


UNIVERSIDADE FEDERAL DO PARANÁ

DANIEL VRIESMAN

SISTEMA DE VISÃO COMPUTACIONAL APLICADO À INSPEÇÃO AUTOMÁTICA  
INTERNA DE TUBOS DE PEQUENO DIÂMETRO



CURITIBA

2018

DANIEL VRIESMAN

SISTEMA DE VISÃO COMPUTACIONAL APLICADO À INSPEÇÃO AUTOMÁTICA  
INTERNA DE TUBOS DE PEQUENO DIÂMETRO

Dissertação apresentada ao Curso de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia, da Universidade Federal do Paraná, como requisito parcial à obtenção de título de Mestre em Engenharia Elétrica.

Orientador: Prof<sup>o</sup> Alessandro Zimmer, DEng

Coorientador: Prof<sup>o</sup> Alceu Britto Júnior, DSc

CURITIBA

2018

Catálogo na Fonte: Sistema de Bibliotecas, UFPR  
Biblioteca de Ciência e Tecnologia

V982s

Vriesman, Daniel

Sistema de visão computacional aplicado à inspeção automática interna de tubos de pequeno diâmetro / Daniel Vriesman. – Curitiba, 2018.

Dissertação - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, 2018.

Orientador: Alessandro Zimmer. Coorientador: Alceu Britto Júnior.

1. Processamento de imagens. 2. Tubulação. 3. Visão por computador. I. Universidade Federal do Paraná. II. Zimmer, Alessandro. III. Britto Júnior, Alceu. IV. Título.

CDD: 006.37

Bibliotecária: Vanusa Maciel CRB- 9/1928




MINISTÉRIO DA EDUCAÇÃO  
SETOR TECNOLOGIA  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA  
ELÉTRICA

ATA Nº249

## ATA DE SESSÃO PÚBLICA DE DEFESA DE MESTRADO PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA

No dia vinte e seis de junho de dois mil e dezoito às 09:30 horas, na sala A definir, UFPR-DELT, foram instalados os trabalhos de arguição do mestrando **DANIEL VRIESMAN** para a Defesa Pública de sua Dissertação intitulada **Sistema de Visão Computacional Aplicado à Inspeção Automática Interna de Tubos de Pequeno Diâmetro**. A Banca Examinadora, designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA ELÉTRICA da Universidade Federal do Paraná, foi constituída pelos seguintes Membros: ALESSANDRO ZIMMER (UFPR), ALCEU DE SOUZA BRITTO JR (PUC/PR), CLODOALDO APARECIDO DE MORAES LIMA (USP), EDUARDO PARENTE RIBEIRO (UFPR). Dando início à sessão, a presidência passou a palavra ao discente, para que o mesmo expusesse seu trabalho aos presentes. Em seguida, a presidência passou a palavra a cada um dos Examinadores, para suas respectivas arguições. O aluno respondeu a cada um dos arguidores. A presidência retomou a palavra para suas considerações finais. A Banca Examinadora, então, reuniu-se e, após a discussão de suas avaliações, decidiu-se pela APROVAÇÃO do aluno. O mestrando foi convidado a ingressar novamente na sala, bem como os demais assistentes, após o que a presidência fez a leitura do Parecer da Banca Examinadora. A aprovação no rito de defesa deverá ser homologada pelo Colegiado do programa, mediante o atendimento de todas as indicações e correções solicitadas pela banca dentro dos prazos regimentais do programa. A outorga do título de mestre está condicionada ao atendimento de todos os requisitos e prazos determinados no regimento do Programa de Pós-Graduação. Nada mais havendo a tratar a presidência deu por encerrada a sessão, da qual eu, ALESSANDRO ZIMMER, lavrei a presente ata, que vai assinada por mim e pelos membros da Comissão Examinadora.

Curitiba, 26 de Junho de 2018.

  
ALESSANDRO ZIMMER  
Presidente da Banca Examinadora (UFPR)

  
ALCEU DE SOUZA BRITTO JR  
Coorientador - Avaliador Externo (PUC/PR)

  
CLODOALDO APARECIDO DE MORAES LIMA  
Avaliador Externo (USP)

  
EDUARDO PARENTE RIBEIRO  
Avaliador Interno (UFPR)



MINISTÉRIO DA EDUCAÇÃO  
SETOR TECNOLOGIA  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA  
ELÉTRICA

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **DANIEL VRIESMAN** intitulada: **Sistema de Visão Computacional Aplicado à Inspeção Automática Interna de Tubos de Pequeno Diâmetro**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 26 de Junho de 2018.



ALESSANDRO ZIMMER

Presidente da Banca Examinadora (UFPR)



ALCEU DE SOUZA BRITTO JR

Coorientador - Avaliador Externo (PUC/PR)



CLODOALDO APARECIDO DE MORAES LIMA

Avaliador Externo (USP)



EDUARDO PARENTE RIBEIRO

Avaliador Interno (UFPR)

*"O ponto de partida de Makiguti e Toda era a educação como fonte da mudança do indivíduo e da sociedade, e, por conseguinte, do futuro da humanidade. O que propunham era um novo olhar, um olhar humanista sobre a educação. A ideia de, por meio da educação, desenvolver indivíduos de valor e felizes por toda a existência, livres, mas comprometidos com a dignidade da vida e a justiça, compunham princípios que fluíam avidamente em direção ao profundo humanismo contido nos ensinamentos de Nitiren Daishonin. A educação humana e o budismo são dois aspectos da mesma realidade."*

*(Dr. Daisaku Ikeda)*

## RESUMO

Esta dissertação apresenta os principais aspectos de desenvolvimento de um sistema de aquisição e processamento de imagens que pode ser inserido em sistemas de tubos metálicos de termoelétricas a fim de se capturar imagens da região interna de tais tubos para análise. Após a imagem ser capturada, esta é processada resultando vários segmentos, nos quais são aplicados uma análise de textura e então utilizado um classificador para identificar de maneira automática alguns tipos de corrosão ou defeito. Os testes experimentais feitos com base em um conjunto de 2,615 imagens mostraram que os modelos propostos de classificação podem atingir taxas de acerto entre 90% e 94% ao classificarem um conjunto de imagens para teste, obtidas com um modelo de câmera, factível as dimensões demandadas do projeto, e 100% nas imagens de teste, obtidas com outro modelo de câmera, com dimensões não factíveis ao projeto final. Palavras-chave: Inspeção visual. Textura. Fusão de características. Inspeção automática.

## **ABSTRACT**

This dissertation presents the main aspects of the design of an image acquisition and processing approach that can be inserted into thermoelectric metal pipe systems and travel inside the pipes to capture images from the inner surface of such pipes for further analysis. After the image capture, a texture analysis of its internal surface is carried out to classify automatically segments from the image that present some type of corrosion or defects. The experimental results on a dataset of 2,615 images have shown that proposed classification models can achieve accuracy between 90% and 94% on the test set, using a feasible camera for the project and 100% using another camera model. Keywords: Visual inspection. Texture. Fusion of features. Automatic inspection

## LISTA DE ILUSTRAÇÕES

FIGURA 1 – Representação do conjunto de tubos que conduzem o vapor à turbina . . . . .	13
FIGURA 2 – Aplicação do algoritmo LPQ nos segmentos da imagem processada	20
FIGURA 3 – Conceito da redução de dimensionalidade com base em W utilizando ADL . . . . .	24
FIGURA 4 – Conceito de Máquinas Vetor Suporte com margens flexíveis . . .	26
FIGURA 5 – Conceito da aquisição da situação interna da tubulação vertical com acesso via tubo horizontal . . . . .	28
FIGURA 6 – Visão geral do sistema de inserção e seus principais componentes: módulo de inspeção; guia de condução e sistema de movimentação	29
FIGURA 7 – Simulação do sistema de inspeção em bancada . . . . .	29
FIGURA 8 – Invólucro de encapsulamento para o sistema de aquisição representados em visão frontal (a) e lateral (b) . . . . .	30
FIGURA 9 – Bancada de laboratório para aquisição e realização dos testes . .	31
FIGURA 10 – Conjunto de lentes M12, com indicações conforme Figura 11, e câmera Xima MU9PC-MH . . . . .	31
FIGURA 11 – Imagens adquiridas com as lentes descritas na Tabela 1, utilizando a câmera Ximea MU9PC-MH . . . . .	32
FIGURA 12 – Imagem capturada pelo sistema de aquisição proposto comparada a um olho humano . . . . .	33
FIGURA 13 – Região focada utilizada para o processo de extração de características . . . . .	34
FIGURA 14 – Processamento da imagem utilizando linear-polar (a) e log-polar (b)	35
FIGURA 15 – Região entre os círculos pontilhados (Figura 13) transformada em coordenadas logarítmicas polares e fatiada em segmentos mais estreitos . . . . .	35
FIGURA 16 – Aplicação do algoritmo LPQ nos segmentos da imagem pré-processada	36
FIGURA 17 – Formação do vetor de características com base no algoritmo LPQ	37
FIGURA 18 – Aplicação dos descritores de Haralick em quatro direções . . . .	37
FIGURA 19 – Processo de treinamento de validação dos classificadores . . . .	38
FIGURA 20 – Processo de teste da acurácia do modelo treinado . . . . .	39
FIGURA 21 – Tubos utilizados para imagens de treinamento e validação . . . .	40
FIGURA 22 – Tubos utilizados para imagens de teste . . . . .	41
FIGURA 23 – Imagem da situação interna de tubos sem presença de defeitos .	41

FIGURA 24 – Imagem da situação interna de tubos com a presença de corrosão salina . . . . .	42
FIGURA 25 – Imagem da situação interna de tubos com simulação de pitting por meio de usinagem . . . . .	42
FIGURA 26 – Aquisição de imagem. A imagem dentro do tubo (1296×972 pixels), trecho em foco recortado (100×972 pixels), e imagem final pós fatiamento(5, 7 and 9×972 pixels) . . . . .	44
FIGURA 27 – Aplicação da extração de características utilizando o algoritmo LPQ	45
FIGURA 28 – Aplicação da extração de características utilizando parâmetros de haralick . . . . .	45
FIGURA 29 – Exemplo de imagens pré-processadas da base de teste representando as três classes: (a) sem defeito, (b) corrosão salina, e (c) usinado . . . . .	48
FIGURA 30 – Câmera Mizumi MD-B5014, visão lateral (a) e frontal (b) . . . . .	49
FIGURA 31 – Invólucro para câmera Mizumi, visão lateral (a) e frontal (b) . . . . .	50
FIGURA 32 – Comparação de imagens adquiridas com a câmera ximea (a) e mizumi (b) . . . . .	53

## LISTA DE TABELAS

TABELA 1 – Descrição de parâmetros relevantes das lentes avaliadas . . . . .	32
TABELA 2 – Base de imagens com diferentes espessuras (5,7 e 9 pixels) . . .	43
TABELA 3 – Diferentes configurações de extratores de características avaliados considerando LPQ com diferentes janelas e espessuras de filete; descritores de Haralick com diferentes espessuras de filete; e concatenação de ambos algoritmos . . . . .	46
TABELA 4 – Taxa de acerto utilizando ADL e diferentes configurações de extratores de características com base nos dados de validação . . . .	47
TABELA 5 – Taxa de acerto utilizando SVM e diferentes configurações de extratores de características com base nos dados de validação . . . .	47
TABELA 6 – Número de amostras para teste por classe (Classe 1 : sem defeito, Classe 2: corrosão salina, e Classe 3: usinado) para cada base de imagens e suas respectivas espessuras (EB1, EB2 e EB3)) . . .	47
TABELA 7 – Taxa de acerto usando ADL e diferentes configurações de extração de característica sobre o conjunto de teste . . . . .	48
TABELA 8 – Taxa de acerto usando SVM e diferentes configurações de extração de característica sobre o conjunto de teste . . . . .	49
TABELA 9 – Nova base de imagens com espessura de 7 pixels . . . . .	50
TABELA 10 – Taxa de acerto em relação aos dados de validação utilizando a melhor configuração de extração de característica ( $LPQ_{7,3} + Har_7$ ) e classificador (ADL) . . . . .	50
TABELA 11 – Número de amostras para teste por classe da nova base <b>EB4</b> (Classe 1 : sem defeito, Classe 2: corrosão salina, e Classe 3: usinado) . . . . .	51
TABELA 12 – Taxa de acerto em relação aos dados de teste utilizando a melhor configuração de extração de característica ( $LPQ_{7,3} + Har_7$ ); classificador (ADL); e 100% dos dados de treinamento para gerar o modelo . . . . .	51
TABELA 13 – Média das taxas de classificação de cada classificador conforme a espessura do filete . . . . .	51

