

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

**Um Estudo sobre a Influência da *Turbidez* na Inspeção
Visual Automática de Cordões de Solda em Imagens
Subsea**

Patrick da Silva Baldez

Orientadora: Prof. Dr. Silvia Silva da Costa Botelho

Rio Grande, 2021

Ficha Catalográfica

B176e Baldez, Patrick da Silva.

Um estudo sobre a influência da turbidez na inspeção visual automática de cordões de solda em imagens *subsea* / Patrick da Silva Baldez. – 2021.

66 f.

Dissertação (mestrado) – Universidade Federal do Rio Grande – FURG, Programa de Pós-Graduação em Computação, Rio Grande/RS, 2021.

Orientadora: Dra. Silvia Silva da Costa Botelho.

1. Rede Neural 2. Inspeção de Soldagem 3. Visão Computacional
I. Botelho, Silvia Silva da Costa II. Título.

CDU 621.791

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

DISSERTAÇÃO DE MESTRADO

Um Estudo sobre a Influência da Turbidez na Inspeção Visual Automática de Cordões de Solda em Imagens Subsea

Patrick da Silva Baldez

Banca examinadora:

RENATO VENTURA BAYAN
HENRIQUES:43954677091

Assinado de forma digital por
RENATO VENTURA BAYAN
HENRIQUES:43954677091
Dados: 2021.11.16 14:31:36 -03'00'

Prof. Dr. Renato Ventura Bayan Henriques



Documento assinado digitalmente
Ricardo Nagel Rodrigues
Data: 17/11/2021 21:23:34-0300
Verifique em <https://verificador.iti.br>

Prof. Dr. Ricardo Nagel Rodrigues



Prof. Dr. Silvia Silva da Costa Botelho
Orientadora

RESUMO

BALDEZ, Patrick da Silva. **Um Estudo sobre a Influência da *Turbidez* na Inspeção Visual Automática de Cordões de Solda em Imagens Subsea**. 2021. 65 f. . Universidade Federal do Rio Grande, Rio Grande.

O processo de soldagem é um dos mais críticos na construção e reparação de navios, onde uma falha no cordão de solda, não identificada no processo de controle de qualidade, pode acarretar a segurança de sua estrutura. Sendo assim, a inspeção visual de soldas em ambiente subaquático é fundamental, onde é comum a utilização de métodos computacionais, baseados em visão computacional, e testes não destrutivos para auxílio na inspeção visual do cordão de solda. O trabalho apresenta um estudo sobre inspeção de textura de cordões de solda utilizando métodos de visão computacional, onde foi realizado uma revisão bibliográfica nos moldes da revisão sistemática da literatura. Com base na revisão, é possível identificar que o problema de inspeção visual de processos de soldagem é atual, e técnicas de visão computacional e aprendizagem profunda estão sendo utilizadas. Portanto, a contribuição principal deste trabalho é apresentar um estudo de um método capaz de identificar irregularidades na textura do cordão de solda de chapas metálicas, adicionando uma etapa de pré-processamento da imagem visando a inspeção de textura em cordões de solda em diferentes níveis de *turbidez* no ambiente subaquático.

Palavras-chave: Rede Neural, Inspeção de Soldagem, Visão Computacional.

ABSTRACT

BALDEZ, Patrick da Silva. **Passive Vision System for Weld Bead Texture Inspection in Underwater Environments**. 2021. 65 f. . Universidade Federal do Rio Grande, Rio Grande.

The welding process is one of the most critical in the construction and repair of ships, where a failure in the weld bead, not identified in the quality control process, can cause the safety of its structure. Therefore, visual inspection of welds in an underwater environment is essential, where it is common to use computational methods, based on computer vision, and non-destructive tests to aid in the visual inspection of the weld bead. The work presents a study on weld bead texture inspection using computer vision methods, where a bibliographical review was carried out along the lines of the systematic literature review. Therefore, a main contribution of this work is to present a study of a method capable of identifying irregularities in the texture of the weld bead of sheet metal, adding an image pre-processing step raised to texture in weld beads at different levels of turbidity in the underwater environment.

Keywords: Network Neural, Vision Computer, Welding Inspection.

LISTA DE FIGURAS

Figura 1	Processo FCAW (CORREA; MASTELARI; MORENO, 2014). . . .	11
Figura 2	a)Imagem com textura sem irregularidades. b)Imagem com textura irregular.	11
Figura 3	Exemplos de imagens turvas capturadas em ambientes subaquáticos naturais (DUARTE et al., 2016).	13
Figura 4	Diagrama do Processo de Seleção dos Estudos.	19
Figura 5	Relação de Tipo de Imagem pelos Estudos Seleccionados.	23
Figura 6	Relação de Orientação da Imagem pelos Estudos Seleccionados. . . .	23
Figura 7	Relação do Momento da Inspeção pelos Estudos Seleccionados. . . .	24
Figura 8	Relação dos Tipos de Descontinuidades pela suas Quantidades. . . .	24
Figura 9	Relação dos Métodos de Identificação de Descontinuidades pela suas Quantidades.	25
Figura 10	Relação dos Métodos de Classificação de Descontinuidades pela suas Quantidades.	26
Figura 11	Método de Classificação para Defeitos de Solda (YAN et al., 2017). .	27
Figura 12	Diagrama do Sistema (SASSI; TRIPICCHIO; AVIZZANO, 2019). . .	28
Figura 13	Arquitetura da Rede Neural (GOLODOV; MITTSEVA, 2019).	28
Figura 14	Fluxograma Geral do Modelo Proposto (HOU et al., 2018).	29
Figura 15	Arquitetura da Rede (YAPING; WEIXIN, 2019).	29
Figura 16	Modelo do Método (MERA et al., 2016).	30
Figura 17	Rede (BACIOIU et al., 2019).	30
Figura 18	Rede (ZHANG; WEN; CHEN, 2019).	31
Figura 19	Rede (LIU et al., 2017).	32
Figura 20	Rede (GONZALEZ-VAL et al., 2019).	33
Figura 21	Rede (WANG; SHI; TONG, 2019).	34
Figura 22	Rede (NAGATA et al., 2019).	35
Figura 23	Diagrama do método de identificação de textura proposto por (SOARES et al., 2019).	38
Figura 24	Diagrama conceitual do método (MELLO et al., 2020).	40
Figura 25	Arquitetura da rede neural (MELLO et al., 2020).	40
Figura 26	Linha superior: imagens originais, meio: imagens de entrada com gama alterado e linha inferior: imagens restauradas: (a) Imagens para $\gamma = 3$ (b) Imagens para $\gamma = 1/3$ (MELLO et al., 2020).	41
Figura 27	Imagens do trabalho de (DUARTE et al., 2016).	43
Figura 28	Cenário do experimento.	43

Figura 29	Conjunto de dados obtido no experimento com os 19 níveis de <i>turbidez</i> simulados.	45
Figura 30	a) Imagem com textura sem irregularidades. b) Imagem com textura irregular.	46
Figura 31	Exemplos de segmentos de 100×100 pixels de uma imagem de um cordão de solda.	47
Figura 32	Resultado da inspeção de textura aplicada nos 19 níveis de <i>turbidez</i> . .	48
Figura 33	Gráfico verdadeiro positivo.	50
Figura 34	Gráfico falso positivo.	50
Figura 35	Gráfico verdadeiro negativo.	51
Figura 36	Gráfico falso negativo.	51
Figura 37	Gráfico acurácia.	52
Figura 38	Diagrama da proposta.	53
Figura 39	Resultado da restauração.	53
Figura 40	Resultado da rede de reconstrução para os 19 níveis de <i>turbidez</i> . . .	54
Figura 41	Inspeção das imagens após a reconstrução.	55
Figura 42	Gráfico de comparação do verdadeiro positivo.	57
Figura 43	Gráfico de comparação do falso positivo.	57
Figura 44	Gráfico de comparação do verdadeiro negativo.	58
Figura 45	Gráfico de comparação do falso negativo.	58
Figura 46	Gráfico de comparação da acurácia.	59

LISTA DE TABELAS

Tabela 1	Bases de Dados Seleccionadas	16
Tabela 2	Palavras-Chave Definidas	16
Tabela 3	Estudos Retornados pela Estratégia de Busca	17
Tabela 4	Estudos Seleccionados após os Critérios de Inclusão	18
Tabela 5	Estudos Seleccionados após os Critérios de Exclusão	18
Tabela 6	Estudos Seleccionados após os Leitura Integral	18
Tabela 7	Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q1: "Quais os tipos de imagens de cordões de solda para inspeção visual?"	20
Tabela 8	Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q2: "Que configuração de posicionamento de câmara e, consequentemente, que tipos de vistas (superior, frontal, etc) estão sendo utilizadas nos trabalhos?"	20
Tabela 9	Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q3: "Os resultados são obtidos durante ou após o processo de soldagem?"	20
Tabela 10	Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q4: "Quais os tipos de discontinuidades visuais nos cordões de solda estão sendo identificados?"	21
Tabela 11	Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q5: "Quais as técnicas utilizadas para detectar discontinuidades visuais nos cordões de solda?"	21
Tabela 12	Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q6: "Quais os métodos para classificação dos tipos de discontinuidades visuais nos cordões de solda?"	22
Tabela 13	Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q7: "Quais métodos estão sendo utilizados para reconstrução de imagens com <i>turbidez</i> ?"	22
Tabela 14	Quantidade de leite integral adicionado a cada captura de imagem. A primeira coluna descreve o identificador da imagem. A segunda coluna descreve a quantidade de leite adicionado. A terceira coluna mostra a quantidade total de leite diluído em 500 litros de água. . . .	44

Tabela 15	Resultado da inspeção de textura do cordão de solda com 19 níveis de <i>turbidez</i>	49
Tabela 16	Resultado da inspeção de textura do cordão de solda com 19 níveis de <i>turbidez</i> após a reconstrução.	56

LISTA DE ABREVIATURAS E SIGLAS

2DLF	<i>Filtro Esquerdo Bidimensional</i>
ANN	<i>Rede Neural Artificial</i>
BN	<i>Rede Bayesiana</i>
CLTP	<i>Padrão Ternário Local Completo</i>
DNN	<i>Rede Neural Profunda</i>
HMM	<i>Modelo Oculto de Markov</i>
MIL	<i>Aprendizado Multi Instância</i>
MLP	<i>Perceptron Multicamadas</i>
PCA	<i>Análise de Componentes Principais</i>
RSL	<i>Revisão Sistemática da Literatura</i>
SVM	<i>Máquina de Vetores de Suporte</i>

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Problema	13
1.2	Objetivo	14
1.3	Objetivos Específicos	14
2	REVISÃO BIBLIOGRÁFICA	15
2.1	Revisão Sistemática dos Trabalhos Relacionados	15
2.1.1	Questão e Subquestões de Pesquisa	15
2.1.2	Extração de Dados	19
2.2	Resultados	22
2.2.1	Síntese	22
2.2.2	Visão Geral dos Trabalhos Relacionados	26
2.3	Referencial Teórico	38
2.3.1	Visão Computacional para Detecção de Descontinuidades de Textura em Cordões de Solda	38
2.3.2	Tratamento de Imagens Subsea	39
	2.3.2.1 A <i>Turbidez</i> em Imagens Subsea	39
	2.3.2.2 Redes Encoder-Decoder para Reconstrução de Imagens	39
3	METODOLOGIA	42
3.1	Avaliação da <i>Turbidez</i> na Inspeção de Textura em Cordões de Solda	42
3.1.1	Organização e composição do cenário e estrutura	42
3.1.2	Adição de leite integral para produção de <i>turbidez</i> na água	44
3.1.3	Aquisição das Imagens	45
3.2	Método para avaliação da <i>turbidez</i> no desempenho de visão computacional para inspeção de textura em cordões de solda	45
3.2.1	Treinamento	46
3.2.2	Inspeção de Textura	47
3.3	Tratamento da <i>Turbidez</i> para Inspeção Visual de Cordões de Solda	52
3.3.1	Rede de Reconstrução	53
4	CONCLUSÃO	60
	REFERÊNCIAS	61

1 INTRODUÇÃO

Dentre as operações industriais, o processo de soldagem é um dos mais críticos do ciclo de vida da planta, precisando ser inspecionado para garantir a qualidade da solda. Pequenas imperfeições na solda podem levar a consequências graves na construção, reparação e montagem da peça (BRACARENSE et al., 2002). Além disso, é um trabalho insalubre para o operador que está em contato direto com respingos, fumos e eletricidade.

