

DESENVOLVIMENTO DA SEGUNDA GERAÇÃO DO BUSCA-PITE, A
MÁQUINA PARA CARACTERIZAÇÃO DE PITES DE CORROSÃO

IANNE LIMA NOGUEIRA

UNIVERSIDADE ESTADUAL DO NORTE FLUMINENSE – UENF

CAMPOS DOS GOYTACAZES – RJ

AGOSTO – 2018

DESENVOLVIMENTO DA SEGUNDA GERAÇÃO DO BUSCA-PITE, A MÁQUINA PARA CARACTERIZAÇÃO DE PITES DE CORROSÃO

IANNE LIMA NOGUEIRA

Tese apresentada ao Centro de Ciência e Tecnologia, da Universidade Estadual do Norte Fluminense, como parte das exigências para obtenção de título de Doutor em Engenharia e Ciência dos Materiais.

Orientador: Prof. D.Sc. Angelus Giuseppe Pereira da Silva

CAMPOS DOS GOYTACAZES – RJ

AGOSTO – 2018

FICHA CATALOGRÁFICA

Preparada pela Biblioteca do **CCT / UENF**

66/2018

Nogueira, Ianne Lima

Desenvolvimento da segunda geração do busca-pite, a máquina para caracterização de pites de corrosão / Ianne Lima Nogueira. – Campos dos Goytacazes, 2018.

xiv, 100 f. : il.

Tese (Doutorado em Engenharia e Ciência dos Materiais) -- Universidade Estadual do Norte Fluminense Darcy Ribeiro. Centro de Ciência e Tecnologia. Laboratório de Materiais Avançados. Campos dos Goytacazes, 2018.

Orientador: Angelus Giuseppe Pereira da Silva.

Área de concentração: Materiais e meio ambiente.

Bibliografia: f. 93-100.

1. MÁQUINA BUSCA-PITE 2. VARIAÇÃO DE FOCO 3. CORROSÃO POR PITES 4. CARACTERIZAÇÃO DE PITES 5. AUTOMAÇÃO I.

Universidade Estadual do Norte Fluminense Darcy Ribeiro. Centro de Ciência e Tecnologia. Laboratório de Materiais Avançados II. Título

CDD 620.11223

DESENVOLVIMENTO DA SEGUNDA GERAÇÃO DO BUSCA-PITE, A MÁQUINA PARA CARACTERIZAÇÃO DE PITES DE CORROSÃO

IANNE LIMA NOGUEIRA

Tese apresentada ao Centro de Ciência e Tecnologia, da Universidade Estadual do Norte Fluminense, como parte das exigências para obtenção de título de Doutor em Engenharia e Ciência dos Materiais.

Aprovada em 10 de Agosto de 2018.

Comissão Examinadora:



Prof. Eglon Rhuan S. Guimarães (D.Sc, Engenharia e Ciência dos Materiais) – IFES



Prof. Ítalo de Oliveira Matias (D.Sc., Sistemas Computacionais) – UCAM



Prof^a. Elaine C. Pereira (D.Sc, Engenharia e Ciência dos Materiais) – UENF



Prof. Angelus Giuseppe Pereira da Silva (D.Sc., Ciências Técnicas) – UENF

Orientador

DEDICATÓRIA

À minha mãe,
minha fonte de inspiração.

AGRADECIMENTOS

Agradeço a Deus pela saúde.

Aos meus pais, em especial à minha mãe, por ser minha calma, meu porto seguro e principalmente por me amar e apoiar de forma incondicional.

Ao meu orientador, Prof. Angelus Giuseppe Pereira da Silva, pela infinita paciência, amizade, conhecimento e ensinamentos compartilhados. Por acreditar e confiar em mim.

Ao meu amigo Daniel Corrêa pelo apoio, companheirismo e contribuição.

Ao meu amigo Weverson Oliveira, pela indispensável ajuda e contribuição ao compartilhar seu sistema de redes neurais e auxiliar na execução dos testes.

Aos meus amigos do IFF pelo apoio, em especial aos professores Matheus Dimas e Fabrício Barros por suas valiosas contribuições na execução deste trabalho.

Aos meus amigos por sempre me incentivarem e acreditarem no meu sucesso.

Aos professores integrantes da banca por toda contribuição que foi dada a este trabalho.

Ao Instituto Federal Fluminense – Campus Bom Jesus pelo incentivo à qualificação de seus servidores.

A UENF pela oportunidade e espaço físico.

SUMÁRIO

LISTA DE FIGURAS	ix
LISTA DE TABELAS	xii
RESUMO	xiii
ABSTRACT	xiv
CAPÍTULO 1 – INTRODUÇÃO	15
1.1 – Objetivo.....	17
1.2– Justificativa.....	18
1.3 – Ineditismo	18
1.4 – Organização	19
CAPÍTULO 2 – REVISÃO BIBLIOGRÁFICA	20
2.1 – Corrosão	20
2.1.1 – Representação da Corrosão por Pites Segundo as Normas	21
2.1.2 – Método Convencional de Caracterização de Pites de Corrosão ..	22
2.2 – Máquina Busca-Pites.....	23
2.2.1 – Caracterização de Pites com a Máquina Busca-Pites	35
2.2.1 – Comparação entre Técnicas Diferentes de Caracterização de Pites	36
2.2.1.1 – Método Convencional	36
2.2.1.2 – Microscópio Confocal.....	37
2.2.1.3 – Busca-Pite.....	38
2.3 – Computação Gráfica.....	40
2.3.1 – Reconhecimento de Foco.....	40
2.3.2 – Variação de Foco	42
2.3.3 – Point Spread Function (PSF).....	43
2.3.3.1 – Restauração de Imagens com Uso da PSF	47
2.3.4 – Estimadores.....	49
2.3.4.1 – Laplaciano.....	49
2.3.4.2 – Entropia.....	50
2.3.4.3 – Intensidades do Histograma	50
2.3.5 – Técnicas de Determinação de Relevo de Superfície por Variação de Foco	51
2.4 – Redes Neurais Artificiais (RNA's)	52
2.5 – Trabalhos Correlatos	54

CAPÍTULO 3 - METODOLOGIA.....	56
3.1 – Ferramentas	57
3.1.1 – Máquina Busca-Pites.....	57
3.1.2 – Análise de Foco.....	58
3.1.3 – Observar Pixel	60
3.1.4 – Rede Neural	60
3.2 – Recursos do Sistema.....	61
3.2.1 – Construção da Imagem em Foco	61
3.2.2 – Mapeamento de Profundidade	61
3.2.3 – Nivelamento da Superfície.....	61
3.2.4 – Gráfico 3D	62
3.2.5 – Profundidade do Pixel	62
3.2.6 – Distância entre dois Pontos	62
3.3 – Teste do Sistema.....	63
CAPÍTULO 4 – RESULTADOS E DISCUSSÃO.....	64
4.1 – Análise de Foco	64
4.1.1 – Interface Gráfica do Análise de Foco	64
4.1.2 – Alinhamento de Imagens.....	66
4.1.3 – Verificação de Foco.....	67
4.1.3.1 – Pontos de Referência para Teste	68
4.1.3.2 – Determinação Visual de Foco	69
4.1.3.3 – Estimadores de Foco	69
4.1.4 – Rede Neural.....	76
4.2 – Observar Pixel	77
4.4 – Nova Versão do Software da Máquina Busca-Pite	79
4.4.1 – Construção de Imagem em Foco	80
4.4.2 – Mapeamento de Profundidade	81
4.4.3 – Nivelamento.....	83
4.4.4 – Gráfico 3D	84
4.4.5 – Profundidade do Pixel	86
4.4.6 – Distância entre Dois Pontos	87
4.5 – Comparação entre a Qualificação do Foco pelo Olho Humano e pelos Estimadores.....	87
CAPÍTULO 5 – CONCLUSÃO.....	90

CAPÍTULO 6 – TRABALHOS FUTUROS.....	92
REFERÊNCIAS BIBLIOGRÁFICAS	93

LISTA DE FIGURAS

Figura 2.1 - Mesa XY modelo LNE 250 na Newmark Systems (Manhães, 2015).	24
Figura 2.2 - a) Controlador da mesa XY. b) Joystic. (Manhães, 2015).....	24
Figura 2.3 - Software Galil Tools (Manhães, 2015).	25
Figura 2.4 - Conjunto controlador/sensor confocal ligados por fibra ótica (Manhães, 2015).	26
Figura 2.5 - Câmera Canon Rebel T3i (Manhães, 2015).	26
Figura 2.6 - Microscópio estereoscópio (Manhães, 2015).....	27
Figura 2.7 - Adaptador câmera/microscópio (Manhães, 2015).	27
Figura 2.8 - Fonte de luz MW150R (Manhães, 2015).	28
Figura 2.9 - Roteador TPLink (Manhães, 2015)	28
Figura 2.10 - Rack 16U Fabricante Nilko (Manhães, 2015).	28
Figura 2.11 - Estrutura metálica construída com tampão de granito (Manhães, 2015).	29
Figura 2.12 - Tela principal do programa (Nogueira, 2013).....	30
Figura 2.13 - Resultado da aplicação do operador de borda (Nogueira, 2013).....	30
Figura 2.14 - Tela para preenchimento de informações da escala (Nogueira, 2013).	31
Figura 2.15 - Imagem de uma binarização manual. Adaptada de (Nogueira, 2013). 31	
Figura 2.16 - Pites selecionados pelo software. Adaptada de (Manhães, 2015).....	32
Figura 2.17 - Histograma da distribuição do tamanho dos pites (Nogueira, 2013)....	33
Figura 2.18 – Relatório final do programa com a medição de profundidade (Manhães, 2015).	33
Figura 2.19 - Pite selecionado para varredura (Manhães, 2015).	34
Figura 2.20 - Gráfico gerado em excel da vista superior do pite (a) e vista lateral (b). Adaptada de (Manhães, 2015).	34
Figura 2.21 - Esquematização da formação de uma imagem por uma lente. Somente os pontos do objeto observado cuja luz converge no plano focal aparecerão nítidos ao observador. Fonte: adaptado de (Spitaler, 2018)	41
Figura 2.22 - Pilha de imagens com diferentes focos do objeto e imagem com total nitidez, á direita (Ferraro, et al., 2005).	43
Figura 2.23 - Imagem de superfície com relevo em degraus observada com microscópio capturada por sensor ótico. Fonte: próprio autor.....	44

Figura 2.24 - Imagens de um ponto luminoso tomadas em diferentes distâncias entre a lente e o objeto. A imagem torna-se mais nítida à medida que a distância ao objeto se aproxima da distância focal (imagem do centro). A intensidade da luz em cada ponto representa o valor da PSF. Adaptada de (Spitaler, 2018).....	45
Figura 2.25 - Seção da PSF no plano YZ que passa pela origem. Adaptada de (Spitaler, 2018).....	46
Figura 2.26 - A imagem capturada é resultante da convolução entre a imagem real do objeto e a PSF. Adaptada de (Default007, 2018).....	46
Figura 2.27 - Imagens dos planos XZ, XY, YZ e da representação 3D de uma PSF determinada experimentalmente de um microscópio confocal usando objetos de 100nm com luz de comprimento de onda entre 500 e 620nm (Vindin, 2018).	47
Figura 2.28 - Imagens restauradas com aplicação do filtro inverso, sem e com a presença de ruído. Adaptado de (Solomon e Breckon, 2013).....	48
Figura 2.29 - Máscaras para o cálculo do laplaciano: (a) 3 x 3, (b) 5 x 5, (c) 9 x 9 (Marques Filho e Vieira Neto, 1999).....	49
Figura 2.30 - Histograma de frequência de uma imagem (Gomes e Velho, 2003)....	50
Figura 2.31 - Modelo não-linear de um neurônio (Haykin, 2007).	53
Figura 3.1 - Fluxograma com as etapas de execução da metodologia.	56
Figura 4.1 - Tela principal do programa Análise de Foco.....	65
Figura 4.2 - Tela do programa Análise de Foco após selecionada a função Abrir Lote de Imagens.....	66
Figura 4.3 - Esquema de imagens alinhadas. Onde (a) e (b) representam a primeira e última imagem da pilha antes do alinhamento e (c) e (d) são as mesmas imagens após o alinhamento.	67
Figura 4.4 - Tela do programa mostrando a seleção de um pixel, uma linha e uma coluna.....	68
Figura 4.5 - Tela dos estimadores de foco.	70
Figura 4.6 - Relatório de estimadores aplicados por pixel em uma pilha de imagens.	71
Figura 4.7 - Estimadores aplicados em uma linha da imagem.	71
Figura 4.8 - Gráficos de um ponto na pilha de 100 imagens para diferentes estimadores. (a) DQLBN(23), (b) DQLB(23), (c)LM(5) e (d) IN(23).....	75
Figura 4.9 - Curva de valores do estimador DQLBN(23) na pilha de imagens com ajuste gaussiano.	76

Figura 4.10 - Tela do programa Observar Pixel.	78
Figura 4.11 - Tela do Observar Pixel exibindo os valores do pixel selecionado para uma máscara 5x5.	79
Figura 4.12 - Interface atualizada do software da Máquina Busca-Pite.	80
Figura 4.13 - (a) Imagem inicial da pilha; (b) Imagem final da pilha; e (c) Imagem composta após o processamento.	81
Figura 4.14 - Tela do mapeamento de profundidade.	82
Figura 4.15 - Imagem mapeada.	82
Figura 4.16 - (a) Imagem inicial da pilha; (b) imagem final da pilha; (c) imagem composta; e (d) imagem mapeada.	83
Figura 4.17 - Imagem nivelada.	84
Figura 4.18 - Diferentes faces do gráfico 3D de um pite de uma imagem de um cupom de superfície inclinada.	85
Figura 4.19 - Gráficos de diferentes ângulos de um pite de uma imagem de um cupom de superfície plana.	86
Figura 4.20 - Exibição da profundidade de um pixel após o nivelamento.	87
Figura 4.21 - Exibição dos cálculos das distâncias entre dois pontos.	87
Figura 4.22 - Esquema de 101 imagens de 23x23.	88
Figura 4.23 - Imagem com destaque de um ponto.	89

LISTA DE TABELAS

Tabela 1 - Tempo médio por imagem de caracterização de pites usando o Busca-Pite.....	39
Tabela 2 - Tempo médio por imagem de caracterização de pites usando o método convencional (microscópio ótico).	39
Tabela 3 – Tempo médio por imagem de caracterização de pites usando o microscópio confocal.....	39
Tabela 4 - Alguns programas que usam a técnica de focus stacking.....	51
Tabela 5 - Taxas de acerto dos estimadores.	74
Tabela 6 - Resultados da rede neural.	77

Resumo da tese apresentada ao CCT-UENF como parte dos requisitos para obtenção do grau de Doutor em Engenharia e Ciência dos Materiais.

DESENVOLVIMENTO DA SEGUNDA GERAÇÃO DO BUSCA-PITE, A MÁQUINA PARA CARACTERIZAÇÃO DE PITES DE CORROSÃO

Ianne Lima Nogueira

10 de Agosto de 2018

Orientador: Prof. Angelus Giuseppe Pereira da Silva

O presente trabalho tem por objetivo apresentar uma nova versão do software da máquina Busca-Pite, utilizando a tecnologia de variação de foco, para obter imagens de superfícies irregulares em foco nítido. A máquina, já desenvolvida em projetos anteriores para a análise da corrosão por pites usando sensor confocal, combina técnicas de automação e de computação gráfica. Apesar dos efeitos positivos obtidos no processo de caracterização de pites, a máquina possuía limitações. A introdução da nova tecnologia possibilita a análise de toda uma área de uma única vez, visto que é gerada uma imagem em foco nítido a partir de uma pilha de imagens, capturadas em diferentes distâncias da área em estudo. Para identificar a região focalizada em cada imagem da pilha foram testados diversos estimadores, tendo o melhor deles uma taxa de acerto de 75%. O relevo da superfície da área em análise pode ser mapeado, utilizando a altura em que cada fotografia foi capturada. Em casos de inclinação da superfície do cupom é possível efetuar um nivelamento para descartar dados irrelevantes. A partir do mapa de altura da imagem, gráficos tridimensionais podem ser gerados possibilitando assim outra forma de observar a topografia do cupom. Os testes mostraram que a tecnologia de variação de foco é capaz de auxiliar e otimizar o processo de caracterização de pites de corrosão em cupons, mas é necessário refinar o algoritmo para reduzir a taxa de erros.

Palavras chave: máquina Busca-Pite, variação de foco, corrosão por pites, caracterização de pites, automação

Abstract of thesis presented to CCT-UENF as a part of the requirements for the degree of Doctor of Science in Engineering and Materials Science.

THE DEVELOPMENT OF BUSCA-PITE SECOND GENERATION, THE MACHINE FOR CHARACTERIZATION OF CORROSION PITS

Ianne Lima Nogueira

August 10, 2018

Advisor: Prof. Angelus Giuseppe Pereira da Silva

The present work aims to present a new version of the Busca-Pite machine software, using focus variation technology, to obtain images of irregular surfaces in sharp focus. The machine, already developed in previous projects for pitting corrosion analysis using confocal sensor, combines automation and computer graphics techniques. Despite the positive effects obtained in the pitting characterization process, the machine had limitations. The introduction of the new technology allows the analysis of an entire area at a single time, since a sharp focus image is generated from a stack of images captured at different distances from the study area. To identify the focused region in each stack image, several estimators were tested, the best of which was a 75% hit rate. The surface relief of the area under analysis can be mapped using the height at which each photograph was captured. In cases of tilting the coupon surface, a leveling can be performed to discard irrelevant data. From the height map of the image, three-dimensional graphs can be generated allowing another way to observe the topography of the coupon. The tests showed that the technology of focus variation is able to aid and optimize the process of characterization of pits of corrosion in coupons, but it is necessary to refine the algorithm to reduce the error rate.

Keywords: Busca-Pite machine, focus variation, pitting corrosion, characterization of pits, automation

CAPÍTULO 1

INTRODUÇÃO

A corrosão é um processo resultante da ação do meio sobre um material, causando a deterioração de suas propriedades e funcionalidades. Apesar da estreita relação com os metais, esse fenômeno ocorre em outros materiais, como concreto e polímeros orgânicos, entre outros (Merçon *et al.*, 2004).

Significantes perdas econômicas estão associadas a sua ocorrência e a seu combate e controle (Gentil, 1996; Felipe *et al.*, 2013). As perdas são causadas pela substituição das partes e peças atingidas; pelas paradas de produção para substituição e inspeções; por danos ambientais e materiais (vazamento de químicos de tubulações metálicas), e pelas medidas de monitoramento e prevenção da corrosão (Gentil, 1996; Sheir *et al.*, 2000; Costa, 2008; Frauches-Santos *et al.*, 2014). Além disso, existem os fatores psicológicos decorrentes da suspeita de insegurança em equipamentos, que minam a produtividade do pessoal (Revista Química e Derivados, 1996).

Um das formas de corrosão mais destrutivas e insidiosas é a corrosão por pites. Neste tipo, o ataque é muito localizado e a destruição é confinada a pequenas áreas, da ordem de milímetros quadrados ou menos, resultando em pequenos furos que penetram o metal, enquanto que as outras partes de sua superfície permanecem praticamente sem ataque (Galvele *et al.*, 1978; Gentil, 1996; Ferreira *et al.*, 2002; Picon, 2010).

O mecanismo de formação dos pites é de difícil determinação devido ao pequeno tamanho que eles aparecem. Eles requerem um tempo razoável até que possam ser visualizados e ocorrem em locais de irregularidades superficiais, tais como arranhão, heterogeneidade química, ou um dano à camada protetora (Dexter, 1987). Superfícies polidas mostram maior resistência a este tipo de corrosão (Quiumento, 2011). De acordo com Pereira (2010) é importante destacar que nem todo defeito nucleia pite, mas quanto maior o número de defeitos maior o número de pites. Para um material livre de defeitos, a corrosão por pite é causada predominantemente pela

ação química do ambiente em que este se encontra, o qual podem conter espécies químicas agressivas como o íon cloreto (Picon, 2010; Quiumento, 2011).

O monitoramento da corrosão deve ser feito com uso de diferentes técnicas para garantir redundância e complementaridade. Cupons de corrosão são largamente utilizados com este propósito. Cupons de corrosão, ou cupons de perda de massa, são pequenas peças metálicas construídas de diversas ligas em diferentes geometrias que são expostas na instalação a ser monitorada por um determinado tempo (Ferreira *et al.*, 2002; Simor e Novais, 2002; Terzi e Mainier, 2008).

Após o período de exposição, os cupons são preparados e caracterizados. Diversas informações podem ser obtidas: tipos de corrosão que ocorrem; produtos de corrosão formados; taxa de corrosão uniforme, determinada pela perda de massa; e taxa de corrosão por pites, determinada pela profundidade dos pites (Ferreira *et al.*, 2002; Simor e Novais, 2002; Terzi e Mainier, 2008).

Quando muitos cupons são usados na monitoração sua caracterização torna-se dispendiosa, dado que a caracterização demanda tempo e trabalho (Simor e Novais, 2002). Além da limpeza dos cupons, há a medição da taxa de corrosão.

A caracterização de corrosão por pites em cupons é guiada pelas normas (ASTM, 1994) e (NACE, 2005). Estas normas preveem a medição de alguns parâmetros. Os três parâmetros para análise de pites mais apontada são: densidade, tamanho médio e taxa de corrosão, representada pelo aumento anual da profundidade dos pites. As normas apontam diversas técnicas para medição de cada um destes parâmetros. Na prática, a microscopia ótica é a técnica mais empregada.

Esta técnica de caracterização é, por natureza, lenta e trabalhosa. Especialmente, para a medição da profundidade de pites, a microscopia ótica envolve um conjunto de ações que exigem do operador tempo e esforço (ASTM, 1994). Baixa produtividade e cansaço estão associados a este procedimento e são causa potencial para baixa precisão de resultados.

Programas de computador são usados para medir parte dos parâmetros. Isto trouxe o aumento da produtividade, porém a medição de profundidade de pites continua a ser manual. A máquina Busca-Pite foi desenvolvida com o objetivo de aumentar a automatização do procedimento (Nogueira, 2013; Manhães, 2015). Com isso, efeitos positivos são esperados sobre a produtividade e a precisão dos resultados. A máquina combina recursos de computação gráfica com automação. A medi-

ção de profundidade de pites é automatizada e se torna muito mais rápida do que o procedimento manual convencional da microscopia ótica.

A medição automatizada de profundidade de pites realizada pelo Busca-Pite é baseada na tecnologia confocal. Esta técnica possui precisão micrométrica, porém possui limitações. Uma delas é a de medir distâncias entre pontos individuais. Outra é a dependência da qualidade da superfície do objeto em análise. A primeira limitação citada implica em que a medição da profundidade do pite deva ser feita na posição em que o pite seja mais profundo. Isto ainda torna o uso da técnica de medição confocal desvantajosa para varredura 3D de superfície, dado que isto implica na medição de milhares de pontos em cada varredura. A segunda limitação torna difícil o uso da técnica em superfícies muito rugosas.

Em uma tentativa de vencer essas limitações, uma nova versão do Busca-Pite está sendo proposta com base em outra tecnologia: a variação de foco. Esta tecnologia começou a ser usada como forma de produzir imagens de microscopia de superfícies irregulares completamente em foco, mas atualmente sua técnica evoluiu para produzir varreduras dessas superfícies. Esta técnica permite a medição de uma grande quantidade de pontos em pouco tempo e a rugosidade superficial não é tão limitante quanto na técnica confocal.

A principal inovação deste projeto, em comparação com a versão atual do Busca-Pite, é a introdução da técnica de variação de foco para medição de profundidade de pite. Isto fará com que a etapa de identificação de pites presentes seja mais rápida e precisa, além de mais confiável. Além dessa, outras inovações serão introduzidas para facilitar a operação da máquina.

1.1 – Objetivo

O objetivo principal deste projeto é o desenvolvimento da segunda geração do software da máquina de caracterização de pites de corrosão em cupons, denominada de Busca-Pite, utilizando a técnica de variação de foco na caracterização dos pites. São objetivos específicos do projeto:

- Desenvolver algoritmos para reconhecimento de foco.
- Construir imagens em foco nítido.
- Mapear a topografia do relevo da superfície da área em análise.
- Medir distâncias entre pontos da superfície da imagem.