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	ESTRUTURA DA DISSERTAÇÃO	16
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>17</b>
2.1	INSPEÇÃO VISUAL	17
2.2	TRABALHOS RELACIONADOS	17
2.2.1	Inspeção Automática em Tubulações	17
2.2.2	Sistema de Inpeção Visual para Tubulações de Pequeno Diâmetro	18
2.3	EXTRATORES DE CARACTERÍSTICAS	18
2.3.1	Local Phase Quantization	19
2.3.2	Parâmetros de Haralick	21
2.4	CLASSIFICADORES	23
2.4.1	Análise Discriminante Linear (ADL)	23
2.4.2	Máquina de Vetores Suporte	25
<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	<b>28</b>
3.1	SISTEMA DE AQUISIÇÃO	28
3.2	DEFINIÇÃO DE LENTES	30
3.3	PROCESSAMENTO DE IMAGENS E CLASSIFICAÇÃO	32
3.3.1	Pré-processamento	33
3.3.2	Extração de Características	36
3.3.2.1	Local Phase Quantization	36
3.3.2.2	Parâmetros de Haralick	37
3.3.3	Classificação	38
3.3.3.1	Treinamento, Validação e Teste	38
<b>4</b>	<b>RESULTADOS</b>	<b>40</b>
4.1	CONSTRUÇÃO DA BASE DE IMAGENS	40
4.2	EXTRAÇÃO DE CARACTERÍSTICAS	44
4.3	EXPERIMENTOS DE CLASSIFICAÇÃO	45
4.4	REPLICAÇÃO DOS TESTES	49
4.5	DISCUSSÃO	51
<b>5</b>	<b>CONCLUSÃO</b>	<b>54</b>
5.1	TRABALHOS FUTUROS	54

**REFERÊNCIAS . . . . . 56**

## 1 INTRODUÇÃO

No final do século 16, o motor a vapor se tornou a fundação da Primeira Revolução Industrial. Desde sua invenção, esta tecnologia foi aplicada em vários ramos da indústria. Dentre estes ramos, encontra-se a geração de energia por meio de turbinas. O vapor gerado por meio de uma caldeira, a qual é alimentada por combustíveis fósseis (como carvão ou óleo), é conduzido até a turbina por meio de tubulações, como por exemplo, o modelo exposto na Figura 1. Estas tubulações são cruciais para uma usina termoelétrica, pois o vapor deve ser transportado de uma maneira eficiente, garantindo segurança e confiabilidade, mantendo o fluxo de vapor a um determinado limite de pressão (OBRUTSKY; RENAUD; LAKHAN, 2009).

FIGURA 1 – Representação do conjunto de tubos que conduzem o vapor à turbina



FONTE: O AUTOR(2018)

Devido as severas condições de operação, como alta temperatura e alta pressão, a matéria que compõe o sistema de condução é sujeito a variados tipos de degradação, como corrosão por pite, perda material volumétrica, corrosão acelerada por fluxo (conhecida como FAC, do inglês *Flow Accelerated Corrosion*) e corrosão sob tensão (OBRUTSKY; LAKHAN; RENAUD, 2007). Uma vez que a degradação chegue em níveis agravantes, tal fato pode ocasionar uma falha nos tubos, levando a uma possível perda de eficiência ou até mesmo um acidente, como uma explosão por

exemplo.

Para evitar tais eventos, uma inspeção regular nas tubulações torna-se necessária. Entretanto, o processo de inspeção pode ser complexo e custoso e demanda atenção em vários aspectos importantes, como: escopo de inspeção, tecnologia da sonda, equipamento de aquisição, software de análise de dados, métodos de análise dos dados e habilidade do inspetor (OBRUTSKY; RENAUD; LAKHAN, 2009). No que diz respeito ao inspetor, o qual é um dos principais componentes no processo de inspeção, o mesmo deve possuir um conhecimento específico em relação aos defeitos analisados e uma qualificação profissional. Tarefas como inspeções visuais, tendem a ser tediosas e difíceis, até para os inspetores mais hábeis e a repetição e longa duração de uma inspeção pode levar o profissional a um estado de fadiga, fazendo com que possa ocorrer falhas durante o processo de detecção e identificação das degradações. Deve-se levar em conta também o fato de que as informações da superfície interna da tubulação seja rapidamente extraída com intuito de diagnosticar a região analisada durante o andamento da inspeção (MALAMAS et al., 2003; NGAN; PANG; YUNG, 2011). Além disso, considerando o equipamento de aquisição, as tecnologias atuais utilizadas para inspecionar este tipo de configuração de tubos (Figura 1), possuem alguns desafios técnicos, como: movimentação da sonda sem nenhum fluido pressurizado; enviar os dados adquiridos durante a inspeção em tempo real; mobilidade nos tubos horizontais e verticais e restrições geradas pela pequena dimensão dos tubos utilizados nos trocadores de calor (3 a 6 polegadas) (DEBENEST; GUARNIERI; HIROSE, 2014). Considerando este contexto, visando auxiliar e melhorar o processo de inspeção visual, o objetivo geral deste trabalho foca no desenvolvimento de um sistema de inspeção, que tenha como escopo a inspeção de modelos de tubulação em forma de flauta (Figura 1). O modelo consiste em um sistema de visão computacional que identifique automaticamente a situação interna dos tubos com base em sua textura, o qual será auxiliado por um sistema de inserção. Sendo assim, a fim de se consolidar o objetivo geral do trabalho proposto, são dados os objetivos específicos, os quais são:

- Desenvolver um módulo de inserção, que permita acesso da câmera nos tubos verticais
- Desenvolver um módulo de aquisição, que possua iluminação ideal e adquira imagens
- Extrair características de textura de imagens, pré-processadas com base na técnica de reconhecimento de íris, por meio dos algoritmos LPQ e Parâmetros de Haralick
- Determinar melhor topologia para os classificadores com base em características extraídas da textura interna da superfície dos tubos

- Comparar o desempenho destas topologias quando treinadas com diferentes combinações de características

Dentre as etapas que constituem um projeto que envolva visão computacional, a etapa de aquisição é fundamental, pois nela define-se a qualidade das imagens que irão influenciar a qualidade das informações a serem extraídas das imagens. Sendo assim, testes foram conduzidos para a escolha da lente que melhor visualize a parte interna da tubulação. Uma vez definida a lente, um invólucro foi desenvolvido, o qual possui um compartimento para encaixe da câmera em conjunto com a sua lente, além de dispor também de um sistema de iluminação composto por LEDs. Este sistema de aquisição possui como finalidade obter uma imagem capaz de captar toda a circunferência da superfície interna da tubulação. A região capturada possui duas regiões distintas, uma focalizada e outra fora de foco. Para extrair as informações de maneira eficiente, parte-se da premissa da similaridade da imagem capturada com um globo ocular. Posto isto, a etapa de pré-processamento inspira-se no processo de reconhecimento de íris, que possui como principal etapa a transformação da imagem do plano cartesiano para polar. Após transformada, a imagem é segmentada, onde cada segmento representa pequenas seções anelares da tubulação. Os segmentos então passam por um processo de extração de características, etapa a qual baseia-se na aplicação de algoritmos de análise de textura, sendo eles: Local Phase Quantization (LPQ) e Parâmetros de Haralick. Após extraídas, as informações são utilizadas como alimentação para dois classificadores, sendo eles, Análise Discriminante Linear (LDA, sigla do inglês Linear Discriminant Analysis) e Máquinas de Vetores Suporte (SVM, sigla do inglês Support Vector Machine), a fim de se gerar um modelo matemático capaz de identificar automaticamente as texturas analisadas.

Para avaliar a capacidade dos modelos, o protocolo de treinamento e validação consiste na utilização de amostras de tubos para treinamento e de amostras de tubos para teste. Dentre os testes observou-se variação da acurácia tanto em relação ao tamanho da imagem quanto as características extraídas. Os resultados demonstraram que imagens de maior espessura, conseguem representar de maneira mais eficiente a textura presente na superfície. Tratando-se dos métodos de extração de características, notou-se que a fusão de informações de ambas as técnicas oferecem uma melhor generalização para imagens desconhecidas. Os modelos apresentados nesta dissertação apresentam faixas de acurácia entre 90% e 94% baseados em imagens obtidas com um modelo de câmera e 100% para modelos treinados com imagens obtidas de outro modelo.

Com resultados promissores, a metodologia do trabalho proposto poderá abrir novas possibilidades em questões de inspeções automáticas em tubulações de pequeno diâmetro, as quais são frequentemente requeridas no ramo da indústria.

## 1.1 ESTRUTURA DA DISSERTAÇÃO

A estrutura da dissertação consiste em cinco capítulos e um apêndice, os quais são:

1. Introdução: afere a contextualização e problemática da qual o trabalho toma como base, como também a motivação e os objetivos a serem cumpridos;
2. Fundamentação Teórica: explana sobre os conceitos utilizados no trabalho e contextualiza sobre o estado da arte de tecnologias similares;
3. Materiais e Métodos: descreve o sistema desenvolvido, abordando tanto as questões mecânicas como computacionais (desenvolvimento do algoritmo para extração de características e treinamento de classificadores)
4. Resultados e Discussão: expõe os resultados obtidos por meio da aplicação da metodologia e a discussão sobre os mesmos;
5. Conclusão: conclui sobre a colaboração do desenvolvimento do trabalho para o mundo acadêmico e sugestões para melhorias e implementações futuras;

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 INSPEÇÃO VISUAL

Dentre os principais componentes para funcionamento de uma usina termoelétrica, encontram-se as caldeiras e seus sistemas de conexão. Ao gerar vapor no sistema de caldeiras, o mesmo é conduzido por meio de tubulações até as turbinas, gerando então energia. Porém a fabricação e construção destes sistemas possui um alto custo, fazendo com que se busque maior investimento em alternativas para estender a vida de funcionamento destes sistemas. Esta extensão está relacionada diretamente a ações como: inspeção de partes aonde ocorrem pressurização; tipo de inspeções a serem feitas; e quantidade e localização destas inspeções. Tratando-se das partes a serem inspecionadas, estas são priorizadas de acordo com seu impacto em relação a fatores como segurança, confiabilidade, e performance da caldeira, dentre eles encontram-se as tubulações, as quais fazem transporte do vapor ao longo do sistema.

Para a avaliação destes sistemas recomenda-se variados tipos de inspeções como: inspeção visual, medição de espessura via ultrassom, medição de espessura via campo magnético. Tratando-se da inspeção visual, esta ao ser executada, é responsável pela captura de imagens as quais são analisadas a fim de se diagnosticar a integridade dos tubos e identificar regiões com erosões e corrosões severas (HOVINGA; NAKONECZNY, 2000).

### 2.2 TRABALHOS RELACIONADOS

Este capítulo aborda o estado da arte do trabalho apresentado, o qual é dividido em duas partes. A primeira parte possui enfoque em sistemas de visão computacional aplicada a inspeção automática de tubulações e outra parte com foco em sistemas de inspeção visual para tubulações de pequeno diâmetro.

