertilizante.




Figura 11: Intersecção das linhas verticais com a fatia para obter as alturas, .

4.1.3 Perfis de Treinamento

A Figura 12 apresenta os modelos de obstrução elaborados para a construção do *dataset*.




Figura 12: Padrões de obstrução elaborados. A primeira coluna apresenta um desenho de como a obstrução ocupa o duto, a coluna central apresenta uma vista do escaneamento, e a terceira coluna apresenta a imagem final do modelo de depósito após o processamento do objeto escaneado.

Os perfis foram elaborados supondo possíveis estágios de obstrução. Pretende-se que eles representem o acúmulo em diferentes conformações e estágios, entendendo que os mesmos são suficientemente variados para cobrir diferentes formas de obstrução. O padrão 1 representa um acúmulo quase total da seção do tubo. O padrão 2 representa um acúmulo parcial de aproximadamente metade da seção da tubulação. Os padrões 3 e 4, representam acúmulos com uma formação inclinada para as duas possíveis direções do fluxo. Já os padrões 5 e 6 representam estágios iniciais de acúmulo constante ao longo da tubulação. As diferentes espessuras de um depósito, das menores para as maiores, são representadas por tons de cinza mais escuros para mais claros, respectivamente.

4.1.4 Associação entre Imagens Térmicas e Perfis de Depósito

Como já antecipado resumidamente, há que se determinar a associação entre os pixels da imagem térmica e as alturas Z_{altura} de acúmulo correspondentes. A Figura 13 apresenta a proposta final de construção do *dataset*. A câmera será posicionada de forma a imagear a vista x, y da tubulação. Para isso o objeto digitalizado é então fatiado a fim de calcular a altura nos pontos de interesse em cada fatia, (ver Figura 10).

Para gerar o conjunto de dados considera-se um fragmento da imagem térmica original,




Figura 13: O mapeamento é obtido a partir de uma câmera que capture a projeção no plano x, y da temperatura da superfície da tubulação.

de modo obter a intensidade dos pixels térmicos nesta janela. Duas formas para obtenção do nível de obstrução são utilizadas. Uma considera a intensidade dos pixels na janela, e a outra, a intensidade dos pixels e a altura em que a janela está sendo percorrida na imagem. Esta segunda alternativa incorpora-se explicitamente na estrutura da rede a distinção de espessura decorrente de se estar aferindo uma região específica com relação a dimensão y da tubulação (por exemplo se esta mais próximo ao fundo, em uma vista inferior térmica do fenômeno). Assim, espera-se com esta informação suplementar, diminuir a complexidade de mapeamento da rede. Para a imagem da espessura do fertilizante sedimentado é usado o mesmo tamanho de janela utilizado na imagem térmica, mas considera-se apenas o pixel central da mesma. Diferentes tamanhos de janela podem ser utilizados. Os dados são normalizados e aplicados na rede neural.

4.1.5 Um Modelo para Mapear Imagens Térmicas em Perfis de Depósito

O objetivo final é elaborar um modelo de depósito através de imagens térmicas não invasivas. Para isso, propõe-se o uso de redes neurais que aprendam a associação entre os pixels da imagem térmica $I^T(a, b)$ e o perfil de depósito $z(a, b)$. Considera-se percorrer janelas sobre a imagem térmica para treinar a rede neural, como a ilustrada na Figura 4.

A rede neural proposta é uma *Multilayer Perceptron* (Perceptron Multicamadas). A arquitetura da rede conta com uma camada de entrada com n^2 neurônios, uma camada escondida com $2n^2$ neurônios e 1 neurônio na camada de saída. Utiliza-se a função de ativação do tipo ReLu em todas as camadas. O algoritmo de otimização *Adam* (Kingma and Ba, 2014) é utilizado para ajustar os pesos da rede a fim de minimizar a função de erro. As imagens resultantes dos padrões aprendidos pela rede foram filtradas utilizando o filtro guiado, de maneira a remover possíveis descontinuidades que podem ser geradas pelo fato da imagem ser percorrida janela a janela.

5 RESULTADOS

Para validar o estudo proposto, um conjunto de dados em escala reduzida foi desenvolvido. A rede neural é então treinada com este *dataset*.

5.1 O Setup e o Conjunto de Dados

A abordagem utilizada considera que uma rede neural artificial pode aprender um conjunto de dados em escala reduzida para mapear a imagem térmica em um perfil de depósito. Desenvolveu-se então uma maquete constituída por um tubo de aço com 600 mm de comprimento, 100 mm de diâmetro externo e uma espessura de parede de 0,43 mm. O tubo apoia-se nas extremidades. Foi instalado um soprador de calor ajustável em um lado e um exaustor no outro. A hipótese aqui adotada é que vários cenários possam ser configurados, ajustando a temperatura, a vazão e o formato dos modelos de sedimento instalados no interior do duto.