- Gerar gráficos tridimensionais para auxiliar na análise dos pites.

1.2 – Justificativa

A máquina Busca-Pite atual representa um grande avanço no processo de caracterização de pites em cupons de corrosão. Ela permitiu reduzir o tempo de análise e aumentar a produtividade, reduzindo o esforço humano e ganhando em qualidade de resultados. Porém, ela possui limitações. Quando se trata de caracterizar amostras com pites pequenos, o sensor confocal, responsável pela medida de profundidade, não funciona adequadamente. Existem ainda limitações quanto ao ponto em que a profundidade dos pites é medida. Nem sempre o local onde é realizada a medição é de fato o ponto mais profundo do pite (Nogueira, 2013; Manhães, 2015). Esta nova versão da máquina propõe usar a tecnologia de variação de foco na caracterização de pites, assim toda uma área superficial é capturada de uma única vez, ao invés de pontos isolados como ocorre atualmente. Desta maneira, a identificação dos pites se torna mais rápida e a medição de sua profundidade ganha em precisão. Apesar de existirem equipamentos que utilizam essa técnica (Danzl et al., 2009; Olympus, 2013), os mesmos possuem um custo elevado. A nova versão da máquina busca também reduzir esse custo, tornando a tecnologia mais acessível.

1.3 – Ineditismo

A máquina de caracterização de pites, o Busca-Pite, é criação de pesquisadores do LAMAV/PPGECM. A versão original foi tema de duas dissertações de mestrado.

A técnica de variação de foco aplicada à caracterização de pites, junto das novas funcionalidades adicionadas ao sistema, confere ao trabalho o ineditismo exigido para o doutoramento. Para a verificação do ineditismo, foram realizadas pesquisas nas bases de conhecimento *ProQuest – Engineered Materials Abstracts* e *Scopus* (ProQuest LLC, 2018) (Elsevier B.V., 2018). As pesquisas realizadas em ambas as bases com as expressões abaixo obtiveram resultado nulo.

- “software” AND “focus variation” AND “characterization of pitting” AND “depth map” AND “graph 3d”;

- “software” AND “focus variation” AND “characterization of pitting” AND “depth map”;
- “software” AND “focus variation” AND “characterization of pitting” and “graph 3d”;
- “software” AND “focus variation” AND “depth map” AND “graph 3d”;
- “software” AND “focus variation” AND “pit analysis”;

1.4 – Organização

Além desta Introdução, esse trabalho se divide nos seguintes capítulos:

Capítulo 2 – Revisão Bibliográfica: Este capítulo descreve o embasamento teórico dos assuntos principais deste trabalho que são a computação gráfica e corrosão e o funcionamento da máquina Busca-Pite.

Capítulo 3 – Metodologia: Este capítulo apresenta as ferramentas e tecnologias utilizadas no desenvolvimento deste projeto. São descritas as funcionalidades do sistema.

Capítulo 4 – Resultados e Discussão: Neste capítulo, tanto as ferramentas desenvolvidas para auxílio quanto o programa desenvolvido são descrito em detalhes (interface e funcionalidades). Também são apresentados alguns resultados da utilização do sistema.

Capítulo 5 e 6 – Conclusão e Trabalhos Futuros: Estes capítulos apresentam a conclusão do projeto e propostas para trabalhos futuros, respectivamente.

CAPÍTULO 2

REVISÃO BIBLIOGRÁFICA

Este Capítulo apresenta o referencial teórico que embasa o trabalho de tese.

2.1 – Corrosão

A corrosão pode ser definida como a destruição ou deterioração de um material devido a reações químicas ou eletroquímicas com o meio onde se encontra, aliada ou não a tensões, ou ainda como um processo natural resultante da inerente tendência dos metais se reverterem para sua forma mais estável (Gentil, 1996). É um problema que ocorre em diversos materiais, em especial com os metais e suas ligas. Ela é o principal mecanismo de degradação de materiais.

Em determinadas áreas, como na indústria de extração de petróleo (Rodrigues *et al.*, 2013; Colares, 2009), a corrosão assume uma dimensão ainda maior por uma série de fatores: os custos operacionais extremamente elevados que exigem o mínimo de paradas de produção; o uso intensivo de metais, que são os materiais mais suscetíveis à corrosão; o ambiente agressivo de trabalho, formado pelo ambiente marinho e pelos fluidos de trabalho; e os riscos ambientais inerentes a esta atividade industrial. Isto torna o monitoramento da corrosão uma atividade crucial nesta indústria (Terzi e Mainier, 2008). Tecnologias de inspeção e de mitigação dos processos corrosivos encontram amplo espaço de aplicação.

O conhecimento das diferentes formas sob as quais a corrosão ocorre é importante no estudo do processo corrosivo. O processo de corrosão pode ser dividido em tipos de acordo com a aparência ou forma de ataque, e ainda as diferentes causas da corrosão e seus mecanismos (Gentil, 1996; Ferreira *et al.*, 2002; Pannoni, 2007). Assim, os tipos de corrosão podem ser classificados segundo a morfologia, as causas ou mecanismos, os fatores mecânicos ou o meio corrosivo.

A monitoração da corrosão é uma forma sistemática de medição da corrosão ou da degradação de um determinado componente de um equipamento, com o objetivo de auxiliar a compreensão do processo corrosivo e/ou obter informações úteis para o controle da corrosão e das suas consequências (Gentil, 1996).

O monitoramento é uma ferramenta fundamental do plano de controle de corrosão, visto que é capaz de fornecer informações relevantes sobre a evolução do processo corrosivo, bem como identificar e monitorar, regularmente, os parâmetros operacionais (composição química da carga ou do meio corrosivo, temperatura do processo, teor de contaminantes, etc.) responsáveis pela elevação significativa da atividade corrosiva (Gentil, 1996; Ferreira *et al.*, 2002).

2.1.1 – Representação da Corrosão por Pites Segundo as Normas

As normas ASTM (1994) e NACE (2005) são usadas para guiar a caracterização de corrosão por pites em cupons de corrosão.

A norma ASTM (1994) descreve diferentes formas de caracterizar a intensidade da corrosão por pites. O método *standard chart* é aquele descrito na norma usado neste projeto.

No método *standard chart*, três parâmetros representam a intensidade da corrosão por pites: a densidade de pites, a área média da abertura dos pites e a profundidade média dos pites presentes. A própria norma ASTM (1994) observa que esse método demanda muito esforço, visto que requer a medição da área e da profundidade de todos os pites presentes em cada cupom. Esse esforço nem sempre é justificado, pois muitas vezes os valores máximos são mais significantes do que os valores médios.

Uma vez determinados os três parâmetros, o método usa uma representação alfanumérica, em cinco níveis, para classificar a densidade de pites, área média de abertura dos pites e profundidade média de pites, representados pelas letras A, B e C, respectivamente. E os números de 1 a 5 são usados após as letras, para indicar o nível de cada parâmetro. Um exemplo seria A3-B2-C4. A intensidade aumenta de 1 a 5.

No método da penetração do metal, outro método descrito pela norma, a intensidade da corrosão por pites é representada pela profundidade do pite mais profundo, ou pela profundidade média dos dez pites mais profundos. Outra maneira de representar a penetração do metal é por meio do fator de pite (FP). Ele é definido pela razão entre a profundidade do pite mais profundo e a penetração média do metal, determinada pela perda de massa do cupom. O problema dessa definição é que quando não há corrosão uniforme (a perda de massa é muito pequena, pois se refe-

re apenas aos pites), o FP tende a infinito. Quando os pites forem muito pequenos, o FP tende a zero.

A norma NACE (2005) recomenda representar a intensidade da corrosão por pite por um único parâmetro: a taxa de crescimento máxima de pite. Esse parâmetro é determinado medindo-se a profundidade do maior pite encontrado na superfície exposta e dividindo pelo tempo de exposição. A unidade de medida é o mm/ano. Ao representar a corrosão por pite dessa forma, a norma subentende que a velocidade de crescimento da profundidade do pite mais profundo é a característica que importa para representar o dano causado por este tipo de corrosão.

A norma NACE RP0775 classifica a taxa de corrosão por pites em quatro níveis, de acordo com o valor medido, que são: baixo, moderado, alto e severo.

2.1.2 – Método Convencional de Caracterização de Pites de Corrosão

A caracterização de pites de corrosão em cupons usando os três parâmetros (densidade, tamanho e taxa de corrosão) é uma tarefa que demanda muito tempo e trabalho. Diversas técnicas podem ser usadas para medir cada parâmetro. A medição da densidade, que envolve a contagem de pites, pode ser feita pelos métodos supracitados. Cada um possui suas vantagens e limitações.

A medição do tamanho dos pites envolve a medida da área da abertura de cada pite. A maneira mais rápida de medir áreas de regiões que se destacam pelo tom de cinza ou formato em uma imagem é por meio do uso de programas de computador. Alguns programas possuem recursos que “segmentam”, ou seja, separam do restante da imagem, as regiões que se destacam automaticamente. Ou oferecem recursos para o operador circundar manualmente cada região de interesse. As áreas das regiões segmentadas são então medidas. Se houver grande quantidade de pites presentes, esta tarefa pode demorar. Por isso a norma fala em, alternativamente, usar a média dos pites maiores. Reconhecer os pites de maiores áreas é muito mais fácil e rápido do que reconhecer os pites de maior profundidade.

Este último é o parâmetro mais trabalhoso e demorado de ser medido. Existem vários métodos. O mais usado é aquele que usa o microscópio. A profundidade é medida pite-a-pite. Para medir a profundidade de um determinado pite, sua imagem é ampliada até ocupar a maior parte do campo de visão do microscópio. Com auxílio do botão de ajuste de foco, o operador ajusta o foco para visualizar um ponto

na borda do pite. Feito isso, anota o valor correspondente na escala existente no botão de foco. Em seguida, o operador volta a ajustar o foco para observar o local mais profundo do pite e anota o valor da escala no botão de foco. A diferença entre os valores anotados é convertida em micrometros. O procedimento deve ser repetido para cada pite. Por isso admite-se que se restrinja à medição do pite mais profundo presente no cupom, ou dos dez mais profundos. O problema é que nem sempre a profundidade dos pites é aparente.

A caracterização de pites de corrosão requer, portanto, três “camadas” de trabalho subsequentes. Na primeira, o operador faz a contagem dos pites para determinar a densidade. Posteriormente, volta a observar a amostra, às vezes em um aumento maior do microscópio, para segmentar todos os pites, ou apenas os maiores, seja automática ou manualmente. Com isso, as áreas dos pites são medidas. A terceira camada de trabalho deve ser realizada em aumento ainda maior, para aumentar a precisão. Caso o operador decida medir apenas o mais profundo, ou os mais profundos, deve antes observar o aspecto geral de toda a superfície para identificar os pites que possuem a tonalidade mais escura. Geralmente, estes são mais profundos. Depois, deve ir a cada pite escolhido e executar o procedimento já descrito. Percebe-se que a restrição aos mais profundos é fortemente influenciada pela dificuldade de medição.

Cada camada de trabalho requer cálculos que devem ser executados manualmente.

2.2 – Máquina Busca-Pites

Busca-Pites é o nome da máquina de caracterização de pites de corrosão em cupons que foi desenvolvida como parte do convênio estabelecido entre a PETROBRAS e a UENF. O objetivo da máquina é aumentar a produtividade da caracterização da corrosão por pites em cupons (Nogueira, 2013; Manhães, 2015).

Ao medir, a máquina modifica a rotina do método convencional de caracterização, diminuindo o trabalho e encurtando o tempo de medição. Ela faz uso de técnicas de computação gráfica para determinar densidade e tamanho de pites e de medição de profundidade dos pites pela técnica ótica confocal. O método é classificado como semiautomático, ou assistido pelo operador.

A construção da máquina se deu em duas etapas principais: montagem e configuração do hardware e desenvolvimento do software para caracterização. A seguir serão descritas as partes que a compõe.

Para realizar o deslocamento do microscópio ao sensor confocal do cupom a ser analisado, uma mesa XY é utilizada, como mostra a Figura 2.1. Esta mesa de dois graus de liberdade possui uma faixa de deslocamento de 25 cm nos dois eixos. A comunicação com o controlador se dá através da porta serial. A mesa recebe comandos de movimento e retorna informações como posição, velocidade, aceleração, entre outros



Figura 2.1 - Mesa XY modelo LNE 250 na Newmark Systems (Manhães, 2015).

A máquina possui ainda um Joystic (Figura 2.2.b), este também se comunica com o controlador (Figura 2.2.a) por meio de um cabo serial, permitindo que os movimentos manuais sejam convertidos em movimento da mesa.




Figura 2.2 - a) Controlador da mesa XY. b) Joystic. (Manhães, 2015)

O conjunto possui um programa chamado GalilTools (Figura 2.3), o qual permite a operação, programação, e leitura das variáveis presentes no controlador. É possível produzir sub-rotinas que facilitam o movimento da mesa a partir de movimento pré-configurados. O controlador possui duas opções de comunicação com o PC: ethernet e a serial. Uma biblioteca chamada galil.h também é disponibilizada para que o desenvolvedor possa acrescentar a sua aplicação o comando da mesa.

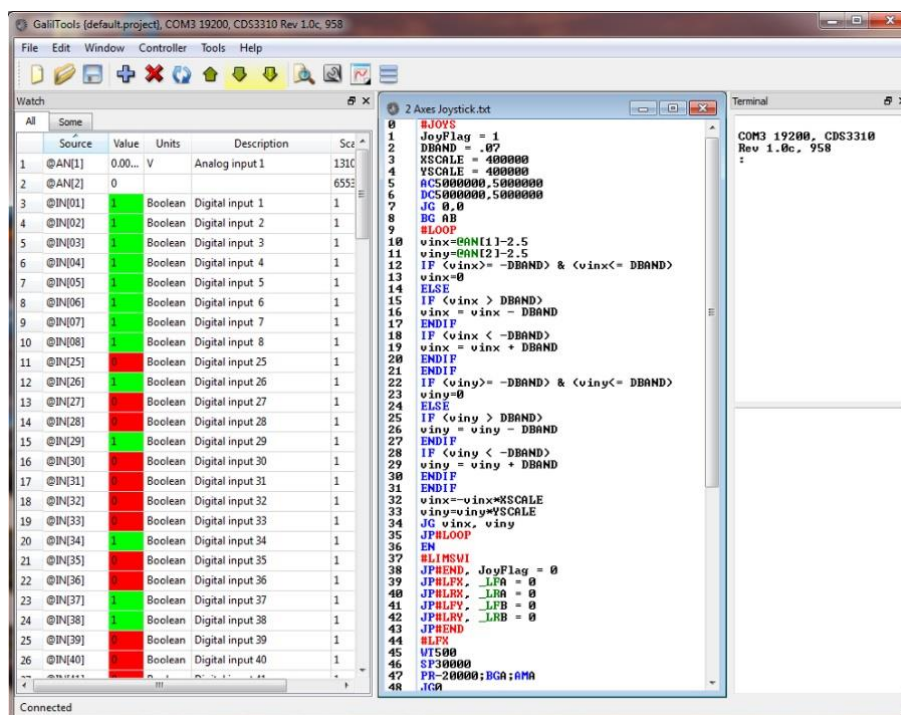


Figura 2.3 - Software Galil Tools (Manhães, 2015).

As medições de profundidade são realizadas através de um sensor/controlador conectados por um cabo de fibra óptica (Figura 2.4). O sensor é o modelo IFS 2401-3 da fabricante Micro-epsilon. Uma limitação do equipamento é o ângulo máximo da reflexão do sinal luminoso, se este retornar ao sensor com um ângulo superior a 22° do feixe emitido, isto acarretará em falha no valor de leitura. O controlador, modelo confocalDT 2451, possui comunicação, via cabo Ethernet, com um software próprio para leitura e configuração, além de um servidor web interno que permite configurá-lo via um navegador web. O fabricante disponibiliza uma biblioteca MEDAQLib.h para linguagem em C que permite ao usuário produzir suas próprias aplicações utilizando o sensor.




Figura 2.4 - Conjunto controlador/sensor confocal ligados por fibra ótica (Manhães, 2015).

As imagens analisadas são capturadas por uma câmera (Figura 2.5), que permite a operação remota via cabo USB, acoplada a um microscópio estereoscópio com aumento de até 40x (Figura 2.6). Para a conexão entre a câmera e o microscópio é necessário um adaptador, como mostra a Figura 2.7. O dispositivo possui uma lente auxiliar de 2x que permite o aumento da capacidade de ampliação para 80x. Assim como os outros dispositivos, a câmera possui uma biblioteca para desenvolvimento de aplicações.



Figura 2.5 - Câmera Canon Rebel T3i (Manhães, 2015).



Figura 2.6 - Microscópio estereoscópio (Manhães, 2015).



Figura 2.7 - Adaptador câmera/microscópio (Manhães, 2015).

O hardware da máquina é composto ainda por uma fonte de luz (Figura 2.8); um roteador (Figura 2.9), que concentra as comunicações entre os principais equipamentos do sistema: o controlador da mesa, o controlador de sensor e o computador com o software de operação; um rack (Figura 2.10), equipamento utilizado para proteção de alguns dos dispositivos; e uma estrutura metálica rígida, com um tampão de granito, que tem a função de absorver vibrações causadas pelo movimento da mesa XY (Figura 2.11).



Figura 2.8 - Fonte de luz MW150R (Manhães, 2015).



Figura 2.9 - Roteador TPLink (Manhães, 2015)



Figura 2.10 - Rack 16U Fabricante Nilko (Manhães, 2015).



Figura 2.11 - Estrutura metálica construída com tampão de granito (Manhães, 2015).

O software que compõe o Busca-Pite foi desenvolvido utilizando a linguagem C++, o framework Qt para construção da interface e a biblioteca de processamento de imagens e visão computacional OpenCV. Todas estas ferramentas foram compiladas em ambiente Windows.

O programa permite ao usuário tratar uma imagem previamente, no intuito de destacar determinados objetos ou regiões, propiciando a caracterização e a análise com medições mais acuradas.

A interface do sistema possui uma área de exibição/edição de imagens, uma barra de títulos, uma barra de menus e barras de rolagem, como mostra a Figura 2.12. Essa interface se assemelha àquelas presentes em programas editores de imagem. Isto permite que o usuário não enfrente dificuldade ao iniciar seu uso, aproveitando sua vivência com outros programas. Esta estrutura de interface caracteriza-se pela simplicidade e intuitividade, facilitando a operabilidade do mesmo.

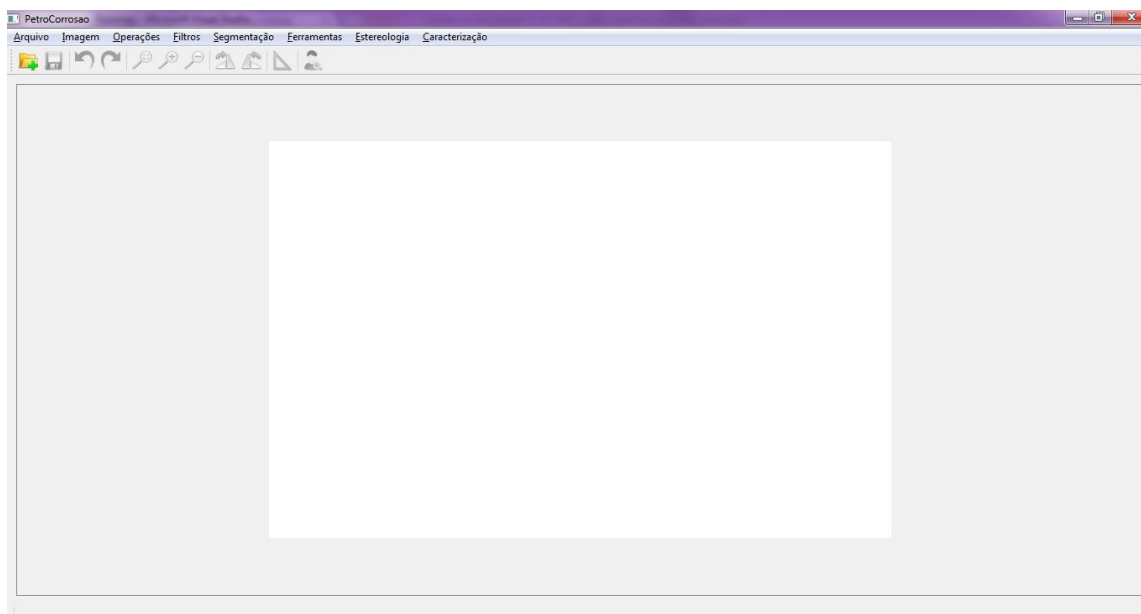


Figura 2.12 - Tela principal do programa (Nogueira, 2013).

Em algumas ocasiões, a imagem deve ser editada para aumentar contraste, destacar detalhes etc. O sistema contém alguns recursos de edição mais usuais para que o usuário não necessite utilizar outro programa de edição de imagens previamente, poupando-lhe tempo. Os seguintes filtros estão incluídos: suavização (Blur, Gaussiano e Média), detecção de borda (borda, Sobel e Laplace) e os morfológicos (erosão e dilatação). A Figura 2.13 ilustra a imagem de trabalho após ser submetida ao operador de borda.




Figura 2.13 - Resultado da aplicação do operador de borda (Nogueira, 2013).

O software possui o recurso de calibração da dimensão das imagens. A função deste recurso é a de determinar a quantos pixels da imagem corresponde uma unidade de comprimento em uso para medir dimensões na estrutura. Por exemplo,

quantos pixels da imagem correspondem a 1 μm na estrutura. Com esta relação, qualquer medição em pixels feita pelo programa na imagem, pode ser convertida para uma unidade de comprimento, área ou volume. O sistema permite salvar a escala ou abrir uma previamente armazenada (Figura 2.14).

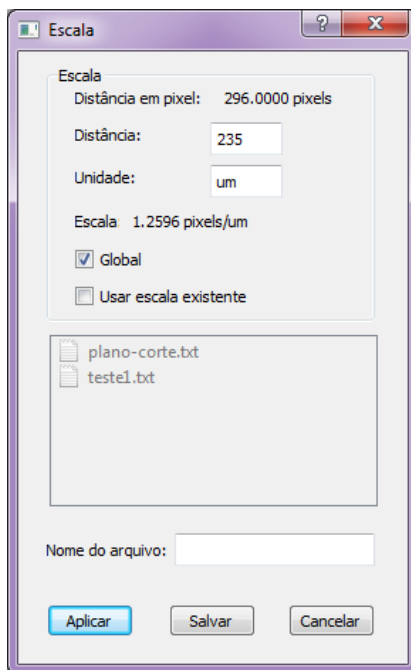


Figura 2.14 - Tela para preenchimento de informações da escala (Nogueira, 2013).

Um dos processos de identificação dos pites na imagem é realizada por uma rotina de segmentação que consiste em dividi-la em regiões distintas, com base na diferença de tons de cinza, como pode ser observado na Figura 2.15. O sistema conta com quatro operações: binária, detecção de contorno, limiar e cluster. O local de medição da profundidade deve ser determinado pelo operador.




Figura 2.15 - Imagem de uma binarização manual. Adaptada de (Nogueira, 2013).

A aplicação possui um segundo recurso de identificação dos pites, denominado de “Segmentação Supervisionada”, a qual é feita manualmente. Por meio dele, é possível incluir, eliminar, erodir e dilatar pites. Os pites identificados são circundados por uma linha vermelha, como mostra a Figura 2.16. Quando um pite é selecionado, o software identifica seu centroide para ser medida a profundidade, mas o usuário pode determinar outro ponto qualquer dentro da região do pite para ser realizada a medição.




Figura 2.16 - Pites selecionados pelo software. Adaptada de (Manhães, 2015).

O sistema conta ainda com um recurso de apagar um lote de pites (Figura 2.17). A partir da análise do histograma da distribuição dos tamanhos dos pites, pode-se informar um parâmetro de corte. Todos os objetos de tamanho menor ou igual ao parâmetro serão apagados da imagem. Esse recurso é utilizado quando se opta por efetuar a identificação dos pites através da segmentação em blocos, para eliminar os ruídos presentes na imagem (Figura 2.15).