O oceano assume uma posição de destaque na economia global e isso se deve ao fato da grande importância da indústria de exploração, extração e produção de minerais. Os oceanos ocupam aproximadamente dois terços da superfície terrestre e permanecem pouco estudados e explorados, pois oferecem perigos e adversidades à vida humana, sendo então uma área promissora para uso e aplicação de robôs e sistemas autônomos (YUH; MARANI; BLIDBERG, 2011). A falha das soldas em estruturas metálicas expostas ao mar pode resultar na perda da embarcação, perda de vidas e impactos ambientais significativos.

Todas as soldas das estruturas expostas ao mar devem ser inspecionadas antes de sua entrada em serviço e em intervalos periódicos durante sua vida útil de acordo com as diretrizes emitidas pelas sociedades de classificação (IACS, 2019).

Navios, plataformas e embarcações flutuantes estão continuamente expostos à dinâmica e condições ambientais adversas do oceano que podem causar danos estruturais e defeitos físicos, como rachaduras, corrosão e incrustação biológica no casco. A inspeção periódica do casco é necessária para verificar a integridade estrutural e a bioincrustação da superfície do casco, sendo de grande importância para melhorar a segurança operacional e a eficiência dos navios. Tradicionalmente, na água, a inspeção das estruturas metálicas vem sendo realizada principalmente com base em observações visuais conduzidas por mergulhadores humanos. No entanto, este tipo de atividade é bastante insalubre constituindo em tarefa trabalhosa e demorada para os seres humanos e, portanto, a eficiência prática e a qualidade dos resultados da inspeção são frequentemente limitadas.

Diferentes tecnologias podem ser utilizadas para soldagem de materiais (BARBEDO, 2011). O processo conhecido por FCAW (soldagem por arco de núcleo fundido), mostrado na Figura 1, é um dos processos de soldagem mais utilizados para soldagem de chapas metálicas. As diversas vantagens deste processo de soldagem permitem o seu emprego

na indústria, tendo em vista que o principal foco deste setor é aumentar a produtividade mantendo a qualidade de seus processos (MACHADO et al., 2015).




Figura 1: Processo FCAW (CORREA; MASTELARI; MORENO, 2014).

Os processos de soldagem representam uma parte bastante significativa dos custos de fabricação de um produto. Uma falha, no cordão de solda, não identificada no processo de controle de qualidade, pode acarretar grandes consequências ao fabricante do equipamento (ANDREUCCI, 2013).

A Figura 2 apresenta dois cordões de solda FCAW onde o cordão a direita apresenta falha acarretada pela imperfeição do depósito caracterizado pela rugosidade da textura do cordão.




Figura 2: a)Imagem com textura sem irregularidades. b)Imagem com textura irregular.

Com base na possibilidade de identificação visual de falhas, técnicas de visão computacional estão sendo utilizadas para inspeção automática de cordões. Estas técnicas utilizam câmeras para capturar a imagem e algoritmos capazes de processar os ruídos presentes,

segmentar o cordão e classificar os defeitos. Muitos destes sistemas são acoplados a robôs que imageiam o chanfro durante o processo de depósito do material servindo como base para acoplamento do sistema visual (SOARES et al., 2019).

Em (AMER et al., 2015) são examinadas e discutidas as tecnologias de inspeção offshore, onde são incluídas técnicas de inspeção visual e testes não-destrutivos subaquáticos. O autor ainda cita que dentro da área de inspeção subaquática existem três níveis de inspeção: Inspeção Visual Geral (IVG), Inspeção Visual Detalhada (IVD) e Inspeção Visual Fechada (IVF). Por meio do primeiro nível é possível que o mergulhador ou o ROV execute uma inspeção visual de maiores defeitos na estrutura, pelo olho humano ou pelo sistema de câmeras, visto que não é necessária uma limpeza do crescimento marinho sobre a estrutura. Já o segundo nível requer limpeza mínima e geralmente pode ser alcançado com escova de aço ou jato de água de alta pressão. Por fim, no terceiro nível, assim como (AMER et al., 2015), também é relatado por (FAHRNI et al., 2018) que todo crescimento marinho da estrutura é limpo antes da inspeção, o que também é possível com ferramentas do ROV. Desta forma, será possível que tanto o mergulhador ou o ROV inspecione qualquer dano visível causado por corrosão ou por falha no processo de soldagem.

Ao se tratar de problemas relacionados a danos de solda em ambientes subaquáticos, em (RAINE, 1995) foi descrito um ROV equipado com o sistema de medição de campo de corrente alternada (ACFM) para identificar trincas de solda na superfície de estruturas subaquáticas. Por outro lado, associado a ambiente de chão de fábrica, existem alguns métodos de inspeção e análise de cordões de solda de chapas metálicas utilizadas para construção de grandes estruturas metálicas, que poderiam estar embarcados em ROVS (LEONARDO et al., 2016; SOARES et al., 2019). A exemplo, (SOARES et al., 2019) propôs um sistema automático para inspeção visual de cordões de solda. O sistema é acoplado a um robô de soldagem linear e é capaz de detectar descontinuidades nos cordões de solda. Porém estes algoritmos não tratam aspectos importante das imagens subaquáticas causadas pela *turbidez* da água. A suspensão de partículas no meio pode inviabilizar o uso de técnicas de visão computacional utilizadas para inspeção de cordões de solda, tornando este tópico um desafio em aberto.

Com base no uso da informação visual para inspeção da qualidade de cordões de solda e da natureza do meio subaquático, o uso de sistemas automáticos de visão computacional para inspeção subsea (subaquática) destes elementos pode ser uma solução viável. Para tal, é importante considerar os aspectos relacionados ao imageamento e tratamento de imagens subsea.

Como o oceano é um meio composto por partículas em suspensão, estas partículas provocam algumas distorções na propagação da luz na água. A *turbidez* descreve o grau destes efeitos, causando assim degradação que devem ser tratados pelos algoritmos de visão computacional em sistemas automáticos de imageamento.

A atenuação da luz subaquática não é constante e varia com as condições geográficas e ambientais da água (BERMAN et al., 2020). A variabilidade da *turbidez*, luz ambiente e o elenco de cores representam um desafio significativo para restauração de imagens em ambiente subaquático. Por exemplo, em função do nível de *turbidez*, as imagens subsea apresentam efeitos presentes na Figura 3.




Figura 3: Exemplos de imagens turvas capturadas em ambientes subaquáticos naturais (DUARTE et al., 2016).

O uso de visão computacional para processamento de imagens subsea ainda é um problema em aberto em computação. Esta dissertação tratará este desafio de forma a avaliar o impacto da *turbidez* em algoritmos de inspeção de cordões de solda em ambientes subsea de forma a conceber sistemas capazes de auxiliar os seres humanos em tarefas de inspeção de soldagem subaquática.

1.1 Problema

Com base no trabalho de (SOARES et al., 2019), esta dissertação abordará o problema da inspeção visual automática de cordões de solda em ambientes subsea. Surgem como perguntas a serem respondidas nesta dissertação

Qual a influência da turbidez do meio subaquático nos algoritmos para classificação de texturas em cordões de solda?

Como prover sistemas de visão computacional que auxiliem o operador na detecção de falhas na textura de cordões de solda?

A maioria das técnicas apresentadas são utilizadas para inspecionar o casco de navios quando estão em processo de docagem em um dique seco, o qual é bastante trabalhoso e desfavorável economicamente já que o navio precisa parar a produção. Logo o problema industrial a ser abordado é a inspeção da textura nos cordões de solda em ambientes subaquáticos, que possam vir a invalidar a qualidade da peça soldada. O problema computacional associa-se a necessidade de avaliar o impacto da *turbidez* do meio aquático nos métodos para detecção de irregularidades na textura da solda, tendo como base visão computacional. Busca-se com a investigação desses problemas facilitar a inspeção de textura do cordão de solda subsea.

1.2 Objetivo

Este trabalho tem como objetivo o estudo de um método de inspeção de textura dos cordões de solda em ambiente subsea. O estudo tratará os aspectos de *turbidez* associado à imagem e seu impacto na detecção de irregularidades na textura afim de propor um modelo. O modelo será validado em ambiente controlado frente a diferentes condições de *turbidez*.

1.3 Objetivos Específicos

- Explorar técnicas de processamento de imagem para inspeção de textura em cordões de solda;
- Avaliar experimentalmente a influência da *turbidez* no desempenho do algoritmo para detecção de texturas;
- Explorar técnicas de processamento visual subsea capazes de tratar a *turbidez*;
- Propor um modelo com base no levantamento bibliográfico e experimentos;
- Testar e validar o modelo em ambiente subsea controlado com diferentes níveis de *turbidez*.

2 REVISÃO BIBLIOGRÁFICA

2.1 Revisão Sistemática dos Trabalhos Relacionados

Visando estabelecer um escopo para o campo de pesquisa, foi realizada uma revisão dos trabalhos relacionados nos moldes da Revisão Sistemática da Literatura (RSL).

2.1.1 Questão e Subquestões de Pesquisa

Com base nas questões de pesquisa definidas na introdução foram definidas as subquestões da pesquisa, de forma a possibilitar a análise e extração dos dados presentes nos artigos selecionados ao longo da pesquisa.