A termografia infravermelha é realizada usando a câmera térmica Thermoteknix 307k. Ela é capaz de capturar comportamentos térmicos monocromáticos a uma resolução de 640×480 pixels. Também possui correção de não uniformidade (NUC - *Non Uniformity Correction*), um recurso que permite a auto-calibração para obter uma imagem uniforme, de maneira a corrigir pequenas variações indesejadas entre os pixels vizinhos, o que é normal para dispositivos desse tipo (Mudau et al., 2011, Vollmer, 2018). O componente que captura a imagem no interior da câmera não é um dispositivo de carga acoplado (CCD), mas um conjunto de microbolômetros composto por elementos amorfos de silício e óxido de vanádio. Estes são afetados pela radiação eletromagnética de comprimentos de onda entre 7,5 e 14 micrômetros, alterando sua resistência interna e compondo a imagem térmica (Vollmer, 2018).

As imagens térmicas capturadas são organizadas seguindo um padrão e armazenadas em um formato não compactado para evitar a perda de dados. Os nomes dos arquivos incluem informações como temperatura ambiente, registro de data e hora e indicações de qual tipo de obstrução está sendo testado.

Para dar início ao processo de captura das imagens termográficas, a distância entre

a lente da câmera e o modelo é ajustada para 800 mm. O soprador de ar para 100°C e a tensão de entrada do exaustor para 12V. A escala de temperatura da câmera é fixada em 25°C para o mínimo e 55°C para o máximo e a paleta de cores é definida em escala de cinza. Se necessário, a escala pode ser reajustada, tendo o cuidado de compensá-la no pré-processamento. Com o sistema configurado é necessário um período para a estabilização do processo térmico. É importante disparar a rotina de autocalibração da câmera antes de capturar qualquer imagem, para garantir consistência devido ao fator de não uniformidade.

Os grãos de fertilizante do tipo NPK (Nitrogênio, Fósforo e Potássio) são adicionados ao duto maquete para que eles se aglutinem com o calor. A Figura 14 ilustra esse processo, de formação do depósito. O soprador de ar é então ligado por aproximadamente 60 minutos para capturar a imagem térmica do duto com o depósito de fertilizante. A estabilização do sistema é verificada e a nova imagem é capturada e anotada. Os dados são analisados quando todo o processo é finalizado.



Figura 14: Fertilizante no fundo do duto maquete.

O próximo passo é escanear a pedra de fertilizante que foi formada na presença de calor no interior do modelo em escala. O escaneamento é realizado apontando o escâner SenseTM 3D para a sedimentação e rotacionando-o 360° ao redor do objeto, para que todas as feições do depósito sejam escaneadas.

5.2 O Treinamento da RNA

Cada amostra corresponde a uma janela $n \times n$ contendo a intensidade dos pixels. A janela percorre a imagem térmica. A amostra possui como rótulo o Z_{altura} , que corresponde ao pixel central da máscara de mesmo tamanho $n \times n$, obtido da medida do escâner na mesma área. As configurações da rede foram testadas com diferentes tamanhos de janelas, sendo elas, 3×3 , 5×5 , 7×7 , 9×9 , 11×11 e 13×13 . A complexidade computacional é

a mesma para os diferentes tamanhos de janela. Para avaliar o tempo de execução para os diferentes tamanhos de janela para amostras de até 240x80, utilizou-se um *notebook* Macbook Air 2012, processador Intel Core i5 Dual-Core 1,8 GHz, memória 4 GB, capacidade SSD Apple 120 GB, Intel HD Graphics 4000. Os treinamentos realizados com os diferentes tamanhos de janela resultaram em tempos semelhantes, na ordem de 20 minutos. Abaixo serão apresentados os resultados obtidos com a janela 9×9 , que apresentaram uma performance estatística superior às demais janelas e com precisão das respostas suficientes para o problema em questão.

Os dados foram divididos em uma configuração 80/20, de treinamento e de teste, respectivamente. A implementação da rede neural foi realizada no ambiente de desenvolvimento científico Spyder. Python foi a linguagem de programação escolhida e as bibliotecas Keras (construção da rede neural), Pandas (leitura dos dados) e Scikit-learn (normalização dos dados e análises estatísticas) foram utilizadas para o desenvolvimento da RNA.

A performance do modelo no conjunto de dados em escala foi avaliada através da raiz do erro quadrático médio (RMSE - *Root-Mean-Square Error*), Equação 4 e do erro absoluto médio (MAE - *Mean Absolute Error*), Equação 5. O RMSE mede o grau de dispersão em torno da linha de regressão, através do cálculo da média quadrática das diferenças entre os valores medidos e os preditos pela rede neural. Já o MAE calcula o desvio médio entre os valores medidos e os previstos. O R^2 , também conhecido como coeficiente de determinação, é a porcentagem da variação da variável resposta que é explicada por um modelo linear. O R^2 possui um intervalo de 0 a 1, onde 0 indica que o modelo não explica a variabilidade dos dados de resposta ao redor de sua média, e 1 indica que o modelo explica toda a variabilidade dos dados de resposta ao redor de sua média, então, quanto maior o R^2 , melhor o modelo se ajusta aos dados.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Medido_i - Predito_i)^2}. \quad (4)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Medido_i - Predito_i|. \quad (5)$$

As métricas de avaliação são calculadas com os resultados obtidos em todos os modelos. Quanto mais próximos de 0 forem os valores de RMSE e MAE, significa um melhor ajuste ao conjunto de dados.