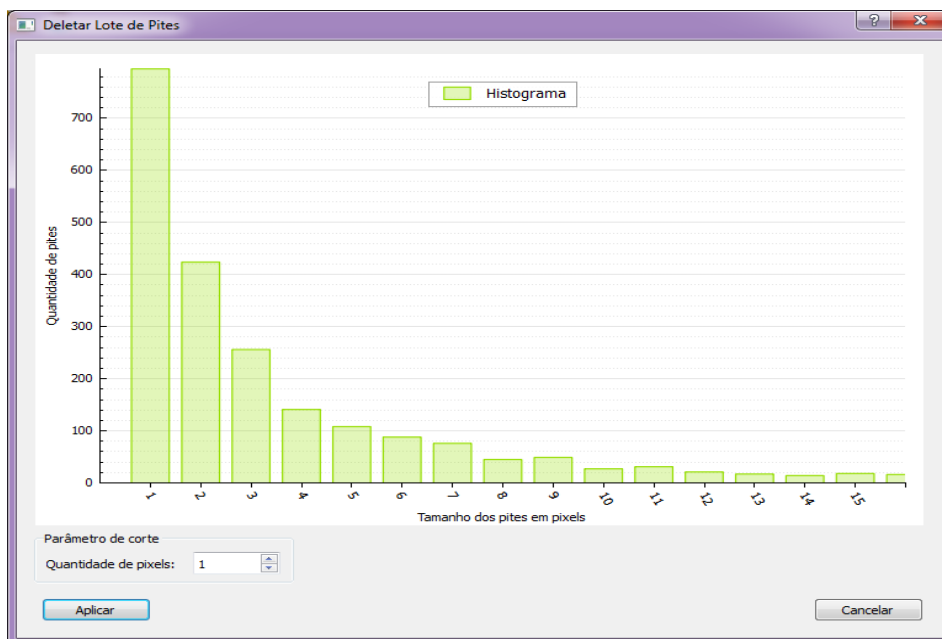


Figura 2.17 - Histograma da distribuição do tamanho dos pites (Nogueira, 2013).

O procedimento de caracterização dos pites fornece como resultado um relatório com as seguintes informações: número total de pites reconhecidos na imagem, escala adotada, densidade de pites, área total dos pites, área média de pites, número de pixels, coordenadas de centroide e profundidade de cada pixel da imagem. Caso uma escala ainda não esteja atribuída à imagem, o sistema requisitará que o usuário o faça. Ao finalizar a análise de pites, uma tela como aquela mostrada na Figura 2.18 é exibida. O relatório pode ser salvo em um arquivo no formato txt.

Medições:

Número de Pites: 4
 Densidade: 2,0757e-07
 Escala: 0,9642 pixels/um
 Área Média: 130152,3498
 Área Total: 520609,3991

Pite	Pixels	Área	Centroide	Profundidade
1 1	268078	288354,6243	(1222, 2443)	0,0827
2 2	79139	85124,8391	(3922, 3092)	0,0789
3 3	79716	85745,4816	(4657, 1948)	0,0893
4 4	57068	61384,4541	(2487, 2743)	0,0840

Figura 2.18 – Relatório final do programa com a medição de profundidade (Manhães, 2015).

A máquina possui ainda uma rotina chamada de Modo Scanner 3D. Este recurso está implementado, parte no software PetroCorrosão, parte no controlador da mesa. Seleccionada a região da amostra, é realizada uma varredura pelo sensor confocal, linha a linha até completar a área seleccionada (Figura 2.19). Os resultados obtidos são salvos em relatório que pode ser analisado com o Excel.




Figura 2.19 - Pite selecionado para varredura (Manhães, 2015).

Os resultados são apresentados em valores de profundidade. Contudo para facilitar a visualização, gráficos podem ser gerados. A Figura 2.20 exhibe um gráfico de vista superior (a), onde se pode visualizar o contorno do pite (em azul), e outro com uma vista lateral (b), para observar a diferença da distância entre as duas regiões que são o fundo e a superfície em volta do pite.

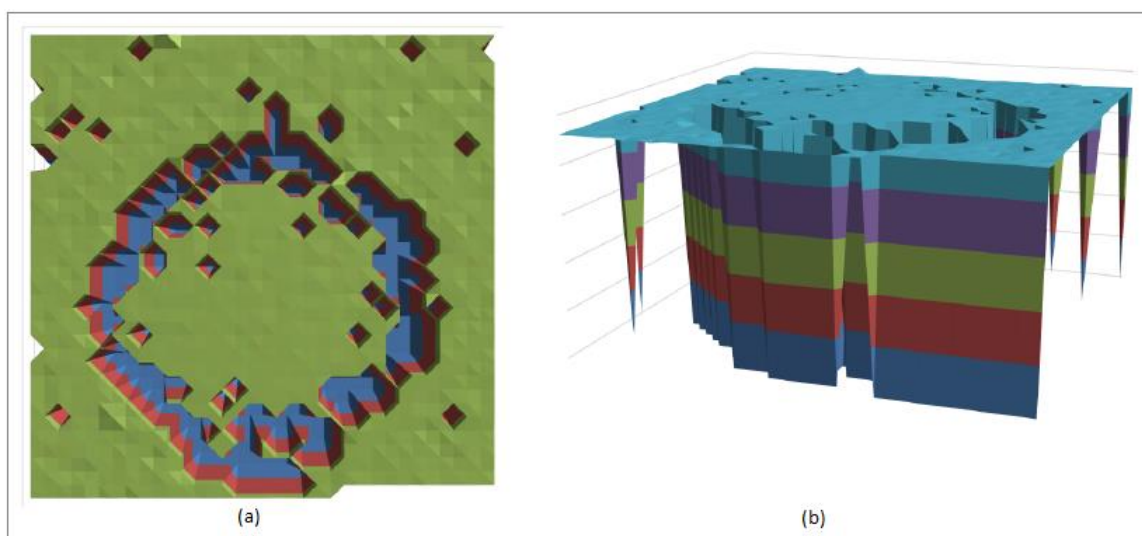


Figura 2.20 - Gráfico gerado em excel da vista superior do pite (a) e vista lateral (b). Adaptada de (Manhães, 2015).

2.2.1 – Caracterização de Pites com a Máquina Busca-Pites

Um método de caracterização foi desenvolvido para operar a máquina, que envolve a medição de tamanho e de profundidade de um grande número de pites, porém o método convencional de medir apenas os maiores e mais profundos pode também ser usado, acelerando o processo de medição (Nogueira, 2013; Manhães, 2015).

Inicialmente, o cupom de corrosão é dividido em regiões. Um certo número de imagens capturadas em locais aleatórios de cada região é usado para a caracterização. O aumento de microscópio é escolhido de acordo com o tamanho dos pites presentes. Deve ser tal que inclua na imagem quantidades representativas dos pites maiores e dos menores. Em cupons que apresentam grande quantidade de pites é impraticável medir toda sua superfície. Porém, o número de imagens sugerida pelo método é superior àquele praticado geralmente.

Em seguida, a imagem é capturada e o operador executa a segmentação dos pites presentes na imagem. O programa possui recursos de segmentação de blocos de pites baseados em contraste de tons de cinza. Este método é muito rápido, pois segmenta todos os pites de uma vez só, mas geralmente, as imagens não são “limpas” o suficiente, e muitos ruídos são também segmentados. Recursos de limpeza disponíveis devem então ser empregados para eliminar o ruído. Às vezes, o tempo gasto para tal é muito longo e o método manual torna-se compensador.

O programa possui recursos de segmentação manual. Neste caso, o operador aponta, sobre a imagem, com o mouse, cada pite que ele deseja segmentar.

Todos os pites segmentados são contados. Como a área da imagem é conhecida, a densidade de pites é determinada. As áreas de todos os pites segmentados são medidas, não apenas as dos maiores pites.

As coordenadas do centroide de cada pite segmentado são determinadas pelo programa ou definidas pelo operador. Estas coordenadas serão usadas para mover o cupom de maneira que cada pite seja iluminado pelo feixe de luz do sensor confocal, de maneira que sua profundidade seja medida. As profundidades de todos os pites segmentados são medidas, não apenas as dos mais profundos.

Ao final, o relatório é preparado com o resultado apresentado segundo as recomendações das normas (ASTM, 1994) e (NACE, 2005), sem a necessidade de cálculos manuais. Outras informações são fornecidas, tais como tamanho e profun-

didade de cada pite. Isto permite a construção de curvas de distribuição de tamanho e profundidade de pites.

2.2.1 – Comparação entre Técnicas Diferentes de Caracterização de Pites

Para comparar o tempo que o Busca-Pite demanda para a caracterização de um cupom de corrosão em relação aos outros métodos, foi utilizada a chamada técnica indireta. Esta técnica possui como característica não analisar necessariamente os mesmos pites nos diferentes equipamentos analisados. A busca por pites específicos demandaria muito tempo e esforço do operador, o que prejudicaria os resultados e inviabilizaria a comparação (Manhães, 2015).

Para realização deste estudo comparativo, um cupom de aço inoxidável T9 exposto em água potável aerada durante 30 dias foi utilizado. O cupom apresentou baixa densidade de pites, de contornos bem definidos. O cupom foi dividido em 26 regiões de frente, verso e lateral. Imagens em posições aleatórias de cada região foram tomadas proporcionalmente à área de cada região. Ao todo, 58 imagens do cupom foram analisadas, totalizando 15% de sua área total (Manhães, 2015).

2.2.1.1 – Método Convencional

O método possui três camadas de medição, conforme descrito. Para acelerar o processo de caracterização, duas camadas foram reunidas em uma só com uso de um software analisador de imagens. O procedimento está descrito em seguida.

O cupom é colocado em um microscópio estereoscópico, acoplado ao Busca-Pite. Uma posição aleatória em uma região do cupom é determinada e fotografada. A imagem é capturada. O cupom é movido para a próxima posição naquela região para nova captura de imagem (Pereira *et al.*, 2016; Silva, 2016). O procedimento é repetido para todas as regiões, até que todas as 58 imagens sejam capturadas.

Em seguida, as imagens são transferidas para o programa OLYMPUS ANALYSIS FIVE. Neste programa, uma imagem é aberta e cada pite presente nela é contornado com a ajuda do mouse. O programa mede a área no interior do contorno e salva em um arquivo. Ao final, o arquivo contém o número de pites medidos, a área de cada pite, e a área média de pite.

Para a caracterização da profundidade, optou-se por seguir estritamente a norma G46 e medir apenas as profundidades dos dez pites mais profundos do cupom. Para isto, a superfície é examinada a olho nu e os pites que aparentam ser os mais profundos, por sua tonalidade escura, são medidos. O procedimento para medição da profundidade já foi descrito. A profundidade de cada pite é anotada em papel.

Ao final, o arquivo com os valores de área média de pite e o número total de pites é aberto. A área média de pite representa o tamanho médio de pite. O número de pites medidos, dividido pela área total da imagem representa a densidade de pites. A média aritmética das profundidades medidas dos dez pites supostamente mais profundos é calculada. Assim, o resultado final é obtido.

2.2.1.2 – Microscópio Confocal

Neste microscópio, o cupom é colocado no estágio e movido para a região a ser fotografada. Ajustados o aumento e foco, a imagem é capturada. Este processo demora alguns minutos para se completar. A imagem é processada e sua versão em 3D é exibida na tela. Uma vez que o relevo é exibido, é fácil reconhecer a posição dos pites. Cada pite é contornado com uma ferramenta específica. O valor da área contornada é medido e salvo em arquivo. Este procedimento se repete para cada pite da imagem. Para medir a profundidade de cada pite, faz-se uso de outra ferramenta que traça o perfil linear do pite. A linha de perfil é posicionada para coincidir com a máxima profundidade do pite a ser medido. Com auxílio de outra ferramenta, a profundidade é medida e salva em arquivo (Pereira *et al.*, 2016; Silva, 2016).

O sistema gera dois arquivos separados com os resultados de área e profundidade. Os valores médios de área e de profundidade devem ser calculados em planilha. É importante ressaltar que o microscópio confocal permitiu a determinação rápida da profundidade de todos os pites presentes na imagem, e não somente dos dez pites supostamente mais profundos do cupom. A não ser que o operador se preocupe especificamente, a ordem de medição das áreas de cada pite e das profundidades diferem. Com isso, não se pode assegurar, por exemplo, que a primeira área e a primeira profundidade medidas correspondem ao mesmo pite. Porém, para cálculo de valores médios isto não importa. A densidade de pites da imagem é cal-

culada dividindo-se o número de pites (todos) pela área da imagem, que é informada pelo microscópio.

2.2.1.3 – Busca-Pite

O procedimento de uso do Busca-Pite foi descrito anteriormente. O cupom é colocado no estágio do microscópio, o aumento e o foco são ajustados, e a posição aleatória em uma dada região do cupom é determinada. Uma imagem da superfície do cupom é capturada. Com auxílio de uma ferramenta específica do programa, cada pite é segmentado por um clique de mouse sobre sua imagem. Esta segmentação funciona com base no tom de cinza mais escuro dos pites. Há casos em que os pites apresentam grande variação de tonalidade. Por isso, o programa segmenta apenas parcialmente o pite. Quando isso ocorre, outros cliques em regiões vizinhas são necessários para que todo o pite seja segmentado. O método de segmentação em bloco não foi usado por não ter se mostrado eficiente (Nogueira, 2013; Manhães, 2015; Pereira *et al.*, 2016; Silva, 2016).

Após a segmentação de todos os pites presentes na imagem, o operador aciona a rotina de análise. O programa mede instantaneamente a área de todos os pites presentes, conta o número de pites e a área total da imagem. A densidade de pites é calculada. Em seguida, o cupom é movido na direção do sensor que mede a profundidade, segundo as coordenadas do centroide de cada pite. A profundidade do centroide de cada pite é medida sequencialmente. Ao fim, o sistema exibe uma tela com o relatório. Os valores de área média, profundidade média, densidade de pites, área de cada pite, profundidade de cada pite são salvos em um só arquivo, sem a necessidade de cálculos posteriores. Neste relatório, sabe-se exatamente qual a área e a profundidade de cada pite.

As Tabelas 1 a 3 apresentam as medidas de tempo médio de caracterização por imagem com uso das três técnicas de caracterização apresentadas. Há, geralmente, entre 8 e 10 pites por imagem.

Tabela 1 - Tempo médio por imagem de caracterização de pites usando o Busca-Pite.

Etapas	Descrição	Tempo Gasto (min)
1	Captura da imagem	0,7
2	Segmentação dos pites	4
3	Determinação de densidade, tamanho e profundidade	1
4	Obtenção dos resultados finais	0
Tempo Total Consumido (min)		5,7

Fonte: Projeto Petro-Corrosão, UENF-PETROBRAS(2015) *apud* (Manhães, 2015).

Tabela 2 - Tempo médio por imagem de caracterização de pites usando o método convencional (microscópio ótico).

Etapas	Descrição	Tempo Gasto (min)
1	Captura da imagem	0,7
2	Segmentação dos pites	5
3	Determinação de densidade e tamanho médio dos pites	3
Tempo Parcial Consumido por imagem (min)		8,7
4	Determinação das profundidades dos 10 pites mais profundos	40
5	Determinação da profundidade média dos pites mais profundos	3
Tempo Parcial Consumido por cupom (min)		43

Fonte: Projeto Petro-Corrosão, UENF-PETROBRAS(2015) *apud* (Manhães, 2015).

Tabela 3 – Tempo médio por imagem de caracterização de pites usando o microscópio confocal.

Etapas	Descrição	Tempo Gasto (min)
1	Captura da imagem	4
2	Segmentação dos pites	2
3	Determinação de densidade e tamanho médio dos pites	3
4	Medição das profundidades dos pites	3
5	Determinação da profundidade média dos pites	0
Tempo Total Consumido (min)		12

Fonte: Projeto Petro-Corrosão, UENF-PETROBRAS(2015) *apud* (Manhães, 2015).

O método Busca-Pite e o microscópio confocal medem a profundidade de todos os pites segmentados na imagem, algo que seria inviável no método tradicional, que só mede os dez pontos mais profundos de cada cupom. Isto por conta do tempo gasto para a determinação da profundidade de um pite no método convencional ser muito grande. O tempo que se leva no método convencional para determinar a densidade e a área dos pites também se mostrou bastante elevado em relação ao busca-pites (Manhães, 2015).

O tempo gasto para a caracterização dos pites via Busca-Pites se mostrou bastante reduzido em relação ao método convencional e ao método que utiliza o microscópio confocal. Isto possibilita a análise de um número maior de amostras em um determinado período, se colocado em comparação às outras duas técnicas (Manhães, 2015).

Para a caracterização de todas as imagens de um cupom o tempo médio deve ser multiplicado pelo número total de imagens. Assim, para caracterizar um cupom com as características semelhantes ao do teste serão demandados 5,51 horas com a utilização da máquina Busca-Pite, 9,12 horas pelo método convencional e 11,6 horas pelo método microscópio confocal (Manhães, 2015).

2.3 – Computação Gráfica

A Computação Gráfica é a área da Ciência da Computação que estuda a geração, manipulação e análise de imagens, desenvolvendo técnicas e algoritmos com essas finalidades (Manssour e Cohen, 2006). A Computação Gráfica está presente em quase todas as áreas do conhecimento humano, desde o projeto de um novo modelo de automóvel até o desenvolvimento de ferramentas de entretenimento (Santos *et al.*, 2001; Azevedo e Conci, 2003; Manssour e Cohen, 2006).

Segundo (Gomes e Velho, 2003) a computação gráfica pode ser dividida em quatro subáreas que relacionam dados e imagens. Essas subáreas são tão próximas que estão muitas vezes interligadas, em determinados momentos são até confundidas. Estas subáreas são: Modelagem Geométrica, Síntese de Imagem, Processamento de Imagem e Análise de Imagens.

O Processamento de Imagens assume como informação de entrada uma imagem, processa-a e produz outra imagem como informação de saída (Gomes e Velho, 2003). As técnicas desta área podem ser utilizadas, por exemplo, para melhorar a qualidade de uma imagem antiga ou danificada, produzindo outra imagem com menos ruídos (Marques Filho e Vieira Neto, 1999).

2.3.1 – Reconhecimento de Foco

Em um microscópio, a imagem de um objeto percebida por um olho, ou algum sensor ótico, estará em foco, se o objeto sob observação estiver a uma determinada

distância da lente objetiva. Distâncias maiores ou menores que aquela, não revelará nenhum detalhe adicional da estrutura (Mannheimer, 2002). Sempre que a imagem de um determinado objeto estiver em foco, tem-se a distância de trabalho, que é a distância entre a superfície do objeto e a lente objetiva (Dedavid *et al.*, 2007; Keller, 2006; Olympus, 2018). Desta maneira, é possível usar o foco de uma imagem como indicador de distâncias.

A Figura 2.21 ilustra a situação em que o volume de uma amostra é observado através de uma lente. Diferentes pontos do volume da amostra situam-se a distâncias diferentes da lente. A luz que parte de cada ponto da amostra converge em distâncias diferentes do outro lado da lente. O detalhe abaixo, em negro, representa a imagem observada no plano identificado como plano focal. Somente o ponto em foco neste plano é visto com nitidez. Todos os demais pontos parecem fora de foco.

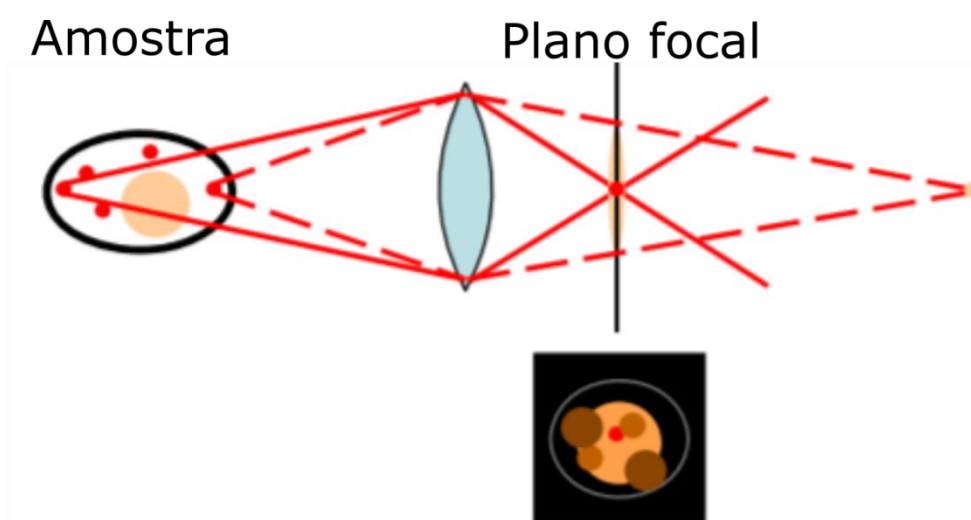


Figura 2.21 - Esquematização da formação de uma imagem por uma lente. Somente os pontos do objeto observado cuja luz converge no plano focal aparecerão nítidos ao observador. Fonte: adaptado de (Spitaler, 2018)

Se as distâncias entre dois objetos e a objetiva de um microscópio forem diferentes, pode-se determinar a distância entre os dois objetos (Gartner e Hiatt, 2007; Mannheimer, 2002). Para isso deve-se ajustar a distância entre o primeiro objeto e a objetiva, até que sua imagem esteja em foco. O segundo objeto parecerá fora de foco. Em seguida, ajusta-se a distância da lente até que a imagem do segundo objeto esteja em foco. A imagem do primeiro objeto perderá o foco. A distância em que a objetiva foi movida, para focar os diferentes objetos, é a distância entre eles. Este é o princípio de funcionamento da técnica de variação de foco. Ela pode ser usada para determinar a topografia de uma superfície.

Se uma superfície que contenha relevo (não plana) for observada por meio de um microscópio, apenas as partes da superfície que estiverem a uma dada distância da objetiva, parecerão em foco na imagem. As partes com outras distâncias parecerão fora de foco. Movendo-se a objetiva para mais próximo ou distante da superfície, ou equivalentemente, movendo-se a superfície para mais próximo ou distante da objetiva, outras partes da superfície passarão a estar em foco, enquanto que as partes antes em foco, perderão o foco (Häusler, 1972; Pieper e Korpel, 1983; Danzl *et al.*, 2011). A distância no eixo de movimento entre dois pontos em foco em duas fotografias distintas será a distância percorrida no dado movimento.

Para determinar o relevo da superfície, pode-se utilizar uma série de fotografias da mesma superfície. Cada fotografia é feita com uma distância diferente entre a superfície e a objetiva (Ortega, *et al.*, 2000; Ferraro, *et al.*, 2005). Essa distância não precisa ser conhecida. Basta que se conheça a distância entre as posições em que cada fotografia foi feita. Isso pode ser feito movendo a objetiva para mais perto ou distante da superfície ou movendo a superfície para mais perto ou distante da objetiva. Em cada fotografia, partes diferentes da imagem estarão em foco. Ao se identificar dois pontos em duas imagens que estejam em foco, a distância entre esses pontos será a distância entre as duas posições em que as fotografias foram feitas. Usando esse procedimento para todos os pontos das imagens, determina-se a topografia da superfície em observação. O problema resume-se desta maneira a saber reconhecer quando os pontos nas imagens estão ou não em foco.

2.3.2 – Variação de Foco

A variação de foco consiste na construção de uma única imagem, com total nitidez na região observada do objeto, a partir de um conjunto de imagens do mesmo local da superfície (Ferraro, *et al.*, 2005; Nguyen *et al.*, 2012). Cada foto é analisada e suas partes em foco nítido são copiadas, com base em algoritmos numéricos, para uma imagem auxiliar, como pode ser observado na Figura 2.22. As partes em foco são identificadas através da análise de contraste (Ortega, *et al.*, 2000; Mir *et al.*, 2014).

Para observar um objeto de forma complexa, com elevada ampliação, é necessário alterar a distância entre o objeto e o microscópio para focalizar diferentes partes da superfície na imagem (Figura 2.22) (Häusler, 1972; Pieper e Korpel, 1983;

Danzl *et al.*, 2011). O microscópio é movido ao longo do eixo óptico com um determinado número de passos entre o mais próximo e o mais distante do objeto. Para cada passo, uma imagem é armazenada junto com a informação da profundidade do foco em que foi obtida, devido à importância das propriedades tridimensionais do objeto que está sendo fotografado (Bradburn *et al.*, 1997; Ortega, et al., 2000; Ohba *et al.*, 2003; Ferraro, et al., 2005).