- Q1: Quais os tipos de imagens de cordões de solda para inspeção visual?
- Q2: Que configuração de posicionamento de câmera e, conseqüentemente, que tipos de vistas (superior, frontal, etc) estão sendo utilizadas nos trabalhos?
- Q3: Os resultados são obtidos durante ou após o processo de soldagem?
- Q4: Quais os tipos de descontinuidades visuais nos cordões de solda estão sendo identificados?
- Q5: Quais as técnicas utilizadas para detectar descontinuidades visuais nos cordões de solda ?
- Q6: Quais os métodos para classificação dos tipos de descontinuidades visuais nos cordões de solda?
- Q7: Quais métodos estão sendo utilizados para reconstrução de imagens com *turbi-dez*?

A primeira subquestão (Q1) pretende identificar os tipos de imagens de cordões de solda utilizado para inspeção visual. A segunda subquestão (Q2) pretende identificar em quais orientações podem ser adquiridas as imagens de cordões de solda. A terceira subquestão (Q3) pretende identificar se os resultados são obtidos durante ou após o

processo de soldagem. A quarta subquestão (Q4) pretende listar os diferentes tipos de descontinuidades identificados visualmente nos cordões de solda. A quinta subquestão (Q5) pretende identificar as técnicas utilizadas para detectar descontinuidades visuais nos cordões de solda. A sexta subquestão (Q6) pretende identificar os métodos computacionais utilizados para classificar os diferentes tipos de descontinuidades visuais nos cordões de solda. A última subquestão (Q7) refere-se a quais métodos atualmente estão sendo utilizados para reconstrução de imagens turvas.

Com base nas questões é possível determinar as palavras-chave para busca nas bases de dados, as bases de dados mais relevantes e que possuem uma relação direta com o tema são os veículos de publicação científica, anais de eventos e periódicos, bem como revistas de renome científico possuindo publicações na área de tecnologia. Neste escopo temos as bases de dados listadas na tabela 1.

Tabela 1: Bases de Dados Seleccionadas

Bases de Dados

ACM Digital Library
 IEEE Xplore
 IOPScience
 ScienceDirect
 Springer Link

Para realizar a busca automática nos repositórios online foram pesquisadas as palavras-chave listadas na tabela 2.

Tabela 2: Palavras-Chave Definidas

Palavras-Chave

Computer Vision
 Convolutional Neural Network
 Deep Learning
 Deep Neural NetWork
 Defect
 Discontinuities
 Inspection
 Machine Vision
 Quality
 Subsea
 System Vision
 Underwater
 Weld
 Welding

A partir das palavras-chave foram escolhidos os conectores lógicos AND e OR com a finalidade de otimizar a busca. A estratégia de busca traçada foi:

((Defect OR Discontinuities OR Inspection OR Quality) AND (Weld OR Welding)) OR (Subsea OR Underwater)) AND (Computer Vision OR Convolutional Neural Network OR Deep Learning OR Deep Neural NetWork OR System Vision OR Machine Vision)

A estratégia de busca tem como objetivo cruzar as strings para maximizar o número de trabalhos relacionados e garantir que apenas os artigos relevantes para a pesquisa sejam retornados, no entanto, ainda é necessário realizar os critérios de inclusão e exclusão para aprimorar mais a seleção dos trabalhos relacionados.

A definição de critérios de seleção foi realizada para garantir a qualidade nos resultados obtidos na RSL. Os critérios de inclusão definidos para seleção de estudos são:

- Estudos publicados no período de 2010 até 2021;
- Estudos nos quais os termos de pesquisa estejam presentes no título, nas palavras-chave ou no resumo.

Os critérios de exclusão definidos para seleção de estudos são:

- Estudos duplicados, que foram encontrados em mais de um banco de dados;
- Estudos curtos, com menos de 5 páginas;
- Estudos que não estão escritos nos idiomas inglês ou português;
- Estudos sem relação com a identificação de discontinuidades visuais de soldagem;
- Relatórios técnicos e outros documentos conhecidos como literatura cinza;
- Estudos que não são artigos, enciclopédias, resumos de palestras, revisões de conferências, e feedbacks da oficina.

Com a definição dos critérios de seleção, primeiramente foi utilizada a estratégia de busca nas bases de dados, retornando a quantidade de estudos conforme tabela 3.

Tabela 3: Estudos Retornados pela Estratégia de Busca

Bases de Dados	Quantidade
ACM Digital Library	8
IEEE Xplore	84
IOPScience	19
ScienceDirect	800
Springer Link	1191
Total	2102

Com a estratégia de busca é retornado um número consideravelmente alto para realizar a avaliação de todos, portanto, os critérios de seleção especificam as principais características

e conteúdos que os estudos devem ter para serem incluídos ou excluídos, com o objetivo de coletar um número considerável de trabalhos selecionados para as fases seguintes.

A quantidade de estudos que atendem os critérios de inclusão podem ser visto na tabela 4.

Tabela 4: Estudos Selecionados após os Critérios de Inclusão

Bases de Dados	Quantidade
ACM Digital Library	3
IEEE Xplore	12
IOPScience	13
ScienceDirect	14
Springer Link	65
Total	107

A quantidade de estudos após os critérios de exclusão podem ser visto na tabela 5.

Tabela 5: Estudos Selecionados após os Critérios de Exclusão

Bases de Dados	Quantidade
ACM Digital Library	2
IEEE Xplore	6
IOPScience	2
ScienceDirect	8
Springer Link	26
Total	44

Por fim, os estudos selecionados após os critérios de seleção foram lidos integralmente, e os que não tinham relação com a pesquisa desse trabalho foram descartados. A quantidade de estudos resultante é apresentado na tabela 6.

Tabela 6: Estudos Selecionados após os Leitura Integral

Bases de Dados	Quantidade
ACM Digital Library	2
IEEE Xplore	2
IOPScience	2
ScienceDirect	3
Springer Link	9
Total	18

Foram selecionados 18 estudos relacionados para essa pesquisa. Na Figura 4 é ilustrado o processo de seleção para obter esses estudos.




Figura 4: Diagrama do Processo de Seleção dos Estudos.

Após a atividade de seleção, os dados contidos nos estudos selecionados devem ser extraídos e sintetizados. A extração de dados é utilizada para coletar os dados que sejam necessários para responder as subquestões de pesquisa da revisão e para facilitar posteriormente as análises e síntese dos resultados. Na próxima etapa será realizada a extração de dados desses estudos.

2.1.2 Extração de Dados

A extração de dados foi baseada nas questões de pesquisa definidas na introdução. Onde busca-se fornecer um conjunto de respostas para cada subquestão.

Na tabela 7, é mostrada a extração de dados obtida a partir da subquestão Q1, onde, de acordo com a extração de dados dos estudos selecionados, as imagens podem ser adquiridas de três formas diferentes, imagem digital, imagem radiográfica ou imagem termográfica. As mais utilizadas para detecção de discontinuidades nos cordões de solda são as radiográficas, com 9 trabalho relacionados, e as digitais, com 8 trabalhos. Já a termográfica está presente em apenas 1 trabalho relacionado.

Tabela 7: Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q1: "Quais os tipos de imagens de cordões de solda para inspeção visual?"

Tipo	Quantidade
Digital	8
Radiografia	9
Termografia	1

A tabela 8 apresenta os dados extraídos da subquestão Q2, onde é feita uma análise de qual a configuração de posicionamento de câmera e, consequentemente, que vista da cena está sendo capturada. A orientação superior é utilizada em todos trabalhos, e apenas 1 trabalho apresenta três tipos de orientações, frontal, superior e traseira, para inspeção de soldagem.

Tabela 8: Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q2: "Que configuração de posicionamento de câmera e, consequentemente, que tipos de vistas (superior, frontal, etc) estão sendo utilizadas nos trabalhos?"

Tipo	Quantidade
Frontal	1
Superior	18
Traseiro	1

Na subquestão Q3 questiona-se se a inspeção é realizada durante ou após a soldagem, e, conforme a tabela 9, a maioria dos trabalhos realizam a inspeção após o processo de soldagem.

Tabela 9: Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q3: "Os resultados são obtidos durante ou após o processo de soldagem?"

Tipo	Quantidade
Offline	16
Online	2

A tabela 10 apresenta os tipos de discontinuidades que os estudos seleccionados identificam, respondendo a subquestão Q4.

Tabela 10: Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q4: "Quais os tipos de descontinuidades visuais nos cordões de solda estão sendo identificados?"

Descontinuidade	Quantidade
Desalinhamento	3
Excesso de Deposição	2
Falta de Deposição	3
Falta de Fusão	4
Falta de Penetração	6
Inclusão de Escória	6
Porosidade	10
Trinca	5

Os métodos de detecção de descontinuidades nos cordões de solda são listados na tabela 11, sendo questionado na subquestão Q5.

Tabela 11: Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q5: "Quais as técnicas utilizadas para detectar descontinuidades visuais nos cordões de solda?"

Método	Quantidade
Análise de Componentes Principais (PCA)	1
Filtro Canny	1
Filtro Esquerdo Bidimensional (2DLF)	1
Filtro Gaussiano	3
Gradiente	2
Histograma	3
Interpolação Polinomial Splines Cúbica	1
Método de Otsu	1
Método Sobel	1
Modelo Oculto de Markov (HMM)	1
Padrão Ternário Local Completo (CLTP)	1
Thresholds	4

A subquestão Q6 questiona-se sobre os métodos de classificação das descontinuidades nos cordões de solda. A tabela 12 apresenta os métodos de classificação extraídos dos estudos seleccionados.

Tabela 12: Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q6: "Quais os métodos para classificação dos tipos de discontinuidades visuais nos cordões de solda?"

Método	Quantidade
Aprendizado Multi Instância (MIL)	1
Máquina de Vetores de Suporte (SVM)	3
Rede Neural Artificial (ANN)	1
Rede Neural Profunda (DNN)	13
Perceptron Multicamadas (MLP)	1
Rede Bayesiana (BN)	1

Por fim a subquestão Q7 questiona-se sobre os métodos utilizados para reconstrução de imagens com *turbidez*. A tabela 13 apresenta os métodos de reconstrução extraídos dos estudos seleccionados.

Tabela 13: Dados Extraídos dos Estudos Seleccionados Referentes a Subquestão Q7: "Quais métodos estão sendo utilizados para reconstrução de imagens com *turbidez*?"

Método	Quantidade
Rede Neural Convolutacional (CNNs)	3

Com as todas as subquestões respondidas pelos estudos seleccionados, a extração de dados está concluída, na próxima fase é realizada a síntese e avaliação dos resultados.

2.2 Resultados

Nessa seção são apresentados os resultados obtidos a partir da RSL, iniciando-se pela síntese da revisão realizada, e após discute-se a pesquisa de alguns estudos seleccionados.

2.2.1 Síntese

A síntese é realizada como complemento das tabelas descritas anteriormente, através de gráficos para melhor visualização e entendimento dos dados, a fim de estender a compreensão da análise da RSL.

Os resultados da extração de dados da subquestão Q1, conforme Figura 5, demonstram que o formato de imagem para inspeção de soldagem mais utilizado é a radiografia, porém a utilização de imagem digital é utilizada em boa parte dos estudos seleccionados. Somente a termografia que não é pouco utilizada, apresentado em apenas 1 estudo seleccionado.