Outra abordagem para verificar o desempenho do modelo é analisar o resíduo. O resíduo é a diferença entre o valor verdadeiro medido e o predito pela rede. Os resíduos representam a parte do valor medido que o modelo não consegue prever. A seguir são apresentadas análises dos resíduos, através dos histogramas dos resíduos.

Os histogramas dos resíduos, quando apresentados sob a forma de sino e na base zero indicam que o modelo comete erros aleatórios, não prevendo sistematicamente, para mais

ou para menos, nenhum intervalo de valores de destino. Se os resíduos não se apresentam sob a forma de sino de base zero, há alguma estrutura no erro de previsão do modelo. A adição de mais variáveis pode ajudar a capturar o padrão que não é captado pelo modelo adotado. Um resíduo positivo indica que o modelo subestima o destino (o valor real é maior do que o predito). Um resíduo negativo indica uma superestimação (o valor real é menor do que o predito).

Para o problema apresentado, uma subestimação do modelo significaria que a tubulação apresentaria uma maior obstrução do que a prevista pelo modelo. Já uma superestimação significaria ter uma obstrução menor da que a que o modelo previa.

Cada padrão elaborado e sua respectiva imagem térmica, foram utilizados individualmente para o treinamento da rede. Após o treinamento individual, as amostras foram treinados em conjunto. Os resultados obtidos foram então submetidos ao *guided filter*, conforme descrito na Seção 3.3, utilizando como imagem âncora a própria imagem a ser filtrada.

A seguir são apresentados os resultados obtidos do treinamento da rede com cada padrão individualmente. Para cada um deles foram realizadas análises estatísticas apresentadas nas Tabelas 3, 4, 5, 6, 7 e 8. Foram realizadas análises da dispersão em torno da linha de regressão dos valores medidos e dos preditos pela rede, vide Figuras 15, 18, 21, 24, 27 e 30.


Os histogramas dos resíduos também foram aplicados nos resultados obtidos, Figuras 16, 19, 22, 25, 28 e 31. Também foi verificado o desempenho da rede, submetendo à ela para predição o mesmo padrão adotado para o seu treinamento, Figuras 17, 20, 23, 26, 29 e 32.

5.2.1 Padrão 1

Considerando a imagem térmica obtida com o padrão 1, conforme Figura 12, como obstrução, foram obtidas 16705 amostras. A seguir estão os resultados após 1000 épocas.


Tabela 3: Resultados obtidos do Padrão 1 e utilizando uma janela 9×9 .

Entrada	RMSE	MAE	R ²
Intensidade pixel térmico + altura	0.02	0.01	0.99
Intensidade pixel térmico	0.05	0.03	0.95



(a) Resultado obtido ao considerar apenas as intensidades dos pixels. (b) Resultado obtido ao considerar as intensidades dos pixels e a altura como entrada da rede.

Figura 15: Mapeamento obtido ao considerar uma janela 9×9 .



(a) Entrada da rede: intensidades dos pixels. (b) Entrada da rede: intensidades dos pixels+altura.

Figura 16: Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 1.





Figura 17: Resultados obtidos da predição o Padrão 1.

5.2.2 Padrão 2


Considerando a imagem térmica obtidas com o padrão 2, conforme Figura 12, como obstrução, foram obtidas 8101 amostras. A seguir estão os resultados obtidos após 1000 épocas.

Tabela 4: Resultados obtidos do Padrão 2 e utilizando uma janela 9×9 .

Entrada	RMSE	MAE	R^2
Intensidade pixel térmico + altura	0.02	0.01	0.99
Intensidade pixel térmico	0.04	0.03	0.97



(a) Resultado obtido ao considerar apenas as intensidades dos pixels. (b) Resultado obtido ao considerar as intensidades dos pixels e a altura como entrada da rede.

Figura 18: Mapeamento obtido ao considerar uma janela 9×9 .

(a) Entrada da rede: intensidades dos pixels. (b) Entrada da rede: intensidades dos pixels+altura.

Figura 19: Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 1.

A Figura 20 apresenta o resultado predito pela rede





Figura 20: Resultados obtidos da predição o Padrão 2.

5.2.3 Padrão 3

Considerando a imagem térmica obtidas com o padrão 3, conforme Figura 12, como obstrução, foram obtidas 8269 amostras. A seguir estão os resultados obtidos após 1000 épocas.


Tabela 5: Resultados obtidos do Padrão 3 e utilizando uma janela 9×9 .

Entrada	RMSE	MAE	R^2
Intensidade pixel térmico + altura	0.02	0.01	0.99
Intensidade pixel térmico	0.05	0.02	0.96



(a) Resultado obtido ao considerar apenas as intensidades dos pixels. (b) Resultado obtido ao considerar as intensidades dos pixels e a altura como entrada da rede.

Figura 21: Mapeamento obtido ao considerar uma janela 9×9 .