#### 2.2.1 Inspeção Automática em Tubulações

Trabalhos na literatura sugerem a aplicação de técnicas de visão aplicadas na área de inspeção de tubulações. (DURAN; ALTHOEFER; SENEVIRATNE, 2003) propõe um sistema de perfil a laser capturado via câmera CCD. Este perfil é utilizado como informação para treinamento de uma Rede Neuro-Fuzzy, tornando-a capaz de classificar falhas presentes em tubos de esgoto com taxas de acerto de até 92%. (S. K. SINHA; P. W. FIEGUTH, 2006) propõe um sistema baseado em imagens pré-segmentadas, extraindo informações como tamanho e formato para treinar um sistema neuro-fuzzy a fim de classificar automaticamente diferentes defeitos, apresentando

modelos com acurácias entre 91 e 96%. Já (S. SINHA; P. FIEGUTH, 2006), descreve uma abordagem utilizando operadores morfológicos para distinguir e classificar defeitos de acordo com as propriedades do elemento estrutural circular, com taxas de 91 a 92%. (HALFAWY; HENGMEECHAI, 2014) utilizou características baseadas na aplicação de Histograma de Gradientes Orientados. As informações extraídas são utilizadas para alimentar o classificador de Máquina de Vetores Suporte, o qual utiliza tanto função linear quanto função de base radial como kernel, apresentando acurácias de 75 e 86% respectivamente. (MYRANS; KAPELAN; EVERSON, 2016) aplicando o algoritmo baseado em Gabor Wavelets como extrator de característica, classifica as informações por meio da técnica de Random Forest, conseguindo separar imagens com uma taxa de acerto de 88%.

### 2.2.2 Sistema de Inpeção Visual para Tubulações de Pequeno Diâmetro

Apesar dos trabalhos citados envolverem sistemas de inspeção visual inteligentes, tanto o material da tubulação quanto o diâmetro não condizem com o contexto abordado por este trabalho. Portanto, vale mencionar trabalhos que abordam sistemas de aquisição para tubos de caldeira, mesmo que estes não apresentem nenhum processamento nas imagens adquiridas.

(SUZUMORI et al., 1999) traz um conceito de um micro-robô para inspeções de tubulações de 1 polegada. O sistema além de garras para segurar objetos, possui uma micro câmera CCD, a qual transmite a imagem para o operador para que este faça a interpretação das informações. Já (DEBENEST; GUARNIERI; HIROSE, 2014), descreve a série Pipetron, que são robôs desenvolvidos para inspeção de tubos de 3 a 6 polegadas, possuindo câmeras e lentes com amplo ângulo de visão.

## 2.3 EXTRATORES DE CARACTERÍSTICAS

Quando uma perda de material ocorre na tubulação devida as condições de operação, a superfície interna da tubulação muda de acordo com o mecanismo de ataque. Por exemplo, efeitos de erosão e corrosão são representadas por sulcos, ranhuras ou buracos arredondados. Outro evento comum é a corrosão acelerada por fluxo (conhecida por FAC) que possui como assinatura uma perda de material com padrão ondulado (KAIN et al., 2011). Como os efeitos de corrosão modificam a aparência da superfície, a abordagem utilizada para extração de características é baseada em análise de textura, uma vez que as falhas são caracterizadas pela mudança da textura da superfície. Considerando o fato de que a variação da superfície pode variar a luminosidade e refletância, descritores de textura robustos se fazem necessários. Para uma análise local, foi implementado o algoritmo Local Phase Quantization, devido a sua capacidade de codificação de pequenos detalhes independente da variação de

luminosidade e/ou de regiões não tão nítidas (OJANSIVU; HEIKKILÄ, 2008). Para uma análise global, foi utilizado os Parâmetros de Haralick, uma vez que as características são extraídas de acordo com a relação das tonalidades de cinza da matriz de co-ocorrência. A análise da textura ocorre por meio da dependência espacial e relações estatísticas das tonalidades de cinza, o que torna este algoritmo robusto e capaz de uma boa generalização (HARALICK; DINSTEIN; SHANMUGAM, 1973).

### 2.3.1 Local Phase Quantization

Dado o ambiente de inspeção, deve-se considerar algumas condições como a variância da iluminação e regiões turvas que acasionalmente apresentem uma falta de foco. Mesmo sobre essas condições, o algoritmo Local Phase Quantization (LPQ) é capaz de extrair informações correspondentes a textura, o que faz com que seja aplicado amplamente para solução de variados problemas de visão como por exemplo, reconhecimento facial e reconhecimento de expressões faciais (YUAN; SUN; LV, 2016; PONTES et al., 2016). O algoritmo se baseia na informação de fase local, a qual é extraída por meio de uma transformada de Fourier de curto termo (STFT, sigla do inglês Short-Term Fourier Transform) aplicada a uma vizinhança  $N_x$ , a qual é formada por um pixel central  $x$  e seus pixels vizinhos presentes em uma janela retangular de  $M \times M$ , ou  $M^2$ , pixels. Logo, tomando como base a imagem  $f(x)$ , para cada pixel  $x$  e seus correspondentes pixels vizinhos, é aplicado então a Equação 1.

$$F(u, x) = \sum_{y \in N_x} f(x - y) e^{-j2\pi u^T y} = w_u^T f_x \quad (1)$$

Onde o vetor  $w_u$  é o vetor base da STFT na frequência  $u$  e  $f_x$  é outro vetor composto por todas as imagens  $M^2$ , que são formadas pelas vizinhanças  $N_x$ . Tratando-se em frequência, o LPQ baseia-se nas frequências correspondentes a duas dimensões, sendo elas,  $u_1 = [a, 0]^T$ ,  $u_2 = [0, a]^T$ ,  $u_3 = [a, a]^T$  e  $u_4 = [a, -a]^T$ , onde  $a$  é uma frequência escalar utilizada para auxiliar o cálculo da transformada em regiões turvas ou fora de foco (OJANSIVU; HEIKKILÄ, 2008). Sendo assim, cada coeficiente é calculado conforme a Equação 2 e 3.

$$F_x^c = [F(u_1, x), F(u_2, x), F(u_3, x), F(u_4, x)] \quad (2)$$

$$F_x = [Re \{F_x^c\}, Im \{F_x^c\}]^T \quad (3)$$

Onde  $Re \{.\}$  e  $Im \{.\}$  retornam respectivamente as partes reais e imaginárias dos números complexos de cada coeficiente calculado para cada janela  $M^2$ , conforme

a Equação 4.

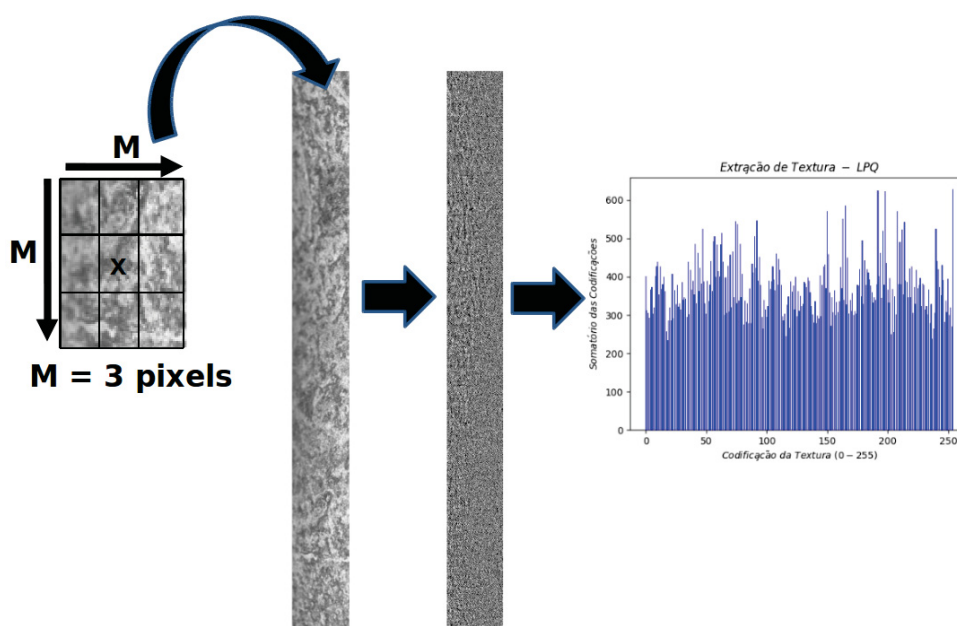
$$W = [Re \{w_{u_1}, w_{u_2}, w_{u_3}, w_{u_4}\}, Im \{w_{u_1}, w_{u_2}, w_{u_3}, w_{u_4}\}]^T \quad (4)$$

Logo, para cada pixel  $x$  e sua respectiva  $M^2$  é retornado um vetor  $W$ , o qual é quantizado com base na Equação 5, a fim de se discretizar os valores para 0 e 1, formando então um código binário de 8-bits, o qual irá variar de acordo com a textura contida no espaço analisado. No domínio de 8 valores binários, este pode ser representado no domínio dos números decimais por valores que variam entre 0 e 255, sendo então os códigos convertidos para seus respectivos valores decimais.

$$f_{LPQ}(x) = \sum_{j=1}^8 q_j(x) 2^{j-1} \quad (5)$$

Depois de toda a imagem  $f(x)$  ser analisada, é alocado um vetor de 256 posições, onde para cada posição do vetor é associada o código gerado pelo LPQ e a frequência que o mesmo se apresenta ao longo da imagem. O processo de aplicação do algoritmo pode ser observado graficamente na Figura 2, na qual a imagem em escala de cinza, após a aplicação do algoritmo LPQ, recebe novos valores para cada pixel (entre 0 e 255), de acordo com a textura analisada. Ao final obtém-se então o gráfico relacionado a quantização dos códigos binários no vetor de 256 posições.

FIGURA 2 – Aplicação do algoritmo LPQ nos segmentos da imagem processada



FONTE: AUTOR(2018)

### 2.3.2 Parâmetros de Haralick

Outro descritor de textura robusto foi proposto por Haralick, o qual extrai a textura presente em uma imagem baseada nas dependências espaciais das tonalidades de cinza. Com base na matriz de co-ocorrência, são calculados 13 parâmetros relacionados às características da textura. Estas são: segundo momento angular, contraste, correlação, variância, homogeneidade, soma das médias, soma da variância, soma da entropia, entropia, diferença de variância, diferença de entropia, informação da medida de correlação 1 e 2 (SUBBAN; DATTATREYA, 2017; CAVALIN et al., 2006; COSTA et al., 2012).