Figura 5: Relação de Tipo de Imagem pelos Estudos Seleccionados.

A Figura 6 mostra o gráfico em relação a extração de dados da subquestão Q2, onde apenas a orientação superior é utilizada em todos artigos exceto 1 artigo que utiliza além da superior, a orientação frontal e traseira.




Figura 6: Relação de Orientação da Imagem pelos Estudos Seleccionados.

Em resposta a subquestão Q3, os estudos seleccionados apresentam em sua maioria a identificação de descontinuidades após o processo de soldagem, sendo classificada como inspeção offline com 88.9%, e apenas 11.1% identificam online, ou seja, durante o processo de soldagem, conforme Figura 7.




Figura 7: Relação do Momento da Inspeção pelos Estudos Seleccionados.

Em relação aos tipos de descontinuidades identificadas questionado na subquestão Q4, a porosidade é a mais comum nos trabalhos relacionados, conforme Figura 8.




Figura 8: Relação dos Tipos de Descontinuidades pela suas Quantidades.

A subquestão Q5 é referente ao método computacional para identificação de descontinuidades no cordão de solda, e o método de Thresholds é o que mais aparece nos estudos seleccionados, seguido do método Gaussiano e Histograma, conforme Figura 9.




Figura 9: Relação dos Métodos de Identificação de Descontinuidades pela suas Quantidades.

Para classificação dos diferentes tipos de descontinuidades dos cordões de solda, em resposta da subquestão Q6, a rede neural convulacional é certamente a mais utilizada, como pode ser visto no gráfico da Figura 10.




Figura 10: Relação dos Métodos de Classificação de Descontinuidades pela suas Quantidades.

Para reconstrução das imagens com *turbidez*, em resposta a subquestão Q7, os estudos selecionados utilizam Redes Neurais Convulacionais (CNNs).

Nesta seção foi feita uma síntese da RSL, apresentando os resultados de uma forma mais demonstrativa. Na próxima seção é discutido as propostas, resultados e lacunas dos estudos selecionados.

2.2.2 Visão Geral dos Trabalhos Relacionados

Nesta seção são discutidos os métodos utilizados, resultados e lacunas dos trabalhos relacionandos, concedendo conceito geral de cada trabalho.

No trabalho de Soares et al. (SOARES et al., 2019), foi desenvolvido um sistema automatizado para analisar descontinuidades na textura nos cordões de solda. Foram utilizadas imagens digitais com orientação superior do chanfro, pré soldagem e pós soldagem. A inspeção é realizada offline e são detectados as irregularidades nas texturas dos cordões de solda. As imagens são classificadas utilizando o método SVM (CORTES; VAPNIK, 1995) com treinamento realizado com dataset próprio. Este trabalho foi escolhido como referencial para esta dissertação.

O artigo de Yan et al. (YAN et al., 2017) utiliza CLTP (RASSEM; KHOO, 2014) para detectar defeitos de soldas em imagens radiográficas. Para classificar os diferentes tipos de defeitos detectados é utilizado um classificador SVM, treinado com images do banco de dados Outex_TC_10010. A inspeção é realizada offline, e os tipos de defeitos classificados são porosidade, inclusão de escória, falta de penetração, falta de fusão e trinca. O método de classificação de defeitos de solda é mostrado na Figura 11, onde a classificação é determinada de acordo com os parâmetros de circularidade, diferença entre

defeito e fundo (Δh), área equivalente (S/C), contraste (CON) e entropia (ENT) na imagem da solda.



Figura 11: Método de Classificação para Defeitos de Solda (YAN et al., 2017).

O artigo Sassi et al. (SASSI; TRIPICCHIO; AVIZZANO, 2019), apresenta um sistema offline de detecção automática de defeitos de soldagem. As imagens digitais são processadas utilizando os métodos de Histograma, filtro Gaussiano, Thresholds e filtro Canny. Os tipos de defeitos detectados são porosidade, falta de deposição, excesso de deposição e desalinhamento. A classificação utiliza rede neural profunda com uma precisão de 0.921, sendo treinadas com 378 imagens de um dataset próprio. O diagrama do sistema é mostrado na Figura 12.




Figura 12: Diagrama do Sistema (SASSI; TRIPICCHIO; AVIZZANO, 2019).

Golodov e Mittseva (GOLODOV; MITTSEVA, 2019), propõem uma abordagem para detecção de defeitos de solda automatizada em imagens radiográficas. O pré-processamento da imagem é realizado utilizando os métodos de histograma e gradiente (LOWE, 2004). O sistema desenvolvido é offline e utiliza rede neural convulucional para classificar se a imagem possui ou não defeito de soldagem, mostrada na Figura 13. A rede foi treinada com 115182 imagens autorais, e obteve uma precisão de reconhecimento de 0.842.




Figura 13: Arquitetura da Rede Neural (GOLODOV; MITTSEVA, 2019).

No artigo do Wenhui Hou et al. (HOU et al., 2018), foi proposto um sistema offline para detecção automática de defeitos de solda em imagens radiográficas. Para o pré-processamento da imagem são utilizados os métodos de Otsu (OTSU, 1979) e Threshold (WESZKA, 1978). Para classificar se a imagem possui ou não defeito, é utilizada uma rede neural convulacional, treinada com 88 imagens do banco de dados público GDXray (MERY et al., 2015), obtendo uma precisão de 0.918. A Figura 14 apresenta o fluxograma do sistema.




Figura 14: Fluxograma Geral do Modelo Proposto (HOU et al., 2018).

No estudo de Yaping e Weixin (YAPING; WEIXIN, 2019), propõe-se o uso da rede neural convolucional para identificação offline de defeitos de soldagem em imagens radiográficas. A classificação é realizada sem o pré-processamento da imagem, onde a rede foi treinada com 1740 imagens, e a precisão pode chegar a 0.988 depois da quinta iteração. Na Figura 15 é mostrada a arquitetura da rede.




Figura 15: Arquitetura da Rede (YAPING; WEIXIN, 2019).

No trabalho de Mera et al. (MERA et al., 2016), é realizada inspeção visual offline em imagens digitais de cordão de solda. Para o pré-processamento da imagem é utilizado o método de histograma e a classificação é feita utilizando método MIL (DIETTERICH; LATHROP; LOZANO-PÉREZ, 1997), onde foram utilizadas um conjunto de dados com 500 amostras da base de dados W0001 do GRIMA. O modelo do método proposto é

mostrado na Figura 16.

Treinando




Figura 16: Modelo do Método (MERA et al., 2016).

O estudo de Bacioiu et al. (BACIOIU et al., 2019), investiga um sistema offline para avaliar a soldagem com a utilização de redes neurais artificiais para processamento das imagens digitais. Os tipos de defeitos classificados foram porosidade, inclusão de escória, falta de fusão, desalinhamento e falta de penetração. A análise envolveu a construção de um modelo baseado na rede neural convulacional e rede neural totalmente conectada, conforme Figura 17, a rede foi treinada com 33254 imagens próprias e obteve uma precisão de até 0.95.




Figura 17: Rede (BACIOIU et al., 2019).

O trabalho de Zhang et al. (ZHANG; WEN; CHEN, 2019) estudou técnicas para detecção de defeitos em imagens digitais de cordão de solda. O sistema é capaz de detectar

defeitos de porosidade e falta de penetração, utilizando 3 orientações de imagem, frontal, superior e traseira. Com a utilização de redes neurais convolucionais e uma precisão média de 0,993, foi possível detectar defeitos durante o processo de soldagem. A estrutura da rede neural convulacional foi projetada conforme a estrutura da Figura 18, e treinada com 3810 imagens.




Figura 18: Rede (ZHANG; WEN; CHEN, 2019).

No trabalho de Goumeidane et al. (GOUMEIDANE et al., 2015), é investigado o uso da Rede Bayesiana no escopo de classificação offline de defeitos de solda em imagens radiográficas. Foram utilizadas 344 imagens de defeitos de solda fornecidas pelo Instituto Internacional de Soldagem, onde foram pré-processadas utilizando os métodos de interpolação polinomial splines cúbica e filtro gaussiano. Os defeitos de solda detectados são porosidade, inclusão de escória, falta de fusão, trica e falta de penetração. Os resultados são muito promissores para uma aplicação sensível, apesar da simplicidade da estrutura do classificador usado.

No artigo de Moghaddama e Rangarajan (MOGHADDAM; RANGARAJAN, 2016), é descrito um sistema automático para classificação de defeitos de soldagem a partir de imagens radiográficas. A classificação é realizada após o processo, e são identificados os defeitos de falta de penetração, falta de fusão e porosidade, onde foram utilizadas uma quantidade de imagens dos tipos de defeitos de 816, 566 e 379, respectivamente. O pré-processamento da imagem utiliza os métodos de filtro esquerdo bidimensional e thresholds. O método proposto foi comparado com os métodos de SVM e KNN (K-Nearest Neighbors) (DUDA; HART et al., 1973), e obteve resultados melhores de classificação, com reconhecimento de 98% das imagens com defeito.

No trabalho de Liu et al. (LIU et al., 2017), foi proposta uma estrutura com rede neural convulacional para classificar defeitos de soldagem em imagens radiográficas. A rede obteve uma precisão de 0.976 com um conjunto de dados de 3000 imagens do banco de dados GDXray. A classificação é utilizada após a soldagem e detecta defeitos de inclusão de escória e trinca. A estrutura da rede é mostrada na Figura 19.



Figura 19: Rede (LIU et al., 2017).

No trabalho de Gonzales et al. (GONZALEZ-VAL et al., 2019), apresenta uma abordagem para localização de defeitos em processos de soldagem com imagem termográfica. A abordagem detecta em tempo real os defeitos de porosidade e falta de deposição, determinando sua posição, tamanho e comprimento. O método de classificação utiliza rede neural convulacional, que foi treinada com 160000 imagens, e obteve uma precisão de 0.975. A Figura 20 mostra a estrutura da rede.




Figura 20: Rede (GONZALEZ-VAL et al., 2019).

O trabalho de Guo et al. (GUO; HUANG; LIANG, 2018), utiliza rede neural convolucional para classificar se imagens radiográficas possuem defeitos. No pré-processamento das imagens é utilizado o método de Thresholds. A classificação é realizada após a soldagem, onde a rede foi treinada com 13006 imagens. Esse trabalho avaliou a sensibilidade do método a presença ou não de pré-processamento, e concluiu que com pré-processamento obteve melhor resultado.

O artigo de Wang et al. (WANG; SHI; TONG, 2019), propõe uma abordagem offline adotando uma rede neural convolucional para identificar automaticamente defeitos de soldagem em imagens radiográficas. Os tipos de defeitos detectados são porosidade, falta de penetração e inclusão de escória, as precisões dos defeitos são de 0.76, 0.79 e 0.92, respectivamente. A rede foi treinada com 6714 imagens obtidas tanto do banco de dados GDXray, quanto de uma empresa de soldagem, sua arquitetura é mostrada na Figura 21.




Figura 21: Rede (WANG; SHI; TONG, 2019).