(a) Entrada da rede: intensidades dos pixels. (b) Entrada da rede: intensidades dos pixels+altura.

Figura 22: Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 3.




Figura 23: Resultados obtidos da predição o Padrão 3.

5.2.4 Padrão 4

Considerando a imagem térmica obtidas com o padrão 4, conforme Figura 12, como obstrução, foram obtidas 8269 amostras. A seguir estão os resultados obtidos após 1000 épocas.


Tabela 6: Resultados obtidos do Padrão 4 e utilizando uma janela 9×9 .

Entrada	RMSE	MAE	R^2
Intensidade pixel térmico + altura	0.02	0.015	0.99
Intensidade pixel térmico	0.042	0.029	0.97



(a) Resultado obtido ao considerar apenas as intensidades dos pixels. (b) Resultado obtido ao considerar as intensidades dos pixels e a altura como entrada da rede.

Figura 24: Mapeamento obtido ao considerar uma janela 9×9 .



(a) Entrada da rede: intensidades dos pixels. (b) Entrada da rede: intensidades dos pixels+altura.

Figura 25: Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 3.




Figura 26: Resultados obtidos da predição o Padrão 4.

5.2.5 Padrão 5

Considerando a imagem térmica obtidas com o padrão 5, conforme Figura 12, como obstrução, foram obtidas 7730 amostras. A seguir estão os resultados obtidos após 1000 épocas.


Tabela 7: Resultados obtidos do Padrão 5 e utilizando uma janela 9×9 .

Entrada	RMSE	MAE	R^2
Intensidade pixel térmico + altura	0.022	0.014	0.97
Intensidade pixel térmico	0.05	0.032	0.89



(a) Resultado obtido ao considerar apenas as intensidades dos pixels. (b) Resultado obtido ao considerar as intensidades dos pixels e a altura como entrada da rede.

Figura 27: Mapeamento obtido ao considerar uma janela 9×9 .



(a) Entrada da rede: intensidades dos pixels. (b) Entrada da rede: intensidades dos pixels+altura.

Figura 28: Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 5.




Figura 29: Resultados obtidos da predição o Padrão 5.

5.2.6 Padrão 6


Considerando a imagem térmica obtidas com o padrão 6, conforme Figura 12, como obstrução, foram obtidas 10208 amostras. A seguir estão os resultados obtidos após 1000 épocas.

Tabela 8: Resultados obtidos do Padrão 6 e utilizando uma janela 9×9 .

Entrada	RMSE	MAE	R^2
Intensidade pixel térmico + altura	0.042	0.024	0.85
Intensidade pixel térmico	0.057	0.034	0.72



(a) Resultado obtido ao considerar apenas as intensidades dos pixels. (b) Resultado obtido ao considerar as intensidades dos pixels e a altura como entrada da rede.

Figura 30: Mapeamento obtido ao considerar uma janela 9×9 .

(a) Entrada da rede: intensidades dos pixels. (b) Entrada da rede: intensidades dos pixels+altura.


Figura 31: Histogramas dos resíduos considerando uma janela 9×9 para o Padrão 3.

Figura 32: Resultados obtidos da predição o Padrão 6.


5.2.7 Treinamento com todos padrões

Ainda de modo a avaliar a qualidade dos resultados a rede foi treinada com todos os padrões em conjunto, conforme acima descrito (Seção 5.2). O conjunto de dados

contendo todos os padrões desejados gerou 59276 amostras. A performance do modelo foi analisada com o objetivo de verificar se a rede é capaz de mapear as feições dos padrões. A seguir estão os resultados obtidos após 2000 épocas. Os resultados obtidos se mostraram satisfatórios conforme os resultados apresentados abaixo.


Tabela 9: Resultados obtidos do treinamento de todos os padrões em conjunto utilizando uma janela 9×9 .

Entrada	RMSE	MAE	R^2
Intensidade pixel térmico + altura	0.05	0.04	0.93
Intensidade pixel térmico	0.12	0.08	0.70



(a) Resultado obtido ao considerar apenas as intensidades dos pixels. (b) Resultado obtido ao considerar as intensidades dos pixels e a altura como entrada da rede.

Figura 33: Mapeamento obtido ao considerar uma janela 9×9 e todos os padrões.



(a) Resultado obtido ao considerar apenas as intensidades dos pixels. (b) Resultado obtido ao considerar as intensidades dos pixels e a altura como entrada da rede.

Figura 34: Curvas de aprendizados obtidas ao considerar uma janela 9×9 e todos os padrões.




Figura 35: Histogramas dos resíduos considerando uma janela 9×9 e as intensidades dos pixels.




Figura 36: Histogramas dos resíduos considerando uma janela 9×9 e as intensidades dos pixels+altura.

Ainda quanto ao modelo aqui adotado, a utilização da intensidade dos pixels juntamente com o valor da altura em que a janela se encontra na imagem térmica trouxe melhores resultados para o mapeamento. Foi adicionada mais informação, removendo assim possíveis ambiguidades nos dados. Isto pode ser observado nos histogramas das Figuras 36(a) e 36(b). Nelas, os dados apresentam uma melhor distribuição em torno de 0 do que as apresentadas nos modelos que não consideram a altura. Indicando que o modelo comete erros aleatórios.