Para cálculo destes parâmetros, deve-se primeiramente calcular a matriz de co-ocorrência em níveis de cinza ( $MC$ ) com dimensões iguais ao número de níveis de cinza  $L$  na imagem  $I$ . Cada elemento  $p(i, j)$  de  $MC$  representa a probabilidade que o pixel de valor  $i$  será encontrado na adjacência do pixel de valor  $j$ , onde  $i = 0 \dots L$  e  $j = 0 \dots L$ .

$$MC = \begin{bmatrix} p(1, 1) & p(1, 2) & \dots & p(1, L) \\ p(2, 1) & p(2, 2) & \dots & p(2, L) \\ \vdots & \vdots & \ddots & \vdots \\ p(L, 1) & p(L, 2) & \dots & p(L, L) \end{bmatrix} \quad (6)$$

Dada a matriz  $MC$ , os Parâmetros de Haralick são calculados conforme as equações:

$$f_1 = \sum_{i=1}^L \sum_{j=1}^L p(i, j)^2 \quad (7)$$

$$f_2 = \sum_{i=0}^{L-1} k^2 \sum_{i=1}^L \sum_{j=1}^L p(i, j) \quad (8)$$

onde,  $k = |i - j|$ .

$$f_3 = \frac{\sum_{i=1}^L \sum_{j=1}^L (ij)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (9)$$

onde  $\mu_x$ ,  $\mu_y$ ,  $\sigma_x$ , e  $\sigma_y$  são médias e desvios padrões de  $p_x$  e  $p_y$ , que são funções de densidade de probabilidade parcial.

$$f_4 = \sum_{i=1}^L \sum_{j=1}^L (i - \mu)^2 p(i, j) \quad (10)$$

$$f_5 = \sum_{i=1}^L \sum_{j=1}^L \frac{1}{1 + (i-j)^2} p(i, j) \quad (11)$$

$$f_6 = \sum_{i=2}^{2L} i p_{x+y}(i) \quad (12)$$

onde  $x$  e  $y$  são coordenadas (linha e coluna) de uma entrada na matriz de co-ocorrência, e  $p_{x+y}(i)$  é a probabilidade das coordenadas da matriz de co-ocorrência somadas a  $x + y$ .

$$f_7 = \sum_{i=2}^{2L} (i - f_8)^2 p_{x+y}(i) \quad (13)$$

$$f_8 = - \sum_{i=2}^{2L} p_{x+y}(i) \log p_{x+y}(i) \quad (14)$$

$$f_9 = - \sum_{i=1}^L \sum_{j=1}^L p(i, j) \log p(i, j) \quad (15)$$

$$f_{10} = \sum_{i=0}^{L-1} i^2 p_{x-y}(i) \quad (16)$$

$$f_{11} = - \sum_{i=0}^{L-1} p_{x-y}(i) \log p_{x-y}(i) \quad (17)$$

$$f_{12} = \frac{f_9 - \left( - \sum_{i=1}^L \sum_{j=1}^L p(i, j) \log p_x(i) p_y(j) \right)}{\max \left\{ - \sum_{i=1}^L p_x(i) \log p_x(i), - \sum_{j=1}^L p_y(j) \log p_y(j) \right\}} \quad (18)$$

$$f_{13} = \left[ 1 - e^{-2\left(-\sum_{i=1}^L \sum_{j=1}^L p_x(i)p_y(j) \log p_x(i)p_y(j) - f_9\right)} \right]^{\frac{1}{2}} \quad (19)$$

Estas medidas ( $f_1$  to  $f_{13}$ ) podem ser calculadas em diferentes direções angulares na matriz de co-corrência, o que resulta em vários valores para cada equação descrita.

## 2.4 CLASSIFICADORES

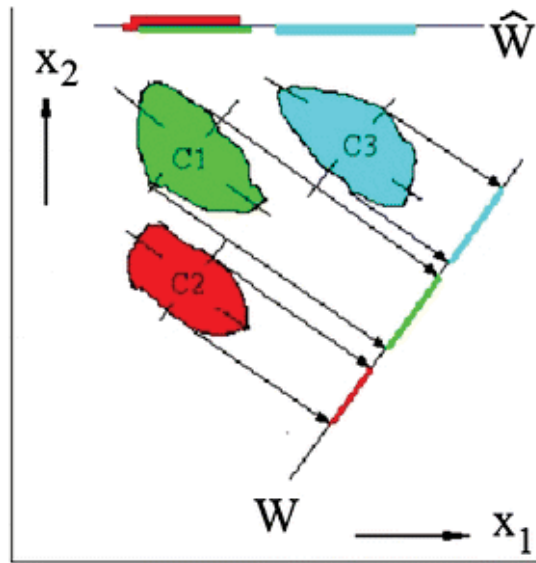
Classificadores são algoritmos que, com base em modelos matemáticos, se adequem a um determinado conjunto de dados, de maneira que ao receber uma nova entrada, ofereça em sua saída a classificação da mesma com base no conhecimento adquirido. Neste trabalho são abordados dois classificadores diferentes, sendo eles: Análise Discriminante Linear e Support Vector Machine.

### 2.4.1 Análise Discriminante Linear (ADL)

A técnica ADL consiste em um método de redução de dimensionalidade por meio da remoção de características correlacionadas ou redundantes. Tal redução faz com que ocorra a transformação do vetor de características de um espaço de maior dimensão para um espaço de menor dimensão, implicando na maximização da razão entre a variância entre classes pela variância intra classes, garantindo assim uma separabilidade das classes que compõe o problema. A redução da dimensionalidade acontece por meio da reprojeção dos dados dada uma orientação  $\mathbf{W}$ . Como pode-se observar na Figura 3, as três classes (C1, C2 e C3) são reprojadas de um espaço de maior para um espaço bidimensional, definidos por  $\hat{\mathbf{W}}$ , com o qual não é possível separar de maneira eficiente as classes C1 e C2 e  $\mathbf{W}$ , a qual é possível separar perfeitamente as classes (SHARMA; PALIWAL, 2015).

Para a estimativa de um  $W$  ideal, utiliza-se o critério de Fisher  $J(W)$ , o qual baseia-se em na orientação  $\mathbf{W}$ , de dimensões  $d \times h$  (onde  $d$  é valor da dimensão original dos dados e  $h$  o valor da dimensão reduzida) e nas matrizes  $S_W$  (dispersão intra-classe) e  $S_B$  (dispersão entre classes). Supondo um conjunto de dados  $X$  e seu respectivo centróide  $\mu$ , temos que este  $X$  é formado por subconjuntos  $X_j$ , onde  $j$  é o número de classes que compõe os dados. Cada subconjunto  $X_j$ , possui seu respectivo centróide

FIGURA 3 – Conceito da redução de dimensionalidade com base em W utilizando ADL



FONTE: (SHARMA; PALIWAL, 2015)

$(\mu_j)$ . Sendo assim, pode-se definir as matrizes de dispersão conforme as Equações 20, 21 e 22.

$$S_T = \sum_{x \in \mathbf{X}} (x - \mu)(x - \mu)^T \quad (20)$$

$$S_W = \sum_{j=1}^c \sum_{x \in X_j} (x - \mu_j)(x - \mu_j)^T \quad (21)$$

$$S_B = \sum_{j=1}^c n_j (\mu_j - \mu)(\mu_j - \mu)^T \quad (22)$$

Obtendo as matrizes de dispersão, pode-se definir o critério de Fisher em função da orientação  $W$  utilizando a Equação

$$J(W) = \frac{|W^T S_B W|}{|W^T S_W W|} \quad (23)$$

Já a orientação em  $W$ , dá-se pela solução do problema de autovalor exposto na Equação 24.

$$S_W^{-1} S_B w_i = \lambda_i w_i \quad (24)$$

onde  $w_i$  são as colunas de vetores de  $W$  que correspondem aos maiores autovalores ( $\lambda_i$ ). Uma vez que os dados são transformados para um outro espaço, define-se então uma função de decisão com melhores fronteiras para classificação de novas entradas.

### 2.4.2 Máquina de Vetores Suporte

O algoritmo Máquina de Vetores Suporte (do inglês, Support Vector Machine, SVM) é um classificador amplamente utilizado, primeira vez exposto ao final da década de 70 por Vladimir Vapnik. O algoritmo consiste no mapeamento não linear dos vetores de entrada para um espaço de maior dimensão. Neste novo espaço então é projetado um hiperplano linear o qual faz a separação dos dados por meio de suas margens. Estas as quais, com o auxílio de alguns dados de treinamento, conhecidos por vetores suporte, são calculadas a fim de definir uma distância máxima entre as classes, garantindo assim então, juntamente com outras propriedades, uma boa generalização do modelo treinado, quando este classifica novos dados. (CORTES; VAPNIK, 1995). Supondo que dados representantes de duas classes, definidos como,  $(y_1, x_1) \dots, (y_i, x_i)$ , onde  $y_i \in \{-1, 1\}$  e  $x_i$  representa o vetor de entradas, são mapeados para um plano de maior dimensionalidade dado um *kernel*  $\phi$ , projeta-se um hiperplano e suas margens, partindo da premissa que a formulação das mesmas, consiste em um vetor  $w$  e um escalar  $b$ , os quais satisfazem as desigualdades representadas na Equação 25. As delimitações de tais equações são determinadas pelos vetores suporte, ou seja, o limite máximo de fronteira da classe correspondente. Já os dados utilizados como vetor suporte, são aqueles que satisfazem as igualdades representadas na Equação 26. Situando-se entre os vetores suporte, encontra-se o hiperplano ótimo, o qual satisfaz a Equação 27, como demonstra a Figura 4.

$$w \cdot x_i + b \geq 1 \text{ se } y_i = 1, \text{ e } w \cdot x_i + b \leq -1 \text{ se } y_i = -1 \quad (25)$$

$$w \cdot x_i + b = 1 \text{ para } y_i = 1, \text{ e } w \cdot x_i + b = -1 \text{ para } y_i = -1 \quad (26)$$

$$w_0 \cdot x + b_0 = 0 \quad (27)$$

Porém ao projetar as margens desta maneira, diz-se que o modelo possui margens rígidas, ou seja, faz com que a presença de erros, entre a área das margens, impeça o modelo de convergir durante o seu aprendizado. Sendo assim, para adicionar uma flexibilidade para a resolução do problema, para que o modelo faça seu aprendizado com um erro mínimo, é adicionado então variáveis não negativas, como  $\xi_i, i = 0, \dots, l$  (onde  $l$  é a quantidade de dados de treinamento), como mostra a Equação 28, e representado graficamente na Figura 4.

$$\Phi(\xi) = \sum_{i=1}^l \xi_i^\sigma \quad (28)$$

Onde para um pequeno valor de  $\sigma > 0$ , sujeito as restrições representadas nas Equações 29 a 31.

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad i=1, \dots, l, \quad (29)$$

$$y_i(w \cdot x_i + b) \leq 1 + \xi_i, \quad i=1, \dots, l, \quad (30)$$


$$\xi_i \geq 0, \quad i=1, \dots, l, \quad (31)$$

Logo, estimando um  $\sigma$  suficientemente pequeno, a Equação 28 auxilia na geração de um subconjunto mínimo de erros, os quais se excluídos, fazem com que o modelo se torne capaz de separar o restante dos dados de treinamento sem erro. Este conceito pode ser aplicado na formulação do hiperplano ótimo por meio da minimização da Equação 32, a qual é sujeita as restrições das Equações 29 e 30 e multiplicada por uma constante  $C$ .

$$\frac{1}{2} \mathbf{w}^2 + C \cdot F \left( \sum_{i=1}^N \xi_i \right) \quad (32)$$

A constante  $C$  possui grande importância no aprendizado do modelo, uma vez que esta implica diretamente na flexibilidade das margens projetadas com base no erro. Esta, possuindo um valor grande o suficiente, ao mesmo tempo que  $\sigma$  possua um valor pequeno, possibilita a minimização do número de erros do hiperplano durante a etapa de treinamento, separando o restante dos dados com uma distância máxima.

FIGURA 4 – Conceito de Máquinas Vetor Suporte com margens flexíveis




FONTE: (LEE et al., 2013)

Porém a resolução do algoritmo de Máquinas de Vetor Suporte consiste em uma resolução binária, ou seja, para duas classes. Sendo assim a fim de se estender a funcionalidade para problemas multi classes, diferentes abordagens foram desenvolvidas, como por exemplo um contra todos e um contra um. Tratando-se da abordagem um contra todos, o método consiste na geração de  $k$  modelos, onde  $k$  é o número de classes. Cada modelo gerado é treinado com os dados da classe correspondente, os quais são rotulados como positivo e o restante dos dados não pertencentes aquela classe como negativo. Ao final, ao classificar um novo dado, o mesmo é classificado de acordo com o modelo que apresentar o maior valor de sua função de decisão (HSU; LIN, 2002).

### 3 MATERIAIS E MÉTODOS

Este capítulo aborda a metodologia proposta e equipamentos utilizados, contendo o desenvolvimento dos conceitos do sistema de aquisição e de inserção. O desenvolvimento dos conceitos foram baseados em um dos desafios do escopo abordado, que consiste na captura da situação interna dos tubos verticais, os quais são acessados por meio do tubo horizontal (Figura 5). Este tipo de estrutura em modelo de flauta, requer um sistema que percorra o tubo horizontal ( $\phi$  3 polegadas), e insira o módulo de aquisição nos verticais ( $\phi$  2 polegadas).