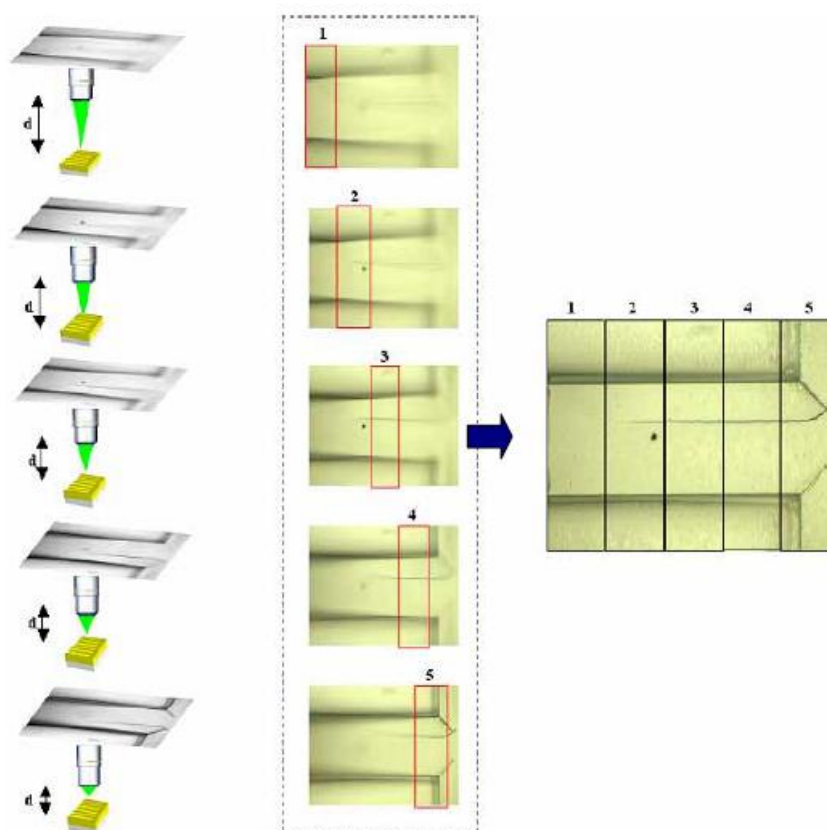


Figura 2.22 - Pilha de imagens com diferentes focos do objeto e imagem com total nitidez, á direita (Ferraro, et al., 2005).

2.3.3 – Point Spread Function (PSF)

Na realidade, o problema descrito na seção 2.3.1 – Reconhecimento de Foco é um tanto mais complexo. A Figura 2.23 ilustra uma superfície hipotética com relevo em forma de degraus à frente de um microscópio, enquanto um sensor de uma câmera fotográfica captura a imagem produzida em um plano. Cada pixel do sensor óptico captura luz oriunda de diversos pontos da superfície com diferentes intensidades. O pixel central captura com maior intensidade, a luz vinda do degrau central da superfície devido a sua posição, mas principalmente devido a estar no plano focal em razão da distância entre este ponto da superfície e a objetiva do microscópio. No

entanto, este mesmo pixel do sensor captura luz vinda também de pontos vizinhos da superfície. Estejam eles na mesma distância para a lente ou não. Entretanto, a intensidade da luz captada desses pontos é menor. A intensidade da luz é indicada pela tonalidade do vetor que representa o feixe de luz que parte de cada ponto da superfície e chega a cada pixel do sensor óptico. Quanto mais escura a tonalidade, mais intensa é a luz. Assim, a luz captada por cada pixel do sensor é uma sobreposição de feixes de diferentes intensidades oriundos de diferentes pontos da superfície, situados a diferentes distâncias laterais e verticais. A distribuição de entrada de cada pixel pode ser considerada como consistindo em uma coleção muito grande de pontos muito pequenos (infinitesimal¹) de intensidade variável. A informação de como cada um destes pontos aparecerá na saída é dada pela função de espalhamento de ponto ou Point Spread Function (PSF), pois ela mede o espalhamento na resposta de intensidade de saída devido a um ponto infinitesimal de entrada (Marques, 1994; Solomon e Breckon, 2013; Alberts, et al., 2017).




Figura 2.23 - Imagem de superfície com relevo em degraus observada com microscópio capturada por sensor óptico. Fonte: próprio autor

Essa situação pode ser modelada matematicamente. Seja S a superfície em observação dentro de um volume Ω e seja S' a imagem da superfície S capturada por um sensor plano instalado em um microscópio. A imagem S pode ser representada pela equação:

$$S' = P * S + R, \quad (2.1)$$

onde R é a soma de todos os ruídos presentes durante o período de captura e P é denominada função de espalhamento de ponto, ou Point Spread Function (PSF), do microscópio (Solomon e Breckon, 2013).

¹ Infinitamente preciso.

O símbolo * representa a operação de convolução entre a função que representa a superfície e a PSF, que pode ser escrita matematicamente como:

$$S'(x, y) = \int \int \int P(u, v, w, x, y)S(u, v, w)dudvdw + R(x + y). \quad (2.2)$$

Quando a PSF é invariante sob translação, caso da maioria das lentes, tem-se:

$$P(u, v, w, x, y, z) = P(u - x, v - y, w - z). \quad (2.3)$$

A PSF descreve como a luz que parte do objeto é “processada” pelo dispositivo ótico (microscópio) antes de sensibilizar o sensor. É ela que guarda a informação de como os feixes de luz oriundos de diferentes pontos do objeto sensibilizam diferentes pixels do sensor de captura da imagem (ZEISS, 2018; Huang *et al.*, 2002).

O significado da PSF talvez seja mais bem descrito supondo que um feixe de luz oriundo de um pequeno ponto percorre o sistema ótico de um microscópio. Se fotografias daquele pequeno ponto são tomadas em diferentes distâncias entre o objeto e a lente objetiva do microscópio, as imagens capturadas parecerão com aquelas exibidas na Figura 2.24. Observe que é a fotografia central que representa mais fielmente a imagem do ponto observado. Isso ocorre porque o objeto está a tal distância que sua imagem está em foco. Quando a distância é diferente daquela, sua imagem torna-se menos nítida. Porém, mesmo em foco, a imagem do ponto ainda é um tanto difusa. A PSF é uma função cujo valor em cada ponto (x,y,z) representa a intensidade de luz capturada pelo sensor. A Figura 2.25 mostra uma seção da PSF no plano YZ, passando pela origem.




Figura 2.24 - Imagens de um ponto luminoso tomadas em diferentes distâncias entre a lente e o objeto. A imagem torna-se mais nítida à medida que a distância ao objeto se aproxima da distância focal (imagem do centro). A intensidade da luz em cada ponto representa o valor da PSF. Adaptada de (Spitaler, 2018).




Figura 2.25 - Seção da PSF no plano YZ que passa pela origem. Adaptada de (Spitaler, 2018).

A Figura 2.26 ilustra graficamente o efeito da convolução da imagem real do objeto com a PSF para dar origem à imagem capturada pelo microscópio.




Figura 2.26 - A imagem capturada é resultante da convolução entre a imagem real do objeto e a PSF. Adaptada de (Default007, 2018)

A PSF pode ser determinada experimentalmente, ou pode ser modelada a partir de uma expressão padrão adaptada a informações do dispositivo ótico em uso. A Figura 2.27 exibe imagens da PSF de um microscópio confocal usando uma lente objetiva imersa em óleo e abertura numérica de 1,4 com ampliação de 63X.




Figura 2.27 - Imagens dos planos XZ, XY, YZ e da representação 3D de uma PSF determinada experimentalmente de um microscópio confocal usando objetos de 100nm com luz de comprimento de onda entre 500 e 620nm (Vindin, 2018).

2.3.3.1 – Restauração de Imagens com Uso da PSF

A convolução entre a PSF e a imagem real resulta em uma imagem capturada que não representa fidedignamente a imagem real. É possível, usando a imagem capturada e a PSF, obter a imagem real. A esta operação, denomina-se deconvolução. Também chamada genericamente de restauração da imagem (Solomon e Breckon, 2013; Jansson, 2014).

Extraindo a transformada de Fourier da expressão:

$$S' = P * S + R, \quad (2.4)$$

tem-se

$$F\{S'\} = F\{P * S\} + F\{R\}. \quad (2.5)$$

Contudo, pelo teorema da convolução, a transformada de Fourier da convolução de duas funções é o produto das transformadas de ambas as funções (Solomon e Breckon, 2013). Ou seja,

$$F\{S'\} = F\{P\}F\{S\} + F\{R\}. \quad (2.6)$$

A transformada de Fourier da PSF é denominada de Função de Transferência Ótica (FTO). Ela indica como as frequências que compõem a imagem do objeto são convertidas pelo microscópio para as frequências da imagem capturada (Solomon e Breckon, 2013).

Ao ignorar o ruído da imagem, a expressão pode ser reescrita como:

$$F\{S\} = \frac{F\{S'\}}{F\{P\}}. \quad (2.7)$$

O inverso da transformada de Fourier da FTO é denominado de filtro inverso. Assim, ao aplicar o filtro inverso na transformada de Fourier da imagem capturada, obtém-se a transformada de Fourier da imagem real do objeto. A transformada inversa será a imagem real do objeto. Ou seja, a imagem restaurada.

O filtro inverso é apenas uma das técnicas de restauração usando a PSF. O uso desse filtro frequentemente traz resultados insatisfatórios e imprevisíveis. Quando a contribuição de determinadas frequências é nula ou muito pequena, o filtro inverso tende a infinito. A solução encontrada é truncar o filtro inverso dessas frequências. O problema maior, entretanto, ocorre na presença de ruído, visto que ele insere no problema uma variável de valor imprevisível. A Figura 2.28 ilustra dois casos em que uma imagem foi submetida ao filtro inverso. Na sequência de cima, não há ruído na imagem original. Vê-se a PSF, a FTO e a imagem restaurada com a aplicação do filtro inverso. Na sequência inferior, um ruído gaussiano foi introduzido na imagem original. A PSF e a FTO são mostradas. A aplicação do filtro inverso nesse caso leva a uma imagem completamente distinta daquela original.




Figura 2.28 - Imagens restauradas com aplicação do filtro inverso, sem e com a presença de ruído. Adaptado de (Solomon e Breckon, 2013).

O filtro de Wiener-Helstrom é uma técnica que procura resolver as falhas do filtro inverso. Ele possui as seguintes características: a) suprime as frequências nas quais o ruído é muito maior do que na imagem original; b) tende ao filtro inverso quando a contribuição do ruído pode ser desprezada e; c) quando as componentes de frequência de ruído e da imagem original são da mesma magnitude, o filtro avalia a necessidade de supressão ou aceitação (Solomon e Breckon, 2013).

Existem diversos métodos de deconvolução. Todos baseados na PSF. Alguns são executados em uma única etapa e são rápidos, podendo ser empregados em tempo real, mas são altamente imprecisos e suscetíveis a efeito de ruídos. Outros são iterativos, requerem PSF experimentalmente determinadas, ou usam uma PSF calculada que vai sendo otimizada durante o processo. Esses métodos são muito intensivos em tempo de máquina (Spitaler, 2018). No caso deste trabalho, a PSF é desconhecida, assim como as informações básicas para determiná-la por meio de cálculos. Além disso, o tempo curto de processamento é uma restrição importante a ser observada. Isso elimina o uso desses métodos no trabalho.

2.3.4 – Estimadores

Os estimadores são algoritmos implementados a partir de princípios matemáticos, com o objetivo de reconhecer se um pixel de uma imagem se encontra, ou não, em foco nítido.

2.3.4.1 – Laplaciano

Segundo (Gonzalez e Woods, 2002) o laplaciano de uma função de duas variáveis $f(x, y)$ é uma derivada de segunda ordem definida como:

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}. \quad (2.8)$$

A Figura 2.29 exhibe máscaras para as quais o operador pode ser aproximado:

$$\begin{array}{ccc}
 \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} & \begin{bmatrix} -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & 24 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \end{bmatrix} & \begin{bmatrix} -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & 8 & 8 & 8 & -1 & -1 & -1 \\ -1 & -1 & -1 & 8 & 8 & 8 & -1 & -1 & -1 \\ -1 & -1 & -1 & 8 & 8 & 8 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \end{bmatrix} \\
 \text{(a)} & \text{(b)} & \text{(c)}
 \end{array}$$

Figura 2.29 - Máscaras para o cálculo do laplaciano: (a) 3 x 3, (b) 5 x 5, (c) 9 x 9 (Marques Filho e Vieira Neto, 1999).

Embora o laplaciano seja insensível à rotação, e, portanto capaz de realçar ou detectar bordas em qualquer direção, seu uso é restrito devido a sua grande susceptibilidade a ruído.

2.3.4.2 – Entropia

A entropia é uma medida do conteúdo da informação ou da organização de um sistema. Considerando que existem n símbolos possíveis x (por exemplo, letras ou dígitos) e esse símbolo i ocorrerá com probabilidade $p(x_i)$, quanto maior for este número, mais informação estará associada à imagem analisada. De acordo com Albuquerque, *et al.* (2004) e Assirati (2014) o cálculo da entropia de uma imagem X pode ser realizado através da seguinte fórmula:

$$H(X) = - \sum_{i=1}^n p(x_i) \ln(p(x_i)) \quad (2.9)$$

Este número indica a quantidade média de informação em unidades binárias obtida da imagem.

2.3.4.3 – Intensidades do Histograma

O histograma é uma das formas mais comuns de se representar a distribuição de valores de pixel de uma imagem. Ao observá-lo (Figura 2.30), tem-se uma noção instantânea sobre as características de uma imagem, visto que por sua forma é possível inferir informações relevantes, tais como intensidade média e distribuição dos valores de pixel. Quanto maior a distribuição ao longo do eixo dos valores de pixel maior o contraste da imagem (Neta *et al.*, 2008).




Figura 2.30 - Histograma de frequência de uma imagem (Gomes e Velho, 2003).

2.3.5 – Técnicas de Determinação de Relevância de Superfície por Variação de Foco

Essas técnicas procuram identificar nas imagens de uma pilha as partes de cada uma que estão em foco sem usar a deconvolução. Portanto, não precisam da PSF. Elas buscam um compromisso entre precisão e velocidade. As técnicas de deconvolução, em princípio, eliminam de cada pixel os sinais superpostos oriundos de áreas adjacentes da superfície em observação. Essas técnicas não fazem isso. Elas apenas tentam identificar as partes da imagem que estão em foco. Isso já é suficiente para compor uma imagem toda em foco, com as informações sobre o relevo da superfície.

A Tabela 4 lista alguns programas que determinam relevo de superfícies a partir de pilhas de imagens obtidas em diferentes distâncias.

Tabela 4 - Alguns programas que usam a técnica de focus stacking.

Programa	Autor	Licença	Uso
ALE	David Hilvert	Open source, GPL	Grátis
CombineZM	Alan Hadley	Open source, GPL	Grátis
Image Pro Express	Media Cybernetics	Proprietário	Comercial
Image Pro Plus	Media Cybernetics	Proprietário	Comercial
Photoshop CS4 extended	Adobe Inc.	Proprietário	Comercial
Extended Depth of Field (plug in do Image J)	Alex Prudencio	Proprietário	Grátis para pesquisa
Stack Focuser (plug in para Image J)	Michael Umorin	Open source, GPL	Grátis

Fonte: Adaptado de (Palaeo-electronica, 2018).

Todos esses programas usam a mesma técnica já descrita na seção 2.3.2 – Variação de Foco. A principal diferença entre eles está na forma de apontar em que imagem está o melhor foco de uma determinada parte da cena.

O plugin Stack Focuser para o Image J executa a técnica de variação de foco nas seguintes etapas (Umorin, 2018):

- A imagem é colocada em tons de cinza.
- Executa um filtro mediano com máscara 3x3 para eliminar ruído da imagem original
- Executa um filtro Sobel para detecção de bordas.
- Executa um filtro de máximo, procurando o maior valor de pixel em uma máscara 3x3 em torno do pixel sob exame. O foco naquele pixel estará na imagem que possui o maior valor encontrado pelo filtro de máximo.

O plugin Extended Depth of Field para o Image J coloca à disposição do usuário diversos critérios de verificação de foco (Biomedical Imaging Group, 2018). São eles: Sobel, variância, wavelets reais e wavelets complexas. Os autores do plugin ainda disponibilizam uma outra técnica denominada de Método Baseado em Modelo. Essa técnica faz uso de uma PSF calculada com base na função gaussiana. Durante o processo iterativo, a PSF é otimizada e a textura e a topografia da superfície são construídas (Aguet *et al.*, 2007). Segundo os autores, o melhor resultado é encontrado pela última técnica citada, porém às custas do tempo de execução.

Aydin e Akgul (2008) descrevem uma técnica de variação de foco que envolve uma variante do filtro laplaciano em que o valor do filtro para cada pixel é calculado com a adição de um peso. O filtro laplaciano envolve o cálculo da segunda derivada em todos os pixels dentro da máscara usada. Quanto mais próximo o pixel estiver do centro da máscara e mais próximo estiver a tonalidade do pixel daquele do centro da máscara, maior será o peso atribuído àquela derivada. Os autores usaram máscaras de tamanhos entre 9x9 e 25x25. Eles relatam resultados superiores a outro sem os pesos. Dizem que seu método é especificamente vantajoso na preservação das bordas entre regiões adjacentes com descontinuidades severas de relevo.

2.4 – Redes Neurais Artificiais (RNA's)

As redes neurais artificiais (RNA's) são sistemas que buscam imitar o comportamento e a estrutura do cérebro humano, contudo, possuindo um conjunto limitado de neurônios. Esses neurônios, por sua vez, processam paralelamente os dados e os propagam através de uma complexa malha de interconexão (Finocchio, 2014). A Figura 2.31 mostra o modelo de um neurônio, que forma a base para o projeto de redes neurais. Na figura se pode observar os três elementos básicos do modelo neuronal, que são (Haykin, 2007):

- Um conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso ou força própria.
- Um somador para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio.
- Uma função de ativação para restringir a amplitude da saída de um neurônio. Tipicamente, o intervalo normalizado da amplitude da saída de

um neurônio é escrito como o intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$.

O modelo neuronal inclui também um bias aplicado externamente, representado por b_k , que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente.




Figura 2.31 - Modelo não-linear de um neurônio (Haykin, 2007).

Segundo Haykin (2007), a maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. A propriedade primordial de uma rede neural é a sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem. A melhoria do desempenho ocorre com o tempo de acordo com alguma medida preestabelecida. Uma rede neural aprende acerca do seu ambiente através de um processo iterativo de ajustes alocados a seus pesos sinápticos e níveis de bias. Idealmente, a rede se torna mais instruída sobre o seu ambiente após cada iteração do processo de aprendizagem.

Os modelos RNA's constituem uma importante técnica estatística não-linear capaz de resolver uma gama de problemas de grande complexidade. Por isso, são modelos úteis em situações que não é possível definir explicitamente uma lista de regras. Em geral, isso acontece quando o ambiente gerador dos dados muda constantemente. As principais áreas de atuação são para classificação de padrões e previsão (Velasco, 2007).

2.5 – Trabalhos Correlatos

O microscópio óptico sempre teve grande importância na pesquisa e desenvolvimento de materiais (Fazano, 2005). Com a microscopia, consegue-se obter grandes ampliações para a investigação de micro objetos. Entretanto, quanto maior é a ampliação, mais fina é a imagem correspondente em foco (Fraser, 2003). Em objetos de formas complexas, isto é, três dimensões ou mesmo de superfície irregular, apenas uma parte dele aparece em bom foco para o observador (Ferraro, et al., 2005).

Uma análise acurada requer toda a superfície de um objeto em foco na imagem, mesmo se os planos forem irregulares ao longo da direção longitudinal (Merz, 1965). Tal limitação leva à criação de diversas imagens (Schroettner *et al.*, 2006) para análise e assim, torna o trabalho mais árduo e moroso. A técnica de variação de foco insere-se nesse contexto como uma alternativa para superar essa limitação.

Em seu trabalho Danzl *et al.* (2009), descrevem um microscópio óptico de foco infinito, o Alicona Infinite Focus. O equipamento conta com um sistema de lentes. Este instrumento realiza uma varredura no plano XY para cada posição incremental no eixo Z e, para cada novo posicionamento são adquiridos os pontos pertencentes à região reconhecida como “focalizada” da peça. Por fim, todos os pontos são processados e a peça tridimensional é montada com emprego de um programa computacional. Ou seja, o aparelho varia seu foco desde o ponto mais alto da peça até o ponto mais baixo, montando posteriormente a peça camada por camada na forma de uma imagem tridimensional do objeto.

Similar ao Alicona, tem-se ainda o microscópio Olympus DSX 510 (Olympus, 2018). O equipamento processa um conjunto de imagens focalizadas em diferentes planos do objeto, resultando em uma imagem totalmente focalizada. Os pontos capturados durante a varredura, também são utilizados para a construção da imagem 3D. Isso torna superfícies irregulares simples para a análise.

Ainda existem poucos equipamentos disponíveis no mercado que façam uso da variação de foco. Apesar de muitos trabalhos como (Schroettner *et al.*, 2006; Ren *et al.*, 2009; Boeira *et al.*, 2009; Winkler, et al., 2010; B.Cook *et al.*, 2015; Chen e Ju, 2015; Chen *et al.*, 2016), utilizarem a tecnologia, eles não a desenvolveram. Os produtos disponíveis ainda possuem custos muito altos e por isso de difícil acesso a

grande parte dos pesquisadores. O procedimento proposto nesta tese, além de inserir a tecnologia de variação de foco, como as utilizadas por Danzl *et al.* (2009) e Olympus (2013), visando aumentar a produtividade e a qualidade na caracterização de cupons de corrosão, em especial na medição da profundidade, busca ainda a redução do custo do equipamento.

CAPÍTULO 3

METODOLOGIA

Esse capítulo apresenta as ferramentas e tecnologias utilizadas no desenvolvimento deste projeto. São descritas as funcionalidades do sistema.

A execução deste trabalho seguiu as etapas ilustradas no fluxograma exibido na Figura 3.1. A metodologia proposta será detalhada no decorrer deste capítulo.

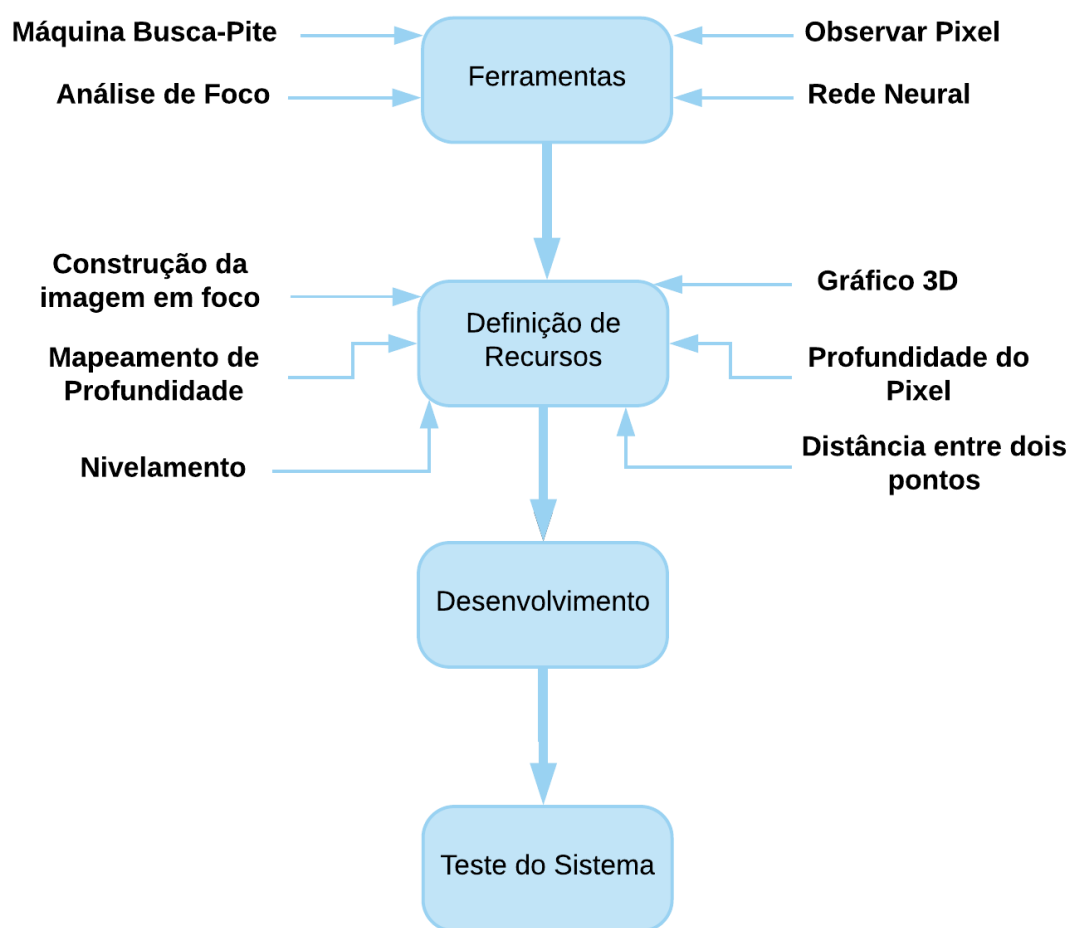


Figura 3.1 - Fluxograma com as etapas de execução da metodologia.