As Figuras 37 e 38 apresentam os resultados dos padrões preditos pela rede. Observa-se nos resultados obtidos quando considerando como entrada da rede a intensidade dos pixels e a altura da janela que o modelo foi capaz de identificar as feições dos padrões, e as descontinuidades foram minimizadas através do filtro guiado.




Figura 37: Resultados obtidos com todos os padrões e considerando como entrada da rede neural as intensidades dos pixels, e os resultados filtrados




Figura 38: Resultados obtidos com todos os padrões e considerando como entrada da rede neural as intensidades dos pixels+altura, e os resultados filtrados

6 CONCLUSÕES E TRABALHOS FUTUROS

O trabalho desenvolvido apresentou um modelo para inspeção não invasiva de tubulações, utilizando câmera térmica, escâner a laser 3D e redes neurais, capaz de identificar o estágio de obstrução em dutos da indústria de fertilizantes.

Obter um *dataset* para realizar o mapeamento do comportamento térmico em perfil de depósito é uma tarefa difícil para ser realizada *in loco*. Portanto, foi desenvolvida uma maquete em escala para reprodução em laboratório dos fenômenos de depósito encontrados na indústria. Para capturar o comportamento térmico foi utilizada uma câmera térmica e um laser escâner 3D foi usado para escanear os padrões de depósito desenvolvidos.

Os perfis foram elaborados supondo possíveis estágios de obstrução. Entendeu-se que eles são capazes de representar o acúmulo em diferentes conformações e estágios. Admitiu-se que os mesmos são suficientemente variados para cobrir as possíveis diferentes formas de obstrução.

O conjunto de dados é gerado a partir de um fragmento da imagem térmica original, para obter a intensidade dos pixels na janela. Foram utilizadas duas abordagens diferentes para a obtenção do nível de obstrução. Uma considerou apenas a intensidade dos pixels na janela e a outra a intensidade dos pixels e a altura em que a janela estava sendo percorrida na imagem. Para a imagem da espessura do fertilizante utilizou-se a mesma janela considerada para a imagem térmica, mas apenas o pixel central é considerado.

Para aprender o mapeamento do perfil térmico em perfil de depósito foi utilizada uma rede neural Multi-layer Perceptron (MLP). A rede analisou a intensidade dos pixels da janela $n \times n$ (entrada) fornecendo o perfil de depósito associado ao centro da janela (saída). A arquitetura da rede contou com uma camada de entrada com n^2 neurônios, uma camada escondida com $2n^2$ neurônios e 1 neurônio na camada de saída. Utiliza-se a função de ativação do tipo ReLu em todas as camadas. Foram utilizadas janelas de tamanho 3×3 , 5×5 , 7×7 e 9×9 , entretanto foram reportados os resultados obtidos com janela 9×9 por apresentarem desempenho superior aos das janelas de menor tamanho, em tempos de execução semelhantes. Janelas de maior tamanho, como 11×11 e 13×13 apresentaram resultados semelhantes aos obtidos com janela de tamanho 9×9 , porém em maior tempo de execução.

As imagens resultantes dos padrões aprendidos pela rede foram filtradas utilizando o filtro guiado, de maneira a remover possíveis discontinuidades que podem ser geradas pelo fato da imagem ser percorrida janela a janela.

A rede neural foi capaz de aprender o mapeamento de pixel térmico em perfil de depósito obtendo resultados satisfatórios, mostrando ser possível detectar a sedimentação que está ocorrendo no interior de um duto a partir de uma imagem térmica obtida externamente.

Como trabalhos futuros, um mecanismo de notificação de eventuais obstruções do duto deve ser elaborado, agregando as medidas de entupimento resultantes do método ao longo de toda seção do tubo.

Também como trabalho futuro, a solução desenvolvida para o protótipo deverá ser transportada ao caso real da indústria. Para isso, deverá ser observada a correspondência entre as características das imagens térmicas obtidas *in loco* e as espessuras das incrustações que se depositam no interior dos tubos a serem monitorados, com a finalidade de determinar a ação de desobstrução a ser adotada.

Por fim, propõe-se o desenvolvimento de um sistema capaz de dispersar o depósito formado no interior do tubo. A ideia em perspectiva é adotar canhões de ar comprimido instalados junto ao duto, capazes de dispersar o material depositado, de modo a que ele seja novamente arrastado pelo fluxo circulante no tubo. Os canhões poderão ser acionados automaticamente a cada notificação encaminhada pelo procedimento que detecte a iminência de obstrução.