FIGURA 5 – Conceito da aquisição da situação interna da tubulação vertical com acesso via tubo horizontal




FONTE: O AUTOR (2018)

#### 3.1 SISTEMA DE AQUISIÇÃO

Para que fosse possível o acesso do sistema de aquisição nas regiões de interesse, foi desenvolvido um sistema para transporte e inserção do mesmo, conforme o conceito geral exposto na Figura 6. Após o sistema ser inserido em uma abertura lateral do tubo horizontal, o mesmo percorre ao longo da tubulação, e ao se posicionar na entrada dos tubos verticais, o módulo de aquisição é impulsionado pela guia. A guia de condução do sistema de aquisição consiste em um conduíte de 5 mm, que apesar de certa rigidez, possui a capacidade de se deformar elasticamente. Esta capacidade de deformação permite que, por meio de um conjunto de rolamentos presente na


estrutura de transporte, mantenha o módulo de aquisição na posição vertical. Quando o módulo de inspeção se posiciona na entrada dos tubos verticais, a guia de condução é empurrada, externamente ao tubo horizontal. Dada a rigidez da guia e o sistema de rolamentos, o módulo de aquisição é impulsionado verticalmente possibilitando então o início do processo de inspeção. O processo pode ser observado na Figura 7, representando o sistema em funcionamento em bancada.

FIGURA 6 – Visão geral do sistema de inserção e seus principais componentes: módulo de inspeção; guia de condução e sistema de movimentação



FONTE: O AUTOR (2018)


FIGURA 7 – Simulação do sistema de inspeção em bancada



FONTE: AUTOR (2018)

Referindo-se ao módulo de inspeção, devido as restrições de diâmetro da tubulação a ser inspecionada, uma câmera pequena se faz necessária. A câmera utilizada para o sistema de aquisição é da fabricante alemã Ximea de modelo MU9PC-MH, a qual possui dimensões de 15x15x8mm e um sensor CMOS de 1/2.5 polegadas, oferecendo uma resolução de 5 Megapixels. Com intuito de guiar a câmera durante a inspeção com um bom encapsulamento para proteção, centralização e iluminação, um invólucro foi desenvolvido (Figura 8(a) e (b)). Prototipado por meio de uma impressora 3D, além de comportar a câmera montada com sua lente, o invólucro possui também um sistema de iluminação (Figura 8(b)). O sistema de iluminação em formato anelar, possui diâmetro interno de 15.5mm e externo de 22mm. Este anel dispõe de 26 LEDs SMD (0805) e 52 resistores SMD (0201). Para cada LED, são soldados em série dois resistores em paralelo. A tensão de funcionamento do sistema varia de 2.5V a 5.0V, variando a corrente consumida e conseqüentemente o brilho emitido pelo sistema.

FIGURA 8 – Invólucro de encapsulamento para o sistema de aquisição representados em visão frontal (a) e lateral (b)



FONTE: O AUTOR (2018)

### 3.2 DEFINIÇÃO DE LENTES

A lente possui uma grande importância quando se trata de aquisição de imagens, pois influencia diretamente na qualidade da imagem obtida. A fim de se testar as lentes de uma maneira confiável, foi utilizada uma bancada de laboratório (Figura 9).

Com um suporte para a câmera, esta é posicionada sobre o tubo. Possuindo um grau de liberdade, a estrutura permite um ajuste fino da distância entre a câmera e


FIGURA 9 – Bancada de laboratório para aquisição e realização dos testes



FONTE: O AUTOR (2018)

o tubo. Uma vez que o foco é ajustado, é possível observar as propriedades de cada lente quando estas observam a área interna da tubulação de uma mesma distância. O conjunto de lentes do tipo M12, mostradas da Figura 10, foram utilizadas juntamente com a câmera Ximea. Alguns parâmetros foram considerados a fim de se definir a melhor lente, sendo eles: campo de visão; profundidade de campo e região de foco. Quanto maior a profundidade de campo e mais amplo o campo de visão, melhor é a lente para esta solução, visto que a região focada será maior e mais próxima da câmera.

FIGURA 10 – Conjunto de lentes M12, com indicações conforme Figura 11, e câmera Xima MU9PC-MH




FONTE: O AUTOR (2018)

Algumas das lentes utilizadas são descritas na Tabela 1, com seus respectivos parâmetros como Distância Focal (FD), Campo de Visão (CV) e Abertura (F).

TABELA 1 – Descrição de parâmetros relevantes das lentes avaliadas

Lens	FD (mm)	CV(°)	F
A	12,5	38,8	4
B	17,5	27,8	2,5
C	12,5	38,8	5,6
D	3,6	75	1,8

FIGURA 11 – Imagens adquiridas com as lentes descritas na Tabela 1, utilizando a câmera Ximea MU9PC-MH



FONTE: O AUTOR (2018)


### 3.3 PROCESSAMENTO DE IMAGENS E CLASSIFICAÇÃO

Neste capítulo serão descritos o processo de extração de características com base na textura das imagens pré-processadas e o processo de aprendizado e classificação com base nas informações extraídas.

### 3.3.1 Pré-processamento

Como sugere a Figura 12, a imagem capturada pelo sistema de aquisição é similar a um olho humano. Se ao considerar o centro do tubo como a pupila, a superfície da tubulação próxima a câmera, ao redor do centro, deve corresponder a íris, a qual varia sua textura de acordo com a situação interna do tubo. Baseando-se em tal similaridade, a metodologia proposta para o pré-processamento das imagens adquiridas é inspirada no processo de reconhecimento de íris. O núcleo deste algoritmo consiste na transformação da imagem em suas coordenadas cartesianas para coordenadas polares. Segundo (DAUGMAN, 2003) e (HUANG; LUO; CHEN, 2002), convertendo uma imagem de seu plano cartesiano para polar, baseado em um centro de referência (pólo), faz com que o processo de reconhecimento de padrões ao longo da imagem se torne mais robusto. Tal processo faz com que as características relacionadas a textura se tornem invariantes a mudança de tamanho, posição e orientação, aumentando então a eficiência no processo de extração de características.

FIGURA 12 – Imagem capturada pelo sistema de aquisição proposto comparada a um olho humano



FONTE: O AUTOR (2018)


Uma das tarefas antes do processo de transformação polar é a localização da pupila e seu centro. Neste caso, devido ao encapsulamento da câmera fazer com que o sistema fique aproximadamente centralizado ao tubo, a etapa de localização do centro não se faz necessária. Sendo assim, adota-se como ponto central o centro da imagem adquirida  $(i_c, j_c)$ . Uma vez que o centro é determinado, é aplicada uma transformação logarítmica, conforme as Equações 33 e 34, onde o valor do pixel analisado da imagem referência  $(I(i, j))$  é transferido para a imagem de destino  $(I'(\rho, \theta))$  em uma coordenada diferente.

$$\rho = \log\sqrt{(i - i_c)^2 + (j - j_c)^2} \quad (33)$$

$$\theta = \tan^{-1} \frac{j - j_c}{i - i_c} \quad (34)$$

Sendo assim, considerando a imagem como um todo, haverá a presença de dois tipos de regiões que variam de acordo com a lente utilizada, sendo elas: a região em foco (região entre o pontilhado vermelho na Figura 13), formada mais ao centro da imagem, e a região fora de foco, sendo a região mais periférica da imagem devido sua proximidade com a câmera (região fora da área entre o pontilhado vermelho na Figura 13).

FIGURA 13 – Região focada utilizada para o processo de extração de características




FONTE: O AUTOR (2018)

Posto isto, ao aplicar o processo utilizando a função logarítmica, é possível conservar a resolução da região focal da lente durante o processo de transformação polar preservando a resolução da região central da imagem, conforme a Figura 14, a qual compara o processo de transformação polar de maneira linear e logarítmica.

Devido a região de foco representar as características presentes na imagem de melhor forma, o processo de extração de características é aplicado somente sobre esta área. Desta forma, a imagem depois de processada é recortada de acordo com a região de interesse. A espessura desta região irá variar de acordo com a lente, logo a região recortada é definida manualmente uma vez durante o processo de calibragem. Com objetivo de analisar o segmento recortado, de uma maneira detalhada, o mesmo é fatiado em várias fatias mais estreitas (Figura 15), as quais correspondem a seções


FIGURA 14 – Processamento da imagem utilizando linear-polar (a) e log-polar (b)



FONTE: O AUTOR (2018)

anelares abertas da tubulação. Portanto, para cada segmento é aplicado o processo de extração de características.

FIGURA 15 – Região entre os círculos pontilhados (Figura 13) transformada em coordenadas logarítmicas polares e fatiada em segmentos mais estreitos



FONTE: O AUTOR (2018)


### 3.3.2 Extração de Características

Uma vez que as imagens são pré-processadas e segmentadas em filetes menores, aplica-se então nestes filetes os extratores de características baseados em textura, sendo eles: Local Phase Quantization e Parâmetros de Haralick.

#### 3.3.2.1 Local Phase Quantization

Conforme o funcionamento exposto no Capítulo 2.3.1, a fim de se aplicar as funções de Transformada de Fourier de Curto Termo (TFCT) e identificação dos sinais dos valores reais e imaginários, foi utilizado a linguagem Python juntamente com as bibliotecas matemáticas Numpy e Scypi. Os segmentos oriundos das imagens pré-processadas são dados como entrada na função, já em escala de cinza. Ao definir o tamanho da janela em pixels (para análise dos pixels vizinhos), é aplicado então a transformada de Fourier, com base nos quatro coeficientes, e então feita a codificação daquela região com base nos sinais dos valores das funções (Figura 16).

FIGURA 16 – Aplicação do algoritmo LPQ nos segmentos da imagem pré-processada



FONTE: O AUTOR (2018)

Ao fazer a codificação de toda a imagem é retornado então um vetor de 256 posições, onde cada posição, correspondente ao seu respectivo código binário, contém a informação da quantização daquele valor ao longo da imagem (Figura 17).

FIGURA 17 – Formação do vetor de características com base no algoritmo LPQ




FONTE: O AUTOR(2018)

### 3.3.2.2 Parâmetros de Haralick

A fim de se extrair os descritores de Haralick, com base das formulações apresentadas no Capítulo 2.3.2, foi utilizado a biblioteca Mahotas (COELHO, 2012) para a linguagem Python. O filete recortado da imagem pré-processada, em escala de cinza, é dado como entrada na função, onde é calculado a matriz de co-ocorrência e então aplicado o cálculo dos descritores em quatro diferentes direções ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ), como mostra o exemplo da Figura 18.

FIGURA 18 – Aplicação dos descritores de Haralick em quatro direções



FONTE: O AUTOR (2018)

Terminado os cálculos, ao final da execução, a função retorna um vetor de 52 posições, correspondente a concatenação dos 13 valores calculados para cada uma das quatro direções.

### 3.3.3 Classificação

Uma vez que as características são extraídas das imagens, estas são utilizadas para alimentar um classificador, a fim de que se gere um modelo capaz de associar automaticamente as características de uma imagem desconhecida uma das classes. Para definir qual técnica apresenta um melhor comportamento para classificação dos dados, foram conduzidos experimentos preliminares utilizando a base de imagens EB1 (Tabela 2) e aplicando o algoritmo LPQ, com uma janela de 5x5 pixels, como extrator de característica. Diferentes classificadores foram testados com base no processo de treinamento e validação descritos no Capítulo 3.3.3.1. Os experimentos abordaram testes com classificadores como rede neurais artificiais, máquina de vetores suporte (com diferentes *kernels*), análise discriminante linear e florestas randômicas.

#### 3.3.3.1 Treinamento, Validação e Teste

Para o ajuste de melhores parâmetros dos classificadores escolhidos, foram utilizadas duas bases de imagens, sendo uma delas utilizada para treinamento e validação, e outra para teste do modelo treinado. Para cada conjunto de parâmetros de configuração dos classificadores, utilizou-se a base de treinamento e validação, a qual 70% dos dados eram destinados a treinamento e 30% dos dados destinados para validação do modelo treinado. Para cada configuração dos classificadores, este processo foi aplicado 10 vezes consecutivas, onde para cada vez a base era embaralhada randomicamente, fazendo com que os conjuntos de treinamento e validação fossem diferentes a cada iteração. Ao final das 10 iterações é feita então a média da acurácia do classificador em relação ao conjunto de validação (Figura 19).