No artigo de Park et al. (PARK; AN; KANG, 2019), é proposto um método baseado em rede neural convolucional que inspeciona defeitos de soldagem não padronizados utilizando uma câmera digital. Os defeitos são detectados após o processo de soldagem e o método consegue classificar os tipos de defeitos de trinca, porosidade e inclusão de escória. A rede foi treinada com 32014 imagens obtidas no próprio estudo.

No artigo de Nagata et al. (NAGATA et al., 2019), é introduzido um método de detecção de defeitos de solda em imagens digitais, utilizando redes neurais convolucionais e SVM. Os tipos de defeitos de solda detectados são trincas e porosidades. A rede foi treinada com 3000 imagens e sua estrutura é mostrada na Figura 22.




Figura 22: Rede (NAGATA et al., 2019).

Em (FERNÁNDEZ-ISLA; NAVARRO; ALCOVER, 2013) é proposto um algoritmo utilizando a Transformada de Wavelet com aplicação da Entropia de Shannon, com objetivo de reduzir os ruídos e evitar degradar as imagens, permitindo segmentar as falhas apresentadas na textura dos cascos dos navios (como a corrosão) e após é aplicada a técnica de binarização. Este algoritmo foi aplicado em um conjunto de 120 imagens (com e sem falhas na textura) de cascos de navios onde 6,8% apresentaram falsos positivos, ou seja, algoritmo detectou uma falha onde não havia e 0,9% apresentaram falsos negativos, são imagens que tinham alguma falha e o algoritmo não detectou. Os autores afirmam que os resultados em relação à confiabilidade foram muito semelhantes aos alcançados com inspetores, porém a inspeção foi realizada em um tempo bem menor do que por um humano e ainda minimiza a fadiga do operador.

Já em (BONNÍN-PASCUAL; ORTIZ, 2010) são apresentadas quatro técnicas diferentes. A primeira é um algoritmo que se propõe a identificar rachaduras, definido como Percolation - based Crack Detector (PCD) o objetivo é identificar conjuntos de píxeis escuros, estreitos e alongados, que são rotulados como rachaduras. Assim, é configurado um limiar com o nível de cinza desejado para a identificação destes píxeis e o algoritmo percorre regiões das imagens para identificar esses píxeis. No final do processo de percolação, o nível médio de escala de cinza do conjunto de píxeis é verificado para determinar se está escuro o suficiente para ser considerado como uma rachadura. Caso contrário, o conjunto de píxeis é rejeitado e nada é marcado na imagem. Por fim, o algoritmo analisa 15 imagens e identifica se encontra ou não rachaduras nas mesmas. Os resultados apresentados são

2,29% para falsos positivos e 0,47% para falsos negativos.

A segunda técnica é denominada de Colour-based Corrosion Detector (CCD) a abordagem deste algoritmo visa identificar a corrosão utilizando um esquema de classificação supervisionado. O classificador utiliza um dicionário onde cada palavra consiste em histogramas empilhados para os canais de cores vermelho, verde e azul de amostras de imagens contendo diferentes tipos de ferrugem. Amostras de diferentes tipos de corrosão foram coletadas de 30 imagens metálicas. Para tornar o dicionário mais compacto, as palavras de código foram agrupadas, independentemente do tipo de ferrugem, por meio do algoritmo Kmeans. O tamanho do dicionário para cada tipo de corrosão, ou seja, o número de modelos, é determinado pelo número de clusters selecionados durante o processo de agrupamento. Após a construção do dicionário, o detector de corrosão continua a digitalização da imagem e classifica cada patch da imagem como afetado por corrosão ou não. Outro fator que o algoritmo leva em consideração é a rugosidade apresentada na imagem, pois quanto maior o valor da rugosidade é sinal que a imagem apresenta uma maior corrosão, esse parâmetro inserido no algoritmo é ajustável. O algoritmo foi testado em 11 imagens e o número de classificações incorretas apresentado é abaixo de 10% para os falsos positivos e cerca de 18% para os falsos negativos.

A terceira técnica é Weak-classifier Colour-based Corrosion Detector (WCCD), assim como o CCD, o novo classificador foi construído em torno de um esquema em cascata, embora os dois estágios do novo detector de corrosão possam ser considerados dois classificadores fracos. O primeiro estágio da cascata é o estágio de rugosidade igual ao realizado no CCD. Esse estágio retorna as amostras de imagens que apresentam uma textura rugosa. O segundo estágio opera sobre os píxeis dos patches da imagem que passaram no estágio de rugosidade. Diferentemente do primeiro, esse estágio utiliza as informações de cores que podem ser observadas em áreas corroídas. O classificador trabalha no espaço Hue-Saturation-Value (HSV) após perceber que os valores HSV que podem ser observados em áreas corroídas estão confinados em um subespaço delimitado do plano HS. Embora o componente V não tenha sido observado nem significativo para descrever a cor da corrosão, ele é usado para evitar instabilidades conhecidas no cálculo de matiz e saturação quando a cor está próxima de branco ou preto. Nesse caso, o pixel é classificado como não corroído. Uma etapa de treinamento é realizada antes da aplicação deste segundo estágio do classificador de corrosão. O treinamento consiste em criar um histograma bidimensional dos valores de HS para píxeis de imagem que são afetados pela corrosão no conjunto das imagens de treinamento. O algoritmo foi submetido a testes com as mesmas 11 imagens que foram testadas no CCD e apresentou porcentagens de falsos positivos e falsos negativos da mesma ordem que as porcentagens obtidas com o primeiro método. No entanto, o tempo de execução foi consideravelmente reduzido.

A última técnica é o algoritmo Guided Percolation-based Crack Detector (GPCD), que combina os algoritmos WCCD com a estratégia do PCD baseada em percolação.

Os autores afirmam, após análises e testes, que a maioria das rachaduras nas superfícies metálicas aparece em áreas corroídas. Portanto, uma detecção de corrosão bem-sucedida pode ser usada para orientar a localização de rachaduras na imagem. Para implementar a detecção guiada de trincas, a condição inicial que inicia uma percolação foi modificada para que comece em um determinado pixel somente se ele for rotulado como corroído, ou seja, o algoritmo começa a procurar trincas/rachaduras somente nas áreas das imagens que contém corrosão. O tempo de execução foi menor que nos outros algoritmos e os valores para as porcentagens de falso positivo e falso negativo são de 0,72% e 0,57%, respectivamente.

Em relação aos métodos de restauração de imagem, um dos principais problemas enfrentados para realizar a remoção da degradação, é estimar o mapa de transmissão do meio para uma dada imagem degradada. Com isso, ambos os trabalhos (CAI et al., 2016), (REN et al., 2016) e (OLIVEIRA GAYA et al., 2019) utilizam-se de CNNs para estimar o mapa de transmissão da imagem, e assim recupera-lá utilizando modelo tradicional. Esses métodos são capazes de aprender heurísticas mais complexas, que os humanos não conseguiriam perceber, podendo levar a melhores resultados de restauração em uma gama mais ampla de situações.

De acordo com a análise dos estudos selecionados na RSL, a utilização de redes neurais pode ser uma potencial vantagem para classificação de descontinuidades no cordão de solda, além disso, a aplicação de técnicas de visão computacional, como Thresholds, filtro Gaussiano e Histograma, podem aumentar a precisão de detecção dessas descontinuidades.

O uso de imagens digitais e radiográficas apresentaram resultados relevantes nas pesquisas, sendo necessária uma avaliação comparativa para determinar qual é a mais apropriada para essa pesquisa.

Apenas os trabalhos de Zhang et al. (ZHANG; WEN; CHEN, 2019) e Gonzales et al. (GONZALEZ-VAL et al., 2019) apresentaram a identificação e classificação de descontinuidades durante o processo de soldagem, isso devido ao custo computacional, o que pode trazer imprecisão para os resultados, portanto a classificação e identificação de descontinuidades após o processo de soldagem garantem maior precisão nos resultados.

Nenhum dos trabalhos envolveu o tratamento de imagens subsea. Efeitos da *turbidez* não foram abordados em nenhum trabalho da revisão realizada. No entanto, a área de reconstrução de imagens subsea aborda nos últimos 10 anos muitas pesquisas relacionadas. Métodos baseados em modelos físicos estão sendo ultrapassados por abordagens baseadas em aprendizado profundo. Com base neste levantamento, apresenta-se a seguir os principais conceitos e algoritmos que serão utilizados nesta proposta.

Com base na revisão bibliográfica realizada definiu-se mais claramente o escopo do problema e seus desafios. A revisão bibliográfica confirma que o problema de inspeção visual de processos de soldagem subsea é atual e técnicas de aprendizagem profunda estão sendo utilizadas na reconstrução.

2.3 Referencial Teórico

Nesta seção serão abordados os principais conceitos e algoritmos utilizados neste trabalho. Como a proposta envolve o uso de algoritmos de visão computacional para classificação e o tratamento de imagens subsea, este referencial teórico estará limitado a este escopo.

2.3.1 Visão Computacional para Detecção de Descontinuidades de Textura em Cordões de Solda

A proposta desta dissertação visa avaliar e adaptar o trabalho de (SOARES et al., 2019) para ambiente subsea. O trabalho de (SOARES et al., 2019) apresenta um sistema de visão computacional baseado em uma câmera monocular passiva para análise de texturas de cordões de solda. Uma imagem é capturada com uma vista superior do cordão de solda, e depois processado para análise. O diagrama da Figura 23 ilustra as duas etapas, treinamento e inferência, do método proposto para identificação de texturas. A etapa de treinamento é realizado com o uso de aprendizado de máquina, aprende-se as características das superfícies com e sem texturas irregulares. Posteriormente, o método treinado é aplicado em novas imagens para validação dos resultados.




Figura 23: Diagrama do método de identificação de textura proposto por (SOARES et al., 2019).

2.3.2 Tratamento de Imagens Subsea

2.3.2.1 A Turbidez em Imagens Subsea

A interação dos raios de luz com as partículas presentes no meio causam degradação em imagens subaquáticas (DUNTLEY, 1963). Um termo comumente utilizado relacionado a esses fenômenos é *turbidez*. *Turbidez* é uma propriedade comum no meio aquático que está relacionada com a quantidade de luz que é absorvida ou espalhada ao invés de ser transmitida em uma linha reta (BIN OMAR; BIN MATJAFRI, 2009).

Algoritmos de processamento de imagens são amplamente utilizados para melhorar a qualidade de imagens degradadas pela interação dos raios com as partículas suspensas no ambiente. Esses métodos são chamados de métodos de restauração de imagens. Um dos grandes problemas enfrentados para criação de métodos robustos de restauração de imagens se dá pela dificuldade de estimativa dos parâmetros do ambiente. Diferentes meios possuem propriedades específicas, como a diferença de cor, diferentes partículas presente no meio, dentro outros, precisando ser estimado diferentes parâmetros para cada tipo de ambiente.