REFERÊNCIAS

- Acampora, L., De Filippis, F., Martucci, A., and Sorgi, L. (2011). 3d reconstruction of thermal images. In *Proceedings of 26th Aerospace Testing Seminar, Los Angeles (USA)*.
- Al-Kassir, A. R., Fernandez, J., Tinaut, F., and Castro, F. (2005). Thermographic study of energetic installations. *Applied Thermal Engineering*, 25(2-3):183–190.
- Bagavathiappan, S., Lahiri, B., Saravanan, T., Philip, J., and Jayakumar, T. (2013). Infrared thermography for condition monitoring—a review. *Infrared Physics & Technology*, 60:35–55.
- Balaras, C. A. and Argiriou, A. (2002). Infrared thermography for building diagnostics. *Energy and buildings*, 34(2):171–183.
- Basheer, I. A. and Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1):3–31.
- Bergman, T. L., Incropera, F. P., DeWitt, D. P., and Lavine, A. S. (2011). *Fundamentals of heat and mass transfer*. John Wiley & Sons.
- Bhowmik, M. K., Saha, K., Majumder, S., Majumder, G., Saha, A., Sarma, A. N., Bhattacharjee, D., Basu, D. K., and Nasipuri, M. (2011). Thermal infrared face recognition—a biometric identification technique for robust security system. *Reviews, refinements and new ideas in face recognition*, 7.
- Boehler, W. and Marbs, A. (2002). 3d scanning instruments. *Proceedings of the CIPA WG*, 6:9–18.
- Boehler, W., Vicent, M. B., Marbs, A., et al. (2003). Investigating laser scanner accuracy. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34(Part 5):696–701.
- Bokhabrine, Y., Seulin, R., Voon, L. F. L. Y., Gorria, P., Girardin, G., Gomez, M., and Jobard, D. (2012). 3d characterization of hot metallic shells during industrial forging. *Machine vision and applications*, 23(3):417–425.

- Boznar, M., Lesjak, M., and Mlakar, P. (1993). A neural network-based method for short-term predictions of ambient so₂ concentrations in highly polluted industrial areas of complex terrain. *Atmospheric Environment. Part B. Urban Atmosphere*, 27(2):221–230.
- Cavalieri, S., Maccarrone, P., and Pinto, R. (2004). Parametric vs. neural network models for the estimation of production costs: A case study in the automotive industry. *International Journal of Production Economics*, 91(2):165–177.
- Chang, D.-Y. and Chang, Y.-M. (2002). A freeform surface modelling system based on laser scan data for reverse engineering. *The international journal of advanced manufacturing technology*, 20(1):9–19.
- Chen, C.-Y., Yeh, C.-H., Chang, B. R., and Pan, J.-M. (2015). 3d reconstruction from ir thermal images and reprojective evaluations. *Mathematical Problems in Engineering*, 2015.
- Daniel, G. (2013). *Principles of artificial neural networks*, volume 7. World Scientific.
- Datta, S. and Sarkar, S. (2016). A review on different pipeline fault detection methods. *Journal of Loss Prevention in the Process Industries*, 41:97–106.
- Dey, N., Ashour, A. S., and Althoupety, A. S. (2017). Thermal imaging in medical science. In *Recent Advances in Applied Thermal Imaging for Industrial Applications*, pages 87–117. IGI Global.
- Duan, H., Lee, P., Ghidaoui, M. S., and Tuck, J. (2014). Transient wave-blockage interaction and extended blockage detection in elastic water pipelines. *Journal of fluids and structures*, 46:2–16.
- Duan, W., Kirby, R., Prisutova, J., and Horoshenkov, K. V. (2015). On the use of power reflection ratio and phase change to determine the geometry of a blockage in a pipe. *Applied Acoustics*, 87:190–197.
- Duan, Y., Liu, S., Hu, C., Hu, J., Zhang, H., Yan, Y., Tao, N., Zhang, C., Maldague, X., Fang, Q., et al. (2019). Automated defect classification in infrared thermography based on a neural network. *NDT & E International*, 107:102147.
- Duran, O., Rodriguez, N., and Consalter, L. A. (2009). Neural networks for cost estimation of shell and tube heat exchangers. *Expert Systems with Applications*, 36(4):7435–7440.
- Ebrahim, M. (2016). *3D laser scanners: History, applications, and future*. LAP LAMBERT Academic Publishing.
- Ebrahim, M. A.-B. (2015). 3d laser scanners' techniques overview. *Int J Sci Res*, 4(10):323–331.

Economics, T. Brazil gdp from agriculture. Accessed: 2019-01-21.

Gade, R. and Moeslund, T. B. (2014). Thermal cameras and applications: a survey. *Machine vision and applications*, 25(1):245–262.

Gade, R., Moeslund, T. B., Nielsen, S. Z., Skov-Petersen, H., Andersen, H. J., Basselbjerg, K., Dam, H. T., Jensen, O. B., Jørgensen, A., Lahrmann, H., et al. (2016). Thermal imaging systems for real-time applications in smart cities. *IJCAT*, 53(4):291–308.

Gan, C., Limsombunchao, V., Clemes, M. D., and Weng, Y. Y. (2005). Consumer choice prediction: Artificial neural networks versus logistic models.

Gardner, M. W. and Dorling, S. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, 32(14-15):2627–2636.

Gaudart, J., Giusiano, B., and Huiart, L. (2004). Comparison of the performance of multi-layer perceptron and linear regression for epidemiological data. *Computational statistics & data analysis*, 44(4):547–570.