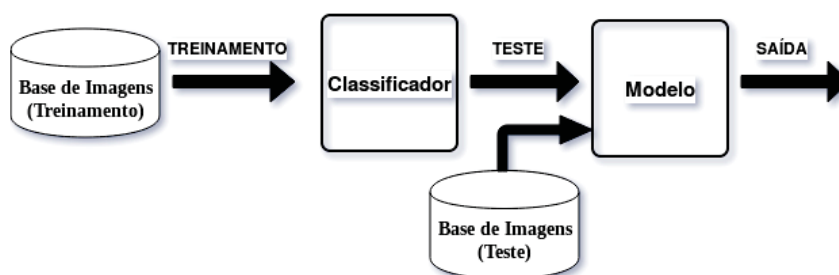
FIGURA 19 – Processo de treinamento de validação dos classificadores



FONTE: O AUTOR (2018)

Após a definição dos melhores parâmetros com base nas melhores médias, o classificador então é treinado utilizando 100% das imagens da base de treinamento gerando um modelo com os pesos ajustados. A fim de se avaliar a acurácia e capacidade de generalização para dados desconhecidos é fornecido como entrada para o modelo as imagens de teste, as quais são desconhecidas pelo algoritmo, sendo possível então observar a capacidade de assimilação de dados desconhecidos com as classes conhecidas.

FIGURA 20 – Processo de teste da acurácia do modelo treinado



FONTE: O AUTOR (2018)


## 4 RESULTADOS

Os testes foram executados em um computador de ambiente Linux (Ubuntu 16.04.3 LTS - 64bits) com 8GB de memória RAM e processador da família Intel i7-7700 3.60 GHz em ambiente de programação Python 2.7.

### 4.1 CONSTRUÇÃO DA BASE DE IMAGENS

Normalmente durante manutenções em termoeletricas, nas quais ocorrem trocas de trechos de tubulações danificadas, os tubos são descartados, dificultando a obtenção de amostras reais e seus respectivos defeitos. Sendo assim, com intuito de validar a metodologia proposta, as amostras de trechos de tubulações foram geradas em laboratório. Ao total seis tubos de 2 polegadas foram utilizados para aplicação do protocolo experimental, sendo três deles para obtenção de imagens para treinamento e validação do classificador (Figura 21) e outros três para obtenção de imagens para teste do modelo treinado (Figura 22).

FIGURA 21 – Tubos utilizados para imagens de treinamento e validação



FONTE: O AUTOR (2018)

Estes tubos apresentam diferentes condições internas de superfície, as quais são distribuídas da seguinte forma: dois tubos não defeituosos (Figura 23), dois tubos


FIGURA 22 – Tubos utilizados para imagens de teste



FONTE: O AUTOR (2018)


representando uma situação de corrosão utilizando sal (Figura 24) e os outros dois tubos representando a condição de pitting ou FAC, por meio de usinagem (Figura 25). Sendo assim, há dois tubos para representação de cada classe, sendo um destinado para imagens com finalidade de treinar o modelo e outro para teste, gerando duas bases de imagens distintas.

FIGURA 23 – Imagem da situação interna de tubos sem presença de defeitos




FONTE: O AUTOR (2018)

FIGURA 24 – Imagem da situação interna de tubos com a presença de corrosão salina



FONTE: O AUTOR (2018)

FIGURA 25 – Imagem da situação interna de tubos com simulação de pitting por meio de usinagem



FONTE: O AUTOR (2018)

Dentre as lentes avaliadas neste trabalho, a Lente 1 (Tabela 1) demonstrou-se ideal para utilização em conjunto com a câmera, pois esta apresentou uma maior área focalizada quando comparada com as outras lentes, fazendo-se possível a aquisição de um banco de imagens. Tratando-se do sistema de iluminação, este foi alimentado com uma tensão de 3,3 Volts resultando na emissão de aproximadamente 2600 lux. A resolução utilizada para captura das imagens foi de 1296x972 pixels e a área focalizada presente na mesma, possui uma profundidade, em medidas reais, de aproximadamente 20mm. Definido os parâmetros para aquisição, visto que na etapa da construção do banco de imagens o conceito de inserção vertical não estava pronto, para que pudesse ser feita a aquisição das imagens dos tubos, estes foram posicionados horizontalmente sobre uma bancada. Uma vez posicionados, o módulo de aquisição foi posto dentro

de cada tubo e então movimentado em passos de 20mm, onde a cada passo uma imagem era adquirida. A captura foi feita desta maneira a fim de se analisar diferentes imagens da região interna da superfície sem que haja a sobreposição e análise com base em uma mesma área. Para a construção do banco de imagens para amostras de treinamento e validação (Tabela 2), aonde os tubos possuíam o comprimento de aproximadamente 260-300mm, foram adquiridas 13 imagens para cada tipo de situação interna, resultando no total de 39 imagens. Visto que cada situação interna representará uma classe, a quantidade de 13 imagens foi definida com base no tubo de menor comprimento, para que ao final cada classe fosse representada pela mesma quantidade de imagens. Já para a aquisição de imagens dos tubos destinados a teste, os quais possuem um comprimento variando entre aproximadamente 120-140mm, foram adquiridas entre 6 e 7 imagens para cada classe, resultando ao total de 19 imagens, as quais foram destinadas para a geração das amostras de teste (Tabela 2).


Adquirido o conjunto de imagens de cada tubo, o processo de transformação polar foi aplicado sobre as mesmas. Para a extração somente da região de maior nitidez após o processamento, foi definido durante o processo de calibração uma região de recorte fixa, a qual foi aplicada para todas as imagens. Ao final, para cada imagem foi retornado uma nova imagem com dimensões de 100x972 pixels, a qual é fatiada em três diferentes espessuras (5, 7 e 9 pixels). A construção de bases com diferentes espessuras foi feita a fim de se analisar qual espessura pode representar de melhor maneira a textura ao longo da imagem sem que haja perda de informação. Todo o processo de aquisição, pré-processamento e segmentação pode ser observado na Figura 26, enquanto a Tabela 2 descreve as bases de amostras em diferentes tamanhos de segmentos oriundos das imagens adquiridas, de acordo com espessura (EB1, EB2 e EB3) e suas respectivas quantidades de amostras destinadas tanto para treinamento quanto para teste.

TABELA 2 – Base de imagens com diferentes espessuras (5, 7 e 9 pixels)

<b>Espessura da base</b>	<b>Dimensão dos filetes (em pixels)</b>	<b># amostras de treinamento</b>	<b># amostras de teste</b>
EB1	5×972	780	382
EB2	7×972	546	268
EB3	9×972	429	210

Como pode-se observar, o tamanho da base de imagens varia de acordo com a espessura do filete, podendo avaliar então diferentes representações da superfície interna da tubulação. Conforme a metodologia proposta no Capítulo 3.3.3.1, da base de amostras de treinamento, 70% são destinadas ao treinamento do classificador e 30% para validação, já a base de amostras para teste são utilizadas na etapa final de avaliação da abordagem proposta.

FIGURA 26 – Aquisição de imagem. A imagem dentro do tubo ( $1296 \times 972$  pixels), trecho em foco recortado ( $100 \times 972$  pixels), e imagem final pós fatiamento ( $5, 7$  and  $9 \times 972$  pixels)



FONTE: O AUTOR (2018)


## 4.2 EXTRAÇÃO DE CARACTERÍSTICAS

A fim de se extrair informações das bases de imagens, foram utilizadas duas abordagens: uma utilizando o algoritmo Local Phase Quantization e a outra Parâmetros de Haralick. Para a primeira, dois tamanhos de janelas foram utilizados para análise de pixels vizinhos, sendo uma  $3 \times 3$  e outra de  $5 \times 5$  pixels. Ao percorrer a janela ao longo da imagem (Figura 27), um vetor de 256 características de acordo com a quantização dos padrões observados é retornado.

Já para a segunda, 13 parâmetros de Haralick foram computados com base matriz de co-ocorrência obtida da imagem em escala de cinza, considerando quatro diferentes direções ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ), Figura 28, resultando em um vetor de 52 posições.


Além de se usar estes dois vetores separadamente, foi avaliado a fusão de informações por meio da concatenação dos vetores de ambos algoritmos e normalizando-os por meio da divisão dos valores pela raiz quadrada da soma dos quadrados, resultando em um vetor de 308 posições. As diferentes combinações de características são resumidas na Tabela 3, aonde os índices de  $LPQ$  denotam respectivamente a espessura

FIGURA 27 – Aplicação da extração de características utilizando o algoritmo LPQ



FONTE: O AUTOR (2018)

FIGURA 28 – Aplicação da extração de características utilizando parâmetros de haralick



FONTE: O AUTOR (2018)

do filete analisado e a dimensão da janela e o índice de *Har* indica a espessura do filete.

#### 4.3 EXPERIMENTOS DE CLASSIFICAÇÃO

Os testes preliminares, conforme o Capítulo 3.3.3, dentre os classificadores avaliados, os que se demonstraram promissores foram os algoritmos de Análise Discriminante Linear (ADL) e Máquina de Vetores Suporte (MVS), utilizando um kernel linear. Para o primeiro, para a definição da função de decisão ótima, aplicou-se a

TABELA 3 – Diferentes configurações de extratores de características avaliados considerando LPQ com diferentes janelas e espessuras de filete; descritores de Haralick com diferentes espessuras de filete; e concatenação de ambos algoritmos

<b>Extração de Característica</b>	<b>Espessura Filete (em pixels)</b>	<b>Tamanho da Janela (em pixels)</b>
<i>LPQ</i> <sub>5,3</sub>	5	3×3
<i>LPQ</i> <sub>7,3</sub>	7	3×3
<i>LPQ</i> <sub>9,3</sub>	9	3×3
<i>LPQ</i> <sub>5,5</sub>	5	5×5
<i>LPQ</i> <sub>7,5</sub>	7	5×5
<i>LPQ</i> <sub>9,5</sub>	9	5×5
<i>Har</i> <sub>5</sub>	5	-
<i>Har</i> <sub>7</sub>	7	-
<i>Har</i> <sub>9</sub>	9	-
<i>LPQ</i> <sub>5,3</sub> + <i>Har</i> <sub>5</sub>	5	3×3
<i>LPQ</i> <sub>7,3</sub> + <i>Har</i> <sub>7</sub>	7	3×3
<i>LPQ</i> <sub>9,3</sub> + <i>Har</i> <sub>9</sub>	9	3×3
<i>LPQ</i> <sub>5,5</sub> + <i>Har</i> <sub>5</sub>	5	5×5
<i>LPQ</i> <sub>7,5</sub> + <i>Har</i> <sub>7</sub>	7	5×5
<i>LPQ</i> <sub>9,5</sub> + <i>Har</i> <sub>9</sub>	9	5×5

função dos mínimos quadrados. Esta a qual, foi aplicada juntamente com método de encolhimento automático, proposto por (LEDOIT; WOLF, 2004), que auxilia no estimativa das matrizes de covariância por meio da adição de restrições aos valores dos coeficientes, fazendo com que haja redução na variância e uma melhora no resultado de classificação. Já para o SVM, dada a distribuição linear dos dados, optou-se pela utilização de um *kernel* linear, utilizando a metodologia de classificação *um contra todos* e uma penalização *C* de valor 300, o qual foi ajustado por meio da observação da performance do classificador em relação aos dados de validação. Com intuito de observar a acurácia dos modelos conforme as características, parte dos dados de treinamento (Tabela 2) foi utilizada para treinar o classificador e outra para validação, repetindo o processo por dez vezes, randomizando a base a cada iteração. A média da acurácia da classificação dos dados de validação pode ser observada na Tabela 4.