2.3.2.2 Redes Encoder-Decoder para Reconstrução de Imagens

A restauração de imagens subaquáticas representa um desafio para visão computacional e processamento de imagens baseada redes neurais, dadas a complexidade na remoção da *turbidez* da água e a carência de imagens pareadas (datasets). No trabalho de (MELLO et al., 2020), é apresentado e testado um algoritmo para a restauração de imagens subaquáticas, utilizando aprendizado não-supervisionado. Empregando arquitetura encoder-decoder, o algoritmo utiliza durante o treinamento o bloco de degradação para reforçar a degradação na saída da rede. As imagens de entrada e saída degradada são utilizadas na função de perda, produzindo uma correção na saída da rede. O trabalho se destina a inspeção de estruturas e objetos submersos, como casco e navios, cabos, dutos, sistemas de ancoragem, etc.

A descrição conceitual do método é indicado na Figura 24. Uma imagem real degradada de entrada I , é codificada pelo encoder G_E e gera uma codificação latente Y e o decoder G_D produz uma versão decodificada e similar à imagem de entrada, $\hat{I}$. O bloco de degradação B é inserido no treinamento da rede e tem o objetivo de produzir a degradação que se deseja corrigir. A minimização da diferença entre a imagem de entrada (degradada) e a com degradação adicional (via loss), produz a redução na degradação na imagem de saída $\hat{I}$. A rede neural implementada é mostrada na Figura 25. São utilizados dois pipelines no encoder para maior diversificação na extração de features de alto e baixo níveis. São empregadas *skip connections* entre o encoder e o decoder, sendo utilizadas para reforço na reconstrução da imagem.




Figura 24: Diagrama conceitual do método (MELLO et al., 2020).




Figura 25: Arquitetura da rede neural (MELLO et al., 2020).

As imagens apresentadas nas Figura 26 correspondem às imagens originais, saídas restauradas e entrada com degradação para $\gamma=3$ e $\gamma=1/3$, respectivamente. A observação mostra que a rede realizou a restauração para as degradações propostas, com qualidade visual satisfatória. Há um leve clareamento nas imagens de saída, dado pela perda de informação, dado que a reconstrução não é perfeita.




Figura 26: Linha superior: imagens originais, meio: imagens de entrada com gama alterado e linha inferior: imagens restauradas: (a) Imagens para $\gamma = 3$ (b) Imagens para $\gamma = 1/3$ (MELLO et al., 2020).

3 METODOLOGIA

O objetivo principal desta dissertação é avaliar o efeito da *turbidez* na inspeção visual de textura utilizando visão computacional. Para tal a metodologia proposta é baseada em duas etapas:

- a) Avaliação em ambiente controlado da influência da *turbidez* nos métodos de identificação de falhas;
- b) Proposta de um modelo que trate a *turbidez* de forma a permitir a detecção automática de falhas.

A seguir descreve-se cada uma das etapas da metodologia.

3.1 Avaliação da *Turbidez* na Inspeção de Textura em Cordões de Solda

Com base no levantamento bibliográfico realizado e nas pesquisas do grupo NAUTEC, optou-se por utilizar o trabalho de (DUARTE et al., 2016) como base para análise do efeito da *turbidez*. Os resultados obtidos neste trabalho o colocam como uma das propostas em nível de estado da arte no tema.

Assim, propõe-se um experimento no qual o nível de *turbidez* da água é controlado e variado continuamente. A cada variação os algoritmos para inspeção de textura são aplicados e avaliados quanto sua sensibilidade a variação.

As próximas seções detalham a metodologia proposta para controle da *turbidez* e os algoritmos avaliados.

3.1.1 Organização e composição do cenário e estrutura

Busca-se estabelecer uma metodologia capaz de fornecer um setup para o experimento adequado para avaliar algoritmos de visão na inspeção de textura em cordões de solda imersos em ambientes subaquáticos. A proposta é baseada no trabalho de (DUARTE et al., 2016) o qual apresenta um método com o uso de leite para turvar a água em tanque imageado por câmera superior, a Figura 27 apresenta o aumento da *turbidez* conforme adição de leite.




Figura 27: Imagens do trabalho de (DUARTE et al., 2016).

Para a composição do experimento propõe-se o uso de um recipiente com tamanho de 500 litros, onde insere-se na posição vertical um corpo de prova de metal com chanfro do tipo V já soldado, e duas lâmpadas *Light Emitting Diode* (LED) de 9,5 Watts e 6500 *kelvins*, equivalente a luz branca conforme Figura 28. O cordão de solda apresenta dois tipos de textura: metade com textura regular, considerada aprovada pelos profissionais de soldagem e metade com textura irregular ocasionada por alguma alteração do processo, como por exemplo, falta de gás de proteção. Uma câmera é posicionada a 10 cm de distância do corpo de prova para captura das imagens, simulando a distância de um ROV ou de um mergulhador.




Figura 28: Cenário do experimento.

3.1.2 Adição de leite integral para produção de *turbidez* na água

Devido a *turbidez*, as imagens subaquáticas apresentam qualidade visual reduzida, tipo de coloração diferenciada, baixo contraste e iluminação não uniforme, o que ocasionam na obscuridade da cena, ou imagem capturada (HOU; WEIDEMANN, 2007; MAHIDDINE et al., 2012).

Conforme (DUARTE et al., 2016), opta-se pelo uso do leite integral, o qual é comprovado que possui partículas que provocam o espalhamento grande angular da luz em ambientes subaquáticos. A tabela 14 apresenta a quantidade de leite adicionada a cada ensaio para simular 19 níveis de *turbidez*. A quantidade de leite adicionada em cada etapa foi previamente avaliada em pequena escala no trabalho de (DUARTE et al., 2016), onde foi possível definir a quantidade necessária a ser diluída em 500 litros de água utilizada nesse trabalho.

Tabela 14: Quantidade de leite integral adicionado a cada captura de imagem. A primeira coluna descreve o identificador da imagem. A segunda coluna descreve a quantidade de leite adicionado. A terceira coluna mostra a quantidade total de leite diluído em 500 litros de água.

Imagem (I_i)	Quantidade adicionada de leite (ml)	Quantidade total de leite (ml)
I_1	2,5	2,5
I_2	2,5	5
I_3	2,5	7,5
I_4	2,5	10
I_5	2,5	12,5
I_6	2,5	15
I_7	3	18
I_8	3	21
I_9	4	25
I_{10}	4	29
I_{11}	4	33
I_{12}	4	37
I_{13}	4	41
I_{14}	4	45
I_{15}	5	50
I_{16}	5	55
I_{17}	5	60
I_{18}	5	65
I_{19}	30	95

3.1.3 Aquisição das Imagens

Foram adquiridas 19 imagens em ambiente subaquático com níveis de degradação diferentes devido a adição de leite a cada captura, totalizando 95 ml de leite no recipiente. A única propriedade que muda entre as cenas está na degradação da imagem devido a *turbidez*, para minimizar outros fenômenos possíveis nas imagens. As imagens podem ser visualizadas na Figura 29, onde é possível verificar 19 níveis de *turbidez*. O cordão de solda escolhido para o experimento tem uma parte de textura irregular, pois o gás de proteção foi desligado propositalmente no processo para obter as irregularidades. A região da imagem destacada no retângulo vermelho é onde o método deve identificar anomalias, essa região é onde a textura do cordão de solda é irregular de acordo com os inspetores de soldagem. A câmera utilizada para captura das imagens é uma GoPro HERO 6 Black modelo CHDHX-601.




Figura 29: Conjunto de dados obtido no experimento com os 19 níveis de *turbidez* simulados.

3.2 Método para avaliação da *turbidez* no desempenho de visão computacional para inspeção de textura em cordões de solda

Nesta etapa é proposto averiguar a sensibilidade dos métodos de visão computacional frente a diferentes níveis de *turbidez* produzidos no experimento anterior no que tange a identificação das irregularidades na textura de um cordão de solda. Se distinguirá um cordão de solda que sofreu alguma alteração do processo, como: falta de gás de proteção, problemas na fonte de alimentação ou erro de parametrização pelo operador.

O processo de soldagem com arame tubular (FCAW) proporciona a união de metais

pela fusão destes por meio do aquecimento promovido pelo arco elétrico estabelecido entre a ponta do arame e a peça de trabalho. A proteção da poça de fusão e do arco elétrico é feita pelo gás de proteção, para obter uma solda com textura irregular foi desligado o gás de proteção durante o processo de soldagem. Na Figura 30 pode-se verificar a diferença de um cordão para outro. Pode-se observar que a textura do cordão que não sofre nenhuma ocorrência é uniforme, já a textura do cordão que o processo apresentou algum desequilíbrio, se mostra visivelmente rugosa e irregular.




Figura 30: a) Imagem com textura sem irregularidades. b) Imagem com textura irregular.

3.2.1 Treinamento

Deve-se selecionar um conjunto de imagens para treinamento dos métodos. No caso da análise foram tiradas 15 imagens de cordões de solda, sendo 11 imagens com textura irregular e 4 imagens com textura regular, as quais foram particionadas em regiões de 100×100 pixels, resultando em 18000 patches para treinamento. Através do aplicativo *Classification Learner* do *software* Matlab foram testados 23 classificadores e após a avaliação dos resultados, foi escolhido o classificador SVM, do inglês, *Support Vector Machines* o qual apresentou a maior precisão, 97,6% para as amostras testadas. É importante destacar que o conjunto de dados utilizado para o treinamento é composto por imagens fora do ambiente subaquático, com o objetivo de dar mais detalhes da textura ao classificador, e também imagens dentro do ambiente subaquático para que o classificador aprenda os detalhes do ambiente participativo. As imagens para treinamento são separadas em duas classes, a classe 0 onde o cordão de solda apresenta uma textura regular e classe 1 onde o cordão de solda apresenta uma textura irregular. As bordas marcadas manualmente são adicionadas à essas imagens para delimitar a região que será analisada.

Logo após, é aplicado o Principal Component Analysis (PCA) com um total de 100 componentes. Com o objetivo de realizar uma transformação linear das amostras para um espaço dimensional menor e extrair as características mais importantes, mantendo a maior

parte destas informações. Sendo assim, é iniciado o treinamento do SVM.

3.2.2 Inspeção de Textura

Após o treinamento do classificador, a etapa de inspeção, que consiste em realizar a classificação da textura em novas imagens, é então iniciada. Para esta etapa foram selecionadas as imagens com os 19 níveis de *turbidez*. As imagens são divididas em segmentos de 100×100 pixels, a Figura 31 apresenta exemplos desses segmentos.




Figura 31: Exemplos de segmentos de 100×100 pixels de uma imagem de um cordão de solda.

As regiões de cada imagem são verificadas pelo classificador, o qual realiza uma marcação na imagem quando encontra uma textura de classe 1, ou seja, com irregularidade. A Figura 32 apresenta o resultado da inspeção para os 19 níveis de *turbidez*.




Figura 32: Resultado da inspeção de textura aplicada nos 19 níveis de *turbidez*.