3.1 – Ferramentas

Esta seção descreve as ferramentas usadas no desenvolvimento do trabalho. A primeira versão da máquina Busca-Pites foi usada como base, tanto seu hardware, quanto o software que a comanda. Ela foi adaptada para suportar a nova tecnologia de variação de foco, que é o princípio de seu funcionamento atual. No entanto, para desenvolver a tecnologia de variação de foco, várias outras ferramentas foram desenvolvidas com o intuito de investigar as diferentes estratégias de determinação do melhor foco e selecionar aquelas que apresentam os melhores resultados. Em seguida, essas ferramentas serão descritas.

3.1.1 – Máquina Busca-Pites

O software da primeira versão da máquina Busca-Pites foi desenvolvido utilizando a linguagem C++, o framework Qt para construção da interface e a biblioteca de processamento de imagens e visão computacional OpenCV. Todas estas ferramentas foram compiladas em ambiente Windows. Entretanto, cabe ressaltar que são ferramentas multiplataforma, permitindo facilmente que se altere o ambiente de execução. As ferramentas auxiliam enormemente o desenvolvimento do código, sendo importante para o contínuo e planejado aprimoramento do programa, com a adição de novos recursos.

Qt é um framework de desenvolvimento em C++ consistente e abrangente, que permite criar aplicações multiplataforma. Contudo, essa não é a única vantagem. Esse framework permite a utilização de uma API rica e útil, e oferece um ambiente de programação em C++ mais amigável, permitindo a criação de interfaces gráficas elegantes (Blanchette, 2008).

O OpenCV (*Open Source Computer Vision*) é uma biblioteca open source e multiplataforma de visão computacional, com o objetivo de facilitar o desenvolvimento de aplicações. A biblioteca foi desenvolvida utilizando as linguagens de programação C e C++ e engloba um conjunto de algoritmos otimizados que podem ser utilizadas em diversas áreas, tais como: segmentação, reconhecimento de faces, filtragem de imagens, aprendizado de máquinas, calibração de câmeras, identificação de objetos, dentre outras (OpenCV, 2012).

O ambiente de desenvolvimento foi mantido para este projeto.

O hardware da máquina Busca-Pites em sua versão original foi alterado. A versão original possuía capacidade de movimentar a imagem horizontalmente ao longo dos eixos X-Y. Tanto o posicionamento quanto o movimento em ambos os eixos eram controlados. A câmera fotografava a região de interesse. Em seguida, o software de análise segmentava os pites presentes na imagem, seja de forma automática, seja de maneira supervisionada pelo operador. Cada pite segmentado era medido com respeito à área e sua posição respectiva. O número de pites era contado para medição da densidade de pites. Finalmente, a amostra era movida em direção ao sensor confocal que determinava a profundidade de cada pixel segmentado. O sucesso dessa medição dependia da precisão com que a amostra era movida.

O pite a ser medido deveria ser “iluminado” perfeitamente pelo feixe de luz do sensor, de modo que o feixe atingisse a região mais profunda do pite. Dependia também da declividade do fundo do pite, onde a luz era refletida. Declividades altas desviavam o feixe, impedindo a obtenção de uma medida válida. Razão por essa que a máquina realizava um movimento muito curto em busca de nova posição para refletir o feixe no fundo do mesmo pite.

A medição da profundidade do pite era feita sequencialmente para cada pite segmentado na imagem.

Na nova versão da máquina, um terceiro motor de passo foi adicionado aos outros dois. O novo motor dá à máquina a capacidade de mover a amostra ao longo do eixo Z. Uma vez escolhida a região de interesse, o operador move a amostra verticalmente e observa a imagem no monitor para encontrar o deslocamento vertical que faz todas as partes da região de interesse estar em foco. Determinado esse deslocamento, a máquina fotografa a região de interesse em diferentes distâncias verticais da superfície, obtendo uma pilha de imagens com diferentes distâncias focais. É essa pilha de imagens que será analisada pelo software de variação de foco. Ele encontrará em cada fotografia da pilha, a região que possui o melhor foco. Conhecendo-se a distância entre imagem e a lente, pode-se obter o relevo da superfície observada.

3.1.2 – Análise de Foco

Esta foi uma ferramenta (software) desenvolvida para a determinação do melhor foco para uma determinada região da superfície observada na pilha de imagens.

Um estimador de foco é um algoritmo que tem a função de avaliar a qualidade de foco de uma determinada região de uma imagem. Se o algoritmo é aplicado à mesma região da superfície, em todas as imagens da pilha, pode-se determinar em que imagem aquela região tem o melhor foco.

Devido ao grande número de estimadores de foco testados, foi necessário o desenvolvimento de uma ferramenta exclusiva para avaliar diferentes estimadores aplicados a uma mesma região.

As regiões para testar os estimadores poderiam ser escolhidas intuitivamente, como pontos e linhas horizontal ou vertical, ou utilizar um conjunto de pontos definido previamente. O programa fornece como saída um arquivo com o valor de cada estimador aplicado naquela região para cada imagem da pilha. Um gráfico pode ser construído a partir desse arquivo para determinar os estimadores que apresentaram os melhores resultados para a região escolhida. Esta foi a ferramenta que decidiu qual o melhor estimador a ser usado no desenvolvimento da nova versão do software da máquina Busca-Pite.

Nos primeiros testes com a ferramenta, foi observado que o motor de passo vertical realiza um ligeiro deslocamento horizontal ao se deslocar verticalmente. É imperceptível a olho nu, mas o suficiente para desalinhar as imagens da pilha que são produzidas em diferentes distâncias verticais. É imprescindível para a determinação do melhor foco de uma região na pilha de imagens que o estimador de foco seja aplicado à mesma região. O desalinhamento impedia o correto funcionamento do estimador.

Para corrigir esse problema, um recurso inicialmente não planejado teve que ser adicionado ao programa. Esse recurso faz o alinhamento das imagens através do registro das imagens. Ao alinhar as imagens, é necessário também fazer um corte das imagens de maneira que todas fiquem alinhadas e do mesmo tamanho. Isso também foi realizado. Assim, a ferramenta alinha as imagens da pilha, faz seu corte para ajuste de tamanho, escolhe a região a ser analisada e avalia os estimadores de foco escolhidos na região selecionada. O programa Análise de Foco contém as funcionalidades básicas de um editor de imagens. O programa possui o mesmo ambiente de desenvolvimento da máquina Busca-Pite.

3.1.3 – Observar Pixel

Essa ferramenta foi desenvolvida para exibir os valores dos pixels de uma pequena região em torno de um pixel selecionado em uma dada imagem da pilha. Ele exibe ainda os valores dos pixels da mesma região da imagem anterior e da posterior àquela na pilha.

Essa ferramenta foi desenvolvida com o objetivo de revelar como a intensidade dos pixels varia na pilha de imagens. Os valores de intensidade dos pixels de uma pequena região no entorno de um determinado pixel são usados pelos estimadores para avaliar a qualidade do foco. Compreender como esses valores se comportam ao longo da pilha, quando elas estão em diferentes qualidades de foco é importante para compreender o comportamento dos estimadores.

O Observar Pixel possui o mesmo ambiente de desenvolvimento da máquina Busca-Pite. Trata-se de mais uma ferramenta para auxiliar o desenvolvimento. Variações de intensidades de pixels entre as imagens subsequentes na pilha de imagens de uma mesma cena muitas vezes alteram o valor dos estimadores e produzem erros de estimativa de foco. Ruídos são fontes de variações que produzem tais erros.

3.1.4 – Rede Neural

Os estimadores usados para avaliar a qualidade do foco são baseados no contraste entre os pixels de uma região no entorno de um determinado pixel. Uma alternativa para avaliação do foco foi tentada com a utilização de uma rede neural. Redes neurais são muito usadas para reconhecimento de padrões. Procurou-se, como o uso delas, explorar o fato que se a qualidade do foco pode ser representada por algum padrão, uma rede neural poderia reconhecer esse padrão.

A rede neural utilizada foi desenvolvida por (Oliveira, 2012) para reconhecer padrões em imagens de mamografia relacionados a câncer de mama. A rede foi adaptada para tentar reconhecer padrões relacionados ao foco. Um conjunto de pontos foi usado para treinar a rede e outro conjunto foi utilizado para testar seu desempenho. As informações de entrada para a rede neural são as mesmas recebidas pelos estimadores de foco.

3.2 – Recursos do Sistema

3.2.1 – Construção da Imagem em Foco

Em cada imagem da pilha de imagens são encontrados pixels com diferentes qualidades de focos, devido às mesmas serem capturadas a diferentes distâncias. Para cada pixel, haverá uma imagem em que o foco deste pixel é o melhor de todas as imagens da pilha. Se, para cada pixel da imagem, o melhor foco for selecionado, é possível construir uma imagem da cena em que todos seus pixels estão em foco. A isso, denomina-se construção da imagem em foco.

Este recurso foi adicionado ao projeto, o estimador de foco é aplicado a cada pixel de toda a pilha de imagens e o melhor foco é selecionado. Em seguida, o programa constrói uma imagem somente dos pixels em foco. Assim, a imagem realista da superfície pode ser exibida completamente em foco.

Este é um dos resultados que a técnica de variação de foco pode produzir.

3.2.2 – Mapeamento de Profundidade

A técnica de variação de foco permite também fazer o mapeamento do relevo da superfície observada. Uma vez que o estimador de foco é capaz de determinar em que imagem da pilha o foco de determinado pixel é o melhor, conhecendo-se a distância vertical em que a imagem foi produzida, pode-se determinar o relevo de toda a superfície. Essa informação é usada para produzir uma matriz em que o valor de cada elemento é a altura de cada pixel da imagem. Essa matriz será usada para gerar informações gráficas e numéricas sobre o relevo superficial.

3.2.3 – Nivelamento da Superfície

Em algumas ocasiões, a superfície dos cupons está inclinada, seja por mal posicionamento do cupom, seja por má construção do cupom. A ocorrência de um plano inclinado na superfície do cupom não representa qualquer informação útil sobre a superfície. Essa inclinação é detectada pelo recurso de mapeamento de profundidade.

O recurso do nivelamento elimina a inclinação de maneira a retirar da topografia a informação desnecessária. O recurso é supervisionado pelo operador e faz uso das informações do mapeamento de profundidade para eliminar a inclinação indesejada.

3.2.4 – Gráfico 3D

A matriz de relevo produzida pelo recurso de mapeamento da superfície é a representação numérica da topografia da superfície, antes ou após a aplicação do recurso de nivelamento. Essa matriz é usada para exibir o relevo da superfície de maneira gráfica de duas formas distintas.

No primeiro caso, o relevo da superfície é exibido em uma escala de cores, em que cada cor representa um intervalo de profundidade da superfície. Nessa forma de exibição, toda a superfície é representada. No segundo caso, um gráfico 3D é construído a partir da matriz de relevo. O gráfico pode ser rotacionado para exibir a topografia do ponto de vista mais adequado, segundo o interesse do operador. Devido ao custo operacional, apenas uma parte da superfície, devidamente selecionada pelo operador, é exibida pelo gráfico.

3.2.5 – Profundidade do Pixel

Uma vez que o relevo da superfície é conhecido da matriz de relevo, esse recurso consegue extrair a profundidade de cada pixel da imagem. Basta deslizar o mouse sobre a imagem e a profundidade é exibida em tela. A profundidade é a diferença entre a coordenada Z do ponto selecionado e uma coordenada escolhida previamente como referência.

3.2.6 – Distância entre dois Pontos

Essa funcionalidade permite efetuar cálculos de três distâncias diferentes entre dois pontos selecionados pelo operador com o mouse. Sendo elas: horizontal, vertical e 3D. A distância horizontal é o comprimento do segmento de reta entre os dois pontos selecionados no plano X-Y. A distância vertical é a diferença entre as

coordenadas Z de ambos os pontos. A distância 3D é o comprimento do segmento de reta entre ambos os pontos.

3.3 – Teste do Sistema

O sistema construído foi testado para avaliar se atinge satisfatoriamente os objetivos planejados. O teste do sistema foi realizado a partir de uma pilha de imagens capturadas no âmbito do projeto que desenvolve o hardware da máquina. São imagens de um cupom de aço grau T9 exposto por três meses em água potável, após a devida preparação para caracterização da corrosão sofrida. Em posse das imagens alinhadas e recortadas, as mesmas foram processadas para se obter uma única imagem em foco nítido. A partir do resultado foram executadas as demais funcionalidades.

CAPÍTULO 4

RESULTADOS E DISCUSSÃO

Nesse capítulo, a nova versão do programa desenvolvido é descrito em detalhes (interface e funcionalidades). São descritas também as ferramentas de apoio utilizadas no desenvolvimento da nova versão do software da máquina Busca-Pites e os resultados obtidos com elas.

Para fins de organização e entendimento, primeiro serão apresentadas as ferramentas e suas funcionalidades e resultados. E na sequência será feita a descrição do sistema. A Máquina Busca-Pite, apesar de ser a ferramenta base deste trabalho, não será descrita neste capítulo por já ter sido detalhada na seção 2.2 – Máquina Busca-Pites.

4.1 – Análise de Foco

Desenvolvido para auxiliar no alinhamento e corte das imagens da pilha de imagens e na avaliação e seleção dos estimadores, o programa possui o mesmo ambiente de desenvolvimento do software da máquina Busca-Pite.

4.1.1 – Interface Gráfica do Análise de Foco

A interface do sistema segue a mesma estrutura e estética do programa da Busca-Pite, visando facilitar a usabilidade do mesmo. Ao ser executado, o sistema exibe a tela principal (Figura 4.1). Cada uma das opções existentes na barra de menu principal exibe mais opções relacionadas, em um menu suspenso, quando o usuário clica com o mouse sobre elas.

A barra de menus é composta por 3 opções organizadas da seguinte forma:

- *Arquivo*: Abrir, Abrir Lote de Imagens, Alinhamento de Imagens, Construir Imagem em Foco, Salvar, Salvar Como e Sair;

- *Imagem*: Zoom (Zoom In, Zoom Out e Tamanho Normal), Desfazer, Refazer e Transformar (Espelhar verticalmente, Espelhar horizontalmente, Rotacionar 90° horário e Rotacionar 90° anti-horário);
- *Operações*: Mapeamento e Nivelamento.

A interface do sistema contém ainda uma barra de ferramentas, que possui algumas funções idênticas às aquelas encontradas na barra de menus, e outras específicas; barras de rolagem, vertical e horizontal; uma barra de status, onde são exibidas informações como, a posição (x, y) do pixel, tamanho e dimensões da imagem; e uma área de exibição.

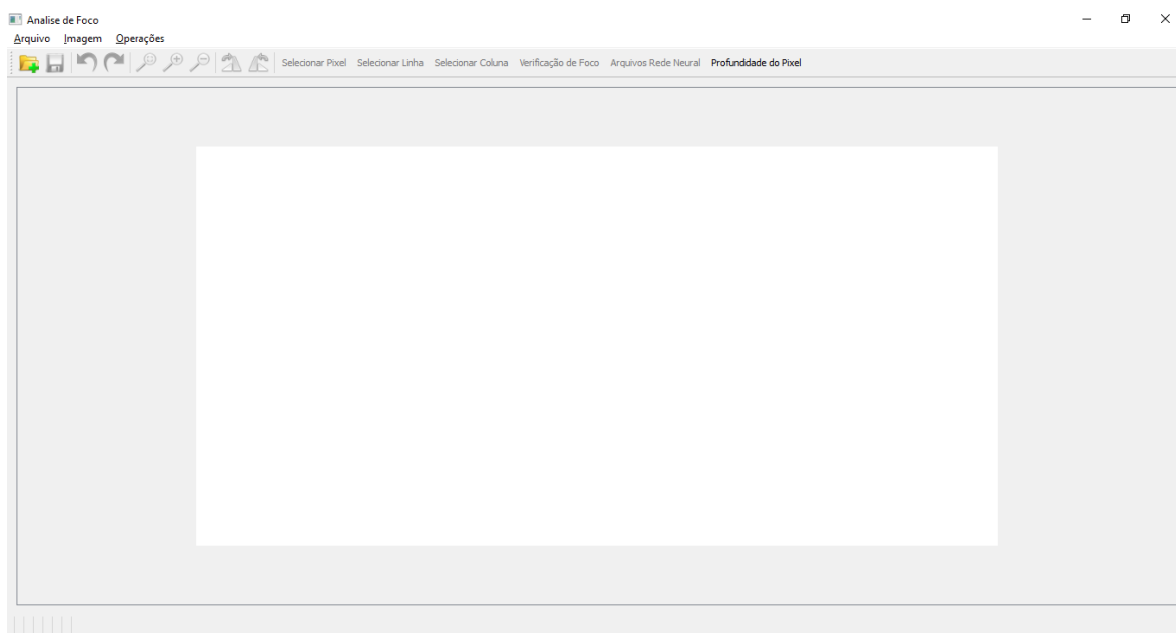


Figura 4.1 - Tela principal do programa Análise de Foco.

Para a utilização do programa, o usuário deve acessar o menu “Arquivo” e escolher o sub-menu que deseja operar. A opção “Abrir” permite carregar uma única imagem. Com a “Abrir Lote de Imagens” é possível carregar uma pilha de imagens de uma única vez. Para alternar entre as imagens da pilha o usuário pode utilizar as setas direita/esquerda do teclado, utilizar o *spinbox* que é exibido na barra de status (Figura 4.2) ou ainda digitar o número da imagem na pilha. A opção “Alinhamento de Imagens” permite selecionar uma pilha de imagens para efetuar o alinhamento e corte. Cabe ressaltar que esta opção não exibe a pilha de imagens. O sub-menu “Construir Imagem em Foco” permite construir uma imagem em foco nítido a partir de uma pilha de imagens. Apenas a imagem composta é exibida. Nesse menu o usuário tem ainda as opções de salvar uma imagem processada ou sair do programa.

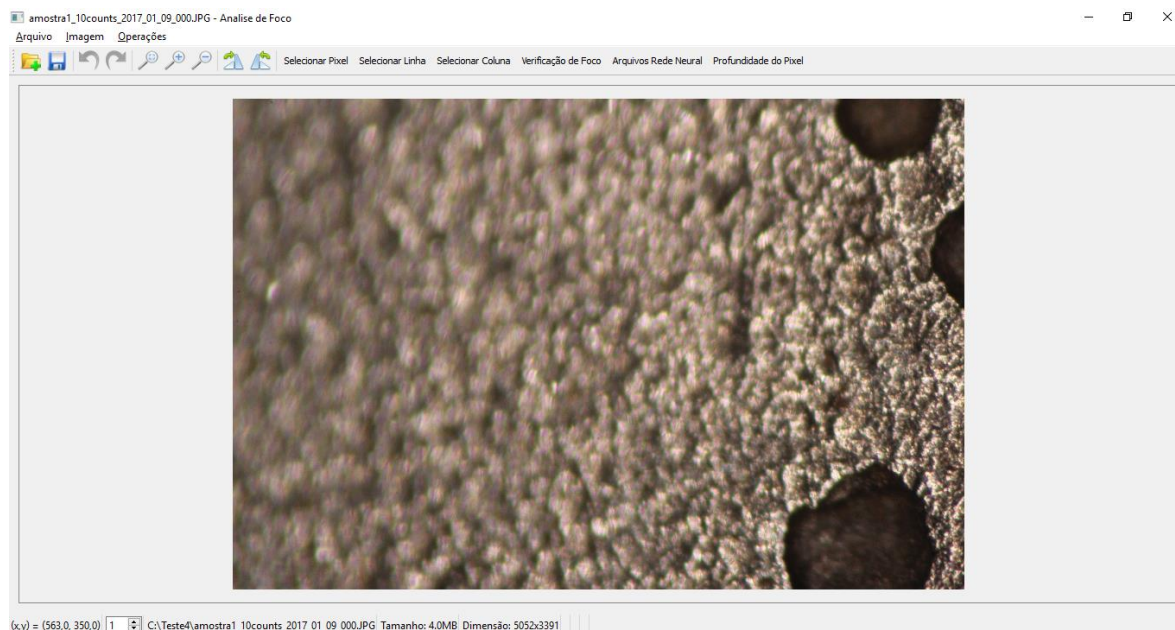


Figura 4.2 - Tela do programa Análise de Foco após selecionada a função Abrir Lote de Imagens.

O programa oferece suporte aos seguintes formatos de imagens: bmp, dib, jpeg, jpg, jpe, pgm, pbm, ppm, png, tif e tiff.

4.1.2 – Alinhamento de Imagens

As imagens da pilha capturadas em diferentes distâncias apresentaram um desalinhamento provocado pelo estágio sobre o qual fica a amostra e que tem a função de realizar o movimento vertical da amostra, causando erros na estimativa de foco. Esse recurso possui a finalidade de alinhar as imagens, encontrando o centro comum entre elas, e recortá-las, eliminando uma fonte de erro.

O registro das imagens é feito em pares de imagens da pilha. Para cada par de imagens, por exemplo, imagens i e $i + 1$, uma subimagem de tamanho 101×101 pixels é extraída do centro da imagem $i + 1$. Essa subimagem é utilizada como modelo de comparação na varredura realizada na imagem i . É realizada uma varredura na imagem i , para determinar qual região dela possui maior similaridade com a subimagem. Essa varredura é realizada dividindo a imagem i em subimagens de tamanho 101×101 pixels e aplicando a seguinte fórmula:

$$R(x, y) = \sum_{x', y'} (T(x', y') - I(x + x', y + y'))^2, \quad (4.1)$$

onde T é a subimagem extraída da imagem $i + 1$ e I é a região em varredura da imagem i . A correspondência ocorre onde a diferença for mínima.

O pixel central da região da imagem i , onde ocorre a correspondência, é a coordenada do centro da imagem i em relação à imagem $i + 1$. Após determinar o centro de cada imagem da pilha, toma-se por base o centro da última imagem da pilha para como origem do sistema de coordenadas. Assim é possível determinar quantas linhas e colunas deverão ser cortadas acima, abaixo, à esquerda e à direita para alinhar a pilha de imagens.

Na Figura 4.3 se pode observar duas imagens antes e depois do alinhamento. O problema é notado com maior facilidade observando o lado direito das imagens.




Figura 4.3 - Esquema de imagens alinhadas. Onde (a) e (b) representam a primeira e última imagem da pilha antes do alinhamento e (c) e (d) são as mesmas imagens após o alinhamento.

4.1.3 – Verificação de Foco

Esse recurso permite testar diferentes estimadores de foco para um ponto, linha ou coluna. Ele está localizado na barra de tarefas e só é ativado após o carregamento de pelo menos uma imagem.

A Figura 4.4 exibe uma imagem da pilha na interface de trabalho. É possível ver desenhadas sobre a imagem, em vermelho, uma linha horizontal, uma linha vertical e a interseção entre essas duas linhas. São as regiões selecionadas para apli-

cação dos estimadores de foco. As informações ficam expostas na barra de status do programa.