Com base no valor médio da acurácia mostrados na Tabela 4 e Tabela 5, uma pré-seleção dos modelos foi feita, para aplicar na etapa de teste, com base nas melhores taxas de acerto. Sendo assim, foram selecionados apenas as configurações de extração de características que apresentaram uma acurácia maior ou igual a 90% utilizando ambos classificadores (ADL e SVM). Consequente, treinando os modelos selecionados com 100% da base de treinamento e aplicando-os na base de teste, é possível observar a capacidade de cada modelo na generalização de dados desconhecidos. A Tabela 6 apresenta a distribuição de amostras para teste por classe, as quais são obtidas das imagens da base de teste (Figura 29).

TABELA 4 – Taxa de acerto utilizando ADL e diferentes configurações de extratores de características com base nos dados de validação

<b>Extração de Característica</b>	<b>Classe 1 (%)</b>	<b>Classe 2 (%)</b>	<b>Classe 3 (%)</b>	<b>Média (%)</b>
<i>LPQ</i> <sub>9,3</sub>	95	96	93	95
<i>LPQ</i> <sub>9,5</sub>	99	97	91	95
<i>LPQ</i> <sub>9,3</sub> + <i>Har</i> <sub>9</sub>	94	92	99	95
<i>LPQ</i> <sub>9,5</sub> + <i>Har</i> <sub>9</sub>	93	96	98	95
<i>LPQ</i> <sub>7,5</sub>	98	95	88	94
<i>Har</i> <sub>7</sub>	93	91	98	94
<i>Har</i> <sub>9</sub>	93	89	99	94
<i>Har</i> <sub>5</sub>	92	90	96	93
<i>LPQ</i> <sub>7,3</sub> + <i>Har</i> <sub>7</sub>	92	89	98	93
<i>LPQ</i> <sub>7,5</sub> + <i>Har</i> <sub>7</sub>	89	91	99	93
<i>LPQ</i> <sub>7,3</sub>	93	96	89	92
<i>LPQ</i> <sub>5,3</sub> + <i>Har</i> <sub>5</sub>	87	87	98	91
<i>LPQ</i> <sub>5,5</sub> + <i>Har</i> <sub>5</sub>	82	86	98	89
<i>LPQ</i> <sub>5,3</sub>	89	93	80	87
<i>LPQ</i> <sub>5,5</sub>	93	90	78	87


TABELA 5 – Taxa de acerto utilizando SVM e diferentes configurações de extratores de características com base nos dados de validação

<b>Extração de Característica</b>	<b>Classe 1 (%)</b>	<b>Classe 2 (%)</b>	<b>Classe 3 (%)</b>	<b>Média (%)</b>
<i>LPQ</i> <sub>9,3</sub>	97	98	96	97
<i>LPQ</i> <sub>7,3</sub> + <i>Har</i> <sub>7</sub>	99	94	98	97
<i>LPQ</i> <sub>9,5</sub>	99	97	92	96
<i>LPQ</i> <sub>5,3</sub> + <i>Har</i> <sub>5</sub>	97	94	99	96
<i>LPQ</i> <sub>9,3</sub> + <i>Har</i> <sub>9</sub>	99	94	97	96
<i>LPQ</i> <sub>7,5</sub> + <i>Har</i> <sub>7</sub>	97	92	98	96
<i>LPQ</i> <sub>9,5</sub> + <i>Har</i> <sub>9</sub>	99	92	98	96
<i>Har</i> <sub>7</sub>	95	94	95	95
<i>Har</i> <sub>9</sub>	96	92	96	95
<i>LPQ</i> <sub>7,5</sub>	96	96	92	94
<i>Har</i> <sub>5</sub>	93	93	92	93
<i>LPQ</i> <sub>7,3</sub>	94	95	88	92
<i>LPQ</i> <sub>5,5</sub> + <i>Har</i> <sub>5</sub>	93	88	94	92
<i>LPQ</i> <sub>5,3</sub>	91	91	82	88
<i>LPQ</i> <sub>5,5</sub>	85	85	73	81

TABELA 6 – Número de amostras para teste por classe (Classe 1 : sem defeito, Classe 2: corrosão salina, e Classe 3: usinado) para cada base de imagens e suas respectivas espessuras (EB1, EB2 e EB3))

<b>Classe</b>	<b>EB1</b>	<b>EB2</b>	<b>EB3</b>
1	120	84	66
2	140	98	77
3	122	86	67

FIGURA 29 – Exemplo de imagens pré-processadas da base de teste representando as três classes: (a) sem defeito, (b) corrosão salina, e (c) usinado



FONTE: O AUTOR(2018)

A acurácia dos modelos aplicados na base de teste está relacionada diretamente, tanto com a capacidade das características extraídas distinguirem as classes corretamente (as quais representam três tipos de situações internas da tubulação), quanto com o modelo matemático treinado pelo classificador. As taxas de acerto dos modelos utilizando tanto Análise Discriminante Linear quanto Máquina de Vetores Suporte, podem ser observadas respectivamente nas Tabelas 7 e 8.

TABELA 7 – Taxa de acerto usando ADL e diferentes configurações de extração de característica sobre o conjunto de teste

<b>Extração de Característica</b>	<b>Classe 1 (%)</b>	<b>Classe 2 (%)</b>	<b>Classe 3 (%)</b>	<b>Média (%)</b>
$LPQ_{7,3} + Har_7$	94	91	98	94
$LPQ_{9,5} + Har_9$	85	94	97	92
$LPQ_{9,3} + Har_9$	83	92	96	90
$LPQ_{5,3} + Har_5$	80	86	92	86
$LPQ_{7,5} + Har_7$	74	89	94	86
$Har_9$	95	81	79	85
$Har_7$	94	73	81	83
$LPQ_{9,5}$	98	91	48	79
$Har_5$	96	60	82	79
$LPQ_{9,3}$	97	90	37	75
$LPQ_{7,5}$	94	83	44	74
$LPQ_{7,3}$	98	80	38	72

TABELA 8 – Taxa de acerto usando SVM e diferentes configurações de extração de característica sobre o conjunto de teste


<b>Extração de Característica</b>	<b>Classe 1 (%)</b>	<b>Classe 2 (%)</b>	<b>Classe 3 (%)</b>	<b>Média (%)</b>
<i>LPQ<sub>9,3</sub> + Har<sub>9</sub></i>	100	88	88	92
<i>LPQ<sub>7,3</sub> + Har<sub>7</sub></i>	100	88	88	92
<i>LPQ<sub>5,3</sub> + Har<sub>5</sub></i>	100	79	88	89
<i>Har<sub>5</sub></i>	100	83	74	86
<i>LPQ<sub>7,5</sub> + Har<sub>7</sub></i>	84	82	88	85
<i>LPQ<sub>9,5</sub> + Har<sub>9</sub></i>	84	82	88	85
<i>Har<sub>7</sub></i>	100	77	70	82
<i>Har<sub>9</sub></i>	100	77	70	82
<i>LPQ<sub>7,5</sub></i>	95	82	60	79
<i>LPQ<sub>9,5</sub></i>	95	82	60	79
<i>LPQ<sub>7,3</sub></i>	100	80	36	72
<i>LPQ<sub>9,3</sub></i>	100	80	36	72

#### 4.4 REPLICAÇÃO DOS TESTES

A fim de se testar a confiabilidade dos resultados e repetibilidade da metodologia proposta, o processo foi aplicado utilizando um outro sistema de câmera e lente, que foi adquirido próximo as etapas finais do trabalho.

A câmera da marca Mizumi, possui um diâmetro de 14mm e um comprimento total de 30mm. O sensor, de tecnologia CMOS, possui uma resolução de 5 Megapixels e a lente, utilizada para a câmera, possui as seguintes características: distância focal de 3mm; abertura de 2; e um campo de visão de 90°(Figura 30).


FIGURA 30 – Câmera Mizumi MD-B5014, visão lateral (a) e frontal (b)



FONTE: O AUTOR (2018)

Para que se pudesse adaptar a câmera ao sistema de iluminação, uma nova case foi desenvolvida em uma impressora 3D (Figura 31).

FIGURA 31 – Invólucro para câmera Mizumi, visão lateral (a) e frontal (b)



FONTE: O AUTOR (2018)

Uma vez adaptada a câmera, a metodologia proposta no Capítulo 3 foi aplicada. A tensão utilizada para o sistema de iluminação foi de mesmo valor, resultando em aproximadamente 2600 lux, e a resolução, para aquisição das imagens, foi de 1280x960 pixels. Com a lente ajustada em seu melhor foco, a região nítida na imagem representa em medidas reais uma profundidade de aproximadamente 27mm e após seu pré-processamento, o segmento resultante do recorte da região de interesse apresentou dimensões de 100x960 pixels. Desta forma, as imagens foram adquiridas da mesma maneira, dos tubos destinados a treinamento (Figura 21) e dos tubos destinados a teste (Figura 22). Visando aplicar a melhor configuração resultante do trabalho apresentado ( $LPQ_{7,3} + Har_7$ ), as imagens foram fatiadas em segmentos de 7x960 pixels, resultando em uma nova base, conforme a Tabela 9.

TABELA 9 – Nova base de imagens com espessura de 7 pixels

<b>Espessura da base</b>	<b>Dimensão dos filetes (em pixels)</b>	<b># amostras de treinamento</b>	<b># amostras de teste</b>
EB4	7×960	378	225

Utilizando o algoritmo ADL para classificação, a nova base de treinamento foi então dividida em 70% para treinar o algoritmo e 30% para validar. Utilizando as amostras de treinamento (Tabela 9), os mesmos parâmetros para o classificador e a metodologia proposta no Capítulo 3.3.3.1 foi aplicado, resultando então na Tabela 10, a qual possui a média da taxa de acerto das execuções em relação aos dados de validação.

TABELA 10 – Taxa de acerto em relação aos dados de validação utilizando a melhor configuração de extração de característica ( $LPQ_{7,3} + Har_7$ ) e classificador (ADL)

<b>Extração de Característica</b>	<b>Classe 1 (%)</b>	<b>Classe 2 (%)</b>	<b>Classe 3 (%)</b>	<b>Média (%)</b>
$LPQ_{7,3} + Har_7$	99	96	99	98

Uma vez que o modelo demonstrou uma boa taxa de acerto durante a etapa de treinamento e validação, esta foi treinada utilizando 100% dos dados de treinamento

e então utilizado as amostras de teste (Tabela 10), as quais possuem a distribuição conforme a Tabela 11.

TABELA 11 – Número de amostras para teste por classe da nova base **EB4** (Classe 1 : sem defeito, Classe 2: corrosão salina, e Classe 3: usinado)

<b>Base</b>	<b>Classe1</b>	<b>Classe2</b>	<b>Classe3</b>
EB4	70	83	72

TABELA 12 – Taxa de acerto em relação aos dados de teste utilizando a melhor configuração de extração de característica ( $LPQ_{7,3} + Har_7$ ); classificador (ADL); e 100% dos dados de treinamento para gerar o modelo

<b>Extração de Característica</b>	<b>Classe 1 (%)</b>	<b>Classe 2 (%)</b>	<b>Classe 3 (%)</b>	<b>Média (%)</b>
$LPQ_{7,3} + Har_7$	100	100	100	100

#### 4.5 DISCUSSÃO

A performance de ambos classificadores (ADL e SVM) se demonstraram semelhantes, quando aplicados os mesmos vetores de característica. Entretanto, é claro que a fusão das características tem um importante papel no processo de classificação, principalmente quando são usados as amostras de teste para validar a capacidade de generalização dos modelos treinados, como pode-se observar na Tabela 7 e na Tabela 8. A espessura do filete, a qual contém a área da seção anelar da tubulação, é diretamente relacionada com a quantidade de informação que represente a situação interna real por meio de sua textura. A Tabela 13 representa a média da taxa de acerto da Tabela 7 e Tabela 8, a fim de analisar a acurácia conforme a espessura da imagem e classificador.