Geng, Z. and Bidanda, B. (2017). Review of reverse engineering systems—current state of the art. *Virtual and Physical Prototyping*, 12(2):161–172.

Grosso, M. (2016). *DETECÇÃO DE DEFEITOS EM AÇOS COM REVESTIMENTOS ANTICORROSIVOS ATRAVÉS DA TÉCNICA DE TERMOGRAFIA ALIADA AO EMPREGO DE SIMULAÇÃO COMPUTACIONAL*. PhD thesis, Universidade Federal do Rio de Janeiro.

Haykin, S. (2007). *Redes neurais: princípios e prática*. Bookman Editora.

He, K., Sun, J., and Tang, X. (2012). Guided image filtering. *IEEE transactions on pattern analysis and machine intelligence*, 35(6):1397–1409.

Herráez, J., Martínez, J. C., Coll, E., Martín, M. T., and Rodríguez, J. (2016). 3d modeling by means of videogrammetry and laser scanners for reverse engineering. *Measurement*, 87:216–227.

Ishimwe, R., Abutaleb, K., and Ahmed, F. (2014). Applications of thermal imaging in agriculture—a review. *Advances in remote Sensing*, 3(03):128.

Jain, A. K., Mao, J., and Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3):31–44.

Jones, B. F. (1998). A reappraisal of the use of infrared thermal image analysis in medicine. *IEEE transactions on medical imaging*, 17(6):1019–1027.

- Kao, C.-C., Lai, J.-H., and Chien, S.-Y. (2013). Vlsi architecture design of guided filter for 30 frames/s full-hd video. *IEEE Transactions on circuits and systems for video technology*, 24(3):513–524.
- Kastek, M., Dulski, R., Trzaskawka, P., Sosnowski, T., and Madura, H. (2010). Concept of infrared sensor module for sniper detection system. In *35th International Conference on Infrared, Millimeter, and Terahertz Waves*, pages 1–2. IEEE.
- Kennedy, D. A., Lee, T., and Seely, D. (2009). A comparative review of thermography as a breast cancer screening technique. *Integrative cancer therapies*, 8(1):9–16.
- Khanal, S., Fulton, J., and Shearer, S. (2017). An overview of current and potential applications of thermal remote sensing in precision agriculture. *Computers and Electronics in Agriculture*, 139:22–32.
- Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Lee, M., Lee, S., Kwon, S., and Chin, S. (2017). A study on scan data matching for reverse engineering of pipes in plant construction. *KSCE Journal of Civil Engineering*, 21(6):2027–2036.
- Lee, W.-H., Kim, M. S., Lee, H., Delwiche, S. R., Bae, H., Kim, D.-Y., and Cho, B.-K. (2014). Hyperspectral near-infrared imaging for the detection of physical damages of pear. *Journal of Food Engineering*, 130:1–7.
- Lile, N., Jaafar, M., Roslan, M., and Azmi Muhamad, M. (2012). Blockage detection in circular pipe using vibration analysis. *Int J Adv Sci Eng Inf Technol*, 2(3):54–57.
- Ljungberg, S. A. (1994). Infrared techniques in buildings and structures: Operation and maintenance. *Infrared methodology and technology*, 7:211.
- MacDonald, J., Lockwood, J., McFee, J., Altshuler, T., and Broach, T. (2003). Alternatives for landmine detection. Technical report, RAND CORP SANTA MONICA CA.
- Maldague, X. et al. (2001). Theory and practice of infrared technology for nondestructive testing.
- Maldague, X. P. (2002). Introduction to ndt by active infrared thermography. *Materials Evaluation*, 60(9):1060–1073.
- Massari, C., Yeh, T.-C., Ferrante, M., Brunone, B., and Meniconi, S. (2014). A stochastic tool for determining the presence of partial blockages in viscoelastic pipelines: first experimental results. *Procedia Engineering*, 70:1112–1120.

McCulloch, W. S. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133.

Miserque, O. and Pirard, E. (2004). Segregation of the bulk blend fertilizers. *Chemometrics and intelligent laboratory systems*, 74(1):215–224.

Moreno, A., Velez, G., Ardanza, A., Barandiaran, I., de Infante, Á. R., and Chopitea, R. (2017). Virtualisation process of a sheet metal punching machine within the industry 4.0 vision. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 11(2):365–373.

Mudau, A. E., Willers, C. J., Griffith, D., and le Roux, F. P. (2011). Non-uniformity correction and bad pixel replacement on lwir and mwir images. In *2011 Saudi International Electronics, Communications and Photonics Conference (SIEPCP)*, pages 1–5. IEEE.

O’Mahony, N., Campbell, S., Carvalho, A., Harapanahalli, S., Hernandez, G. V., Krpalkova, L., Riordan, D., and Walsh, J. (2019). Deep learning vs. traditional computer vision. In *Science and Information Conference*, pages 128–144. Springer.

Paliwal, M. and Kumar, U. A. (2009). Neural networks and statistical techniques: A review of applications. *Expert systems with applications*, 36(1):2–17.