Quando a região selecionada é um pixel, os estimadores são aplicados àquele pixel em todas as imagens da pilha. Porém, se a região selecionada for uma linha, os estimadores são aplicados sobre todos os pixels da linha selecionada apenas da imagem exibida em tela.

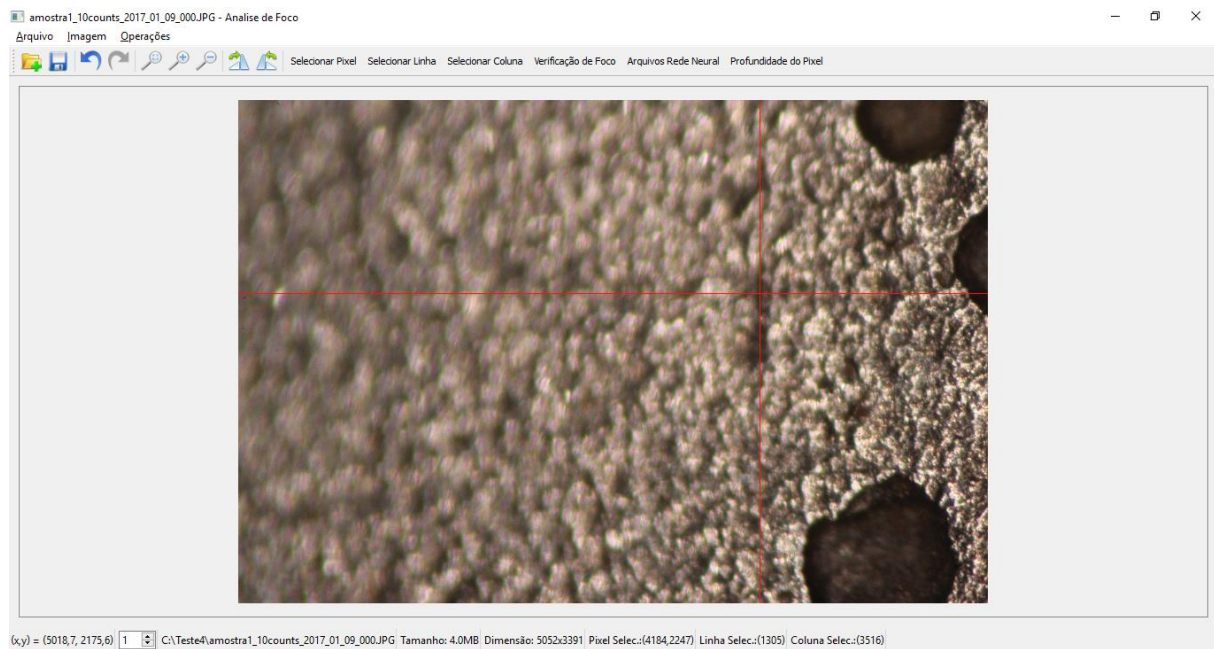


Figura 4.4 - Tela do programa mostrando a seleção de um pixel, uma linha e uma coluna.

4.1.3.1 – Pontos de Referência para Teste

Os estimadores de foco têm como objetivo avaliar a qualidade do foco na região do entorno do pixel selecionado. Resultados de diferentes estimadores podem ser diretamente comparados no arquivo de saída do programa. Porém, esses resultados devem ser comparados com avaliações do foco feitas por um operador humano. Para tal, cem pontos distintos foram selecionados na imagem da superfície. Esse número de pontos foi definido para que houvesse uma amostragem grande o suficiente para quantificar o resultado, mas pequena o bastante para ser possível analisar. Para uma imagem de tamanho $M \times N$, os cem pontos utilizados foram selecionados de acordo com as coordenadas:

$$I_{\frac{N}{20} + (i-1)\frac{N}{10}, \frac{M}{20} + (j-1)\frac{M}{10}} \quad (4.2)$$

em que $i=1,2,\dots,10$ e $j=1,2,\dots,10$.

Desta forma cada linha selecionada possui 10 pontos e cada coluna possui 10 pontos.

4.1.3.2 – Determinação Visual de Foco

Como afirmado na seção 4.1.3.1 – Pontos de Referência para Teste, a comparação entre os estimadores de foco foi também avaliada por inspeção a olho nu de um operador humano. Isso se fez necessário para verificar se os estimadores eram realmente capazes de qualificar o foco e se o resultado estava de acordo com o julgamento humano. Para tal, cem pontos foram selecionados sobre a imagem.

Com o auxílio do programa Analise de Foco, a pilha de imagens era aberta e a primeira imagem da pilha era observada no ponto selecionado. Em seguida, a próxima imagem da pilha era aberta e o mesmo ponto era observado. A qualidade do foco do pixel selecionado nas duas imagens era comparada. Em seguida, a terceira imagem da pilha era aberta e a mesma comparação era feita. Isso se repetiu com todas as imagens da pilha. Dessa forma, a imagem em que está o melhor foco para o ponto selecionado pode ser determinada.

Para determinar a qualidade do foco em torno de um dado ponto, o operador humano inicialmente examina uma grande região no entorno do pixel em questão. Faz isso em várias imagens, até escolher aquelas que apresentam o maior contraste. Esse grupo de imagens escolhidas será novamente observado, mas dessa vez examinando-se uma região menor em torno do ponto. A mesma comparação é feita para se selecionar um grupo menor de imagens. O processo se repete até que se chega a um pequeno conjunto ou a uma única imagem com focos de qualidade comparável. No presente caso, a determinação visual do foco selecionou um grupo de imagens com os focos de maior qualidade e dentre esse grupo, selecionou aquela imagem que aparentava possuir o melhor foco.

4.1.3.3 – Estimadores de Foco

Os estimadores de foco têm como objetivo identificar a qualidade do foco em um dado pixel. Os estimadores são expressões matemáticas que tentam quantificar de maneiras distintas o contraste existente em torno de um dado pixel.

O contraste entre os pixels é usado como indicador de foco. Em uma imagem real, as variações de cor e intensidade luminosa contribuem para a variação natural dos valores dos pixels em uma dada região da imagem. No entanto, quando a região está fora de foco, a luz proveniente de cada ponto da superfície é espalhada. A imagem resultante parece “borrada”. O contraste entre os pixels diminui. Por isso, o contraste é frequentemente usado como indicador de foco.

Diversos tipos de estimadores de foco foram testados. Todos eles baseados em contraste. Eles se diferenciam pela forma de representar o contraste e pela área em torno do pixel de cujo foco se quer avaliar. Ao todo foram testados 8 estimadores distintos, com máscaras variando de 3x3 a 25x25. A Figura 4.5 mostra a tela de seleção dos estimadores e o tamanho das máscaras. É possível selecionar diversos estimadores e tamanhos de máscara de forma simultânea.

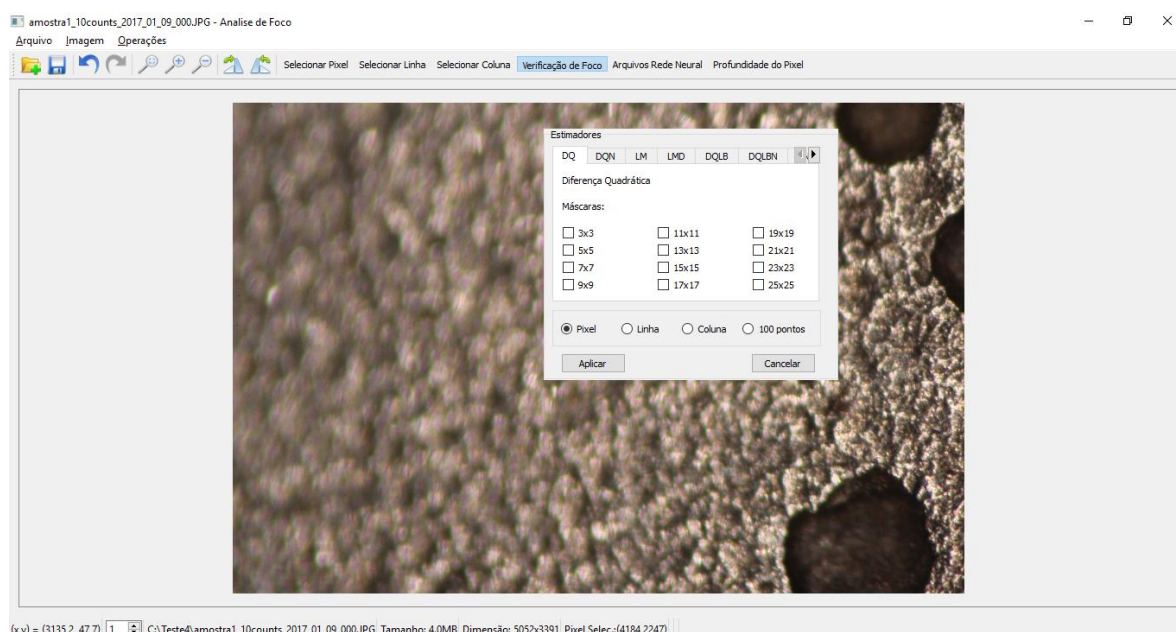


Figura 4.5 - Tela dos estimadores de foco.

Os resultados dos estimadores são exibidos em relatório, como mostra a Figura 4.6. Nos nomes das colunas estão os nomes dos estimadores e o tamanho das máscaras. Nas linhas, estão o número da imagem e os valores de cada estimador, quando o estimador é aplicado em um único pixel. Quando o estimador é aplicado em uma linha, as linhas do relatório correspondem ao número do pixel analisado na linha e ao valor de cada estimador, como mostra a Figura 4.7. Os pixels da linha ou da coluna, próximos da borda, são descartados, visto que não seria possível trabalhar com a máscara completa, o que geraria resultados falsos.

Estimador por pixel

Informações:
 Pixel Selecionado: (4714,1716)
 Número de imagens: 101

	DQ(3)	DQN(3)	LMD(3)	DQLB(3)	DQLBN(3)	EN(3)	IN(3)
1	16	0,000986	17	39	0,002403	1,522955	3
2	5	0,000345	2	6	0,000414	1,060857	3
3	12	0,000772	4	16	0,001029	1,214890	3
4	16	0,001117	12	22	0,001535	1,214890	3
5	135	0,010167	26	290	0,021841	1,889159	2
6	16	0,001175	9	21	0,001542	1,214890	3
7	12	0,000912	4	18	0,001368	1,464816	2
8	30	0,002417	11	29	0,002336	1,464816	2
9	6	0,000508	5	9	0,000762	1,060857	3
10	32	0,002841	8	38	0,003374	1,581094	2
11	13	0,001114	8	10	0,000857	0,995027	2
12	28	0,002599	11	43	0,003991	1,464816	2
13	60	0,004789	3	61	0,004869	1,889159	2
14	79	0,007181	15	73	0,006635	1,581094	2

Relatório Fechar

Figura 4.6 - Relatório de estimadores aplicados por pixel em uma pilha de imagens.

Estimador por pixel

Informações:
 Linha Selecionada: 1621
 Número da imagem: 1 Arquivo: C:\Users\Tanne Nogueira\Google Drive\Compartilhados com Tanne\Imagens após o corte\TESTE4\amostra:

	Pixel	DQ(5)	DQN(5)	LM(5)	DQLB(5)	DQLBN(5)	EN(5)
1	(0,1621)						
2	(1,1621)						
3	(2,1621)	78	0,000331	-1	138	0,000586	1,664736
4	(3,1621)	106	0,000459	7	154	0,000667	1,854228
5	(4,1621)	267	0,001166	12	170	0,000743	1,843405
6	(5,1621)	136	0,000599	14	184	0,000810	1,926040
7	(6,1621)	267	0,001196	14	284	0,001272	2,034175
8	(7,1621)	131	0,000591	-3	292	0,001318	2,055105
9	(8,1621)	754	0,003414	17	288	0,001304	2,078804
10	(9,1621)	602	0,002759	18	270	0,001237	2,053945
11	(10,1621)	355	0,001635	15	210	0,000967	1,898856
12	(11,1621)	81	0,000375	3	130	0,000601	1,452998
13	(12,1621)	25	0,000116	-3	72	0,000333	1,217599
14	(13,1621)	60	0,000277	-3	84	0,000387	1,338165

Relatório Fechar

Figura 4.7 - Estimadores aplicados em uma linha da imagem.

Os estimadores utilizados no programa são apresentados a seguir. Para as equações 4.3 a 4.10, considere N o tamanho da máscara e (k, l) o pixel a ser analisado.

- **Diferença Quadrática (DQ)**

$$\Delta_{k,l}^2 = \sum_{i,j=1}^N A_{i,j}^2 - 2A_{k,l} \sum_{i,j=1}^N A_{i,j} + N^2 A_{k,l} \quad (4.3)$$

- **Diferença Quadrática Normalizada (DQN)**

$$\Delta_{k,l}^2 = \frac{\sum_{i,j=1}^N A_{i,j}^2 - 2A_{k,l} \sum_{i,j=1}^N A_{i,j} + N^2 A_{k,l}}{\sum_{i,j=1}^N A_{i,j}^2} \quad (4.4)$$

- **Laplaciano Modificado (LM)**

Por trabalhar com máscara de convolução, este estimador é o único a operar apenas com máscara de 5x5. Esta é a matriz de convolução utilizada por este estimador.

$$\begin{bmatrix} 2 & 0 & 1 & 0 & 2 \\ 0 & -2 & -1 & -2 & 0 \\ 1 & -1 & 0 & -1 & 1 \\ 0 & -2 & -1 & -2 & 0 \\ 2 & 0 & 1 & 0 & 2 \end{bmatrix} \quad (4.5)$$

- **Laplaciano Modular (LMD)**

$$LMD_{k,l} = \sum_{i=-\frac{N-1}{2}}^{\frac{N-1}{2}} \sum_{j=1}^{\frac{N-1}{2}} \{ |I_{k+i,l-j} - 2I_{k+i,l} + I_{k+i,l+j}| \\ + |I_{k-j,l+i} - 2I_{k,l+i} + I_{k+j,l+i}| \} \quad (4.6)$$

- **Diferença Quadrática Linear Bidirecional (DQLB)**

$$DQLB_{k,l} = \sum_{i=1}^N \sum_{j=1}^{N-1} (I_{i,j+1} - I_{i,j})^2 + \sum_{i=1}^N \sum_{j=1}^{N-1} (I_{j+1,i} - I_{j,i})^2 \quad (4.7)$$

- **Diferença Quadrática Linear Bidirecional Normalizada (DQLBN)**

$$DQLBN_{k,l} = \frac{DQLB_{k,l}}{\sum_{i=1}^N \sum_{j=1}^N I_{i,j+1}^2} \quad (4.8)$$

- **Entropia (EN)**

$$EN_{k,l} = \sum_{i=1}^N p(x_i) \ln\left(\frac{1}{p(x_i)}\right) \quad (4.9)$$

Onde $p(x_i)$ é a probabilidade do tom do pixel ocorrer.

- **Intensidades do Histograma (IN)**

Seja $M_{n \times n}$ uma matriz. Definimos uma matriz $I_{n \times n}$ tal que

$$\begin{cases} I_{i,j} = 1, \text{ se } M_{i,j} \neq M_{k,l}, \text{ para todo } k \neq i \text{ e } l \neq j \\ I_{i,j} = 0, \text{ do contrário} \end{cases}$$

Definimos então

$$D = \sum_{i,j=1}^N I_{i,j} \quad (4.10)$$

como o número de elementos diferentes da matriz $M_{n \times n}$.

Com base nesses estimadores, foram realizados testes para selecionar aquele que retornava o melhor resultado. Para isso eles foram aplicados nos 100 pontos de teste mencionados na seção 4.1.3.1 – Pontos de Referência para Teste de cada imagem de uma pilha de 101 imagens, com dimensões de 5052x3391 pixels, utilizando máscaras de 3x3, 13x13 e 23x23. Os resultados obtidos para cada estimador permitiram apontar a imagem em que cada um dos 100 pixels testados apresentava o melhor foco. Em seguida, esse resultado foi confrontado com aquele apontado pela inspeção visual, conforme descrito na seção 4.1.3.2 – Determinação Visual de Foco, para verificar se o resultado dos estimadores correspondia àquele do olho humano. O resultado está exposto na Tabela 5. A tabela está em ordem decrescente de sucesso.

Tabela 5 - Taxas de acerto dos estimadores.

Estimador	Taxa de Acertos
DQLBN(23)	75%
DQLB(23)	61%
DQN(23)	55%
DQLBN(13)	53%
LMD(23)	51%
DQN(13)	48%
DQ(23)	47%
DQLB(13)	47%
LMD(13)	44%
DQ(13)	41%
EN(23)	40%
DQLBN(5)	37%
EN(13)	35%
DQN(5)	33%
DQLB(5)	30%
EN(5)	28%
LMD(5)	26%
DQ(5)	25%
IN(5)	25%
IN(13)	25%
LM(5)	20%
IN(23)	15%

O estimador de foco que apresentou de longe o melhor desempenho foi o DQLBN(23), ou seja a Diferença Quadrada Linear Bidirecional Normalizada, com máscara de tamanho 23x23. Esse estimador apontou que o melhor foco concordava em 75% das vezes com o julgamento do operador humano. Em geral, os estimadores normalizados apresentam melhor desempenho do que seus equivalentes não normalizados. Isto ocorre porque a normalização extrai do estimador a influência da variação de intensidade dos pixels da região da máscara entre imagens distintas, restando apenas a variação da intensidade na própria imagem.

Observa-se ainda que os estimadores determinados em máscaras maiores eram mais bem-sucedidos. Isso é de se esperar, pois máscaras maiores permitem analisar uma amostragem maior de pixels da imagem e isso representa melhor a qualidade do foco. O problema é que quanto maior a máscara utilizada, maior é também o esforço computacional para a aplicação do estimador.

Com o relatório emitido pelo programa para cada estimador avaliado, é possível produzir gráficos do valor de cada estimador em cada imagem da pilha. A Figura

4.8 mostra alguns gráficos produzidos para vários estimadores aplicados em um determinado ponto da imagem. Para efeito de comparação todos são do mesmo ponto da pilha de imagens. O intervalo de imagens da pilha analisada em que este ponto se encontra em foco, pela observação visual, é da imagem 37 a 50. Nestes gráficos o eixo horizontal corresponde ao número da imagem e o eixo vertical ao valor encontrado pelo estimador em cada imagem da pilha.




Figura 4.8 - Gráficos de um ponto na pilha de 100 imagens para diferentes estimadores. (a) DQLBN(23), (b) DQLB(23), (c) LM(5) e (d) IN(23).

As curvas mostram como, para o caso de um ponto particular, os estimadores se comportam distintamente. Os operadores LM(5) e IN(23) apresentam grande variação sem padrão aparente, demonstrando sua incapacidade de representar a qualidade do foco. Os estimadores DQLBN(23) e DQLB(23), por outro lado, apesar das variações, apresenta um padrão de variação. Este padrão é bem visível no estimador DQLBN(23), em que a curva tem a forma de um sino cujo máximo se situa pouco abaixo de 50, coincidindo com a região de melhor foco, apontada pelo operador humano. Esse padrão aparece na maioria das vezes para este operador, indicando que ele consegue detectar um padrão para a qualidade de foco, baseando-se no contraste, que coincide com a forma com que o olho humano qualifica o foco.

A curva do estimador DQLBN(23) pode ser razoavelmente bem descrita por uma gaussiana. No entanto, devido às variações bruscas de valor, nem sempre o valor máximo do estimador coincide com o máximo da curva gaussiana de ajuste. Isso é uma das fontes de erro encontradas para esse estimador, visto que o sistema detecta o valor máximo como o melhor foco, quando na verdade, o mais indicado seria usar o valor máximo da gaussiana de ajuste da curva. Outra fonte de erro desse estimador é que nem sempre a curva apresenta o comportamento gaussiano. Em casos assim, não é possível usar o estimador para qualificar o foco.

Na Figura 4.9, uma curva do estimador DQLBN(23) aplicado a um ponto é exibida. A curva é razoavelmente aproximada por uma gaussiana. Há muitas oscilações em torno do comportamento gaussiano. Neste caso, coincidentemente, a maior variação coincidiu com o pico da gaussiana. Às vezes, alguma variação que não ocorre no pico da gaussiana torna-se o máximo da curva do estimador, gerando um erro de qualificação do foco.




Figura 4.9 - Curva de valores do estimador DQLBN(23) na pilha de imagens com ajuste gaussiano.

4.1.4 – Rede Neural

Outra tentativa de qualificação do foco foi com uso de uma rede neural. Para tal, um conjunto de pontos foi escolhido para treinar a rede e outro conjunto para testá-la.

Cada arquivo usado para treinar ou testar a rede neural era constituído de uma matriz de dimensão 23x23, cujos elementos são os valores dos pixels no entor-

no do ponto cujo foco está sendo qualificado. O pixel central da matriz é exatamente o ponto para ser qualificado.

A rede neural possui como parâmetros de ajuste o número de arquivos usados para o treinamento, o erro associado à estimativa de foco e o número de neurônios em cada camada. Este último foi fixado para todos os testes. Somente o erro e o número de arquivos foram variados. Observa-se que o treinamento era muito demorado. Quanto menor o erro e maior o número de arquivos, maior era o tempo de treinamento, que podia exceder quatro semanas.

Cada arquivo recebia um valor que representava a qualidade do foco. Dessa maneira, a rede neural podia ser treinada. Os valores atribuídos a cada arquivo foram obtidos da análise visual de foco e da curva gaussiana que qualifica o foco no estimador DQLBN(23). A análise visual determina em que imagem da pilha está o melhor foco. Esta imagem recebe o maior valor de qualificação de foco. Os demais arquivos recebem valores de acordo com a gaussiana centrada na imagem de melhor foco.

A Tabela 6 exhibe o resumo dos resultados na forma de taxa de acertos da rede neural para qualificar o foco em função dos diversos parâmetros de ajuste. Em nenhum dos casos, a taxa de acerto se comparou àquela atingida pelo estimador DQLBN(23), que foi de 75%. Verifica-se ainda que os parâmetros de ajuste empregados não influenciaram o desempenho da rede para qualificar o foco, embora tenham muito efeito sobre o tempo de treinamento.

Tabela 6 - Resultados da rede neural.

Parâmetros	1000 Arq 1e-2	1000 Arq 1e-3	1500 Arq 1e-2	2000 Arq 1e-2
Taxa de Acertos	60%	20%	60%	20%

4.2 – Observar Pixel

O programa Observar Pixel foi desenvolvido para auxiliar na observação dos valores dos pixels de uma pilha de imagens. Estes valores são importantes para entender o comportamento dos estimadores. O ambiente de desenvolvimento é o mesmo da Máquina Busca-Pite. O sistema oferece suporte aos mesmos formatos de imagens dos outros dois sistemas.

A interface do sistema segue a mesma linha do Análise de Foco e do Busca-Pite. Ele contém uma barra de menu, uma barra de tarefas, uma barra de status,

uma área de exibição e uma aba lateral para visualização dos valores dos pixels .A tela da Figura 4.10 é exibida ao executar o programa.




Figura 4.10 - Tela do programa Observar Pixel.

A barra de menus é composta por 2 opções organizadas da seguinte forma:

- *Arquivo*: Abrir Lote de Imagens, Salvar, Salvar Como e Sair;
- *Imagem*: Zoom (Zoom In, Zoom Out e Tamanho Normal), Desfazer, Refazer e Transformar (Espelhar verticalmente, Espelhar horizontalmente, Rotacionar 90° horário e Rotacionar 90° anti-horário);

Após abrir um lote de imagens o usuário tem duas opções específicas para observar os valores dos pixels, que são: “Observar Pixel” e “Selecionar Linha”. Estas opções estão localizadas na barra de tarefas.

Ao selecionar o recurso de “Observar Pixel”, o usuário pode clicar sobre a imagem para selecionar o pixel a ser observado ou apenas digitar a coordenada desejada nas *spinbox* que são exibidas na barra de status, como mostra a Figura 4.11. O tamanho da máscara que será observado é definido na *spinbox* exibida na parte superior da aba lateral esquerda. As 3 caixas de texto da aba lateral exibem os valores dos pixels da imagem atual, da anterior e da próxima, na sequência da pilha de imagens. Os valores da imagem em exibição podem ser salvos em um arquivo .csv selecionando a opção “Matriz” e clicando no botão “Salvar”. A coordenada do pixel selecionado é exibida na barra de status.