A tabela 16 apresenta o resultado da inspeção de forma mais detalhada, com os dados de verdadeiro positivo, quando o método marca a textura irregular de forma correta, falso positivo, quando o método falha na marcação da textura regular como irregular, verdadeiro negativo, quando o método acerta em não marcar uma textura regular, falso negativo, quando o método não marca uma textura irregular, e por fim, a acurácia de cada inspeção.

Tabela 15: Resultado da inspeção de textura do cordão de solda com 19 níveis de *turbidez*.

Imagem (I_i)	Verdadeiro Positivo	Falso Positivo	Verdadeiro Negativo	Falso Negativo	Acurácia
I_1	43%	8%	44%	5%	87%
I_2	35,5%	3%	49%	12,5%	84,5%
I_3	36%	2%	50%	12%	86%
I_4	33%	3%	49%	15%	82%
I_5	24%	0,5%	51,5%	24%	75,5%
I_6	21%	0%	52%	27%	73%
I_7	22%	0%	52%	26%	74%
I_8	17,5%	0%	52%	30,5%	69,5%
I_9	18,5%	0%	52%	29,5%	70,5%
I_{10}	15%	0%	52%	33%	67%
I_{11}	13%	0%	52%	35%	65%
I_{12}	14%	0%	52%	34%	66%
I_{13}	13,5%	0%	52%	34,5%	65,5%
I_{14}	11,5%	0%	52%	36,5%	63,5%
I_{15}	13%	0%	52%	35%	65%
I_{16}	12,5%	0%	52%	35,5%	64,5%
I_{17}	11,5%	0%	52%	36,5%	63,5%
I_{18}	9%	0%	52%	39%	61%
I_{19}	5,5%	0%	52%	42,5%	57,5%

Nos gráficos abaixo é observado o comportamento do método de acordo com a *turbidez* nas imagens.




Figura 33: Gráfico verdadeiro positivo.




Figura 34: Gráfico falso positivo.




Figura 35: Gráfico verdadeiro negativo.




Figura 36: Gráfico falso negativo.




Figura 37: Gráfico acurácia.

Através dos gráficos consegue-se analisar que a maior influência da perda da acurácia do classificador é em função dos falsos negativos, ou seja, quando as amostras são classificadas com a classe 0 (textura regular) onde na verdade o correto é serem classificadas com a classe 1 (textura irregular). O próximo passo é diminuir esse erro, utilizando redes neurais para reconstrução das imagens.

3.3 Tratamento da *Turbidez* para Inspeção Visual de Cordões de Solda

Percebe-se que a medida que a água torna-se mais turva, os algoritmos de detecção de falhas degradam o seu desempenho. O efeito da *turbidez* reduz o contraste da imagem, além de adicionar a névoa, própria deste tipo de ambiente. Desta forma, perde-se informação de textura e cor, importantes para detecção de falhas.

Nesta dissertação propõe-se um modelo que adiciona uma etapa de pré-processamento capaz de tratar a *turbidez*, a partir da reconstrução da imagem subaquática de entrada.

A Figura 38 apresenta um *overview* da proposta. A imagem turva de entrada é apresentada a uma rede de reconstrução treinada para atenuar a *turbidez* da imagem. Uma vez reconstruída a imagem é apresentada ao algoritmo de classificação já utilizado nas seções anteriores.



Figura 38: Diagrama da proposta.

3.3.1 Rede de Reconstrução

Para a implementação do módulo de reconstrução propõe-se o uso de uma rede encoder-decoder (MELLO et al., 2020).

A rede foi descrita na seção 2.3.3.2, onde foi treinada nas seguintes condições:

- Dataset: 1175 imagens
- Split dos dados: 80% (treino – 70% + validação – 10%), 20% teste
- Configuração: i5-6400 – 32GB RAM – GPU Titan X
- Treino: 1000 épocas, Batch size = 8
- Avaliação: dataset adicional com 47 imagens, não utilizadas no treinamento
- Ponderação dos termos da loss: $k_1 = 0.17$; $k_2 = 0.03$; $k_3 = 0.67$ e $k_4 = 0.13$ que correspondem a (20% cena: 80% imagem; 85% YUV: 15% HSV)
- Loss = 0.0196; validation loss = 0.0194

A Figura 39 apresenta os resultados da restauração obtida pela rede descrita.




Figura 39: Resultado da restauração.

Percebe-se que a rede reconstrói a imagem, reduzindo o efeito da *turbidez*, na Figura 40 é apresentando a reconstrução dos 19 níveis de *turbidez* utilizados anteriormente.




Figura 40: Resultado da rede de reconstrução para os 19 níveis de *turbidez*

Com o resultado da reconstrução é realizado a inspeção de textura e comparado com inspeção das imagens antes da reconstrução. A Figura 41 apresenta a inspeção de textura das imagens após a reconstrução.




Figura 41: Inspeção das imagens após a reconstrução.

A tabela 16 apresenta os resultados de forma mais detalhada da inspeção de textura da imagens após a reconstrução.

Tabela 16: Resultado da inspeção de textura do cordão de solda com 19 níveis de *turbidez* após a reconstrução.

Imagem (I_i)	Verdadeiro Positivo	Falso Positivo	Verdadeiro Negativo	Falso Negativo	Acurácia
I_1	32%	0%	52%	16%	84%
I_2	33,5%	0%	52%	14,5%	85,5%
I_3	34%	0%	52%	14%	86%
I_4	33,5%	0%	52%	14,5%	85,5%
I_5	35%	0%	52%	13%	87%
I_6	35,5%	0%	52%	12,5%	87,5%
I_7	34%	0%	52%	14%	86%
I_8	33,5%	0%	52%	14,5%	85,5%
I_9	34,5%	0%	52%	13,5%	86,5%
I_{10}	32,5%	0%	52%	15,5%	84,5%
I_{11}	34,5%	0%	52%	13,5%	86,5%
I_{12}	32,5%	0%	52%	15,5%	84,5%
I_{13}	36%	0%	52%	12%	88%
I_{14}	34%	0%	52%	14%	86%
I_{15}	33,5%	0%	52%	14,5%	85,5%
I_{16}	35,5%	0%	52%	12,5%	87,5%
I_{17}	35%	0%	52%	13%	87%
I_{18}	33,5%	0%	52%	14,5%	85,5%
I_{19}	34,5%	0%	52%	13,5%	86,5%

Para comparar as inspeções das imagens antes e depois da reconstrução, foram plotados os gráficos dos resultados.




Figura 42: Gráfico de comparação do verdadeiro positivo.




Figura 43: Gráfico de comparação do falso positivo.




Figura 44: Gráfico de comparação do verdadeiro negativo.




Figura 45: Gráfico de comparação do falso negativo.




Figura 46: Gráfico de comparação da acurácia.

Na Figura 46 é possível observar que a acurácia da inspeção com as imagens após a reconstrução tiveram um resultado parecido em todos os níveis de *turbidez*. O resultado é obtido devido aos falsos negativos, conforme é possível observar na Figura 45, que não aumentam conforme o nível de *turbidez*. Com isso a rede de reconstrução resultou em um melhor desempenho nas imagens com o nível de *turbidez* mais elevado.

4 CONCLUSÃO

A inspeção de textura no cordão de solda é uma tarefa crucial para as estruturas subseas. Pequenos defeitos tem um impacto econômico significativo e podem representar riscos ao meio ambiente. Devido a insalubridade de métodos visuais, métodos computacionais de inspeção visual podem ser uma interessante alternativa.

Trabalhos anteriores propuseram métodos usando visão computacional para inspeção de cordões de solda. O trabalho de (SOARES et al., 2019) apresenta um sistema de visão computacional capaz de identificar irregularidades nas texturas dos cordões de solda utilizando uma câmera acoplado a um robô de soldagem em ambiente industrial. O objetivo desta dissertação foi averiguar a influência da *turbidez* neste método em ambientes subsea, adicionando uma etapa de restauração da imagem com redes encode-decoder antes da inspeção, onde foi utilizado como referência o trabalho de (MELLO et al., 2020) para restauração da imagem. Os principais conceitos para essa dissertação foi apresentado no referencial teórico.

Foi realizada uma análise da sensibilidade do trabalho de (SOARES et al., 2019) a *turbidez*. Neste contexto foi utilizado a metodologia do trabalho de (DUARTE et al., 2016) para reprodução de ambientes subaquáticos simulando diferentes níveis de *turbidez*.

Foi apresentado um modelo de inspeção visual capaz de tratar a *turbidez* a partir do pré-processamento com reconstrução da imagem.

Sendo assim os resultados das inspeções de texturas nos cordões de solda cobriram a diversidade de degradações decorrentes da *turbidez*. Logo os objetivos propostos neste trabalho foram alcançados. Posteriormente, etapas futuras serão executadas como:

- Inspeção em ambientes subseas reais utilizando uma câmera acoplada a um ROV;
- Classificação dos tipos de descontinuidades encontrados na inspeção visual de soldagem;

Durante o desenvolvimento desse trabalho destaca-se a publicação do artigo (BALDEZ et al., 2020) A Passive Vision System for Weld Bead Inspection System Textures in Underwater Environments.

REFERÊNCIAS

AMER, A.; ABDELLATIF, F.; OUTA, A.; TRIGUI, H.; PATEL, S.; OBEDAN, A.; LEDEZMA, F. D.; AL SAIARI, H.; TAIE, I. Survey of Underwater NDT Technologies for Offshore Assets. , [S.l.], 2015.

ANDREUCCI, R. Aspectos industriais: Proteção radiológica. **Associação Brasileira de Ensaios Não Destrutivos (ABENDI)**, [S.l.], 2013.

BACIOIU, D.; MELTON, G.; PAPAELIAS, M.; SHAW, R. Automated defect classification of Aluminium 5083 TIG welding using HDR camera and neural networks. **Journal of Manufacturing Processes**, [S.l.], v.45, p.603–613, 2019.

BALDEZ, P.; SOARES, L.; DEBIAZE, D.; BOTELHO, S.; NAGEL, R.; ESPÍNDOLA, D. A Passive Vision System for Weld Bead Inspection System Textures in Underwater Environments. In: LATIN AMERICAN ROBOTICS SYMPOSIUM (LARS), 2020 BRAZILIAN SYMPOSIUM ON ROBOTICS (SBR) AND 2020 WORKSHOP ON ROBOTICS IN EDUCATION (WRE), 2020., 2020. **Anais...** [S.l.: s.n.], 2020. p.1–6.

BARBEDO, N. D. D. Avaliação comparativa dos processos de soldagem GMAW e FCAW utilizando aço ASTM A-36 para verificar a soldabilidade, propriedades metalúrgicas e geométricas, e resistência mecânica. , [S.l.], 2011.

BERMAN, D.; LEVY, D.; AVIDAN, S.; TREIBITZ, T. Underwater single image color restoration using haze-lines and a new quantitative dataset. **IEEE transactions on pattern analysis and machine intelligence**, [S.l.], 2020.

BIN OMAR, A. F.; BIN MATJAFRI, M. Z. Turbidimeter design and analysis: a review on optical fiber sensors for the measurement of water turbidity. **Sensors**, [S.l.], v.9, n.10, p.8311–8335, 2009.