TABELA 13 – Média das taxas de classificação de cada classificador conforme a espessura do filete

<b>Classificador</b>	<b>Espessura (pixels)</b>	<b>Média (%)</b>
ADL	5	76
	7	82
	9	84
SVM	5	80
	7	82
	9	86


Durante a pré-seleção dos melhores modelos, de cinco diferentes configurações para extração de características, para as imagens de 5 pixels de espessura, apenas duas delas conseguiram atingir uma porcentagem maior de 90% em ambos

classificadores. Tal fator aponta uma limitação dada a espessura em termos de representação da característica interna da superfície quando comparada a espessuras maiores. Por outro lado, as taxas maiores de acerto foram observadas em imagens de espessura de 9 pixels, demonstrando que filetes de maior espessura representam melhor a superfície interna. Considerando as técnicas de extração de características, no estágio de treinamento, a performance de todas as configurações foram similares, mas no estágio de teste foi possível observar as diferenças na capacidade de generalização. Focando nos configurações com sete e nove pixels, utilizando apenas LPQ como extrator, para amostras desconhecidas, independente da espessura, o método demonstrou baixa performance tentando classificar corretamente a Classe 3. Por outro lado, utilizando apenas Parâmetros de Haralick, a taxa de acerto para a Classe 3 se demonstrou mais alta, porém tratando-se da Classe 2, a taxa foi mais baixa do que se aplicando LPQ. Ambos extratores possuíram boa taxa de acerto em relação a Classe 1 e uma taxa complementar tratando-se da Classe 2 e 3. Desta maneira, com intuito de se melhorar a representação por meio das características extraídas, uma concatenação e normalização das informações de ambos extratores em somente um vetor foi feita. Esta fusão de informações relacionadas a textura gerou uma melhora na capacidade de generalização dos classificadores para dados desconhecidos (Tabela 7 e Tabela 8), resultando em uma taxa de acerto promissora para todas as três classes. Tratando-se do melhor modelo, este apresentou uma acurácia de 94% utilizando como classificador o algoritmo ADL e a configuração  $LPQ_{7,3} + Har_7$ . Apesar da configuração não ser do filete de imagem mais espesso (9 pixels), uma imagem de espessura de 7 pixels foi capaz de representar de maneira eficiente as informações presentes na superfície da tubulação.

Com base nos dados apresentados utilizando a nova câmera, nota-se a repetibilidade do teste e confiabilidade da metodologia, uma vez que as imagens capturadas possuem diferenças tanto em dimensões quanto em aparência em relação as imagens utilizadas no trabalho proposto, conforme a Figura 32. Apesar dos bons resultados, a câmera possui restrições de tamanho devido ao seu comprimento, fazendo com que esta não seja ideal para o projeto final.

Apesar da quantidade menor de amostras utilizadas, os resultados se demonstraram melhores na taxa de acerto das amostras de testes, indicando que a metodologia é robusta o suficiente em identificar as texturas presentes independente de variações na captura das imagens, quando esta feita por diferentes câmeras.

FIGURA 32 – Comparação de imagens adquiridas com a câmera ximea (a) e mizumi (b)



FONTE: O AUTOR (2018)

## 5 CONCLUSÃO

O trabalho apresentado propõe uma nova abordagem para detecção automática de regiões defeituosas em tubos metálicos de pequeno diâmetro, como os tubos que fazem a condução do vapor em uma usina termoelétrica. Os resultados demonstraram que possuindo um sistema apropriado de inserção da câmera com um bom sistema de iluminação e uma lente ideal, que seja capaz de capturar de maneira nítida as condições internas da tubulação, é possível analisar e diagnosticar a condição interna da superfície. A abordagem de pré-processamento inspirada no processo de reconhecimento de íris, devido a similaridade da imagem capturada da região interna do tubo com um globo ocular, se demonstrou válida, visto que as características extraídas dessas imagens, quando usadas para alimentar um classificador linear, gera um modelo capaz de distinguir se a região interna da tubulação se encontra sem defeitos ou com algum tipo de defeito como corrosão ou cavidades. Os experimentos feitos com dois tipos diferentes de algoritmos de análise de textura, LPQ e Parâmetros de Haralick, mostraram que a melhor abordagem é, baseado em imagens de 7 e 9 pixels de espessura, extrair e juntar as informações de ambos algoritmos. Tal abordagem resultou em modelos com acurácia entre 90% e 94%. O trabalho proposto expõe uma metodologia inovadora, reunindo dois conceitos, onde um visa o diagnóstico automático baseado em visão computacional, porém em tubulações de concreto de grande diâmetro e outro que adquire imagens de tubos de condução de vapor em termoelétricas mas sem identificar nenhum defeito automaticamente. Com resultados promissores, o presente trabalho abre uma nova gama de possibilidades no ramo de inspeção visual em indústrias, onde tubulações de pequeno diâmetro sejam essenciais para seu funcionamento, podendo oferecer alternativas como auxiliar inspetores a detectarem regiões defeituosas durante a inspeção ou também a possibilidade de criar uma ferramenta autônoma de inspeção baseada em visão, que poderia fazer do processo de inspeção mais rápido, economizando tempo e gastos. Logo, as principais contribuições deste trabalho são: conceito de inserção de sistemas de inspeção em tubos verticais; uma nova abordagem para aquisição e análise de imagens de um tubo de pequeno diâmetro; e extrair informações de maneira efetiva da textura da superfície sob condições de variação de iluminação.

### 5.1 TRABALHOS FUTUROS

Os trabalhos futuros consistem na aquisição de trechos de tubulação que apresentem defeitos reais oriundos de uma usina termoelétrica e treinar um modelo com base na metodologia proposta, a fim de avaliar a performance do sistema em

situação real.

## REFERÊNCIAS

- CAVALIN, P. et al. Wood Defect Detection using Grayscale Images and an Optimized Feature Set. In: *IECON 2006 - 32nd Annual Conference on IEEE Industrial Electronics*. [S.l.: s.n.], nov. 2006. p. 3408–3412. Citado 1 vez na página 21.
- COELHO, L. P. “Mahotas: Open source software for scriptable computer vision,” *p*, p. 1–7, 2012. Citado 1 vez na página 37.
- CORTES, C.; VAPNIK, V. Support-Vector Networks. *Machine Learning*, v. 20, p. 273–297, set. 1995. Citado 1 vez na página 25.
- COSTA, Yandre M. G. et al. Comparing textural features for music genre classification. In: *The 2012 International Joint Conference on Neural Networks (IJCNN)*. [S.l.]: IEEE, jun. 2012. p. 1–6. Citado 1 vez na página 21.
- DAUGMAN, J. The importance of being random: Statistical principles of iris recognition. *Pattern Recognition*, v. 36, n. 2, p. 279–291, 2003. Citado 1 vez na página 33.
- DEBENEST, P.; GUARNIERI, M.; HIROSE, S. PipeTron series - Robots for pipe inspection. *Applied Robotics for the Power Industry*, out. 2014. Citado 2 vezes nas páginas 14, 18.
- DURAN, O.; ALTHOEFER, K.; SENEVIRATNE, L. D. Pipe inspection using a laser-based transducer and automated analysis techniques. *IEEE/ASME Transactions on Mechatronics*, p. 401–409, 2003. Citado 1 vez na página 17.
- HALFAWY, M. R.; HENGMEECHAI, J. Automated defect detection in sewer closed circuit television images using histograms of oriented gradients and support vector machine. *Automation in Construction*, v. 38, p. 1–13, 2014. Citado 1 vez na página 18.
- HARALICK, R. M.; DINSTEIN, I.; SHANMUGAM, K. Textural features for image classification. *IEEE Transactions On Systems Man And Cybernetics*, IEEE, v. 3, n. 6, p. 610–621, 1973. Citado 1 vez na página 19.
- HOVINGA, M. N.; NAKONECZNY, G. J. Standard Recommendations for Pressure Part Inspection During a Boiler Life Extension Program. *International Conference on Life Management and Life Extension of Power Plant*, maio 2000. Citado 1 vez na página 17.
- HSU, C.; LIN, C. A Comparison of Methods for Multiclass Support Vector Machines. *IEEE TRANSACTIONS ON NEURAL NETWORKS*, v. 13, p. 415–425, mar. 2002. Citado 1 vez na página 27.
- HUANG, H.-Y.; LUO, S.-W.; CHEN, E.-Y. An efficient iris recognition system. In: *Proceedings. Int. Conf. Mach. Learn. Cybern.* [S.l.: s.n.], 2002. v. 4, p. 450–454. Citado 1 vez na página 33.

- KAIN, V. et al. Flow accelerated corrosion: Experience from examination of components from nuclear power plants. *Engineering Failure Analysis*, v. 18, p. 2028–2041, jul. 2011. Citado 1 vez na página 18.
- LEDOIT, O.; WOLF, M. Honey, I Shrunk the Sample Covariance Matrix. *Engineering Failure Analysis*, p. 106–119, jul. 2004. Citado 1 vez na página 46.
- LEE, J. et al. A SNP Harvester Analysis to Better Detect SNPs of CCDC158 Gene That Are Associated with Carcass Quality Traits in Hanwoo. *Asian-Australasian Journal of Animal Sciences*, v. 26, p. 766–771, fev. 2013. Citado 0 vez na página 26.
- MALAMAS, E. N. et al. A survey on industrial vision systems, applications and tools. *Image Vis Comput.*, v. 21, p. 171–188, 2003. Citado 1 vez na página 14.
- MYRANS, J.; KAPELAN, Z.; EVERSON, R. Automated Detection of Faults in Wastewater Pipes from CCTV Footage by Using Random Forests. *Procedia Eng.*, v. 154, p. 36–41, 2016. Citado 1 vez na página 18.
- NGAN, H. Y. T.; PANG, G. K. H.; YUNG, N. H. C. Automated fabric defect detection. A review. *Image Vis Comput.*, v. 29, p. 442–458, 2011. Citado 1 vez na página 14.
- OBRUTSKY, L.; LAKHAN, R.; RENAUD, J. Steam Generator Inspections: Faster, Cheaper and Better, Are We There Yet? *IV Conferencia Panamericana de END*, p. 1–17, 2007. Citado 1 vez na página 13.
- OBRUTSKY, L.; RENAUD, J.; LAKHAN, R. Overview of Steam Generator Tube-Inspection Technology. *CINDE Journal*, v. 35, n. 2, p. 5–13, 2009. Citado 2 vezes nas páginas 13, 14.
- OJANSIVU, V.; HEIKKILÄ, J. Blur Insensitive Texture Classification Using Local Phase Quantization. In: *3rd International Conference on Image and Signal Processing*. [S.l.: s.n.], 2008. p. 236–243. Citado 2 vez na página 19.
- PONTES, Jhony K. et al. A flexible hierarchical approach for facial age estimation based on multiple features. *Pattern Recognition*, v. 54, p. 34–51, jun. 2016. Citado 1 vez na página 19.
- SHARMA, A.; PALIWAL, K. K. Linear discriminant analysis for the small sample size problem: an overview. *International Journal of Machine Learning and Cybernetics*, v. 6, p. 443–454, jun. 2015. Citado 1 vez nas páginas 23, 24.
- SINHA, S. K.; FIEGUTH, P. W. Neuro-fuzzy network for the classification of buried pipe defects. *Autom. Constr.*, v. 15, n. 1, p. 73–83, 2006. Citado 1 vez na página 17.
- SINHA, S.; FIEGUTH, P. Morphological segmentation and classification of underground pipe images. *Machine Vision and Applications*, v. 17, n. 1, p. 21–31, 2006. Citado 1 vez na página 18.

SUBBAN, R.; DATTATREYA, N. S. Efficient iris recognition using Haralick features based extraction and fuzzy particle swarm optimization. *Cluster Comput.*, 2017. Citado 1 vez na página 21.

SUZUMORI, K. et al. Micro Inspection Robot for 1-in Pipes. *IEEE/ASME TRANSACTIONS ON MECHATRONICS*, v. 8, p. 286–292, set. 1999. Citado 1 vez na página 18.

YUAN, C.; SUN, X.; LV, R. Fingerprint liveness detection based on multi-scale LPQ and PCA. *China Communications*, v. 13, n. 7, p. 60–65, 2016. Citado 1 vez na página 19.