Figura 4.11 - Tela do Observar Pixel exibindo os valores do pixel selecionado para uma máscara 5x5.

O recurso “Selecionar Linha” permite que uma linha seja selecionada e os valores dos pixels sejam armazenados em um arquivo .csv. Para isso basta que o usuário selecione a linha e em seguida escolha a opção “Linha” na parte superior da aba lateral, e em seguida clique no botão “Salvar”. O número da linha selecionada é exibido na barra de status.

Essa ferramenta foi útil para compreender como variam as intensidades dos pixels nas regiões usadas pelos estimadores para qualificar o foco e como eles variam em imagens com diferentes qualidades de foco. Com isso, era mais fácil compreender o comportamento exibido pelos estimadores.

4.4 – Nova Versão do Software da Máquina Busca-Pite

A estrutura do software da Máquina Busca-Pite foi mantida, tendo sido acrescentadas as funcionalidades desenvolvidas neste projeto. A interface gráfica ganhou novo menu e submenus para comportar as novas rotinas. Sendo eles:

- *Imagem em Foco*: Construção, Mapeamento, Nivelamento, Gráfico 3D, Profundidade do Pixel e Distância entre Dois Pontos.

A Figura 4.12 exhibe a atualização da interface do sistema.

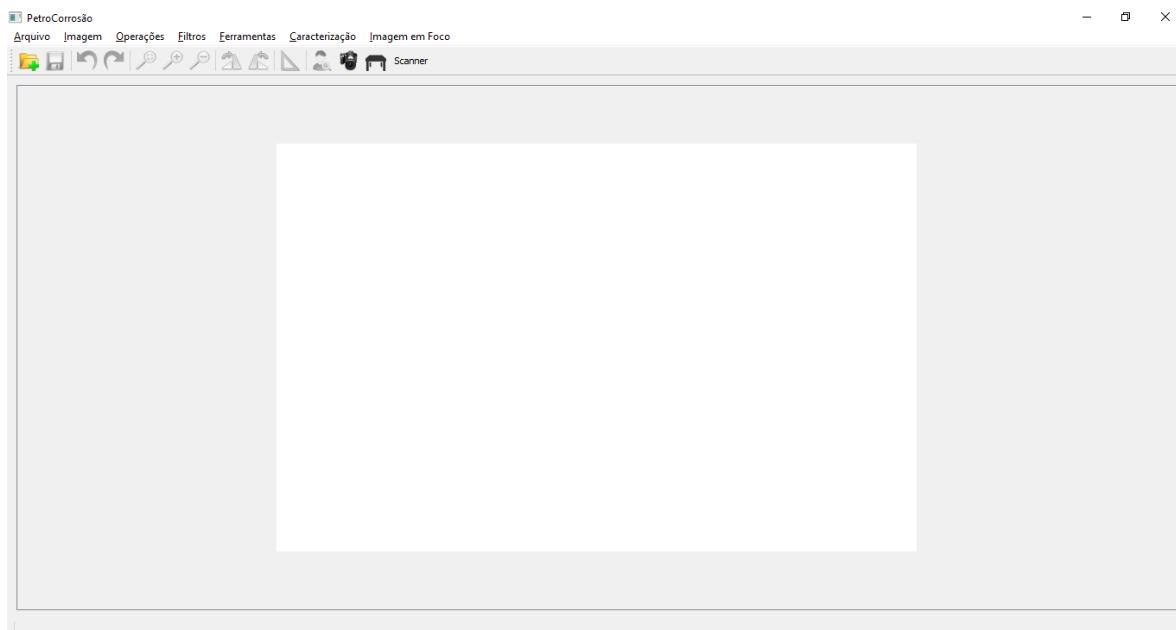


Figura 4.12 - Interface atualizada do software da Máquina Busca-Pite.

4.4.1 – Construção de Imagem em Foco

Este recurso permite ao usuário construir uma imagem em foco nítido a partir de uma pilha de imagens capturadas em diferentes distâncias. Esta imagem é por vezes denominada de imagem composta, visto que ela é a composição das partes das imagens da pilha que exibem a maior qualidade de foco. Para isso o usuário deve acessar o menu “Imagem em Foco” e em seguida a opção “Construção”. Deve então selecionar o conjunto de imagens a ser analisado e o resultado será exibido na tela ao fim do processo.

Com base nos testes, o estimador selecionado para esta funcionalidade, foi o Diferença Quadrática Linear Bidirecional Normalizada (DQLBN), utilizando uma máscara de 23x23, visto que esse estimador apresentou a maior taxa de acertos (75%), tendo como referência a análise do operador humano.

A Figura 4.13 exibe a imagem inicial e final de uma pilha de 101 imagens e o resultado obtido após o processamento. É perfeitamente possível notar, nas imagens (a) e (b), que são a primeira e a última imagem da pilha, respectivamente, regiões dentro e fora de foco. Na primeira imagem da pilha (a) o lado esquerdo da imagem está claramente fora de foco, enquanto o lado direito está em foco. Na última imagem (b) da pilha, é a esquerda da imagem que está em foco. Na imagem composta (c), toda a extensão da imagem parece estar em foco. De fato, observando a

imagem com esse nível de magnificação, a imagem composta parece estar perfeita. Somente observando a imagem composta com magnificação considerável, é possível notar que a imagem possui pixels que não parecem “naturais” da superfície. Seriam “ruídos” que foram erroneamente considerados em foco pelo estimador de foco.




Figura 4.13 - (a) Imagem inicial da pilha; (b) Imagem final da pilha; e (c) Imagem composta após o processamento.

4.4.2 – Mapeamento de Profundidade

Esse procedimento permite mapear o relevo da superfície da amostra por meio das informações de altura em que cada imagem foi capturada. O resultado desse recurso é uma imagem colorida, cujas cores representam o relevo. Para usar o recurso, o usuário deve acessar o menu “Imagem em Foco” e em seguida a opção “Mapeamento”, a tela exibida na Figura 4.14 será apresentada. O usuário deverá informar em qual direção a mesa da máquina se movimentou verticalmente e também qual o tamanho do passo, isto é, a distância entre as imagens capturadas ao longo do eixo vertical.

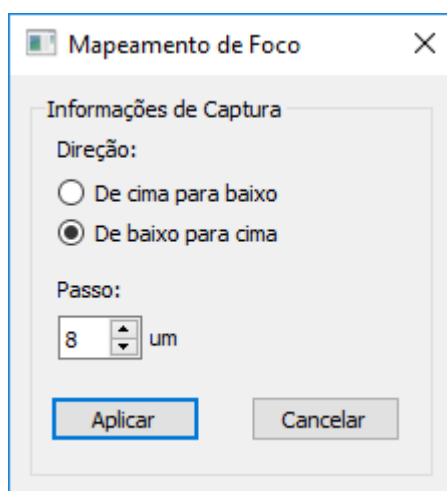


Figura 4.14 - Tela do mapeamento de profundidade.

Após o processamento, o resultado do mapeamento é exibido na tela, como mostra a Figura 4.15. A configuração de captura é a exibida na Figura 4.14. Os fundos de escala de cor são as cores vermelha e rosa, para o menor e maior valor de profundidade, respectivamente, conforme mostra a legenda.

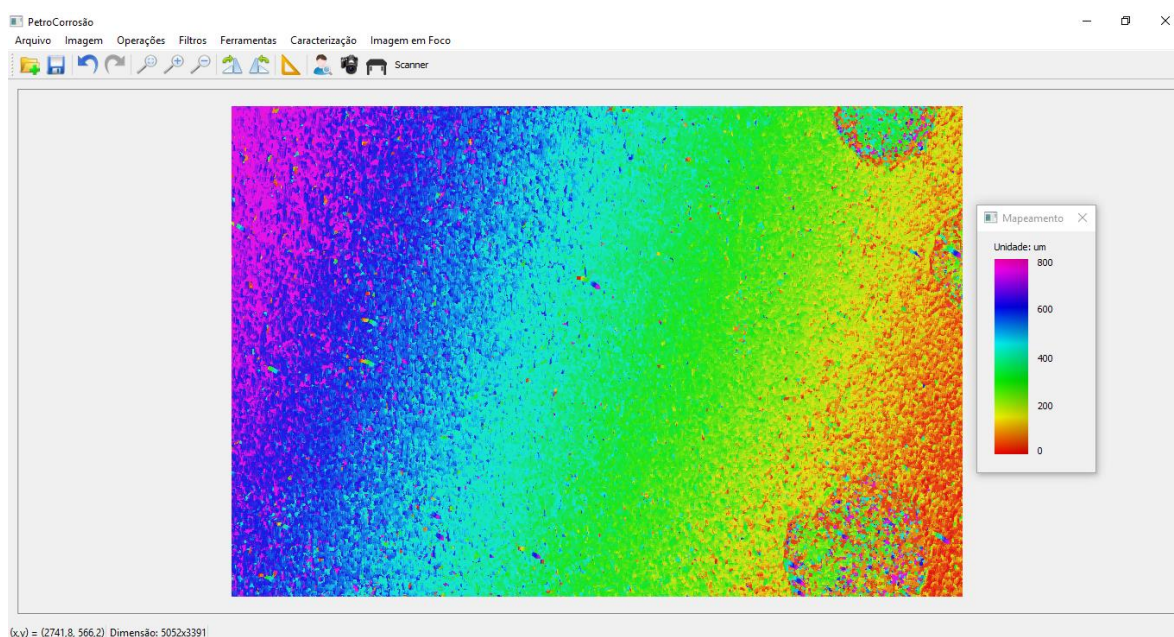


Figura 4.15 - Imagem mapeada.

Observando a imagem é possível notar a transição de cores em faixas diagonais, do vermelho à direita ao rosa à esquerda. É possível ver ainda que as faixas de cores possuem pontos isolados de outras cores. Muitos desses pontos são “ruídos”, provocados pelos erros do algoritmo, visto que ele possui uma taxa de acertos de 75%. Isso pode ser mais claramente observado no interior dos pites situados à direita da imagem. O fundo dos pites deveria ter coloração mais uniforme. No entanto,

pixels de diversas cores aparecem, indicando, falsamente, que o relevo é bastante irregular.

4.4.3 – Nivelamento

Analisando as imagens a e b da Figura 4.13 e a Figura 4.15, onde as faixas de cores distintas indicam mudança de relevo, nota-se que o cupom apresenta uma inclinação em sua superfície. Caso o mesmo fosse totalmente plano, toda a superfície estaria em foco em uma única imagem e o degrade na superfície da imagem mapeada não ocorreria. A Figura 4.16 exibe um conjunto de imagens que representam a primeira e a última imagem de uma pilha, nas imagens (a) e (b), a imagem composta (c) e a imagem com o relevo mapeado (d). Nesta última, vários pites podem ser observados, com o fundo representado majoritariamente pela cor verde, e com o restante da superfície quase todo pelo vermelho. Isso denota que a superfície dessa amostra não apresentava qualquer inclinação original.

Em casos como aqueles representados na Figura 4.15, a aplicação do recurso de nivelamento elimina a inclinação, fazendo com que apenas o relevo que realmente possui significado seja exibido na imagem.




Figura 4.16 - (a) Imagem inicial da pilha; (b) imagem final da pilha; (c) imagem composta; e (d) imagem mapeada.

Para utilizar esta funcionalidade, o usuário deve acessar o menu “Imagem em Foco” e selecionar o submenu “Nivelamento”. Essa opção só fica disponível após o mapeamento da imagem em foco. Selecionado o recurso, o usuário terá que escolher, com o clique do mouse, três pontos na superfície para efetuar o nivelamento, o que torna a qualidade do resultado dependente das escolhas do operador. O operador deve escolher os três pontos que ele acredita que melhor representam o plano de inclinação da superfície. O procedimento é realizado utilizando as coordenadas dos três pontos selecionados para determinar a equação do plano de inclinação da superfície para retirar o desnível.

$$\begin{aligned} & \left| \begin{matrix} (y_2 - y_1) & (z_2 - z_1) \\ (y_3 - y_1) & (z_3 - z_1) \end{matrix} \right| (x - x_1) + \left| \begin{matrix} (z_2 - z_1) & (x_2 - x_1) \\ (z_3 - z_1) & (x_3 - x_1) \end{matrix} \right| (y - y_1) \\ & + \left| \begin{matrix} (x_2 - x_1) & (y_2 - y_1) \\ (x_3 - x_1) & (y_3 - y_1) \end{matrix} \right| (z - z_1) = 0 \end{aligned} \quad (4.11)$$

Um resultado de nivelamento para a imagem mapeada da Figura 4.15 é mostrado na Figura 4.17. É possível observar que a tonalidade da superfície está mais homogênea e que o fundo dos pites são mais facilmente observados. A legenda das cores é exibida junto da imagem.

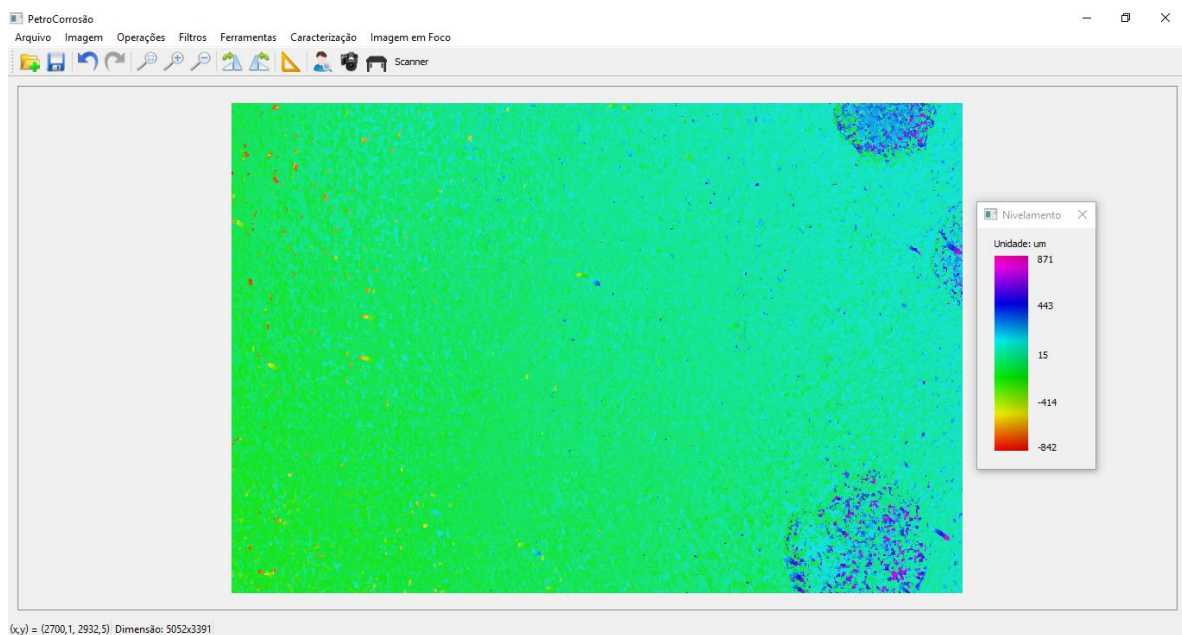


Figura 4.17 - Imagem nivelada.

4.4.4 – Gráfico 3D

Este recurso permite ao operador observar a topografia da imagem de forma tridimensional. Somente após a imagem ter sido mapeada ou nivelada o usuário po-

de fazer uso do mesmo. Para isso basta acessar o menu “Imagem em Foco” e depois a opção “Gráfico 3D”. Será requisitado ao operador que selecione uma área da imagem para gerar o gráfico. O gráfico pode ser rotacionado para melhor visualização da região. Existe ainda a opção de salvar o gráfico. É salva sempre a visualização corrente. Para saber as coordenadas de um determinado ponto, basta apontar o mouse para o local desejado e será informada a coordenada (x,y,z). A Figura 4.18 mostra algumas faces do gráfico do pite superior da imagem nivelada na Figura 4.17.

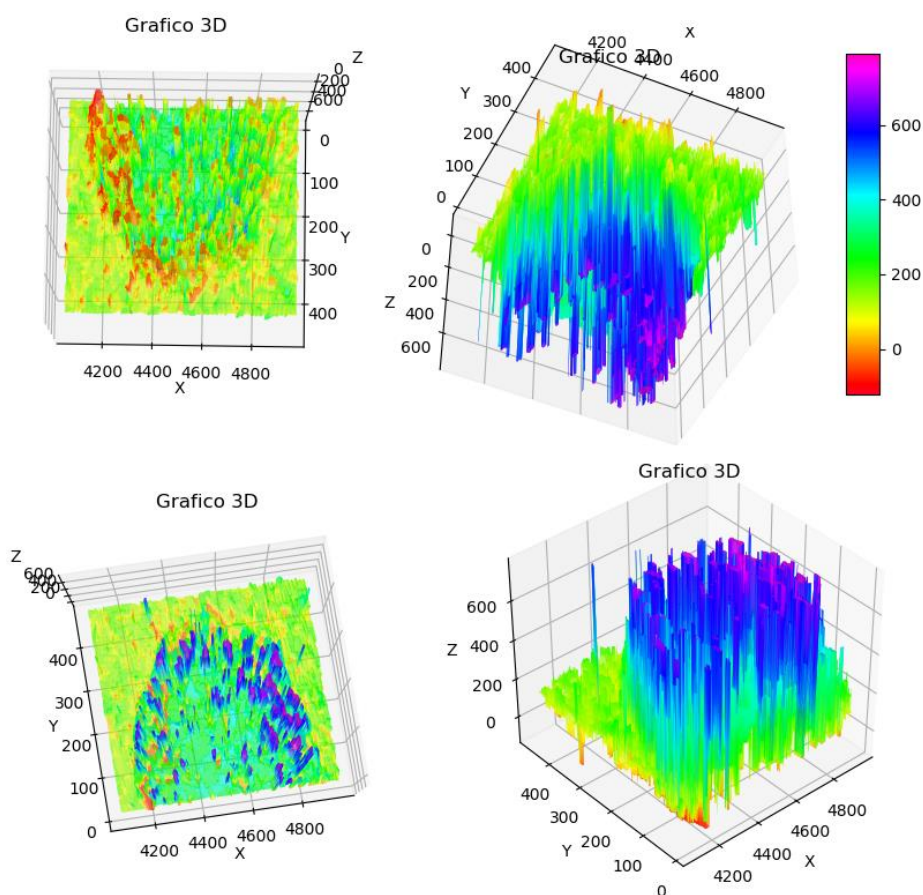


Figura 4.18 - Diferentes faces do gráfico 3D de um pite de uma imagem de um cupom de superfície inclinada.

A Figura 4.19 mostra o gráfico do pite posicionado mais a esquerda da imagem Figura 4.16. Devido à superfície plana do cupom, a imagem não necessitou de nivelamento. Comparando os dois gráficos se observa que cupons de superfície plana geram melhores resultados.

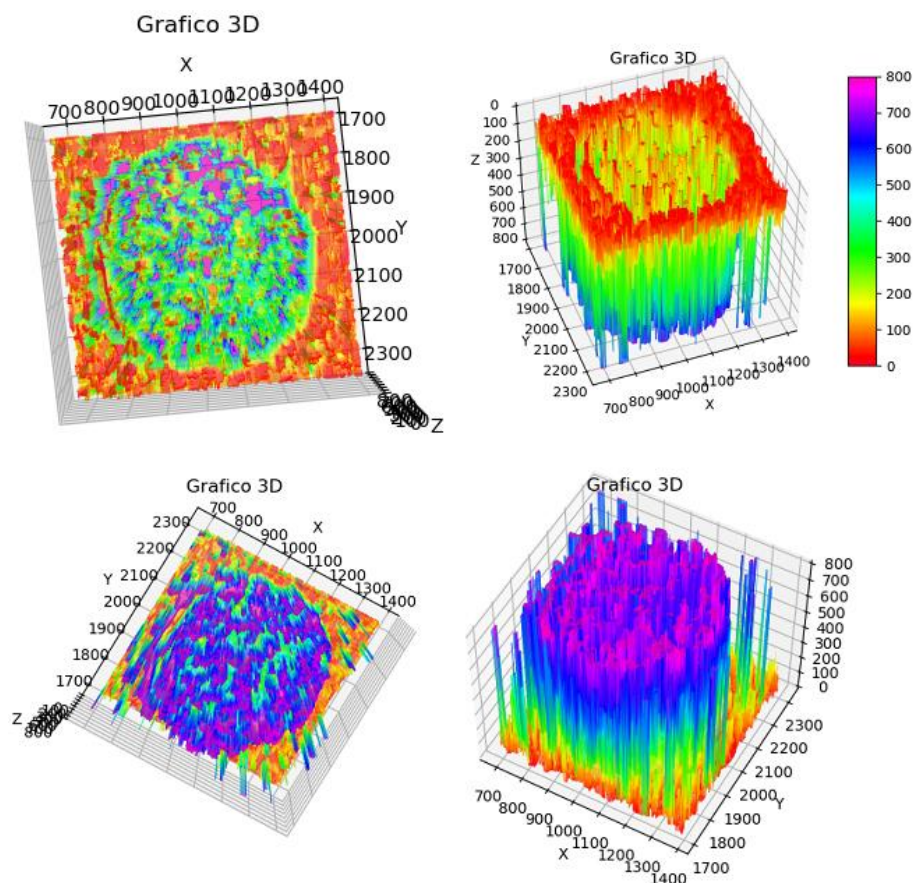


Figura 4.19 - Gráficos de diferentes ângulos de um pite de uma imagem de um cupom de superfície plana.

Os ruídos das falhas do algoritmo são notados com maior nitidez ao observar o gráfico.

O gráfico é gerado por uma biblioteca Python chamada Matplotlib.

4.4.5 – Profundidade do Pixel

Esta funcionalidade permite ao operador saber a profundidade de um pixel sem gerar o gráfico tridimensional, ou seja, apenas com a imagem mapeada, exibida pela escala de cores. Para isso basta acessar o menu “Imagem em Foco” e a opção “Profundidade do Pixel”, a qual fica disponível após o mapeamento. Com a função ativada, basta deslizar o mouse sobre a imagem e a profundidade de cada pixel será exibida em um *tooltip* sobre a imagem. Caso a imagem tenha sido nivelada, será informada a profundidade após e antes do nivelamento. Um exemplo é exibido na Figura 4.20.




Figura 4.20 - Exibição da profundidade de um pixel após o nivelamento.

4.4.6 – Distância entre Dois Pontos

Este procedimento permite calcular três distâncias diferentes entre dois pontos da imagem. Essa função fica disponível após o mapeamento. Para utilizá-la o operador deve acessar o menu “Imagem em Foco” e selecionar a opção “Distância entre Dois Pontos”. O programa pedirá que o usuário selecione os pontos na imagem e em seguida o resultado é exibido, como mostra a Figura 4.21. Este recurso pode ser utilizado tanto na imagem mapeada quanto na nivelada.

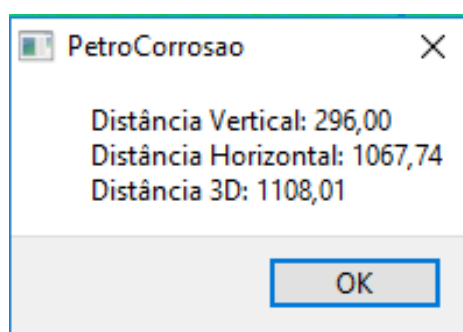


Figura 4.21 - Exibição dos cálculos das distâncias entre dois pontos.

4.5 – Comparação entre a Qualificação do Foco pelo Olho Humano e pelos Estimadores

Os estimadores utilizados para determinar a qualidade do foco de um pixel da imagem usam pequenas regiões ao redor do mesmo. Essas regiões podem ser tão pequenas quanto 5x5 ou tão grandes quanto 23x23. O contraste entre os pixels desta região indica a qualidade do foco. Comparando-se o contraste entre os pixels da mesma região em todas as imagens da pilha, pode-se apontar que aquela fotografia em que o contraste for maior será a que possui o melhor foco. Cabe ao estimador representar matematicamente o contraste.