Pandey, P. and Barai, S. (1995). Multilayer perceptron in damage detection of bridge structures. *Computers & structures*, 54(4):597–608.

Pang, J., Au, O. C., and Guo, Z. (2011). Improved single image dehazing using guided filter. In *Proc. APSIPA ASC*, pages 1–4.

Paulus, S., Schumann, H., Kuhlmann, H., and Léon, J. (2014). High-precision laser scanning system for capturing 3d plant architecture and analysing growth of cereal plants. *Biosystems Engineering*, 121:1–11.

Pfeifer, N. and Briese, C. (2007). Laser scanning—principles and applications. In *GeoSiberia 2007-International Exhibition and Scientific Congress*. Citeseer.

Planck, M. (1901). On the law of distribution of energy in the normal spectrum. *Annalen der physik*, 4(553):1.

Posada, J., Toro, C., Barandiaran, I., Oyarzun, D., Stricker, D., De Amicis, R., Pinto, E. B., Eisert, P., Döllner, J., and Vallarino, I. (2015). Visual computing as a key enabling technology for industrie 4.0 and industrial internet. *IEEE computer graphics and applications*, 35(2):26–40.

PricewaterhouseCoopers Brasil Ltda (2013). Agribusiness in brazil: an overview. Accessed: 2019-01-21.

- Rajendran, R., Rao, S. P., Agaian, S. S., and Panetta, K. (2016). A versatile edge preserving image enhancement approach for medical images using guided filter. In *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 002341–002346. IEEE.
- Robins, L. (2005). On-line diagnostics techniques in the oil, gas, and chemical industry. In *Proceedings Third Middle East Non-destructive Testing Conference*, pages 27–30.
- Roopaei, M., Rad, P., and Choo, K.-K. R. (2017). Cloud of things in smart agriculture: Intelligent irrigation monitoring by thermal imaging. *IEEE Cloud computing*, 4(1):10–15.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088):533–536.
- Santhi, V. (2017). *Recent advances in applied thermal imaging for industrial applications*. IGI Global.
- Sato, K., Young, C., and Patterson, D. (2017). An in-depth look at google’s first tensor processing unit (tpu). *Google Cloud Big Data and Machine Learning Blog*, 12.
- Siegel, R. (2002). Land mine detection. *IEEE instrumentation & measurement magazine*, 5(4):22–28.
- Silva, W. F. d. (2019). Desenvolvimento de um algoritmo de processamento de dados radiométricos obtidos por termografia ativa pulsada.
- Sola, J. and Sevilla, J. (1997). Importance of input data normalization for the application of neural networks to complex industrial problems. *IEEE Transactions on nuclear science*, 44(3):1464–1468.
- Son, S., Park, H., and Lee, K. H. (2002). Automated laser scanning system for reverse engineering and inspection. *International Journal of Machine Tools and Manufacture*, 42(8):889–897.
- Stork, A. (2015). Visual computing challenges of advanced manufacturing and industrie 4.0 [guest editors’ introduction]. *IEEE computer graphics and applications*, 35(2):21–25.
- Subasi, A. and Ercelebi, E. (2005). Classification of eeg signals using neural network and logistic regression. *Computer methods and programs in biomedicine*, 78(2):87–99.
- Vadivambal, R. and Jayas, D. S. (2011). Applications of thermal imaging in agriculture and food industry—a review. *Food and Bioprocess Technology*, 4(2):186–199.
- Vavilov, V. P. (2014). Modeling thermal ndt problems. *International Journal of Heat and Mass Transfer*, 72:75–86.

Vollmer, M. (2018). *Infrared Thermal Imaging: Fundamentals, Research And Applications*. Wiley-vch.

vs Regulations, V. I. (2007). Fertilizer best management practices.

Wang, X., Lennox, B., Turner, J., Lewis, K., Ding, Z., Short, G., and Dawson, K. (2009). Blockage detection in long lengths of pipeline using a new acoustic method. In *Proceeding of 16th international congress on sound and vibration, ICSV16. Kraków, Poland*, volume 1, pages 140–147.

Wegelin, F. A. (2014). *SISTEMA DE DETECC AO DE VAZAMENTOS EM DUTOS UTILIZANDO FILTRAGEM ADAPTATIVA*. PhD thesis, Universidade Federal do Rio de Janeiro.

Wuhua, C. and Zongchang, Z. (2006). Thermodynamic modeling of wax precipitation in crude oils. *Chinese Journal of Chemical Engineering*, 14(5):685–689.

Yoon, Y., Swales Jr, G., and Margavio, T. M. (1993). A comparison of discriminant analysis versus artificial neural networks. *Journal of the Operational Research Society*, 44(1):51–60.

Zadeh, H. G., Haddadnia, J., Seryasat, O. R., and Isfahani, S. M. M. (2016). Segmenting breast cancerous regions in thermal images using fuzzy active contours. *EXCLI journal*, 15:532.

Zhang, J., Lin, G., Wu, L., and Cheng, Y. (2016). Speckle filtering of medical ultrasonic images using wavelet and guided filter. *Ultrasonics*, 65:177–193.