BONNÍN-PASCUAL, F.; ORTIZ, A. Detection of Cracks and Corrosion for Automated Vessels Visual Inspection. In: CCIA, 2010. **Anais...** [S.l.: s.n.], 2010. p.111–120.

BRACARENSE, A. Q.; BASTOS FILHO, T.; FELIZARDO, I.; ROGANA, W. Soldagem Robotizada. **Robótica Industrial. Aplicação na Indústria de Manufatura e de Processos.** São Paulo: Edgard Blücher. cap, [S.l.], v.8, p.139–155, 2002.

CAI, B.; XU, X.; JIA, K.; QING, C.; TAO, D. Dehazenet: An end-to-end system for single image haze removal. **IEEE Transactions on Image Processing**, [S.l.], v.25, n.11, p.5187–5198, 2016.

CORREA, C. A.; MASTELARI, N.; MORENO, J. R. S. Effect of welding parameters in flux core arc welding (FCAW) with conventional and pulsed current in the efficiency and fusion rate of melting coating. **Scientific Research and Essays**, [S.l.], v.9, n.23, p.976–983, 2014.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine learning**, [S.l.], v.20, n.3, p.273–297, 1995.

DIETTERICH, T. G.; LATHROP, R. H.; LOZANO-PÉREZ, T. Solving the multiple instance problem with axis-parallel rectangles. **Artificial intelligence**, [S.l.], v.89, n.1-2, p.31–71, 1997.

DUARTE, A.; CODEVILLA, F.; GAYA, J. D. O.; BOTELHO, S. S. A dataset to evaluate underwater image restoration methods. In: OCEANS 2016-SHANGHAI, 2016. **Anais...** [S.l.: s.n.], 2016. p.1–6.

DUDA, R. O.; HART, P. E. et al. **Pattern classification and scene analysis**. [S.l.]: Wiley New York, 1973. v.3.

DUNTLEY, S. Q. Light in the sea. **JOSA**, [S.l.], v.53, n.2, p.214–233, 1963.

FAHRNI, L.; THIES, P.; JOHANNING, L.; COWLES, J. Scope and feasibility of autonomous robotic subsea intervention systems for offshore inspection, maintenance and repair. , [S.l.], 2018.

FERNÁNDEZ-ISLA, C.; NAVARRO, P. J.; ALCOVER, P. M. Automated visual inspection of ship hull surfaces using the wavelet transform. **Mathematical Problems in Engineering**, [S.l.], v.2013, 2013.

GOLODOV, V. A.; MITTSEVA, A. A. Weld Segmentation and Defect Detection in Radiographic Images of Pipe Welds. In: INTERNATIONAL RUSSIAN AUTOMATION CONFERENCE (RUSAUTOCON), 2019., 2019. **Anais...** [S.l.: s.n.], 2019. p.1–6.

GONZALEZ-VAL, C.; PALLAS, A.; PANADEIRO, V.; RODRIGUEZ, A. A convolutional approach to quality monitoring for laser manufacturing. **Journal of Intelligent Manufacturing**, [S.l.], p.1–7, 2019.

GOUMEIDANE, A. B.; BOUZAIENI, A.; NACEREDDINE, N.; TABBONE, S. Bayesian Networks-Based Defects Classes Discrimination in Weld Radiographic Images. In: INTERNATIONAL CONFERENCE ON COMPUTER ANALYSIS OF IMAGES AND PATTERNS, 2015. **Anais...** [S.l.: s.n.], 2015. p.554–565.

GUO, W.; HUANG, L.; LIANG, L. A Weld Seam Dataset and Automatic Detection of Welding Defects Using Convolutional Neural Network. In: INTERNATIONAL CONFERENCE ON COMPUTER ENGINEERING AND NETWORKS, 2018. **Anais...** [S.l.: s.n.], 2018. p.434–443.

HOU, W.; WEI, Y.; GUO, J.; JIN, Y.; ZHU, C. Automatic detection of welding defects using deep neural network. In: JOURNAL OF PHYSICS: CONFERENCE SERIES, 2018. **Anais...** [S.l.: s.n.], 2018. v.933, n.1, p.012006.

HOU, W.; WEIDEMANN, A. D. Objectively assessing underwater image quality for the purpose of automated restoration. In: VISUAL INFORMATION PROCESSING XVI, 2007. **Anais...** [S.l.: s.n.], 2007. v.6575, p.65750Q.

IACS. Non-destructive testing of ship hull steel welds. , [S.l.], 2019.

LEONARDO, B. Q.; STEFFENS, C. R.; SILVA FILHO, S. C. da; MÓR, J. L.; HÜTTNER, V.; AMARAL LEIVAS, E. do; DA ROSA, V. S.; COSTA BOTELHO, S. S. da. Vision-based system for welding groove measurements for robotic welding applications. In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION (ICRA), 2016., 2016. **Anais...** [S.l.: s.n.], 2016. p.5650–5655.

LIU, B.; ZHANG, X.; GAO, Z.; CHEN, L. Weld Defect Images Classification with VGG16-Based Neural Network. In: INTERNATIONAL FORUM ON DIGITAL TV AND WIRELESS MULTIMEDIA COMMUNICATIONS, 2017. **Anais...** [S.l.: s.n.], 2017. p.215–223.

LOWE, D. G. Distinctive image features from scale-invariant keypoints. **International journal of computer vision**, [S.l.], v.60, n.2, p.91–110, 2004.

MACHADO, Á. R.; COELHO, R. T.; ABRÃO, A. M.; SILVA, M. B. da. **Teoria da usinagem dos materiais**. [S.l.]: Editora Blucher, 2015.

MAHIDDINE, A.; SEINTURIER, J.; BOÏ, D. P. J.-M.; DRAP, P.; MERAD, D.; LONG, L. Underwater image preprocessing for automated photogrammetry in high turbidity water: An application on the Arles-Rhone XIII roman wreck in the Rhodano river, France. In: INTERNATIONAL CONFERENCE ON VIRTUAL SYSTEMS AND MULTIMEDIA, 2012., 2012. **Anais...** [S.l.: s.n.], 2012. p.189–194.

MELLO, C. D.; MESSIAS, L. R.; DREWS-JR, P. L. J.; BOTELHO, S. S. Unsupervised Learning Method for Encoder-Decoder-Based Image Restoration. In: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS, 2020. **Anais...** [S.l.: s.n.], 2020. p.348–360.

MERA, C.; OROZCO-ALZATE, M.; BRANCH, J.; MERY, D. Automatic visual inspection: An approach with multi-instance learning. **Computers in Industry**, [S.l.], v.83, p.46–54, 2016.

MERY, D.; RIFFO, V.; ZSCHERPEL, U.; MONDRAGÓN, G.; LILLO, I.; ZUCCAR, I.; LOBEL, H.; CARRASCO, M. GDXray: The database of X-ray images for nondestructive testing. **Journal of Nondestructive Evaluation**, [S.l.], v.34, n.4, p.1–12, 2015.

MOGHADDAM, A. A.; RANGARAJAN, L. Classification of welding defects in radiographic images. **Pattern Recognition and Image Analysis**, [S.l.], v.26, n.1, p.54–60, 2016.

NAGATA, F.; TOKUNO, K.; MITARAI, K.; OTSUKA, A.; IKEDA, T.; OCHI, H.; WATANABE, K.; HABIB, M. K. Defect detection method using deep convolutional neural network, support vector machine and template matching techniques. **Artificial Life and Robotics**, [S.l.], p.1–8, 2019.

OLIVEIRA GAYA, J. F. de; DUARTE, A.; MORAES, F. C.; DREWS-JR, P.; COSTA BOTELHO, S. S. da. Single image restoration for participating media based on prior fusion. **IEEE computer graphics and applications**, [S.l.], v.39, n.1, p.71–83, 2019.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE transactions on systems, man, and cybernetics**, [S.l.], v.9, n.1, p.62–66, 1979.

PARK, J.-K.; AN, W.-H.; KANG, D.-J. Convolutional Neural Network Based Surface Inspection System for Non-patterned Welding Defects. **International Journal of Precision Engineering and Manufacturing**, [S.l.], v.20, n.3, p.363–374, 2019.

RAINE, G. **ROV inspection of welds—A reality**. [S.l.]: American Society for Nondestructive Testing, Inc., Columbus, OH (United States), 1995.

RASSEM, T. H.; KHOO, B. E. Completed local ternary pattern for rotation invariant texture classification. **The Scientific World Journal**, [S.l.], v.2014, 2014.

REN, W.; LIU, S.; ZHANG, H.; PAN, J.; CAO, X.; YANG, M.-H. Single image dehazing via multi-scale convolutional neural networks. In: EUROPEAN CONFERENCE ON COMPUTER VISION, 2016. **Anais...** [S.l.: s.n.], 2016. p.154–169.

SASSI, P.; TRIPICCHIO, P.; AVIZZANO, C. A. A Smart Monitoring System for Automatic Welding Defect Detection. **IEEE Transactions on Industrial Electronics**, [S.l.], 2019.

SOARES, L. B.; WEIS, Á. A.; RODRIGUES, R. N.; BOTELHO, S. S. d. C. A Robotic Passive Vision System for Texture Analysis in Weld Beads. In: IEEE 17TH INTERNATIONAL CONFERENCE ON INDUSTRIAL INFORMATICS (INDIN), 2019., 2019. **Anais...** [S.l.: s.n.], 2019. v.1, p.535–540.

WANG, Y.; SHI, F.; TONG, X. A Welding Defect Identification Approach in X-ray Images Based on Deep Convolutional Neural Networks. In: INTERNATIONAL CONFERENCE ON INTELLIGENT COMPUTING, 2019. **Anais...** [S.l.: s.n.], 2019. p.53–64.

WESZKA, J. S. A survey of threshold selection techniques. **Computer graphics and Image processing**, [S.l.], v.7, n.2, p.259–265, 1978.

YAN, K.; DONG, Q.; SUN, T.; ZHANG, M.; ZHANG, S. Weld Defect Detection based on Completed Local Ternary Patterns. In: INTERNATIONAL CONFERENCE ON VIDEO AND IMAGE PROCESSING, 2017. **Proceedings...** [S.l.: s.n.], 2017. p.6–14.

YAPING, L.; WEIXIN, G. Research on X-ray welding image defect detection based on convolution neural network. In: JOURNAL OF PHYSICS: CONFERENCE SERIES, 2019. **Anais...** [S.l.: s.n.], 2019. v.1237, n.3, p.032005.

YUH, J.; MARANI, G.; BLIDBERG, D. R. Applications of marine robotic vehicles. **Intelligent service robotics**, [S.l.], v.4, n.4, p.221, 2011.

ZHANG, Z.; WEN, G.; CHEN, S. Weld image deep learning-based on-line defects detection using convolutional neural networks for Al alloy in robotic arc welding. **Journal of Manufacturing Processes**, [S.l.], v.45, p.208–216, 2019.