O olho humano também qualifica o foco pelo contraste, mas de uma maneira diferente. Inicialmente, o operador humano examina a qualidade do foco em uma região ampla em torno do ponto em questão. Usando esse procedimento, ele seleci-

ona as imagens com maior contraste. Em seguida, usa esse conjunto de imagens para avaliar a qualidade do foco em uma região menor em torno do mesmo ponto para reduzir o número de imagens. O procedimento segue, até que se chega a uma imagem ou a um grupo cuja qualidade pareça similar ao olho humano.

O problema de se considerar regiões grandes para avaliar o contraste é que não há garantia de que o amplo entorno do ponto represente o ponto. O problema de se considerar regiões pequenas é que a pequena amostragem a ser analisada fica muito vulnerável ao efeito da variação estatística dos valores dos pixels.

Um teste foi feito para investigar a capacidade que tem o olho humano de diferenciar contrastes em regiões pequenas. Um ponto foi escolhido na imagem da superfície, como mostra a Figura 4.23, no centro do círculo vermelho. Em seguida, uma região de dimensão 23x23 foi selecionada em torno do pixel central em cada imagem da pilha, totalizando 101 imagens, como mostra a Figura 4.22.

Um operador humano agora tentou qualificar o foco apenas com base no exame visual dessas pequenas imagens. Verificou-se que não foi possível ao olho humano qualificar satisfatoriamente o foco dessa maneira. Usando o método convencional, o olho humano apontou as imagens que correspondem aos quadros G3, B8, C6, G1, A2, E6, E4 e A13 com foco de boa qualidade e a imagem correspondente à A2 como o melhor foco de todos. Essa imagem corresponde àquela exibida pela Figura 4.23.

Enquanto o olho humano não é capaz de qualificar o foco examinando regiões pequenas, o estimador usado conseguiu fazer isso, de tal modo que concordou com o resultado humano em 75% das vezes.




Figura 4.22 - Esquema de 101 imagens de 23x23.



Figura 4.23 - Imagem com destaque de um ponto.

CAPÍTULO 5

CONCLUSÃO

Neste trabalho, uma nova versão do sistema da Máquina Busca-Pite, baseada na técnica de variação de foco, foi apresentada. O programa manteve todos os recursos existentes na versão anterior, acrescentando as novas funcionalidades. O foco do trabalho se concentra em construir uma imagem em foco a partir de um conjunto de imagens capturadas a diferentes distâncias.

Para encontrar o melhor algoritmo de reconhecimento de foco, foi necessário testar uma série de estimadores de foco baseados em contraste. Para isso foi preciso desenvolver dois programas auxiliares, sendo eles o Análise de Foco e o Observar Pixel. Testes foram também realizados com uma rede neural. O melhor resultado foi obtido por um estimador que conseguiu uma taxa de acertos de 75% em comparação ao resultado obtido por um observador humano, usado como referência.

A partir da variação do foco, é possível produzir uma imagem composta que é resultante da composição de cada pixel em foco de toda a pilha de imagens. Essa imagem aparenta estar totalmente em foco, quando observada em baixa ampliação. É também possível mapear o relevo da superfície e representar esse relevo graficamente através de uma imagem em cores que seguem uma escala de profundidade. Nessa imagem, pode-se medir distâncias verticais e horizontais entre pontos e medir profundidades. Se há alguma inclinação plana da superfície da amostra, é possível proceder um nivelamento. Por fim, é possível construir um gráfico 3D para mostrar o relevo de uma parcela selecionada da superfície pelo operador. Esse gráfico pode ser rotacionado a fim de exibir o melhor ângulo de observação.

O resultado dos testes feitos com cupons que exibiam corrosão por pites mostrou que o algoritmo de variação de foco é capaz de identificar pites, determinar sua extensão de área e profundidade, porém a quantidade de erros encontrados ainda impossibilita seu uso para caracterização. A taxa de erros deve ser reduzida.

Os testes de desempenho do algoritmo foram comparados à avaliação realizada a olho nu. O que mostrou que a forma como o olho humano avalia o foco é diferente do modo como o algoritmo trabalha. O olho humano avalia o contraste entre pixels de grandes regiões ao redor do ponto para determinar o foco e vai gradualmente reduzindo o tamanho da região, enquanto o algoritmo utiliza diretamente o

contraste dos pixels de uma região tão pequena que o olho humano não consegue diferenciar o contraste.

CAPÍTULO 6

TRABALHOS FUTUROS

A máquina Busca-Pites com tecnologia de variação de foco precisa ser ainda muito aperfeiçoada em vários aspectos. Um deles diz respeito à automação. A máquina deve registrar partes de uma grande área da superfície previamente selecionada pelo operador e em seguida montar o mosaico para formar uma só grande imagem dessa região.

A máquina deve ainda conter toda a rotina de caracterização da corrosão por pites através dos parâmetros densidade, área de pite e taxa de corrosão por pite determinada pela profundidade dos pites. Essa rotina não foi implementada na versão atual devido ao desempenho insatisfatório da detecção de foco.

É a detecção de foco a principal melhoria que deve ser efetuada. É necessário diminuir a taxa de erros. Para isso, novas estratégias de detecção de foco devem ser testadas. Essas estratégias devem ter o baixo esforço computacional como compromisso. Uma estratégia possível é aquela adotada pelo olho humano, ou seja, a redução sucessiva do número de imagens comparadas à medida que se reduz a área observada em torno de um ponto.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABNT. (1987). NBR 9771. *Exame e avaliação da corrosão por pite*.
- Aguet, F., Van De Ville, D., & Unser, M. (2007). Model-based 2.5-D deconvolution for extended depth-of-field in brightfield microscopy. *IEEE Transactions Image Processing*, vol. 17, No7, 1144-1153.
- Alberts, B., Johnson, A., Lewis, J., Morgan, D., Raff, M., Roberts, K., et al. (2017). *Biologia Molecular da Célula* (6ª ed.). Porto Alegre: Artmed.
- Albuquerque, M. P., Esquef, I., & Mello, A. G. (2004). Image thresholding using Tsallis entropy. *Pattern Recognition Letters*, 25(9), 1059-1065.
- Alves, G. M. (2006). *Método Fundamentado em Processamento Digital de Imagens para Contagem Automática de Unidades Formadoras de Colônias*. Dissertação (Mestrado em Ciência da Computação) - São Paulo - SP, Universidade Federal de São Carlos - UFSCar, 105 p.
- Arruda, E. A. (2009). *Estudo Comparativo do Processo Corrosivo do Aço Patinável e do Aço Carbono Comum*. Monografia (Engenharia Mecânica) - Belém - PA, Universidade Federal do Pará - UFPA, 80p.
- Assirati, L. (2014). *Entropia Aplicada ao Reconhecimento de Parões em Imagens*. Dissertação (Mestrado. Programa de Pós-Graduação em Física Aplicada Computacional) - Instituto de Física de São Carlos, Universidade de São Paulo.
- ASTM. (1994). G46-94. *Standard Guide for Examination and Evaluation of Pitting Corrosion*.
- Aydin, T., & Akgul, Y. S. (2008). A new adaptative focus measure for shape from focus. *British Machine Conference* (pp. 8.1-8.10). Leeds: BMVA Press.
- Azevedo, E., & Conci, A. (2003). *Computação gráfica: teoria e prática*. Rio de Janeiro: Campus.
- B.Cook, R., Shearwood-Porter, N. R., Latham, J. M., & Wood, R. J. (2015). Volumetric assessment of material loss from retrieved cemented metal hip replacement stems. *Tribology International*.
- Biomedical Imaging Group. (02 de 04 de 2018). *Extended Depth of Field*. Fonte: Biomedical Imaging Group of EPFL: <http://bigwww.epfl.ch/demo/edf/>
- Blanchette, J. S. (2008). *C++ Gui Programming with Qt 4*. (2 ed.). Massachusetts: Prentice Hall.

- Boeira, A. M., Kuster, F., Wegener, K., Knoblauch, R., Margot, R., & Schroeter, R. B. (2009). Descrição da Geometria de Brocas Helicoidais a partir de Modelos Matemáticos Combinados a Métodos de Medição Tridimensional. V Congresso Brasileiro de Engenharia de Fabricação.
- Bradburn, S., Cathey, W. T., & Dowski, E. R. (1997). Realizations of Focus Invariance in Optical/Digital Systems with Wavefront Coding. *Applied optics*, 36(35), 9157-9166.
- Chen, Y., & Ju, L.-K. (2015). Method for Fast Quantification of Pitting Using 3D Surface Parameters Generated with Infinite Focus Microscope. *Corrosion*, 71(10), 1184-1196.
- Chen, Y., Torres, J., Castaneda, H., & Ju, L.-K. (2016). Quantitative comparison of anaerobic pitting patterns and damage risks by chloride versus *Desulfovibrio vulgaris* using a fast pitting-characterization method. *International Biodeterioration & Biodegradation*, 109, 119-131.
- Colares, R. P. (2009). *Estudo da inibição da corrosão do zinco por íons iorgânicos ecologicamente amigáveis: molibdato, tungstato, silicato e fosfato*. Tese (Doutorado em Química). Fortaleza - Ceará. Universidade Federal do Ceará.
- Costa, E. A. (2008). *Avaliação da Resistência a Corrosão da Liga Ni-W Obtida por Eletrodeposição*. Dissertação (Mestre em Engenharia Química). Campina Grande, SP. Universidade Federal de Campina Grande, UFCG, 69p.
- Danzl, R., Helmlí, F., & Scherer, S. (2009). Focus variation—a new technology for high resolution optical 3D surface metrology. *Proceedings of the 10th international conference of the Slovenian society for non-destructive testing*.
- Danzl, R., Helmlí, F., & Scherer, S. (2011). Focus Variation – a Robust Technology for High Resolution Optical 3D Surface Metrology. *Strojniški vestnik-Journal of mechanical engineering*, 57(3), 245-256.
- Dedavid, B. A., Gomes, C. I., & Machado, G. (2007). *Microscopia eletrônica de varredura : aplicações e preparação de amostras : materiais poliméricos, metálicos e semicondutores*. Porto Alegre: EDIPUCRS.
- Default007. (2018). *Convolution illustrated*. Acesso em 31 de Março de 2018, disponível em Wikimedia Commons: https://commons.wikimedia.org/wiki/File%3AConvolution_Illustrated_eng.png
- Dexter, S. (1987). Localized corrosion. *Corrosion*(13), 104.
- Elsevier B.V. (2018). *Scopus*. Acesso em 10 de Junho de 2018, disponível em <https://www.scopus.com/home.uri>

- Fazano, C. A. (Outubro/Novembro de 2005). A Aplicação da Análise de Imagem na Quantificação das Características Microestruturais de Materiais. *Revista Analytica*(19), 46-60.
- Felipe, M. B., Maciel, M. A., Medeiros, S. R., & Silva, D. R. (2013). Aspectos gerais sobre corrosão e inibidores vegetais. *Revista Virtual de Química*, 5(4), pp.746-759.
- Fernandes, J. C. (2010). *Desenvolvimento de um Dispositivo Tipo Carga Constante para Avaliação da Susceptibilidade à Corrosão Sob Tensão de Aço Inoxidável Austenítico*. Dissertação (Mestrado em Materiais para Engenharia) - Itajubá - MG, Universidade Federal de Itajubá - UNIFEI, 94 p.
- Ferraro, P., Grilli, S., Alfieri, D., Nicola, S. D., Finizio, A., Pierattini, G., et al. (2005). Extended focused image in microscopy by digital holography. *Optics express*, 13(18), 6738-6749.
- Ferreira, L. A., Costacurta, R. F., Alberti, S. M., & Zdebsky, S. R. (2002). *Curso de Formação de Operadores de Refinaria - Química Aplicada - Corrosão*. Curitiba: UnicemP.
- Finocchio, M. A. (Julho de 2014). Noções de Redes Neurais Artificiais. Paraná, Brasil: Laboratório de Segurança Iluminação e Eficiência Energética. UTFPR.
- Fraser, S. E. (2003). Crystal gazing in optical microscopy. *Nature biotechnology*, 21(11), 1272-1273.
- Frauches-Santos, C., Albuquerque, M. A., Oliveira, M. C., & Echevarria, A. (2014). A Corrosão e os Agentes Anticorrosivos. *Revista Virtual de Química*, 6(2), pp.293-309.
- Galvele, J. R., Frankenthal, R. P., & Kruger, J. (1978). Passivity of metals. *The electrochemical Society*.
- Gartner, L. P., & Hiatt, J. L. (2007). *Tratado de histologia em cores* (Tradução da 3ª edição ed.). Rio de Janeiro: Elsevier.
- Gentil, V. (1996). *Corrosão*. (3 ed.). Rio de Janeiro: LTC.
- Gomes, J., & Velho, L. (2003). *Fundamentos da Computação Gráfica*. (Vol. S.I.). Rio de Janeiro: IMPA.
- Gonçalves, J. (s.d.). *Hiperbytes*. Acesso em 20 de outubro de 2012, disponível em <http://www.hiperbytes.com.br/artigos/introducao-a-computacao-grafica/>
- Gonzalez, R., & Woods, R. (2002). *Digital Image Processing*. (2 ed.). Upper Saddle River, New Jersey: Prentice Hall.

- Groen, F. C., Young, I. T., & Lighthart, G. (1985). A comparison of different focus functions for use in autofocus algorithms. *Cytometry*, 6(2), 81-91.
- Häusler, G. (1972). A method to increase the depth of focus by two step image processing. *Optics Communications*, 6(1), 38-42.
- Haykin, S. (2001). *Redes Neurais-Princípios e Prática*. (2 ed.). Porto Alegre: Bookman.
- Haykin, S. (2007). *Redes Neurais: princípios e prática*. Bookman.
- Huang, C., Townshend, J. R., Liang, S., Kalluri, S. N., & DeFries, R. S. (2002). Impact of sensor's point spread function on land cover characterization. *Remote Sensing of Environment*, 80(2), 203-212.
- Jansson, P. A. (2014). *Deconvolution of Images and Spectra*. New York: Courier Corporation.
- Keller, H. E. (2006). *Handbook of Biological Confocal Microscopy* (3^a ed.). New York: James B. Pawley, Springer Science+Business Media, LLC.
- Manhães, D. C. (2015). *Desenvolvimento e Montagem de Micro SCANNER 3D de Superfície para Caracterização de Pites de Corrosão*. Dissertação (Mestrado em Engenharia e Ciência dos Materiais). Campos dos Goytacazes - RJ. Universidade Estadual do Norte Fluminense - Darcy Ribeiro - UENF, LAMV.
- Mannheimer, W. A. (2002). *Microscopia dos Materiais: Uma Introdução*. Rio de Janeiro: E-papers Serviços Editoriais.
- Manssour, I. H., & Cohen, M. (2006). Introdução à Computação Gráfica. *Rita, Volume XIII, Número 2*.
- Marques Filho, O., & Vieira Neto, H. (1999). *Processamento Digital de Imagens*. Rio de Janeiro: Brasport.
- Marques, P. M. (1994). *Avaliação ponto a ponto de sistemas de imagem radiológica utilizando funções de espalhamento de ponto simuladas*. Tese (Doutorado em Física Aplicada/Computacional). São Carlos - SP. Universidade de São Paulo, Instituto de Física de São Carlos.
- Matias, I. O. (2007). *O Uso do Algoritmo Genético em Segmentação de Imagens Digitais*. Tese (Doutorado em Engenharia Civil) - Rio de Janeiro - RJ, Universidade Federal do Rio de Janeiro - UFRJ, 89p.
- Merçon, F., Guimarães, P. I., & Mainier, F. B. (2004). Corrosão: Um Exemplo Usual de Fenômeno Químico. *Química Nova na Escola*(19).
- Merz, L. (1965). *Transformation in Optics*. New York: Wiley.

- Mir, H., Xu, P., & van Beek, P. (2014). An extensive empirical evaluation of focus measures for digital photography. *IS&T/SPIE Electronic Imaging*, 90230I-90230I.
- NACE. (2005). NACE Standard RP0775. *Preparation, Installation, Analysis, and Interpretation of Corrosion Coupons in Oilfield Operations*.
- Neta, S. R., Dutra, L. V., & Erthal, G. J. (2008). Limiarização automática em histogramas multimodais. *Proceedings of the 7th Brazilian Conference on Dynamics, Control and Applications, FCT– Unesp de Presidente Prudente*.
- Nguyen, C.-N., Ohara, K., EbubekirAvci, Takubo, T., Mae, Y., & Arai, T. (2012). Real-time precise 3D measurement of micro transparent objects using All-In-Focus imaging system. *Journal of Micro-Nano Mechatronics*, 7(1-3), 21-31.
- Nogueira, I. L. (2013). *Desenvolvimento de Software para Identificação e Caracterização de Pites de Corrosão em Cupons*. Dissertação (Mestrado em Engenharia e Ciência dos Materiais). Campos dos Goytacazes - RJ. Universidade Estadual do Norte Fluminense - Darcy Ribeiro - UENF, LAMAV.
- Ohba, K., Ortega, J. C., Tanie, K., Tsuji, M., & Yamada, S. (2003). Microscopic vision system with all-in-focus and depth images. *Machine Vision and Applications*, 15(2), 55-62.
- Oliveira, W. M. (2012). *Sistema de Apoio ao Diagnóstico na Detecção de Microcalcificações em Mamografias Digitais*. Dissertação (Mestrado em Pesquisa Operacional e Inteligência Computacional). Campos dos Goytacazes - Rio de Janeiro. Universidade Candido Mendes.
- Olympus. (2018). *Distância de trabalho (W.D.)*. Acesso em 3 de Maio de 2018, disponível em Olympus Scientific Solutions: https://www.olympus-ims.com/pt/microscope/terms/working_distance/
- Olympus. (2018). *Soluções em microscopia DSX 110*. Acesso em 06 de 05 de 2018, disponível em Olympus: <https://www.olympus-ims.com/pt/microscope/dsx510/#!>
- OpenCV. (2012). Acesso em 23 de setembro de 2012, disponível em <http://opencv.willowgarage.com/wiki/>
- Ortega, J., Ohba, K., Tanie, K., Rin, G., Dangi, R., Takei, Y., et al. (2000). Real-time VR camera system. *In: Proc. 4th Asian conf comput vis., 9*, 503–513.
- Palaeo-electronica. (01 de 04 de 2018). *List of available software with image stacking and/or focus stacking capabilities*. Fonte: Palaeo-electronica.org: http://palaeo-electronica.org/2009_2/170/table1.htm
- Pannoni, F. D. (2007). *Fundamentos da corrosão. Proteção Estrutural Aço Minas AS*. Acesso em 13 de 01 de 2015, disponível em

http://colegiometeta.yolasite.com/resources/Fundamentos_da_corros%C3%A3o.pdf

- Passaglia, E. (1979). *The Economic Effects of Corrosion Research, Corrosion* (Vol. 35).
- Pereira, E. C., Silva, A. G., Silva, G. B., Nogueira, I. L., & Manhães, D. (2016). Caracterização da Corrosão Puntiforme em Cupons de Perda de Massa por Microscopia Ótica, Confocal e a Nova Tecnologia BUSCA-PITE. 22º CBECiMat - Congresso Brasileiro de Engenharia e Ciência dos Materiais.
- Pereira, M. C. (2010). *Estudo morfológico e cinético da corrosão por pites em liga de alumínio 1050*. : Tese (Doutorado em Engenharia Mecânica). Guaratinguetá - SP. Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá.
- Picon, C. A. (3 de 2010). Estudo do mecanismo de corrosão por pites em água do mar de aços inoxidáveis supermartensíticos microligados com Nb e Ti. *Revista Escola de Minas*, 63(1), 65-69.
- Pieper, R. J., & Korpel, A. (1983). Image processing for extended depth of field. *Applied Optics*, 22(10), 1449-1453.
- ProQuest LLC. (2018). Acesso em 15 de Junho de 2018, disponível em Materials Science & Engineering Database: <https://search.proquest.com/materialscienceengineering/>
- Queiroz, J. E., & Gomes, H. M. (2001). Introdução ao Processamento Digital de Imagens. *Rita, Volume VIII, Número 1*.
- Quiumento, F. (14 de Dezembro de 2011). *knowledgeispowerquiumento*. Acesso em 13 de Julho de 2013, disponível em <http://knowledgeispowerquiumento.wordpress.com/article/corrosao-por-pites-2tlel7k7dcy4s-94/>
- Ren, Y.-F., Amin, A., & Malmstrom, H. (2009). Effects of tooth whitening and orange juice on surface properties of dental enamel. *Journal of dentistry*, 37(6), 424-431.
- Revista Química e Derivados. (31 de Julho de 1996). Corrosão: Novas Soluções para o Problema. *Revista Química e Derivados*(340).
- Riella, H. G. (2009). *Apostila de corrosão*. Florianópolis: Universidade Federal de Santa Catarina, Laboratório de Materiais e Corrosão-LABMAC.
- Rodrigues, C. J., Maciel, M. A., & Lima, K. M. (2013). Sorbitans as Corrosion Inhibitors. *Revista Virtual de Química*, 5(5), 912-920.

- Santos, E. T., Zuffo, M. K., Netto, M. L., & de Deus Lopes, R. (2001). Computação Gráfica: Estado da arte ea pesquisa na USP. *Simpósio Nacional de Geometria Descritiva e Desenho Técnico*, 15, 3.
- Schroettner, H., Schmied, M., & Scherer, S. (2006). Comparison of 3D surface reconstruction data from certified depth standards obtained by SEM and an infinite focus measurement machine (IFM). *Microchimica Acta*, 155(1-2), 279-284.
- Sheir, L. L., Jarman, R. A., & Burstein, G. T. (2000). *Corrosion Control* (3ª ed.). Oxford: Butterworth-Heinemann.
- Silva, G. B. (2016). *Caracterização de cupons de corrosão através de diferentes técnicas comparativas*. Dissertação (Mestrado em Engenharia e Ciência dos Materiais) - Universidade Estadual do Norte Fluminense Darcy Ribeiro. Centro de Ciência e Tecnologia. Laboratório de Materiais Avançados. Campos dos Goytacazes.
- Simor, E., & Novais, A. P. (2002). Gerenciamento da Taxa de Corrosão por Cupons por Perda de Massa. 6º COTEQ - *Conferência sobre Tecnologia de Equipamentos*. Salvador: 22º CONBRASCORR – Congresso Brasileiro de Corrosão.
- Solomon, S., & Breckon, T. (2013). *Fundamentos de processamento digital de imagens*. Rio de Janeiro: LTC.
- Spitaler, M. (2018). *Microscopic Image Restoration by Deconvolution*. Acesso em 29 de Março de 2018, disponível em Imperial College London: <http://www.imperial.ac.uk/media/imperial-college/medicine/facilities/film/Deconvolution-training-140219.pdf>
- Terzi, R., & Mainier, F. B. (2008). Monitoramento da Corrosão Interna em Plataformas Offshore. *Tecno-Lógica*, 12(1), 14-21.
- Tsai, D.-C., & Chen, H. H. (2012). Reciprocal Focus Profile. *Image Processing, IEEE Transactions on*, 21(2), 459-468.
- Umorin, M. (02 de 03 de 2018). *Stack Focuser*. Fonte: imagej.nih.gov: <https://imagej.nih.gov/ij/plugins/stack-focuser.html>
- Velasco, M. M. (2007). *Redes Neurais Artificiais*. Rio de Janeiro, Rio de Janeiro, Brasil: Laboratório de Inteligência Computacional Aplicada. PUC-RJ.
- Vindin. (2018). *Point Spread Function*. Acesso em 31 de 3 de 2018, disponível em Wikimidea Commons: https://upload.wikimedia.org/wikipedia/commons/4/43/63x_1.4NA_Confocal_Point_Spread_Function_2%2B3D.png

Winkler, T., Hoenig, E., Gildenhaar, R., Berger, G., Fritsch, D., Janssen, R., et al. (2010). Volumetric analysis of osteoclastic bioresorption of calcium phosphate ceramics with different solubilities. *Acta biomaterialia*, 6(10), 4127-4135.

ZEISS. (2018). *The Point Spread Function*. Acesso em 5 de Maio de 2018, disponível em ZEISS: <https://www.zeiss.com/microscopy/int/solutions/reference/basic-microscopy/the-point-spread-function.html>